

基于特征检测与深度特征描述的点云粗对齐算法



史文凯 张昭晨 喻孟娟 吴瑞 聂建辉

南京邮电大学自动化、人工智能学院 南京 210023

(wenkaishi.njupt@gmail.com)

摘要 点云对齐是点云数据处理的重要步骤之一,粗对齐则是其中的难点。近年来,基于深度学习的点云对齐取得了较大进展,特别是 3DMatch 方法,能够在噪声、低分辨率以及数据缺失的条件下取得较好的对齐效果。3DMatch 采用随机采样的方式产生待匹配点,当采样点个数较少时会导致匹配率较低,因此对齐效果不佳。为此,利用 ISS 特征点检测代替随机采样,然后以 3DMatch 为特征点生成描述符,最后通过匹配特征描述符实现数据对齐。由于 ISS 特征点检测具有良好的重复性,同时 3DMatch 能够提供具有高区分度的描述符,因此该方法大大提高了匹配的鲁棒性和准确性。实验结果表明,与随机采样相比,特征点采样在初始点云无噪、弱噪和强噪的情况下对齐效果更好、鲁棒性更强,并且在粗对齐效果相似的情况下,所需特征采样点的个数仅为随机采样点个数的 10%,极大地提高了对齐的效率。

关键词: 点云对齐;粗对齐;深度学习;3DMatch;特征点检测

中图分类号 TP391

Point Cloud Coarse Alignment Algorithm Based on Feature Detection and Depth Feature Description

SHI Wen-kai, ZHANG Zhao-chen, YU Meng-juan, WU Rui and NIE Jian-hui

College of Automation & Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

Abstract Point cloud alignment is one of the important steps in point cloud data processing, and coarse alignment is the hard part. In recent years, great progress has been made in point cloud alignment based on deep learning. In particular, the method of 3DMatch can achieve a better alignment effect under the conditions of noise, low resolution and missing data. However, this method uses random sampling to generate alignment points. When the number of sampling points is small, the matching rate will be low and the alignment effect is not good. Therefore, ISS feature point detection is used instead of random sampling, and then 3DMatch is used to generate descriptors for feature points. Finally, data alignment is achieved through matching feature descriptors. Since ISS feature point detection has good repeatability and 3DMatch can provide descriptors with high degree of discrimination, this method greatly improves the robustness and accuracy of matching. Experiment shows that, compared with random sampling, the alignment effect and robustness of feature point sampling are better when the initial point cloud has no noise, weak noise and strong noise. Moreover, when the coarse alignment effect is similar, the number of feature points only accounts for 10% of the number of random points, which greatly improves the alignment efficiency.

Keywords Point cloud alignment, Coarse alignment, Deep learning, 3DMatch, Feature point detection

1 简介

点云对齐是三维模型重建的关键步骤之一。特别是粗对齐,需要在不清楚两片点云的相对位置关系的情况下,通过找到一个变换关系来使两片点云的共同部分较好地重叠在一起。一个好的粗对齐结果能为后续的精细对齐提供良好的初始位置,并避免精细对齐^[1-2]陷入局部最优解。

传统的粗对齐方法有很多,但容易受到噪声、数据缺失等因素的影响。近年来,深度学习尤其是卷积神经网络的发展,

催生了很多相关的对齐方法,3DMatch^[3-4]便是其中的典型代表。该方法利用 RGB-D^[5] 重构结果生成数百万个对应的标签,对其进行训练后能够得到鲁棒性好、泛化能力强的特征描述符。通过寻找生成特征描述符的匹配关系,即可实现粗对齐。但该方法中的待匹配点是通过随机采样获得的,对于规模较大的点云数据,采样点的重复性差、匹配率低,从而导致粗对齐效果不佳。

针对上述问题,本文基于 ISS^[6] 特征检测的方法,对原始点云进行特征点提取,以提高待匹配点的重复性,同时采用深

收稿日期:2019-10-13 返修日期:2020-01-17 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:江苏省青年科学基金(BK20140892);国家自然科学基金青年科学基金(61802204)

This work was supported by the Jiangsu Youth Science Foundation(BK20140892) and National Natural Science Foundation of China(61802204).

