

基于候选共识和多分辨率迭代的异尺度点云配准算法

赵夫群^{1,2}, 崔泽豪^{1,2}, 周明全³

(1. 西安财经大学信息学院, 陕西 西安 710100; 2. 智财协同可信计算陕西省高等学校重点实验室, 陕西 西安 710100; 3. 西北大学计算机学院 (软件学院), 陕西 西安 710127)

摘要: 针对异尺度点云配准中同时存在整体缩放、点数不一致、采样密度差异、分辨率变化、噪声和不完全重叠的问题, 提出一种基于候选共识和多分辨率迭代的异尺度点云配准算法。首先, 对源点云和目标点云进行点数约束的体素化预处理, 以减弱密度不均对特征提取和最近邻搜索的影响; 然后, 基于点对方向、法向和局部角度关系构造尺度保持的紧凑特征描述子, 并通过软双向匹配得到候选对应; 在粗配准阶段, 采用对数尺度投票、多几何共识旋转候选和三维网格投票的平移估计生成相似变换候选; 最后, 利用双向裁剪误差和覆盖率评分筛选初值, 并通过尺度锚定的鲁棒多分辨率精配准进一步优化。实验在 Stanford 点云数据、ScanNet 室内场景点云数据和 MVP 部分可见的点云数据上进行, 其结果表明了该方法在几何尺度和采样尺度均变化的条件下具有较好的配准精度和鲁棒性。

关键词: 异尺度点云配准; 候选共识; 尺度投票; 采样密度差异; 相似变换; 多分辨率迭代

中图分类号: TP391

文献标志码: A

doi: 10.11959/j.issn.1000

Cross-Scale Point Cloud Registration Algorithm Based on Candidate Consensus and Multi-Resolution Iteration

Zhao Fuqun^{1,2}, Cui Zehao^{1,2}, Zhou Mingquan³

1. School of Information, Xi'an University of Finance and Economics, Xi'an 710100, China

2. Shaanxi Province Key Laboratory of Intelligent Finance Collaboration and Trusted Computing, Xi'an 710100, China

3. School of Computer (School of Software), Northwest University, Xi'an 710127, China

Abstract: To address the challenges of global scaling, inconsistent point counts, sampling-density differences, resolution changes, noise, and partial overlap in cross-scale point cloud registration, a cross-scale point cloud registration algorithm based on candidate consensus and multi-resolution iteration was proposed. First, voxelization preprocessing with point-count constraints was performed on the source and target point clouds to reduce the influence of density nonuniformity on feature extraction and nearest-neighbor search. Then, a scale-preserving compact feature descriptor was constructed based on point-pair directions, normals, and local angular relationships, and candidate correspondences were obtained through soft bidirectional matching. In the coarse registration stage, similarity transformation candidates were generated through logarithmic-scale voting, multi-geometric-consensus rotation candidate estimation, and translation estimation based on three-dimensional grid voting. Finally, the initial transformation was selected using bidirectional trimmed error and coverage-rate scoring, and it was further optimized through scale-anchored robust multi-resolution fine registration.

收稿日期: 2026-07-03; 修回日期: XXXX-XX-XX

通信作者: 赵夫群, fuqunzhao@126.com

基金项目: 国家自然科学基金资助项目 (No.62271393); 陕西省教育厅科学研究计划资助项目 (No.25JS049); 西安财经大学研究生创新基金资助项目 (No.25YC034)

Foundation Items: The National Natural Science Foundation of China (No.62271393), Shaanxi Provincial Department of Education Scientific Research Program (No.25JS049), Xi'an University of Finance and Economics Graduate Student Innovation Fund (No.25YC034)

Experiments were conducted on Stanford point cloud data, ScanNet indoor scene point cloud data, and MVP partially visible point cloud data, and good registration accuracy and robustness were observed under variations in both geometric scale and sampling scale. The proposed method demonstrates strong adaptability to cross-scale point cloud registration with complex scale and sampling variations.

Key words: cross-scale point cloud registration, candidate consensus, scale voting, sampling density variation, similarity transformation, multi-resolution iterative

0 引言

随着激光雷达、结构光传感器和立体相机等三维数据采集设备的成熟与普及,点云数据的获取日益便捷,点云数据处理技术成为计算机视觉和图形学等领域的研究热点^[1-2]。其中,点云配准作为点云数据处理的一项基础而核心的任务,旨在寻找一个刚性变换运动参数,将其作用于源点云使得可以与目标点云对齐,从而将不同站点、不同视角下采集的多片点云拼接为完整三维点云模型。点云配准已成为实景三维建模^[3]、智能驾驶^[4]、数字文物保护^[5]和工业检测^[6]等中的关键技术,具有重要应用价值。

现有点云配准方法大致可分为传统优化方法和基于深度学习的方法两大类。传统方法通常将点云配准过程分为粗配准和精配准两个阶段。粗配准阶段用于估计具备全局收敛性的初始位姿,精配准阶段再基于该初值进行局部迭代优化从而实现高精度对齐。其中,迭代最近点(iterative closest point, ICP)算法^[7]是三维点云配准领域最经典且应用最广的传统方法。然而,该算法对点云的初始位置有较高要求,当初始位姿差异较大或点云重叠度较小时,算法易陷入局部最优。

传统点云配准通常假设源点云和目标点云之间只存在旋转和平移变换,即求解六自由度刚体变换。然而,在实际应用中,由于点云数据采集设备的差异、扫描距离和点云数据的保存方式不同,点云数据之间往往存在放缩尺度不一致的问题。ICP算法假设点云间仅存在旋转和平移变换,无法直接处理存在尺度差异的点云配准问题。虽然研究者已提出Scale-ICP^[8]等改进方法尝试引入尺度因子,但现有处理不同缩放尺度点云配准时仍存在精度和鲁棒性方面的不足。因此,为了实现包含尺度、旋转和平移的七自由度相似变换的高精度估计,有必要进一步探索异尺度点云配准方法。

现有的异尺度点云配准研究将尺度差理解

为物体或场景的整体大小不同或坐标单位不一致,通常先尝试估计尺度因子,再结合ICP完成配准。例如,孙水发等^[9]提出基于几何重心和质心距离比的变尺度配准方法,通过刚性变换中重心与质心相对距离比的尺度不变性逐步细化尺度因子。该方法计算简单,在无噪声和规则采样条件下精度较高,但依赖全局重心、质心及整体分布,易受遮挡、局部缺失和非均匀采样影响;张顺利等^[10]提出基于广义自适应邻域GAN匹配的方法,通过曲率筛选初始匹配点对,结合自适应邻域、Delaunay三角剖分和残差角序列剔除误匹配,证明局部上下文约束对异尺度匹配的重要性,但流程复杂、计算开销较大;王玉文等^[11]基于OBB对应边长估计尺度因子,并利用包围盒顶点关系求取旋转候选,再结合ICP精配准。该方法速度较快,但包围盒方向和边长对离群点、遮挡及局部缺失较敏感。近年来,群智能优化也被用于异尺度配准。范怡萍等^[12]将尺度因子、欧拉角和平移作为人工蜂群算法变量,增强了全局搜索能力,但迭代过程需反复进行点云变换和最近邻搜索,耗时较大;师芸等^[13]进一步融合OBB、主成分分析、ISS关键点和人工蜂群尺度优化,提高了部分场景下的精度,但算法参数较多。此外,蒋悦等^[14]通过高维正交子空间映射估计相似变换,但仍依赖全局协方差和能量分布;Zheng等^[15]提出基于几何最大重叠的鲁棒点云配准框架,降低了算法复杂度,但主要面向固定尺度刚体配准。

在真实点云配准场景中,源点云与目标点云之间的真值变化通常难以直接获得,尤其是在缺少高精度外参标定、同一坐标基准或人工标注的情况下。实际点云中常存在由局部几何相似、描述子区分性不足、采样密度差异引起的错误匹配;由对称或规则物体等重复结构导致的匹配歧义;以及由视角限制、传感器遮挡、扫描盲区和物体自遮挡造成的局部缺失与非重叠区域。因此,异尺度点云配准的关键不仅在于相似变换模型本身的求解,更在于

噪声、遮挡、错误匹配和非均匀采样条件下生成可靠的候选对应与初始相似变换。跨尺度点云配准的研究尚处于早期阶段,现有方法大多都假设点云数据完全重叠。对于源和目标点云存在部分重叠的点云数据,如何处理其存在的程度差异和旋转变换,相关问题尚未得到充分解决^[16]。现有方法主要处理全局几何差异,而没有充分考虑点数、密度、点间距、分辨率和非均匀采样等采样尺度差异。实际扫描中,采样尺度差异会改变局部邻域结构质量和最近邻分布,是导致配准不稳定的重要因素。

基于上述存在的问题,本文提出一种基于候选共识和多分辨率迭代的异尺度点云配准算法,其主要目标在于:第一,在不存在可靠初始位姿的情况下,实现源点云到目标点云的自动相似变换粗配准;第二,在点数、密度和分辨率不一致的情况下,减小高密度区域对特征匹配和几何评分的影响;第三,在存在噪声、离群点和部分重叠时,提高尺度、旋转和平移估计的影响。

该算法以三维相似变换为配准模型,通过体素化均衡点云密度,并构造尺度保持的紧凑特征描述子实现双向软特征匹配。在粗配准阶段,根据匹配点对距离比进行对数尺度投票,结合点对方向、几何框架和非退化三元组生成旋转候选,并通过三维平移投票得到完整变换;接着,采用双向裁剪误差和覆盖率联合评分筛选候选结果,并通过尺度锚定的鲁棒多分辨率精配准过程进行精化,从而实现无初始位姿、异尺度和噪声条件下的稳定配准。其整体流程如图1所示。

本文的主要工作如下:

1) 不再仅将异尺度点云视为整体大小或单位不同,而是区分几何尺度差异和采样尺度差异。几何尺度差异由相似变换中的尺度因子描述,采样尺度由点数、分辨率和非均匀采样模式等描述。在随

机稀疏采样、梯度非均匀采样、径向采样、不同点保留率、噪声和离群点条件下开展实验,以更接近真实跨设备、跨分辨率点云配准场景。

2) 提出点数约束的体素化密度均衡策略与空间覆盖关键点选取机制,构建尺度保持的紧凑特征描述子,使描述子计算和匹配不再过度集中高密度区域,从而改善采样密度不一致造成的匹配偏差。

3) 构建粗到精配准框架。粗配准阶段采用点对距离对数尺度投票、多几何共识候选生成和三维网格平移投票;精配准阶段提出尺度锚定的鲁棒多分辨率配准算法,提高点云在噪声、离群点和部分重叠条件下的配准精度。

1 相关工作

1.1 基于对应点的闭式相似变换估计

在已知对应关系的条件下,含尺度因子的点云配准可转化为最小二乘意义下的相似变换估计。Arun等^[17]提出基于奇异值分解的三维点集刚体变换估计方法;Horn^[18]基于单位四元数给出绝对取向闭式解,并讨论旋转、平移与尺度关系;Umeyama^[19]进一步给出相似变换参数的最小二乘估计定理。

该类方法理论清晰、计算高效,在对应关系准确时可获得全局最优解,常用于特征匹配后的位姿求解或ICP迭代更新。但其强依赖正确对应,难以处理误匹配、离群点、部分重叠和非均匀噪声,因此通常作为鲁棒配准框架中的子模块使用。

1.2 含尺度估计的迭代最近点类方法

原始ICP默认点云一致,仅估计旋转和平移。为了处理含尺度差异的点云配准问题,许多含尺度估计的ICP类算法被提出^[20-21]。Du等^[22]通过带边界约束的尺度矩阵估计尺度,但算法对初值和最近邻对应敏感;Lin等^[23]通过多邻域旋转图像和主成




图1 异尺度点云配准算法整体流程

分分析将尺度差异转化为曲线配准问题以预估尺度,但不能直接求解完整位姿; Xu等^[24]构造分式目标函数以避免尺度趋零病态; Wu等^[25]基于最大相关熵准则增强抗噪性,但核宽度选择较为敏感; Sahillioğlu等^[26]提出尺度自适应最近点迭代,方法高效但仅支持统一尺度; Lv等^[27]基于形状空间构造尺度不变表示,可减弱密度差异影响,但在严重缺失或对称结构肯可能产生错误对齐。

1.3 基于特征、全局搜索和无显示对应的方法

Mellado等^[28]通过多尺度局部几何描述子实现跨源相对尺度估计; Lim等^[29]将二维尺度空间思想扩展到三维特征提取中,但描述子计算复杂; Bülow等^[30]将三维傅里叶变换、Mellin变换和旋转群傅里叶变换结合同时估计尺度、旋转和平移。该方法具备全局搜索能力,但实现复杂; Sun等^[31]提出快速函数配准方法估计尺度,可以避免显式对应搜索,但依赖函数表示和基函数近似质量。

1.4 鲁棒的相似变换估计方法

Yang等^[32]提出 TEASER/TEASER++, 通过图论框架估计相似变换,并结合投票、最大团和半定松弛/GNC剔除外点,鲁棒性强但依赖候选对应和噪声界限; IRON^[33]通过不变量一致性筛选内点并估计尺度,抗外点能力较强,但流程复杂; Li等^[34]面向七参数配准提出单点RANSAC和尺度退火双权重估计,并借助线向量降低采样复杂度。该方法适合跨源误匹配场景,但依赖线向量构造和前端匹配质量。

1.5 基于深度学习的点云配准方法

近年来,许多深度学习方法也被广泛用于实现点云配准。例如, DCP^[35]、RPM-Net^[36]、PointDSC^[37]和 GeoTransformer^[38]等方法分别从特征学习、软匹配、空间一致性和几何Transformer表达等角度提高了配准鲁棒性。此外, HDRNet^[39]方法对噪声和大旋转角度具有鲁棒性,并且可以有效处理部分重叠和多尺度点云配准的问题,但尺度分布和场景类别存在依赖,在真实跨源、低重叠和密度差异明显的点云上仍可能出现泛化不足。

基于深度学习的方法通常需要训练数据,模型泛化验证和较复杂的学习框架,并且大多数方法默认源点云与目标点云处于相同尺度或主要关注刚体配准问题。然而,对于工程场景中常见的异尺度、非均匀密度和无训练数据条件,仍然需要一种纯几

