

文章编号:1001-5078(2023)12-1935-09

· 图像与信号处理 ·

## 基于 WHI 及 ICP 的点云配准算法

王正家<sup>1,2</sup>, 苏超全<sup>1</sup>, 聂磊<sup>1,2</sup>

(1. 湖北工业大学机械工程学院, 湖北 武汉 430068; 2. 湖北工业大学现代制造质量工程湖北省重点实验室, 湖北 武汉 430068)

**摘要:**针对两步点云配准中精度差、计算效率低、易受噪声干扰的问题,提出一种基于 WHI 特征描述符结合改进的 ICP 点云配准算法。首先,对大数据量的点云通过 ISS 算法提取特征点集作为配准点云;然后,计算特征点云的 WHI 特征描述符,利用随机采样一致性算法完成粗配准;最后,基于安德森加速迭代 ICP 算法对粗配准点云进行精确配准。通过多组点云数据集对所提算法进行验证,实验表明,该算法配准精度高、速度快,在含有噪声数据集的优势更明显。在不同的点云模型下,所提算法的配准效率提高 2 倍以上,在噪声环境下具有一定的鲁棒性。

**关键词:**点云配准;特征点集;粗配准;精确配准;配准效率

**中图分类号:**TP391.41 **文献标识码:**A **DOI:**10.3969/j.issn.1001-5078.2023.12.021

## Point cloud registration algorithm based on WHI and ICP

WANG Zheng-jia<sup>1,2</sup>, SU Chao-quan<sup>1</sup>, NIE Lei<sup>1,2</sup>

(1. School of Mechanical Engineering, Hubei University of Technology, Wuhan 430068, China;

2. Hubei Provincial Key Laboratory of Modern Manufacturing Quality Engineering, Hubei University of Technology, Wuhan 430068, China)

**Abstract:**In this paper, an improved ICP point cloud registration algorithm based on WHI feature descriptors is proposed to address the problems of poor accuracy, low computational efficiency and susceptibility to noise interference in two-step point cloud registration. Firstly, the ISS algorithm is used to extract the feature point set from the point cloud with a large amount of data as the registration point cloud. Then, the WHI feature descriptor of the feature point cloud is calculated, and the random sampling consensus algorithm is used to complete the rough registration. Finally, based on Anderson accelerated iteration, the ICP algorithm performs precise registration on the coarse registration point cloud. The proposed algorithm is verified by multiple sets of point cloud datasets. The experimental results show that the algorithm is highly accurate and fast in alignment, and its advantages are more obvious in datasets containing noise. Under different point cloud models, the proposed algorithm improves the alignment efficiency by more than two times, and has certain robustness in the noise environment.

**Keywords:**point cloud registration; feature points set; coarse registration; precise registration; registration efficiency

### 1 引言

随着 3D 成像技术的兴起,激光扫描仪在机器

人、智能制造、文物保护等领域得到了广泛的应用<sup>[1]</sup>。然而,在实际扫描过程中,由于测量环境和

**基金项目:**国家自然科学基金项目(No. 51975191)。

**作者简介:**王正家,男,博士,副教授,主研领域为电机智能控制、智能装备与仪器。E-mail:276318532@qq.com

**通讯作者:**苏超全,男,硕士研究生,主要研究领域为三维点云处理,机器视觉。E-mail:2408507189@qq.com

**收稿日期:**2023-02-21; **修订日期:**2023-04-24

仪器设备等因素的影响,通常需要对物体多视角扫描,并通过配准把不同视角的点云变换到同一坐标系下<sup>[2]</sup>。点云配准通常分为粗配准和精细配准<sup>[3]</sup>。粗配准算法主要有有人工设计的特征配准、基于学习的特征配准<sup>[4]</sup>、随机样本一致性(Random Sample Consensus, RANSAC)、概率分布配准和基于投影的配准<sup>[5]</sup>。精确配准主要包括 Besl<sup>[6]</sup>等提出的迭代最近点(iterative closest point, ICP)算法, ICP 算法时间复杂度高,需要良好的初始位姿,不然容易陷入局部最优。Chetverikov、Dong 等人对 ICP 的改进提高了算法的效率和准确性<sup>[7-8]</sup>,对于数据量大的情况下迭代耗时。Biber<sup>[9]</sup>提出了基于概率密度分布的 NDT 算法,算法精度高、计算速度快但对初始位姿有一定的要求。Rusu<sup>[10-11]</sup>提出了持久特征直方图配准(Persistent Feature Histograms)算法,计算复杂度高,速度慢,接着提出优化后的快速点特征直方图(Fast Point Feature Histograms, FPFH)描述符,基于样本共识的方法(Sample Consensus Initial Align, SAC-IA)进行特征配准,提高了配准速度,克服了点云位置的局限性,配准精度不高。考虑到粗配准和精确配准优缺点,两步配准算法成为了主流。荆路等人<sup>[12]</sup>提出一种基于 FPFH 的 SAC-IA 和 NDT(Normal Distributions Transform)融合的点云配准方法,点云采样的大小对配准速度有很大的影响以及 NDT 的配准精度相比 ICP 稍微降低。赵明富、宋涛等人<sup>[13]</sup>提出了基于 FPFH 融合采样一致性和迭代最近点算法的点云配准方法,解决了 ICP 算法陷入局部最优的问题,在计算 FPFH 特征时耗时有待于进一步改进。刘今越等人<sup>[14]</sup>提出一种基于曲率精简点云,融合 NDT 与 ICP 的点云配准算法提高了点云配准的速度,模型数据不具普适性。Sun T 等人<sup>[15]</sup>提出结构紧凑的加权高度图像描述符(Weighted Height Image, WHI),并用于点云粗配准,配准精度、效率高。

