

基于UGV表型平台的作物三维表型获取方法与性能对比研究

杨 斯^{1,2} 郭新宇^{1,2} 蔡双泽^{1,2} 苟文博^{1,2} 卢宪菊^{1,2} 仇广杰^{1,2}

(1.北京市农林科学院信息技术研究中心,北京 100097; 2.国家农业信息化工程技术研究中心,北京 100097)

摘要: 高通量作物原位三维重建技术是现代作物表型组学研究的核心方法之一,为作物形态结构解析、株型特征精准评估及表型与基因型关联分析提供了关键数据支持。针对传统人工测量效率低下且易出错的问题,本研究构建了一套基于无人地面车辆(Unmanned ground vehicle, UGV)的高通量作物三维表型数据原位获取平台,并系统探究了4种主流传感器(FLIR可见光相机、Kinect DK、Velodyne VLP-16、Livox Avia)的三维重建算法的性能。对比了基于运动恢复结构与多视角立体视觉(Structure-from-motion and multi-view stereo, SfM-MVS)的可见光图像三维重建、基于迭代最近点(Iterative closest point, ICP)的RGB-Depth图像三维重建、基于激光惯性里程计(LiDAR-inertial odometry, LIO)的固态激光雷达三维重建,以及基于匀速叠加帧的机械式激光雷达点云拼接重建的4种方法。以温室盆栽生菜为例,对4种方法获取的点云数据进行标准化处理,通过开发的自动化处理管道实现了株高和最大冠幅等关键表型参数的精确提取与分析。本研究深入探究并分析了上述方法的优缺点,从点云质量、重建效率、表型性状解析精度与系统成本等方面,对上述方法的适用性进行了全面评估。研究结果不仅可为UGV表型平台的传感器选型和算法开发提供实验依据,也可为育种家和农学家选取高效、精准的表型信息获取方式提供参考。

关键词: 作物表型; 无人车; 传感器; 高通量; 三维重建

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 1000-1298(2026)01-0041-10

OSID:



Comparison of Crop Three-dimensional Phenotyping Methods and Performance Based on UGV Phenotyping Platform

YANG Si^{1,2} GUO Xinyu^{1,2} CAI Shuangze^{1,2} GOU Wenbo^{1,2} LU Xianju^{1,2} QIU Guangjie^{1,2}

(1. Information Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China

2. National Engineering Research Center for Information Technology in Agriculture, Beijing 100097, China)

Abstract: High-throughput 3D crop phenotyping is one of the core methodologies in modern crop phenomics research, providing crucial data support for holistic morphological structure analysis, precise evaluation of plant architectural traits, and genotype-phenotype association analysis. Aiming to address the challenges of low efficiency and limited data accuracy inherent in traditional manual measurements, a high-throughput 3D crop phenotyping data acquisition platform was developed based on an unmanned ground vehicle (UGV). The performance of four mainstream sensors (FLIR visible light camera, Kinect DK, Velodyne VLP-16, and Livox Avia) and their corresponding 3D reconstruction algorithms for crop phenotyping were systematically investigated. Specifically, it was compared the 3D reconstruction from visible light images based on structure-from-motion (SfM) and multi-view stereo (MVS), 3D reconstruction from RGB-depth images based on iterative closest point (ICP), point cloud reconstruction from solid-state LiDAR leveraging LiDAR-inertial odometry (LIO) and point cloud stitching from mechanical rotating LiDAR by using uniform velocity frame superposition. Experiments were conducted on potted lettuce plants in a greenhouse, where point cloud data acquired by the four methods underwent

收稿日期: 2025-09-30 修回日期: 2025-10-17

基金项目: 北京市农林科学院改革与发展项目(GCFZ20240102)、国家重点研发计划项目(2022YFD2002300)、北京市乡村振兴项目(NY2401040025)、北京市农林科学院博士后基金项目和博士后科学基金项目(2025MM772488)

作者简介: 杨斯(1992—),女,助理研究员,博士,主要从事表型机器人研究,E-mail: yangsi4212@163.com

通信作者: 郭新宇(1973—),男,研究员,博士,主要从事作物表型组学研究,E-mail: guoxy73@163.com

standardized processing. An automated processing pipeline was developed, enabling precise extraction and analysis of key phenotypic parameters, such as plant height and maximum canopy width. This research thoroughly explored and analyzed the characteristics, advantages, and disadvantages of each method. Their applicability was comprehensively evaluated based on point cloud quality, reconstruction efficiency, phenotypic trait accuracy and system cost. The findings can not only provide experimental basis for sensor selection and algorithm development of 3D phenotyping UGVs but also can offer valuable references for breeders and agronomists in selecting efficient and accurate phenotyping data acquisition approaches.

Key words: crop phenotyping; unmanned ground vehicle; sensor; high-throughput; 3D reconstruction

0 引言

植物表型是基因与环境相互作用产生的可辨识的物理、生理和生化特征及性状,是连接基因型与农艺性状的桥梁^[1-2]。近 20 年来,植物表型组学快速发展,对高效、精准与可重复的表型获取提出了更高要求^[3]。随着全球人口增长和气候变化,对作物育种和栽培管理的需求日益迫切,高效、精准地获取作物表型数据对于提高作物改良效率至关重要^[4]。然而,传统人工测量方法普遍存在耗时耗力、主观性强、易受环境影响且数据精度和一致性难以保证等缺点,已成为作物育种的主要瓶颈之一^[5-6],无法满足现代高通量表型组学研究的需求。

