

# 基于特征点匹配的排水管道声点云模型配准算法

张体浪<sup>1</sup>, 徐晓龙<sup>2</sup>, 杨亚峻<sup>1</sup>, 许俊松<sup>1</sup>, 宋柯<sup>2</sup>,  
黄英<sup>1</sup>, 李志伟<sup>2</sup>, 黄俊凯<sup>2</sup>, 江雅馨<sup>2</sup>

(1. 中建七局第二建筑有限公司, 江苏 苏州 215300; 2. 河海大学 信息科学与工程学院, 江苏 常州 213002)

**摘要:** 三维重建技术逐渐成为获取全面、完备、准确的排水管道信息的关键手段; 而实际检测受到管道堵塞等工况与管道检测规程等因素限制, 造成所获得的管道声呐点云模型会出现位姿不同、部分重叠或空缺等情况, 需要通过配准获取完整管道模型; 同时, 传统 ICP 算法针对管道模型存在效率低、精度差的问题; 因此, 文章提出基于特征点匹配的粗配准与改进的 ICP 精细配准相结合的点云配准算法; 首先, 利用 ISS 特征点检测法检测出模型特征点, 通过 FPFH 对特征点进行进一步的描述; 其次, 采用 RANSAC 算法筛选出正确特征匹配点集, 利用四元数法解算出初始变换参数完成粗配准; 最后, 在粗配准基础上, 通过改进最近对应点查询的 ICP 算法完成精细配准; 实验结果表明了该文算法的可行性与优越性, 能为后续排水管道缺陷检测提供高完备、全面、准确的点云模型。

**关键词:** 声呐点云; 点云配准; 特征匹配; 随机采样一致性; 迭代最近点

## Sound Point Cloud Model Registration Algorithm for Drainage Pipeline Based on Feature Point Matching

ZHANG Tilang<sup>1</sup>, XU Xiaolong<sup>2</sup>, YANG Yajun<sup>1</sup>, XU Junsong<sup>1</sup>, SONG Ke<sup>2</sup>,  
HUANG Ying<sup>1</sup>, LI Zhiwei<sup>2</sup>, HUANG Junkai<sup>2</sup>, JIANG Yaxin<sup>2</sup>

(1. The second Construction Co., Ltd. of 7 Engineering Bureau CSEEC, Suzhou 215300, China;

2. School of Information Science and Engineering, Hohai University, Changzhou 213000, China)

**Abstract:** 3D reconstruction technology is becoming a key tool for obtaining comprehensive, complete and accurate information about drainage pipes. Actual inspections are limited by the factors such as pipe blockage and pipe inspection protocols, resulting in different positions, partial overlaps or gaps in the obtained sonar point cloud model, which needs to obtain a complete pipe model through alignment. At the same time, the traditional ICP algorithm has the problems of low efficiency and poor accuracy for the pipeline model. Therefore, this paper proposes a point cloud alignment algorithm that combines coarse alignment based on feature point matching with improved ICP fine alignment. Firstly, the ISS feature point detection method is used to detect the model feature points, and further describe the feature points by the fast point feature histograms (FPFH); Secondly, the random sample consensus (RANSAC) algorithm is used to filter the correct feature matching point set, solve the initial transformation parameters by the quadratic method and complete the coarse alignment; Finally, based on the coarse alignment, the ICP algorithm with the improved nearest corresponding point query is used to complete the fine alignment. The experimental results demonstrate the feasibility and superiority of the proposed algorithm, which it provides a high-precision point cloud data model for the subsequent detection of tunnel defects.

**Keywords:** sonar point cloud; point cloud alignment; feature matching; random sampling consistency; iterative nearest point

## 0 引言

近年来由于我国城市建设日新月异和管网长期服役, 导致管道结构性破坏和功能性损伤时有发生<sup>[1]</sup>, 造成现有管道信息不全面、不完备、不准确<sup>[2]</sup>, 对其进行检测修复是保障城市管网安全运行的重要手段。目前声呐成像检测

技术是管网满水或半水工况下内部检测的唯一手段。基于声呐的排水管道三维重建技术相较于传统人工分段检测手段, 不仅能有效反映探测目标的形状<sup>[3]</sup>, 同时可实现对目标物进行剖面提取、坐标查询、距离测量等三维视觉损伤评估和测量功能。因此三维重建技术<sup>[4]</sup>逐渐成为城市排水管网安全检测的关键手段。但实际检测排水管道检测的过

收稿日期: 2023-05-25; 修回日期: 2023-06-30。

基金项目: 住房和城乡建设部 2022 年科学技术计划项目(2022-K-165); 中国建筑第七工程局有限公司局课题(CSEEC7b-2022-Z-5)。

作者简介: 张体浪(1981-), 男, 大学本科, 高级工程师。

通讯作者: 徐晓龙(1974-), 男, 硕士, 高级实验师。

引用格式: 张体浪, 徐晓龙, 杨亚峻, 等. 基于特征点匹配的排水管道声点云模型配准算法[J]. 计算机测量与控制, 2024, 32(5): 215-223.

程中, 由于受到管道堵塞等工况与管道检测规程等因素限制, 管道检测作业往往会进行多次、分段地采集<sup>[5]</sup>, 造成所获得的管道声呐点云模型会出现位姿不同、部分重叠或空缺等情况, 最终导致排水管道模型的完整性较差<sup>[6]</sup>。因此, 为了更好的实现排水管道三维重建, 需要进行点云模型配准<sup>[7]</sup>。

目前主流三维点云配准算法包含粗配准和精细配准<sup>[8]</sup>两个步骤。粗配准又叫全局配准, 因它主要针对任意初始位进行粗略的配准, 所以逐渐成为国内外学者们的研究重点<sup>[9]</sup>。文献 [10] 首先提出了基于随机取样一致性 (RANSAC, random sample consensus) 配准, 在忽略初始位置情况下依然可解决部分点云重叠的配准问题; 文献 [11] 提出了基于 RANSAC 的四点配准算法, 这类算法存在配准过程耗时较长、配准结果随机、对点云模型分辨率敏感等问题。为此基于局部特征的配准算法研究的逐渐变多<sup>[12]</sup>, 特征配准的关键便是对特征的描述<sup>[13]</sup>。文献 [14] 首先提出的一种点特征直方图 (PFH, point feature histogram) 描述, 首先利用局部坐标系, 将点与点之间的向量夹角等信息转化成多维特征向量, 最后通过直方图描述。然而, PFH 的计算复杂度较高, 不利于实际应用<sup>[15]</sup>。针对该问题, 文献 [16] 提出一种能保留 FPH 关键特征, 且优化算法复杂度的快速点特征直方图 (FPFH, fast point feature histograms), 该算法的快速的特点使其拥有实际应用的可能性; 基于上述算法的思想, 针对部分重叠的三维点云的粗匹配问题, 文献 [17] 提出一种基于 FPFH 的高级图形匹配算法来解决; 文献 [18] 提出了一种结合了签名法和直方图的方位标签直方图描述子, 该特征描述算法针对噪声与形状变化具有出色的鲁棒性。除此之外, 文献 [19] 提出的基于旋转图像 (Spin Image) 特征描述子的配准方法也在实践中广泛应用。基于旋转图像对遮挡、杂乱的稳定性和旋转平移不变性的优势, 针对杂乱且存在遮挡的三维点云的配准, 该方法能够取得比较满意的效果。

