

基于多特征关键点提取与相似三角形优化点云的点云配准

涂浩文^{1,2,3}, 吴建华^{1,2,3}, 王渊^{1,2}

1. 江西师范大学 地理与环境学院, 南昌 330022;

2. 联合国教科文组织国际自然与文化遗产空间技术中心南昌分中心, 南昌 330022;

3. 江西师范大学 语言空间信息科学研究中心, 南昌 330022

摘要: 现有点云配准算法中点特征计算通常采用固定邻域, 难以适用复杂点云的特征计算, 导致关键点提取结果较差且对应点中存在大量外点等问题, 进而影响点云配准的精度。为此, 本文提出一种基于多特征关键点提取与相似三角形优化点云的点云配准方法, 其核心在于通过自适应邻域策略来提取关键点, 并对匹配相似度模型进行了优化。首先采用体素下采样和混合滤波对数据进行预处理, 根据特征熵函数确定点云最优邻域, 结合邻域内法向量夹角标准差、各向异性、曲率提取关键点; 其次利用方向直方图 (SHOT) 计算关键点特征; 然后采用双向最近邻距离比 (BNDR) 构建初始匹配点对, 并提出一种基于相似三角形的计算模型优化点对完成粗配准。最后, 采用添加法向量夹角约束的点平面迭代最近点 (Point to plane ICP) 算法实现精配准。本文选取 Stanford 数据集进行实验, 结果表明, 与经典 ICP、基于关键点的 4 点一致性集 (K-4PCS) 和采样一致性 (SAC-IA) 结合 ICP 的点云配准算法相比, 本文方法的误差最小。此外, 在实测数据配准应用中本文方法也展现出了显著的优势。

关键词: 遥感, 自适应邻域, 点云配准, 相似三角形, 点到平面 ICP

中图分类号: P237/P2

引用格式: 涂浩文, 吴建华, 王渊. 2025. 基于多特征关键点提取与相似三角形优化点云的点云配准. 遥感学报, 29(12): 3706–3722

Tu H W, Wu J H and Wang Y. 2025. A point cloud registration method using multi-feature keypoint extraction and similar triangle-based point pair optimization. National Remote Sensing Bulletin, 29 (12) : 3706–3722 [DOI: 10.11834/jrs.20254532]

1 引言

随着计算机视觉和三维激光扫描技术的快速发展, 点云作为一种重要的三维数据, 已被广泛应用于智慧交通 (Zhang 等, 2022a)、形变监测 (Luo 等, 2022)、三维重建 (Huang 等, 2024) 和文物数字化 (Yang 等, 2023) 等多个领域。然而, 受限于激光扫描设备视角单一且物体形状的复杂, 单次扫描往往难以捕捉物体的全貌, 易受到环境噪声干扰, 导致点云数据在完整性上存在显著不足。为解决这一问题, 点云配准技术应运而生, 其核心在于通过算法精确对齐和融合来自不同视角或不同传感器的点云数据, 从而构建出完整的

三维模型。因此, 研究高精度、高鲁棒性的点云配准方法具有重要意义。

点云配准旨在将不同坐标系下采集的点云数据变换到统一的坐标系中 (杨佳琪 等, 2022), 主要分为传统方法与基于学习的方法。传统方法又包括局部特征配准与全局配准。本文采用传统的由粗到精的局部特征方法进行点云配准。在粗配准阶段, Xu 等 (2021) 将固有形状特征 (ISS) 与 3D 形状上下文 (3DSC) 描述子相结合, 并利用随机抽样一致性 (RANSAC) 算法进行粗配准, 最终配准精度与速度取得了不错的效果。王文博等 (2022) 提出将古建筑点云分块后提取尺度不变特征转换 (SIFT3D) 关键点, 并采用快速点特征

收稿日期: 2024-11-22; 预印本: 2025-08-14

基金项目: 国家自然科学基金 (编号: 41561084, 41201409); 江西省自然科学基金 (编号: 20242BAB21014, 20252BAC240107); 江西省教育厅研究生创新基金 (编号: YC2023-S219)

第一作者简介: 涂浩文, 研究方向为点云配准与建模。E-mail: tuhaowen0204@126.com

通信作者简介: 吴建华, 研究方向为空间数据智能集成、地理信息工程、语言空间智能。E-mail: wjhgis@126.com

直方图 (FPFH) 进行特征描述, 使用采样一致性 (SAC-IA) 算法实现粗配准, 该算法适用于重叠率较低的点云, 精度较高。刘如飞等 (2022) 提出一种多尺度关键点提取方法, 首先建立多尺度邻域搜索半径, 在不同尺度下根据特征值属性、主曲率、形状指数逐步筛选提取关键点, 再利用 4 点一致性集 (4PCS) 完成粗配准。上述算法虽然精度较高, 但却普遍存在一个不足之处: 其关键点提取过程依赖于人为经验来设定邻域范围。如果邻域范围设置不当, 可能会导致无法准确捕捉点云表面几何结构信息。近年来, 许多学者相继提出自适应的点云关键点提取方法, 旨在更精确地获取局部细节关键点。例如, Jia 等 (2023) 首先计算每个点法向量与其邻域内法向量的投影距离提取潜在关键点, 再规定初始邻域半径, 根据点云局部特征与邻域半径之间的数学表达式, 自适应地调整各点的邻域大小, 再对潜在关键点进行聚类, 以提取最终关键点, 但计算方法较为复杂。王明军等 (2022) 提出利用加权协方差矩阵求解出表面变化因子, 设置尖锐与平坦部位的阈值大小提取出关键点, 再利用 FPFH 与 RANSAC 进行粗配准, 取得了较好的鲁棒性, 但该方法最终并未探究非同源点云之间的配准问题。另外在为所有关键点建立对应关系后, 不可避免地会出现错误匹配点对, 需将这些错误关系进行剔除。李宇翔等 (2020) 将 ISS 与方向直方图 (SHOT) 描述子相结合, 利用余弦相似度构建初始匹配点对, 再用 RANSAC 剔除错误点对, 但使用余弦相似度构建初始点对只考虑了特征向量方向上的差异, 并未考虑局部几何一致性因素。张少杰等 (2019) 提出点间距离构建近似全等三角形, 并利用曲面变分筛选近似全等三角形, 最终找到满足条件的匹配点对。

在精配准阶段, Besl 和 McKay (1992) 提出了经典的 ICP 算法, 但该算法高度依赖较好的初始位姿, 存在易陷入局部最优解以及收敛速度过慢的问题。针对 ICP 算法易陷入局部最优解的问题, Chetverikov 等 (2002) 提出修剪迭代最近点 (TrICP), 引入正则化项和修剪策略减少错误点对的干扰, 适用于较高重叠率的点云。Yang 等 (2013) 使用八叉树数据结构将点云空间划分为多个子空间, 利用分支定界原则细分出满足条件的子空间, 进而找到最优变换, 这种方法称为 GO-ICP, 但未

解决初始位姿问题。在解决 ICP 算法收敛速度过慢问题时, Zhu 等 (2019) 把两两配准问题拓展成为一种聚类问题。即使用 k -means 聚类的算法简化 ICP 算法的初始点对, 从而显著减少了计算时间。Zhang 等 (2022b) 提出一种快速且鲁棒的 ICP 算法, 将 Anderson 加速算法最大化—最小化策略与 ICP、甚至点到平面 ICP (Point to plane ICP) 结合, 提高了配准的收敛速度与鲁棒性。

综上所述, 传统方法在点云关键点提取的精确性、错误对应关系的有效剔除以及配准的精度上存在一定的不足。针对这些问题, 本文创新性地提出一种基于多特征关键点提取与相似三角形优化点云的点云配准方法。该算法可有效提高关键点提取的精确性, 解决传统点云配准算法对初始位姿的依赖性, 进一步提升配准的鲁棒性, 并可应用于非同源点云之间的配准, 为目前点云配准技术的发展提供了新的思路和方法。

