点云数据驱动的玉米叶片生物量估算方法

武张斌[1,2,3], 何 宁[3], 吴延东[3], 郭新宇[1,3], 温维亮[1,2,3*]

(1. 北京市农林科学院信息技术研究中心,北京 100097,中国; 2. 沈阳农业大学 信息与电气工程学院,沈阳 110161,中国; 3. 国家农业信息化工程技术研究中心数字植物北京市重点实验室,北京 100097,中国)

摘 要: **[目的/意义]** 玉米叶片干重生物量是反映植株生理过程的关键性状,可有效表征玉米生长状态。准确估算玉米叶片干重生物量,对于预测玉米产量和生产管理决策具有重要意义。传统的生物量预测研究主要集中在群体冠层尺度,缺少植株和器官尺度的干重生物量预测方法。围绕玉米栽培管理等研究对器官干重生物量信息快速获取的需求,开展基于叶片3D点云和机器学习的玉米叶片干重生物量无损测量方法研究。**[方法]** 本研究使用多视角三维重建、激光雷达三维扫描和3D数字化三种方式获取玉米叶片点云数据。运用随机森林、梯度提升回归树和支持向量回归三种机器学习方法,以及卷积神经网络和全连接神经网络(Fully Connected Neural Network, FCNN)两种深度学习方法进行玉米叶片干重预测,进而构建基于点云的玉米叶片干重生物量预测模型。**[结果和讨论]** 使用激光雷达点云数据结合FCNN方法构建的生物量预测模型精度最高,平均绝对误差为0.08 g,平均绝对百分比误差为4.60%,均方根误差为0.10 g,决定系数为0.98。**[结论]** 利用高分辨率的玉米叶片3D点云结合机器学习方法,可实现玉米叶片干重的高精度估算,为作物器官生物量无损测算提供新途径。

关键词: 玉米叶片;3D点云;机器学习;生物量预测;深度学习

中图分类号: TP399;S513 **文献标识码:** A **文章编号:** SA202509015

引用格式:武张斌, 何宁, 吴延东, 郭新宇, 温维亮 . 点云数据驱动的玉米叶片生物量估算方法[J]. 智慧农业(中英文), 2026, 8(1): 156-166. DOI: 10.12133/j.smartag.SA202509015

WU Zhangbin, HE Ning, WU Yandong, GUO Xinyu, WEN Weiliang. Point Cloud Data-driven Methods for Estimating Maize Leaf Biomass[J]. Smart Agriculture, 2026, 8(1): 156-166. DOI: 10.12133/j.smartag.SA202509015 (in Chinese with English abstract)

0 引 言

作物叶片生物量是反映植株光合能力与营养状况的关键参数,其动态变化可有效指示作物生长状态。准确估算作物叶片生物量,对于预测作物产量和作物产中管理决策具有重要的价值。传统的作物生物量等表型分析方法主要依赖于手工测量[1],工作量大、效率低,易对作物造成破坏,测量结果受个人主观因素影响较大[2]。近年来,计算机视觉算法在作物表型数据[3]获取中得到大规模应用[4],极大地推动了表型大数据的处理、解析与可视化[5]。基于高通量表型技术[6]的作物生物量快速测算对于作物科学研究具有重要意义[7]。

玉米是重要的粮食作物[8],快速、无损和准确测量地上生物量对玉米育种与栽培研究具有直接的推动作用。现有的表型装备能够获取玉米小区[9]或植株的图像[10]、光谱[11]和点云[12]等数据,通过对一种或多种融合数据[13]的解析能够得到影响玉米地上生物量的相关因子[14]并实现玉米地上生物量的估算。樊鸿叶等[15]使用无人机获取多光谱数据,提取了叶面积指数,使用幂函数、指数函数的方法预测玉米地上干重生物量,平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)为61.9 g/m^2。王毅等[16]使用无人机获取图像数据,

收稿日期:2025-09-05

基金项目:农业农村部科技项目;国家自然科学基金(32572199);国家重点研发计划(2022YFD2001003)

作者简介:武张斌,硕士研究生,研究方向为植物三维表型。E-mail:wuzhangbin163@163.com

*通信作者:温维亮,博士,副研究员,研究方向为植物三维表型高通量获取与自动解析、植物三维重建与可视化计算。E-mail:wlwen37@163.com

copyright©2026 by the authors

提取了作物参数、植被指数和气象参数等相关特征，引入卷积神经网络、长短期记忆网络和自注意力机制构建模型，并分析了影响因子与玉米地上干重生物量之间的皮尔逊相关系数，最终模型决定系数（R-squared, R^2）为0.86，均方根误差（Root Mean Square Error, RMSE）和平均绝对误差（Mean Absolute Error, MAE）分别为107.53 g/m^{2}和55.19 g/m^2。ZHU等[17]使用无人机挂载激光雷达获取点云数据，提取了作物高度等特征，使用多元线性回归、随机森林（Random Forest， RF）和支持向量回归（Support Vector Regression， SVR）等方法预测玉米的地上鲜重和干重生物量，但多组实验的R^2仅为0.50左右。亚森等[18]提取了叶面积指数特征，运用点数法和经验公式法对常见绿化树种的叶鲜重生物量进行估算，最终结果生物量变异数的平均值为5.93%和7.57%。VUORINNE等[19]使用Sentinel-2多光谱卫星图像获取光谱数据，提取植被指数对龙舌兰叶片的鲜重和干重生物量进行研究，解释偏差为76%。对玉米叶片的生物量进行估算能够预测玉米生长状态、评估玉米产量并指导灌溉及施肥决策[20]。JIN等[12]使用激光雷达获取玉米叶片点云数据，提取了高度、体积等特征，运用逐步多元回归（Stepwise Multiple Regression, SMR）、人工神经网络（Artificial Neural Network, ANN）等方法预测玉米叶片干重生物量，模型R^2可达到0.86。由于高精度的3D数据获取依赖仪器设备，成本较高，且数据处理对算法要求较高，导致针对玉米叶片等器官尺度的生物量预测研究较少，精度较低，难以满足玉米育种和栽培研究对叶片生物量测算的需求。

大量作物生物量估算研究表明，表征作物形态结构特征的3D点云数据及基于其提取的特征与作物生物量具有极高的相关性。玉米的三维点云数据能够准确反映出玉米的三维形态，而玉米生物量与形态结构相关的特征关系显著，在提高玉米生物量的准确性和效率方面具有显著优势。随着表型装备的快速发展，获取作物点云数据的设备和数据处理方式也越来越多样化。通过多个不同视角（Multi-View Stereo, MVS）协同工作，采集玉米植株的多视角图像数据，极大地提升了获取效率[21]，利用3D高斯（3D Gaussian Splatting, 3DGS）[22]等算法对图像数据进行拼接实现玉米植株的三维重建[23]。将玉米植株点云数据进行分割，得到玉米叶片点云，提取玉米叶片的形态参数，为后续基于叶片形态特征的玉米叶片生物量预测研究工作提供可靠的数据基础。激光雷达三维扫描（Lidar 3D Scanning, Laser）能够通过激光反射来探测玉米植株的三维形态，运用特定的算法与模型对激光雷达的数据进行处理，实现玉米植株的表型解析和三维重建。使用激光雷达获取的点云数据更能精准地反映玉米叶片的形态特征。使用深度学习分割算法[24]可以对玉米叶片点云进行分割，为玉米叶片生物量预测提供有力的数据支撑。三维数字化的方法（3D Digitalization, DT）能够在自然光照条件下对玉米植株和器官的几何拓扑[25]信息进行扫描，获取田间原位的玉米形态结构数据，实现带有语义信息的玉米植株三维重建[26]为玉米生物量预测工作提供基础。

