

# 融合先验信息的单株植物三维结构点云配准方法

王太阳<sup>1</sup>,张熙空<sup>2,3</sup>,马楠<sup>3</sup>,曾宝秀<sup>4</sup>

(1. 东华理工大学 测绘与空间信息工程学院,江西 南昌 330006;

2. 山东科技大学 测绘与空间信息学院,山东 青岛 266590;

3. 青岛星科瑞升信息科技有限公司,山东 青岛 266590;

4. 中科卫星(山东)科技集团有限公司,山东 济南 250000)

**摘要:**针对样本一致性初始对化(SAC-IA)点云配准算法在处理样本抽样和误差计算时存在的高计算成本和鲁棒性不足的问题,提出一种融合先验信息的单株植物三维结构点云粗配准方法。该方法首先采用“体素下采样+直通滤波+统计离群点去除”的点云预处理策略,在有效降低点云数据量的同时保留植物结构的关键特征信息。通过引入基于先验知识的初始姿态约束,对 SAC-IA 算法进行改进,减少不合理变换矩阵的迭代次数,从而提高配准效率,降低误匹配风险。实验结果证明,所提方法配准均方根误差为 6.242,时间为 0.902 s,相比 SAC-IA 方法节省了 1.407 s,显著提升了单株植物三维结构点云配准的运算效率和鲁棒性。

**关键词:**SAC-IA 方法;点云配准;先验信息;单株植物

中图分类号:TP391

文献标志码:A

## A 3D structural point cloud registration method for individual plants incorporating prior information

WANG Taiyang<sup>1</sup>, ZHANG Xikong<sup>2,3</sup>, MA Nan<sup>3</sup>, ZENG Baoxiu<sup>4</sup>

(1. College of Geodesy and Geomatics, East China University of Science and Technology, Nanchang 330006, China;

2. College of Geodesy and Geomatics, Shandong University of Science and Technology, Qingdao 266590, China;

3. Star-rising Technology Co. Ltd, Qingdao 266590, China;

4. AIR Satellite (Shandong) Technology Group Co. Ltd, Jinan 250000, China)

**Abstract:** To address the issues of high computational cost and insufficient robustness in sampling and error calculation of the sample consensus initial alignment (SAC-IA) point cloud registration algorithm, this paper proposes a novel coarse registration method for 3D structural point cloud of individual plants by incorporating prior information. The proposed method adopts a “voxel downsampling + passthrough filtering + statistical outlier removal” point cloud preprocessing strategy to preserve the key structural features of plants while effectively reducing the point cloud data volume. By introducing initial pose constraints based on prior knowledge, the SAC-IA algorithm is improved to reduce the number of iterations for unreasonable transformation matrices, thereby improving the registration efficiency and lowering the risk of mismatches. The experimental results demonstrate that the proposed method achieves a registration root mean square error of 6.242 and a processing time of 0.902 seconds, which saves 1.407 seconds compared to the SAC-IA method, significantly enhancing the computational efficiency and robustness of point cloud registration for three-dimensional structures of individual plants.

**Key words:** sample consensus initial alignment (SAC-IA) method; point cloud registration; prior information; individual plants

收稿日期:2023-11-30

作者简介:王太阳(1998—),男,甘肃会宁人,硕士研究生,主要从事生态遥感技术的研究。

张熙空(1995—),男,内蒙古赤峰人,硕士研究生,主要从事遥感图像处理方法研究,本文通信作者。

E-mail:zhangxikong@gmail.com

植物三维结构信息在生态、环境、农业、林业、城市规划等方面具有重要的应用价值,能够提供植物的生长状态、分布情况及其与环境的相互作用,用于评估生态系统的健康状况、监测环境变化、预测生态系统的响应等<sup>[1-2]</sup>。在农业和林业领域,植被三维结构信息对于精准农业和林业管理至关重要,可优化种植布局、提高作物产量,并辅助实现农业和林业的可持续发展,还可用于评估森林生物量、监测森林病虫害以及制定合理的森林砍伐和恢复计划。在城市规划和景观设计方面,通过了解植被的三维形态和空间分布提升城市绿地的设计能力<sup>[3-4]</sup>。三维点云数据是单株植物三维结构信息提取的重要手段,获取多视角点云数据常用的方法包括基于移动平台的动态采集、固定视角下的物体旋转以及多相机同步捕捉系统等,单株植物的完整三维表型数据是通过传感器从多个角度对目标进行拍摄后配准获取的。点云预处理技术的步骤包括去除噪声、下采样以及点云配准技术,准确高效的点云粗配准算法是获取单株植物三维结构信息的关键环节<sup>[5-6]</sup>。

