中国光学（中英文） Chinese Optics 核心期刊

基于逐点前进法的改进型点云配准方法

李茂月 许圣博 孟令强 刘志诚

An improved point cloud registration method based on the point-by-point forward method

LI Mao-yue, XU Sheng-bo, MENG Ling-qiang, LIU Zhi-cheng

引用本文:
李茂月, 许圣博, 孟令强, 刘志诚. 基于逐点前进法的改进型点云配准方法[J]. 中国光学, 2024, 17(4): 875-885. doi: 10.37188/CO.2023-0166
LI Mao-yue, XU Sheng-bo, MENG Ling-qiang, LIU Zhi-cheng. An improved point cloud registration method based on the point-by-point forward method[J]. *Chinese Optics*, 2024, 17(4): 875-885. doi: 10.37188/CO.2023-0166

在线阅读 View online: https://doi.org/10.37188/CO.2023-0166

您可能感兴趣的其他文章

Articles you may be interested in

激光扫描匹配方法研究综述

A survey of laser scan matching methods

中国光学（中英文）. 2018, 11(6): 914 https://doi.org/10.3788/CO.20181106.0914

基于改进的局部表面凸性算法三维点云分割

Improved local convexity algorithm of segmentation for 3D point cloud

中国光学（中英文）. 2017, 10(3): 348 https://doi.org/10.3788/CO.20171003.0348

基于点光源和球面光源的集鱼灯照度模型比较研究

Comparative study on the illumination model of fishing lamps based on point light sources and spherical light sources

中国光学（中英文）. 2019, 12(2): 274 https://doi.org/10.3788/CO.20191202.0274

高灵敏度空间点目标探测系统设计

Design of highly sensitive space point target detection system

中国光学（中英文）. 2018, 11(1): 115 https://doi.org/10.3788/CO.20181101.0115

基于线结构光传感器的轨道板几何形貌检测方法

A detection method based on line-structured light sensor for geometrical morphology of track slab

中国光学（中英文）. 2018, 11(5): 841 https://doi.org/10.3788/CO.20181105.0841

点衍射干涉检测技术

Point diffraction in terference detection technology

中国光学（中英文）. 2017, 10(4): 391 https://doi.org/10.3788/CO.20171004.0391

文章编号　2097-1842(2024)04-0875-11

基于逐点前进法的改进型点云配准方法

李茂月*, 许圣博, 孟令强, 刘志诚
（哈尔滨理工大学 先进制造智能化技术教育部重点实验室, 黑龙江 哈尔滨 150080）

摘要: 点云配准是获取三维点云模型空间姿态的关键步骤, 为了进一步提高点云配准的效率和准确性, 提出了一种基于逐点前进法特征点提取的改进型点云配准方法。首先, 利用逐点前进法快速提取点云特征点, 在保留点云模型特征的同时大幅精简点云数量。然后, 通过使用法向量约束改进的 KN-4PCS 算法进行粗配准, 以实现源点云与目标点云的初步配准。最后, 使用双向 Kd-tree 优化的 LM-ICP 算法完成精配准。实验结果显示: 在斯坦福大学开放点云数据配准实验中, 其平均误差较 SAC-IA+ICP 算法减少了约 70.2%, 较 NDT+ICP 算法减少了约 49.6%, 配准耗时分别减少约 86.2% 和 81.9%, 同时在引入不同程度的高斯噪声后仍能保持较高的精度和较低的耗时。在真实室内物体点云配准实验中, 其平均配准误差为 0.0742 mm, 算法耗时平均为 0.572 s。通过斯坦福开放数据与真实室内场景物体点云数据对比分析结果表明: 本方法能够有效提高点云配准的效率、准确性和鲁棒性, 为基于点云的室内目标识别与位姿估计奠定了良好的基础。

关　键　词: 点云配准; KN-4PCS; 双向 Kd-tree; LM-ICP
中图分类号: TP394.1　　**文献标志码:** A　　**doi:** 10.37188/CO.2023-0166

An improved point cloud registration method based on the point-by-point forward method

LI Mao-yue*, XU Sheng-bo, MENG Ling-qiang, LIU Zhi-cheng
(*The Key Laboratory of Advanced Manufacturing and Intelligent Technology of the Ministry of Education, Harbin University of Science and Technology, Harbin* 150080, *China*)
* *Corresponding author, E-mail: lmy*0500@163.*com*

Abstract: We propose an improved point cloud registration method based on point-by-point forward feature point extraction to improve the efficiency and accuracy of point cloud registration. Firstly, the point-by-point forward method was used to quickly extract the point cloud feature points, significantly reducing the number of point clouds while retaining the characteristics of the point cloud model. Then, the improved KN-4PCS algorithm using normal vector constraints was coarsely registered to achieve the preliminary registration of the source point cloud and the target point cloud. Finally, the two-way Kd-tree optimized LM-ICP algorithm was used to complete the fine registration. In this paper, registration experiments were conducted on different point cloud data. In the registration experiment on Stanford University open point cloud data, the average er-

收稿日期: 2023-09-22; **修订日期:** 2023-10-19
基金项目: 国家自然科学基金(No. 51975169); 黑龙江省自然科学基金(No. LH2022E085)
Supported by National Natural Science Foundation of China (No. 51975169); Natural Science Foundation of Heilongjiang Province (No. LH2022E085)

ror was reduced by about 70.2% compared with the SAC-IA+ICP algorithm, about 49.6% compared with the NDT+ICP algorithm, and the registration time was reduced by about 86.2% and 81.9%, respectively, while maintaining high accuracy and lower time consumption after introducing different degrees of Gaussian noise. In the point cloud registration experiment on real indoor objects, the average registration error was 0.0742 mm, and the average algorithm time was 0.572 s. The experimental results show that the proposed method can effectively improve the point cloud registration's efficiency, accuracy, and robustness, thereby providing a solid foundation for indoor target recognition and pose estimation based on the point cloud.

