

基于无人机图像和改进 YOLOv8 的烟草植株株高检测

南德旺¹, 李军营², 梁虹¹, 马二登², 张宏², 肖恒树¹

(1. 云南大学 信息学院, 昆明 650504; 2. 云南省烟草农业科学研究院, 昆明 650504)

摘要: 针对烟草植株高通量株高数据获取困难问题, 提出一种基于无人机图像与改进 YOLOv8 的大田烟株株高检测方法; 该方法运用无人机倾斜摄影获取大田烟株图片生成三维模型, 提取高程信息; 并采用一种轻量级 DSW-YOLOv8n 算法, 通过结合组卷积与异构卷积的 DualConv 轻量化卷积模块代替主干 C2f 卷积模块, 以减少模型参数量; 提出一种由空间深度转换卷积和 VoV-GSCSP 构造的 SV-neck 代替 neck, 提高检测精度; 引入 WIOU 损失函数加快模型收敛速度, 以实现植株中心位置检测, 对应得到株高; 经过实验测试, 该算法较原始模型参数量下降 18.1%, 模型大小减少 15.9%, mAP_{50} 为 98.4%, $mAP_{50\sim 95}$ 为 63.1%, 较原始模型分别提高 2.1%, 1.6%; 株高估计值与实测值拟合直线斜率为 1.09, R^2 为 0.88, 实现对大田烟草植株株高的高通量检测。

关键词: 大田烟株; 株高检测; YOLOv8; 高通量; 三维建模; 无人机倾斜摄影

Tobacco Plant Height Detection Based on Drone Images and Improved YOLOv8

NAN Dewang¹, LI Junying², LIANG Hong¹, MA Erdeng², ZHANG Hong², XIAO Hengshu¹

(1. School of Information Science and Technology, Yunnan University, Kunming 650504, China;

2. Yunnan Academy of Tobacco Agricultural Sciences, Kunming 650504, China)

Abstract: It is difficult to obtain high-throughput plant height data of tobacco plants. To address this issue, a field tobacco plant height detection method based on UAV images and improved YOLOv8 is proposed. This method adopts UAV tilt photography to obtain the images of field tobacco plant to generate a three-dimensional model and extract elevation information; By using the lightweight DSW-YOLOv8n algorithm and combining group convolution and heterogeneous convolution, the DualConv lightweight convolution module is replaced with the backbone C2f convolution module to reduce training parameters. A SV-neck constructed by spatial depth conversion convolution and VoV-GSCSP is proposed to replace the neck to improve detection accuracy. The WIOU loss function is introduced to accelerate the convergence speed of the model, so as to detect the center position of the plant and obtain the height of the plant. After experimental testing, and compared with the original model, the parameters of the algorithm are reduced by 18.1%, the model size by 15.9%, the mAP_{50} by 98.4%, the $mAP_{50\sim 95}$ by 63.1%, and the mAP_{50} and $mAP_{50\sim 95}$ of the model are 2.1% and 1.6% higher than those of the original model. The fitting slope between the estimated and measured values of plant height is 1.09, and the R^2 is 0.88, which realizes high-throughput detection of tobacco plant height in the field.

Keywords: field tobacco plant; plant height detection; YOLOv8; high throughput; 3D modeling; drone oblique photography

0 引言

烟草是以收获叶片器官为目的的特殊经济作物, 在我国国民经济中占有重要的地位。近几十年来, 我国烟草事业取得长足进步, 全国烟草种植面积及烟叶产量均居世界首位^[1]。一般来说, 烟叶产量与其自身的植株高度、叶片数、叶片面积等表型性状显著相关, 烟株表型

研究是烟草长势监测、产量预估及育苗育种的重要内容。在众多表型中, 株高一直是作物学研究的重点, 传统的基于田间人工作业的株高获取方法周期长、效率低、成本高, 无法满足高通量快速获取大田烟株表型获取的要求^[2]。随着植物表型数据研究技术的提升, 研究人员越来越关注如何利用这些数据来监测作物长势、改进育苗育种, 目前基于无人机与机器学习的株高测量逐

收稿日期: 2024-05-23; 修回日期: 2024-07-03。

基金项目: 中国烟草总公司云南省公司科技计划项目(2021530000241025)。

作者简介: 南德旺(2000-), 男, 硕士。

梁虹(1965-), 女, 硕士, 教授。

引用格式: 南德旺, 李军营, 梁虹, 等. 基于无人机图像和改进 YOLOv8 的烟草植株株高检测[J]. 计算机测量与控制, 2025, 33(7): 19-26.

