

DOI:10.11918/202507052

融合改进 SAC-IA 与加权 ICP 的高效点云配准方法

殷果^{1,2}, 王大庆², 孙玉香^{2,3}, 高理富^{2,3}

(1. 安徽建筑大学 电子与信息工程学院, 合肥 230061; 2. 中国科学院合肥物质科学研究院, 合肥 230031;
3. 中国科学技术大学 自动化系, 合肥 230026)

摘要:为解决传统迭代最近点(iterative closest point, ICP)算法在处理巷道等大型结构化场景时,对初始位姿敏感且易因重复性几何结构陷入局部最优的问题,本文提出一种高效的两阶段点云配准框架。在粗配准阶段,通过改进采样一致性初始配准(sample consensus initial alignment, SAC-IA)算法的关键点采样策略,从下采样后的点云中快速获取全局最优初始位姿;精配准阶段设计了一种融合欧氏距离、法向量夹角与曲率信息的多维加权 ICP 算法,通过构建综合几何特征的优化目标函数,有效降低了巷道平直区域的误匹配率。在斯坦福公开数据集上对改进的粗配准与精配准算法分别进行了验证,结果表明:改进后的粗配准算法相比传统 SAC-IA,计算效率提升了 44.1%;基于几何特征的加权 ICP 算法相比传统 ICP,配准精度提高了 23.81%,耗时降低了 25.9%。在实测巷道点云的综合配准实验中,本文提出的配准框架整体表现显著优于传统方法,在整体精度与效率方面的提升均超过 20%。与主流深度学习方法相比,该框架无需依赖高性能 GPU,仅使用 CPU 即可实现处理效率数倍的提升,并在真实巷道场景中取得了更鲁棒的配准效果。实验表明,该框架能够为大型结构化场景下的点云自动配准提供一种同时满足工业级实时性与轻量化要求的高效解决方案。

关键词:点云配准;采样一致性初始配准;下采样;加权 ICP;几何特征;深度学习

中图分类号: TP391

文献标志码: A

文章编号: 0367-6234(2026)05-0103-13

Efficient point cloud registration method integrating improved SAC-IA and weighted ICP

YIN Guo^{1,2}, WANG Daqing², SUN Yuxiang^{2,3}, GAO Lifu^{2,3}

(1. Anhui Jianzhu University, School of Electronic and Information Engineering, Hefei 230061, China;

2. Hefei Institutes of Physical Science, Chinese Academy of Sciences, Hefei 230031, China;

3. University of Science and Technology of China, Department of Automation, Hefei 230026, China)

Abstract: Traditional Iterative Closest Point (ICP) algorithms are susceptible to local optima and sensitive to initial pose when applied to large-scale structured scenes, such as underground tunnels, due to their repetitive geometric features. To address these challenges, this paper proposes an efficient two-stage point cloud registration framework. In the coarse registration stage, an improved Sample Consensus Initial Alignment (SAC-IA) algorithm with an enhanced keypoint sampling strategy is introduced to rapidly obtain a globally optimal initial pose from the downsampled point cloud. Subsequently, the fine registration stage employs a novel multi-dimensional weighted ICP algorithm. This algorithm integrates Euclidean distance, normal vector angles, and curvature information into a comprehensive geometric objective function, effectively reducing the mismatch rate in the planar regions of tunnels. The proposed components were individually validated on the Stanford public dataset. Results show that the improved coarse registration algorithm increases computational efficiency by 44.1% over the conventional SAC-IA, while the geometry-based weighted ICP algorithm improves registration accuracy by 23.81% and reduces computation time by 25.9% compared to the traditional ICP. Comprehensive experiments on real-world tunnel point clouds demonstrate that the proposed framework significantly outperforms traditional methods, improving both overall accuracy and efficiency by over 20%. Furthermore, compared to mainstream deep learning methods, this framework obviates the need for high-performance GPUs. It achieves a several-fold increase in processing efficiency on a standard CPU and delivers more robust registration results in realistic tunnel scenarios. Ultimately, this framework provides a highly efficient solution for automatic point cloud registration in large-scale structured environments, fully satisfying industrial demands for real-time processing and lightweight implementation.

收稿日期: 2025-07-22; 录用日期: 2025-09-12; 网络首发日期: 2025-10-11

网络首发地址: <https://link.cnki.net/urlid/23.1235.t.20251010.1655.006>

基金项目: 国家重点研发计划(2023YFB4704600); 中国科学院合肥物质科学研究院院长基金(YZJJQY202305)

作者简介: 殷果(2001—),男,硕士研究生;高理富(1970—),男,研究员,博士生导师

通信作者: 高理富, lifugao@iim.ac.cn

Keywords: point cloud registration; sample consensus initial alignment; downsampling; weighted ICP; geometric features; deep learning

随着三维激光雷达技术的发展,点云作为反映真实空间结构的重要数据形式,广泛应用于建筑建模、隧道测绘、采矿工程和机器人导航等领域。在矿井巷道环境中,由于采集视角受限、行人遮挡、光照反射及粉尘干扰等因素影响,常导致获取的点云数据局部不连续,从而给后续三维建模和空间分析带来困难^[1]。为实现多视角点云的统一表示,点云配准作为关键技术,其精度与效率直接影响系统的整体性能。

目前,应用最广泛的点云配准方法是由 Besl 等^[2]在 1992 年提出的 ICP 算法,该算法通过不断迭代最小化两组点云之间的欧氏距离,实现配准对齐。然而,传统 ICP 方法对初始姿态高度敏感,当点云之间初始位置偏差较大或缺乏显著特征时,极易陷入局部最优解,导致配准失败或效率低下^[3]。为解决上述问题,许多学者提出基于“先粗后精”的两阶段点云配准方法,即先进行粗配准获取较好的初始位姿,再通过改进 ICP 算法精细对齐^[4]。近年来,以 PointNetLK^[5]、DGR (deep global registration)^[6] 为代表的方法将深度学习引入点云配准,通过构建端到端的神经网络,直接从原始数据中学习特征表示并预测两者间的空间变换关系,虽在部分公共数据集上表现优异,但此类方法依赖大规模标注数据训练和高性能 GPU 推理,限制了其在开槽机器人等需要轻量化部署的工业场景中的直接应用,且泛化能力不足。因此,本文聚焦无需训练、不依赖特定硬件的传统几何优化路径,通过对经典框架进行深度改进,实现高精度、实时鲁棒配准,为独特场景智能装备提供高效易部署解决方案。

在粗配准阶段,基于特征匹配的方法是当前研究的主流。该方法通常首先通过体素滤波^[7]等方式对原始点云进行降采样,以降低数据冗余、提高运算效率。随后,从降采样^[8]后的点云中提取具有代表性的关键点。在基于特征的点云配准研究中,关键点检测算子的选择至关重要。例如,刘翔宇等^[9]与张平等^[10]分别基于 3DSIFT 算子构建了配准流程,用以改善配准效果,而景会成等^[11]则采用了 3DHarris 算子提取关键点,并结合 FPFH 描述子来完成点云的初始对齐;魏永超等^[12]通过融合内部形状描述子 (intrinsic shape signatures, ISS) 与边界点,提出了一种边界增强型关键点提取策略。在提取关键点后,需要计算其特征描述子来量化局部几何信息。其中,由 Rusu 等^[13]提出的快速点特征直方图 (fast point feature histograms, FPFH),因其对平移旋转的不变性和较高的描述性,成为应用最广泛的特

