

## 基于流形聚类的非球类目标多站三维点云配准方法

陈辉<sup>1</sup>, 王怡博<sup>1</sup>, 黄和平<sup>2</sup>, 延菲<sup>3</sup>, 黄云峰<sup>1\*</sup><sup>1</sup>上海电力大学自动化工程学院, 上海 200090;<sup>2</sup>浙江正泰仪器仪表有限责任公司杭州分公司, 浙江 杭州 310052;<sup>3</sup>上海明华电力科技有限公司, 上海 200437

**摘要** 非球类物体形状结构复杂, 利用点云直接进行配准易出现误匹配现象。针对该问题, 引入流形上的测地距离结合物体的实际几何形状, 将三维点云配准问题转换为聚类问题, 提出一种基于流形聚类的多站点云配准方法。首先, 将粗配准后的三维点云划分为若干个聚类; 然后, 以测地距离作为聚类划分的依据更新聚类中心, 同时更新刚性变换, 再循环迭代此过程以获得最终配准结果; 最后, 由于在配准过程中计算测地距离矩阵时易产生计算消耗, 引入热梯度法将点集在空间中的遍历过程转换为泊松方程的求解过程以提升效率, 完成多站点云配准。在斯坦福大学公共数据集集中的 Bunny、Dragon 等点云数据上的实验结果表明, 所提方法可有效将非球类物体的配准精度整体提升 20%~30%。

**关键词** 机器视觉; 点云配准; 多站点云; 流形聚类; 测地距离; 热梯度

中图分类号 751.1

文献标志码 A

DOI: 10.3788/LOP222574

## Multiview Point Cloud Registration Method for Nonspherical Objects Based on Manifold Clustering

Chen Hui<sup>1</sup>, Wang Yibo<sup>1</sup>, Huang Heping<sup>2</sup>, Yan Fei<sup>3</sup>, Huang Yunfeng<sup>1\*</sup><sup>1</sup>College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;<sup>2</sup>Zhengtai Instrument (Hangzhou) Co., Ltd., Hangzhou 310052, Zhejiang, China;<sup>3</sup>Shanghai Minghua Electric Power Science & Technology Co., Ltd., Shanghai 200437, China

**Abstract** The shape and structure of nonspherical objects are complex, and it is easy to mismatch when using point clouds for direct registration. Aiming at this problem, the geodesic distance on the manifold is introduced here along with the actual geometric shape of the object. Additionally, the three-dimensional (3D) point cloud registration problem is converted into a clustering problem, and a multisite cloud registration method based on manifold clustering is proposed. First, the 3D point cloud after rough registration was divided into several clusters. Then, the geodesic distance was used as the basis of cluster division to update the cluster center while updating the rigid transformation simultaneously. The process was repeatedly iterated to obtain the final registration result. Finally, in the registration process, the geodesic distance matrix calculation easily generated a computational consumption, and the thermal gradient method was applied to transform the traversal process of point sets in space into a Poisson equation solution to improve efficiency and complete the multisite cloud registration. Experimental results on Bunny, Dragon, and other point cloud data in the Stanford University public dataset show that the proposed method can effectively improve the registration accuracy of nonspherical objects by 20%–30%.

**Key words** machine vision; point cloud registration; multiview point, manifold clustering; geodesic distance; thermal gradient

## 1 引言

准确获取复杂物体的三维形貌一直是机器视

觉<sup>[1-2]</sup>、计算机图像<sup>[3-4]</sup>、机器人<sup>[5-6]</sup>及图像处理<sup>[7-9]</sup>等领域中的重要研究问题。随着三维激光扫描技术的快速发展<sup>[10]</sup>, 三维物体表面的坐标信息更易获取, 但受扫描仪

收稿日期: 2022-09-19; 修回日期: 2022-10-12; 录用日期: 2022-10-27; 网络首发日期: 2022-11-04

基金项目: 国家科技部外国专家局项目(DL2022013007L)、上海市自然科学基金(20ZR1421300)、上海市科委项目(21DZ1207300)、上海市浦江计划(21PJD025)

通信作者: \*riverhuang@shiep.edu.cn

视角、物体几何形状以及测量环境遮挡等因素影响,无法从一次扫描中获取物体完整的表面三维信息,需要从不同角度扫描再配准与拼接<sup>[11]</sup>。

点云配准方法目前主要分为两类:成对点云配准和多站点云配准。在成对配准方法中,最经典的是迭代最近点(ICP)<sup>[12]</sup>算法,其计算过程简单,但对初始特征点对选取要求较高,点对搜索效率较低且易陷入局部最优<sup>[13]</sup>。Masuda等<sup>[14]</sup>为了提高点对搜索效率,在当前帧的点云中选取代表点进行搜索,缩小对应点搜索范围,以减少点云匹配所消耗的时间。Chetverikov等<sup>[15]</sup>提出修剪ICP(TrICP)算法,通过引入参数表示重叠部分点集所占的百分比自动去除离群点,实现精确配准。其他学者<sup>[16-22]</sup>也针对该类问题,提出了很多改进算法,但多视图点云在配准过程中仍会存在误差累积,视图站数越多,积累误差越大。