传统的玉米叶片生物量预测研究工作主要集中在群体冠层尺度，对于玉米器官尺度的生物量的研究较少。虽然能够获取玉米植株点云数据的设备较多，但并未见能够精准估算和获取玉米叶片生物量的配套方法，无法满足玉米研究对生物量信息获取快速测算的需求。为此，本研究提出了基于玉米叶片3D点云和机器学习算法实现玉米叶片生物量无损测算，并使用机器学习算法中的特征重要性分析和皮尔逊相关性分析方法，明确主要叶型参数指标对叶片生物量预测的重要性，以期提供玉米叶片生物量无损测算方法，提升测算效率，为作物器官生物量测算提供新途径。

1 材料和方法

1.1 数据获取

本研究基于团队前期[25]使用激光雷达、植株多视角表型平台和三维数字化仪设备[27]采集的吐丝期至灌浆期长势一致的玉米植株、叶片的三维点云数据和玉米叶片生物量数据进行生物量估算模型构建，具体数据获取和预处理流程如图1所示。对于取样的植株，使用三种方式获取玉米3D点云数据。一是基于MVS Pheno[21]平台获取玉米单株MVS数据，该平台可以批量自动提取玉米空间几何结构的特征，将相机分辨率像素设置为2 560×1 920对玉米植株多视角图像数据进行获取。二是使用机械臂高精度3D扫描仪（FARO Design ScanArm 2.5C）对玉米植株直接扫描，获取高分辨率的玉米植株Laser点云数据。三是使用FastScan三维数字化仪对玉米植株的叶片进行三维数字化数据获取，得到带有语义信息的叶片3D数据。获取三维数据后，逐个取下叶片装入信封做好品种和叶序

标记，烘箱内进行杀青和烘干。烘干后使用天平测量叶片干重，测量单位为克，小数点精确到后3位。

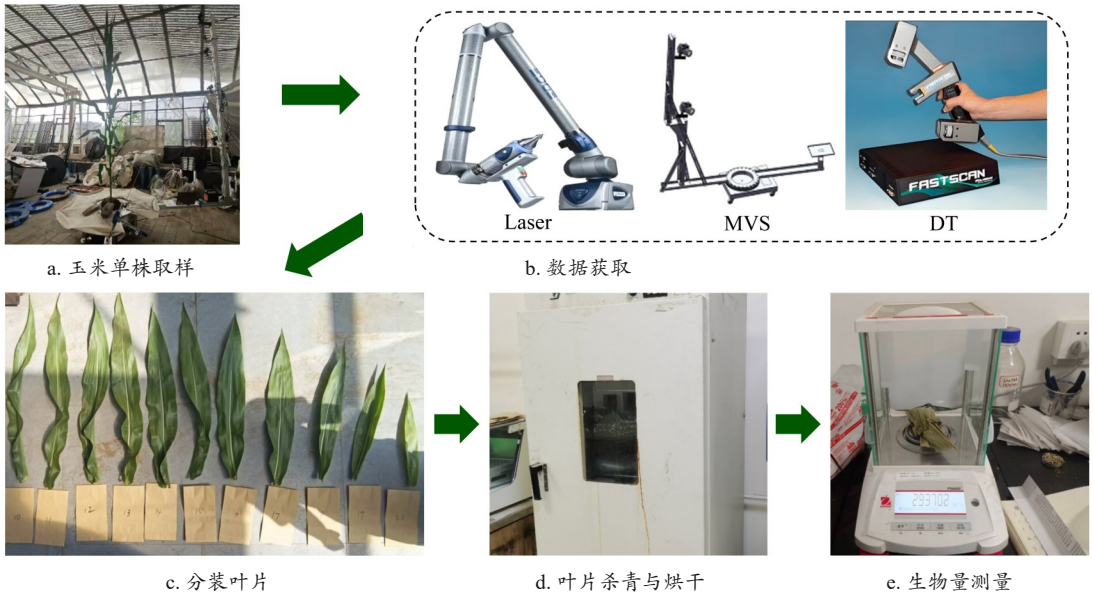


图1 玉米植株叶片3D和生物量数据获取流程

Fig. 1 3D and biomass data acquisition process of maize leaves

1.2 叶片3D数据预处理

使用MVS、Laser和DT获取的原始数据不能直接进行生物量预测，需要对获取的原始数据进行预处理。本研究针对每种方法获取数据的不同特性采用不同的预处理方式，以得到玉米叶片点云。具体的数据预处理流程如下。

1）MVS数据处理。使用MVS Pheno[21]平台获取玉米植株多个角度的2D图像数据，利用3DGS[22]进行多视角数据三维重建和尺度校准，使用CloudCompare软件将重建场景进行分割得到玉米单株点云数据。使用Label3DMaize[28]软件进行分割标注，并采用DeepSeg3DMaize[29]进行植株到叶片的点云分割。但算法不能精准分割玉米叶片点云，尤其是对玉米叶片与茎秆、叶鞘粘连处的分割。因此，使用CloudCompare软件对玉米叶片点云进行二次分割，得到精准的玉米叶片点云数据，如图2a所示。

2）Laser数据处理。所得到的Laser高精度点云数据包含噪声和玉米茎秆或叶鞘等扫描场景的其他数据，运用CloudCompare软件将得到的点云进行裁剪和去噪，得到最终的叶片点云数据，如图2b所示。

3）DT数据处理。使用MaizeTypeOpt[30]软件对获取的DT数据进行处理得到玉米叶片3D网格数据，网格数据的每个点都有相应的语义，运用Loop细分加细方法将玉米叶片的面数增加到15倍，使用4次Loop细分迭代，保留加细后的所有顶点，进而得到加细后的玉米叶片点云数据，如图2c所示。

1.3 玉米叶片形态结构特征提取

获取玉米叶片点云数据后，需对点云特征进行提取以用于生物量预测模型的构建，在特征提取前对所有点云进行体素下采样，设置体素大小为0.5 cm，以确保不同数据源提取特征的一致性。下面介绍部分叶片形态结构特征的提取方法：

V_{OBB}和S_{OBB}是方向包围盒体积和方向包围盒表面积，方向包围盒是能紧密包裹点云且方向可旋转的最小长方体，其方向由点云的主成分决定。首先计算均值与协方差矩阵，协方差矩阵能够反映点云在各维度上的分布关系并确定方向包围盒的主轴方向。然后对协方差矩阵进行平方根分解得到半轴长度。最后计算方向包围盒体积V_{OBB}和表面积S_{OBB}，如公式（1）和公式（2）所示。

$$V_{OBB}=2\times(L_{obb_a}+L_{obb_b}+L_{obb_c}) \quad (1)$$

$$S_{OBB}=2\times(2\times L_{obb_a}\times L_{obb_b})+2\times(2\times L_{obb_a}\times L_{obb_c})+2\times(2\times L_{obb_b}\times L_{obb_c}) \quad (2)$$