征描述子之一^[14]。赵云涛等^[15]和赵辉友等^[16]均基于改进的 FPFH 展开研究,利用随机采样一致性 (RANSAC)^[17]算法或其变体 SAC-IA,从 FPFH 等特征匹配对中剔除误匹配,鲁棒地估计出初始变换矩阵。此外,一些全局配准算法也为粗配准提供了有效途径,如 Aiger 等^[18]提出的超广义四点一致性 (4-points congruent sets, 4PCS) 算法,后续 Mellado 等^[19]通过智能索引将其优化为 Super4PCS,提升了运行效率。

在精配准阶段,研究主要聚焦于对经典 ICP 算法的改进。为提升效率,沈晨等^[20]验证了采用 KD-Tree 加速最近邻搜索的有效性。为提高精度和鲁棒性,学者们提出了多种 ICP 变体。例如,徐浩鸿等^[21]将 GICP 与体素化思想结合,张前等^[22]则通过改进 ThCP 算法来处理多源点云。近年来,大量研究尝试将几何信息融入 ICP 的迭代过程。Guan 等^[23]和 Chen 等^[24]的研究均表明,相较于传统的点到点距离度量,基于点到面的误差模型在配准精度上表现更优。赵夫群等^[25]通过融合曲率、法向角度等多种几何特征来提取特征点,单馨平等^[26]设计了基于法向量和 ISS 的双约束特征提取方法。上述研究表明,在特定应用场景中,几何特征的有效融合是提升配准鲁棒性和精度的关键因素。此外,一些学者从全局优化角度出发,引入智能优化策略以突破局部最优的限制。如 Liu 等^[27]将基于马尔可夫链蒙特卡洛的模拟退火算法 (Markov chain Monte Carlo-simulated annealing, MCMC-SA) 引入 ICP, Lan 等^[28]利用蜂群算法 (bees algorithm) 进行全局优化,以跳出局部最优。

尽管现有点云配准算法取得了一定进展,但在矿井巷道等大型结构化场景中仍面临挑战:特征重复性导致基于 FPFH 等方法的粗配准难以获得准确初始位姿;传统 ICP 及其变体在精配准阶段仅依赖最近邻距离,易在结构相似区域产生误匹配,降低配准精度。为此,本文提出一种结合 SAC-IA 与加权 ICP 的两阶段点云配准方法:首先采用“体素下采样 + 优化的 SAC-IA”实现粗配准,提供良好初始位姿;随后在精配准阶段提出一种融合几何特征的加权 ICP 算法,该算法不再使用单一的最小距离准则,而是通过构建一个结合欧氏距离、法向量夹角和曲率差异的加权成本函数综合评估匹配质量,从而提升匹配点对筛选的判别性,有效抑制误匹配,进而提高配准精度。

1 本文算法

本文提出一种融合改进 SAC-IA 与加权 ICP 的

高效点云配准方法, 整体框架由粗配准与精配准两个阶段构成, 算法流程如图 1 所示。源点云与目标点云经 SOR 滤波完成降噪预处理, 粗配准阶段通过体素下采样与关键点提取, 结合改进的 SAC-IA 算法实现初步对齐, 精配准阶段基于法向量估计与几何特征构建, 引入加权 ICP 算法进行配准优化, 最终获得高精度配准结果。

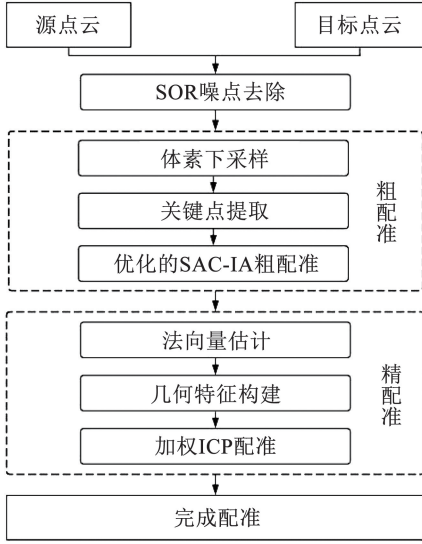


图 1 两阶段点云配准算法流程图

Fig. 1 Flowchart of the two-stage point cloud registration algorithm

2 点云粗配准

2.1 基于重心邻近点的体素下采样

高分辨率点云数据不仅包含宏观外形, 还蕴含微观几何结构, 因其密度大, 需通过下采样降低计算与存储开销。相较于破坏结构的随机下采样, 体素滤波更适用于保留整体形状与细节。传统体素滤波以体素内点的重心为代表, 易丢失原始细节^[29], 本文改用距离重心最近的原始点作为代表点, 能够更

准确保留局部结构, 为后续配准与分割等任务提供更高质量的数据基础。具体改进步骤如下。

1) 依据点云数据坐标集合, 求取 X 、 Y 、 Z 三个坐标轴上的最大值 X_{\max} 、 Y_{\max} 、 Z_{\max} 和最小值 X_{\min} 、 Y_{\min} 、 Z_{\min} 。

2) 根据 X 、 Y 、 Z 三个坐标轴上的最大、最小值, 求得点云最小包围盒的边长 l_x 、 l_y 、 l_z , 即

$$\begin{cases} l_x = x_{\max} - x_{\min} \\ l_y = y_{\max} - y_{\min} \\ l_z = z_{\max} - z_{\min} \end{cases} \quad (1)$$

3) 设置体素栅格的边长 r 。

4) 计算体素栅格尺寸, 根据体素边长 r , 计算各轴上的体素数量:

$$\begin{cases} D_x = \lfloor l_x / r \rfloor \\ D_y = \lfloor l_y / r \rfloor \\ D_z = \lfloor l_z / r \rfloor \end{cases} \quad (2)$$

式中 $\lfloor i \rfloor$ 表示对 i 向下取整。

5) 计算点云中每一个在体素小栅格内的索引 h ,

$$\begin{cases} h_x = \lfloor (x - x_{\min}) / r \rfloor \\ h_y = \lfloor (y - y_{\min}) / r \rfloor \\ h_z = \lfloor (z - z_{\min}) / r \rfloor \end{cases} \quad (3)$$

$$h = h_x + h_y \times D_x + h_z \times D_x \times D_y$$

6) 将 h 的元素按降序排序, 计算每个体素的重心, 并将体素内的所有点替换为重心。

7) 找到距体素重心最近的点, 并将其替换为体素的中心。

以斯坦福公开数据集 (Bunny 和 Dragon) 为例, 对比了不同下采样方法的处理效果。图 2 中从左至右依次展示了原始点云、本文提出的改进体素滤波、均匀下采样及随机下采样的结果。由图 2 可以直观地看出, 相较于传统方法, 本文方法在有效降低点云密度的同时, 实现了更优的分布均匀性, 并更好地保留了模型的关键结构特征。




图 2 斯坦福数据集下采样结果对比

Fig. 2 Comparison of downsampling results on the Stanford dataset

表 1 为不同下采样方法结果,可以看出,改进的体素滤波下采样后的点云数量更少,表明该方法在有效压缩数据的同时,能够更好地保留原始点云的关键结构特征,可为后续的点云配准工作提供更稳定可靠的数据基础。

