doi:10.6041/j.issn.1000-1298.2026.12.023

基于多源视觉检测与自适应校正的玉米茎秆直径测量方法

杨琳琳　黄中豪　潘志伟　王学睿　刘　瑞　赵磊磊　孙　波
（云南农业大学机电工程学院，昆明 650001）

摘要：玉米茎秆直径是评估抗倒伏能力和整体植株健康状况的重要指标，然而，在田间环境下，叶片遮挡和相机拍摄角度偏差等复杂因素给玉米茎秆的准确检测和直径测量带来了巨大挑战。本研究提出了一种基于颜色和深度信息（RGB－D）的玉米茎秆直径估测方法，基于多源视觉检测数据建立改进玉米茎秆检测模型 APCM－DETR，提高遮挡情况下视觉检测的可靠性。添加深度引导自适应边界框处理模块（Depth-guided adaptive bounding box，DABB），确保检测框内包含足够且完整的有效深度信息；提出基于点云的自适应校正直径估算模块（Point cloud-based adaptive diameter estimation，PADA），补偿由拍摄角度偏差引起的测量误差并实现茎秆直径的精确计算。通过引入基于 APBottleneck 构建的 APCM 骨干网络并融合卷积注意力模块 CBAM，增强通道-空间联合特征建模能力，从而提升复杂田间环境下检测性能；DABB 通过分析检测框边界处有效深度点比例，自适应调整边界位置，以提高检测框区域内深度信息的有效性；PADA 通过拟合茎秆边界点云计算茎秆倾斜角，对检测框内点云进行角度补偿，并重建校正后的茎秆横截面凸包，实现玉米茎秆直径测量。试验结果表明，APCM－DETR 检测模型精确率为 88.2%，召回率为 83.4%，F1 分数为 85.0%，模型内存占用量为 54.6 MB，推理速度为 121 f/s，平均精度均值为 85.8%，与基线模型相比，内存占用量降低 26.1 MB。玉米茎秆直径估计试验结果表明，R^2 为 0.88，RMSE 为 6.19 mm。研究结果不仅在实地场景中提高了茎秆识别能力和拍摄角度出现偏差下的测量准确性，还为精准数字农业提高无损化实时分析效率提供了实用的理论基础。

关键词：多源视觉；APCM－DETR；茎秆直径测量；自适应校正；精准数字农业
中图分类号：S237　　**文献标识码**：A　　**文章编号**：1000-1298(2026)12-0242-12　　**OSID**：

Measurement Method of Maize Stalk Diameter Based on Multi-source Visual Detection and Adaptive Correction

YANG Linlin　HUANG Zhonghao　PAN Zhiwei　WANG Xuerui　LIU Rui　ZHAO Leilei　SUN Bo
(*College of Mechanical and Electrical Engineering*, *Yunnan Agricultural University*, *Kunming* 650001, *China*)

Abstract: Corn stalk diameter is an important indicator for evaluating lodging resistance and overall plant health. However, in field environments, complex factors such as leaf occlusion and camera shooting angle deviations pose significant challenges for accurate stalk detection and diameter measurement. A method for estimating corn stalk diameter was proposed based on color and depth information (RGB－D), established on a multi-source vision detection scheme: an improved corn stalk detection model, APCM－DETR, to enhance the reliability of computer vision detection under occlusion conditions. Adding depth-guided adaptive bounding box (DABB) processing module to ensure that the detection box contained sufficient and complete effective depth information, and a point cloud-based adaptive diameter estimation (PADA) module to compensate for measurement errors caused by shooting angle deviations and achieve accurate calculation of stalk diameter. APCM－DETR improved detection performance in complex field environments by introducing an APCM backbone network based on APBottleneck and integrating the convolutional block attention module (CBAM) to enhance channel-spatial joint feature modeling capabilities; DABB adaptively adjusted the boundary position by analyzing the proportion of effective depth points at the edges of the detection box, thereby improving the validity of depth

收稿日期：2025－12－01　修回日期：2026－01－26
基金项目：国家自然科学基金项目(32160420)、云南省国际联合实验室项目(202303AP140014)和云南省农业联合专项(202301BD070001－172)
作者简介：杨琳琳(1979—)，女，教授，博士，主要从事智能检测及自动控制研究，E-mail：kgy200398@126.com
通信作者：孙波(1970—)，女，正高级工程师，主要从事农业工程装备研究，E-mail：1403898755@qq.com

information within the detection box region; PADA calculated the stalk tilt angle by fitting the stalk boundary point cloud, applied angle compensation to the point cloud within the detection box, and reconstructed the corrected cross-sectional convex hull of the stalk to achieve diameter measurement. Experimental results showed that: the APCM - DETR detection model achieved a precision of 88.2%, recall of 80.3%, F1 score of 85.0%, model memory usage of 54.6 MB, inference speed of 121 f/s, and mean average precision of 85.8%, indicating a reduction of 26.1 MB in memory usage compared with that of the baseline model. The corn stalk diameter estimation experiment yielded an R^2 of 0.88 and RMSE of 6.19 mm. The research results not only improved stalk recognition capability in field scenarios and measurement accuracy under shooting angle deviations but also provided a practical theoretical foundation for enhancing the efficiency of non-destructive real-time analysis.

Key words: multi-source visual; APCM - DETR; stalk diameter measurement; adaptive correction; precision digital agriculture

0　引言

玉米是中国的重要粮食作物,在种植面积和产量上均居首位,保障我国的战略粮食安全[1]。国家统计局 2025 年 12 月 12 日发布数据显示,全国粮食产量 7.15×10^{11} kg,比上年增加 8.375×10^{9} kg,其中,全国玉米产量 3.01×10^{11} kg,比上年增加 6.32×10^{9} kg,增长 2.1%,具有较高的生产潜力和经济效益。玉米茎秆性状是评估玉米生长状态和抗倒性能的重要指标,尤其是在抽穗期,茎秆直径变化最为明显。在田间无损化玉米茎秆性状的检测中,一般是由高通量表型(High-throughput phenotyping,HTP)平台或人工在不平整的地面上操作,会使拍摄角度产生一定偏差,从而导致多源图像信息中茎秆深度数据投影失真。这些拍摄误差可能导致模型检测中茎秆直径测量不准确,进而影响实际种植生产中对玉米生长状况的评估、精细管理以及相关决策,如育种改良方案等[2]。因此,开发高效且实用的精准检测方法确保玉米茎径性状测量的可靠性势在必行。

得益于深度学习在图像识别任务中展现的高精度与高效率,以及在视觉任务中强大的特征提取与领域泛化能力,模型在处理复杂背景和提升泛化性能方面取得了显著突破[3-5],为 RT - DETR 等检测模型的发展奠定了坚实基础,并在农业玉米表型性状检测中展现出巨大潜力[6-11]。当前,RT - DETR 及改进模型被广泛研究与应用,旨在实现更高的实时检测精度[12-14]。利用深度学习方法实现作物直径测量主要有 2 种策略:①引入深度信息作为额外特征通道输入,或在统一网络中对 RGB 与深度信息进行早期或中期融合[15-16],虽然这种方法提高了测量精度,但在训练过程会显著增加计算负担,并限制模型的泛化能力,从而影响实时部署性能,且对于未显式集成深度信息的检测模型,由于无法有效提取茎部的深度特征,即使经过优化训练,在不同数据集上仍会出现显著的性能下降[17-21]。②采用语义分割方法可以有效提升检测精度,但在引入深度信息进行多源信息融合时,其后处理过程往往较为复杂,尤其是在直径参数提取与几何约束建模方面仍存在一定困难[22]。GAO 等[23]提出了一种点云补全模型,可恢复被遮挡或缺失的玉米点云,从而提高茎秆直径测量的准确性。这种三维点云后处理方法值得借鉴,但并未解决因拍摄相机角度偏差在真实场景中导致的信息不匹配和测量精度下降的问题[24-26]。该问题对高通量表型机器人在复杂田间路况的自主作业构成了严峻挑战[27-31],因此,研究面向复杂场景的自适应检测与直径测量策略至关重要。

