

尺度可变的快速全局点云配准方法

张琮毅 魏子庄 徐昊文 陈毅松 汪国平

(北京大学信息科学技术学院 北京 100871)

(北京市虚拟仿真与可视化工程研究中心 北京 100871)

摘 要 随着三维场景数字化技术的发展,人们获取真实物体三维点云模型的途径愈发丰富.通过设备采集或多视图重建得到的分片点云模型需要进行配准生成完整模型,而由于获取途径不同或设备误差影响,分片点云往往具有放缩尺度不一致,初始相对位置关系不可靠,特征错配率高且噪声较大等问题.本文提出了一种尺度可变的快速全局点云配准方法,从点云中首先提取局部特征信息并进行匹配,在特征匹配关系确定的情况下,交替优化目标函数中的不同分量,使之快速收敛至最优解.由于目标函数带有鲁棒核,从而对实际问题中不可避免的特征错误匹配所带来的干扰具备较大容错能力.此外,本文设计了完整的端对端点云匹配流程,提出了考虑尺度差异的局部特征匹配方法,且对于高维特征描述子 CSHOT 使用降维方法大幅提升匹配速度.本文在多种类型的数据中进行测试,实验结果表明,本文方法在处理尺度不一致的点云模型配准问题中兼具效率与效果优势,与点云的初始相对摆放位置无关,且对于噪声较大和特征错配率高的数据均具有稳定性.

关键词 点云配准;线性优化;局部特征描述子;特征匹配;目标函数

中图法分类号 TP391 **DOI号** 10.11897/SP.J.1016.2019.01939

Scale Variable Fast Global Point Cloud Registration

ZHANG Cong-Yi WEI Zi-Zhuang XU Hao-Wen CHEN Yi-Song WANG Guo-Ping

(School of Electronics Engineering and Computer Science, Peking University, Beijing 100871)

(Beijing Engineering Research Center for Virtual Simulation and Visualization, Beijing 100871)

Abstract With the development of digitalization of 3D scene, people can acquire 3D point clouds of real objects via various approaches. Point cloud patches generated by scanning or multi-view reconstruction need to be registered to produce the unified model. But because of different capture techniques or errors from devices, the point cloud patches usually have inconsistent scales, unreliable initial configurations, high ratio of spurious feature correspondences and large noises. In order to tackle these issues, we propose a scale variable method for fast global point cloud registration. First, we compute local features for point clouds and build correspondences among them. To attain more reliable correspondences, a simple yet effective criterion is devised to filter out ill-matched features based on the similarity of triangles. Second, with given correspondences, we alternatively optimize the objective function with regard to scaling factor, rotation, translation and the parameter in robust kernel to convergence. Due to the robust kernel in the objective function and the alternating optimization strategy, our method can resist inevitable erroneous correspondences. Furthermore, we devise an entire end-to-end framework for scale variable point cloud registration. Specifically, we compute the local features in a neighborhood with an adaptive radius according to

收稿日期:2018-09-06;在线出版日期:2019-04-08. 本课题得到国家重点研发计划课题(2017YFB1002601)、国家自然科学基金联合基金项目(61661146002)、国家自然科学基金重点项目(61632003)、国家海洋公益性项目(201505014-3)和装备预研基金项目(315050501)资助. 张琮毅,博士研究生,主要研究方向为计算机图形学、计算机视觉、人机交互. E-mail: cyzh@pku.edu.cn. 魏子庄,博士研究生,主要研究方向为计算机视觉. 徐昊文,硕士,主要研究方向为计算机图形学. 陈毅松,博士,副教授,主要研究方向为计算机视觉、图像处理. 汪国平(通信作者),博士,教授,博士生导师,中国计算机学会(CCF)会员,主要研究领域为计算机图形学、虚拟现实、人机交互. E-mail: wgp@pku.edu.cn.

point cloud size to make the Fast Point Feature Histogram (FPFH) and Color-Signature of Histograms of Orientations (CSHOT) scale invariant; we reduce the dimension of the CSHOT using principal component analysis to save memory and time consumption and downsample the large-scale point clouds to further speed up the feature computing and matching phases. Our method is firstly validated on synthetic range data with various scale differences. Experimental results show that our method can produce valid, consistent results when the scale differences from 2^{-10} to 2^{10} , and is resilient to different initial configuration and stable to large noises. Comparison with related work also demonstrates our efficiency and accurate in terms of root mean squared error. We also validate the proposed approach on large-scale, colored point clouds, which were obtained from multi-view reconstruction for urban reconstruction. Visually seamless results are obtained through a fully automatic process even with arbitrary initial relative positions and scales. We further discuss the effect of the feature dimension reduction and point cloud down sampling on the accuracy of feature matching. Then we evaluate the time costs of principal component analysis and feature matching, respectively, under different feature dimension reserved. By trading off the feature matching accuracy and time costs in computation, we adopt practical values for the number of feature dimension reserved and the number of down sampling of original point clouds to achieve valid results. Thirdly, we test our method on point clouds that are obtained from multi-view reconstruction and laser scanning respectively and the result shows that our method is also applicable to cross-source point cloud registration.

Keywords point cloud registration; non-linear optimization; local feature descriptor; feature matching; objective function

1 引 言

三维点云模型的配准是计算机图形学、计算机视觉和机器人领域共同关注的关键问题之一. 其应用范围涵盖摄影测绘学、数字化考古学和建筑学等各个学科. 在过去的几十年间有大量的工作针对不同的数据类型设计算法自动完成这一任务. 给定两片点云模型, 本文的目标是找出最优的空间变换使得它们的重叠部分对齐. 对齐后的两片点云可以进一步融合为一个点云模型, 以便进行后续的处理和计算, 例如语义分割和曲面重建等工作.

处理这一问题经典的迭代最近点 (Iterative Closest Point, ICP) 方法由文献[1]提出, 该方法不断在两个三维形状的当前相对位置关系下搜索最近点对, 在最小二乘意义下估计一个刚性变换以最小化这些点对的均方距离, 之后更新三维形状相对位置, 并迭代此步骤. 由于这一方法对处理实际问题十分有效且简便易实现, 它在许多相关问题中被广泛使用. 然而由于这一优化问题目标函数的非凸性质, 基于局部搜索的优化策略都极易陷入局部极小, 因

此两片点云的初始匹配精度和噪声程度极大影响了算法的结果. 当初值较差或噪声较大时, 采用基于局部搜索的 ICP 方法往往不能得到令人满意的配准结果.