表 1 不同下采样方法结果数据比较

Tab. 1 Comparison of results from different downsampling methods

Model	Original point cloud	Improved voxel filtering	Uniform sampling	Random downsampling
Bunny	40 256	7 813	8 192	8 051
Dragon	41 841	8 121	8 515	8 368

2.2 基于 SAC-IA 优化的粗配准算法

2.2.1 算法概述

SAC-IA 算法旨在为初始位姿差异较大的点云提供鲁棒的粗配准,以避免后续 ICP 陷入局部最优。该方法通过 FPFH 等特征建立初步对应关系,并采用 RANSAC 在可能存在大量误匹配的点对中反复采样,最终选取内点支持最多的变换作为全局最优的初始位姿。然而,其随机采样策略在处理低质量匹配集时效率低且稳定性不足。本文提出一种鲁棒且高效的改进 SAC-IA 框架,其核心创新在于引入一种基于局部几何一致性验证的“预排除”机制。该机制在 RANSAC 每次迭代中,首先对采样点的几何相容性进行快速判断,提前剔除不满足一致性要求的无效样本,以避免后续昂贵的变换矩阵计算和验证开销。同时,算法强制执行最小内点比例约束,以保证算法在点云数据不完整(如存在遮挡和缺失)的挑战性场景下,最终输出的变换模型仍具备高匹配质量和稳定性。该方法通过从源头提升采样质量,显著增强了 SAC-IA 在复杂场景下的配准精度、收敛速度和鲁棒性。

2.2.2 SAC-IA 算法优化流程

在形式上,点云配准的目标是估计变换 \hat{T} ,该变换最小化源点云 P 上的每个点 p 和目标点云 Q 中的对应点 q 之间的平方距离之和。

$$\hat{T} = \operatorname{argmin}_T \varepsilon(T) = \operatorname{argmin}_T \sum_{p \in P} (Tp - q)^2 \quad (4)$$

为统一表示点的空间变换,上式采用齐次坐标形式。姿态估计通常采用 RANSAC 等鲁棒算法,通过特征对应关系反复执行随机采样、变换估计和一致性验证,有效提升配准精度并抑制异常值影响。

其具体迭代步骤如下。

1) 随机匹配采样点:根据 FPFH 特征,先在源点云 P 中随机选取 $n \geq 3$ 个点,并通过最近邻搜索确定其在目标点云 Q 中的对应点。

2) 估计初始变换:利用选取的 n 个采样匹配,计算出一个初始的假设变换 \hat{T} 。

3) 应用变换:将该初始变换应用于整个源点云 P 。

4) 内点筛选:通过欧氏距离阈值,在变换后的源点云 P 与目标点云 Q 之间进行最近邻搜索,筛选出满足匹配条件的内点集合;若内点数量不足,重新执行步骤 1)。

5) 优化变换:使用新的内点对关系,重新估计更精确的假设变换 \hat{T} 。

6) 更新最优结果:计算当前内点对应点之间的距离 $\varepsilon(\hat{T})$,若该距离达到最小值,则 \hat{T} 作为当前最优变换。重复上述过程,直至达到设定迭代次数或误差收敛。

2.2.3 粗配准实验

将 Bunny 源点云与目标点云经过基于重心邻近点的体素下采样处理后,采用改进的 SAC-IA 算法与传统的 SAC-IA、FPFH、PCA、4PCS 粗配准算法进行对比。

实验以点云配准均方根误差(RMSE)定量评估配准精度,均方根误差越小,说明配准精度越高,以算法耗时评估配准实时性。

$$\operatorname{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n \|P_i - Q_i\|^2} \quad (5)$$

式中: P_i 和 Q_i 分别为第 i 对点云和目标点云中的点, n 为 P 和 Q 重叠部分点的数量。

图 3 为 Bunny 在粗配准算法下的效果图,可以看出,除 PCA 粗配准失败外,其他算法虽均完成了配准,但不同程度地存在误差或瑕疵。相比之下,本文提出的配准方法在点云配准结果的几何一致性和结构连续性方面表现更为优异。Bunny 粗配准实验数据见表 2,可以看到,与原始方法相比,改进后的 SAC-IA 在配准时间上加快了 44.1%,配准精度也有所提升。整体来看,该方法在配准精度和计算效率方面均优于 FPFH、PCA 和 4PCS 等传统方法,在保障较高配准精度的同时有效提升了运算效率,实现了精度与效率之间的良好平衡。




图3 Bunny 在粗配准算法下效果图

Fig. 3 Registration results of Bunny under different coarse alignment algorithms

表2 Bunny 粗配准实验数据

Tab. 2 Experimental data of coarse registration on the Bunny dataset

算法	RMSE/(10^{-6} m)	t/s
SAC-IA	6.2	0.762
FPFH	6.4	0.512
PCA	16.8	0.572
4PCS	13.9	0.536
Proposed method	5.4	0.426

3 点云精配准

3.1 几何特征提取

3.1.1 法向量

点云法向量用于描述点所在局部曲面的朝向,反映其几何结构特性,可辅助识别边缘、拐角等区域,并在结构复杂或遮挡场景中提升配准精度。常用的 PCA 法向量计算方法通过分析点的邻域分布,构建协方差矩阵并进行特征值分解,提取主方向信息,进而计算点间法向量夹角,为后续基于表面特征的精配准提供关键支持。

1) 计算质心

对于点云 $P = \{p_1, p_2, \dots, p_N\}$, 每个点 $p_i = (x_i, y_i, z_i)$, 质心 μ 的公式为

$$\mu = \frac{1}{N} \sum_{i=1}^N p_i = \left(\frac{1}{N} \sum_{i=1}^N x_i, \frac{1}{N} \sum_{i=1}^N y_i, \frac{1}{N} \sum_{i=1}^N z_i \right) \quad (6)$$

2) 中心化点云

将每个点减去质心,得到中心化点集 $P' = \{p'_1, p'_2, \dots, p'_N\}$, 其中

$$p'_i = p_i - \mu \quad (7)$$

3) 构建协方差矩阵

对中心化后的点云数据 P' , 计算协方差矩阵 C

$$C = \frac{1}{N} \sum_{i=1}^N p'_i (p'_i)^T \quad (8)$$

4) 特征值分解

对协方差矩阵 C 进行特征值分解,得到特征值 $\lambda_1, \lambda_2, \lambda_3$ (按降序排列: $\lambda_1 \geq \lambda_2 \geq \lambda_3$) 和对应的特征向量 v_1, v_2, v_3 , 其分别表示点云的主方向、次主方向和最小方向。

5) 计算法向量夹角

法向量角度通常指点云主方向与某个参考方向的夹角,或多个主成分之间的角度。 v_1 与参考向量 r 的夹角为

$$\begin{cases} \cos \theta = \frac{v_1 \cdot r}{\|v_1\| \|r\|} \\ \theta = \arccos \left(\frac{v_1 \cdot r}{\|v_1\| \|r\|} \right) \end{cases} \quad (9)$$