何且具有可解释性的配准方法。

2 异尺度点云配准算法

2.1 问题定义

设待配准的源点云为 $\mathbf{P} = \{\mathbf{p}_i \in \mathbb{R}^3 | i = 1, 2, \dots, N\}$, 目标点云为 $\mathbf{Q} = \{\mathbf{q}_j \in \mathbb{R}^3 | j = 1, 2, \dots, M\}$, 其中, N 和 M 分别表示源点云与目标点云的点数。

异尺度点云配准问题,即源点云与目标点云之间不仅存在旋转和平移,还可能存在全局缩放、点数差异、密度差异以及分辨率差异,由此可将点云异尺度差异分为以下两类。

首先是点云几何尺度差异,即两片点云之间存在全局相似变换

$$\mathbf{q} = s\mathbf{R}\mathbf{p} + \mathbf{t} \quad (1)$$

式中, s 表示尺度因子; $\mathbf{R} \in \text{SO}(3)$ 表示旋转矩阵; $\mathbf{t} \in \mathbb{R}^3$ 表示平移向量。

其次是点云采样尺度差异,即两片点云虽然描述同一物体或场景,但具有不同点数、不同平均点间距、不同局部密度和不同空间分辨率,可表示为

$$N \neq M, \rho_{\mathbf{P}}(\mathbf{x}) \neq \rho_{\mathbf{Q}}(\mathbf{x}) \quad (2)$$

式中, $\rho_{\mathbf{P}}$ 和 $\rho_{\mathbf{Q}}(\mathbf{x})$ 分别表示源点云和目标点云在空间位置 $\mathbf{x}$ 附近的局部采样密度。

由于实际点云通常存在部分重叠、遮挡和离群点,因此可构建鲁棒优化的异尺度点云配准目标

$$\min_{s, \mathbf{R}, \mathbf{t}, \mathbf{S}_0, \mathbf{g}} \sum_{i \in \mathbf{S}_0} \rho \left(\frac{\|s\mathbf{R}\mathbf{p}_i + \mathbf{t} - \mathbf{q}_{g(i)}\|_2}{D_{\mathbf{Q}}} \right) \quad (3)$$

式中, $\mathbf{S}_0 \subseteq \{1, \dots, N\}$ 表示源点云中位于两片点云重叠区域的点集; ρ 表示鲁棒损失函数, $D_{\mathbf{Q}}$ 为目标点云的稳健直径。

异尺度点云配准不仅要确定空间姿态,还需恢复尺度因子。若尺度估计错误,则会直接影响最近邻对应,从而导致最近点迭代过程收敛到错误局部极值。

2.2 点数约束的体素化预处理

由于异尺度点云不仅可能整体大小不同,还可能具有不同的采样密度,若直接在原始点云上估计法向、计算点云描述子和建立最近邻对应,则高密度点云会在优化中占据过大权重,从而影响配准结果。为此,首先对源点云和目标点云进行点数约束的体素预处理,使两片点云密度均衡。

对点任意点云 $\mathbf{X}$, 定义其分位数包围尺度为

$$D_X = \|\mathcal{Q}_{0.99}(\mathbf{X}) - \mathcal{Q}_{0.01}(\mathbf{X})\|_2 \quad (4)$$

式中, $\mathcal{Q}_{0.99}(\mathbf{X})$ 和 $\mathcal{Q}_{0.01}(\mathbf{X})$ 分别表示点云在三个坐标分量上的 0.99 和 0.01 分位点组成向量。与最大最小包围盒相比, 分位数包围尺度可以减少少量离群点对尺度估计的影响。

设点云的简化目标点数为 N_0 , 定义点云的初始体素尺寸为

$$h^{(0)} = \alpha_h \frac{D_P}{\sqrt{N_0}} \quad (5)$$

式中, α_h 表示经验因子。由于点云主要分布在二维表面上, 经过体素处理得到的点数与体素尺寸近似成反比。因此, 根据第 r 次体素处理得到的点数 $N^{(r)}$ 自适应更新体素尺寸

$$h^{(r+1)} = h^{(r)} \sqrt{\frac{N^{(r)}}{N_0}} \quad (6)$$

对位于同一体素的点取均值, 得到体素代表点

$$\bar{\mathbf{x}}_v = \frac{1}{|\mathbf{V}_v|} \sum_{\mathbf{x}_i \in \mathbf{V}_v} \mathbf{x}_i \quad (7)$$

式中, $\mathbf{V}_v$ 表示第 v 个体素中的点集。将该过程分别作用于源点云和目标点云, 可使两片点云具有相近的点数规模。

2.3 关键点特征描述子计算与特征匹配

1) 法向估计与关键点选取

对于经过体素化预处理的点云中的每个点, 首先搜索其 k 个最近邻点, 通过计算邻居点构成的协方差矩阵并进行特征值分解, 提取最小特征值对应的特征向量作为该点的初始法向量。

针对法向存在的正负号不确定性问题, 通过计算当前点到点云中心向量的点积符号, 对法向方向进行统一调整, 使得法向一致指向点云外侧或内测, 从而有效提高特征描述与匹配的一致性。

为了提高计算效率并保证特征覆盖的均匀性, 通过最远点采样^[40]选择空间分布均匀的关键点集合。

设当前已选关键点集合为

$$\mathbf{x}_{k_m} = \{\mathbf{x}_{k_1}, \mathbf{x}_{k_2}, \dots, \mathbf{x}_{k_m}\} \quad (8)$$

则下一个关键点为

$$k_{m+1} = \arg \max_i \min_{1 \leq r \leq m} \|\mathbf{x}_i - \mathbf{x}_{k_r}\|_2^2 \quad (9)$$

与计算曲率等选取关键点的方法不同, 该策略通过迭代寻找距离已选关键点集合最远的点, 直接保证了关键点在空间上的均匀分布。对于密度不均匀点云, 首先进行体素化预处理再执行最远点采样, 可以有效避免关键点过度集中在高密度区域, 使得在各种密度分布下都能提取到具有代表性的特征点。

2) 尺度保持的紧凑特征描述子计算

在相似变换下, 点云中的点间距离会随尺度成比例变化, 但点间方向、角度和归一化内积保持不变。基于此, 通过点对方向、中心法向和邻域法向之间的角度关系构造相似变换保持的紧凑特征描述符^[41]。

对于关键点 $\mathbf{x}_i$ 及其邻域点 $\mathbf{x}_j$, 首先构建局部坐标系 $(\mathbf{u}_{ij}, \mathbf{v}_{ij}, \mathbf{w}_{ij})$, 并在其中定义三组不变量

$$\alpha_{ij} = \mathbf{v}_{ij}^T \mathbf{n}_j \quad (10)$$

$$\phi_{ij} = \mathbf{u}_{ij}^T \mathbf{d}_{ij} \quad (11)$$

$$\theta_{ij} = \text{atan} 2(\mathbf{w}_{ij}^T \mathbf{n}_j, \mathbf{u}_{ij}^T \mathbf{n}_j) \quad (12)$$

式中, α_{ij} 表示邻域法向在轴 $\mathbf{v}_{ij}$ 上的投影; ϕ_{ij} 表示中心法向与点对方向之间的关系; θ_{ij} 表示邻域法向在局部法向平面内的转角。

将 α 、 ϕ 和 θ 分别划分为 B 个区间, 得到三组归一化直方图

$$H_i^a(b) = \frac{1}{Z_i} \sum_{\mathbf{x}_j \in N_i} w_{ij} \mathbb{I}[\alpha_{ij} \in B_b^a] \quad (13)$$

$$H_i^\phi(b) = \frac{1}{Z_i} \sum_{\mathbf{x}_j \in N_i} w_{ij} \mathbb{I}[\phi_{ij} \in B_b^\phi] \quad (14)$$

$$H_i^\theta(b) = \frac{1}{Z_i} \sum_{\mathbf{x}_j \in N_i} w_{ij} \mathbb{I}[\theta_{ij} \in B_b^\theta] \quad (15)$$

式中, $\mathbb{I}$ 为指示函数; B_b^a 、 B_b^ϕ 和 B_b^θ 表示第 b 个直方图区间; Z_i 和 w_{ij} 分别为归一化因子和邻域权重, 且

$$w_{ij} = \frac{\left(\|\mathbf{x}_j - \mathbf{x}_i\|_2\right)^{-1}}{\sum_{\mathbf{x}_l \in N_i} \left(\|\mathbf{x}_l - \mathbf{x}_i\|_2\right)^{-1}} \quad (16)$$

$$Z_i = \sum_j w_{ij} \quad (17)$$

将直方图进行归一化可得最终点云特征描述子

$$f_i = \frac{\sqrt{[H_i^a, H_i^\phi, H_i^\theta]}}{\left\| \sqrt{[H_i^a, H_i^\phi, H_i^\theta]} \right\|_2} \quad (18)$$

平方根归一化使得高频分箱对欧式距离的支配作用更小。该特征描述子仅由三组角度直方图构成, 维度较低且计算量小。

不难证明, 在点云邻域拓扑保持一致时, 该特征描述子对于平移、旋转和正尺度变化保持不变。同时又由于其具有维度较低且计算量小的特性, 因此是一种尺度保持的紧凑特征描述子。对于采样密度差异导致的邻域拓扑变化, 点数约束的体素化预处理和直方图结合可在一定程度上提高配准的稳定性。

3) 软双向特征匹配

为了改善严格一对一最近邻匹配在平滑区域或重复结构易误删正确对应的问题, 通过软双向一对多匹配方式, 对每个源描述子 f_i^P , 在目标描述子集合中搜索前个 k_m 最近邻, 保留所有候选对应, 并为其分配匹配权重。

对于第 a 个候选对应 (p_a, q_a) , 匹配权重定义为

$$w_a = \exp \left[- \frac{(d_a^f)^2}{2\tau_f^2} \right] \cdot \frac{1}{1 + r_a} \cdot \mu_a \quad (19)$$

式中, d_a^f 为候选描述子间的距离; r_a 为该候选在目标点集中近邻排序; τ_f 为描述子距离带宽, 用于控制距离衰减速度; μ_a 为互近邻系数, 若该对应为双向互近邻, 则取值为 1, 否则取值为 $\mu_0 (0 < \mu_0 < 1)$ 。

经过软双向特征匹配, 最终得到候选对应集合 $C = \{c_a = (p_a, q_a, w_a) | a = 1, 2, \dots, N_C\}$, 其中, N_C 为保留的候选对应的数量。

2.4 相似变换候选估计

1) 候选匹配共同投票的对数尺度估计

候选对应中存在大量误匹配, 无法直接通过单组对应估计尺度。若只用一组点对估计尺度, 结果可能不可靠。因此, 让大量匹配点产生尺度估计, 在尺度空间进行投票。正确匹配产生的尺度会集中在真实尺度附近, 而错误匹配产生的尺度通常比较分散。

通过两组候选对应的点对距离比生成尺度观测。若两组对应均为正确匹配, 则其点对距离比应

近似等于尺度的缩放因子 s 。由此, 定义对数尺度观测

$$s_{ab} = \log \frac{\|q_a - q_b\|_2}{\|p_a - p_b\|_2} \quad (20)$$

式中, s_{ab} 表示一组匹配点对对尺度的投票意见。同时, 为了减小短边受噪声的影响, 仅保留满足

$$\|p_a - p_b\| > \tau_P D_P, \|q_a - q_b\| > \tau_Q D_Q \quad (21)$$

的点对。式中, D_P 和 D_Q 分别表示源、目标点分位数包围尺度; τ_P 和 τ_Q 表示距离阈值比例。

由于尺度观测由两组匹配共同决定, 因此可定义尺度观测投票因子

$$\eta_{ab} = \sqrt{w_a w_b} \quad (22)$$

在对数尺度搜索区间 $[\log s_{\min}, \log s_{\max}]$ 上构建加权直方图。设 L_l 表示第 l 个对数尺度区间, 则第 l 个区间的投票值定义为

$$H_s(l) = \sum_{(a,b)} \eta_{ab} \mathbb{I}[s_{ab} \in L_l] \quad (23)$$

式中, $H_s(l)$ 表示第 l 个尺度区间的累计投票值; $\mathbb{I}$ 为指示函数, 当 s_{ab} 落入区间 L_l 时取 1, 否则取 0。若大量高可信匹配点对支持同一尺度, 则对应的直方图区间会形成明显峰值。

通过对尺度投票直方图 H_s 进行峰值检测, 得到若干对数尺度峰值, 将其进行指数化得到尺度候选

$$\hat{s}_l = e^{u_l}, l = 1, 2, \dots, L_s \quad (24)$$

由此得到尺度候选集合 $S = \{\hat{s}_1, \hat{s}_2, \dots, \hat{s}_{L_s}\}$ 。

为了避免在同一尺度附近保留多个重复候选, 对多尺度候选进行合并。若尺度候选满足

$$\left| \log \frac{\hat{s}_i}{\hat{s}_j} \right| < \delta_s \quad (25)$$

则认为二者在对数尺度空间中过于接近, 仅保留投票支持度较高的候选。其中, δ_s 表示尺度候选合并阈值。

通过上述方式, 算法可以从大量含早匹配中提取少量具有代表性的尺度假设, 为旋转估计和平移投票提供可靠尺度基础。

2) 多几何共识的旋转估计

在完成尺度候选估计的基础上, 还需确定源点云到目标点云间的旋转变换。从点云自身的几何结

构和候选匹配自动生成旋转候选。将构造的旋转候选集合记为

$$\mathbf{S}_R = \mathbf{S}_{R_1} \cup \mathbf{S}_{R_2} \cup \mathbf{S}_{R_3} \cup \mathbf{S}_{R_4} \quad (26)$$

式中, $\mathbf{S}_{R_1}$ 、 $\mathbf{S}_{R_2}$ 、 $\mathbf{S}_{R_3}$ 和 $\mathbf{S}_{R_4}$ 分别表示由主成分分析主轴映射、点对方向一致性、点对几何框架和非退化三元组估计得到的旋转候选。多来源候选的目的在于提高旋转覆盖能力, 使算法可以适应大角度旋转、遮挡和局部重复结构。