基于全局优化的点云配准方法能够在一定程度上解决陷入局部极小的问题, 但是由于解空间随着点云规模增加而急剧增大, 导致在大规模点云模型的配准问题中迭代最近点算法效率严重下降. 近年来, 一些基于点云局部描述子建立特征点匹配的全局配准算法^[2-3]有助于解决效率问题, 能够处理大规模点云, 但未考虑待配准点云模型间的尺度差异. 而实际待拼接的三维点云数据由于获取途径不同和设备误差问题等, 往往不仅相差一个刚性变换, 尺度也并不一致, 这将严重影响刚性配准方法的结果. 特别地, 在大规模场景的配准问题中会因为尺度差异而导致传统的刚性变换配准方法在局部产生分层现象. 已有的点云配准全局求解框架并不能直接引入带尺度变换的自由度. 文献[4]在全局意义下讨论有尺度差异的点云与三角网格模型间的配准问题, 文献[5]利用抗尺度的特征描述子对两片 2.5 维深度点云数据快速匹配进而配准. 然而无论点云与离散

三角网格模型的配准问题还是两片深度点云间的配准问题,都无法直接推广到利用多视图重建等方法得到的三维点云数据中,面向三维点云的尺度可变的全局方法仍然是一项具有挑战的工作。

本文提出了一种允许尺度变化、与初始摆放位置无关且具有抗噪能力的快速全局点云配准方法,并通过大量实验证明该算法广泛适用于存在一定范围尺度差异、具有较高错配率、受不同程度噪声影响的点云数据,且与相关既有方法相比具有优势。

本文的创新点包括:

(1) 在点云刚性配准的全局能量优化框架中引入尺度参数,使其适用于尺度可变的全局配准问题,且能量优化收敛速度保持同一水平。

(2) 针对快速点特征直方图描述子(Fast Point Feature Histogram, FPFH)^[2]和带颜色的方向直方图签名描述子(Color-Signature of Histograms of Orientations, CSHOT)^[6],提出尺度具有差异的点云的特征描述和匹配方法。特别地,对高维描述子 CSHOT 提出有效的降维手段,有效降低匹配时间。

(3) 提出一套完整的全局点云配准框架,对于两片具有尺度差异的点云数据的配准具有实用价值。

2 相关工作

2.1 点云配准的局部方法

ICP 方法是一种局部搜索并迭代优化的方法,由于点云配准目标能量的高度非线性性,这一类方法在初值不准确时难以收敛至全局最小,也对噪声和重合区域占比较为敏感。后续的许多方法都在一定程度上克服了这些缺陷。文献[7]提出了利用 Levenberg-Marquardt 方法对衡量配准误差的目标函数进行非线性优化,其误差度量并不局限于二范数的形式,当采用某些鲁棒核(Robust Kernel)函数时,其方法具有一定的抗噪声能力。除鲁棒核外,通过在配准误差度量中加入点云法向、颜色^[8]等辅助信息,都有助于提高配准质量。此外,文献[9]将整体点云分解为多个子区域进行分别配准,再根据一致性准则求解统一的刚性变换,能够一定程度上克服重叠区域占比较少的问题。但由于迭代最近点算法的特点,这类方法对于大规模点云数据处理效率较低,且在有噪声的情况下收敛速度较慢。

文献[10]提出正态分布变换方法(Normal Distributions Transform, NDT),首先在空间区域

中划分均匀的网格,在每一格点中用正态分布函数拟合属于这一格点的点云,将另一点云模型添加到网格中并优化其位置使得其与该分布尽可能匹配。另外一些基于统计学的方法^[11-13]将两片点云的配准问题转化为概率密度函数的估计问题,通过最大似然估计方法以其中一片点云为模板构建高斯混合模型(Gaussian Mixture Model, GMM)去拟合另一片点云数据,从而实现点云配准。这类方法的好处是它们不像 ICP 一样要求建立两片点云模型间的点点对应,即避免了噪声等造成的错误对应问题,从而提升鲁棒性。由于这类配准工作的优化方法仍然基于从初值出发的局部优化以计算空间变换参数,因此当两片点云间初始位置较差或重合较少时,它们依然容易陷入局部极小。

2.2 点云配准的全局方法

为避免初值等因素的影响,出现了一些采用全局优化方法的点云配准工作,例如模拟退火方法^[14]、结合分支定界(Branch-and-Bound, BnB)策略的全局搜索方法^[15],从而找到两片点云间的配准误差度量函数的全局最小值。然而这些基于全局优化的 ICP 方法往往比局部方法耗时更久,无法处理较大规模的点云配准问题。为加速这一过程,一些方法利用定义在点云上的特征描述子进行特征空间的初始匹配,并根据这一匹配建立的对对应关系求解原始点云的匹配问题。文献[2]首先在点云中计算 FPFH,根据正确匹配应具有较强的空间变换一致性原理,用一致性采样初配的 SAC-IA 方法筛选出可靠匹配特征点对进行粗略配准,以粗配结果为初值再使用局部方法进一步求精。文献[3]采用同样的 FPFH 特征描述子提取方法并提出更为简单快速的匹配准则,适用以线过程(Line Process)与稳健统计(Robust Statistics)相结合的优化方法求解点云间刚性配准问题,其方法特点在于允许大量错误匹配的特征点对,且收敛速度快,适用于较大规模点云配准任务。然而其方法中未有允许尺度变化的讨论,而尺度不一致是在点云匹配的实际问题中经常出现的,在全局方法中平凡地引入尺度放缩因子会导致解空间维度增大且增强非线性程度而降低算法效率或是无法收敛至正确解。本文希望在点云配准的全局方法中引入尺度放缩因子,以扩展其处理问题的范围,进一步提高匹配精度。

2.3 尺度可变的点云配准方法

文献[16]通过推广刚性配准问题的 SVD 分解

方法^[17]提出了假定点云之间对应关系给定前提下,同时估计尺度放缩因子和旋转平移参数的方法.文献[18]在 ICP 算法的基础上,给出了估计各向同性尺度与迭代搜索最近点结合的 Scale-ICP 方法,不再要求对应关系给定.文献[19]进一步引入李群参数化方法并结合针对重叠区域的裁剪策略^[20]求解了各向异性的尺度放缩问题.然而作为局部方法,他们对于初值与噪声均较为敏感.文献[21]设计了一种点云自适应邻域并根据其局部形状信息进行匹配,为局部方法生成较为准确的初始位置的方法,但由于其匹配方法计算量大,因此算法耗时较长.文献[4]通过定义点到三角面片间的距离,采用差分进化算法进行全局优化得到配准结果,其方法不要求预先进行粗配提供初值;文献[5]将图像中抗尺度变化的 SIFT 特征描述子推广至深度点云数据进行不同尺度间点云的快速匹配.然而点到面片的鲁棒距离度量或是深度点云数据在一般点云数据中都无法应用,一般点云数据间带尺度差异的全局配准问题仍是一项未解决的重要问题.

