

DOI:10.3969/j.issn.1003-5060.2026.03.006

## 基于 Louvain 改进的点云配准算法

陈 钰<sup>1</sup>, 余 敏<sup>1</sup>, 屈小川<sup>1</sup>, 李苗苗<sup>2</sup>, 高 鹏<sup>1</sup>

(1. 合肥工业大学 土木与水利工程学院, 安徽 合肥 230009; 2. 东北大学 工商管理学院, 辽宁 沈阳 110169)

**摘 要:**针对迭代最近点(iterative closest point, ICP)算法对初始位姿敏感的缺点,文章提出一种基于 Louvain 改进的快速点特征直方图(fast point feature histograms, FPFH)点云配准算法。首先,使用 FPFH 算法提取下采样后的点云局部特征,建立待配准点云之间的几何对应关系;其次,利用成对距离约束计算对应点对的一阶空间相似性,构建一阶无向加权图,将欧氏空间中的几何对应关系转化为图空间中的节点和边;再次,采用奇异值分解对由 Louvain 算法迭代得到的聚类节点求解空间变换矩阵,从而完成粗配准;最后基于 ICP 算法完成精配准。选取斯坦福大学 3 组公共点云集进行实验,结果表明,相较于采样一致性初始配准(sample consensus initial alignment, SAC-IA)算法,文章算法在达到近似甚至更高配准精度的情况下,配准时间缩短了约 20 倍,并且运行稳定可靠。

**关键词:**点云配准;Louvain 分区算法;快速点特征直方图(FPFH);迭代最近点(ICP);图论

**中图分类号:**TP391.412 **文献标志码:**A **文章编号:**1003-5060(2026)03-0325-05

## Improved point cloud registration algorithm based on Louvain

CHEN Yu<sup>1</sup>, YU Min<sup>1</sup>, QU Xiaochuan<sup>1</sup>, LI Miaomiao<sup>2</sup>, GAO Peng<sup>1</sup>

(1. School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China; 2. School of Business Administration, Northeastern University, Shenyang 110169, China)

**Abstract:** Aiming at the disadvantage that the iterative closest point(ICP) algorithm is sensitive to the initial pose, an improved point cloud registration algorithm based on Louvain using fast point feature histograms(FPFH) is proposed. Firstly, the local features of the down-sampled point clouds are extracted by FPFH algorithm, and the geometric correspondence between the point clouds to be registered is established. Secondly, the first-order spatial similarity of corresponding point pairs is calculated by using pairwise distance constraints, and the first-order undirected weighted graph is constructed to transform the geometric correspondence in Euclidean space into nodes and edges in graph space. Thirdly, the singular value decomposition is used to solve the spatial transformation matrix of the clustering nodes obtained by Louvain, thus completing the rough registration. Finally, precise registration is completed based on ICP algorithm. Three groups of public points from Stanford University are selected for experiments. The results show that compared with sample consensus initial alignment (SAC-IA) algorithm, the registration time of this algorithm is shortened by about 20 times with similar or even higher registration accuracy. Furthermore, the algorithm is stable and reliable.

**Key words:** point cloud registration; Louvain partition algorithm; fast point feature histograms (FPFH); iterative closest point(ICP); graph theory

收稿日期:2023-12-04;修回日期:2023-12-23

基金项目:国家自然科学基金资助项目(42171141);安徽省自然科学基金资助项目(2308085MD123)

作者简介:陈 钰(2000—),男,江西九江人,合肥工业大学硕士生;

余 敏(1976—),男,安徽歙县人,合肥工业大学讲师,通信作者,E-mail:yumin@hfut.edu.cn.

