光电技术及应用

DOI：10.16818/j.issn1001－5868.20250430001

基于3D-Harris关键点检测结合改进ICP的姿态估计算法

陈宇超，蔡体菁*

（东南大学 仪器科学与工程学院，南京 210096）

摘　要： 针对传统激光雷达姿态估计过程中原始点云存在离群噪声点、配准易陷入局部最优、计算效率低的问题，文章提出一种基于3D-Harris关键点与改进迭代最近点（ICP）相结合的三维点云配准算法。该算法首先采用体素滤波与统计滤波进行点云预处理，以去除异常噪声点；随后，利用3D-Harris关键点检测算法，缩减姿态估计过程中的对应点搜索空间，提升配准效率；在粗配准阶段，基于快速点特征直方图特征描述的采样一致性算法，对关键点进行特征描述并提供初始旋转平移矩阵，以优化精配准的初始值，提升姿态估计精度；在精配准过程中，通过Kd-tree的近邻搜索，优化ICP算法执行效率。实验结果表明，所提出的算法在配准精度和计算效率方面均优于传统方法，具有较高的应用价值。

关键词： 三维激光点云；3D-Harris；姿态估计；改进ICP；配准算法

中图分类号： TP391.4；TN958.98　**文章编号：** 1001－5868(2025)05－0919－09

Attitude Estimation Algorithm Using 3D-Harris Keypoint Detection Combined With Improved ICP

CHEN Yuchao, CAI Tijing

(**School of Instrument Science and Engineering, Southeast University, Nanjing 210096, CHN**)

Abstract: To address challenges such as outlier noise, sensitivity to local optima during registration, and the low efficiency of traditional LiDAR-based attitude estimation using raw point clouds, this study proposes a novel 3D point cloud registration algorithm. The method integrates 3D-Harris keypoint detection with an improved Iterative Closest Point (ICP) algorithm. Pre-processing combines voxel grid filtering and statistical outlier removal to eliminate abnormal noise points. Subsequently, 3D-Harris keypoint detection is applied to reduce the search space for correspondence, enhancing computational efficiency. For coarse registration, a sample consensus initial alignment algorithm based on Fast Point Feature Histograms is employed to describe keypoint features and estimate an initial rotation and translation matrix. This initialization improves the accuracy and convergence of the fine registration stage. The fine registration process utilizes a Kd-tree-based nearest neighbor search to accelerate the ICP algorithm. Experimental results show that the proposed method achieves higher registration accuracy and computational efficiency than traditional approaches, demonstrating strong practical applicability.

Key words: 3D laser point cloud; 3D-Harris; attitude estimation; improved ICP; registration algorithm

收稿日期：2025－04－30.

*通信作者：蔡体菁

0 引言

在三维激光测量技术中[1]，由于激光无法穿透物体本身且常受物体自遮挡的影响[2]，采集到的点云数据往往只覆盖了目标物体上的局部，使得成像的视角较为单一[3]。在利用激光点云进行重构并对目标物体复原成像的过程中[4]，无论是旋转以测量设备质点为中心的相机坐标系，还是旋转以探测点云质点为中心的点云坐标系，三维重构的形状结果都可能会与目标物体存在显著差异[5]。基于这种现象，亟需一种高精度的姿态估计算法[6]，用于估计其初始位姿，将局部点云准确还原为原始完整的目标点云。激光点云配准这种方法可以实现这一目的[7]。其结果不仅可以直接影响点云还原的准确度，还可以判定待测目标物体在六个自由度上，点云相对于目标物体、测量设备和世界坐标系的相对位姿关系[8]。提高姿态估计精度和检测效率，对改进目标的定位与追踪性能具有重大意义[9]。

使用点云配准（Registration）算法来解算待测目标的姿态变换数据是目前在六维（Six-dimensional，6D）姿态估计方法中较为常见的解决方法之一[10]。一个完整的基于激光点云配准的姿态估计过程一般需要被分为粗配准[11]和精配准[12]两个过程。粗配准算法根据算法原理的不同，主要分为三大类：基于概率密度的方法[13]、基于特征描述的方法[14]和基于全局搜索方式的方法[15]。Rusu等基于特征描述的方法提出点特征直方图（Point Feature Histograms，PFH），通过分析不同尺度特征的不变性，提取出一个最佳集合，该集合表征了给定的点云，将数据集变换到其收敛域，为配准算法提供了良好的起点[16]。之后，Rusu等对PFH特征描述符进行改进，进一步提出快速点特征直方图（Fast Point Feature Histograms，FPFH），该算法在保留PFH的大部分鉴别能力的基础上，对PFH算法原理的数学表达式进行简化，大幅提高了算法的运算效率[17]。精配准算法就用于在粗配准之后进一步迭代，其传统的算法的提出可以追溯到1992年。Besl和McKay等提出的迭代最近点（Iterative Closest Point，ICP）算法是基于最小二乘的原理的精配准算法[18]，该算法运用广泛，但其作为传统的精配准算法存效率不高、容易局部收敛等不足。

为改进配准算法的不足，本文提出一种基于3D-Harris关键点结合改进ICP的三维点云配准算法。首先，引入体素滤波结合统计滤波的点云预处理技术，以降低点云密度；其次，结合3D-Harris关键点检测算法，进一步减小配准算法的对应点搜索空间；然后，利用基于FPFH特征描述的采样一致性初始配准（Sample Consensus Initial Alignment，SAC-IA）点云算法实现粗配准，对关键点进行特征描述并提供初始旋转平移矩阵；最后，通过Kd-tree的近邻搜索功能加速ICP，实现快速精配准。实验结果表明，所提出的算法配准精度较优，配准效率较高。