3 算法概述

本文首先利用点云局部特征描述子对两片点云在全局意义下进行初始匹配,之后在匹配点对构成的集合上定义配准能量函数,通过优化该能量求得最优的缩放、旋转和平移参数.以下详细介绍问题定义与算法流程.

给定两个点集 P 和 Q ,假设可以在它们之间建立对应关系 $\mathcal{K} = \{(p, q) | p \in P, q \in Q\}$,本文希望找到最佳的缩放 s 、旋转 R 和平移 T ,使得对应点间的均方误差 (Mean Squared Error, MSE) 最小:

$$E(s, R, T) = \frac{1}{|\mathcal{K}|} \sum_{(p, q) \in \mathcal{K}} \|s \cdot Rq + T - p\|^2 \quad (1)$$

但是考虑到实际问题中通过特征匹配求得的 $\mathcal{K}$ 中可能存在相当比例的错误匹配,此时直接在最小二乘意义下优化式(1)得到的解将严重受到噪声影响.为兼顾鲁棒性与优化效率,本文借鉴文献[10]的优化框架,设计了一套快速全局配准方法以解决尺度可变的点云配准问题.为抵抗噪声,本文的优化目标函数可变为

$$E(s, R, T) = \sum_{(p, q) \in \mathcal{K}} \rho(\|s \cdot Rq + T - p\|) \quad (2)$$

其中 ρ 取为带缩放系数的 Geman-McClure 函数

$\rho(x) = \frac{\mu x^2}{\mu + x^2}$,它表示一种对误差的度量,相比于均

方误差具有更好的抗噪性.当其中参数 μ 较大时, $\rho(x)$ 受较大范围的自变量变化影响,而随着 μ 的减小, $\rho(x)$ 将更容易受到较小 x 的影响,从而将距离较大的匹配点对作为异常点(outlier)无效化.

围绕优化式(2)为核心,本文提出点云配准的端对端完整流程如图 1 所示.




图 1 本文方法流程示意图

首先在点云 P 和 Q 中分别计算局部特征描述子,随着点云规模的增大,这一步计算量往往也较大.因此当点云规模较大时,在两片输入点云中分别采样一定比例的点作为计算局部特征的种子点,对于原始点云模型仅在这些点处计算特征.

本文所提出的处理框架适用于快速点特征直方图 FPFH 和带颜色的方向直方图签名 CSHOT 这两种局部特征描述子,在处理实际问题时本文根据数据类型更换不同的局部特征以得到可靠且数量充足的特征匹配.为增强特征匹配的可靠性,本文不仅对特征空间中的最近特征点对进行交叉检查,还针对三维空间尺度可变问题设计了基于相似三角形的一致性准则对随机选出的成对特征三元组进行验证(详见第 4 节).此外,随着特征的描述性增强,CSHOT 特征的维度相比 FPFH 也大幅增加,配准算法时间开销也较大,但由于待配准点云数据相似度较高,因此特征描述子在高维空间的分布也具备共性,其整体具有较大的降维压缩空间.因此首先将两片点云分别提取的 CSHOT 特征描述子合并在一起,采用主成分分析(Principal Components Analysis, PCA)方法提取出其若干个较显著分量张成低维特征子空间,从而达到降维加速匹配的目的.以降维后的低维特征描述子,再根据本文提出的匹配策略进行特征匹配得到对应关系集合 $\mathcal{K}$,本文将在结果部分中详细讨论这一方法的有效性.

将特征空间建立的匹配关系代入式(2)中可进行配准优化。但由于直接对各变量求偏导所得的梯度形式复杂,非线性程度高,想要对式(2)进行快速优化是一件困难的工作,本文第5节中将详细讨论该问题的快速优化方法。

最后,考虑到根据特征点对应集合 $\mathcal{K}$ 优化得到的最佳的缩放 s 、旋转矩阵 $\mathbf{R}$ 和平移 $\mathbf{T}$ 仅针对给定的特征匹配关系最优,并不一定作用在原点云 P 和 Q 上得到最优的点云匹配结果,本文将进一步以当前求得的变换作为初值,采用带尺度变化的 Scale-ICP 方法^[18]对点云 P 和 Q 进行进一步精准匹配。

本文将在第4节介绍特征降维与匹配方法以求得高质量的匹配点对集合;之后在第5节介绍目标函数的高效优化方法;在第6节展示本文方法的实验结果;最后在第7节总结和展望未来工作。

4 点云局部特征的降维与匹配

如前所述,特征对应关系 $\mathcal{K}$ 由点云局部特征描述子匹配决定,本节将讨论特征提取与匹配的细节。

对于点云 P 和 Q ,记它们的特征分别为 $\mathbf{F}(P)=\{\mathbf{F}(p):p\in P\}$ 和 $\mathbf{F}(Q)=\{\mathbf{F}(q):q\in Q\}$ 。本文采用如下匹配方法进行两片点云之间的匹配,可分为三步:

Step 1. 对每一个 $p\in P$,在集合 $\mathbf{F}(Q)$ 中查询与 $\mathbf{F}(p)$ 的 L_2 距离最近的 $\mathbf{F}(q)$,将所有这样的点对 (p,q) 加入集合 $\mathcal{K}_1$ 。

Step 2. 对集合 $\mathcal{K}_1$ 中的每一对 (p,q) ,如果 $\mathbf{F}(p)$ 同时是 $\mathbf{F}(q)$ 在 $\mathbf{F}(P)$ 中的最近点,则将这点对加入集合 $\mathcal{K}_2$ 。

Step 3. 在集合 $\mathcal{K}_2$ 中随机采样的3对点,记为 $(p_1, q_1), (p_2, q_2), (p_3, q_3)$,将 $\{p_1, p_2, p_3\}$ 和 $\{q_1, q_2, q_3\}$ 构成的三角形分别记为 T_p 和 T_q ,根据其匹配关系导出的对应边分别记为 $\{a_1, a_2, a_3\}$ 和 $\{b_1, b_2, b_3\}$,

计算对应边长间的比例 $\lambda_i = \frac{\|a_i\|}{\|b_i\|}$,验证:

$$\tau < \frac{\lambda_i}{\lambda_j \lambda_k} < \frac{1}{\tau}, \quad \forall \{i, j, k\} = \{1, 2, 3\},$$

