

基于扩展的点特征直方图特征的点云匹配算法

汤慧^{1,2}, 周明全^{1,3*}, 耿国华¹

¹西北大学信息科学与技术学院, 陕西 西安 710127;

²西安财经大学实验实训教学管理中心, 陕西 西安 710127;

³北京师范大学艺术与传媒学院, 北京 100875

摘要 针对传统匹配方法存在匹配精度低、速度慢等问题,提出一种基于扩展点特征直方图(EPFH)特征的点云匹配算法,该算法采用先粗配再细配的策略。利用 ISS (intrinsic shape signature)特征检测算法获取点云上的显著特征点集;对特征点进行 EPFH 特征描述;通过采样一致性算法估算刚体变换矩阵,完成待匹配点云和目标点云的初始匹配;接着使用基于 k -d 树的迭代最近点算法实现两片点云的精细匹配;最后将本文算法分别应用于公共数据集和兵马俑特殊数据集进行实验验证。实验结果表明,相比传统方法而言,本文算法具有更高的匹配精度和速度。

关键词 机器视觉; 点云匹配; 特征提取; 采样一致性; k -d 树

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP56.241503

Point Cloud Registration Algorithm Based on Extended Point Feature Histogram Feature

Tang Hui^{1,2}, Zhou Mingquan^{1,3*}, Geng Guohua¹

¹School of Information Science & Technology, Northwest University, Xi'an, Shaanxi 710127, China;

²Experimental Training Teaching Management Center, Xi'an University of Finance and Economics, Xi'an, Shaanxi 710127, China;

³School of Arts & Communication, Beijing Normal University, Beijing 100875, China

Abstract This paper proposes a point cloud registration algorithm based on extended point feature histogram (EPFH) feature. In the proposed algorithm, the strategy of rough registration prior to fine registration is adopted. The purpose of this paper is to overcome the problems of low registration accuracy and slow speed which are encountered in traditional registration methods. Initially, the intrinsic shape signature (ISS) feature-detection algorithm is used to obtain the salient feature-point set on the point clouds. Then, the EPFH feature description is applied on these feature points. Subsequently, the rigid body transformation matrix is estimated using the sampling consistency algorithm to complete the initial registration of the point clouds and the target point clouds. The k -d tree-based iterative nearest-point algorithm is used to implement the fine registration of the two-point clouds. Finally, experimental verification is performed by applying the proposed algorithm to the public data set and the terracotta warrior data set. The experimental results show that the proposed algorithm exhibits higher registration accuracy and higher speed than traditional methods.

Key words machine vision; point cloud registration; feature extraction; sample consensus; k -d tree

OCIS codes 150.1135; 100.5010; 150.0155

收稿日期: 2019-04-29; 修回日期: 2019-05-28; 录用日期: 2019-06-13

基金项目: 国家自然科学基金青年科学基金项目(61802311, 61731015, 61602380)、国家自然科学基金面上项目(61673319)、陕西省重点研发计划一般项目(2019SF-272)、陕西省教育厅自然科学基金专项(18JK0795)、青岛市自主创新重大专项项目(2017-4-3-2-xcl)

* E-mail: puss.tang@qq.com

1 引言

随着三维激光扫描设备的迅速发展,点云数据的处理受到广泛的关注。特别地,扫描设备易受测量环境及设备本身的限制,无法一次性完成整个实体的扫描,因此,如何将不同视角下扫描的点云数据对齐成为近年来许多学者研究的热点。点云匹配正是解决此问题的方法,通过寻找最优的刚体变换将不同视角下的点云进行对齐,其匹配的精度在三维模型的后续处理中发挥着至关重要的作用。

解决该问题最为经典的方法是由 Besl 等^[1]提出的迭代最近点(ICP)算法,该算法通过迭代的方式使得两片点云之间的距离最小化,以此来实现两片点云之间的匹配。但是若这两片点云之间的距离相差较远,算法容易陷入局部最优,且迭代耗时^[2]。之后,有许多学者提出一系列改进的点云匹配算法。Rusu 等^[3]通过提取点邻域的几何特征,构建快速点特征直方图(FPFH)描述子,作为点的局部特征,以此实现点云之间的匹配。Xian 等^[4]利用球面极坐标将点云数据转换为数字图像,然后提取该图像的尺度不变特征,利用图像匹配实现三维点云的匹配。Jiang 等^[5]考虑到角度特征具有刚体不变性,所以采用夹角特征来进行匹配。王鹏等^[6]基于 B-SHOT 描述子对特征点进行描述,通过双向汉明距离确定匹配点对,采用随机采样一致性算法估算刚体变换参数进行初始匹配,然后再采用 3D-NDT 算法完成精确匹配。赵夫群等^[7]利用特征点的曲率特征对特征点进行描述,确定匹配点对,通过四元数法进行粗匹配,最后采用改进的 ICP 算法实现精确匹配。