Key words: point cloud registration; KN-4PCS; bidirectional Kd-tree; LM-ICP

1 引 言

随着机器视觉技术的发展，三维点云被应用在医学、工业、文物保护、机器人技术等多个领域[1]。三维点云数据是从现实世界中直接采集的，具有很高的真实性和准确性，不仅包含了空间中的几何信息，还可以包含颜色、法线等信息。在众多的三维点云传感器中，深度相机具有成本较低，结构简单，使用灵活方便等特点，因此多被用作室内移动机器人的视觉传感器。通过深度相机采集的室内点云数据，机器人可以完成建图导航、抓取等操作。然而，在室内救援场景下，点云数据的应用不仅仅局限于一般的任务需求，它在提高救援效率和成功率方面也扮演着关键角色。对于室内救援任务，机器人需要获取目标的准确位姿。这涉及到识别被困者的确切位置以及可能的移动状态。通过精准的点云配准，机器人可以将实际观测到的点云数据与先前建立的地图或模型进行对比，确定目标的位置和方向，确保精确的抓取和救援。同时，在救援任务中点云配准还需具有较好的实时性。救援过程中的环境可能会发生变化，例如，由于被困者的移动或障碍物的移动，救援机器人必须能够实时更新环境信息。高效的点云配准可以帮助机器人持续跟踪目标的位置和姿态，确保机器人可以快速适应变化的情况，避免碰撞冲突，提高救援过程的安全性。综上所述，准确高效的点云配准在室内救援场景中扮演着至关重要的角色。它不仅提供了目标的准确位置和姿态信息，还赋予了机器人实时感知和反应能力，从而确保救援任务的成功执行。

点云配准方法一般分为两个过程：点云粗配准和点云精配准。点云粗配准是指在点云配准的初始阶段，使两个点云在大致位置上达到一定的对齐，目的是快速找到两个点云的初始变换，为后续的精配准提供一个良好的初始估计。Zou 等人[2] 提出了一种基于平面的全局配准方法，该方法在粗配准阶段使用 M 估计采样（M-Estimate Sample Consensus, MSAC）算法计算平面的旋转矩阵和平面平移向量，可以显著减少垂直方向的配准误差。Cao 等人[3] 将粗配准的问题表述为多特征匹配问题，该方法根据预先提取的点云模型的轴线结构匹配每一特征，将注意力集中在检索相似的轴线结构上，从而大大降低了计算成本，但此方法只适用于具有较规则的点云模型。Deng 等人[4] 基于采样一致性初始配准（Sample Consensus Initial Aligment, SAC-IA）算法的 SAC-IA-ICP 配准方法进行点云位姿估计，在粗配准阶段利用 FPFH 特征描述符在点云中搜索相应点对，然后利用采样一致性不断迭代，去除错误点对，求解具有最小配准误差的刚性变换矩阵。Shi 等人[5] 针对点云规模较大时传统的 ICP 算法配准速度较慢的问题，提出一种基于正态分布变换（Normal Distributions Transform, NDT）的迭代最接近配准算法。该算法采用 NDT 作为粗配准算法，不需要花费过多时间去寻找最近邻匹配点，加快了配准速度。全等四点集（4-Points Congruent Sets, 4PCS）方法是一种常用的点云粗配准方法，由 Aiger 等人[6] 提出。该方法基于仿射不变性，不依赖其他局部特征，在处理低重叠率点云时鲁棒性较强[7]。Theiler 等人[8] 为提高传统 4PCS 算法的效率，将特征点提取算法与 4PCS 算法结合提出了 K-4PCS 算法，大大提高了算法的实时性。Tao 等人[9] 为了进一步提高 4PCS 算法的准确性，提出了结合局部形状描述符的广义四点共线集（G4PCS）算法。该算法使用一个具有高计算效率的描述符来

建立点对关系, 并利用三个角度的约束筛选正确的点对, 提高了配准精度, 但是由于引入了额外的描述符进行计算, 对配准效率产生了一定的影响。

点云精配准是指在点云粗配准之后, 通过更精确的方法来进一步优化初始估计的变换, 以实现更为准确的点云对齐。精配准的目标是使两个点云之间的匹配误差最小化, 从而达到更高的配准精度。点云精配准中最常用的方法是 Besl 等人[10] 提出的迭代最近点 ICP 算法, 其通过寻找到源点云中的每个点在目标点云中的最近邻点, 然后根据这些最近邻点的对应关系计算出一个最佳的刚性变换, 使得源点云尽可能地与目标点云对齐, 迭代更新变换矩阵, 直到收敛到一个最优的变换解[11]。Yao 等人[12] 提出一种基于点云曲率特征相似性的改进迭代最近点算法。该算法首先采用离散指标映射和模板进行采样, 以简化点云数据, 提高配准效率, 之后根据曲率特征相似度搜索欧氏距离的最近点, 以提高配准精度。Lv 等人[13] 基于肯德尔形状空间(Kendall Shape Space, KSS)理论, 提出了一种新的点云配准方法 KSS-ICP, 将点云映射到 KSS 来保持与原始点云的几何一致性, 同时减少不均匀密度、位置和比例的影响以实现精确的配准。Liu 等人[14] 提出了基于切比雪夫元模型的改进型 ICP 点云配准方法。该方法使用切比雪夫元模型近似平移模型, 以单个嵌套分支定界(Branch and Bound, BnB)方案来有效地搜索 3D 点集配准的全局最优值, 然而该方法的耗时有所增加。

近年来, 基于神经网络的点云配准方法也得到了发展。Xie 等人[15] 提出了一种卷积孪生(Convolutional Siamese Point Net, CSPN)点云配准网络, 设计了一个金字塔架构来学习每个点的多尺度特征, 同时提出了一种新的注意力机制来处理特征空间和坐标空间得到的匹配矩阵之间的冲突。

Zhang 等人[16] 提出了一种基于学习的新型 3D 点云配准网络, 在 3D 点云配准中模拟了专用的刚性变换等价方差, 使用刚性变换等变性(Rigid Transformation Equivariance, RTE)结构, 挖掘两对点云之间的相对位姿约束, 从学习的成本量中计算回归矩阵。基于神经网络的点云配准方法可以通过深度学习等技术获取更丰富的点云特征信息, 但是这些方法通常需要大量的训练数据集和计算资源。

在实际应用中, 受噪声干扰、点云数据局部缺失等情况的影响, 现有方法仍存在点云配准效率不高、鲁棒性较差的问题。因此, 针对深度相机采集的室内目标三维模型, 本文构建了一种改进型 4PCS-ICP 点云配准方法。首先, 利用逐点前进法快速提取点云特征点, 在保留点云模型特征的同时大幅精简点云数量。然后, 通过使用法向量约束改进的 KN-4PCS 算法进行粗配准, 以实现源点云与目标点云的初步配准。最后, 使用双向 Kd-tree 优化 LM-ICP 算法进行精配准。该方法不仅可以降低配准误差及耗时, 还可以提高配准鲁棒性, 为后续救援机器人的目标识别定位及夹取等救援操作提供感知基础。