通信作者:聂建辉 (njh19@163.com)

度特征描述符来改善待匹配点的相似度量。实验结果表明,本文方法能够在采样点较少的情况下取得更好的对齐效果,同时匹配效率更高。

2 相关工作

近年来,点云数据粗对齐和特征检测方法得到了广泛的研究,相关方法的描述如下。

2.1 粗对齐

粗对齐算法大致可分为两类:一类为传统的粗对齐算法;另一类为基于深度学习的粗对齐算法。

(1)传统的粗对齐算法

4PCS^[7-8]的基本思想来源于 RANSAC^[9]算法,其优化了寻找两片点云“对应点”的策略。基于共面四点对的仿射不变性,该算法从源点集中选取共面的四点作为基面,然后在目标点集中找到所有与基面近似一致的共面四点对,以此进行粗对齐。该算法尽管能够取得较好的对齐效果,但是在目标点集中找到的与源点集基面对应的4个点会存在误匹配点,而剔除错误点会耗费大量的时间,从而降低了对齐效率。

Super 4PCS^[10]算法改进了4PCS算法,通过添加额外的约束条件来滤除潜在的错误点对,从而得到了与基面对应的唯一四点集,并加快了算法的执行速度。但是 Super 4PCS对噪声较大的点云的对齐效果不佳,且对齐时长不稳定。

SAC-IA^[11-12]算法首先分别计算源点云和目标点云的FPFH(Fast Point Feature Histograms)特征描述子,然后在目标点云中查找与源点云中采样点具有相似FPFH特征的点,最后从这些相似点中随机选取一个点作为源点云与目标点云的对应点,并通过 Huber 罚函数计算距离误差和,完成对齐。但是,SAC-IA在点云数量较多的情况下,计算FPFH特征较慢,算法效率低,因此需要对点云进行下采样处理,以减少点的数量,但这会造成部分特征点丢失,从而降低对齐的准确度。

综合而言,传统方法是基于手动设计的描述符进行对齐的,很难完全利用点云中蕴含的有效信息,尤其是当点云中包含噪声、离群点时,对齐效果可能会受到较大的影响。

(2)基于深度学习的粗对齐算法

近年来,深度学习方法在三维数据处理中得到了广泛的应用。其中,3DShapeNets^[13]将深度学习引入三维建模中,通过计算三维数据的深层特征来提取全局特征,其抗噪性能好,但是细节区分能力差,因此仅当数据重合度很大时才能得到很好的对齐效果。Guo等^[14]通过2D卷积神经网络生成描述符来进行局部特征匹配,但只是把图像块特征向量连接起来作为网络的训练样本,因此缺少空间的关联性。Andy等^[3]提出一种叫3DMatch的自监督学习方法,其利用RGB-D重构结果中的数百万个正负标签,通过孪生网络结构的3D卷积神经网络,训练出鲁棒性高且泛化能力强的描述符,在新的场景下依然能实现粗对齐。基于上述工作,Quan等^[15]提出基于位选择的二进制局部特征描述符,能够有效减小计算量。Srivastava等^[16]通过增加训练样本中负样本的权重,提出了一种基于多边缘的损失函数,增加了正负样本之间的差距。本文也是基于3DMatch提出用特征点检测代替随机采样来

提取待匹配点,实验证明本文算法可以提高对齐效率且对噪声具有鲁棒性。

相比传统算法,基于深度学习的对齐算法能够利用训练好的权重为局部特征快速生成描述符以进行对齐,并且对噪声、离群点具有鲁棒性。

2.2 特征检测及描述符构建

特征检测及特征描述符构建是三维模型粗对齐中重要的一环。常用的特征检测方法有SIFT特征检测^[17]、NARF特征检测^[18]、Harris3D角点检测^[19]和ISS特征检测。

SIFT特征检测通过在空间尺度中寻找极值点,来提取其位置、尺度、旋转不变量,因此基于SIFT特征检测提取的特征点具有鲁棒性。SIFT描述符通过对特征点的周围图像区域进行分块,来计算尺度空间内的128维向量,并将其作为该区域的特征。但是,SIFT特征检测多适用于带有颜色映射的点云模型。