基于此现状,本文提出一种以 RGB 图像和深度信息结合的处理方法,通过改进基于视觉的玉米茎秆检测模型 APCM - DETR,增强复杂背景和遮挡条件下玉米茎秆视觉检测可靠性,从而为深度信息处理提供稳定的目标区域,并装载于高通量表型平台(HTP)测量不同生长阶段的玉米茎秆直径。针对检测结果与深度数据在实际应用中难以有效对齐的问题,提出深度引导自适应边界框处理方法(Depth-guided adaptive bounding box, DABB),以提高检测框内有效深度信息完整性和可用性。在此基础上,提出基于点云的自适应直径估算方法(Point cloud-based adaptive diameter estimation,PADA),通过对茎秆点云进行角度补偿和几何重建,减弱拍摄角度偏差对直径测量结果的影响。将自主设计的 DABB 和 PADA 方法集成到基于深度信息的后处理策略中,以期提高测量精度的同时,解决因拍摄角度偏差而引起的直径测量误差,为玉米高通量表型分析提供一种具有较强实用性的技术方案。

1　材料与方法

1.1　田间高通量表型检测机器人

本文自主设计并搭建一款专用的高通量表型平

台(HTP)移动机器人以还原实际作业场景,其结构由底层驱动部分和上层延伸部分组成。底层部分包括传动框架、弹簧减震器以及 6 个独立驱动轮,而上层用于安装计算设备和传感器。可调节的 2 根后桅杆(高度为 80 ~ 160 cm)上各安装有 RGB - D 相机,以捕捉玉米茎秆性状在不同生长阶段的特征。HTP 机器人结构如图 1 所示。

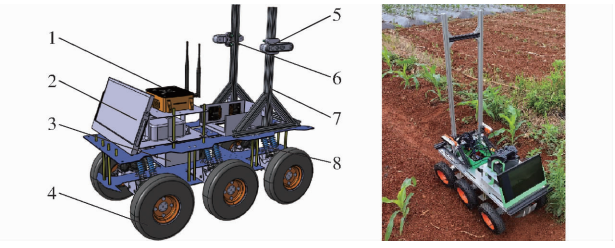

图 1 HTP 机器人平台结构

Fig. 1 Schematic of HTP robotic platform structure

1. 边缘计算设备 2. 触控显示屏 3. 电源电池组 4. 驱动轮 5. 摄像头 6. 自锁导轨滑块 7. 后桅杆 8. 弹簧减震器

HTP 机器人信息采集与处理系统由底盘控制模块、图像采集模块和表型数据处理模块 3 个部分组成。边缘计算设备与 Arduino Mega 2560 底盘控制器进行通信控制底盘运动,同时控制 RGB - D 相机进行数据实时采集与处理,并在可视化触摸屏上显示具体信息。HTP 机器人主要规格参数如表 1 所示。

表 1 HTP 机器人主要规格和参数

Tab. 1 Main specifications and parameters of HTP robot

参数	数值/形式
整体尺寸/(m × m × m)	0.75 × 0.37 × 0.74
工作时间/h	2 ~ 4
离地间隙/cm	15
前接近角/(°)	57
摄像头类型	Intel D - 435
质量/kg	20
工作电压/V	12 ~ 19
驱动形式	6 轮独立驱动
转向形式	差速转向
工作速度/(m·s^{-1})	0.1

1.2 数据采集与处理

数据采集试验在中国云南省楚雄市禄丰县仁兴镇古城村的玉米田地进行。种植玉米品种为罗单 566DT,播种日期为 2025 年 4 月 27 日,数据采集分别在 5 月 31 日(拔节初期)和 7 月 6 日(抽穗后期)进行,而验证试验则在 7 月 30 日进行。此外,从所有标记的茎秆目标中随机选择 205 株玉米,并用游标卡尺同步测量近似圆形直径。HTP 机器人在田间作业示意图如图 2 所示。

数据集增强后的图像和标注类型如图 3 所示。

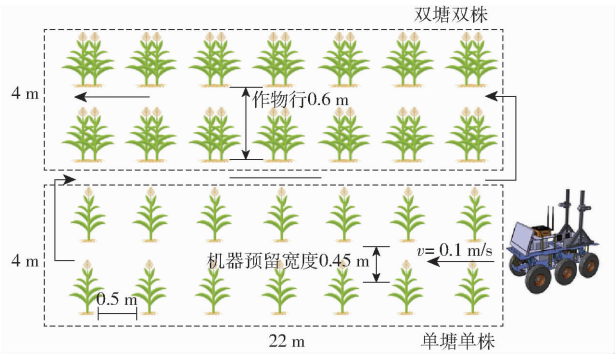

图 2 HTP 机器人在现场采集数据示意图

Fig. 2 Schematic of HTP robot collecting data in field

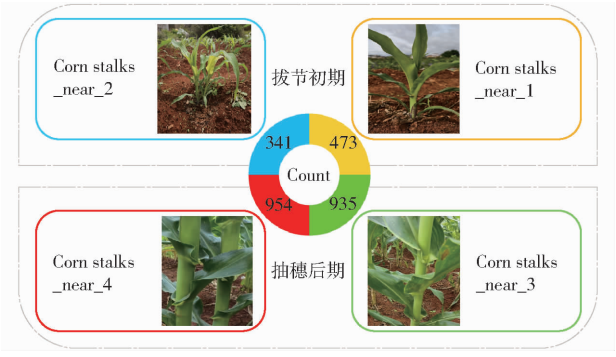

图 3 采集的玉米茎秆数据注释和数量

Fig. 3 Annotations and quantities of collected data

使用 Labeling 软件(版本 1.8.6)对不同生长阶段以及与相机不同距离处的玉米茎秆目标进行标注。为了更清晰辨别,所有标记的玉米茎秆特征目标都加上前缀“Corn stalks”;对于主要目标,附加标签“near”,对于背景中次要茎部目标,则使用标签“far”。随后添加奇数标注作为后缀以表示单塘单株栽培,而偶数标注则表示双塘双株栽培。图像数据集经过增强和扩展,以平衡不同特征标签的图像数量,增强数据集的泛化能力,然后将所有图像按比例 7∶2∶1 划分为训练集、验证集和测试集。模型在配备 Intel Xeon E5 - 2680 CPU 和 NVIDIA RTX 4090 24 GB GPU 的计算机上进行训练,操作系统为 Windows 10 专业版。训练轮次设置为 300。

1.3 APCM - DETR 玉米茎秆检测模型

RT - DETR 在处理遮挡目标和复杂背景方面具有显著优势[32]。因此,以 RT - DETR - r18 作为基线模型,采用自适应金字塔跨阶段模块(APCM)作为模型骨干网络,构建 APCM - DETR 模型,旨在增强对玉米茎秆目标的检测能力。APCM - DETR 整体架构如图 4 所示。

1.3.1 APCM 模块

以 APCM 模块改进基准模型 RT - DETR - r18 的骨干网络,APCM 模块结构如图 5 所示。APCM 模块作为 APCM - DETR 骨干网络核心增强单元,整体结构如图 5a 所示,通过多层瓶颈重构和注意力引

