

基于卷积神经网络的点云配准方法

舒程珣¹, 何云涛¹, 孙庆科²

¹北京航空航天大学电子信息工程学院, 北京 100191;

²河北远东通信系统工程有限公司, 河北 石家庄 050200

摘要 点云配准是三维点云信息处理中的重要问题。传统点云配准方法计算量大,不利于实时计算与移动计算。针对传统点云配准方法存在的问题,提出了一种利用卷积神经网络进行点云配准的方法。首先计算点云的深度图像,利用卷积神经网络提取深度图像对的特征差,将深度图像对的特征差作为全连接网络的输入并计算点云配准参数,迭代地执行上述操作直至配准误差小于可接受阈值。实验结果表明,相比传统的点云配准方法,基于卷积神经网络的点云配准方法具有所需计算量小、配准效率高、对噪声点和异常点不敏感的优点。

关键词 图像处理; 点云配准; 深度学习; 卷积神经网络; 深度图像

中图分类号 TP249 文献标识码 A

doi: 10.3788/LOP54.031001

Point Cloud Registration Based on Convolutional Neural Network

Shu Chengxun¹, He Yuntao¹, Sun Qingke²

¹*School of Electronics and Information Engineering, Beijing University of Aeronautics and Astronautics, Beijing 100191, China;*

²*Hebei Far-East Communication System Engineering Co., Ltd, Shijiazhuang, Hebei 050200, China*

Abstract Point cloud registration is an important issue in 3D information processing. The traditional point cloud registration needs a huge amount of computation, thus it is not suitable for real-time and mobile computation. In order to solve the problem of traditional point cloud registration method, a method based on convolutional neural network is proposed. The depth image of point cloud is calculated and the differential feature vector of depth images extracted by the convolutional neural network is regarded as input of fully connected neural network to calculate registration parameters. Iteratively executing the above process until registration error is acceptable. Experimental results show that the point cloud registration based on convolutional neural network is simpler in computation, more efficient in registration rate, and less sensitive to noise and outlier than the traditional methods.

Key words image processing; point cloud registration; deep learning; convolutional neural network; depth image

OCIS codes 100.5010; 100.6890; 280.3640

1 引言

在机器视觉领域,点云配准是指通过空间变换使得两片点云在同一坐标系中对齐的过程。随着三维(3D)扫描和3D打印技术的发展,实物的三维模型在工程中所扮演的角色越来越重要。受测量条件的限制,扫描物体表面往往需要多次测量才能够完成。由于多次测量时,通常无法有效估计测量设备与被测物体之间空间位置的相对变化,因此需要利用算法对扫描得到的三维点云进行整合和配准,以得到一幅完整的物体点云图像。

传统的点云配准算法一般分为粗配准和精准配准。粗配准用于缩小点云之间的旋转和错位误差,为精准配准提供良好的初始值,以提高配准的效率;精准配准使两片点云的配准误差达到最小。精准配准的一种

收稿日期: 2016-10-24; 收到修改稿日期: 2016-11-09

基金项目: 上海航天创新基金 SAST(2015090)

作者简介: 舒程珣(1991—),男,硕士研究生,主要从事深度学习方面的研究。E-mail: shuchengxun@163.com

导师简介: 何云涛(1982—),男,博士,讲师,主要从事成像技术、激光雷达探测等方面的研究。

E-mail: yuntaohe@buaa.edu.cn(通信联系人)