式中：L_{obb_a}、L_{obb_b}和L_{obb_c}分别表示方向包围盒的长、宽、高。

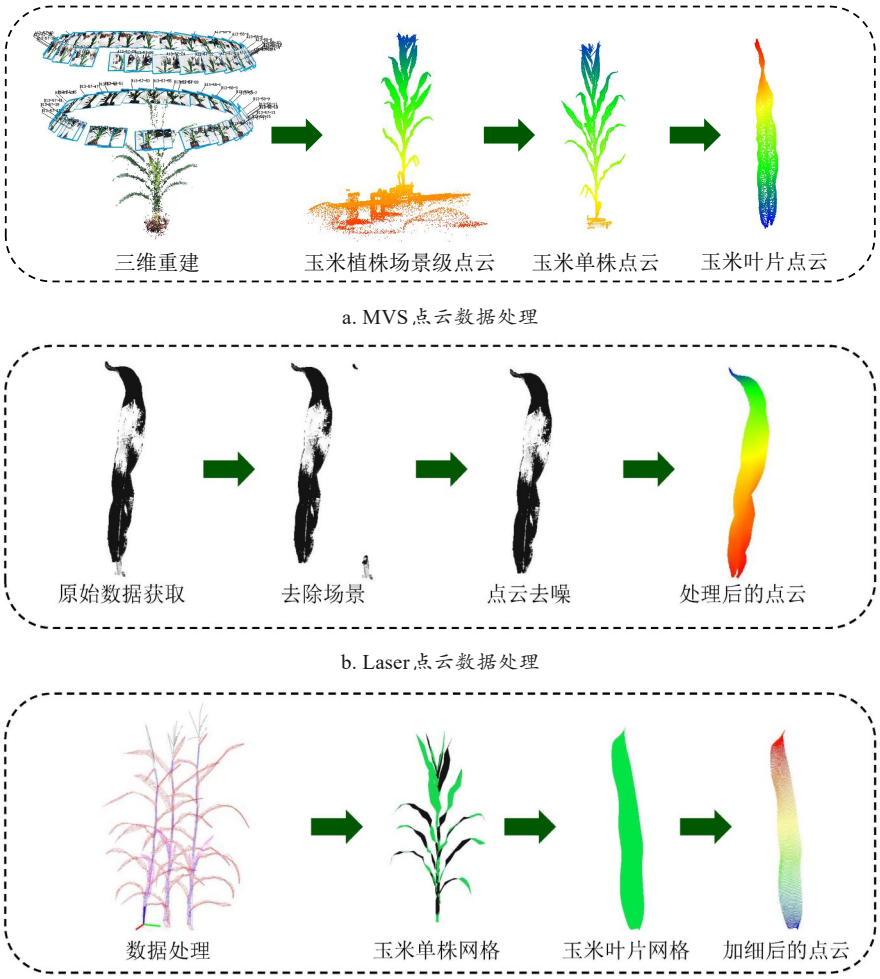


图2 玉米点云数据处理

Fig. 2 Processing of maize point cloud data

V_{AABB}和S_{AABB}是轴对齐包围盒体积和表面积，轴对齐包围盒是与坐标轴平行的最小长方体，完全包含点云中所有点，其边与X、Y、Z轴平行。L_{mrb}是点云最小外包盒对角线长度。

V_{hull}和S_{hull}是点云的凸包体积和表面积，点云的凸包体积是指包含该点云的最小凸多面体的体积，用于描述点云在三维空间中的整体分布范围。将凸包网格拆分为多个三角形面片。以坐标原点为基准，将每个三角形面片与原点组成一个四面体。计算每个四面体的体积，如公式（3）所示。

$$V_{hull}=\frac{1}{6}|\overrightarrow{AB}\times(\overrightarrow{AC}\times\overrightarrow{AD})| \quad (3)$$

式中：点A、B、C、D是三维空间中的四个点；$\overrightarrow{AB}$、$\overrightarrow{AC}$、$\overrightarrow{AD}$表示从同一个起点出发到三个不同终点的有向线段。对所有三角形面片的面积求和即为S_{hull}。

D_{max}和D_{min}是点云中的点到其质心的最大距离和最小距离，首先沿第0轴（行方向）计算均值，得到质心的坐标，然后计算点云中所有的点到质心的欧氏距离，如公式（4）所示。

$$D_{max}/D_{min}=\sqrt{(x_i-c_x)^2+(y_i-c_y)^2+(z_i-c_z)^2} \quad (4)$$

式中：x_i、y_i、z_i分别为点云中第i个点在x轴、y轴和z轴的坐标；c_x、c_y、c_z分别是点云的质心在x轴、y轴和z轴的坐标。最后排序得到点云到质心的最大距离和最小距离。

由于MVS和Laser获取的点云不包含语义信息，能够提取的点云特征较少，DT获取的网格数据包含语义信息，因此能够提取的特征较多。表1列举了本研究中提取的所有玉米叶片特征，MVS和Laser获取的数据能够提取13个特征，DT获取的数据能够提取24个特征。

表1 玉米叶片特征提取

Table 1 Feature extraction of maize leaves

特征	变量	简介	Laser	MVS	DT
data source	*DS*	数据来源	○	○	○
leaf_ID	*ID*	自下而上叶片的顺序	●	●	●
cultivar	*C*	品种	●	●	●
leaf_growth_height	H_{lg}	叶片基部距地面高度	○	○	●
leaf_angle	θ	叶倾角	○	○	●
leaf_azimuth	α	方位角	○	○	●
leaf_length	*L*	叶片长度	○	○	●
leaf_width	*W*	叶片平均宽度	○	○	●
top_is_tip	*TiT*	叶顶与叶尖高度是否相等	○	○	●
leaf_top_height	H_{top}	叶片顶部距地面高度	○	○	●
leaf_top_level_length	L_{topl}	叶片顶部距茎水平长度	○	○	●
leaf_tip_height	H_{tip}	叶片尖部距地面高度	○	○	●
leaf_tip_level_length	L_{tipl}	叶片尖部距茎水平长度	○	○	●
Leaf_area	*S*	叶面积(网格面积)	●	●	●
Leaf_top_curve_length	L_{topc}	叶片基部距叶片最高点水平长度	○	○	●
number	*N*	点云中的点个数	●	●	●
obb_volume	V_{OBB}	紧密包裹点云且方向可旋转的最小长方体体积	●	●	●
obb_area	S_{OBB}	紧密包裹点云且方向可旋转的最小长方体表面积	●	●	●
AABB_volume	V_{AABB}	与坐标轴平行的最小长方体体积	●	●	●
AABB_area	S_{AABB}	与坐标轴平行的最小长方体表面积	●	●	●
MRB_length	L_{mrb}	最小外包盒对角线长度	●	●	●
max_distance	D_{max}	点云中的点到其质心的最大距离	●	●	●
min_distance	D_{min}	点云中的点到其质心的最小距离	●	●	●
hull_volume	V_{hull}	点云的最小凸多面体的体积	●	●	●
hull_area	S_{hull}	点云的最小凸多面体的表面积	●	●	●

