

6-20-2023

Point Cloud Surface Matching Method Based on Precise Matching of Critical Point

Xiaojuan Ning

School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China; Shaanxi Provincial Key Laboratory of Network Computing and Security Technology, Xi'an 710048, China,
ningxiaojuan@xaut.edu.cn

Chunxu Li

School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China,
876167524@qq.com

Jiahao Wang

School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China

Jing Tang

School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Point Cloud Surface Matching Method Based on Precise Matching of Critical Point

Abstract

To solve the low matching efficiency and insufficient accuracy of feature-based point cloud surface matching method during critical point matching, a point cloud surface matching method based on the pairing extraction of critical points is proposed. *An improved 3D scale-invariant feature transform(3D-SIFT) algorithm based on curvature information is presented to extract the critical points. Fast point feature histograms(FPFH) feature, the angle between the vector from the center to critical points and the principal direction of the model are taken as the constraints to obtain the exact critical point matching point pair set. The initial matching of the model surface is implemented by the rigid body transformation parameters, and further the accurate matching of the model surface is achieved by iterative closest point(ICP).* Experiments show that the approach can not only improve the critical point matching accuracy, but also enhance the matching efficiency. Compared with other methods, the method is slightly better on the matching speed.

Keywords

scale-invariant feature transformation, fast point feature histogram, principal direction, rigid body transformation parameters, iterative closest point

Authors

Xiaojuan Ning, Chunxu Li, Jiahao Wang, Jing Tang, Yinghui Wang, and Haiyan Jin

Recommended Citation

Xiaojuan Ning, Chunxu Li, Jiahao Wang, Jing Tang, Yinghui Wang, Haiyan Jin. Point Cloud Surface Matching Method Based on Precise Matching of Critical Point[J]. Journal of System Simulation, 2023, 35(6): 1169-1182.

基于关键点精确配对的点云曲面匹配方法

宁小娟^{1,2}, 李春旭^{1*}, 王嘉豪¹, 唐婧¹, 王映辉³, 金海燕^{1,2}

(1. 西安理工大学 计算机科学与工程学院, 陕西 西安 710048; 2. 陕西省网络计算与安全技术重点实验室, 陕西 西安 710048;
3. 江南大学 人工智能与计算机学院, 江苏 无锡 214122)

摘要: 针对基于特征的点云曲面匹配方法在关键点匹配时匹配效率低和精度不够的问题, 提出了一种基于关键点精确配对的点云曲面匹配方法。通过采用基于曲率信息的改进 3D-SIFT(3D scale-invariant feature transform) 算法, 提取点云数据的关键点; 将关键点处的 FPFH(fast point feature histograms) 特征描述以及模型中心点到关键点的向量与模型主趋势的夹角作为约束条件, 获取精确的关键点匹配点对集合; 求解刚体变换参数实现模型曲面的初始匹配; 使用 ICP(iterative closest point) 算法进行二次优化, 实现模型曲面的精确匹配。实验表明: 该方法既能解决关键点匹配精度问题, 又能很好地解决匹配效率的问题。

关键词: 尺度不变特征变换; 快速点特征直方图; 主趋势; 刚体变换参数; 迭代最近点

中图分类号: TP391 文献标志码: A 文章编号: 1004-731X(2023)06-1169-14

DOI: 10.16182/j.issn1004731x.joss.22-0146

引用格式: 宁小娟, 李春旭, 王嘉豪, 等. 基于关键点精确配对的点云曲面匹配方法[J]. 系统仿真学报, 2023, 35(6): 1169-1182.

Reference format: Ning Xiaojuan, Li Chunxu, Wang Jiahao, et al. Point Cloud Surface Matching Method Based on Precise Matching of Critical Point[J]. Journal of System Simulation, 2023, 35(6): 1169-1182.

Point Cloud Surface Matching Method Based on Precise Matching of Critical Point

Ning Xiaojuan^{1,2}, Li Chunxu^{1*}, Wang Jiahao¹, Tang Jing¹, Wang Yinghui³, Jin Haiyan^{1,2}

(1. School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China; 2. Shaanxi Provincial Key Laboratory of Network Computing and Security Technology, Xi'an 710048, China; 3. School of Artificial Intelligence and Computer, Jiangnan University, Wuxi 214122, China)

Abstract: To solve the low matching efficiency and insufficient accuracy of feature-based point cloud surface matching method during critical point matching, a point cloud surface matching method based on the pairing exaction of critical points is proposed. An improved 3D scale-invariant feature transform(3D-SIFT) algorithm based on curvature information is presented to extract the critical points. Fast point feature histograms(FPFH) feature, the angle between the vector from the center to critical points and the principal direction of the model are taken as the constraints to obtain the exact critical point matching point pair set. The initial matching of the model surface is implemented by the rigid body transformation parameters, and further the accurate matching of the model surface is achieved by iterative closest point (ICP). Experiments show that the approach can not only improve the critical point matching accuracy, but also enhance the matching efficiency. Compared with other methods, the method is slightly better on the matching speed.

Keywords: scale-invariant feature transformation; fast point feature histogram; principal direction; rigid body transformation parameters; iterative closest point

收稿日期: 2022-02-08 修回日期: 2022-04-13

基金项目: 国家自然科学基金(61871320, 61872291); 西安市碑林区科技计划(GX2107)

第一作者: 宁小娟(1982-), 女, 教授, 博士, 研究方向为模式识别与图像处理。Email: ningxiaojuan@xaut.edu.cn

通讯作者: 李春旭(1997-), 女, 硕士生, 研究方向为点云建筑物开口检测。Email: 876167524@qq.com

0 引言

三维空间的曲面匹配是逆向工程^[1]和计算机视觉智能的核心技术,也是场景三维重建^[2]、文物保护^[3]和医学图像配准^[4]等应用领域的基础工作。然而由于点云的散乱性、稀疏性和多噪声等都会对最终匹配结果产生影响,并且目前主流匹配算法的匹配精度和普适性仍有不足。因此,本文以离散点云数据作为研究对象,探索一种基于关键点精确配对的点云曲面匹配方法。

目前,三维点云匹配技术按照不同的搜索空间分为局部匹配和全局匹配^[5-6];根据不同的匹配精度分为初始匹配和精确匹配^[7]。本文将通过初始匹配与精确匹配相结合的方式对三维曲面匹配方法进行研究。

在初始匹配算法中,Rusu等^[8]提出了快速点特征直方图(fast point feature histograms, FPFH)算法,在一定程度上降低了复杂性和噪声对匹配的影响,但匹配的整体效率低。4PCS(4 point congruent sets)算法作为另一种经典的点云初始匹配方法^[9],不需要提供初始位姿,但当两片点云重叠率较低时,算法耗时长且配准容易失败。因此,许多学者对其进行了一系列改进。刘世光等^[10]提出了一种快速四点一致性点云粗配准算法,通过在边界特征带中选取具有一致性的四点基集合和限制四点基特征来去除无效的四点基,从而提高算法的运行效率,但是针对大规模点云数据集,运行时间仍然过长。此外,研究者们还提出了许多基于关键点提取的初始匹配算法。彭真等^[11]将体素格滤波和法向距离相结合进行关键点提取,然后通过计算关键点的FPFH特征,采用对应关系优化随机采样一致性算法进行初始匹配来提高匹配精度。孙培芪等^[12]提出了一种基于特征点提取与配对的初始匹配算法,不仅提高了匹配精度,还缩短了匹配时间,但是初始匹配时使用尺度不变特征变换(scale-invariant feature transform, SIFT)算法提取特征点的时间性能仍需优化。SIFT算法