1 激光点云处理技术

1.1 激光探测系统

激光探测系统设计的目的是采集精准的三维点云数据集[19]，为配准算法提供良好的测试环境。该系统总体结构如图1所示。系统的传感器选用面阵激光雷达三维探测传感器去探测待测目标[20]，获取三维激光点云[21]。面阵激光雷达通过相应的通信串口连接计算机终端，根据相应的通信协议实现与计算机的关联。计算机是整个系统的数据处理中心。

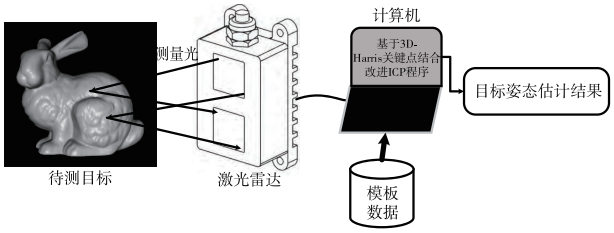


图1 系统总体结构

测量开始时，固定传感器与目标的相对位姿。面阵激光雷达发射红外850 nm的激光簇，这一簇激光称为测量光。测量光到达置于平整平台的目标表面，部分激光经过反射返回面阵激光雷达，这部分反射光由激光雷达感光器件接收。激光雷达将输出的数据转移进入计算机，计算机根据飞行时间（Time of Flight，ToF）原理实时计算距离，输出三维点云并提取出距离阈值外的原始点云数据。与此同时，控制计算机终端从模板数据中选择与实物相对应的目标点云。模板数据中的目标点云一般在程序运行前，用基于多视角扫描的高精度重建技术生成，生成的点云具有目标物体全方位坐标信息的三维数据[22]。之后，计算机运行由基于3D-Harris关键点结合改进ICP算法编写的程序，将原始点云与目标点云进行配准并输出姿

态估计结果。

实际上，通过激光雷达对获取到的点云数据进行处理前，经常会遇到这几种问题：一是点云中的点数过多，数据量过大，点云密度过高，数据处理缓慢；二是探测过程存在环境干扰，且激光雷达传感器系统本身存在误差，会不可避免地引入一些噪声和离群点，从而导致配准结果精度下降[23]。因此，为改善配准精度，提高运算效率，需要对点云探测得到的点云数据进行滤波及下采样预处理。

体素滤波在不改变点云的形状的前提下，把每个体素格内的点云用最接近体素格形心的点替代，即均匀降采样，从而近似原点云并降低点云密度[24]。在点云库（Point Cloud Library，PCL）中，该滤波器中体素格的大小参数需要在程序中给定。

统计滤波是基于离群点和噪声周围点云密度较低的特点，统计分析点云的密度分布。该滤波器根据高斯分布的概率判定，将密度低于一定标准值的点云删除，而点云密度又是由该块空间中每个点到其他点的距离决定的，所以需要计算点云的距离分布[25]。在 PCL 中，需要设置的参数包括每个点的需要计算距离的邻近点个数和判断是否为离群点或噪声的标准阈值。

1.2　基于 FPFH 特征描述的 SAC-IA 粗配准

在众多粗配准算法中，SAC-IA 粗配准算法较为稳定，且能用于单视角下得到的原始点云配准。本文采用 FPFH 特征描述结合 SAC-IA 采样一致性算法实现点云粗配准，下面介绍该粗配准算法的原理。

FPFH 快速点特征直方图描述子能将时间复杂度减小到 $o(n\cdot k)$，n 表示点云中的点数，k 表示每个点在其给定半径球形邻域内其余点的个数。FPFH 算法具体步骤如下：

（1）首先计算简化点特征直方图（Simplified Point Feature Histogramd，SPFH）。SPFH 的构成为单点 p_q 与其 K 邻域[26]内所有点 p_k 之间的角度特征变量。为分析角度特征变量计算方法所定义的局部坐标系如图 2 所示。

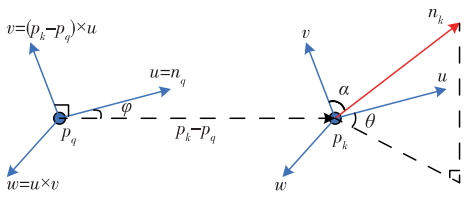


图 2　局部坐标系

图 2 中，$\boldsymbol{n}_q$ 是 p_q 的法向量，$\boldsymbol{n}_k$ 是 p_k 的法向量。根据图中的几何关系可得角度特征变量 α,φ,θ 如下：

$$\begin{cases}\alpha=\boldsymbol{v}\cdot\boldsymbol{n}_k\\ \varphi=\dfrac{\boldsymbol{u}\cdot(p_k-p_q)}{\|p_k-p_q\|}\\ \theta=\arctan(\boldsymbol{w}\cdot\boldsymbol{n}_k,\boldsymbol{u}\cdot\boldsymbol{n}_k)\end{cases}\tag{1}$$

SPFH 的引入使得 FPFH 不必像 PFH 一样复杂，不需要在计算特征值前计算 K 邻域内所有邻近点对的角度特征变量，仅计算单点邻域内的角度信息，减少了信息冗余，从而降低了计算时间复杂度。