注：表中“●”表示已经提取的特征，“○”表示未进行提取的特征。

1.4 玉米叶片生物量预测方法

使用MVS、Laser和DT三种设备共获取670个玉米叶片和对应生物量的数据。将三种设备各获取的点云数据，以及融合了三种设备获取的所有点云数据构建的数据集，共四种数据集进行归一化处理，对*C*、*DS*和*TiT*三个特征进行独热编码，使用scikit-learn库中的train_test_split函数，将数据集划分为训练集和测试集，比例设置为3∶1，并设置随机种子，以确保模型的可复现性。分别运用RF、梯度提升回归树（Gradient Boosting Regression Tree, GBRT）和SVR三种机器学习方法，以及卷积神经网络（Convolutional Neural Network, CNN）和全连接神经网络（Fully Connected Neural Network, FCNN）两种深度学习方法进行生物量预测。

1.4.1 随机森林

RF是一种能够结合多个决策树的预测结果来提高模型精度的机器学习算法。本研究使用网格搜索的优化方法对RF的超参数进行优化，具体包括：树的数量、树的最大深度、节点分裂的最小样本数、叶子节点的最小样本数、每节点分裂的最大特征数和每棵树的子采样比例。以MAE为损失确定最佳RF超参数，并保存最佳模型的特征重要性排序。

1.4.2 梯度提升回归树

GBRT是一种集成学习和梯度下降的机器学习回归算法，通过串行构建多棵决策树来提高整体模

型的性能。本研究使用网格搜索的优化方法对GBRT的超参数进行优化，具体包括：树的数量、学习率、树的最大深度、最小样本数、叶子节点的最小样本数、子采样比例和每节点分裂的最大特征数。以MAE为损失确定最佳梯度提升回归树参数，并保存最佳模型的特征重要性排序。

1.4.3　支持向量回归

SVR是一种可以用于回归任务的监督学习算法。本研究使用网格搜索的优化方法对SVR的超参数进行优化，具体包括：正则化参数、epsilon、核函数和多项式核的参数。以MAE为损失确定SVR超参数，并保存最佳模型。

1.4.4　卷积神经网络

CNN是深度学习的核心模型之一，其结构属于一种前馈神经网络，它可以通过局部连接和权重共享机制，高效地提取数据的层次化特征。本研究使用网格搜索的方法对CNN的超参数进行优化，具体包括：卷积输出通道数、卷积核大小、隐藏层神经元数量、学习率和批处理大小。以MAE为损失确定并保存最佳模型。

1.4.5　全连接神经网络

FCNN也称多层感知机，是深度学习中基础的神经网络结构之一，它能够通过密集的连接方式实现数据的非线性变换和特征提取。本研究使用网格搜索的方法对FCNN的超参数进行优化，具体包括：学习率、批次大小、隐藏层大小、Droupout概率、激活函数类型和权重衰减。以MAE作为损失确定超参数，并保存最佳模型。

1.5 评价指标

本研究使用MAE、MAPE、RMSE和R^2作为模型的评价指标。MAE是预测值与真实值之间的绝对差值的平均数，其数值越小表示模型预测越准确，它的单位与目标值的单位相同，因此可以直接与数据的实际量纲进行比较。MAPE是平均绝对百分比误差，平均绝对百分比误差常用于衡量预测准确性的统计指标，MAPE值越小，表示预测模型越准确，预测值与实际值之间的误差越小。RMSE是均方根误差，它可以测量误差的平均幅度，并关注与实际值的偏差，RMSE的值越低，模型的效果越好。R^2是决定系数，是用来评估回归模型的重要指标，R^2的数值越高，模型的效果越好。具体计算如公式（5）～公式（8）所示。

$$\mathrm{MAE}=\frac{1}{n}\sum_{i=1}^{n}\left|y_i-\hat{y}_i\right| \tag{5}$$

$$\mathrm{MAPE}=\frac{1}{n}\sum_{i=1}^{n}\left|\frac{\hat{y}_i-y_i}{y_i}\right| \tag{6}$$

$$\mathrm{RMSE}=\sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i-\hat{y}_i)^2} \tag{7}$$

$$R^2=1-\frac{\sum_{i=1}^{n}(y_i-\hat{y}_i)^2}{\sum_{i=1}^{n}(y_i-\bar{y})^2} \tag{8}$$

式中：y_i是玉米叶片生物量真实值；$\hat{y}_i$是玉米叶片生物量的预测值；$\bar{y}$表示与玉米叶片生物量预测值对应真实值的均值。

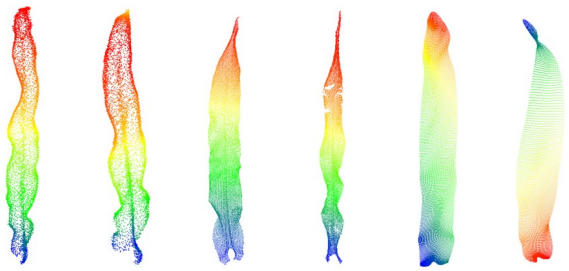
2　结果与分析

2.1 玉米叶片点云对比分析

本研究使用MVS、Laser和DT三种不同的设备获取点云数据。在获取流程方面，MVS设备在数据获取过程中流程简单，获取时间短，速度较快，受人为因素影响较小。Laser和DT两种设备的获取流程复杂，速度较慢，获取时间较长，受人为因素干扰的影响较大。在数据处理方面，MVS方法需使用多视角三维重建算法才能完成玉米植株的三维重建，Laser设备直接得到玉米叶片点云数据，DT是直接得到带有语义信息的植株和叶片点云数据。在获取玉米叶片点云数据时，MVS获取的数据需运用植株-器官点云分割方法获取玉米叶片点云，DT获取的数据可以根据语义信息得到玉米叶片点云。在数据质量方面，通过MVS获取的数据运用3DGS技术对玉米植株进行三维重建，再经过算法处理配合手动分割，最终得到玉米叶片点云，如图3a所示，所得的玉米叶片点云边缘和叶脉处点云较密集，其他部分点云较稀疏，在一定程度上更能反映出玉米叶片边缘和叶脉部分的特征。Laser获取的点云数据比较稠密，数据质量较高，能够反映叶片的空间形态，如图3b所示。但部分点云数据存在缺失情况。使用DT获取的数据是网格数据，经过加细后得到的点云数据没有缺失情况，如图3c所示，但与真实的玉米叶片数据相比加细后的点云更加平滑，一些细节的地方无法还原真实的叶片。

