doi:10.6041/j.issn.1000-1298.2025.06.047

基于多维成像特征 +UGV 的设施蔬菜表型参数检测方法

张晓东[1]　蔡宗耀[1]　胡　炼[2]　毛罕平[1]　李铁柱[1]　张怡雪[1]
(1. 江苏大学农业工程学院, 镇江 212013; 2. 华南农业大学工程学院, 广州 510642)

摘要: 为解决作物表型参数获取困难且精度不高的问题,以设施生菜为研究对象,提出了一套高精度、低成本的生菜表型参数获取方法。采用具备自动导航、多模态和多视场成像功能的无人地面车(Unmanned ground vehicle, UGV),进行作物生长信息自动巡航采集。本文设计的表型分析管道加入了随机下采样算法,以增强作物点云数据的处理效率,并结合图像分割、聚类等算法提取了生菜高度、最大宽度、植被指数和纹理指数等多维表型特征。此外,将获取的多维成像特征参数与生菜地上生物量实测值进行了皮尔逊(Pearson)相关性分析,筛选出对地上生物量预测最敏感的 4 个特征变量,利用误差反向传播算法(Back propagation algorithm, BP)分别构建了单一特征和多维特征组合的生物量估测模型。研究结果表明:本文设计的表型分析管道处理 5 000 下采样点云单帧数据平均耗时为 0.41 s,生菜高度、最大宽度估测的 R^2 分别为 0.79、0.77,MAPE 分别为 4.94%、5.02%。相较于其它生物量估测模型,融合了 4 个特征变量的估测模型(HWVD)最优,R^2、RMSE 和 MAPE 分别为 0.82、4.03 g、6.04%。本研究为面向现场的作物表型信息快速、准确、无损检测提供了一种有效的方法。

关键词: 生菜; 点云下采样; 地上生物量; 作物表型; 多维成像特征
中图分类号: S24; TP391.4　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)06-0509-09　　**OSID**:

Phenotypic Detection of Facility Vegetables Based on Multi-dimensional Imaging Features and UGV

ZHANG Xiaodong[1]　CAI Zongyao[1]　HU Lian[2]　MAO Hanping[1]　LI Tiezhu[1]　ZHANG Yixue[1]
(1. *College of Agricultural Engineering*, *Jiangsu University*, *Zhenjiang* 212013, *China*
2. *College of Engineering*, *South China Agricultural University*, *Guangzhou* 510642, *China*)

Abstract: Aiming to address the challenges of low accuracy and inefficiency in phenotypic data acquisition, a high-precision, low-cost method for lettuce phenotypic parameter extraction in controlled environments was developed. An unmanned ground vehicle (UGV) equipped with autonomous navigation, multi-modal sensing, and multi-view imaging was deployed for automated in-situ data collection. A phenotype analysis pipeline incorporating a random under-sampling algorithm was designed to enhance point cloud processing efficiency. Image segmentation and clustering algorithms were implemented to extract multi-dimensional features, including plant height, maximum width, vegetation indices, and texture indices. Pearson correlation analysis between these imaging features and fresh biomass measurements identified four key variables highly correlated with biomass prediction. Single-feature and multi-feature biomass estimation models were constructed by using a back propagation algorithm. Results showed that the phenotyping pipeline designed took an average of 0.41 s to process a single frame of data from a 5 000 downsampled point cloud. The estimation models for lettuce height and maximum width achieved R^2 values of 0.79 and 0.77, with mean absolute percentage errors (MAPE) of 4.94% and 5.02%, respectively. Compared with other biomass estimation models, the hybrid model incorporating four feature variables (HWVD) showed optimal performance, achieving an R^2 of 0.82, RMSE of 4.03 g, and MAPE of 6.04%. This method can provide a rapid, accurate, and non-destructive solution for field-based phenotyping and serve as a robust framework for investigating additional phenotypic traits.

Key words: lettuce; point cloud sampling; aboveground biomass; crop phenotype; multi-dimensional imaging characteristics

收稿日期: 2025-02-27　修回日期: 2025-03-19
基金项目: 江苏大学农业装备学部项目(NZXB20210106)和国家重点研发计划项目(2022YFD2002302)
作者简介: 张晓东(1970—),男,教授,博士生导师,主要从事作物表型检测研究,E-mail: zxd700227@126.com
通信作者: 张怡雪(1996—),女,实验师,主要从事作物表型检测研究,E-mail: 926322968@qq.com

0 引言

植物的表型参数是指作物在生长过程中所反映的信息,包括作物不同器官的颜色、纹理、尺寸和形状[1]。这些表型参数能够反映植物的生长水平和健康状况,有助于生产者进行管理和决策[2],可以为“菜篮子”工程提供保障,助力蔬菜产业发展。传统的人工作物表型测量方法效率低、耗时、劳动强度高、主观性强,且难以快速获取海量数据[3]。与传统表型测量方法相比,机器视觉技术具有非破坏性、高效率、可连续工作的特点[4]。与 2D 成像相比,3D 成像技术可以获得作物的点云,由此可以精确地计算植物生长期间的空间形态特征[5]。配备传感器的无人车(UGV)结合机器视觉技术构建的作物表型巡检平台,可以高通量采集作物表型数据,实现作物生长状态的高效、准确、无损监测[6]。

目前很多学者已经将机器视觉方法应用于作物表型信息的获取研究[7-9]。多维成像特征数据融合可以获得比单一成像特征数据更高的表型评估精度[10],因为植株的植被指数、纹理指数和形态结构信息,提供了有助于评估植物表型的独特和互补的信息[11-13]。

地上生物量(Above-ground biomass,AGB)是评估作物生长和产量的关键参数。监测 AGB 可以使农民做出正确的决策,例如在早期阶段实施优化施肥和调整灌溉计划,从而促进作物的生长和发育[14]。目前,大多数研究主要基于单一成像特征参数构建 AGB 估测模型[15],而对融合颜色、纹理、形态等多维成像特征的生菜 AGB 估测研究较为有限。多维特征融合对产量表型估测精度的影响效应及其在模型优化中的潜力尚未得到充分探索和深入研究。