多站点云配准方法将所有视图的点云同时考虑,可有效避免误差在配准过程中的传递。谭颀等<sup>[23]</sup>利用激光跟踪仪跟踪、求解地面三维激光扫描仪移站前后的位置及姿态变化,建立相应的数学模型,从而实现多视角地面激光点云数据的配准。Jian等<sup>[24]</sup>将高斯混合模型(GMM)引入多站点云配准中,用GMM来表示输入点集,将点集配准问题转化为两个高斯混合模型的配准问题,在配准过程使两个对应模型之间的统计差异度最小,具有较好的鲁棒性和精度。Evangelidis等<sup>[25]</sup>在GMM的基础上提出多点集联合配准方法(JRMPC),假设多站点云配准中涉及的所有点都是从单个高斯混合物中提取出来的,从而将配准问题转换成一个聚类问题。受到JRMPC的启发,Zhu等<sup>[26]</sup>采用K-means聚类方法来解决配准问题,利用质心更新过程中的变换相应地更新刚性变换矩阵从而实现精确配准。然而对于形状结构较为复杂的非球类物体,不适合的聚类方法会影响配准的结果,同时初始质心选择不当的话也会陷入局部最优。

针对非球类目标,本文提出一种基于流形聚类的多站点云配准方法。在聚类过程中引入测地距离作为不同聚类之间划分的相似性度量,充分考虑实际物体的几何形状,更适合形状结构复杂的非球类物体。同时引入热梯度法,将点集遍历过程转换成泊松方程的求解过程,加快测地距离的计算速度。

## 2 算法原理

### 2.1 基于测地距离的计算方法

空间中两点之间的欧氏距离不能直接作为复杂物体聚类划分的标准,图1(a)中箭头之间的距离表示欧氏距离,而图1(b)中线段的长度表示测地距离。欧氏距离很短,不能完全表达两点之间的状态过程;测地距离很长,正好反映两点之间的差异。因此,引入测地距离代替传统的欧氏距离作为聚类划分的相似性度量来解决形状结构较为复杂物体配准精度较低的问题。




图1 欧氏距离和测地距离的比较。(a)欧氏距离;(b)测地距离  
Fig. 1 Comparison between Euclidean distance and geodesic distance. (a) Euclidean distance; (b) geodesic distance

测地距离可以理解为空间中两点之间的最短路径。将数据点看作是图 $G=(V, E)$ 的顶点,令 $p=\{p_1, p_2, \dots, p_l\} \in V^l$ 表示图上一条连接点 $p_1$ 与 $p_l$ 的路径,其中,边 $(p_k, p_{k+1}) \in E, 1 < k < l-1$ ,令 $P_{i,j}$ 表示连接点 $x_i$ 与 $x_j$ 之间的所有路径的集合,则 $x_i$ 与 $x_j$ 之间的测地距离为

$$D(x_i, x_j) = \min_{p \in P_{i,j}} \sum_{k=1}^{l-1} L(p_k, p_{k+1}), \quad (1)$$

$$L(x_i, x_j) = \rho^{\text{dist}(x_i, x_j)} - 1, \quad (2)$$

式中: $L(p_k, p_{k+1})$ 为空间中两点 $p_k$ 与 $p_{k+1}$ 之间在流形上的线段长度; $\text{dist}(x_i, x_j)$ 为 $x_i$ 与 $x_j$ 之间的欧氏距离; $\rho > 1$ ,为伸缩因子。

图2为测地距离的计算方法,以空间中的带权图为例,计算测地距离的过程相当于在空间中寻找最短路径的过程。比如点1和点5之间的直接路径距离为10,而点1和点5之间的最短路径其实是从点1到点2再到点5,最短路径为9。计算测地距离的过程也就是在空间中搜索最短路径,最短路径对应的数值即为测地距离。

虽然采用测地距离可以更好地解决形状结构较为复杂物体的配准问题,但是测地距离的计算需要对空间中的每个点进行遍历来搜索最短路径,因而计算效率较低。为了解决以上问题,通过引入热梯度法来加速测地距离矩阵的计算。

求解物体表面两点之间的最短路径的过程,可以等效为热粒子从一点扩散到另一点的过程。由于热量在传播过程中会形成一个矢量场,矢量场中每一点都会有一个梯度方向,热粒子正是朝着温度梯度的反方向扩散的,用热粒子扩散过程通过的距离之和近似等效空间中两点之间的测地距离,再结合欧拉-拉格朗日方程 $\Delta\phi = \nabla \cdot \mathbf{X}$ <sup>[27]</sup>便可快速地得到测地距离的近似值。该方法主要包括以下步骤,具体流程如图3所示。

1) 先使热量 $u$ 在物体表面扩散一小段时间 $t$ ,得到热梯度 $\dot{u}$ ;

2) 对热梯度归一化并求反,得到一个指向测地线方向的单位矢量场 $\mathbf{X}$ ;