点云粗配准旨在实现两个数据集在大致位置和方向上的初步对齐,为后续的精确保准奠定基础。在粗配准阶段,点云的几何特征发挥至关重要的作用。点云的几何特征通常可分为全局特征和局部特征两类。全局特征从整体上描述点云的宏观结构和形态,例如点对特征(point pair features, PPF)<sup>[7]</sup>及其衍生特征<sup>[8]</sup>等,其核心原理是利用点对间的相对几何关系建立全局描述符,并通过霍夫投票的方式实现点云配准;3D霍夫变换<sup>[9]</sup>是霍夫变换在三维空间的扩展,通过将点云数据从空间域转换到参数域的方法,使得具有相同几何属性的点集在参数域中聚集进而实现点云配准。与全局特征相比,局部特征更专注于点云中具体区域的细节结构,如快速点特征直方图(fast point feature histograms, FPFH)<sup>[10]</sup>通过分析点及其邻域内点的特定几何关系,并将这些信息编码成直方图,进而得到目标的局部特征;方向直方图特征(signature of histograms of orientations, SHOT)<sup>[11]</sup>则通过对每个点邻域空间的不同部分计算方向直方图,能详细描述该点的局部几何特性。样本一致性初始对化(sample consensus initial alignment, SAC-IA)是一种被广泛认可和应用的局部特征匹配方法,对于受噪声、遮挡和不完整性等问题影响的点云数据,SAC-IA通过随机采样及内点累积的匹配策略提高配准的准确性与鲁棒性<sup>[12]</sup>。但SAC-IA特征对齐策略在处理样本抽样和误差计算时存在迭代计算成本高以及鲁棒性不足的问题,同时在植物的点云数据中,存在大量相似局部特征,比如树枝和叶子等,增加了配准的难度。

植物点云配准方法包括基于外界标志信息的方法和基于特征提取的方法。其中,基于外界标志信息的方法,通过在环境中预设的标志或标记来辅助配准点云数据,并通过识别和匹配这些标志,确定不同点云之间的相对位置和方向,进而完成点云配准<sup>[13]</sup>;基于特征提取的方法,通过提取点云数据本身几何特征信息实现配准,无需额外的外界标志<sup>[14]</sup>。依赖外界标志进行植物点云配准易受到环境限制,且可能干扰植物的自然生长,不利于持续性研究。基于几何特征的配准方法在计算效率和稳定性方面存在挑战。因此,研究既稳定又通用的植物点云配准策略尤为重要。

针对SAC-IA方法存在的上述问题,本研究提出一种融合先验信息的单株植物三维结构点云粗配准方法。该方法首先采用“体素下采样+直通滤波+统计离群点去除”的点云预处理策略,有效降低点云数据量的同时保留植物结构的关键信息;其次,引入先验的姿态信息,约束SAC-IA算法中随机采样的搜索空间,实现单株植物点云的高效率、强鲁棒性初步对齐。

## 1 SAC-IA方法

SAC-IA方法的基本思想是:首先计算目标点云和源点云的局部特征,然后根据这些特征之间的空间变换关系确定两个点云的初步变换矩阵,为后续步骤的精确保准提供良好的初始位姿,具体步骤如下。

- 1) 对于源点云 $Q$ 和目标点云 $P$ ,分别选取合适数量的点计算局部特征描述符;
- 2) 基于计算得到的描述符,找出可能的点对对应关系,推导出其空间变换 $(R, t)$ ;
- 3) 进行误差评估与更新,应用计算得到的 $(R, t)$ 变换到整个源点云上,然后在目标点云中寻找相应的匹配点,计算该变换条件下所有点对之间的误差,

$$E(R, t) = \frac{1}{N} \sum_{i=1}^N \|R p_i + t - q_i\|^2. \quad (1)$$

式中, $p_i \in P, q_i \in Q$  通过比较每次迭代过程中的误差,更新误差最小值及对应的最优变换矩阵。

4) 重复步骤 2)、3), 直至完成迭代次数, 选择最终的变换矩阵。

对原始点云应用随机生成的旋转和偏移矩阵进行变换, 产生源点云和目标点云。对算法进行迭代实验分析, 记录并可视化 8 次迭代的采样结果, 如图 1 所示。图 1(a)~1(h) 分别对应 8 次迭代的采样结果, 可以看出, SAC-IA 采样得到的变换关系存在随机性, 计算迭代变换后对应点之间的欧式距离误差, 从所有迭代中选取误差最小的变换关系作为最终的配准结果。其中, 图 1(g) 的均方根误差最小, 因此图 1(g) 对应的变换关系被认为是 SAC-IA 的最优解。



图 1 原始 SAC-IA 算法

Fig. 1 Original SAC-IA algorithm

SAC-IA 方法在处理样本抽样和误差计算时主要存在两个问题: 一是处理高密度点云数据时, 重复进行空间变换和误差计算极大降低了算法的执行效率; 二是对于具有相似纹理特征的非对应点, 误匹配导致大量不必要的计算。由于 SAC-IA 方法可能将任何姿态的变换关系视为最优, 导致搜索空间过大, 因此降低了算法的鲁棒性。

