

基于深度学习的几何特征匹配方法

李 健¹ 杨祥如¹ 何 斌²

(陕西科技大学电气与信息工程学院 西安 710021)¹ (同济大学电气与信息工程学院 上海 201804)²

摘 要 Kinect 等深度相机采集的三维数据往往存在噪音、低分辨率等问题,导致两帧点云的局部几何特征匹配一直面临挑战。目前多采用基于特征直方图的方法解决这一问题,但其计算量较大,且对场景旋转平移的要求较为严格。文中提出了一种基于数据驱动的方法,首先从大量重建好的 RGB-D 数据集中,通过自监督的深度学习方法构建能够描述三维数据几何特征的模型;然后利用基于 KD-Tree 的 K 近邻算法(KNN)得到两部分点云的特征对应点,通过 RANSAC 剔除误匹配点对;最后通过得到的较准确的位置关系估计两帧点云的几何变换,从而完成配准。基于斯坦福大学点云库中的模型以及真实环境下 Kinect 采集到的大卫石膏像模型的配准和比较实验表明,所提方法不仅可以提取未知物体的局部几何特征进行配准,还可以较好地应对空间角度变换大的情况。

关键词 点云特征配准,深度学习,自监督,KD-Tree,大角度变换

中图分类号 TP391 文献标识码 A DOI 10.11896/j.issn.1002-137X.2019.07.042

Geometric Features Matching with Deep Learning

LI Jian¹ YANG Xiang-ru¹ HE Bin²

(School of Electrical and Information Engineering, Shaanxi University of Science & Technology, Xi'an 710021, China)¹

(School of Electrical and Information Engineering, Tongji University, Shanghai 201804, China)²

Abstract Matching local geometric features on real-world depth images is a challenging task due to the noisy and low-resolution of 3D scan captured by depth cameras like Kinect. At present, most of the solutions to this problem are based on the feature histogram method, which requires a large amount of calculation and strict requirements on the rotation of the scene. This paper proposed a method based on data-driven. From a large number of well-reconstructed RGB-D data sets, a self-supervised deep learning method is used to construct a model that can describe the geometric correspondence between three-dimensional data. Then, corresponding approximate points of two parts of the point cloud are obtained by using KD-Tree-based K Nearest Neighbor (KNN) algorithm. Through removing erroneous matching point pairs using RANSAC, a relatively accurate set of feature point pairs is obtained by estimating the geometric transformation. By registering and comparing the models in the Stanford University point cloud library and the David plaster model collected in the real environment, the experiments show that the proposed method can not only extract the local geometric features of unknown objects for registration, but also show good performance when dealing with large changes in spatial angle.

Keywords Point cloud feature registration, Deep learning, Self-supervised, KD-Tree, Large angle transformation

1 引言

在计算机视觉和 SLAM 等领域中,由于深度相机采集的点云数据存在不完整、旋转平移错位等情况,要得到完整的三维点云,就需要对局部点云进行配准,将各个视角得到的点集合并到统一的坐标系下形成完整的三维场景,以便于进行可视化操作。从计算机视觉和几何学发展开始,三维点云数据的配准就一直是研究的热点,已经成为包括物体位姿估计、场景三维重建和视觉 SLAM 在内的许多应用的首要任务。

现有的点云几何特征配准的方法有:1)基于构建几何特性的直方图,如基于快速点特征直方图(Fast Point Feature Histograms, FPFH)^[1-2]的计算方法通过多维直方图来描述查询点与邻域点之间的空间差异;2)基于距离度量的 ICP 算法^[3-4],通过最小二乘的方法重复选择对应关系点对,计算最优刚体变换,直到满足正确配准的收敛精度要求。该方法对角度和尺度变化较大的待匹配点云容易产生错误的对应点,或陷入局部最优而导致配准失败。此外,还有基于几何形状的配准算法,如 4PCS^[5-6]算法通过查找两个点集上全等且共

收稿日期:2018-06-21 返修日期:2018-08-32 本文受国家自然科学基金项目(51538009),陕西省工业攻关项目(2015GY044)资助。

李 健(1975-),男,教授,硕士生导师,主要研究方向为计算机视觉、计算机图形学,E-mail:498009028@qq.com;杨祥如(1993-),男,硕士生,主要研究方向为计算机视觉、计算机图形学;何 斌(1975-),男,博士,教授,博士生导师,主要研究方向为新型机器人动力学及智能控制,E-mail:hebin@tongji.edu.cn(通信作者)。