3) 通过求解泊松方程 $\Delta\phi = \nabla \cdot \mathbf{X}$ 得到最终的测地距离。

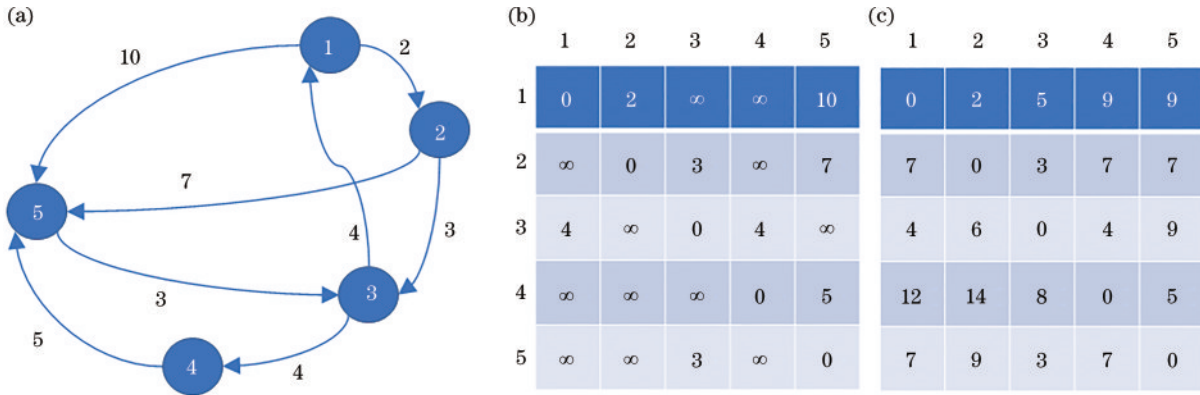


图 2 测地距离计算方法。(a)空间中有向带权图;(b)两点之间的权重;(c)两点之间的最短路径

Fig. 2 Calculation method of geodesic distance. (a) Directed weighted graph in space; (b) weight between two points; (c) shortest path between two points

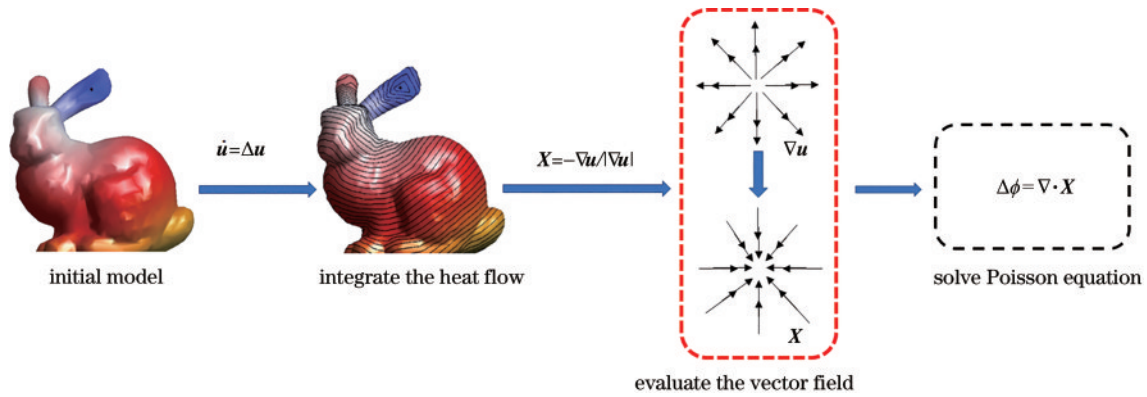


图 3 热梯度法流程

Fig. 3 Flowchart of the thermal gradient method

泊松方程中,  $\phi$  为所求测地距离的近似值, 当时间  $t$  越短时, 该结果越接近于真实值,  $\Delta$  为作用于黎曼流形上弱可微实值函数的负半定 Laplace-Beltrami 算子。

### 2.2 局部邻域特征点选择

在多站点云配准过程中经常会由于初始质心选择不当而陷入局部最优, 影响最终的配准结果。通过引入局部邻域特征点的选择方法, 选择能够代表物体几何特征的点作为初始质心, 从而优化配准结果。具体的选择方法如图 4 所示, 该方法选择局部邻域内变化

较大的点, 即物体表面起伏较大的点作为特征点, 能够更具体地反映物体的几何特征, 从而尽可能减少在配准过程中陷入局部最优的情况。

在点云中选择一个点  $p_i$ , 其邻域的协方差矩阵为

$$C = \frac{1}{k} \sum_{j=1}^k (p_{ij} - \bar{p}_i) \cdot (p_{ij} - \bar{p}_i)^T, \quad (3)$$

式中:  $\bar{p}_i = \frac{1}{k} \sum_{j=1}^k p_{ij}$ 。根据式(3)的协方差矩阵得到特征值  $\lambda_1, \lambda_2, \lambda_3$ , 令  $\lambda_1 < \lambda_2 < \lambda_3$ , 则  $\lambda_1$  对应的特征向量为点  $p_i$  的法向量  $e_1$ , 邻域表面的变化因子为

$$\sigma(p_i) = \frac{3\lambda_1}{\lambda_1 + \lambda_2 + \lambda_3}. \quad (4)$$

利用采样点邻域的平均变化来判断该点是否为特征点, 设置的阈值如式(5)所示, 平均变化大于该阈值时则该点被选取为特征点。

$$\epsilon_i = \frac{1}{k} \sum_{i=1}^k \sigma(p_i). \quad (5)$$




图 4 邻域特征点的选取。(a)表面变化较小的曲面;(b)表面变化较大的曲面

Fig. 4 Selection of neighbourhood feature points. (a) Curve with little surface change; (b) curve with large surface changes

### 2.3 基于流形聚类的多站点云配准方法

若将一个具有  $N$  个视图的多站点云配准到同一个坐标系中, 将点云模型所包含的所有点按照一定的规则划分成  $K$  个聚类。假设所有的聚类中心能够组合成一个完整精确的三维模型, 那么聚类效果如果足够好,

则能够通过聚类中心与每个点集之间的成对配准实现多站点云配准,从而将配准问题转换为聚类问题。

首先通过基于局部特征的粗配准方法获取不同视图的初始刚性变换矩阵  $\{R_i^0, t_i^0\}_{i=1}^N$ 。其中,  $R_i^0$  是初始旋转矩阵,  $t_i^0$  是初始平移矩阵。经过粗配准后,  $N$  个视图的点云数据大致重合在一起,但是在精度上还达不到实际的需求,因此需要通过精配准过程进一步提升多站点云配准的精度。