近年来,随着计算机视觉技术的发展,点云配准在三维重建<sup>[1]</sup>、目标检测<sup>[2]</sup>、同时定位与地图构建<sup>[3]</sup>等领域有着广泛应用。点云配准的目的是求解源点云与目标点云之间的正确空间变换矩阵,实现两片点云的对应点对齐到同一空间坐标系下。

根据配准精度,点云配准可以分为粗配准和精配准。粗配准是通过初步的匹配和估计,获得源点云与目标点云之间良好的初始姿态。精配准是在粗配准的基础上进一步优化点云的配准结果,提高配准精度。目前,国内外学者对点云配准进行了深入研究,其中文献<sup>[4]</sup>提出的迭代最近点(iterative closest point, ICP)算法在点云配准中得到了广泛应用。该算法使用最近邻搜索来寻找对应点对,并利用最小二乘法估计初始姿态。然而,传统的 ICP 算法存在对待配准点云初始姿态敏感、容易陷入局部最优和计算效率低等缺点。

为解决上述问题,大部分学者考虑通过粗配准给 ICP 算法提供一个具有良好初始位姿的点云,粗配准的核心问题在于估计正确的对应关系。例如:文献<sup>[5]</sup>提出一种使用主成分分析和矫正主轴方向的点云粗配准算法,但该方法会由于主成分分析本身的缺陷导致配准效果不佳;文献<sup>[6]</sup>利用主成分分析提取特征点,再根据轴向偏离比计算点的相似性,通过相似性建立的对应关系实现粗配准,该算法的局限性在于受噪声影响较大;文献<sup>[7]</sup>提出一种快速点特征直方图(fast point feature histograms, FPFH)的粗配准算法,这类方法对异常值和重复几何结构很敏感,缺乏点云的语义信息,因此精度较低且鲁棒性较差。为提高计算精度,部分学者通过增加约束条件来剔除错误对应关系。例如:文献<sup>[8]</sup>提出使用  $K$ -means 算法对 FPFH 中找到的匹配点集进行聚类,但该算法需要预设定簇的数量;文献<sup>[9]</sup>引入特征点的欧式距离约束来减少 FPFH 中的错匹配关系,然而单个点的距离约束存在模糊性;文献<sup>[10]</sup>引入成对距离约束建立兼容性三角形来去除错匹配关系,但存在计算效率低的缺点。

为提高配准的效率和精度,本文提出一种基于 FPFH 特征提取与 Louvain 分区聚类相结合的点云配准方法。首先,为提高 FPFH 特征提取的计算效率,本文对原始点云进行体素栅格下采样,针对 FPFH 得到的匹配点对存在大量错匹配关系的问题,使用一阶空间相似性测度将 FPFH 建立的几何对应关系转换为图空间的节点,选择相似性高的匹配点对建立边,从而克服使用单个

点对的欧式距离进行约束存在的模糊性,提高配准精度;然后,利用 Louvain 算法进行图空间中节点的聚类,选择聚类后包含节点最多的社区,利用奇异值分解求解空间变换矩阵进行粗配准;最后,使用 ICP 算法完成精配准。

## 1 理论方法

### 1.1 体素栅格法下采样

点云数据相较于二维图像具有几何特征信息丰富、数据量大和空间复杂度高的特点,因此对点云数据中的所有点进行处理会造成大量的计算开销。为了提升运算效率,在保留点云原有空间结构的前提下,本文采用体素栅格法对点云数据进行下采样。体素栅格采样的核心思想是将原始点云沿各个坐标轴方向划分为三维体素栅格,然后计算得到每个立方栅格的重心,最后将这些重心作为下采样点。

### 1.2 FPFH 特征描述

FPFH 是一种用于描述点云数据中局部特征的算法。它通过计算每个点的局部特征直方图来表示该点周围区域的几何结构信息。相较于其他基于特征的描述子,FPFH 的计算复杂度较低,在保留全局点云特性的情况下,能高效提取点云中的关键特征点。FPFH 计算示意图如图 1 所示。




图 1 FPFH 计算示意图

FPFH 计算步骤如下:

1) 对点云中的每个点矢量  $p$ , 选择在给定半径或者  $k$  邻域内的所有点。根据这些邻域中的每一对点矢量  $p_i$  和  $p_j$  ( $i \neq j$ ) 以及估计的法向量  $n_i$  和  $n_j$ , 构建一个  $uvw$  局部坐标系 ( $u = n_i$ ,  $v = (p_j - p_i) \times u$ ,  $w = u \times v$ ), 则  $p_i$  和  $p_j$  的 3 个特征元素  $\alpha, \varphi, \theta$  的计算公式如下:

$$\alpha = v \cdot n_j,$$

$$\begin{aligned}\varphi &= [\mathbf{u} \cdot (\mathbf{p}_j - \mathbf{p}_i)] / \|\mathbf{p}_i - \mathbf{p}_j\|, \\ \theta &= \arctan(\mathbf{w} \cdot \mathbf{n}_j, \mathbf{u} \cdot \mathbf{n}_j)\end{aligned}\quad (1)$$

