

文章编号 1004-924X(2025)19-3106-15

三维点云的邻域分布快速配准

余永维, 方 荣, 杜柳青*, 刘 豪, 刘中元
(重庆理工大学 机械工程学院, 重庆 400054)

摘要:针对基于传统点云特征的粗-精两步配准算法存在高维特征计算复杂耗时、稠密点云配准速度慢等问题,提出一种三维点云的邻域分布快速配准方法。首先,定义邻域点的三种深层次几何特征,提出低维度多尺度邻域分布特征描述,以大幅降低特征计算复杂度,同时提高特征描述的区分度,实现点云局部特性的高效表征。然后,提出基于邻域分布特征的快速粗配准方法,根据点云整体起伏程度与邻域分布方向提取特征点,依据邻域分布特征描述建立特征点初步匹配的条件,并改进点对间欧氏距离约束条件以剔除错误匹配点对,实现高效准确粗配准。最后,为解决稠密点云配准速度慢问题,提出通过 k 维树及体素化网格法改进迭代最近点(Iterative Closest Point, ICP)算法,并采用二次精配准策略修正降采样引起的配准误差,进一步提高精配准的准确性和效率。斯坦福模型实验和实际工业零件点云配准实验均表明,本文方法相较于现有传统特征描述的配准方法而言,配准精度提升了22%以上,耗时降低了43%以上,证明本方法能够快速有效配准不同视角物体表面点云,具有较好的稳定性和适用性。

关键词:点云配准;邻域分布特征;匹配点对优化;迭代最近点;体素化网格法

中图分类号:TP391.41 **文献标识码:**A

doi:10.37188/OPE.20253319.3106

CSTR:32169.14.OPE.20253319.3106

Rapid registration for neighborhood distribution of 3D point cloud

YU Yongwei, FANG Rong, DU Liuqing*, LIU Hao, LIU Zhongyuan

(College of Mechanical Engineering, Chongqing University of Technology, Chongqing 400054, China)

* Corresponding author, E-mail: lqdu@cqut.edu.cn

Abstract: A fast point-cloud registration method based on neighborhood distribution features is proposed to address the high computational cost of traditional high-dimensional feature extraction and the slow performance of dense registration algorithms that rely on coarse-fine two-step feature matching. First, three deep geometric features of neighboring points are defined, and a low-dimensional, multi-scale neighborhood distribution descriptor is introduced to substantially reduce feature-computation complexity while enhancing descriptor discriminability for efficient characterization of local point-cloud properties. Second, a rapid coarse-registration scheme is developed using the neighborhood distribution descriptor: feature points are selected according to the global undulation degree and neighborhood distribution direction; initial correspondences are established based on the neighborhood distribution descriptor; and Euclidean-distance con-

收稿日期:2025-05-30;修订日期:2025-07-10.

基金项目:国家自然科学基金资助项目(No. 52375083);重庆英才资助项目(No. QYC20220207232, No. cstc2024ycjh-bgzxm0052);重庆教委科研重大资助项目(No. KJZD-M202401101, No. KJZD-M202501102);重庆技术创新与应用资助项目(No. CSTB2022TIAD-CUX0017);重庆理工大学研究生创新资助项目(No. gzl-cx20253073);精密机械检测技术与装备工程中心资助项目(No. 2023PTTS001)

straints between point pairs are strengthened to remove incorrect matches, enabling efficient and accurate coarse alignment. Finally, to accelerate dense registration, the iterative closest point (ICP) algorithm is improved using a k-dimensional tree and voxel-grid downsampling, and a quadratic fine-registration strategy is employed to correct downsampling-induced errors, thereby further improving fine-registration accuracy and efficiency. Experiments on Stanford models and industrial part point clouds demonstrate that, compared with conventional feature-descriptor-based methods, the proposed approach increases registration accuracy by over 22% and reduces computation time by more than 43%, confirming its effectiveness, robustness, and practical applicability for rapid registration of object-surface point clouds acquired from different viewpoints.

Key words: point cloud registration; neighborhood distribution feature; matched point pair optimization; iterative closest point; voxelized grid method

1 引言

点云配准作为三维点云处理技术中的重要部分,广泛应用于工业检测^[1]、三维测绘^[2]、文物数字化^[3]等领域。点云配准通过多视角点云数据在全局坐标系中的对齐完成三维模型重建,配准算法的性能会影响目标信息获取的效率与准确性。点云配准通常采用粗-精两阶段配准框架来提高配准准确性^[4],即先由粗配准获取两片点云间的初始变换矩阵后,再进行精细配准,以获取准确的配准结果。在粗配准阶段,点云特征的描述对配准的效率和准确性有十分重要的作用。特征描述可分为全局特征与局部特征,局部特征在计算效率与对噪声的稳定性上优于全局特征,应用局部特征获取点对间的匹配关系是目前的研究热点之一。常用的局部特征描述有快速点特征直方图(Fast Point Feature Histogram, FPFH)^[5]、方向直方图签名(Signature of Histogram of Orientation, SHOT)^[6]、三维形状上下文(3D Shape Context, 3DSC)^[7]等。

上述方法均采用高维特征,描述性强,但计算复杂,且在点对匹配的过程中存在错误的匹配点对,影响点云配准的效率与精度。针对高维特征计算复杂的问题,研究人员通过提取具有代表性的局部几何属性构建低维特征,并用它代替传统高维特征描述以提高特征的计算效率。Huang等^[8]将多视角点云投影至局部坐标系平面并划分区域,以其中边缘点与投影点的距离以及投影点数量作为特征描述,完成了点对的匹配。Zhao等^[9]将点云曲率、法线夹角、点与邻域点积以及点

与邻域距离的直方图作为特征描述,实现了点云粗配准。林森等^[10]利用邻域法向量、点密度和表面曲率划分的多个直方图作为局部特征描述,建立了点云粗配准算法。上述低维特征构建方法在一定程度上降低了特征的计算复杂度,但基于多视角投影以及多属性直方图统计的操作导致特征维度上升,增加了特征计算时间。如何平衡特征描述性能与配准效率是粗配准阶段需要解决的难题。

在精配准阶段,迭代最近点(Iterative Closest Point, ICP)算法是最经典的点云配准算法^[11],对完全重叠的点云具有较好的配准效果。然而,ICP算法存在计算效率低、易陷入局部最小值的问题。针对配准的效率、精度等问题,研究人员对ICP算法进行了改进。司垒等^[12]综合法向量夹角阈值与双向Kd-tree加速对应点匹配完成精配准。陈仲生等^[13]采用线性最小二乘优化求解改进ICP算法,加快了精配准速度。郑源等^[14]通过设定对应点间欧氏距离阈值剔除异常点对,实现点云精配准。改进ICP算法在配准精度与效率上取得了良好效果,然而对于稠密的点云模型,其配准效率仍然较低,依然难以快速完成精配准。

