

DOI:10.19651/j.cnki.emt.2211291

多特征关键点的自适应尺度融合特征点云配准*

赵迪 赵祖高 程煜林 聂磊

(湖北工业大学机械工程学院 武汉 430068)

摘要: 针对点云在噪声、遮挡及相似特征多个干扰条件下容易产生错误配准的问题,提出一种基于多特征的关键点提取算法和自适应尺度的融合特征点云配准方法。在关键点提取时,同时计算多个特征,使关键点更具描述性和鲁棒性。特征描述时,在自适应尺度的基础上使用 FPFH 和 RoPs 特征两种特征分别进行初始配准和错误点对剔除,最终各自得到多个相似的转换矩阵。完成上述求解后,将两者得到的矩阵组成集合进行聚类并对矩阵数最多的类取平均值处理作为最终的结果以完成特征的融合。实验研究表明,在忽略极少数无法具体化的错误配准点的情况下,真实场景下所提算法的 RMSE、ATI 和 ERR 分别为 0.46 mm, 1 和 0.37;使用数据集测试得到的正确率为 99.3%,均表明该算法的精度和鲁棒性较高。

关键词: 关键点;自适应尺度;特征融合;点云配准

中图分类号: TP391.41 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Adaptive scale fusion feature point cloud registration for multi-feature key points

Zhao Di Zhao Zugao Cheng Yulin Nie Lei

(School of Mechanical Engineering, Hubei University of Technology, Wuhan 430068, China)

Abstract: Aiming at the problem that point clouds are prone to misregistration under multiple interference conditions of noise, occlusion and similar features, a point cloud registration method based on multi-feature key point extraction algorithm and adaptive scale fusion features was proposed. In keypoint extraction, multiple features are computed simultaneously to make keypoints more descriptive and robust. On the basis of adaptive scale, FPFH and RoPs features are used for initial registration and error point pair elimination, and multiple similar transformation matrices are obtained respectively. After the above solution is completed, the matrix obtained by the two is formed into a set for clustering, and the class with the largest number of matrices is averaged as the final result to complete the feature fusion. The experimental results show that the RMSE, ATI and ERR of the proposed algorithm are 0.46 mm, 1 and 0.37 in the actual scenario when a few unrealized error registration points are ignored. The accuracy of the dataset test was 99.3%. It shows that the algorithm has high accuracy and robustness.

Keywords: key point; adaptive scale; feature fusion; point cloud registration

0 引言

点云数据具有颜色、强度以及目标的空间位置姿态等重要信息,因此对三维点云数据的研究与应用具有重要的意义^[1-3]。点云配准是点云数据应用的重要环节,在三维重建、目标识别、逆向工程等领域作为核心技术之一^[4-5]。目前已经有的各种形式的配准算法大部分泛用性和鲁棒性较差。其中一个重要的方面就在于多干扰条件下算法的精度与鲁棒性问题。

基于特征点云配准结果优良与否受多个因素的影响,主要包括关键点提取、特征描述以及配准方法3个部分。关键点提取已有许多经典算法^[6],例如ISS3D、SIFT、NARF算法等。ISS3D算法获得的关键点数量较少,容易忽略重要的特征点,而且该方法对噪声敏感;SIFT是一种优秀的经典算法,但是该算法对离群噪声点的鲁棒差;NARF对边界上的关键点检测效果较好,却忽略的其他地方的重要特征点。国内外也提出了许多创新的关键点提取算法,兰渐霞等^[7]提出正态形状索引的关键点提取算法。

收稿日期:2022-09-06

* 基金项目:国家自然科学基金(51975191)项目资助

该方法能有效的适应不同形状的曲面,但算法对噪声的鲁棒性依然较弱。Tinchev等^[8]设计了一种关键点检测器,它以点云的位置梯度作为显著性估计的测度,得到的关键点具有很好的鲁棒性,但该方法的使用条件苛刻。宋涛等^[9]提出了一种改进的关键点提取方法,在关键点提取阶段将边缘的关键点剔除,以减少配准的误差。实际上,这个方法提升了算法的效率,却没有很好的增强算法的抗干扰能力。特征描述阶段的算法已经很成熟^[10],例如点以特征直方图FPH和旋转投影统计特征RoPs为代表的局部特征描述;以视点特征直方图VFH为代表的全局特征描述。FPPH将点的空间差异进行参数化描述,对细节的变化敏感,对噪声和点云的密度变化也具有一定的鲁棒性;RoPs具备很强的鉴别力以及对噪声和数据分辨率变化等干扰的良好稳健性;VFH是基于FPPH改进和扩展得到的全局特征描述,具有强大的识别力和较快的识别速度。Besl等提出的最近迭代算法^[11](ICP)以及它的改进^[12-13]是传统方法的代表,单独使用时配准精度低、速度慢、鲁棒差。熊风光等^[14]针对混杂场景下已有配准算法的配对结果不理想、易产生错误配准等问题,提出了一种错误配准关系的剔除方法,增加了配准算法的可靠性,但该算法牺牲了算法的时间效率。Lu等^[15]提出了一种顾及点与面之间距离的点云分块配准方法,该方法在纹理对齐和配准精度上有显著提高,但该方法依赖于模型表面的重叠且计算复杂。