由Lowe于1999年提出^[13],2004年完善^[14],被广泛应用于物体识别、图像匹配、三维模型重建等。3D-SIFT算法则是通过对2D-SIFT特征进行扩充后应用于3D空间。该算法对旋转、尺度变化、亮度变化保持了不变性,不仅可以检测出大量的特征点,还能更加准确地描述物体的局部空间关系。但是该算法计算需要强度值或RGB值,所以对于一般的点云数据并不适用。上述算法虽然在匹配精度上有所提高,但是针对特征不明显的点云,仍然存在错误的匹配点对,并且对于大数据量的点云,存在耗时问题。

在精确匹配算法中,由Besl等^[15]提出的迭代最近点(iterative closest point, ICP)算法最为流行。但是该算法对点云的初始位姿依赖性较高,若源点云与目标点云初始位置相差较大,极易陷入局部最优,且计算效率低,在配准中也没有涉及到尺度变化问题。因此,许多学者在此基础上进行了一系列研究。孙水发等^[16]提出一种多尺度点云配准算法,解决了匹配中的多尺度问题,提高了匹配精度。石珣等^[17]将点云曲率特征与连贯点漂移结合提出一种快速配准点云的方法,能够快速处理远距离对应点配准,但在细节上匹配精度稍差,存在旋转角度有所限制的问题。王飞鹏等^[18]通过设置高斯曲率阈值过滤出非关键点和噪点,然后只对关键点进行ICP匹配,提高了运行效率。Yao等^[19]利用曲率特征的相似性对经典ICP算法进行了改进,减少了噪声点对匹配结果的影响,但计算量大,存在耗时问题。上述方法都存在易受两点云初始相对位置影响的问题。

为此,本文设计了一种基于改进的3D-SIFT算法提取关键点,并基于FPFH和模型主趋势约束进行关键点匹配,通过利用关键点对匹配的点集合实现尺度匹配,最终通过精确的关键点匹配点对集合求取模型曲面之间的初始位姿,再结合ICP算法实现基于迭代的曲面精确匹配。本文方法可以提高关键点匹配的正确率和效率,并且对两点云初始相对位置没有要求。

1 曲面匹配

本文的曲面匹配流程如图1所示, 主要包括关键点提取、关键点对应关系估计、初始匹配, 以及精确匹配4个部分。具体描述如下:

(1) 关键点提取。采用曲率特征替代3D-SIFT算法中所需的三维点云强度值或RGB值, 并通过改进后的3D-SIFT算法对仅包含顶点坐标信息的点云数据进行关键点提取。

(2) 关键点对应关系估计。首先通过主成分分析法(principal components analysis, PCA)求取空间点集主趋势, 然后利用模型中心点到关键点的向

量与模型主趋势的夹角作为约束条件进行关键点匹配, 最后将FPFH特征描述作为新的约束条件对关键点之间的对应关系进行进一步的筛选, 得到精确的关键点匹配结果。

(3) 初始匹配。根据关键点匹配点对集合计算2个点云模型之间的等比例尺度缩放因子, 对2个点云模型进行尺度匹配, 然后通过奇异值分解法计算2个点云模型的刚体变换参数, 实现2个点云模型之间的初始匹配。

(4) 精确匹配。在初始匹配的基础上, 利用ICP算法实现2个点云模型之间的精确匹配。

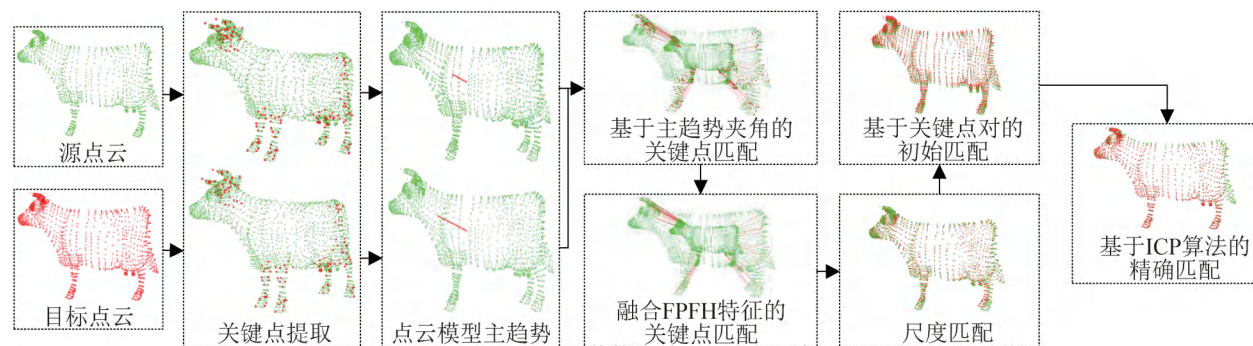


图1 点云曲面匹配过程
Fig. 1 Process of point cloud surface matching

1.1 点云曲面关键点提取

通常情况下, 获得的原始点云数据都不含强度值或RGB值, 并且在点云匹配、无人驾驶、目标检测等领域大都采用无强度值或RGB值的点云数据。因此, 本文针对点云数据不包含3D-SIFT算法中所需的强度值或RGB值, 设计了一种基于曲率的3D-SIFT关键点提取算法。该算法主要通过曲率特征对算法的适用性进行改进, 使其能够适用本文所处理的点云数据。

为了在三维点云数据上实现SIFT算法, 首先对点云数据进行降采样得到一系列点集规模大小不同的点云数据, 即子八度。然后在每个子八度上定义三维点云的尺度空间函数 $L(x, y, z, \sigma)$ 为一个变化尺度的高斯函数 $G(x, y, z, \sigma)$ 与 $I(x, y, z)$ 的

卷积^[20]。其中, $I(x, y, z)$ 一般采用三维点云数据的强度值或RGB值。最后通过式(2)对离散点云数据构造不同的三维尺度空间。

$$L(x, y, z, \sigma) = G(x, y, z, \sigma) \cdot I(x, y, z) \quad (1)$$

高斯函数 $G(x, y, z, \sigma)$ 的定义为

$$G(x, y, z, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2+z^2)}{2\sigma^2}} \quad (2)$$