综上所述,粗-精两阶段点云配准算法仍存在特征描述计算复杂、错误匹配点对影响配准精度及效率、对稠密或部分重叠的点云整体配准时间较长等问题。智能产线上,对实体三维模型获取、空间位姿识别、制造误差检测等具有实时性要求,以适应产线节拍,而现有算法不能较好地满足该要求。本文针对工业智能化产线中实体

空间信息的获取对实时点云配准的需求,采用提取具有代表性的局部几何属性构建低维特征以提高特征计算效率的策略,提出一种基于邻域分布(Neighborhood Point Distribution, NPD)特征的快速点云配准方法。首先,结合邻域点三种深层次的几何特性,提出低维度多尺度的邻域分布特征描述,平衡特征计算复杂度的同时,保证特征的描述性能。然后,针对特征点匹配过程存在的错误匹配点对,在综合点云整体弯曲程度与邻域点分布方向提取特征点,建立特征点匹配关系的同时,结合特征点的法线信息,改进点对间欧氏距离约束条件,准确地剔除错误点对,实现快速准确粗配准。最后,融合 k 维树及体素化网格法改进ICP算法,并采用二次精配准策略修正降采样引起的配准误差,实现快速精配准,解决配准稠密点云效率低的问题。

2 NPD特征的提出及描述

在点云粗配准中,特征描述使得点的特征信息容易对比,更利于关键点的匹配^[15]。但高维特征计算复杂度高,而单一的低维特征描述性差,均不利于点云配准任务。为此,定义一种低维度多尺度的点特征即邻域分布特征来解决上述问题。

点云模型中,不同点的邻域分布含有差异,邻域点的分布亦不随模型的旋转和平移发生变化。因此,综合考虑特征描述性能与配准效率,将点的邻域分布作为特征描述,定义点邻域的邻域曲率、邻域距离和邻域夹角3个几何特性来深层次描述点的邻域分布,以提高特征描述的区分度和稳定性。

2.1 邻域曲率

邻域曲率为表征邻域表面弯曲特性的高斯曲率和平均曲率,将这两种曲率作为点的第一个特征描述尺度,通过二次曲面拟合方法^[16]计算:

$$K = k_1 \cdot k_2, \quad (1)$$

$$H = \frac{k_1 + k_2}{2}, \quad (2)$$

式中: k_1, k_2 分别为最大主曲率与最小主曲率, K 为高斯曲率, H 为平均曲率。

2.2 邻域距离

邻域距离为点到其邻域投影点重心的距离。

点云的3D投影对噪声具有稳定性^[17],为降低噪声对特征描述的影响,将查询点的邻域点投影至某一平面,以投影点的几何特征作为点的特征描述。

设待配准点云为 $P = \{p_i | i = 1, 2, \dots, n_p\}$, n_p 为点云 P 中点的数量,查询点 p_i 在邻域半径 r 下的邻域点集为 $N_i = \{p_{ij} | j = 1, 2, \dots, k'\}$, j 为邻域点的索引, k' 为邻域点数量,则构建加权协方差矩阵:

$$\text{cov}(p_i) = \frac{\sum_{|p_i - p_{ij}| < r} \omega_{ij} (p_i - p_{ij})(p_i - p_{ij})^T}{\sum_{|p_i - p_{ij}| < r} \omega_{ij}}, \quad (3)$$

式中: $\omega_{ij} = \frac{1}{|p_i - p_{ij}|}$ 为相邻点不均匀采样的补偿

权重,用于减少遮挡和杂波的影响。

计算 3×3 实对称矩阵 $\text{cov}(p_i)$ 的3个特征值并降序排列为 $\{\lambda_1, \lambda_2, \lambda_3\}$,对应的特征向量 $\{v_1, v_2, v_3\}$ 蕴含着存在噪声和杂波时的可重复正交方向,因此可利用特征向量构建局部参考坐标系。以查询点 p_i 为局部坐标系的原点, $v_1, v_3, v_1 \times v_3$ 作为坐标系的 u 轴、 w 轴与 v 轴,选择 uv 平面作为投影平面。

由于特征向量方向具有 180° 的模糊度,根据局部轴方向与 p_i 到其邻域点 p_{ij} 所形成向量方向大多数相一致的原则^[18],确定 u 轴方向:

$$u = \begin{cases} u^+, \sum_{j=1}^{k'} (p_i - p_{ij}) \cdot u^+ > 0 \\ u^-, \sum_{j=1}^{k'} (p_i - p_{ij}) \cdot u^+ \leq 0 \end{cases}, \quad (4)$$

式中: u^+ 为特征向量 v_1 的原始方向, u^- 为其反方向。

同理确定 w 轴的方向,并根据 $u \times w$ 确定 v 轴方向。将 p_i 邻域点 p_{ij} 投影到 uv 平面,如图1所示。

点 p_i 到其邻域投影点重心 $\bar{p}'_i$ 的距离 $d(p_i)$ 可有效描述邻域分布,将 $d(p_i)$ 作为点的第二个特征描述尺度。按式(5)计算邻域投影点重心 $\bar{p}'_i$,按式(6)计算 p_i 到邻域投影点重心的距离 $d(p_i)$ 。




图1 邻域点投影特征

Fig. 1 Neighborhood point projection feature

$$\bar{p}'_i = \frac{1}{k'} \sum_{j=1}^{k'} p'_{ij}, \quad (5)$$

$$d(p_i) = \|\bar{p}'_i - p_i\|, \quad (6)$$

式中: p'_{ij} 为邻域点 p_{ij} 投影点, $\|\cdot\|$ 表示欧氏距离。

2.3 邻域夹角

邻域夹角为点到其邻域投影点重心的向量

与局部参考坐标系轴的夹角。为进一步区别不同点的邻域分布特征,将点 p_i 到其邻域投影点重心 $\bar{p}'_i$ 的向量与局部坐标系 u 轴的夹角 $\theta(p_i)$ 作为点的第 3 个特征描述尺度,在方向上描述邻域点分布如下:

$$\theta(p_i) = \arccos \left(\frac{p_i \bar{p}'_i \cdot u}{|p_i \bar{p}'_i| \cdot |u|} \right), \quad (7)$$