NARF特征检测对法向量的估计比较稳定,该算法将点云数据转换成2D深度图,其计算量小于直接操作点云数据的方法。NARF描述符能够描述物体表面以及外部空间形状,对特征点建立唯一的一个局部坐标系并通过距离函数区别特征,从而找到匹配对。但是,NARF算法适用于较为规则的深度图像,并不适用于本文实验中的散乱点云模型。Harris3D角点检测是2D Harris算法的一种延伸。该算法借助离散点云的法向信息构造协方差矩阵,并根据角点响应函数计算点云中每个角点的响应值,最后将响应值大于设定阈值的局部极大值点判定为特征点。Harris3D角点检测具有很强的旋转不变性,但通过该方法提取到的特征点数量不如ISS特征检测提取到的多,而且在平滑表面上的差距更为明显。另外,Harris3D角点检测的效率也远不如ISS特征点检测。

ISS特征检测首先构建基于当前点的局部坐标系,并在该坐标系下对邻域点协方差矩阵进行特征分解,然后得到协方差矩阵的特征值。特征值对应的椭球形态是对邻近点分布状态的抽象总结,因此根据椭球的3个主方向的大小关系判断该点是否为特征点。基于ISS特征检测提取的特征点数量多、重复性好,而且对噪声具有鲁棒性,结合3DMatch算法,对特征点生成对应的描述符来寻找匹配对,可以较好地实现数据对齐。

3 本文算法

3DMatch采用随机采样的方式产生待匹配点。实验表明,通过随机采样获取待匹配点时,会因重复采样而导致匹配率低,且当采样点数量过少时,其对齐效果不好。因此,本文提出利用ISS特征检测替代3DMatch中的随机采样。特征点是点云中具有稳定性、易区别性,且数量比原始点云少得多的点,能够很好地解决随机采样带来的低重复性问题,提高了两片点云的粗对齐率。具体地,首先分别对源点云和目标点云进行ISS特征检测,然后利用3DMatch网络对特征点生成对应的512维DNN描述符,最后结合KD-Tree^[20]搜索,对两点的描述符计算L2范数来判断这两个点是否为匹配对,并通过RANSAC算法求得最优的旋转平移矩阵。本文算法的流程如图1所示。

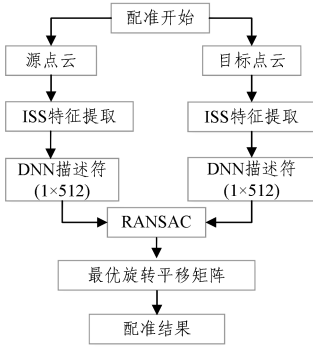


图1 本文算法的流程图

Fig. 1 Algorithm flow chart

3.1 ISS 特征检测

ISS 特征检测算法首先对点云上的每个点都定义一个局部坐标系,然后通过协方差矩阵建模,求得 3 个特征值和特征向量。这 3 个特征值和特征向量定义了一个椭球空间,其中,特征值代表椭球轴的长度,特征向量代表以该点为中心的椭球的 3 个主方向。若某一点的 3 个主方向大小相近,则表明当前点处曲面起伏很大,进而可以判定该点为特征点。ISS 特征检测较其他特征检测具有两个优势:1)ISS 特征检测算法的原理简单,可以直接对点云进行处理,不需要预处理;2)基于 ISS 特征检测提取的特征点数量较多、重复性好,且对噪声具有鲁棒性。ISS 特征检测算法如算法 1 所示。

算法 1 ISS 特征检测

1. 对点云上的每个点 p_i 定义一个局部坐标系,并给定每个点的搜索半径 r_{frame} ;
2. 查询点云数据中每个点 p_i 在半径 r_{frame} 内的所有点,并计算其权值,即: $w_{ij} = 1/|p_i - p_j|, |p_i - p_j| < r_{frame}$ (1)
3. 计算每个点 p_i 的协方差矩阵: $cov(p_i) = \sum_{|p_i - p_j| < r_{frame}} w_{ij} (p_i - p_j)(p_i - p_j)^T / \sum_{|p_i - p_j| < r_{frame}} w_{ij}$ (2)
4. 计算每个点 p_i 的协方差矩阵 $cov(p_i)$ 的特征值 $\{\lambda_1^i, \lambda_2^i, \lambda_3^i\}$,并按从大到小的顺序排列;
5. 设置阈值 ϵ_1 与 ϵ_2 ,满足下列条件的点则视为 ISS 特征点。 $\lambda_2^i/\lambda_1^i \leq \epsilon_1, \lambda_3^i/\lambda_1^i \leq \epsilon_2$ (3)