精配准过程主要包括如下步骤,流程图如图 5 所示。

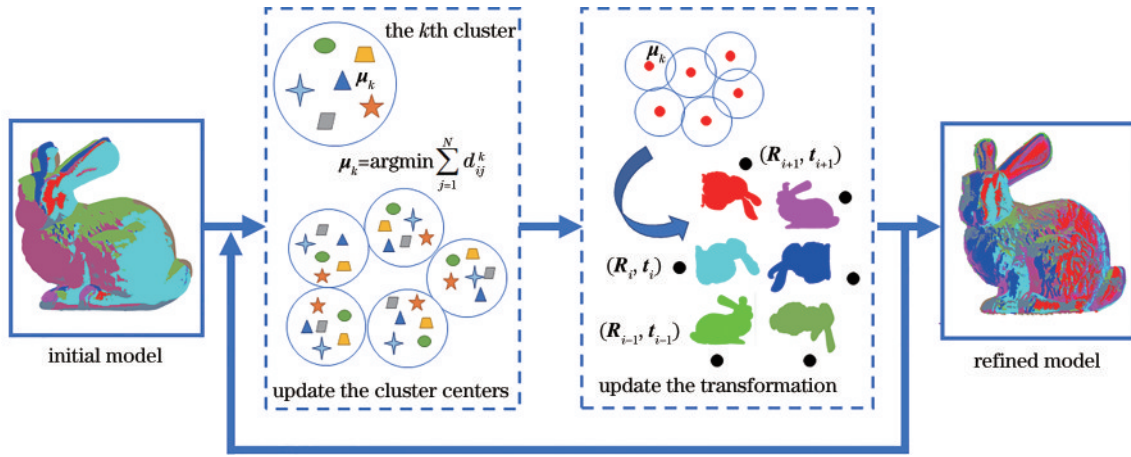


图 5 精配准流程图

Fig. 5 Flowchart of fine registration

首先根据局部邻域特征点的选择方法获取初始质心  $\mu_0$  并通过式(6)<sup>[26]</sup>将每个点分配到相应的群簇中。

$$c^q(i, j) = \underset{k \in \{1, 2, \dots, K\}}{\operatorname{argmin}} \left\| R_i^q p_{i,j} + t_i^q - \mu_k^q \right\|_2^2, \quad (6)$$

式中:  $q$  为迭代的次数;  $k$  代表第  $k$  个聚类;  $p_{i,j}$  表示第  $i$  个聚类中第  $j$  个点。该数据点分配过程相当于空间中近邻点的搜索过程,可通过  $k$  近邻搜索算法实现。

然后通过热梯度法快速准确地计算出测地距离矩阵,通过计算每个点到同一簇中其他点的测地距离之和,将测地距离之和最小的点更新为新的聚类中心。

接着根据质心的变换相应地更新刚性变换矩阵,更新的过程可以用式(7)<sup>[26]</sup>表示:

$$(R_i^q, t_i^q) = \underset{R_i, t_i}{\operatorname{argmin}} \sum_{j=1}^{M_i} \left\| R_i^q p_{i,j} + t_i^q - \mu_{c^q(i,j)}^q \right\|_2^2, \quad (7)$$

式中:  $\mu_{c^q(i,j)}^q$  为更新  $q$  代后的聚类中心;  $R_i^q, t_i^q$  分别为更新  $q$  代后的旋转变换矩阵和平移变换矩阵。

重复迭代更新质心和更新刚性变换这两个过程,当满足迭代停止条件时停止迭代得到最终的精配准结果  $R_i^q, t_i^q$ 。

### 3 实验结果及分析

为了验证所提方法的有效性,选取斯坦福大学公

1)选择初始质心  $\mu_0$ ,并将每个点分配到相应的群簇中;

2)将每个点划分到测地距离最近的群簇中,根据此时聚类中的点更新聚类中心;

3)根据质心的变换相应地更新刚性变换矩阵;

4)循环迭代步骤2)、步骤3)直到满足迭代的停止条件。

图 5 中,  $\mu_k$  为第  $k$  个聚类的聚类中心,  $(R_{i-1}, t_{i-1})$ 、 $(R_i, t_i)$ 、 $(R_{i+1}, t_{i+1})$  分别为第  $i-1$  个视图、第  $i$  个视图以及第  $i+1$  个视图的旋转变换矩阵和平移变换矩阵。

共数据集中的 Bunny、Dragon、Happy 以及 Chicken 数据集进行实验验证,数据集详细信息如表 1 所示,所有的实验均在 MATLAB R2021b 上测试,并在 2.30 GHz 8 核配有 16 GB 内存的电脑上运行,实验中所涉及的初始参数均设置为相同值。

表 1 点云数据信息

Table 1 Point cloud data information

Dataset	Bunny	Dragon	Happy	Chicken
Number of views	10	15	15	16
Total points	362272	469193	1099005	418412