精细配准算法旨在求解最佳的变换关系, 通过逐步迭代的方式将一对三维点云的距离误差最小化。然而, 由于迭代过程容易陷入局部最优解, 无法保证收敛到全局最佳结果。因此下一步配准之前, 要通过粗配准提供一个较好的初始值, 从而增加迭代收敛到全局最佳位置的概率。目前常见的精细配准方法是迭代最近点 (ICP, iterative closest point) 算法。文献 [20] 最先提出了最近点迭代算法。该算法的基本原理是通过查找源点云在目标点云中的最近点, 将点到点的均方误差构成误差函数, 不断迭代获得最优值, 它最大的问题是对点云初始值要求较高。而文献 [21] 则提出了一种由点到其最近点切平面的均方误差构成的误差函数, 同时利用了局部集合特征的方式提升整个配准算法的收敛速度。两个 ICP 算法在迭代模式上是一致的且几乎同时提出, 所以都是经典 ICP 算法。

经典 ICP 算法经常出现陷入局部最优, 从而忽略全局最佳而导致效率和精度不高的问题。许多文献为了解决此

问题, 提出许多改进建议及相关研究。文献 [22] 首先提出了 Go-ICP 算法, 该算法采用了一种不依赖局部初始值的策略, 通过全局融合的方式实现精细配准, 在提高配准效率的同时, 保证了整体配准的精度和整体收敛速度的提升; 而文献 [23] 则提出了一种改进的点到切平面距离的计算方法, 该方法将点云中点到其切平面距离与点到投影距离两种距离相结合, 兼具精度优点以及速度优点, 实现了高效而快速的配准过程; 同时文献 [24] 通过增加了辅助条件, 引入强度信息来优化最近点搜索过程, 改进后的方法提高了点对之间匹配的准确性, 并且减少了算法消耗的时间, 进而提高整体的配准精度。此外文献 [25] 提出了 Generalized-ICP 算法, 将概率模型引入, 改良迭代条件中的误差函数, 提高对错误对应点的容错率, 优化经典 ICP 算法。此算法的优点在于对噪点有更强的鲁棒性的同时保留了 ICP 算法的高效率、低复杂度等优点。文献 [26] 则是依据点云的单应性, 针对性的提出一种迭代最近点匹配算法, 提高了在点云配准应用领域下 ICP 算法的性能。文献 [27] 则提出一种耦合法向量夹角、曲率、重心距离等特征参数, 来提高构成匹配点对的准确性, 从而提高 ICP 算法的精度。

综上所述, 传统 ICP 算法针对排水管道模型配准效率低、精度差, 本文来兼顾两种粗配准算法优点, 通过特征点匹配算法解决配准结果随机的的问题, 融合 RANSAC 算法进行验证与筛选来提高粗配准的效率与精度, 从而获取良好位姿, 优化 ICP 算法。此外本文还需要研究优化最近点对查询提高 ICP 算法效率, 降低整体配准计算时间提高三维重建的效率。最后本文从经典数据与水下管道两个数据集验证本文算法的可行性与优越性。

## 1 基于特征点匹配的点云粗配准

为了获取良好的初始位姿, 提高整体配准的精度与效率。本文提出了基于特征点匹配的三维点云粗匹配, 其主要步骤分别为特征点检测、特征点描述和特征匹配, 具体框架如图 1 所示。

### 1.1 基于 ISS 的特征点提取

为了能够保证点云能快速且有效地配准, 第一步需要完成两个点云模型的特征点集合提取。目前的特征点检测过程主要以固定尺度为主方法, 即以一个固定邻域半径为参数, 对特征点进行检测。其中常见的如基于法向量的特征点检测方法与内在形状特征点检测方法, 这两种检测方法的优点是简单易行、速度快, 十分适合于对管道模型的特征点提取。基于内在形状特征 (ISS, intrinsic shape signatures) 的特征点检测方法的基本原理是通过主成分分析法求解协方差矩阵, 获得其特征值, 然后基于特征值分析实现特征点提取。

假设某点云内共有  $N$  个点, 其中的任意一点  $p_i$  的坐标为  $(x_i, y_i, z_i)$ ,  $i \in \{0, \dots, N-1\}$ 。其具体步骤如下。

1) 以初始点云上的每一个点  $p_i$  为原点, 构成一个局部坐标系。基于已知邻域搜索半径  $r$ , 利用 k-d tree 搜索方法

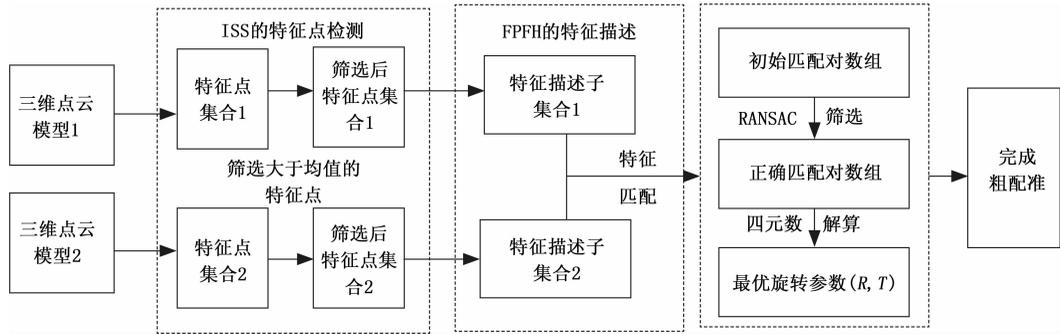


图 1 基于特征点匹配的粗配准框架

确定其邻域点集  $\{q_j, j \in \{1, \dots, k\}\}$ 。

2) 遍历点  $p_i$  中邻域半径  $r$  的邻域点集  $\{q_j, j \in \{1, \dots, k\}\}$  中所有的点, 并计算这些点的权值  $w_{ij}$ , 权值表达式为:

$$w_{ij} = 1 / \| p_i - q_j \|, | p_i - q_j | < r$$

$$i \in 0, \dots, N-1, j \in 0, \dots, k \quad (1)$$

3) 然后根据式 (2) 计算每个点  $p_i$  的协方差矩阵:

$$\text{cov}(p_i) = \frac{\sum_{|p_i - q_j| < r} w_{ij} (p_i - q_j)(p_i - q_j)^T}{\sum_{|p_i - q_j| < r} w_{ij}} \quad (2)$$