2.2 玉米叶片生物量预测精度

本研究使用三种不同的设备获取玉米叶片点云数据，使用网格搜索的方法对三种不同的机器学习方法和两种深度学习方法的超参数进行优化得到最佳的生物量预测模型。用4种评价指标对各种模型进行评估，详细结果如表2所示。结果显示，使用Laser获取点云数据，运用FCNN方法进行生物量



a. MVS数据 b. Laser数据 c. DT数据

图3 玉米叶片点云数据可视化

Fig. 3 Visualization of maize leaf point cloud data

预测能够得到最高的精度，MAE为0.08 g，MAPE为4.60%，RMSE为0.10 g，R^2达到了0.98。这主要是因为Laser获取的点云数据更能反映玉米叶片的特征，而DT获取的数据虽然有较多的语义信息，但点云数据较为平滑，MVS获取的数据需要对每个植株进行比例校正，这会导致玉米叶片大小出现误差，进而对玉米叶片特征的提取造成误差。MVS获取数据构建的生物量模型的MAE数值较大，为0.40 g，这主要是因为通过MVS数据获取的玉米杂交品种的生物量数值相差较大，因此相比于Laser和DT其MAE数值偏高。而将三种设备的数据融合构建的生物量预测模型的精度比DT和MVS的精度高，R^2能达到0.92，但比Laser的精度低，可见将三种数据进行整合增加样本量并不能提高生物量预测的精度。

表2 玉米叶片生物量预测精度

Table 2 Prediction accuracy of maize leaf biomass

方法	Laser				DT			
	MAE/g	MAPE/%	R^2	RMSE/g	MAE/g	MAPE/%	R^2	RMSE/g
RF	0.14	8.54	0.93	0.19	0.31	21.04	0.83	0.43
GBRT	0.10	6.21	0.96	0.14	0.26	17.41	0.86	0.40
SVR	0.09	5.45	0.97	0.13	0.26	18.51	0.86	0.39
CNN	0.09	5.17	0.97	0.12	**0.25**	**17.04**	0.87	0.38
FCNN	**0.08**	**4.60**	**0.98**	**0.10**	0.27	19.87	**0.88**	**0.36**
方法	MVS				Mix			
	MAE/g	MAPE/%	R^2	RMSE/g	MAE/g	MAPE/%	R^2	RMSE/g
RF	0.58	17.20	0.74	0.80	0.33	20.18	0.85	0.50
GBRT	0.55	13.88	0.77	0.76	0.28	19.45	0.90	0.41
SVR	**0.40**	10.44	**0.87**	0.57	0.25	**17.79**	0.91	0.39
CNN	0.42	**10.41**	**0.87**	**0.56**	0.27	18.11	0.89	0.42
FCNN	0.48	13.60	0.84	0.64	**0.24**	18.31	**0.92**	**0.36**

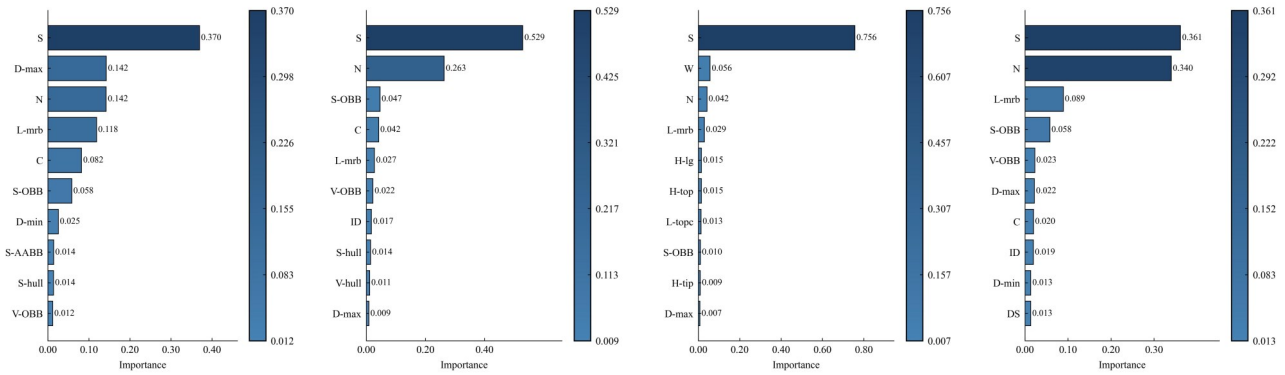
注：表中加粗数值表示相应设备与方法的组合在对应评价指标中取得的最佳结果。

2.3 玉米叶片生物量与三维形态结构关系分析

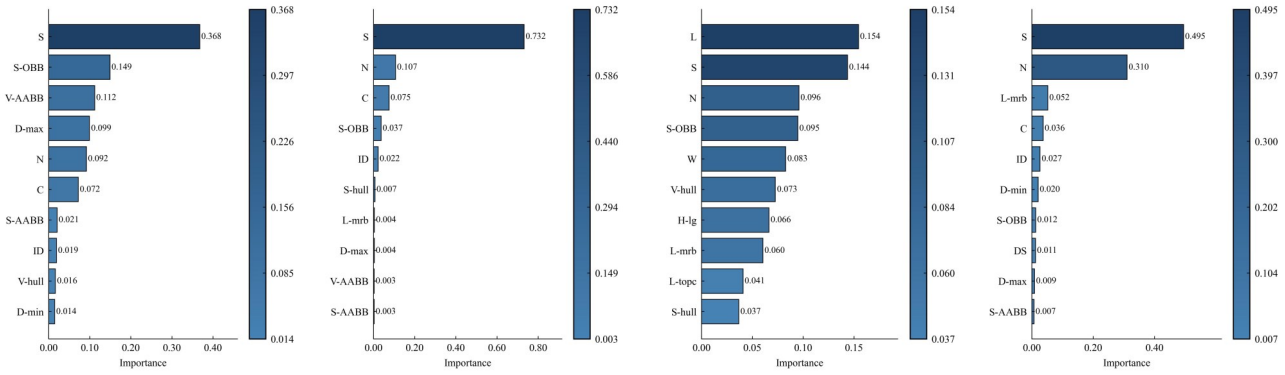
RF和GBRT两种方法拥有集成树模型的内在机制，能够对特征的重要性进行排序。运用RF默认的基于均方误差减少的方法和GBRT的基于决策树分裂累积改进的方法将最佳模型的特征重要性进行排序并将排在前10的特征进行可视化，如图4所示。叶面积S在所有特征重要性排序中均在前2位，可见叶面积S对于生物量模型的精度影响最高，也进一步证明了，玉米叶片生物量大小与叶面积S大小的相关性最高。

为了研究其他特征与玉米叶片生物量的相关性，本研究运用皮尔逊相关性分析方法将三种设备获取的数据融合构建的数据和DT数据的特征与玉米叶片生物量之间的相关性进行分析，如图5所示。

在相关性分析中，叶面积S与生物量的相关性最高，可达0.92，证明叶面积S对玉米叶片生物量的影响较高。本研究对叶片点云进行统一的体素下采样，使得尺寸较大的玉米叶片的点较多，尺寸较小的玉米叶片的点较少，因此点个数N的大小能够反映出玉米叶片尺寸的大小。在特征重要性排序中，点个数N基本在前3的位置，且点个数N与生物量的相关性最高可达0.88，可见玉米叶片尺寸的大小对玉米叶片生物量的影响较大。叶长L和叶宽W与叶片尺寸的大小十分相关，与玉米叶片生物量的相关性分别为0.77和0.86，尤其是叶长L，在使用DT设备获取数据，使用GBRT方法进行生物量预测时，经过超参数优化，叶长L的特征重要性超