2　点云粗配准

传统 4PCS 算法在实际应用中, 相似四点集的数量会随着点云数量的提高而大大增加, 且容易受到噪声等的影响, 同时提取相似集和验证变换的耗时具有二次时间复杂性, 这使其在配准过程中的效率不高。为此在基于特征点的 K-4PCS 算法基础上引入法向量约束, 进一步筛选共面四点集点对的数量, 以提高算法效率。

2.1　逐点前进法特征点提取

为了在保留特征的同时大幅减少原始点云的密度, 需要进行特征点提取。传统特征点采样存在不同程度的特征点缺失, 且对初始参数比较敏感, 不能较好保留数据特征, 针对这些问题, 本文采用逐点前进法[17] 进行特征点提取, 将点云投影到二维平面上, 再从一个端点出发, 逐点前进由近及远地查找特征点。

逐点前进法的具体步骤如下:

Step1 给定离散点列 $P_1(x_1, y_1)$, $P_2(x_2, y_2)$, $\cdots$, $P_i(x_i, y_i)$

Step2 选取起始点 $A=P(x_1, y_1)$ 和另一个点 $B=P(x_2, y_2)$, 然后用一条直线段连接 A、B 两点, 并将 A 点作为特征点列的首个点。

Step3 在线段 AB 围成的区域内寻找距离线段 AB 最远的点, 将其标记为 C。

Step4 判断点 C 到直线段 AB 的距离与设定

阈值 D_T 的大小关系。若点 C 到线段 AB 的距离大于阈值，则将 A 设为 C，并将 C 按原顺序放入特征点列，然后用线段连接 AB，返回步骤 **Step3**。

Step5 继续寻找下一个点 B^+，然后用线段连接 AB^+，重复步骤 **Step3** 和 **Step4**，直到 B 等于最后一个点 $P_i(x_i, y_i)$，将最后的点 B 放入特征点列的末尾，完成特征点提取。

2.2 基于法向量约束的 KN-4PCS 点云粗配准

2.2.1 点云法向量计算

点云法向量是点云的一项重要几何特征，在点云配准过程中，可以利用法向量约束筛选点对，提高配准的效率，本文采用主成分分析法 (Principal Component Analysis, PCA) 计算点云的法向量[18]。对于点云中的某一点 p，通过设置搜索半径 r，选择一个相邻的点集 P^r 作为局部邻域。

以该邻域点集为样本数据，采用最小二乘原理拟合局部最优空间切平面，即以样本数据与目标平面的距离平方最小化为约束条件，构建目标平面参数求解的目标函数 $J(\boldsymbol{v},d)$，如式(1)所示[18]：

$$J(\boldsymbol{v},d)=\arg_{(\boldsymbol{v},d)}\min\sum_{j=1}^{n}\left(\boldsymbol{v}\cdot\boldsymbol{P}_j^r-d\right)^2 \quad , \qquad (1)$$

式中，$\boldsymbol{v}$ 表示目标平面的法向量；d 表示到目标平面的空间距离。

采用 PCA 计算空间平面的法向量，并将其视为采样点的法向量。上式的求解过程可转化为对局部邻域点集构成的协方差矩阵 $\boldsymbol{C}$ 进行特征值分解，如式(2)所示：

$$\boldsymbol{C}=\frac{1}{n}\sum_{j}^{n}\left(\boldsymbol{P}_j^r-\overline{\boldsymbol{P}}\right)\cdot\left(\boldsymbol{P}_j^r-\overline{\boldsymbol{P}}\right)^{\mathrm{T}}=\sum_{m}^{3}\boldsymbol{e}_m\lambda_m\boldsymbol{e}_m^{\mathrm{T}} \quad , \qquad (2)$$

式中，$\overline{P}$表示邻域点集的重心；λ 和 $\boldsymbol{e}$ 分别表示矩阵 $\boldsymbol{C}$ 的特征值和特征值对应的特征向量，且 $\lambda_1\geqslant\lambda_2\geqslant\lambda_3$。最小特征值 λ_3 对应的特征向量 $\boldsymbol{e}_3$，即为采样点的法向量 $\boldsymbol{N}_P$ 的估算值。

2.2.2 改进的 KN-4PCS 算法

4PCS 法是一种常用的点云粗配准方法，通过识别具有相似的共面四点集来实现点云粗配准，即使用点云 P 中的一组共面四点集作为点基 B，通过仿射不变量找到另一点云 Q 中与 B 近似全等的点子集，来估计初始的变换矩阵[6]。K-4PCS 是将特征点提取与 4PCS 结合的算法。

(1)共面四点集的仿射不变量

在点云 P 中取一组不共线的共面四点 $X\equiv\{a,b,c,d\}$，设线段 ab 和线段 cd 的交点为 e，点 e 与 X 中各点的相对距离可表示为：

$$\begin{cases} r_1=\|a-e\|/\|a-b\| \\ r_2=\|c-e\|/\|c-d\| \end{cases} \quad , \qquad (3)$$

式中，比率 r_1 和 r_2 具有仿射不变性。

对另一个点云 Q，通过给定两个仿射不变比 r_1 和 r_2，可以有效地提取 Q 中与 X 对应的四点集，如图 1 所示。

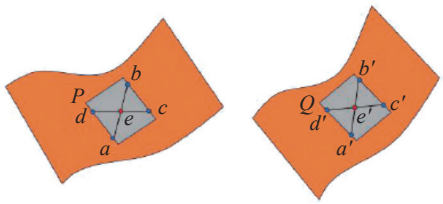

图 1 共面四点集的仿射不变量

Fig. 1 Affine invariant ratio for congruent 4-points

(2)全等四点集提取

在点云配准中，首先从特征点提取后的源点云 P 中选取 3 个点，确定一个平面，再选择与其共面的第 4 个点，形成共面四点集 $B\equiv\{a,b,c,d\}$，在特征点提取后的目标点云 Q 中，依据两个仿射不变比提取近似水平小于 δ 的与点集 B 近似全等的四点集，如图 2(彩图见期刊电子版)所示。

对于每对点 $\{q_1,q_2\}\epsilon Q$，根据 r_1 和 r_2 计算两个交叉点：

$$\begin{cases} e_1=p_1+r_1\cdot(p_2-p_1) \\ e_2=p_2+r_2\cdot(p_2-p_1) \end{cases} \quad , \qquad (4)$$

式中，e_1 和 e_2 分别由 r_1 和 r_2 计算产生。当从 Q 中提取的四点集与点集 B 近似全等时，e_1 和 e_2 应近似重合，如图 2(c) 所示红色交点对应的四点集 $\{q_1,q_3\ q_4,q_5\}$，即为与 B 对应的点集。