4) 然后通过特征值分解, 计算出每个点的  $p_i$  协方差矩阵  $\text{cov}(p_i)$  的三个特征值  $\{\lambda_{i1}, \lambda_{i2}, \lambda_{i3}\}$ , 并将获得的三个特征值按照从大到小正序排列。

5) 设定区域判断阈值  $\epsilon_1$  与  $\epsilon_2$ , 满足公式 (3) 点  $p_i$  可以视为 ISS 特征点。

$$\frac{\lambda_{i2}}{\lambda_{i1}} \leq \epsilon_1, \frac{\lambda_{i3}}{\lambda_{i2}} \leq \epsilon_2 \quad (3)$$

其中: 阈值  $\epsilon_1$  和  $\epsilon_2$  的取值不能超过 1。该公式主要目的是删选那些与主方向上具有相似性的点作为查询候选点, 提高算法的精度与效率。在完成阈值筛选后, 便可以获得点云的特征点集合。

以经典数据集中斯坦福兔子数据为例, 以搜索半径  $r$  和阈值  $\epsilon_1$ 、 $\epsilon_2$  为变化因素, 完成 ISS 特征点提取后结果如图 2 所示。从图 2 中可以显然看出, 当  $\epsilon_1$  和  $\epsilon_2$  的取值相对较大时, 会保留更多的初始点云的细节信息, 当  $r$  值较小时, 提取后的点云特征点的点密度较大, 因此需要进选取最优参数更好的保留点云特征区域的细节信息。

### 1.2 基于 FPFH 的特征描述子

在 1.1 小节的基础上, 提取出两个点云模型的特征点集合, 下一步需要对其进行特征描述, 即需要通过特征描述子对特征点集进行局部信息描述, 以便之后的两个点云的特征描述子集合中的特征描述子匹配, 建立两个描述子集合间的对应关系, 从而确立特征点之间的对应关系。

特征描述子又称特征向量本质是以数据的形式表达点特征, 目前常用的特征描述子有旋转图像描述子、点特征直方图描述子、唯一形状环境描述子。点特征直方图描述子通过计算特征点于其邻域内点之间的空间差异, 并通过统计直方图的形式, 来描述特征点的  $r$  邻域几何属性。本文

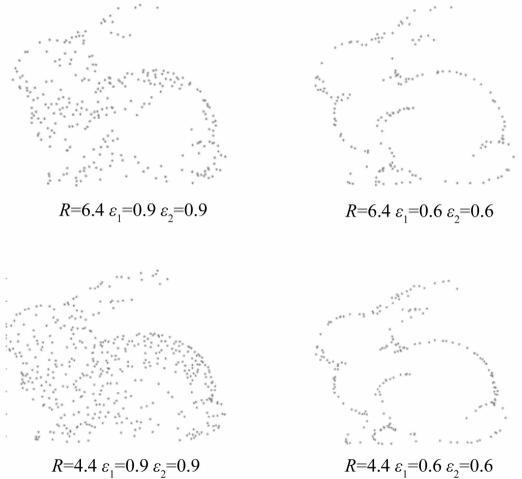


图 2 不同参数下的特征点集合图

采用 FPFH 进行特征描述, 该方法在点特征直方图描述子的基础上, 保留其旋转不变的特性, 简化计算复杂度, 提高整体运算效率。具体的计算流程如下:

1) 设点云中某一点  $p_i$ , 基于  $k$ -d tree 搜索确认  $k$  个邻域点的子集  $\{q_j, j \in \{1, \dots, k\}\}$ , 以两点之间相对应的法线为  $n_i$  和  $n_j$ 。在点  $p_i$  上定义如图 3 所示的一个局部的坐标系  $uvw$ , 方便计算两点的法线  $n_i$  和  $n_j$  之间存在的相对偏差, 其具体公式如 (4) 所示:

$$\begin{cases} u = n_i \\ v = u \times \frac{(p_i - q_j)}{\| p_i - q_j \|_2} \\ w = u \times v \end{cases} \quad (4)$$

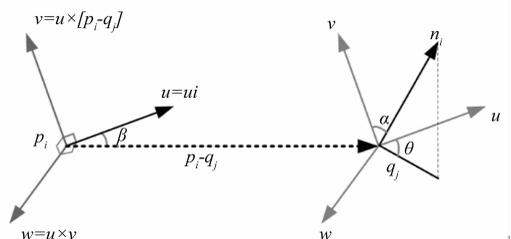


图 3 局部坐标系图

2) 在图 3 中点  $p_i$  的  $uvw$  局部坐标系上, 采用  $(\alpha, \beta,$

0) 角度三元素, 更精确的表达法线  $n_i$  和  $n_j$  两者间的偏差关系, 具体如公式 (5) 所示:

$$\begin{cases} \alpha = v \cdot n_j \\ \beta = u \cdot \frac{p_i - q_i}{d} \\ \theta = \arctan(\omega \cdot n_i, u \cdot n_j) \\ d = \|p_i - q_i\| \end{cases} \quad (5)$$

计算点  $p_i$  与其每一个邻域点的之间的一组  $(\alpha, \beta, \theta)$  角度三元素, 这个过程即为 SPFH。

3) 如图 4 所示, 其为 FPFH 的原理示意图, 在 1) 的基础上可以获得邻域点  $q_j$ , 然后搜寻其包含  $k$  个邻域点的邻域点子集, 计算点  $q_j$  点的 SPFH, 最后通过加权计算得到最终的 FPFH。公式如 (6) 所示:

$$FPFH(p_i) = PFH(p_i) + \frac{1}{k} \sum_{j=1}^k \frac{1}{\omega_k} SPFH(q_j) \quad (6)$$

其中:  $\omega_k$  是权重, 其由点  $p_i$  和其邻域点  $\{q_j, j \in \{1, \dots, k\}\}$  之间的距离来衡量。

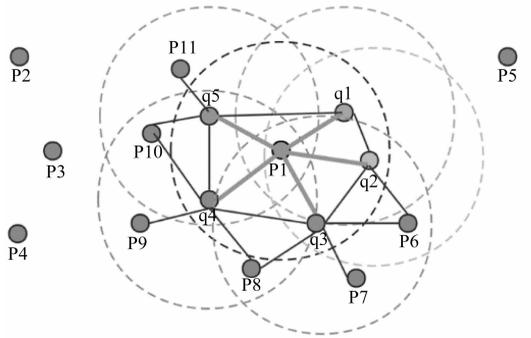


图 4 FPFH 原理示意图

4) 最后循环整个特征点集, 计算每个点的特征描述子, 每个特征点 FPFH 描述子是 33 维。如图 5 所示, 其展示两个特征点的快速点特征直方图。从图中可以明显看出两个特征点的特征信息不一致。下一步就是计算两个点云模型所有特征点的特征直方图, 并进行特征匹配。