渐开展。石文强^[3]等人利用无人机获取大豆田间影像及数字模型,并结合克里金插值算法获取大豆株高。赵永杰^[4]等人利用 RGB 图像获取玉米幼苗影像,并利用单目深度估计技术获取幼苗最高点和附近地面深度完成玉米株高的测量;刘建春^[5]等人提出一种估测水稻株高的基于无人机的多光谱植被指数的模型,实现了水稻株高的测量;张宏鸣^[6]等人结合无人机与骨架算法获取玉米植株高度。然而在烟草领域,由于烟草表型数据的不足,对高通量表型数据获取技术的研究和探索还相对较少,烟草产业在智能化育种和产值预估方面缺乏决策支持。因此,如何在保证数据精度的同时,实现高通量、低成本的大田烟草株高快速获取,成为烟草行业亟需解决的问题。

为此,本文提出一种基于无人机影像和深度学习的烟草植株株高获取方法,通过将无人机影像与目标检测模型相结合实现对大田中的烟草植株株高的测算,实现了低成本、高精度的高通量株高数据获取,为现代化农业提供了可靠的技术支持,为烟草农业的数字化和智能化育苗育种提供了技术支撑。

1 数据处理

本研究选择云南省玉溪市澄江市的烟草种植基地作为实验区域。该地区气候条件适宜,光照充足,且雨热同期,有利于烟草植株的生长发育^[7]。并且该地地势平坦,有利于无人机对大范围烟草数据进行采集与分析。

本研究采用配备有 2 000 万像素相机的大疆无人机 PHANTOM 4 PRO 无人机进行烟草数据的采集,其最大分辨率为 $5\,472 \times 3\,956$,焦距为 9 mm,采集过程分为两个阶段。第一阶段为烟草植株数据三维建模阶段,以试验田标记好的位置为兴趣点进行环绕飞行,拍摄不同高度及角度的图像。第二阶段为烟草植株检测数据采集阶段,通过设置无人机相关参数获取大面积烟草正射影像。从中分割出单个烟草植株的正射影像,并采用 LabelImg 工具其中心进行标注,标注标签为 'center',制成烟草数据集,如图 1 所示。每个标注好的矩形框,会生成包含了相应图像中目标烟草植株像素的位置和标签信息的 txt 文件,并按照 7:2:1 的比例将标注好的数据划分为训练集、测试集和验证集。训练集包含 70% 的数据,用于模型的训练过程。测试集占 20%,用于评估模型的性能和准确度。验证集占 10%,用于调整模型的超参数以及验证模型的泛化能力。

2 研究方法

本研究主要分为四步,第一步首先将无人机倾斜摄影得到的大田烟草植株图片导入 ContextCapture 软件进行三维重建,生成大田烟草植株三维模型,并生成区域内数字正射影像和包含高程信息的数字表面模型,进一




图 1 烟草植株中心标注数据集

步导出单个烟草植株的数字正射影像 (DOM, digital orthophoto map) 及数字表面模型 (DSM, digital surface model); 第二步利用改进的 DSW-Yolov8n 算法对标注好的烟草植株中心数据集进行训练,得到训练好的模型;第三步利用训练好的模型对第一步生成的单个烟草正射影像进行植株中心检测,输出每株烟草的中心位置。第四步将中心位置与数字表面模型进行对应,得到对应位置的高程信息即株高。技术路线如图 2 所示。

2.1 三维数据生成

使用 ContextCapture 软件对无人机倾斜摄影得到的烟草植株图片进行三维建模,包括生成三维点云、数字正射影像和数字表面模型。具体流程如图 3。首先,将由无人机拍摄的建模图像导入 ContextCapture,自动对照片位置坐标信息进行读取;然后,检查影像文件的完整性,提交第一次空三运算,运算结束后导入像控点进行刺点,随后提交第二次空三运算;完成运算后,根据需要进行分块设置,生成烟草植株三维模型;接着生成区域内烟草植株正射影像及数字表面模型;最后导出单个植株的数字正射影像和数字表面模型,如图 4 所示,以便于高程信息的读取。