(3)基于法向量的点对筛选

设 $B\equiv\{a,b,c,d\}$是点云 P 中的 4 个共面点，$\boldsymbol{O}\equiv\{\boldsymbol{N}_a, \boldsymbol{N}_b, \boldsymbol{N}_c, \boldsymbol{N}_d\}$是它们的关联法向量，$d_1=\|a-b\|$，$d_2=\|c-d\|$。设 $N(x, y)$ 表示点 x 和 y 处两条局部法向量之间的夹角。所有满足 $\|q_i-q_j\|\approx d_1$ 或 $\|q_i-q_j\|\approx d_2$ 的点对 $\{q_i-q_j\}\epsilon\ Q$ 都通过以下计算进行进一步的修剪筛选：选择一个任意点 $q_i\ \epsilon Q$，计算其对应的法向量 $\boldsymbol{N}_q$，然后提取所有满足 $N(q_i-q_j)\approx N(a,b)$ 或 $N(q_i-q_j)\approx N(c,d)$ 的点 $q_j\ \epsilon Q$。

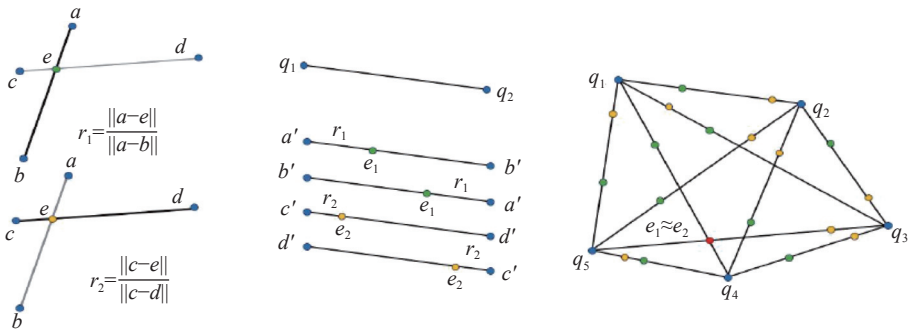

(a) 仿射不变比计算
(a) Affine invariant ratio calculation

(b) 交叉点计算
(b) Intersection point calculation

(c) 四点集提取
(c) 4-Points sets extraction

图 2　仿射不变四点集提取示意图

Fig. 2　Schematic diagram of affine invariant 4-point set extraction

具体来说, 法向量约束改进的 KN-4PCS 算法步骤如下:

Step1 基于逐点前进法对源点云和目标点云分别提取特征点, 利用 PCA 法对二者特征点云分别计算法向量, 并将其存储在对应的点属性中;

Step2 源特征点云 P 中选取共面四点集 B, 由公式(3)计算仿射不变比 r_1 和 r_2。

Step3 在特征点提取后的目标点云 Q 中, 依据两个仿射不变比提取近似水平小于 δ 的与点集 B 近似全等的四点集, 根据公式(4)计算两个交叉点 e_1 和 e_2。

Step4 搜索 e_1 和 e_2 近似重合的四点集, 并根据法向量关系 $N(q_i-q_j)\approx N(a,b)$ 或 $N(q_i-q_j)\approx N(c,d)$ 原则对点对进行进一步筛选。

Step5 通过最小二乘法计算变换矩阵 $\boldsymbol{M}_i$, 不断迭代上述过程, 基于最大公共点集(Largest Common Pointest, LCP)准则获取最优变换矩阵 $\boldsymbol{M}$, $\boldsymbol{M}$ 即粗配准的变换矩阵。

3　点云精配准

在粗配准后源点云和目标点云具有大致相近的位姿, 为获取更为精确的变换关系, 需要进行精配准。ICP 是目前常用的点云配准方法, 但传统 ICP 存在依赖良好初始位姿、容易陷入局部最优、匹配点搜索耗时较长等问题。本研究采用基于双向 Kd-tree 优化改进的 LM-ICP 算法, 以实现高效精配准。

3.1　双向 Kd-tree 点对搜索

在传统的 ICP 算法中, 在从粗配准的两个点云数据之间计算最近点时, 会出现一对多的情况, 导致点云配准效率低下。双向 Kd-tree 加快点云配准搜索是对目标点云和参考点云分别建立 Kd-tree, 并利用 Kd-tree 数据结构实现搜索加速, 如图 3 所示。

首先建立点云数据 P 和 Q 的 Kd-tree 数据结构。对于 P 中的每个点 p_i, 搜索到 Q 中最近的点 q_i, 再以 q_i 向 P 中搜索。如果 P 中 q_i 的最近点不是 p_i, 则继续搜索下一个最近点 q_{i+1}。如果 P 中 q_i 的最近点是 p_i, 则 p_i 和 q_i 被视为具有对应关系的点对。

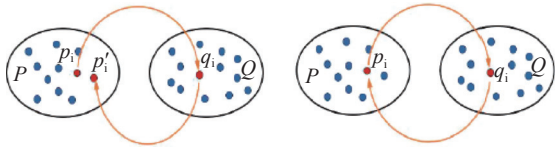

(a) 非对应点对
(a) Noncorresponding point pairs

(b) 对应点对
(b) Corresponding point pairs

图 3　双向 Kd-tree 点对搜索示意图

Fig. 3　Schematic diagram of bidirectional Kd-tree point pair search

3.2　LM-ICP 精配准

为了降低传统 ICP 算法对初始位姿的敏感性, 提高算法收敛性, 在双向 Kd-tree 基础上使用基于 Levenberg-Marquardt 模型改进的 LM-ICP 算法进行点云精配准。

LM 优化算法是一种非线性最小二乘优化算法, 通过结合高斯-牛顿法和梯度下降法, 实现对参数的逐步优化, 对参数初始值不敏感且具有高效的局部收敛性[19], 可以降低对点云初始位姿的限制, 有效提高配准灵活性。LM-ICP 是一种点到面的配准, 其误差函数为:

$$E(T)=\frac{1}{n}\sum_{i=1}^{n}\|(\boldsymbol{T}p_i-q_i)\cdot\boldsymbol{N}_i\|^2 \quad , \qquad (5)$$

式中，n 为配准点对数，$\boldsymbol{T}$ 为配准刚性变换矩阵，p_i 和 q_i 分别为源点云与目标点云中的对应点，$\boldsymbol{N}_i$ 为对应点的法向量。