在计算机技术和农业的学科交叉融合中,机器视觉技术在植物表型组学领域得到了越来越广泛和深入的应用^[7]。它能较为准确、有效地测量株高、最大冠幅等常见作物特别是叶菜类作物的重要生长参数^[8]。然而,植物的特殊结构及其所处的复杂环境使得通过二维图像获取高精度的植物表型参数具有一定的局限性^[9],二维图像丢失了三维空间中的另一维度数据^[10-11]。因此,越来越多的研究开始倾向于获取植物的三维结构来评估其生长状态^[12],并逐步证实作物冠层三维表型精准获取装备及技术对优质育种、科学栽培和精细管理具有重要意义^[13-15]。

在多类表型平台中,基于无人地面车辆(Unmanned ground vehicle, UGV)表型平台能够搭载多种先进传感器,实现作物生长过程中多维度、高频率、非接触式的表型数据采集,显著提高了数据获取效率和精度^[16-18]。UGV 表型平台已在作物氮素状况测量^[19]、地上生物量估计^[20]以及种植密度测量^[15,21]等方面得到了应用。

尽管已有诸多研究致力于作物三维表型数据获取^[22-25],但针对不同传感器类型、不同重建算法以及不同作物形态之间性能差异的系统性对比研究仍相对缺乏。特别是在 UGV 表型平台集成多源传感器背景下,如何根据实际应用场景选择最适宜的传

感器配置和数据处理方案,是当前研究面临的挑战^[18]。为此,本文构建一套基于 UGV 的高通量原位三维表型获取平台与数据标准化及自动化解析管道。以温室盆栽生菜为对象,系统评估 UGV 表型平台上 4 种典型“传感器-算法”组合的性能与适用性:可见光 (FLIR 型相机) + SfM - MVS、RGB - D (Kinect DK 型深度相机) + ICP 配准、固态 LiDAR (Livox Avia) + LIO、机械式 LiDAR (Velodyne VLP - 16) + 匀速叠加帧拼接。其中,机械式 LiDAR + 匀速叠加帧拼接方法为本文提出的基于电动滑轨驱动的激光雷达扫描方式,旨在缓解地面不平带来的微振动对配准与重建精度的影响以及轨道式表型平台成本高、不可移动的问题。通过开发的自动化数据解析管道,实现株高、最大冠幅等关键表型参数提取。最后,从点云质量、重建效率、表型性状解析精度与系统成本等方面进行全面评估。

1 材料与方法

1.1 实验设计

实验在北京市农林科学院的联栋温室 (39°56'N, 116°16'E) 进行。生菜种植区域尺寸为 10 m × 40 m,采用盆栽模式,盆直径为 33 cm。实验种植了结球 (C)、野生 (W)、罗马 (R)、茎用 (S)、奶油 (B) 和散叶 (L) 共 6 种主要类型生菜,每种类型包含 3 个不同品种,总计 18 个生菜品种。每个品种设置 3 个生物学重复,每盆种植 1 株生菜,并进行标准的水肥管理。于 2023 年 2 月 10 日进行数据获取,共采集了 54 盆生菜的表型数据。

基于温室生菜的种植情况,本研究设计了一款专用的 UGV 表型获取平台。该平台旨在实现温室生菜作物条带的三维点云高通量获取,并代替人工进行表型参数无损测量。生菜盆栽的种植布局为:每 2 列盆栽作物构成 1 个条带,盆与盆之间间隔为 30 cm,使得每 2 个条带的总宽度约为 150 cm。UGV 的设计要求能够横跨 2 个条带,使其搭载的传感器能够覆盖 2 个条带的宽度范围,实现单次扫描覆盖更广的区域。具体的温室生菜条带种植布局 (2 条

带)如图 1 所示。



图 1 温室生菜条带种植布局

Fig. 1 Planting layout of lettuce strips in greenhouse

为了满足上述场景覆盖需求,所设计的 UGV 轮间距设定为 180 cm。考虑到生菜植株高度(含盆)通常不超过 100 cm,且传感器需安装在 UGV 底部并预留电动滑轨空间,底盘高度的设计至关重要。过高的底盘会导致重心不稳,增加行驶和转弯时的侧翻风险;而过低的底盘又会使传感器距离作物冠层过近,可能导致传感器视野范围无法完全覆盖作物场景。综合考虑稳定性、传感器视野和电动滑轨的安装空间,将 UGV 底盘设计高度确定为 140 cm。

为全面评估不同传感器三维场景重建与表型解析的性能,利用所设计的 UGV 搭载了 4 种不同传感器:FLIR 型可见光相机、Kinect DK 型深度相机、Livox Avia 型固态激光雷达和 Velodyne VLP-16 型机械式激光雷达。这些传感器在 UGV 上的安装位置如图 2 所示。




图 2 UGV 搭载 4 种传感器及其安装位置

Fig. 2 UGV equipped with four types of sensors and their installation positions

利用该 UGV 表型平台,结合上述 4 种三维表型获取方法,于 2023 年 2 月 10 日进行了一次表型数据采集。此次数据采集选择同一条带有 54 株生菜的典型条带进行。采用 2 类数据采集模式:行进式采集与定点采集。其中,FLIR 型可见光相机、Kinect DK 型深度相机和 Livox Avia 型固态激光雷达采用 UGV 在完整条带行走过程中同步连续获取数据的方式,即行进式采集,而电动滑轨驱动的 Velodyne VLP-16 型激光雷达的表型数据获取方式采用定点采集模式,即 UGV 在每个预设位置短暂停留以完成数据采集。数据采集共分为 2 次 UGV 行走:第 1 次行走同时启用 FLIR 可见光相机、Kinect DK 型深度相机和 Livox Avia 型激光雷达进行连续采集;第 2