2 点云配准算法

2.1 算法流程

本文提出的点云配准方法流程如图 1 所示。主要包括 3 个核心内容: (1) 数据预处理: 鉴于点云数据量较大、存在噪声点和地面点, 本文采用体素下采样的方法降低点云数据量, 采用混合滤波 (统计滤波和布料模拟滤波) (Zeybek 和 Şanlıoğlu, 2019) 去除噪声点和地面点。(2) 点云粗配准: 首先提出了一种结合邻域内法向量夹角标准差、各向异性、曲率 (Standard Deviation of Normal Vectors' Angles-Anisotropy and Curvature, 以下简称 SDNVA-AC) 的方法自适应提取关键点, 并对提取的关键点计算 SHOT 特征描述, 通过 BNDR 构建源点云和目标点云之间的初始匹配点对, 并提出一种基于相似三角形优化匹配点对的方法, 最后采用 SVD (奇异值分解) 完成粗配准。(3) 点云精配准: 利用添加法向量夹角约束条件的 Point to plane ICP 算法完成精配准。

2.2 基于自适应邻域的关键点提取方法

点云局部邻域包含了丰富的信息, 包括法向量、曲率变化以及梯度分布等, 这些局部信息能够有效刻画点云特征。传统的邻域搜索方法包括 k 近邻搜索和固定半径搜索, 但二者在鲁棒性和适应性上均存在不足。其中, k 近邻搜索存在对点密

度不鲁棒、固定半径搜索无法适用于复杂点云等劣势，二者均难以保证关键点提取的精确性。因此，本文设计了一种基于自适应邻域的关键点提

取方法 (SDNVA-AC)，使用邻域内最小特征熵计算最优邻域，根据自适应邻域计算法向量夹角、各向异性和曲率特征，从而优化关键点提取。




图1 算法流程图

Fig. 1 The flow of algorithm

2.2.1 基于局部特征熵的最优邻域计算

由于点云中每个采样点几何特征的精确计算高度依赖于其局部邻域内的点集，因此通过确定最优邻域能够显著提升几何特征的计算精度。三维空间中协方差矩阵能够反映数据在不同方向上的分布集中趋势及其相互间的关联性。这一过程也称主成分分析法 (Abdi 和 Williams, 2010)。三维空间中任一点的法向量可由协方差矩阵的特征向量计算得出，由于点云形状的非规则性，邻域的大小直接影响法向量的方向。如图2所示，在曲面非尖锐区域 (点A处)，即平坦部分，图2中局部邻域内虽有波动，但整体趋于平缓，此时使用较大邻域计算得出的法向量更能反映真实方向。在点云曲面尖锐区域 (点B处)，即尖锐部分，用较小邻域可反映正确的法向量，而在较大邻域内法向量方向发生改变，显然不能反映正确的法向量方向。因此尖锐区域适合较小邻域。




图2 不同邻域内法向量变化情况

Fig. 2 The variation of normal vectors in different neighborhoods

为了确定最优的邻域，本文首先对点云建立KD-Tree，并设定初始半径 r_0 和搜索步长 Δr ，构建

半径集合 $(r_0, r_1, r_2, \dots, r_i)$ 。其中 $r_i = r_{i-1} + \Delta r$ ，且 $r_i < r_{\max}$ 。假设点云中任意点 p_i ，其邻域内的点 $p_{i1}, p_{i2}, p_{i3}, \dots, p_{ik}$ ，由式 (1) 计算协方差矩阵。

$$\mathbf{Cov} = \frac{1}{k} \sum_{j=1}^k (p_{ij} - \bar{p}_i)(p_{ij} - \bar{p}_i)^T \quad (1)$$

式中， $\bar{p}_i = \frac{1}{k} \sum_{j=1}^k p_{ij}$ 为邻域的重心。

对协方差矩阵 $\mathbf{Cov}$ 进行特征值分解，得到特征值 $\lambda_1, \lambda_2, \lambda_3$ ($0 < \lambda_3 \leq \lambda_2 \leq \lambda_1$)，最小特征值对应的特征向量即为法向量。之后引入局部特征熵函数 (Demantké 等, 2012)，如式 (2) 所示：

$$E_\lambda = -\lambda_1 \ln(\lambda_1) - \lambda_2 \ln(\lambda_2) - \lambda_3 \ln(\lambda_3) \quad (2)$$

在点云维度特征函数理论 (Weinmann 等, 2014) 中，特征值有以下特性：

- (1) 当 $\lambda_1 \gg \lambda_2, \lambda_3 \approx 0$ 时，表示一维线性特征。
- (2) 当 $\lambda_1, \lambda_2 \gg \lambda_3 \approx 0$ 时，表示二维平面特征。
- (3) 当 $\lambda_1 \approx \lambda_2 \approx \lambda_3$ 时，表示三维曲面特征。

根据特征值的特性，建立维度特征函数 a_{1D} 、 a_{2D} 和 a_{3D} ，三者分别反映局部邻域内点云的线性、平面、曲面3种特征，该函数如式 (3) 所示。

$$\begin{cases} a_{1D} = \frac{\sqrt{\lambda_1} - \sqrt{\lambda_2}}{\sqrt{\lambda_1}} \\ a_{2D} = \frac{\sqrt{\lambda_2} - \sqrt{\lambda_3}}{\sqrt{\lambda_1}} \\ a_{3D} = \frac{\sqrt{\lambda_3}}{\sqrt{\lambda_1}} \end{cases} \quad (3)$$

式中， $a_{1D} + a_{2D} + a_{3D} = 1$ 。结合式 (2) 和式 (3) 可得局部特征熵表达式：

$$E_f = -(a_{1D} \ln(a_{1D}) + a_{2D} \ln(a_{2D}) + a_{3D} \ln(a_{3D})) \quad (4)$$

由式 (4) 可知, E_f 越小, 该点云属于某一维度特征的可能性相较于其他两种维度特征更大, 表明点云在该邻域范围内的几何形状分布更为一致, 因而更加准确地反映其局部几何结构。此时 E_f 所对应的邻域半径即为最优邻域半径 R_{optimal} 。

Weinmann 等 (2014) 指出, 由于实际的点云形状较为复杂, 仅使用 a_{1D} 、 a_{2D} 和 a_{3D} 3 个特征提取信息不够精确, 为了更好的提取特征, 直接使用特征值表达式作为 E_f 的参数。如式 (5), 通过 3 个特征值的和对各个特征值进行归一化。该方法能够弥补原始维度特征函数的局限性, 从而提供更多点云局部结构的细节, 能够有效区分相似的维度特征。因此, 本文使用该方法确定最优邻域。

$$E_f = -\sum_{i=1}^3 e_i \ln(e_i) \quad (5)$$

式中, $e_i = \lambda_i / \sum \lambda_i$ 表示求和为 1 的归一化特征值。

2.2.2 SDNVA-AC 关键点提取

体素下采样后的点云规模仍然较大, 采用全部点进行配准计算成本高, 需要提取点云表面特征明显的点进行配准。常见的点云关键点提取方法在处理曲面尖锐特征时提取的点数量有限, 难以有效区分某些关键区域。因此本文遵循一种曲面尖锐区域点数较多, 而曲面非尖锐区域点数较少的原则, 用以区分尖锐与平坦区域。以此设计一种基于多种几何形态特征提取关键点的方法。根据 2.2.1 节理论, 在尖锐区域的局部邻域内, 采样点与其邻域内其它点的法向量夹角显著偏离 0 度, 反之在平坦或光滑区域, 法向量夹角应无限趋近于 0 度, 表明表面变化平缓。在根据最小特征熵得到最优半径后, 为了更精细地刻画邻域内点与采样点之间的空间关系, 提升法向量估计的精确度和鲁棒性。本文引入高斯距离权重机制, 该权重服从高斯分布, 自动为距离较近的邻域点赋予更高的权重, 距离较远的点赋予较低的权重。该方法不仅增强了局部特征的敏感性, 还有效抑制了噪声和远距离点对结果的干扰。另外点云协方差矩阵的特征值可表示多种特征。其中各向异性 A_λ 量化了点云表面的起伏程度, 表面曲率 C_λ 反映了局部区域的弯曲细节, 二者计算方法如式 (6) 所示。本文将二者进行组合, 针对不同的曲面区域, 计算不同的特征, 以捕捉各点中的显著几何特性, 增强关键点提取的灵活性。

$$\begin{cases} A_\lambda = \frac{\lambda_1 - \lambda_3}{\lambda_1} \\ C_\lambda = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} \end{cases} \quad (6)$$