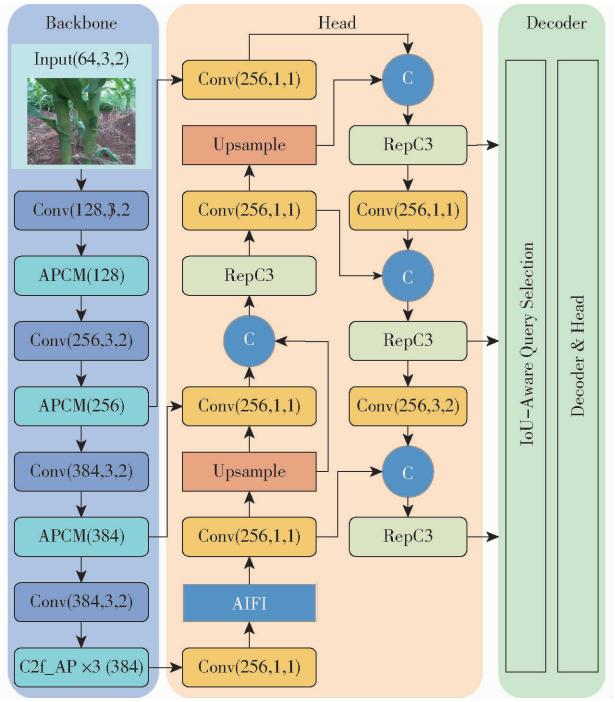

图 4　APCM－DETR 模型结构

Fig. 4　Structure of APCM－DETR model

导融合机制，强化输入特征的表征能力与结构稳定性。该模块重构了 RT－DETR－r18 原有的骨干网络卷积结构，输入特征首先经过 Conv1 实现通道扩展，在保持空间维度的同时增加特征表示的多样性。随后，扩展后的特征被拆分为 2 个分支：①保留分支（下侧路径），直接保留输入特征的几何轮廓和局部语义信息而不进行深度变换，为最终融合阶段提供稳定的低层次结构参考。②重构分支（上侧路径），经过若干级联的 APBottleneck[33]，结构如图 5b 所示。APBottleneck 通过“降维卷积—特征重构—升维恢复”的操作流程实现轻量化特征表达。首先通过 1×1 卷积对输入特征进行降维以降低计算量，随后进入核心特征交互模块，通过卷积与自适应加权机制的结合增强特征图信息中目标边缘、轮廓连续性和纹理变化等关键信息，最后通过 1×1 卷积融合实现升维，使通道数与残差路径对齐，以获得感受野更强的卷积特征结果。APBottleneck 的启用能够保证深层堆叠时梯度稳定与信息连续性。

双路径-多瓶颈的融合结构与 APBottleneck 模块重构机制共同构成了 APCM 网络核心。与此同时，在 APCM 模块的每一层特征输出端还引入卷积块注意力模块（Convolutional block attention module，CBAM），不仅同步建模局部纹理与深层语义，还能确保复杂环境下特征稳定性，提升 APCM－DETR 对玉米茎秆的检测性能。

1.3.2　CBAM 注意力机制

卷积块注意力模块 CBAM 是一种轻量级注意力机制模块，由 WOO 等[34]在 2018 年首次提出。该模块旨在通过特征图的空间和通道维度上应用加权操作，增强神经网络感知关键区域的能力，同时在增强对小目标关注的同时不会显著增加计算量。CBAM 整体结构分为通道注意力模块和空间注意力模块，如图 6 所示。

图 6 中通道注意力模块（Channel attention module，CAM）将输入特征图首先经过全局平均池化（AvgPool）和全局最大池化（MaxPool）生成 2 个描述向量。将这些向量通过共享的多层感知机（MLP）进行非线性变换，生成 2 个 MLP 输出。再将 2 个输出相加，并通过 Sigmoid 函数激活，以获得最终的通道注意力权重。图 6 中空间注意力模块（Spatial attention module，SAM）以 CAM 输出的特征图为输

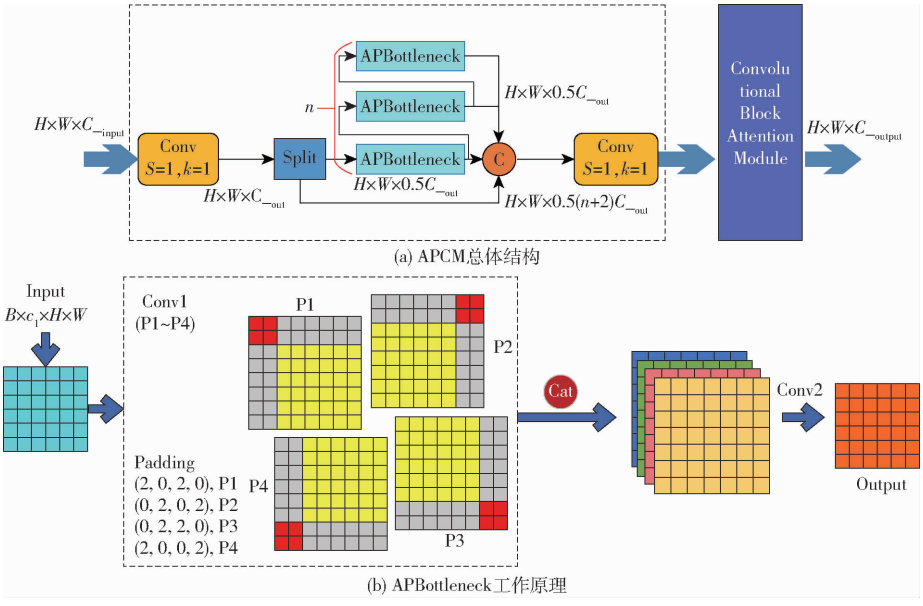

图 5　APCM 模块示意图

Fig. 5　Illustrations of APCM module

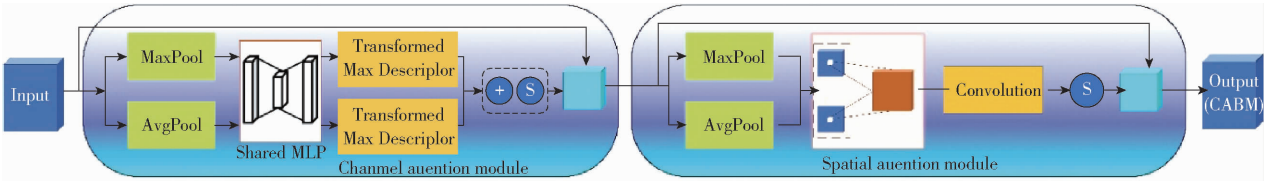

图 6 CBAM 机制

Fig. 6 CBAM mechanism

入,应用全局平均池化(AvgPool)和全局最大池化(MaxPool)生成 2 个二维特征图,然后进行拼接并对拼接结果应用卷积核操作,最后通过 Sigmoid 函数激活将生成的注意力图与输入特征图逐元素相乘,从而得到最终输出。

通过上述操作,CBAM 模块在通道与空间 2 个层面对特征图进行重标定,使网络更加关注与茎秆目标相关的区域特征,并降低非目标区域的响应强度,因此有助于缓解复杂背景和叶片遮挡对检测性能的影响。

1.4 深度信息引导的检测边界框自适应调整方法

为了提高茎秆几何特征提取准确性,提出了一种基于深度边界完整性的自适应边界框优化方法(DABB)。根据初始检测框边界深度有效性,判断当前边界框是否充分覆盖了玉米茎秆的深度信息。通过水平扩展或收缩边界框,以更好地覆盖目标区域并排除背景深度信息干扰。DABB 方法流程如图 7 所示。

检测模型首先生成初始的 RGB 玉米茎秆图像边界框,由于该边界框仅基于颜色或纹理特征生成,无法完全覆盖三维空间中茎秆信息。因此,首先将边界框的坐标信息映射到相应的深度数据上,并对深度数据进行去噪以消除测量噪声。从边界框内提取所有有效的深度点,将边界框坐标中心定义为深度参照基线,显著偏离该参考深度的深度点(表示背景结构)以及对应于遮挡物体(例如叶片)的深度点随后被过滤。深度点过滤计算式为

$$Z_{\text{mask}}=\begin{cases}1 & (|Z_{(x,y)}-Z_0|<\delta_{\text{far}})\\ 1 & (Z_{(x,y)}>Z_0-\delta_{\text{near}})\\ 0 & (\text{其他})\end{cases} \tag{1}$$