然而,上述方法存在匹配精度低、耗时长、特征易受噪声影响等问题,因此本文提出一种基于扩展的点特征直方图(PFH)特征点云匹配算法。该算法采用先粗配后细配的策略,首先针对点云上的显著特征点构建扩展点特征直方图(EFPFH)特征描述子,该描述子具有较强的区分度;再通过采样一致性(SAC-IA)方法估算刚体变换矩阵,实现待匹配点云和目标点云的初始匹配;然后利用基于 k - d 树的 ICP 算法实现两片点云的精细匹配;最后将本文算法应用于公共数据集和兵马俑特殊数据集进行验证。结果表明本文算法在一定程度上解决了传统算法所存在的问题。

2 特征点检测

由于原始点云数据量大,在处理过程中存在计

算复杂度高、耗时长等问题。近年来,一些学者相继提出多种特征点检测算法,此类算法可以有效提取点云内在的显著特征点。特征点又称为关键点,它是点云上具有稳定性、代表性的点集,特征点的数量远远小于原始点云的数据量。然后通过特征描述函数对特征点加以描述,以此形成的特征点描述子是原始点云的紧凑表示,从而可以加快速度的处理速度。

在特征点检测阶段,采用已有的 ISS^[8-9](intrinsic shape signature)算法提取点云有效的特征点。其算法如下所述。

假设点云模型 \mathbf{P} 上有 N_1 个点, \mathbf{p}_i 为其上任意一点,其坐标为 $(x_i, y_i, z_i), i=1, 2, \dots, N_1$ 。

1) 以点云模型 \mathbf{P} 上的任意一点 \mathbf{p}_i 为中心,设定其邻域半径为 r ,搜索到中心点 \mathbf{p}_i 的距离不大于半径 r 的所有点 \mathbf{p}_j ,计算其权值 w_{ij} 为

$$w_{ij} = \frac{1}{\|\mathbf{p}_i - \mathbf{p}_j\|}, \quad (1)$$

式中: $\|\mathbf{p}_i - \mathbf{p}_j\| \leq r, \|\mathbf{p}_i - \mathbf{p}_j\|$ 为点 \mathbf{p}_i 到点 \mathbf{p}_j 之间的欧氏距离。

2) 构造 \mathbf{p}_i 点的加权协方差矩阵 $\mathbf{M}_{\text{cov}}(\mathbf{p}_i)$,计算方程为

$$\mathbf{M}_{\text{cov}}(\mathbf{p}_i) = \sum_{\|\mathbf{p}_i - \mathbf{p}_j\| \leq r} w_{ij} (\mathbf{p}_i - \mathbf{p}_j) (\mathbf{p}_i - \mathbf{p}_j)^T / \sum_{\|\mathbf{p}_i - \mathbf{p}_j\| \leq r} w_{ij}. \quad (2)$$

3) 计算(2)式协方差矩阵 $\mathbf{M}_{\text{cov}}(\mathbf{p}_i)$ 的特征值,设其特征值为 $\lambda_i^{(1)}, \lambda_i^{(2)}, \lambda_i^{(3)}$,且 $\lambda_i^{(1)} \leq \lambda_i^{(2)} \leq \lambda_i^{(3)}$ 。

4) 选取特征值满足 $\frac{\lambda_i^{(2)}}{\lambda_i^{(1)}} \leq \epsilon_1, \frac{\lambda_i^{(3)}}{\lambda_i^{(2)}} \leq \epsilon_2$ 的点为模型的特征点,其中 ϵ_1, ϵ_2 为初始设定的阈值,该阈值的设定依赖于所处理的模型。

3 EFPFH 特征提取

传统的点特征直方图(PFH)特征是由 Rusu 等^[10]提出的一种点云特征描述子,其构建了一个高维超信息空间的点集合特征表达,描述了中心点与其邻域范围点之间的空间差异。图 1 为特征点 p_0 的 PFH 计算影响区域,小方框标记的点为特征点 p_0 ,小三角标记的点为 p_0 的 k 邻域点(k 为邻域点个数),该邻域是由以 p_0 为中心,到其距离不大于所给半径 r 的所有点构成的一个全连通网络。