2.2 Yolov8 简介

目前目标检测算法如 Mask R-CNN^[8]、Faster R-CNN^[9]、SSD^[10]、FCOS^[11] 和 YOLO^[12] 系列等以单阶段、双阶段、有锚框和无锚框等特点而著名。Mask R-CNN 和 Faster R-CNN 是基于候选区域的两阶段算法,检测精度高但速度较慢。相比之下,SSD、FCOS 和 YOLO 系列等基于回归的单阶段算法则不使用候选区域,因此具有更快的检测速度和更好的实时性。为了实现大规模高效率的烟草植株株高检测,我们选择了最新的 Yolov8^[13] 模型,它综合了 YOLO 系列的优势,能够快速准确地检测烟草植株。

Yolov8 主要由输入、特征提取骨干、特征融合颈部和检测头四部分组成。输入端采用自适应图片缩放和 Mosaic 数据增强,可以有效提升模型的鲁棒性。主干




图 2 株高获取方法




图 3 三维建模流程

网络由 C2f (Cross Stage Fusion)、SPPF (Spatial Pyramid Pooling Fusion) 和 CBS (Convolution, Batch Normalization, SiLU Activation) 模块组成, C2f 模块与 YOLOv5 的 C3 模块相比, 通过增加了跳层连接和额外的 Split 操作丰富模型的梯度流。SPPF 模块的核心思想是针对输入特征图进行金字塔池化操作, 从不同尺度上提取特征信息。通过金字塔池化, 模块可以感受到不同尺度上的上下文信息, 使得模型能够对不同尺度的目标进行更好的识别和定位。CBS 模块主要由卷积模块、批




图 4 单个烟草植株数字正射影像

归一化模块和 SiLU 激活函数组成, 它可以提高模型的稳定性和收敛速度。在颈部部分, 采用自顶向下和自下向顶的跨层连接, 可以更充分融合提取到的特征。在检测头部分, 采用解耦头将检测和分类任务分离。这种结构的好处是可以灵活地调整不同任务的权重, 以适应不同任务的需求, 进而有效提升模型的性能。YOLOv8 的网络结构如图 5 所示。

目前, YOLOv8 官方代码中给出 n 、 s 、 m 、 l 、 x 共 5 个不同网络宽度和深度的版本。它们的网络深度和宽度依次递增, 检测速度及精度也依次增加, 为了实现高精度轻量化检测, 本研究选取 Yolov8n 模型作为基线模型进行改进。

2.3 DSW-Yolov8n 算法

由于烟草植株高度获取工作对实时性和精确性有一定要求, 如何实现符合烟草植株特点的低成本、高通量、高精度的快速获取成为问题的关键。目前大多数深度学习模型能够对多种物体实现一定精度的检测, 但对特定目标的检测性能不够突出。

为此, 本文提出一种改进 DSW-Yolov8n 算法, 其以 Yolov8n 为基线模型, 用 DualConv^[14] 卷积模块替换主干中的 C2f 卷积模块, 降低模型参数量; 并设计一种融合空间到深度卷积 (space-to-depth convolution, SPD-Conv)^[15] 和 VoV-GSCSP^[16] 的新型颈部 SV-neck 代替原有模型的颈部, 将图形空间信息转换成深度信息, 使模型更加有效的融合图像特征, 提高对烟草植株中心小目标的检测能力, 在提高模型检测精度的基础上进一步降低参数量, 实现模型的轻量化; 最后采用 WIOU (Wise-IoU)^[17] 损失函数代替原有 CIOU 损失函数, 加快模型收敛速度, 有效提高模型的检测性能, 实现烟草植株株高的高精度快速获取。改进后的 Yolov8 模型结构如图 6 所示。




图 5 YOLOv8 结构图




图 6 改进的 YOLOv8 结构图

2.3.1 DualConv 轻量化卷积模块

YOLOv8 采用的 C2f 模块含有更多的 Bottleneck 结构，在提取更多特征的同时导致了通道信息的过度冗余，增加模型计算量，为此，本文选用 DualConv 轻量化卷积模块代替 C2f 模块，降低模型参数量，实现轻