本文提出的 SDNVA-AC 关键点提取的流程图如图 3 所示。




图 3 SDNVA-AC 关键点提取流程图

Fig. 3 The keypoint extraction flow chart of SDNVA-AC

算法具体流程如下:

(1) 首先为点云 P 中每个点 p_i 建立局部坐标系, 根据最小特征熵计算最优邻域半径。

(2) 以每个 p_i 为中心, R_{optimal} 为半径进行邻域搜索, 计算 R_{optimal} 内每一点 p_j 的加权协方差矩阵, 计算公式为式 (7)。

$$Cov = \frac{\sum_{|p_i - p_j| < R} w_{ij} (p_{ij} - \bar{p}_i)(p_{ij} - \bar{p}_i)^T}{\sum_{|p_i - p_j| < R} w_{ij}} \quad (7)$$

式中, 权重 w_{ij} 的计算公式为 $w_{ij} = e^{-\frac{\|p_i - p_j\|^2}{2\sigma^2}}$ 。再根据协方差矩阵得到的特征值按从小到大的顺序进行排序 $\{\lambda_3, \lambda_2, \lambda_1\}$, 最小特征值所对应的特征向量即为法向量。

(3) 由于法向量具有二义性, 故需要对法向量进行一致化处理, 以确保后续处理的准确性和一致性。

(4) 依据式 (8) 计算每个采样点与其邻域内其他点法向量夹角的均值, 进而求得标准差, 归

一化后设定阈值, 并区分曲面尖锐区域与曲面非尖锐区域。

$$\delta = \mu + \omega\sigma \quad (8)$$

式中, μ 为法向量夹角的均值、 ω 为系数、 σ 为标准差。设定 α 为阈值, 如果 $\delta > \alpha$ 则称为曲面尖锐区域, 反之称为曲面非尖锐区域。

(5) 对于曲面尖锐区域, 计算所有点的各向异性值 A_λ , 并将 A_λ 值从大到小排序, 设定百分比阈值 β , 取前 $\beta\%$ 的各向异性值所对应的点为候选关键点。

(6) 考虑到某些光滑表面 (如球体), 只提取曲面尖锐区域的点可能存在点较少的情况, 因此, 对于曲面非尖锐区域, 计算所有点的表面曲率值 C_λ , 并进行非极大值抑制, 得到的点为候选关键点。

(7) 综合上述两类候选关键点, 得到最终的关键点。

2.3 粗配准

2.3.1 构建初始匹配点对

由于点云本质上是一种离散、非结构化的数据, 易受环境噪声、物体遮挡等多种外部因素的干扰。故直接使用关键点构建源点云与目标点云之间的对应关系往往不够稳健, 因此引入 SHOT 特征描述子 (Salti 等, 2014), 增强其特征表达的鲁棒性。SHOT 是一种局部直方图描述子, 其计算步骤如下:

(1) 对提取到的关键点构建协方差矩阵 M , 其中 d 表示邻域内点到质心 $\bar{p}_i$ 的距离。

$$M = \frac{\sum_{d < R} (r - d)(p_{ij} - \bar{p}_i)(p_{ij} - \bar{p}_i)^T}{\sum_{d < R} (r - d)} \quad (9)$$

(2) 对 M 求解特征值 (λ_1 、 λ_2 、 λ_3) 和特征向量 (v_1 、 v_2 、 v_3), 特征向量分别代表 x 、 y 、 z 轴。

(3) 以每个 p_i 为中心, 建立以 r 为半径的球形邻域, 将球形坐标系从半径、经度、纬度 3 个维度划分为 32 个区域, 如图 4 所示。




图 4 SHOT 描述子结构

Fig. 4 The description substructure of SHOT

(4) 计算 32 个子空间中每个采样点及其邻域点之间的法向量夹角余弦。

(5) 统计各个子区域内夹角余弦值。将余弦值的取值范围划分为 11 个 bin (区间), 再将每个子区域的 bin 组合在一起, 形成 $11 \times 32 = 352$ 的特征向量。

对关键点进行 SHOT 特征描述后, 本文采用 BNDR (熊风光, 2018) 的方法进行特征匹配, 构建点云初始匹配点对。该方法可有效建立源点云与目标点云之间的一一对应关系, 为精配准提供良好的初始位姿。其原理如下:

设源点云描述子值的集合为 $D_s = \{d_{s1}, d_{s2}, \dots, d_{sk}\}$, 目标点云描述子值的集合为 $D_t = \{d_{t1}, d_{t2}, \dots, d_{tk}\}$, 分别对应的关键点集合为 $P_s = \{p_{s1}, p_{s2}, \dots, p_{sk}\}$ 和 $Q_t = \{q_{t1}, q_{t2}, \dots, q_{tk}\}$, 其中 k 是点云的数量。首先进行正向搜索: 针对 D_t 中的任一描述子在 D_s 中搜索与其距离最近和次近的描述子 d_{sk} 、 d'_{sk} 。设定阈值 τ , 如果 $d_{sk}/d'_{sk} < \tau$, 则进行逆向搜索: 针对 D_s 中的任一描述子在 D_t 中搜索与其距离最近和次近的描述子 d_{tk} 、 d'_{tk} 。如果 $d_{tk}/d'_{tk} < \tau$ 且 d_{sk} 和 d_{tk} 描述子所对应的关键点为同一关键点, 表明关键点为一对匹配点, 即内点。重复上述过程, 直到找到所有匹配的内点。

2.3.2 基于相似三角形优化匹配点对

根据上述方法获取的内点中仍有很多错误的匹配点, 即外点。本文采取几何一致性的方法剔除外点, 从而提高配准精度。具体步骤如下: 首先设计了一种基于相似三角形优化点对的模型, 然后通过三角形相似性比较, 有效优化匹配点对, 最后利用 SVD 分解完成粗配准。

在点云配准中, 若两个点被判定为内点, 则它们相邻的内点之间应当展现出近似相等的拓扑关系。根据空间解析几何原理可知, 两个完全相等的三角形所对应的 3 条边和 3 个角度完全相等, 这样的三角形被称为全等三角形, 并且具有旋转、平移、翻折不变性。本文将这一概念引入点云中, 对点云建立三角形拓扑关系后, 可将两个三角形的 3 个顶点建立一一一对应关系。然而, 在实际的三维空间中, 找到完全相等的两个三角形的概率较低, 故只能找到近似相等的两个三角形, 即相似三角形。本文结合相似三角形的性质, 构建了一种相似度计算模型, 用以衡量通过 BNDR 方法建立的

内点（以下称为初始匹配点对）的可靠性，通过计算点对间对应三角形结构的相似度，剔除外点。算法具体计算步骤如下：

(1) 首先提取所有初始匹配点对，并在其中随机选取一组内点对，记为 A_i 、 A'_i 。分别找寻与 A_i 、 A'_i 最邻近以及次邻近的点，记为 (B_i, C_i) 、 (B'_i, C'_i) 。其中 B_i 与 B'_i 是一组内点对、 C_i 与 C'_i 也是一组内点对。由 (A_i, B_i, C_i) 和 (A'_i, B'_i, C'_i) 建立相似三角形，记为 $\Delta A_i B_i C_i$ 、 $\Delta A'_i B'_i C'_i$ 。如图5所示。