□ 主成分分析主轴映射候选

对源点云和目标点云进行主成分分析, 得到主轴框架 $\mathbf{F}_P$ 和 $\mathbf{F}_Q$ 。由于主成分分析存在符号翻转和轴顺序不确定性, 因此引入带符号置换矩阵 $\mathbf{M}$ 对主轴映射进行扩展, 最终主成分分析旋转候选可表示为

$$\mathbf{R}_1 = \mathbf{F}_Q \mathbf{M} \mathbf{F}_P^T \quad (27)$$

通过枚举满足条件的 $\mathbf{M}$, 可得到一组主轴对齐候选。

该类候选主要提供全局方向参考, 但由于主成分分析容易受到遮挡、非均匀采样和物体对称性的影响, 因此不单独作为最终旋转结果, 而是与其他候选共同参与筛选。

□ 点对方向一致性候选

对于尺度候选 $\hat{s}$, 选取满足

$$|s_{ab} - \log \hat{s}| < \tau_s \quad (28)$$

的候选对应点对。该步骤可以提前剔除与当前尺度明显不一致的错误点对。

对于每个点对, 定义归一化源方向和目标方向

$$\mathbf{a}_{ab} = \frac{\mathbf{p}_b - \mathbf{p}_a}{\|\mathbf{p}_b - \mathbf{p}_a\|_2}, \mathbf{b}_{ab} = \frac{\mathbf{q}_b - \mathbf{q}_a}{\|\mathbf{q}_b - \mathbf{q}_a\|_2} \quad (29)$$

式中, $\mathbf{a}_{ab}$ 和 $\mathbf{b}_{ab}$ 均为单位方向向量。由于两点相减消除了平移影响, 单位化又消除了尺度影响, 因此正确匹配满足

$$\mathbf{b}_{ab} \approx \mathbf{R} \mathbf{a}_{ab} \quad (30)$$

由此可将多组方向对应关系转化为 Wahba 问题

$$\mathbf{R}^* = \arg \max_{\mathbf{R} \in \text{SO}(3)} \sum_{(a,b)} \eta_{ab} \mathbf{b}_{ab}^T \mathbf{R} \mathbf{a}_{ab} \quad (31)$$

并通过标准奇异值分解进行求解得到 $\mathbf{R}$, 将其记为 $\mathbf{R}_4$ 。在实际算法中, 从高置信点对中多次抽样并求其解式, 保留若干得分较高的旋转候选 $\mathbf{S}_{R_2}$ 。

□ 点对几何框架候选

点对方向只提供一维方向约束, 仍可能存在绕该轴方向旋转的不确定性。为了增强旋转候选的约束性, 进一步通过点对方向和法向构造点对几何框架。

对于源点对 $(\mathbf{p}_a, \mathbf{p}_b)$, 以点对方向作为第一个轴, 并结合点 $\mathbf{p}_a$ 或 $\mathbf{p}_b$ 的法向可构造正交坐标局部框架 $\mathbf{F}_{ab}^P = [\mathbf{e}_1^P, \mathbf{e}_2^P, \mathbf{e}_3^P]$ 。同理, 对目标点对 $(\mathbf{q}_a, \mathbf{q}_b)$ 构造对应框架 $\mathbf{F}_{ab}^Q = [\mathbf{e}_1^Q, \mathbf{e}_2^Q, \mathbf{e}_3^Q]$ 。将源点对框架对齐到目标点对框架, 可得到旋转候选

$$\mathbf{R}_3 = \mathbf{F}_{ab}^Q (\mathbf{F}_{ab}^P)^T \quad (32)$$

该方法同时利用点对方向和表面法向信息, 可以补充方向一致性方法中的姿态约束不足问题。

□ 非退化三元组候选

除了点对约束外, 三组非共线对应点可以直接确定一个三维相似变换。因此, 从候选匹配中随机选取三元组对应, 并由其估计三维相似变换。

为了避免共线三元组导致的数值不稳定, 使用三角形质量判断三元组是否退化。设选取的源点云三元组为 $\{(\mathbf{p}_1, \mathbf{q}_1), (\mathbf{p}_2, \mathbf{q}_2), (\mathbf{p}_3, \mathbf{q}_3)\}$, 定义其三元组质量为

$$\Gamma(\mathbf{P}_3) = \frac{\|(\mathbf{p}_2 - \mathbf{p}_1) \times (\mathbf{p}_3 - \mathbf{p}_1)\|_2}{\|\mathbf{p}_2 - \mathbf{p}_1\|_2 \cdot \|\mathbf{p}_3 - \mathbf{p}_1\|_2} \quad (33)$$

式中, $\Gamma(\mathbf{P}_3)$ 表示源三元组的非退化程度。同理, 目标三元组质量 $\Gamma(\mathbf{Q}_3)$ 按相同方式定义。若 $\Gamma(\mathbf{P}_3) < \tau_r$ 或 $\Gamma(\mathbf{Q}_3) < \tau_r$, 则认为该三元组近似共线并将其舍弃。其中, τ_r 表示三元组退化阈值。

对于通过筛选的三元组, 使用加权 Umeyama 方法估计相似变化。若通过三元组估计得到的尺度与候选集合中的某一尺度一致, 则将求解得到的旋转 $\mathbf{R}_4$ 加入旋转候选集合 $\mathbf{S}_{R_4}$ 。

通过上述四类候选生成方式, 可以得到覆盖范围较广的旋转候选集合。算法将在尺度候选、旋转候选和平移投票结果的组合中, 通过几何评分选择最优相似变化。

3) 基于三维网格投票的平移估计

基于得到的尺度候选集合和旋转候选集合, 进一步估计平移向量。给定尺度候选 $s \in \mathbf{S}$ 和旋转候选 $\mathbf{R} \in \mathbf{S}_R$, 每组候选对应都可以产生一个平移

$$\mathbf{t}_a = \mathbf{q}_a - s \mathbf{R} \mathbf{p}_a \quad (34)$$

式中, $\mathbf{t}_a$ 表示第 a 组匹配在当前尺度和旋转下的平移估计。若尺度、旋转和匹配关系均正确, 则大量正确匹配产生的 $\mathbf{t}_a$ 会集中在真实平移附近; 错误匹配产生的平移则通常较为分散。因此, 使用三维网格投票估计平移。

设平移投票网格尺寸为

$$h_t = \eta_t D_Q \quad (35)$$

式中, h_t 表示平移空间的网格尺寸; η_t 表示无量纲网格比例。将 $\mathbf{t}_a$ 映射到三维网格

$$\mathbf{k}_a = \left\lfloor \frac{\mathbf{t}_a}{h_t} \right\rfloor \quad (36)$$

式中, $\mathbf{k}_a \in \mathbb{Z}^3$ 表示平移 $\mathbf{t}_a$ 对应的网格索引。接着对每个网格累加匹配置信度, 得到平移投票函数

$$H_t(\mathbf{k}) = \sum_{a=1}^M w_a \mathbb{I}[\mathbf{k}_a = \mathbf{k}] \quad (37)$$

式中, $H_t(\mathbf{k})$ 表示网格 $\mathbf{k}$ 的加权支持度。选择投票得分最高的网格作为主要平移区域

$$\mathbf{k}^* = \arg \max_{\mathbf{k}} H_t(\mathbf{k}) \quad (38)$$

为了减小网格边界对平移估计的影响, 将主网格及其邻近网格内的平移估计组成参与最终平移估计的匹配集合 $\mathbf{S}_T = \left\{ a \mid \|\mathbf{k}_a - \mathbf{k}^*\|_{\infty} \leq 1 \right\}$ 。通过加权平均可得最终平移向量

$$\hat{\mathbf{t}} = \frac{\sum_{a \in \mathbf{S}_T} w_a \mathbf{t}_a}{\sum_{a \in \mathbf{S}_T} w_a} \quad (39)$$

由此, 可得到完整相似变换候选 $\mathbf{T} = (s, \mathbf{R}, \hat{\mathbf{t}})$ 。对所有尺度候选和选择候选重复上述过程, 即可生成一组三维相似候选变换。算法将通过双向裁剪几何误差和覆盖率对这些候选进行评分, 并选择最优候选进入精配准阶段。

2.5 基于覆盖率约束的相似变换候选验证

经过尺度投票、旋转候选生成和平移投票, 算法可以得到一组相似变换候选。由于候选匹配中仍可能存在错误对应, 仅使用最近邻误差容易将小范围局部重合误判为整体配准成功。尤其在真实多视角点云中, 错误姿态可能使局部相似区域接近, 但整体旋转仍然错误。为此, 采用双向几何误差与覆盖率相结合的方式, 对候选变换进行验证。

设候选变换为 $\mathbf{T}_t$, 变换后的源点云为 $\hat{\mathbf{P}} = \mathbf{T}_t(\mathbf{P})$ 。为了同时衡量两个方向的贴合程度, 定义

源到目标的最近邻距离为

$$d_i^{\mathbf{P} \rightarrow \mathbf{Q}} = \min_{\mathbf{q}_j \in \mathbf{Q}} \|\mathbf{T}_t(\mathbf{p}_i) - \mathbf{q}_j\|_2 \quad (40)$$

目标到源的最近邻距离为

$$d_j^{\mathbf{Q} \rightarrow \mathbf{P}} = \min_{\mathbf{p}_i \in \mathbf{P}} \|\mathbf{q}_j - \mathbf{T}_t(\mathbf{p}_i)\|_2 \quad (41)$$

式中, $d_i^{\mathbf{P} \rightarrow \mathbf{Q}}$ 表示第 i 个变换源点到目标点云的最近邻距离; $d_j^{\mathbf{Q} \rightarrow \mathbf{P}}$ 表示第 j 个目标点到变换原点云的最近邻距离。双向最近邻距离可以减少单向误差对局部密集区域的偏置, 使评分更加关注整体对齐效果。

考虑到点云中可能存在遮挡区域、非重叠区域和离群点, 因此不直接对所有最近邻距离计算均方根误差, 而是采用裁剪策略^[42]。将两个方向距离按从小到大排序, 保留最小的 γ_c 比例, 得到对应的裁剪误差

$$E_{\mathbf{P} \rightarrow \mathbf{Q}} = \sqrt{\frac{1}{\lceil \gamma_c N \rceil} \sum_{i=1}^{\lceil \gamma_c N \rceil} (d_{(i)}^{\mathbf{P} \rightarrow \mathbf{Q}})^2} \quad (42)$$

$$E_{\mathbf{Q} \rightarrow \mathbf{P}} = \sqrt{\frac{1}{\lceil \gamma_c M \rceil} \sum_{j=1}^{\lceil \gamma_c M \rceil} (d_{(j)}^{\mathbf{Q} \rightarrow \mathbf{P}})^2} \quad (43)$$

由此, 进一步得到候选变换的双向裁剪几何误差

$$E(\mathbf{T}_t) = \sqrt{\frac{E_{\mathbf{P} \rightarrow \mathbf{Q}}^2 + E_{\mathbf{Q} \rightarrow \mathbf{P}}^2}{2}} \quad (44)$$

该值越小, 说明两片点云的重叠区域越贴合。

仅采用误差大小仍可能导致源点云和目标点云局部小范围贴合, 因此进一步通过覆盖率评价候选变换的整体对齐范围。

首先, 定义覆盖阈值为

$$\tau_c = \eta_c D_Q \quad (45)$$

式中, η_c 表示覆盖阈值比例。由此, 可将源到目标和目标到源覆盖率分别定义为

$$C_{\mathbf{P} \rightarrow \mathbf{Q}} = \frac{1}{N} \sum_{i=1}^N \mathbb{I}[d_i^{\mathbf{P} \rightarrow \mathbf{Q}} < \tau_c] \quad (46)$$

$$C_{\mathbf{Q} \rightarrow \mathbf{P}} = \frac{1}{M} \sum_{j=1}^M \mathbb{I}[d_j^{\mathbf{Q} \rightarrow \mathbf{P}} < \tau_c] \quad (47)$$

为了同时考虑两个方向的覆盖情况, 通过调和平均定义双向覆盖率为

$$C(\mathbf{T}_t) = \frac{2C_{\mathbf{P} \rightarrow \mathbf{Q}}C_{\mathbf{Q} \rightarrow \mathbf{P}}}{C_{\mathbf{P} \rightarrow \mathbf{Q}} + C_{\mathbf{Q} \rightarrow \mathbf{P}}} \quad (48)$$

该值越大,说明更多源点和目标点在变换后可以找到足够近的对点。

综合双向裁剪误差和覆盖率,候选变换的评分函数可定义为

$$J(\mathbf{T}_t) = \frac{E(\mathbf{T}_t)/D_Q}{\varepsilon + C(\mathbf{T}_t)} \quad (49)$$

式中, ε 为稳定常数。评分越小,表示候选变换越可靠。选择评分最小的候选 $\mathbf{T}^{(0)} = (s_0, \mathbf{R}_0, \mathbf{t}_0)$ 作为粗配准阶段的最优候选和精配准初值。

2.6 尺度锚定的鲁棒多分辨率精配准

粗配准阶段得到的候选变换已经提供了较可靠的尺度、旋转和平移,使得源点云可以大致对齐到目标点云。但由于候选对应、点云采样差异和噪声影响,还需进一步精配准。

精配准过程通过尺度锚定的鲁棒多分辨率 ICP 算法实现。SICP 在尺度因子趋近于 0 时,源点可能集中并对应到同一个目标点,从而产生局部极值。为此,本文从对应关系和尺度更新两个方面应对,一是采用目标点唯一对应和重叠裁剪,二是将尺度更新锚定在粗配准尺度附近。与普通 ICP 不同,本文精配准阶段同时优化尺度、旋转和平移,并引入多分辨率处理、法向一致性约束、鲁棒权重和尺度锚点策略,以提高算法在异尺度和部分重叠条件下的稳定性。