式中 Z_0——边界框中心像素深度

Z_{mask}——二值掩码,确定当前像素是否被保留

$Z_{(x,y)}$——深度图中对应像素深度

δ_{far}、δ_{near}——远处背景点和过近遮挡物(如树叶)允许深度偏差

根据现场实际数据采集情况,将δ_{far}和δ_{near}分别设定为 120 mm 和 30 mm。

将保留边界框深度信息位置与映射到真实世界边界框左右边界实际深度位置进行比较,评估边界框边界的有效性,计算式为

$$r_{\text{avg}}=\frac{r_L+r_R}{2} \tag{2}$$

其中 $$r_L=\frac{\sum 1(Z_L>0)}{kH}\qquad r_R=\frac{\sum 1(Z_R>0)}{kH}$$

$$H=y_{\max}-y_{\min}$$

式中 r_L、r_R——左边界和右边界上有效深度点比例

$1(\cdot)$——指示函数,当条件满足时取值为 1,不满足时取 0

H——边界框像素高度

k——边界框边界像素宽度,取 5

Z_L——边界框左边界深度图像区域

Z_R——边界框右边界深度图像区域

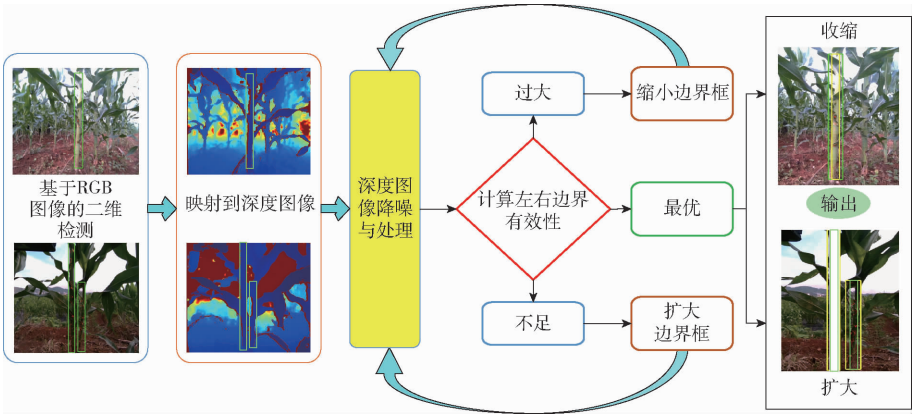

图 7 DABB 方法流程

Fig. 7 DABB method process

r_{avg}——r_L和r_R平均值

τ为判定边界框深度有效比例的临界值，根据所收集数据集的特性并综合考虑边界完整性判定的稳定性与边界调整的灵敏度，τ设为 0.84，以判定检测框左右边界是否具备足够完整的有效深度信息。当$r_{avg} \geqslant \tau$时，边界框被认为完整，并且边界框会被扩展以捕获更多茎秆有效深度信息；当$r_{avg} < \tau$时，边界被认为不完整，边界框会收缩以排除沿边缘的多余无效区域。

边界通过多次迭代计算进行处理，每一轮都进行迭代扩展、收缩和验证计算。

扩展模式计算式为

$$\begin{cases} x_{\min}^{(t+1)} = \max(0, x_{\min}^{(t)} - \Delta x) \\ x_{\max}^{(t+1)} = \min(W, x_{\max}^{(t)} + \Delta x) \end{cases} \tag{3}$$

式中　$x_{\min}^{(t)}$、$x_{\max}^{(t)}$——第 t 次迭代边界框左边界和右边界位置

Δx——每次迭代边界调整步长，取 5

W——图像最大宽度

收缩模式计算式为

$$\begin{cases} x_{\min}^{(t+1)} = x_{\min}^{(t)} + \Delta x \\ x_{\max}^{(t+1)} = x_{\max}^{(t)} - \Delta x \end{cases} \tag{4}$$

新边界框验证计算式为

$$| r_{avg}^{(t+1)} - \tau | \leqslant \epsilon \tag{5}$$

式中　ϵ——允许误差，取 0.1

1.5　基于点云的自适应茎秆直径估计

为解决高通量表型机器人（HTP）因受到行间不平整导致拍摄角度偏差的影响，从而导致测量不准确，提出一种基于点云的茎秆直径自适应补偿方法（PADA），在 DABB 基础上提高玉米茎秆直径估算的准确性。PADA 工作流程如图 8 所示。

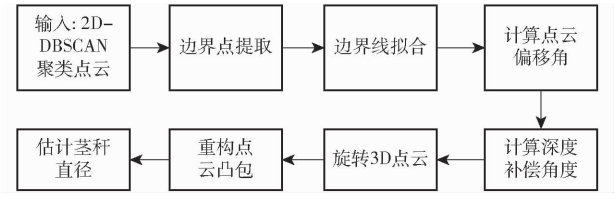

图 8　茎秆直径估算 PADA 方法流程

Fig. 8　PADA method process for estimating stem diameter

（1）边界点提取与拟合。对更新的边界框内深度信息进行逐行扫描，将边界框中像素点反投影到三维空间中生成对应的点云数据。对每一行点云数据，同时从左边和右边向中心扫描，识别最左和最右的有效深度点，这些点分别作为该行的左、右边界点，经过滤波处理以去除明显的噪声点。应用最小二乘拟合和 RANSAC 算法，对左、右边界分别进行空间直线拟合。

（2）点云偏移角计算。基于 2 条拟合直线的空间方向向量，计算边界平均方向向量。利用该向量与理想拍摄方向向量计算偏移角，计算式为

$$\theta = \arccos \frac{\boldsymbol{V}_{avg} \boldsymbol{V}_{ideal}}{\| \boldsymbol{V}_{avg} \| \| \boldsymbol{V}_{ideal} \|} \tag{6}$$

式中　θ——2 个方向向量之间的夹角，即偏移角

$\boldsymbol{V}_{avg}$——左右边界线平均方向向量

$\boldsymbol{V}_{ideal}$——理想方向向量，取(0,1,0)

θ用于判断重建的点云相对于拍摄方向是否存在明显倾斜。

（3）深度信息角度补偿。将偏移角θ分解为绕 X 轴旋转φ_x和绕 Z 轴旋转φ_z。应用旋转矩阵对点云进行角度补偿。旋转矩阵计算式为

$$\begin{cases} \boldsymbol{R}_x(\varphi_x) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos\varphi_x & -\sin\varphi_x \\ 0 & \sin\varphi_x & \cos\varphi_x \end{bmatrix} \\ \boldsymbol{R}_z(\varphi_z) = \begin{bmatrix} \cos\varphi_z & -\sin\varphi_z & 0 \\ \sin\varphi_z & \cos\varphi_z & 0 \\ 0 & 0 & 1 \end{bmatrix} \end{cases} \tag{7}$$

式中　$\boldsymbol{R}_x(\varphi_x)$——绕 X 轴旋转矩阵

$\boldsymbol{R}_z(\varphi_z)$——绕 Z 轴旋转矩阵

经过方向校正的点云矩阵计算式为

$$\boldsymbol{P}_{corr} = \boldsymbol{R}_x(\varphi_x) \boldsymbol{R}_z(\varphi_z) \boldsymbol{P}_{raw} \tag{8}$$

式中　$\boldsymbol{P}_{raw}$——在边界框内捕获的有效原始 3D 点云矩阵

$\boldsymbol{P}_{corr}$——角度补偿后 3D 点云矩阵

（4）玉米茎秆直径估算。由于玉米茎秆形态可以近似为圆柱形，将边界框内校正后的三维点云重建为圆柱形凸包，并计算其体积。需要注意的是，凸包体积对应于圆柱体积的一半，因为点云仅覆盖深度相机可见茎秆的一半，根据半圆柱体积计算拟合圆直径，计算式为

$$D = 2\sqrt{\frac{2V}{\pi h}} \tag{9}$$

式中　D、V——半圆柱体直径和体积

h——半圆柱体高度

2　试验与结果分析

从检测模块和测量模块 2 个层面对所提方法性能进行评估。分析 APCM－DETR 检测模型的整体性能及消融试验结果，重点评估基于深度信息的 DABB 和 PADA 方法对玉米茎秆直径测量的有效性。

2.1　APCM－DETR 模型检测性能评估

2.1.1　APCM－DETR 与基线模型检测结果

图 9 为 APCM－DETR 模型与 RT－DETR－r18

基线模型在不同茎秆标签类型上的检测结果。对于大多数茎秆类型，APCM－DETR 的精确率高于原始基线模型，图中折线反映了不同模型在对同一类标签性状上的精确率提升变化。值得注意的是，在 HTP 机器人数据采集过程，原始的玉米 Corn stalks_far_3 标签受到玉米叶片严重干扰，导致其检测精度明显低于其他类型。然而，在 APCM－DETR 的训练