2) 将  $\alpha, \varphi, \theta$  均划分为 11 个区间, 统计查询点  $\mathbf{p}$  与其  $k$  邻域的所有点  $\mathbf{p}_k$  的特征元素在 3 个分量上的直方图, 拼接为一个 33 维的特征向量, 称为简化点特征直方图, 记为  $S(\mathbf{p})$ 。

3) 每个点重新确定其  $k$  个近邻点, 并使用近邻的 SPFH 值对最终  $\mathbf{p}$  点的直方图进行加权, 称为快速特征点直方图, 记为  $F(\mathbf{p})$ , 即

$$F(\mathbf{p}) = S(\mathbf{p}) + \frac{1}{k} \sum_{i=1}^k \frac{1}{\omega_k} S(\mathbf{p}_k) \quad (2)$$

其中,  $\omega_k$  代表查询点  $\mathbf{p}$  与其  $k$  邻域的点  $\mathbf{p}_k$  之间的欧氏距离。

### 1.3 基于空间相似性的一阶无向加权图的建立

相较于欧式空间, 图空间可以更好地表示复杂的非线性关系和匹配关系的关联程度, 这有助于在配准过程中减小噪声和异常点的影响。

根据 FPFH 特征, 可以计算得到点云之间的几何对应关系。但由于各种误差的影响, 这些对应关系存在较多错匹配情况, 会降低配准精度, 因此需要剔除。一阶空间相似性测度是源点云中的两点  $\mathbf{p}_i^S$  与  $\mathbf{p}_j^S$  的欧式距离和目标点云的对应点  $\mathbf{p}_i^T$  与  $\mathbf{p}_j^T$  的欧式距离的差值, 差值越小, 则两组对应点越相似。通过相似性测度建立的成对距离约束可以避免单个点对约束的模糊性。通过遍历匹配点, 计算得到任意两组匹配点对的空间相似性, 并剔除相似性较低的点对来提高配准精度。

假设有两组匹配点对  $(\mathbf{c}_i, \mathbf{c}_j)$ , 该组点对的空间相似性计算公式如下:

$$S_{\text{dist}}(\mathbf{c}_i, \mathbf{c}_j) = |\mathbf{p}_i^S - \mathbf{p}_j^S| - |\mathbf{p}_i^T - \mathbf{p}_j^T| \quad (3)$$

$$S_{\text{cmp}} = \exp(-S_{\text{dist}}(\mathbf{c}_i, \mathbf{c}_j)^2 / 2d_{\text{cmp}}^2) \quad (4)$$

其中:  $S_{\text{dist}}$  为两组匹配点对的欧式距离差值;  $S_{\text{cmp}}$  为匹配点对  $(\mathbf{c}_i, \mathbf{c}_j)$  的相似性分数;  $d_{\text{cmp}}$  为距离差阈值。

根据以上分析, 可以构造一个一阶无向加权图。无向图是一个集合对  $G=(N, E)$ , 其中  $N$  是节点集,  $E$  是边集。如果  $(X, Y) \in E$ , 那么称  $G$  中的 2 个节点  $X$  与  $Y$  是相邻的。本文取匹配点的个数作为节点个数, 若  $S_{\text{cmp}}$  大于设定的阈值, 则对  $(i, j)$  建立边  $V$ ,  $S_{\text{cmp}}$  作为节点的权重赋值给边  $V$ , 由此将点云在欧氏空间中的几何对应关系转换为图空间中的节点和边。

### 1.4 基于 Louvain 算法的图空间聚类

在建立一阶无向加权图后, 若使用加权图中的全部的点对来求解空间变换矩阵, 则仍然存在一些空间相似性约束无法去除的错匹配关系影响

配准精度。因为正确的匹配点对具有更高的内部一致性, 所以可以对无向加权图的聚类结果进行求解, 以提高配准精度。

传统  $K$ -means 聚类<sup>[11]</sup> 是基于欧式空间进行的, 无法对图空间结构进行聚类。为解决这一问题, 引入相似度度量, 将对象的相似度作为其连边, 每个对象作为节点构建网络。此时, 欧式空间的聚类问题就转化为网络社区划分问题, 网络的社区划分结果即为聚类的结果<sup>[12]</sup>。