针对点云两步配准效率低、配准精度差的问题,提出 ISS 算法(Intrinsic Shape Signatures, ISS)精简点云,通过 WHI 描述符完成粗配准,利用安德森算法改进 ICP 完成点云的精确配准。实验表明所提算法的速度、精度都有一定程度的提高,在噪声环境下配准效果良好。

## 2 加权高度图像描述符

加权高度图像描述符(Weighted Height Image,

WHI)是一种三维信息二维离散化的表达,主要包括简化 LRF(local coordinate reference system, LRF)和基于良态空间优化的加权编码两个部分。

### 2.1 局部坐标参考系

一个独特的、可重复的、鲁棒的局部坐标参考系对于特征描述是非常重要的<sup>[16]</sup>。LRF 估计一般通过局部点云的协方差矩阵特征值分解得到:

$$C(p_f) = \sum_{i: d_i \leq \mu r} (r - d_i)(p_i - p_f)(p_i - p_f)^T \quad (1)$$

式中,  $p_f$  为特征点;  $r$  是搜索半径;  $p_i$  为支持域内的点;  $\mu$  邻域控制因子,  $d_i = \|p_i - p_f\|_2$ 。

协方差矩阵中,对离特征点较远的邻域点进行较小权值的加权,这可以在遮挡存在的情况下增加 LRF 的可再现性。由于协方差矩阵  $C(p_f)$  是实对称矩阵,对其进行特征值分解可以得到:

$$C(p_f) = Q\Lambda Q^T \quad (2)$$

其中,  $Q = [\gamma_1 \ \gamma_2 \ \gamma_3]$  是正交矩阵;  $\Lambda$  是由特征值  $\lambda_1 \lambda_2 \lambda_3$  ( $\lambda_1 > \lambda_2 > \lambda_3$ ) 构成的对角矩阵。 $\gamma_1 \gamma_2 \gamma_3$  是一组标准正交向量。基于 LRF 的方法中,特征点  $p_f$  与邻域点  $p_i$  构成的平移不变向量  $p_{if} = p_i - p_f$ ,其旋转不变性是基于 LRF 的坐标变换实现的即:

$$p_{if}^{\text{am}} = R^{\text{am}} p_{if} = [x_i^{\text{am}}, y_i^{\text{am}}, z_i^{\text{am}}]^T \quad (3)$$

式中,  $R^{\text{am}} = [\gamma_x^{\text{am}}, \gamma_y^{\text{am}}, \gamma_z^{\text{am}}]^T \gamma_x^{\text{am}} = \gamma_1, \gamma_z^{\text{am}} = \gamma_3, \gamma_y^{\text{am}} = \gamma_2 \times \gamma_x^{\text{am}}$  坐标轴方向仍然是不确定的,坐标轴的正负方向需要重新定义。为了唯一地确定 LRF,根据文献[15]的方法利用局部点云重心符号对坐标轴的方向进行重定向。对于  $x$  轴和  $z$  轴,分别计算新坐标系下的坐标分量:

$$\text{sum}_x = \sum_{i: d_i \leq r} x_i^{\text{am}} \quad (4)$$

$$\text{sum}_z = \sum_{i: d_i \leq r} z_i^{\text{am}} \quad (5)$$

然后根据坐标分量和定义坐标轴的方向,如下:

$$\text{sign}_x = \begin{cases} 1 & \text{sum}_x \geq 0 \\ -1 & \text{sum}_x < 0 \end{cases} \quad (6)$$

$$\text{sign}_z = \begin{cases} 1 & \text{sum}_z \geq 0 \\ -1 & \text{sum}_z < 0 \end{cases} \quad (7)$$

$$\text{sign}_y = \text{sign}_x \times \text{sign}_z \quad (8)$$

定义一个符号向量  $S = [\text{sign}_x \ \text{sign}_y \ \text{sign}_z]^T$ ,则支撑区域内各点的最终坐标可表示为:

$$P_{if}^{\text{LRF}} = S R^{\text{am}} p_{if} = R^{\text{LRF}} p_{if} = (\gamma_x^T p_{if}, \gamma_y^T p_{if}, \gamma_z^T p_{if})$$