式中, $\|\cdot\|$ 表示向量模长。

3.1.2 曲率

曲率是衡量点云表面局部几何变化的重要特征,可用于识别边缘、角点等关键区域,在复杂场景下提升配准的准确性与鲁棒性。其计算核心在于局部近似:通过主成分分析(PCA)估计点的法向量,确定局部切平面;随后在邻域内拟合二次曲面,并利用其微分几何性质计算主曲率、平均曲率和高斯曲率,从而实现点对点云局部形状的精确定义。计算流程如下。

1) 建立局部坐标系

2) 拟合二次平面

在局部坐标系中,假设曲面可以近似为一个二

次函数。

$$z' = f(x', y') = Ax'^2 + By'^2 + Cx'y' \quad (10)$$

使用最小二乘法拟合系数 A, B, C , 目标是使最小化所有邻域点 $(x'_{ij}, y'_{ij}, z'_{ij})$ 到拟合曲面的残差平方和。

$$\min \sum_{j=1}^k (Ax'_{ij}{}^2 + By'_{ij}{}^2 + Cx'_{ij}y'_{ij} - z'_{ij})^2 \quad (11)$$

3) 计算曲率

高斯曲率 K (gaussian curvature): 描述了曲面在某个点的局部形状。

$$K = \frac{\partial^2 z'}{\partial x'^2 \partial y'^2} - \left(\frac{\partial^2 z'}{\partial x' \partial y'} \right)^2 = 4AB - C^2 \quad (12)$$

平均曲率 H (mean curvature): 描述了曲面在所有方向上的平均弯曲程度。

$$H = \frac{1}{2} \left(\frac{\partial^2 z'}{\partial x'^2} + \frac{\partial^2 z'}{\partial y'^2} \right) = A + B \quad (13)$$

主曲率 k_1, k_2 (principal curvatures): 描述了曲面在两个相互正交的主方向上的最大和最小弯曲程度。

$$k_{1,2} = H \pm \sqrt{H^2 - K} \quad (14)$$

3.2 基于几何特征的加权 ICP 精配准算法

3.2.1 核心内容

在改进的 SAC-IA 粗配准后, 源点云与目标点云已基本对齐, 但仍存在误差, 需进一步精配准。传统 ICP 仅依赖空间距离, 易受巷道点云中较大初始偏差、噪声干扰及复杂几何结构影响, 陷入局部最优, 配准精度和稳定性有限^[30]。为此, 本文提出了一种基于几何特征的自适应加权 ICP 算法, 通过引入法向量约束兼顾空间距离与方向一致性以增强几何匹配; 设计结合点间距离、法向量夹角和曲率差异的自适应权重机制, 突出高质量匹配并抑制噪声影响; 基于加权质心和加权协方差矩阵优化变换估计, 使结果更偏向可靠匹配; 并通过迭代更新匹配点、权重与变换参数, 逐步最小化加权均方根误差, 显著提升配准精度与收敛速度。

3.2.2 算法流程

1) ICP 算法

x_i 和 p_j 分别表示点云 X 和 P 中的第 i 个和第 j 个点的坐标。目标是找到刚性变换 $\mathbf{M} = (\mathbf{M}_R, \mathbf{M}_T)$, 其中, \mathbf{M}_R 是旋转矩阵, \mathbf{M}_T 是平移向量, 使得点云 X 和变换后的点云 P 之间的误差最小。传统 ICP 的误差函数为

$$\operatorname{argmin} N_c^{-1} \cdot \sum_{i=1}^{N_c} \| x_i - (\mathbf{M}_R p_i + \mathbf{M}_T) \|^2 \quad (15)$$

式中: N_c 为对应点对的数量, x_i 和 p_i 为对应点对。

2) 法向量

为了引入几何特征, 算法首先计算每个点的法向量角度变化。设点的法向量 x_i 为 \vec{n}_{x_i} , 其邻域点 x_j 的法向量为 \vec{n}_{x_j} 。两点之间的法向量夹角 $\beta_{x_i x_j}$ 的余弦值定义为

$$\cos \beta_{x_i x_j} = \frac{\vec{n}_{x_i} \cdot \vec{n}_{x_j}}{|\vec{n}_{x_i}| \cdot |\vec{n}_{x_j}|} \quad (16)$$

式中: $\beta_{x_i x_j} \in [0, \pi]$, $\alpha(x_i)$ 为点的法向量角度参数, 定义该点与其邻域内所有点的法向量夹角之和为

$$\alpha(x_i) = \sum_{x_j \in N(x_i)} \beta_{x_i x_j} \quad (17)$$

式中 $N(x_i)$ 为点 x_i 的邻域点集。通过计算 $\alpha(x_i)$, 可以表示点 x_i 在局部几何结构中的特征。

3) 曲率

点云 X 和 P 的每个点 x_i 和 p_i 分别具有曲率值 $K(x_i)$ 和 $K(p_i)$, 曲率差异项可以通过两点曲率的绝对差值 (ΔK_i) 来量化。

$$\Delta K_i = |K(x_i) - K(p_i)| \quad (18)$$

由于曲率值的量纲与欧几里得距离和法向量角度差异不同, 因此对曲率差异进行归一化处理, 以确保误差函数的各部分在同一尺度上。归一化后的曲率差异可以表示为

$$\Delta K'_i = \frac{|K(x_i) - K(p_i)|}{K_{\max}} \quad (19)$$

4) 优化对应点选择

在传统 ICP 中, 对应点通过最小欧几里得距离确定。本文通过法向量角度差异引入约束条件: 对于点云 X 和 P 中的每个点, 计算其 k 个最近邻点的法向量角度 $\alpha(x_i)$ 和 $\alpha(p_i)$ 。选择初始对应点对时, 分别增加法向量角度阈值和曲率阈值约束,

$$\begin{cases} |\alpha(x_i) - \alpha(p_i)| \leq \tau, \\ |K(x_i) - K(p_i)| \leq \tau_k \end{cases} \quad (20)$$

5) 改进的误差函数

在每次迭代中, 算法计算旋转矩阵 \mathbf{M}_R^S 和平移矩阵 \mathbf{M}_T^S , 并引入一个综合了点点到点空间距离、法向量角度及曲率差异的改进误差函数得到

$$E^S = K^{-1} \cdot \sum_{i=1}^K [\| x_i - \mathbf{M}_R^S p_i - \mathbf{M}_T^S \|^2 + |\alpha(x_i) - \alpha(p_i)| + \Delta K'_i] \quad (21)$$

式中 S 为当前迭代次数, 通过最小化 E^S , 算法同时优化空间距离和几何特征的匹配。

6) 设置权重

计算所有对应点对的欧几里得距离、法向量角度差异、曲率差异, 并分别计算标准差 $\sigma_d, \sigma_\alpha, \sigma_k$, 初始权重可以设置为各误差项标准差的倒数, 以平衡其权重占比。

$$w_1 = \frac{1}{\sigma_d}, w_2 = \frac{1}{\sigma_\alpha}, w_3 = \frac{1}{\sigma_k} \quad (22)$$

这种权重分配机制旨在平衡不同误差项的贡献,减小因噪声或点云稀疏性产生的极端值对误差函数的主导作用。为了进一步优化权重,可以将 w_1 、 w_2 、 w_3 视为优化变量,通过最小化配准误差来确定。约束 $w_1 + w_2 + w_3 = 1, w_1, w_2, w_3 \geq 0$,确保权重的相对性,防止误差函数的尺度失衡。最终误差函数为

$$E^S = K^{-1} \cdot \sum_{i=1}^K [w_1 \|x_i - M_R^S p_i - M_T^S\|^2 + w_2 |\alpha(x_i) - \alpha(p_i)| + w_3 \Delta K'_i] \quad (23)$$