为了提高算法的鲁棒性, 定义高斯差分函数 $D(x, y, z, \sigma)$ 以搜索空间离散点集的局部极值点。

$$D(x, y, z, \sigma) = (G(x, y, z, k\sigma) - G(x, y, z, \sigma)) \times I(x, y, z) \quad (3)$$

$$k = \sigma \times 2^{(i-1)/s}$$

式中: k 为相邻尺度空间倍数的常量; s 为子八度内的层数; i 为每一层的索引。

为了得到模型的关键点, 本文先将求取的点

集模型每个顶点的局部曲率作为一个顶点的曲率特征来替换代表点云数据强度值或RGB值的 $I(x,y,z)$ ，然后检测尺度空间函数中的局部极值，从而获得基于曲率信息下的局部极值点，即关键点。其中，通过平面拟合的方法求解点云数据中每个样本点处的曲率信息。

以曲率特征改进3D-SIFT算法进行关键点提取，结果如图2所示。由图2蓝色框可以看出，3

种模型在头部区域的关键点是一致的，而红色框和黑色框内的关键点即鸟模型翅膀区域和尾部区域的关键点在数量和位置上都有一定的误差。对比图2(b)和(c)可以观察到，关键点的数量虽然明显减少，但是分布情况并没有大的变化，关键点之间的位置误差都不大。由此可见，采用曲率特征对3D-SIFT算法的适用性进行改进是可行的，可以为之后的关键点匹配工作的精确度提供保证。




图2 鸟模型3D-SIFT关键点提取
Fig. 2 3D-SIFT critical point extraction of bird model

1.2 点云曲面关键点对应关系估计

基于特征的三维曲面匹配方法主要通过采用随机采样的方式对点集进行粗匹配，再利用迭代的方法得出其最优解，但是，通过随机采样的方式计算两点云之间的刚体变化参数会导致每次的计算结果随机性很大，使该方法的稳定性不高，容易陷入局部最优解。为了解决该问题须提高迭代次数，通过大量的迭代计算来消除随机性带来的影响，但是，随着点云规模的增大，选择通过提高迭代次数来提高算法精确度和稳定性具有很大弊端，而且对于不仅有刚体变换还有尺度变化的点云模型，会因为没有得到精确的关键点对应关系，而无法确定源点云和目标点云之间的等比例尺度缩放因子，所以，本文给出了一种比较精确的关键点匹配方法。

1.2.1 计算点云模型主趋势

在刚体变换下，任意点云模型的走向趋势相对模型本身是不变的，即点云模型的主趋势对于

模型在三维空间下的刚体变换和等比例尺度缩放具有一定的不变性。因此，本文将使用Chung等^[21]提到的基于PCA的方法来计算待测点集的主趋势。

首先，通过式(4)对点集 $P=\{p_1, p_2, \dots, p_n\}$ ， $p_i=(x_i, y_i, z_i)^T$ ， $i=1, 2, \dots, n$ ，计算其中心点 p_m ，然后通过式(5)计算其三阶协方差矩阵 C 。

$$p_m = \frac{1}{n} \sum_{i=1}^n p_i \quad (4)$$

$$C = E\{(p_i - p_m)(p_i - p_m)^T\} = \frac{1}{n} \sum_{i=1}^n (p_i - p_m)(p_i - p_m)^T \quad (5)$$

根据协方差矩阵 C 可以计算得出3个特征值 λ_1 、 λ_2 和 λ_3 。然后将这3个特征值分别按降序排列 $\lambda_1 > \lambda_2 > \lambda_3$ ，3个特征值对应的特征向量分别为 v_1 、 v_2 和 v_3 。由PCA算法原理可知，最大的特征值 λ_1 所对应的特征向量 v_1 代表了点云模型数据的最大方差方向，该方向就是本文所要求取的点云模型的主趋势。

如图 3 所示, 针对鸟模型在不同情况下分别使用 PCA 算法进行主趋势计算, 所得到的主趋势基本一致, 即基于 PCA 算法计算主趋势, 对于模型的空间变换和尺度变化均保持着较好的不变性和稳定性。




图 3 鸟模型主趋势
Fig. 3 Principal direction of bird model

1.2.2 基于主趋势夹角的关键点匹配

首先根据 1.2.1 节计算出源点云和目标点云的主趋势向量 U_{src} 和 U_{tgt} , 然后通过点云模型的主趋势估计出关键点间的对应关系。如图 4 所示, 蓝色点为基于 3D-SIFT 算法提取的关键点集合, 红色点为点集的中心点, 根据点集的中心点到关键点作向量, 计算此向量和点集的主趋势向量的夹角, 并以此夹角作为约束条件对目标点云中的 3D-SIFT 关键点进行筛选和匹配, 具体步骤如下。

对于给定的源点云 $P = \{p_1, p_2, \dots, p_n\}$, $p_i = (x_i, y_i, z_i)$, $i = 1, 2, \dots, n$ 和目标点云 $Q = \{q_1, q_2, \dots, q_n\}$, $q_i = (x_i, y_i, z_i)$, $i = 1, 2, \dots, n$, 分别通过式(4)和式(6)计算其中心点的坐标:

$$q_m = \frac{1}{n} \sum_{i=1}^n q_i \quad (6)$$

使用 1.1 节中所提到的改进后的 3D-SIFT 算法分别提取源点云和目标点云的 3D-SIFT 关键点集合 $S^p = \{s_1, s_2, \dots, s_n\}$ 和 $S^q = \{s_1, s_2, \dots, s_n\}$, 并根据式(7)分别计算每个 3D-SIFT 关键点到点集中心的向量 V_i^{src} 和 V_i^{tgt} :

$$V_i = (s_x^i, s_y^i, s_z^i) - (p_x, p_y, p_z), \quad i = 1, 2, \dots, k \quad (7)$$

根据式(8)分别求出源点云和目标点云上所有 3D-SIFT 关键点到点集中心的向量和点集主趋势向量夹角 $\cos^p \theta$, $i = 1, 2, \dots, k$ 和 $\cos^q \theta$, $i = 1, 2, \dots, m$, 再由式(9)根据夹角计算出源点云关键点和目标点

云关键点的夹角误差:

$$\cos \theta = \frac{(V_x, V_y, V_z) (U_x, U_y, U_z)}{\sqrt{V_x^2 + V_y^2 + V_z^2} \sqrt{U_x^2 + U_y^2 + U_z^2}} \quad (8)$$

$$\omega = (\arccos^p \theta - \arccos^q \theta) < \varepsilon \quad (9)$$

式中: ε 为根据模型各自特点所设定的阈值。




图 4 关键点与模型主趋势夹角计算
Fig. 4 Calculation of induced angle between critical point and principal direction of model

计算源点云上关键点 p 在目标点云上的对应点的示意图, 如图 5 所示。蓝色点表示从源点云和目标点云分别提取的 3D-SIFT 关键点, 黄色点表示源点云和目标点云的中心点。具体计算步骤: 计算源点云中心点到关键点 p 的向量与源点云主趋势向量的夹角 α ; 在目标点云上分别计算每一个目标点云中心点到关键点的向量与目标点云主趋势向量的夹角; 将设定好的 ε 值作为两点云夹角误差的约束条件, 在目标点云的关键点集合中进行筛选得到源点云上关键点 p 在目标点云上的对应关键点 q 和 s 。通过计算发现由 s 点计算得出的夹角 β 与源点云 p 计算得到的夹角 α 误差最小, 因此, 源点云关键点 p 在目标点云上匹配的关键点为 s , 在图中用红色虚线相连。