#### 3.1 多站点云配准方法对比实验

针对以上 4 组点云数据进行多站点云配准,并与 MAICP<sup>[19]</sup>、LRS<sup>[28]</sup>、JRMPC<sup>[25]</sup>及 K-means<sup>[26]</sup>方法的配准结果进行对比。MAICP 在 ICP 的基础上加入运动平均算法进行多站点云配准,LRS 是一种基于低秩稀疏矩阵分解的方法,JRMPC 与 K-means 方法分别是基于概率问题中的高斯混合模型以及 K-means 聚类的多站点云配准方法。首先对不同数据集各个视图的点云通过基于局部特征的粗配准方法获取初始刚性变换矩阵,接着采用以上 4 种方法以及所提配准方法对粗配准结果进行精配准,迭代过程的停止条件为迭代次数

大于 200 或者误差小于  $10^{-5}$ 。其中,误差为各个视图的旋转误差矩阵与单位矩阵之差的绝对值之和。各种

算法配准结果的横截面如图 6 所示,通过横截面的图像可以清楚地看到每种算法的整体配准效果。图 7 为

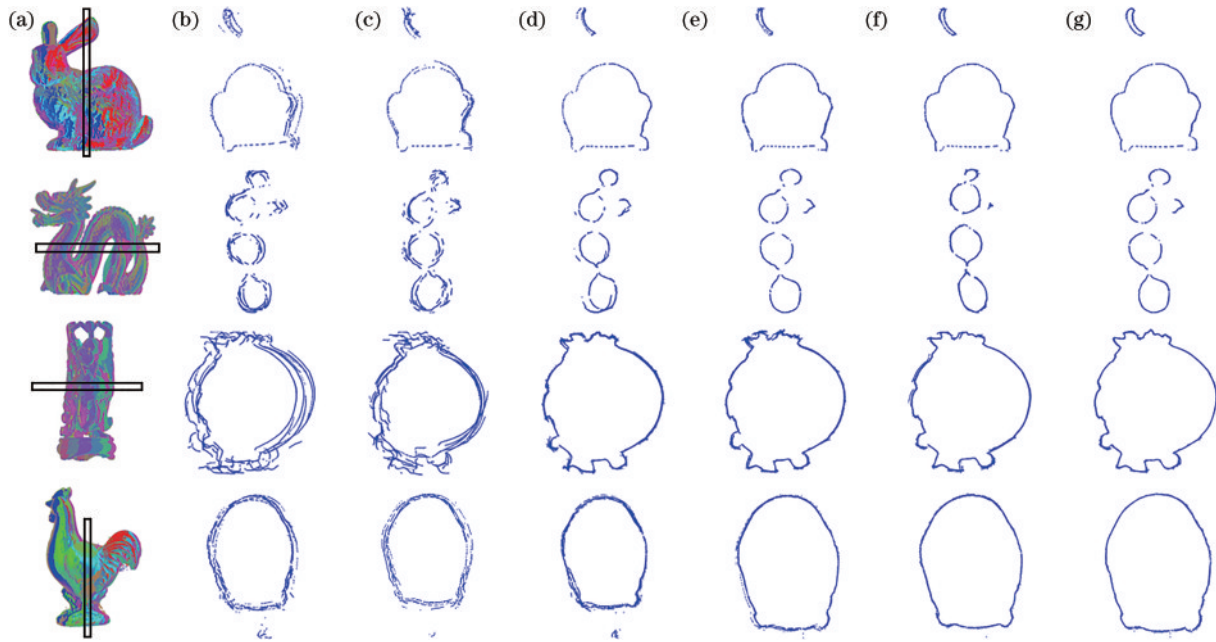


图 6 多站点云配准结果截面图。(a)多站点云配准后模型;(b)精配准初始横截面;(c)MAICP方法的结果;(d)LRS方法的结果;(e)JRMPC方法的结果;(f)K-means方法的结果;(g)所提方法的结果

Fig. 6 Cross-section of multiview point cloud registration. (a) Multiview point cloud registration model; (b) the initial cross-section of fine registration; (c) the results of the MAICP method; (d) the results of the LRS method; (e) the results of the JRMPC method; (f) the results of K-means method; (g) the results of the proposed method

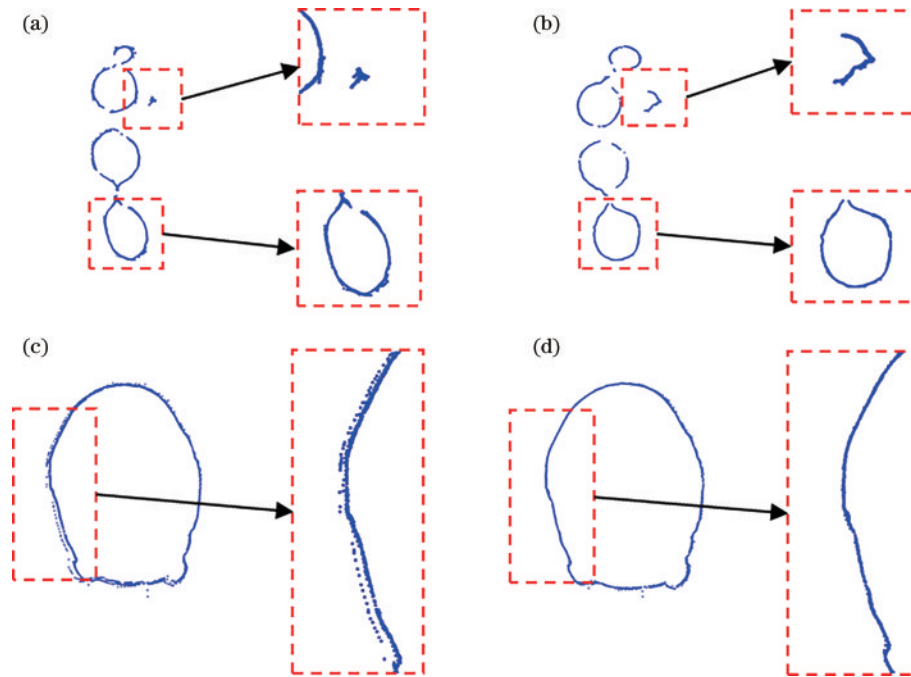


图 7 截面图局部效果比较。(a)由 K-means 方法得到的 Dragon 模型配准结果局部放大效果;(b)由所提方法得到的 Dragon 模型配准结果局部放大效果;(c)由 JRMPC 方法得到的 Chicken 模型配准结果局部放大效果;(d)由所提方法得到的 Chicken 模型配准结果局部放大效果