3.2 RANSAC 算法

虽然基于 ISS 特征检测算法提取的点都是特征点,但因受到噪声等影响,特征点集中也会包含错误数据,因此需要对其进行滤除。而 RANSAC 算法能够通过模型估计将数据区分为内点和外点,并能剔除外点,即错误点,因此采用 RANSAC 算法。RANSAC 算法的基本假设是样本中既包含正确数据又包含错误数据,首先随机选择样本数据集的子空间生成模型估计,测试和评估剩余样本数据集中的点,符合该模型的点称为内点,反之为外点,然后通过不断迭代,最终找出内点个数最多、误差最小的单应性矩阵。此时认为所有的外点均为错误数据并将其滤除。RANSAC 算法的步骤如算法 2 所示。

算法 2 RANSAC

1. 在源点集中和目标点集中随机选取 4 对匹配特征点作为内点集合 S_i ,估计初始的单应性矩阵 H_i ,如式(4)所示:

$$H_i = \begin{bmatrix} R_1 & R_2 & R_3 & T_1 \\ R_4 & R_5 & R_6 & T_2 \\ R_7 & R_8 & R_9 & T_3 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4)$$

其中,前 3 列为旋转矩阵,最后 1 列为平移矩阵,即对应点之间的变换关系为:

$$\begin{bmatrix} x_i' \\ y_i' \\ z_i' \\ 1 \end{bmatrix} = \begin{bmatrix} R_1 & R_2 & R_3 & T_1 \\ R_4 & R_5 & R_6 & T_2 \\ R_7 & R_8 & R_9 & T_3 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_i \\ y_i \\ z_i \\ 1 \end{bmatrix} \quad (5)$$

其中, (x_i', y_i', z_i') 为源集中的随机点, (x_i, y_i, z_i) 为目标点集中与源点集中 (x_i', y_i', z_i') 对应的点;

2. 利用 H_i 计算源点集和目标点集中剩余的匹配点对,若某点对的距离误差小于某一阈值 ϵ ,则将其添加到内点集 S_i 中;
3. 若内点集 S_i 中点的个数大于事先设定的阈值个数,则重新估计模型;
4. 若内点集 S_i 中点的个数小于事先设定的阈值个数,则重新选取样本,重复上述步骤,同时更新迭代次数 k ,迭代公式如下:

$$k = \frac{\log(1-p)}{\log(1-w^n)} \quad (6)$$

其中, p 为置信度,一般设置为 $[0.95, 0.99]$; w 表示每次从数据集选取一个内点的概率, n 为计算模型所需的最少样本数;

5. 经过 k 次迭代,选用内点集中点个数最多的模型估计作为最终的模型估计。

3.3 3DMatch 算法

3DMatch 是一种数据驱动模型,该模型采用自监督的特征学习方法,利用局部体素网格的描述符来建立三维数据之间的对应关系。3DMatch 算法利用已有的 RGB-D 重建结果生成数百万个正负标签,并通过孪生神经网络训练得到鲁棒性和泛化能力均很强的描述符,能够在有噪声、低分辨率、不完整的三维扫描数据情况下完成对齐。该网络结构如图 2 所示。利用 3DMatch 进行点云对齐的具体过程如下:首先对目标点云和源点云进行随机采样,并以每个采样点为中心提取大小为 $30 \times 30 \times 30$ 的体素网格来代表该点,其中每个小体素格子的具体尺寸根据输入点云模型的大小进行自适应调整;然后计算网格中每个小体素格子的 TDF 值,这些值代表该体素中心与最近的 3D 表面之间的距离,再将 TDF 值归一化(1 代表在点云表面上,0 代表远离点云表面);接着以该点的体素网格作为神经网络的输入生成对应的特征描述符;最后通过 l_2 范数进行相似性度量并结合对比损失函数建模,从而判断两点是否为匹配对。3DMatch 生成的特征描述符具备很好的区分性,但是所采用的随机采样方式使得待匹配点的重复性较差。为了解决上述问题,本文采用 ISS 特征检测代替随机采样,实验结果表明,本文方法能够极大地减少匹配所需的采样点数量,且对齐效果更佳。