本文针对噪声、遮挡和相似特征多干扰条件下的点云配准问题,提出相应的解决方案。在关键点的提取阶段,提出基于局部形状曲率、角度特征和维度特征的多特征关键点提取方案,以期得到代表性强、可重复性高的关键点;在特征描述和配准时,使用协方差计算关键点的自适应尺度,然后计算RoPs和FPPH两种局部特征,使用向量的欧式距离确定初始的对应关系并利用霍夫投票得到多个可能的位姿。最后将两者得到的位姿组成一个集合并对其聚类,将位姿个数最多的类取平均得到最终的转换矩阵,实现一种特殊的融合特征点云配准,该方法能很好的利用RoPs和FPPH各自的优点。实验证明该算法在多干扰条件下具有较好的鲁棒性,配准的准确率和精度较高。

1 基于多特征的关键点提取

该阶段获取的关键点应具有稳定性、区别性以及不失代表性及描述性。针对已有的关键点提取算法鲁棒性差、外点率高等问题,提出了一种基于局部形状曲率、角度特征和维度特征的关键点提取算法。

形状索引值可以度量局部表面的最大相异性,以形状索引值作为局部形状曲率的数学描述是挑选出合适关键点的重要方法之一。具体过程包括采用曲面拟合的方法得到各点的曲率值,以及根据曲率值计算出形状索引值。对于点云中的一点,设置邻域为 r 时其二次曲面的参数方程如式(1)所示。

$$z = f(xy) = A_0x^2 + A_1y^2 + A_2xy + A_3x + A_4y + A_5 \quad (1)$$

式中: A_n 为拟合表面的参数; $n=1,2,3,4,5$ 。

使用最小二乘法估计拟合曲面参数,并使用微积分计算该点的平均曲率、高斯曲率以及主曲率如式(2)和(3):

$$K_1 = \frac{LN - M^2}{EG - F^2}, K_2 = \frac{EN - 2FM + GL}{2(EG - F^2)} \quad (2)$$

$$k_1, k_2 = K_2 \pm \sqrt{K_2^2 - K_1} \quad (3)$$

式中: K_1 表示高斯曲率; K_2 表示平均曲率; k_1, k_2 则表示主曲率; $E = r_x \cdot r_x$; $F = r_x \cdot r_y$; $G = r_y \cdot r_y$; $L = r_{xx} \cdot n$; $M = r_{xy} \cdot n$; $N = r_{yy} \cdot n$; $r_x, r_y, r_{xy}, r_{xx}, r_{yy}$ 为 $r(x, y)$ 的偏微分; n 为曲面的单位法向量。

根据形状值索引式(4)即可求得第 i 点的形状索引值 S_i ($0 \leq S_i \leq 1$)。

$$S_i = \frac{1}{2} - \frac{1}{\pi} \arctan \frac{k_1 + k_2}{k_1 - k_2} \quad (4)$$

如图1所示,对于给定的点 P 以及它的邻域内的一点 P_i , α 是 P 点的法向量 n_p 与向量 P_iP 的夹角,表达局部表面的凹性; β 表示 P_j 点的法向量 n_{pj} 与向量 P_jP 的夹角,描述该点相对于 P 的局部曲率; γ 表示 P_i 点的法向量 n_{pi} 与 P 点的法向量 n_p 的夹角,描述 P 邻域内的局部曲率。 α, β, γ (均取锐角)组成的向量 (α, β, γ) 表达的是该局部表面的角度特征。




图1 角度特征

维度特征 a_{1d}, a_{2d}, a_{3d} 的表达如式(5)所示。

$$\begin{cases} a_{1d} = \frac{\lambda_1 - \lambda_2}{\lambda_1} \\ a_{2d} = \frac{\lambda_2 - \lambda_3}{\lambda_1}, a_{3d} = \frac{\lambda_3}{\lambda_1} \end{cases} \quad (5)$$