次行走则专门用于 Velodyne VLP-16 型激光雷达的定点采集。

2 次行走均保持一致的路径规划与环境条件控制(相同的温室通道与照明设置)。上述设计可在统一场景下获得 4 种传感器的代表性数据。

1.2 基于 UGV 的三维表型数据获取

1.2.1 基于 FLIR 可见光相机的三维表型数据获取

基于 FLIR 可见光(RGB)图像的三维重建是作物表型三维获取的典型方法之一,主要采用运动恢复结构(Structure from motion, SfM)与多视图立体重建(Multi-view stereo, MVS)相结合的技术路线^[22]。该方法通过从多视角、无序的二维图像序列中恢复相机的位姿与场景的三维结构,实现对作物场景的高精度三维重建。整体流程包括 SfM 位姿估计与稀疏重建和 MVS 稠密重建 2 个阶段。

(1)SfM 位姿估计与稀疏重建

特征点提取与匹配:对采集的多视角 RGB 图像进行局部特征点(如 SIFT、ORB、SURF 等)提取,通过特征匹配算法(如 FLANN、KNN)寻找不同图像间的对应点对。为保证后续重建质量,相邻图像需保持足够的视角重叠度,以确保匹配的稳定性与冗余性。

相机姿态估计:基于匹配的特征点,利用捆绑调整(Bundle adjustment, BA)算法对所有图像的相机外参(旋转矩阵与平移向量)及内参(焦距、主点坐标、畸变系数)进行联合优化,从而建立精确的多视图几何约束关系。

稀疏点云生成:在优化后的相机姿态基础上,通过三角测量恢复场景空间点的三维坐标,形成作物的初步稀疏点云。该阶段的结果可勾勒出作物株体结构的基本形态与空间布局,为后续稠密重建提供先验几何框架和相机位姿。

(2)MVS 稠密重建

深度图生成与多视角融合:利用 SfM 获得的相机位姿和稀疏点云作为初始条件,结合多视角图像的视差信息生成高精度深度图。通过立体匹配算法提取不同视角下的深度信息,为稠密点云构建提供可靠输入。

稠密点云融合与优化:将各视角的深度图进行空间融合,生成高密度、连续的作物三维点云。该过程中通常结合空间一致性约束与离群点剔除策略,以抑制误匹配与噪声点,提高点云的精度与完整度。

1.2.2 基于 RGB-D 相机的三维表型数据获取

RGB-D 相机(如 Kinect DK)可同步获取场景的彩色图像(RGB)与深度信息(Depth),在单次采集中同时提供纹理与几何数据,为作物三维表型获

取提供了一种高效、低成本的解决方案。本研究利用 RGB-D 相机开展三维重建,结合特征匹配与迭代最近点 (Iterative closest point, ICP) 算法,实现多帧点云的精确拼接与优化^[10]。

(1)特征点检测与匹配

从连续帧的 RGB 图像中提取局部特征 (如 ORB、SIFT、FAST 等) 及其描述符,通过特征匹配算法 (如 FLANN 或 KNN) 识别相邻帧之间的对应点。为保证匹配的稳定性,图像采集过程中需维持适当帧率与视角重叠,以确保关键特征在多帧图像中得到连续观测。

(2)相机位姿估计

基于匹配到的特征点对,采用几何约束模型 (如基础矩阵、本质矩阵或 PnP 算法) 求解相邻帧的旋转和平移参数,从而估计相机的相对运动轨迹。为提高姿态估计的鲁棒性,通常引入随机抽样一致性 (RANSAC) 算法剔除误匹配点,防止异常值对结果造成干扰。

(3)RGB-D 点云拼接与 ICP 优化

利用估计得到的相机位姿,将相邻帧 RGB-D 数据转换至同一坐标系下,完成初步点云拼接。为进一步减小配准误差并提升几何一致性,采用 ICP 算法进行全局优化。ICP 通过最小化 2 帧点云对应点间的欧氏距离,反复迭代优化位姿变换矩阵,从而实现高精度点云配准与融合。

经过多帧累积与优化后,可获得连续、完整的作物三维点云模型,为后续的结构参数提取与表型分析提供高质量基础数据。

1.2.3 基于固态激光雷达的三维表型数据获取

固态激光雷达作为一种轻量化、高分辨率的三维传感器,能够快速准确地捕获场景的深度信息。相较于传统的机械式 LiDAR,固态 LiDAR (如本研究使用的 Livox Avia) 具有体积小、功耗低、耐用性强且扫描模式灵活等优势。Livox Avia 型固态激光雷达集成了惯性测量单元 (IMU),本研究利用基于激光雷达和惯性传感器 (LiDAR-IMU) 的同步定位与建图 (SLAM) 算法,对温室中的生菜作物进行高精度三维建图,以获取其形态特征。

LiDAR-IMU SLAM 系统通过融合激光雷达点云数据和 IMU 惯导数据,能够显著提升 UGV 在复杂环境 (如光线变化、遮挡、运动模糊) 中的定位精度和地图构建鲁棒性。该系统主要包括前端和后端 2 个关键部分:

(1)前端数据配准与位姿估计:前端模块负责对激光雷达和 IMU 采集的数据进行实时配准,以计算 UGV 在不同时间点的位姿变化。这个过程通常

采用 scan-to-map 或 scan-to-scan 匹配方法。在这些方法中,新采集的激光雷达点云数据会与已构建的局部地图或前一帧点云数据进行匹配,从而估算 UGV 的即时位姿。IMU 数据在此过程中提供高频、短时运动信息,辅助激光雷达点云的去畸变和粗略位姿估计,提高匹配的初始精度和鲁棒性。