近年来,基于深度相机(RGB-D)的作物 3D 表型分析方法被提出。RGB-D 传感器,如奥比中光和英特尔 Realsense 相机,由于其低成本和易于集成而得到广泛应用[16]。除了 3 个颜色通道(红、绿、蓝),RGB-D 传感器还提供了深度通道(D),结合颜色和深度图像可以构建作物彩色点云,可以同时获取作物的形态特征和植被、纹理指数信息。

作物点云数据量至少有上百万点,规模大、处理时间长[17-18]。利用下采样的方法可以减小点云数据规模,提高点云数据处理效率,同时保留点云的总体形态和特性,可以进一步提高原位检测效率。

成像设备与移动式或固定式检测平台结合使用,将大大提高作物表型信息采集的效率和成本效益。现有的轨道式[19]、龙门式[20]、成像室式[21]设施表型平台具有自动化、高通量、高精度的特点,但只适用于固定检测区域的作物信息采集,而且在不同温室之间进行跨区巡航检测需要重复布置表型平台和成像设备,其建设成本很高。无人车式[22]表型平台可以实现跨区巡航检测,极大地降低了表型平台和成像设备的建设成本。因此,无人车式表型平台更加适合非结构化温室环境的跨区巡航检测的需求。

本文将搭建一个 UGV 表型检测平台,研究基于超绿算法(Excess green index algorithm,ExG)、随机下采样算法(Random under-sampling algorithm)、基于密度的聚类算法(Density-based spatial clustering of applications with noise,DBSCAN)和灰度共生矩阵(Grey level co-occurrence matrix,GLCM)的生菜多维成像特征参数提取方法,并设计一个表型数据分析管道。利用皮尔逊相关性筛选出对地上生物量预测最敏感的预测变量,基于多维特征参数和误差反向传播算法(Back propagation algorithm,BP)建立生菜地上生物量的预测模型。

1 材料与方法

1.1 试验材料和数据采集

于 2024 年 11 月在镇江市港华紫荆农庄的温室内进行试验。该温室内生菜采用水培的方式种植,生菜品种为意大利生菜。在生菜 5~6 片真叶时于 2024 年 11 月下旬从育苗盘移栽到水培区域,在该区域生长 28 d。在第 29 天开始进行测量试验,使用无人车表型平台采集设施生菜图像数据,随后对所选生菜进行破坏性测量以确定其地上生物量,平台采集和破坏性测量在同一天进行。对采集图像后的生菜,使用直尺人工测量生菜最高点到水培泡沫板平面的距离作为株高,用天平(精度 0.01 g)称量生菜去除根部后的质量作为地上生物量,共采集 160 株生菜样本。

如图 1 所示,本文所研制的无人车表型平台主要由感知模块(深度相机)、位姿调节模块和自主导航模块组成。基于模块化设计理念,本感知模块支持多源传感器类型的灵活扩展,可适配不同应用场景下的数据采集需求。无人车表型平台搭载的深度相机为适应不同株高和不同视场的信息采集,通过由升降立柱和电控云台组成的位姿调节模块实现深度相机垂直方向的升降和俯仰调节。为适应非结构化的设施环境,车体长度设计为 774 mm,底盘宽度设计为 600 mm。表型平台驱动形式为后轮驱动,采用阿克曼转向,可以提高平台整体强度,使车身过弯姿态更加顺畅稳定。除此之外,表型平台还采用橡

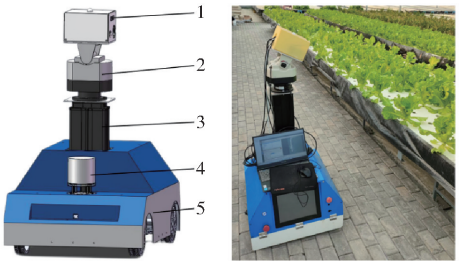

图 1　无人车表型平台结构图和实物图

Fig. 1　Unmanned vehicle phenotype platform

1. 深度相机　2. 电控云台　3. 升降立柱　4. 三维激光雷达　5. 底盘

胶轮与共轴摆式悬挂的复合设计，使得平台具有较强的地面适应性以及更强的负载能力。无人车表型平台通过对三维激光雷达采集的三维点云数据进行滤波并融合成二维点云数据，然后利用 Gmapping SLAM 算法构建基于点云数据的温室环境地图，并通过自适应蒙特卡罗定位算法实现在未知环境中的定位。表型平台的全局路径规划采用迪杰斯特拉算法，局部路径规划采用时间弹性带算法。最后，表型平台将上述信息集成到机器人开发平台（Robot operating system，ROS）提供的可视化工具中，并利用多目标导航设置实现了无人车在温室中的自主导航。

使用无人车表型平台自动采集生菜图像，平台最高速度为 0.5 m/s。利用 Python、OpenCV 和 Scikit - learn 开发了生菜表型分析管道，该管道能够捕获彩色图像和深度图像。奥比中光 336L 型深度相机的最小工作距离为 0.25 m，在摄像头 2 m 范围内可获得良好的深度图像。为了确保深度图像的品质，以创建精确的 3D 点云，相机与生菜的距离在 1.1 m 以内。传感器 X 轴的正方向与平台运动的方向相反。在数据采集过程中，平台以设定的 0.2 m/s 的速度沿着作物行移动。深度图像和 RGB 图像均自动采集，分辨率均设置为 1 280 像素 × 800 像素，频率为 5 Hz。移动平台可配备便携式计算机，其连接到奥比中光 336L 型深度相机，并控制深度相机连续采集和存储深度图像、彩色图像。