1) 多分辨率处理

通过多分辨率策略构建由粗到细的点云层。设共有 L 个分辨率层,第 l 层使用的源点云和和目标点云分别为 $\mathbf{P}_l = \{(\mathbf{p}_i, \mathbf{n}_i^p)\}_{i=1}^{N_l^p}$, $\mathbf{Q}_l = \{(\mathbf{q}_j, \mathbf{n}_j^q)\}_{j=1}^{N_l^q}$ 。其中, $\mathbf{n}_i^p$ 和 $\mathbf{n}_j^q$ 分别表示对应法向; N_l^p 和 N_l^q 分别表示第 l 层的源点数和目标点数。粗层用于扩大收敛范围并减小计算量,细层用于提高最终对齐精度。

2) 匹配对应构建

在第 l 个分辨率层的第 k 次迭代中,源点 $\mathbf{p}_i$ 在当前变换 $\mathbf{T}^{(k)} = (s^{(k)}, \mathbf{R}^{(k)}, \mathbf{t}^{(k)})$ 下的位置为

$$\mathbf{x}_i^{(k)} = s^{(k)} \mathbf{R}^{(k)} \mathbf{p}_i + \mathbf{t}^{(k)} \quad (50)$$

对应的源点法向变换为

$$\mathbf{m}_i^{(k)} = \mathbf{R}^{(k)} \mathbf{n}_i^p \quad (51)$$

对每个 $\mathbf{x}_i^{(k)}$,在目标点云中寻找最近邻

$$j(i) = \arg \min_j \|\mathbf{x}_i^{(k)} - \mathbf{q}_j\|_2 \quad (52)$$

式中, $j(i)$ 表示第 i 个变换源点最近的目标点索引。最近邻距离和法向一致性分别为

$$d_i = \|\mathbf{x}_i^{(k)} - \mathbf{q}_{j(i)}\|_2 \quad (53)$$

$$v_i = \left| (\mathbf{m}_i^{(k)})^T \mathbf{n}_{j(i)}^q \right| \quad (54)$$

式中, d_i 表示最近邻距离; v_i 表示源点法向与目标最近邻法向之间的绝对余弦相似度。由于法向可能存在正负方向不一致,因此使用绝对值。

为了去除明显错误对应,设定距离门限比例 g_l 和法向一致性门限 τ_v 进行筛选,从而得到有效对应集合 $\mathbf{S}_l = \{i \mid d_i < g_l D_Q, v_i > \tau_v\}$ 。

为了防止多个源点同时对对应到同一个目标点而造成局部塌缩,通过目标点唯一对应策略进行处理。具体而言,若多个源点对应同一个目标点,则仅保留距离最小的源点。接着,在有效对应中按距离从小到大排序,并保留前 τ_l 比例的对应,得到用于位姿更新的集合 $\mathbf{U}_l$ 。其中, τ_l 表示第 l 层的裁剪比例。

3) 鲁棒权重计算

为了减小离群点和残余错误对应的影响,将保留的对应关系赋予鲁棒权重。

首先,基于保留距离集合计算中位数 m_d ,估计距离残差尺度

$$\sigma_d = k_c \text{median} \{ |d_i - m_d| \mid i \in \mathbf{U}_l \} \quad (55)$$

式中, σ_d 表示鲁棒尺度估计; k_c 表示将中位绝对偏差转换为标准差的一致估计。

接着,定义 Tukey 截断尺度为

$$c_d = \max(m_d + 3\sigma_d \rho_d D_Q) \quad (56)$$

式中, ρ_d 表示最小截断尺度比例。令

$$u_i = \frac{d_i}{c_d} \quad (57)$$

在此基础上, Tukey 距离权重可定义为

$$w_i^d = \begin{cases} (1 - u_i^2)^2, & u_i < 1 \\ 0, & u_i \geq 1 \end{cases} \quad (58)$$

式中, w_i^d 表示距离鲁棒权重。距离越小,权重越大;当距离超过截断尺度是,权重为 0。再进一步引入法向一致性权重,则最终对应权重可表示为

$$w_i = w_i^d(v_i)^2 \quad (59)$$

4) 加权相似变换增量估计

根据得到的加权对应集合, 可估计增量相似变换 $\Delta T = (\Delta s, \Delta R, \Delta t)$, 使当前变换后的源点 $\mathbf{x}_i^{(k)}$ 进一步对齐到对应目标点 $\mathbf{q}_{j(i)}$ 。

首先, 对权重进行归一化

$$\bar{w}_i = \frac{w_i}{\sum_j w_j} \quad (60)$$

并计算加权质心

$$\bar{\mathbf{x}} = \sum_i \bar{w}_i \mathbf{x}_i^{(k)}, \bar{\mathbf{q}} = \sum_i \bar{w}_i \mathbf{q}_{ji}^{(k)} \quad (61)$$

接着, 基于加权质心构造加权协方差矩阵 $\mathbf{C}$, 通过对其进行奇异值分解可得原始增量旋转为

$$\Delta \mathbf{R}_0 = \mathbf{U} \mathbf{D} \mathbf{V}^T \quad (62)$$

原始增量尺度为

$$\Delta s_0 = \frac{\text{tr}(\sum \mathbf{D})}{\sum_i \tilde{w}_i \|\tilde{\mathbf{x}}_i\|_2^2} \quad (63)$$

式中, $\mathbf{U}, \mathbf{\Sigma}, \mathbf{V}, \mathbf{D}$ 为协方差矩阵分解得到的矩阵。

直接使用 Δs_0 可能导致尺度突变, 因此对尺度增量进行锚点约束。限制对数尺度更新步长为

$$\Delta \sigma = \text{clip}(\log \Delta s_0, -\sigma_h, \sigma_h) \quad (64)$$

式中, σ_h 表示单次迭代允许的最大对数尺度变化; clip 表示截断函数。

以粗配准尺度为锚点, 将更新后的尺度限制在尺度锚点附近

$$s^{(k+1)} = \text{clip}\left(s^{(k)} \exp(\Delta \sigma), \frac{s_a}{\alpha_s}, s_a \alpha_s\right) \quad (65)$$

式中, α_s 表示尺度相对锚点的最大允许变化比例。最终增量尺度为

$$\Delta s = \frac{s^{(k+1)}}{s^{(k)}} \quad (66)$$

尺度经过锚定修正, 可计算平移增量

$$\Delta \mathbf{t} = \bar{\mathbf{q}} - \Delta s \Delta \mathbf{R}_0 \bar{\mathbf{x}} \quad (67)$$

5) 变换更新与收敛准则

通过左复合的形式更新当前相似变换

$$\mathbf{T}^{(k+1)} = \Delta \mathbf{T} \circ \mathbf{T}^{(k)} \quad (68)$$

为了判断迭代是否收敛, 定义相邻两次迭代变化量

$$\Delta_k = \left| \log \frac{s^{(k+1)}}{s^{(k)}} \right| + \theta \left(\mathbf{R}^{(k+1)} (\mathbf{R}^{(k)})^T \right) + \frac{\|\mathbf{t}^{(k+1)} - \mathbf{t}^{(k)}\|_2}{D_0} \quad (69)$$

式中, θ 表示旋转矩阵对应的旋转角; 第一项衡量尺度变化; 第二项衡量旋转变化; 第三项衡量归一化平移变化。

定义当前对应关系的误差为

$$\varepsilon_k = \sqrt{\frac{\sum_i w_i \|\mathbf{x}_i^{(k)} - \mathbf{q}_{ji}\|_2^2}{\sum_i w_i}} \quad (70)$$

当 Δ_k 达到收敛阈值或最大迭代次数时, 当前分辨率层停止。若某次更新导致 ε_k 变大, 则通过缩小步长的方式重新更新; 若误差无法继续下降, 则提前结束当前层迭代。在最细分辨率层, 为了避免尺度微小抖动, 固定尺度, 仅优化旋转和平移。

对于粗配准阶段保留的多个候选变换, 分别执行上述多分辨率精配准过程, 并在结束后重新计算评分函数, 最终选择评分最小的相似变换。

通过尺度锚定、鲁棒权重、法向约束和多分辨率迭代, 算法可以保持相似变化优化能力, 并减小离群点、错误对应和部分重叠区域对配准结果的影响。

3 实验结果与分析

3.1 实验环境与实验数据

实验主要在 windows 环境下完成, 整体算法框架使用 Python 语言实现。

为了验证所提算法在异尺度条件下的适用性, 选取 Stanford 3-D Scanning Repository^[43]、ScanNet^[44]和 MVP^[45]三类点云数据进行实验。

3.2 算法评价指标

从点云几何重合程度、表面法向一致性以及真实变换误差等多个角度综合评估算法的配准性能。

将归一化双向裁剪均方根误差 $\varepsilon_{\text{nRMSE}}$ 、归一化双向二阶倒角距离 ε_{CD} 、法向均方根误差 $\varepsilon_{\text{NRMSE}}$ 、双向覆盖率 r_{CR} 、相对旋转误差 ε_{RRE} 、归一化相对平移误差 ε_{RTE} 和尺度相对百分误差 ε_s 作为算法评价指标。

3.3 Stanford 3-D Scanning Repository 点云配准

该实验用于验证算法在真实多视角物体点云上的异尺度配准能力。为了模拟杂散点和错误测量

点, 随机选取指定比例的源点, 并将其替换为目标点分位数包围盒扩展区域内的均匀随机点; 同时, 为了模拟测量误差, 实验中对源点云加入零均值各向同性高斯噪声。设目标点云的分位数包围尺度为 D_Q , 噪声比例为 ρ , 则每个源点坐标加入的噪声服从 $N(0, (\rho D_Q)^2 I^3)$ 。

1) 不同视角与几何尺度变化实验

不同视角扫描之间不仅存在空间姿态差异, 而且源点云和目标点云的可见区域并不完全一致, 因此该实验能够同时考察尺度恢复、旋转估计、平移估计和部分重叠条件下的配准鲁棒性。图2~图5给出了各点云模型在不同实验组中的源点云和初始位姿。

Bunny 点云配准设置4组实验。其中, 第3组实验施加0.001的噪声和0.02比例的离群点; 第4组实验选取bun090到bun000的大视角差配准任务, 并同时施加2.0倍尺度、35%源点保留率、70%目标点保留率、梯度非均匀采样、噪声和离群点等干扰, 以验证算法在复杂异尺度条件下的鲁棒性。

Bunny 点云的配准结果如表1所示, 对应的配准效果如图6~图9所示。

由表1可知, 在第1、2组实验中, 文献[14]和文献[11]的均方根误差已经小于多数算法, 但其旋转误差仍在 10° 左右, 说明局部最近邻误差小并不代表整体姿态正确。本文算法在两组实验中均保持较小配准误差且覆盖率较大。图6-7显示其与目标点云的整体重合程度较高, 局部轮廓没有出现明显




图2 待配准的Bunny源点云




图3 Bunny点云的初始位姿




图4 待配准的Dragon源点云



图5 Dragon点云的初始位姿

错位。

第3、4组实验难度明显增加。对比算法误差普遍变大,多数方法的相对旋转误差接近或超过 90° ,甚至接近 180° ,而本文算法在该组中表现最好。

Dragon点云配准设置3组实验。第3组实验施加0.001的噪声和0.02的离群点。Dragon点云表面细节更丰富,局部结构重复性更强,因此对旋转候选筛选和法向一致性评价要求更高。Dragon点云配准结果如表2所示,对应的配准效果如图10~图12所示。

实验结果表明,本文算法姿态恢复更稳定,部分算法仅实现局部结构贴近,整体姿态存在偏移。

综合上述实验,本文算法在中等视角差和一般尺度变化下优势明显,整体稳定性优于对比方法。

2) 尺度、点密度和分辨率差异实验

各组实验均施加0.001的噪声和0.02的离群点。表3和表4给出了代表性算法的配准结果,其对应的配准效果如图13~图17所示。

由实验结果可知,对比算法误差变化明显。第3、4组实验进一步施加非均匀采样,本文算法仍能保持较好的整体重合,说明对数尺度投票和三维平移投票对采样密度不均具有较强鲁棒性。

由实验结果可知,本文算法整体表现更好较好,说明其在点数减少和局部密度不均时仍能形成可靠的候选共识。综合实验表明,采样尺度差异会显著影响传统异尺度点云配准方法。本文算法结合密度均衡、尺度投票、旋转共识、平移投票和覆盖率验证,保持较小误差,验证了尺度划分的必要性。

3.4 ScanNet室内场景点云配准

ScanNet室内场景点云配准实验用于验证算法

在大规模场景点云中的适用性。该类数据包含墙面、地面、桌椅等大面积平面和重复结构,空间范围大、密度变化明显,更容易产生伪匹配。

实验在同一场景内构造源点云和目标点云,设置三组条件,均加入0.001的噪声和0.01比例的离群点。图18为原始ScanNet点云模型如所示,表5给出了不同实验条件下的配准结果。本文算法的配准效果如图19所示。

表5中文献[39] HDRNet算法通过尺度相关回归模块预测尺度因子,文献[46] ScaleLK算法则直接在相似变换空间中进行优化,因此实验中直接通过原始尺度估计能力进行测试。而文献[38] Geo Transformer算法和文献[47] ScaleLK算法,由于二者主要针对固定刚体尺度配准任务,无法原生支持尺度估计,因此实验通过基于主成分包围盒的尺度归一化策略^[48]进行处理。具体而言,对于源点云和目标点云,分别计算其包围盒尺度因子,并将二者映射到统一尺度空间再进行配准;对于模型来源,优先使用公开发布的官方模型进行测试,实验中对于Geo Transformer算法,使用了公开预训练模型进行推理;此外,对于输入数据网络的数据,所有对比方法均使用相同的数据生成流程。

由表5可知,部分算法的旋转误差达几十度甚至上百度,说明场景中的大面积点云和重复结构干扰会干扰全局统计量。由图19可见,配准前紫色源点云与目标点云在尺度和位姿上存在明显差异,而经过配准的红色源点云与绿色目标点云在墙面、地面和主要物体轮廓处基本重合。