式中 $p_i \bar{p}'_i$ 为 p_i 到邻域投影点重心 $\bar{p}'_i$ 的向量。

3 基于 NPD 特征的点云快速粗配准

基于 NPD 特征的点云粗配准包括特征点提取、NPD 特征描述以及特征匹配 3 个部分,配准原理如图 2 所示。




图2 基于 NPD 特征的点云快速粗配准原理

Fig. 2 Principle for fast coarse point cloud registration based on NPD feature

3.1 融合曲率与邻域分布方向的特征点提取

对于待匹配点云数据,直接采用全部点集进行匹配点对搜索会使得计算量过大,配准效率降低。提取具有稳定、可区别和特征信息丰富的特征点,利用特征点代替数据量大的原始点云获取初始变换位姿矩阵,可加快点云配准速度。此外,单独分析特征点邻域分布特征也利于避免点云的相似区域对粗配准的影响。因此,考虑点云表面的整体弯曲程度以及点邻域分布方向,进行特征点提取。

点云上某个点处的曲面起伏程度较大时,表明该点处邻域变化剧烈,可标记为关键特征点。采用基于点邻域协方差矩阵的主成分分析

(Principal Component Analysis, PCA) 法计算的曲率值可衡量邻域点变化程度。该方法相较于二次曲面拟合方法具有更快的计算速度,因为二次拟合的方法需对点进行多项式拟合,而 PCA 方法只需计算协方差矩阵与特征值,时间复杂度更低。以降采样后的目标点云的曲率计算耗时,为量化指标评价两种方法,如表 1 所示,PCA 方法计算曲率的耗时远低于二次拟合的方法。

PCA 法具体为:对于点云 P 内的查询点 p_i ,通过邻域点 p_{ij} 构造协方差矩阵:

$$E = \frac{1}{k'} \sum_{j=1}^{k'} (p_{ij} - \bar{p}_i) \cdot (p_{ij} - \bar{p}_i)^T, \quad (8)$$

表 1 不同曲率计算方法的耗时对比

Tab.1 Runtime comparison of curvature computation methods

Point cloud model	Downsampled point count	Runtime of different methods/s	
		PCA	Quadratic fitting
Bunny target point cloud	6 828	6.034	32.070
Dragon target point cloud	6 432	4.501	24.154
Crankshaft target point cloud	40 214	8.306	44.814

式中 $\bar{p}_i$ 为邻域的质心。

将矩阵 E 的特征向量降序排列为 $\{\lambda'_1, \lambda'_2, \lambda'_3\}$, 则点 p_i 的曲率值 c_i 为:

$$c_i = \frac{\lambda'_3}{\lambda'_1 + \lambda'_2 + \lambda'_3}. \quad (9)$$

点云的曲率均值可有效评估点云的整体起伏程度, 将曲率均值的倍数作为阈值, 筛选出邻域变化剧烈的曲率特征点:

$$c > \alpha \cdot \frac{1}{n_p} \sum_{i=1}^{n_p} c_i, \quad (10)$$

式中: c 为曲率特征点的曲率, α 为倍数阈值。其中, α 值越大, 提取到的特征点数越少。

基于 PCA 法初步筛选出的特征点包含较多相似曲率点及邻域, 会对后续点对匹配造成较大干扰且增加计算量。加权协方差矩阵 $\text{cov}(p_i)$ 的特征向量 v_1, v_2, v_3 抽象描述了邻域点分布的 3 个主方向^[19], 对应的特征值描述了邻域点沿特征向量分散的程度, 因此, 点 p_i 的邻域分布的主要方向为 v_1 , 而沿 v_3 方向分散的程度最小, 沿 v_2 方向的分散的程度介于 v_1 与 v_3 之间。利用该特性, 保留满足式(11)的点, 避免检测到的特征点沿主方向具有相似的扩展性^[17]。

$$\lambda_2/\lambda_1 < t_1, \quad \lambda_3/\lambda_2 < t_2, \quad (11)$$

式中: t_1, t_2 为特征值变化量阈值, $t_1 = t_2 = 0.8$ 。

对于待配准的输入点云, 给定邻域半径 r , 满足式(10)及式(11)的点即为特征点。

3.2 基于 NPD 特征描述的快速特征匹配

3.2.1 基于 NPD 特征的点对匹配

准确建立源点云特征点与目标点云特征点

间的匹配关系, 是计算初始变换矩阵的前提, 具体点对匹配关系的建立过程如下:

(1) 提取源点云 P 和目标点云 Q 的特征点集 F_P 与 F_Q 。

$$F_P = \{f_P^{(s)} | s = 1, 2, \dots, n_1\}, \quad (12)$$

$$F_Q = \{f_Q^{(t)} | t = 1, 2, \dots, n_2\}, \quad (13)$$

式中: n_1, n_2 分别为点云 P 与 Q 特征点的数量。

(2) 设特征点集 F_P, F_Q 中的特征点 $f_P^{(s)}, f_Q^{(t)}$ 在邻域半径 r 下的高斯曲率为 $K(f_P^{(s)}), K(f_Q^{(t)})$, 平均曲率为 $H(f_P^{(s)}), H(f_Q^{(t)})$, 邻域距离为 $d(f_P^{(s)}), d(f_Q^{(t)})$, 以及邻域夹角为 $\theta(f_P^{(s)}), \theta(f_Q^{(t)})$ 。搜索点 $f_P^{(s)}$ 在点集 F_Q 中的对应点 $f_Q^{(t)}$:

$$\frac{|K(f_P^{(s)}) - K(f_Q^{(t)})|}{[K(f_P^{(s)}) + K(f_Q^{(t)})]} \leq \epsilon_1, \quad (14)$$

$$\frac{|H(f_P^{(s)}) - H(f_Q^{(t)})|}{[H(f_P^{(s)}) + H(f_Q^{(t)})]} \leq \epsilon_2, \quad (15)$$

$$\frac{|d(f_P^{(s)}) - d(f_Q^{(t)})|}{[d(f_P^{(s)}) + d(f_Q^{(t)})]} \leq \epsilon_3, \quad (16)$$

$$\frac{|\theta(f_P^{(s)}) - \theta(f_Q^{(t)})|}{[\theta(f_P^{(s)}) + \theta(f_Q^{(t)})]} \leq \epsilon_4, \quad (17)$$

式中: 阈值 $\epsilon_i \in (0, 1), i = 1, 2, 3, 4, \epsilon_1 = \epsilon_2 = 0.03, \epsilon_3 = \epsilon_4 = 0.1$ 。

