

基于轻量化 DeepLabV3 + 的作物茎粗测量方法

李莉¹ 李昱熹¹ 杨佳昊² 冉杨² 葛世龙¹ 仇瑞承³

(1. 中国农业大学农业农村部农业信息获取技术重点实验室, 北京 100083;
2. 中国农业大学智慧农业系统集成研究教育部重点实验室, 北京 100083;
3. 中国农业大学信息与电气工程学院, 北京 100083)

摘要: 茎粗是作物长势的关键表型参数,其原位实时无损监测对优化农业生产管理具有重要意义。本研究利用集成 VPU 加速单元的 OAK-D 相机获取番茄茎秆 RGB-D 数据,对以 MobileNetV2 为主干的 DeepLabV3+ 语义分割模型实施剪枝与微调,构建轻量化网络。依托该轻量化网络输出的高保真二值化分割掩膜,利用骨架线算法提取茎秆平面像素宽度,并融合区域深度信息解算真实茎粗。试验结果表明,与原 DeepLabV3+、U-Net、PSPNet 及 BiSeNetV2 模型相比,轻量化 DeepLabV3+ 展现出卓越的工程部署优势。参数量减至 1.48×10^6 ,模型内存占用量仅 4.03 MB,在 OAK-D 端帧率为 5.50 f/s。在参数规模大幅缩减的同时,模型像素级感知力并未退化,精确率、召回率、F1 分数与 IoU 分别达 96.03%、96.19%、96.11% 与 92.51%。基于该高质量分割基底,茎粗计算值均值与中值决定系数 R^2 分别达到 0.987 和 0.990。所提面向边缘设备的轻量化测量方法,可为温室移动在线巡检装备的嵌入式感知系统设计及智慧灌溉管理提供理论依据与技术支撑。

关键词: 作物茎粗; 双目视觉; DeepLabV3+; 轻量化模型; 边缘计算; 在线监测

中图分类号: TP391.4; TP181 文献标识码: A 文章编号: 1000-1298(2026)14-0032-07 OSID: 

Crop Stem Diameter Measurement Method Based on Lightweight DeepLabV3 +

Li Li¹ Li Yuxi¹ Yang Jiahao² Ran Yang² Ge Shilong¹ Qiu Ruicheng³

(1. Key Laboratory of Agricultural Information Acquisition Technology, Ministry of Agriculture and Rural Affairs, China Agricultural University, Beijing 100083, China
2. Key Laboratory of Smart Agriculture System Integration, Ministry of Education, China Agricultural University, Beijing 100083, China
3. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: Stem diameter is a critical phenotypic parameter of crop growth. Its in-situ, real-time, and non-destructive monitoring is of great significance for optimizing agricultural production management. It utilized an OAK-D camera integrated with a VPU acceleration unit to acquire RGB-D data of tomato stems. Pruning and fine-tuning were utilized to a MobileNetV2-based DeepLabV3+ semantic segmentation model to construct a lightweight network. Relying on the high-fidelity binarized segmentation masks outputed by this lightweight network, a skeletonization algorithm extracted the planar pixel width of the stems. This width was then fused with regional depth information to calculate the actual stem diameter. Experimental results indicated that, compared with the original DeepLabV3+, U-Net, PSPNet, and BiSeNetV2 models, the lightweight DeepLabV3+ demonstrated remarkable engineering deployment advantages. Its parameter count was reduced to 1.48×10^6 , the model memory footprint was only 4.03 MB, and the frame rate on the OAK-D side was 5.50 f/s. Despite the substantial reduction in parameter scale, the pixel-level perception capability of the model did not degrade. Precision, recall, F1 score, and IoU reached high levels of 96.03%, 96.19%, 96.11%, and 92.51%, respectively. Based on this high-quality segmentation foundation, the mean and median determination coefficients (R^2) of the calculated stem diameters reached 0.987 and 0.990, respectively. The proposed lightweight measurement method oriented toward edge devices provided a theoretical basis and technical support for the design of embedded perception systems in greenhouse mobile inspection equipment and smart irrigation management.