图5 相似三角形示意图

Fig. 5 The diagram of similar triangle

(2) 如果两个三角形相似，其对应边、对应角应该近似相等。设 A_i 与 B_i 、 B_i 与 C_i 、 C_i 与 A_i 之间的距离为 d_{i1} 、 d_{i2} 、 d_{i3} ， A'_i 与 B'_i 、 B'_i 与 C'_i 、 C'_i 与 A'_i 之间的距离为 d'_{i1} 、 d'_{i2} 、 d'_{i3} ，由式 (10) 计算距离：

$$d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2 + (z_i - z_j)^2} \quad (10)$$

式中， (x, y, z) 是内点的坐标。

之后根据余弦定理分别计算两边 $(A_i B_i$ 与 $A'_i B'_i$ 、 $A_i C_i$ 与 $A'_i C'_i$) 的夹角 θ_i 、 θ'_i 。下面由式 (11) 给出 θ_i 的计算方法， θ'_i 同理可得。

$$\theta_i = \arccos\left(\frac{d_{i2}^2 + d_{i3}^2 - d_{i1}^2}{2d_{i2}d_{i3}}\right) \quad (11)$$

(3) 根据标准差的定义，较小的标准差表明数据分布更为集中，即数据点之间更为相似。因此，将标准差与相似三角形进行结合，设定对应边长比例标准差相似度因子 S_{side} 、对应角度比例标准差相似度因子 S_{angle} ，其中 μ_{side} 与 μ_{angle} 分别代表边长比例和角度比例的均值。计算方法如式 (12) 所示。

$$\begin{cases} S_{side} = \frac{1}{3} \sqrt{\sum_{j=1}^3 \left(\left| \frac{d_{ij}}{d'_{ij}} \right| - \mu_{side} \right)^2} \\ S_{angle} = \frac{1}{3} \sqrt{\sum_{j=1}^3 \left(\left| \frac{\theta_{ij}}{\theta'_{ij}} \right| - \mu_{angle} \right)^2} \end{cases} \quad (12)$$

(4) 根据两种相似度因子得出相似度计算模型，其计算方法如式 (13) 所示。

$$S = \varphi S_{side} + (1 - \varphi) S_{angle} \quad (13)$$

式中， φ 是权重系数。 $S \in [0, 1]$ 。定义阈值 ϕ ，如果 $S < \phi$ 则表示两个三角形越相似，内点所占比例越高。

(5) 鉴于不同数据 φ 的取值大不相同，往往需要找到最优权重后，方可将错误的三角形对完全去除。因此，本文在算法中内置一个遍历步骤，设定步长为 0.1，找出所有符合条件的内点，并检查内点是否相同，如果相同则只保留一个内点对。重复上述过程，直到找到所有符合条件的内点对。

(6) 随机找寻至少 3 对符合条件的内点，利用 SVD 分解，估计出初始旋转矩阵和平移向量，并计算变换后的源点云与目标点云中所有对应点的距离，不断迭代上述过程，直到找到最小距离所对应的转换参数，最终完成粗配准。

2.4 添加法向量夹角约束条件的 Point to plane ICP 算法

经过粗配准后，两片点云已基本对齐，但配准误差较大还需进行精确配准。传统 ICP 算法属于点对点的精配准方法，其在第一步构建初始点对时，仅以欧氏距离最近的点作为点对筛选条件，该方法易陷入局部最优解，难以达到全局最优的配准结果。针对该问题，Chen 和 Medioni (1992) 提出了 Point to plane ICP 算法，该方法相比传统 ICP 迭代次数更少且缓解了局部最优的问题。它是将传统 ICP 计算点对之间的欧式距离改为计算点与对应点切平面之间的距离，并通过点与对应点切平面之间的不断迭代，计算出源点云与目标点云之间的最优旋转矩阵 R 与平移向量 T ，使得误差不断缩小达到收敛状态，其计算模型如下：

$$E(R, T) = \argmin_E \sum_{i=1}^N \left\| (R \cdot P_i + T - Q_i) \cdot n_i \right\|^2 \quad (14)$$

式中， P_i 、 Q_i 分别为源点云与目标点云中的对应点， n_i 表示 Q_i 对应点切平面计算出的法向量。图6为 Point to plane ICP 示意图。




图6 Point to plane ICP 示意图

Fig. 6 The diagram of point to plane ICP

本文采用一种添加法向量夹角约束条件的 Point to plane ICP 算法, 具体步骤如下:

(1) 首先计算由目标点云 Q 中的点 q_i 及其法向量 n_i 确定切平面 N_{q_i} , 之后遍历源点云 P 中的点 p_i , 并找寻 p_i 与 Q 中的最近的切平面 N_{q_j} , 则认为 p_i 与 N_{q_j} 对应点 q_j 是匹配点对。

(2) 其次在所获得的所有对应点集中计算各点的法向量夹角, 对于不同数据设定不同的角度阈值, 选出所有满足阈值条件的对应点集。

(3) 最后, 根据筛选出的匹配点集, 构建目标误差函数, 将式 (14) 转化成一个线性最小二乘问题进行求解。通过规定迭代次数, 不断迭代直到求解出满足式 (14) 最小值的解, 即为最终刚体变换矩阵。

3 实验与应用

3.1 数据与实验环境

本文实验选取斯坦福大学利用 Cyberware3030 MS 扫描仪所采集的 3D 点云数据 (数据来源: <https://graphics.stanford.edu/data/3Dscanrep/> [2024-11-22]) 和笔者利用 RIEGL_VZ-400i 三维激光扫

描仪采集的部分数据进行点云配准实验。其中斯坦福数据集包括 Bunny (兔子)、China Dragon (中国龙)、Happy Buddha (佛像) 等点云数据。笔者采集的点云数据集包括构筑物 A (桃李鼎)、构筑物 B (校训墙)、构筑物 C (校史柱)。其中关键点提取实验采用完整的点云模型, 后续配准实验采用不同视角下 Bunny、China Dragon、Happy Buddha 的数据进行配准, 其中 Bunny 采用 0° 和 315° 视角下的数据, 考虑到 China Dragon 0° 和 024° 、Happy Buddha 0° 和 336° 两组数据都存在较高的重叠率, 使用它们进行实验难以体现配准算法的优越性, 同时为了增加实验的多样性, 本文将 China Dragon 024° 数据与 Happy Buddha 336° 数据分别沿 y 轴、 z 轴方向旋转 180° 、 45° 。再沿 x 轴分别平移 0.05 m、0.1 m, 其中后者再沿 y 轴平移 0.05 m 形成源点云, 并将其转换为后缀名为 .pcd 格式的文件。通过体素下采样保持数据形态的同时精简数据。由于两种扫描仪采集的点云密度不同, 因此需要设置不同的体素下采样和混合滤波参数, 并且斯坦福数据集并没有地面点, 因此只针对真实场景数据集设置布料模拟滤波参数。预处理阶段参数如表 1 所示。

表 1 预处理参数表

Table 1 The table of preprocessing parameter

数据类型	预处理步骤						
	体素下采样	统计滤波		布料模拟滤波			
	体素边长	K 近邻个数	标准差倍数	迭代次数	网格大小	刚性程度	分类阈值
斯坦福数据集	0.002f	10	3	—	—	—	—
真实场景数据集	0.1f	20	2	100	0.45	2	0.01、0.5、0.02

注: “—”表示该算法不包含对应的参数。

本文在 Microsoft Visual Studio 2015 集成开发环境下, 使用 C++ 编程语言, 并调用点云库 (PCL1.8.1) 实现相关算法。实验所用的计算机硬件配置包括 Intel (R) Core (TM) i5-1240P 的 GPU、16 GB 内存、64 位 Win11 操作系统计算机。基于该环境, 进行了自适应邻域关键点提取实验和多种点云数据的配准算法对比实验, 并将本文实验结果与 ICP、ISS+K-4PCS+ICP、SIFT3D+FPFH+SAC-IA+ICP 的配准结果进行了对比与分析。