3.5 MVP部分可见点云的配准

该实验用于验证算法在局部缺损、不完整形状和低点数条件下的泛化能力。MVP样本的主要困难不只是尺度变换,而是尺度变化与部分可见、局

表 1		Bunny 点云模型配结果										
实验	尺度	源点 保留 率/%	目标 点 保留 率/%	源点采样	算法	$\varepsilon_{\text{nRMSE}}$	ε_{CD}	$\varepsilon_{\text{NRMSE}}/(\circ)$	r_{CR}	$\varepsilon_{\text{RRE}}/(\circ)$	ε_{RTE}	ε_{s}
第 1 组	1	100	100	原始	文献[9]	0.046	0.007	41.536	0.231	86.548	0.466	4.424
					文献[12]	0.039	0.011	38.628	0.352	83.476	0.380	15.513
					文献[10]	0.032	0.009	31.438	0.427	80.928	0.329	18.675
					文献[8]	0.025	0.004	23.909	0.432	34.737	0.135	6.795
					文献[13]	0.016	0.001	18.242	0.558	11.027	0.082	14.428
					文献[14]	0.012	0.001	16.363	0.672	10.237	0.067	1.584
					文献[11]	0.012	0.001	16.321	0.677	10.412	0.066	1.624
					本文算法	0.003	0.000	2.385	0.932	0.102	0.001	0.058
第 2 组	0.5	50	80	随机	文献[9]	0.035	0.007	31.870	0.311	85.006	0.755	8.279
					文献[12]	0.072	0.020	42.493	0.198	117.688	0.700	27.307
					文献[10]	0.083	0.036	33.026	0.295	56.056	0.430	45.704
					文献[8]	0.025	0.004	23.790	0.428	34.921	0.323	7.144
					文献[13]	0.017	0.001	19.185	0.548	8.328	0.208	15.326
					文献[14]	0.012	0.001	16.478	0.686	10.961	0.186	1.444
					文献[11]	0.011	0.001	16.099	0.701	9.645	0.181	1.487
					本文算法	0.003	0.000	2.491	0.937	0.053	0.234	0.166
第 3 组	2.0	35	70	梯度非均匀 0.9	文献[9]	0.030	0.004	28.026	0.348	174.951	0.635	23.025
					文献[12]	0.052	0.013	45.217	0.255	82.221	0.568	29.383
					文献[10]	0.030	0.008	30.961	0.427	71.397	0.346	14.885
					文献[8]	0.027	0.005	25.016	0.408	33.598	0.097	9.341
					文献[13]	0.031	0.004	28.235	0.377	7.874	0.236	39.959
					文献[14]	0.010	0.001	13.320	0.788	6.943	0.158	1.812
					文献[11]	0.011	0.001	15.220	0.724	6.358	0.163	9.333
					本文算法	0.003	0.001	2.661	0.929	0.098	0.117	0.022
第 4 组	2.0	35	70	梯度非均匀 0.9	文献[9]	0.035	0.006	41.885	0.295	177.638	0.617	19.983
					文献[12]	0.062	0.017	39.949	0.246	136.637	0.520	37.580
					文献[10]	0.047	0.011	42.210	0.257	150.054	0.613	13.454
					文献[8]	0.048	0.013	40.729	0.229	96.185	0.169	5.610
					文献[13]	0.041	0.007	44.196	0.277	178.534	0.523	38.973
					文献[14]	0.035	0.005	35.171	0.282	178..505	0.581	10.789
					文献[11]	0.036	0.005	35.262	0.255	179.308	0.597	6.526
					本文算法	0.025	0.007	22.200	0.473	56.214	0.217	7.224

部缺失和对称结构作用。MVP 点云数据配准的实验结果如表 6 所示，部分算法配准效果如图 20~图 23 所示。

实验结果表明，本文算法对 MVP 部分可见点

云具有较好适应性，但并非全部成功。前 3 组实验的配准误差和尺度误差较小，说明尺度投票和平移投票具有一定鲁棒性；但第 1 组实现出现明显旋转模态错误，这表明在强对称结构下，算法可能产生




图6 第1组实验不同算法配准效果




图7 第2组实验不同算法配准效果

错误旋转候选。由此表明未来的研究方向：需进一步引入对称结构消歧、重叠区域预测或多候选验证机制，以提高算法稳定性。

3.6 消融实验

为了验证算法核心模块的实际贡献，将点数约束体素均衡、多几何共识候选生成和尺度锚定鲁棒多分辨率精配准分别记为V、G和M，选取Bunny和Dragon点云模型进行消融实验。实验中，对源点云施加一定比例的噪声和离群点，保持源和目标点云的点保留率不同，并将源点云尺度均设为1.5。

将不采用点数约束体素均衡和多几何共识候选，而使用相同点数随机采样、单一非退化三元组

估计粗配准，并以单分辨率、无尺度锚定的最近点迭代实现精配准的过程作为基线实验。消融实验结果如表7所示。

由表7的实验结果可知，在Bunny点云困难异尺度配准任务中，在基线基础上施加模块V，尺度误差由21.030%下降至2.767%，误差减小约87%，同时相对旋转误差减小约83%，相对平移误差减小约72%，这说明密度均衡主要解决点数和非均匀采样造成的配准误差。从完整算法中移除V，相对旋转误差再次变大至102.085°，进一步验证了该模块在困难采样条件下的重要性；Dragon点云消融实验更能体现模块G和M的作用。在模块V的基础




图8 第3组实验不同算法配准效果




图9 第4组实验不同算法配准效果

上施加G, 相对旋转误差从 6.783° 降至 1.045° , 减小约85%, 同时相对平移误差减小约84%, 说明多几何候选共识主要提高粗配准候选的可靠性, 进一步施加M, 相对旋转误差和相对平移误差分别减小约55%和50%, 这说明尺度锚定多分辨率优化主要负责可靠初值附近的最终精化。此外, 由ScanNet点云消融实验结果发现, 在已有较充分的场景几何约束情况下, 算法复杂模块的增益趋于饱和。总体实验结果表明, 多几何候选机制对困难场景配准具有重要作用。

通过前两组实验G和M模块的消融结果, 可以进一步区分三个模块在不同阶段的作用。对于Bunny点云, V模块的贡献最为明显, 施加V模块时尺度、旋转和平移误差均大幅下降, 说明其可以有效减弱采样密度差异对特征匹配和后续相似变换估计的影响。相比之下, G单独使用虽能一定程度改善候选质量, 但在密度差异尚未消除时提升相对有限; M单独使用改善较小, 说明当粗配准初值偏差较大时, 仅依赖局部精化难以恢复正确位姿。对于Dragon点云, M单独使用可改善配准精度, 而

表 2

Dragon 点云模型配准结果

实验	尺度	源点 保留率/%	目标点 保留率/%	源点采样	算法	$\varepsilon_{\text{RMSE}}$	ε_{CD}	$\varepsilon_{\text{NRMSE}}/(\circ)$	r_{CR}	$\varepsilon_{\text{RRE}}/(\circ)$	ε_{RTE}	ε_s
第 1 组	1.0	100	100	原始	文献[9]	0.015	0.002	25.048	0.592	10.921	0.076	6.719
					文献[12]	0.063	0.018	38.319	0.231	133.572	0.419	46.388
					文献[10]	0.046	0.011	40.330	0.308	110.520	0.376	27.781
					文献[8]	0.042	0.005	32.390	0.201	24.533	0.206	3.214
					文献[13]	0.019	0.002	29.546	0.482	11.318	0.044	6.750
					文献[14]	0.021	0.002	28.882	0.460	11.392	0.057	11.138
					文献[11]	0.022	0.002	27.352	0.446	11.334	0.074	14.789
					本文算法	0.004	0.001	8.103	0.814	0.123	0.003	0.156
第 2 组	0.5	50	80	原始	文献[9]	0.017	0.002	28.015	0.550	11.076	0.060	6.316
					文献[12]	0.063	0.015	40.742	0.210	112.309	0.630	44.192
					文献[10]	0.038	0.008	41.404	0.282	170.465	0.699	27.422
					文献[8]	0.042	0.005	32.798	0.202	24.770	0.206	3.533
					文献[13]	0.018	0.002	31.545	0.508	11.513	0.040	2.538
					文献[14]	0.021	0.002	31.393	0.454	12.053	0.061	10.078
					文献[11]	0.021	0.002	28.282	0.445	11.735	0.079	14.375
					本文算法	0.004	0.001	8.451	0.811	0.284	0.005	0.104
第 3 组	2.0	35	70	梯度非均匀 0.9	文献[9]	0.020	0.002	29.574	0.490	9.241	0.091	12.886
					文献[12]	0.048	0.014	40.693	0.313	55.148	0.454	16.657
					文献[10]	0.050	0.011	42.158	0.255	143.021	0.504	22.475
					文献[8]	0.070	0.013	43.079	0.096	48.145	0.117	5.713
					文献[13]	0.027	0.004	31.228	0.392	9.229	0.189	34.885
					文献[14]	0.022	0.002	32.458	0.431	9.199	0.076	11.291
					文献[11]	0.021	0.002	29.338	0.445	9.941	0.097	16.417
					本文算法	0.006	0.001	11.392	0.797	1.287	0.023	2.447

G在与V或M组合时表现出更加明显的增益,说明V、G和M分别主要用于密度均衡、多几何候选约束和可靠初值附近精细优化,三个模块既具有相对独立的功能,又存在明显的互补关系。

由Dragon点云不同条件下的消融结果可知,V模块的性能与点云采样状态有关。V均能减小尺度估计误差,但部分旋转和平移指标出现退化。这是因为V的主要目标是均衡源、目标点云的空间密度差异,而不是直接优化位姿参数;其在削弱高密度区域偏置的同时,也可能改变局部邻域、法向和特征分布,从而使原本较稳定的候选产生一定的扰动。然而,当噪声和离群点进一步增大时,V的作用更加明显,旋转误差减小约84%,平移误差减小

约77%,表明在采样偏置与较强数据扰动共同存在时,密度均衡可以有效提高后续匹配稳定性。同时,在V模块基础上施加G,不同径向采样条件下的旋转误差可进一步减小约75%~85%,说明G能够有效抑制V对配准误差的影响。因此,V的增益具有采样条件依赖性,但其与G、M组合后可以形成稳定的互补作用。

3.7 算法参数敏感性分析

为了分析关键参数对不同类型异尺度点云的影响,选取Bunny、ScanNet和MVP三类点云数据进行参数敏感性实验,分别覆盖非均匀采样的大视角物体、复杂室内场景和部分可见点云,且均含1%的离群点。参数敏感性实验设置如表8所示。实验




图 10 第1组实验不同算法配准效果




图 11 第2组实验不同算法配准效果

采用单因素变量法,对体素经验因子 α_h 、尺度候选合并阈值 δ_s 、三元组退化阈值 τ_r 、平移投票网格比例 η_t 、分辨率层数 L 和尺度锚定范围 α_s 分别进行敏感性测试,部分实验结果如表9所示。

算法参数敏感性实验结果表明,各参数敏感程度存在明显差异。完整实验结果表明, α_h 对非均匀采样任务影响较为明显。Bunny配准实验中,当 $\alpha_h = 0.55$ 时相对旋转误差为 42.764° ,当 $\alpha_h = 0.72$ 时相对旋转误差降至 42.764° ,因此0.72作为默认值具有较好的综合稳定性; δ_s 在0.03~0.05范围内表现稳定; τ_r 在0.03~0.05范围内未引起最终精度指标变化,说明算法对该参数具有较宽稳定区间,同时表明只要能够排除明显近共线三元组,该参数通常不需要调整;随着多分辨率层数 L 的增加能够

进一步改善配准精度,但迭代次数也随之增加,因此3层作为精度与优化开销的折中; η_t 是实验中较敏感的参数,在MVP点云数据配准中,当 $\eta_t = 0.012$ 时相对旋转误差为 1.387° ,而 η_t 增大至0.030时相对旋转误差达到 28.791° ,说明网格过粗或过细均可能影响配准结果,当出现粗配准位姿不稳定时,应优先对该参数进行小范围调整; α_s 在1.05~1.5范围内各项配准指标保持一致,说明在粗配准尺度较准确时,该参数通常不需精细调节。

当高密度或者非均匀采样导致配准结果不稳定时,优先调整 α_h 和 N_0 ;当粗配准误差较大时,可优先在约0.012~0.020范围内调整 η_t ,其次调整 δ_s ;若粗配准精度不足,可增加多分辨率层数;而 τ_r 和 α_s 在正常工作范围内通常无需调整。




图12 第3组实验不同算法配准效果

表3

Bunny 点云尺度、点密度和分辨率差异配准结果

实验	尺度	源点 保留 率/%	目标 点 保留 率/%	源点采样方式	算法	$\varepsilon_{\text{nRMSE}}$	ε_{CD}	$\varepsilon_{\text{NRMSE}}/(\circ)$	r_{CR}	$\varepsilon_{\text{RRE}}/(\circ)$	ε_{RTE}	ε_{s}
第1组	0.5	50	80	随机	文献[8]	0.049	0.017	39.676	0.216	52.293	0.294	30.787
					文献[13]	0.036	0.008	39.123	0.275	157.589	0.630	69.895
					文献[14]	0.032	0.011	34.084	0.315	135.495	0.606	49.255
					文献[11]	0.030	0.008	36.547	0.276	83.643	0.413	61.434
					本文算法	0.004	0.031	2.396	0.956	0.039	0.001	0.091
第2组	1.0	100	100	原始	文献[8]	0.056	0.013	44.178	0.184	61.359	0.265	20.933
					文献[13]	0.031	0.006	37.142	0.390	85.682	0.407	57.116
					文献[14]	0.023	0.005	28.837	0.433	35.725	0.243	21.713
					文献[11]	0.025	0.005	32.527	0.390	82.762	0.363	38.272
					本文算法	0.003	0.009	2.221	0.919	0.061	0.000	0.038
第3组	1.5	35	70	梯度非均匀0.9	文献[8]	0.055	0.011	36.138	0.184	49.697	0.198	15.484
					文献[13]	0.032	0.004	25.318	0.342	6.585	0.238	44.258
					文献[14]	0.014	0.003	11.803	0.740	61.096	0.211	3.640
					文献[11]	0.009	0.002	10.011	0.811	3.668	0.074	12.395
					本文算法	0.003	0.002	2.102	0.971	0.027	0.000	0.015
第4组	2.0	25	60	径向非均匀0.9	文献[8]	0.062	0.014	39.038	0.176	56.723	0.225	22.235
					文献[13]	0.036	0.004	25.481	0.331	6.886	0.231	42.739
					文献[14]	0.004	0.001	3.279	0.975	1.154	0.016	1.369
					文献[11]	0.008	0.001	8.024	0.859	3.466	0.068	7.847
					本文算法	0.003	0.001	2.166	0.978	0.030	0.000	0.052