## 2 融合先验信息的单株植物三维结构点云配准方法

为改善上述问题, 本研究对 SAC-IA 的迭代过程进行优化。在随机采样步骤中, 引入基于先验条件的初始姿态约束, 有效减少不合理变换矩阵的迭代次数, 提高配准效率, 降低误匹配的概率。该策略减少了由于误采样而在局部特征配准过程中产生的非实际对应特征之间的冗余迭代计算, 有效解决了配准效率低下和误配准问题, 改进方法流程如图 2 所示。首先, 对目标点云和源点云进行预处理, 并记录目标点云的方向特征, 即欧拉角  $\alpha$ 。其次, 分别计算目标点云与源点云的局部特征, 初始化变换矩阵  $T$  为单位矩阵, 并将误差  $E$  的初始值设为正无穷大, 设定角度误差的阈值  $d$  为先验条件的容差大小。接着, 通过采样选取具有相似特征的点对集, 利用这些点对集的对对应关系计算出新的变换矩阵  $T'$ , 使用  $T'$  计算源点云的方向特征, 即可得到欧拉角  $\gamma'$ , 并计算欧拉角  $\alpha$  与  $\gamma'$  之间的差值; 如果这个差值大于阈值  $d$ , 则认为本次采样是无效的, 需要重新选取具有相似特征的点对并重复计算, 如果差值小于阈值  $d$ , 则认为本次采样是有效的; 在确认采样有效后, 计算新的均方根误差  $E'$ , 如果  $E'$  小于当前误差  $E$ , 则更新变换矩阵  $T$  为  $T'$ , 同时更新误差  $E$  为  $E'$ , 视为找到了一个更优的变换矩阵。重复此流程, 直至达到设定的最大迭代次数。最后, 将得到的变换矩阵  $T'$  作

为最终的变换矩阵,此时的均方根误差是最小的。

### 2.1 点云预处理

点云预处理的主要目的是改善点云数据的质量,以便支持后续的分析和应用。点云预处理包括去除噪声、下采样等步骤。植物点云具有数据量大、背景干扰大以及拍摄环境导致的噪声等问题,通过合适的预处理方式,可在有效解决上述问题的同时,增强数据的特征表达。

本研究对体素下采样、均匀下采样和随机下采样方法进行比较,结果如图 3 和表 1 所示。采样点的数量一致时,均匀下采样的用时最长,随机下采样用时最短。体素下采样方法通过划分空间并快速归类点到对应的体素中,减少了处理点云时的冗余计算,而均匀下采样方法需要采用邻域算法确定点及其邻近点的关系,导致邻域算法的构建和查询过程通常比简单的空间划分要复杂,所以在效率上体素下采样方法高于均匀下采样。随机下采样方法由于不涉及上述复杂的空间划分或邻近点搜索,仅基于随机选择而不考虑点与点之间的空间关系,使得随机降采样方法在执行时拥有最高的效率。综上,体素下采样在减少数据量、保留特征、降低噪声和提高计算效率方面为综合效果最好的解决方案,因此本研究最终采用体素下采样方法对点云进行精简。