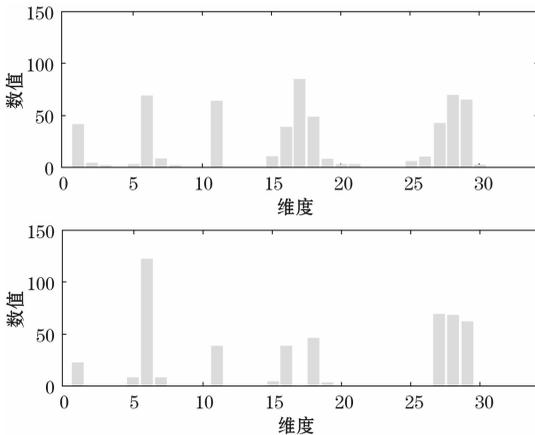


图 5 两个特征点的 FPFH 直方图

### 1.3 基于改进 RANSAC 算法的特征匹配

在 1.2 小节的基础上, 根据特征点之间的对应关系,

选出相互匹配的特征点对。其中常用的算法包括阈值法、最近邻法、双向最近邻法与距离比法等, 此类都是通过索引两点间欧式距离的关系来实现特征匹配的算法。然而, RANSAC 算法特殊之处在于不考虑点云间欧式距离的相差大小, 其核心思想是通过将数据经过一系列迭代而推算出相关的数学模型所需参数。使用 RANSAC 算法有着必要的前提: 首先, 假设原数据集包含正确数据和异常数据; 其次, 假设一定有方法能够从一组正确的数据中计算出一组符合映射关系的数学模型的参数。

因 RANSAC 算法存在正确特征点配对率影响算法稳定性与计算效率的问题, 所以当出现重叠区域过多、错误匹配点对过多等情况, 单靠该算法会使粗配准精度差且效率低。因此需要在 RANSAC 算法之前, 进行预筛选, 减少匹配点对数组的量; 同时还需结合刚体变换的距离不变性原则, 减少算法迭代次数, 提高正确特征匹配点对筛选精度, 提高粗配准效率。

基于此, 本文首先基于两点间欧式距离, 筛选初始的特征匹配点对集合; 其次, 采用一种结合刚体变换的距离不变性原则的自适应的 RANSAC 算法, 以此实现对配对点集的筛选, 从而优化了特征匹配的选取; 最后运用四元素法计算获得初始配准参数, 完成粗配准。以斯坦福大学 bunny 数据为例, 详细的算法步骤如下所示。

1) 两个点云的特征点子集分别为  $P_i$  和  $Q_i$ , 假设两个点云之间存在部分重叠, 以两点间的欧式距离为准则, 并设置阈值  $\epsilon_3$ , 去除特征点子集点中间距离大于  $\epsilon_3$  的匹配点对, 将剩下的记为初始匹配点对数组  $S_m$ , 计算公式如式 (7) 所示。最终的初始特征点匹配如图 6 所示。

$$S_m = (s_i^1, s_i^2) \mid s_i^1 \in P_i, s_i^2 \in Q_i, i=1, 2, 3, \dots, n \quad (7)$$

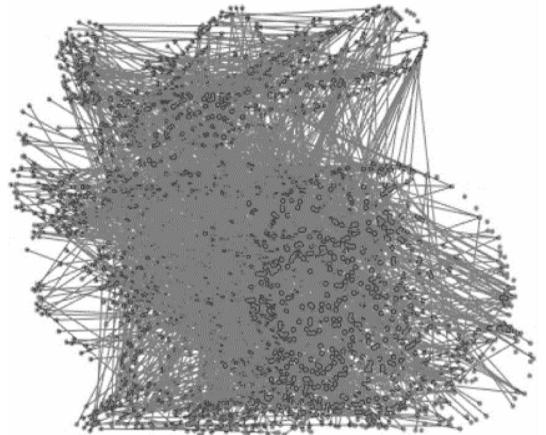


图 6 初始特征点的匹配图

2) 设初始匹配点对数组  $S_m$  中任意两个点对  $(s_i^1, s_i^2)$  和  $(s_j^1, s_j^2)$ , 为正确的匹配点对, 则其满足刚体变换中点间距离不变性原则。于是设定阈值  $\epsilon_4$ , 计算点  $(s_i^1, s_i^2)$  除自身外, 满足公式 (8) 约束的点的数目  $num_i$ , 如图 7 所示为按照刚性不变原则筛选后的特征点匹配。

$$\frac{\left| \frac{\|s_i^1 - s_j^1\|}{\|s_i^1 - s_i^2\|} - \frac{\|s_j^1 - s_j^2\|}{\|s_j^1 - s_j^2\|} \right|}{\frac{\|s_i^1 - s_j^1\|}{\|s_i^1 - s_i^2\|} + \frac{\|s_j^1 - s_j^2\|}{\|s_j^1 - s_j^2\|}} < \epsilon_4 \quad (8)$$

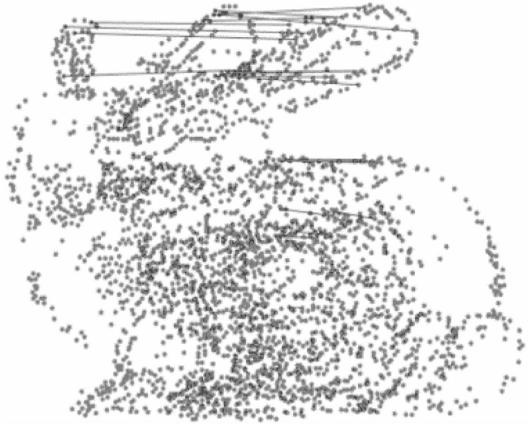


图 7 通过刚性不变约束的特征匹配图

3) 由于假定初始匹配点对数组中已经存在一定的满足约束的正确匹配点对, 且该点对数目  $num_i$  相对较大。当计算出每个点对的  $num_i$  值后, 按照  $num_i$  值大小排序, 选取前  $N$  个点对进行筛选, 下一步通过 RANSAC 检验是否为正确匹配点。

4) 根据刚体变换矩阵  $T_{ic}$  求解原则, 从  $N$  个点对中随机选取 3 个点对作为第一次计算的选取点, 并假定它们为正确匹配点对, 计算刚体变换矩阵  $T_{ic}$ 。

5) 判断其余  $N-3$  个点对, 再经过刚体变换矩阵  $T_{ic}$  后是否满足式 (9) 约束。

$$\|T_{ic}(s_i^1), s_i^2\| < \epsilon_5 \quad (9)$$

其中:  $\epsilon_5$  的值一般为点间平均距离的 2 倍。将满足公式约束的  $(s_i^1, s_i^2)$  视为正确匹配点; 否则,  $(s_i^1, s_i^2)$  视作错误匹配点。将所有正确匹配点组成本次采集的一次数组, 然后根据内点的数目更新采用次数上限。