（2）根据 K 邻域内的邻近点 SPFH 值进行特征值计算。即对点 p_q 的 SPFH 值根据邻近点 p_k 的 SPFH 值进行加权求和，计算得出特征值 FPFH 的输出结果为：

$$FPFH(p_q)=SPFH(p_q)+\frac{1}{k}\sum_{i=1}^{k}\frac{1}{w_k}SPFH(p_k)\tag{2}$$

式中，k 为 K 领域内的点数，权重 w_k 定义为在 n 维空间中当前点 p_q 与其球形邻域内近邻邻域内的点 p_k 之间的欧几里得距离，即：

$$w_k=\sqrt{\sum_{i=1}^{n}(p_{qi}-p_{ki})^2}\tag{3}$$

（3）对数据集中所有点重复上述操作。计算得到的点 p_q 为球形邻域中心点时，FPFH 覆盖空间在平面上的投影如图 3 所示。

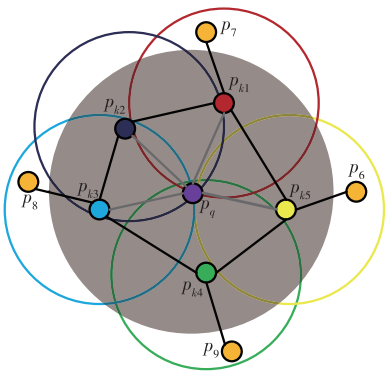


图 3　球形邻域中心点的 FPFH 覆盖空间

在对原始点云和目标点云进行 FPFH 局部特征描述之后，分别得到原始点云和目标点云的特征描述子以及点特征直方图。点云的数据不仅包含原来的三维信息，还包含点云表面上各点法向量之间的相对空间夹角等数据，数据集成为增广向量组。该增广向量组需要作为 SAC-IA 算法的输入数据，目的是找到最优的旋转平移变换使得原始点云上的点经过旋转平移后与目标点云上的对应点距

离均尽可能最小。SAC-IA算法的步骤如下：

（1）设定对应点之间最小的距离和单次原始点云采样中点的个数为N；在原始点云中随机采样N个点，这N个点满足点之间最小距离超过最小距离，从而保证各点的特征直方图尽可能不同；

（2）针对每一个采样得到的点，在目标点云中通过Kd-tree最近邻搜索得到一个或多个与采样点特征直方图相似甚至相同的点，从中选择一个点作为与原始点云上的采样点相对应的点；

（3）对第（2）步中得到的每一对对应点进行旋转平移变换配对，得到旋转平移矩阵，结合Huber罚函数来判断当前配准变换的性能。将上述步骤不断迭代找到最小的罚函数数值后，其对应的旋转平移矩阵就是粗配准的最终结果。Huber罚函数记作$H(l_i)$，其表达式为：

$$H(l_i)=\begin{cases}\dfrac{1}{2}l_i^2 & \|l_i\|\leqslant ml\\ \dfrac{1}{2}ml(2\|l_i\|-ml) & \|l_i\|>ml\end{cases} \tag{4}$$

式中，ml为预先设定的值，l_i为一距离差，由第i组对应点对之间计算得到。

选择合适的较小的单次采样个数N能降低配准时间，合适的最小距离能提高配准精度，为后续的精配准算法提供一个良好的初始矩阵。但无论这些参数如何设置，由于SAC-IA粗配准算法是基于特征直方图的相似性原理查找对应点的，粗配准算法的配准精度仍然无法达到精配准算法的配准精度。因此，需要精配准算法进一步提高精度。

1.3 基于Kd-tree加速的改进ICP精配准

传统ICP算法查找对应点的时间较长，且它占用了ICP算法中大部分计算时间，极大延长了配准的总时间。而Kd-tree具有近邻搜索的功能，可以优化查找最近点的效率，从而加快查找多维数据得到对应点对，大幅提高ICP算法的计算效率。因此，利用Kd-tree这一数据结构，近邻搜索获取对应点，就可以达到加速精配准算法的目的。

Kd-tree是一种用于在具有K维的空间中组织一定数量点的二叉树数据结构。当Kd-tree用于处理三维点云数据时，Kd-tree是三维的数据结构。三维的Kd-tree示例如图4所示。

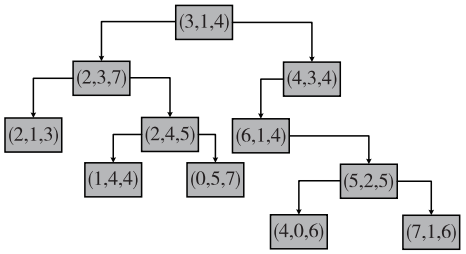


图4 三维Kd-tree示例

Kd-tree的构建遵循如下原则：所有子级都被Kd-tree的每一级用垂直相应轴的超平面沿特定维度分割。在树的根部，所有子项都将根据第一个维数据进行拆分，如果第一维数据坐标小于根，它将在左子树中；如果它大于根，则在右子树中。树中的每个级别在下一个维度上划分，一旦所有的其他维度都用尽，就会返回到第一个维度。可以说，Kd-tree用空间上的复杂度取代了一部分的时间复杂度。可以按照如下步骤进行加速精配准：

第一步，分别对原始点云和目标点云创建Kd-tree。Kd-tree是一种用于在具有K维的空间中组织一定数量点的二叉树数据结构。当Kd-tree用于处理三维点云数据时，Kd-tree是三维的数据结构。创建Kd-tree便于加速后续的最近邻搜索。