面的四边形建立对应关系,但对于重叠区域较小的点集,通常难以找到对应关系。基于 4PCS 方法的 Super4PCS 算法^[7]改善了这一问题,但其时间复杂度仍然远高于同类算法。以上算法对场景简单的点云数据的配准能得到较好的效果;但在实际应用场景中,如 SLAM 应对帧间配准解决闭环问题时,从深度相机获取的点云数据往往存在只有部分局部点云重合、旋转平移变换角度大等情况,这些算法往往难以取得较为理想的效果。

随着深度学习的提出,不少学者也开始将深度学习用于三维数据的建模和局部点云特征的提取配准。其中,Xiao 等提出的 ShapeNet^[8]将深度学习用于三维几何形状的重建,使用 CAD 数据作为训练数据,使用卷积 DBN 网络构建了一个 3DShapeNets,对 Kinect 传感器获取的 2.5 维深度图进行目标识别和复原,从而得到全局三维形状。之后他们又提出 3DMatch^[9],将配准延伸到三维场景的拼接和全局重建中。Guo 等利用二维的 ConvNet^[10]特征描述符进行局部点云的几何特征匹配,但该方法仅适用于较为简单的场景且仍须手工设置标签。本文提出了一种基于三维卷积网络的自监督的点云配准方法,在处理 Kinect 等深度相机获得的真实场景数据时,其对角度变化大、物体存在遮挡和视差变化等情况都有更好的鲁棒性;并且该方法仅提供少量的匹配对和不匹配对两种标签,从现有的大量未标注的重建好的 RGB-D 数据集中自监督地提取标签,无须人工手动标注,训练优化后得到高质量的配准模型。

2 总体框架

本文算法总体框架如图 1 所示。

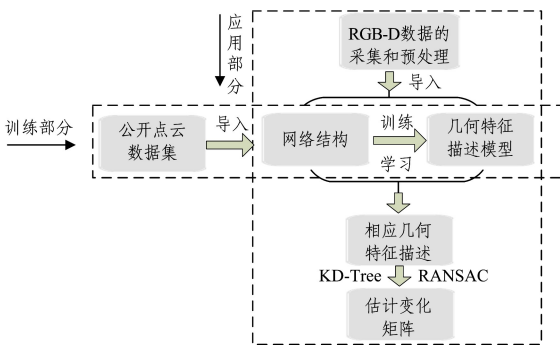


图 1 配准算法的总体框架

Fig.1 Framework of registration algorithm

本文算法总体分为训练和应用两部分。在训练部分,首先将公开的高质量 RGB-D 点云数据集导入构建好的适合三维数据的深度学习网络结构中,仅提供少量的标签和大量未标注的样本自监督地进行训练,最后通过前向和反向传播的不断迭代优化得到能够描述点云局部几何特征的权重模型。在应用部分,首先进行物体或场景点云数据的采集,对于采集到的深度图,通过深度阈值分割的方法提取出有效区域,位于有效范围外的点云不参加计算,提高了算法效率。然后将处理过的数据导入模型和网络结构中,分别得到两部分点云的几何特征表示。最后,采用 KD-Tree 搜索^[11]的方式选取特征

对应点,应用 RANSAC^[12]算法剔除误匹配点对,再计算两部分点云的位置变换关系,并将其变换关系应用到原始点云上得到最终的配准结果。

3 本文配准算法的详细描述

3.1 基于三维卷积网络的模型训练

卷积神经网络是人工神经网络的一种,已成为当前计算机视觉领域的研究热点。它的权值共享网络结构使其更类似于生物神经网络,降低了网络模型的复杂度,减少了权值的数量。

本文将卷积网络延伸到三维空间内,给定来自 Kinect 扫描数据的两部分三维点云,首先随机地从每片点云中提取 n 个特征点,并且得到特征点邻域的三维体积区域,然后将其从点云数据转换为 $30 \times 30 \times 30$ 的 TDF (Truncated Distance Function) 体素网格表示。这种中间形式的表示方法不仅有助于将特征还原成网格或点云数据,而且更利于预测真实场景中的空间尺度和被遮挡区域。之后对这些 TDF 体块进行卷积操作,类似于二维深度学习中的 kernel 卷积核,此处我们将其定义为卷积块。经过卷积计算后,提取三维数据的局部几何特征,进而根据对应部分的几何相似度进行后续配准、重建等应用。