针对不同场景的点云,权重 w_1 、 w_2 、 w_3 的设置可以通过分析点云的几何特性和应用需求来直观确定。在规则几何场景(如隧道圆弧表面),优先提高法向角度和曲率差异的权重 w_2 、 w_3 ,以强调局部几何特征;对于稀疏或噪声较大的点云,适当增加欧几里得距离的权重 w_1 ,以保证空间匹配的稳定性。在复杂场景(如隧道缺陷区域),可以试验性地调整权重,结合小规模点云测试,观察配准误差和视觉效果,根据场景特点逐步偏向几何特征或空间距离,确保配准精度与计算效率的平衡,逐步调优。

3.3 精配准实验分析

3.3.1 Bunny 数据权重分析

在粗配准提供的良好初始位姿基础上,进一步采用融合几何特征的加权 ICP 算法进行精配准。该方法通过联合量化点对间的欧氏距离、法向量夹角及曲率差异,实现了一套自适应的权重分配机制,以差异化的方式处理不同匹配对,从而有效提升了配准效果。在 Bunny 点云实验中,得到的一组有效自适应权重约为(0.5, 0.25, 0.25)。为验证其性能,将该权重组合与多组典型的固定权重方案进行对比,结果如表 3 所示。图 4 和图 5 分别展示了 Bunny 数据在不同权重组合下的 RMSE 及配准耗时对比,综合分析认为,自适应权重在配准精度和计算效率方面均优于其他方案,展现出良好的鲁棒性与适应性。

表 3 Bunny 数据下不同权重组合配准效果

Tab.3 Registration performance under different weight combinations on the Bunny dataset

权重组合	距离	法向量	曲率	RMSE/(10 ⁻⁶ m)	时间/s
A	1	0	0	4.2	0.845
B	1/3	1/3	1/3	4.0	0.736
C	0.5	0.40	0.10	3.8	0.702
D	0.5	0.30	0.20	3.4	0.648
E	0.5	0.20	0.30	3.6	0.649
F	0.4	0.50	0.10	3.9	0.701
G	0.4	0.10	0.50	4.1	0.784
自适应	0.5	0.25	0.25	3.2	0.626




图 4 Bunny 数据下不同权重组合的 RMSE 对比图

Fig.4 RMSE comparison under different weight combinations on the Bunny dataset




图 5 Bunny 数据下不同权重组合的配准耗时对比图

Fig.5 Comparison of registration time under different weight combinations on the Bunny dataset

3.3.2 算法性能对比

为全面评估所提算法的性能,本文将其分别与传统精配准算法(ICP^[31]、PICP^[32]、GICP^[33]和 VGICP^[34])以及主流深度学习配准算法(PointNetLK、DCP^[35](deep closest point)和 DGR^[36])进行了对比实验。传统算法与深度学习算法的定性配准效果分别如图 6 和图 7 所示,对应的定量性能评估数据分别如表 4 和表 5 所示。

分析表 4 数据可知,在与传统算法的对比中,本文方法在配准精度和计算效率方面均表现出显著优势。在计算效率方面,虽然本文算法的单次迭代耗时略长,但由于引入几何特征后收敛速度更快、所需迭代次数更少,整体配准时间较 ICP、PICP、GICP 和 VGICP 分别缩短了约 25.9%、28.5%、97.1% 和 50.3%。在配准精度方面,本文算法较上述 4 种传统算法分别提升了约 23.81%、21.95%、38.46% 和 58.97%。




图 6 Bunny 在传统精配准算法下效果图

Fig. 6 Registration results of Bunny under traditional fine registration algorithms




图 7 Bunny 在深度学习配准算法下效果图

Fig. 7 Registration results of Bunny under deep learning-based algorithms

表 4 Bunny 传统精配准实验数据

Tab. 4 Experimental data of Bunny using traditional fine registration algorithms

算法	RMSE/(10 ⁻⁶ m)	t/s
ICP	4.2	0.845
PICP	4.1	0.875
GICP	5.2	21.785
VGICP	7.8	1.260
Proposed method	3.2	0.626

表 5 Bunny 深度学习配准实验数据

Tab. 5 Experimental data of Bunny using deep learning registration methods

算法	RMSE/(10 ⁻⁶ m)	t/s	
		CPU	GPU
PointNetLK	3.4	8.52	0.85
DCP	3.1	10.15	0.58
DGR	3.0	12.61	0.43

进一步结合表 5 中深度学习方法的配准结果可知,DCP 和 DGR 凭借其强大的特征学习能力,在

GPU 加速下展现了较高的配准精度。然而,此类方法高度依赖高性能 GPU 硬件,运行效率远低于本文算法(耗时通常为其 10 倍以上)。相比之下,本文算法仅依靠普通 CPU 即可达到与 SOTA 深度学习方法相当的配准精度,且耗时仅 0.626 s,效率优势明显。上述综合对比结果充分表明,本文提出的加权 ICP 算法通过有效融合几何特征,成功实现了高精度与高效率的平衡,尤为适用于无法配备高性能 GPU 的轻量化工业应用场景。

4 巷道点云数据配准分析

尽管本文提出的粗、精配准算法已在斯坦福公共数据集上验证了其各自的优越性,但这类理想化的数据主要用于评估算法的理论性能上限。为了全面检验所提出的完整两阶段配准框架在真实、复杂场景下的实际效能与鲁棒性,本文特别采用一组实测的巷道点云数据进行实验。巷道场景点云数据不仅规模庞大,更因行人遮挡、粉尘、反光等干扰,呈现出分布不均、局部稀疏与高噪声等非理想特性,能够

更有效地检验算法在真实场景中的性能。

4.1 巷道点云数据采集

本文所用数据采集自某矿井下巷道,巷道宽 3~4 m、高 3~5 m,墙体存在不规则起伏、拐角和支撑结构等多种几何特征。点云由安装在机器人两侧的两台 32 线 Livox Avia 固态激光雷达从不同角度采集,视角互补以实现全景覆盖,采样频率为 10 Hz,单帧点数 10~50 万,点云数据量庞大。实验环境配

置如下:处理器为 Intel(R) Core(TM) i7-11370H @ 3.30 GHz,GPU 为 NVIDIA RTX 3080,内存 16 GB,操作系统为 Ubuntu 20.04。在传统配准算法实验中,基于 Visual Studio 2019 平台,使用 C++ 语言与 PCL 1.14.1 库实现;在深度学习实验中,则基于 PyCharm Community Edition 2022.1.2 环境,使用 Python 语言和 PyTorch 框架完成算法实现。Livox Avia 激光雷达的主要参数如表 6 所示。

表 6 激光雷达基本参数

Tab. 6 Basic parameters of the LiDAR sensor

最大测距/m	激光波长/nm	测距精度/cm	扫描频率/(点·s ⁻¹)	视场角/(°)	
				非重复扫描	重复扫描
240	905	±2	240 000	70.4×77.2	70.4×4.5