为了能够计算特征点邻域表面的几何不变量,需要为每一组点对构造一个局部 Darboux 框架。

Darboux 框架如图 2 所示,其中 $\mathbf{u}, \mathbf{v}, \mathbf{w}$ 为 Darboux 框架下的坐标轴。假设 $\mathbf{p}_s, \mathbf{p}_t$ 为其中任意一组点对,其中 s 代表源点, t 代表目标点, $\mathbf{n}_s, \mathbf{n}_t$ 分别为其法向量,则其局部 Darboux 框架的坐标轴构造为

$$\begin{cases} \mathbf{u} = \mathbf{n}_s \\ \mathbf{v} = (\mathbf{p}_s - \mathbf{p}_t) \times \mathbf{n}_s \\ \mathbf{w} = \mathbf{u} \times \mathbf{v} \end{cases} \quad (3)$$

得到任意一组点对的 Darboux 框架后,即可计算 α, φ, θ 三个不变特征,具体计算方式为

$$\begin{cases} \alpha = \mathbf{v} \mathbf{n}_t \\ \phi = \mathbf{u} \frac{(\mathbf{p}_t - \mathbf{p}_s)}{\|\mathbf{p}_t - \mathbf{p}_s\|} \\ \theta = \arctan(\mathbf{w} \mathbf{n}_t, \mathbf{u} \mathbf{n}_t) \end{cases} \quad (4)$$

将每个特征分量划分为 b 个子区间,对其三元组以统计的方式放进直方图中,统计落在每个子区间中的点数目,即可得最后的 PFH 特征。然而,上述不变量仅反映点对之间的几何关系,并未体现其空间信息。为了能够提高该特征描述子的区分度,采用一种同时包含几何和空间关系的新的特征描述子 EPFH,以此来提高点云匹配的精度。




图 1 特征点 p_0 的 PFH 计算影响区域

Fig. 1 Effected region of PFH calculation for feature point p_0




图 2 Darboux 框架示意图

Fig. 2 Schematic of Darboux frame

3.1 建立局部坐标系

一个好的特征描述子应当对刚体变换具有不变性,这样才能实现不同视角下两片点云之间的精确特征匹配。一个典型的思路是给每个特征点建立

一个局部坐标系,并在此坐标系下构建特征点的局部特征描述子^[3]。

给定一个特征点 \mathbf{p}_{key} 及其邻域点集合 $\{\mathbf{p}_a | a = 1, 2, \dots, N_2\}$,则该邻域点的加权协方差矩阵为

$$\mathbf{M} = \frac{1}{N_2} \sum_{a=1}^{N_2} (r - d_a) (\mathbf{p}_a - \mathbf{p}_{key}) (\mathbf{p}_a - \mathbf{p}_{key})^T, \quad (5)$$

式中: r 为支撑域的大小, d_a 为特征点 \mathbf{p}_{key} 到其邻域点 \mathbf{p}_a 的最短距离。

对协方差矩阵 \mathbf{M} 进行特征值分解,便可得到

$$\mathbf{M} = \mathbf{V}_1 \mathbf{D}_1 \mathbf{V}_1^T, \quad (6)$$

式中: \mathbf{V}_1 为协方差矩阵 \mathbf{M} 的三个特征值分别对应的特征向量 $\{\mathbf{e}_1, \mathbf{e}_2, \mathbf{e}_3\}$ 构成的矩阵; \mathbf{D}_1 为协方差矩阵 \mathbf{M} 的三个特征值构成的对角矩阵。

由于特征向量彼此之间都是正交的,因此本文采用协方差矩阵 \mathbf{M} 的三个特征向量来建立局部坐标系。为了能够得到唯一的坐标系,需要消除每个特征向量的方向模糊性。采用文献[11]的方法来消除特征向量的方向模糊,该方法首先计算特征点到其所有邻域点的向量,然后对这些向量的分布情况进行统计,并使特征向量方向与上述向量的多数方向相一致。

首先挑选出与向量 \mathbf{e}_1 方向相一致的所有邻域点,将其构成集合 S_1^+ ,即

$$S_1^+ = \{a | (\mathbf{p}_a - \mathbf{p}_{key}) \mathbf{e}_1 \geq 0\}. \quad (7)$$

然后挑选出与向量 \mathbf{e}_1 方向相反的所有邻域点,将其构成集合 S_1^- ,即

$$S_1^- = \{a | (\mathbf{p}_a - \mathbf{p}_{key}) \mathbf{e}_1 < 0\}. \quad (8)$$