1.2　点云处理与表型估计

利用 Python 语言、PyCharm 2023 IDE 和表型分析管道对 RGB 图和深度图重构的点云进行后处理和作物表型估计。如图 2 所示，首先对作物带中 UGV 获取的 RGB 图像使用超绿算法进行灰度处理，接着进行线性归一化并转换为 8 位图像，然后利用大津法（Otsu's method，OTSU）和开运算制作掩膜，将掩膜与 RGB 原图按位与计算去除背景噪声，然后基于深度图 Z 轴距离信息（Z 大于 1.1 m）分割单行作物，利用处理后的 RGB 图与深度图进行点云重构，生成彩色点云。然后利用随机下采样和聚类算法对单株作物进行分割，提取出单株作物的株高、最大宽度和植被指数特征，对分割后的 RGB 图进行灰度化处理，利用灰度共生矩阵法提取出纹理指数特征。将提取的多维成像特征参数导入基于 BP 神经网络算法构建的地上生物量估测模型，预测出生菜生物量。在采集数据时，深度相机镜头表面到前两排生菜间中点的距离在 1.1 m 内，故 Z 轴距离设置为 1.1 m。

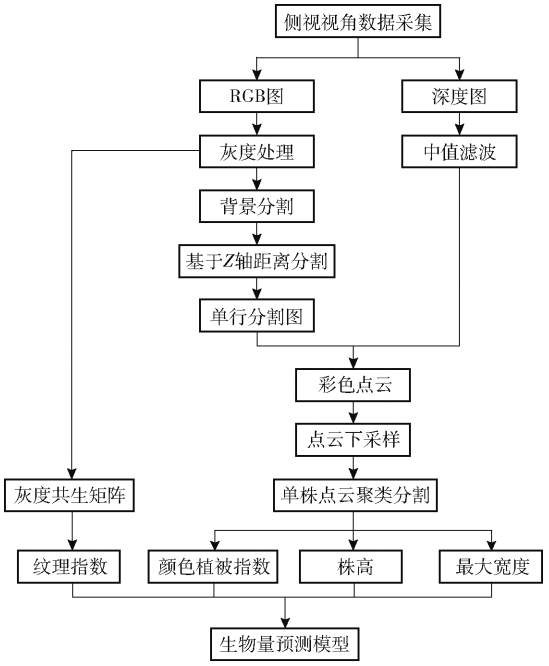

图 2　表型分析管道技术流程图

Fig. 2　Phenotypic analysis pipeline technology flowchart

1.2.1　三维点云重构

由于彩色图像中的透视关系，每个像素在与目标不同的距离时显示不同的缩放比例。奥比中光 336L 型深度相机（RGB - D）可以同时获取 RGB 图像和深度图像，RGB - D 图像中的 RGB 图像提供了像素坐标系下的 (x,y) 坐标，而深度图直接提供了相机坐标系下的 Z 坐标，深度相机的 SDK 中提供了深度图像和彩色图像的内部参考旋转矩阵 $\boldsymbol{C}$，其中 f_x、f_y、c_x、c_y 分别为 645.193、645.193、643.682、347.782 像素。这里，使用公式通过平移和旋转使深度图像的空间坐标与彩色图像的同一点空间坐标对齐，重构三维彩色点云（图 3）。其计算公式为

$$\frac{d_z}{s}\begin{bmatrix}u\\v\\1\end{bmatrix}=\boldsymbol{C}\left(\boldsymbol{R}\begin{bmatrix}x\\y\\z\end{bmatrix}+\boldsymbol{t}\right) \tag{1}$$

其中

$$x=(u-c_x)z/f_x \tag{2}$$

$$y=(v-c_y)z/f_y \tag{3}$$

$$z=d_z/s \tag{4}$$

式中　d_z——深度图中存储的深度，mm

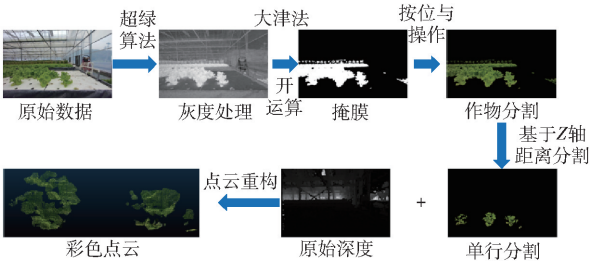

图 3 点云重构过程

Fig. 3 Point cloud reconstruction process

s——深度图缩放因子

(u,v)——图像坐标系下任意点坐标,像素

$\boldsymbol{R}$——深度相机旋转矩阵

$\boldsymbol{t}$——深度相机平移矩阵

(x,y,z)——世界坐标系下三维坐标

f_x、f_y、c_x、c_y——深度相机内参,像素

因为是单幅点云,336L 型深度相机没有旋转和平移。所以,把 $\boldsymbol{R}$ 设成单位矩阵 $\boldsymbol{I}$,$\boldsymbol{t}$ 设成零矩阵,s 为 1 000。

1.2.2 点云下采样

通过点云下采样的方法,可以减小点云数据规模,提高点云数据处理效率,同时保留点云的总体形态和特性。图 4 为不同数量点云随机下采样形式。

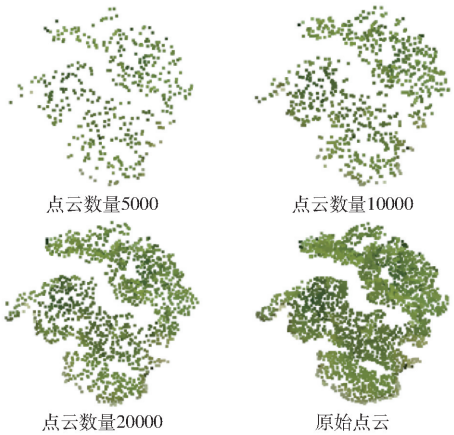

图 4 不同下采样数量的生菜点云

Fig. 4 Lettuce point clouds with different downsampling numbers

采用随机下采样方法对点云数据进行稀疏化处理,从原始点云数据中随机选择一部分点,形成一个数量较少但具有代表性的子集。原始点云数据量为 40 000 左右,点云随机下采样合适比例通常为 10% ~ 50%。