4.2 巷道数据预处理

激光雷达对巷道环境扫描后记录了连续点云数据流。通过 ROS 解析逐帧提取原始点云,每帧含 12~15 万个点,为提升效率并验证算法稳健性,配准实验中选取间隔 50 帧的两组点云进行处理。由于巷道环境复杂,原始数据中存在多路径噪点、测距误差导致的孤立点及遮挡造成的孔洞等(图 8),这些

噪点会影响配准精度,并降低后续特征提取与对应点匹配的稳定性。为此,配准前采用统计离群点剔除(statistical outlier removal, SOR)方法对点云进行预处理,结果如图 9 所示,可以看到,巷道内外的噪点均已去除,有效提升了数据质量,可为后续点云配准提供更可靠的数据基础。




图 8 初始巷道点云
Fig. 8 Raw point cloud of the tunnel




图 9 SOR 巷道点云去噪
Fig. 9 SOR denoising of tunnel point cloud

由于点云数据量庞大,为满足实际应用中轻量化处理的需求,本文采用基于重心邻近点的体素

下采样方法对巷道点云进行简化。多次实验表明,当体素网格尺寸设置为 0.05 时,可取得较理想的下

采样效果。采用基于重心邻近点的体素下采样法对巷道点云进行处理,其可视化结果见图 10。该方法在显著压缩点云数据规模的同时,较好地保留了整体形状特征,有效维护了巷道的几何结构与局部细节。下采样前后的点云数量变化如表 7 所示。




图 10 巷道点云体素下采样

Fig. 10 Voxel downsampling of tunnel point cloud

表 7 预处理后巷道点云数量

Tab. 7 Number of tunnel point clouds after preprocessing

点云类型	原始点数	SOR 去噪后点数	体素下采样后点数
源点云	134 072	130 138	63 264
目标点云	133 668	125 873	62 906

4.3 巷道点云配准实验

将预处理后的巷道点云数据依次采用提出的粗配准与精配准算法,旨在实现多视角激光雷达数据的高效对齐,重建结构完整、无缝衔接的巷道点云模型,尤其用于修复因行人遮挡导致的局部孔洞,提升模型完整性与连续性。

4.3.1 巷道数据权重分析

针对巷道点云中大面积平直、结构规整且特征分布不均的特点,实验选取了多组典型的权重组合方案,并与自适应权重组合进行对比,结果如表 8 所示。图 11 与图 12 分别为不同权重组合下巷道数据的 RMSE 及配准耗时对比,综合两图分析可见,自适应权重组在配准精度和计算效率方面均表现最优。

表 8 巷道数据下不同权重组合配准效果

Tab. 8 Registration performance under different weight combinations on tunnel data

权重组合	距离	法向量	曲率	RMSE/(10 ⁻⁶ m)	时间/s
A	1	0	0	41.3	21.34
B	1/3	1/3	1/3	37.8	21.12
C	0.5	0.4	0.1	35.5	19.31
D	0.6	0.3	0.1	36.8	20.18
E	0.4	0.5	0.1	30.1	18.89
F	0.5	0.2	0.3	39.8	20.16
G	0.4	0.4	0.2	36.6	19.84
自适应	0.3	0.6	0.1	27.2	18.66




图 11 巷道数据下不同权重组合的 RMSE 对比图

Fig. 11 RMSE comparison under different weight combinations on tunnel data




图 12 巷道数据下不同权重组合的配准耗时对比图

Fig. 12 Comparison of registration time under different weight combinations on tunnel data

该组合中,法向量权重约为 0.6,作为主要配准约束,有助于强化对墙面、顶底板等大尺度结构的对齐效果;欧氏距离权重约为 0.3,用于保证点对之间在空间上的邻近性,从而提升整体配准的一致性;曲率权重约为 0.1,主要针对角落、管道等局部高曲率区域进行细节补偿与约束,以减少噪声干扰并提高局部贴合度。最终选定自适应权重作为巷道点云精配准阶段的最优参数设置。

4.3.2 巷道配准结果分析

图 13 与图 14 分别为本文方法配准后的巷道整体轮廓与内壁细节,可以清晰地看出,配准后的点云不仅有效填补了因遮挡造成的缺失区域,还提升了整体点云的结构一致性和平滑度,为后续的三维重建、目标识别和轨迹规划等任务奠定了高质量的数据基础。




图 13 配准后整体巷道轮廓

Fig. 13 Overall tunnel contour after registration




图 14 配准后巷道内壁

Fig. 14 Inner wall of the tunnel after registration

将所提出的配准算法与多种经典的粗精配准组合方法进行了对比实验,包括 SAC-IA + ICP、NDT + ICP、FPFH + ICP、ISS + ICP 和 RANSAC + ICP。表 9 对比了实测巷道点云在不同传统配准算法下的性能表现。由表 9 可知,本文方法在配准精度和运行效率方面均表现出显著优势:在运行时间方面,较 SAC-IA + ICP、NDT + ICP、FPFH + ICP、ISS + ICP 和 RANSAC + ICP 分别加快了 68.93%、21.44%、70.33%、87.94% 和 66.41%;在配准精度方面,分别提升了约 22.46%、31.00%、57.73%、46.84% 和 50.90%。上述结果充分验证了本文所提算法在精度与效率之间实现了良好平衡,尤其在面对结构复杂或存在局部遮挡的点云数据时,表现出更强的鲁棒性与适应性。

表 9 实测巷道点云不同传统配准算法的性能比较

Tab. 9 Performance comparison of different traditional registration algorithms for measured tunnel point clouds

算法	RMSE/(10^{-6} m)	t/s
SAC-IA + ICP	18.34	106.880
NDT + ICP	20.61	42.266
FPFH + ICP	33.64	111.929
ISS + ICP	26.75	275.333
RANSAC + ICP	28.96	98.862
Proposed method	14.22	33.206

将本文算法与 SOTA 深度学习算法在真实的巷道数据上进行了比较,实验结果如表 10 所示,可以看到 DGR 方法凭借其强大的全局特征描述能力,在配准精度方面取得了最优结果。值得注意的是,在

这一更具挑战性的实测巷道场景中,本文提出的方法在精度上优于 DCP 和 PointNetLK,表明本文算法利用显式几何约束,在处理具有重复性结构和噪声的真实数据时具有更强的鲁棒性。在计算效率和硬件依赖方面,本文算法的优势极为突出,在 CPU 平台上,本文算法的配准速度比其他 3 种深度学习方法快 6~8 倍。在高性能 GPU 上运行,即使是 SOTA 方法,其最快速度(DCP 的 35.2 s)也比本文算法在普通 CPU 上的运行速度慢。综上所述,考虑到开槽机器人作业平台对算法轻量化、低功耗和高实时性的严苛要求,本文提出的方法无需依赖昂贵的 GPU 硬件,即可在普通 CPU 上实现高精度、高效率的配准,展现了其在工业落地应用中的潜力和实用价值。

表 10 实测巷道点云不同深度学习配准算法性能比较

Tab. 10 Performance comparison of different deep learning registration algorithms for measured tunnel point clouds

算法	RMSE/(10^{-6} m)	t/s	
		CPU	GPU
PointNetLK	15.12	205.4	45.8
DCP	14.96	260.8	35.2
DGR	13.86	291.3	40.6