若 $|S_1^+| \geq |S_1^-|$,则局部坐标系的 x 轴定义为向量 \mathbf{e}_1 ,否则定义为向量 $-\mathbf{e}_1$ 。利用上述类似方法作用于 \mathbf{e}_3 以获得坐标系的 z 轴,则其 y 轴由 $x \times z$ 得到,因此,最终的局部坐标系是以特征点 \mathbf{p}_{key} 为原点,以 x 轴、 y 轴、 z 轴分别为其坐标轴建立起来的。

3.2 构建 EPFH 特征描述子

为能够确切地对特征点进行描述,需构建特征点的 EPFH 特征描述子,首先将特征点的所有邻域点变换到以特征点为原点的局部坐标系下,从而可使该特征描述子具有刚体不变性。然后,采用一个三维球形栅格沿距离、方位角和俯仰角三个维度,将每个特征点的邻域空间划分为多个子空间。图 3 为三维球形栅格示意图。该栅格在距离维度上将空间划分为 2 个部分,在方位角维度上将空间划分为 8 个部分,在俯仰角维度上将空间划分为 2 个部分。因此,特征点的邻域空间可被划分为 32 个子空间。



图3 三维球形栅格示意图

Fig. 3 Diagram of 3D spherical grid

之所以这样设计,是因为在每个子空间中采用了点对几何不变量进行特征描述。描述子本身已具有较高的区分度,因而仅需要划分少量的子空间即可使得该描述子具有更高的区分度,较小的子空间数量有利于获得紧凑且高效的特征描述子^[12]。

在每个子空间中,分别采用属于该子空间中的每组点对之间的几何不变量 α, φ, θ 构建一个局部直方图;然后将这些直方图连接起来即可得到该子空间的子特征;最后将每个子空间中的子特征连接起来即可形成特征点的 EPFH 特征描述子。通过反复实验发现,将每个局部直方图划分为 10 个子区间时可以很好地取得描述子长度与区分度之间的折中。所以,本文将每个局部直方图划分为 10 个子区间,那么每个特征点的特征描述子长度即为 $10 \times 3 \times 32 = 960$ 。因为采用了不同的不变量来描述点云所代表的局部表面,所以得到的特征描述子具有很强的区分度。

3.3 特征描述子降维

由上述描述可知,该特征描述子的长度维度太高,不易于实现高效的特征存储和匹配。实际上,此描述子存在较多的冗余信息,所以采用主成分分析 (PCA) 法对该描述子进行降维处理,以获得更加紧凑且区分度更强的特征描述子。PCA 是一种非常典型的降维方法,通过将高维特征向量映射到低维向量空间来揭示其内在结构,在特征压缩、特征选择及目标识别领域得到了大量的应用^[13]。本文采用 PCA 对 EPFH 特征描述子降维过程如下。

假设点云模型 P 上的所有特征点的特征描述子集合为 $\{f_b | b = 1, 2, \dots, N_f\}$, 其中 N_f 为模型本身的特征点数量。首先计算其协方差矩阵 C ,

$$C = \frac{1}{N_f} \sum_{b=1}^{N_f} (f_b - \bar{f})(f_b - \bar{f})^T, \quad (9)$$

式中: \bar{f} 为特征描述子集合中所有特征的均值。

然后对协方差矩阵 C 进行特征值分解,便可得到

$$C = V_2 D_2 V_2^T, \quad (10)$$

式中: V_2 为协方差矩阵 C 的特征向量所构成的矩阵; D_2 为协方差矩阵 C 的特征值构成的对角矩阵。

为降低特征描述子的维度,将 C 的所有特征值由大到小进行排序,并将前 N_{fd2} 个特征值对应的特征向量构成投影矩阵 V_c 。在对特征向量个数进行选择时,需满足下述要求:

$$\sum_{d'=1}^{N_{fd2}} \lambda_{d'} / \sum_{d'=1}^{N_{fd1}} \lambda_{d'} \geq \eta, \quad (11)$$

式中: $\{\lambda_{d'} | d' = 1, 2, \dots, N_{fd1}\}$ 为特征值按照降序排列的集合; N_{fd1} 为降维前特征描述子的维度; N_{fd2} 为降维后的特征描述子维度; η 为特征压缩系数。