其中 $\tau < 1$ 为一给定阈值。当上式成立时,将这3对点都加入匹配点对集合 $\mathcal{K}$ 。

由于尺度的不一致,正确的匹配关系应当能够保证步骤3中的三角形 T_p 和 T_q 相似(如图2所示),因此步骤3的验证过程实质上是在检查它们之间的相似性。在本文的实现中, τ 统一取值0.95。




图2 相似性匹配准则示意图

根据文献[6]中提出的分类法与相关讨论,特征描述子主要可分为签名(Signature)和直方图(Histogram)两类,Signature 具有较强描述性,而Histogram 具有较强鲁棒性。鲁棒性强的特征(如FPFH等直方图特征)在本文提出的匹配准则下往往能找到较多的匹配但其中错误匹配占比也较大,描述性较强的签名特征则往往能够得到较为精准的匹配结果但成功匹配的数目较少。针对不同类型的点云数据往往需要选择不同的特征描述子以得到足够多的匹配数目和其中一定比例的正确匹配关系,以保证后续配准算法的优化结果可靠。

综合考虑特征子计算复杂度与适用范围,本文对于无颜色的点云数据采用FPFH特征;而对于有颜色的点云数据采用带颜色的SHOT特征(CSHOT)以提高其匹配准确率。具体地,在每个采样点周围以半径 r 建立包围球。FPFH描述子先计算采样点处的法向,再分别计算包围球中其余点的法向及它们与采样点法向的角度差,将差异欧拉角的3个分量各自分为11个区间,统计直方图记为SPFH。最后计算当前采样点的SPFH与其包围球内其余采样点的SPFH加权和(权重为距离的倒数),构成33维的FPFH特征。而CSHOT描述子将包围球沿径向分为2份,沿经度分为8份,沿纬度分为2份,共划分32个空间格点,在每一格点内统计形状信息并分为11个区间构成直方图,统计颜色信息并分为31个区间构成直方图,于是该描述子共计1344维。注意到这两种特征均未用到绝对距离度量描述采样点及其邻域内的性质,因此它们对于尺度的变化不敏感,从而适用于变尺度上下文中的特征匹配算法。

本文的匹配方法的Step1和Step2需要在集合

$\mathbf{F}(P)$ 和 $\mathbf{F}(Q)$ 中进行多次最近点查找,本文采用目前对高维数据最高效的优先搜索 k -平均树算法^[22]对这一查找过程进行加速,根据其算法复杂度分析,该方法建树和查询的复杂度均与特征描述子维数成正比.此外,记点云规模为 n ,则建树复杂度与 $n \log n$ 成正比,查询复杂度与 $\log n$ 成正比.因此,大规模点云的 CSHOT 描述子的匹配过程往往需要相当长的时间,成为本文端对端处理过程的速度瓶颈.

实际上,待配准的两片点云由于表达的三维形状具有相似性,因此 CSHOT 特征描述子在高维空间的分布具有一定规律,利用这一特点,可以对其进行有效的降维压缩处理,从而加快匹配效率.

将 P 与 Q 中提取的 CSHOT 特征描述子分别记为 $N_P \times 1344$ 和 $N_Q \times 1344$ 维的两个矩阵 $\mathbf{F}_P$ 和 $\mathbf{F}_Q$,其中 N_P 和 N_Q 分别是 P 和 Q 中计算特征的采样点数目.将其按行拼合在一起得到合并的 $(N_P + N_Q) \times 1344$ 描述子矩阵 $\mathbf{F}$ 后对其进行 PCA,取其前 d 个特征值对应的特征向量,将 $\mathbf{F}_P$ 和 $\mathbf{F}_Q$ 投影到这些特征向量张成的 d 维子空间中以达到降维目的.具体地,将这些特征向量按对应特征值从大到小的顺序列为 $1344 \times d$ 维的矩阵 $\mathbf{B}$,分别计算 $\mathbf{F}_P \cdot \mathbf{B}$ 和 $\mathbf{F}_Q \cdot \mathbf{B}$ 作为降维后的特征.在实验部分,本文将讨论 d 的取值对特征匹配带来的效果与效率影响,并依据实验与分析给出取值建议.

5 目标函数的高效优化方法

文献[3]给出了不考虑尺度变化($s=1$)时对式(2)的优化方法,但引入尺度放缩变量 s 后,由于无法以线性方程近似表示空间变换的增量(存在关于优化变量的二次项),因此该方法无法直接应用.本节将对其求解框架进行改进,在不增加算法复杂度的情况下同时对放缩变量 s 进行优化.为保证本文论述的完整性,以下内容将包含对原求解框架的介绍.

首先,文献[23]通过将线过程(Line Process)与稳健统计(Robust Statistics)相结合给出了求解式(2)的方法:通过构造特征点对应关系 $\mathcal{K}$ 上的权重集合(线过程) $\mathbb{L} = \{l_{p,q}\}$,从而优化关于变量 $s, \mathbf{R}, \mathbf{T}$ 和 $\mathbb{L}$ 的联合目标函数:

$$E(s, \mathbf{R}, \mathbf{T}, \mathbb{L}) = \sum_{(p,q) \in \mathcal{K}} l_{p,q} \|s \cdot \mathbf{R}q + \mathbf{T} - p\|^2 + \sum_{(p,q) \in \mathcal{K}} \Psi(l_{p,q}) \quad (3)$$

其中 $\Psi(l_{p,q})$ 是一个先验函数,取为

$$\Psi(l_{p,q}) = \mu(\sqrt{l_{p,q}} - 1)^2.$$

为优化 $E(s, \mathbf{R}, \mathbf{T}, \mathbb{L})$,先将它关于 $l_{p,q}$ 求偏导

并令导数为零,整理得到使得目标函数最小的 $l_{p,q}$:

$$l_{p,q} = \left(\frac{\mu}{\mu + \|s \cdot \mathbf{R}q + \mathbf{T} - p\|^2} \right)^2 \quad (4)$$

其中 $s, \mathbf{R}$ 和 $\mathbf{T}$ 使用当前迭代步的值而被视为固定项,从 $l_{p,q}$ 的表达式中可以看出,当前迭代步中最优的 $l_{p,q}$ 与两片点云对应点的距离反相关,从而作为该对应点的权重项趋向于将错误匹配的点对无效化.随着优化迭代的进行,逐渐减小 μ 的取值可以在优化中不断降低噪声和异常点的影响.注意到将式(4)代入优化目标 $E(s, \mathbf{R}, \mathbf{T}, \mathbb{L})$,该式将与式(2)形式一致.这表示使得优化目标式(3)最小的一组 $s, \mathbf{R}$ 和 $\mathbf{T}$ 同样也是原优化目标(2)的解.