3.2 评价指标

为验证本文算法的有效性与可行性, 选取点云

重复性 (Tombari 等, 2013) 和均方根误差 (RMSE) 作为评价指标。

(1) 点云重复性。点云重复性的目的是检验提取出的源点云关键点是否具备经过旋转、平移或加入一定噪声后, 在目标点云中也能提取出相同关键点的能力, 主要分为两部分: 稳定性与抗噪性。设源点云集合 P 、目标点云集合 Q , P 与 Q 之间的真实旋转矩阵 R 、平移向量 T , 其中 R 是一个 3×3 矩阵、 T 是一个 3×1 列向量。步骤如下:

1) 首先对源点云集合 P 提取关键点, 记为 P' , 根据式 (15) 对 P' 进行刚体变换, 得到 P'' 。

$$p'' = R \cdot P' + T \quad (15)$$

2) 其次对目标点云集合 Q 提取关键点, 记为 Q' 。根据式 (16) 在 Q' 中找寻与 P'' 最近邻的点, 记为 Q'' , 计算 P'' 与 Q'' 之间的距离是否小于阈值 δ_{dis} , 从而判断关键点的重复性。

$$\|p'' - q'\| < \delta_{dis} \quad (16)$$

3) 设关键点 P' 的数量为 n_1 、可重复的关键点数量为 n_2 , 则可重复比率 (rt) 如式 (17) 所示。

$$rt = \frac{n_2}{n_1} \quad (17)$$

(2) 均方根误差。真实场景下, 源点云与目标点云之间的真实旋转矩阵和平移向量未知, 可采用式 (18) 计算两种点云之间欧氏距离的 RMSE 值衡量配准精度。

$$RMSE = \frac{1}{N} \sqrt{\sum_{i=1}^N \|R \cdot P_i + T - Q_i\|^2} \quad (18)$$

式中, N 表示配准后所有对应点的总数, RMSE 值越小, 表明配准误差越低, 配准精度越高。

3.3 实验、结果分析与应用

3.3.1 关键点阈值选取分析

首先为了便于相关参数的设定, 引入点云分辨率 (mr) 概念, 定义为点云中所有点到其最近邻点距离的平均值 (熊风光, 2018)。根据上文所提出的关键点检测方法, 本节实验中各参数如下: 各算法初始邻域半径 r_0 均设为 3 mr。其中本文所提算法步长 Δr_i 设为 1 mr, 高斯距离权重 σ 设为 0.6 mr, 式 (8) 中系数 ω 设为 1.5, 阈值 α 、 β 分别设为 0.15、15%, 非极大值抑制 k 近邻个数为 25, 距离阈值 δ_{dis} 设为 0.005 mr。ISS 算法中特征值之比为 0.975、0.975。LSP 算法中 α 设为 0.3, β 设为 0.2。Harris3D 算法中关键点阈值设为 PCL 默认参数。SIFT3D 算法中最小尺度的标准偏差设为 0.6 mr, 金字塔层数设为 3, 尺度空间层数设为 4, 阈值设为 0.06 mr。关键点提取实验的参数如表 2 所示。

表 2 关键点提取实验参数表

Table 2 The table of keypoint extraction experimental parameter

算法名称	邻域半径/mr	NMS 最小 k 近邻个数	其他参数
LSP	3	4	$\alpha: 0.3, \beta: 0.2$
ISS	3	10	$Th_{12}: 0.975, Th_{23}: 0.975$
Harris3D	3	—	PCL 默认参数
SIFT3D	—	—	金字塔层数: 3、尺度空间层数: 4、阈值: 0.06 mr
本文方法	3	25	$\Delta r_i: 1 \text{ mr}, \sigma: 0.6 \text{ mr}, \omega: 1.5, \alpha: 0.15, \beta: 15\%$

本文算法中初始邻域半径 r_0 和阈值 α 的选取在很大程度上影响着最终配准的精度。因此, 在斯坦福数据集上对 r_0 和 α 分别进行阈值分析。考虑到过小的邻域范围无法捕捉足够的邻域信息, 影响关键点提取的准确性, 过大则导致计算效率过低。因此, 对于初始半径 r_0 , 选取 2.5—6 mr 的邻域范围, 实验结果如图 7 (a) — (c) 所示。从图 7 中

可以看出在 Bunny、China Dragon 和 Happy Buddha 第 3 种数据上, 随着 r_0 的增加, 配准误差 RMSE 均呈现下降后升高的特点, 当 r_0 为 3 mr 时 3 种数据的 RMSE 均达到最低值, 此时邻域范围既能充分捕捉局部几何特征, 又避免了因半径过大导致的冗余计算和噪声干扰, 此时关键点的质量最优, 因此选取 3 mr 为初始邻域半径。





图 7 不同初始邻域半径对最终配准的影响

Fig. 7 The effect of different initial neighborhood radii on the final registration


阈值 α 影响曲面尖锐与非尖锐区域的判定, 阈值 α 越大, 表明只有最显著的几何特征 (如棱角、尖刺) 会被保留, 关键点数量变少, 反之, 关键点数量变多。图 8 (a) — (b) 展示了阈值 α 在 Bunny、China Dragon 和 Happy Buddha 3 种数据上对配准误差 RMSE 和关键点数量的影响。从图 8 (a) 中可知随着 α 的增加, 3 种数据的 RMSE 呈现不同的趋势, 其中 Bunny 数据呈现逐渐上升的趋势, 这是因为 Bunny 模型的几何特征以平滑曲面为主, 当 α 增大时, 关键点过度集中在极少

数尖锐区域 (如耳朵尖端), 导致配准时的对应关系不足, RMSE 上升; Happy Buddha 数据呈现先下降后上升的趋势; China Dragon 数据则变化平稳, 表明阈值 α 的变化对关键点分布的影响较小, 故 RMSE 波动不明显。当阈值 α 取 0.15 时, Bunny 和 Happy Buddha 数据的 RMSE 值发生突变, 表明此时为曲面尖锐区域与非尖锐区域的划分边界。从图 8 (b) 中发现关键点数量随着阈值 α 的增加而逐渐减少。综合以上分析, 本文选取阈值 α 的值为 0.15。



(a) 阈值 α 与配准误差的关系

(a) The relationship between threshold α and registration error



(b) 阈值 α 与关键点数量的关系

(b) The relationship between threshold α and the number of keypoints


—●— Bunny —●— China Dragon —■— Happy Buddha

图 8 阈值 α 对最终配准的影响

Fig. 8 The effect of threshold α on the final registration


此外, 为验证自适应邻域算法的优越性, 本文对比分析了固定邻域与自适应邻域对配准精度的影响。如图 9 (a) 所示, 固定邻域半径下, Bunny 数据的 RMSE 值呈现先下降后上升的趋势, 且在 2—4 mr 范围内趋于稳定。从图 9 (b) — (d) 中可以发现, 当固定半径设为 2.5 mr 时, Bunny 数据达到最低 RMSE 值, 但经过关键点可视化验证后发

现 Bunny 数据的背脊处表面曲率较大区域未提取出来。另外, China Dragon 数据的 RMSE 值仍显著高于自适应方法的结果。进一步分析图 9 (b) — (d) 可发现, 本文提出的自适应方法在 3 种数据上均表现出更稳定的低误差特性。综合以上原因, 本文所提自适应方法能够克服固定半径的局限性有着较低的配准误差与较好的稳定性。



(a) 两种邻域搜索方法在 3 种数据上的配准误差影响

(a) The effect of registration errors of two neighborhood search methods on three types of data



(b) 两种邻域搜索方法在 Bunny 数据上的配准误差影响

(b) The effect of registration errors of two neighborhood search methods on Bunny data




图9 固定邻域搜索与自适应邻域搜索对配准误差的影响

Fig. 9 The effect of fixed neighborhood search and adaptive neighborhood search on registration error