(2)后端优化与地图构建:后端模块负责对前端估计的 UGV 位姿和构建的地图进行全局优化。通过使用非线性优化或图优化等算法,该模块能够有效地减少累积定位误差和地图误差,进而得到更加精确和稳定的三维点云地图。后端优化通常会考虑回环检测 (Loop closure detection),以消除长时间运行造成的漂移。

本研究采用 LiDAR-IMU SLAM 算法中的 FAST-LIO2 框架^[26],以实现快速、稳健且高精度的激光雷达导航与三维建图,为生菜作物的高通量表型获取提供可靠的技术保障。

1.2.4 基于机械式激光雷达的三维表型数据获取

机械式激光雷达 (如 Velodyne VLP-16 型) 通过高速旋转扫描实现全方位的激光探测,每秒能够发射上百万个激光脉冲,并通过测量激光返回时间精确计算距离。这种传感器能够生成大范围、高密度的点云数据,特别适合对田间作物的整体结构进行三维重建。

针对传统激光里程计方法在 SLAM 建图过程中易受环境扰动影响,导致定位精度波动较大的问题,本研究采用了一种基于电动滑轨驱动的激光雷达扫描方式。在该设计中,Velodyne VLP-16 型激光雷达被固定在电动滑轨上,并以恒定速度匀速移动。这种策略的核心优势在于,无需复杂地估计每帧之间的相对位姿变换,激光雷达的精确位置由已知的滑轨速度直接确定,极大地简化了数据处理流程并提高了精度。

假设电动滑轨沿某一方向 (例如 z 轴) 以已知速度 v (mm/s) 匀速移动,激光雷达以 15 f/s 的频率进行数据采集。对于正在处理的第 k 帧中的每一个点 P ,其在原始坐标系下的齐次坐标表示为

$$P = [x \quad y \quad z \quad 1]^T \tag{1}$$

其中, x 、 y 、 z 表示点的三维空间坐标,沿着向量 d 平移后的新坐标 P' 可表示为 $P' = P + d$ 。

由滑轨的已知速度 v 和采集时间的的时间间隔推导可得

$$d = [\Delta x \quad \Delta y \quad \Delta z \quad 1]^T \tag{2}$$

从点 P 到点 P' 的变换过程可表示为: $P' = TP$,其中,变换矩阵 T 为

$$T = T(\Delta x, \Delta y, \Delta z) = \begin{bmatrix} 1 & 0 & 0 & \Delta x \\ 0 & 1 & 0 & \Delta y \\ 0 & 0 & 1 & \Delta z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (3)$$

其中, Δx 、 Δy 、 Δz 分别表示沿 3 个方向的平移量, 由于滑轨的运动沿着 z 轴方向, 则每帧之间的平移量计算公式为

$$\begin{cases} \Delta x = 0 \\ \Delta y = 0 \\ \Delta z = \frac{v}{15} \end{cases} \quad (4)$$

则变换矩阵 T 可以简化为

$$T = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}^T \quad (5)$$

通过应用此变换矩阵 T , 将激光雷达在滑轨上匀速移动过程中每秒采集的 15 帧点云数据进行精确平移和拼接。这种“匀速叠加帧”的方法能够克服传统 SLAM 方法的局限性, 高效且准确地形成完整的定点区域密集点云。最终, 将轨道行程内所有帧的平移点云进行叠加拼接, 进而形成连续、高密度的作物三维点云模型, 为后续的表型分析奠定基础。

1.3 表型数据解析

获取高质量的作物点云数据是表型分析的第一步, 而从这些数据中高效、准确地提取关键表型参数则是核心目标。本研究在初步获取每一区块的密集点云数据后, 开发了一套基于 Python 语言、Visual Studio 2019 集成开发环境并利用 Open3D 库函数的自动化处理管道。该管道能够对点云数据进行系统化的后处理, 实现作物的精细化表型估计。具体流程包括: 首先对同一条带内的所有区块点云进行高精度拼接; 随后进行噪声去除、感兴趣区域 (Region of interest, ROI) 提取并精确拟合地面; 接着通过聚类算法实现单株作物的精确分割; 最后, 针对每一株作物提取株高和最大冠幅等关键表型参数。

1.3.1 数据预处理

点云数据预处理是后续表型解析的基础, 旨在提升点云质量, 并为单株分割提供纯净、规整的数据。本研究主要包括统计离群值去噪、ICP 点云配准和地面点云识别 3 个步骤。

(1) 统计离群值点云去噪

激光雷达点云数据在采集过程中, 由于传感器误差、环境干扰或多路径效应, 不可避免地会存在孤立的噪点和离群点。为了提高点云数据的质量和准确性, 本研究采用统计离群值去除 (Statistical outlier removal, SOR) 方法, 该方法基于高斯分布假设识别并去除异常点。

(2) ICP 点云配准

为构建一个完整的条带作物三维点云地图, 需要去噪后的各个区块点云数据按顺序进行高精度拼接。ICP 算法是一种广泛应用于点云对齐的经典算法。它通过迭代优化变换矩阵, 最小化源点云和目标点云之间对应点集的距离, 从而实现 2 组点云的精确配准。

(3) 地面点云识别

在获取拼接后的作物点云数据后, 为了准确提取作物个体并避免地面背景的干扰, 需要识别并去除地面点。本研究采用随机抽样一致性 (Random sample consensus, RANSAC) 算法, 这是一种从包含大量噪声的数据中估计模型参数的迭代算法, 特别适用于平面模型拟合。

1.3.2 单株点云分割

单株作物点云的精确分割是作物个体表型参数提取的前提。本研究结合了欧氏聚类算法和 K-Means 聚类算法, 以应对不同复杂度的生菜群体点云分割需求。

(1) 欧氏聚类

欧氏聚类是一种基于欧氏距离的空间聚类算法, 通过计算点之间的距离将空间上接近的点划分为同一簇。在点云分割中, 它能有效地将距离较近的独立单株作物从群体点云中分离出来。本研究首先使用欧氏聚类算法对温室中的生菜点云群体进行初步分割。