式中: λ_1, λ_2 和 λ_3 ($\lambda_1 \geq \lambda_2 \geq \lambda_3$)是对 P 的邻域进行主成分分析得到的特征值,当 $\lambda_1 \gg \lambda_2, \lambda_3$,则 $a_{1d} \gg a_{2d}, a_{3d}$,此时局部表面为线性结构;当 $\lambda_1 \approx \lambda_2 \gg \lambda_3$,此时 a_{2d} 最大,局部表面表现为平面结构;当 $\lambda_1 \approx \lambda_2 \approx \lambda_3$,此时 a_{3d} 最大,局部表面表现为分散的结构。

将 $\alpha, \beta, \gamma, a_{1d}, a_{2d}, a_{3d}$ 均归一化使其值在 $[0, 1]$ 内。 α, β, γ 计算各自与 180° 的比值, a_{1d}, a_{2d}, a_{3d} 则计算它们与 $(a_{3d} - a_{1d})$ 的比值。对于给定点 P 以及它的3个不同描述,可以定义一个新的向量 f_i ,如式(6)。对 P 及其邻域内的点,就形成了一个向量集合 D ,如式(7)。

$$f_i = (S_i, \alpha, \beta, \gamma, a_{1d}, a_{2d}, a_{3d}) \quad (6)$$

$$D = \{f_i, i = 1, 2, 3, \dots, n\} \quad (7)$$

式中: n 表示近邻点的个数; $\alpha, \beta, \gamma, a_{1d}, a_{2d}, a_{3d}$ 为归一化

后的值。获得 f_i 和 D 后,可得点 P 邻域内有关 7 维向量 f_i 的协方差矩阵为式(8)。

$$C_D = \frac{1}{n-1} \sum_{i=1}^n (f_i - \mu)^\top (f_i - \mu) \quad (8)$$

式中: n 表示集合 D 的势; D 表示所有向量的平均值。

对于协方差矩阵,对角线上的元素为每个变量对应的方差;非对角线上的元素为随机变量两两之间的协方差,用来刻画两个向量的相似程度。当维度大于 1 时,协方差矩阵的行列式与方差性质相似,此处表示邻域内点的特征向量与期望值之间的离散程度。因此,行列式 $|C_D|$ 的值越大,该点邻域内的特征变化越明显。按照给定的邻域半径,遍历经处理后的点云,计算每个点对应的协方差矩阵的行列式的值。将各点按行列式的值从大到小依次排序,设置阈值 τ , 将 $|C_D| > \tau |C_D|$ (不考虑正负,只观察绝对值的大小)的点记为关键点。

2 自适应尺度的融合特征

2.1 基于协方差的自适应尺度

在特征描述阶段,不可避免的涉及曲率、法线、局部坐标以及拟合曲面中的一个或者多个变量的计算。由于点云特殊的数据形式,计算这些变量需要选择一个合适的邻域大小,即包含尺度选择问题。针对上述问题,提出一种自适应尺度的方法,即对不同的关键点求出各自相对最佳的 r 值。在获取关键点时将点邻域上的协方差矩阵的行列式定义为局部表面特征变化的度量,该行列式是一个随邻域 r 变化的值。由于它是一个特征变化的度量,也可以看作关键点相对于尺度的鉴别力的指标,那么使 $|C_D^o|$ 值最大的邻域半径 r_0 即可认为是计算特征时的最优尺度,最终选择的尺度 r_0 满足式(9)。为了使上述方案可以计算,定义 r 值的集合如式(10)。

$$|C_D^o| = \max\{|C_D^o|\} \quad (9)$$

$$r \in \{S_m \mid S_m = t_0 \cdot q^m\} \quad (10)$$

式中: t_0 设置为点云分辨率的 20 倍; q 设置为 1.2, $m=1, 2, 3, 4, 5$ 。

2.2 融合特征描述

由于采集设备性能和其他因素的影响,采集到的点云往往包含许多噪声点,在某些情况下,不合适的采集角度还会导致产生遮挡的问题。另外,一个场景中常包含多个相似的特征,如场景中的对称物体以及多个相似的物体。已有的局部特征描述很难同时解决这几个问题,因此,找到有利于多干扰条件下配准的方法是很有必要的。针对多干扰条件下的特征描述,提出了一种自适应尺度特征融合的方法。