第二步，从根节点开始，递归下降。

第三步，当下降到叶节点时，默认将该节点作为“当前最佳点”。计算当前点和目标点之间的距离，采用欧氏距离计算。

第四步，向前回溯，对每个经过的节点进行两种逻辑判断。判断当前节点是否比当前最佳点更靠近输入点，则将其变为当前最佳点；判断另一边子树有没有更接近的点，若有则从该点往下找。

第五步，在当前节点搜索完毕之后，即完成最邻近搜索。

第六步，用上述最近邻搜索的方法知道原始点云与目标点云中各点的正确对应关系，完成这一步就可以确定两个点云坐标系之间的相对旋转平移变换关系有唯一的解析解。

第七步，分别计算源点云和目标点云的质心，然后在计算旋转平移矩阵之前，在两个点云中分别减去对应的质心。

第八步，根据求得的误差函数，以误差函数的最优为目标，选取特定的方法计算旋转平移矩阵。

第九步，预设参数给定阈值以及迭代次数，判断相邻迭代的矩阵差值是否小于阈值，或总迭代次数是否超过给定的迭代次数等迭代条件，若是则算法结束。

2　关键点与粗精配准融合算法

2.1　3D-Harris关键点检测

3D-Harris关键点检测算法是由2D-Harris演变而来，在原理上与2D-Harris相似，通过3D-Harris算法能够直接将关键点提取出来。但是两者的不同之处在于2D-Harris是利用方形窗口在二维图像上进行移动，通过移动窗口的灰度变化判断是否为关键点[27]，而3D-Harris是将整个目标点云空间分成均匀大小的立方体，并将每个立方体中点云的个数看作是二维图像的灰度值，最后在此基础之上向前后、左右、上下六个方向分别移动计算以提取所有的关键点。3D-Harris算法具体流程如下：

（1）首先构建出目标点云的k维树空间并将点云之间形成连通关系。

（2）对目标点云的点p_j的邻域空间进行协方差矩阵构建：

$$\boldsymbol{E}_{p_i}=\frac{1}{\left|N(p_i)\right|}\sum_{|p_j|\in N(p_i)}(p_j-\bar{p})\cdot(p_j-\bar{p})^T \quad (5)$$

式中，$N(p_i)$是点p_i构建的球形邻域，球半径为r，$\bar{p}=\frac{1}{k}\sum_{p_j\in N(p_j)}p_j$为点$p_i$球形邻域$N(p_i)$的质心，$\left|N(p_i)\right|$表示为$p_i$点球形邻域中包含点云的个数。

（3）对协方差矩阵$\boldsymbol{E}_{p_i}$进行SVD分解求得特征值$\lambda_1^i,\lambda_2^i,\lambda_3^i$，其中$\lambda_1^i>\lambda_2^i>\lambda_3^i$，其分别对应特征向量$\boldsymbol{v}_1^i,\boldsymbol{v}_2^i,\boldsymbol{v}_3^i$。该点的法向量$\boldsymbol{n}_i=\left(n_{xi},n_{yi},n_{zi}\right)$为特征向量$\boldsymbol{v}_3^i$。

（4）在点p_i的球形邻域中构建法向量协方差矩阵：

$$\boldsymbol{E}_n=\frac{1}{\left|N(p_i)\right|}\cdot\sum_{n_j\in N(p_i)}\boldsymbol{n}_j\cdot\boldsymbol{n}_j^T \quad (6)$$

关键点检测函数为：

$$V(p_i)=\mathrm{Det}(\boldsymbol{E}_n)-\alpha\times\mathrm{Tr}(\boldsymbol{E}_n)^2 \quad (7)$$

式中，行列式$\mathrm{Det}(\boldsymbol{E}_n)$为矩阵$\boldsymbol{E}_n$特征值之积；矩阵主对角线上元素的总和$\mathrm{Tr}(\boldsymbol{E}_n)$为矩阵特征值之和。$\alpha$为经验常数，设置关键点阈值$\varepsilon$，使$V(p_i)>\varepsilon$的点判断为关键点。对点云上所有的点进行此操作即可采集得到所有的关键点的集合，称为关键点集。

2.2　基于3D-Harris关键点结合改进ICP

本节提出基于3D-Harris关键点结合改进ICP的算法，将3D-Harris关键点检测算法与基于Kd-tree加速的改进ICP精配准算法结合。该算法用于姿态估计系统，可对单视角下探测得到的原始点云实现快速精确配准，最终的算法流程如图5所示。