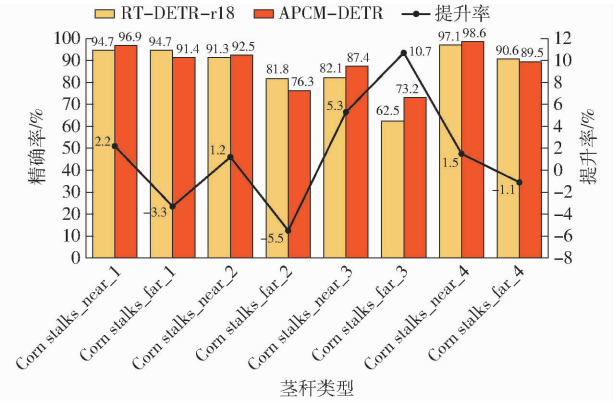

图 9 APCM－DETR 和 RT－DETR－r18 模型对不同茎秆标签的识别结果

Fig. 9 Recognition result of APCM－DETR and RT－DETR－r18 models for different stalk labels

下，其检测精确率仍实现了显著提升，升幅达 10.7%。这表明 APCM 骨干架构能够在复杂背景和模糊特征下有效增强目标区域的特征表示，从而提高模型的稳健性和检测效果。

2.1.2 不同模型性能试验

通过替换不同的主流骨干网络和主流 YOLO 系列模型进行精确率试验，以分析 APCM－DETR 模型整体性能，试验结果如表 3 所示。由表 3 可知，APCM－DETR 模型精确率相比最低模型 YOLO v8n 提升 21.6%，表明改进模型在目标定位和识别方面具有更高的准确性。召回率与其他模型相比提升 2.7～15.0 个百分点，说明本文模型对茎部目标漏检率更低，感知能力更强。平均精度均值（mAP）相比其他模型提高 0.3～15.7 个百分点，在多个决策阈值下仍保持出色的检测精度和稳定性。对于 F1 分数，改进模型提升幅度最高达 18 个百分点，表明在精确率与召回率之间取得了更好的平衡，整体上具有更优的鲁棒性。在计算量和模型复杂性方面，APCM－DETR 模型浮点运算量为 4.70×10^{10}，参数量为 1.33×10^{7}，模型内存占用量仅为 54.6 MB，展现出良好的实时性能和部署效率。

表 3 不同模型性能试验结果

Tab. 3 Performance experiment results of different models

模型	精确率/%	召回率/%	平均精度均值/%	F1 分数/%	浮点运算量	参数量	内存占用量/MB	推理速度/(f·s^{-1})
APCM－DETR	88.2	83.4	85.8	85.0	4.70×10^{10}	1.33×10^{7}	54.6	121
RR－DETR－ASF	82.2	80.7	81.7	81.0	4.08×10^{10}	1.18×10^{7}	47.7	110
RT－DETR－GOLDYOLO－ASF	89.1	80.4	85.5	85.0	6.32×10^{10}	2.28×10^{7}	91.5	86
RT－DETR－L	88.0	80.0	82.4	84.0	1.04×10^{11}	3.29×10^{7}	132.0	66
Rtdetr－MobilenetV4	84.7	76.5	79.6	80.0	3.97×10^{10}	1.16×10^{7}	46.8	118
YOLO 11n	76.6	68.6	70.1	67.0	6.30×10^{9}	2.59×10^{6}	10.7	275
YOLO v8n	75.6	68.4	71.0	71.0	1.17×10^{10}	6.20×10^{6}	24.6	205
RT－DETR－r18	87.6	80.3	83.6	84.0	5.70×10^{10}	2.09×10^{7}	80.7	92

2.1.3 消融试验

表 4 为将 APCM 模块和 CBAM 注意力机制模块引入 RT－DETR－r18 基线模型后进行的消融试验结果。当单独引入 APCM 模块时，与基线模型（表 4 第 1 行）相比，召回率和平均精度均值分别提高 1.3、1.1 个百分点，而模型参数量和内存占用量则分别减少 4.46×10^{6} 和 17.8 MB，表明 APCM 模块通过多分支特征融合和高效的瓶颈结构，可以显著降低改进模型的参数量和计算量，尽管精确率略有下降。当单独引入 CBAM 机制时，与基线模型相比，精确率、召回率、mAP 和 F1 分数分别提高 0.2、2.3、1.5、1.0 个百分点，表明 CBAM 中通道注意力机制（CAM）和空间注意力机制（SAM）增强了模型的判别能力和特征表示能力，提高了在检测关键区域时的有效性，而参数量变化很小。当 APCM 和 CBAM 同时引入后，为 APCM－DETR 模型，精确率为 88.2%，召回率为 83.4%，F1 分数为 85.0%，模型内存占用量为 54.6 MB，推理速度为 121 f/s，平均精度均值为 85.8%。APCM－DETR 达到了最佳性能，精确率、召回率和平均精度均值分别提高 0.6、3.1、2.2 个百分点，同时参数量和浮点运算量分别减少 6.54×10^{6} 和 1.0×10^{10}，模型内存占用量减少 26.1 MB，表明 2 个模块具有互补优势，使模型在保持高精度的同时进一步降低了计算复杂度。

2.2 DABB 方法有效性分析

试验从 4 种主要直径表型类别（Corn stalks_near_1～4）中选择 280 个样本，并使用 APCM－DETR 模型生成的原始检测框以及应用 DABB 方法

表 4　模型改进试验结果

Tab. 4　Model improvement experiment results

APCM	CBAM	精确率/%	召回率/%	平均精度均值/%	F1 分数/%	浮点运算量	参数量	内存占用量/MB	推理速度/(f·s^{-1})
×	×	87.6	80.3	83.6	84.0	5.70×10^{10}	1.98×10^{7}	80.7	92
√	×	86.7	81.6	84.7	84.0	5.26×10^{10}	1.54×10^{7}	62.9	107
×	√	87.8	82.6	85.1	85.0	5.70×10^{10}	1.99×10^{7}	81.1	93
√	√	88.2	83.4	85.8	85.0	4.70×10^{10}	1.33×10^{7}	54.6	121

注：√表示引入模块，×表示不引入模块。

后获得的检测框评估其有效性。采用边界框有效信息比率(BoxBorderRatio，BBR)和框内有效信息比率(BoxCountRatio，BCR)，分别表示检测框边界和检测框内的有效深度数据比例，计算式为

$$\begin{cases}\eta_B=\dfrac{N_{\mathrm{BV}}}{N_{\mathrm{BR}}}\times100\%\\ \eta_C=\dfrac{N_{\mathrm{CV}}}{N_{\mathrm{CR}}}\times100\%\end{cases}\tag{10}$$

式中　N_{BV}——检测框边界上有效深度像素数量

N_{BR}——检测框边界上深度像素总数

N_{CV}——检测框内有效深度像素数量

N_{CR}——检测框内深度像素总数

如图 10 所示，在应用 DABB 自适应边界框调整方法后，4 种茎秆类型边界深度有效性(BBR)和边框内整体深度数据有效性(BCR)均显著提升，BBR 提升 8.6～14.1 个百分点，而 BCR 提升 11.7～13.9 个百分点。此外，应用 DABB 方法后，箱线图四分位间距(IQR)明显减小，特别是 Corn stalks_near_4 类别，四分位间距显著缩小，表明有效值的分布更加集中，凸显在处理原始边界框深度数据偏差的能力。

由图 10 可知，DABB 方法对 BoxCountRatio 影响大于对 BoxBorderRatio 的影响，与图 10a 相比，图 10b 有效性比率中位数在 BoxBorderRatio 和 BoxCountRatio 方面分别提高 12.3、12.6 个百分点。表明尽管 DABB 原理是为调整边界框的边界有效性，但调整后边界框进一步增加了整个边界框内有效深度像素比例。

图 11 为不同玉米茎秆表型启用 DABB 前后 2 个指标变化热力图，图中较深蓝色表示平均改善更显著，而较浅颜色则表示改善较低。由于 DABB 方法主要调整检测边界框，因此在 BoxBorderRatio 上改善最为显著，Corn stalks_near_1 和 Corn stalks_near_4 分别提高 14.1% 和 13.7%，在所有改善中最优。而 BoxCountRatio 的改善更为均衡，4 种表型均表现出超过 11% 的增长。表明 DABB 边界框策略在保持整体深度信息方面具有良好的泛化能力，不仅优化了边界的结构完整性，还为三维点云处理和茎秆直径估算提供了更高质量的原始数据。