3.1.1 网络结构设计

本文使用的网络结构是一种标准的三维卷积网络,其借鉴了多伦多大学 Alex 提出的 Alexnet^[13],通过 8 个卷积层和 1 个池化层来计算 512 维特征输出,每个卷积层都会连接一个 Relu 激活函数作为线性修正单元,以提高模型应对方向和角度变化的能力。因为初始输入的维度较小,所以结构中仅包含了 1 个池化层,这样可以避免数据信息的丢失。具体的网络维度参数如表 1 所列。

表 1 网络维度参数

Table 1 Network dimension parameters

Contrastive L_2 loss	
descriptor 1	descriptor 2
conv ($3^3, 512$)	conv ($3^3, 512$)
conv ($3^3, 512$)	conv ($3^3, 512$)
conv ($3^3, 256$)	conv ($3^3, 256$)
conv ($3^3, 256$)	conv ($3^3, 256$)
conv ($3^3, 128$)	conv ($3^3, 128$)
conv ($3^3, 128$)	conv ($3^3, 128$)
pool ($2^3, 64$)	pool ($2^3, 64$)
conv ($3^3, 64$)	conv ($3^3, 64$)
conv ($3^3, 64$)	conv ($3^3, 64$)
30^3 patch	30^3 patch

在点云配准问题上,我们的目标是建立一个优化函数 L ,对于三维表面上各点的局部体积块,通过卷积操作计算其特征描述的向量;对于待匹配的两帧点云数据,通过随机梯度下降(SGD)的方法不断优化对应点间的距离。为此,我们通过双分支网络的传递方式来学习训练模型。

3.1.2 网络模型训练

本文方法通过上述双分支网络结构从公开 RGB-D 数据集 Analysis-by-Synthesis^[14], 7- Scenes^[15], SUN3D^[16], Stan-

ford 3D Scanning Repository^[17]中自监督地生成标签进行训练,从而得到特征提取模型。训练示意图如图2所示。

图2(a)为Stanford 3D Scanning数据集中的Lucy模型,将其每一帧点云数据作为训练集,标注少量的匹配对标签和非匹配对标签,构成图2(b)中的三维卷积块,将其导入图2(c)中的双分支网络,其中每个分支独立计算不同的三维体素网格的特征描述向量。2个分支网络的结构相同且网络间的权值参数共享。第一个网络为匹配对数据流,第二个网络为不匹配对数据流。训练时,将匹配对和不匹配对数据1:1地输入网络,通过SGD的方法最小化匹配对之间的距离 L_1 并最大化不匹配对之间的距离 L_2 来得到最终的损失函数。这样的平衡训练机制更有助于数据拟合和模型优化。

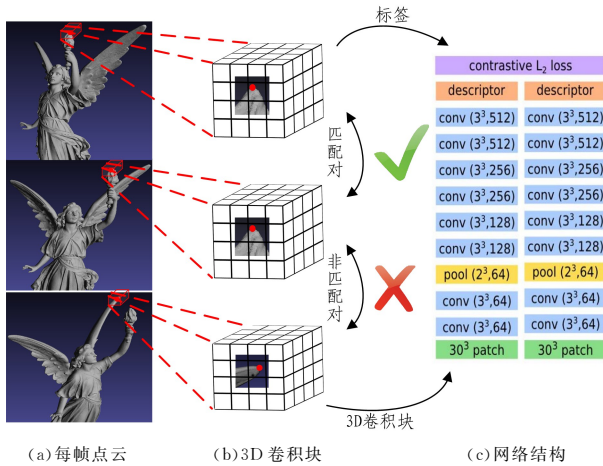


图2 训练示意图

Fig. 2 Training diagram

3.2 模型应用

在模型的应用部分,将采集到的点云数据进行深度阈值分割处理后输入到训练好的模型中,可以分别得到两部分点云的特征点信息和对应的二进制特征表示;然后使用基于KD-Tree搜索的KNN算法和RANSAC去除误匹配来估计点云的变换矩阵。