6) 依照采样数量, 重复执行步骤 4) 与 5)。将正确匹配点数目最多的刚体变换矩阵作为正确的刚体变换矩阵  $T_{ic}$ , 依据矩阵  $T_{ic}$  计算出初始匹配点集中的精确匹配点对。经过 RANSAC 算法处理后的匹配点对如图 8 所示。

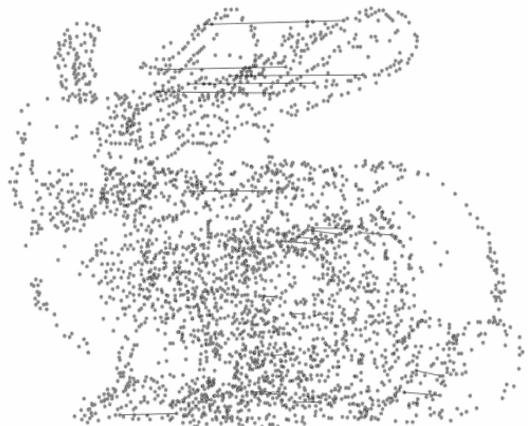


图 8 经过 RANSAC 筛选后的特征匹配图

最后在精确匹配点集的基础上, 通过四元数法计算获得旋转矩阵  $R$  与平移矩阵  $T$ 。并且依照公式 (10), 将点云

$P$  中的点  $p_i$  变换到点云  $Q$  所在的坐标系下, 并将转换后的点云记为  $p'_i$ , 最后完成粗配准。

$$p'_i = R \cdot p_i + T \quad (10)$$

## 2 基于改进 ICP 算法的点云精细配准方法

在上一小节的基础上, 已经将两个不同时刻采集的位姿复杂的点云模型变换进入同一个坐标系中, 并使得点云模型有一个相对较好的初始位姿。但两个点云模型配准的精度目标未能满足需求, 因此需将粗配准的结果作为 ICP 的初始值进行精确配准。

ICP 算法思路是: 首先依据前置条件获得的初始值或者上一次迭代计算出的变换矩阵与中间过渡点云, 设置源点云与目标点云, 随机寻找源点云中某点与其在目标点云中的最近点组成点对; 其次根据估计的变换关系, 求解变换参数如平移矩阵  $T$  和旋转矩阵  $R$ ; 再次计算位姿变换后的两个距离最近点之间的距离误差函数  $E$ , 不断迭代直至误差小于预设的阈值  $\epsilon_6$  或者达到迭代次数  $i_{max}$ ; 最后求解出最优变换关系, 实现点云配准。ICP 算法流程如图 9 所示。

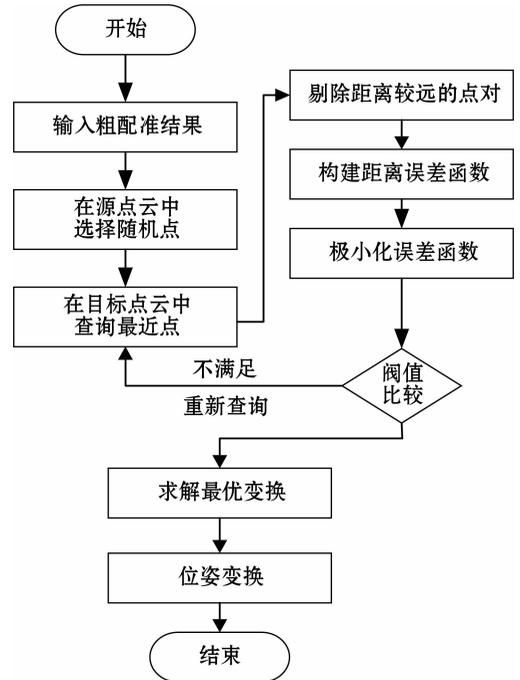


图 9 ICP 算法流程图

根据距离最近原则可得出, 源点云  $S = \{S_1, S_2, S_3, \dots, S_N\}$  与目标点云中  $P = \{P_1, P_2, P_3, \dots, P_N\}$ , 其中点  $S_i$  与  $P_i$  组成对应点。可以求解出旋转参数  $R$  和  $T$ , 构建距离误差函数  $E$ , 如公式 (11) 所示, 并使其最小。

$$E(R, T) = \frac{1}{N} \sum_{i=1}^N \|S_i - (RP_i + T)\|^2 \quad (11)$$

ICP 算法的关键在于假设距离最近的点是相互匹配的, 以此为基础求解变换矩阵, 然后重复迭代直到满足误差需求。所以关键是最近对应点的查找。传统 ICP 算法是直接两片点云中查找最近对应点, 在程序实现过程中嵌入双

重循环, 会严重耗时影响整体配准效率。同时当两片点云之间仅仅存在部分重叠并非包含关系, 传统 ICP 算法由会受到非重叠区域点的影响, 导致配准的精度较低。

针对传统算法的不足, 本文对最近对应点的查找算法提出改进。在降低算法复杂度问题上, 可以通过构建 k-d tree 数据结构, 优化加速查找过程; 此外可以通过筛出内点, 提高整体效率与精度。具体的算法步骤如下所示。

1) 基于先前小节的特征点匹配的粗配准基础, 已经获得了同一坐标系下良好的初始位置关系。将粗配准的误差值设定为阈值  $\sigma$ 。其中阈值  $\sigma$  初始值为粗配准后的距离误差值, 之后取上一次迭代后的距离误差值。

2) 假设目标点集中  $S_i$  与参考点集中的最近点  $P_i$ , 若满足公式 (12) 则将点  $S_i$  记为内点, 否则记为外点并提出。

$$\|S_i - P_i\| < \sigma \quad (12)$$

3) 利用筛选后的内点集求解变换矩阵, 然后进行下一次 ICP 迭代, 直到满足算法终止条件之一。

### 3 实验结果与分析

为验证本文提出的配准算法具有优越性, 本文分别采用经典数据集包括斯坦福大学提供的扫描数据兔子 (bunny)、椅子 (Chair) 和马 (Horse), 与实验采集的管道数据包括 PipeA 和 PipeB, 进行配准实验。因本文采用的是一种基于特征的粗配准与 ICP 精细配准相结合的点云配准算法, 所以本文选取了 FPFH-ICP 算法与传统的 ICP 算法作为对比实验, 以验证本文算法的可行性以及针对管道配准的优势。本文实验采用的计算机设备, 具体参数如下 Inter Core 17-10750H CPU、16 GB 内存。

#### 3.1 点云配准客观评价指标

为了验证算法的精度与效率, 本文提出了均方根误差 (RMSE, root mean square error)、运算时间和迭代次数作为客观评价指标。RMSE 的定义如下式 (13) 所示:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N d_i^2}{N}} \quad (13)$$

$$d = \|\mathbf{R}p_i + \mathbf{T} - q_i\| \quad (14)$$

其中:  $[\mathbf{R}, \mathbf{T}]$  为配准算法计算出的旋转参数, 公式 (14) 是计算配准后模型之间最近点的欧式距离。RMSE 现实描述的是两个不同时刻测量的值, 在其中某一时刻的值配准后, 两者之间的偏差的平方和观测次数  $N$  比值的平方根, 其值越小说明配准的效果越好。运算时间越小说明算法的效率越高。而迭代次数主要是评价粗配准的效率, 粗配准得到的旋转参数越好, 精配准所需的迭代次数越小。最后本文实验中, 待配准点云的初始位置随机, 算法的基本参数设置如下:  $r=5, k=6; N=50$ 。