如图 6 所示, 通过上述算法对不同变换下的鸟模型进行关键点匹配, 虽然关键点匹配结果基本正确, 但是计算得到的关键点之间的对应关系比较多, 存在特征差异较大的错误匹配点, 所以仍需要进一步排除错误点对。





图5 基于夹角约束条件的对应关系估计

Fig. 5 Correspondence estimation based on included angle constraints

图6 鸟模型的关键点匹配
Fig. 6 Critical point matching of bird mode

1.2.3 融合FPFH特征的关键点匹配

由于仅将主趋势夹角作为约束条件进行关键点匹配存在误差，故仍需对本文所给出的关键点匹配算法进行优化。FPFH特征描述子对点集局部曲面的特征描述比较精确，尤其针对特征明显的点云模型的匹配效果最好，因此，本文选择FPFH特征算法对所给出的关键点匹配算法进行优化。优化后的算法步骤如下：

step 1: 根据FPFH特征算法分别计算源点云和目标点云上的关键点处的FPFH特征描述子；

step 2: 通过目标点云上的关键点处的特征描述子构造KD-Tree搜索空间；


step 3: 根据源点云上的每一个关键点处的FPFH特征描述子，分别在所构造的KD-Tree上搜索其 k 个近邻点；

step 4: 通过本文所给出的基于模型主趋势夹角约束的关键点匹配方法，计算源点云上每一个关键点在其 k 个近邻点中的匹配点。

由上述算法可知，对于2个分别含有 n 个关键

点的点云模型进行关键点匹配时，优化前的算法时间复杂度近似是 $o(n^2)$ ，而优化后的算法时间复杂度近似是 $o(n \cdot k)$ ，其中 k 为关键点查找的近邻点的数目。优化后的算法根据关键点处的FPFH特征进行第1次的匹配点筛选，然后基于筛选后的点再使用向量夹角作为约束条件进行2次筛选，将通过2次筛选得出的最优解作为所计算的待匹配关键点在目标点云上对应的关键点，使得关键点匹配的精确度有了一定的提升。

如图7所示，通过改进后的算法所得到的关键点对应关系相较于图6明显减少，关键点匹配结果更加精确，具有更好的有效性和精确性。

图7 改进后的鸟模型关键点匹配结果
Fig. 7 Improved critical point matching result

1.3 基于关键点对的初始匹配

点云匹配过程中最重要的一步是求解从源点云到目标点云的刚体变换，而求得刚体变换参数的前提是根据关键点匹配点集先完成源点云模型到目标点云模型上的尺度匹配，再在相同的尺度空间下，求取刚体变换参数实现初始匹配。

1.3.1 尺度匹配

基于本文所给出的关键点匹配算法，可以在源点云和目标点云之间得到较为精确的关键点对应关系；根据这种对应关系分别计算出关键点到各自点集中心的距离，并将其作为尺度标准；通过相对应的关键点到各自点集中心的距离比值求出等比例尺度缩放因子 σ ，从而对源点云所有的点进行尺度变换，使得源点云的尺度大小能够尽可能与目标点云的尺度大小相一致。

基于3D-SIFT关键点提取算法得到待匹配点

云关键点集合 $S=\{s_1, s_2, \dots, s_k\}$, $k=1, 2, \dots, r$ 和对应的目标点云关键点集合 $T=\{t_1, t_2, \dots, t_k\}$, $k=1, 2, \dots, r$ 。

根据本文所给出的关键点匹配算法对 S 和 T 两集合中的关键点进行匹配得到匹配的点对集合 $\Omega=\{(s_1, t_1), (s_2, t_2), \dots, (s_n, t_n)\}$, 其中 s_k, t_k 表示所求出的对应点对集合中的某一个对应点对。

基于对应的匹配关系根据式(10)和(11)分别计算出关键点在各自尺度空间下到点集中心的距离:

$$d_s^k = \sqrt{(s_x^k - p_x)^2 + (s_y^k - p_y)^2 + (s_z^k - p_z)^2} \quad (10)$$

$$d_t^k = \sqrt{(t_x^k - q_x)^2 + (t_y^k - q_y)^2 + (t_z^k - q_z)^2} \quad (11)$$

式中: p_x, p_y, p_z 和 q_x, q_y, q_z 分别为待匹配点云和目标点云的中心点。

根据式(12)所计算出的等比例尺度缩放因子 σ 对源点云中所有的点进行尺度变化, 使源点云的尺度大小通过使用等比例尺度缩放因子能够尽可能与目标点云的尺度大小相一致。

$$\sigma = \frac{1}{n} \sum_{k=1}^n \left| \frac{d_s^k}{d_t^k} \right| \quad (12)$$

如图 8 所示, 对于尺度缩小后的模型采用本文方法进行尺度匹配可以得出, 基于本文的尺度匹配方法无论是对简单的、没有复杂曲面的鸟模型, 点集密度较为稀疏的牛模型, 还是点集密度较大、模型曲面复杂的龙模型进行匹配, 得到的匹配结果都效果较好、匹配误差小。因此, 本文提出的关键点匹配算法和尺度匹配方法可以适用于各种模型, 并且保持着不错的稳定性和精确性。



图 8 不同模型的尺度匹配

Fig. 8 Scale matching of different models

1.3.2 基于奇异值分解的刚体变换

在 1.3.1 节尺度匹配的基础上, 利用奇异值分解(singular value decomposition, SVD)^[22]的方法求解

源点云模型到目标点云模型之间的刚体变换参数。

给定 2 个点集 $P=\{p_i\}$, $i=1, 2, \dots, n$ 和 $Q=\{q_i\}$, $i=1, 2, \dots, n$, 然后找到能使这 2 个点集对齐的最优旋转矩阵 R 和平移矢量 t 。

$$(R, t) = \arg \min \sum_{i=1}^n w_i \| (Rp_i + t) - q_i \|^2 \quad (13)$$

式中: $w_i > 0$ 是点集中每个匹配点对的权重值。本文最终所求得的最优解就是取式(13)中的最小值, 即对式中的 R 和 t 求导数为 0 的解。由此便可得到源点云到目标点云的刚体变换参数, 从而得到初始匹配结果。由图 9(a)可以看出经过旋转平移后的鸟模型与原始的鸟模型之间的匹配效果良好; 而图 9(b)中的匹配结果仍有略微的偏移, 但是已经基本完成 2 个点云模型的匹配工作。