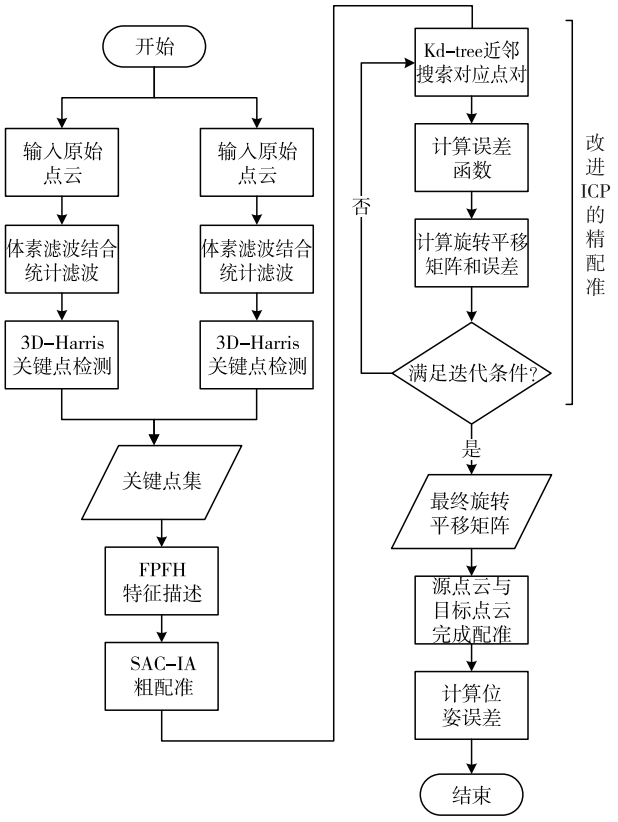


图5　基于3D-Harris关键点结合改进ICP的算法流程图

算法流程分析如下：首先，分别输入待测目标的原始点云和目标点云，并分别对原始点云和目标点云运用体素滤波结合统计滤波的预处理技术，以达到去除两片点云噪声、离群点以及降低点云密度的效果；其次，检测两点云的3D-Harris关键点得到只含关键点的关键点集；接着，对关键点集分别进行FPFH特征描述，得到两片点云的点特征直方图；然后，将计算得到的关键点集与点特征直方图共同作为配准算法的输入数据，进行SAC-IA采样一致性粗配准匹配相似特征描述的点，得到关键点集的对应点对；将粗配准的结果输出为旋转平移矩阵，计算粗配准误差并完成原始点云的第一次旋转平移变换；在完成了基于FPFH特征描述的SAC-IA点云粗配准之后，以粗配准完成的第一次旋转平移变换为基础，采用基于Kd-tree加速的改进ICP算法实现两片点云精配准，即使用Kd-tree近邻搜索对应点对，以误差函数的最优为目标，选取特定的方法计算旋转平移矩阵和误差，重复迭代直到满足相邻迭代的矩阵差值小于阈值或总迭代次数超过给定的迭代次数这些迭代条件；最后，根据输出的

最终旋转平移矩阵，原始点云进行旋转平移变换，完成与目标点云的配准。

3 实验结果与分析

3.1 实验设计

根据原始点云数据的完整程度，实验分成两部分，分别为单视角下的局部点云数据配准和全视角下的完整点云数据配准。

将待测目标设定为斯坦福大学的开源兔子点云模型，其表面反射率理想。程序运行前，目标点云文件与原始点云文件作为算法的输入数据。预先在模板数据中输入目标点云PCD文件“bunny”数据，准备好单视角下的原始点云PCD文件“bun000”数据。文件中包含了各点云坐标系的原始位姿信息，固定目标点云坐标系、世界坐标系和相机坐标系，原始点云坐标系待估计。目标点云的点数为35 947个点，原始点云的点数为19 700个点。

为保证提出的算法与不计算关键点的对比配准算法，即基于FPFH特征的点云配准算法[28]，在点云预处理后的点云点数相等，实验设定预处理算法中体素滤波的体素网格边长为0.005个单位，统计滤波的邻近点数为9，离群点阈值为1个标准差。

在不同角度的激光雷达所采集到的原始点云，其完整程度不同。因此，将原始点云类型分为单视角下的原始点云和全视角下的完整原始点云。在工程实际中，完整原始点云一般由基于多视角扫描的三维扫描仪测得，是一个有着待测目标物体全方位三维信息的完整点云。单视角下的原始点云和完整原始点云虽然源自同一个待测目标，但由于单视角下的原始点云能体现的特征信息较少，会降低配准精度以及影响姿态估计结果。实验采用的完整原始点云“bunny45”数据是由目标点云PCD文件“bunny”数据绕Z轴旋转45°复制而来。这样得到完整原始点云有两点好处：一是不需要使用高价的三维扫描仪就可以对算法性能进行验证，实验条件经济且简单易重复，得到的结果与算法应用于实际工程中的结果相似；二是原始点云坐标系的真实值已知，有参考矩阵方便计算误差矩阵且可以在有限角度范围内进行欧拉角角度误差分析，姿态估计结果的精度可直观表示。

实验一，对单视角下的原始点云进行姿态估计。目的是验证本文算法用于姿态估计单视角下的原始点云的精度与效率。此时，目标点云坐标系与原始点云坐标系的初始位姿相对关系未知，对姿态估计结果采用配准精度的评价指标进行误差分析。设定输入的原始点云及初始相对位姿如图6所示。



图6 实验一中单视角下的原始点云及初始相对位姿

图6中，完整的点云是目标点云“bunny”数据，单视角下的点云是原始点云“bun000”数据。将实验一中本文基于3D-Harris关键点结合改进ICP算法的精配准时间、算法总时间、配准精度结果分别与传统ICP算法和FPFH配准算法[28]的结果进行对比。

实验二，对全视角下完整原始点云进行姿态估计。目的是验证所提出的算法用于配准全方位完整原始点云的精度与效率。首先将复制得到的原始点云坐标系与目标点云坐标系重合，然后将原始点云坐标系和“bunny45”进行给定的旋转，设定为欧拉角Z-Y-X值为$(0°, 45°, 0°)$，即绕$\boldsymbol{Y}_t$轴旋转45°，对应给定的旋转平移矩阵$\boldsymbol{R}_{ref}$为：

$$\boldsymbol{R}_{ref}=\begin{bmatrix} 0.707\,11 & 0 & 0.707\,11 & 0 \\ 0 & 1 & 0 & 0 \\ -0.707\,11 & 0 & 0.707\,11 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \tag{8}$$