令 $e_i=\frac{1}{\sqrt{n}}(\boldsymbol{T}p_i-q_i)\cdot\boldsymbol{N}_i$，则式 (5) 可写为：

$$E(\boldsymbol{T})=\sum_{i=1}^{n}\|e_i\|^2 \quad . \qquad (6)$$

LM 优化每次迭代的目标是对当前估计值 $\boldsymbol{T}_k$ 的增量 $\Delta\boldsymbol{T}$ 进行更新，则将 $E(\boldsymbol{T})$ 在 $\boldsymbol{T}_k$ 处进行二次泰勒展开：

$$E(\boldsymbol{T}_k+\Delta\boldsymbol{T})=E(\boldsymbol{T}_k)+(\nabla E(\boldsymbol{T}_k)\cdot\Delta\boldsymbol{T})+\frac{1}{2!}\left(\left(\nabla^2E(\boldsymbol{T}_k)\cdot\Delta\boldsymbol{T}\right)\cdot\Delta\boldsymbol{T}\right) \quad . \qquad (7)$$

定义雅克比矩阵 $J=\nabla\vec{\boldsymbol{e}}$，则式 (7) 可写为：

$$E(\boldsymbol{T}_k+\Delta\boldsymbol{T})=\vec{\boldsymbol{e}}^{\mathrm{T}}\vec{\boldsymbol{e}}+(\Delta\boldsymbol{T})^{\mathrm{T}}\boldsymbol{J}^{\mathrm{T}}\vec{\boldsymbol{e}}+(\Delta\boldsymbol{T})^{\mathrm{T}}\boldsymbol{J}^{\mathrm{T}}\boldsymbol{J}\Delta\boldsymbol{T} \quad . \qquad (8)$$

对 $\Delta\boldsymbol{T}$ 进行更新迭代使得 $E(\boldsymbol{T}_k+\Delta\boldsymbol{T})$ 最小，LM-ICP 算法迭代增量方程为：

$$\Delta\boldsymbol{T}=-\left(\boldsymbol{J}^{\mathrm{T}}\boldsymbol{J}+\lambda\boldsymbol{I}\right)^{-1}\boldsymbol{J}^{\mathrm{T}}\vec{\boldsymbol{e}} \quad , \qquad (9)$$

式中，$\vec{\boldsymbol{e}}$ 为源点云与目标点云中对应点对的残差向量，$\boldsymbol{I}=\vec{\boldsymbol{e}}^{\mathrm{T}}\vec{\boldsymbol{e}}$，$\lambda$ 为 LM 梯度参数，$\lambda>0$。

具体来说，基于双向 Kd-tree 优化改进的 LM-ICP 算法步骤如下：

Step1 对粗配准后的源点云和目标点云进行初始化，利用双向 Kd-tree 搜索源点云中每个点在参考点云中的最近邻点；

Step2 根据对应点对，计算初始刚性变换矩阵 $\boldsymbol{T}$，及误差函数 $E(\boldsymbol{T})$；

Step3 使用 LM 优化算法计算迭代增量 $\Delta\boldsymbol{T}$，基于 $\Delta\boldsymbol{T}$ 迭代更新变换矩阵，并计算对应的误差函数；

Step4 判断误差函数是否小于设定阈值，迭代次数是否达到设定的最大迭代次数；

Step5 不断迭代上述过程，当满足终止条件时，返回最优刚性变换矩阵 $\boldsymbol{T}$，将源点云与参考点云进行配准。

综上所述，本文的点云配准方法如图 4 所示。

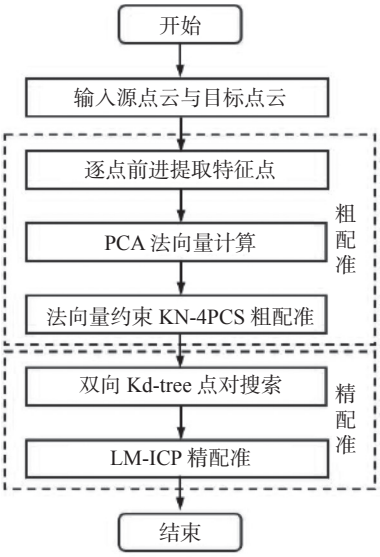

图 4 点云配准方法总流程图

Fig. 4 Flowchart of the point cloud registration algorithm

4 实验结果与分析

为了验证本文提出的点云配准算法的有效性和鲁棒性，分别使用公共数据集和真实室内物体点云进行实验，以点云配准均方根误差（RMSE）来定量评价点云配准精度，以算法耗时来评价点云配准实时性。

$$RMSE=\sqrt{\frac{1}{n}\sum_{i=1}^{n}\|P_i-Q_i\|^2} \quad , \qquad (10)$$

式中，P_i 和 Q_i 分别为第 i 对源点云和目标点云中的点[20]。

公共数据集使用斯坦福大学开放点云数据；真实点云数据以搭载奥比中光 Astra Pro 深度相机的移动救援机器人平台采集的室内场景下的物体点云数据为基础（点云数据采集系统如图 5 所示），选取部分经过前景提取及点云聚类分割等预处理后的单个物体聚类点云作为实验数据。

图 5 点云数据采集系统

Fig. 5 Point cloud data acquisition system

实验环境为 12th Gen Intel Core i5-12400F CPU @4.00 GHz 处理器, 16 GB 内存, 采用 C++及 PCL 点云库实现。采集真实数据使用的 AstraPro 深度相机主要参数, 如表 1 所示。

表 1　深度相机参数

Tab. 1　RGB-D camera's parameters

	参数名称	数值
深度	工作范围	0.6~8 m
	精度	1 m: ±3 mm
	视场角(FOV)	H58.4 × V45.5°
	分辨率@帧率	640 × 480@30 fps
RGB	视场角(FOV)	H66.1° × 740.2°
	分辨率@帧率	640 × 480@30 fps
	UVC	支持