Louvain 算法<sup>[13]</sup> 是一种用于大型网络划分的迭代优化算法, 旨在将网络中的节点划分成内部具有紧密关联而外部关联稀疏的社区。该算法基于模块度的概念提出, 模块度用于度量网络中节点社区划分的质量, 通过衡量网络内部边的数量相对于预期随机分布情况下的数量是否更多, 从而判断节点在社区内聚类的程度。Louvain 算法通过最大化图的模块度来寻找最佳的社区划分。

基于图空间, 本文在点云配准领域中首次引入 Louvain 分区算法进行网络结构的聚类。该方法能快速有效地搜索到内部一致性更高的正确匹配点对, 且不需要事先指定聚类中心, 在效率和精度等方面具有显著优势。

Louvain 算法的 2 个主要参数是模块度  $Q$ <sup>[14]</sup> 和模块度增益  $\Delta Q$ 。Louvain 算法计算步骤如下:

1) 初始时将每个节点当作 1 个社区, 社区个数与节点个数相同。

2) 依次将每个节点与其相邻节点合并在一起, 计算它们最大的模块度增益。若大于 0, 则将该节点归入模块度增量最大的相邻节点所在社区。

3) 迭代步骤 2), 直至算法稳定, 即所有节点所属社区不再变化。

4) 将各个社区所有节点压缩成为 1 个节点, 社区内节点边的权重转化为新节点环的权重, 社区间边权重转化为新节点边的权重。

5) 重复步骤 1)~步骤 4), 直至算法稳定。

## 2 实验环境和实验分析

### 2.1 实验环境

实验环境设计的代码均采用 C++ 编写, 使用 open-source point cloud library 开源库 1.11.1, 编译器为 Microsoft Visual C++ (MSVC) 14.27, 未开启编译优化。计算机硬件配置为 Intel Core™ i7-10 700KF 处理器, 主频为 3.80 GHz, 内存为 32 GiB, 操作系统为 Windows 11。

数据集初始位置如图 2 所示。




图 2 实验测试数据集

本文的实验数据包括斯坦福大学经典的 Bunny、Armadillo 和 Happy Buddha 数据集。源点云选取 bun000、ArmadilloBack\_0、happyStandRight\_0 这 3 组点云。目标点云由 bun045、ArmadilloBack\_30 和 happyStandRight\_48 这 3 组点云通过平移参数(0.030, 0.020, 0.015) m 和旋转角度(50°, 70°, 120°)生成的空间变换矩阵得到, 其中平移旋转顺序为  $x \rightarrow y \rightarrow z$ 。源点云与目标点云具有不同的重叠度, Bunny 点云的重叠度约为 80%, Armadillo 点云的重叠度约为 60%, Happy Buddha 点云的重叠度约为 70%。

## 2.2 实验分析

为验证本文配准算法性能, 选取图 2 所示的

表 1 3 种数据集按不同算法粗配准的时间与精度

数据集	FPFH		SAC-IA		本文算法	
	$E_{RMS}/\text{mm}$	$t/\text{s}$	$E_{RMS}/\text{mm}$	$t/\text{s}$	$E_{RMS}/\text{mm}$	$t/\text{s}$
Bunny	0.152 817	3.831	0.010 155	354.496	0.004 551	18.349
Armadillo	0.183 835	1.692	0.016 908	60.116	0.025 557	2.307
Happy Buddha	0.126 485	4.858	0.006 838	221.178	0.026 182	6.972