将实验二中本文算法的精配准时间、算法总时间、配准精度结果分别与传统ICP算法和FPFH配准算法[28]的配准结果进行对比。最后，输出实验二中本文算法配准的结果。目标点云坐标系与原始点云坐标系的参考位姿相对关系已知，且在有限角度变化范围内，采用旋转矩阵法与欧拉角法进行误差分析。设定输入的原始点云及初始相对位姿如图7所示。

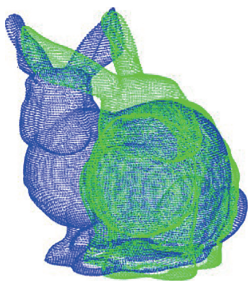
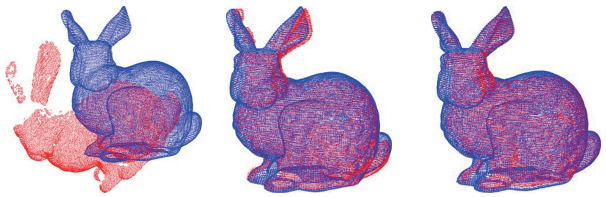


图7 实验二中全视角的原始点云及初始相对位姿

3.2　实验结果分析

在控制实验其他无关变量参数相等的条件下，实验一中不同算法的配准效果在可视化后如图8所示，红色为配准后得到的点云。本文算法配准后，两片点云基本重叠，效果良好。



（a）传统ICP算法配准结果　（b）FPFH配准算法配准结果　（c）本文算法配准结果

图8　单视角点云的不同算法配准结果对比图

进一步将点云配准结果量化，得到不同算法的精配准时间、算法总时间、均方根误差RMSE结果，RMSE保留到小数点后六位。本文算法在进行3D-Harris关键点检测后，从原始点云中提取了121个关键点，从目标点云中提取了341个关键点。实验一数据如表1所示。

可以看到，本文的基于3D-Harris关键点结合改进ICP算法的精配准时间最短，配准精度最高。FPFH配准算法虽然相对于传统ICP算法的配准精度及精配准时间有提高，但是算法总时间被大大延长，且仍存在较大误差。主要原因是FPFH配准算法对单视角原始点云的边界点的特征描述是不够准确的，降低了配准精度且延长了配准时间。由于传统ICP算法中没有粗精配准结合的策略[29]，其算法总时间与精配准时间相等，配准精度上陷入了局部最优。本文算法在单视角点云场景下，相较于传统ICP精配准的效率加快了98.4%，相较于FPFH配准算法精配准的效率加快了61.5%。在保证配准精度的同时，本文算法相较于FPFH配准算法的效率同样加快了91.6%，并且均方根误差仅为0.000 838 m。综上所述，本文算法在配准单视角原始点云时，提取了关键点并舍弃了部分特征描述不准确的点，同时采用改进ICP算法，可以有较高的配准精度以及较快的配准效率。

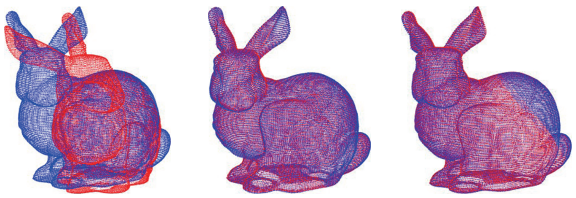
表1　实验一中各算法配准结果

配准算法	时间		*RMSE*/m
	精配准/s	总时间/s	
传统ICP	3.088	3.088	0.002 563
FPFH配准算法	0.130	68.855	0.001 373
本文算法	0.050	5.815	0.000 838

最后，由本文算法进行姿态估计后得到的欧拉角Z-Y-X值为$(45.442^\circ, -0.789\,58^\circ, 1.536\,8^\circ)$，以目标点云坐标系为参考坐标系的旋转平移矩阵为：

$$\boldsymbol{R}_{ZYX}=\begin{bmatrix} 0.701\,56 & -0.712\,55 & 0.009\,443\,8 & 0.000\,381\,58 \\ 0.712\,48 & 0.701\,11 & -0.028\,632 & 0.000\,477\,76 \\ 0.013\,780 & 0.026\,816 & 0.999\,54 & -0.001\,608\,9 \\ 0 & 0 & 0 & 1 \end{bmatrix} \tag{9}$$

实验二中不同算法的配准效果在可视化后如图9所示。本文算法配准后，两片点云基本重叠，配准效果良好。



（a）传统ICP算法配准结果　（b）FPFH配准算法配准结果　（c）本文算法配准结果

图9　全视角点云的不同算法配准效果对比图

实验二对全视角下完整原始点云进行姿态估计数据如表2所示。

在进行3D-Harris关键点检测后，从原始点云中提取了335个点，从目标点云中提取了341个点。可以看到，本文算法的精配准时间最短，配准精度最高。FPFH配准算法虽然相对于传统ICP算法的配准精度及精配准时间有所提高，但是算法总时间被大大延长。本文算法相较于传统ICP算法精配准的效率加快了98.9%，相较于FPFH配准算法精配准的效率加快了69.6%。在保证配准精度的同时，本文算法相较于FPFH配准算法的效率同样加快