#### 3.2 经典数据配准对比实验

##### 3.2.1 主观评价

在 3 个经典数据上的不同算法的配准效果如图 10 所示。选取这 3 种经典数据是为了验证算法在不同特征、不同尺度上都有效果。为了增强主观判断, 本文将两个点云分别

渲染成绿色和紫色, 通过颜色重叠程度, 判断配准效果。图 10 中第三行至第五行为 3 种配准算法的实际效果, 可以明显看出 3 种配准算法在 3 个模型上均能实现一定的点云配准。第二行展示的是本文算法的基于特征点匹配的粗配准结果, 其优秀的粗配准已经和传统 ICP 算法效果差不多, 在此基础上的改进型 ICP 的精细配准, 如图中第三行所显示的, 本文算法在边缘细节上由于其余两种算法。

虽然 3 个经典模型的特征不同、大小不同, 直接用传统 ICP 算法整体上点的精确重合程度明显比其他两种算法弱, 两个点云的边缘部分颜色分布误差比较明显。此外 FPFH-ICP 算法相对于 ICP 算法有优势, 但是在尺度较大的如 Horse 模型与 Chair 模型配准中, 其仍出现多块独立的不重叠情况, 明显差于本文算法。所以在主观评价方面, 本文配准算法效果优于其余两种算法。

##### 3.2.2 客观评价

经典模型数据不同配准算法的客观评价指标结果如表 1 和表 2 所示, 表 1 为本文配准算法前后两步配准的客观评价指标结果, 表 2 为不同配准算法客观评价指标对比。表 1 与表 2 的结果是分别对每组模型进行 10 组实验并取平均值后得到配准误差和耗时。从表 1 中可以看出, 本文算法的粗配准阶段耗时略长, 所以粗配准的精度较好, 同时也降低了精细配准的迭代次数, 提高精细配准的效率, 最终整体的配准效率依然不错。

表 1 本文配准算法的结果

点云模型	粗配准时间/s	精配准时间/s	整体配准	
			时间/s	误差/mm
Bunny	1.645	1.108	2.753	$2.688 \times 10^{-6}$
Horse	1.795	1.021	2.516	$6.461 \times 10^{-8}$
Chair	2.848	1.201	4.053	$3.313 \times 10^{-6}$

表 2 不同配准算法的客观评价指标结果

点云模型		Bunny	Horse	Chair
ICP	时间/s	11.945	8.654	24.041
	误差/mm	$2.703 \times 10^{-5}$	$3.412 \times 10^{-6}$	$1.723 \times 10^{-5}$
	迭代次数	11	9	14
FPFH-ICP	时间/s	3.472	2.731	8.012
	误差/mm	$3.792 \times 10^{-6}$	$1.219 \times 10^{-6}$	$2.471 \times 10^{-5}$
	迭代次数	4	8	11
本文算法	时间/s	2.753	2.516	4.053
	误差/mm	$2.688 \times 10^{-6}$	$6.461 \times 10^{-8}$	$3.313 \times 10^{-6}$
	迭代次数	2	2	3

从表 2 的数据可以观察到, bunny 模型的三种方法都表现出极小的误差。然而, 传统 ICP 算法虽然效果显著, 由于其迭代次数较多因此效率相对较低。与之相比, FPFH-ICP 算法明显提升了配准的效率。本文提出的算法通过两个关键步骤优化了这一流程: 首先, 通过优化粗配准以获得更佳的初始位置, 从而减少精细配准所需的迭代次数; 其