接下来将权重 $l_{p,q}$ 视为固定值,交替优化其余变量,舍掉此时的常数项 $\Psi(l_{p,q})$,目标能量可被整理为

$$\tilde{E}(s, \mathbf{R}, \mathbf{T}) = \sum_{(p,q) \in \mathcal{K}} l_{p,q} \|s \cdot \mathbf{R}q + \mathbf{T} - p\|^2 \quad (5)$$

对 $\mathbf{T}$ 求偏导后令导数等于零得到

$$\mathbf{T} = \frac{\sum_{(p,q) \in \mathcal{K}} l_{p,q} p - s \cdot \mathbf{R} \sum_{(p,q) \in \mathcal{K}} l_{p,q} q}{\sum_{(p,q) \in \mathcal{K}} l_{p,q}} = \hat{p} - s \cdot \mathbf{R} \hat{q},$$

其中 $\hat{p} = \frac{\sum_{(p,q) \in \mathcal{K}} l_{p,q} p}{\sum_{(p,q) \in \mathcal{K}} l_{p,q}}$ 和 $\hat{q} = \frac{\sum_{(p,q) \in \mathcal{K}} l_{p,q} q}{\sum_{(p,q) \in \mathcal{K}} l_{p,q}}$,将 $\mathbf{T}$ 代入式(4),得到

$$\tilde{E}(s, \mathbf{R}) = \sum_{(p,q) \in \mathcal{K}} l_{p,q} \|s \cdot \mathbf{R}(q - \hat{q}) - (p - \hat{p})\|^2 = \sum_{(p,q) \in \mathcal{K}} \|s \cdot \mathbf{R} \tilde{q} - \tilde{p}\|^2,$$

其中 $\tilde{q} = \sqrt{l_{p,q}}(q - \hat{q})$, $\tilde{p} = \sqrt{l_{p,q}}(p - \hat{p})$. 这表示对 s 和 $\mathbf{R}$ 的内层优化可等价于对两片新的点云 $\tilde{P}$ 和 $\tilde{Q}$ 进行配准.这一问题可以用 SVD 方法直接求解^[11],然而由于优化过程中初始迭代步中的 $\tilde{P}$ 和 $\tilde{Q}$ 具有较大噪声且 $l_{p,q}$ 随着优化不断变化, SVD 方法在不同迭代步中会解得剧烈变化的结果,而严重偏离目标的空间变换会产生错误估计的 $l_{p,q}$,从而使算法收敛至错误结果.根据问题特点,本文希望使用梯度下降法迭代求解而非利用闭形式求解,因此为了使 $\mathbf{R}$ 在 $SO(3)$ 的旋转矩阵空间中根据其三个自由度进行梯度下降,将其在当前迭代步的旋转增量表示为空间的欧拉角 $\omega = (\alpha, \beta, \gamma)^T$,于是可将第 k 个迭代步求得的 $\mathbf{R}$ 近似表示为

$$\mathbf{R} \approx \begin{bmatrix} 1 & -\gamma & \beta \\ \gamma & 1 & -\alpha \\ -\beta & \alpha & 1 \end{bmatrix} \mathbf{R}^{k-1},$$

其中 $\mathbf{R}^{k-1}$ 为第 $k-1$ 迭代步求得的旋转,初始的 $\mathbf{R}^0$

为单位阵. 该近似表示使用了 $\sin x \sim x, \cos x \sim 1$. 这是由于每一迭代步旋转角度较小从而能够舍弃精确计算式中的高阶无穷小量.

由于旋转 $\mathbf{R}^{k-1}$ 是已知量, 并暂时将 s 视为常量, 于是利用 Gauss-Newton 方法, ω 可以通过求解如下线性方程组得到:

$$\mathbf{J}_r^T \mathbf{J}_r \omega = -\mathbf{J}_r^T \mathbf{r},$$

其中 $\mathbf{r}$ 是剩余向量而 $\mathbf{J}_r$ 是它的 Jacobian 矩阵.

此后再对 s 求导, 令导数等于零得到:

$$s = \frac{\sum_{(p,q) \in \mathcal{K}} \tilde{p}^T \mathbf{R} \tilde{q}}{\sum_{(p,q) \in \mathcal{K}} \|\tilde{q}\|^2}.$$

最后再利用优化后的 s 和 $\mathbf{R}$ 将平移 $\mathbf{T}$ 更新为

$$\mathbf{T} = \hat{p} - s \cdot \mathbf{R} \hat{q}.$$

从而通过交替优化 $\mathbb{L}, \mathbf{T}, s$ 和 $\mathbf{R}$, 同时每个迭代步将 μ 缩小为原值的 0.9 倍, 在 μ 从包围盒对角线平方变化至两正确匹配点间距离阈值平方时, 能够将 P 和 Q 两片点云配准. 实际中一般迭代 50 步以内即可得到较好的结果.

为证明本文方法的收敛性, 首先将式(3)在第 t 步的值记为 $E^t(s^t, \mathbf{R}^t, \mathbf{T}^t, \mathbb{L}^t, \mu^t)$, 由于交替优化过程中每一步都保证目标函数值下降, 因此有

$$E^t(s^t, \mathbf{R}^t, \mathbf{T}^t, \mathbb{L}^t, \mu^t) >$$

$$E^{t+1}(s^{t+1}, \mathbf{R}^{t+1}, \mathbf{T}^{t+1}, \mathbb{L}^{t+1}, \mu^{t+1}) > \dots > 0.$$

这表示目标函数值序列 $\{E^t\}_{t \geq 1}$ 单调递减且有下界, 从而收敛. 需要注意的是, 该收敛并不能保证收敛于能量函数的全局最小值, 但本文实验部分将表明该收敛值相比于其他方法为后续的精准配准 (Scale-ICP) 提供了更好的初值, 在不同尺度不同噪声的数据集中本文方法均可稳定得到令人满意的最终解.

6 实验结果

本文方法采用 C++ 实现, 除特征提取步骤使用 CPU 并行外, 其余算法均为 CPU 单线程实现. 本文实验平台为 Intel i5 3450 处理器搭配 8 GB 内存. 首先将本文方法在文献[3]提供的合成数据集进行了测试, 这一数据集包含无噪声、噪声标准差为 0.0025 的高斯噪声以及噪声标准差为 0.005 的高斯噪声各 25 组数据, 其中标准差为在模型直径归一化下的数值. 它们的重叠区域占比为 47% 至 90% 不等. 由于该测试数据不具有颜色信息, 特征描述子均采用 33 维的 FPFH, 其计算半径设为模型包围盒对角线的 10%. 由于这一数据集的测试数据间并没有


尺度差异, 本文方法首先在无尺度差异的实验中取得与文献[3]基本一致的精度和时间效率.