$$= (x_i^{\text{LRF}}, y_i^{\text{LRF}}, z_i^{\text{LRF}})^T \quad (9)$$

其中,  $R^{\text{LRF}} = SR^{\text{am}}$ , 是符号重定向后的局部坐标系。

## 2.2 WHI 特征描述符生成

基于二维形式的三维信息编码被广泛地应用在三维局部描述子中, 不同描述子的编码方法定义对应的编码函数, 三维局部形状一般为三维空间中的一个表面, 表面对应的函数可以表示为  $F(x, y, z) = 0$ 。LRF 方法中, 点  $p_i = [x_i, y_i, z_i]^T$  首先与特征点  $p_f$  建立平移不变向量, 然后再进行坐标变换, 用编码函数表示见式 10。

$$F(x_i, y_i) = z_i = p_{ij}^T \gamma_z = (p_i - p_f)^T \gamma_z \quad (10)$$

提出一种权函数对编码函数进行加权, 以使得特征空间更加逼近于良态空间, 权函数定义为:

$$W(x, y, z) = \eta + (1 - \eta) \frac{(r - d_i(x, y, z))}{r},$$

$$0 < \eta \leq 1 \quad (11)$$

其中,  $r$  是搜索半径,  $d_i(x, y, z)$  是点  $p_f$  与点  $p_i$  的距离,  $\eta$  是权函数值域范围的控制因子, 它使得  $W(x, y, z)$  的值域为  $[\eta, 1]$ 。则优化后的编码函数见下式:

$$F(x, y, z) = W(x, y, z) F_z(x, y) = \left[ \left( \eta + (1 - \eta) \frac{(r - d_i)}{r} \right) \times z_{(x, y)} \right] \quad (12)$$

$F_z(x, y) = z$ , 为了生成描述符, 编码函数应该重新编码或直接离散成描述符。在  $p_f$  建立 LRF, 点  $p_f$  的切平面是由基点  $p_f$  和它的法向量  $n$  唯一决定的。另外两个正交分量  $n_x, n_y$  位于平面内。落入支持区域的点沿法向量投影到平面上。图像的像素值由所有加权高度的平均值决定, 而不是由最小距离决定。WHI 计算公式见下式:

$$\text{WHI}(x, y) = \frac{1}{k(x, y)} \sum_{(x_i^{\text{LRF}}, y_i^{\text{LRF}}, z_i^{\text{LRF}}) \in \text{WHI}(x, y)} (x_i^{\text{LRF}}, y_i^{\text{LRF}}, z_i^{\text{LRF}}) \cdot z_i^{\text{LRF}} \quad (13)$$

其中,  $k(x, y)$  是局部邻域点投影在像素  $\text{WHI}(x, y)$  内的点的个数。 $z_i^{\text{LRF}} = \gamma_z^T p_{ij}$ 。WHI 的分辨率为  $m \times m$ , 其中  $m$  值决定了网格的尺寸, 可根据点云分辨率或不同应用场景对  $m$  值进行选择。在投影的过程中可能导致某些网格内没有投影点, 造成网格的空洞, 提出利用高斯滤波对局部高度图像进行平滑和填充, 进而可一定程度地恢复由量化造成的信息损失, 也可对抗各类噪声干扰。假设随机的三维局部表面的点坐标在  $x - y$  平面内服从均匀分布。则概率密度

函数为下式:

$$f(x, y) = \begin{cases} \frac{1}{4R^2}, & (x, y) \in D \\ 0, & (x, y) \notin D \end{cases} \quad (14)$$

其中,  $D$  是局部高度图像对应的正方形区域 ( $D: -R \leq x \leq R, -R \leq y \leq R$ )。则  $x$  方向(用随机变量  $X$  表示)对应的边缘概率密度函数为下式:

$$f_X(x) = \int_{-R}^R \frac{1}{4R^2} dy = \frac{1}{2R} \quad (15)$$

同理:

$$f_Y(y) = \int_{-R}^R \frac{1}{4R^2} dx = \frac{1}{2R} \quad (16)$$

随机变量  $X$  和  $Y$  都服从均匀分布, 他们的均值为  $E(X) = E(Y) = 0$ , 方差  $\sigma_x^2 = \sigma_y^2 = \frac{4R^2}{12} = \frac{R^2}{3}$ 。

高斯滤波见下式:

$$H(u, v) = \exp\left(-\frac{u^2}{2\sigma_x^2} - \frac{v^2}{2\sigma_y^2}\right) = \exp\left(-\frac{3(u^2 + v^2)}{2R^2}\right) \quad (17)$$

采用的卷积核尺寸为  $5 \times 5$ 。利用该滤波器对局部高度图像进行滤波并保持分辨率不变, 最后将滤波后  $m \times m$  的局部高度图像按照一定顺序展开成一维向量, 即可得到该特征点的 WHI 描述子。

## 3 特征点提取及点云配准

### 3.1 ISS 算法

由于点云数量较大, 一般提取点云中几何特征明显的点来代表整体点云。ISS 算法具有丰富的几何信息, 可以完成高质量的点云配准。ISS 特征点算法检测原理如下:

Step1: 利用  $\text{kd\_tree}$  构建三维点云  $k$  邻域内的拓扑结构, 从而利于三维点云的搜索;