3.2.1 特征描述模型的应用

Kinect等深度相机采集到的数据中往往存在噪音和信息缺失的情况,并且每次获得的点云数据都包含了大量无用的场景点云,这增加了本方法应用于特定物体时的计算量和复杂性。因此,我们采用对深度图进行阈值分割的方法,选取距离相机一定阈值距离范围内的点云进行保留,将其余无用的非应用目标的点剔除,以此提高运算的效率和精度。

之后将预处理过的点云转化成与训练时相同的 $30 \times 30 \times 30$ 的TDF体素网格,以满足网络结构的参数输入形式。结合训练时得到的特征描述的权重模型,将转化后的TDF体素网格放入网络结构中进行前向传播,最后输出相应点云的特征点个数、位置信息以及几何特征描述的二进制表示。

3.2.2 估计变换矩阵

(1) 基于KD-Tree的KNN算法

在利用KNN算法求对应点对时,若选取所有的点进行计算,则耗时较长且计算成本过大。本文采用了KD-Tree的方法,仅对上述得到的特征点 R 半径邻域内的点做变换矩阵的估计。

在具体的搜索过程中,将特征点作为查询点输入,给定查询点和查询距离的阈值(即查询半径 R),从点云中找出所有与查询点距离小于阈值的点。如图3所示,在点云空间中以 Q 点为例,以给定的查询距离 R 为半径画球体,球体内所有的点即为要查询的邻域点。

然后利用KNN算法对两部分点云特征点邻域内的所有点集 $P_i(x_i, y_i, z_i)$ 和 $P_j(x_j, y_j, z_j)$ 进行处理,不断迭代优化,最后将欧氏距离最小的点对作为对应点对。




图3 R 半径搜索示意图

Fig. 3 R radius search diagram

通过以欧氏距离为度量表示的KNN算法,可以得到两部分点云中特征点的大致对应点对集合。

(2) RANSAC 滤除误匹配

通过KNN算法得到的对应关系并不是完全正确的,采用RANSAC算法剔除其中的错误匹配,能够得到相对准确的对应关系。

RANSAC算法是一种简单有效的去除误匹配的方法,通过建立一个特定的数学模型将数据点分为“内点”和“外点”,采用迭代估计的方法计算出最优参数模型,找到的不符合该模型的“外点”为误匹配点,符合模型的“内点”为精确匹配。该方法在特征匹配以及帧间拼接方面得到了广泛应用。

本文利用RANSAC算法从之前得到的匹配点对中随机抽出4个点云样本并保证4个样本之间不共线,计算出单源性矩阵;然后利用该模型测试所有数据,计算满足这个模型的点云个数,并不断迭代优化代价函数;最后得到较为准确的点云匹配对,并且计算对应点对间的变换关系。

通过RANSAC变换之后,将点云的配准问题转化为求解优化式(1)中代价函数 $F(R, T)$ 的问题。

$$F(R, T) = \min_{i=1}^m \| R \vec{p}_i + T - \vec{q}_i \|^2 \quad (1)$$

其中, m 为点集中对应点对的个数, R 和 T 分别为旋转和平移变换矩阵。

4 实验结果与分析

本文通过对斯坦福点云数据集进行仿真实验和对Kinect采集的大卫石膏像进行真实实验,将本文方法与传统算法FPFH、改进后的ICP以及Super4PCS与同样是将深度学习用于提取几何特征的3Dmatch从配准精度、计算时间和点云重合率上进行对比。

电脑配置:Windows10操作系统/Intel Core i5-8400 CPU/8G RAM/Intel UHD Graphics 630/无GPU加速。

数据集来源:斯坦福大学点云集。

算法实现:PCL点云库/C++语言。

4.1 仿真部分

斯坦福兔子扫描数据Bunny000和Bunny045模型在初

始状态下的位置关系如图 4(a)所示, Bunny000 和 Bunny045 是对同一个兔子模型分别从 0° 和 45° 扫描得到的点云数据, 两片点云间含有部分不共有的数据。