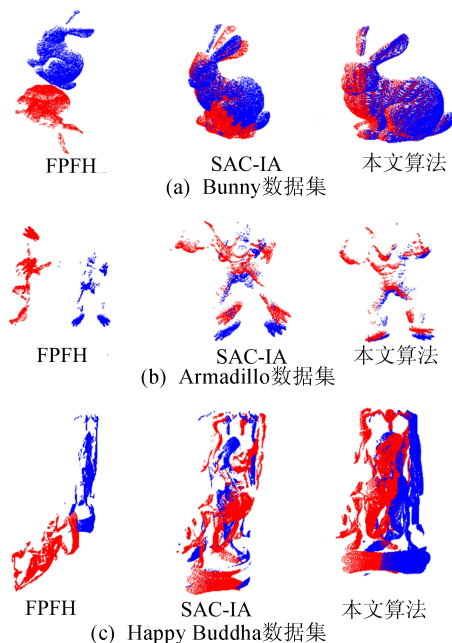


图 3 3 组数据集使用各算法粗配准实验结果

由图 3 可知, 3 组数据集姿态通过 FPFH 算

3 组点云作为实验数据集, 对 ICP、FPFH+ICP<sup>[15]</sup>、SAC-IA+ICP<sup>[16]</sup> 和本文算法+ICP 这 4 种算法进行粗配准和精配准的对比实验。其中 ICP 最大迭代次数和体素栅格下采样参数分别设置为 1 00 和 0.001。实验采用均方根误差 (root mean squared error, RMSE) 来衡量配准精度, 即

$$E_{RMS} = \sqrt{\frac{1}{R} \sum_{(i,j) \in R} \|G(\mathbf{p}_i^S) - \mathbf{p}_j^T\|^2} \quad (5)$$

其中:  $R$  为源点云和目标点云的对应点数量;  $G(\mathbf{p}_i^S)$  为源点云的点经过刚性变换矩阵变换后的点;  $G$  为空间变换函数;  $\mathbf{p}_j^T$  为目标点云中与源点云对应的点。粗配准实验结果见表 1 所列, 配准后的点云数据集如图 3 所示。

由表 1 可知: 在 3 组数据集中, FPFH 算法粗配准的时间最短, 配准精度最低; 在 Bunny 数据集中, 本文算法的配准精度最高, 配准时间比 SAC-IA 算法缩短近 20 倍; 在 Armadillo 和 Happy Buddha 数据集中, 本文算法精度略低于 SAC-IA 算法, 但配准时间分别缩短近 30 倍和 40 倍。

法粗配准后仍存在较大的偏差, 而利用本文算法进行粗配准后则大致重合, 视觉效果最好。

本文直接使用经典 ICP 算法进行精配准, 并将上述粗配准结果分别作为经典 ICP 算法的初始值进行精配准。3 种数据集按不同算法精配准实验结果见表 2 所列, 配准后的点云数据集如图 4 所示。

由表 2 可知: 直接使用 ICP 算法进行精配准的时间最长; 本文算法+ICP 的精配准时间相较于 ICP、FPFH+ICP、SAC-IA+ICP 分别缩短了近 100、4、4 倍, 平均配准时间与 FPFH+ICP 和 SAC-IA+ICP 算法相比也具有优势。

从图 4 可以看出, 对于初始位置姿态偏差较大的点云, ICP 和 FPFH+ICP 算法的配准结果均不理想。原因在于传统的 FPFH 算法包含大量的错误对应关系, 使得求解的空间变换矩阵存在较大偏差, 无法给 ICP 算法提供一个良好的初始位姿。

表 2 3 种数据集按不同算法精配准的时间与精度

数据集	ICP		FPFH+ICP		SAC-IA+ICP		本文算法+ICP	
	$E_{RMS}/mm$	$t/s$	$E_{RMS}/mm$	$t/s$	$E_{RMS}/mm$	$t/s$	$E_{RMS}/mm$	$t/s$
Bunny	0.019 174	74.039	0.016 957	12.611	0.003 397	1.508	0.003 399	0.734
Armadillo	0.019 335	2.786	0.028 169	1.129	0.014 787	0.517	0.014 726	0.563
Happy Buddha	0.009 698	9.778	0.010 371	12.867	0.004 913	2.256	0.004 916	2.249