4.1　基于斯坦福大学开放点云数据的配准实验验证

使用斯坦福大学开放点云数据中的 Armadillo 和 Dragon 模型, 将本文算法与 SAC-IA+ICP[4]、NDT+ICP[5] 两种算法进行对比。配准效果如图 6 (彩图见期刊电子版) 所示, Armadillo 模型源点云为 29 885 个点, 目标点云为 32 385 个点; Dragon 模型源点云为 34 836 个点, 目标点云为 41 841 个点。图 6(a) 为点云数据初始位姿, 其中绿色为源点云, 蓝色为参考点云; 图 6(b) 为 SAC-IA+ICP 的实验结果; 图 6(c) 为 NDT+ICP 的实验结果; 图 6(d) 为本文算法结果。从图中配准效果可以看出, 本文算法优于其他几种方法。在 Armadillo 模型的配准对比中, 3 种配准方法在模型躯干和腿部等部分存在明显差异。SAC-IA+ICP 方法在这两个部分的重合性最差, 整体配准效果一般; NDT+ICP 方法在躯干部分配准效果较好, 但腿部的重合性仍较差; 本文方法在配准后整体的重合性最好。在更为复杂的 Dragon 模型的配准对比中, SAC-IA+ICP 方法和 NDT+ICP 方法在模型头部、躯干和尾部都存在较大面积的重合不良区域; 本文方法在上述部分的重合性较其余方法提升明显。

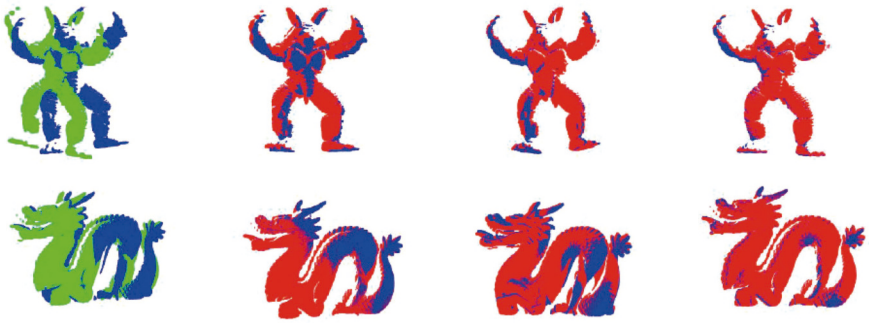

(a) Initial point cloud　(b) SAC-IA+ICP　(c) NDT+ICP　(d) Ours

图 6　斯坦福点云配准结果

Fig. 6　Registration results of Stanford point cloud data

以点云配准误差 RMSE 和配准耗时 Time 作为评价指标, 进行量化分析。表 2 为配准精度误差与计算耗时对比结果。

表 2　斯坦福点云配准定量分析结果

Tab. 2　Quantitative analysis results of Stanford point cloud data registration

Model	SAC-IA+ICP		NDT+ICP		Ours	
	RMSE/mm	Time/s	RMSE/mm	Time/s	RMSE/mm	Time/s
Armadillo	0.0288	3.21	0.0168	2.19	**0.00730**	**0.437**
Dragon	0.0363	3.77	0.0218	3.25	**0.0125**	**0.528**

从对比数据可以看出, 本文算法的配准精度与效率均优于 SAC-IA+ICP 和 NDT+ICP。对于 Armadillo 模型, 本文方法的配准误差分别减少了 74.7% 和 56.5%, 配准耗时分别减少了 86.4% 和 80.0%。对于 Dragon 模型, 本文方法的配准误差分别减少了 65.6% 和 42.7%, 配准耗时分别减少了 86.0% 和 83.8%。本文方法利用逐点前进法进行特征点提取, 最大程度保留了点云模型的初始特征, 而 SAC-IA+ICP、NDT+ICP 两种算法仅利用体素下采样对点云进行精简, 会对点云特征造成一定的损失; 同时由于法向量约束和双向 Kd-

tree 搜索的引入，使得本文方法可以利用几何特征更准确地确定点云间的对应关系，因此使得配准准确性和实时性得到提高。上述对斯坦福大学开放点云数据的配准结果，可以有效证明本文算法的配准精度和实时性良好。

4.2 不同噪声水平下的鲁棒性验证

真实场景下，使用深度相机采集的数据不可避免会有噪声干扰，为此在上述两个点云模型上添加不同程度（σ=0.001~ 0.005）的高斯噪声验证算法的鲁棒性。图 7（彩图见期刊电子版）为高斯噪声为 σ=0.003 时点云的配准效果，图 8 和图 9 分别为不同高斯噪声时各算法的配准误差和耗时。由图 8 可以看出，在引入高斯噪声后 SAC-IA+ICP 方法和 NDT+ICP 方法的配准误差都明显大于本文方法，且在面对不同程度的高斯噪声时本文方法的误差波动最小。同时由图 9 可知，在

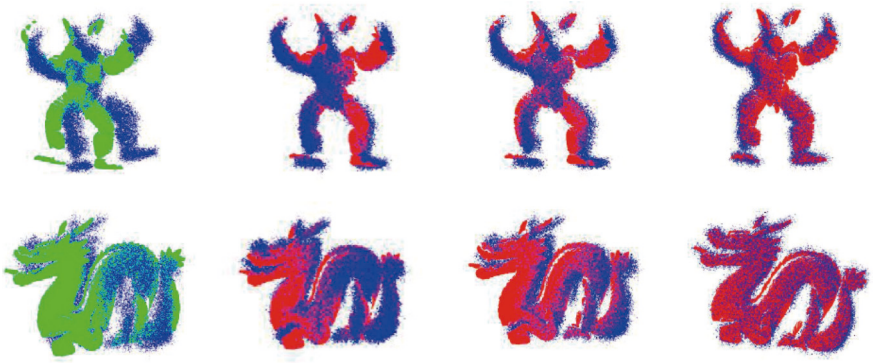

(a) Gaussian noise point cloud (b) SAC-IA+ICP (c) NDT+ICP (d) Ours

图 7 高斯噪声 σ=0.003 时斯坦福点云的配准结果

Fig. 7 Registration results of Stanford point cloud data with Gaussian noise of σ= 0.003