5 结 语

为提升矿井巷道等大型结构化场景中点云配准的精度、效率与鲁棒性,本文提出了一种基于“粗配准 + 精配准”框架的改进型点云配准方法。首先对初始点云进行预处理,引入基于重心邻近点的体素下采样算法,在有效降低数据规模的同时,较好地保留了局部几何特征,实现工程轻量化。粗配准阶段采用改进的 SAC-IA 算法,以获得更稳健的初始对齐结果;精配准阶段融合欧氏距离、法向量夹角和曲率等多维特征信息,构建加权 ICP 算法,有效缓解了结构重复所引发的匹配误差。实验结果表明,改进的 SAC-IA 算法在斯坦福数据集上相较于传统粗配准方法,在配准精度与计算效率方面均有明显提升;相比传统 ICP 算法,加权 ICP 算法配准精度提升 23.81%,计算效率提升 25.9%。在实测矿井巷道点云数据上,本文方法在配准精度与效率方面最高分别提升 57.73% 与 87.94%,进一步验证了其在复杂结构场景下的高鲁棒性与适应性。与主流深度学习算法相比,本文方法在无需 GPU 加速的情况下,实现了与之相当的配准精度,并展现出卓越的计算效率,更适用于轻量化应用场景。在更具挑战性的实测巷道场景中,本文方法利用显式几何约束,表现

出比部分深度学习方法更强的鲁棒性与精度,且在 CPU 平台的运行速度超越了依赖 GPU 的 SOTA 方法,凸显了其工业落地价值。

尽管本文提出的方法在实验中表现出显著优势,但其应用仍受两方面局限:一是其性能依赖于场景的结构化特征,在几何信息无序的自然环境中,基于稳定特征的加权机制可能失效;二是其自动化程度不足,核心权重外的关键超参数(如体素尺寸)仍需人工设定,增加了算法向新数据类型迁移时的调参负担。

综上,本文所提出的配准方法具有良好的通用性,适用于大型工业环境中的三维重建任务。未来工作将进一步探索加权机制与深度学习模型的融合,可设计一个小型注意力网络替代当前基于统计方差的权重分配模块,以局部点云片的几何统计特征为输入,输出欧氏距离、法向量夹角与曲率 3 类误差项的最优权重。通过这种数据驱动的智能权重分配机制,在不增加计算开销的前提下,进一步提升算法在复杂场景中的自适应性与精度。

参考文献

- [1] YANG Jianjian, WANG Chao, LUO Wenjie, et al. Research on point cloud registering method of tunneling roadway based on 3D NDT-ICP algorithm[J]. *Sensors*, 2021, 21(13): 4448. DOI: 10.3390/s21134448
- [2] BESL P J, MCKAY N D. Method for registration of 3-D shapes[C]// *Sensor Fusion IV: Control Paradigms and Data Structures*. Bellingham, WA: Spie, 1992, 1611: 586. DOI: 10.1117/12.57955
- [3] 马然. 基于特征点提取和 PCA 的改进 ICP 点云配准方法[J]. *电子技术应用*, 2025, 51(4): 110
MA Ran. Improved ICP point cloud registration method based on feature point extraction and PCA [J]. *Application of Electronic Technique*, 2025, 51(4): 110. DOI: 10.16157/j. issn. 0258 - 7998. 245473
- [4] 卢升, 韩俊刚, 王连哲, 等. 两阶段变尺度三维点云配准算法研究[J]. *激光与光电子学进展*, 2020, 57(20): 286
LU Sheng, HAN Jungang, WANG Lianzhe, et al. Research on two-stage variable scale three-dimensional point cloud registration algorithm[J]. *Laser & Optoelectronics Progress*, 2020, 57(20): 286. DOI: 10.3788/LOP57.201503
- [5] AOKI Y, GOFORTH H, SRIVATSAN R A, et al. Pointnetk: Robust & efficient point cloud registration using pointnet [C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Long Beach, CA: IEEE, 2019: 7163. DOI: 10.1109/CVPR.2019.00733
- [6] CHOY C, DONG Wei, KOLTUN V. Deep global registration[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Seattle, WA: IEEE, 2020: 2514. DOI: 10.1109/cvpr42600.2020.00259
- [7] 王明, 邓志良, 严飞, 等. 基于下采样优化的点云配准方法[J]. *应用激光*, 2024, 44(5): 201
WANG Ming, DENG Zhiliang, YAN Fei, et al. Point cloud registration method based on down sampling optimization [J]. *Applied Laser*, 2024, 44(5): 201. DOI: 10.14128/j. cnki. al. 20244405. 201
- [8] 许航, 孙宏昌, 梁志强, 等. 基于快速鲁棒-最近点迭代算法的构件点云配准方法[J]. *制造技术与机床*, 2025(8): 77
XU Hang, SUN Hongchang, LIANG Zhiqiang, et al. Component point cloud registration method based on fast and robust-iterative closest point algorithm [J]. *Manufacturing Technology & MachineTool*, 2025(8): 77. DOI: 10.19287/j. mtmt. 1005 - 2402. 2025. 08. 009
- [9] 刘翔宇, 王健, 王效盖, 等. 基于 3DSIFT 特征点的改进 ICP 点云配准算法[J]. *应用激光*, 2023, 43(11): 153
LIU Xiangyu, WANG Jian, WANG Xiaogai, et al. Point cloud registration algorithm based on the 3DSIFT feature points with improved ICP algorithm[J]. *Applied Laser*, 2023, 43(11): 153. DOI: 10.14128/j. cnki. al. 20234311. 153
- [10] 张平均, 赵浩. 基于改进 3DSIFT 算法的点云配准方法[J]. *激光与红外*, 2025, 55(2): 296
ZHANG Pingjun, ZHAO Hao. Point cloud registration based on improved 3DSIFT algorithm[J]. *Laser and Infrared*, 2025, 55(2): 296. DOI: 10.3969/j. issn. 1001 - 5078. 2025. 020
- [11] 景会成, 王睿宇, 张靖轩, 等. 基于 3DHarris-FPFH 特征点云配准方法[J]. *激光与红外*, 2024, 54(12): 1948
JING Huicheng, WANG Ruiyu, ZHANG Jingxuan, et al. Point cloud registration method based on 3DHarris-FPFH features[J]. *Laser & Infrared*, 2024, 54(12): 1948. DOI: 10.3969/j. issn. 1001 - 5078. 2024. 12. 021
- [12] 魏永超, 邓毅. 基于关键点的边界增强改进点云配准算法[J]. *中国测试*, 2023, 49(12): 29
WEI Yongchao, DENG Yi. Improved point cloud alignment algorithm with key point based boundary enhancement [J]. *China Measurement & Test*, 2023, 49(12): 29. DOI: 10.11857/j. issn. 1674 - 5124. 2022050168
- [13] RUSU R B, BLODOW N, BEETZ M. Fast point feature histograms (FPFH) for 3D registration [C]// *2009 IEEE International Conference on Robotics and Automation*. Piscataway: IEEE, 2009: 3212. DOI: 10.1109/ROBOT.2009.5152473
- [14] RUSU R B. Semantic 3D object maps for everyday manipulation in human living environments [J]. *Künstl Intell.*, 2010, 24: 345. DOI: 10.1007/s13218 - 010 - 0059 - 6
- [15] 赵云涛, 胡佳明, 李维刚, 等. 基于改进 FPFH 特征提取的点云模板匹配方法[J]. *应用激光*, 2024, 44(4): 196
ZHAO Yuntao, HU Jiaming, LI Weigang, et al. Point cloud template matching method based on improved FPFH feature extraction [J]. *Applied Laser*, 2024, 44(4): 196. DOI: 10.14128/j. cnki. al. 20244404. 196
- [16] 赵辉友, 吴学群, 刘洋. 基于 FPFH 的双向 K 维树最邻近距离比点云配准方法研究[J]. *应用激光*, 2024, 44(6): 184
ZHAO Huiyou, WU Xuequn, LIU Yang. Research on the closest distance ratio point cloud registration method of bidirectional K-dimensional trees based on FPFH [J]. *Applied Laser*, 2024, 44(6): 184. DOI: 10.14128/j. cnki. al. 20244406. 184
- [17] 李岩, 张子毅, 王建柱. 基于特征点提取的 RANSAC-ICP 三维点云配准方法[J]. *山东大学学报(工学版)*, 2024, 54(5): 144