(3) 遍历点集 F_P , 得到初始匹配点对集 C_0 。

$$C_0 = \{(f_P^{(c)}, f_Q^{(c)}) | c = 1, 2, \dots, n_0\}, \quad (18)$$

式中 n_0 为匹配点对的数量。

3.2.2 基于改进欧氏距离约束条件的匹配点对筛选

初始匹配点对集 C_0 中不可避免地包含了错误匹配点对, 使得初始变换位姿矩阵准确性降低。现有算法多使用欧氏距离约束法^[20]来提高匹配点对的正确率。

首先, 建立欧氏距离约束条件:

$$\frac{\|f_P^{(ci)} - f_P^{(cj)}\| - \|f_Q^{(ci)} - f_Q^{(cj)}\|}{\|f_P^{(ci)} - f_P^{(cj)}\| + \|f_Q^{(ci)} - f_Q^{(cj)}\|} < \epsilon, \quad (19)$$

式中: $(f_P^{(ci)}, f_Q^{(ci)})$ 与 $(f_P^{(cj)}, f_Q^{(cj)})$ 为点对集 C_0 中任意两对匹配点对, $ci, cj \in \{1, 2, \dots, n_0\}, \epsilon$ 为距离约束阈值。

统计点对 $(f_P^{(ci)}, f_Q^{(ci)})$ 与其余点对符合约束条件的数量 N_{ci} , 按 N_{ci} 对点对集 C_0 降序排列, 选取

前 n_1 个点作为正确匹配点对,满足:

$$n_1 = n_0 \cdot \delta, \quad (20)$$

式中 $\delta \in (0, 1)$ 。

由于初始匹配点集 C_0 中存在一定数量的错误点对,欧氏距离约束法难以准确筛选正确点对。如图 3 所示,样条曲线点云的匹配点对中,点对 $(f_p^{(ci)}, f_q^{(ci)})$ 在 $ci = 1, 2, 3, 4$ 时为正确匹配点对, $ci = 5, 6, 7, 8$ 时为错误匹配点对,则正确点对满足欧氏距离约束条件的数量为 3 对,错误点对满足欧氏距离约束条件的数量也为 3 对,此时难以通过式(20)筛选正确点对。





图 3 样条曲线点云的匹配点对

Fig. 3 Matched point pairs of spline curve point cloud

在正确匹配的点对中,除欧氏距离相似以外,点对间的法向量夹角亦是近似的。因此,针对欧氏距离约束法筛选点对存在的问题,提出利用点对间法向量夹角改进欧氏距离约束条件,以增加正确匹配点对的比例。

建立改进欧氏距离约束条件:

$$\begin{cases} \frac{\left| \|f_p^{(ci)} - f_p^{(cj)}\| - \|f_q^{(ci)} - f_q^{(cj)}\| \right|}{\|f_p^{(ci)} - f_p^{(cj)}\| + \|f_q^{(ci)} - f_q^{(cj)}\|} < \epsilon_d \\ \frac{|\theta_p - \theta_q|}{\theta_p + \theta_q} < \epsilon_\theta \end{cases}, \quad (21)$$



式中: θ_p 为 $f_p^{(ci)}$ 与 $f_p^{(cj)}$ 的法向量夹角, θ_q 为 $f_q^{(ci)}$ 与 $f_q^{(cj)}$ 的法向量夹角, $\epsilon_d \in (0, 1)$ 为距离约束阈值, $\epsilon_\theta \in (0, 1)$ 为点对间法向量夹角的约束阈值。

匹配点对筛选的距离约束阈值 ϵ_d 与夹角约束阈值 ϵ_θ 对后续配准效果有极大影响, ϵ_d 与 ϵ_θ 取较小值有利于区分匹配点对类型,但过小时,可能将正确匹配点对误判为错误点对。采用旋转误差 e_θ 与平移误差 e_t 评价不同阈值的配准性能,误差指标定义如下:


$$e_\theta = \arccos\left(\frac{\text{trace}(\mathbf{R}_e \mathbf{R}_c^{-1}) - 1}{2}\right) \frac{180}{\pi}, \quad (22)$$

$$e_t = \|\mathbf{T}_e - \mathbf{T}_c\|, \quad (23)$$

式中: $\mathbf{R}_c$ 为实际配准旋转矩阵, $\mathbf{R}_e$ 为配准算法计算的旋转矩阵, $\mathbf{T}_c$ 为实际配准平移向量, $\mathbf{T}_e$ 为配准算法计算的平移向量。

采用交叉验证法确定阈值, ϵ_d 取 0.1 与 0.2 时, ϵ_θ 在 0.1~0.7 间变化; ϵ_θ 取 0.2 与 0.3 时, ϵ_d 在 0.05~0.3 间变化。采用不同阈值对 Bunny 模型进行粗配准以分析 ϵ_d 与 ϵ_θ 的选取范围,粗配准误差结果如图 4 所示。由图 4 可知, ϵ_d 取 0.1 与 0.2, ϵ_θ 取 0.2~0.5, 以及 ϵ_θ 取 0.2 与 0.3, ϵ_d 取 0.05~0.2 时,错误点对的剔除效果较好,可取得较高的粗配准精度。此外,固定 $\epsilon_d, \epsilon_\theta$ 的值由 0.7 降低至 0.5 时,粗配准精度得到提升,即增强点对间法向量夹角约束后,正确点对比例得到提高,验证了本文所提法向量夹角筛选点对的有效性。

统计点对 $(f_p^{(ci)}, f_q^{(ci)})$ 与其余点对符合约束条件的数量并降序排列,据此选取前 n_1 个点作为正确匹配点对,满足式(20),得到正确率更高的匹配点对集 C_1 。






图 4 不同阈值下的粗配准误差

Fig. 4 Coarse registration error at different thresholds

采用改进欧氏距离约束条件,筛选图 3 中样条曲线点云的匹配点对,此时正确点对满足约束条件的数量为 3 对,错误点对满足约束条件的数量为 0 对,通过式(20)可有效筛选正确点对。

获得源点云 P 和目标点云 Q 的匹配点对集 C_1 后,使用矩阵的奇异值分解法(Single Value Decomposition, SVD)计算两点云之间的初始位姿变换矩阵 $M_0(R_0, T_0)$ 。

4 基于体素化网格的优化 ICP 点云高效精配准

对于原始位姿差异较大的源点云 P 和目标点云 Q ,使用粗配准获取的变换矩阵 $M_0(R_0, T_0)$ 将源点云 P 变换为 P_0 ,即:

$$P_0 = R_0 \cdot P + T_0. \quad (24)$$

变换后源点云 P_0 与目标点云 Q 具有良好初始位姿,可使用 ICP 算法进行精配准。由于 ICP 算法需搜索输入点云间的最近点,直接使用原始点云与大迭代次数会使得精配准时间较长,若输入点云为稠密点云则将大幅增加精配准用时。利用体素化网格法可大幅降低输入点云数据,但降采样的点云是用重心替代,非真实点云,求解的变换矩阵与真实变换矩阵存在一定误差。