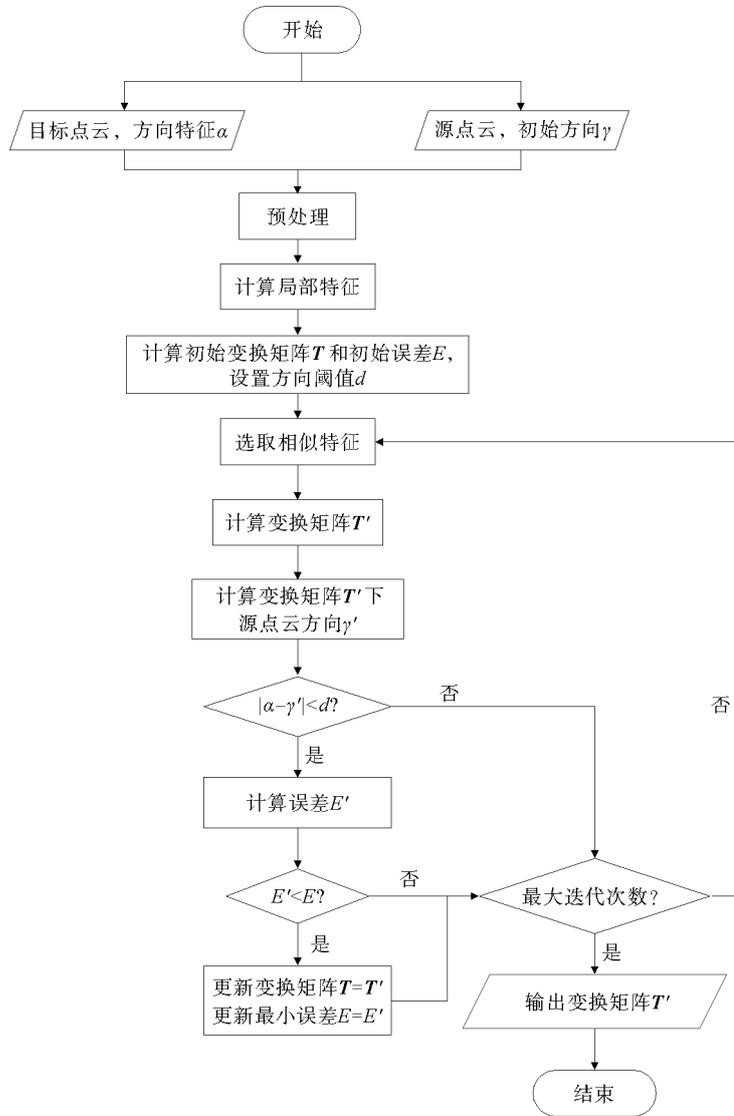


图 2 改进 SAC-IA 方法流程图

Fig. 2 Flowchart of improved SAC-IA method

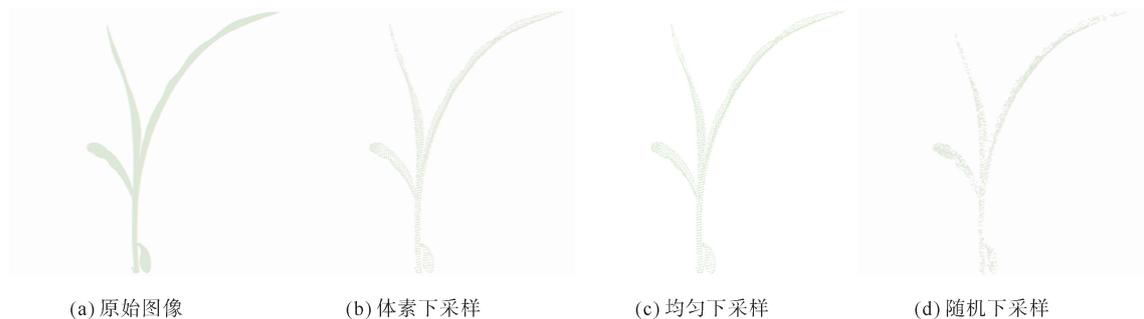


图 3 不同下采样方法对比

Fig. 3 Comparison of different downsampling methods

表 1 不同下采样方法的相关数据

Table 1 Data related to different downsampling methods

方法	采样前点云数量/个	采样后点云数量/个	采样时间/s
体素下采样	891 541	2 044	0.016
均匀下采样	891 541	2 044	0.025
随机下采样	891 541	2 044	0.010

表 2 不同滤波方法的相关数据

Table 2 Data related to different filtering methods

方法	滤波前噪声点数量/个	滤波后噪声点数量/个	采样时间/s
统计离群点去除	200	15	0.005
半径离群点去除	200	21	0.005
直通滤波	200	123	0.001

针对点云去噪处理,本研究对统计离群点去除法、半径离群点去除法以及直通滤波法进行对比,结果如表 2 和图 4 所示。直通滤波法通过指定坐标值的范围快速剔除不感兴趣的区域,提高数据处理的效率和后续分析的专注度,但直通滤波法剔除了沿某方向一定范围的所有点,包括噪声点和有用信息,不能直接用于离散噪声的去除。统计离群点去除法通过利用局部邻域内的统计信息,能够鲁棒地识别并去除点云数据中的离群点。因此本研究采用“直通滤波+统计离群点去除”结合的策略,先用直通滤波法快速去除无关区域的数据,再通过统计离群点去除法精细去噪,提升处理效率和去噪质量,同时保持对复杂环境的适应性。

通过以上对比分析,本研究采用“体素下采样+直通滤波+统计离群点去除”的点云预处理策略。

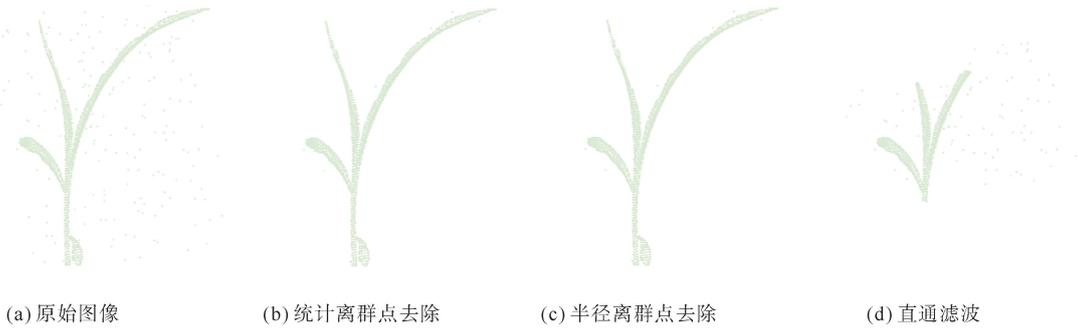


图 4 不同滤波方法对比

Fig. 4 Comparison of different filtering methods

## 2.2 融合先验信息改进 SAC-IA 方法

对于目标静止、传感器位姿已知,或传感器静止、目标姿态已知的情况,融合先验信息改进 SAC-IA 方法具体操作步骤如下。

1) 创建姿态表达方式:以 ZYX 外旋的方式建立欧拉角表示的空间位姿。设源点云获取的姿态为  $A_{Source}(\phi, \vartheta, \psi)$ ,目标点云获取的相对姿态  $A_{Target}(\delta, \epsilon, \eta)$ ,将  $A_{Source}$  转换为旋转矩阵  $R_{Source}$ 。

$$R_{Source} = \begin{pmatrix} c(\phi)c(\vartheta) & c(\phi)s(\vartheta)s(\psi) - s(\phi)c(\psi) & c(\phi)s(\vartheta)c(\psi) + s(\phi)c(\psi) \\ s(\phi)c(\vartheta) & s(\phi)s(\vartheta)s(\psi) + c(\phi)c(\psi) & s(\phi)s(\vartheta)c(\psi) - c(\phi)s(\psi) \\ -s(\vartheta) & c(\vartheta)s(\psi) & c(\vartheta)c(\psi) \end{pmatrix} \quad (2)$$