图 9 不同角度下的鸟模型的初始匹配

Fig. 9 Initial matching of bird model from different perspectives

1.4 基于 ICP 算法的精确匹配

使用基于关键点精确配对的匹配方法进行初始匹配, 匹配的结果仍有略微的偏移。因此, 为了获得更精确的匹配结果, 将在此基础上使用 ICP 算法进行精确匹配。具体步骤如下。

step 1: 构造匹配点对, 使用 KD-Tree 方法对源点云中的所有点搜索其在目标点云上的最近点, 并构造匹配点对;

step 2: 去除噪声值, 使用随机抽样一致算法(random sample consensus, RANSAC)去除构造的匹配点对集合中的异常值;

step 3: 根据构造的点对集合, 使用 SVD 计算最优旋转矩阵 R 和平移矢量 t ;

step 4: 由上一步得出的旋转平移变换矩阵对源点云进行旋转平移计算, 得到源点云刚体变换

后的新点集；

step 5: 重复计算 step1~4, 直到2次迭代间求解的旋转平移结果收敛或者已达到最大迭代次数。

由于ICP算法在很大程度上都依赖于点云之间的初始距离, 很容易导致匹配结果局部收敛以及匹配结果误差较大。而基于关键点精确匹配的匹配方法对两点云的初始位置没有要求, 所以本文选择先通过基于关键点精确匹配的匹配方法进行初始匹配, 然后再通过ICP精确匹配方法进行二次匹配, 从而达到更好的匹配效果。

2 实验结果与分析

为了验证所提算法的可行性和适用性, 本文算法是在 Intel(R) Core(TM) i7-7700 CPU @ 3.60 GHz 3.60 GHz 8 G RAM 计算机, 开源点云库为 PCL1.6.0, Visual Studio 2010 环境下的 C++ 语言实现。本文的实验数据采用的是斯坦福大学 3D 点云数据库中的鸟、牛、龙、兔、茶壶、大象和海马模型; 普林斯顿大学的 ModelNet 数据集^[23] 中的帽子和椅子模型以及通过 Kinect 采集的实测室内场

景点云数据。其中, 旋转平移是对原始模型绕 z 轴旋转 18° 并沿 x 轴平移 1 单位(1 m), 尺度缩小是对原始模型的顶点坐标整体缩小 2 倍。

2.1 关键点提取实验

Harris 角点检测算法是常见的关键点提取算法, 适用于提取角点或边缘点, 主要应用于模型表面变化比较明显的区域。该算法对旋转保持了不变性, 提取结果稳定可靠, 仅利用点云的几何特征便可进行关键点提取, 适用范围广。因此, 本文选择将基于曲率的 3D-SIFT 算法与 Harris 算法进行对比, 来验证本文算法的可行性和普适性。如图 10 所示, (a)、(b)和(c)中左侧是改进后的 3D-SIFT 算法, 右侧是 Harris 算法。改进后的 3D-SIFT 算法在模型不同变换下所提取的关键点均保持着很好的不变性和稳定性, 而 Harris 算法所提取的关键点数目少且误差很大。通过表 1 所记录的各项模型关键点提取时间可以看出, 基于曲率的 3D-SIFT 算法的计算效率较高。因此, 当处理仅包含顶点坐标信息的点云数据时, 基于曲率的 3D-SIFT 算法对于不同模型在不同刚体变换下都保持了一定的不变性和稳定性。

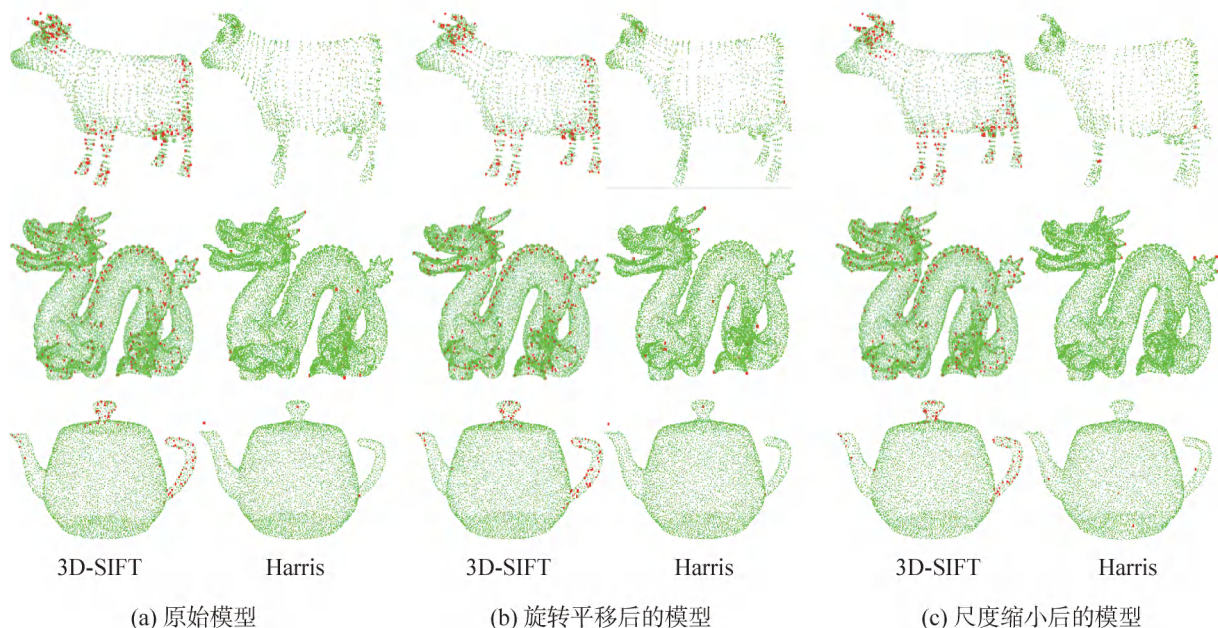


图 10 不同模型关键点提取对比结果

Fig. 10 Comparative results of critical point extraction for different models

<http://www.china-simulation.com>

• 1176 •

表 1 各模型关键点提取时间
Table 1 Critical point extraction time for different models

模型	算法	牛	龙	茶壶
原始	3D-SIFT	4.350	3.540	3.381
	Harris	12.186	11.564	23.836
旋转平移	3D-SIFT	13.419	10.391	13.013
	Harris	15.416	15.970	20.287
尺度缩小	3D-SIFT	8.973	9.185	7.122
	Harris	13.111	12.044	48.784

2.2 关键点匹配实验

为了验证本文基于 FPFH 和模型主趋势约束进行关键点匹配算法的可行性, 利用不同密度、曲面复杂度的模型分别在不同的刚体变换程度下进行实验。

图 11 是基于改进前后算法的关键点匹配结果。分析图中 2 种方法得到的结果, 改进前的算法虽然对于点云密度均匀、模型曲面简单的鸟模型和密度

不均匀的牛模型的关键点匹配结果基本正确, 但是对于点集规模大、密度均匀且曲面模型复杂的龙模型的关键点匹配结果较差, 且基于点集中心到关键点的向量与模型主趋势向量的夹角容易出现相似的情况, 从而对匹配结果产生影响。而改进后的算法通过加入 FPFH 特征描述先对目标点云上的关键点进行筛选, 剔除了特征差异较大的错误匹配点, 计算得到的关键点之间的对应关系明显减少。如表 2 所示, 对改进前后算法的匹配正确率进行比较, 改进后的算法对于不同类型的匹配正确率均有所提升, 尤其对于曲面复杂的龙模型的提升最明显。虽然仍存在错误的键点对应关系, 但是通过对算法的改进可以减少错误匹配点对的数量, 提高匹配精度, 并且针对曲面复杂模型的关键点匹配效果更好。其中, 实验中计算 FPFH 特征描述所选取的近邻点 k 为 30; 源点云关键点和目标点云关键点夹角误差 ϵ 为 0.02。