因此,降维后的特征描述子自定义为

$$\bar{f}_b = V_c^T f_b, \quad (12)$$

式中: \bar{f}_b 即为最终降维后对局部点云进行描述的 EPFH 特征描述子。

4 点云匹配

为能使不同视角下的点云进行融合,本文在上述所提取 EPFH 特征的基础上,首先采用 SAC-IA 方法^[14]对两片点云进行粗匹配,使两片点云获得较好的初始位置。为使匹配后的点云匹配精度更高,再采用改进的 ICP 算法实现精匹配。

4.1 基于 SAC-IA 的粗匹配

首先采用 SAC-IA 方法实现点云之间的粗匹配,其算法过程如下:

a) 从待匹配点云 P 的特征点集合中选择 m 个样本特征点,为保证所提取的样本点足够均匀,所采取的样本点之间的距离应不小于预先设定的最小距离阈值 d ;

b) 在目标点云 Q 的特征点集合中找出与待匹配点云 P 中的采样点具有相似 EPFH 特征的一个或者多个点,然后从这些点中随机选取一个作为当前采样点的一一对应点;

c) 计算对应点之间的刚体变换矩阵,并通过计算对应点变换后的“距离误差和”函数来评价当前变换的质量。此处采用 Huber 惩罚函数作为误差度量,记作 $\sum_{l=1}^m L_h(e_l)$, 其中

$$L_h(e_l) = \begin{cases} \frac{1}{2} e_l^2, & |e_l| \leq t_e \\ \frac{1}{2} t_e (2|e_l| - t_e), & |e_l| > t_e \end{cases}, \quad (13)$$

式中: t_e 为预先设定的阈值; e_l 为第 l 组对应点变换后的距离误差。不断重复 a)~c), 直至达到最佳的误差度量结果。最后采用 Levenberg-Marquardt 算法^[3]进行局部优化, 即可完成两片点云之间的初始匹配。

4.2 基于 k -d 树的精匹配

经过 SAC-IA 粗匹配, 已基本将两片点云模型进行粗对齐, 但是为了减小待匹配点云和目标点云之间的误差, 获得更高的匹配精度, 必须采用 ICP 算法进行精匹配。但经典的 ICP 算法^[1]是基于迭代的, 这会造成搜索两片点云之间对应点对的速度过慢。为了能够提高匹配的速度, 本文在经典 ICP 算法的基础上引入 k -d 树^[15-17]来搜索对应点对, 以此实现两片点云的精匹配。

改进的 ICP 算法的匹配步骤如下:

a) 假设待匹配点云 P 经过坐标变换后得到粗匹配后的点云 P' , 在其上选取 N 个数据点作为匹配数据集 $f_p = \{p_g | g=1, 2, \dots, N\}$;

b) 对于 f_p 中的每一个点 p_g , 利用 k -d 树在目标点云 Q 上寻找到其距离最近的对应点 q_g , 将其构成有序对作为初始对应点对。为防止构成的对应点对是错误的, 避免对最终匹配结果造成影响, 本文采用文献^[14]的方法剔除错误的对应点对;

c) 采用最小二乘法计算旋转矩阵 R_{o+1} 和平移矩阵 t_{o+1} , 使得 $d_{o+1} = \frac{1}{N} \sum_{g=1}^N \|q_{og} - (R_{o+1} p_{og} + t_{o+1})\|^2$ 最小, 其中 d_{o+1} 为第 $o+1$ 次迭代的均方误差;

d) 将计算得到的刚体变换参数作用于点云 P' , $P'' = R_{o+1} P' + t_{o+1}$;

e) 判断迭代终止条件, 设定初始阈值 ϵ 和迭代次数 K , 当满足 $d_o - d_{o+1} < \epsilon$ 或者 $o > K$ 时, 停止迭代, 否则重复 a)~d), 直至满足条件为止。

5 实验结果与分析

为了验证本文算法的有效性, 将其分别应用于公共数据集和兵马俑特殊数据集。其中, 兵马俑数据集中所有的碎块数据均采用三维专业扫描设备进行获取, 在实验前, 需进行去噪、断裂面分割等步骤, 然后采用本文算法验证是否能够将邻接碎块进行正确拼接。本文实验采用 Visual Studio 2015 和 PCL 库编程, 在 CPU 主频为 3.4 GHz, 内存为 8 G 的 Win7 系统上实现。