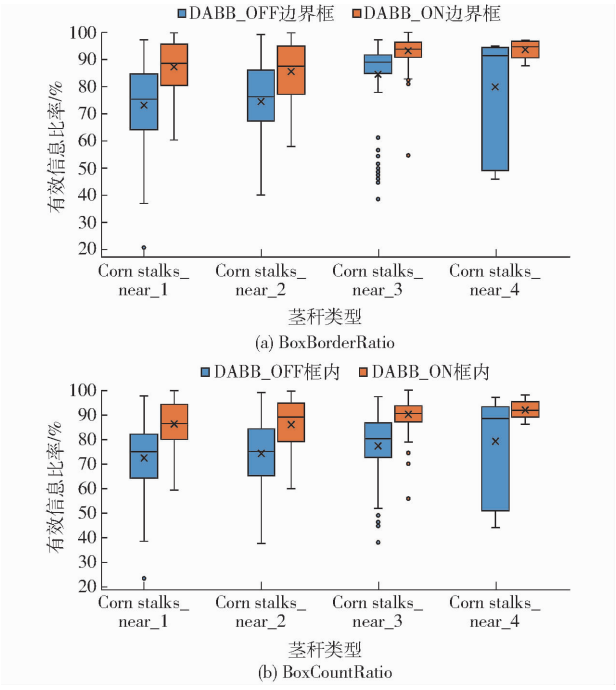

图 10　DABB 方法有效性箱线图

Fig. 10　Boxplots of effectiveness of DABB method

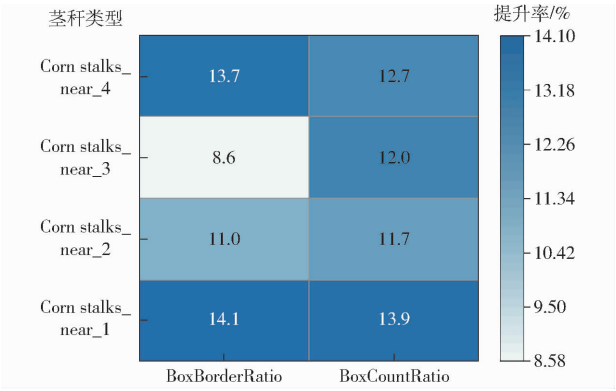

图 11　有效信息比率改进热力图

Fig. 11　Heatmap of effective information ratio improvement

2.3　PADA 精确率评估

试验使用 PADA_ON、PADA_OFF 方法以及手工测量方法(Manual measurement)测量 205 组 4 种不同玉米茎秆类型的直径，其中，PADA_OFF 表示不进行角度校正的基线边界框检测方法。如图 12 所示，展示了所有测量方法和对不同类型茎秆直径箱线分布图。

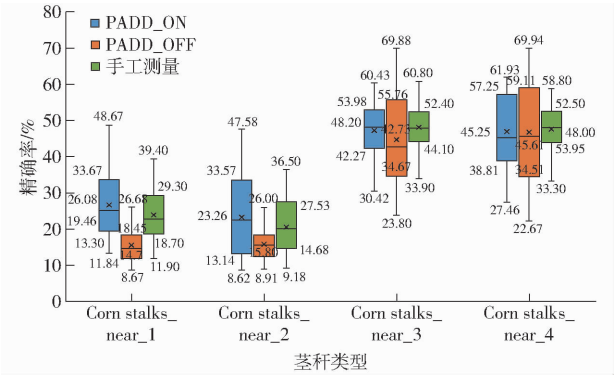

图 12 不同茎秆类型在不同测量方法下直径精确率箱线图

Fig. 12 Boxplot of diameter accuracy for different stalk types under various measurement methods

2.3.1 不同测量方法对茎秆直径评估

表 5 为使用 PADA 方法(PADA_ON)和基线方法(PADA_OFF)对 4 种不同茎秆标签直径估计误差测量结果。采用 R^2 和 RMSE 对测量结果进行评估,此外,还将平均绝对误差(MAE)作为比较指标,从而更全面地评估不同算法在茎秆直径估计中的鲁棒性。从表 5 可看出,采用 PADA 方法后,对于茎秆标签类型 Corn stalks_near_3,R^2 最大达到 0.88,而 Corn stalks_near_4,在 RMSE 和 MAE 上测量效果最为显著,分别比 PADA_OFF 降低 9.36 mm 和 8.8 mm。对于其余 2 种标签类型,采用 PADA 方法后误差也有明显缩小。因此所有类型茎秆直径估计精度均超过了未使用 PADA 方法。

表 5 不同 PADA 测量方法评估指标

Tab. 5 Evaluation metrics for different PADA measurement methods

茎秆类型	PADA_ON			PADA_OFF		
	R^2	RMSE/mm	MAE/mm	R^2	RMSE/mm	MAE/mm
Corn stalks_near_1	0.63	6.50	3.69	0.45	11.86	9.97
Corn stalks_near_2	0.69	7.42	4.84	0.54	8.82	7.16
Corn stalks_near_3	0.88	4.16	3.19	0.44	12.80	10.50
Corn stalks_near_4	0.80	6.19	5.03	0.31	15.55	13.83

为更直观地展示在应用 PADA 方法前后情况,绘制 PADA_OFF 和 PADA_ON 方法获得的测量结果散点图和回归直线,如图 13 所示。由图 13 可看出,PADA 方法拟合线更接近理想拟合线(黑色),表明其预测结果与实际情况更加一致,同时,使用 PADA 方法获得的数据分布更加集中。相比之下,PADA_OFF 散点图(图 13a)显示在 Corn stalks_near_3 和 Corn stalks_near_4 类别的部分区域具有较高的离散度(理想情况下应集中于图 13b 的右上方),也是拟合直线斜率偏差的主要原因之一。试验结果验证了 PADA 方法可以有效提高玉米茎秆直径测量精度。

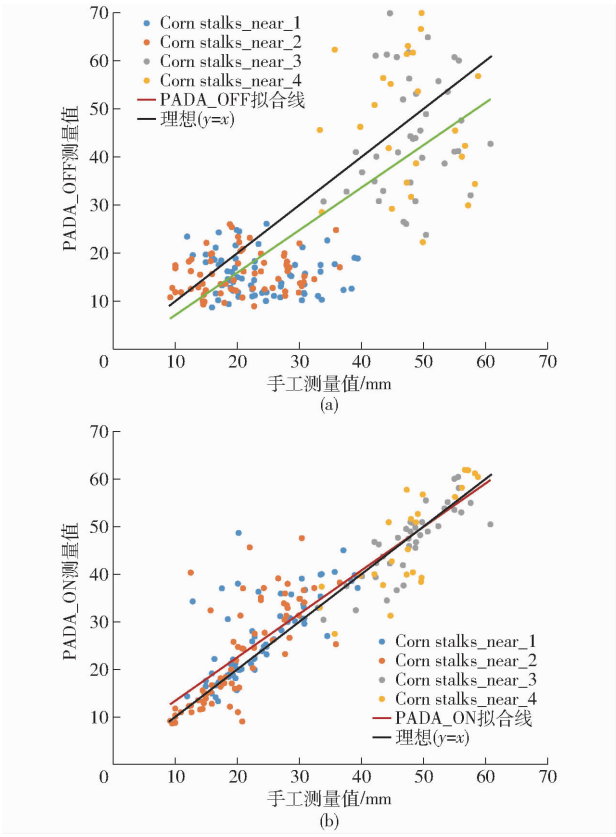

图 13 茎秆直径测量结果

Fig. 13 Stem diameter measurement results

2.3.2 PADA 方法中角度补偿有效性评估

表 6 为 PADA 方法不同茎秆类型目标角度补偿值频率,PADA 方法产生的角度补偿值主要集中在 0°~15°范围,表明 HTP 机器人拍摄偏差主要在低角度范围内。

表 6 PADA 修正角范围频率

Tab. 6 Frequency of PADA correction angle ranges

茎秆类型	0°~5°	5°~10°	10°~15°	15°~20°	20°~25°	25°~30°
Corn stalks_near_1	24	18	16	6	4	2
Corn stalks_near_2	29	19	14	5	3	1
Corn stalks_near_3	16	14	6	2	1	0
Corn stalks_near_4	10	7	5	2	1	0
合计	79	58	41	15	9	3