图 13 第1组实验不同算法配准效果



图 14 第2组实验不同算法配准效果



图 15 第3组实验不同算法配准效果



图 16 第4组实验不同算法配准效果

3.8 特征描述子鲁棒性实验

为了验证尺度保持紧凑特征描述子的实际有效性,并分析点云局部邻域结构变化对描述子匹配性能的影响,将描述子从粗配准和精配准过程中独立出来,进行对应点匹配实验。该实验不以配准误差作为评价依据,直接衡量描述子产生的局部对应关系,从而避免后续候选估计和精配准对描述子性能的补偿作用。

选取 Spin Image^[49]和 FPFH^[41]两种代表性点云特征描述子进行较比,且 FPFH 采用标准 33 维实

现。为了避免在异尺度实验中人为将真实尺度因子提供给对比方法,两类描述子均不使用源、目标点云之间的真正尺度,而是分别根据当前点云自身可观测的空间分辨率确定局部支撑范围。对于未进行体素化的点云,以初始体素尺度作为当前点云的有效空间分辨率;经过体素均衡处理,则直接使用实际体素尺寸作为当前点云的可观测分辨率。

考虑到本文研究的异尺度问题同时包含几何尺度和采样尺度变化,因此设置全局尺度变化、源点保留率变化和非均匀采样实验,并比较描述子在原

表 4

Dragon 点云尺度、点密度和分辨率差异配准结果

实验	尺度	源点 保留 率/%	目标 点 保留 率/%	源点采样	算法	$\varepsilon_{\text{nRMSE}}$	ε_{CD}	$\varepsilon_{\text{NRMSE}}/(^{\circ})$	r_{CR}	$\varepsilon_{\text{RRE}}/(^{\circ})$	ε_{RTE}	ε_{s}
第1组	0.5	50	80	随机	文献[8]	0.063	0.024	47.333	0.136	65.728	0.436	27.771
					文献[13]	0.034	0.007	42.316	0.271	99.852	0.655	70.590
					文献[14]	0.029	0.008	38.465	0.340	100.375	0.693	52.782
					文献[11]	0.029	0.006	42.904	0.299	130.485	0.707	65.971
					本文算法	0.004	0.037	2.839	0.955	0.067	0.001	0.102
第2组	1.0	100	100	原始	文献[8]	0.063	0.017	45.740	0.164	71.030	0.362	19.492
					文献[13]	0.035	0.007	43.270	0.376	168.894	0.702	57.511
					文献[14]	0.029	0.007	43.376	0.344	160.344	0.540	22.426
					文献[11]	0.026	0.006	43.047	0.381	166.924	0.777	41.462
					本文算法	0.003	0.012	2.759	0.916	0.023	0.000	0.032
第3组	1.5	35	70	梯度非均匀0.9	文献[8]	0.065	0.021	41.926	0.159	56.388	0.302	3.800
					文献[13]	0.035	0.006	28.190	0.379	5.317	0.258	45.829
					文献[14]	0.009	0.002	11.521	0.831	0.899	0.046	3.130
					文献[11]	0.016	0.002	19.463	0.577	2.209	0.137	22.384
					本文算法	0.003	0.002	2.592	0.969	0.042	0.001	0.078
第4组	2.0	25	60	径向非均匀0.9	文献[8]	0.085	0.027	46.918	0.116	70.401	0.313	9.589
					文献[13]	0.033	0.005	27.244	0.392	5.849	0.254	44.187
					文献[14]	0.007	0.001	8.246	0.902	0.966	0.039	4.277
					文献[11]	0.015	0.002	20.151	0.592	2.534	0.132	21.589
					本文算法	0.003	0.001	2.539	0.978	0.020	0.000	0.032



图17 第4组实验不同算法配准效果



图18 原始ScanNet室内场景点云模型

表5 ScanNet室内场景点云配准结果													
点云模型	尺度	源点保留率/%	目标点保留率/%	源点采样	算法	$\varepsilon_{\text{nRMSE}}$	ε_{CD}	$\varepsilon_{\text{NRMSE}}/({}^{\circ})$	r_{CR}	$\varepsilon_{\text{RRE}}/({}^{\circ})$	ε_{RTE}	ε_{s}	
第1组	1.50	15	65	梯度非均匀0.85	文献[9]	0.018	0.003	13.207	0.528	44.193	0.420	4.280	
					文献[12]	0.073	0.020	42.163	0.206	100.926	0.658	51.146	
					文献[10]	0.033	0.009	28.309	0.425	78.570	0.470	22.812	
					文献[8]	0.051	0.012	40.619	0.186	80.855	0.666	12.501	
					文献[13]	0.053	0.007	31.169	0.214	18.574	0.385	49.795	
					文献[14]	0.025	0.005	14.115	0.421	17.308	0.233	10.299	
					文献[11]	0.020	0.002	13.119	0.474	15.065	0.233	18.264	
					文献[38]	0.025	0.006	15.772	0.579	13.554	0.418	11.335	
					文献[39]	0.195	0.006	10.175	0.755	7.258	0.201	12.119	
					文献[46]	0.022	0.058	11.395	0.601	10.376	0.389	13.402	
					文献[47]	0.011	0.005	8.793	0.801	6.330	0.145	10.058	
					本文算法	0.004	0.003	1.742	0.979	0.039	0.000	0.027	
第2组	0.50	45	75	径向非均匀0.82	文献[9]	0.020	0.021	8.802	0.501	9.425	0.132	5.743	
					文献[12]	0.039	0.006	44.885	0.224	142.039	0.829	72.043	
					文献[10]	0.035	0.015	35.185	0.325	96.136	0.644	17.955	
					文献[8]	0.048	0.017	43.480	0.189	72.516	0.720	21.905	
					文献[13]	0.045	0.010	38.820	0.190	44.242	0.576	59.874	
					文献[14]	0.032	0.011	17.740	0.350	8.507	0.304	33.296	
					文献[11]	0.040	0.009	45.862	0.231	160.261	0.924	55.970	
					文献[38]	0.021	0.018	8.005	0.425	20.752	0.144	10.258	
					文献[39]	0.012	0.017	10.105	0.708	14.115	0.106	8.442	
					文献[46]	0.017	0.017	7.950	0.588	16.099	0.145	7.251	
					文献[47]	0.010	0.021	8.102	0.785	10.005	0.103	9.010	
					本文算法	0.004	0.016	1.840	0.982	0.065	0.001	0.026	
第3组	2.00	50	55	梯度非均匀0.80	文献[9]	0.032	0.006	37.174	0.327	101.504	0.604	25.204	
					文献[12]	0.064	0.016	48.314	0.229	138.350	0.570	52.833	
					文献[10]	0.045	0.013	45.547	0.264	152.420	0.614	28.351	
					文献[8]	0.057	0.013	51.807	0.171	133.786	0.837	12.566	
					文献[13]	0.052	0.008	40.227	0.243	120.615	0.610	52.972	
					文献[14]	0.032	0.006	38.903	0.323	144.817	0.752	20.060	
					文献[11]	0.037	0.006	39.265	0.320	47.089	0.390	37.788	
					文献[38]	0.029	0.010	20.799	0.379	42.054	0.478	15.785	
					文献[39]	0.021	0.011	16.789	0.609	35.115	0.398	16.005	
					文献[46]	0.020	0.013	22.557	0.406	39.877	0.477	16.009	
					文献[47]	0.016	0.011	12.788	0.705	29.876	0.351	12.535	
					本文算法	0.004	0.007	1.258	0.968	0.030	0.000	0.031	




图19 ScanNet点云初始位姿和配准效果

始点云、统一点数和体素均衡3类点云预处理条件下的性能。其中，统一点数实验的目的在于避免将体素均衡带来的性能变化简单归因于点数减少。表10给出了Dragon点云的描述子匹配结果。

全局尺度变化实验使用相同随机种子保持不同尺度条件下的源点采样集合不变，当尺度发生变化时，源点之间的距离整体按相同比例变化，而点的最近邻排序基本不发生改变，该实验主要验证描述

子在局部邻域拓扑保持条件下的尺度保持性质；源点保留率实验固定源点云尺度为1，仅改变源点数量，用于验证点数减少及其对应的有效空间分辨率降低对局部邻域的影响；梯度和径向非均匀实验同样固定源点尺度为1，并将源点总保留率保持在45%，主要改变点在空间中的分布方式，从而考察局部密度不均造成的邻域结构变化。

表10 描述子匹配实验结果

点云预处理	实验类型	参数值	Spin Image			FPFH			Proposed		
			$r_{IR@1}$	$r_{R@5}$	$\epsilon_{DG@1}$	$r_{IR@1}$	$r_{R@5}$	$\epsilon_{DG@1}$	$r_{IR@1}$	$r_{R@5}$	$\epsilon_{DG@1}$
原始点云	尺度变化	0.5	0.0424	0.1401	0.0729	0.2433	0.5114	0.0387	0.2605	0.5095	0.0341
		0.75	0.0424	0.1401	0.0729	0.2433	0.5114	0.0387	0.2605	0.5095	0.0341
		1	0.0424	0.1401	0.0729	0.2438	0.5114	0.0388	0.2605	0.5095	0.3041
		1.5	0.0424	0.1401	0.0729	0.2443	0.5114	0.0386	0.2605	0.5095	0.0341
		2	0.0424	0.1401	0.0729	0.2443	0.5114	0.0386	0.2605	0.5095	0.0341
	源点保留率	0.8	0.0424	0.1401	0.0729	0.2438	0.5109	0.0388	0.2605	0.5095	0.0341
		0.6	0.0381	0.1248	0.0696	0.2019	0.4474	0.0414	0.2343	0.5102	0.0368
		0.4	0.0271	0.1002	0.0705	0.0933	0.2605	0.0590	0.1186	0.3044	0.0513
		0.25	0.0110	0.0529	0.0721	0.0329	0.1186	0.0706	0.0371	0.1396	0.0693
	梯度非均匀	0	0.0252	0.1092	0.0715	0.1300	0.3305	0.0536	0.1414	0.3529	0.0479
		0.5	0.0295	0.1110	0.0716	0.1414	0.3576	0.0515	0.1419	0.3648	0.0471
		0.75	0.0300	0.1077	0.0715	0.1338	0.3661	0.0493	0.1571	0.3756	0.0482
		0.9	0.0248	0.1068	0.0711	0.1438	0.3575	0.0520	0.1500	0.3713	0.0507
	径向非均匀	0	0.0252	0.1092	0.0715	0.1300	0.3305	0.0536	0.1414	0.3529	0.0479
		0.5	0.0305	0.0962	0.0699	0.1105	0.3139	0.0567	0.1648	0.3830	0.0468

续表

点云预处理	实验类型	参数值	Spin Image			FPFH			Proposed		
			$r_{IR@1}$	$r_{R@5}$	$\varepsilon_{DG@1}$	$r_{IR@1}$	$r_{R@5}$	$\varepsilon_{DG@1}$	$r_{IR@1}$	$r_{R@5}$	$\varepsilon_{DG@1}$
统一点数		0.75	0.0305	0.1071	0.0703	0.1305	0.3248	0.0543	0.1648	0.3705	0.0496
		0.9	0.0295	0.1152	0.0693	0.1300	0.3338	0.0575	0.1571	0.3776	0.0532
	尺度变化	0.5	0.0748	0.2217	0.0619	0.3162	0.5828	0.0140	0.2781	0.5622	0.0186
		0.75	0.0748	0.2217	0.0619	0.3162	0.5824	0.0140	0.2781	0.5622	0.0186
		1	0.0748	0.2217	0.0619	0.3167	0.5828	0.0140	0.2781	0.5622	0.0186
		1.5	0.0748	0.2217	0.0619	0.3167	0.5828	0.0140	0.2781	0.5622	0.0186
		2	0.0748	0.2217	0.0619	0.3167	0.5824	0.0140	0.2781	0.5622	0.0186
	源点保留率	0.8	0.0748	0.2217	0.0619	0.3167	0.5828	0.0140	0.2781	0.5622	0.0186
		0.6	0.0676	0.2022	0.0608	0.3010	0.5913	0.0139	0.2819	0.5534	0.0151
		0.4	0.0710	0.2016	0.0610	0.2957	0.5574	0.0156	0.2781	0.5699	0.0159
		0.25	0.0781	0.2191	0.0580	0.3095	0.5935	0.0141	0.2724	0.5642	0.0182
	梯度非均匀	0	0.0829	0.2300	0.0609	0.3171	0.5954	0.0133	0.2857	0.5624	0.0167
		0.5	0.0652	0.2286	0.0621	0.3133	0.6013	0.0142	0.2805	0.5605	0.0191
		0.75	0.0738	0.2035	0.0629	0.3052	0.5800	0.0144	0.2695	0.5560	0.0194
		0.9	0.0762	0.2195	0.0620	0.3171	0.6238	0.0125	0.2938	0.5681	0.0159
	径向非均匀	0	0.0829	0.2300	0.0609	0.3171	0.5954	0.0133	0.2857	0.5624	0.0167
		0.5	0.0767	0.2249	0.0594	0.2905	0.5664	0.0155	0.2895	0.5615	0.0163
		0.75	0.0752	0.2141	0.0633	0.2757	0.5569	0.0175	0.2729	0.5391	0.0198
		0.9	0.0743	0.1945	0.0626	0.2762	0.5582	0.0166	0.2548	0.5285	0.0207
	体素均衡	0.5	0.2229	0.4624	0.0421	0.6195	0.8310	0.0039	0.5567	0.8290	0.0048
		0.75	0.2229	0.4624	0.0421	0.6200	0.8305	0.0039	0.5567	0.8290	0.0048
		1	0.2229	0.4624	0.0421	0.6190	0.8300	0.0039	0.5567	0.8290	0.0048
		1.5	0.2229	0.4624	0.0421	0.6205	0.8305	0.0039	0.5567	0.8290	0.0048
		2	0.2229	0.4624	0.0421	0.6195	0.8310	0.0039	0.5567	0.8290	0.0048
		0.8	0.2229	0.4624	0.0421	0.6190	0.8300	0.0039	0.5567	0.8290	0.0048
		0.6	0.2305	0.4621	0.0439	0.6257	0.8342	0.0040	0.5633	0.8080	0.0047
		0.4	0.2252	0.4481	0.0426	0.6080	0.8343	0.0042	0.5533	0.8181	0.0049
		0.25	0.1562	0.3786	0.0558	0.5467	0.8010	0.0050	0.5238	0.8067	0.0052
		0	0.2386	0.4581	0.0417	0.6138	0.8295	0.0041	0.5438	0.8229	0.0050
		0.5	0.2419	0.4605	0.0394	0.6286	0.8305	0.0039	0.5729	0.8290	0.0044
		0.75	0.2238	0.4410	0.0433	0.6210	0.8333	0.0041	0.5862	0.8410	0.0044
		0.9	0.2205	0.4571	0.0395	0.6195	0.8433	0.0041	0.5624	0.8538	0.0047
		0	0.2386	0.4581	0.0417	0.6138	0.8295	0.0041	0.5438	0.8229	0.0050
		0.5	0.2248	0.4500	0.0413	0.6205	0.8357	0.0041	0.5833	0.8505	0.0044
		0.75	0.2371	0.4667	0.0419	0.6195	0.8390	0.0040	0.5629	0.8424	0.0048
		0.9	0.2314	0.4576	0.0423	0.6238	0.8343	0.0040	0.5838	0.8352	0.0045