量化。

DualConv 是一种创新型网络结构，旨在构建轻量级深度神经网络。它融合了异构卷积（HetConv）^[18] 和组卷积（Group Convolution）技术，其结构如图 7 所示。在 DualConv 中， 3×3 卷积核被用于提取特征图的空间特征， 1×1 卷积核则被用来整合这些特征，并减少模型参数。图中描绘了 3×3 和 1×1 卷积核在输入特征映射通道上的并行布局，其利用组卷积技术将卷积核分组，并在同一组内并行使用不同尺寸的卷积核，这样有利于同时利用大尺寸卷积核的空间特征提取能力和小尺寸卷积核的计算能力，从而在确保准确性的同时减少模型的参数量和计算成本。将该模块代替 YOLOv8n 模型主干中的 C2f 卷积模块，以实现模型的轻量化。

2.3.2 融合 SPD-Conv 和 VoV-GSCSP 的 SV-neck

SV-neck 是一种通过将图像空间信息转换成深度信息，使模型更加有效的学习图像特征以提高准确度的技术，是 SPD-Conv 和 VoV-GSCSP 基础上的进一步融合。其在 neck 中将 SPD-Conv 代替 C2f 卷积模块，并使用 VoV-GSCSP 代替 neck 中的 C3 模块，构成 SV-neck，在提升精度的同时降低模型参数量。

由于传统 CNN 架构中的步长卷积层和池化层在处理低分辨率图像或小物体时会导致细粒度信息丢失，






图 7 DualConv 卷积结构图

SPD-Conv 是替代它们的一种新的 CNN 架构, 其结构如图 8 (a) 所示。SPD-Conv 使用空间到深度 (SPD) 层, 该层将特征图的空间维度转换成深度维度, 以此来增加通道数, 同时减少空间分辨率。随后是非步长卷积层, 它进一步处理重新排列后的特征图, 确保有效特征的提取和使用, 从而提高模型对于小物体和低分辨率图像的识别性能。

VoV-GSCSP 是基于 GS-Conv^[19] 和跨级部分的网络结构, 其结构图如图 8 (b) 所示, 在 VoV-GSCSP 网络中, GSConv 被用来代替传统的卷积操作, 将 2 个 GSConv 模块进行串联, 使用 VoV-GSCSP 来代替颈部网络中的 C3 结构, 将不同尺度的特征图按照顺序连接起来形成一个更长的特征向量, 以增加模型的多样性, 跨级部分则用来增加网络的深度和非线性能力, 融合结果以期在降低模型计算量的同时, 提高模型精度。



(a) SPD-Conv 卷积结构图



(b) VoV-GSCSP 网络结构

图 8 SV-neck 中各个模块结构图

2.3.3 Wiou 损失函数

Yolov8 采用的损失函数为 CIOU^[20] 损失函数, 它

考虑了目标框之间的完整交叉, 并引入了修正因子以更准确的度量目标框之间的准确性, 其中 CIOU 的计算公式如式 (5):

$$IOU = \frac{S_o}{S_u} \quad (1)$$

$$v = \frac{4 \times \left(\arctan \frac{w_G}{h_G} - \arctan \frac{w_P}{h_P} \right)^2}{\pi^2} \quad (2)$$

$$\alpha = \frac{v}{(1 - IOU) + v} \quad (3)$$

$$CIOU = IOU - \frac{d^2}{c^2} - \alpha v \quad (4)$$

$$Loss_{CIOU} = 1 - IOU + \frac{d^2}{c^2} + \alpha v \quad (5)$$

式中, s_o 为预测框与真实框交集区域面积, s_u 为两个框并集区域面积, w_G 为真实框的宽, h_G 为真实框的高, w_P 为预测框的宽, h_P 为预测框的高, v 为修正因子, α 为权重系数, d 为两框中心点的距离, c 为两框最小外接矩形的对角线距离。

但 CIOU 损失函数无法精确反应两个框之间重合度的大小, 导致模型收敛速度较慢且预测不准确。因此 EIOU^[21] 损失函数被提出, 与 CIOU 不同的是, 它通过将预测框和真实框的纵横比的影响因子拆开以计算预测框和真实框的长和宽, 其计算公式如式 (6):

$$L_{EIOU} = L_{IOU} + L_{dis} + L_{asp} = 1 - IOU + \frac{p^2(b_G, b_P)}{c_w^2 + c_h^2} + \frac{p^2(w_G, w_P)}{c_w^2} + \frac{p^2(h_G, h_P)}{c_h^2} \quad (6)$$