图2 孪生神经网络结构图

Fig. 2 Siamese network diagram

4 实验

本文的实验平台为: Intel Core i7 8700 CPU@3.2 GHz,

16 GB 内存,Ubuntu16.04。实验选用斯坦福三维扫描存储库中的 Dragon 模型(dragon_0,dragon_48),该模型表面曲率变化大,细节纹理非常丰富,有助于特征点提取,使得实验对比效果更加鲜明,且两帧数据有 48° 的视角差别,既避免了因大角度旋转导致的对齐效果不佳从而无法进行比较的情况,又避免了因角度过小、对齐效果区分度低而无法进行比较的情况。模型中点云平均采样距为 0.001。为了测试本文算法的可行性,首先在无噪声的情况下将特征点采样和随机采样进行比较;接着又在弱噪和强噪的情况下分别进行实验,以测试本文算法的普适性与鲁棒性;最后,为了测试本文算法的通用性,在无噪声的情况下对 Bunny 模型(bun000,bun045)和 Horse 模型(horse1,horse2(随机坐标系下的前端视角))进行了实验。每次实验中均随机采样 3 次,依次采样 20 个点、100 个点和 200 个点,实验效果如图 3—图 7 所示。在各种噪声水平下随机采样 20 个点均无法进行粗对齐,因此在实验结果中没有贴图,仅起到与特征点采样的对比作用(特征点采样个数约为 20)。




图 5 强噪声情况下随机采样与特征检测算法的比较

Fig. 5 Comparison of random sampling and feature detection under strong noise




图 3 无噪声情况下随机采样与特征检测算法的比较

Fig. 3 Comparison of random sampling and feature detection under noiseless




图 6 Bunny 模型无噪声

Fig. 6 Bunny model without noise

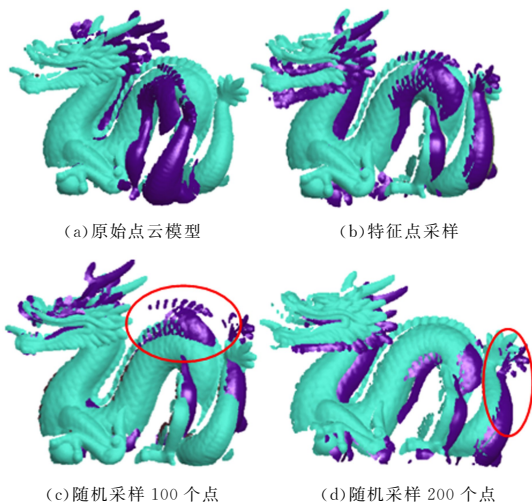


图 4 弱噪声情况下随机采样与特征检测算法的比较

Fig. 4 Comparison of random sampling and feature detection under weak noise

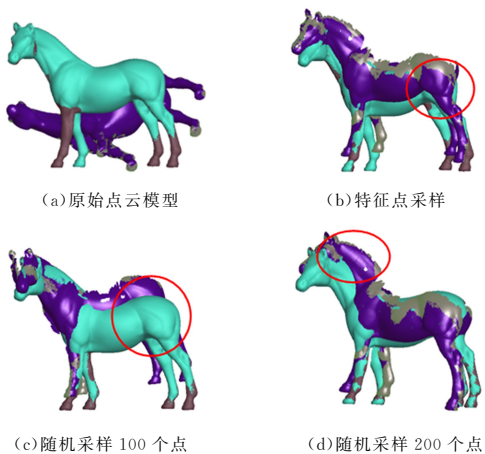


图 7 Horse 模型无噪声

Fig. 7 Horse model without noise

图 3 为无噪声情况下特征采样与随机采样的效果对比图。首先对原始点云进行特征点采样,在源点云 dragon_0 中提取了 23 个特征点,在目标点云 dragon_48 中提取了 19 个特征点。与原始点云相比,特征采样点个数很少,但因特征点