3.3.2 基于自适应邻域的关键点提取实验

图10—12展示了部分数据利用不同算法提取 keypoints 的结果，其中红色点代表原始点云，蓝色点代表提取出的关键点。可以看出本文算法在曲面尖锐区域，关键点分布较为集中，如Bunny的耳部边缘、脖颈、尾颈和腿部连接处，China Dragon的角尖、舌尖、鼻尖、尾尖和脊背处，构筑物A的棱角处、鼎角处和底角处，这些部位都是点云各向异性值较大区域；而在曲面光滑区域，关键点分布较少且平均分散，如Bunny的弧形躯干和臀部部位，China Dragon的弧形躯干等部位，构筑物

A的立面部位，关键点分布稀疏且均匀。本文也与其他关键点检测算法的效果进行了对比。其中ISS算法关键点分布较为平均，但在弧形躯干表面检测出过多无用关键点；Harris3D算法虽然对角点提取效果较好，但缺点与ISS算法一致；SIFT3D算法提取的关键点只根据高斯差分金字塔局部邻域情况来提取关键点，存在某些区域关键点较为集中、特征区分度不够明显的情况，与本文提出的算法相比，本文关键点分布较为明显，曲面尖锐区域与光滑区域的区分度较高，边界点和内部特征点均被提取，优势明显。




图10 不同算法对Bunny的关键点提取结果

Fig. 10 The keypoints of Bunny to different algorithms extract




图11 不同算法对China Dragon的关键点提取结果

Fig. 11 The keypoints of China Dragon to different algorithms extract




图 12 不同算法对构筑物 A 的关键点提取结果
Fig. 12 The keypoints of structure A to different algorithms extract

如表 3 所示, 本文所提算法得到的可重复比率均为 100%, 说明本文算法具备良好的旋转、平移不变性特征, 稳定性较好。

表 3 本文所提算法可重复比率
Table 3 The repeatability ratio of our algorithm

点云名称	点云数目	关键点数	可重复比率/%
Bunny	15805	680	100
China Dragon	24147	1743	100
Happy Buddha	18072	1877	100
构筑物 A	8348	820	100
构筑物 B	22134	1851	100
构筑物 C	17837	1562	100

表 4 展示了本文所提算法与其他算法的可重复比率对比表, 从表 4 中可知其他所有算法也具有旋转、平移不变性的特点。

表 4 本文所提算法与其他算法可重复比率对比表
Table 4 The comparison table of the repeatability ratio between our algorithm and other algorithms

点云名称	算法名称					/%
	LSP	ISS	Harris3D	SIFT3D	本文方法	
Bunny	100	100	100	100	100	
China Dragon	100	100	100	100	100	
Happy Buddha	100	100	100	100	100	
构筑物 A	100	100	100	100	100	
构筑物 B	100	100	100	100	100	
构筑物 C	100	100	100	100	100	

为验证本算法抗噪效果, 在斯坦福数据集中为源点云分别添加 0.1 mr、0.2 mr、0.3 mr、0.4 mr、0.5 mr、0.6 mr 和 0.7 mr 的高斯噪声, 在真实场景数据集中为源点云分别添加 0.06 mr、0.08 mr、0.1 mr、0.12 mr、0.14 mr、0.16 mr 和 0.18 mr 的高斯噪声。并与 LSP、ISS、Harris3D 和 SIFT3D 算法

进行点云重复性对比分析。如图 13 (a) — (f) 所示, 随着噪声的增加, 所有点云表面粗糙程度增大, 5 种算法的可重复比率均呈下降趋势, 其中本文算法除 Bunny 数据集以外, 抗噪性均明显优于其他 4 种算法, 这是因为其他数据集具有较多的尖锐特征, 复杂性较高, 而 Bunny 数据集躯干表面较为光滑、尖锐部分较少, 使得本算法的优势在该数据集上表现不够突出。因此, 本文算法在处理具有复杂特征点云数据时, 展现出了更为显著的抗噪性能。

本文算法遵循曲面尖锐区域点数较多, 曲面光滑区域点数较少的原则, 因此本文算法不适用于存在较多光滑曲面数据集, 因为这类数据中大部分法向量方向一致, 检测出关键点的数量较少。另外本算法引入高斯权重计算法向量, 高斯权重 σ 值越小, 抗噪性越弱, 但对尖锐特征识别较为明显, 高斯权重 σ 值越大, 抗噪性越强, 但尖锐关键点数较多, 造成重复, 不利于后续特征匹配。为了避免曲面上尖锐区域关键点过多, 同时保持良好的抗噪声性能, 经过反复实验, 选取 0.6 mr 作为最优的 σ 值, 实现了这两个方面的平衡。

用上述方法提取出关键点后, 需对关键点进行 SHOT 特征描述, 利用 BNND 建立源点云与目标点云之间的初始对应关系, 之后利用本文提出的相似三角形计算模型优化匹配点对, 再利用 SVD 分解求解出源点云与目标点云之间的初始旋转矩阵和平移向量。如图 14 (a) — (b) 所示, 橙色代表目标点云, 浅蓝色代表源点云, 蓝色点代表提取出的关键点, 绿线、红线分别代表正确、错误的点对映射图。其中图 14 (a) 表示根据 BNND 建立的初始点对, 图 14 (b) 表示根据相似三角形计算模型将对应点进行优化后得到的正确点对示意图。




图 13 5种算法的抗噪性对比结果

Fig. 13 The comparison results of noise resistance of five algorithms




图 14 Bunny 匹配点对映射图

Fig. 14 The point to point mapping of Bunny

3.3.3 点云配准算法实验与对比

图 15—17 给出了经典 ICP 算法、基于 ISS 关键点的 K-4PCS 与 ICP 相结合的算法（以下称为 K-

4PCS+ICP 算法）、基于 SIFT3D 关键点的 FPFH+SAC-IA 与 ICP 结合的算法（以下称为 SAC-IA+ICP 算法）与本文方法的配准实验对比图，其中橙色代表目标点云，浅蓝色代表源点云。从配准结果图来看，ICP 算法分别在 Bunny 数据的兔子耳朵部分、Happy Buddha 数据的佛像顶部配准偏差较大，并且在 China Dragon 数据中配准失败。表 5 给出 4 种算法的均方根误差与配准时间，从表 5 中可以看出 ICP 算法耗时最短，但配准精度最差，由于没有粗配准，容易陷入局部最优解。而本文算法虽相比 ICP 配准时间有所增加，这是由于提取自适应关键点时，求解最优半径有所耗时，但配准误差

却大幅度缩小。在3种数据集上，本文算法相比其他3种算法平均精度分别提高63.32%、38.08%、37.39%，表明本文所提算法的配准精度较高、配准效果较好，具有一定适用性。




图15 不同算法对Bunny0°和315°数据的配准结果
Fig. 15 The registration result of Bunny0° & 315° data to different algorithms




图16 不同算法对China Dragon0°和024°数据的配准结果
Fig. 16 The registration result of China Dragon0° & 024° data to different algorithms




图17 不同算法对Happy Buddha0°和336°数据的配准结果
Fig. 17 The registration result of Happy Buddha0° & 336° data to different algorithms

本文对前文所提的几种算法的收敛次数进行了对比分析，以Happy Buddha数据为例，图18给出4种算法在不同迭代次数下的收敛情况，图18中蓝色、橙色、青色、红色曲线分别代表经典ICP算法、K-4PCS+ICP算法、SAC-IA+ICP算法和本文方法的

收敛曲线。其中本文方法在迭代5次后收敛，ICP算法、K-4PCS+ICP算法、SAC-IA+ICP算法迭代次数分别为27次、13次、14次后才收敛，相比其他3种算法，本文方法收敛次数分别提高了81.5%、61.5%、64.2%。说明本文方法能够更快速收敛。