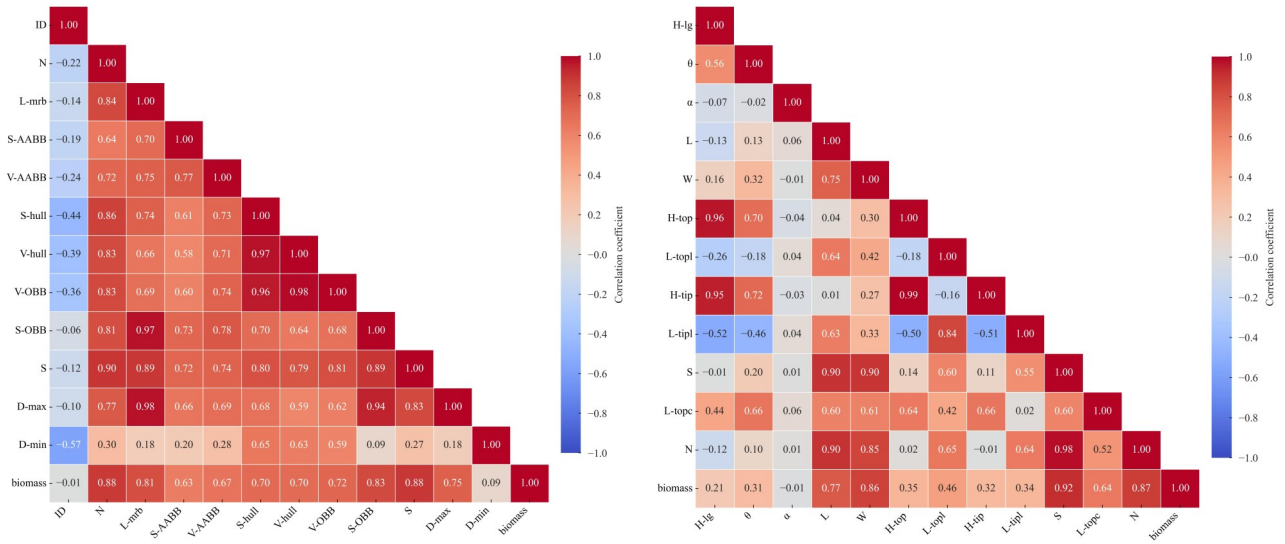
a. MVS-RF　　b. Laser-RF　　c. DT-RF　　d. Mix-RF



e. MVS-GBRT　　f. Laser-GBRT　　g. DT-GBRT　　h. Mix-GBRT

图 4　玉米叶片点云生物量特征重要性

Fig. 4　Importance of biomass characteristics of maize leaf point cloud



a. Total 相关性分析　　b. DT 相关性分析

图 5　玉米叶片点云特征与生物量的相关性分析热力图

Fig. 5　Correlation analysis between point cloud characteristics of maize leaves and biomass thermogram

过了叶面积S，如图4g所示，从而进一步论证了玉米叶片尺寸的大小与玉米叶片生物量十分相关。对于叶序ID来说，其在特征重要性权值排序中的排名并不是十分靠前，且相关性较低，仅为−0.01，而H_{lg}、L_{tipl}、L_{topl}和方位角α等与叶片高度和位置相关特征的相关性和特征重要性均较低，方位角α的相关性仅达到了−0.01，因此玉米叶片的生长高度和位置对玉米叶片生物量的影响较小。对于一些点

云特征，S_{OBB}和L_{mrb}与玉米叶片生物量的相关性较高，分别为0.83和0.81，而D_{min}与玉米叶片的生物量较低，仅为0.09。S_{OBB}和L_{mrb}等包围盒特征能够反映玉米叶片尺寸大小，D_{max}可以通过计算点云到质心的最大距离对点云大小进行数字化描述，而D_{min}不能反映玉米叶片点云的大小，仅能通过点云到质心的最小距离反映玉米叶片点云的密度。由此可见，与玉米叶片尺寸相关的特征对玉米叶片生物量的影响较大。

3 讨 论

3.1 玉米叶片生物量预测方法先进性分析

本研究的玉米叶片生物量估算方法的先进性主要体现在获取方式、数据处理和模型精度三个方面。下面将本研究与目前最先进的工作进行对比。

在数据获取方式上，LIU等[20]使用植株的吐丝期和成熟期每隔30 cm测量一次叶面积和干物质，所有器官在冠层中被切断，这种测量的方式较为耗时。JIN等[12]仅使用Laser设备获取玉米叶片点云数据，而本研究使用Laser、DT和MVS三种设备获取玉米叶片数据，并对三种设备的获取流程、数据处理和数据质量等进行评估，其中，MVS设备获取的速度最快，Laser设备获取的精度最高。如果需要快速获取玉米植株点云数据，可以选择MVS；如果需要获取高精度的点云设备可以选择Laser。

在数据处理上，LIU等[20]使用人工的方式对玉米植株进行分割，JIN等[12]使用基于体素的卷积神经网络（A Voxel-Based Convolution Neural Network, VCNN）分割单个叶片，本研究使用深度学习算法结合ClouldCompare软件手动分割得到更高精度的玉米叶片点云，高精度的玉米叶片点云更能反映玉米叶片的三维形态，因此在玉米叶片的水平上，本研究方法取得的精度较高。

在模型精度上，JIN等[12]在玉米小区、单株和叶片等多尺度上建立生物量预测模型，由于玉米小区群体生物量较大，预测误差相对较高，因此对于玉米小区群体的生物量预测精度较低，R^2仅为0.80。而精确到单株的玉米生物量预测精度R^2高达0.96，玉米叶片的生物量预测R^2仅有0.86。本研究使用四种数据集构建的玉米叶片生物量预测模型的R^2均高于0.86。其中Laser获取玉米叶片点云建立生物量预测模型的精度在几个损失中表现较好，R^2能够达到0.98，提升了0.12。

3.2 局限性和下一步工作

与以往的研究相比，本研究虽然在玉米叶片生物量预测的精度上进行了提升，但仍存在一定的局限性。下面将在数据获取、数据质量和算法几个方面介绍本研究的局限性，并对未来工作进行展望。

在数据获取方面，本研究仅获取了玉米叶片点云数据，通过对玉米叶片形态结构分析进行生物量预测，但玉米叶片的生物量与玉米叶片的颜色纹理、光谱等数据中蕴含的特征相关，本研究虽然将三种设备获取的数据进行融合构建了生物量预测模型，但相比于Laser的精度较低，且均是点云数据，因此亟需通过多源数据融合对生物量预测模型进行校准，进一步提升生物量预测的精度。本研究仅进行了玉米叶片干重的预测研究，但玉米叶片的鲜重也是农学领域关注的重点，如果能够获取到玉米叶片的光谱等数据，在后面的研究工作中也需要重点研究玉米叶片鲜重的预测方法。