从图 4 可以看出, FPFH 和 3Dmatch 方法在面对大角度变化的物体点云配准时, 无法做到精配准, 点云重合率和配准精度较低; ICP 在处理单一自由度变化(横向角度从 0° 变化 45°)时效果较为理想, 但在 Bunny 背部和耳朵部分的配准还不够精确。研究还发现, Super4PCS 虽然在嘴部区域的配准精度有所改善, 但在耳朵和背部区域仍存在误差。

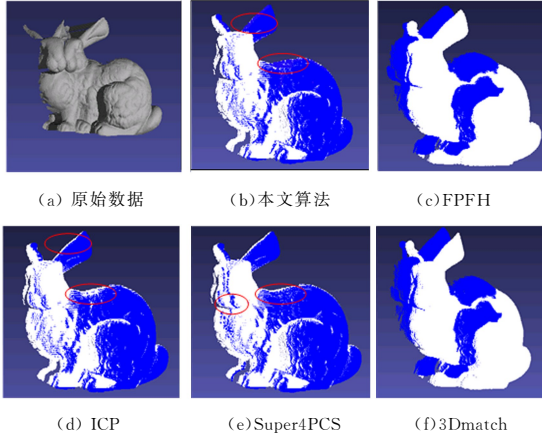


图 4 Bunny 实验结果对比

Fig. 4 Bunny comparison

为进一步验证本文方法的普适性和鲁棒性, 又选取了 Stanford 点云集中的 Dragon 模型进行仿真。Dragon 模型相较于 Bunny 模型, 表面曲率变化较大且具有更丰富的细节纹理。本文选取了 Dragon0 与 Dragon24 进行实验。两帧数据在扫描时有 24° 的旋转, 因此含有部分点云不共有的点。在此基础上, 将 Dragon24 模型分别沿 X, Y, Z 轴旋转 35° , 平移 0.05 m , 得到的点云位置关系如图 5(a)所示。

从图 5 可以看出, 对于经过多方向大角度变换的两部分点云, 本文方法仍具有较好的鲁棒性。FPFH 方法在应对这一问题时仍无法做到较为精确的配准, 在模型的细节部分, 如身体边缘和尾巴等, 配准精度有待改善。而 ICP 方法和 3Dmatch 方法在应对多自由度变换的两部分点云时, 配准完全失败。Super4PCS 方法对各部分的细节匹配都有较好的效果, 而且相较于本文算法, 其在 Dragon 脚部的配准效果略好, 但配准花费的时间成本大幅增加。

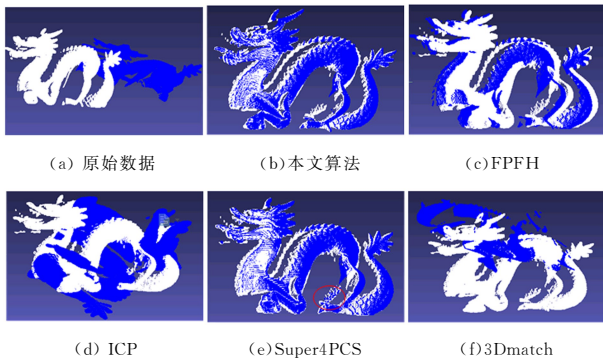


图 5 Dragon 实验结果对比

Fig. 5 Dragon comparison

4.2 实验部分

与 Kinect 采集到的真实点云数据相比, 斯坦福大学的标准数据集没有加入真实环境中的噪声影响。为了验证本文方法在真实场景下的鲁棒性, 选取了 Kinect 采集的大卫石膏像的两组未经滤波去噪或通过其他光度或深度方法修正 Kinect 误差的数据进行实验, 以此来应对完全未进行预处理的 Kinect 数据的配准, 实验结果如图 6 和图 7 所示。