(2) K-Means 聚类

尽管欧氏聚类算法对生菜点云群体取得了较好的初步分割效果, 但在实验中发现, 当生菜冠幅较大, 不同植株叶片间出现交叉重叠时, 欧氏聚类算法难以有效区分。考虑到 K-Means 聚类算法基于多维特征空间进行分割的特点, 本研究在欧氏聚类之后, 进一步使用 K-Means 聚类算法对可能存在交叉重叠的簇进行细化分割。K-Means 聚类能够结合颜色、深度、纹理等特征来度量相似性。

1.3.3 表型参数提取

对作物表型参数的精准获取是智慧农业育种、栽培管理及生长模型构建的关键环节。本研究主要针对生菜的株高和冠幅进行提取, 并详细阐述了其测量原理与算法实现。

1.3.3.1 株高提取方法

株高是反映作物生长状态的重要指标之一。本研究采用点云数据直接计算作物株高, 避免了传统人工测量的误差和效率问题。

通过三维点云数据获取作物每个点的三维坐标信息 (X, Y, Z)。株高定义为作物在垂直方向上的

最高点与最低点之间的距离。考虑到实验中作物通常种植在标准花盆中,需要减去花盆的高度以获得真实的作物株高,如图 3 所示。株高计算公式为

$$h = Z_{\max} - Z_{\min} - h_p \tag{6}$$

式中 h ——生菜株高
 $Z_{\max}$ ——最高点 Z 值
 $Z_{\min}$ ——最低点 Z 值
 h_p ——花盆的高度




图 3 生菜株高测量示意图

Fig. 3 Schematic of height measurement of lettuce plants

1.3.3.2 最大冠幅提取方法

最大冠幅是衡量作物横向生长状况和叶片展开程度的关键参数,对于评估作物群体覆盖度、光能利用率及预测产量具有重要意义。在单株作物的点云数据中,将点云投影至水平平面,寻找其中欧氏距离最大的两点,并将该距离定义为该植株的最大冠幅。本研究采用基于凸包和旋转卡壳算法的方法来精确计算作物的最大冠幅。为了在二维平面上进行冠幅计算,首先将三维作物点云数据投影到 XY 平面。通过将所有点的 Z 坐标值设置为零来实现,从而将三维点云转换为二维平面点集。对降维后的二维点集执行凸包 (Convex hull) 算法,以获取包围所有叶片点集的最小凸多边形轮廓。凸包代表了作物在水平方向上的最大外轮廓边界。在获得的二维凸包上,利用旋转卡壳 (Rotating calipers) 算法来计算凸多边形的最远点对。该算法以其高效性 (时间复杂度为 $O(n)$) 而著称,算法流程为:

- (1) 识别凸多边形在 Y 方向上的 2 个极值点,即 Y 坐标最小的点 P_{ymin} 和 Y 坐标最大的点 P_{ymax} 。这 2 个点作为初始的 1 对对踵点 (antipodal pair)。
- (2) 以 P_{ymin} 和 P_{ymax} 为基准,构造 2 条平行的水平切线,分别与这 2 个点相切。计算两点之间的距离,并将其初始化为当前最大直径。
- (3) 同时逆时针旋转这 2 条切线,直到其中 1 条切线与凸多边形的某条边重合。在旋转过程中,新的对踵点对会不断产生。
- (4) 对于每组新产生的对踵点对,计算它们之间的欧氏距离,并与当前最大直径进行比较。如果新距离更大,则更新最大直径和对应的对踵点对。

(5) 重复步骤 (3) 和步骤 (4),直到切线完成一整周的旋转,再次回到初始的对踵点对直到再次产生对踵点对 (P_{ymin}, P_{ymax})。

(6) 最终输出的最大直径即为该单株作物的最大冠幅,对应的对踵点对定义了冠幅的 2 个端点。

通过上述方法,可以准确、鲁棒地提取出单株作物的最大冠幅,为后续的作物生长分析提供精确的表型数据。图 4 是生菜冠幅测量示意图,图中, L 为作物最大冠幅。




图 4 生菜冠幅测量示意图

Fig. 4 Schematic of lettuce crown measurement

2 结果与分析

2.1 高通量三维表型数据获取

基于 RGB 相机的 SfM - MVS 方法依赖于多视角图像间的特征匹配与几何约束实现三维重建,但其缺点在于缺乏直接的深度测量能力,导致重建结果处于任意尺度空间,即点云比例因子与实际物理尺寸不一致。因此,在实际应用中需引入已知尺寸的参照物进行尺度校准,以将点云转换至真实世界坐标系。与之相比,RGB - D 相机 (以 Kinect - DK 型深度相机为例) 基于飞行时间或结构光原理直接获取像素深度信息,理论上可直接生成具备真实尺度的点云数据,无需额外缩放处理。而 Velodyne VLP - 16 型与 Livox Avia 型激光雷达均基于飞行时间原理,通过精确测量激光信号往返时间直接获取目标的真实距离,因此其点云数据具有比例 1 : 1 的物理尺度精度,无需进行任何尺寸校准。

针对 SfM - MVS 重建结果的尺度不一致性问题,本研究采用标准尺寸参照法进行校准。选用一个 10 cm × 10 cm 的灰色立方体作为参照物,在同一环境条件下分别利用 RGB 相机与深度相机获取其点云数据 (图 5)。通过 CloudCompare 软件对 SfM - MVS 生成的参照物点云进行精确测量,结果显示立方体边长约为 0.33 cm,而实际尺寸为 10 cm,计算得到缩放比例约为 1 : 30。因此,需将 SfM - MVS 生成的点云按约 30 倍比例放大以恢复真实尺度。相比之下,深度相机点云测得的边长接近 10 cm,验证