其中一组噪声数据的初始摆放如图 3(a) 所示, 浅灰色为固定的参考点云, 深灰色为待配准点云, 标准差为 0.0025. 图 3(b) 为本文方法配准的结果, 展示了这一例子中本文方法与 FGR^[3]、Go-ICP^[15] 和 Scale-ICP^[18] 的收敛速度对比实验, 如图 3(c) 所示. 其中均方根误差 (Root Mean Squared Error, RMSE) 的计算方式为在数据集提供的深灰色点云真实值 (ground-truth) 与优化结果值间根据逐点一一对应计算并对模型对角线长度做归一化. 从图 3(c) 中可以看出, 本文方法对于初始匹配较差但尺度一致的带噪声点云配准问题相比 Go-ICP 和 Scale-ICP 使用更少的迭代步数, 与 FGR 方法比较无明显差异. 可见本文虽增加了尺度变化的自由度, 但是在无尺度变化的配准问题中保持与 FGR 方法基本一致的收敛率. 由于本文与 FGR 方法均不更换匹配点, 于是在每个迭代步中不涉及搜索最近点的操作, 因此本文方法不仅收敛速度较快, 且每一迭代步的时间开销远小于 ICP 相关方法, 于是该实验结果可以证



(a) 输入点云

(b) 本文方法配准结果



(c) 收敛速度对比

图 3 四种点云配准方法收敛速度对比

明本文方法对于测试数据与 ICP 相关方法比较兼具效率和效果优势.

为验证本文方法对于尺度变化数据的有效性,并可视化对比结果,本文将数据集中一组无噪声的数据和一组标准差为 0.0025 的数据做手动的尺度变化,对图 4(a)中的深灰色点云整体乘以 1.2 倍的放缩系数.为使得对比更为公平,本文在所对比的每一方法后增加 Scale-ICP 局部迭代优化算法来增加这些算法对尺度变化点云的处理能力.实验结果如图 4 所示,由深色至浅色的过渡表示点云中每点与其 ground-truth 位置距离的近到远.由于存在尺度

差异,且初始相对位置关系相差较大,重合区域约 60%,可以看出 FGR 与 Go-ICP 搭配 Scale-ICP 均无法得到精确的配准结果.而本文方法无论从视觉还是数值上都取得了较好效果.这是由于 FGR 与 Go-ICP 在全局配准过程中并未考虑尺度差异这一因素,因此即便是很小的尺度差异都会造成较大的错配,即便 Scale-ICP 在其输出结果的基础上进行了考虑尺度差异的精确配准,仍无法收敛于合适的配准位置.本文方法在全局配准过程中即考虑了尺度差异,因此提供给 Scale-ICP 足够好的初值,使其收敛于更为精准的配准位置.




图 4 尺度可变的点云配准问题不同方法

本文将文献[3]合成数据集中的无噪声、噪声标准差分别为 0.0025 和 0.005 的全部 25 组数据中待配准点云的放缩尺度从 $\frac{1}{3}$ 到 3 之间以 $9^{\frac{1}{5}}$ 为公比等比采样 50 个值,分别执行本文优化方法并设置总迭代步数为 128 步(不执行 Scale-ICP 后处理),不同噪声下其 25 组数据在每一尺度差异的 RMSE 平均值如图 5 所示.该组测试数据在无尺度变化下,采用 FGR 优化得到的基准 RMSE 平均值在图中用单点标出,分别为 0.0043、0.0064 和 0.0115.本实验中特征描述子均为 FPFH 且计算半径均为各自点云包围盒对角线的 10%.可以看出,本文方法在不同放




图 5 本文算法在点云数据集中不同尺度差异下的 RMSE

缩尺度情况下的实验均取得了可与无放缩变化的基准测试相当的结果. 由于本文采用了各点云包围盒对角线作为 FPFH 特征描述子估计半径的参考, 因此实际上对于不同尺度的点云采用了大小不同的半径计算, 这一策略使得 FPFH 特征描述子具备尺度无关的描述能力.

上述实验的各步骤时间开销如表 1 所示, 可以看出本文方法的平均配准总时间较低, 其中特征提取与匹配占据了超过 95% 的时间, 能量优化步骤具有较高的效率.

表 1 本文方法各步骤时间开销 (单位: ms)			
特征提取	特征匹配	优化能量	总计
1379	1471	137	2987

为验证本文方法对于较大范围缩放尺度变化的鲁棒性, 在 2^{-10} 到 2^{10} 间等比采样 100 个尺度放缩值, 分别对图 4 所示的配准数据中的深灰色点云进行放缩, 运行本文优化算法得到其 RMSE 数据作图 6. 这一实验证明了基于合理估计半径的 FPFH 能够对具有极大尺度差异的点云进行匹配. 而基于合理的半径估计策略, 本文方法能够处理大范围的尺度变化, 在无噪声时表现出较好的稳定性, 低噪声时有小幅变化, 但整体配准误差仍然较小.




图 6 尺度差异较大时本文方法的 RMSE

如图 7 所示, 希望对两片分别通过无人机航拍彩色图像重建得到的带颜色信息的城市场景点云数据进行匹配, 其重叠区域在各自点云中占比约 30%, 为方便后文描述, 设其包围盒对角线为 1. 由于这类城市场景数据量往往较为庞大(分别包含 87 万和 93 万点), 本文各在其中均匀采样 10 万种子点进行特征描述子的计算. 针对图 7 所示的大规模彩色点云模型, 本文首先统一以 0.05 为特征描述子, 计算半径分别提取其 FPFH 特征与 CSHOT 特征, 特征匹配的准确率分别为 1.3% 和 68.4%. 这里匹配准确率的定义为: 当两片点云准确匹配时, 特征点

对间距离小于 0.01 的点对个数除以总特征点对的个数. 由此可见, FPFH 无法提供可靠的匹配, 而 CSHOT 可大幅提升匹配准确率. 这是由于带颜色的 SHOT 特征对于具有颜色信息的大规模点云数据以增大维度为代价提供了更丰富全面的信息, 而在颜色一致性较好的上下文中更容易找到准确匹配, 因此相比 FPFH 能够降低错配率. 然而由于本文计算的 CSHOT 维度高达 1344 维, 直接匹配这样大规模的高维数据所使用的辅助数据结构将消耗超过 3GB 内存, 耗时超过 2 h. 为减少计算开销, 正如本文第 4 节所述, 希望对其进行降维.