经典算法是迭代最近点算法(ICP)^[2]。ICP算法是一种基于自由形态曲面的配准算法,具有简单易行的优点,但ICP算法的效率不高,因此人们在此基础上做出了许多改进。Chen等^[3]利用切平面逼近点云,将问题归结为求点到切平面的最小二乘距离,该方法不需要考虑点与点的对应关系,从而使得配准效率在一定程度上有所提高。Blais等^[4]利用逆向标定法和随机搜寻找提高配准速度,但是配准精度受到了一定影响。韦盛斌等^[5]提出了一种单应性迭代最近点配准算法,通过建立单应性点对推导点云之间的坐标变化,该方法具有稳健性强、速度快、精度高的优点。左超等^[6]提出了一种通过分析点云的空间分布规律并基于信息熵的概念进行初始配准的方法,该方法可以寻找较好的初始拼接位置。伍梦琦等^[7]提出了一种通过图像特征评价进行自适应拼接的方法,通过自适应地选择配准算法,可以实现不同表面点云的稳定拼接。黄源等^[8]提出了一种基于特征提取的点云自动配准算法,通过点云在不同半径内的法向量变化度提取特征点,并综合利用点云局部点的三种几何特征搜索匹配点对,相较于ICP算法提高了配准的速度和精度。张晓等^[9]提出了一种基于正态分布变换的点云配准算法,该算法通过将点云图像化,利用加速稳健特性提取图像特征,找到点云映射关系,完成点云配准。该方法具有精度高、速度快的特点。上述方法均能进行点云配准,但计算量较大,较难应用于手持式3D扫描设备等对计算实时性要求较高且计算能力有限的设备。

近年来,随着大数据的普及和图形处理器计算能力的显著提高,深度学习^[10]技术在语音识别^[11]、图像分类^[12]、药品分子分析^[13]、棋类博弈^[14]等领域取得了重大突破。深度学习技术利用包含多层非线性结构的深层神经网络对数据进行处理。每一层神经网络都能对数据进行非线性变换,从而形成从低层到高层的逐层表示变换,反映数据中复杂的非线性关系。通过反向传播算法,神经网络可以有效提取输入数据中的信息并产生使问题更容易解决的表示。卷积神经网络(CNN)作为深度学习的经典模型,通过在空间中的不同位置共享卷积核参数,大大减小了模型规模,广泛应用于图像识别、场景感知等领域^[15]。

传统意义上卷积神经网络多用于解决分类问题,在回归问题上应用较少。例如物体识别^[12],虽然利用卷积神经网络逐层自动提取图像特征的优点,可以取得非常好的效果,但是由于回归问题需要计算准确的回归参数,而不是某一类的分类概率,对准确度要求较高,难以一次性输出准确值。针对点云配准的参数回归问题,本文提出一种基于卷积神经网络的点云配准方法。首先计算点云的深度图像,利用卷积神经网络提取深度图像对的特征差,将深度图像对的特征差作为全连接网络的输入并计算点云配准参数,并且迭代地执行上述操作直至配准误差小于可接受阈值。实验结果表明,本文方法能够完成点云配准的任务,且具有计算量小、配准效率高、对噪声点和异常点不敏感的优点。

2 卷积神经网络

卷积神经网络是一种在深度学习中常用的神经网络模型。通常卷积神经网络由卷积层和池化层组成。卷积层利用不同的卷积核对输入图像进行卷积操作以提取输入图像的不同特征,卷积操作使得卷积核的参数在图像的不同位置共享,大大降低了模型的参数量,并且提取到的特征与出现的空间位置无关。在卷积层之后会接入非线性激活函数如双曲正切函数、线性修正单元(ReLU)^[16]等。现代的卷积神经网络一般使用ReLU作为激活函数。池化层对卷积层的输出进行下采样,减小了模型的规模并且使模型对位移、缩放等变换具有更好的稳健性。

卷积神经网络示意图如图1所示。通常,对于边长为 L_k 的卷积核,若卷积核移动步长为 S ,输入图像边长为 L_w ,在输入图像四周补真空白的宽度为 P ,则卷积层输出边长为 $L_h = (L_w - L_k + 2 \times P) / S + 1$ 。若在池化层对卷积层输出进行 D 倍下采样则池化层输出边长为 $L_p = L_h / D$ 。对于输入 x 卷积层输出的第 k 种特征可表示为

$$h^k = f(x * W^k + b^k), \quad (1)$$

式中 $*$ 为卷积操作, W^k 为第 k 个卷积核, b^k 为相应的偏置, f 是激活函数。

多层卷积神经网络可以逐层提取输入图像在不同层次的特征。最底层的卷积核通常表示图像不同方向的点或线,较上一层的卷积核通常表示图像中的形状,更高层的卷积核可表示某一类物体或物体中的某一部分,直至最高层表示输入数据的最高层次抽象。通过卷积和池化操作,多层卷积神经网络可以提取所需的输入图像的高级特征而不被底层噪声或扰动所干扰。