表5 不同算法配准参数

Table 5 The registration parameters of different algorithms

点云名称	算法	RMSE/m	时间/ms
Bunny 0°&315°	ICP	1.85860×10^{-3}	9738
	K-4PCS+ICP	1.78725×10^{-3}	10407
	SAC-IA+ICP	1.76909×10^{-3}	51333
	本文算法	0.72629×10^{-3}	52249
China Dragon 0°&024°	ICP	28.0400×10^{-4}	7575
	K-4PCS+ICP	7.21307×10^{-4}	43309
	SAC-IA+ICP	7.17705×10^{-4}	45302
	本文算法	6.40700×10^{-4}	49617
Happy Buddha 0°&336°	ICP	1.15839×10^{-3}	5096
	K-4PCS+ICP	0.98991×10^{-3}	6556
	SAC-IA+ICP	0.96930×10^{-3}	41162
	本文算法	0.55729×10^{-3}	46380

注：加粗数值为本文算法在均方根误差(RMSE)指标上的表现，优于其他对比方法。




图 18 不同算法迭代次数示意图

Fig. 18 The diagram of iteration times to different algorithms

3.3.4 算法实际应用

为验证本文算法的有效性，本文将其扩展应用于激光点云与无人机倾斜摄影点云之间的配准。如图 19 (a) — (f)、图 20 (a) — (f) 所示，选取江西师范大学瑶湖校区的构筑物B、构筑物C为待配准对象。其中红色点云是利用三维激光扫描仪所采集的激光点云，蓝色点云是利用 DJI M300RTK 无人机进行影像采集，通过软件生成的倾斜摄影点云。从图 19、图 20 中可发现 ICP 算法均出现局部最优解，导致两种点云配准失败。另外 SAC-IA+ICP 方法在构筑物 B、C 上配准效果不佳，点云偏移较大，这是由于 SAC-IA 为 ICP 提供的初始位姿较差，导致 ICP 算法无法有效地进行精细对齐。虽然 K-4PCS+ICP 算法在构筑物 B、C 上均能有效配准，但在细节处配准效果不如本文算法。图 19 (f) 中本文所提算法对构筑物 B 各个拐角处配准的效果明显优于其他算法，未出现较大偏移。表 6 给出 4 种算法的均方根误差与配准时间，从表中可以看出本文方法在两种数据上的 RMSE 值均为最低，相较其他 3 种算法配准的平均精度分别提高 66.1%、15.78%、35.12%。对于 ICP 算法，由于均出现局部最优解，因此所有的 RMSE 值最高，配准效果最差；对于 SAC-IA 算法，在构筑物 B 上由于并未完全配准，因此 RMSE 值较大。相比之下，本文算法在设计中融入了更多的几何信息和约束，使得配准结果更加符合构筑物的实际结构特征。因此，本文对于多源点云也有较好的配准效果。




图 19 不同算法构筑物 B 配准结果

Fig. 19 The registration result of structure B data to different algorithms




图 20 不同算法构筑物C配准结果
Fig. 20 The registration result of structure C data to different algorithms

表 6 不同算法构筑物配准参数
Table 6 The structures registration parameters of different algorithms

点云名称	算法	RMSE/m	时间/ms
构筑物B	ICP	7.36940×10^{-2}	8774
	K-4PCS+ICP	5.31545×10^{-2}	23527
	SAC-IA+ICP	9.03344×10^{-2}	199334
	本文算法	4.61793×10^{-2}	262291
构筑物C	ICP	22.0413×10^{-2}	3507
	K-4PCS+ICP	3.65079×10^{-2}	16221
	SAC-IA+ICP	5.69839×10^{-2}	164588
	本文算法	3.01890×10^{-2}	201018

注:加粗数值为本文算法在均方根误差(RMSE)指标上的表现,优于其他对比方法。

4 结 论

针对当前对点云配准算法中关键点提取方法不足进而导致配准精度不高的问题,本文提出了一种基于多特征关键点提取与相似三角形优化点对的点云配准方法,其创新点主要包括:(1)提出了一种名为SDNVA-AC的自适应邻域关键点提取方法,并融合SHOT特征,增强了关键点提取的准确性。(2)提出了将BNDR与三角形相似度模型进行组合的配准策略,提高了粗配准精度。(3)通过

引入法向量夹角约束条件的策略改进了Point to plane ICP算法,提升了精配准精度。实验结果表明,与现有的3种算法相比,本文算法的配准误差明显降低,平均配准精度均得到了显著提高,在实际应用中也表现出较强的优势。然而,本文算法也存在不足,主要表现在采用自适应邻域的方法提取关键点时计算时间稍长。因此,未来的研究将注重进一步提升点云配准的精度,同时兼顾自适应关键点提取速度,以实现更加高效、准确的点云配准。

参考文献(References)

Abdi H and Williams L J. 2010. Principal component analysis. WIREs: Computational Statistics, 2(4): 433-459 [DOI: 10.1002/wics.101]

Besl P J and McKay N D. 1992. Method for registration of 3-D shapes// Proceedings Volume 1611, Sensor Fusion IV: Control Paradigms and Data Structures. Boston: SPIE: 586-606 [DOI: 10.1117/12.57955]

Chen Y and Medioni G. 1992. Object modelling by registration of multiple range images. Image and Vision Computing, 10(3): 145-155 [DOI: 10.1016/0262-8856(92)90066-C]

Chetverikov D, Svirkov D, Stepanov D and Krsek P. 2002. The trimmed iterative closest point algorithm//2002 International Conference on Pattern Recognition. Quebec City: IEEE: 545-548 [DOI: 10.1109/ICPR.2002.1047997]