的高重复性,粗对齐效果较好,但当随机采样 20 个点时,无法实现对齐。增加随机采样点个数至 100,能粗略实现对齐;增加随机采样点个数至 200,对齐效果与特征采样对齐效果相当。因此,在无噪声情况下,通过增加随机采样点个数,对齐效果也能与特征采样相似,但随机采样点个数远大于特征点。

如图 4 所示,为了测试本文算法的鲁棒性,对源点云 dragon_0 添加了噪声方差为 9×10^{-5} 的高斯噪声,为点云采样密度的 9%,属于弱噪声。从图中不难发现,基于特征点采样的对齐效果仍较好,但随机采样的效果一般,说明本文算法对弱噪声具有鲁棒性。

如图 5 所示,为了进一步验证算法的鲁棒性,对源点云 dragon_0 添加了噪声方差为 5×10^{-4} 的高斯噪声,为点云采样密度的 50%,属于强噪声。此时,基于特征点采样的对齐效果仍然很好。而随机采样则因为有强噪声的介入,对齐效果会出现一定的偏差。

如图 6 与图 7 所示,Bunny 模型和 Horse 模型基于特征点采样的粗对齐效果都不错。即在不同的点云模型上本文算法都能较好地实现粗对齐,说明本文算法具有良好的通用性。

表 1 列出了 Dragon 模型分别经特征检测和随机采样后,在无噪、弱噪和强噪情况下的粗对齐率对比结果。纵向来看,无论噪声水平强弱,随机采样 20 个点都不能进行数据对齐,这验证了上文所述的随机采样会因采样点个数过少而无法进行对齐的观点。同时,随着噪声水平增加至点云平均采样密度的 50%,本文算法与随机采样 200 个点的粗对齐率都有所下降,分别下降了 2.2% 和 5.8%,且与无噪声时相比特征点减少了 4 个,说明噪声的介入会对最终的对齐效果产生负面影响,同时也说明了本文算法较为鲁棒;而随机采样 100 个点时,随着噪声水平的提高,粗对齐率不降反增,上升了 1.8%,这验证了随机采样的随机性。横向来看,无论是若噪声还是强噪声,本文算法总是优于随机采样 100 个点,略逊于随机采样 200 个点,说明虽然 ISS 特征检测采样到的点数量很少,但是具有易区别性和稳定性,且当特征点的个数为随机采样点个数的 10%~20% 时,最终的对齐效果是相仿的。本文在统计对齐率时规定了一些参数:距离阈值设置为 0.006,是点云平均采样密度的 6 倍;点云总设置为 dragon_0(41 841) 与 dragon_48(22 092) 的平均值,即 31 967。

表 1 点云粗对齐率对比

Table 1 Comparison of point cloud coarse alignment

Noise level	Our method			Random sample			Random sample			Random sample		
	dragon_0	dragon_48	rate/%	dragon_0	dragon_48	rate/%	dragon_0	dragon_48	rate/%	dragon_0	dragon_48	rate/%
noiseless	23	19	37.4	20	20	Unmatch	100	100	31.7	200	200	42.0
Sampling density(9%)	23	19	35.3	20	20	Unmatch	100	100	32.7	200	200	41.5
Sampling density(50%)	19	19	35.2	20	20	Unmatch	100	100	33.5	200	200	36.2

本文列出了 Dargon 模型、Bunny 模型和 Horse 模型在无噪声情况下从开始采样到最终对齐完成的各部分时间,如表 2 所列。采样部分,我们忽略了随机采样的时间,而对点云数据进行特征检测确实会增加额外开销,但因特征点个数远远少于随机采样点个数,所以后续生成 DNN 描述符的时间会缩短。同理,较少的特征点也会使得 RANSAC 的次数减少。虽然 RANSAC 具有一定的随机性,但通过取多次实验的平均时间,也能反映出在进行数据对齐时本文方法耗时更短。

表 2 算法执行时间

Table 2 Algorithm execution time

(单位:s)