PFH 特征基于关键点与其 k 邻域之间的关系以及它们的估计法线之间的相对偏差,将关键点与邻域内其他点之间的空间差异参数化,尝试得到最好的局部表面变化的描述。PFH 的描述如下:如图 2 所如示, n_i 和 n_j 分别表示点 P_i 和 P_j 处的法向量, uvw 组成局部坐标系,在该坐标系

下,对尺度 r_0 邻域内的 k 个元素,如式(11)计算所有点之间的 α, ϕ, θ, d (一般 d 是可以省略的)。快速点特征直方图(fast point feature histogram, FPFH)是基于 PFH 的改进方法,在仍保持 FPH 基本特点的基础上减少了计算量。如图 3,它只计算关键点及查询点(P_{ki} 为查询点)与邻域内其他点之间的关系,称为简化特征直方图(simple point feature histogram, SPFH),并且对查询点分配一个权重,最后结果如式(12)。根据 FPFH 特征对局部表面具有平移旋转不变性,并且在不同邻域内对采样密度具有鲁棒性和对细节刻画的能力,它至少具有以下两个特点:1)对没有遮挡部分的特征表达能力极强,有利于解决部分遮挡的问题;2)对相似特征具有较强的区别力。

$$\begin{cases} \alpha = v \cdot n_i, \phi = u \cdot \frac{(p_i - p_j)}{d} \\ \theta = \arctan(w \cdot n_i, u \cdot n_i) \end{cases} \quad (11)$$

$$FPFH = SPFH(p) + \frac{1}{\omega_i} SPFH(p_{ki}) \quad (12)$$

式中: ω_i 表示查询点到关键点的距离。




图 2 FPH 特征参数




图 3 FPFH 结构示意图

RoPs 特征的计算过程包括局部坐标系的建立和特征描述两部分。局部坐标系的建立:按照前面确定的关键点和尺度半径可以得到一个局部表面,计算该表面的散布矩阵并对其进行特征分解得到特征向量 v_1, v_2, v_3 , 消除向量 v_1, v_2, v_3 的二义性后将其定义为局部坐标系的 3 个坐标轴。特征描述如下:1)将局部表面上的点云转换到局部坐标系下,记为 R ;2) R 绕 x 轴旋转角度 θ_k 并向坐标平面投影获得点云 $R_i(\theta_k) i=1, 2, 3$, 将投影划分为 $L \times L$ 的分布矩阵并归一化;3)计算分布矩阵的中心矩和浓香熵,将它们合起来得到一个子特征。4)同理得到绕 x 和 y 轴的子特征

征。将子特征合起来得到最终的 RoPs 特征描述,特征描述子表达如式(13)。

$$f = \{f_x(\theta_k), f_y(\theta_k), f_z(\theta_k)\}, k = 1, 2, 3, \dots, n \quad (13)$$

式中: $f_x(\theta_k), f_y(\theta_k), f_z(\theta_k)$ 分别表示绕 x 轴、 y 轴、 z 轴的子特征; k 表示绕轴旋转的第 k 个角度。

由于 RoPs 特征从多个角度多个方向对图像进行高效简洁的描述,故具有很强的鉴别力,对噪声和数据的分辨率变化等干扰具有鲁棒性,由此它具有以下两个特点:1)对噪声的鲁棒性好;2)鉴别能力强,对未被遮挡的部分具有良好的描述性。

FPFH 和 RoPs 特征分别能解决多干扰条件下配准中的相似特征和噪声干扰的问题且都对未遮挡部分表达能力极强,于是提出一种特殊的融合方法将两种配准方法进行融合以提高配准的精度。先利用 FPFH 特征完成转换矩阵的求解过程。FPFH 特征可以表达为一个 33 维向量的形式,故可以采用模型和场景的最近欧式距离^[16-17]完成初始配准。假设模型中的关键点 P_i 的特征为 $f_i^p = \{a_1, a_2, \dots, a_{33}\}$, 场景中关键点 q_i 的特征为 $f_i^s = \{b_1, b_2, \dots, b_{33}\}$ 。在模型上选取一个关键点 P , 遍历场景中的关键点 q_i , 计算:

$$D(p, q_i) = \sqrt{(a_1 - b_1)^2 + \dots + (a_{33} - b_{33})^2} \quad (14)$$

设定阈值 σ , 当 $D(p, q_i) < \sigma$, 就认为 q_i 是 P 对应的点;然后逆向计算 q_i 在模型上的对应点 P' , 如果 P 和 P' 是同一点,则建立对应关系。找到初始的匹配关系后,进一步使用霍夫投票剔除错误的匹配关系,进而得到最终的转换矩阵。如图 4, C 为模型的质心,将关键点指向质心的向量转换到局部参考坐标系下形成投票向量 F 。因为局部坐标系具有唯一性,所以局部坐标系下的投票向量具有刚体变换不变特性,即投票向量 F 和 V 相等,然后把向量 V 转换到场景全局坐标系下。由于关键点已知,根据场景全局坐标系下的向量就可以得到场景全局坐标系下目标的一个质心的位置。对初始匹配得到的对应点重复进行上述过程,每次都对场景中目标的质心进行一次投票,记录质心位置和投票数。将得票数较多的几个质心对应的匹配关系保留,并根据它们计算出相应的转换矩阵。按照上述过程得到的是一系列相差不大的转换矩阵。按照 RoPs 特征同理进行上述的配准过程,也得到一系列的转换矩阵。将按两种特征得到的转换矩阵放到同一个集合中,然后采用贪婪算法对其进行聚类^[18]。随机选择集合中的一个矩阵作为聚类中心,接着判断其他的矩阵是否与其相似,如果相似,则加入;反之,新建一个聚类中心继续进行聚类过程。最后将矩阵数最多的类中的所有矩阵取平均值处理作为配准的转换矩阵。判断矩阵相似的依据如式(15)、(16):

$$\left| \arccos\left(\frac{|tra - 1|}{2}\right) - \arccos\left(\frac{|tra^* - 1|}{2}\right) \right| \leq \epsilon \quad (15)$$

$$|t - t^*| \leq \delta \quad (16)$$

式中: tra 和 tra^* 分别表示聚类中心和候选矩阵的迹, ϵ 和 δ 分别为旋转的角度阈值和平移的距离阈值, t 和 t^* 分别为聚类中心和候选矩阵的平移向量。




图4 霍夫投票示意图

3 实验验证

本文提出的配准方法的整个过程如图 5 所示。

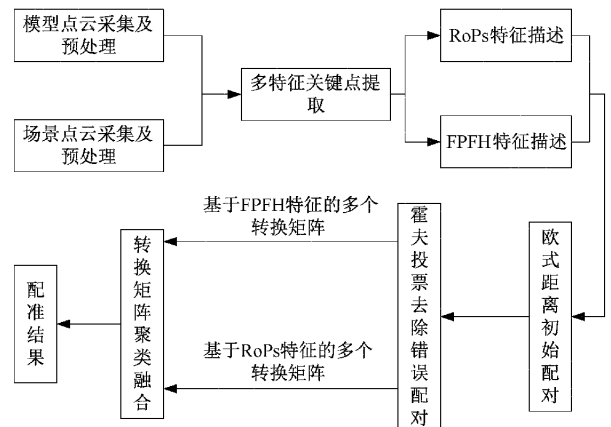


图5 配准的流程

3.1 实验数据与实验条件

为了对上述方法进行实验验证,分别在真实场景以及点云数据集上进行多次实验。真实场景的实验环境搭建如图 6 所示,其中包括显示器、计算机、Kinect2.0 深度相机和实验场景。实验场景由牛奶盒、不规则形状的瓶子、连接机构以及数据转换器组成,其中数据转换器为待配准的目标。使用 kinect2.0 获取实验所需的模型点云和场景点云,同时对其进行简单的预处理,包括使用条件滤波去除离目标较远的无效点云以及采用体素网格法进行下采样。最终获得的点云如图 7(放大图)、图 8 所示。可以看出 Kinect2.0 获取的点云含有大量的噪声点,而且在场景中加入了一个与数据转换器具有相似特征的牛奶盒,同时牛奶盒遮挡了部分数据转换器。

数据集使用的是斯坦福大学的三维点云数据集,一共包括 10 个模型。图 9 所示为数据集中的兔子的以及加上高斯噪声后的兔子点云图。

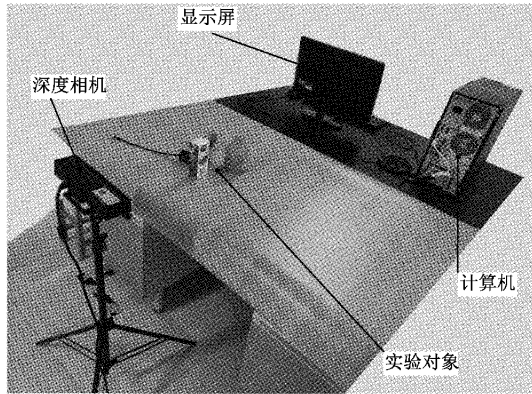


图 6 实验环境搭建




图 7 模型点云




图 8 场景点云




图 9 斯坦福数据

实验配置的硬件和软件的参数如表 1 所示。

3.2 实验评价标准

为了对实验结果进行量化分析,设定几个衡量指标:均方根误差 (root-mean-square error, RMSE)、抗干扰指数 (anti-interference, ATI) 和错误剔除率 (Error rejection rate, ERR)。均方根误差通过计算转换后的模型与场景中对应特征点的欧氏距离的均方根值来衡量配准精度,如