式中:  $c$  为余弦值,  $s$  为正弦值。

2) 特征提取:分别对源点云  $Q$  和目标点云  $P$  计算局部特征描述符。

3) 特征匹配:根据描述符的相似性,寻找可能的点对应关系并求解变换矩阵  $T'$ ,将变换矩阵分解得到旋转矩阵  $R'$ ,则此变化下源点云的姿态为  $R$ ,

$$R = R' \times R_{Source} = \begin{bmatrix} R_{11} & R_{12} & R_{13} \\ R_{21} & R_{22} & R_{23} \\ R_{31} & R_{32} & R_{33} \end{bmatrix} \quad (3)$$

此时源点云在空间坐标系下的三个方向分量分别为:

$$A_x = \arctan(R_{23}/R_{33}), \quad (4)$$

$$A_y = \arctan(-R_{13}/\sqrt{R_{11}^2 + R_{12}^2}), \quad (5)$$

$$A_z = \arctan(R_{12}/R_{11}). \quad (6)$$

4) 设置判定条件:设置每个方向的误差阈值  $T_x$ 、 $T_y$ 、 $T_z$ , 如果满足

$$|A_x - \delta| < T_x \wedge |A_y - \varepsilon| < T_y \wedge |A_z - \eta| < T_z, \quad (7)$$

则将变换矩阵  $T'$  应用到整个源点云, 并计算该变换的所有点对的对齐误差  $E'$ ; 否则重新进行步骤 3)~4)。

5) 迭代更新最优解: 根据每次迭代的误差更新最小误差与最佳变换矩阵, 直至满足迭代次数。

如图 5 所示, 传感器的拍摄姿态为已知或大致方向能够被确定时, 本研究采用先验姿态信息优化配准过程: 首先, 分析每个采样变换矩阵, 通过限制变换矩阵中一个或多个方向的偏差阈值, 判断其是否与预设的拍摄姿态条件相符; 当变换矩阵的偏差在设定的阈值范围内时, 继续计算配准误差, 否则重新采样变换矩阵。该策略提高了配准结果可靠性的同时减少了冗余计算, 显著提升了算法的执行速度。

因此, 通过引入先验姿态信息, 改进了 SAC-IA 方法的迭代过程, 缩小了原始算法的位姿变换搜索空间, 并在减小计算量的同时, 保证了计算结果的可靠性。

### 2.3 评价指标

本研究采用均方根误差衡量两个点云之间对应点的空间位置差异, 均方根误差的值越小, 表示两个点云之间的差异越小, 配准结果越好。计算公式为:

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (p_i - q_i)^2}. \quad (8)$$

式中:  $R_{MSE}$  为均方根误差,  $q_i$  表示源点云中的一点,  $p_i$  表示  $q_i$  在目标点云中的对应点。

## 3 实验与结果分析

### 3.1 实验数据

本研究采用波恩大学发布的 4D Plant Registration Dataset 点云数据集<sup>[13]</sup>作为基础数据, 并进行多视角点云模拟数据生成。4D Plant Registration Dataset 是一个高质量的植物点云数据集, 包含了多个植物在不同时间点的三维扫描数据, 涵盖了多种植物品种, 如蔬菜、花卉和灌木等。该数据集提供了高分辨率的点云数据, 并配有详细的植物结构标注, 如茎干、主要分支和叶子等, 为植物形态学、生长分析和机器学习算法的开发提供了丰富支撑。本研究在原始点云中选择  $0^\circ$ 、 $45^\circ$ 、 $90^\circ$ 、 $145^\circ$ 、 $180^\circ$ 、 $225^\circ$ 、 $270^\circ$  和  $315^\circ$  共 8 个方位角点作为观测点, 隐藏点移除后得到点云分布。为更好地体现不同视角的遮挡缺失情况, 采用同一视角展示点云数据, 如图 6 所示。

### 3.2 结果与分析

本研究采用 SHOT 作为实验的特征描述符, 选用图 6(b)  $45^\circ$  视角点云与图 6(d)  $145^\circ$  视角点云分别作为源点云和目标点云, 姿态偏差阈值设为  $10^\circ$ , 以本研究提出的改进 SAC-IA 为例, 实验结果的 8 次采样过程如图 7 所示, 可以看出本研究方法能够根据先验姿态信息有效检测迭代过程中产生的随机偏差。