式中, L_{IOU} 为 IOU 损失, L_{dis} 为距离损失, L_{asp} 为边长损失, b_G, b_P 分别为真实框和预测框的中心点, c_w 和 c_h 为预测框和真实框最小围框的宽和高。

但由于 EIOU 的聚焦机制是静态的, 不能充分利用单调聚焦机制, 因此 WIou 损失函数被提出, 它使用“离群度”代替原有的 IOU 对锚框进行质量评估, 并利用梯度分配增益策略减小低质量图片产生的有害梯度, 成功克服了目标模糊难以检测等问题。其计算公式如式 (10) 所示:

$$\beta = \frac{L_{\text{IOU}}^*}{L_{\text{IOU}}} \in [0, +\infty) \quad (7)$$

$$r = \frac{\beta}{\delta \alpha^{\beta-\delta}} \quad (8)$$

$$R_{\text{WIOU}} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(c_w^2 + c_h^2)}\right) \quad (9)$$

$$L_{\text{WIOU}} = r \times R_{\text{WIOU}} \times L_{\text{IOU}} \quad (10)$$

式中, x_{gt}, y_{gt} 为真实框中心点坐标, x, y 为预测框中心点坐标, β 为离群度, 其越小边框质量越高, r 为非单调聚焦参数, α 和 δ 为超参数, 它们的取值可以根据不同模型和数据集进行更改。

3 实验结果与分析

3.1 实验环境及配置

本文实验在 ubuntu20.04 操作系统下进行, python 版本 3.8, 采用 PyTorch 1.10.0 深度学习框架。详细数据见表 1。

表 1 实验环境

类别	参数
系统	ubuntu20.04
CPU	18 vCPU AMD EPYC 9754 128-Core Processor
GPU	RTX 4090D
Cuda	11.3
内存	24 GB

3.2 评价指标

评估模型的好坏可以从准确率、召回率、平均精确度 (AP, average precision) 和平均精度均值 (mAP, mean Average Precision) 等多个方面进行。其中, 准确率衡量了模型在预测为正样本中的正确率, 计算公式如公式 (11); 召回率衡量了模型对真正样本的覆盖率, 计算公式如公式 (12); AP 表示不同召回率下的平均精确率, 计算公式如公式 (13); 而 mAP 是所有类别下 AP 的平均值, 计算公式如公式 (14)。这些指标综合考虑了模型的精确性、完整性和整体性能, 在评估模型的质量时提供了全面的参考。其计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (11)$$

$$R = \frac{TP}{TP + FN} \quad (12)$$

$$AP = \sum_{i=1}^{Rank} (R_i - R_{i-1}) \times P_i \quad (13)$$

$$mAP = \frac{\sum_{i=1}^K AP_i}{K} \quad (14)$$

式中, R 为召回率; P 为准确率; TP 为预测值和真实值都为正样本; TN 为预测值和真实值都为负样本; FP 为预测值为正样本, 真实值为负样本; FN 为预测值为负样本,

真实值为正样本; $Rank$ 为模型迭代; N 为样本类别数。

3.3 实验结果分析

本文以 YOLOv8n 为基线模型, 对烟草植株数据集进行训练, 输入网络图像的尺寸设置为 640×640 , batch-size 设置为 1, 即模型根据 GPU 内存自动设置批处理图像数目, 初始学习率为 0.01, 训练轮次 epoch 为 300。在训练阶段, 采用 ultralytics 官方给出的预训练权重进行训练。

3.3.1 轻量化卷积模块选择实验

为了选取较优的轻量化卷积模块, 本文分别将文献 [22] 提出的 C2f-msblock、文献 [23] 提出的 C2f-faster、cspcc、文献 [24] 提出的 C2f-DSCov、DualConv 卷积模块替换主干中 C2f 模块进行实验。实验结果如表 2 所示。DualConv-YOLOv8n 模型相较于 C2f-msblock-YOLOv8n 模型 mAP 提升 2.9%, 准确率提升 3.3%, 模型减小 8.1%, 参数量减小 3.8%; 相较于 C2f-faster-YOLOv8n 和 cspcc-YOLOv8n, 虽然模型大小和参数量略有升高, 但 mAP 分别提高 1.9%、1.4%, 准确率分别提高 2.1%、0.9%; 相较于 C2f-DSCov-YOLOv8n, 准确率下降 0.6%, 但 mAP 提高 1.1%, 模型大小减小 21.9%, 参数量减少 22.1%。综上, 本文选取 DualConv 卷积模块替代模型主干中 C2f 卷积模块对模型进行轻量化改进。