表 1 软硬件平台参数

项目	参数 r
操作系统	Windows 10 系统
GPU	NVIDIA Quadro P2000
CPU	E5-2620 v4@ 2.10 GHz
RAM	192 GB
PCL 环境	pcl-1.10
程序语言	C++

式(16);抗干扰指数是所有配对关系中正确配对所占的比率,值越大表示算法在干扰条件下的鲁棒性越强,如式(17);错误剔除率表示被剔除错误配对关系与所有对应关系的比值,值越大表示对错误配准点对的剔除效果越好,如式(18)。

$$RMSE = \frac{1}{n} \sqrt{\sum_{i=1}^n (\mathbf{R}p_i + \mathbf{T} - q_i)^2} \quad (17)$$

$$ATI = \frac{TP}{TP + FP} \quad (18)$$

$$ERR = \frac{FP}{TP + N + FP} \quad (19)$$

式中: \mathbf{R} 为旋转矩阵; \mathbf{T} 为平移向量; p_i 和 q_i 为模型和场景上对应的一对特征点; TP 是正确的配对关系; N 是剔除的错误点对数; FP 表示错误的配对关系。

3.3 真实场景下的算法验证

配准实验时,先进行关键点的提取。提取关键点时为了降低外点率及提高实验的可重复性,需要选择合适的邻域半径 r 和阈值 τ 。为此,以邻域半径 r 和阈值 τ 为变量,多次进行关键点提取实验,并将结果绘制成图 10。如图,当邻域半径较小,模型关键点数随着邻域半径 r 增长迅速变大,到 $r > 0.003$ m 时,增长速度变慢。但随着邻域半径增大,邻域内的点数增加,会导致计算量大幅增加,故邻域半径不宜过大,此处 r 取 3×10^{-3} m 是适宜的值。模型的阈值 τ 从 4 mm 变为 6 mm 时,关键点的数量发生急剧的变化,说明在这个之间有关键突变。为了保证重要的点不被舍去,同时又尽可能少的将无关点纳入进来, τ 取临界点 4 mm。同理,场景的 $r = 0.004$ m、 $\tau = 6$ mm。按照实验得到的参数 r 和 τ 的值,提取得到的模型和场景的关键点如图 11 所示。

为验证所提的配准算法的有效性,设置如表 2 的四组实验。将上面所提的关键点提取方法记为多特征关键点提取、配准方法记为 FC-FAR (Fusion characteristics of FPFH and ROPs)。其中,第 4 组实验为所提的算法,前 3 组是设置的对照组。第 1 组和第 2 组采用 SIFT 算法提取关键点与多特征关键点形成对比;第 1 组和第 3 组使用 SACIA 粗配准与 ICP 精配准结合的方法与提出的 FC-FAR 配准方法对比。最终的配准结果如图 12 所示,线表示配准关系,点表示配准的结果。




图10 模型关键点变化曲线




图11 关键点提取

表2 实验方案表

组别	关键点提取	配准方法
第1组	SIFT 关键点	SACIA+ICP
第2组	SIFT 关键点	FC-FAR
第3组	多特征关键点	SACIA+ICP
第4组	多特征关键点	FC-FAR

由配准结果图12可知,第1组和第2组的配准结果受到相似特征和噪声的影响;第3组的配准结果也被噪声点干扰,都匹配到了错误的结果。第4组实验结果所有的配准关系都在目标物体数据转换器上,证明了该算法的有效性和优越性。实验过程的具体数据如表3所示。

由图10以及表3关键点数量可知所提的多特征关键点提取算法在保证关键点稳定性与区别性的前提下,获取的关键点数量小于SIFT关键点的数量,有利于提高算法的效率。当对应某个错误配准结果的配准点对数小于3对时,由于无法计算出错误的配准结果,这部分对对的点会被统计到剔除的点对中,因此表3数据整体是可靠的。从表3数据来看,由第3、4组的对应关系数可知提出的多特