使用内点率 $r_{IR@1}$ 、召回率 $r_{R@5}$ 和描述子几何误差 $\varepsilon_{DG@1}$ 单独作为描述子匹配结果的评价指标。

内点率表示关键点中通过描述子距离得到的第一候选对应落在真实几何邻域范围内的比例，用于

表 6

MVP点云数据配准结果

点云模型	尺度	源点保留率/%	目标点保留率/%	源采样和扰动	算法	$\varepsilon_{\text{nRMSE}}$	ε_{CD}	$\varepsilon_{\text{NRMSE}}/(^{\circ})$	ε_{CR}	$\varepsilon_{\text{RRE}}/(^{\circ})$	ε_{RTE}	$\varepsilon_{\text{s}}/\%$
第1组	1.50	50	80	梯度非均匀0.8	文献[12]	0.143	0.074	51.764	0.088	167.536	0.303	112.643
					文献[8]	0.019	0.002	26.610	0.502	3.057	0.117	9.781
					文献[11]	0.022	0.002	32.330	0.459	7.089	0.116	4.916
					文献[38]	0.025	0.005	33.109	0.487	12.355	0.135	6.533
					文献[39]	0.034	0.006	27.051	0.415	15.066	0.142	8.335
					文献[46]	0.042	0.009	31.199	0.465	10.597	0.129	6.564
					文献[47]	0.033	0.007	30.010	0.407	20.051	0.155	12.335
					本文算法	0.030	0.009	30.583	0.390	176.892	0.162	14.884
第2组	0.50	35	70	随机	文献[12]	0.082	0.030	42.058	0.159	167.605	0.408	25.014
					文献[8]	0.027	0.006	21.151	0.403	19.340	0.044	4.128
					文献[11]	0.012	0.003	13.319	0.744	2.563	0.007	26.840
					文献[38]	0.013	0.004	12.115	0.890	3.046	0.102	24.554
					文献[39]	0.010	0.003	10.589	0.901	3.002	0.075	25.004
					文献[46]	0.012	0.004	11.105	0.885	2.988	0.096	20.053
					文献[47]	0.009	0.003	9.109	0.920	2.198	0.076	11.108
					本文算法	0.006	0.003	7.147	0.951	1.625	0.013	0.648
第3组	2.00	25	60	径向非均匀	文献[12]	0.102	0.028	50.877	0.063	67.669	0.306	2.877
					文献[8]	0.026	0.002	22.903	0.363	10.179	0.020	4.895
					文献[11]	0.030	0.003	29.272	0.307	26.471	0.025	7.851
					文献[38]	0.045	0.004	25.109	0.445	21.775	0.100	5.779
					文献[39]	0.030	0.003	22.198	0.587	15.635	0.073	3.109
					文献[46]	0.043	0.004	26.109	0.527	18.109	0.079	5.443
					文献[47]	0.021	0.003	22.015	0.588	16.035	0.062	3.405
					本文算法	0.009	0.001	20.730	0.795	0.889	0.021	1.554
第4组	1.25	50	80	噪声0.002 离群点5%	文献[12]	0.136	0.070	49.518	0.026	82.196	0.534	71.101
					文献[8]	0.020	0.002	23.104	0.484	11.866	0.102	19.834
					文献[11]	0.023	0.003	27.717	0.417	16.152	0.101	16.309
					文献[38]	0.030	0.004	27.589	0.389	20.355	0.205	16.779
					文献[39]	0.028	0.003	30.005	0.391	23.004	0.153	17.054
					文献[46]	0.029	0.004	28.010	0.405	21.399	0.179	16.805
					文献[47]	0.027	0.002	27.981	0.410	23.452	0.132	16.209
					本文算法	0.024	0.002	27.224	0.406	26.404	0.101	15.084

评估描述子最近邻匹配结果的正确性；召回率表示真实对应点是否能够进入前5个候选匹配集合中的比例，用于评估描述子候选集合对真实对应关系的保留能力；描述子几何误差表示最近邻匹配与真实

对应位置之间的典型距离误差，用于评价描述子第一候选匹配在真实几何空间中的偏离程度。

由尺度变化实验结果可知，本文描述子匹配结果的评价指标值保持不变。这说明当局部邻域采样




图20 第1组点云对不同算法配准效果




图21 第2组点云对不同算法配准效果




图22 第3组点云对不同算法配准效果




图23 第4组点云对不同算法配准效果

集合保持不变时,本文描述子可以有效消除全局尺度变换的影响,理论上的尺度保持性能够直接体现在特征对应上,而不仅体现在最终配准结果中。

随着源点保留率的减小,各描述子性能均出现不同程度下降,说明点数减少及其引起的局部邻域变化会直接影响局部几何描述。例如,在原始点云预处理实验条件下,对于本文特征描述子,当源点保留率由80%下降至25%时,内点率和召回率减小,描述子几何误差增大。该结果与额外的实验邻

域验证结果一致,即当源点保留率下降至25%时,源点云、目标点云的局部邻域相对支撑范围比增大至约1.76,说明源端近邻已经需要覆盖明显更大的局部邻域。本文描述子的理论尺度保持建立在局部邻域几何关系基本稳定的条件下,当点数和空间分辨率显著变化导致邻域成员及支撑范围改变时,描述子性能会受到一定程度的影响。然而,在不同的源点保留率条件下,本文尺度保持的紧凑特征描述子匹配性能整体与FPFH相当,说明在邻域发生一

表 7

消融实验结果

点云模型	源点 保留 率/%	目标 点 保留 率/%	源采样和扰动	实验配置	$\varepsilon_{\text{nRMSE}}$	ε_{CD}	$\varepsilon_{\text{nRMSE}}^{\prime}/$ ($^{\circ}$)	ε_{CR}	$\varepsilon_{\text{RRE}}/(^{\circ})$	ε_{RTE}	$\varepsilon_{\text{s}}/\%$	t/s
Bunny	45	80	梯度非均匀 0.8 噪声 0.0005 离群点 2%	基线实验	0.04126	0.01183	33.851	0.341	103.773	0.36793	21.030	3.314
				V	0.02091	0.00668	21.993	0.496	17.787	0.10223	2.767	4.716
				G	0.02982	0.00923	30.830	0.413	94.002	0.25272	6.948	30.791
				M	0.04003	0.01135	33.488	0.344	100.497	0.35313	20.760	4.625
				G+M	0.03037	0.00962	29.174	0.417	102.085	0.32391	8.251	30.856
				V+M	0.02054	0.00673	21.707	0.499	16.580	0.09214	2.678	6.071
				V+G	0.01981	0.00663	21.411	0.508	17.392	0.09820	2.866	32.576
				V+G+M	0.01960	0.00668	21.096	0.508	16.035	0.08735	2.621	35.286
Dragon	40	70	径向非均匀 0.8 噪声 0.001 离群点 2%	基线实验	0.00687	0.00103	12.141	0.773	2.217	0.02895	1.985	3.525
				V	0.01132	0.00201	16.227	0.699	6.783	0.07985	0.953	4.479
				G	0.00764	0.00117	11.894	0.748	2.541	0.03350	2.696	27.955
				M	0.00594	0.00100	11.100	0.789	1.318	0.01783	1.334	4.644
				G+M	0.00550	0.00098	10.716	0.791	0.716	0.01428	1.730	29.058
				V+M	0.00990	0.00175	14.975	0.712	5.374	0.06378	0.446	6.229
				V+G	0.00578	0.00105	10.073	0.788	1.045	0.01277	1.010	30.937
				V+G+M	0.00493	0.00100	9.516	0.800	0.473	0.00642	0.601	33.083
	40	70	径向非均匀 0.8 噪声 0.002 离群点 5%	基线实验	0.01535	0.00200	21.433	0.627	11.503	0.11162	5.559	3.730
				V	0.00661	0.00126	12.048	0.708	1.708	0.02523	2.141	4.234
				G	0.00780	0.00128	13.649	0.760	2.047	0.03498	3.375	23.633
				M	0.01392	0.00193	19.395	0.660	9.790	0.09917	5.260	4.123
				G+M	0.00654	0.00122	12.266	0.782	0.882	0.02429	2.837	24.463
				V+M	0.00572	0.00124	11.198	0.791	0.815	0.01657	1.834	5.188
				V+G	0.00660	0.00131	11.707	0.775	2.054	0.01958	0.749	24.311
				V+G+M	0.00513	0.00098	9.974	0.799	0.307	0.00695	0.851	27.163
	25	70	径向非均匀 0.9 噪声 0.001 离群点 2%	基线实验	0.00732	0.00104	13.534	0.767	2.011	0.02490	2.119	4.480
				V	0.00802	0.00111	12.994	0.752	2.718	0.03618	1.900	4.953
				G	0.00587	0.00101	11.131	0.792	1.144	0.01286	1.453	29.324
				M	0.00634	0.00101	12.221	0.789	1.354	0.01586	1.373	5.386
				G+M	0.00548	0.00100	10.752	0.797	0.726	0.00767	0.953	26.636
				V+M	0.00718	0.00106	11.970	0.769	2.020	0.02658	1.465	5.765
				V+G	0.00556	0.00098	10.378	0.797	0.659	0.01228	1.243	26.688
				V+G+M	0.00513	0.00098	9.974	0.799	0.307	0.00695	0.851	27.163

定程度改变后，其仍具有较好的实际采样鲁棒性。

在梯度和径向非均匀实验中，源点保留率固定为 45%，该实验不仅改变了点总数，还主要改变点在空间中的分布位置。在原始点云预处理实验条件下的梯度非均匀实验中，当非均匀强度为 0.75 时，

本文描述子匹配结果的内点率和召回率均高于 FPFH；在径向非均匀强度下则优势更为明显，内点率和召回率相较于 FPFH 分别提高约 26% 和 21%。在非均匀采样实验中，随着非均匀强度增加，本文描述子整体保持较好的匹配稳定性。由此

表 8 参数敏感性实验设置

点云模型	尺度	源点 保留率/%	目标点 保留率/%	源采样方式	噪声
Bunny	1.5	45	80	梯度非均匀 0.75	0.0005
ScanNet	1.5	40	65	梯度非均匀 0.85	0.001
MVP	2.0	30	60	径向非均匀 0.80	0.001

表 9 算法参数敏感性实验结果

点云模型	参数	参数值	$\varepsilon_{\text{RRE}}(^{\circ})$	ε_{RTE}	$\varepsilon_s\%$	迭代次数
Bunny	α_h	0.55	42.764	0.084	12.270	51
		0.65	2.988	0.026	3.163	51
		0.72	2.950	0.021	1.535	51
		0.8	6.922	0.049	1.481	51
		0.9	6.810	0.029	1.442	51
	L	1	3.609	0.027	2.505	20
		2	3.419	0.024	1.850	33
		3	2.950	0.021	1.535	51
		4	2.281	0.012	1.356	71
	ScanNet	τ_{Γ}	0.02	0.047	0.000	0.018
0.03			0.047	0.000	0.018	49
0.035			0.047	0.000	0.018	49
0.05			0.047	0.000	0.018	49
0.07			0.047	0.000	0.018	49
α_s		1.05	0.047	0.000	0.018	49
		1.1	0.047	0.000	0.018	49
		1.2	0.047	0.000	0.018	49
		1.3	0.047	0.000	0.018	49
		1.5	0.047	0.000	0.018	49
MVP	η_t	0.008	5.449	0.034	1.712	48
		0.012	1.387	0.022	1.506	41
		0.015	8.671	0.025	1.519	44
		0.02	1.746	0.051	1.432	40
		0.03	28.791	0.023	1.429	42
	δ_s	0.03	3.711	0.034	1.380	47
		0.04	8.854	0.026	1.139	45
		0.05	8.671	0.025	1.519	44
		0.06	9.269	0.026	1.548	38
		0.08	9.452	0.026	1.161	39

表明, 虽然非均匀采样会改变局部邻域支撑范围, 但角度直方图统计、归一化因子和邻域权重使本文

描述子仍可以保留较好的局部几何判别能力。
统一点数实验结果表明统一点数规模本身可以

减小部分采样尺度不一致。进一步经过点数约束体素均衡处理,本文描述子的匹配结果的内点率和召回率均变大、描述子几何误差均减小,说明在点数已经基本相同的条件下,空间密度均衡仍能够带来显著额外收益。由实验结果可知,这一现象并非仅存在于本文描述子,点数约束均衡会对三种几何描述子均产生明显改善,因此其作用并非针对本文描述子的特殊适配,而是对局部空间采样分布的通用均衡。