图 14 为不同补偿角度区间下 PADA_ON 与 PADA_OFF 的 MAE。由图 14 可知,在所有补偿角度区间内,PADA_ON 方法均优于 PADA_OFF 方法。在样本量充足的 0°~15°区间内,PADA_ON MAE 约为 PADA_OFF 的一半。虽然在 20°~30°区间内校正数据量较少,但 MAE 仍显著低于 PADA_OFF,并且低于平均误差线。结果表明,PADA 角度补偿机制在提升宽范围偏角下的测量精度方面表现出更优的鲁棒性。

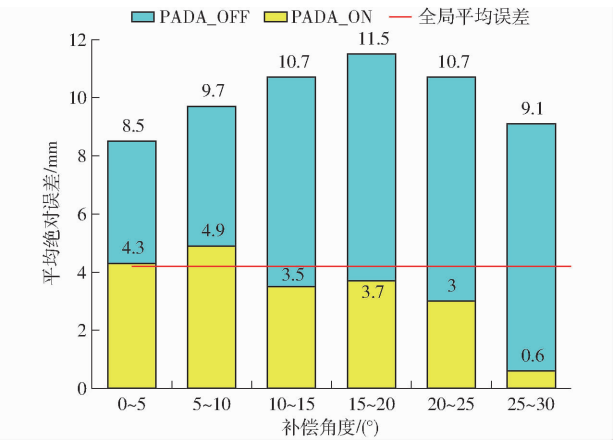

图 14　不同角度补偿下直径估计结果平均绝对误差

Fig. 14　MAE of diameter estimation results under different angle compensations

2.3.3　不同玉米生长阶段茎秆直径估算

图 15 为不同测量方法下玉米在拔节初期(标签 Corn stalks_near_1 和 Corn stalks_near_2)和抽穗晚期(标签 Corn stalks_near_3 和 Corn stalks_near_4)的茎秆直径测量分布结果。由图 15 可看出,与未采用 PADA 方法区域相比,采用 PADA 方法与手工测量的拟合能力更强,表明 PADA 方法在 2 个生长阶段都具有优异的误差压缩能力。

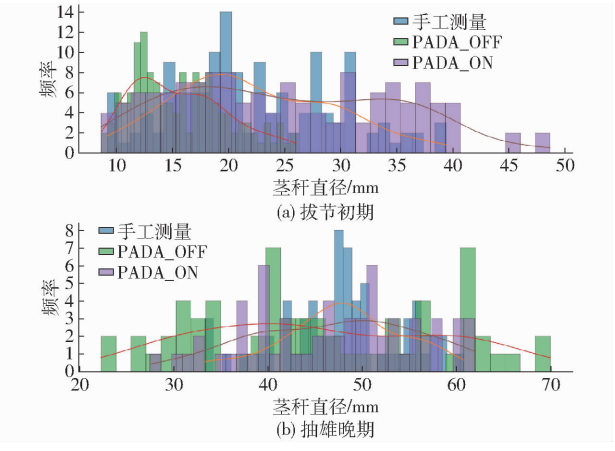

图 15　不同玉米茎秆直径测量结果

Fig. 15　Different corn stalk diameter measurement results

由图 15a 可知,使用 PADA 获得的分布明显左移,这是因为其原始的边界框检测方法直接从边界框计算深度信息。对于早期玉米表型,较小的茎秆直径导致检测框内特征信息模糊,如果不通过深度信息恢复点云进行处理,会得到更高比例的噪声和无效数据,导致系统性低估,从而使分布向左偏移。由图 15b 可知,使用 PADA 方法能够有效减少在抽穗期玉米茎秆表型获取过程由于叶片遮挡、复杂背景和光照条件而导致的测量偏差。

表 6 为不同玉米生长阶段茎秆直径估计结果偏度。偏度是衡量分布非对称性的重要统计量,偏度为 0 表示分布完全对称;负偏度表示左偏分布(低估);正偏度表示右偏分布(高估)。从表 6 可知,PADA_OFF 方法在所有类型中表现出更大的负偏度,其中 stalks_near_1 达到最大偏度为 -1.84。对比拔节初期 Corn stalks_near_1 和 Corn stalks_near_2 偏度误差与 Corn stalks_near_3 和 Corn stalks_near_4 偏度误差可知,拔节初期茎秆直径测量偏度大于抽穗晚期。相比之下,使用 PADA 得到的偏度与人工测量一致,进一步验证了 PADA 方法在提高测量精度方面的有效性。

表 6　茎秆直径估算偏度

Tab. 6　Skewness of stem diameter estimation

茎秆类型	手工测量	PADA_ON	PADA_OFF
Corn stalks_near_1	-0.06	-0.24	-1.84
Corn stalks_near_2	0.03	0.13	-1.12
Corn stalks_near_3	-0.02	-0.11	-1.49
Corn stalks_near_4	0.05	-0.07	-1.67

3　讨论

本文提出了一种基于 RGB-D 数据视觉检测和深度信息处理的玉米茎秆直径测量方法,通过将 APCM-DETR 检测模型的骨干网络替换为 APCM 并整合 CBAM 注意力机制,检测模型识别玉米茎秆特征能力得到了显著提升。在此视觉检测模型增强的基础上,DABB 和 PADA 法被作为基于深度的后处理策略,其中 DABB 用于优化检测框以确保有效的深度覆盖,PADA 则用于补偿因拍摄角度偏差引起的测量误差。这种“检测增强 + 深度后处理”的多阶段策略有效减轻了拍摄角度变化带来的影响,在检测结果与直径测量之间建立了明确的方向与几何联系,从而提升了玉米茎秆直径估算精度。相比完全依赖端到端回归的测量方法,多阶段框架在误差来源可控性和结果可解释性方面具有明显优势,为复杂田间环境下作物茎秆性状的高通量测量提供了一种更具通用性的技术路径。

验证该方法是否具备更好的泛化能力是未来研究的重要方向。目前,该方法仍面临以下亟需解决的问题:①使用更广泛的数据集进行评估:本文方法已在自主建立的数据集上得到了有效验证。但由于数据集主要集中于玉米茎部,是否能在基于不同采集条件下获取的玉米信息建立的数据集上取得类似的性能仍有待评估。②多模态数据融合处理:目前工作仍侧重于将 RGB 数据与深度信息对齐。引入额外的数据源,例如 LiDAR 和光谱信息,以辅助纠正拍摄角度,将有助于提高现有方法的测量性能。③对 DABB 和 PADA 方法更广泛评估——目前,DABB 和 PADA 方法评估主要依赖于与映射到三维

点云中 RGB 检测结果进行比较。未来将扩展评估范围,包括与最先进的多模态处理模型以及直接在深度数据上进行检测的方法进行比较,从而更全面地验证所提方法的有效性和稳健性[35]。

4 结论

(1)提出了一种面向田间环境玉米茎秆检测与直径测量方法,融合 RGB 图像与深度信息,并在高通量表型(HTP)机器人平台上进行了实现与验证。通过改进的 APCM - DETR 检测模型以及基于深度信息的 DABB 和 PADA 处理策略,实现了在复杂田间场景下对玉米茎秆的稳定识别与精确测量。

(2)设计了改进模型 APCM - DETR,整合 APCM 模块和 CBAM 注意力机制,增强对背景遮挡的鲁棒性。APCM - DETR 模型精确率 88.2%、召回率 83.4%、F1 分数 85.0%、平均精度均值 85.8%,相较于基线模型,分别提升 0.6、3.1、1、2.2 个百分点,模型内存占用量 54.6 MB、推理速度 121 f/s,相较基线模型,模型内存占用量减少 26.1 MB,推理速度提高 29 f/s。因此 APCM - DETR 模型在复杂田间环境下取得了更高的检测精度和更稳定的检测性能,表现出更好的鲁棒性。

(3)提出了 DABB 方法,利用深度信息调整由 APCM - DETR 模型识别的检测框,通过计算改进的 BoxBorderRatio 和 BoxCountRatio,相比未使用 DABB 检测框,分别提升 8.6 ~ 14.1 个百分点和 11.7 ~ 13.9 个百分点。

(4)引入 PADA 方法,通过点云的旋转补偿测量玉米茎秆直径,使用 PADA 测量的样本得到最大 R^2 为 0.88,测量效果最为显著的 RMSE 为 6.19 mm,相比未使用 PADA 法测量,RMSE 减少 9.36 mm。

参 考 文 献

[1] 杨子姗, 徐率, 赵苑伶, 等. 云南玉米产业发展状况与制约因素[J]. 耕作与栽培, 2022, 42(5): 63 - 67, 71.
YANG Zishan, XU Shuai, ZHAO Yuanling, et al. The development status and constraints of the corn industry in Yunnan[J]. Cultivation and Planting, 2022, 42(5): 63 - 67,71. (in Chinese)

[2] SUN Manxi, WAN Yuan, WANG Shuang, et al. Analysis of the impact of agricultural mechanization on the economic efficiency of maize production[J]. Sustainability, 2024, 16(13): 5522.