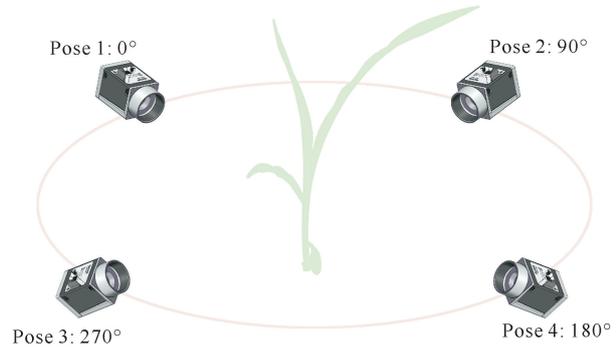


图 5 不同相机姿态获取点云数据示意图

Fig. 5 Diagram of point cloud data acquisition from different camera poses

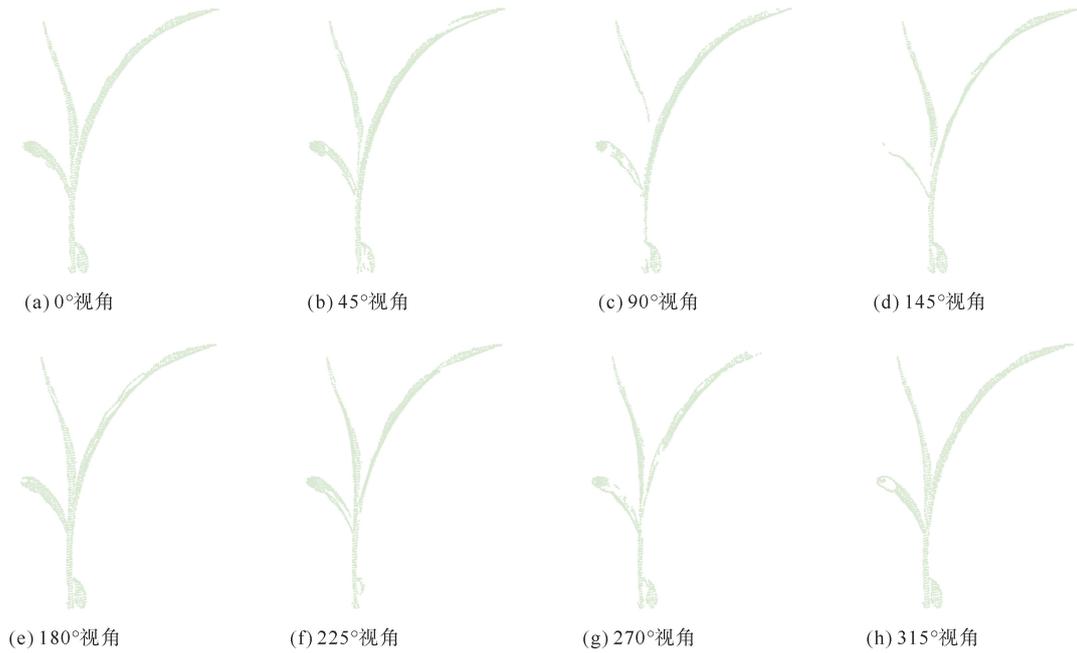


图 6 多视角点云数据

Fig. 6 Multi-view point cloud data

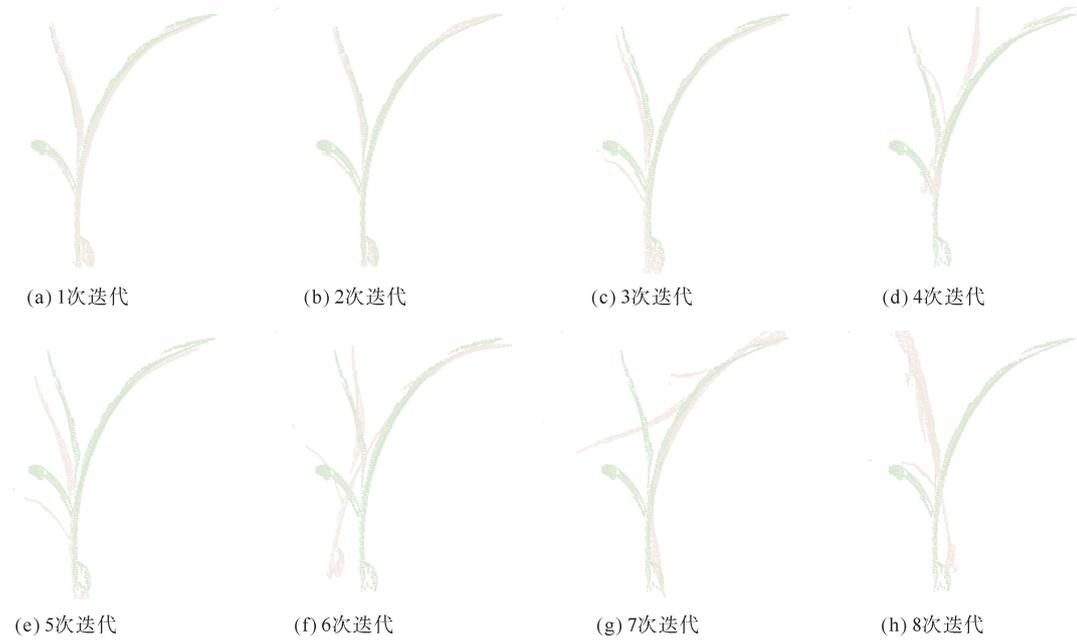


图 7 本研究方法多视角点云迭代过程

Fig. 7 Iterative process of multi-view point cloud of the proposed method

表 3 展示了本研究方法对点云配准迭代过程的评估结果。在迭代误差的计算中,本研究改进的 SAC-IA 算法检测到姿态偏差超过阈值的情况,与原始算法计算了 8 次均方根误差相比,本研究方法仅计算了 3 次姿态偏差阈值内的均方根误差。如表 3 所示,其中, $\theta_x$ 、 $\theta_y$ 、 $\theta_z$  分别代表采样变换关系在  $x$ 、 $y$ 、 $z$  轴的分量,对于迭代采样的变换关系存在明显不符合先验条件的情况,本研究改进算法检测到迭代次序(a)、迭代次序(f)、迭代次序(g)和迭代次序(h)的  $\theta_z$  不在条件约束范围内,迭代次序(d)和迭代次序(g)的  $\theta_x$  不在条件约束范围内,迭代次序(d)、迭代次序(f)和迭代次序(g)的  $\theta_y$  不在约束范围内,因此上述采样得到的变换关系

被认为是无效变换,因此不参与误差计算。

表 3 本研究方法多视角点云迭代过程评估

Table 3 Evaluation of the multi-view point cloud iterative process of the proposed method

评估指标	$\theta_x$	$\theta_y$	$\theta_z$	SAC-IA 的 $R_{MSE}$	改进 SAC-IA 的 $R_{MSE}$
迭代次序(a)	-2.557	6.090	76.394	15.361	—
迭代次序(b)	0.334	0.518	90.158	12.137	12.137
迭代次序(c)	1.335	-0.919	91.189	6.242	6.242
迭代次序(d)	16.805	-12.839	93.913	17.681	—
迭代次序(e)	4.893	-2.870	97.158	28.142	28.142
迭代次序(f)	1.888	-21.412	102.352	32.937	—
迭代次序(g)	-71.506	152.032	131.580	50.736	—
迭代次序(h)	-8.853	-2.184	177.272	21.935	—