采样方式	采样时间		DNN 描述符生成时间		对齐时间	总时间
	Dragon_0	Dragon_48	Dragon_0	Dragon_48		
随机 100	—	—	1.10	1.08	1.7	3.88
随机 200	—	—	1.32	1.30	2.2	4.82
ISS	0.75	0.37	0.66	0.61	0.86	3.25
	Bun000	Bun045	Bun000	Bun045		
随机 100	—	—	1.05	1.03	1.67	3.75
随机 200	—	—	1.30	1.30	1.95	4.55
ISS	0.70	0.73	0.65	0.64	0.83	3.55
	Horse1	Horse2	Horse1	Horse2		
随机 100	—	—	1.10	1.10	2.55	4.75
随机 200	—	—	1.29	1.28	3.23	5.80
ISS	0.67	0.77	0.66	0.69	0.98	3.77

如图 8 所示,在无噪声的情况下,分别对 Horse 模型和 Dragon 模型进行 ISS 和 Harris3D 特征检测,检测时拟合半径设置为模型采样半径的 20 倍,特征点对比结果如表 3 所列。从效率上来看,ISS 检测所需的时间约为 Harris3D 的一半,效率更高。

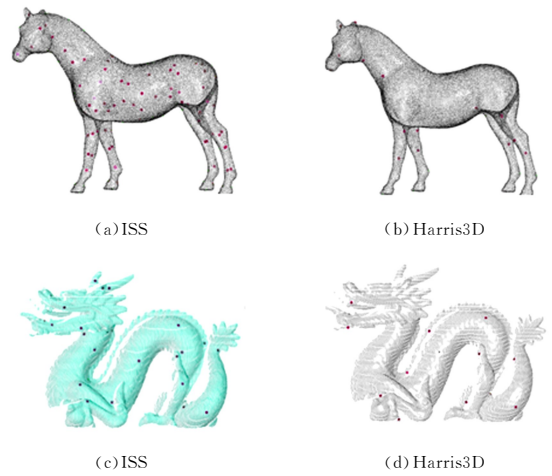


图 8 特征点个数

Fig. 8 Number of feature points

表 3 特征点对比

Table 3 Feature points

comparison Model	Number			Time/s	
	Total	ISS	Harris3D	ISS	Harris3D
Horse	71 030	110	24	0.89	1.57
Dragon_0	41 841	23	12	0.75	2.05

为了充分验证 RANSAC 算法在本文中是有效且必要的,我们在强噪声水平下对 Dragon 模型进行了实验,结果如图 9 所示。图 9(a)为加了 RANSAC 之后的粗对齐效果图,图 9(b)为没加 RANSAC 的粗对齐效果图。可以看到,在加入了 RANSAC 时,即使有强噪声的干扰,Dragon 模型也能基

本实现粗对齐,但当未加入 RANSAC 时,强噪声的介入会使得误匹配点增多,从而导致最终的对齐效果极差。




图9 有无 RANSAC 的对比

Fig.9 Comparison of algorithms with or without RANSAC

结束语 针对点云对齐存在时间空间复杂度高、效率低、对应点易误匹配等缺点,本文基于 3DMatch 算法,提出了一种利用特征检测替代随机采样的改进算法。对初始点云数据利用 ISS 进行特征提取,并利用 3DMatch 生成特征点描述符来寻找匹配对,同时结合 RANSAC 剔除错误匹配对,以此来提高粗对齐率。本文在无噪声、弱噪声和强噪声这 3 种不同情况下,使用不同点云模型对特征检测与随机采样进行了对比。实验数据表明,特征检测不仅能够减少采样点,且粗对齐的效果也较好,而且在弱噪或强噪的情况下依然能够保持高鲁棒性和高效率。


综合对点云对齐的研究学习以及结合深度学习的方法,未来我们可以从以下两个方面进行研究:

(1) 相比二维视图,三维模型储存的信息更为丰富,如本文涉及的 3DMatch 算法,需要大量的训练样本和训练时间,因此在针对不同的测试对象时,制作针对性的数据集能提高效率,也可以从网络结构入手,通过优化网络来提高效率与准确率。