表 2 不同卷积实验结果

模型	mAP/%	Precision/%	大小/MB	参数量
C2f-msblock-YOLOv8n	94.4	93.2	6.2	2 794 115
C2f-faster-YOLOv8n	95.3	94.3	5.6	2 646 275
cspcc-YOLOv8n	95.8	95.4	5.6	2 652 531
C2f-DSCov-YOLOv8n	96	96.9	7.3	3 448 571
DualConv-YOLOv8n	97.1	96.3	5.7	2 687 139

3.3.2 损失函数选择实验

为了选取最优损失函数, 本文分别将 CIOU、EIOU、GIOU、SIOU 和 WIOU 作为模型损失函数进行实验, 实验结果如表 3 所示。WIOU 损失函数与 CIOU 损失函数相比, mAP 提高 1%, mAP (50~95) 提高 0.3%, 准确率提高 0.5%; 与 EIOU 损失函数相比, mAP 提高 0.8%, mAP (50~95) 提高 1.4%, 召回率提高 2.9%, 准确率提高 0.3%; 与 GIOU 损失函数相比, mAP 提高 0.7%, mAP (50~95) 提高 10.1%, 准确率提高 1.6%; 与 SIOU 损失函数相比, mAP 提高 0.3%, 召回率提高 1.5%, 准确率提高 0.2%。综上, WIOU 函数性能皆高于其他损失函数, 本文选取 WIOU 损失函数作为模型的损失函数。

3.3.3 消融实验

为了验证每个改进模块的有效性, 本文进行了消融实验, 得到的结果如表 4 所示。由表可以看出, 本文所

表 3 不同损失函数实验结果

模型	mAP/%	mAP(50~95)/%	召回率/%	准确率/%
CIoU-Yolov8n	97.4	63.9	97.3	97
EIoU-Yolov8n	97.6	63.2	94.6	97.2
GIoU-Yolov8n	97.7	58.2	97.3	96
SIoU-Yolov8n	98.1	63.4	95.9	97.3
WIoU-Yolov8n	98.4	63.1	97.3	97.5

做第一个改进将 DualConv 卷积替换 C2f 卷积， mAP_{50} 较基线模型提升 0.7%， mAP （50~95）提升 1.5%，召回率提升 1.4%，准确率提升 0.9%，模型减小 9.5%，参数量减少 10.7%；本文方法第二个改进将 SV-neck 代替 neck， mAP_{50} 提升 0.3%， mAP （50~95）虽未提升但召回率和准确率分别提升 2.7%和 0.7%，模型大小减少 7%，参数量减少 8.3%；引入 WIoU 损失函数后 mAP_{50} 提升 1%，准确率提高 0.5%。

表 4 消融实验

模型	Dual Conv	SV-neck	WIoU	mAP 50/%	mAP(50~95)/%	召回率/%	准确率/%	大小 /Mb	参数量
Y1	×	×	×	96.4	62.1	93.2	95.4	6.3	3 011 043
Y2	✓	×	×	97.1	63.6	94.6	96.3	5.7	2 687 139
Y3	✓	✓	×	97.4	63.5	97.3	97	5.3	2 465 091
Y4	✓	✓	✓	98.4	63.1	97.3	97.5	5.3	2 465 091

3.3.4 不同模型对比实验

为了验证本文模型的有效性，将本文方法与 Faster R-CNN、Yolov5s、文献 25 所提方法 BGW-Yolov8n、文献 26 所提方法 FEV-Yolov8n 目标检测方法进行对比，其中 Faster R-CNN 为两阶段目标检测算法代表算法，Yolov5 为 Yolov8 前代模型，BGW-Yolov8n 和 FEV-Yolov8n 为其他文献中性能较好算法。为了验证本文算法的可行性，在保持其他实验条件一致的情况下进行对比实验，实验结果如表 5 所示。本文算法与基线模型 Yolov8n 相比， mAP_{50} 较基线模型提升 2 个百分点， mAP （50~95）提升 1 个百分点，召回率提升 4.1 个百分点，准确率提升 2.1 个百分点，模型减小 15.9%，参数量减少 18.1%；与 Faster R-CNN 相比 mAP_{50} 较基线模型提升 7.8 个百分点，召回率提升 4 个百分点，准确率提升 25.8 个百分点；与 Yolov5s 相比， mAP_{50} 提升 3.7 个百分点， mAP （50~95）提升 9.5 个百分点，召回率提升 2.7 个百分点，准确率提升 4.9 个百分点，模型减小 63.2%，参数量减少 64.9%；与 BGW-Yolov8n 相比，虽然 mAP （50~95）下降 0.8 个百分点，但 mAP_{50} 提升 2.3 个百分点，召回率提升 5.4 个百分点，准确率提升 0.5 个百分点，模型减小 22.1%，参数量减少 23.6%；与 FEV-Yolov8n 相比， mAP_{50} 提升 0.3 个百分点， mAP （50~95）提升 5.6 个百分点，