针对上述问题,首先利用 k 维树提高数据的搜索效率,然后使用体素化网格法减少输入点云,同时采用二次精配准策略修正降采样点云带来的配准误差,实现快速准确配准。二次精配准策略为:先对体素化网格法降采样的点云进行一次精配准,获得含有较小误差的变换矩阵,在此基础上对原始点云进行小迭代次数的二次精配

准。优化后 ICP 算法的具体步骤如下:

(1) 设置素化网格大小,均匀划分输入点云 P, Q 为不同个数的三维体素单元,使用体素单元重心 p_c 替代体素单元内的点,将点云 P, Q 降采样为 P_v, Q_v ,使用式(25)计算体素单元重心 p_c :

$$p_c = \left(\frac{1}{h} \sum_{e=1}^h x_e, \frac{1}{h} \sum_{e=1}^h y_e, \frac{1}{h} \sum_{e=1}^h z_e \right), \quad (25)$$

式中: (x_e, y_e, z_e) 为体素单元中第 e 个点的坐标 ($e = 1, 2, \dots, h$), h 为点的总数。

(2) 使用变换矩阵 $M_0(R_0, T_0)$ 将 P_v 变换为 P_{v0} :

$$P_{v0} = R_0 \cdot P_v + T_0. \quad (26)$$

(3) 在第 m 次迭代中,对 P_{v0} 中任一点,用 k 维树在 Q_v 中寻找欧氏距离最近的对应点,得到对应点对,遍历 P_{v0} ,获得 n 对点对集 $C(p'_i, q'_i)$,其中 $p'_i \in P_{v0}, q'_i \in Q_v, i = 1, 2, \dots, n$;

(4) 用 SVD 求解最小化目标函数 d_m ,更新刚体变换关系 $M_m(R_m, T_m)$;

$$M_m = \arg \min d_m, \quad d_m = \frac{1}{n} \sum_{i=1}^n \| R_m \cdot p'_i + T_m - q'_i \|^2. \quad (27)$$

(5) 对步骤(2)到步骤(4)进行迭代,直至满足停止条件:迭代次数大于设定阈值 $I_{\max 1}$ 或 $|d_m - d_{m-1}| < d_{th}$,输出最佳的刚体变换参数 $M_v(R_v, T_v)$,其中 d_{m-1} 为第 $m-1$ 次迭代匹配点对间的距离, d_{th} 为距离阈值;

(6) 使用 $M_v(R_v, T_v)$ 将点云 P_0 变换为 P'_0 ,设定小迭代次数 $I_{\max 2}$,输入点云 P'_0 与目标点云 Q ,执行步骤(2)到步骤(5),输出最佳的刚体变换参数 $M(R, T)$ 。

5 实验及结果分析

为测试算法的性能,本文对斯坦福大学图形实验室公开的 Bunny 与 Dragon 点云进行粗精配准,最后将本文算法应用到曲轴点云配准任务上,测试其配准稠密点云的性能以及对实际工业零件的应用能力。实验硬件平台为 Windows10 操作系统 Intel core i7 2.1GHz CPU、16 GB RAM 的计算机,软件平台为 Visual Studio 2019,算法采用 C++ 结合点云库 PCL 1.11.1 实现。

5.1 点云数据

点云配准实际应用是将不同视角的点云统一到同一坐标系中,因此,实验中均使用不同视角采集的部分重叠点云。为验证本文方法在初始位姿较差情况下的配准性能,将斯坦福源点云大幅度旋转平移变换(R_t, T_t)后,再与目标点云进行配准。对于工业零件曲轴模型的配准,使用原始采集位姿进行配准。点云的具体信息如表 2 所示。

表 2 不同点云模型信息

Tab. 2 Information of different point cloud models

Point cloud model	Number
Bunny source point cloud	40 256
Bunny target point cloud	40 097
Dragon source point cloud	41 841
Dragon target point cloud	34 836
Crankshaft source point cloud	176 734
Crankshaft target point cloud	161 181

5.2 特征计算时间

实验统计 NPD 特征与常用特征的计算时间,以对比不同特征描述的计算复杂度。采用本文特征点提取方法获取目标点云的特征点,其数量如表 3 所示,统计特征点的特征描述在固定邻域半径下的计算时间,如表 4 所示。

表 3 目标点云的特征点提取

Tab. 3 Feature point extraction for target point cloud

Point cloud model	Feature Point Count
Bunny target point cloud	1 324
Dragon target point cloud	1 468
Crankshaft target point cloud	2 453

表 4 特征点的不同特征计算用时

Tab. 4 Run time for different features of feature points

Feature point	Descriptor	Run time/s
Bunny target point cloud	FPFH	30.858
	SHOT	18.473
	3DSC	34.135
	NPD	12.781
Dragon target point cloud	FPFH	29.632
	SHOT	15.063
	3DSC	26.003
	NPD	10.593
Crankshaft target point cloud	FPFH	40.805
	SHOT	14.746
	3DSC	10.192
	NPD	6.157

受模型密度与邻域计算半径的影响,不同模型的同一特征计算用时含有差异。由表 4 可知,NPD 特征相较常用特征所需计算用时最短,原因在于 NPD 特征只计算邻域点 3 个深层次的几何特性,为低维度特征,具有更快计算速度。计算速度较快的特征应用于点云配准可提高配准效率。此外,曲轴点云具有更多特征点,但所属特征计算用时整体上没有明显增加,原因在于曲轴点云密度高于斯坦福点云,其特征计算的邻域半径与斯坦福点云不同。

5.3 配准算法性能对比

为验证基于 NPD 特征的配准算法在点云配准任务中的性能,实验对比基于 FPFH 特征、SHOT 特征以及 3DSC 特征的三种常用配准算法。具体为:(1)采用本文提取特征点方法提取特征点;(2)分别以 FPFH 特征、SHOT 特征、3DSC 特征作为相似度条件,使用采样一致性初始(Sample Consensus Initial Alignment, SAC-IA)算法^[21]选择最佳匹配点对,完成粗配准;(3)采用传统 ICP 算法完成精配准。其中,第 1 步到第 2 步为整体粗配准算法。