在数据质量方面，玉米叶片的叶面积大小与其生物量息息相关，因此玉米叶片点云的完整性对于生物量预测来说至关重要，无论是使用Laser还是使用MVS成像获得的玉米叶片点云均有缺失，因此亟需针对玉米叶片的点云缺失情况，对点云进行补全。玉米叶片的点云形态结构具有相似性，不同品种的玉米叶片也会出现形态结构相似的情况，本研究确保了所有玉米叶片点云数据独立，没有考虑玉米叶片点云数据的相似性，希望在后续的研究中考虑玉米叶片的相似性构建生物量预测模型。

在算法方面，本研究针对点云数据提取的特征数值使用机器学习和深度学习方法进行生物量预测，但目前针对点云数据本身的深度学习方法是主流，而基于点云数据的深度学习模型大多用于解决分类和分割问题，解决回归问题的方法较少，希望未来能够针对点云深度学习回归模型进行研究。本研究的生物量预测模型是针对玉米吐丝期至灌浆期的叶片特征进行优化和验证的，当前模型和方法应用在玉米其他生育期的结果可能有所偏差，玉米叶片的生长形态和生理功能会随着不同生育期而动态变化，因此，针对不同生育期的玉米叶片生物量估算模型研究是未来工作的重点。

4 结 论

本研究使用MVS、Laser和DT三种设备获取玉米叶片点云数据，并将三种方式获取的数据进行整合，构建了四种数据集，运用了RF、GBRT和

SVR三种机器学习方法，以及CNN和FCNN两种深度学习方法进行干重生物量预测，并对玉米叶片的特征与干重生物量进行特征重要性和相关性分析。结果显示，叶面积S和点个数N与干重生物量的特征重要性较高，且相关性权值分别为0.92和0.88；使用Laser直接扫描玉米叶片获取玉米叶片点云数据，运用FCNN进行玉米叶片干重生物量预测得到了最佳模型，MAE为0.08 g，MAPE为4.60%，RMSE为0.10 g，R^2为0.98。研究表明，玉米叶片尺寸相关的特征（叶面积、点云个数、叶长和叶宽等）对玉米叶片干重生物量的精度影响最大，利用高分辨率的玉米叶片3D点云结合机器学习方法，可实现玉米叶片干重的高精度估算，为作物器官生物量无损测算提供新途径。

利益冲突声明：本研究不存在研究者以及与公开研究成果有关的利益冲突。

参考文献：

[1] 翁杨, 曾睿, 吴陈铭, 等. 基于深度学习的农业植物表型研究综述[J]. 中国科学: 生命科学, 2019, 49(6): 698-716.
WENG Y, ZENG R, WU C M, et al. A survey on deep-learning-based plant phenotype research in agriculture[J]. Scientia Sinica (Vitae), 2019, 49(6): 698-716.

[2] AKHTAR M S, ZAFAR Z, NAWAZ R, et al. Unlocking plant secrets: A systematic review of 3D imaging in plant phenotyping techniques[J]. Computers and Electronics in Agriculture, 2024, 222: 109033.

[3] KUMARI P, BHATT A, MEENA V K, et al. Plant phenomics: The force behind tomorrow's crop phenotyping tools[J]. Journal of Plant Growth Regulation, 2025, 44(5): 1791-1809.

[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.
WEN W L, GUO X Y, ZHANG Y, et al. Technology and equipment of big data on crop phenomics[J]. Strategic Study of CAE, 2023, 25(4): 227-238.

[5] MA H Y, WEN W L, GOU W B, et al. 3D time-series phenotyping of lettuce in greenhouses[J]. Biosystems Engineering, 2025, 250: 250-269.

[6] WEN W L, GU S H, ZHANG Y, et al. Standard framework construction of technology and equipment for big data in crop phenomics[J]. Engineering, 2024, 42: 175-184.

[7] 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 C J. Big data of plant phenomics and its research progress [J]. Journal of Agricultural Big Data, 2019, 1(2): 5-18.

[8] WU X, JIANG D, ZHANG F. Increasing impact of compound agricultural drought and hot events on maize yield in China[J]. Climate Research, 2023, 90: 17-29.

[9] ZHAO D, YANG H, YANG G J, et al. Estimation of maize biomass at multi-growing stage using stem and leaf separation strategies with 3D radiative transfer model and CNN transfer learning [J]. Remote Sensing, 2024, 16(16): 3000.

[10] SHU M Y, LI Q, GHAFOOR A, et al. Using the plant height and canopy coverage to estimation maize aboveground biomass with UAV digital images[J]. European Journal of Agronomy, 2023, 151: 126957.

[11] 周敏姑, 闫云才, 高文, 等. 基于多光谱遥感和CNN的玉米地上生物量估算模型[J]. 农业机械学报, 2024, 55(9): 238-248.
ZHOU M G, YAN Y C, GAO W, et al. Estimating aboveground biomass of maize based on multispectral remote sensing and convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(9): 238-248.

[12] JIN S C, SU Y J, SONG S L, et al. Non-destructive estimation of field maize biomass using terrestrial LiDAR: An evaluation from plot level to individual leaf level[J]. Plant Methods, 2020, 16: 69.

[13] WANG C, NIE S, XI X H, et al. Estimating the biomass of maize with hyperspectral and LiDAR data[J]. Remote Sensing, 2017, 9 (1): 11.

[14] LI W, NIU Z, HUANG N, et al. Airborne LiDAR technique for estimating biomass components of maize: A case study in Zhangye city, Northwest China[J]. Ecological Indicators, 2015, 57: 486-496.

[15] 樊鸿叶, 李姚姚, 卢宪菊, 等. 基于无人机多光谱遥感的春玉米叶面积指数和地上部生物量估算模型比较研究[J]. 中国农业科技导报, 2021, 23(9): 112-120.
FAN H Y, LI Y Y, LU X J, et al. Comparative analysis of LAI and above-ground biomass estimation models based on UAV multi-spectral remote sensing[J]. Journal of Agricultural Science and Technology, 2021, 23(9): 112-120.

[16] 王毅, 薛蓉, 韩文霆, 等. 基于CNN-LSTM-SA的玉米地上生物量估算[J]. 智慧农业(中英文), 2025, 7(4): 159-173.
WANG Y, XUE R, HAN W T, et al. Estimation of maize aboveground biomass based on CNN-LSTM-SA[J]. Smart Agriculture, 2025, 7(4): 159-173.

[17] ZHU W X, SUN Z G, PENG J B, et al. Estimating maize above-ground biomass using 3D point clouds of multi-source unmanned aerial vehicle data at multi-spatial scales[J]. Remote Sensing, 2019, 11(22): 2678.

[18] 亚森·吐尔迪, 阿丽亚·拜都热拉, 祖力甫哈尔·阿不都沙拉木, 等. 新疆农业大学校园内常见绿化树种叶片生物量估算[J]. 中国农学通报, 2017, 33(25): 48-51.
YASIN·TURDI, ALIYA·BAIDOURELA, ZULUPKAR·ABDUSALAM, et al. Leaf biomass estimation of common greening tree species in Xinjiang agricultural university campus[J]. Chinese Agricultural Science Bulletin, 2017, 33(25): 48-51.