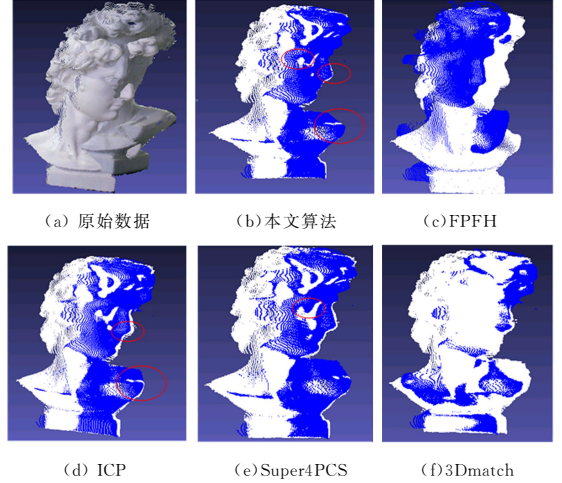


图 6 David 侧面实验结果对比

Fig. 6 David's side comparison




图 7 David 正面实验结果对比

Fig. 7 David's positive comparison

对于大卫侧面的两部分点云, X 轴方向的角度变化约为 25° , Y 轴方向的角度变化约为 25° , Z 轴方向的角度变化约为 60° , 平移距离为 0.5 m 。对于大卫正面的两部分点云, X 轴方向的角度变化约为 30° , Y 轴方向的角度变化约为 25° , Z 轴方向的角度变化约为 45° , 平移距离为 0.3 m 。

通过真实环境下的实验可以看出, 加入噪声和 Kinect 相机自身的物理因素影响后, 本文方法仍能得到较好的配准效果(图 6(b)和图 7(b))。相较于 ICP 方法的结果(图 6(d)和图 7(d)), 本文方法在人物的鼻子、肩部以及底座等细节部分的配准精度较好。而 FPFH 方法因为需要计算查询点邻域半径内所有点的 3 个特征值, 较多地加入了对真实场景中噪

点的计算,所以无法得到较为理想的位置关系。3Dmatch 由于仅通过卷积提取三维体素的几何特征,未进行 RANSAC 和聚类等方法,人物轮廓发生了轻微的漂移,在细节处存在可见的偏差。Super4PCS 在整体配准效果上有不错的表现,只是在面部眼睛和底座部分存在些许误差。

表 2—表 4 为本文方法与 FPFH, ICP, Super4PCS 和 3Dmatch 算法在配准精度、计算时间和点云重合率方面的对比结果。3 个测试指标分别由 Hausdorff 距离测得的均方根值、程序运行的时间、匹配点的重合率来表示。其中,对于匹配点的重合率,本文采用了对应点对的欧氏距离进行平方根计算之后小于 0.05m 的评判标准,符合这一条件的对应点对被认为是重合点。

对于仿真结果来说,从表 2—表 4 中第一组数据 Bunny045 的实验结果可以得到,相比于 FPFH 和 ICP 算法,本文方法的 RMS 值分别降低了 73.4% 和 5.4%,在计算时间上分别缩短了 92.7% 和 65.9%,得到的点云重合率分别高出 28.2% 和 8.9%。在第二组仿真数据中,由于 ICP 在配准多方向大角度变化的数据时陷入了局部最优,故无对比价值。本文方法相比于 FPFH, RMS 值降低了 62.1%,时间缩短了 85.8%,并且在最终配准的点云重合率上高出 10.6%。这说明本文方法在理想条件下应对多方向大角度变化的仿真数据集的配准方面,无论从计算时间还是配准效果上都有了较大的改进。相比于配准领域较为前沿的工作 Super4PCS,本文方法在 RMS 和点云重合率上大致持平,算法时间上大致缩短为 Super4PCS 的 1/5。另外,3Dmatch 方法是通过端到端的前向传播提取几何特征来进行配准,未加入误匹配点对剔除等操作,在时间效率上占优,但难以保证配准的精度,在面面对如 Dragon24 加入旋转平移后的多尺度变换点云时,直接出现了配准失败的情况。

表 2 均方根值的对比

Table 2 Comparison of RMS

数据	均方根值 (RMS) × 10 ⁻³				
	本文算法	FPFH	ICP	Super4PCS	3D match
Bunny045	1.58	5.95	1.67	1.59	4.72
Dragon24	1.76	4.64	7.18	1.65	9.53
David 侧面	10.98	25.80	11.15	10.52	16.62
David 正面	11.47	23.93	11.69	11.33	17.25

表 3 时间的对比

Table 3 Comparison of time

数据	时间/s				
	本文算法	FPFH	ICP	Super4PCS	3D match
Bunny045	15.75	217.08	44.94	56.89	3.32
Dragon24	17.33	122.38	111.67	135.9	4.47
David 侧面	13.54	127.52	59.31	70.63	3.08
David 正面	19.55	149.21	84.88	91.34	4.65