将基于不同特征描述的粗配准算法实验结果统计于表 5 中,粗配准效果如图 5 所示。将基于不同特征描述配准算法的精配准实验结果统计于表 6 中,精配准效果如图 6 所示。配准效果图中,目标点云为蓝色,源点云为红色(彩图见期




图 5 基于不同特征描述的粗配准算法效果

Fig. 5 Effect of coarse registration algorithm based on different feature descriptions




图 6 基于不同特征描述配准算法的精细配准效果

Fig. 6 Fine registration effect of registration algorithm based on different feature descriptions

刊电子版)。

在粗配准阶段,由图 5 及表 5 可知,基于 FPFH 特征、SHOT 特征、3DSC 特征以及 NPD 特征的粗配准算法均能将初始位姿较差点云调整到相较良好位姿,可为精配准提供配准初值,但粗配准效果有所不同。基于 NPD 特征的粗配准算法相较其它三种算法,旋转误差 e_r 减少了 0.9%~68%,平移误差 e_t 减少了 18%~75%,粗配准时间降低 39%~75%,取得良好的配准效

果。主要原因为:(1)NPD 特征计算复杂度低,且特征的描述性良好,在点对匹配时仅判断一次,提高了点对的匹配速度;(2)使用改进欧氏距离约束条件筛选点对,获得了正确率较高的匹配点对集。这使得其粗配准效率与精度得到了提升。值得注意的是,FPFH 特征在正确配准时,使用的邻域半径小于 SHOT 特征与 3DSC 特征,因而基于 FPFH 特征的配准用时仅次于基于 NPD 特征的粗配准算法。

表 5 基于不同特征描述的粗配准算法对比

Tab. 5 Comparison of coarse registration algorithms based on different feature descriptions

Point cloud model	Coarse registration method	Rotational error/(°)	Translation error/mm	Coarse registration time/s
Bunny	FPFH	11.269	2.989×10^{-2}	59.410
	SHOT	10.287	2.255×10^{-2}	79.457
	3DSC	7.760	2.224×10^{-2}	87.019
	Ours(NPD)	7.684	1.802×10^{-2}	36.084
Dragon	FPFH	7.060	1.717×10^{-2}	42.885
	SHOT	15.934	3.873×10^{-2}	81.085
	3DSC	11.450	3.476×10^{-2}	79.062
	Ours(NPD)	5.094	9.395×10^{-3}	19.836

表 6 基于不同特征描述配准算法的精配准结果对比

Tab. 6 Comparison of fine registration results of registration algorithms based on different feature descriptions

Point cloud model	Registration method	Rotational error/(°)	Translation error/mm	Fine registration time/s
Bunny	FPFH+ICP	1.322	1.682×10^{-3}	10.455
	SHOT+ICP	1.601	2.155×10^{-3}	7.858
	3DSC+ICP	1.638	2.506×10^{-3}	8.404
	Ours(NPD+Improved ICP)	0.131	3.512×10^{-4}	3.364
Dragon	FPFH+ICP	0	2.729×10^{-4}	7.272
	SHOT+ICP	0.188	1.022×10^{-3}	6.561
	3DSC+ICP	0	3.175×10^{-4}	8.845
	Ours(NPD+Improved ICP)	0	2.119×10^{-4}	2.065

在精配准阶段,由图 6 及表 6 可知,4 种算法均完成了点云配准,但最终配准精度与用时有一定区别。相较其他 3 种算法,基于 NPD 特征的配准算法平移误差 e_t 降低了 22%~85%,配准耗时降低了 57%~76%,配准性能最优。原因在于,基于 NPD 特征的配准算法使用 k 维树加速了数据搜索,并结合体素化网格法降低了输入点云的数据量,且考虑了降采样点云与原始点云间的配准误差,在粗配准获得良好位姿的基础上进行精配准,最终取得了较高配准效率与配准精度。

综合完整粗精配准过程,基于 NDP 特征的配准算法相比其余算法,配准耗时降低了 43%~75%,且误差最小,配准性能更优。

5.4 噪声实验

在实际获取点云数据时,受光照以及传感器误差等因素影响,点云数据中通常夹杂一定噪声。为验证本文算法对噪声的稳定性,对待配准

的目标点云与源点云,分别加入均值为 0,标准差为 $0.1\bar{r},0.2\bar{r},0.3\bar{r},0.4\bar{r},0.5\bar{r}$ 的高斯噪声,其中 $\bar{r}$ 为点云模型的平均密度。实验配准含有高斯噪声的 Dragon 模型,基于 NPD 特征的算法配准效果如图 7 所示,对比算法配准结果统计于表 7 中,并绘制配准误差点线图如图 8 所示,配准时间点线图如图 9 所示。其中,配准时间是粗、精配准总时间。

高斯噪声水平越高,点云模型表面越粗糙,使得特征描述发生不同程度的变化,对配准工作带来一定干扰。由图 7 和图 8 及表 7 可知,基于 NPD 特征的配准算法在高斯噪声影响下,能够较好地完成配准任务,且算法的旋转误差与平移误差均不随噪声增加而大幅变化。其中,旋转误差均为 0,达到了手动配准水平,优于其余算法;平移误差相比其余算法亦最低。对于算法的配准效率,由图 9 可知,随着噪声水平增大,各算法配




图 7 基于 NPD 特征算法在不同高斯噪声下的配准效果

Fig. 7 Registration effect of NPD feature-based algorithm under different Gaussian noises

表 7 不同高斯噪声下各算法的配准结果

Tab. 7 Registration results of each algorithm under different Gaussian noise

Method	Rotational error/(°)					Time/s				
	0.1 $\bar{\sigma}$	0.2 $\bar{\sigma}$	0.3 $\bar{\sigma}$	0.4 $\bar{\sigma}$	0.5 $\bar{\sigma}$	0.1 $\bar{\sigma}$	0.2 $\bar{\sigma}$	0.3 $\bar{\sigma}$	0.4 $\bar{\sigma}$	0.5 $\bar{\sigma}$
FPFH+ICP	0.192	0.069	0.119	0.048	0.192	51.114	53.984	55.802	63.829	72.804
SHOT+ICP	0.276	0.319	0.028	0.285	0.359	89.094	94.875	101.002	113.397	123.113
3DSC+ICP	0.137	0	0.056	0.151	0	91.875	110.382	121.600	133.947	162.208
NPD+Improved ICP	0	0	0	0	0	22.525	23.759	25.336	27.614	29.083