Fig. 7 Comparison of the local effect of cross-section. (a) The local magnification effect of the registration result of the Dragon model obtained by K-means method; (b) the local magnification effect of the registration result of the Dragon model obtained by the proposed method; (c) the local magnification effect of the registration result of the Chicken model obtained by JRMPC method; (d) the local magnification effect of the registration result of the Chicken model obtained by the proposed method

横截面局部效果比较,表 2 为不同方法的量化指标对比,粗体代表最佳结果。评价标准旋转误差  $E_R = \frac{1}{N} \sum_{i=1}^N \|R_{i,m} - R_{i,g}\|_F$ 、平移误差  $E_t = \frac{1}{N} \sum_{i=1}^N \|t_{i,m} - t_{i,g}\|_2$  均来自论文[26]中。其中,  $R_{i,g}, t_{i,g}$  为第  $i$  个视图刚性变换矩阵的真值,  $R_{i,m}, t_{i,m}$  为多站点云配准方法的估计值。

从图 6、7 以及表 2 可以看出:所提方法在配准精度

上有了较明显的提升;而 MAICP 方法由于误差在不同视图之间的积累,对于视图数较多的点云配准结果较差;由于 K-means 方法在聚类过程中采用的是欧氏距离即空间中的几何距离作为聚类划分的相似性度量,对于 Dragon 等形状结构较为复杂的物体会出现配准结果较差的情况;由于 LRS 方法需要在不同视图的点集之间建立相应的对应关系,因此会影响含有少量噪声点的 Chicken 数据集配准结果的准确性。

表 2 不同方法的准确性对比  
Table 2 Accuracy comparison of different methods

Dataset	Error	Initial	MAICP	LRS	JRMPC	K-means	Proposed method
Bunny	$E_R$	0.0386	0.0378	0.0439	0.0236	0.0219	<b>0.0096</b>
	$E_t$	2.9426	2.1693	2.0452	1.5247	1.1615	<b>0.8556</b>
Dragon	$E_R$	0.0393	0.0420	0.2838	0.0346	0.0433	<b>0.0111</b>
	$E_t$	4.5040	2.9385	2.5304	2.6730	2.9957	<b>1.2980</b>
Happy	$E_R$	0.0429	0.0603	0.0512	0.0217	0.0258	<b>0.0069</b>
	$E_t$	1.5065	1.9258	0.5326	0.4436	0.6094	<b>0.1795</b>
Chicken	$E_R$	0.0395	0.0425	0.0806	0.0274	0.0304	<b>0.0170</b>
	$E_t$	2.3417	2.1060	1.4076	1.1525	0.9927	<b>0.6801</b>

表 3 为 4 组点云数据采用 Floyd 方法和热梯度法选取不同点数计算测地距离矩阵的时间比较。从表 3 可以看到,热梯度法的计算效率相较于 Floyd 法大约提升了 40%~50%,而且 Floyd 法计算测地距离矩阵所需时间随着数据量的增大呈指数式增长,当数据量达到一定程度会由于超出内存而无法计算,而热梯度法则能够保持较快的速度对测地距离矩阵进行计算。

表 4 为各种算法进行多站点云配准所消耗的时间。K-means 方法在时间效率上优势明显;MAICP 由于需要对不同视图的点云逐个配准,因而消耗了较多时间;LRS 方法需要建立对应关系,JRMPC 方法配置参数较多,导致效率较低;所提方法虽然采用热梯度法提升了效率,但是测地距离矩阵的计算仍需要大量时间。

表 3 两种测地距离矩阵计算方法效率比较

Table 3 Efficiency comparison of two kinds of geodesic distance matrix calculation methods unit: s

Dataset	Bunny	Dragon	Happy	Chicken
Matrix order	2950×2950	1915×1915	2241×2241	3558×3558
Floyd method	91.09	33.83	48.11	155.07
Thermal gradient method	<b>52.87</b>	<b>21.65</b>	<b>30.89</b>	<b>82.57</b>

表 4 不同方法配准效率比较

Table 4 Efficiency comparison of different registration methods unit: s

Data	MAICP	LRS	JRMPC	K-means	Proposed method
Bunny	75.59	55.96	344.89	<b>3.11</b>	475.83
Dragon	241.33	695.78	621.71	<b>14.91</b>	1649.59
Happy	272.05	289.00	942.32	<b>34.75</b>	1739.63
Chicken	263.67	317.03	751.89	<b>15.33</b>	1321.12

### 3.2 多站点云配准鲁棒性实验

实际点云数据中经常会不可避免地存在噪声点,噪声点的存在也会对最终配准结果产生影响。因此为了验证所提方法的鲁棒性,对以上 4 组点云数据的每个视图中分别加入 100、200、400 个随机噪声点,结果如表 5~8 所示。