Step2: 假设三维点云中的查询点为  $P_i$ , 邻域的点集  $N(p_i) = \{p_{ij}, j \in \{1, 2, \dots, k\}\}$   $p_{ij}$  表示邻域内的点, 对于邻域内的中心点:

$$\bar{p}_i = \frac{1}{|k|} \sum_{p_{ij} \in N(p_i)} p_{ij} \quad (18)$$

Step3: 依据欧式距离计算点  $p_{ij}$  的权值, 见下式:

$$w_{ij} = \frac{1}{\|p_{ij} - \bar{p}_i\|} \quad (19)$$

Step4: 构建协方差矩阵:

$$\text{cov}(p_i) = \sum_{p_{ij} \in N(p_i)}^k w_{ij} (p_{ij} - \bar{p}_i) (p_{ij} - \bar{p}_i)^T \quad (20)$$

Step5: 求协方差矩阵从大到小排列的特征值  $\lambda_{i1}, \lambda_{i2}, \lambda_{i3}$ , 以及对应的特征向量  $e_{i1}, e_{i2}, e_{i3}$ 。

Step6: 设置筛选特征点的阈值  $\varepsilon_1$  和  $\varepsilon_2$ , 满足以下条件的点设置为关键点:

$$\frac{\lambda_{i2}}{\lambda_{i1}} \leq \varepsilon_1 \quad (21)$$

$$\frac{\lambda_{i3}}{\lambda_{i2}} \leq \varepsilon_2 \quad (22)$$

通过对三维点云的 ISS 特征点作为采样点进行点云的配准, 精简点云数量, 降低点云特征描述的复杂度, 有利于提高点云配准的速度。

### 3.2 基于 WHI 的粗配准

点云配准应满足一个变换矩阵  $\hat{T}$  使得源点云 P 和目标点云 Q 中的距离误差和函数最小。为了精简点云, 提取配准点云的 ISS 特征点, 并计算 WHI 特征描述符, 利用采样一致性配准算法进行点云粗配准。算法原理如下:

(1) 对源点云、目标点云提取 ISS 特征点计算点对的 WHI 特征;

(2) 利用 kdtree 算法搜索相近特征的对应点对, 作为对应点对;

(3) 从对应的点集中随机选取四个对应点对, 采用 SVD 算法计算源点云与目标点云之间的变换矩阵;

(4) 对应点对的源点云进行变换, 计算变换后的点云与原对应点对的目标点云的欧式距离, 如果小于一定阈值作为内点记录, 否则记为外点;

(5) 重复(2)~(4)步直到迭代次数达到设定阈值, 选择最多一个内点的记录, 利用迭代矩阵对源点云进行变换。

### 3.3 基于 ICP 改进的精配准

#### 3.3.1 安德森加速算法

对于一个固定点迭代问题  $x^{(k+1)} = G(x^{(k)})$ , 定义它的残差函数  $F(x) = G(x) - x$ ,  $F^{(k)} = G(x^{(k)})$ 。映射函数  $G(\cdot)$  的固定点满足  $F(x^*) = 0$ , 安德森加速算法利用当前迭代的前  $m$  次迭代产生最新的迭代值<sup>[17]</sup>。

$$x_{AA}^{(k+1)} = G(x^{(k)}) - \sum_{j=1}^m \theta_j^* (G(x^{(k-j+1)}) - G(x^{(k-j)})) \quad (23)$$

$(\theta_1^*, \dots, \theta_m^*)$  是式(24)最小二乘的解:

$$(\theta_1^*, \dots, \theta_m^*) = \text{argmin} \left\| F^{(k)} - \sum_{j=1}^m \theta_j (F^{(k-j+1)} - F^{(k-j)}) \right\| \quad (24)$$

研究表明, Anderson 加速法是求残差函数的根的一种拟牛顿方法, 对于线性收敛的不动点迭代, Anderson 加速法可以提高收敛速度<sup>[18]</sup>。

#### 3.3.2 安德森加速的 ICP 点云配准算法

传统 ICP 配准算法写成关于需要求解的关于  $R, t$  固定点迭代的形式:

$$(R(k+1), t(k+1)) = G_{ICP}(R(k), t(k)) \quad (25)$$

$$G_{ICP}(R(k), t(k)) = \text{argmin}_{R, t} \sum_{i=1}^M \omega_i \cdot \left\| R_i + t - \Pi_Q(R(k) p_i + t(k)) \right\|^2 + I_{SO(d)}(R) \quad (26)$$

$\Pi_Q(\cdot)$  表示在投影在点集 Q 的最近点。然而, 我们不能直接将 Anderson 加速度应用于映射  $G_{ICP}$ 。这是因为安德森加速度将计算 R 的新值作为旋转矩阵的仿射组合, 这通常不是一个旋转矩阵本身。为了解决这个问题, 使用另一组变量 X 来参数化一个刚性变换, 这样 X 的任何值都对应一个有效的刚性变换, 并且 ICP 迭代可以重写为式(27)的形式<sup>[19]</sup>:

$$X(k+1) = \bar{G}_{ICP}(X(k)) \quad (27)$$

然后我们可以通过在每次迭代中执行以下步骤对变量 X 应用安德森加速度:

(1) 从  $x^{(k)}$  计算旋转矩阵  $R^{(k)}$  和平移向量  $t^{(k)}$ ;

(2) ICP 迭代更新:

$$(R', t') = G_{ICP}(R^{(k)}, t^{(k)})。$$

(3) 计算  $\bar{G}_{ICP}(X^{(k)})$ 。

(4) 计算加速值  $X_{AA}$ 。

$R^d$  中的所有刚性变换都形成了特殊的欧几里得群  $SE(d)$ , 这是一个李群, 并产生了一个李代数  $se(d)$ , 它是一个向量空间。可以使用  $se(d)$  中对应的元素将刚性变换参数化。每个点的齐次坐标  $p = [p^T, 1]^T$ , 刚性变换  $T$  通过旋转矩阵平移向量表示:

$$T = \begin{bmatrix} R & t \\ 0 & 1 \end{bmatrix} \in \mathbb{R}^{(d+1) \times (d+1)} \quad (28)$$

对于齐次坐标,所有这些矩阵形成特殊的欧几里得群  $SE(d)$ 。它的李代数  $se(d)$  包含如下形式的矩阵:

$$\check{T} = \begin{bmatrix} S & u \\ 0 & 0 \end{bmatrix} \in \mathbb{R}^{(d+1) \times (d+1)} \quad (29)$$

每一个矩阵  $\check{T} \in se(d)$  对应一个矩阵  $T \in SE(d)$ :

$$\check{T} = \log(T) \quad (30)$$

采用文献[19]方法对这些变换的对数进行安德森加速。由于  $se(d)$  是一个向量空间,加速度值  $\check{T}_{AA}$  也属于  $se(d)$  中的一个刚性变换,  $T_{AA} = \exp(\check{T}_{AA}) \in SE(d)$ 。当加速值与前一次迭代相比降低了目标函数(1)时,加速值作为新的迭代;否则,恢复未加速的 ICP 迭代作为新迭代。我们将所有实验中 Anderson 加速的先前迭代次数设置为  $m=5$ 。

#### 4 实验和分析

实验选取不同的点云模型进行研究,通过点云配准的精度、时间作为配准指标,所提算法和几种先进的算法进行比较证实所提算法的先进性。

##### 4.1 实验数据和实验条件

为了验证本文算法的有效性,通过两组不同数据对文献[12]算法,文献[13]算法、文献[15]算法及所提的算法进行比较。实验数据选用斯坦福 3D 扫描库 (<http://graphics.stanford.edu>) 下载的 Bunny 模型和 Dragon 模型, Bunny 模型选用 bun000 和 bun045 数据, Dragon 模型选用 dragon-StsndRight\_0 和 dragonStsndRight\_24 点云数据。实验电脑配置为 Intel(R) Core(TM) i5-6200 的 CPU, 内存 12 GB, 使用 VS 2019 配置 PCL1.12.0 点云库展开实验。

实验中待配准点云模型的初始位置如图 1, 灰色为待配准点云, 黑色为目标点云。



图 1 点云配准前的 Bunny、Dragon 模型

Fig. 1 Bunny and Dragon models before point cloud registration

#### 4.2 评价指标

##### (1) 精确度指标

点云配准精度通过均方根误差 RMSE (Root Mean Square Error) 评定, RMSE 用以估计源点云和目标点云的平均距离。原始点云的三个维度见表 1。RMSE 的计算公式见式(31),  $n$  为点云配准对应点的数量,  $x_i$  为对应点对的欧式距离,  $\hat{x}_i$  为完全配准后的距离:

$$RMSE = \sqrt{\frac{\sum_1^n (x_i - \hat{x}_i)^2}{n}} \quad (31)$$

表 1 中/的左右数值分别表示待配准点云、目标点云属性的具体值。X、Y、Z 维度表示边界框的三个维度, 边界框是包裹点云的体积最小的长方体。

##### (2) 速率指标

点云配准的效率可以通过运行的时间进行评估, 由于实验环境, 算法原理不同, 通过多次实验求取平均值作为点云配准算法的最终时间。

表 1 原始点云的维度

Tab. 1 Dimensions of the original point cloud

点云	Bunny	Dragon
数量	40256/40097	41841/34836
X 维度	0.1557/0.14725	0.204718/0.195
Y 维度	0.15224/0.15343	0.145172/0.144
Z 维度	0.117421/0.1386	0.071147/0.100

##### 4.3 点云配准时间和精度

从配准时间与精度方面, 将所提算法与几种常见的配准算法进行了对比, 结果如表 2 所示。SAC-IA + NDT<sup>[12]</sup> 首先计算 FPFH 特征, 然后利用 SAC-IA 方法作为粗配准, NDT 算法做为精配准。SAC-IA + ICP<sup>[13]</sup> 以 DNT 方法进行粗配准, ICP 方法进行精配准。WHI + ICP<sup>[15]</sup> 通过体素下采样, 通过点云的 WHI 特征构建对应点对进行粗配准, ICP 算法完成精配准。