为了更直观地说明本研究方法的有效性,将本研究方法与 SAC-IA 以及基于固有形状特征码(Intrinsic shape signatures,ISS)关键点的 SAC-IA(ISS-SAC-IA)方法<sup>[15]</sup>进行对比实验,其中 ISS-SAC-IA 方法结合关键点检测、特征描述和 SAC-IA 方法实现粗略的初始配准。本研究将采样次数设置为 100 次,本研究改进的 SAC-IA 方法、原始 SAC-IA 方法及 ISS-SAC-IA 方法的配准结果如图 8 所示,其中图 8(a)为原始 SAC-IA 配准结果,图 8(b)为 ISS-SAC-IA 配准结果,图 8(c)为本研究改进 SAC-IA 配准结果。三种方法均成功实现了不同视角下植物点云的粗配准,但在细节上,基于 ISS 关键点的 SAC-IA 方法偏差最大,这对后续的精配准工作具有负面影响,本研究提出的融合先验信息的配准方法降低了配准偏差。



图 8 不同方法用于单株植物三维结构点云粗配准结果对比

Fig. 8 Comparison of the results of different methods for the 3D structural point cloud coarse registration of individual plants

表 4 为不同方法配准结果的定量分析:①SAC-IA 算法的运行时间相对较长,主要原因在于该算法需对源点云及目标点云中的所有点执行 100 次平移和旋转操作,并计算每对点间的欧式距离,因而消耗了大量计算资源;②本研究改进的 SAC-IA 方法通过引入先验条件,在计算过程开始前对变换矩阵进行预判,有效排除了超出容差范围的变换矩阵,从而减少了不必要的冗余计算。在精度方面,本研究改进的 SAC-IA 方法与原始 SAC-IA 方法的表现持平,但在鲁棒性和稳定性方面,本研究方法有所改善,原因是搜索空间的减少提

升了算法对噪声和异常值的鲁棒性,降低了错误配准的概率,确保了算法的稳定性。

基于ISS关键点的SAC-IA算法使得局部描述符的计算速度以及SAC-IA的执行速度均取得显著提升。原因是SAC-IA的输入从整体点云特征和坐标变为关键点的特征和坐标,需要计算的特征数量由原始2 923个降为306个,大幅降低了数据处理量,提高了计算效率。然而,在精确度方面,利用关键点进行配准的策略导致更大的误差,且稳定性有所下降。原因是仅在关键点上进行描述符的计算仅利用了点云的部分信息完成配准,导致部分对配准质量有正面贡献的关键信息被忽略,且由于关键点只占据点云少量部分,导致配准过程的冗余度减少,增加了由于误匹配导致的失败风险。而本研究改进的SAC-IA方法无需改变点云数量,而是通过减少无效迭代计算来降低计算量。因此,本研究方法同时保证了配准的精度和效率,获得了准确高效的点云粗配准结果。

表4 不同方法的点云配准结果评估

Table 4 Evaluation of point cloud registration results of different methods

评估指标	参与计算点数/个	误差计算次数/次	时间/s	$R_{MSE}$
SAC-IA <sup>[12]</sup>	2 923	100	2.309	6.242
ISS-SAC-IA <sup>[15]</sup>	306	100	0.321	13.341
本研究方法	2 923	33	0.902	6.242