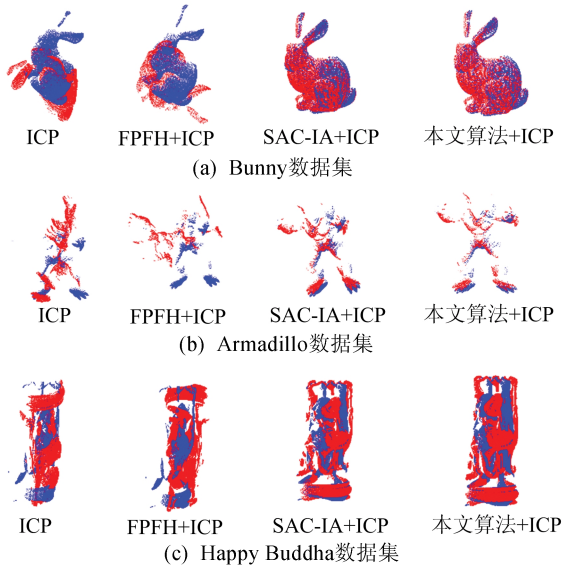


图 4 精配准实验结果

综上所述,经过本文算法粗配准后,3 组点云数据集位置姿态大致重合,可以为 ICP 算法提供良好位姿。

### 3 结 论

针对传统 ICP 算法依赖初始位置姿态的问题,本文提出了一种基于 Louvain 改进的点云配准算法。算法的核心思想为:通过一阶空间相似性将根据 FPFH 特征建立的几何对应关系转换为一阶无向加权图,并利用 Louvain 算法找出图中具有相似结构的节点组成的社区,选择划分社群中具有最多节点社区的匹配索引作为正确的对应关系,使用奇异值分解求解空间变换矩阵完成点云的粗配准。实验结果表明,相较于现有的主流算法,本文算法能为 ICP 算法提供良好的初始位姿,粗配准之后的主观视觉效果较好。在与 SAC-IA 算法配准精度相近甚至更高的情况下,本文算法平均配准时间缩短了近 20 倍,适用于对配准效率和精度要求较高的领域。

### [参 考 文 献]

[1] 于倩,凌晓春,赵明金,等.空地融合的建筑物室内外一体化

点云构建技术[J].测绘通报,2023(8):146-150.

[2] 熊璐,邓振文,田炜,等.融合语义和激光点云空间可见性特征的 3D 行人检测[J].激光与光电子学进展,2023,60(2):426-433.

[3] KIM P, CHEN J, CHO Y K. SLAM-driven robotic mapping and registration of 3D point clouds[J]. Automation in Construction, 2018, 89: 38-48.

[4] BESL P J, MCKAY N D. A method for registration of 3-D shapes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2): 239-256.

[5] 李慧慧,刘超,陶远.一种改进的 ICP 激光点云精确配准方法[J].激光杂志,2021,42(1):84-87.

[6] 代许松,花向红,田朋举,等.一种基于轴向偏离比的点云配准方法[J].测绘科学,2021,46(12):98-105.

[7] RUSU R B, BLONDOW 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. [S. l.]: IEEE, 2008: 3384-3391.

[8] 黄潜,王泽勇,李金龙,等.基于三维扫描的机车走行部螺栓识别与定位[J].光电工程,2018,45(1):51-58.

[9] 靳宇婷,张益华,崔海华,等.一种基于轮廓特征约束的飞机蒙皮配准方法[J].光学学报,2021,41(3):99-107.

[10] YANG J, HUANG Z, QUAN S, et al. SAC-COT: sample consensus by sampling compatibility triangles in graphs for 3-D point cloud registration[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-15.

[11] 何选森,何帆,徐丽,等. K-Means 算法最优聚类数量的确定[J].电子科技大学学报,2022,51(6):904-912.

[12] 柯建坤,许忠好. Louvain 算法与 K 均值聚类算法的比较研究[J].应用概率统计,2022,38(5):780-790.

[13] BLONDEL V D, GUILLAUME J L, LAMBIOTTE R, et al. Fast unfolding of communities in large networks[J]. Journal of Statistical Mechanics-Theory and Experiment, 2008, 2008(10): P10008.

[14] NEWMAN M E J, GIRVAN M. Finding and evaluating community structure in networks[J]. Physical Review E, 2004, 69(2): 026113.

[15] 陆军,彭仲涛.基于快速点特征直方图的特征点云迭代插值配准算法[J].国防科技大学学报,2014,36(6):12-17.

[16] 赵岚,余媛,温秀兰,等.基于机器视觉的分拣机器人 6D 位姿估计[J].计量学报,2023,44(10):1-6.

(责任编辑 胡亚敏)