1.2.3 单株分割

单株作物点云的分割使用 DBSCAN 聚类算法,将彼此接近的点分组成一个类别(图 5)。假设点云 D 中有 n 个点,对于点云 D 中的任意点 p,邻域半径为 r,其计算公式为

$$N_r = \{q \in D \mid d_{(p,q)} \leqslant r\} \tag{5}$$

$$|N_r| \geqslant M \tag{6}$$

式中 $d_{(p,q)}$——生菜彩色点云数据中任意两点之间距离,mm

N_r——以 p 为中心点,在邻域半径为 r 的范围内生菜彩色点云数量

M——在邻域半径为 r 的范围内生菜彩色点云数量最小值

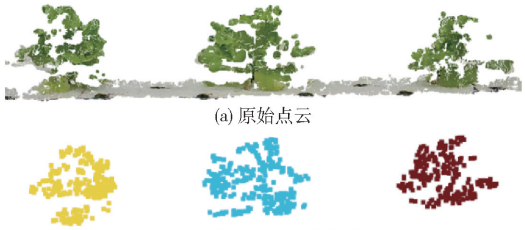

图 5 作物点云聚类单株分割

Fig. 5 Crop point cloud clustering single plant segmentation

1.2.4 作物侧视高度和最大宽度提取

由于无人车表型平台采集的是作物侧视方向的点云数据,其高度和宽度信息分别体现在 Y 轴和 X 轴上。因此,计算单株点云在垂直方向上进行投影。然后求作物最高点 $y_{\max}$ 与最低点 $y_{\min}$ 之差即可得到作物高度 S_h,求作物右侧最远点 $x_{\max}$ 与左侧最远点 $x_{\min}$ 之差即可得到作物最大宽度 S_w(图 6)

$$S_h = y_{\max} - y_{\min} \tag{7}$$

$$S_w = x_{\max} - x_{\min} \tag{8}$$

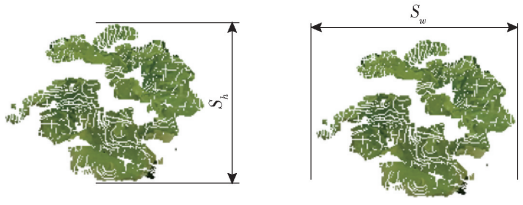

图 6 单株作物高度与最大宽度提取

Fig. 6 Extraction of crop height and maximum width per plant

1.2.5 点云植被指数计算

本研究从彩色点云图像中提取 6 个植被指数,分别为:超绿指数(EXG)[23]、归一化差异指数(NGRDI)[23]、超绿超红差分指数(EXGR)[23]、绿叶植被指数(GLI)[23]、可见光大气阻抗植被指数(VARI)[24]、三角绿度指数(TGI)[24]。

1.3 图像纹理指数的计算

剔除生菜阴影和环境背景后的 RGB 图像用于图像纹理指数计算,本文使用灰度共生矩阵(GLCM)从 RGB 图像中提取 6 个纹理指数,包括角二阶矩(Angular second moment, ASM)[25]、协同性(Homogeneity)[23]、对比度(Contrast)[23]、相异性(Dissimilarity)[23]、熵(Entropy)[23]、相关性(Correlation)[23]。选择 4 个计算方向(0°、45°、90°、135°),像素距离和灰度级数分别为 1、256。使用超

绿算法计算灰度图像，公式为

$$G_{gray} = 2G - R - B \tag{9}$$

式中　R、G、B——RGB 图像红色、绿色、蓝色分量

G_{gray}——图像灰度

1.4　建模校准和验证

BP 算法能够实现从输入到输出的复杂非线性映射，并且具有较好的泛化能力。本研究使用 BP 算法和五折交叉验证构建回归模型，该机器学习算法基于 Python 编程实现。模型在硬件环境为 Intel Core i5 - 11400H CPU，NVIDIA GeForce RTX 4060 Laptop GPU，软件环境为 Windows 11 的计算机上训练。学习率和迭代次数分别设为 0.001、400，训练采用 Adam 优化器和 L1 损失函数。试验共采集到 160 个样本，其中训练集样本数为 120，验证集样本数为 40。

使用决定系数（R^2）、均方根误差（RMSE）、平均绝对误差（MAE）和平均绝对百分比误差（MAPE）评估地上生物量模型估测的准确性。较高的 R^2 和较低的 RMSE、MAE、MAPE 表明模型在估计地上生物量时具有较高的准确度和精密度。

2　结果

2.1　不同下采样点云的作物侧视高度和最大宽度提取

2.1.1　作物侧视高度提取

通过无人车（UGV）表型平台获得生菜点云数据，利用生菜表型分析管道提取生菜的株高和最大冠宽，并从采集的样本数据中随机选取 40 个样本进行验证。使用不同数量下采样点云建立与生菜高度的估计模型，并与手工测量的高度进行比较（图 7）。结果表明，5 000、10 000、20 000 下采样点云和原始点云生菜高度估计值 R^2 分别为 0.79、0.80、0.81、0.80，MAE 分别为 0.82、0.74、0.68、0.65 cm，RMSE 分别为 0.99、0.87、0.82、0.79 cm。表 1 总结了不同数量下采样点云的生菜高度估计值的 MAPE，其中 HA、HB、HC、HD 分别表示 5 000 下采样点云、10 000 下采样点云、20 000 下采样点云、原始点云生菜高度，MAPE 分别为 4.94%、4.43%、4.10%、3.88%。估计生菜高度的精度从高到低排序为 HD、HC、HB、HA，并且当点云数据量下采样到 5 000 后，与原始点云相比 MAPE 增加 1.06 个百分点。结果表明，随着单株生菜点云数量下降，其高度精度也随之下降。