本文选取公开数据集中的 Cake 模型^[18]和特殊

数据集中的 G3-I-C 号俑、G10-5 号俑、G10-6 号俑的部分碎块进行实验。图 4 为本文方法的部分实验结果, 其中图 4(a)、(d)、(g)、(j)、(m) 为 5 组原始碎块, 其中图 4(a)、(d) 为公共数据中的 Cake 碎块, 图 4(g)、(j)、(m) 为兵马俑数据碎块。图 4(b)、(e)、(h)、(k)、(n) 分别为其基于 SAC-IA 算法粗匹配的结果, 虚框标注为匹配部位, 从实验结果来看, 该方法已将相邻碎块基本对齐, 但是仍存在间隙、错位等现象。最后再采用改进的 k -d 树实现精匹配, 最终结果如图 4(c)、(f)、(i)、(l)、(o) 所示, 可以看出, 通过细微的旋转平移可以获得更为精确的匹配结果。本文方法的性能参数如表 1 所示。

为体现本文所提算法的优越性, 本文与文献^[1]中经典的 ICP 方法、文献^[3]中基于 FPFH 特征的点云匹配方法、文献^[7]中基于特征点曲率特征的匹配方法进行对比。不同算法的运行参数对比结果如表 2 所示。

从表 1 和表 2 结果可看出, 本文方法整体上运行时间最短、匹配的精度更高。相比经典的 ICP 方法而言, 本文方法在精度上有大幅度提高; 其次, 本文方法在运行时间上缩短将近一半, 收敛速度更快。其原因是传统 ICP 采用集中所有点进行不断迭代来进行匹配, 其可能会陷入局部最优, 所以其收敛速度慢。而本文方法则是基于特征点集进行匹配的, 而且在精匹配阶段引入了 k -d 树进行快速搜索最近点, 所以收敛速度较快, 且匹配精度更高。相比文献^[3]和文献^[7]而言, 本文方法采用 EPFH 特征对特征点进行描述, 由于该描述子具有较强的鉴别力, 所以在粗匹配阶段, 误匹配对少, 有效匹配对的数目较多, 再加上 FPFH 具有较高的计算效率, EPFH 继承了 FPFH 的高效特点, 所以大大提高了匹配的效率。

6 结 论

针对传统匹配方法存在匹配精度低、速度慢等问题, 提出一种基于扩展的 PFH 特征的点云匹配算法, 该算法采用先粗配再细配的策略。首先对点云上的显著特征点进行 EPFH 特征描述; 然后通过采样一致性算法估算刚体变换矩阵, 完成待匹配点云和目标点云的初始匹配; 接着在经典 ICP 算法的基础上, 引入 k -d 树, 加速搜索最近点的速度。实验结果表明相比传统方法而言, 本文算法具有更高的匹配精度和收敛速度, 是一种有效的点云匹配方法。