所提方法利用 ISS 算法提取特征点完成点云精简, 然后利用 WHI 描述符进行粗配准, 基于安德森加速 ICP 的方法进行精配准。不同点云模型下的配准精度和配准效率见表 2。

从表 2 可以看出, 所提算法在 Bunny 点云数据的配准时间为 4 s 左右, 较 SAC-IA + NDT、SAC-IA + ICP、WHI + ICP 方法的 22 s、26 s、6 s 左右, 在配准效率上分别提高了 450%、550%、50%。所提算法

在 Bunny 点云配准的精度为 0.0029943, 较前三种算法的大致提升了 10% 以上。在 Dragon 模型中, 所提算法的配准时间为 5 s 左右, 较前三种算法的 23 s、28 s、10 s, 分别提升了 360%、440%、50% 左右。所提算法在 Dragon 模型配准的精度为 0.00176953, 较 SAC-IA + ICP、cNDT + ICP 三种算法分别提升了 5% 左右, 相对于 SAC-IA + NDT 算法提升了 39% 左右。所提算法相较于其他三类算法在点云数据配准过程中具有明显优势。

表 2 点云配准精度及效率

Tab. 2 Point cloud registration accuracy and efficiency

点云模型	算法	RMSE	总耗时/s
Bunny	SAC-IA + NDT	0.00482695	22.0525
	SAC-IA + ICP	0.00309348	26.282
	WHI + ICP	0.0029948	6.2098
	所提算法	0.0029943	4.206
Dragon	SAC-IA + NDT	0.00246537	23.2852
	SAC-IA + ICP	0.001777957	28.016
	WHI + ICP	0.00177961	10.5826
	所提算法	0.00176953	5.139

#### 4.4 点云配准算法关键问题分析

##### (1) ISS 算法分析

体素下采样算法在精简点云方面具有广泛的应用, 下采样的点云为原始点云的近似点云。ISS 算法提取的特征点为配准点云集中的点, 速度慢于体素下采样算法, 基于几何特征的优势相比于体素下采样算法更具显著性。实验选用斯坦福的 Armadillo 模型进行实验, 初始位姿如图 2 所示。



图 2 点云配准前的 Armadillo 模型

Fig. 2 Armadillo model before point cloud registration

在实际中由于传感器、扫描环境的影响, 点云获取过程中不可避免的产生噪声, 选取 Armadillo 模型验证算法在噪声环境下的影响。ISS 算法提取后的配准点集如图 3 所示。




图 3 Armadillo 模型的 ISS 特征点集

Fig. 3 ISS feature point set of Armadillo model

提取后的配准点集通过 WHI 进行粗配准如图 4 所示。



图 4 Armadillo 模型粗配准

Fig. 4 Coarse registration of Armadillo model

基于 ISS 与 WHI 特征描述子粗配准后, 模型大致重合, 能够为点云精确配准提供良好的初始点集。基于体素下采样和 WHI 的粗配准算法未能配准成功。基于体素下采样的特征点包含噪声点的信息, 对点云粗配准有很大的影响, ISS 算法过滤了噪声点。因此所提算法在噪声环境下具有一定的鲁棒性。

##### (2) 安德森加速的 ICP 算法分析

安德森加速算法的先前迭代次数  $m$  对 ICP 算法有重要的影响,  $m$  取值越大包含的先前迭代信息越多, 点云配准的时间会增加。 $\{X(k)\}$  收敛到  $G_{ICP}(R(k), t(k))$  取得局部最小值, 进而求得点云配准所需的变换矩阵。点云配准的速度、精度是两个重要的指标, 实验以此为参考确定所需的  $m$  值。实验选取 Bunny 模型, 作为配准点云, 使用 CloudCompare 软件中的三点配准算法进行初始配准, 为加速的 ICP 算法提供良好的位姿, 如图 5 所

示,灰色点云为待配准点云,黑色点云为 bun045 模型三点配准后的点云。




图5 Bunny 模型三点配准

Fig.5 Bunny model registration error

为确定良好的  $m$  值,实验采取单一变量法,改变  $m$  值,记录加速的 ICP 算法收敛时点云配准的误差和配准时间,如图 6,图 7 所示。 $m$  的取值对点云配准的精确度影响比较小, $m$  取值为 5 时获得良好的配准速度,与文献[20]中安德森算法在几何优化中的理论相符。




图6 先前迭代次数对点云配准误差影响

Fig.6 Influence of previous iterations on point cloud registration error




图7 先前迭代次数对点云配准时间影响

Fig.7 Effect of previous iterations on point cloud registration time

为验证改进的精配准算法的可行性,采用基于 WHI 的配准算法对 Bunny 模型进行粗配准,然后利用基于安德森算法的 ICP 算法进行精配准。所提算法与传统的 ICP 算法配准的 RMSE 随着迭代次数的