2.1.2　作物侧视最大宽度提取

从采集的样本数据中随机选取 40 个样本，使用不同数量下采样点云建立与生菜最大宽度的估计模型，并与手工测量的最大宽度进行比较（图 8）。结果表明，5 000、10 000、20 000 下采样点云和原始点云的生菜最大宽度估计值 R^2 分别为 0.77、0.79、0.79、0.79，MAE 分别为 1.11、1.03、1.00、0.99 cm，

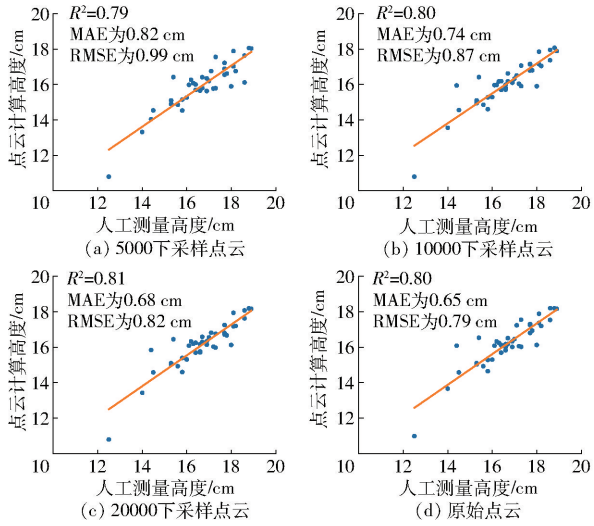

图 7　人工测量和点云计算高度线性拟合

Fig. 7　Manual measurement and point cloud calculation height linear fitting

表 1　生菜高度、最大宽度的平均绝对百分比误差

Tab. 1　MAPE of lettuce height and maximum width

参数	数据类型	MAPE/%
高度	HA	4.94
	HB	4.43
	HC	4.10
	HD	3.88
最大宽度	WA	5.02
	WB	4.66
	WC	4.50
	WD	4.49

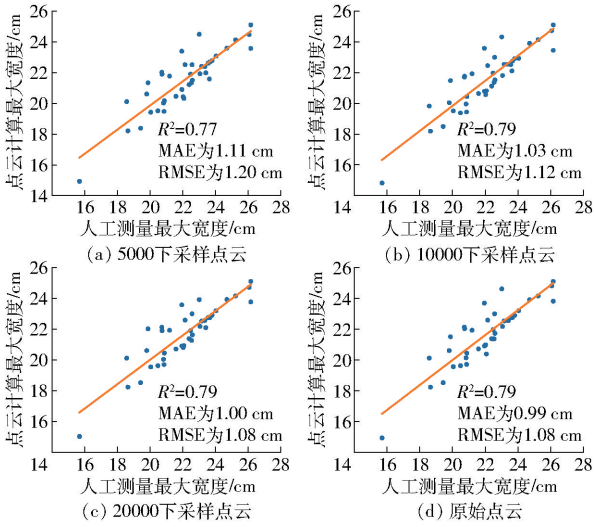

图 8　人工测量和点云计算最大宽度线性拟合

Fig. 8　Manual measurement and point cloud calculation maximum width linear fitting

RMSE 分别为 1.20、1.12、1.08、1.08 cm。

表 1 中总结了不同数量下采样点云的生菜最大宽度估计值的 MAPE，其中 WA、WB、WC、WD 分别表示 5 000 下采样点云、10 000 下采样点云、20 000 下采样点云、原始点云生菜最大宽度，MAPE 分别为 5.02%、4.66%、4.50%、4.49%。估计生菜最大宽度的精度从高到低排序为 WD、WC、WB、WA，并且当点云数据量下采样到 5 000 后，与原始点云相比 MAPE 增加 0.53 个百分点。结果表明，随着单株生菜点云数量下降，其最大宽度精度也随之下降。

2.2 不同数量下采样点云处理时间

随机选取 9 个样本，其使用不同数量下采样点云数据处理时间及其对比如图 9 所示。结果表明，5 000 下采样点云、10 000 下采样点云、20 000 下采样点云、原始点云单帧数据平均处理时间分别为 0.41、0.60、1.41、3.14 s。根据数据平均处理时间排序为原始点云、20 000 下采样点云、10 000 下采样点云、5 000 下采样点云。因此，当下采样点云数据量到 5 000 后，单帧数据平均处理时间达到 0.5 s 以内，相比原始点云，处理时间降低 2.73 s，生菜表型处理效率得到了显著提高。

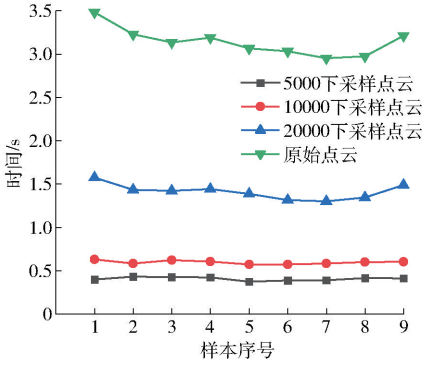

图 9 不同数量下采样点云的数据处理时间

Fig. 9 Data processing time of different numbers of down-sampled point clouds

2.3 多维特征参数与地上生物量相关性分析

2.3.1 生菜高度、最大宽度与地上生物量相关性分析

将手工测量以及不同数量下采样点云提取的生菜高度、最大宽度与测量的地上生物量进行 Pearson 相关性分析。如图 10 所示，HM、WM、Weight 分别代表手工测量的生菜高度、最大宽度、地上生物量，结果表明，不同的生菜高度、最大宽度与地上生物量的相关性变化不大。WB 与地上生物量的相关系数最高，为 0.71。HC 与地上生物量的相关系数最低，为 0.60。其他特征参数与地上生物量相关系数为 0.61～0.70。HM 与 HA、HB、HC、HD 的相关性很高，相关系数分别为 0.89、0.89、0.90、0.89，并且 HA 与 HB、HC、HD 的相关系数分别达到 0.94、0.95、0.95。WM 与 WA、WB、WC、WD 的相关性也很高，相关系数分别为 0.88、0.89、0.89、0.89，并且 WA 与 WB、WC、WD 的相关系数分别达到 0.99、0.99、0.99。不同数量下采样点云提取的生菜高度、最大宽度与手工测量值相关性变化不大。因此，在相关性变化不大的情况下，为提高生菜表型检测效率，选择下采样点云数据量到 5 000 后提取的生菜高度（HA）和最大宽度（WA）用于后续地上生物量估计建模。