图 7 带颜色信息的点云示例

本文将 P 与 Q 的 SHOT 特征拼合在一起后进行 PCA, 提取其中前 60 个主方向对应点特征值, 并将其值可视化如图 8 所示. 从图 8 中可以看出其特征值在第 30 个分量之后已经衰减到 0.005 以下, 实际上经过计算前 30 个特征值之和占全部特征值之和的 40%, 这表示剩余 1314 维的每个维度只包含很少的有效信息(平均每一维不多于 0.046%). 为验证这一观察, 本文进行了将原始维度的 CSHOT 进行 PCA 降维至不同维度的实验并记录其准确率和对应的时间开销.




图 8 前 60 个主方向对应的特征值

本文对于 CSHOT 降维至不同维度后的特征匹配进行了验证,图 9(a)展示了从 10 维到 620 维每 10 维的降维匹配准确率变化曲线,以配准结果而言,本文在特征匹配准确率超过 30% 的点集合中均可得到准确的匹配结果,结合图 9(b)中展示的时间开销变化曲线,权衡特征匹配随维度增加而显著上升的时间开销,本文将使用 30 维为降维目标维度.值得注意的是,降维至 30 维的 CSHOT 特征具有比 33 维的 FPFH 更高的匹配准确率.




图 9 利用 PCA 降维至不同维度的特征匹配实验

当点云中点数较多时,本文还采用了降采样的方式对特征计算、匹配过程进行加速.需要注意的是,本文降采样后计算特征是在原点云中采样点的位置计算特征,计算时仍然使用原点云的信息,而非在降采样后较稀疏的点云上计算特征进行匹配,这样的好处是保持原点云的分布特点,同时能够快速稳定地计算特征.不同采样数目的匹配准确率与各步骤时间开销如图 10 所示,其中特征降维的维度选取为 30 维.权衡随着采样数目上升而显著增加的匹配时间开销,本文采用 10 万点为本文后续实验中的降采样点数.

图 7 中展示的带颜色信息城市场景重建模型的配准结果如图 11 所示,选取图 11(a)中白色矩形内




图 10 不同采样数目的特征匹配实验




图 11 带颜色信息点云匹配结果

的区域以放大的新视角显示如图 11(b),可以看出两片点云较好地融合成一片,优化得到其待配准点云到目标点云的缩放比例为 1.012,如果不考虑这一尺度差异,在城市场景配准中往往会出现某些建筑上明显的点云分层现象,而本文方法通过变化尺度解决了点云分层问题,进一步降低了误差。

本文方法在大量带颜色信息的城市场景点云数据中进行了测试,均取得了满意的配准结果,以下为另一真实数据的展示。

图 12 所示是一个更具挑战性的例子,这是通过无人机航拍重建得到的三维点云模型,由于拍摄条件不同而分为两片重建。点云 P 包含 174 674 个点,点云 Q 包含 380 727 个点,从中分别均匀采样 10 万点,在这些点处计算 1344 维 CSHOT 特征,并降维至 30 维,特征匹配集合 K 大小限制为 6000 对匹配点,在此基础上进行目标函数优化,并最终用全部点进行 Scale-ICP 后处理。整个处理流程共计用时 193 s,其中计算特征描述子共计用时 55.7 s,匹配用时 99.5 s,目标函数优化用时 0.664 s,Scale-ICP 用时 37.1 s。由于图 12(a)中点云 P 与图 12(b)中点云 Q




图 12 带颜色信息大规模场景点云匹配结果

相比较为稀疏且重合区域多为树木,因此特征匹配阶段存在大量错配信息,但本文方法依然能够稳定收敛得到精确配准的结果(图 12(c)、(d)所示)。

对于大规模场景的重建通常需要将照片按照拍摄区域分为不同组分别进行运动恢复结构(SfM)生成三维稀疏点云,而 SfM 生成的分片稀疏点云间由于坐标系选取不同而存在尺度与相对位置不一致的问题,因而是一个非常适合用于验证本文提出的变尺度点云配准的重要应用。利用本文方法对 SfM 重建得到的两片稀疏点云进行配准,配准参数与图 12 例子相同,结果如图 13(c)所示。优化结果显示其尺度差异为 1.7156,本文方法对其进行了正确的配准,未有点云分层现象产生。





图 13 带颜色信息大规模场景特征点云匹配结果

利用本文方法亦可将激光扫描的点云数据与多视图重建得到的点云数据进行配准,如图 14 所示。这组数据来自于标准数据集 Tanks and Temples^[24],其尺度差异为 1.572。其多视图重建点云匹配真实值与激光扫描点云间的均方根误差是 0.164 653,本文方法的均方根误差为 0.166 119,误差可视化如图 14 所示,深色代表误差较低。本文方法除在 SfM 重建数据中裁剪出目标区域外无其他人工过程。



(a) 激光扫描重建的点云模型

(b) COLMAP^[25, 26]方法重建的点云模型

(c) 配准后的误差可视化

图 14 不同生成方式的点云模型配准结果

7 结 语

本文提出了一种尺度可变的全局快速点云配准算法,并设计了完整的端对端三维点云匹配流程,在实验结果中展示了其处理各种数据的效果与效率,且与相关方法比较具有一定优势。

以下将就本文的局限性与未来可能的研究方向进行讨论。首先,本文配准结果依赖于特征匹配结果,因此选取一种好的特征描述子也是决定配准效

率和结果的重要因素。对于尺度相差较为悬殊的点云配准问题,本文方法以包围盒尺度估计了计算特征子的半径尺度从而使得 FPFH 与 CSHOT 具有在不同尺度点云间进行匹配的能力。对于一般问题,仍需要一种能够快速计算抗尺度变换的局部特征描述子才能够得到较好的匹配结果。一种可能的解决方案是,对点云采用不同邻域半径分别计算特征,然后在其中选取匹配点对最多的半径作为特征子计算半径。其次,本文仅考虑两片点云模型的带尺度配准问题,从全局角度联合优化多块尺度不一致点云的配准误差将是未来的重要研究方向。最后,本文从实际问题出发,将各向同性的尺度变化引入全局配准方法中,而考虑各向异性尺度变化的全局方法并不能直接推广得到,解决这一问题将具有一定理论价值。

致 谢 感谢审稿专家老师对本文提出的宝贵意见和建议,帮助作者对本文进行提炼与完善。感谢香港大学王文平教授和杨磊博士的支持与帮助!