表 4 点云重合率的对比

Table 4 Comparison of point cloud coincidence rate

数据	点云重合率/%				
	本文算法	FPFH	ICP	Super4PCS	3D match
Bunny045	98.5	70.3	89.6	97.9	79.4
Dragon24	94.1	83.5	48.1	98.5	32.5
David 侧面	95.3	71.5	83.3	95.8	79.2
David 正面	95.5	69.7	80.2	96.3	75.6

在应对真实环境下的点云配准问题时,本文方法也有所改进。从第三组和第四组数据可以得到本文方法的 RMS 值较 FPFH 方法降低了 57.4% 和 52.1%,时间缩短了 89.4% 和 86.9%,并且对点云重合率的提升均在 20% 以上。相较于 ICP 和 Super4PCS 方法,本文算法虽然在 RMS 精度上只有较小的改进,但从图 6 和图 7 可以看出在大卫像的面部鼻子、肩膀等细节部分的配准精度有所提升,而且在计算效率上有较大的改进,配准时间相比于 ICP 和 Super4PCS 分别缩短了 77.2% 和 78.5%,点云重合率也有 1%~10% 的提升。

为进一步验证本文方法在真实环境下对所有点的配准精度的鲁棒性,将本文实验部分经过几何变换后的点云与目标点云进行注册配准,计算变换点云上的点与原始点云各点的最近几何距离,并以伪彩色图表示。对各算法的结果进行对比,如图 8 和图 9 所示。

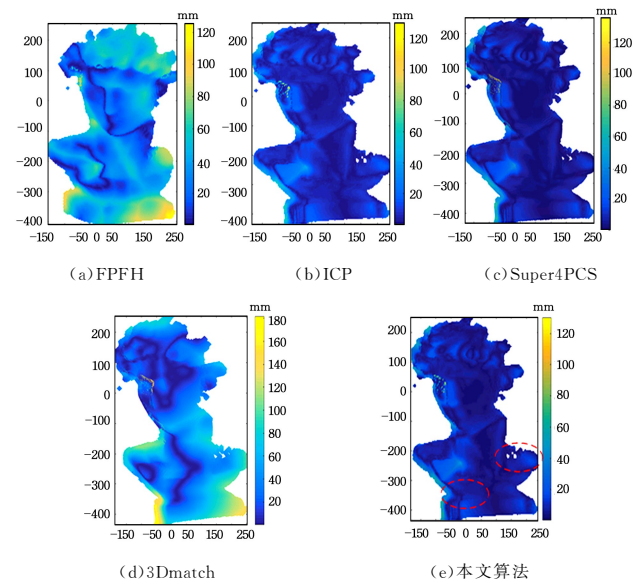


图 8 David 侧面伪彩色图结果对比

Fig. 8 David's side pseudo-color contrast results

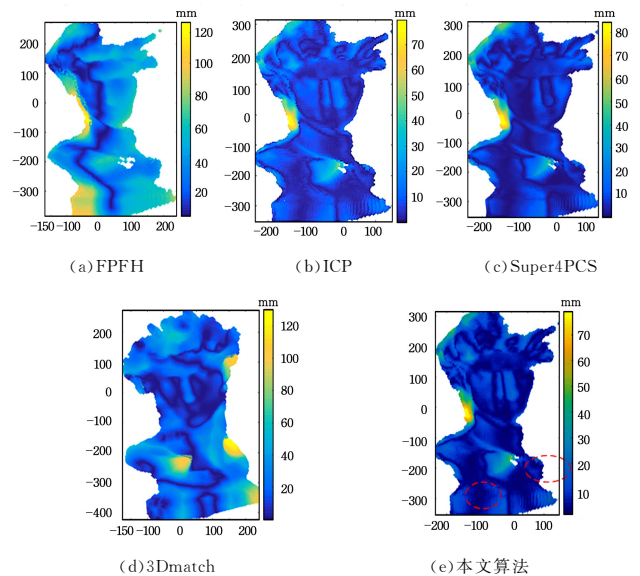


图 9 David 正面伪彩色图结果对比

Fig. 9 David's front pseudo-color contrast results

从伪彩色图的对比结果可以看出,相较于 FPFH 和 3Dmatch 算法,本文方法对两帧点云的误差分布区域更小,如图 9 所示,将最小误差范围从 20 mm 缩小到 10 mm,且整体误差均有较为明显的改善。相比于 ICP 方法,本文算法的整体误差改善效果不是很明显,但在细节部分的伪彩色图颜色更深,如虚线标注的大卫像底座和肩部部分,细节误差更小。从以上伪彩色误差图也可以看出,本文方法与 Super4PCS 方法的配准精度大致持平,在不损失精度的情况下,较好地改善了配准的时间效率。