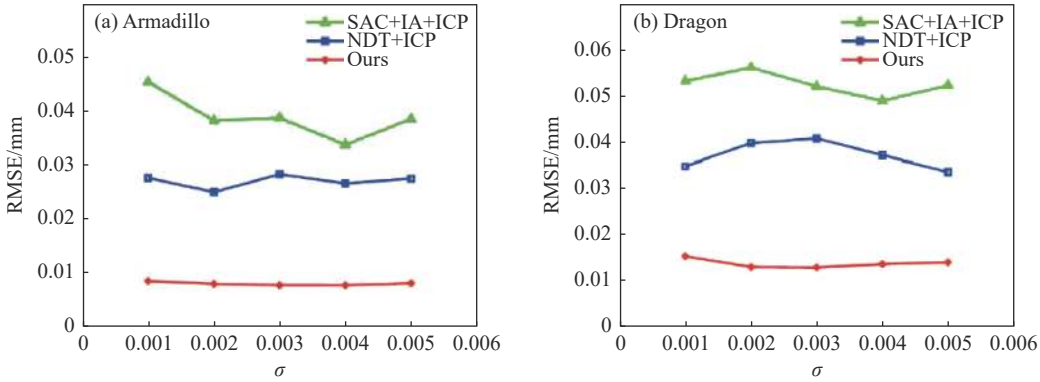

图 8 不同高斯噪声时各算法的配准误差

Fig. 8 Registration error of each algorithm with different Gaussian noises

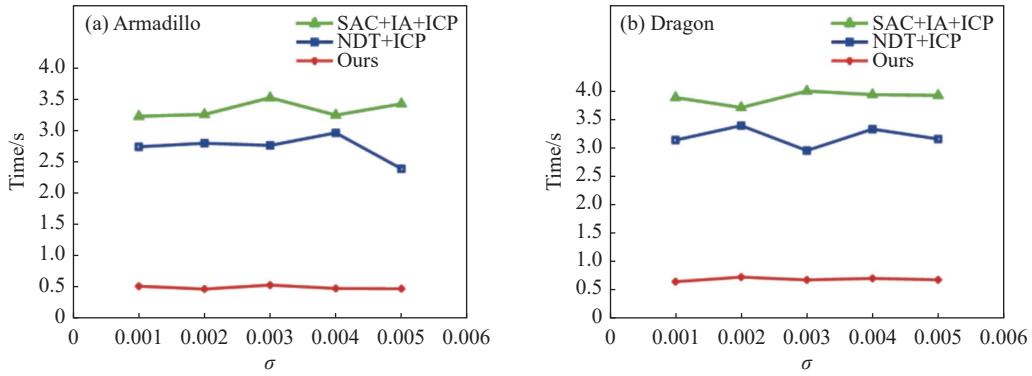

图 9 不同高斯噪声时各算法的配准耗时

Fig. 9 Registration consuming times of each algorithm with different Gaussian noises

面对不同程度的高斯噪声时本文方法的耗时也远低于其余两种对比方法。本文方法引入法向量约束和双向 Kd-tree 搜索后, 可以更为快速准确地区分点云中的噪声点和真正的特征点, 提高了邻近点对搜索的质量, 从而降低了噪声对配准结果的影响。由上可知, 本文算法在不同程度的高斯噪声干扰下仍能保持较好的鲁棒性。

4.3　室内物体点云数据的配准实验

为进一步验证算法的有效性, 对真实数据进行实验。选取椅子(Chair)、水壶(Kettle)、人体模型(Mannequin)分别代表室内家具、生活品、人员等常见目标, 源点云与参考点云分别是同类物体不同位置、不同角度的采集数据, 其中将较为完整的点云作为参考点云, 点云配准效果如图 10 所示。由于消费级深度相机的精度受限, 同时由于光照等其他环境因素的影响, 真实点云数据存在一定的缺失与误差。由表 3 可以得到, 本文方法的配准误差与耗时相较斯坦福开放点云数据有一定的提高, 平均配准误差为 0.0742 mm, 算法耗时平均为 0.572 s, 具有较高的配准精度和较小的耗时。综上分析, 本文配准方法在面对深度相机采集的真实数据时具有较好的配准精度和效率, 可以为后续救援机器人获取目标物体的准确位姿信息提供良好的基础。

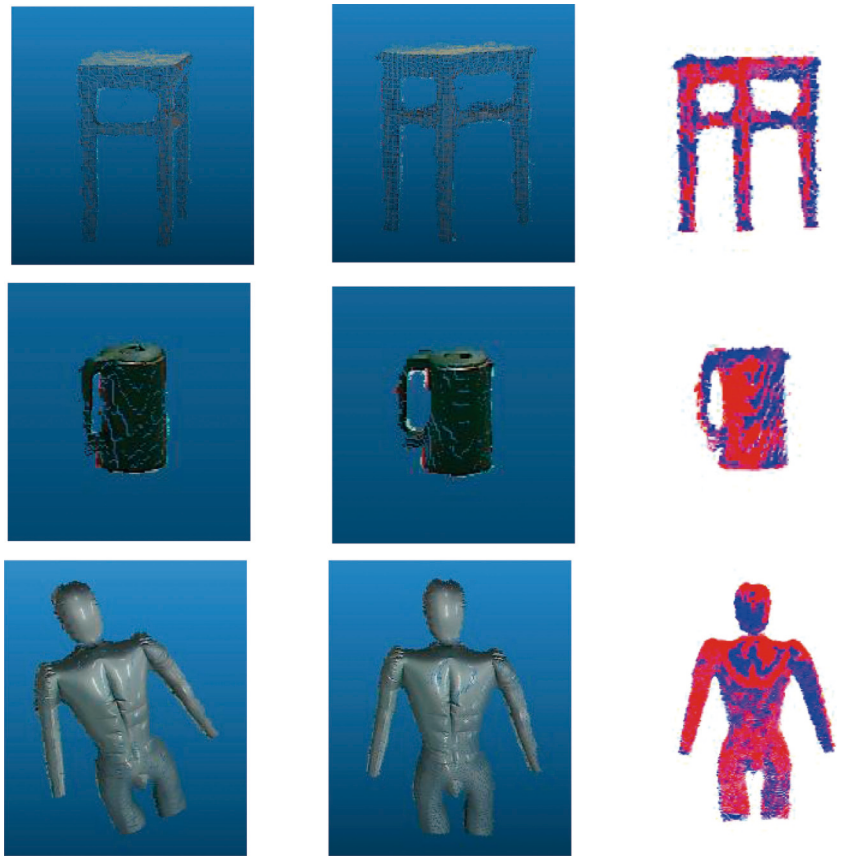

(a) 源点云
(a) Source point cloud

(b) 目标点云
(b) Target point cloud

(c) 配准结果
(c) Registration results

图 10　真实室内场景物体点云配准结果

Fig. 10　Registration results of object point cloud data in indoor scene

表 3　真实室内场景物体点云配准定量分析结果

Tab. 3　Quantitative analysis results of object point cloud data registration in indoor scene

模型	源点云数/个	源点云特征点数/个	目标点云数/个	目标点云特征点数/个	RMSE/mm	平均误差/mm	耗时/s	平均耗时/s
Chair	8549	3702	10431	4847	0.0686		0.544	
Kettle	3713	1359	3879	1449	0.0633	0.0742	0.487	0.572
Mannequin	45292	16098	46507	16462	0.0907		0.686	