Method	Translation error/mm				
	0.1 $\bar{\sigma}$	0.2 $\bar{\sigma}$	0.3 $\bar{\sigma}$	0.4 $\bar{\sigma}$	0.5 $\bar{\sigma}$
FPFH+ICP	4.858×10^{-4}	4.838×10^{-4}	4.323×10^{-4}	4.965×10^{-4}	5.937×10^{-4}
SHOT+ICP	6.874×10^{-4}	1.269×10^{-3}	4.521×10^{-4}	7.476×10^{-4}	1.127×10^{-3}
3DSC+ICP	4.759×10^{-4}	3.105×10^{-4}	4.202×10^{-4}	1.008×10^{-3}	8.373×10^{-4}
NPD+Improved ICP	2.754×10^{-4}	3.093×10^{-4}	2.881×10^{-4}	3.598×10^{-4}	2.989×10^{-4}



(a) 旋转误差
(a) Rotational error(b) 平移误差
(b) Translation error

图 8 不同高斯噪声下各算法配准误差点线图

Fig. 8 Dot plot of registration error of each algorithm under different Gaussian noises




图9 不同高斯噪声下各算法配准时间点线图

Fig. 9 Dot plot of registration time of each algorithm under different Gaussian noises

准时间均有一定幅度增加;相较其余算法,基于NPD特征的配准算法用时减少了54%~82%,且耗时增幅最小。

综合来看,基于NPD特征的配准算法具有更高的配准效率与精度,且在噪声变化下更加稳定,对噪声的稳定性更好。

5.5 工业零件曲轴点云模型配准

为验证基于NPD特征的配准算法配准稠密

点云的性能以及对工业零件的实际应用能力,实验配准不同视角扫描的单缸曲轴点云模型。使用均方根误差(Root Mean Square Error, RMSE)作为配准精度评价指标,即:

$$RMSE(P, Q) = \sqrt{\frac{1}{N_0} \sum_{i=1}^{N_0} \|Mp_i - q_i\|^2}, \quad (28)$$

式中: N_0 表示匹配点对数, p_i 为源点云 P 中与 q_i 匹配的点, q_i 为目标点云 Q 中的点。

除 RMSE 与配准时间外,配准算法所需计算资源同样影响实际应用。本文算法对计算资源需求不高,基于点云 PCL 库在 CPU 上即能实现,无需用到 GPU 资源,故将算法的工作内存占用峰值来衡量计算资源需求。将配准结果数据统计于表 8 中,配准效果如图 10 所示。

由图 10 及表 8 可知,除基于 3DSC 特征的配准算法外,其余算法的工作内存占用峰值均处于较低水平;ICP 对于初始位姿较差点云配准效果较差,配准后源点云与目标点云出现明显分层;由于曲轴点云模型数据稠密,各个算法所需配准用时均有所增加;基于 FPFH 特征、SHOT 特征、3DSC 特征以及 NPD 特征的先粗后精配准方法可有效配准曲轴点云,但配准精度以及配准用时的差异较大。




图 10 曲轴点云配准效果

Fig. 10 Registration effect of crankshaft point cloud

表 8 曲轴点云配准 RMSE、时间与占用内存峰值

Tab. 8 Crankshaft point cloud registration RMSE, time, and peak memory usage

Registration method	RMSE/ mm	Time /s	peak mem- ory/MB
ICP	3. 629	376. 819	43. 508
FPFH+ICP	0. 329	192. 809	47. 430
SHOT+ICP	0. 337	165. 569	60. 008
3DSC+ICP	0. 467	234. 982	119. 914
NPD+Improved ICP	0. 228	79. 025	65. 464

相较其余算法,基于 NPD 特征的配准算法综合性能最优。在精度上提升了 30%~51%,放大的点云对齐情况仍然良好,且在配准耗时上降低了 52%~66%,同时所需计算资源要求较低。实验证明,基于 NPD 特征的配准算法能较好地完成实际工业零件点云配准任务,对于稠密点云的配准同样具有明显优势。

5.6 室外场景点云配准

为验证本文算法对室外场景点云的配准性

能,采用武汉大学公开的 WHU-TLS 室外点云数据集进行配准实验。重叠部分多处特征相似的不同视角点云对特征的描述性能具有较高要求,若特征的描述性弱,难以准确完成配准任务。因此,选择 WHU-TLS 数据集中包含了隧道本体与行人场景的隧道点云作为实验的源点云与目标点云,源点云数量为 23 736,目标点云数量为 31 109。不同算法的配准结果如表 9 所示,配准效果如图 11 所示。

表 9 室外场景点云的配准误差与时间

Tab. 9 Outdoor scene point cloud registration error and time

Registration method	RMSE /mm	Time /s
ICP	—	—
FPFH+ICP	0. 025	109. 808
SHOT+ICP	0. 026	85. 385
3DSC+ICP	0. 035	129. 739
NPD+Improved ICP	0. 019	70. 390

Notes: — indicates registration failure.




图 11 室外场景点云配准效果

Fig. 11 Point cloud registration effect in outdoor scenes

由表 9 及图 11 可知,由于室外场景点云的初始位姿较差,ICP 算法配准失败,基于 4 种特征的先粗后精配准方法能够完成室外场景的配准,但配准精度与用时具有明显差异。基于 3DSC 特征的配准方法精度最低, RMSE 为 0.035 mm,配准效果图中存在部分点云分层。相比其余方法,本文基于 NPD 特征的配准方法精度最高, RMSE 达到 0.019 mm,同时配准用时相较其余方法减少了 17%~45%,说明本文方法对于室外场景点云的配准同样具有更优的性能和更高的效率。

6 结 论

针对采用传统点云特征的粗-精两阶段配准方法存在的高维特征计算复杂耗时、稠密点云配准速度慢等问题,本文提出了一种三维点云的邻域分布快速配准方法,结合邻域点三种深层次的几何特征,提出了低维度多尺度的邻域分布特征描述,大幅降低了特征计算复杂度,同时提高了特征描述的区分度,解决了传统高维特征计算复

杂耗时的瓶颈问题。提出了基于邻域分布特征的快速粗配准方法。根据点云整体起伏程度与邻域点的分布方向,提取特征点,然后建立匹配点对集,并结合特征点的法线信息准确剔除错误匹配点对,解决了因特征描述的相似性而导致部分点对匹配错误的难题,实现了高效准确粗配准。通过 k 维树、体素化网格法及二次精配准策略改进 ICP 算法,解决了传统精配准算法对稠密点云配准速度慢的问题,实现快速精配准。实验结果表明,本文方法能够快速配准不同实物点云,对于稠密的点云配准效率优势更加明显,配准耗时降低了 52%,并具有更高配准精度,且抗噪的稳定性更强。