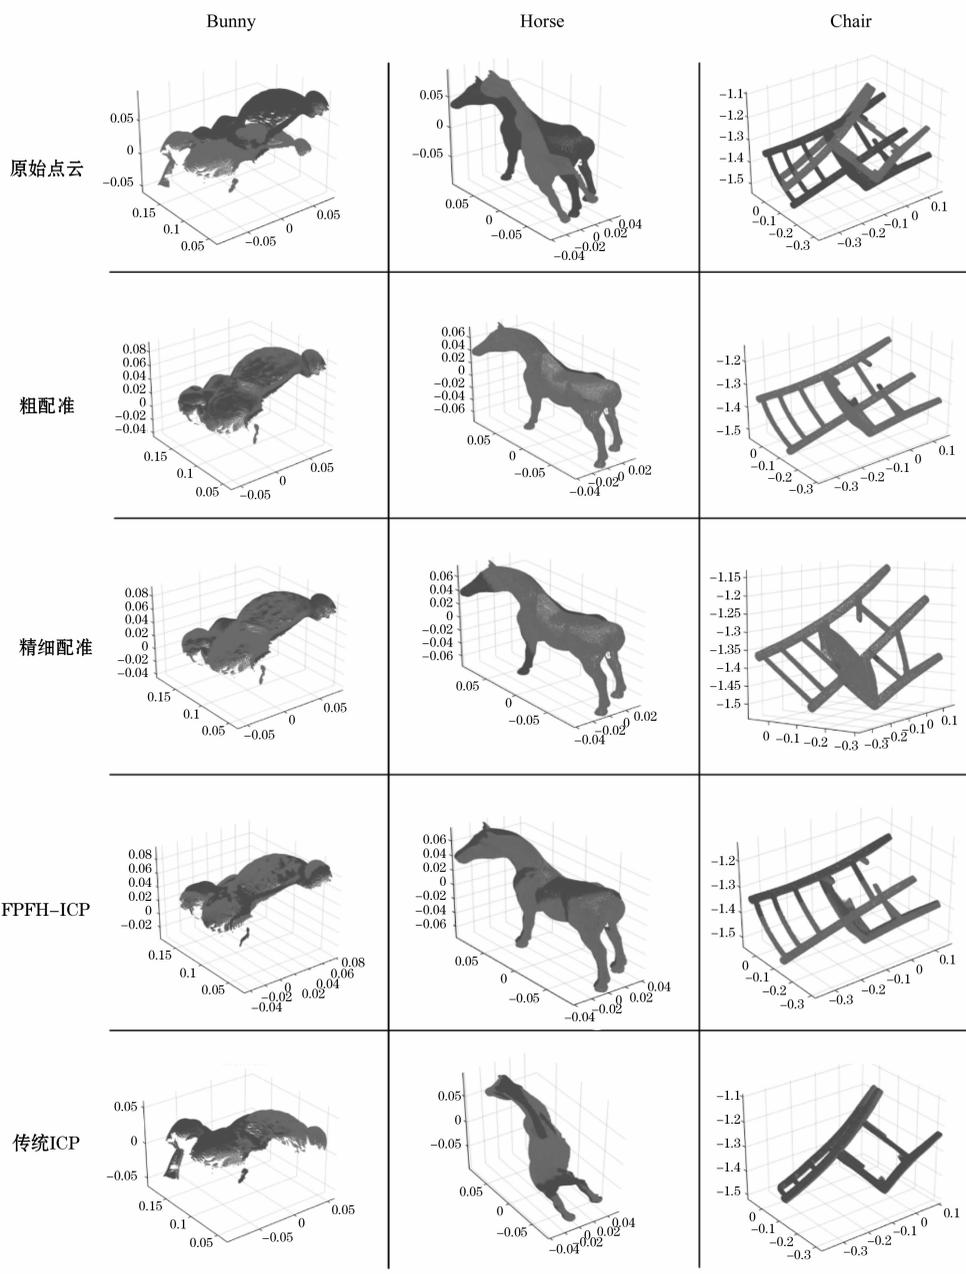


图 10 经典模型不同算法的配准结果图

次, 在精细配准阶段, 通过数据筛选提高了对应点的搜索效率。如此一来, 不仅降低了配准误差, 还减少了整体的配准时间。

本文提出的算法相较于 FPFH-ICP 能够节省大约 24% 的时间。就 Horse 模型而言, 尽管其数据结构和完整性较差, 但在配准性能上超越了 FPFH-ICP 和传统 ICP。尽管耗时相近, 但精度有了显著提升。在 Chair 模型方面, 规模较大但结构相对简单, 三种方法的配准效率都有所下降, 但误差值都保持在较低水平。特别值得一提的是, 本文算法的迭代次数显著少于传统 ICP 算法。

### 3.3 水池管道数据配准对比实验

为验证本文算法的实用性和稳定性, 在第三章所述的基础上设计了实验, 模拟了混凝土管道在水池中的场景。水池尺寸为 6 米长、2 米宽, 水深 1.2 米, 管道长度约为 3 米, 直径约 1 米, 具体示例见图 11。

实验设计注重于实际应用, 因此选择两种典型的数据集。首先, 对同一物体在不同角度进行了多轮测量, 由于每次测量的数据量不同, 通过配准能提升重建的精度, 如 PipeA 模型所示。其次, 收集了同一物体在不同角度下的重复测量, 这些数据存在部分重叠, 配准对于构建完整的点云模型至关重要, 如 PipeB 模型的案例。通过 PipeA 和

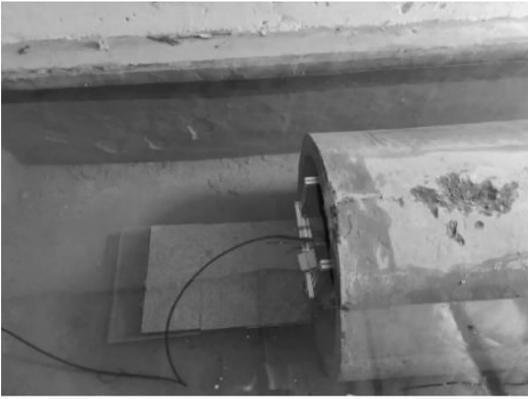


图 11 水池管道模拟实验图

PipeB 的配准实验，将详细展示本文所提出算法在实际场景中的性能和效果。

### 3.3.1 主观评价

PipeA 模型的配准效果如图 12 所示，PipeB 模型的配准效果如图 12 所示。

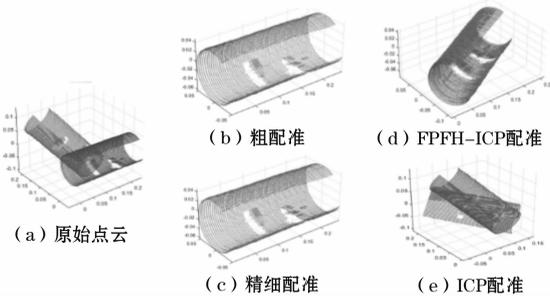


图 12 PipeA 模型配准效果图

图 12 清晰地展示了三种配准算法的对比：图 12 (b) 呈现了特征点匹配的粗略配准，图 12 (c) 展示了改进型 ICP 的精细配准，图 12 (d) 是 FPFH-ICP 的配准结果，而图 12 (e) 则是传统 ICP 的配准。由于实际管道尺寸较大，配准效率受到了影响，因此首先对模型进行了尺寸调整，以提高处理效率。

从视觉效果来看，传统 ICP 在大尺度管道上的表现并不理想。相比之下，FPFH-ICP 算法在配准效果上尤为显著，特别是在管口区域，重叠度明显降低。这表明在处理小尺度管道模型时，本文的配准算法在精度和效率上具有显著优势，尤其在处理这类场景时，其性能得到了充分展现。

图 13 (a) 展示了 PipeB\_1 和 PipeB\_2 的初始状态，其中 PipeB\_1 包含 24, 560 个点，PipeB\_2 有 23, 178 个点。这两个模型虽然存在部分重叠，但它们分别代表了管道在不同角度下的数据。为构建完整的点云模型，精确配准是必要的。从图中观察，三种算法都能实现配准，但传统 ICP 算法的结果显示出明显的坍塌，配准后的模型重叠度较低。尽管 FPFH-ICP 算法减少重叠，却在管道口处仍可见到一些未完全匹配的区域。

本文的配准算法在与 FPFH-ICP 和传统 ICP 的对比中，

表现出更为优秀的配准效果。不仅保持了较高的重叠度，且在处理管道口的细节上更为精确，这表明本文算法在处理这类具有复杂重叠和角度变化的管道模型时，具有显著的优势。

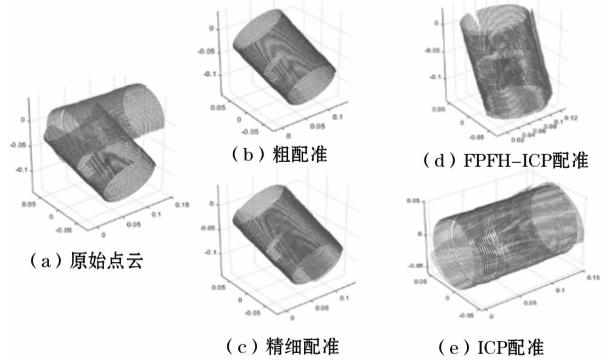


图 13 PipeB 模型配准效果图

### 3.3.2 客观评价

表 3 提供了对 PipeA 和 PipeB 模型点云配准的详细评估。共进行 10 次实验，通过平均值反映了配准误差和耗时。根据表中的数据，可以看出所提出的方法在配准性能上表现出显著优势。以 PipeA 模型为例，本文方法的配准误差比 FPFH-ICP 低了 12%，而在时间上，却比 FPFH-ICP 节省了 30% 的时间。这些结果清楚地表明，对于模拟实际场景采集的管道模型，本文方法在配准精度和效率上都具有明显的优势。