表2　实验二中各算法配准结果

配准算法	时间		*RMSE*/m
	精配准/s	总时间/s	
传统ICP	4.315	4.315	0.002 506
FPFH配准算法	0.158	117.341	0.000 673
本文算法	0.048	9.676	0.000 492

了91.8%,且均方根误差仅为0.000 492 m,配准精度较高。综上所述,本文算法在对完整原始点云姿态估计时,提取了关键点进行粗配准,同时采用改进ICP算法,可以有较高的配准精度以及较快的配准效率。

最后由本文算法计算得到的欧拉角Z-Y-X值为(0.388 90°, 44.871°, 0.538 34°),对应的以目标点云坐标系为参考坐标系的旋转平移矩阵:

$$\boldsymbol{R}_{ZYX}=\begin{bmatrix} 0.708\,67 & -0.004\,606\,1 & 0.705\,53 & 0.000\,428\,51 \\ 0.006\,658\,6 & 0.999\,98 & -0.000\,159\,28 & -0.000\,122\,59 \\ -0.705\,52 & 0.004\,810\,4 & 0.708\,68 & -0.000\,508\,81 \\ 0 & 0 & 0 & 1 \end{bmatrix} \tag{10}$$

欧拉角的角度误差对应三轴Z,Y,X为(0.389°, −0.129°, 0.538°)。计算得到旋转误差矩阵:

$$\boldsymbol{R}_{e}=\begin{bmatrix} 0.001\,56 & -0.004\,61 & -0.001\,58 & 0.000\,43 \\ 0.006\,66 & -0.000\,02 & -0.000\,16 & -0.000\,12 \\ 0.001\,59 & 0.004\,81 & 0.001\,57 & -0.000\,51 \\ 0 & 0 & 0 & 0 \end{bmatrix} \tag{11}$$

分析实验一和实验二的结果,可以得知,本文基于3D-Harris关键点结合改进ICP算法无论是在单视角下的原始点云场景,还是全视角下的原始点云场景进行配准,都能够有效解决局部最优、点云数据量大等问题,平衡了点云配准的精度与效率,适合实时性要求高且初始位姿未知的激光点云配准场景。

4 结论

本文在点云配准算法现状的基础上,提出了基于3D-Harris关键点结合改进ICP的算法。该算法将基于改进ICP算法的姿态估计系统各部分与3D-Harris关键点检测算法结合,先对原始点云预处理,再提取出3D-Harris关键点,然后对关键点集进行FPFH特征描述,提供给SAC-IA采样一致性算法实现粗配准,最后利用Kd-tree加速ICP完成精配准并对配准误差进行计算。

为验证基于3D-Harris关键点结合改进ICP算法的优良性能,对多个视角下的原始点云采用配准算法进行姿态估计,设计了两组配准算法性能对比实验,并用姿态估计的相关误差理论进行了误差分析。实验结果表明,本文算法相比传统配准算法的配准精度更高,配准效率得到有效提升。此外,本文算法用于配准工程实际中的单视角原始点云时,同样表现出了良好的性能,为实际工程应用中基于点云配准的目标姿态估计任务提供了坚实的基础。

参考文献:

[1] Philippova A, Stroiteleva N, Gura D. Characterization of woody and shrubby vegetation in synanthropic forests using three-dimensional laser scanning technology [J]. Forest Science and Technology, 2025, 21(2): 158-164.

[2] Seo H, Sihag P, Fu L, et al. Novel R-C-C fusion machine learning method for automatic damage detection of heritage buildings using 3D point cloud data [J]. Journal of Civil Structural Health Monitoring, 2025, 15(6): 1921-1938.

[3] Tang Z, Tang Q. Weak texture 3D reconstruction method based on laser-assisted scanning and moving platforms [J]. Applied Optics, 2025, 64(7): 1604-1612.

[4] Parfenov V, Igoshin S, Masaylo D, et al. Use of 3D laser scanning and additive technologies for reconstruction of damaged and destroyed cultural heritage objects [J]. Quantum Beam Science, 2022, 6(1): 11.

[5] Xu J, Liu D, Liu Z, et al. Efficient encoding and aligning viewpoints for 6D pose estimation of unseen industrial parts [J]. Measurement Science and Technology, 2025, 36(1): 016034.

[6] 谷学静, 郭志斌. 层内调节特征金字塔的密集人群姿态估计算法[J]. 半导体光电, 2024, 45(6): 931-938.
Gu Xuejing, Guo Zhibin. Dense crowd pose estimation algorithm for in-layer adjustment feature pyramid [J]. Semiconductor Optoelectronics, 2024, 45(6): 931-938.

[7] Guo N, Zhang B, Zhou J, et al. Pose estimation and adaptable grasp configuration with point cloud registration and geometry understanding for fruit grasp planning [J]. Computers and Electronics in Agriculture, 2020, 179: 105818.

[8] Bai Y, Tran H, Damelin S B, et al. Partial transport for point-cloud registration [J]. Sampling Theory, Signal Processing, and Data Analysis, 2025, 23(1): 4.

[9] Chen R, Yang J, Xiao R, et al. Scanned point cloud registration for localization of aircraft access panel and complementary frame with weak features [J]. Advanced Engineering Informatics, 2025, 65: 103209.

[10] Zhang Q, Xue C, Qin J, et al. 6D pose estimation of industrial parts based on point cloud geometric information prediction for robotic grasping [J]. Entropy, 2024, 26(12):

1022.