- LI Yan, ZHANG Ziyi, WANG Jianzhu. RANSAC-ICP 3D point cloud registration method based on featurepoint extraction [J]. Journal of Shandong University (Engineering Science), 2024, 54(5): 144. DOI: 10.6040/j.issn.1672-3961.0.2023.102
- [18] AIGER D, MITRA N J, COHEN-OR D. 4-points congruent sets for robust pairwise surface registration [C]// SIGGRAPH 2008 papers. New York: ACM, 2008; 1. DOI: 10.1145/1399504.1360684
- [19] MELLADO N, AIGER D, MITRA N J. Super 4PCS fast global pointcloud registration via smart indexing [J]. Computer Graphics Forum, 2014, 33(5): 205. DOI: 10.1111/cgf.12446
- [20] 沈晨, 薛龙, 李万祺, 等. 基于 KD-ICP 算法的机器人拆解目标三维点云配准方法 [J]. 科学技术与工程, 2024, 24(21): 9025
- SHEN Chen, XUE Long, LI Wanqi, et al. 3D Point cloud registration method for robot dismantling targets based on KD-ICP algorithm [J]. Science Technology and Engineering, 2024, 24(21): 9025. DOI: 10.12404/j.issn.1671-1815.2305530
- [21] 徐浩鸿, 付昱凯, 崔世界. 基于 PCA 的体素化 GICP 点云配准算法 [J]. 组合机床与自动化加工技术, 2025(1): 155
- XU Haohong, FU Yukai, CUI Shijie. Voxel-based GICP registration algorithm based on PCA [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2025(1): 155. DOI: 10.13462/j.cnki.mmtamt.2025.01.030
- [22] 张前, 王健, 刘春晓, 等. 改进 TrICP 算法的多源点云配准研究 [J]. 应用激光, 2024, 44(2): 69
- ZHANG Qian, WANG Jian, LIU Chunxiao, et al. Multi-source point cloud registration of improved TrICP algorithm [J]. Applied Laser, 2024, 44(2): 69. DOI: 10.14128/j.cnki.al.20244402.069
- [23] GUAN Wei, LI Wentao, REN Yan. Point cloud registration based on improved ICP algorithm [C]//2018 Chinese Control and Decision Conference (CCDC). Piscataway: IEEE, 2018: 1461. DOI: 10.1109/CCDC.2018.8407357
- [24] CHEN Yang, MEDIONI G. Object modelling by registration of multiple range images [J]. Image and Vision Computing, 1992, 10(3): 145. DOI: 10.1016/0262-8856(92)90066-C
- [25] 赵夫群, 黄鹤, 耿国华. 基于主成分特征向量的点云配准方法 [J]. 应用科学学报, 2024, 42(6): 962
- ZHAO Fuqun, HUANG He, GENG Guohua. Point cloud registration method based on principal component eigenvectors [J]. Journal of Applied Science-Electronics and Information Engineering, 2024, 42(6): 962. DOI: 10.3969/j.issn.0255-8297.2024.06.006
- [26] 单馨平, 苏建强, 刘利强, 等. 基于双约束特征提取的三维激光雷达点云 ICP 配准算法 [J]. 应用激光, 2025, 45(1): 143
- SHAN Xiping, SU Jianqiang, LIU Liqiang, et al. A 3D LiDAR point cloud ICP registration algorithm based on dual-constraint feature extraction [J]. Applied Laser, 2025, 45(1): 143. DOI: 10.14128/j.cnki.al.20254501.143
- [27] LIU Haibo, LIU Tianran, LI Yapeng, et al. Point cloud registration based on MCMC-SA ICP algorithm [J]. IEEE Access, 2019, 7: 73637. DOI: 10.1109/ACCESS.2019.2919989
- [28] LAN Feiying, CASTELLANI M, ZHENG Senjing, et al. The SVD-enhanced bees algorithm, a novel procedure for point cloud registration [J]. Swarm and Evolutionary Computation, 2024, 88: 101590. DOI: 10.1016/j.swevo.2024.101590
- [29] ZHAO Haozheng, HU Qingwu. 3D reconstruction and rendering visualization of tunnel point cloud [J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2022, 48: 93. DOI: 10.5194/isprs-archives-XLVIII-3-W1-2022-93-2022
- [30] SONG Qing, XU Degang, FANG Shiyu. 3D tunnel surface reconstruction method in complex scenarios [C]//2021 China Automation Congress (CAC). Piscataway: IEEE, 2021: 1369. DOI: 10.1109/CAC53003.2021.9728513
- [31] 杨玲, 譙舟三, 陈玲玲, 等. 结合 Procrustes 分析法和 ICP 算法的 PICP 配准算法 [J]. 计算机辅助设计与图形学学报, 2017, 29(2): 337
- YANG Ling, QIAO Zhousan, CHEN Lingling, et al. PICP registration method based on procrustes analysis and ICP algorithm [J]. Journal of Computer-Aided Design & Computer Graphics, 2017, 29(2): 337. DOI: 10.3969/j.issn.1003-9775.2017.02.016
- [32] KOIDE K, YOKOZUKA M, OISHI S, et al. Voxelized GICP for fast and accurate 3D point cloud registration [C]//2021 IEEE International Conference on Robotics and Automation (ICRA). Piscataway: IEEE, 2021: 11054. DOI: 10.1109/ICRA48506.2021.9560835
- [33] XIA Y, LIU Z, LIU H. Adaptive Resolution VGICP algorithm for robust and efficient point-cloud registration [J]. Remote Sensing, 2025, 17(17): 3056. DOI: 10.3390/rs17173056
- [34] KOIDE K, YOKOZUKA M, OISHI S, et al. Voxelized GICP for fast and accurate 3D point cloud registration [C]//2021 IEEE International Conference on Robotics and Automation (ICRA). Piscataway: IEEE, 2021: 11054. DOI: 10.1109/ICRA48506.2021.9561044
- [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. Piscataway: IEEE, 2019: 3522. DOI: 10.1109/ICCV.2019.00362
- [36] WEBER M, WILD D, KLEESIEK J, et al. Deep learning-based point cloud registration for augmented reality-guided surgery [C]//2024 IEEE International Symposium on Biomedical Imaging (ISBI). Piscataway: IEEE Computer Society, 2024; 1. DOI: 10.1109/ISBI56570.2024.10635333

(编辑 吕雪梅)