表 3 不同配准算法的客观评价指标结果

点云模型		PipeA	PipeB
ICP	时间/s	3.641	5.741
	误差/mm	$2.787 \times 10^{-2}$	$2.014 \times 10^{-3}$
	迭代次数	8	14
FPFH-ICP	时间/s	1.241	2.912
	误差/mm	$2.437 \times 10^{-6}$	$1.118 \times 10^{-3}$
	迭代次数	5	8
本文算法	时间/s	0.752	1.471
	误差/mm	$3.163 \times 10^{-7}$	$2.237 \times 10^{-4}$
	迭代次数	1	2

综上所述，本文方法在实际应用中的可行性和优越性得到了验证，尤其是在处理这类复杂场景的管道模型时，其高效且精确的配准能力得到了充分展现。

## 4 结束语

本文针对实际采集管道模型存在不完整、部分重叠等问题，提出了一种基于特征点匹配的粗配准与改进的 ICP 精配准相结合的点云配准算法。其中粗配准的关键是通过采用改进的 RANSAC 的特征匹配，即结合刚性变换距离不变原则与 RANSAC 算法筛选出正确的特征匹配点对，提高粗配准的精度与效率。为了验证本文配准算法的精度与效

率,本文从经典公开数据与水池模拟采集的数据两个方面将所提算法与传统ICP算法、FPFH-ICP算法进行对比。在经典数据方面,本文算法的精度已经优于FPFH-ICP算法与传统ICP算法。同时本文配准方法在Bunny模型上比FPFH-ICP算法缩短了24%的时间。在水池模拟采集的管道数据方面,本文配准算法不仅能够有效配准重叠部分较高的管道模型,来减少管道模型的空洞率,而且能实现不同角度下的两个管道模型进行配准拼接,来获得完整的管道模型。并且本文配准算法在精度与效率方面依然优于对比的两种配准算法。

#### 参考文献:

- [1] MA M, WANG H, JIA P, et al. Investigation of inducements and defenses of flash floods and urban waterlogging in Fuzhou, China, from 1950 to 2010 [J]. *Natural Hazards*, 2018, 91 (3): 803-818.
- [2] VISHNUVARDHAN S, MURTHY A R, CHOUDHARY A. A review on pipeline failures, defects in pipelines and their assessment and fatigue life prediction methods [J]. *International Journal of Pressure Vessels and Piping*, 2022: 104853.
- [3] LI B, ZHANG Y H, ZHAO B, et al. 3D-ReConstnet: a single-view 3D-object point cloud reconstruction network [J]. *IEEE Access*, 2020, 8: 83782-83790.
- [4] ZHANG X, CHEN L, ZHANG F, et al. Research on the accuracy and speed of three-dimensional reconstruction of liver surface based on binocular structured light [J]. *IEEE Access*, 2021, 9: 87592-87610.
- [5] MEI R G, WANG T X, QIAN S P, et al. Advanced data mining and applications [M]. Springer Nature Switzerland, 2022: 142-156.
- [6] 吴俊豪, 李琛, 王蓉, 等. 基于密度聚类 and 圆外切线斜率拟合的埋地排水管道声呐点云去噪技术 [J]. *计量学报*, 2023, 44 (2): 7.
- [7] ZHANG L Y, ZHANG F X, XU W L, et al. An innovative method for measuring the three-dimensional water surface morphology of unsteady flow using light detection and ranging technology [J]. *Ocean Engineering*, 2023, 276: 114079.
- [8] 熊风光. 三维点云配准技术研究 [D]. 太原: 中北大学, 2018.
- [9] WANG P, ZHU R Z, SUN C K. Point cloud coarse registration algorithm with scene classification based on improved RANSAC [J]. *Laser & Optoelectronics Progress*, 2020, 57 (4): 041510.
- [10] CHEN C S, HUNG Y P, CHENG J B. RANSAC-Based DARCES: A new approach to fast automatic registration of partially overlapping range images [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2002, 21 (11): 1229-1234.
- [11] AIGER D, MITRA N J, COHEN-OR D. 4-points congruent sets for robust pairwise surface registration [J]. *Acm Transactions on Graphics*, 2008, 27 (3): 1-10.
- [12] 张文丽, 程兰, 任密峰, 等. 基于AGConv局部特征描述符的点云配准方法 [J]. *计算机工程*: 1-10.
- [13] 胡事民, 杨永亮, 来煜坤. 数字几何处理研究进展 [J]. *计算机学报*, 2009 (8): 19.
- [14] RUSU R B, BRADSKI G, THIBAU R, et al. Fast 3d recognition and pose using the viewpoint feature histogram [C] //IEEE, 2010: 2155-2162.
- [15] ALDOMA Buchaca A, VINCZE M. CAD-Model recognition and 6DOF pose estimation using 3D cues [C] //Proc. of the 3rd International IEEE Workshop on 3D Representation and Recognition (3dRR-11), 2011: 8.
- [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, IEEE, 2008: 3384-3391.
- [17] ZHAO J, LI C, TIAN L, et al. FPFH-based graph matching for 3D point cloud registration [C] //Tenth International Conference on Machine Vision (ICMV 2017). SPIE, 2018, 10696: 143-155.
- [18] SALTI S, TOMBARI F, Di STEFANO L. SHOT: Unique signatures of histograms for surface and texture description [J]. *Computer Vision and Image Understanding*, 2014, 125: 251-264.
- [19] DONG Z, LIANG F, YANG B, et al. Registration of large-scale terrestrial laser scanner point clouds: A review and benchmark [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 163: 327-342.
- [20] MA J, JIANG X, FAN A, et al. Image matching from hand-crafted to deep features: A survey [J]. *International Journal of Computer Vision*, 2021, 129: 23-79.
- [21] ZHOU Q Y, PARK J, KOLTUN V. Open3D: A modern library for 3D data processing [J]. *ArXiv Preprint ArXiv: 1801.09847*, 2018.
- [22] YANG J, LI H, CAMPBELL D, et al. Go-ICP: A globally optimal solution to 3D ICP point-set registration [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 38 (11): 2241-2254.
- [23] CHENG L, CHEN S, LIU X, et al. Registration of laser scanning point clouds: A review [J]. *Sensors*, 2018, 18 (5): 1641.
- [24] LI S, LEE D. Fast visual odometry using intensity-assisted iterative closest point [J]. *IEEE Robotics and Automation Letters*, 2016, 1 (2): 992-999.
- [25] BADUE C, GUIDOLINI R, CARNEIRO R V, et al. Self-driving cars: a survey [J]. *Expert Systems with Applications*, 2021, 165: 113816.
- [26] 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 (5): 244-250.
- [27] 李强. 基于多约束八叉树和多重特征的点云配准算法 [D]. 太原: 太原理工大学, 2019.