此外,为了进一步验证几何尺度差异与采样尺度差异同时存在时的性能,将源点保留率和非均匀实验中的全局尺度设置为 1.5,选取 Bunny 和 Dragon 点云模型进行实验,得到了与上述实验相同的总体变化规律。

总体结果表明,当局部邻域组成基本保持时,尺度保持的紧凑特征描述子对几何尺度变化表现出近似不变的特征响应;当点数、分辨率和非均匀采样导致局部邻域发生改变时,描述子性能会受到影响,但仍具有一定的实际鲁棒性。点数约束体素均衡主要改善采样差异造成的局部支撑不一致,通过改善局部采样结构可进一步提高描述子的匹配稳定性。这与整体算法先通过采样密度均衡,再进行尺度保持特征匹配,最后基于候选共识完成全局相似变换估计的设计逻辑一致。

3.9 算法复杂度与效率分析

设原始点云最大点数为 N ,体素化后的点数为 N_0 ,法向估计近邻数为 K ,关键点数为 N_k ,候选对应数为 N_c ,尺度候选数为 L_s ,旋转候选数为 L_r ,候选验证数为 K_c ,精配准总迭代次数为 I ,单层精配准点数为 N_d 。

点数约束体素化预处理可以减小点云规模。在体素迭代次数受限制的情况下,其时间复杂度约为 $O(N)$;法向估计和邻域搜索通过 KD 树实现,复杂度约为 $O(N_0 \log N_0 + N_0 K)$;最远点采样需要在每次选择关键点后更新全部 N_0 个点到已选关键点集合的最小距离,复杂度约为 $O(N_0 N_k)$;尺度保持的紧凑特征描述子主要在局部 K 邻域内统计三组角度直方图,计算复杂度约为 $O(N_0 K)$ 。由于描述子维度固定,通过 KD 树在 N_k 个关键点描述子之间进行软双向近邻匹配,其复杂度约为 $O(N_k \log N_k)$ 。

尺度投票由随机候选点对产生,尺度观测计算

和直方图累积的复杂度为 $O(N_s)$;旋转候选生成主要包括主成分分析主轴映射、点对方向一致性、几何框架和三元组估计,其复杂度可记为 $O(L_r N_c)$;对于每组尺度候选和选择候选,需要根据候选对应生成平移向量,并执行三维网格划分、排序和投票。单组相似变换假设的复杂度约为 $O(N_c \log N_c)$,因此全部尺度和旋转组合的三维平移投票复杂度为 $O(L_s L_r N_c \log N_c)$;候选验证需最近邻搜索,复杂度约为 $O(K_c N_0 \log N_0)$;多分辨率精配准的复杂度约为 $O(IN_d \log N_d)$ 。

因此,算法总体时间复杂度可表示为

$$O(N + N_0 \log N_0 + N_0 K + N_0 N_k + N_k \log N_k + N_s + L_r N_c + L_s L_r N_c \log N_c + K_c N_0 \log N_0 + IN_d \log N_d)$$

当 K , L_s , L_r 和 K_c 由参数限制在固定范围内时,算法计算量主要来自候选投票和多分辨率最近邻迭代影响。其中,三维平移投票需要对 $L_s L_r$ 组合重复处理候选对应,其复杂度包含 $L_s L_r N_c \log N_c$ 项,因此在候选数量较多时具有较大的实际计算开销。

为了进一步定位计算瓶颈,对算法内部各阶段进行独立计时。实验表明实际运行时间与上述分析一致。在 Bunny、Dragon、ScanNet 和 MVP 点云数据配准任务中,三维平移投票时间分别为 31.249s, 30.526s, 33.785s, 24.748s, 分别占算法总运行时间的 82.87%、84.70%、80.11% 和 88.69%,明显高于其他计算阶段,说明当前实现的主要瓶颈集中于尺度、旋转组合下的平移候选生成和网格投票。相比之下,特征计算与匹配占比较低,多分辨率精配准约占总时间的 3.62%~9.37%。此外,相较于已有算法虽时间开销较大但更加鲁棒,更能应对对配准精度有较高要求的场景,且无需大量训练数据和深度学习算法存在的数据泛化能力问题。尽管如此,后续研究将重点考虑从候选压缩、平移投票并行化和 GPU 加速等方面提高算法效率。

此外,相比构造稠密对应图的 $O(N_c^2)$ 方法,本文通过候选采样和三维网格投票降低了空间复杂度,整体空间复杂度约为 $O(N_0 + N_c + L_s L_r)$ 。

4 结束语

本文提出了一种基于候选共识和多分辨率迭代

的异尺度点云配准算法,针对点云整体尺度、采样密度、分辨率和部分重叠差异,构建了尺度保持特征、尺度、旋转、平移共识估计和尺度锚定精配准的配准流程。实验表明了该方法在多种数据集上具有较好的鲁棒性,下一步将围绕强对称和严重缺失点云、候选数量压缩和平移投票并行化改进算法以提升其性能。

参考文献:

- [1] 杨军, 党吉圣. 基于上下文注意力 CNN 的三维点云语义分割[J]. 通信学报, 2020, 41(7): 195-203.
- [2] 鲁斌, 孙洋, 杨振宇. 基于原始点云网格自注意力机制的三维目标检测方法[J]. 通信学报, 2023, 44(10): 72-84.
- [3] 李鹏飞, 韩磊. 无人机影像联合 LiDAR 点云的城市建筑三维建模[J]. 激光与红外, 2026, 56(2): 197-201.
- [4] Yan D L, Wang W W, Li S H, et al. A Speedy Point Cloud Registration Method Based on Region Feature Extraction in Intelligent Driving Scene [J]. Sensors (Basel, Switzerland), 2023, 23(9): 4504.
- [5] 赵夫群, 耿国华. 基于特征区域划分的文物碎片自动匹配算法[J]. 电子学报, 2022, 50(6): 1436-1443.
- [6] Guo Z T, Ma H B. Enhanced point cloud registration for workpieces using triangular constraint sampling consistency in complex industrial environment[J]. The Visual Computer, 2026, 42(5): 221-221.
- [7] 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.
- [8] Abbas M, Elhamshary M, Rizk H, et al. WiDeep: WiFi-based accurate Zinßer T, Schmidt J, and Niemann H. Point set registration with integrated scale estimation[C]//International conference on pattern recognition and image processing, 2005, 116-119.
- [9] 孙水发, 李准, 夏坤, 等. 变尺度点云配准算法[J]. 系统仿真学报, 2018, 30(7): 2465-2474.
- [10] 张顺利, 徐艳芝, 周明全, 等. 基于自适应邻域匹配的点云配准方法[J]. 计算机学报, 2019, 42(9): 2114-2126.
- [11] 王玉文, 李珊君, 杨赞秀, 等. 基于有向包围盒的尺度点云配准算法[J]. 激光杂志, 2022, 43(1): 12-18.
- [12] 范怡萍, 葛宝臻, 陈雷. 基于人工蜂群优化的异尺度点云配准算法[J]. 激光与光电子学进展, 2023, 60(12): 246-255.
- [13] 师芸, 闫永智. 改进迭代最近点的异尺度点云配准算法[J]. 激光与光电子学进展, 2025, 62(22): 295-303.
- [14] 蒋悦, 黄宏光, 舒勤, 等. 高维正交子空间映射的尺度点云配准算法[J]. 光学学报, 2019, 39(3): 290-300.
- [15] Z heng Z, Fan J F, Shao L, et al. Robust Point Cloud Registration via Geometric Overlapping Guided Rotation Search[J/OL]. arXiv preprint arXiv: 2508. 17427, 2025.
- [16] Yang J Q, ZHANG C A, WANG Z B, et al. 3registration inD 30 years: A survey[J/OL]. arXiv preprint arXiv: 2412. 13735, 2024.
- [17] Arun K S, Huang T S, Blostein S D. Least-squares fitting of two 3-d point sets[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1987, 9(5): 698-700.
- [18] Horn B K P. Closed-form solution of absolute orientation using unit quaternions[J]. Journal of the Optical Society of America A, 1987, 4(4): 629-642.
- [19] Umeyama S. Least-squares estimation of transformation parameters between two point patterns[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1991, 13(4): 376-380.
- [20] Ying S, Peng J, Du S, et al. A scale stretch method based on ICP for 3D data registration[J]. IEEE Transactions on Automation Science and Engineering, 2009, 6(3): 559-565.
- [21] Du S Y, Zhu J H, Zheng N N, et al. Isotropic scaling iterative closest point algorithm for partial registration[J]. Electronics Letters, 2011, 47(14): 799-800.
- [22] Du S Y, Zheng N N, Xiong L, et al. Scaling iterative closest point algorithm for registration of m -D point sets[J]. Journal of Visual Communication & Image Representation, 2010, 21(5-6): 442-452.
- [23] Lin B W, Tamaki T, Raychev B, et al. Scale ratio ICP for 3D point clouds with different scales[C]//2013 IEEE International Conference on Image Processing, Piscataway: IEEE Press, 2013: 2217-2221.
- [24] Xu S Y, Zhu J H, Li Y C, et al. Effective scaling registration approach by imposing emphasis on scale factor[J]. Electronics Letters, 2018, 54(7): 422-424.
- [25] Wu Z Z, Chen H C, Du S Y, et al. Correntropy based scale ICP algorithm for robust point set registration[J]. Pattern Recognition, 2019, 93: 14-24.
- [26] Sahillioglu Y, Kavan L. Scale-Adaptive ICP[J]. Graphical Models, 2021, 116: 101113.
- [27] Lv C L, Lin W S, Zhao B Q. KSS-ICP: point cloud registration based on kendall shape space[J]. IEEE Transactions on Image Processing, 2023, 32: 1681-1693.
- [28] Mellado N, Dellepiane M, Scopigno R. Relative scale estimation and 3D registration of multi-modal geometry using Growing Least Squares [J]. IEEE Transaction on Visualization and Computer Graphics, 2016, 22(9): 2160-2173.
- [29] Lim J, Lee K. 3D object recognition using scale-invariant features[J]. The Visual Computer: International Journal of Computer Graphics, 2019, 35(1): 71-84.
- [30] Bülow H, Birk A. Scale-free registrations in 3D: 7 Degrees of freedom with Fourier Mellin SOFT transforms[J]. International Journal of Computer Vision, 2018, 126(7): 731-750.
- [31] Sun M C, Pinosky A, Abraham I, et al. Scale-Invariant Fast Functional Registration[J/OL]. arXiv preprint arXiv: 2209. 12763, 2022.
- [32] Yang H, Shi J N, Carlone L. TEASER: Fast and certifiable point cloud registration[J]. IEEE Transactions on Robotics, 2021, 37(2): 314-33.
- [33] Sun L. IRON: invariant-based highly robust point cloud registration[J/OL]. arXiv preprint arXiv: 2103. 04357, 2021.
- [34] Li J Y, Hu Q W, Ai M Y. point cloud registration based on one-point RANSAC and scale-annealing biweight estimation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(11): 9716-9729.
- [35] Wang Y, Solomon J M. Deep closest point: Learning representations for point cloud registration[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Los Alamitos: IEEE Computer Society Press, 2019: 3522-3531.
- [36] Yew Z J, Lee G H. RPM-Net: Robust point matching using learned features[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2020: 11821-11830.

- [37] Bai X Y, Luo Z X, Zhou L, et al. PointDSC: Robust point cloud registration using deep spatial consistency[J/OL]. arXiv preprint arXiv: 2103.05465, 2021.
- [38] Qin Z, Yu H, Wang C J, et al. GeoTransformer: fast and robust point cloud registration with geometric transformer[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(8): 9806-9821.
- [39] Gao J, Zhang Y H, Liu Z H, et al. HDRNet: High-dimensional regression network for point cloud registration[J]. Computer Graphics Forum, 2023, 42(1): 33-46.
- [40] Qi C R, Yi L, Su H, et al. PointNet++: Deep hierarchical feature learning on point sets in a metric space[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc, 2017: 5105-5114.
- [41] Rusu R B, Blodow N, Beetz M. Fast point feature histograms (FPFH) for 3D registration[C]//Proceedings of the IEEE International Conference on Robotics and Automation. Los Alamitos: IEEE Computer Society Press, 2009: 3212-3217.
- [42] Chetverikov D, Stepanov D, Krsek P. Robust Euclidean alignment of 3D point sets: the trimmed iterative closest point algorithm[J]. Image and Vision Computing, 2005, 23(3): 299-309.
- [43] Curless B, Levoy M. A volumetric method for building complex models from range images[C]//Proceedings of the 23rd Annual Conference on Computer Graphics and Interactive Techniques. New York, NY, USA: ACM, 1996: 303-312.
- [44] Dai A, Chang A X, Savva M, et al. ScanNet: Richly-annotated 3D Reconstructions of Indoor Scenes[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2017: 5828-5839.
- [45] Pan L, Chen X Y, Cai Z G, et al. Variational relational point completion network[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 8524-8533.
- [46] Xu S, Shang Y L. ScaleLK: Registration of point clouds with different scales using deep learning methods[C]//IOP Conference Series: Materials Science and Engineering, 2020, 768: 072089.
- [47] Slimani K, Tamadazte B, Achard C. LoGDesc: local geometric features aggregation for robust point cloud registration[C]//Asian Conference on Computer Vision (ACCV), 2024: 402-418.
- [48] Dimitrov D, Knauer C, Kriegel K, et al. Bounds on the quality of the PCA bounding boxes[J]. Computational Geometry, 2009, 42(8): 772-789.
- [49] Johnson A E, Hebert M. Using spin images for efficient object recognition in cluttered 3D scenes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1999, 21(5): 433-449.



赵夫群 (1982—), 女, 山东临沂人, 博士, 西安财经大学教授, 主要研究方向为图形图像处理、计算机视觉和三维重建。



崔泽豪 (2000—), 男, 陕西咸阳人, 西安财经大学硕士生, 主要研究方向为三维点云数据处理、计算机视觉和人工智能。



周明全 (1954—), 男, 陕西西安人, 硕士, 西北大学教授、博士生导师, 主要研究方向为虚拟现实与计算机可视化技术、智能信息处理和模式识别。