图1 卷积神经网络示意图

Fig. 1 Diagram of convolutional neural network

3 三维点云配准

三维点云的配准问题即寻找适当的平移参数和旋转参数,使得配准后的点云在同一空间坐标系中对齐的问题。三维刚体的配准一般可以由6个参数确定,分别是三个方向的平移参数 t_x 、 t_y 、 t_z 和三个方向的旋转参数 t_α 、 t_β 、 t_θ ,如图2所示。其中, t_x 、 t_y 、 t_θ 对刚体的操作限定在观测平面内,被称为平面内参数; t_α 、 t_β 、 t_z 对刚体的操作超出观测平面,被称为平面外参数^[17]。点云的配准即估计以上6个参数,以使配准后的两片点云尽可能吻合。

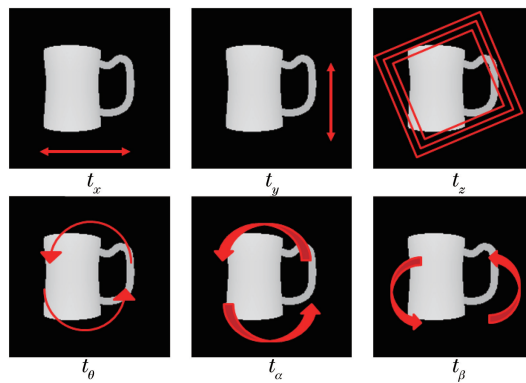


图2 3D点云配准的6种参数

Fig. 2 Six parameters in 3D point cloud registration

4 点云配准模型

给定两片点云 P_1 和 P_2 ,计算其深度图像 X_1 和 X_2 ,将深度图像作为输入,模型需要输出配准参数 t_x 、 t_y 、 t_z 、 t_α 、 t_β 、 t_θ ,以使得尽可能减小配准误差。不同于传统方法,卷积神经网络没有用于分类,而将卷积神经网络用于回归。通过计算卷积神经网络提取输入深度图像 X_1 、 X_2 的特征,将特征差分向量作为回归模型的输入,可以有效迅速地输出配准参数。

4.1 深度图像计算

给定点云 P ,其中观测视角处点 (x, y) 的深度为 D ,则该点在深度图像中的像素值 c 可表示为

$$c = \left[255 - 255 \times \frac{2 \times N}{F + N - D \times (F - N)} \right] \times 4, \quad (2)$$

式中 F 和 N 被设置为合适值使得计算得到的深度图像对比充分,利于之后的计算。通过计算点云的深度图像,三维数据被投影到二维有利于卷积神经网络对数据的处理。

4.2 网络结构

基于卷积神经网络的点云配准方法的整体模型如图3所示。模型大致分为两个部分,首先利用卷积神

神经网络计算点云深度图像的特征,再利用得到的特征计算配准参数。为了使模型在不同的配准参数区间内均能正常工作,模型采用了20组并联的卷积神经网络相互独立地提取深度图像的20种不同特征,每种特征为128维向量。将图像 X_1 的第一种特征向量 \mathbf{x}_1^1 与图像 X_2 的第一种特征向量 \mathbf{x}_2^1 相减,得到第一种特征的差分向量 \mathbf{d}_1 。将20种不同的差分向量 $\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_{20}$ 并联作为配准的整体差分向量。整体差分向量经过以ReLU为激活函数的全连接层 F_2 得到256维向量。最后经过全连接层 F_3 得到6种不同的配准参数。通过对整个网络进行端到端的训练,网络各部分得以协调,使得在各种配准参数范围内网络均能有效配准。