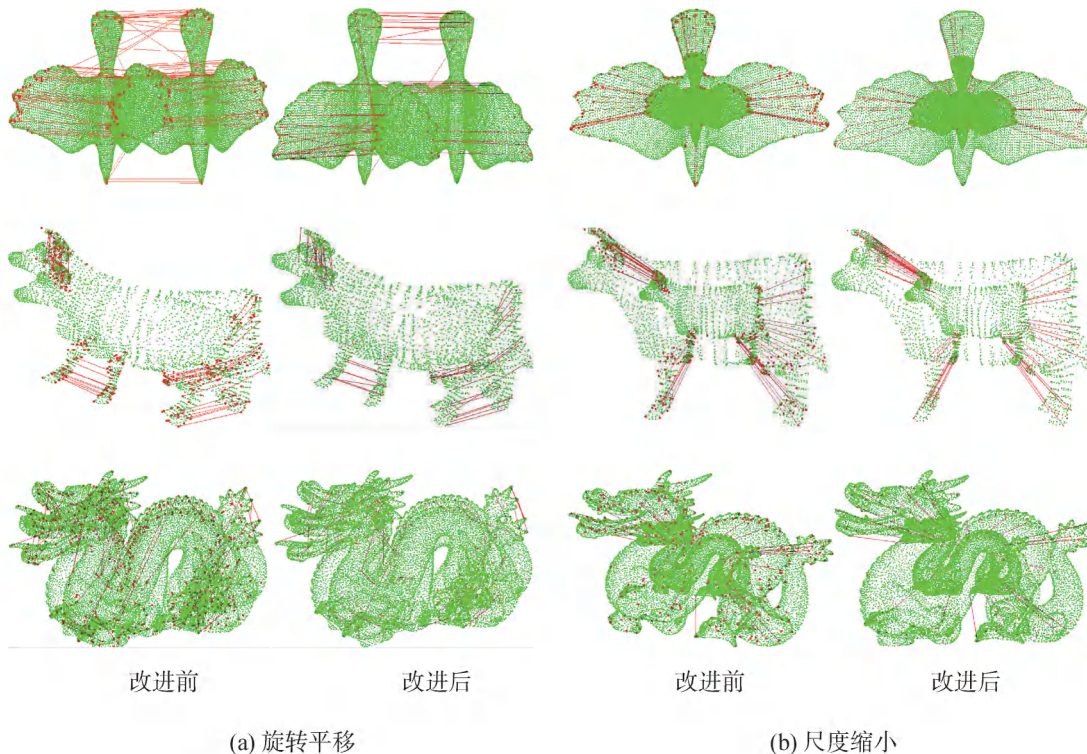


图 11 不同模型关键点匹配结果
Fig. 11 Critical point matching results of different models

表2 改进前后算法的关键点匹配正确率对比
Table 2 Comparison of critical point matching accuracy %

模型	旋转平移	尺寸缩小
	改进前/改进后	改进前/改进后
鸟	83.6/88.5	100/100
牛	74.3/84.0	91.9/92.8
龙	29.0/66.4	70.1/89.5

2.3 点云匹配实验

通过对不同密度、曲面复杂度的模型分别在不同的刚体变换下进行实验，从而验证本文所给出的基于关键点精确配对的匹配算法的可行性。如图12所示，无论是针对密度均匀的鸟、龙模型还是不同密度的牛、大象和河马模型，本文所给出的匹配算法在不同的刚体变换和曲面复杂度下都具有良好的匹配效果，并且保持了一定的稳定性。除此之外，为了验证本文算法不仅适用于从开源数据集获取的简单、单一点云模型，还适用于复杂的、由多种单一模

型组成的实测复杂场景点云数据，本文还对实测复杂场景点云数据进行了实验。如图13所示，(a)场景中只包含2个凳子，由于是单侧扫描数据，因此还包含墙壁点云数据；(b)场景中包含了书柜、桌子、凳子和电脑显示器等多种单一点云模型。通过实验结果可得，无论是简单的还是复杂的实测点云数据，本文所给出的匹配算法都可以完全适用，都会使空间变化下的2个点云场景完全匹配。

除此之外，实际点云在扫描过程中会存在噪声情况，为了验证本文算法的抗噪性，还进行了有噪声的点云匹配实验。实验数据选取了鸟、牛、龙模型，并分别对每个点云数据添加高斯噪声。其中，高斯噪声服从 $N(0, \sigma^2)$ ，所设置的方差参数 σ^2 分别为0.05, 0.1和0.15。如图14所示，高斯噪声的增加对于鸟模型和牛模型的匹配结果没有影响，几乎完全匹配，但是龙模型的匹配结果存在少量误差。




图12 本文算法匹配结果

Fig. 12 Matching results based on our method



图13 实测场景匹配结果

Fig. 13 Matching results of scanning scene




图14 噪声模型的匹配结果

Fig. 14 Matching results of different noisy models

2.4 实验对比分析

为了验证本文的匹配算法的可靠性, 在同一实验环境下, 分别对鸟、牛、龙模型采用基于FPFH特征的点云匹配算法、传统的ICP算法、改进的ICP算法^[24]和本文算法进行对比。现有的基于FPFH特征的点云匹配算法是以点云关键点的FPFH特征相似性对点云进行初始匹配, 再使用ICP算法进行精确匹配。传统的ICP算法是一种最经典的点云配准算法。文献[24]是一种结合随机样本一致性算法、固有形状特征和三维形状上下文的改进ICP算法。本文将设定最大迭代次数为500, 对基于FPFH特征匹配算法进行约束以控制实验时间。

如图15所示, 采用基于FPFH特征的点云匹

配算法针对牛模型进行匹配的结果几乎完全重叠, 但是对鸟模型和龙模型进行匹配的匹配结果仍存在较大误差。传统ICP算法虽然针对牛模型的匹配结果良好, 但是因其对点云的初始位姿依赖性较高, 对于鸟模型和龙模型并没有实现精确配准, 存在明显的误差。改进的ICP算法对于鸟模型和牛模型都得到了不错的匹配结果, 但是对于龙模型的匹配没有实现精确匹配。而由图12可知, 本文算法对于不同初始位姿的鸟、牛和龙模型都取得了良好的匹配效果。因此, 根据实验结果可以得出, 本文算法的匹配效果更优于其他匹配算法, 具有一定的通用性和准确度。通过表3的比较也可以得出, 在相同软硬件条件下, 本文算法进行匹配所花费的时间虽然超过传统的ICP