表 5 Bunny 数据集不同方法鲁棒性比较

Table 5 Robustness comparison of different methods for the Bunny dataset unit: mm

Bunny	Error	MAICP	LRS	JRMPC	K-means	Proposed method
100	$E_R$	0.0548	0.0523	0.0210	0.0225	<b>0.0091</b>
	$E_t$	2.2366	1.9532	1.5651	1.1869	<b>0.8695</b>
200	$E_R$	0.0693	0.0753	0.0311	0.0270	<b>0.0109</b>
	$E_t$	2.4352	2.5266	1.6393	1.8636	<b>1.0210</b>
400	$E_R$	0.0780	0.0815	0.0420	0.0308	<b>0.0136</b>
	$E_t$	3.2534	3.7306	1.9634	2.2453	<b>1.0351</b>

从表 5~8 可以看出:在不同数量噪声点的干扰下,各种方法的旋转误差和平移误差也随之增大,且每个视图增加噪声点的数量越多,误差增大也越明显;而

表 6 Dragon 数据集不同方法鲁棒性比较

Dragon	Error	MAICP	LRS	JRMPC	K-means	Proposed method
100	$E_R$	0.0698	0.3157	0.0344	0.0393	<b>0.0134</b>
	$E_I$	3.0489	2.5354	1.6541	2.6498	<b>1.5274</b>
200	$E_R$	0.0823	0.4425	0.0443	0.0516	<b>0.0229</b>
	$E_I$	3.5402	2.7454	2.9126	3.4135	<b>1.7779</b>
400	$E_R$	0.0984	0.5829	<b>0.0569</b>	0.0762	0.0597
	$E_I$	4.1586	3.7205	3.6746	4.3379	<b>1.8025</b>

表 7 Happy 数据集不同方法鲁棒性比较

Happy	Error	MAICP	LRS	JRMPC	K-means	Proposed method
100	$E_R$	0.0759	0.0536	0.0210	0.0383	<b>0.0066</b>
	$E_I$	2.0891	0.7924	0.5609	0.6051	<b>0.2216</b>
200	$E_R$	0.0961	0.0771	0.0414	0.0341	<b>0.0061</b>
	$E_I$	2.3149	1.1587	0.9549	0.7376	<b>0.3141</b>
400	$E_R$	0.1542	0.1428	0.0702	0.0490	<b>0.0131</b>
	$E_I$	2.5044	1.6032	1.5121	1.4671	<b>0.6505</b>

表 8 Chicken 数据集不同方法鲁棒性比较

Chicken	Error	MAICP	LRS	JRMPC	K-means	Proposed method
100	$E_R$	0.0566	0.1217	0.0693	0.0304	<b>0.0286</b>
	$E_I$	2.3039	1.6762	1.3274	1.2214	<b>0.8881</b>
200	$E_R$	0.0735	0.1970	0.0723	0.0342	<b>0.0320</b>
	$E_I$	2.5464	1.9279	1.7106	1.3195	<b>1.0615</b>
400	$E_R$	0.0975	0.1832	0.0825	0.0418	<b>0.0382</b>
	$E_I$	2.9942	2.3206	2.2112	1.7151	<b>1.3654</b>

所提方法采用测地距离作为聚类划分的相似性度量,由于噪声点在流形上实际距离很远,因而能够在聚类过程中减小噪声点对聚类划分的影响,从而减小对最终配准结果的影响。

## 4 结 论

针对形状结构较为复杂的非球状物体配准精度较低问题,提出一种基于流形聚类的多站点云配准方法。该方法通过引入测地距离作为聚类划分的相似性度量对形状结构较为复杂的非球类物体在配准精度上整体提升了 20%~30%。同时对于存在噪声点的数据,由于噪声点在流形上的实际距离很远,该方法对噪声点具有较好的鲁棒性。但是此类从粗配准到精配准的配准方法很大程度上依赖于粗配准的效果,当粗配准的效果很差时,精配准的结果也会受到影响。

针对测地距离矩阵计算效率较低问题,通过引入热梯度法,使测地距离矩阵的计算效率提升了 40%~50%。但是计算测地距离矩阵仍然需要较长的时间,因而该方法在时间效率方面比起 K-means 等快速算法还有待进一步提升。

接下来需要进一步提升初始刚性变换矩阵的精度以及获取效率,即采取效率更高的粗配准方法来获得更加准确的初值,减少在配准过程中陷入局部最优的情况,影响最终的配准结果。同时对于精配准过程中测地距离矩阵的计算过程还需要进一步优化,当测地距离矩阵的计算能够在数十秒内完成时,整体配准效率也会随之提升。