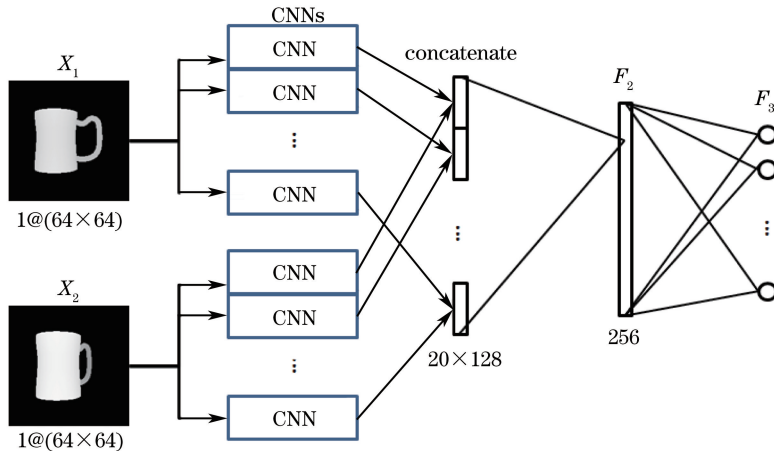


图3 基于CNN的点云配准模型

Fig. 3 Point cloud registration model based on CNN

图3所示的每一组卷积神经网络结构如图4所示。输入为 64×64 的深度图像,经过卷积核大小为 5×5 、步长为1、拥有20个卷积核的卷积层 C_1 ,得到20组 60×60 的图像。经过窗口大小为 2×2 、步长为2的最大值池化层 P_1 ,得到20组 30×30 的图像。再经过卷积核大小为 5×5 、步长为1、拥有20个卷积核的卷积层 C_2 ,得到20组 26×26 的图像。所得图像通过窗口大小为 2×2 、步长为2的最大值池化层 P_2 ,得到20组 13×13 的图像。最后 P_2 输出的图像经过全连接层 F_1 得到128维特征向量。由于回归问题的特殊性,需要更大的反射野以提取整体特征,实验发现使用大小为 5×5 的卷积核效果较好,而不是采用近年来较为流行的小卷积核。




图4 模型采用的CNN结构

Fig. 4 CNN structure of the model

整个网络的优化目标为最小化与真实配准参数的均方损失,定义为

$$L = \frac{1}{M} \sum_{i=1}^M y_i - f(X_i; \theta)_2^2, \quad (3)$$

式中 M 为训练样本数, y_i 为第 i 组样本的真实配准参数, X_i 为第 i 组输入深度图像对, θ 为模型中待训练的

参数。模型采用 Xavier 方法初始化网络的参数以提高网络的训练效率^[18]。训练采用随机梯度下降的方法进行参数优化,其中梯度更新的批大小设置为 100,梯度更新的动量为 $m=0.9$,权值衰减率 $d=0.0001$ 。对于参数 θ 的更新公式可表示为

$$\mu_{i+1} = m\mu_i - d\eta_i\theta_i - \eta_i\partial L/\partial\theta_i, \quad (4)$$

$$\theta_{i+1} = \theta_i + \mu_{i+1}, \quad (5)$$

$$\eta_i = 0.002(1 + 0.0001i)^{-0.75}, \quad (6)$$

式中 i 为梯度更新的次数, μ 是梯度的动量, η_i 是第 i 次梯度更新时的学习率, $\partial L/\partial\theta_i$ 是基于反向传播算法计算得到的目标函数对 i 时刻网络参数的偏导数。学习率 η_i 按照(6)式随着训练而衰减,以使网络训练稳定。

4.3 迭代点云配准方法

由于点云空间位置变换的复杂性,难以有效地对配准参数进行一次性地精确估计。实验中,平面内参数由于只涉及到点云的平移和平面内旋转,不改变图像的形状,比较容易估计。而平面外参数由于会造成物体轮廓的改变,较难估计。因此采用迭代地进行点云配准,将待配准的参数分为三组,即 $t_x, t_y, t_\theta, t_\alpha, t_\beta, t_z$ 。先配准容易估计的配准参数,再配准较难估计的配准参数,使得训练容易进行。首先经过配准网络模型得到配准参数 t_x, t_y, t_θ ,利用得到的参数对点云进行配准,并拍摄配准后的深度图像。然后再经过配准网络模型得到配准参数 t_α, t_β ,利用 t_α, t_β 对点云进行配准,得到新的深度图像。最后经过配准网络得到 t_z ,再次对点云进行配准,并更新深度图像。重复上述步骤 k 次, k 为常数,通常设置为 10 以内,以使配准误差可以接受,算法流程如图 5 所示。