了其测距结果与实际尺寸的一致性,无需额外校准步骤。




图 5 参照物点云
Fig. 5 Point cloud of reference

经过严格的尺寸校准后,各方法生成的点云均能准确反映作物的真实几何结构。图 6 展示了在相同温室环境条件下,利用 4 种传感器对同一条带生菜获取的点云结果。可以明显观察到,不同传感器在点云密度、噪声水平及叶片表面细节还原能力方面存在显著差异,这为后续表型参数提取及传感器性能对比分析提供了可靠的实验基础。




图 6 4 种传感器获取的温室生菜点云
Fig. 6 Greenhouse lettuce point cloud obtained by four sensors

2.2 三维表型提取精度评估

为系统评估不同传感器在作物三维表型参数提取方面的性能表现,本研究基于提出的生菜条带点云处理流程,分别提取了 4 种传感器获取点云的株高与最大冠幅表型参数,并与人工实测数据进行了线性回归分析,通过计算决定系数(R^2)与均方根误差(RMSE)来量化各方法的测量精度与可靠性。

株高测量结果的线性拟合分析如图 7a 所示。基于 Velodyne VLP-16 型激光雷达与电动滑轨组合的表型系统在株高估算方面表现最为优异, R^2 达到 0.968 8, RMSE 为 1.047 cm,这表明在静态或精

确控制条件下,激光雷达能够实现高精度、高稳定性的株高测量。在模拟田间行进采集的实际应用场景中,基于 FLIR RGB 相机经 SfM-MVS 重建的点云在株高测量精度上居于首位, R^2 为 0.959 1, RMSE 为 1.215 cm,表明在图像质量良好且纹理特征充足的条件下,视觉方法仍然能够实现较高的测量精度。Livox Avia 型激光雷达在行进模式下的株高估算精度次之, R^2 为 0.940 2, RMSE 为 2.294 cm。而 Kinect-DK 型深度相机在此项评估中表现相对较差, R^2 为 0.919 6, RMSE 为 2.435 cm。

Kinect-DK 型深度相机在株高测量表现不佳的原因包括:①叶缘/高曲率区的红外漫反射与半透/高反射材料导致深度在轮廓外扩或回波延迟,顶部极值点被低估或抹平。②顶部幼叶常处于陡峭夹




图 7 4 种传感器获取点云估计的表型参数与人工测量值的线性拟合
Fig. 7 Linear fitting of phenotypic parameters estimated by point clouds and manual measurements for four sensors

角,正视单视点在自遮挡下缺失顶端点,致使最大高度统计偏低。③近距为了抑制饱和与环境红外干扰(自然光/补光),设备可能降低积分时间,提升测量量化噪声。④行进式采集时,姿态变化与深度帧同步偏差会放大地面估计与高度极值的随机误差。

最大冠幅测量结果的线性拟合分析如图 7b 所示。FLIR RGB 相机经 MVS 重建的点云在该参数提取中表现出最高的精度, R^2 达到 0.970 6, RMSE 为 1.826 cm,这可能得益于 MVS 方法在重建叶片边缘与轮廓细节方面的独特优势。Kinect-DK 型深度相机在此项测量中表现次之, R^2 为 0.963 8, RMSE 为 1.719 cm,表明其在获取冠层水平投影信息方面具有一定的技术优势。相比之下,2 款激光雷达在冠幅测量中的精度相对较低,其中 Velodyne VLP-16 型激光雷达+匀速叠加帧拼接方法的 R^2 为 0.958 2, RMSE 为 1.855 cm;而 Livox Avia 型激光雷达结合 SLAM 重建的点云精度最低, R^2 仅为 0.905 1, RMSE 达到 4.626 cm。

Livox Avia 型激光雷达在冠幅测量中精度最低的原因:①行进采集下,若轨迹退化(单向直线/纹理稀疏)或回环约束不足,小幅位姿漂移在水平投影上放大为边界外扩/内缩。②固态雷达的非重复扫描在叶缘处采样稀疏,与斜入射下的低反射回波共同造成边界断裂与冠幅低估。③行进引起的轻微摆动使不同时刻的边界点时空错位,SLAM 融合后形成“锯齿/虚影”,影响最大外接宽度。④冠层复杂结构造成回波能量分散,若前处理采用体素/统计滤波,细薄叶缘更易被当作异常点剔除。

综合株高与冠幅参数的精度评估结果,4 种方法均能在一定程度上替代传统人工测量,用于生菜株高与最大冠幅的有效估算。在实际应用中,具体传感器的选择应结合应用场景对精度、成本与数据处理复杂度的综合要求进行权衡。基于 Velodyne VLP-16 型激光雷达+匀速叠加帧拼接方法在株高测量方面精度最高,而 FLIR 型相机+SfM-MVS 方法与 Kinect DK 型深度相机+ICP 配准方法在冠幅测量方面展现出更强的竞争力。

2.3 综合性能与成本分析

在实际农业应用场景中,除了测量精度外,三维表型获取方案的效率、成本与数据处理能力同样是至关重要的考量因素。本研究从采集效率、硬件成本、点云密度及数据处理时间 4 个维度,对 4 种传感器方案进行了系统比较与分析。