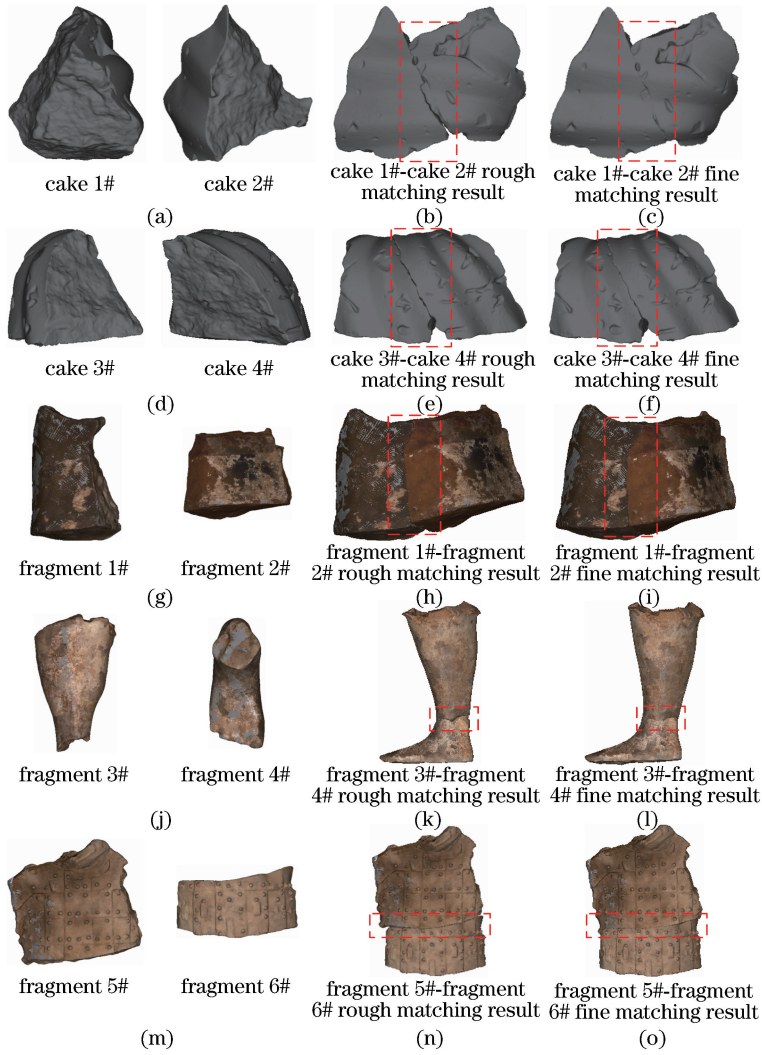


图 4 本文方法实验结果。(a)(d)(g)(j)(m)原始碎块;(b)(e)(h)(k)(n)基于 SAC-IA 算法粗匹配的结果;
(c)(f)(i)(l)(o)基于改进的 k -d 树算法精匹配的结果

Fig. 4 Experimental results of the proposed method. (a)(d)(g)(j)(m) Original pieces; (b)(e)(h)(k)(n) results of rough matching based on SAC-IA algorithm; (c)(f)(i)(l)(o) results of fine matching based on improved k -d tree algorithm

表 1 本文算法的运行参数

Table 1 Operating parameters of the proposed algorithm

Experimental data		Number of points on the fracture surface	Accuracy / mm	Initial matching time /s	Precise matching time /s	Overall running time /s
Cake 1 # ,	Cake 1 #	7035	0.0186	4.431	2.954	7.385
Cake 2 #	Cake 2 #	7942				
Cake 3 # ,	Cake 3 #	9688	0.0213	7.256	2.418	9.674
Cake 4 #	Cake 4 #	6354				
G3-I-C	Fragment 1 #	8643	0.0297	5.177	2.414	7.591
	Fragment 2 #	8937				
G10-5	Fragment 3 #	2543	0.0205	3.802	1.090	4.892
	Fragment 4 #	2711				
G10-6	Fragment 5 #	6041	0.0283	5.623	1.633	7.256
	Fragment 6 #	5486				

表 2 不同算法的运行参数对比

Table 2 Comparison of operating parameters of different algorithms

Experimental data		Number of points on the fracture surface	Method	Accuracy / mm	Overall running time / s
Cake 1 # ,	Cake 1 #	7035	ICP	0.0336	12.364
	Cake 2 #		Method in Ref. [3]	0.0289	9.478
Cake 2 #	Cake 2 #	7942	Method in Ref. [7]	0.0243	10.752
			Our method	0.0186	7.385
Cake 3 # ,	Cake 3 #	9688	ICP	0.0375	18.842
	Cake 4 #		Method in Ref. [3]	0.0248	13.621
Cake 4 #	Cake 4 #	6354	Method in Ref. [7]	0.0251	15.419
			Our method	0.0213	9.674
G3-I-C	Fragment 1 #	8643	ICP	1.0346	13.254
	Fragment 2 #		Method in Ref. [3]	0.0325	8.027
G10-5	Fragment 3 #	2543	Method in Ref. [7]	0.0318	8.361
			Our method	0.0297	7.591
G10-6	Fragment 4 #	2711	ICP	1.0510	6.468
	Fragment 5 #		Method in Ref. [3]	0.0304	5.124
G10-6	Fragment 6 #	5486	Method in Ref. [7]	0.0212	5.867
			Our method	0.0205	4.892
			ICP	1.0397	10.412
			Method in Ref. [3]	0.0341	7.983
			Method in Ref. [7]	0.0365	8.025
			Our method	0.0283	7.256

参 考 文 献

- [1] Besl P J, McKay N D. A method for registration of 3-D shapes [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14 (2): 239-256.
- [2] Zeng F X, Li L, Diao X P. Iterative closest point algorithm registration based on curvature features [J]. Laser & Optoelectronics Progress, 2017, 54 (1): 011003.
曾繁轩, 李亮, 刁鑫鹏. 基于曲率特征的迭代最近点算法配准研究[J]. 激光与光电子学进展, 2017, 54 (1): 011003.
- [3] Rusu R B, Blodow N, Beetz M. Fast point feature histograms (FPFH) for 3D registration [C] // 2009 IEEE International Conference on Robotics and Automation, May 12-17, 2009, Kobe, Japan. New York: IEEE, 2009: 3212-3217.
- [4] Xian Y R, Xiao J, Wang Y. A fast registration algorithm of rock point cloud based on spherical projection and feature extraction [J]. Frontiers of Computer Science, 2019, 13(1): 170-182.
- [5] Jiang J, Cheng J, Chen X L. Registration for 3-D point cloud using angular-invariant feature [J]. Neurocomputing, 2009, 72(16/17/18): 3839-3844.