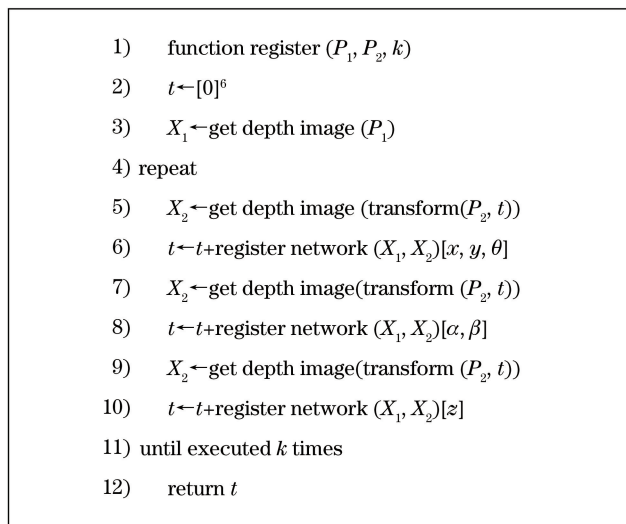


图 5 基于 CNN 的迭代点云配准算法

Fig. 5 Point cloud registration algorithm based on iterative CNN

5 实验结果与分析

5.1 实验数据

实验采用普林斯顿形状数据集中的约 1000 个模型作为训练数据^[19]。为了准确产生真实配准参数,采用自动生成的数据作为模型输入。首先利用 OpenGL 的深度测试功能拍摄三维模型的深度图像 X_1 ,然后按一定的配准参数 t 旋转模型,并拍摄之后的图像 X_2 ,将 X_1, X_2 作为配准网络的输入并将 t 作为训练目标对网络进行训练。利用图 5 所示的算法流程训练整个模型,直至配准误差可以接受。所有的实验点云模型中,选取了 80% 作为训练集,20% 作为测试集,以保证在测试中遇到的点云没有在训练中遇到。所有样本均放置于合适位置,以使拍摄的 64×64 深度图像能够准确表现三维模型的形态。

5.2 实验条件

实验在一台采用 Intel Xeon E5-2620 处理器,配有 128 GB 内存和 Nvidia Tesla K20M 显卡的工作站上




图 6 部分模型及其深度图像

Fig. 6 Some models and their corresponding depth images

进行。工作站采用 Ubuntu 14.04 操作系统,为了渲染三维模型和计算深度图像,采用的 OpenGL 版本为 4.5.0。神经网络的实现中采用了开启 cuDNN 加速的开源深度学习框架 Caffe^[20]。

5.3 实验结果

配准的准确性由包围配准点云边界盒的 8 个顶点与配准目标边界盒的 8 个顶点之间的误差相对于目标边界盒对角距离的平均误差来确定^[21]。将误差小于 1% 的配准视作成功配准。每次迭代的成功配准率是在所有测试集中进行至相应迭代次数时配准成功的次数与总配准测试次数的比值。图 7 所示为不同迭代次数下在测试数据集中的成功配准率。在进行 10 次迭代配准后,配准成功率达到 98% 左右。在实际使用时,可以根据要求的配准精度和配准成功率设置适当的迭代次数。实验显示在 5000 次左右的迭代训练后,训练误差减小至较为稳定的范围,且 10 次迭代配准的配准成功率接近最高值。