(2) 本文实验中所采用的点云模型均为刚体模型,对类似的刚体模型进行特征提取的难度较小;但当模型变为非刚体模型时,由于非刚体三维物体的姿态是任意的,因此对非刚体模型进行特征提取的难度较大,这也是未来的研究方向之一。

参 考 文 献

- [1] BESL P J. A method for registration 3D shapes [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2):193-200.
- [2] ZHOU F Q, ZHOU M Q. Improved probability iterative closest point registration algorithm [J]. Journal of Graphics, 2017, 38(1):15-22.
- [3] ZENG A, SONG S, NIEßNER M, et al. 3DMatch: Learning Local Geometric Descriptors from RGB-D Reconstructions [C] // IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2017:199-208.
- [4] LI J, YANG X R, HE B. Geometric Features Matching with Deep Learning [J]. Computer Science, 2019, 46(7):274-279.
- [5] VALENTIN J, DAI A, NIEßNER M, et al. Learning to Navigate the Energy Landscape [C] // IEEE 2016 Fourth International Conference on 3D Vision (3DV). Stanford, USA, 2016:323-332.
- [6] ZHONG Y. Intrinsic Shape Signatures: A Shape Descriptor for 3d Object Recognition [C] // Proceedings of 2009 IEEE 12th International Conference on Computer Vision Workshops. 2009: 689-696.
- [7] 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.
- [8] YU W L, ZHOU M Q, SHUI W Y, et al. Automatic Registration Method Based on Curvature [J]. Journal of System Simulation, 2015, 27(10):2374-2379, 2386.
- [9] LEBEDA K, MATAS J, CHUM O. Fixing Locally Optimized RANSAC Full Experimental Evaluation [C] // British Machine Vision Conference on Neural Information Processing Systems. 2012:1-11.
- [10] MELLADO N, AIGER D, MITRA N J. Super 4pcs fast global pointcloud registration via smart indexing [J]. Computer Graphics Forum, 2014, 3(5):205-215.
- [11] LU J, PENG Z T, DONG D L. The Registration Algorithm of Point Cloud Based on Optimal Extraction of FPFH Feature [J]. New Industrialization Strategy, 2014, 4(7):75-81.
- [12] RUSU R B, NICO B, MICHAL B. Fast Point Feature Histograms (FPFH) for 3D Registration [C] // 2009 IEEE International Conference on Robotics and Automation. Kobe, IEEE, 2009:3212-3217.
- [13] WU Z, SONG S, KHOSLA A, et al. 3D ShapeNets: A Deep Representation for Volumetric Shapes [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2015:1912-1920.
- [14] GUO K, ZOU D, CHEN X. 3D Mesh Labeling via Deep Convolutional Neural Networks [J]. Acm Transactions on Graphics, 2015, 35(1):1-12.
- [15] QUAN S W, MA J. On Shortened Local Binary Descriptors [J]. Information Science, 2020, 510:33-49.
- [16] SRIVASTAVA S, LALL B. DeepPoint3D: Learning Discriminative Local Descriptors using Deep Metric Learning on 3D Point Clouds [J]. Pattern Recognition Letters, 2019, 127:27-36.
- [17] LOWE D G. Distinctive image features from scale-invariant key points [J]. International Journal of Computer Vision, 2004, 60(2):91-110.
- [18] STEDER B, RUSU R B, KONOLIGE K, et al. Point Feature Extraction On 3D Range Scans Taking Into Account Object Boundaries [C] // Proceedings of 2011 IEEE International Conference on Robotics and Automation. 2011:2601-2608.
- [19] HARRIS C G, STEPHENS M. A combined corner and edge detector [C] // Proceedings of Fourth the Alvey Vision Conference. 1998:147-158.
- [20] ANGELO L D, GIACCARI L. An efficient algorithm for the nearest neighbourhood search for point clouds [J]. International Journal of Computer Science Issues, 2011, 8(5):1-11.



SHI Wen-kai, born in 1995, postgraduate. His main research interests include discrete geometric processing and so on.



NIE Jian-hui, born in 1984, Ph.D, associate professor, postgraduate supervisor, is a member of China Computer Federation. His main research interests include geometric processing and optical measurement.