图12 配准结果

表3 配准的数据

项目	第1组	第2组	第3组	第4组
模型关键点个数	636	636	483	483
场景关键点个数	2 789	2 789	2 463	2 463
对应关系/对	219	296	274	314
配准结果个数	3	2	2	1
正确对应关系/对	149	104	210	198
错误对应关系/对	60	8	24	0
剔除的点对/对	10	184	40	116
计算耗时/s	16.34	6.67	17.56	6.89

征关键点获取的无用点对较少;由第2、4组的剔除的点对数据可知FC-FAR对错误配准结果的剔除效果较好。在时间上,相比于粗配准和精确配准的组合需要迭代,使用特征配准速度更快。在噪声、遮挡以及相似特多个因素的影响下,第四组实验的结果明显优于其他各组,最终得到的转换矩阵如式(16)。

$$\begin{cases} \mathbf{R} = \begin{bmatrix} 0.996 & 0.011 & 0.088 \\ -0.010 & 1.000 & -0.013 \\ -0.088 & -0.012 & 0.996 \end{bmatrix} \\ \mathbf{T} = \langle -0.053, -0.006, -0.002 \rangle \end{cases} \quad (20)$$

然后对实验结果进行量化分析,根据特征点的信息、配准结果以及数据表计算实验结果的3个评价指标。计算均方根误差RMSE时,对于有多个配准结果的,以最优的配

准结果为准。将 $RMSE$ 的计算结果绘制成图 13, ATI 和 ERR 的结果绘制成图 14。




图 13 配准精度图

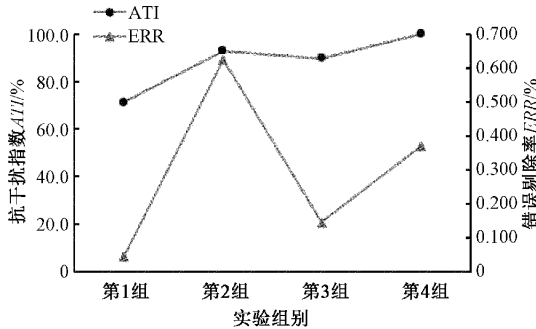


图 14 ATI 和 ERR

第 4 组实验的 $RMSE$ 为 0.46 mm, 精度远高于其他各组, 表明在干扰条件下, 算法的精度较高; 在忽略极少数无法统计的错误配准关系的前提下, ATI 约为 1, ERR 约为 0.37, 表明算法在干扰条件下的鲁棒性较强。比较第 1、3 组和第 2、4 组的 ATI 值可知, 在真实场景下多特征关键点提取算法获得的关键点鲁棒性更强; 比较第 1、2 组和第 3、4 组的 ERR 值可知, 真实场景下所提配准方法对错误配准关系的剔除效果更好, 增强了算法的鲁棒性和准确性。

完成上述对比实验后, 为了进一步验证算法的有效性和先进性, 再将所提出的配准算法与文献[14]进行对比。利用所提的配准方法与文献[14]中的点云数据 chef 和 res1 进行配准实验, 统计配准结果并与文献中的实验结果对比如下表 4 所示。表中的评价指标包括 ATI 以及文献中的旋转误差和平移误差。

表 4 与文献对比结果

算法名称	ATI	旋转误差	平移误差
文献[14]	1	1.489	18.945
本文算法	1	0.823	7.634

由表 4 可知, 所提算法保证算法的可靠性的前提下, 旋转误差减小了 44.7%, 平移误差减小了 59.7%, 因此, 提出的算法的配准精度更高。除此之外, 由于文献中的算法是一种时间换取可靠性的做法, 所提配准算法的时间效率远高于文献[14]中算法的时间效率。综上, 所提算法的性能有明显提高。

3.4 数据集上的算法验证

在实验前, 需要制作符合实验要求的实验场景, 具体过程如下: 1) 从斯坦福数据集里任选 8 个作为实验对象; 2) 选择兔子和中国龙作为两个不同的实验模型, 在剩下的 7 个中选 3 个与前面的两者之一一起组成实验场景并同时加上干扰条件。对每个场景, 都设置 4 种不同的干扰条件, 分别为: 1) 加入高斯噪声; 2) 遮挡部分大于 50%; 3) 加入 10% 以上的相似特征块; 4) 以上 3 种的混合。这样一共得到 280 组实验场景, 一种可以进行 280 次实验。最终评价结果正确的标准为 $RMSE$ 不大于 3 mm 且不出现多个配准结果。按照上述标准得到的整体实验的正确率为 99.3%。其中一组实验的场景和配准结果如图 15 所示。