在采集效率方面, Velodyne VLP-16 型激光雷达需要配合电动滑轨进行定点分段采集,单个条带(包含 4 列,每列 54 盆作物)的采集时间约为

16 min, 通量约为 810 株/h。其余 3 种传感器(Livox Avia 型激光雷达、FLIR 型相机、Kinect-DK 型深度相机)均搭载于 UGV 表型平台,以速度 18 cm/s 进行连续行进式采集,单个条带的采集时间仅需约 90 s, 通量高达 8 640 株/h, 约为 Velodyne VLP-16 型激光雷达方案的 5 倍,这充分展现了行进式采集方案在效率方面的显著优势。

在硬件成本方面, Velodyne VLP-16 型激光雷达与滑轨组合的成本最高, 约为 42 000 元; Livox Avia 型激光雷达次之, 为 19 999 元; FLIR 型相机及配套镜头组合为 7 555 元; Kinect-DK 型深度相机的成本最低, 仅为 2 988 元。这一成本分布清晰地反映了激光雷达类传感器普遍较高的硬件成本, 而视觉类与深度相机在成本控制方面具有明显优势。

在点云密度方面, Velodyne VLP-16 型激光雷达获取的点云密度最高, 平均每株作物约包含 38 万个点; Kinect-DK 型深度相机的点云平均每株包含 14 万个点; FLIR 型相机经 MVS 重建的点云平均每株约 9 万个点; Livox Avia 型激光雷达结合 SLAM 重建的点云密度最低, 平均每株仅约 6 万个点。点云密度直接影响了后续数据处理的工作量和计算负担。

在数据处理时间方面, Velodyne VLP-16 型激光雷达获取的点云处理耗时最长, 平均每株需要 12 628 ms; 其余行进式采集传感器的处理时间相对较短, 依次为 Livox Avia 型激光雷达(4 652 ms/株)、FLIR 型相机(2 990 ms/株)和 Kinect-DK 型深度相机(1 994 ms/株)。数据分析表明, 点云密度与处理时间之间存在明显的正相关关系, 同时处理效率还受到算法复杂度与点云组织形式等多种因素的影响。4 种传感器获取方式的性能与成本对比见表 1。

表 1 4 种传感器获取方式的性能及成本对比

Tab.1 Performance and cost comparison of four sensor acquisition methods

对比项	Velodyne VLP-16 型 激光雷达	Livox Avia 型激 光雷达	FLIR 型 相机	Kinect- DK 型深 度相机
通量/(株·h ⁻¹)	810	8 640	8 640	8 640
成本/元	19 999	9 999	7 555	2 988
点云密度/(点·株 ⁻¹)	380 000	140 000	90 000	6 000
管道化处理时间/ (ms·株 ⁻¹)	12 628	4 652	2 990	1 994

2.4 静态采集与行进式采集对精度的影响

为区分采集模式对精度的影响并确保组间对照公平性, 本文将行进式采集(FLIR 型相机、Kinect DK 型深度相机、Livox Avia 型激光雷达同步连续获取)与定点采集(Velodyne VLP-16 型激光雷达逐

站位停留扫描)分开实施,2 次行走的路径、环境与控制参数保持一致。行进式采集能够提供更高的视角多样性与通量,但在 RGB 易受运动模糊与视差不一致影响、LiDAR 需要去畸与严格时钟同步;定点采集则显著降低运动畸变与姿态扰动,有利于极值几何(如株高)稳定估计。结合 2.2 节的精度结果可见,Velodyne VLP-16 型激光雷达定点采集在株高上表现最佳,而行进式多视角的 FLIR(SfM-MVS)与 Kinect-DK 型深度相机在冠幅等水平轮廓指标上更具优势;Livox Avia 型激光雷达行进式采集的冠幅精度受位姿累积误差与边缘稀疏采样影响较大。

3 结论

(1)本研究系统评估了 4 种高通量三维表型获取方式(可见光(FLIR 型相机)+SfM-MVS、RGB-D(Kinect DK 型深度相机)+ICP 配准、固态 LiDAR(Livox Avia 型)+LIO、机械式 LiDAR(Velodyne VLP-16 型)+匀速叠加帧拼接)在温室生菜表型获取中的综合性能。

(2)在株高测量方面,Velodyne VLP-16 型激光雷达与滑轨组合的测量精度最高,适用于对精度要求极高的科研场景;在行进式采集方案中,FLIR 型相机(SfM-MVS)的株高测量精度最优。在最大冠幅测量方面,FLIR 型相机(SfM-MVS)表现最佳,略优于 Kinect-DK 型深度相机。值得注意的是,激光雷达类传感器在行进模式下的冠幅测量精度普遍低于视觉类传感器,其中 Livox Avia 型激光雷达结合 SLAM 算法的精度最低,这与 SLAM 算法在复杂作物环境中的累积误差以及激光点云在叶片边缘识别方面的局限性密切相关。

(3)在采集效率方面,Velodyne VLP-16 型激光雷达方案受限于定点采集模式,其通量(810 株/h)显著低于行进式方案(8 640 株/h)。在硬件成本方面,Velodyne VLP-16 型激光雷达方案成本最高,Kinect-DK 型深度相机成本最低,为预算有限的用户提供了可行的选择。在点云密度方面,Velodyne VLP-16 型激光雷达最高,Livox Avia 型激光雷达最低,而高点云密度必然伴随更长的数据处理时间。

参 考 文 献

[1] DHONDT S, WUYTS N, INZÉ D. Cell to whole-plant phenotyping: the best is yet to come[J]. Trends in Plant Science, 2013,18(8):428-439.

[2] WATT M, FIORANI F, USADEL B, et al. Phenotyping: new windows into the plant for breeders[J]. Annual Review of Plant Biology, 2020,71(1):689-712.