参 考 文 献

- [1] Besl P J, McKay N D. A method for registration of 3-D shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1992, 14(2): 239-256
- [2] Rusu R B, Blodow N, Beetz M. Fast point feature histograms (FPFH) for 3D registration//*Proceedings of the IEEE International Conference on Robotics and Automation*. Kobe, Japan, 2009: 3212-3217
- [3] Zhou Q Y, Park J, Koltun V. Fast global registration//*Proceedings of the European Conference on Computer Vision*. Amsterdam, The Netherlands, 2016: 766-782
- [4] Urfahoglu O, Mikulastik P, Stegmann I. Scale invariant robust registration of 3D-point data and a triangle mesh by global optimization//*Proceedings of the International Conference on Advanced Concepts for Intelligent Vision Systems*. Antwerp, Belgium, 2006: 1059-1070
- [5] Sehgal A, Cernea D, Makaveeva M. Real-time scale invariant 3D range point cloud registration//*Proceedings of the International Conference Image Analysis and Recognition*. Povia de Varzim, Portugal, 2010: 220-229
- [6] Salti S, Tombari F, Stefano L D. SHOT: Unique signatures of histograms for surface and texture description. *Computer Vision and Image Understanding*, 2014, 125: 251-264
- [7] Fitzgibbon A W. Robust registration of 2D and 3D point sets. *Image and Vision Computing*, 2003, 21(13): 1145-1153
- [8] Park J, Zhou Q Y, Koltun V. Colored point cloud registration

- revisited//Proceedings of the IEEE International Conference on Computer Vision. Venice, Italy, 2017: 143-152
- [9] Han Bao-Chang, Cao Jun-Jie, Su Zhi-Xun. Automatic point clouds registration based on regions. *Journal of Computer-Aided Design & Computer Graphics*, 2015, 27(2): 313-319 (in Chinese)
(韩宝昌, 曹俊杰, 苏志勋. 一种区域层次上的自动点云配准算法. *计算机辅助设计与图形学学报*, 2015, 27(2): 313-319)
- [10] Biber P, Strasser W. The normal distributions transform: A new approach to laser scan matching//Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems. Las Vegas, USA, 2003: 2743-2748
- [11] Chui H, Rangarajan A. A feature registration framework using mixture models//Proceedings of the IEEE Workshop on Mathematical Methods in Biomedical Image Analysis. Hilton Head Island, USA, 2000: 190-197
- [12] Myronenko A, Song X. Point set registration: Coherent point drift. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 32(12): 2262-2275
- [13] Lin Gui-Chao, Tang Yun-Chao, Zou Xiang-Jun, et al. Point cloud registration algorithm combined Gaussian mixture model and point-to-plane metric. *Journal of Computer-Aided Design & Computer Graphics*, 2018, 30(4): 642-650 (in Chinese)
(林桂潮, 唐昀超, 邹湘军等. 融合高斯混合模型和点到面距离的点云配准. *计算机辅助设计与图形学学报*, 2018, 30(4): 642-650)
- [14] Blais G, Levine M D. Registering multiview range data to create 3D computer objects. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1995, 17(8): 820-824
- [15] Yang J, Li H, Campbell D, et al. Go-ICP: A globally optimal solution to 3D ICP point-set registration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(11): 2241-2254
- [16] Umeyama S. Least-squares estimation of transformation parameters between two point patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1991, 13(4): 376-380
- [17] Arun K S, Huang T S, Blostein S D. Least-squares fitting of two 3-D point sets. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1987, 9(5): 698-700
- [18] Ying S, Peng J, Du S, et al. A scale stretch method based on ICP for 3D data registration. *IEEE Transactions on Automation Science and Engineering*, 2009, 6(3): 559-565
- [19] Dong J, Peng Y, Ying S, et al. LieTrICP: An improvement of trimmed iterative closest point algorithm. *Neurocomputing*, 2014, 140: 67-76
- [20] Chetverikov D, Stepanov D, Krsek P. Robust euclidean alignment of 3D point sets; The trimmed iterative closest point algorithm. *Image and Vision Computing*, 2005, 23(3): 299-309
- [21] Zhang Shun-Li, Xu Yan-Zhi, Zhou Ming-Quan, et al. Registration of point clouds based on matching of general adaptive neighbourhood. *Chinese Journal of Computers*, 2019, 42(9): 2096-2108 (in Chinese)
(张顺利, 徐艳芝, 周明全等. 基于自适应邻域匹配的点云配准方法. *计算机学报*, 2019, 42(9): 2096-2108)
- [22] Muja M, Lowe D G. Scalable nearest neighbor algorithms for high dimensional data. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 36(11): 2227-2240
- [23] Black M J, Rangarajan A. On the unification of line processes, outlier rejection, and robust statistics with applications in early vision. *International Journal of Computer Vision*, 1996, 19(1): 57-91
- [24] Knapitsch A, Park J, Zhou Q Y, et al. Tanks and temples: Benchmarking large-scale scene reconstruction. *ACM Transactions on Graphics*, 2017, 36(4): 78
- [25] Schonberger J L, Frahm J M. Structure-from-motion revisited //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA, 2016: 4104-4113
- [26] Schonberger J L, Zheng E, Frahm J M, et al. Pixelwise view selection for unstructured multi-view stereo//Proceeding of the European Conference on Computer Vision. Amsterdam, The Netherlands, 2016: 501-518



ZHANG Cong-Yi, Ph. D. candidate. His research interests include computer graphics, computer vision and human-computer interaction.

is computer vision.

XU Hao-Wen, M. S. His research interest is computer graphics.

CHEN Yi-Song, Ph.D., associate professor. His research interests include computer vision and image processing.

WANG Guo-Ping, Ph. D., professor, Ph. D. supervisor. His research interests include computer graphics, virtual reality and human-computer interaction.

WEI Zi-Zhuang, Ph. D. candidate. His research interest

Background

Three-dimensional point cloud data is one of the most important data forms which can be obtained easily from real world. Point cloud registration is a fundamental technique for fusing pieces of point clouds together seamlessly. But to the best of our knowledge, it is not well discussed till now about one approach that can deal with point cloud patches with inconsistent scales, unreliable initial configurations, low ratio overlap area and large noises. In such settings, a global scale variable registration approach is needed.

In this paper, we propose a scale variable fast global point cloud registration method and test it in various dataset to validate its efficiency and performance.

This work was supported by the National Key R&D Program of China (Grant No. 2017YFB1002601), the National Natural Science Foundation of China (Grant Nos. 61661146002, 61632003), the National Ocean Public Interest Project (No. 201505014-3) and the Equipment Development Project under Grant (No. 315050501).