图 15 结果展示

4 结 论

为解决多干扰条件下的点云配准问题, 提出了一种多特征关键点的自适应尺度融合特征的点云配准方法。主要

包括使用多特征关键点、融合自适应尺度的 FPFH 和 RoPs 特征以及错误配准关系的去除。实验结果表明,在忽略极少数(小于 3 对)错误配准点对的条件下,真实场景下算法的 RMSE、ATI 和 ERR 分别为 0.46 mm, 1 和 0.37;在数据集上进行多次实验得到的正确率为 99.3%。在多干扰条件下,相比已有的算法,本算法配准结果明显更加精准、对干扰的鲁棒性更强。

参考文献

- [1] SUN J, SUN Z L, LAM K M, et al. A robust point set registration approach with multiple effective constraints [J]. IEEE Transactions on Industrial Electronics, 2020, 67(12): 10931-10941.
- [2] PAVAN N L, SANTOS D, KHOSHELHAM K. Global registration of terrestrial laser scanner point clouds using plane-to-plane correspondences [J]. Remote Sensing, 2020, 12(7): 1227.
- [3] LIN Z Y, ZHU J H, JIANGZ T, et al. Merging grid maps in diverse resolutions by the context-based descriptor [J]. ACM Transactions on Internet Technology(TOIT), 2021, 21(4): 91.
- [4] 陈辉,马世伟. 基于激光扫描和 SFM 的非同步点云三维重构方法[J]. 仪器仪表学报, 2016, 37(5): 1148-1157.
- [5] 杨晗,谭川东,盛晋银,等. 基于工业 CT 的零件内外曲面形位误差分析[J]. 仪器仪表学报, 2021, 42(11): 230-238.
- [6] 李建微,占家旺. 三维点云配准方法研究进展[J]. 中国图象图形学报, 2022, 27(2):349-367.
- [7] 兰渐霞,王泽勇,李金龙,等. 基于正态形状索引的关键点提取算法[J]. 激光与光电子学进展, 2020, 57(16):184-193.
- [8] TINCHEV G, PENATE S A, FALLON M. SKD: Keypoint detection for point clouds using saliency estimation [J]. IEEE Robotics and Automation Letters, 2021, 61(99):1-1.
- [9] 宋涛,曹利波,赵明富,等. 三维点云中关键点的配准与优化算法[J]. 激光与光电子学进展, 2021, 58(4): 375-383.
- [10] 王珊,王春阳. 基于特征点匹配的三维点云配准算法[J]. 国外电子测量技术, 2020, 39(12): 23-28.
- [11] 冯川,冯志辉,南亚明,等. 基于特征向量提取的点云配准算法[J]. 电子测量技术, 2022, 45(15):57-62.
- [12] LIU H, ZHANG Y, LEI L, et al. Hierarchical optimization of 3D point cloud registration [J]. Sensors, 2020, 20(23):6999.
- [13] ZHANG J, YAO Y, DENG B. Fast and robust iterative closest point [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(7): 156-161.
- [14] 熊风光,霍旺,韩燮,等. 三维点云中关键点误匹配剔除方法[J]. 光学学报, 2018, 38(2):128-138.
- [15] LU Y, DUAN M, DAI S G. A method of point cloud data block registration with considering distance from point to surface[J]. Bulletin of the Polish Academy of Sciences-Technical Sciences, 2022, 70(2), DOI:10.24425/bpasts.2022.140259.
- [16] 刘润涛,梁建创. 基于新型索引结构的反最近邻查询[J]. 计算机研究与发展, 2020, 57(6):1335-1346.
- [17] 朱晓强,陈琦. 基于三维激光扫描点云配准的目标位姿测量[J]. 电子测量技术, 2022, 45(4):13-18.
- [18] LU X, GUO P, LIU G. Estimation of shoulder width and neck girth based on 3D point cloud data [J]. Thermal Science, 2021, 25:47-471.

作者简介

赵迪,博士,副教授,主要研究方向为机械设计及理论、智能机器人和虚拟现实等。

E-mail:zhao15180636230@163.com

赵祖高,硕士研究生,主要研究方向为智能机器人和机器人视觉等。

程煜林,硕士研究生,主要研究方向为智能机器人和虚拟现实等。

聂磊,博士,教授,主要研究方向为机光电精密测量技术为基础的传感测量、复杂环境条件下的产品状态获取与感知等。