Demantké J, Mallet C, David N and Vallet B. 2012. Dimensionality

- based scale selection in 3D lidar point clouds. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXVIII-5-W12: 97-102 [DOI: 10.5194/isprsarchives-xxxviii-5-w12-97-2011]
- Huang Z J, Wen Y X, Wang Z H, Ren J J and Jia K. 2024. Surface reconstruction from point clouds: a survey and a benchmark. IEEE Transactions on Pattern Analysis and Machine Intelligence, 46(12): 9727-9748 [DOI: 10.1109/TPAMI.2024.3429209]
- Jia C Q, Pang M and Han X. 2023. A feature extraction algorithm based on optimal neighborhood size. Circuits, Systems, and Signal Processing, 42(4): 2193-2214 [DOI: 10.1007/s00034-022-02199-w]
- Li Y X, Guo J M, Pan S Y, Lü L L, Lu Z X and Zhang D. 2020. A point cloud registration algorithm based on ISS-SHOT features. Bulletin of Surveying and Mapping, (4): 21-26 (李宇翔, 郭际明, 潘尚毅, 吕丽丽, 卢主兴, 章迪. 2020. 一种基于ISS-SHOT特征的点云配准算法. 测绘通报, (4): 21-26) [DOI: 10.13474/j.cnki.11-2246.2020.0106]
- Liu R F, Wang F, Ren H W, Wang M Y and Yang J B. 2022. Road scene laser point cloud registration method based on geographical object features. Chinese Journal of Lasers, 49(18): 1810002 (刘如飞, 王飞, 任红伟, 王旻烨, 杨继奔. 2022. 一种利用地理实体目标特征的道路场景激光点云配准方法. 中国激光, 49(18): 1810002) [DOI: 10.3788/CJL202249.1810002]
- Luo R, Zhou Z X, Chu X, Ma W and Meng J H. 2022. 3D deformation monitoring method for temporary structures based on multi-thread LiDAR point cloud. Measurement, 200: 111545 [DOI: 10.1016/j.measurement.2022.111545]
- Salti S, Tombari F and Di Stefano L. 2014. SHOT: unique signatures of histograms for surface and texture description. Computer Vision and Image Understanding, 125: 251-264 [DOI: 10.1016/j.cviu.2014.04.011]
- Tombari F, Salti S and Di Stefano L. 2013. Performance evaluation of 3D keypoint detectors. International Journal of Computer Vision, 102(1): 198-220 [DOI: 10.1007/s11263-012-0545-4]
- Wang M J, Yi F, Li L and Huang C J. 2022. Local neighborhood feature point extraction and matching for point cloud alignment. Infrared and Laser Engineering, 51(5): 20210342 (王明军, 易芳, 李乐, 黄朝军. 2022. 自适应局部邻域特征点提取和匹配的点云配准. 红外与激光工程, 51(5): 20210342) [DOI: 10.3788/IRLA20210342]
- Wang W B, Tian M Y, Yu J Y, Song C H, Li J R and Zhou M L. 2022. Improved iterative nearest point point cloud alignment method. Laser and Optoelectronics Progress, 59(2): 0215007 (王文博, 田茂义, 俞家勇, 宋成航, 李晋儒, 周茂伦. 2022. 改进的迭代最近点点云配准方法. 激光与光电子学进展, 59(2): 0215007) [DOI: 10.3788/LOP202259.0215007]
- Weinmann M, Jutzi B and Mallet C. 2014. Semantic 3D scene interpretation: a framework combining optimal neighborhood size selection with relevant features. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, II-3: 181-188 [DOI: 10.5194/isprsannals-II-3-181-2014]
- Xiong F G. 2018. Research on Registration Technology of 3D Point Cloud. Taiyuan: North University of China (熊风光. 2018. 三维点云配准技术研究. 太原: 中北大学)
- Xu G X, Pang Y J, Bai Z X, Wang Y L and Lu Z W. 2021. A fast point clouds registration algorithm for laser scanners. Applied Sciences, 11(8): 3426 [DOI: 10.3390/app11083426]
- Yang J L, Li H D and Jia Y D. 2013. Go-ICP: solving 3D registration efficiently and globally optimally//Proceedings of the 2013 IEEE International Conference on Computer Vision. Sydney: IEEE: 1457-1464 [DOI: 10.1109/ICCV.2013.184]
- Yang J Q, Zhang S K, Fan S C and Cao Z G. 2022. Survey on multi-view point cloud registration algorithm. Journal of Huazhong University of Science and Technology (Nature Science Edition), 50(11): 16-34, 43 (杨佳琪, 张世坤, 范世超, 曹治国. 2022. 多视图点云配准算法综述. 华中科技大学学报(自然科学版), 50(11): 16-34, 43) [DOI: 10.13245/j.hust.221102]
- Yang S, Hou M L and Li S N. 2023. Three-dimensional point cloud semantic segmentation for cultural heritage: a comprehensive review. Remote Sensing, 15(3): 548 [DOI: 10.3390/rs15030548]
- Zeybek M and Şanlıoğlu İ. 2019. Point cloud filtering on UAV based point cloud. Measurement, 133: 99-111 [DOI: 10.1016/j.measurement.2018.10.013]
- Zhang J Y, Yao Y X and Deng B L. 2022b. Fast and robust iterative closest point. IEEE Transactions on Pattern Analysis and Machine Intelligence, 44(7): 3450-3466 [DOI: 10.1109/TPAMI.2021.3054619]
- Zhang S J, Ma Y Z and Zhao H F. 2019. Elimination algorithm of mismatched point pairs based on point cloud geometric feature. Computer Engineering, 45(4): 163-168 (张少杰, 马银中, 赵海峰. 2019. 基于点云几何特征的错误匹配点对剔除算法. 计算机工程, 45(4): 163-168) [DOI: 10.19678/j.issn.1000-3428.0049468]
- Zhang Z Y, Zheng J Y, Tao Y Y, Xiao Y, Yu S M, Asiri S, Li J C and Li T S. 2022a. Traffic sign based point cloud data registration with roadside LiDARs in complex traffic environments. Electronics, 11(10): 1559 [DOI: 10.3390/electronics11101559]
- Zhu J H, Jiang Z T, Evangelidis G D, Zhang C Q, Pang S M and Li Z Y. 2019. Efficient registration of multi-view point sets by K-means clustering. Information Sciences, 488: 205-218 [DOI: 10.1016/j.ins.2019.03.024]

A point cloud registration method using multi-feature keypoint extraction and similar triangle-based point pair optimization

TU Haowen^{1,2,3}, WU Jianhua^{1,2,3}, WANG Yuan^{1,2}

1.College of Geography and Environment, Jiangxi Normal University, Nanchang 330022, China;

2.Nanchang Base of International Centre on Space Technologies for Natural and Cultural Heritage under the Auspices of UNESCO, Nanchang 330022, China;

3.Research Center for Linguistic Spatial Information Science, Jiangxi Normal University, Nanchang 330022, China

Abstract: With the rapid development of computer vision and 3D laser scanning technology, point cloud data have been widely used in many fields, such as intelligent transportation, deformation monitoring, 3D reconstruction, and digitization of cultural relics, but many challenges exist in the collection process. Given the limitation in the viewing angle of laser scanning equipment and complex and changeable environmental factors, the integrity of the obtained point cloud data exhibits substantial defects, which directly affect the accuracy of subsequent processing and analysis. Therefore, efficient and accurate registration of point cloud data has become a crucial task.

However, in existing point cloud registration algorithms, the calculation of point features usually adopts a fixed neighborhood, which is difficult to apply to the feature calculation of complex point clouds. This difficulty leads to problems, such as poor extraction results of keypoints and a large number of external points in the corresponding points, thereby affecting the accuracy of point cloud registration. To solve this problem, this study presents a point cloud registration method that uses multifeature keypoint extraction and similar triangle-based point pair optimization. The core task is extracting keypoints through the adaptive neighborhood strategy and optimizing the matching similarity model. First, the data are preprocessed by voxel filtering and hybrid filtering, the optimal neighborhood of the point cloud is determined using the characteristic entropy function, and the keypoints are extracted by combining the standard deviation of normal vectors' angle anisotropy and curvature. Second, the signature of histogram of orientation is used to calculate the key features. Third, the bidirectional nearest neighbor distance ratio is employed to construct the initial matching point pairs, and a computational model on the basis of similar triangles is proposed to optimize the point pairs and complete rough registration. Finally, the point-to-plane Iterative Closest Point (ICP) algorithm with the angle constraint of normal vector is adopted to achieve accurate registration.

Two experiments based on adaptive neighborhood keypoint extraction and point cloud registration are conducted to verify the effectiveness of the proposed method. In the adaptive keypoint extraction experiment, the Bunny, China Dragon, and Happy Buddha point cloud data sets collected from Stanford University and the Taoli Tripod, School Motto Wall, and School History Column point cloud data sets collected by our research group are used to extract keypoints. Results show that compared with LSP, ISS, Harris3D, and SIFT3D algorithms, the proposed method has better distinction between the sharp and smooth regions of the surface and better noise resistance. In the latter type of experiments, point cloud data from different perspectives are used for registration investigations. The proposed method has a smaller error compared with the point cloud registration algorithm combined with classic ICP, the keypoint-based four-point congruent set, and the point cloud registration method combined with sampling consistency initial alignment and ICP. In addition, the proposed method shows substantial advantages in the application of measured data registration.

The experimental findings indicate that the proposed method exhibits a considerable improvement in registration accuracy compared with existing methods. This work provides the following innovative contributions. (1) An adaptive neighborhood keypoint extraction method called SDNVA-AC is proposed, and the SHOT feature is integrated to enhance the accuracy of feature extraction. (2) A registration strategy that combines BNDR and the triangular similarity model is proposed to improve rough registration accuracy. (3) The point-to-plane ICP algorithm is improved by adding the angle constraint of normal vector, and the precision of fine registration is improved. This study can provide strong technical support and a theoretical basis for the research and application of multisource point cloud data fusion.

Key words: remote sensing, adaptive neighborhood, point cloud registration, similar triangle, point to plane ICP

Supported by National Natural Science Foundation of China (No. 41561084, 41201409); Jiangxi Provincial Department of Education Graduate Innovation Fund (No. YC2023-S219)