#### 4 结论

为获取单株植物准确的三维结构信息,提升SAC-IA方法的效率,本研究提出一种融合先验信息的单株植物三维结构点云粗配准方法。该方法采用“体素下采样+直通滤波+统计离群点去除”的单株植物点云预处理策略,实现了高效精准的非工作区域点云分割、点云去噪和采样,为后续处理提供了优质数据基础。在SAC-IA方法基础上,引入先验位姿信息作为约束条件,限制了最优变换搜索空间,减少了冗余迭代计算,降低了误配准的风险,提高了配准的效率和鲁棒性。

#### 参考文献:

[1] 费鲜芸,戴哲,刘如飞. 三维激光点云中建筑物立面边界特征提取方法[J]. 山东科技大学学报(自然科学版),2022,41(2): 21-30.  
FEI Xianyun,DAI Zhe,LIU Rufe. Boundary feature extraction method of building facade in 3D laser point cloud[J]. Journal of Shandong University of Science and Technology(Natural Science),2022,41(2):21-30.

[2] 陈嘉阳,卜宪海,陈殿称,等. 顾及地形复杂度因子权重的多波束点云抽稀算法[J]. 山东科技大学学报(自然科学版), 2022,41(5):21-29.  
CHEN Jiayang,BU Xianhai,CHEN Dianchen,et al. A thinning algorithm of multibeam point cloud considering weight of terrain complexity factor[J]. Journal of Shandong University of Science and Technology(Natural Science),2022,41(5):21-29.

[3] PATURKAR A,GUPTA G S,BAILEY D. Non-destructive and cost-effective 3D plant growth monitoring system in outdoor conditions[J]. Multimedia Tools and Applications,2020,79:34955-34971.

[4] ZHANG W D,SUN X W,ZHOU L,et al. Dual-branch collaborative learning network for crop disease identification [J/OL]. Frontiers in Plant Science,2023,14. DOI:10.3389/fpls.2023.1117478.

[5] ZHENG Z J,ZENG Y,SCHNEIDER F D,et al. Mapping functional diversity using individual tree-based morphological and physiological traits in a subtropical forest[J/OL]. Remote Sensing of Environment,2021,252. DOI:10.1016/j.rse.2020.112170.

[6] 王郑阳,俞昊,孟昊,等. POWERLINE-ALS:一种用于输电线路场景深度学习语义分割的机载LiDAR点云数据集[J]. 山东科技大学学报(自然科学版),2023,42(2):33-43.  
WANG Zhengyang,YU Hao,MENG Hao,et al. POWERLINE-ALS: An airborne LiDAR point cloud dataset for transmis-

- sion line scene semantic segmentation with deep learning methods[J]. Journal of Shandong University of Science and Technology(Natural Science), 2023, 42(2): 33-43.
- [7] BIRDAL T, ILIC S. Point pair features based object detection and pose estimation revisited[C]//2015 International Conference on 3D Vision. IEEE, 2015: 527-535.
- [8] MORADI S, LAURENDEAU D, GOSELIN C. Multiple cylinder extraction from organized point clouds[J/OL]. Sensors, 2021, 21. DOI: 10. 3390/s21227630.
- [9] XU Y S, TUTTAS S, HOEGNER L, et al. Voxel-based segmentation of 3D point clouds from construction sites using a probabilistic connectivity model[J]. Pattern Recognition Letters, 2018, 102: 67-74.
- [10] RUSU R B, BLODOW N, BEETZ M. Fast point feature histograms(FPFH) for 3D registration[C]//2009 IEEE International Conference on Robotics and Automation. IEEE, 2009: 3212-3217.
- [11] TOMBARI F, SALTI S, STEFANO L D. Unique signatures of histograms for local surface description[C]//Computer Vision-ECCV 2010: 11th European Conference on Computer Vision, Sep. 5-11, 2010. Proceedings, Part III. Berlin: Springer, 2010: 356-369.
- [12] RUSINKIEWICZ S, LEVOY M. Efficient variants of the ICP algorithm[C]//Proceedings the Third International Conference on 3-D Digital Imaging and Modeling. IEEE, 2001: 145-152.
- [13] 陈海波, 刘圣搏, 王乐乐, 等. 基于 Kinect V3 的单株作物自动化三维重建与验证[J]. 农业工程学报, 2022, 38(16): 215-223.  
CHEN Haibo, LIU Shengbo, WANG Lele, et al. Automatic 3D reconstruction and verification of an individual crop using Kinect V3[J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(16): 215-223.
- [14] PENG Y P, LIN S D, WU H K, et al. Point cloud registration based on fast point feature histogram descriptors for 3D reconstruction of trees[J/OL]. Remote Sensing, 2023, 15. DOI: 10. 3390/rs15153775.
- [15] MIAN A S, BENNAMOUN M, OWENS R. Three-dimensional model-based object recognition and segmentation in cluttered scenes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(10): 1584-1601.

(责任编辑:高丽华)