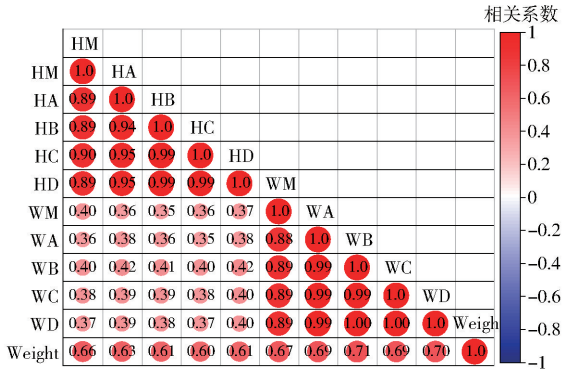

图 10 不同高度、最大宽度与地上生物量的相关性

Fig. 10 Correlation between different height, maximum width and aboveground biomass

2.3.2 植被、纹理指数与地上生物量相关性分析

对 6 种植被指数、纹理指数与测量的地上生物量进行 Pearson 相关性分析，如图 11 所示。结果表明，不同的纹理指数与地上生物量的相关性变化较大，VARI 与地上生物量的相关性最高，相关系数为 0.33。TGI 与地上生物量的相关性最低，相关系数为 −0.062。NGRDI 与 VARI 相关性极高，相关系数为 0.99，属于极端共线性。不同的纹理指数与地上生物量的相关性变化很大。Dissimilarity 与地上生物量的相关性最高，相关系数为 0.40。ASM、Energy、Homogeneity 与地上生物量的相关性最低，相关系数为 −0.42。综上所述，选择与地上生物量

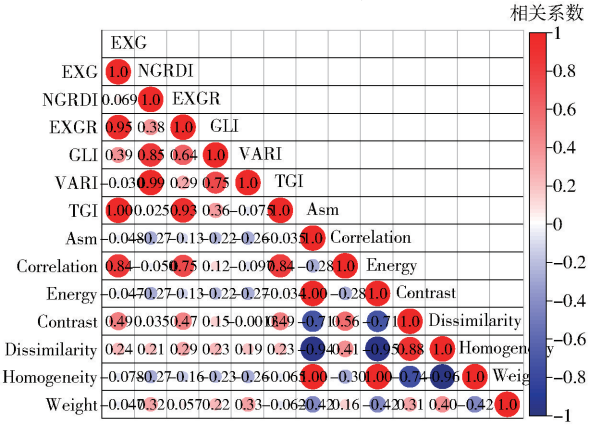

图 11 不同植被、纹理指数与地上生物量的相关性

Fig. 11 Correlation between different vegetation, texture index and aboveground biomass

相关系数最高的植被指数和纹理指数，共筛选出 VARI 和 Dissimilarity 2 个变量用于后续地上生物量估计建模。

2.4　生菜地上生物量估测最优模型

利用 UGV 表型平台获得的生菜表型参数，可用于无损估测生菜地上生物量，将植被指数和纹理指数的信息与生菜的高度和最大宽度数据融合。结果表明，融合模型估计精度显著提高（图 12）。HA 和 WA 模型 R^2 分别为 0.62、0.42，RMSE 分别为 5.64、7.05 g，这表明生菜高度相比最大宽度对估算地上生物量更重要。表 2 呈现了不同特征参数组合模型地上生物量估测结果，HA + WA + VARI + Dissimilarity（HWVD）模型 R^2 达到 0.82，RMSE 为 4.03 g，MAPE 为 6.04%，相比之下，HA + WA（HW）、HA + WA + VARI（HWV）、HA + WA + Dissimilarity（HWD）模型 R^2 分别达到 0.76、0.73、0.74，RMSE 分别为 5.70、4.71、4.58 g，MAPE 分别为 6.68%、8.42%、6.61%。这表明生菜高度、最大宽度相比植被指数、纹理指数信息对估算地上生物量占据更大权重，但仅将植被指数或纹理指数其中的一个特征参数与高度和最大宽度信息融合，难以提高生菜地上生物量估算精度。同时融合高度、最大宽度、植被指数、纹理指数 4 种特征参数的模型估算精度达到最高，因为植被指数和纹理指数能反映作物的生长状况，所以在校准基于点云数据提取的高度、最大宽度特征估测地上生物量时具有重要作用，可进一步提高生菜地上生物量估算的准确性。

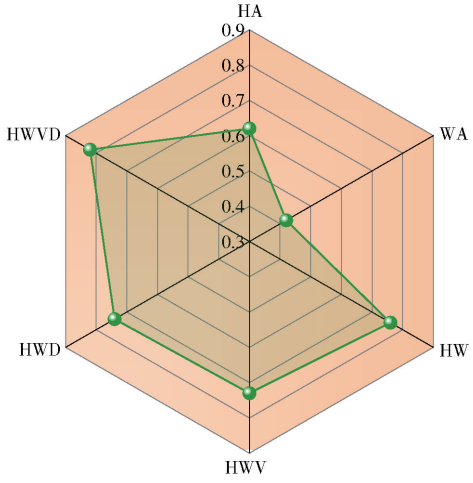

图 12　不同特征参数组合生物量模型估计精度

Fig. 12　Estimation accuracy of biomass model with different characteristic parameter combinations

表 2　生菜地上生物量预测结果

Tab. 2　Prediction results of lettuce aboveground biomass

数据类型	R^2	RMSE/g	MAPE/%
HA	0.62	5.64	8.32
WA	0.42	7.05	9.71
HW	0.76	5.70	6.68
HWV	0.73	4.71	8.42
HWD	0.74	4.58	6.61
HWVD	0.82	4.03	6.04