变化如图 8 所示。

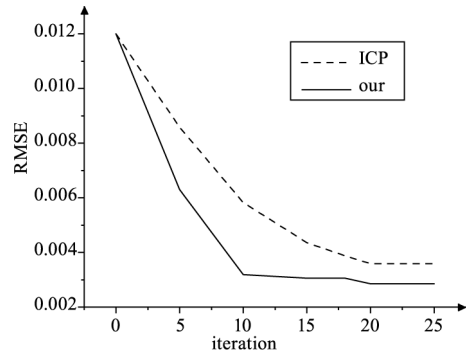


图8 迭代次数对点云配准误差的影响

Fig.8 Effect of iteration number on point cloud registration error

从图 8 中看出,基于安德森的 ICP 配准算法迭代速度快,精度略有提高。实验中基于安德森的 ICP 算法运行时间约为 0.976s, ICP 算法约为 3.225s,配准效率提高了 2.3 倍左右。在同等配准精度下,所提算法迭代速度快于 ICP 算法,可在满足配准精度要求下调整迭代次数进一步提高点云配准速度。

4.5 点云配准性能测试

点云数据获取过程中经常会受到一些外界的干扰,点云配准算法应该具有一定的抗噪能力,在实验中选择 Bunny 模型以及 Dragon 模型分别进行实验,首先对两种模型加入均值为 0 以及标准差以 0.001 为间隔的高斯噪声得到含有噪声的数据。

从图 9 图 10 中看出在点云配准成功情况下,随着噪声的增加几种算法的配准精度都有所提高,这和精度的评价标准有关, RMSE 的评价指标会过滤掉一些错误的配准点对,因此计算出的点云的配准精度有所提高, SAC-IA + ICP 算法在 Bunny 模型配准成功,在 Dragon 实验中配准失败,其他几种算法均能配准成功,配准精度相差无几,所提算法相对精度略高一些。

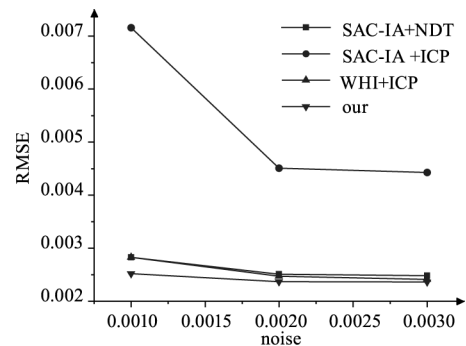


图9 Bunny 模型配准误差

Fig.9 Bunny model registration error

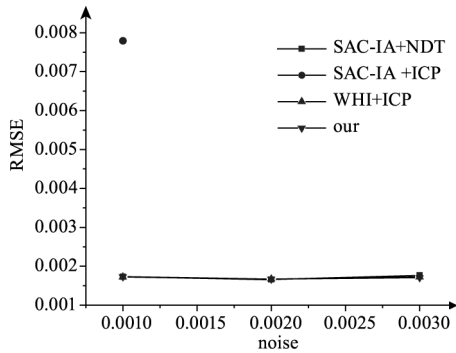


图 10 Dragon 模型配准误差

Fig. 10 Dragon model registration error

4.6 真实环境下点云配准性能测试

为了验证该算法在实际工程应用中的有效性,分别选取室内、室外真实点云数据进行实验,分别来自 PCL 官网<sup>[21]</sup>和文献<sup>[22]</sup>提供的数据集,如图 11、图 12 所示。




图 11 点云配准前的 Room 模型

Fig. 11 Room model before point cloud registration



图 12 点云配准前的 Arch 模型

Fig. 12 Arch model before point cloud registration

图 11 的点云模型灰色为 room\_scan1,黑色为 room\_scan2。图 12 为室外真实场景,灰色点云为 s01,黑色为 s02。室内室外场景的点云数据都存在噪声与离群点,最能真实反映算法的可行性,所提算法可视化结果见图 13、图 14,算法配准时间见表 3。




图 13 Room 模型配准可视化

Fig. 13 Room model registration visualization



图 14 Arch 模型配准可视化

Fig. 14 Arch model registration visualization

表 3 真实场景配准时间

Tab. 3 Real scene registration time

点云模型	算法	总耗时/s
Room (112586/112624)	SAC - IA + NDT	28. 2525
	SAC - IA + ICP	32. 263
	WHI + ICP	9. 20983
	所提算法	4. 178
Arch (686719/427961)	SAC - IA + NDT	45. 2852
	SAC - IA + ICP	48. 018
	WHI + ICP	15. 5876
	所提算法	6. 139

在噪声和离群点存在的情况下利用 RMSE 进行误差计算不合适,因为会包含一些无关点对的计算,从表中看出在含有噪声、离群点的情况下所提算法配准效率更高,在含有噪声的不同场景中配准速度提高了 2 倍以上。

5 结 语

针对现有配准算法在大批量点云配准效率低、配准误差大,容易受噪声的干扰的问题,提出了 ISS 算法精简点云,利用 WHI 描述符进行采样一致性算法完成点云粗配准,接着利用安德森算法加速 ICP 算法完成点云精确配准,与几种先进的算法做对比,实验表明所提的算法在 3D 扫描库场景中点云配准精度、配准速度都有不同程度的提高,在有噪声、离群点的室内、外场景算法依然可用,在工程实际中具有重要的意义。同时也存在不足,ISS 算法参数设置复杂,需要人工干预,实验模型应在更多的场景中进行,这也是后期将要改进的地方。

参考文献:

[1] Xu G, Pang Y, Bai Z, et al. A fast point clouds registration algorithm for laser scanners[J]. Applied Sciences, 2021, 11(8):3426.