作者贡献声明:

余永维:配准方法的提出;

方荣:论文构思和撰写,计算机程序及支持算法执行;

杜柳青:总体方案设计与审核;

刘豪:配准实验设计;

刘中元:配准实验数据分析。

参考文献:

- [1] XIA J Y, LI B W, XU ZH Q, *et al.* Point cloud registration method based on improved TLBO for landing gear components measurement[J]. *Symmetry*, 2024, 16(11): 1506.
- [2] AIJAZI A K, CHECCHIN P. Non-repetitive scanning LiDAR sensor for robust 3D point cloud registration in localization and mapping applications[J]. *Sensors*, 2024, 24(2): 378.
- [3] WANG Y, ZHOU P B, GENG G H, *et al.* Enhancing point cloud registration with transformer: cultural heritage protection of the Terracotta Warriors[J]. *Heritage Science*, 2024, 12: 314.
- [4] 姚敏, 赵增浩, 赵敏, 等. 复杂结构件内部缺陷检测[J]. *仪器仪表学报*, 2020, 41(10): 213-220.
YAO M, ZHAO Z H, ZHAO M, *et al.* Internal defect detection of complex structural parts[J]. *Chinese Journal of Scientific Instrument*, 2020, 41(10): 213-220. (in Chinese)
- [5] GUO F, ZHENG W B, LIAN G F, *et al.* A point cloud registration method based on multiple-local-feature matching[J]. *Optik*, 2023, 295: 171511.
- [6] WEI K, DAI Y, REN B Y. Automatic identification and autonomous sorting of cylindrical parts in cluttered scene based on monocular vision 3D reconstruction [J]. *Sensor Review*, 2019, 39 (6) : 763-775.
- [7] XU G X, PANG Y J, BAI ZH X, *et al.* A fast point clouds registration algorithm for laser scanners [J]. *Applied Sciences*, 2021, 11(8): 3426.
- [8] HUANG SH J, WU SH SH, CHEN L, *et al.* A 3D local feature description algorithm based on point distribution[J]. *Computers and Electrical Engineering*, 2024, 118: 109341.
- [9] ZHAO L D, XIANG ZH F, CHEN M L, *et al.* Establishment and extension of a fast descriptor for point cloud registration[J]. *Remote Sensing*, 2022, 14(17): 4346.
- [10] 林森, 张强. 应用邻域点信息描述与匹配的点云配准[J]. *光学精密工程*, 2022, 30(8): 984-997.
LIN S, ZHANG Q. Point cloud registration using neighborhood point information description and matching[J]. *Opt. Precision Eng.*, 2022, 30(8): 984-997. (in Chinese)

- [11] 陈慧娟, 吴一全, 张耀. 基于深度学习的三维点云分析方法研究进展[J]. 仪器仪表学报, 2023, 44(11): 130-158.
CHEN H X, WU Y Q, ZHANG Y. Research progress of 3D point cloud analysis methods based on deep learning[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(11): 130-158. (in Chinese)
- [12] 司垒, 王忠宾, 李嘉豪, 等. 基于图像和激光点云融合的智能采面煤岩识别[J]. 振动测试与诊断, 2023, 43(2): 254-262, 407.
SI L, WANG ZH B, LI J H, *et al.* Coal-rock recognition of intelligent mining face based on the fusion of image and laser point cloud[J]. *Journal of Vibration, Measurement & Diagnosis*, 2023, 43(2): 254-262, 407. (in Chinese)
- [13] 陈仲生, 李潮林, 左旺, 等. 双重下采样增强的点云改进配准算法研究[J]. 汽车工程, 2023, 45(4): 572-578.
CHEN ZH SH, LI CH L, ZUO W, *et al.* Study on improved point cloud registration algorithm enhanced by double down-sampling[J]. *Automotive Engineering*, 2023, 45(4): 572-578. (in Chinese)
- [14] 郑源, 高峰, 范嘉博, 等. 基于配准与参数迭代优化的叶片面轮廓度评定方法研究[J]. 计算机集成制造系统, 2025, 31(7): 2456-2465.
ZHENG Y, GAO F, FAN J B, *et al.* Evaluation method of blade surface profile based on registration and parameter iterative optimization[J]. *Computer Integrated Manufacturing Systems*, 2025, 31(7): 2456-2465. (in Chinese)
- [15] 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.
LI J W, ZHAN J W. Review on 3D point cloud registration method [J]. *Journal of Image and Graphics*, 2022, 27(2): 349-367. (in Chinese)
- [16] ZHAO F Q, HUANG H, HU W X. An optimized hierarchical point cloud registration algorithm [J]. *Multimedia Systems*, 2024, 31(1): 14.
- [17] XIONG F G, DONG B, HUO W, *et al.* A local feature descriptor based on rotational volume for pairwise registration of point clouds[J]. *IEEE Access*, 2020, 8: 100120-100134.
- [18] YANG J Q, ZHANG Q, XIAO Y, *et al.* TOLDI: an effective and robust approach for 3D local shape description [J]. *Pattern Recognition*, 2017, 65: 175-187.
- [19] 方斌, 丁军峰, 马杰, 等. 三维局部描述子综述[J]. 华中科技大学学报(自然科学版), 2022, 50(11): 1-15.
FANG B, DING J F, MA J, *et al.* 3D local descriptors: a review[J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2022, 50(11): 1-15. (in Chinese)
- [20] HUANG Y, DA F P. Registration algorithm for point cloud based on normalized cross-correlation [J]. *IEEE Access*, 2019, 7: 137136-137146.
- [21] 韩宏琪, 江自真, 周俊, 等. 基于法向量夹角的果树点云配准与枝叶分割方法研究[J]. 农业机械学报, 2024, 55(9): 327-336.
HAN H Q, JIANG Z ZH, ZHOU J, *et al.* Fruit tree point cloud registration based on normal vector angles and branch-leaf segmentation method [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2024, 55(9): 327-336. (in Chinese)

作者简介:



余永维(1973—),男,重庆长寿人,博士,教授,1997年于武汉理工大学获得学士学位,2005年于重庆大学获得硕士学位,2014年于四川大学获得博士学位,主要从事机器视觉及智能控制等方面的研究。E-mail: weiyy@cqut.edu.cn

通讯作者:



杜柳青(1975—),女,重庆长寿人,博士,教授,1996年于四川工业学院获得学士学位,2003年于重庆大学获得硕士学位,2016年于四川大学获得博士学位,主要从事微弱信号检测及先进制造技术等方面的研究。E-mail: lq-du@cqut.edu.cn