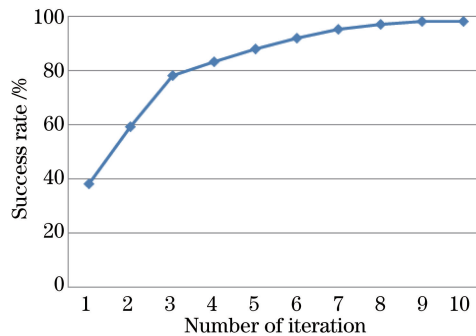


图 7 不同迭代次数下的成功配准率

Fig. 7 Registration success rate at different numbers of iteration

图 8 所示为在一次迭代中深度图像的变化,其中所有计算出的参数均在 X_1 上施加变换而保持 X_2 不变。由图 8 可知,通过先对 t_x 、 t_y 、 t_θ 进行配准,再对 t_a 、 t_β 进行配准,最后对 t_z 进行配准,配准难度被分解,在一次迭代后深度图像已基本配准,之后的迭代利用不同组的卷积神经网络输出不同范围的配准参数可以逐步提高配准的精度。

表 1 所示为 5 次和 10 次迭代后测试数据配准的均方根误差(RMSE)。可以看出,基于卷积神经网络的方法可以准确完成配准。由于不涉及形变, t_x 、 t_y 的配准误差远小于 t_z 的配准误差,对旋转角度的配准误差亦可接受。

图 9 所示为不同迭代次数下待配准点云到它们真实重心的投影方向 RMSE。投影方向 RMSE 越小,表明配准的精度越高。可以看出,配准误差在 5 次迭代之后已显著降低,表明该算法能够有效地完成点云配

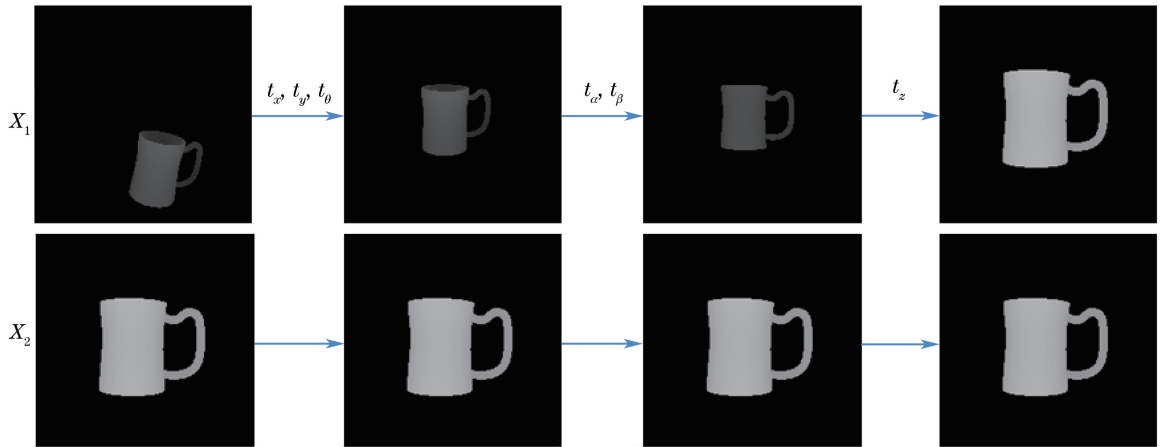


图8 一次迭代中参数逐步配准的过程

Fig. 8 Process of registration in one iteration

准,且对点云配准误差的降低主要发生在前几次迭代中。

表1 基于CNN的配准算法在5次和10次迭代后的RMSE

Table 1 RMSE of CNN based registration after 5 and 10 iterations

	t_x /mm	t_y /mm	t_z /mm	t_α /($^\circ$)	t_β /($^\circ$)	t_θ /($^\circ$)
Before registration	1.12	1.10	7.93	5.62	9.14	9.25
CNN (5 iterations)	0.08	0.07	0.49	0.14	0.30	0.31
CNN (10 iterations)	0.05	0.04	0.33	0.10	0.22	0.24