[19] VUORINNE I, HEISKANEN J, PELLIKKA P K E. Assessing leaf biomass of *Agave sisalana* using Sentinel-2 vegetation indices[J]. Remote Sensing, 2021, 13(2): 233.

[20] LIU G Z, HOU P, XIE R Z, et al. Canopy characteristics of high-yield maize with yield potential of 22.5 Mg ha^{-1}[J]. Field Crops Research, 2017, 213: 221-230.

[21] WU S, ZHANG Y, ZHAO Y X, et al. Using high-throughput phenotyping platform MVS-Pheno to decipher the genetic architecture of plant spatial geometric 3D phenotypes for maize[J]. Computers and Electronics in Agriculture, 2024, 225: 109259.

[22] XU H, WU X L, ZHANG X. 3DGS compression with sparsity-guided hierarchical transform coding[EB/OL]. arXiv: 2505.22908, 2025.

[23] 朱荣胜, 李帅, 孙永哲, 等. 作物三维重构技术研究现状及前景展望[J]. 智慧农业(中英文), 2021, 3(3): 94-115.
ZHU R S, LI S, SUN Y Z, et al. Research advances and prospects of crop 3D reconstruction technology[J]. Smart Agriculture, 2021, 3(3): 94-115.

[24] SONG H L, WEN W L, WU S, et al. Comprehensive review on 3D point cloud segmentation in plants[J]. Artificial Intelligence in Agriculture, 2025, 15(2): 296-315.

[25] WEN W L, WANG J L, ZHAO Y X, et al. 3D morphological feature quantification and analysis of corn leaves[J]. Plant Phenomics, 2024, 6: 225.

[26] WU Y D, WEN W L, GU S H, et al. Three-dimensional modeling of maize canopies based on computational intelligence[J]. Plant Phenomics, 2024, 6: 0160.

[27] WEN W L, WU S, LU X J, et al. Accurate and semantic 3D reconstruction of maize leaves[J]. Computers and Electronics in Agriculture, 2024, 217: 108566.

[28] MIAO T, WEN W L, LI Y L, et al. Label3DMaize: Toolkit for 3D point cloud data annotation of maize shoots[J]. GigaScience, 2021, 10(5): giab031.

[29] LI Y L, WEN W L, MIAO T, et al. Automatic organ-level point cloud segmentation of maize shoots by integrating high-throughput data acquisition and deep learning[J]. Computers and Electronics in Agriculture, 2022, 193: 106702.
[30] 温维亮, 郭新宇, 赵春江, 等. 基于三维数字化的玉米株型参数提取方法研究[J]. 中国农业科学, 2018, 51(6): 1034-1044.
WEN W L, GUO X Y, ZHAO C J, et al. Research on maize plant type parameter extraction by using three dimensional digitizing data[J]. Scientia Agricultura Sinica, 2018, 51(6): 1034-1044.

Point Cloud Data-driven Methods for Estimating Maize Leaf Biomass

WU Zhangbin[1,2,3], HE Ning[3], WU Yandong[3], GUO Xinyu[1,3], WEN Weiliang[1,2,3*]

(1. *Information Technology Research Center*, *Beijing Academy of Agriculture and Forestry Sciences*, *Beijing* 100097, *China*; 2. *College of Information and Electrical Engineering*, *Shenyang Agricultural University*, *Shenyang* 110161, *China*; 3. *Beijing Key Lab of Digital Plant*, *National Engineering Research Center for Information Technology in Agriculture*, *Beijing* 100097, *China*)

Abstract: [Objective] Maize leaf dry biomass is a key trait that reflects plant morphology, growth vigor, and physiological processes including photosynthetic production. Its dynamic changes can effectively characterize the growth status of maize. Accurate estimation of maize leaf dry biomass is crucial for accurately predicting maize yield and informing production management decisions. Extensive research on crop dry biomass estimation indicates that 3D point cloud data characterizing crop morphological structure, along with features derived therefrom, exhibit an extremely high correlation with crop dry biomass. However, traditional dry biomass prediction studies focus primarily on the population canopy scale, and lack effective prediction methods for dry biomass at the plant and organ scales. Research on non-destructive measurement methods for maize leaf dry biomass, based on 3D point clouds and machine learning, the demand is conducted to address for rapid acquisition of organ-level dry biomass information in maize cultivation and management research. **[Methods]** Maize leaf point cloud data were acquired using three techniques: Multi-view stereo (MVS), LiDAR scanning, and 3D digitalization (DT). The leaf point clouds underwent preprocessing steps that included plant segmentation, denoising, mesh refinement, and uniform subsampling. Subsequently, morphological traits were extracted from the processed data, including leaf length, leaf area, bounding box dimensions, and the number of points contained within the leaf point clouds. Three machine learning methods: random forest (RF), gradient boosting regression tree (GBRT), and support vector regression (SVR), as well as two deep learning methods: convolutional neural network (CNN) and fully connected neural network (FCNN), were employed for predicting maize leaf dry weight. A point cloud-based maize leaf dry biomass prediction model was subsequently developed. This study utilized the mean squared error reduction method inherent to RF and the cumulative improvement method based on decision tree splits in GBRT to rank and visualize feature importance for optimal models. The resulting rankings were then visualized. Simultaneously, Pearson correlation analysis was used to analyze the correlations of the features from the fused dataset (integrating data from the three devices) as well as those from the DT data with maize leaf dry biomass. **[Results and Discussions]** The results demonstrated that, among the dry biomass prediction models developed in this study, the model based on Laser point cloud data and the FCNN method achieved the highest accuracy, with a mean absolute error (MAE) of 0.08 g, a mean absolute percentage error (MAPE) of 4.60%, a root mean square error (RMSE) of 0.10 g, and a coefficient of determination (R^2) of 0.98. In the correlation analysis, the leaf area exhibited the strongest correlation with dry biomass (r = 0.92), followed by the number of points (r = 0.88), leaf width (r = 0.86), and leaf length (r = 0.77). In the feature importance ranking, the leaf area trait consistently ranked within the top two positions, whereas the number of points ranked among the top three in most cases. However, features such as the height of the leaf base above the ground, the horizontal distances from the leaf tip and apex to the stem, and the azimuth angle demonstrated low correlations with dry biomass and low feature importance. **[Conclusions]** Among all the maize leaf features investigated in this study, size-related traits (such as leaf area, point count, leaf length, and leaf width) had the greatest impact on the accuracy of dry biomass estimation. The utilization of high-resolution 3D point clouds of maize leaves, combined with machine learning methods, enabled a high-accuracy estimation of leaf dry weight and provided a novel approach for the non-destructive measurement of dry biomass in crop organs.

Key words: maize leaves; 3D point cloud; machine learning; biomass prediction; deep learning

Foundation items: The Science and Technology Project of the Ministry of Agriculture and Rural Affairs; National Natural Science Foundation of China (32572199); National Key Research and Development Program (2022YFD2001003)

First author: WU Zhangbin, E-mail: wuzhangbin163@163.com
***Corresponding author:** WEN Weiliang, E-mail: wlwen37@163.com