3　讨论

本文方法可以代替人工在现场获取作物多维性状表型信息以及基于多维特征参数无损估测生菜地上生物量。该研究在设施环境中使用奥比中光 336L 型深度相机采集 RGB 图和深度图进行三维点云重建，通过基于点云和 RGB 图像获取的生菜高度、最大宽度、地上生物量信息与人工测量的结果相比较，证明了所提出方法的可行性与准确性。在试验中，传感器直接安装在暴露于外部环境的移动平台上，没有遮光，这种传感器对户外环境表现出良好的适应力。该方法为面向现场的作物原位无损表型检测提供了一种解决方案。

轨道式[19]、龙门式[20]、成像室式[21]等设施原位表型平台，需要配合流水线或敷设轨道使用，具有较高的建造成本，占地较多、灵活性较差，且通常难以在不同温室之间进行跨区巡检，而 UGV 和无人机平台由于其灵活性很高[26-27]，可以跨区作业，大幅降低了平台建造成本，相比之下，UGV 和无人机平台成本更低[28]。但无人机平台负载较小、续航能力较弱，且在设施环境中，无人机的飞行空间受到限制。此外，无人机低空飞行时旋翼叶片产生的湍流会对作物结构产生显著影响，导致形态特征参数测量存在较大误差。当无人机飞行至某一高度以避免气流对植物的影响时，传感器所获取的数据分辨率往往显著降低。相比之下，基于 UGV 的表型平台由于传感器更接近作物，因此其获取的图像或点云的分辨率可能高于无人机获取的图像或点云。

在不同的点云下采样试验中，发现随着点云数据量的减少，生菜高度和最大宽度的提取精度会逐渐降低，但在保证生菜表型精度下降幅度较低的情况下，降低点云数据量可以很大程度提高点云数据处理效率。因此，利用下采样的方法可以满足现场检测的快速、准确的需求。

在本研究中，使用机器学习技术来整合整个数据集并创建作物地上生物量预测模型。根据 Pearson 相关性选择了对地上生物量预测最敏感的变量，旨在减轻使用众多变量导致模型精度降低。反映作物形态结构特征的高度和最大宽度在 Pearson 相关性分析（相关系数分别为 0.66、0.71）中被证明是对地上生物量影响最显著的参数。此外，所有植被、纹理指数在预测地上生物量方面的相关性相对较低。作物的

高度和最大宽度对地上生物量高度敏感,因为它提供了作物结构和生菜生长状态的更多细节[29]。然而,VARI 和 Dissimilarity 与地上生物量的相关性最高(相关系数分别为 0.33、0.40),因为它们对叶绿素含量的变化敏感。这些指数可以作为有用的作物生长指标,因为作物地上生物量随着叶绿素含量的增加而变大。最后,选取性能最优的 4 个变量(株高、最大宽度、VARI 和 Dissimilarity)作为预测输入进行生菜地上生物量预测。

4 结论

(1)设计了一套面向现场的高效、精准的作物原位表型检测平台,可以满足设施蔬菜表型检测需求,不仅降低了采集图像数据工作的强度和时间,还提高了生菜表型检测的效率,并兼顾了现场检测的精确性和高通量的需求。

(2)融入了随机下采样算法的表型分析管道极大提高了点云数据处理速度。研究表明,5 000 下采样点云单帧数据处理时间为 0.41 s,相比原始点云、20 000 下采样点云、10 000 下采样点云处理时间分别降低 2.73、1.00、0.19 s。5 000 下采样点云生菜高度和最大宽度 R^2 分别为 0.79、0.77,MAPE 分别为 4.94%、5.02%,与原始点云相比,R^2 分别下降 0.01、0.02,MAPE 分别增加 1.06、0.53 个百分点。综上所述,所提方法提高了生菜表型检测效率,可以满足现场实时检测和准确性需求。

(3)利用 Pearson 相关性筛选出株高、最大宽度、VARI、Dissimilarity 4 个与地上生物量相关性最高的特征变量,基于多维特征数据和 BP 神经网络算法分别构建了单一特征和多维特征组合的地上生物量估测模型。结果表明,融合了株高、最大宽度、VARI、Dissimilarity 的模型(HWVD)精度最高,其预测值 R^2 为 0.82,RMSE 为 4.03 g,MAPE 为 6.04%。因此,基于多维成像特征的地上生物量估测模型可以很大程度上克服单一成像特征在预测地上生物量时的精度受限问题。

参 考 文 献

[1] 宋鹏,李正达,杨蒙,等. 作物表型机器人研究现状与展望[J]. 农业机械学报,2025,56(3):1-17.
SONG Peng, LI Zhengda, YANG Meng, et al. Current status and prospects of crop phenotyping robots[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025,56(3):1-17. (in Chinese)

[2] KONG Y,KONG X,ZHENG Y. Estimating fresh weight of individual pea shoots using measurable morphological characteristics [J]. HortScience,2020,55(7):1111-1118.

[3] LIU T,ZHU S,YANG T, et al. Maize height estimation using combined unmanned aerial vehicle oblique photography and LIDAR canopy dynamic characteristics[J]. Computers and Electronics in Agriculture,2024,218:108685.

[4] REN Guoqiang,WU Hangyu,BAO Anbo, et al. Mobile robotics platform for strawberry temporal-spatial yield monitoring within precision indoor farming systems[J]. Frontiers in Plant Science,2023,14:1162435.

[5] FILIPPO S G D,FULVIA R,WERNER F B, et al. UAV-based high-throughput phenotyping to discriminate barley vigour with visible and near-infrared vegetationindices[J]. International Journal of Remote Sensing,2018,39(15-16):5330-5344.