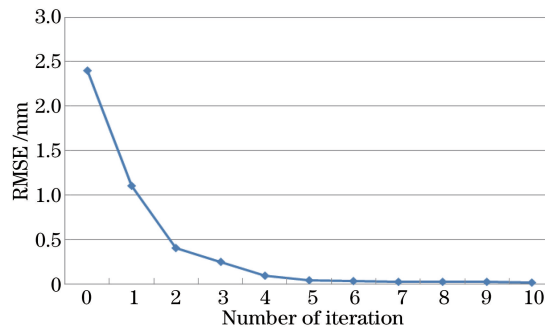


图9 不同迭代次数下待配准点云的投影方向 RMSE

Fig. 9 RMSE of point cloud to be registered in different numbers of iteration

基于卷积神经网络的点云配准方法相比于传统的点云配准方法(例如 ICP)最显著的优点是配准所需时间短。基于卷积神经网络的点云配准方法可用于实时配准。配准网络对每一对输入深度图像的迭代均耗费常数时间,因此完成配准所需总时间与迭代次数成正比例而与点云的规模大小及复杂程度无关。表2所示为不同输入点云大小规模下基于卷积神经网络的点云配准同 ICP 算法花费时间的比较。由表2可知,基于卷积神经网络的配准方法花费时间几乎为常数。

表2 CNN与ICP算法在不同数据规模下运行时间的比较

Table 2 Comparison of consumed time with different points in cloud between CNN and ICP

Points in cloud	Consumed time /s	
	ICP	CNN
3654	3.10	0.31
8750	7.83	0.31
12642	15.22	0.32
14155	17.79	0.32

最后利用基于卷积神经网络的点云配准方法,对实验室利用结构光三维扫描技术得到的点云进行了配准实验,实验结果如图10所示。实验首先使用基于结构光的三维扫描设备获取石膏像的两幅点云数据,两

幅点云数据分别包含 6607 和 5582 个空间点,对它们进行网格化,然后利用基于卷积神经网络的点云配准方法拍摄点云数据的深度图像,并利用卷积神经网络进行迭代配准,直至配准误差可以接受。由图 10 可知,基于卷积神经网络的点云配准模型能够有效地应用于实际中,在手持式 3D 扫描设备等对配准实时性要求较高的场合有较好的应用价值。




图 10 利用模型进行点云配准的实际效果。(a)(b)配准前;(c)配准后

Fig. 10 Actual effect of point cloud registration using the model. (a)(b) Before registration; (c) after registration

6 结 论

针对点云配准的问题提出了一种基于卷积神经网络的点云配准方法,通过一组卷积神经网络计算点云深度图像对的一组特征差,再以特征差向量作为输入,利用全连接的神经网络回归出配准所需参数,迭代地对不同参数按顺序进行配准。实验结果表明,基于卷积神经网络的配准方法能够较好地解决点云配准的问题,同时相较于传统的点云配准方法,计算量大大降低,配准所需时间减少,能够应用到对实时性要求较高的场合。本文将以卷积神经网络为核心的深度神经网络应用于点云配准领域。可以预见,今后以卷积神经网络为代表的深度学习方法将在对象识别、场景感知、图像生成乃至智能博弈等方面发挥更大的作用。

参 考 文 献

- [1] Nguyen T T, Liu Xiuguo, Wang Hongping, *et al.* 3D model reconstruction based on laser scanning technique[J]. *Laser & Optoelectronics Progress*, 2011, 48(8): 081201.
Nguyen T T, 刘修国, 王红平, 等. 基于激光扫描技术的三维模型重建[J]. *激光与光电子学进展*, 2011, 48(8): 081201.
- [2] Besl P J, McKay N D. Method for registration of 3D shapes[C]. *Robotics-DL tentative, International Society for Optics and Photonics*, 1992: 586-606.
- [3] Chen Y, Medioni G. Object modelling by registration of multiple range images[J]. *Image and Vision Computing*, 1992, 10(3): 145-155.
- [4] Blais G, Levine M D. Registering multiview range data to create 3D computer objects[C]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1995, 17(8): 820-824.
- [5] Wei Shengbin, Wang Shaoqing, Zhou Changhe, *et al.* An iterative closest point algorithm based on biunique correspondence of point clouds for 3D reconstruction[J]. *Acta Optica Sinica*, 2015, 35(5): 0515003.
韦盛斌, 王少卿, 周常河, 等. 用于三维重建的点云单应性迭代最近点配准算法[J]. *光学学报*, 2015, 35(5): 0515003.
- [6] Zuo Chao, Lu Min, Tan Zhiguo, *et al.* A novel algorithm for registration of point clouds[J]. *Chinese J Lasers*, 2012, 39(12): 1214004.
左超, 鲁敏, 谭志国, 等. 一种新的点云拼接算法[J]. *中国激光*, 2012, 39(12): 1214004.
- [7] Wu Mengqi, Li Zhongwei, Zhong Kai, *et al.* Adaptive point cloud registration method based on geometric features and photometric features[J]. *Acta Optica Sinica*, 2015, 35(2): 0215002.
伍梦琦, 李中伟, 钟凯, 等. 基于几何特征和图像特征的点云自适应拼接方法[J]. *光学学报*, 2015, 35(2): 0215002.
- [8] Huang Yuan, Da Feipeng, Tao Haiqi. An automatic registration algorithm for point cloud based on feature extraction