[3] YANG L, YANG H, HU B B, et al. A robust driver emotion recognition method based on high-purity feature separation[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24: 15092 - 15104.

[4] YANG L, TIAN Y, SONG Y, et al. A novel feature separation model exchange-GAN for facial expression recognition[J]. Knowledge-Based Systems, 2020, 204: 106217.

[5] YANG L, WEI H, HU Z, et al. A domain generalization method for deploying driver distraction detection models to practical application scenarios[J]. Expert Applications of Artificial Intelligence, 2025, 152: 110844.

[6] 朱惠斌,王明鹏,白丽珍,等.基于视觉识别的玉米病虫害检测与精准变量喷药系统研究[J].农业机械学报,2024,55(增刊 2):210 - 221.
ZHU Huibin, WANG Mingpeng, BAI Lizhen, et al. Maize pest and disease detection and precise variable spraying system based on visual recognition[J]. Transactions of the Chinese Society for Agricultural Machinery,2024,55(Supp. 2):210 - 221. (in Chinese)

[7] 江庆,安东,韩华宇,等.基于激光雷达与 RGB 相机融合的玉米作物行检测算法研究[J].农业机械学报,2024,55(10):263 - 274.
JIANG Qing, AN Dong, HAN Huayu, et al. Maize crop row detection algorithm based on fusion of LiDAR and RGB camera [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(10):263 - 274. (in Chinese)

[8] 程曼,袁洪波,蔡振江,等.田间作物高通量表型信息获取与分析技术研究进展[J].农业机械学报,2020,51(增刊 1):314 - 324.
CHENG Man, YUAN Hongbo, CAI Zhenjiang, et al. Review of field-based information acquisition and analysis of high-throughput phenotyping[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020,51(Supp. 1):314 - 324. (in Chinese)

[9] 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)

[10] 刘文波,叶涛,李颀.基于改进 SOLO v2 的番茄叶部病害检测方法[J].农业机械学报,2021,52(8):213 - 220.
LIU Wenbo, YE Tao, LI Qi. Tomato leaf disease detection method based on Improved SOLO v2[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021,52(8):213 - 220. (in Chinese)

[11] WANG C, HE W, NIE Y, et al. Gold - YOLO: efficient object detector via gather-and-distribute mechanism[J]. Advances in Neural Information Processing Systems, 2023, 36: 51094 - 51112.

[12] ZHAO Y, LU W, XU S, et al. Detrs beat yolos on real-time object detection[C]// Proceedings of the IEEE/CVF Conference

on Computer Vision and Pattern Recognition, 2024: 16965 - 16974.
[13] YAO J, ZHU Z, YUAN M, et al. The detection of maize leaf disease based on an improved real-time detection transformer model[J]. Sensors, 2025, 17: 808.
[14] WU Y, YUAN S, TANG L, et al. Plant recognition of maize seedling stage in UAV remote sensing images based on H - RT - DETR[J]. Plant Methods, 2025, 21: 60.
[15] WU R, WANG H, CHEN H, et al. A comprehensive survey on deep multimodal learning with missing modality[J]. arXiv preprint, arXiv:2409.07825, 2024.
[16] DENG L, YANG M, LI T, et al. RFBNet: deep multimodal networks with residual fusion blocks for RGB - D semantic segmentation[J]. arXiv preprint arXiv:1907.00135, 2019.
[17] ATEFI A, GE Y, PITLA S, et al. Robotic detection and grasp of maize and sorghum: stem measurement with contact[J]. Robotics, 2020, 9(3): 58.
[18] LIU B, CHANG J, HOU D, et al. Recognition and localization of maize leaf and stalk trajectories in RGB images based on point-line net[J]. Plant Phenomics, 2024, 6:199.
[19] ZHOU J, CUI M, WU Y, et al. Detection of diameter by using RGB - D cameras depth information under selected field condition[J]. Frontiers in Plant Science, 2024, 15: 1371252.
[20] 陈燕,李想,曹勉,等.基于语义分割与实例分割的玉米茎秆截面参数测量方法[J].农业机械学报,2023,54(6):214 - 222.
CHEN Yan, LI Xiang, CAO Mian, et al. Measurement of maize stem cross section parameters based on semantic segmentation and instance segmentation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 214 - 222. (in Chinese)
[21] YU Z, YE J, LI C, et al. TasselLFANet: a novel lightweight multi-branch feature aggregation neural network for high-throughput image-based maize tassels detection and counting[J]. Frontiers in Plant Science, 2023, 14: 1158940.
[22] ZHOU J, WU Y, CHEN J, et al. Contour extraction and diameter measurement based on adaptive threshold segmentation in field conditions[J]. Agriculture, 2023, 13: 678.
[23] GAO Y, LI Z, LIU T, et al. Point cloud completion of occluded corn with a 3D positional gated multilayer perceptron and prior shape encoder[J]. Agriculture, 2025, 15: 1155.
[24] SONG P, LI Z, YANG M, 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.
[25] 沈跃,潘成凯,刘慧,等.基于改进 SIFT - ICP 算法的 Kinect 植株点云配准方法[J].农业机械学报,2017,48(12):183 - 189.
SHEN Yue, PAN Chengkai, LIU Hui, et al. Method of plant point cloud registration based on Kinect of improved SIFT - ICP [J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(12): 183 - 189. (in Chinese)
[26] KARIM M R, REZA M N, JIN H, et al. Application of LiDAR sensors for crop and working environment recognition in agriculture: a review[J]. Remote Sensing, 2024, 16: 4623.
[27] 徐圣林,朱立成,韩振浩,等.作物表型信息获取机器人底盘设计与试验[J].农业机械学报,2023,54(增刊 2):388 - 399.
XU Shenglin, ZHU Licheng, HAN Zhenhao, et al. Design and experiment of robot chassis for obtaining crop phenotyic information[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 2): 388 - 399. (in Chinese)
[28] ESSER F, ROSU R A, CORNELIßEN A, et al. Field robot for high-throughput and high-resolution 3D plant phenotyping: towards efficient and sustainable crop production[J]. IEEE Robotics & Automation Magazine, 2023, 30: 20 - 29.
[29] FAN Z, SUN N, QIU Q, et al. In situ measuring stem diameters of maize crops with a high-throughput phenotyping robot[J]. Remote Sensing, 2022, 14: 1030.
[30] VIT A, SHANI G. Comparing RGB - D sensors for close range outdoor agricultural phenotyping[J]. Sensors, 2018, 18: 4413.
[31] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]// European Conference on Computer Vision, 2020: 213 - 229.
[32] 李沂杨,陆声链,王继杰,等.基于 Transformer 的 DETR 目标检测算法研究综述[J].计算机工程, 2026,52(4):62 - 81.
LI Yiyang, LU Shenglian, WANG Jijie, et al. A comprehensive review of the DETR object detection algorithm based on transformer[J]. Computer Engineering, 2026, 52(4): 62 - 81. (in Chinese)
[33] YANG J, LIU S, WU J, et al. Pinwheel-shaped convolution and scale-based dynamic loss for infrared small target detection[J]. arXiv preprint arXiv:2412.16986, 2024.
[34] WOO S, PARK J, LEE JY, et al. CBAM: convolutional block attention module[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 - 19.
[35] MIAO Y, PENG C, WANG L, et al. Measurement method of maize morphological parameters based on point cloud image conversion[J]. Computers and Electronics in Agriculture, 2022, 199: 107174.