- [6] Wang P, Li S D, Zhao X. Point cloud automatic registration based on B-SHOT feature and 3D-NDT [J]. Geospatial Information, 2018, 16(12): 26-27, 64, IV.
王鹏, 李少达, 赵雪. 基于 B-SHOT 特征和 3D-NDT 的点云自动配准[J]. 地理空间信息, 2018, 16(12): 26-27, 64, IV.
- [7] Zhao F Q, Geng G H. Fracture surface matching method for terracotta based on feature points [J]. Laser & Optoelectronics Progress, 2018, 55 (4): 041005.
赵夫群, 耿国华. 基于特征点的秦俑断裂面匹配方法 [J]. 激光与光电子学进展, 2018, 55(4): 041005.
- [8] Zhong Y. Intrinsic shape signatures: a shape descriptor for 3D object recognition [C] // 2009 IEEE 12th International Conference on Computer Vision Workshops, ICCV Workshops, September 27-October 4, 2009, Kyoto, Japan. New York: IEEE, 2009: 689-696.
- [9] Hu J B, Zhou P B, Geng G H, et al. Reassembly method of cultural relics based on feature point matching of fracture surface [J]. Acta Optica Sinica, 2019, 39(9): 0915002.
胡佳贝, 周蓬勃, 耿国华, 等. 基于断裂面特征点匹配的文物碎片重组方法 [J]. 光学学报, 2019, 39

- (9): 0915002.
- [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, September 22-26, 2008, Nice, France. New York: IEEE, 2008: 3384-3391.
- [11] Tombari F, Salti S, di Stefano L. Unique signatures of histograms for local surface description [M] // Daniilidis K, Maragos P, Paragios N. Computer vision-ECCV 2010. Lecture notes in computer science. Berlin, Heidelberg: Springer, 2010, 6313: 356-369.
- [12] Zhuang Z Y, Zhang J, Sun G F. Extended point feature histograms for 3D point cloud representation [J]. Journal of National University of Defense Technology, 2016, 38(6): 124-129.
庄祉昀, 张军, 孙广富. 用于三维点云表示的扩展点特征直方图算法[J]. 国防科技大学学报, 2016, 38(6): 124-129.
- [13] Ke Y, Sukthankar R. PCA-SIFT: a more distinctive representation for local image descriptors [C] // Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004. CVPR 2004., June 27-July 2, 2004, Washington, DC, USA. New York: IEEE, 2004: 8161522.
- [14] Chen X W, Zhu Y L, Wu T, *et al.* The point cloud registration technology based on SAC-IA and improved ICP [J]. Journal of Xi'an Polytechnic University, 2017, 31(3): 395-401.
陈学伟, 朱耀麟, 武桐, 等. 基于 SAC-IA 和改进 ICP 算法的点云配准技术 [J]. 西安工程大学学报, 2017, 31(3): 395-401.
- [15] Greenspan M, Yurick M. Approximate k-d tree search for efficient ICP [C] // Fourth International Conference on 3-D Digital Imaging and Modeling, 2003. 3DIM 2003. Proceedings., October 6-10, 2003, Banff, Alta., Canada. New York: IEEE, 2003: 8322534.
- [16] Nuchter A, Lingemann K, Hertzberg J. Cached k-d tree search for ICP algorithms [C] // Sixth International Conference on 3-D Digital Imaging and Modeling (3DIM 2007), August 21-23, 2007, Montreal, QC, Canada. New York: IEEE, 2007: 9892401.
- [17] Liu J, Zhang X, Zhu J W. ICP three-dimensional point cloud registration based on k-d tree optimization [J]. Engineering of Surveying and Mapping, 2016, 25(6): 15-18.
刘江, 张旭, 朱继文. 一种基于 K-D 树优化的 ICP 三维点云配准方法 [J]. 测绘工程, 2016, 25(6): 15-18.
- [18] Huang Q X, Flöry S, Gelfand N, *et al.* Reassembling fractured objects by geometric matching[J]. ACM Transactions on Graphics, 2006, 25(3): 569-578.