- [J]. Chinese J Lasers, 2015, 42(3): 0308002.
- 黄 源, 达飞鹏, 陶海脐. 一种基于特征提取的点云自动配准算法[J]. 中国激光, 2015, 42(3): 0308002.
- [9] Zhang Xiao, Zhang Aiwu, Wang Zhihua. Pointcloud registration based on improved normal distribution transform algorithm[J]. Laser & Optoelectronics Progress, 2014, 51(4): 041002.
- 张 晓, 张爱武, 王致华. 基于改进正态分布变换算法的点云配准[J]. 激光与光电子学进展, 2014, 51(4): 041002.
- [10] Yu Kai, Jia Lei, Chen Yuqiang, *et al.* Deep learning: yesterday, today, and tomorrow [J]. Journal of Computer Research and Development, 2013, 50(9): 1799-1804
- 余 凯, 贾 磊, 陈雨强, 等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展, 2013, 50(9): 1799-1804.
- [11] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[C]. Advances in Neural Information Processing Systems, 2012, 25(2): 1097-1105.
- [12] Deng J, Dong W, Socher R, *et al.* Image net: a large-scale hierarchical image database[C]. Proceedings of 2009 IEEE on Computer Vision and Pattern Recognition, 2009: 248-255.
- [13] Mikolov T, Deoras A, Povey D, *et al.* Strategies for training large scale neural network language models[C]. IEEE Workshop on Automatic Speech Recognition and Understanding, 2011: 196-201.
- [14] Silver D, Huang A, Maddison C J, *et al.* Mastering the game of Go with deep neural networks and tree search[J]. Nature, 2016, 529(7587): 484-489.
- [15] Le Cun Y, Kavukcuoglu K, Farabet C. Convolutional networks and applications in vision[J]. ISCAS, 2010, 14(5): 253-256.
- [16] Nair V, Hinton G E. Rectifiedlinear units improve restricted Boltzmann machines [C]. Proceedings of the 27th International Conference on Machine Learning, 2010: 807-814.
- [17] Kaiser M, John M, Heimann T, *et al.* 2D/3D registration of TEE probe from two non-orthogonal C-arm directions [C]. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2014: 283-290.
- [18] Glorot X, Bengio Y. Understanding the difficulty of training deep feedforward neural networks [C]. International Conference on Artificial Intelligence and Statistics, 2010, 9: 249-256.
- [19] Shilane P, Min P, Kazhdan M, *et al.* The princeton shape benchmark [C]. Proceedings of 2004 IEEE on Shape Modeling Application, 2004: 167-178.
- [20] Jia Y, Shelhamer E, Donahue J, *et al.* Caffe: Convolutional architecture for fast feature embedding[C]. Proceedings of the 22nd ACM International Conference on Multimedia, 2014: 675-678.
- [21] van de Kraats E B, Penney G P, Tomazevic D, *et al.* Standardized evaluation methodology for 2D-3D registration[J]. IEEE Transactions on Medical Imaging, 2005, 24(9): 1177-1189.