召回率提升 0.2 个百分点，准确率提升 0.2 个百分点，模型减小 5.3%，参数量减少 7.4%；综上，本文提出的算法 DSW-Yolov8n 在多个指标方面均优于其他算法。

表 5 不同模型对比

模型	mAP 50/%	mAP(50~95)/%	召回率/%	准确率/%	大小 /Mb	参数量
Yolov8n	96.4	62.1	93.2	95.4	6.3	3 011 043
Faster R-CNN	90.6	50.7	93.3	71.7	35.7	136 832 634
Yolov5s	94.7	53.6	94.6	92.6	14.4	7 022 326
BGW-Yolov8n	96.1	63.9	91.9	97	6.8	3 223 647
FEV-Yolov8n	98.1	57.5	97.1	97.3	5.6	2 660 115
DSW-Yolov8n (Ours)	98.4	63.1	97.3	97.5	5.3	2 465 091

3.4 株高测定

为了评估烟草植株株高测定结果的优劣，我们对无人机数据采集区域内的 50 株烟草植株进行人工测高，并通过本文方法进行株高估算，将模型估计株高与人工实测株高进行相关性分析，生成的 R^2 、RESM 和拟合曲线如图 9 所示。图中 x 轴为人工实测值， y 轴为模型估算值，单位为厘米；从图中可以看到，估算值与实际值之间的拟合曲线斜率为 1.09， R^2 为 0.88，两者具有很好地相关性，本文方法能够较好的估测出烟草植株株高。




图 9 拟合曲线

4 结束语

本文提出一种结合无人机图像和改进 Yolov8n 的方法实现对高通量烟草植株株高的测量。首先使用 ContextCapture 生成包含高程信息的 DSM 与 DOM 图像，然后针对无人机拍摄的烟草植株中心的检测，提出了改进的目标检测模型 DSW-YOLOv8n，第一针对网络轻量化问题，利用 DualConv 卷积模块替换主干 C2f 卷积模块降低模型参数；第二提出一种新型 SV-neck 代替 neck，加强对烟草植株中心特征的提取能力，提高模型精度；第三引入 WIoU 损失函数，通过增加梯度分配增益策略以减小低质量图片产生的有害梯度，提升模型对模糊

小目标的检测能力。最后利用改进后的目标检测模型对建模生成的烟草植株正射影像进行检测,得到对应烟草植株的高程信息,即株高。由实验结果可知,估算值与实际值具有良好的相关性且误差较小,表明本文提出的烟草植株株高检测模型,实现了低成本、高精度的高通量株高数据获取。但本文方法仍存在一些局限性,例如三维建模精度较低或叶片对中心的遮挡会影响目标检测的准确性,植株侧弯会对株高计算产生影响,接下来我们将进行相关研究,进一步改进模型,从而为烟草农业的数字化和智能化育苗育种提供更可靠的数据基础和技术支持,助力烟草农业迈向现代化和智能化发展。

参考文献:

- [1] 李明钊,李熠胥,王 佳,等. 基于梯度提升回归树模型的烟草产量预测方法 [J]. 云南化工, 2023, 50 (9): 109-111.
- [2] 贾增慧,张继真,郝 航,等. 基于无人机高光谱影像的田块尺度玉米估产与生育时期优选 [J]. 农业资源与环境学报, 2024 (5), 1-14.
- [3] 石文强,张 伟,亓立强,等. 基于无人机遥感的大豆株高计算方法研究 [J]. 农机化研究, 2024, 46 (2): 145-150.
- [4] 赵永杰,蒲六如,宋 磊,等. 基于 Shuffle-ZoeDepth 单目深度估计的苗期玉米株高测量方法 [J]. 农业机械学报, 2024 (5): 1-9.
- [5] 刘建春,陈 思,文波龙,等. 基于无人机多光谱遥感的水稻株高估测方法 [J]. 遥感信息, 2023, 38 (3): 61-68.
- [6] 张宏鸣,谭紫薇,韩文霆,等. 基于无人机遥感的玉米株高提取方法 [J]. 农业机械学报, 2019, 50 (5): 241-250.
- [7] 贺星耀,冯 涛,梁 虹,等. 无人机图像数据驱动的茛苕属株高检测 [J]. 电子测量技术, 2023, 46 (22): 169-176.
- [8] FIZAINI C F, BARD P, PAINDAVOINE M, et al. Historical text line segmentation using deep learning algorithms: Mask-RCNN against U-Net networks [J]. Journal of Imaging, 2024, 10 (3): 65-83.
- [9] HOU J, CHE Y, FANG Y, et al. Early bruise detection in apple based on an improved faster RCNN model [J]. Horticulturae, 2024, 10 (1): 100-107.
- [10] HONG T H, MING Z G, WEI W, et al. Improved lightweight head detection based on GhostNet-SSD [J]. Neural Processing Letters, 2024, 56 (2): 126-144.
- [11] YIN G W, XIAO N L, XUE SH Z, et al. Improved FCOS for detecting the breast cancers [J]. Current Medical Imaging, 2022, 18 (12): 1291-1301.
- [12] CUI Y, GUO D, YUAN H, et al. Enhanced YOLO network for improving the efficiency of traffic sign detection [J]. Applied Sciences, 2024, 14 (2): 555-570.
- [13] YANG T, ZHOU S, XU A, et al. An approach for plant leaf image segmentation based on YOLOV8 and the improved DEEPLABV3 [J]. Plants, 2023, 12 (19): 3438-3455.
- [14] JIA CH Z, JUN Y C, AJMAL M, et al. DualConv: Dual convolutional kernels for lightweight deep neural networks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 9528-9535.
- [15] ZHI CH H, YI W, JUN P W, et al. Improved lightweight rebar detection network based on YOLOv8s algorithm [J]. Advances in Computer, Signals and Systems, 2023, 7 (10): 107-117.
- [16] 刘雅洁,伊力哈木·亚尔买买提,席凌飞,等. 改进 YOLOv5s 的安全帽佩戴检测算法研究 [J]. 计算机工程与应用, 2023, 59 (20): 184-191.
- [17] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism [J]. ArXiv: 2301.10051, 2023: 1-8.
- [18] SINGH P, VERMA K V, RAI P, et al. HetConv: Beyond homogeneous convolution kernels for deep CNNs [J]. International Journal of Computer Vision, 2019, 128 (8): 1-21.
- [19] LI H, LI J, WEI H, et al. Slim-neck by GSConv: A better design paradigm of detector architectures for autonomous vehicles [J]. ArXiv Preprint ArXiv: 2206.02424, 2022: 1-17.
- [20] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C] //Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34 (7): 12993-13000.
- [21] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IoU loss for accurate bounding box regression [J]. Neurocomputing, 2022, 506: 146-157.
- [22] CHEN Y M, XIN B Y, WU R Q, et al. YOLO-MS: Rethinking Multi-Scale representation learning for Real-time object detection [J]. ArXiv: 2308.05480, 2023: 1-13.
- [23] CHEN J, JAO S H, HAO H, et al. Run, Don't walk: Chasing higher FLOPS for faster neural networks [J]. ArXiv: 2303.03667, 2023: 1-15.
- [24] GENNARI M, FAWCETT R, PRISACARIU A V, et al. DSConv: Efficient convolution operator [J]. CoRR, abs/1901.01928, 2019: 5147-5156.
- [25] 庞 超,王传安,苏 煜,等. 基于改进 YOLOv8 的水稻病害检测方法 [J]. 内蒙古农业大学学报 (自然科学版), 2024 (5): 1-9.
- [26] 韩 博,张婧婧,鲁子翱,等. FEV-YOLOv8n: 轻量化安全帽佩戴检测方法 [J]. 计算机测量与控制, 2024 (5): 1-11.