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

[7] 马彦鹏,边明博,樊意广,等. 基于无人机 RGB 影像的马铃薯植株钾含量估算[J]. 农业机械学报,2023,54(7):196-203,233.
MA Yanpeng, BIAN Mingbo, FAN Yiguang, et al. Estimation of potassium content of potato plants based on UAV RGB images [J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(7):196-203,233. (in Chinese)

[8] SHI Yujie,GAO Yuan,WANG Yu, et al. Using unmanned aerial vehicle-based multispectral image data to monitor the growth of intercropping crops in tea plantation[J]. Frontiers in Plant Science,2022,13:820585.

[9] SONG Peng,LI Zhengda,YANG Meng, et al. Dynamic detection of three-dimensional crop phenotypes based on a consumer-grade RGB-D camera[J]. Frontiers in Plant Science,2023,14:1097725.

[10] MAIMAITIJIANG M,SAGAN V,SIDIKE P, et al. Soybean yield prediction from UAV using multimodal data fusion and deep learning[J]. Remote Sensing of Environment,2020,237:111599.

[11] 林洁雯,陈建. 基于多源数据与丰度信息融合的森林生物量估算研究[J]. 农业机械学报,2025,56(1):65-73.
LIN Jiewen, CHEN Jian. Forest biomass estimation based on multi-source data and abundance information fusion [J]. Transactions of the Chinese Society for Agricultural Machinery,2025,56(1):65-73. (in Chinese)

[12] 王晗,向友珍,李汪洋,等. 基于无人机多光谱遥感的冬油菜地上部生物量估算[J]. 农业机械学报,2023,54(8):218-229.
WANG Han, XIANG Youzhen, LI Wangyang, et al. Estimation of winter rapeseed above-ground biomass based on UAV multi-spectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(8):218-229. (in Chinese)

[13] LIU Shuaibing,JIN Xiuliang,NIE Chenwei, et al. Estimating leaf area index using unmanned aerial vehicle data: shallow *vs.* deep machine learning algorithms[J]. Plant physiology,2021,187(3):1551-1576.

[14] CHANG Anjin,JUNG Jinha,YEOM Junho, et al. 3D characterization of sorghum panicles using a 3D point cloud derived from

UAV imagery[J]. Remote Sensing,2021,13(2):282.
[15] JIANG J,JOHANSEN K,STANSCHEWSKI C S, et al. Phenotyping a diversity panel of quinoa using UAV-retrieved leaf area index, spad-based chlorophylland a random forest approach[J]. Precision Agriculture,2022,23:961 - 983.
[16] 劳彩莲,杨瀚,李鹏,等. 基于消费级深度相机的玉米植株三维重建[J]. 农业机械学报,2019,50(7):222 - 228.
LAO Cailian, YANG Han, LI Peng, et al. 3D reconstruction of maize plants based on consumer depth camera[J]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(7):222 - 228. (in Chinese)
[17] MORTENSEN K A,BENDER A,WHELAN B, et al. Segmentation of lettuce in coloured 3D point clouds for fresh weight estimation[J]. Computers and Electronics in Agriculture,2018,154:373 - 381.
[18] CAI Shuangze,GOU Wenbo,WEN Weiliang, 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.
[19] DU Jianjun,FAN Jiangchuan,WANG Chuanyu, et al. Greenhouse-based vegetable high-throughput phenotyping platform and trait evaluation for large-scale lettuces[J]. Computers and Electronics in Agriculture,2021,186:106193.
[20] NICOLAS V,KASRA S,POURIA S, et al. Field scanalyzer: an automated robotic field phenotyping platform for detailed crop monitoring[J]. Functional Plant Biology,2016,44(1):143 - 153.
[21] RITA A,FIRUZ O,VIVEKANAND V, et al. Affordable imaging lab for noninvasive analysis of biomass and early vigour in cereal crops[J]. BioMed Research International,2018,2018:5713158.
[22] YOUNG N S,KAYACAN E,PESCHEL M J. Design and field evaluation of a ground robot for high-throughput phenotyping of energy sorghum[J]. Precision Agriculture,2019,20(4):697 - 722.
[23] 范军亮,王涵,廖振棋,等. 基于纹理-颜色特征与植被指数融合的冬小麦 LAI 估测[J]. 农业机械学报,2023,54(7):347 - 359.
FAN Junliang, WANG Han, LIAO Zhenqi, et al. Winter wheat leaf area index estimation based on texture-color features and vegetation indices[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(7):347 - 359. (in Chinese)
[24] JINYA S,DEWEI Y,MATTHEW C, et al. Spectral analysis and mapping of blackgrass weed by leveraging machine learning and UAV multispectral imagery[J]. Computers and Electronics in Agriculture,2022,192:106621.
[25] LIU X,DU R,XIANG Y, et al. Estimating winter canola aboveground biomass from hyperspectral images using narrowband spectra-texture features and machine learning[J]. Plants,2024,13(21):2978.
[26] FEI Shuaipeng,ADEEL M H,XIAO Yonggui, et al. UAV-based multi-sensor data fusion and machine learning algorithm for yield prediction in wheat[J]. Precision Agriculture,2022,24(1):21 - 26.
[27] 张慧春,周宏平,郑加强,等. 植物表型平台与图像分析技术研究进展与展望[J]. 农业机械学报,2020,51(3):1 - 17.
ZHANG Huichun, ZHOU Hongping, ZHENG Jiaqiang, et al. Research progress and prospect in plant phenotyping platform and image analysis technology[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(3):1 - 17. (in Chinese)
[28] 黄语燕,胡楚涵,王涛,等. 室内植物表型采集平台的研究进展与展望[J]. 安徽农业科学,2024,52(18):10 - 15.
HUANG Yuyan, HU Chuhan, WANG Tao, et al. Research progress and prospect of indoor plant phenotype collection platform[J]. Journal of Anhui Agricultural Sciences,2024,52(18):10 - 15. (in Chinese)
[29] LI W,NIU Z,CHEN H, et al. Remote estimation of canopy height and aboveground biomass of maize using high-resolution stereo images from a low-cost unmanned aerial vehicle system[J]. Ecological Indicators,2016,67:637 - 648.