算法和改进的 ICP 算法，但是要远远小于基于 FPFH 特征的匹配方法。由此可见，本文算法相较于其他算法具有更好的稳定性和匹配效果，虽

然在匹配效率上有不足之处，但是相较于基于 FPFH 特征的匹配算法在匹配效率上有明显提升。

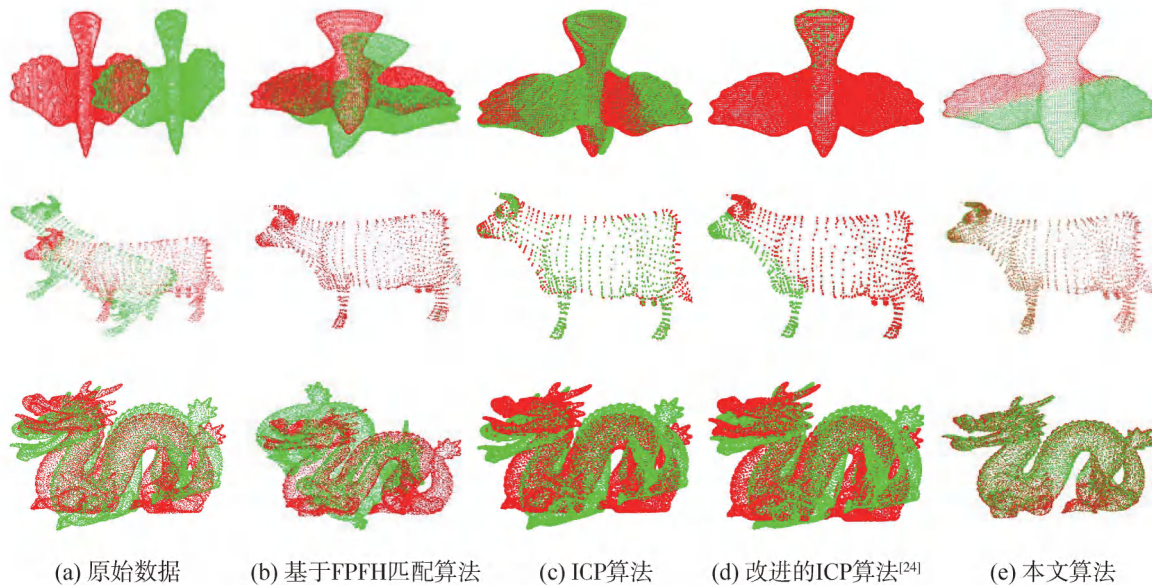


图 15 旋转平移的不同模型匹配实验对比

Fig. 15 Experiment comparison of different models matching through rotation and translation

表 3 不同方法的匹配时间对比

Table 3 Quantitative evaluation of matching time on different models

算法	鸟	牛	龙
FPFH	281.028	57.525	406.530
ICP ^[15]	19.764	2.024	9.404
改进的 ICP 算法 ^[24]	1.608	1.131	1.390
本文	62.451	22.741	116.958

如表 4 所示，还将本文算法与 ICP 算法、基于 Marvin 框架的深度学习方^[25]进行对比。针对旋转 45°的帽子和椅子模型，本文方法相对于深度学习方^[25]在运行效率和旋转误差方面较低，但在平移误差方面要优于深度学习；相对于 ICP 算法虽然运行效率较差，但是旋转平移误差都优于 ICP，匹配精度更高。

2.5 局限性分析

本文算法在针对表面局部几何特征不明显

的模型时效果不佳，如图 16 所示的兔子模型，由于其模型本身的特点，对模型主趋势与点集中心到关键点向量的夹角和 FPFH 特征这 2 种约束条件的计算都具有较大的影响，因此，使用本文所给出的关键点匹配算法所得到的关键点匹配结果不理想，从而导致最终的点云匹配结果存在误差。

表 4 匹配时间和准确度对比

Table 4 Comparison of matching time and accuracy

模型	匹配方法	时间/s	旋转误差	平移误差
帽子	ICP ^[15]	1.125	19.4	0.012 7
	基于 Marvin 的点云匹配 ^[25]	0.761	8.7	0.002 9
	本文算法	11.290	11.9	0.000 7
椅子	ICP ^[15]	1.279	16.2	0.023 7
	基于 Marvin 的点云匹配 ^[25]	0.828	7.0	0.002 4
	本文算法	13.225	11.8	0.000 3

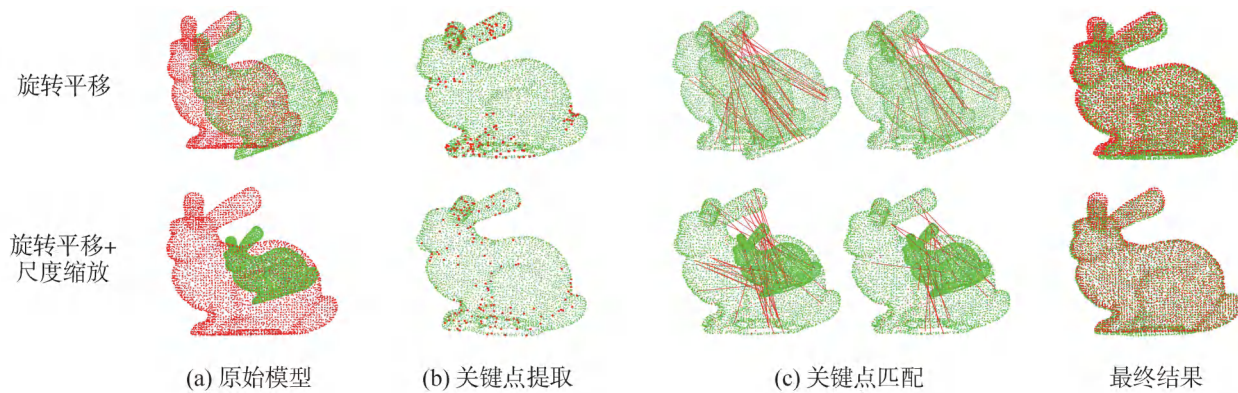


图16 兔子模型匹配结果

Fig. 16 Matching results of rabbit models

3 结论

针对目前基于特征的点云曲面匹配方法在关键点匹配时计算量大, 匹配效率低和精度不够的问题, 提出了一种基于关键点精确配对的点云曲面匹配方法。对尺度不变特征变换算法进行改进, 使其能够处理仅包含顶点坐标信息的点云数据; 将点云模型主趋势夹角和FPFH特征作为约束条件获得更加精确的关键点对应关系; 利用奇异值分解方法进行初始匹配; 使用ICP算法进行精确匹配, 提高了点云匹配的效率和精度。针对噪声和点云数量不同的情况, 本文对各种情况进行了实验。结果表明:

(1) 在无噪声的情况下, 源点云与目标点云初始位置的差值大小对于大多数点云模型的匹配结果影响不大, 都具有很好的匹配效果。最终匹配的均方根误差为 $10^{-4} \sim 10^{-6}$ 。当存在噪声时, 龙模型的匹配结果存在误差; 但是其他模型不会受到噪声影响。