结束语 本文将深度学习用于三维点云局部特征的提取,融合 RANSAC 和 KNN 算法来解决多维度大角度变化的点云配准问题。从仿真和真实实验的结果及数值分析来看,对于两片只有部分重合的变化尺度较大的点云,本文方法可以进行较好的配准。

综合对三维深度学习和最近邻点算法配准的特性分析,未来可以从以下方面进行研究:

(1)对于不同的测试对象,学习训练的数据集选择将更具有针对性。

(2)本文仅是对 Kinect 采集的两帧数据进行配准,但在实际应用中需要对全方位的三维模型进行配准。在本实验基础上实现三维全视角的配准重建将具有更高的实用价值。

(3)本文采用的大卫石膏像为刚性体模型,如何实现动态非刚性物体的配准也是下一步的研究方向。

参 考 文 献

- [1] RUSU R B, BLODOW N, BEETZ M. Fast point feature histograms (FPFH) for 3D registration[C]// IEEE International Conference on Robotics and Automation, Kobe, Japan; IEEE Press, 2009; 3212-3217.
- [2] MA D H, LIU G Z. Improved Method of Point Cloud Registration Based on FPFH Feature[J]. Computer and Modernization, 2017(11): 46-50. (in Chinese)
马大贺, 刘国柱. 改进的基于 FPFH 特征配准点云的方法[J]. 计算机与现代化, 2017(11): 46-50.
- [3] BESL P J. A method for registration 3 D shapes [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2): 193-200.
- [4] ZHAO F Q, ZHOU M Q. Improved Probability Iterative Closest Point Registration Algorithm [J]. Journal of Graphics, 2017, 38(1): 15-22. (in Chinese)
赵夫群, 周明全. 改进的概率迭代最近点配准算法[J]. 图学学报, 2017, 38(1): 15-22.
- [5] 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.
- [6] 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. (in Chinese)
余文利, 周明全, 税午阳, 等. 基于曲率的点云自动配准方法[J]. 系统仿真学报, 2015, 27(10): 2374-2379.
- [7] MELLADO N, AIGER D, MITRA N J. Super 4PCS Fast Global Pointcloud Registration via Smart Indexing [J]. Computer Graphics Forum, 2015, 33(5): 205-215.
- [8] 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 (CVPR). Boston, MA, USA, 2014.
- [9] ZENG A, SONG S, NIEBNER 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.
- [10] GUO K, ZOU D, CHEN X. 3D Mesh Labeling via Deep Convolutional Neural Networks[J]. Acm Transactions on Graphics, 2015, 35(1): 1-12.
- [11] 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.
- [12] LEBEDA K, MATAS J, CHUM O. Fixing Locally Optimized RANSAC Full Experimental Evaluation[C]// British Machine Vision Conference. Guildford, UK, 2012: 1-11.
- [13] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]// International Conference on Neural Information Processing Systems. Curran Associates Inc. 2012: 1097-1105.
- [14] VALENTIN J, DAI A, NIEBNER M, et al. Learning to Navigate the Energy Landscape [C]// IEEE 2016 Fourth International Conference on 3D Vision (3DV). Stanford, CA, USA, 2016: 323-332.
- [15] SHOTTON J, GLOCKER B, ZACH C, et al. Scene Coordinate Regression Forests for Camera Relocalization in RGB-D Images [C]// IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2013: 2930-2937.
- [16] XIAO J, OWENS A, TORRALBA A. SUN3D: A Database of Big Spaces Reconstructed Using SfM and Object Labels[C]// IEEE International Conference on Computer Vision. IEEE Computer Society, 2013: 1625-1632.
- [17] The Stanford 3D Scanning Repository[EB/OL]. (2014-08-19). www.graphics.stanford.edu.