- [2] Jing Lu, Wu Bin, Fang Xilu. Point cloud registration method based on SIFT feature points combined with ICP[J]. *Laserr & Infrared*, 2020, 51(7): 944-9550. (in Chinese) 荆路, 武斌, 方锡禄. 基于 SIFT 特征点结合 ICP 的点云配准方法[J]. *激光与红外*, 2021, 51(7): 944-950.
- [3] Yang Y, Li Y, Li J. Point cloud registration algorithm based on improved rotational projection statistical feature descriptor[J]. *Application Research on Computer*, 2011.
- [4] Yuan M, Li X, Cheng L, et al. A coarse-to-fine registration approach for point cloud data with bipartite graph structure[J]. *Electronics*, 2022, 11(2): 263.
- [5] Xiong B, Li D, Zhou Z, et al. Fast registration of terrestrial LiDAR point clouds based on gaussian-weighting projected image matching [J]. *Remote Sensing*, 2022, 14(6): 1466.
- [6] Besl P J, McKay N D. Method for registration of 3-D shapes[C]//*Sensor fusion IV: control paradigms and data structures*. Spie, 1992, 1611: 586-606.
- [7] 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.
- [8] Dong J, Peng Y, Ying S, et al. LieTrICP: an improvement of trimmed iterative closest point algorithm [J]. *Neuro-computing*, 2014, 140: 67-76.
- [9] Biber P, Strasser W. The normal distributions transform: a new approach to laser scan matching [C]//*Proceedings 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003)*, IEEE, 2003, 3: 2743-2748.
- [10] Rusu R B, Blodow N, Marton Z C, et al. Aligning point cloud views using persistent feature histograms [C]//*2008 IEEE/RSJ International Conference on Intelligent Robots and Systems*, IEEE, 2008: 3384-3391.
- [11] Rusu R B, Blodow N, Beetz M. Fast point feature histograms (FPFH) for 3D registration [C]//*2009 IEEE International Conference on Robotics and Automation*, IEEE, 2009: 3212-3217.
- [12] Jing Lu, Wu Bin, Li Xianshuai. A point cloud registration method based on SAC-IA and NDT fusion[J]. *Journal of Geodesy and Geodynamics*, 2021, 41(4): 378-381. (in Chinese) 荆路, 武斌, 李先帅. 基于 SAC-IA 和 NDT 融合的点云配准方法[J]. *大地测量与地球动力学*, 2021, 41(4): 378-381.
- [13] Zhao Mingfu, Huang Zheng, Song Tao, et al. A point cloud registration method combining sampling consistency and Iterative closest point algorithm[J]. *Laser Journal*, 2019, 40(10): 45-50. (in Chinese) 赵明富, 黄铮, 宋涛, 等. 融合采样一致性和迭代最近点算法的点云配准方法[J]. *激光杂志*, 2019, 40(10): 45-50.
- [14] Liu Jinyue, Zhang Gang, Jia Xiaohui, et al. Research on point cloud registration method based on curvature threshold[J]. *Laser & Optoelectronics Progress*, 2022, 59(18): 466-472. (in Chinese) 刘今越, 张港, 贾晓辉, 等. 基于曲率阈值的点云配准方法研究[J]. *激光与光电子学进展*, 2022, 59(18): 466-472.
- [15] Sun T, Liu G, Liu S, et al. An efficient and compact 3D local descriptor based on the weighted height image [J]. *Information Sciences*, 2020, 520: 209-231.
- [16] Petrelli A, Di Stefano L. On the repeatability of the local reference frame for partial shape matching [C]//*2011 International Conference on Computer Vision*. IEEE, 2011: 2244-2251.
- [17] Walker H F, Ni P. Anderson acceleration for fixed-point iterations [J]. *SIAM Journal on Numerical Analysis*, 2011, 49(4): 1715-1735.
- [18] Evans C, Pollock S, Rebholz L G, et al. A proof that anderson acceleration improves the convergence rate in linearly converging fixed-point methods (but not in those converging quadratically) [J]. *SIAM Journal on Numerical Analysis*, 2020, 58(1): 788-810.
- [19] Zhang J, Yao Y, Deng B. Fast and robust iterative closest point [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 44(7): 3450-3466.
- [20] Peng Y, Deng B, Zhang J, et al. Anderson acceleration for geometry optimization and physics simulation [J]. *ACM Transactions on Graphics (TOG)*, 2018, 37(4): 1-14.
- [21] Rusu R B, Cousins S. 3D is here: Point cloud library (PCL) [C]//*2011 IEEE International Conference on Robotics and Automation*, IEEE, 2011: 1-4.
- [22] Cai Z, Chin T J, Bustos A P, et al. Practical optimal registration of terrestrial LiDAR scan pairs [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 147: 118-131.