(2) 在点云数量不同的情况下, 点云数量越多, 所耗费的时间会越高。

不论原始点云数据有无噪声、点云数量是否相同, 本文所给出的关键点匹配方法的匹配正确率都较高, 具有很好的稳定性, 且基于关键点精确配对匹配方法的匹配效果和效率明显得到了提高, 但是针对大规模数据, 在匹配效

率上仍需提高。针对类似兔子模型这种表面局部几何特征不明显的模型, 未来需要对其进行特定方法的研究, 进而提高本文算法的鲁棒性。

参考文献:

- [1] Eggert D W, Fitzgibbon A W, Fisher R B. Simultaneous Registration of Multiple Range Views for Use in Reverse Engineering[C]//13th International Conference on Pattern Recognition. Vienna, Austria: IEEE, 1996: 243-247.
- [2] Wang Yuan, Yang Bisheng, Chen Yiping, et al. JoKDNet: A Joint Key Point Detection and Description Network for Large-scale Outdoor TLS Point Clouds Registration[J]. International Journal of Applied Earth Observation and Geoinformation (S0303-2434), 2021, 104: 102534.
- [3] Ren T, Wu R. An Acceleration Algorithm of 3D Point Cloud Registration Based on Iterative Closet Point[C]//2020 Asia-Pacific Conference on Image Processing, Electronics and Computers (IPEC). Dalian, China: IEEE, 2020: 271-276.
- [4] Zhao J, Chu J, Feng G, et al. Multimodal Point Cloud Registration Based on Adaptive Feature Region in Radiotherapy Guidance[C]//2020 International Conference on Virtual Reality and Visualization (ICVRV). Recife, Brazil: IEEE, 2020: 185-190.
- [5] Chang W, Zwicker M. Global Registration of Dynamic Range Scans for Articulated Model Reconstruction[J]. ACM Transactions on Graphics, 2011, 30(3): 26-40.
- [6] Yang Y, Ong S H, Foong K W C. A Robust Global and Local Mixture Distance Based Non-rigid Point Set Registration[J]. Pattern Recognition, 2015, 48(1): 156-173.
- [7] Salvi J, Matabosch C, Fofi D, et al. A Review of Recent Range Image Registration Methods with Accuracy Evaluation[J]. Image and Vision Computing, 2007, 25

- (5): 578-596.
- [8] Rusu R B, Blodow N, Beetz M. Fast Point Feature Histograms(FPFH) for 3D Registration[C]//2009 IEEE International Conference on Robotics and Automation. Kobe, Japan: IEEE, 2009: 3212-3217.
- [9] Dror Aiger, Niloy J Mitra, Daniel Cohen-Or. 4-points Congruent Sets for Robust Pairwise Surface Registration[J]. ACM Transactions on Graphics, 2008, 27(3): 1-10.
- [10] 刘世光, 王海荣, 刘锦. 快速四点一致性点云粗配准算法[J]. 山东大学学报(工学版), 2019, 49(2):1-7.
Liu Shiguang, Wang Hairong, Liu Jin. Fast Four-point Consistency Point Cloud Coarse Registration Algorithm[J]. Journal of Shandong University (Engineering Science), 2019, 49(2): 1-7.
- [11] 彭真, 吕远健, 渠超, 等. 基于关键点提取与优化迭代最近点的点云配准[J]. 激光与光电子学进展, 2020, 57(6): 68-79.
Peng Zhen, Lü Yuanjian, Qu Chao, et al. Point Cloud Registration Based on Key Point Extraction and Optimization Iteration[J]. Progress in Laser and Optoelectronics, 2020, 57(6): 68-79.
- [12] 孙培芪, 卜俊洲, 陶庭叶, 等. 基于特征点法向量的点云配准算法[J]. 测绘通报, 2019(8): 48-53.
Sun Peiqi, Bu Junzhou, Tao Tingye, et al. Point Cloud Registration Algorithm Based on Feature Point Normal Vector[J]. Bulletin of Surveying and Mapping, 2019(8): 48-53.
- [13] Lowe D G. Object Recognition from Local Scale-Invariant Features[C]//Seventh IEEE International Conference on Computer Vision. Kerkyra, Greece: IEEE, 1999: 1150-1157.
- [14] Lowe D G. Distinctive Image Features from Scale-invariant Key Points[J]. International Journal of Computer Vision(S0920-5691), 2004, 60(2): 91-110.
- [15] Besl P J, McKay N D. A Method for Registration of 3-D Shapes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence (S1939-3539), 1992, 14(2): 239-256.
- [16] 孙水发, 李准, 夏坤, 等. 变尺度点云配准算法[J]. 系统仿真学报, 2018, 30(7): 2465-2474.
Sun Shuifa, Li Zhun, Xia Kun, et al. Variable-scale Point Cloud Registration Algorithm[J]. Journal of System Simulation, 2018, 30(7): 2465-2474.
- [17] 石珣, 任洁, 任小康, 等. 基于曲率特征的漂移配准方法[J]. 激光与光电子学进展, 2018, 55(8): 248-254.
Shi Xun, Ren Jie, Ren Xiaokang, et al. Drift Registration Method Based on Curvature Characteristics[J]. Advances in Laser and Optoelectronics, 2018, 55(8): 248-254.
- [18] 王飞鹏, 肖俊, 王颖, 等. 一种基于高斯曲率的ICP改进算法[J]. 中国科学院大学学报, 2019, 36(5): 702-708.
Wang Feipeng, Xiao Jun, Wang Ying, et al. An Improved ICP Algorithm Based on Gaussian Curvature[J]. Journal of University of Chinese Academy of Sciences, 2019, 36(5): 702-708.
- [19] Yao Z, Zhao Q, Li X, et al. Point Cloud Registration Algorithm Based on Curvature Feature Similarity[J]. Measurement(S0263-2241), 2021, 177(11): 109274.
- [20] Hu F J, Zhao Y W, Chen J. SIFT Feature Points Detection and Extraction of Three-dimensional Point Cloud[C]//International Conference on Communication Technology and Application. Beijing: WIT Press, 2014: 603-611.
- [21] Chung D H, Yun I D, Sang U L, et al. Registration of Multiple-range Views Using the Reverse-calibration Technique[J]. Pattern Recognition, 1998, 31(4): 457-464.
- [22] Sorkine-Hornung O, Rabinovich M. Least-squares Rigid Motion Using Svd[C]//International Conference on Computational Science. Computing, 2017: 1-5.
- [23] Wu Z, Song S, Khosla A, et al. 3D ShapeNets: A Deep Representation for Volumetric Shapes[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA: IEEE, 2015: 1912-1920.
- [24] Xu G, Pang Y, Bai Z, et al. A Fast Point Clouds Registration Algorithm for Laser Scanners[J]. Applied Sciences(S2076-3417), 2021, 11(8): 3426.
- [25] 梁振斌, 熊风光, 韩燮, 等. 基于深度学习的点云匹配[J]. 计算机工程与设计, 2020, 41(6): 1689-1693.
Liang Zhenbin, Xiong Fengguang, Han Xie, et al. Point-Cloud Matching Based on Deep Learning[J]. Computer Engineering and Design, 2020, 41(6): 1689-1693.