## 参 考 文 献

- [1] Dou J, Niu D M, Feng Z Q, et al. Robust non-rigid point set registration method based on asymmetric Gaussian and structural feature[J]. IET Computer Vision, 2018, 12(6): 806-816.
- [2] Li L, Yang M, Wang C X, et al. Robust point set registration using signature quadratic form distance[J]. IEEE Transactions on Cybernetics, 2020, 50(5): 2097-2109.
- [3] Dai A, Nießner M, Zollhöfer M, et al. BundleFusion: real-time globally consistent 3D reconstruction using on-the-fly surface reintegration[J]. ACM Transactions on Graphics, 2017, 36(4): 76a.
- [4] Maron H, Dym N, Kezurer I, et al. Point registration via efficient convex relaxation[J]. ACM Transactions on Graphics, 2016, 35(4): 73.
- [5] 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, May 30-June 5, 2021, Xi'an, China. New York: IEEE Press, 2021: 11054-11059.
- [6] Liu J, Singh G, Al'Aref S, et al. Review of image registration in medical robotics and intelligent systems: fundamentals and applications[J]. Advanced Intelligent Systems, 2019, 1(6): 1900048.
- [7] Yoo H, Choi A, Mun J H. Acquisition of point cloud in CT image space to improve accuracy of surface registration: application to neurosurgical navigation system[J]. Journal of Mechanical Science and Technology, 2020, 34(6): 2667-2677.
- [8] 刘如飞, 王飞, 任红伟, 等. 一种利用地理实体目标特征的道路场景激光点云配准方法[J]. 中国激光, 2022, 49(18): 1810002.  
Liu R F, Wang F, Ren H W, et al. A road scene laser point cloud registration method based on geographical object features[J]. Chinese Journal of Lasers, 2022, 49(18): 1810002.
- [9] 李奇明, 任杰骥, 裴晓寒, 等. 基于多模态数据协同的弱纹理表面高精度点云配准算法[J]. 光学学报, 2022, 42(8): 0810001.  
Li Q M, Ren J J, Pei X H, et al. High-accuracy point

- cloud matching algorithm for weak-texture surface based on multi-modal data cooperation[J]. *Acta Optica Sinica*, 2022, 42(8): 0810001.
- [10] 任苏霞, 张晨爽, 曹慧群, 等. 基于双螺旋点扩展函数工程的三维多焦点双光子激光扫描显微技术[J]. *光学学报*, 2022, 42(14): 1411001.  
Ren S X, Zhang C S, Cao H Q, et al. Three-dimensional multifocal two-photon laser scanning microscopy based on double-helix point spread function engineering[J]. *Acta Optica Sinica*, 2022, 42(14): 1411001.
- [11] 李天雄, 侯茂盛, 李丽娟, 等. 基于特征自适应的激光扫描投影图形控制点提取及优化方法[J]. *光学学报*, 2021, 41(24): 2411004.  
Li T X, Hou M S, Li L J, et al. Control point extraction and optimization method of laser scanning projection graphics based on feature adaptation[J]. *Acta Optica Sinica*, 2021, 41(24): 2411004.
- [12] Besl P J, McKay N D. Method for registration of 3-D shapes[J]. *Proceedings of SPIE*, 1992, 1611: 586-606. [LinkOut]
- [13] 李绕波, 袁希平, 甘淑, 等. 一种基于对偶四元素描述的线面特征约束的点云配准方法[J]. *光学学报*, 2022, 42(2): 0214003.  
Li R B, Yuan X P, Gan S, et al. Point cloud registration method based on dual quaternion description of line-planar feature constraints[J]. *Acta Optica Sinica*, 2022, 42(2): 0214003.
- [14] Masuda T, Yokoya N. A robust method for registration and segmentation of multiple range images[J]. *Computer Vision and Image Understanding*, 1995, 61(3): 295-307.
- [15] 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.
- [16] Akca D, Gruen A. Fast correspondence search for 3D surface matching[J]. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2006, XXXVI(3/W19): 186-191.
- [17] Phillips J M, Liu R, Tomasi C. Outlier robust ICP for minimizing fractional RMSD[C]//Sixth International Conference on 3-D Digital Imaging and Modeling (3DIM 2007), Montreal, QC, Canada. New York: IEEE Press, 2007: 427-434. [LinkOut]
- [18] Sandhu R, Dambreville S, Tannenbaum A. Point set registration via particle filtering and stochastic dynamics[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(8): 1459-1473.
- [19] Govindu V M, Pooja A. On averaging multiview relations for 3D scan registration[J]. *IEEE Transactions on Image Processing*, 2014, 23(3): 1289-1302.
- [20] Zhu J H, Wang D, Bai X X, et al. Registration of point clouds based on the ratio of bidirectional distances[C]//2016 Fourth International Conference on 3D Vision (3DV), October 25-28, 2016, Stanford, CA, USA. New York: IEEE Press, 2016: 102-107.
- [21] 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.
- [22] Li J Y, Hu Q W, Zhang Y J, et al. Robust symmetric iterative closest point[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2022, 185: 219-231.
- [23] 谭舸, 花向红, 陶武勇, 等. 基于激光跟踪仪的多测站地面激光扫描点云配准方法[J]. *中国激光*, 2021, 48(17): 1710002.  
Tan G, Hua X H, Tao W Y, et al. Multiview terrestrial laser scanning point cloud registration method based on laser tracker[J]. *Chinese Journal of Lasers*, 2021, 48(17): 1710002.
- [24] Jian B, Vemuri B C. Robust point set registration using gaussian mixture models[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(8): 1633-1645.
- [25] Evangelidis G D, Horaud R. Joint alignment of multiple point sets with batch and incremental expectation-maximization[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(6): 1397-1410.
- [26] Zhu J H, Jiang Z T, Evangelidis G D, et al. Efficient registration of multi-view point sets by K-means clustering[J]. *Information Sciences*, 2019, 488: 205-218.
- [27] Schwarz G. Hodge decomposition: a method for solving boundary value problems[M]. Heidelberg: Springer, 1995.
- [28] Arrigoni F, Rossi B, Fusiello A. Global registration of 3D point sets via LRS decomposition[M]//Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016*. Lecture notes in computer science. Cham: Springer, 2016, 9908: 489-504.