[3] 赵春江. 植物表型组学大数据及其研究进展[J]. 农业大数据学报, 2019,1(2):5-18.
ZHAO Chunjiang. Big data of plant phenomics and its research progress[J]. Journal of Agricultural Big Data, 2019,1(2):5-18. (in Chinese)

[4] 温维亮,郭新宇,张颖,等. 作物表型组大数据技术及装备发展研究[J]. 中国工程科学, 2023,25(4):227-238.
WHEN Weiliang, GUO Xinyu, ZHANG Ying, et al. Technology and equipment of big data on crop phenomics[J]. Strategic Study of CAE,2023,25(4):227-238. (in Chinese)

[5] GROBKINSKY D K, SVENSGAARD J, CHRISTENSEN S, et al. Plant phenomics and the need for physiological phenotyping across scales to narrow the genotype-to-phenotype knowledge gap[J]. Journal of Experimental Botany, 2015,66(18):5429-5440.

[6] KIM S, SOLEHATI N, CHOI I, et al. Data management for plant phenomics[J]. Journal of Plant Biology, 2017,60(4):285-297.

[7] 李英伦. 基于多源数据和深度学习的玉米形态结构表型解析方法研究[D]. 长春:吉林农业大学, 2021.
LI Yinglun. Morphological and structural phenotypes extraction of maize using multi-source data and deep learning[D]. Changchun: Jilin Agricultural University, 2021. (in Chinese)

[8] LATI R N, FILIN S, EIZENBERG H. Estimation of plants' growth parameters via image-based reconstruction of their three-dimensional shape[J]. Agronomy Journal, 2013,105(1):191-198.

[9] YANG S, ZHENG L, CHEN X, et al. Transfer learning from synthetic in-vitro soybean pods dataset for in-situ segmentation of on-branch soybean pods[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition,2022:1666-1675.

[10] 杨斯,高万林,米家奇,等. 基于 RGB-D 相机的蔬菜苗群体株高测量方法[J]. 农业机械学报, 2019,50(增刊1):128-135.
YANG Si, GAO Wanlin, MI Jiaqi, et al. Method for measurement of vegetable seedlings height based on RGB-D camera[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019,50(Supp.1):128-135. (in Chinese)

[11] YANG S, ZHENG L, GAO W, et al. An efficient processing approach for colored point cloud-based high-throughput seedling phenotyping[J]. Remote Sensing, 2020,12(10):1540.

[12] JIN S, LI D, YUN T, et al. Deep learning for three-dimensional (3D) plant phenomics[J]. Plant Phenomics, 2025,7(4):

100107.

[13] ZHAO C, ZHANG Y, DU J, et al. Crop phenomics: current status and perspectives[J]. *Frontiers in Plant Science*, 2019, 10:714.

[14] MCCARTHY C L, HANCOCK N H, RAINE S R. Applied machine vision of plants: a review with implications for field deployment in automated farming operations[J]. *Intelligent Service Robotics*, 2010,3(4):209 – 217.

[15] JIN S, SU Y, WU F, et al. Stem-leaf segmentation and phenotypic trait extraction of individual maize using terrestrial LiDAR data[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018,57(3):1336 – 1346.

[16] CAI S, GOU W, WEN W, et al. Design and development of a low-cost UGV 3D phenotyping platform with integrated LiDAR and electric slide rail[J]. *Plants*, 2023,12(3):483.

[17] PIRE T, MUJICA M, CIVERA J, et al. The Rosario dataset: multisensor data for localization and mapping in agricultural environments[J]. *The International Journal of Robotics Research*, 2019,38(6):633 – 641.

[18] TENG H, WANG Y, SONG X, et al. Multimodal dataset for localization, mapping and crop monitoring in citrus tree farms [C]//*International Symposium on Visual Computing*. Cham: Springer Nature Switzerland, 2023: 571 – 582.

[19] EITEL J U, VIERLING L A, LONG D S, et al. Early season remote sensing of wheat nitrogen status using a green scanning laser[J]. *Agricultural and Forest Meteorology*, 2011,151(10):1338 – 1345.

[20] NGUYEN P, BADENHORST P E, SHI F, et al. Design of an unmanned ground vehicle and LiDAR pipeline for the high-throughput phenotyping of biomass in perennial ryegrass[J]. *Remote Sensing*, 2020,13(1):20.

[21] SANZ R, ROSELL J R, LLORENS J, et al. Relationship between tree row LiDAR-volume and leaf area density for fruit orchards and vineyards obtained with a LiDAR 3D dynamic measurement system[J]. *Agricultural and Forest Meteorology*, 2013,171:153 – 162.

[22] SMITT C, HALSTEAD M, ZIMMER P, et al. PAg – NeRF: towards fast and efficient end-to-end panoptic 3D representations for agricultural robotics[J]. *IEEE Robotics and Automation Letters*, 2023,9(1):907 – 914.

[23] YUAN J, HONG J, SATTAR J, et al. ROW – SLAM: under-canopy cornfield semantic SLAM [C]//*2022 International Conference on Robotics and Automation (ICRA)*. IEEE, 2022: 2244 – 2250.

[24] KIM K, DEB A, CAPPELLERI D J. P – AgSLAM: in-row and under-canopy SLAM for agricultural monitoring in cornfields [J]. *IEEE Robotics and Automation Letters*, 2024,9(6):4982 – 4989.

[25] PAN Y, HU K, LIU T, et al. Pheno-robot: an auto-digital modelling system for in-situ phenotyping in the field[J]. *arXiv Preprint*, arXiv:2402.09685, 2024.

[26] XU W, CAI Y, HE D, et al. Fast – lio2: fast direct lidar-inertial odometry[J]. *IEEE Transactions on Robotics*, 2022, 38(4):2053 – 2073.