[11] 侯　彬，金尚忠，王　赟，等. 点云配准方法在粗配准中的比较[J]. 激光与光电子学进展，2020，57(8)：294-301.
Hou Bin，Jin Shangzhong，Wang Yun，et al. Comparison of point cloud registration methods in coarse registration [J]. Laser & Optoelectronics Progress，2020，57(8)：294-301.

[12] Gou F，Li Y，Mao Y，et al. Planar tunnel point cloud fine registration under multiple constraints [J]. The Visual Computer，2025，41(10)：7319-7340.

[13] Zhao F，Huang H，Hu W. An optimized hierarchical point cloud registration algorithm[J]. Multimedia Systems，2024，31(1)：14.

[14] Yang L，Xu S，Yang Z，et al. Fast registration algorithm for laser point cloud based on 3D-SIFT features[J]. Sensors，2025，25(3)：628.

[15] Zhang Y，Wu J，Yang Z，et al. A coarse-to-fine DLG and TLS data registration method[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing，2023，16：3506-3518.

[16] Rusu R B，Blodow N，Marton Z C，et al. Aligning point cloud views using persistent feature histograms [C]//2008 IEEE/RSJ International Conference on Intelligent Robots and Systems，2008：3384-3391.

[17] Rusu R B，Blodow N，Beetz M. Fast point feature histograms (FPFH) for 3D registration [C]//2009 IEEE International Conference on Robotics and Automation，2009：3212-3217.

[18] Besl P J，Mckay N D. Method for registration of 3-D shapes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，1992，14(2)：239-256.

[19] 郑维刚，赵振威，唐　红，等. 基于三维激光点云的隧道电缆敷设质量参数自动检测方法[J]. 半导体光电，2023，44(3)：460-466.
Zheng Weigang，Zhao Zhenwei，Tang Hong，et al. Automatic detection method for tunnel cable laying quality parameters based on three-dimensional laser point cloud[J]. Semiconductor Optoelectronics，2023，44(3)：460-466.

[20] 赖慧敏，刘　杰，刘红海，等. 激光雷达接收机中时刻鉴别模块的研究和设计[J]. 半导体光电，2024，45(2)：303-307.
Lai Huimin，Liu Jie，Liu Honghai，et al. Design of time discrimination module in LiDAR receiver[J]. Semiconductor Optoelectronics，2024，45(2)：303-307.

[21] 王德智，周芸伊，刘晗庆，等. 多层次架构下融合自注意力的三维激光点云语义分割算法[J]. 半导体光电，2024，45(4)：646-652.
Wang Dezhi，Zhou Yunyi，Liu Hanqing，et al. 3D laser point cloud with self-attention under multi-level architecture semantic segmentation algorithms [J]. Semiconductor Optoelectronics，2024，45(4)：646-652.

[22] Yuan Q，Luo Y，Wang H. 3D point cloud recognition of substation equipment based on plane detection[J]. Results in Engineering，2022，15：100545.

[23] Camara M，Wang L，You Z. Three-dimensional point cloud displacement analysis for tunnel deformation detection using mobile laser scanning[J]. Applied Sciences，2025，15(2)：625.

[24] Zhou Z，Zhu H，Chen Y，et al. A feature-preserving simplification method for dense point clouds based on voxel priority filtering[J]. Measurement Science and Technology，2025，36(1)：015033.

[25] 阎雨梦，张　元，庞　敏，等. 改进的点云引导滤波算法[J]. 激光与光电子学进展，2023，60(22)：203-210.
Yan Yumeng，Zhang Yuan，Pang Min，et al. Improved point cloud guided filtering algorithm[J]. Laser & Optoelectronics Progress，2023，60(22)：203-210.

[26] 谷学静，杨宝上，刘秋月. 基于高斯滤波和AKAZE-LATCH的图像匹配算法[J]. 半导体光电，2023，44(4)：639-644.
Gu Xuejing，Yang Baoshang，Liu Qiuyue. Image matching algorithm based on Gaussian filtering and AKAZE-LATCH[J]. Semiconductor Optoelectronics，2023，44(4)：639-644.

[27] 张维刚，谢志华，车　驰，等. 基于二进制自相似描述符的多模态图像配准[J]. 半导体光电，2024，45(6)：966-970.
Zhang Weigang，Xie Zhihua，Che Chi，et al. Multimodal image registration based on binary self-similarity descriptors [J]. Semiconductor Optoelectronics，2024，45(6)：966-970.

[28] 赵云涛，胡佳明，李维刚，等. 基于改进FPFH特征提取的点云模板匹配方法[J]. 应用激光，2024，44(4)：196-204.
Zhao Yuntao，Hu Jiaming，Li Weigang，et al. Point cloud template matching method based on improved FPFH feature extraction[J]. Applied Laser，2024，44(4)：196-204.

[29] 谷学静，刘威威. 基于双边滤波和AGAST-BEBLID的图像匹配算法[J]. 半导体光电，2023，44(6)：919-923.
Gu Xuejing，Liu Weiwei. Image matching algorithm based on bilateral filtering and AGAST-BEBLID [J]. Semiconductor Optoelectronics，2023，44(6)：919-923.

作者简介：

陈宇超(1999—)，男，浙江省宁波市人，硕士研究生，主要研究方向为姿态估计算法；

蔡体菁(1961—)，男，浙江省宁波市人，博士，教授，博士生导师，主要从事惯性导航、组合导航和重力测量技术的研究。