5 结 论

为了提高三维点云数据配准的精度、效率以及鲁棒性，以粗配准+精配准的方式为基础，结合特征点提取、法向约束点对筛选、双向 Kd-tree、列文伯格-马夸尔特模型等，提出了一种改进型点云配准方法。实验结果表明，本文配准方法具有较高的精度和效率，同时具有较好的鲁棒性，在开放点云数据配准实验中，平均误差较 SAC-IA+ICP 算法减少了约 70.2%，较 NDT+ICP 算法减少了约 49.6%，配准耗时分别减少约 86.2% 和 81.9%，同时，在引入不同程度的高斯噪声后仍能保持较高的精度和较低的耗时。在真实室内物体点云模型配准实验中，平均配准误差为 0.0742 mm，平均算法耗时为 0.572 s，具有较高的配准精度和较低的耗时。改进算法的优势主要体现在两方面，一是通过法向量约束与双向 Kd-tree 优化使得配准精度好、效率高；二是面对噪声影响时本文算法具有很强的鲁棒性。本文算法可以应用于三维点云模型配准等领域。进一步优化配准方法，以及将本文配准方法用于其它应用环境中，比如室内救援中的不同姿态识别，不同类型的物体抓取等问题，是下一步研究的方向。

参考文献：

[1] 杨鹏程, 杨朝, 孟杰, 等. 基于法向量和面状指数特征的文物点云棱界配准方法[J]. 中国光学 (中英文), 2023, 16(3): 654-662.
YANG P CH, YANG ZH, MENG J, *et al*.. Aligning method for point cloud prism boundaries of cultural relics based on normal vector and faceted index features[J]. *Chinese Optics*, 2023, 16(3): 654-662. (in Chinese).

[2] ZOU ZH, LANG H, LOU Y X, *et al*.. Plane-based global registration for pavement 3D reconstruction using hybrid solid-state LiDAR point cloud[J]. *Automation in Construction*, 2023, 152: 104907.

[3] CAO T, LIU Y P, DAI J J, *et al*.. Local scanned point-cloud registration of aeroengine pipeline system based on axial constraints[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 2527011.

[4] DENG Y H, CHEN G H, LIU X L, *et al*.. 3D pose recognition of small special-shaped sheet metal with multi-objective overlapping[J]. *Electronics*, 2023, 12(12): 2613.

[5] SHI X Y, PENG J J, LI J P, *et al*.. The iterative closest point registration algorithm based on the normal distribution transformation[J]. *Procedia Computer Science*, 2019, 147: 181-190.

[6] AIGER D, MITRA N J, COHEN-OR D. 4-points congruent sets for robust pairwise surface registration[J]. *ACM Transactions on Graphics*, 2008, 27(3): 1-10.

[7] 傅瑶, 陈鹏, 郭贵松, 等. 基于 4PCS 和 SICP 的点云配准方法在钢轨磨耗计算中的应用[J]. 电子测量与仪器学报, 2022, 36(12): 210-218.
FU Y, CHEN P, GUO G S, *et al*.. Application of the point cloud registration method based on 4PCS and SICP in rail wear calculation[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(12): 210-218. (in Chinese).

[8] THEILER P W, WEGNER J D, SCHINDLER K. Keypoint-based 4-points congruent sets–automated marker-less registration of laser scans[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2014, 96: 149-163.

[9] TAO W Y, LIU J B, XU D, *et al*.. Automatic registration of point clouds by combining local shape descriptor and G4PCS algorithm[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 6339-6351.

[10] BESL P J, MCKAY N D. Method for registration of 3-D shapes[J]. *Proceedings of SPIE*, 1992, 1611: 586-606.

[11] 林森, 张强. 应用邻域点信息描述与匹配的点云配准[J]. 光学 精密工程, 2022, 30(8): 984-997.
LIN S, ZHANG Q. Point cloud registration using neighborhood point information description and matching[J]. *Optics and Precision Engineering*, 2022, 30(8): 984-997. (in Chinese).

[12] YAO Z W, ZHAO Q X, LI X F, *et al*.. Point cloud registration algorithm based on curvature feature similarity[J]. *Measurement*, 2021, 177: 109274.

[13] LV CH 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.

[14] LIU Y SH, CHEN X D, WANG K F, *et al*.. A Chebyshev metamodel based BnB approach to efficiently search global optimum for 3D ICP point set registration[J]. *Computer Aided Geometric Design*, 2023, 101: 102178.

[15] XIE L F, ZHU Y Y, YIN M, *et al*.. Self-feature-based point cloud registration method with a novel convolutional Siamese point net for optical measurement of blade profile[J]. *Mechanical Systems and Signal Processing*, 2022, 178: 109243.

[16] ZHANG ZH Y, SUN J D, DAI Y CH, *et al*.. Self-supervised rigid transformation equivariance for accurate 3D point cloud registration[J]. *Pattern Recognition*, 2022, 130: 108784.

[17] 何宽, 孙瑞, 官云兰, 等. 基于逐点前进法的点云数据精简[J]. 测绘通报, 2022(9): 167-169.
HE K, SUN R, GUAN Y L, *et al*.. Point cloud data simplification based on point-by-point advancing method[J]. *Bulletin of Surveying and Mapping*, 2022(9): 167-169. (in Chinese).

[18] 李茂月, 赵伟翔, 马康盛, 等. 结构光检测点云精简与重构参数自动调节方法[J]. 仪器仪表学报, 2022, 43(8): 122-130.
LI M Y, ZHAO W X, MA K SH, *et al*.. Point cloud simplification and reconstruction parameters' automatic adjustment method of structured light detection[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(8): 122-130. (in Chinese).

[19] FITZGIBBON A W. Robust registration of 2D and 3D point sets[J]. *Image and Vision Computing*, 2003, 21(13-14): 1145-1153.

[20] 王宾, 刘林, 侯榆青, 等. 应用改进迭代最近点方法的三维心脏点云配准[J]. 光学 精密工程, 2020, 28(2): 474-484.
WANG B, LIU L, HOU Y Q, *et al*.. Three-dimensional cardiac point cloud registration by improved iterative closest point method[J]. *Optics and Precision Engineering*, 2020, 28(2): 474-484. (in Chinese).

作者简介：

李茂月(1981—), 男, 山东青岛人, 博士, 教授, 博士生导师, 2004 年于南京林业大学获得学士学位, 2007 年于长安大学获得硕士学位, 2012 年于哈尔滨工业大学获得博士学位, 主要从事智能加工与光学检测技术方面的研究。E-mail: lmy0500@163.com