Key words: crop stem diameter; binocular vision; DeepLabV3+; lightweight model; edge computing; online monitoring

收稿日期: 2026-03-20 修回日期: 2026-04-11
基金项目: 农业农村部重点攻关项目(NK2023XXXX)
作者简介: 李莉(1978—),女,副教授,博士生导师,主要从事智慧农业和农业信息化技术研究, E-mail: lily@cau.edu.cn

0 引言

茎粗是评价作物长势、抗倒伏能力的关键表型参数^[1]。传统接触式测量方式效率低且易损伤植株,难以满足设施园艺高通量、无损监测的需求。相比激光雷达^[2-3]的高成本与飞行时间相机^[4-5]的光照敏感性,双目视觉凭借成本优势及 RGB-D 数据获取能力,是复杂环境下表型获取的理想手段^[6-7]。

茎粗视觉测量早期研究多依赖颜色空间与形态学骨架提取定位茎秆中心^[8-9],但缺乏深度信息且易受光照影响、鲁棒性差。借助深度学习技术,YOLO 等目标检测模型能够在复杂背景中有效计算茎秆宽度^[10],但输出的矩形边界框无法精准贴合不规则茎秆边缘,导致测量值几何误差难以消除。

为解决矩形框的精度局限,基于全卷积神经网络(FCNN)的语义分割技术逐渐成为主流。特别是 DeepLabV3+ 模型,其空洞空间金字塔池化(ASPP)模块在多尺度特征提取与边缘恢复方面表现卓越,为细长茎秆精细化分割提供了理论基础^[11-13]。

引入实例分割技术能提高边缘提取精准度^[14],但高精度模型网络结构复杂,依赖高性能 GPU,难以在资源受限的巡检机器人或物联网终端上部署。

为解决上述“高精度分割”与“边缘算力受限”矛盾,本研究提出一种面向 VPU 的嵌入式轻量化测量方法。通过轻量化重构 DeepLabV3+ 网络以适应边缘推理,利用 OAK-D 相机片上算力获取目标区域深度,并结合“骨架线-区域深度”融合算法计算真实茎粗,以期实现温室作物茎粗的低成本、实时与高精度原位监测。

1 材料与方法

1.1 样本采集与预处理

试验选取 10 株茎粗 4~15 mm 番茄样本。用无损碳素墨水标记目标茎节,规避多株识别、全株茎秆提取的算力冗余。

1.1.1 样本采集

试验在北京市平谷区峪口镇设施农业智慧云服务系统产业化博士农场 3 号棚(40°17'N, 117°01'E)开展。试验基地日光温室环境如图 1 所示。

选用‘原味一号’番茄品种,采用基质袋栽培。对应的栽培基质由草炭、蛭石和珍珠岩按比例 3:1:1 组成。水肥系统在晴天 11:00 通过滴灌方式为植株根部补充水肥,阴天则不进行灌溉。针对处于第 5 穗果结果期的番茄植株,从 2024 年 1 月 10 日起开展不间断数据采集。使用 OAK-D 双目相机采集番茄茎秆 RGB-D 图像。利用支架将相机平行于番茄



图 1 试验基地日光温室环境
Fig. 1 Environmental conditions within solar greenhouse at experimental station

种植行固定,镜头离地面高 1 m,与目标茎秆距离 0.2~0.5 m。主要拍摄番茄 2 片复叶间的茎段。在晴天 10:00,对每株茎秆重复拍摄 5 次,同时用游标卡尺测量并记录茎粗。最终采集双目图像共 900 幅。采集图像原始分辨率为 3 024 像素×4 032 像素。双目相机获取的左、右目图像如图 2 所示。




图 2 双目相机采集的番茄茎秆图像
Fig. 2 Tomato stem images acquired by binocular camera

1.1.2 数据预处理

截取左目图像,作为模型数据集,按比例 8:1:1 随机划分为训练集、验证集与测试集。针对温室环境,需同时克服番茄茎秆弯曲、倾斜等复杂姿态形变及光照强度变化的干扰。为提高训练模型的鲁棒性和泛化性,通过数据增强技术定向处理训练集图像。对训练集图像实施旋转、亮度调节、对比度变换等操作,最终扩充至 4 000 幅。增强后训练集如图 3 所示。




图 3 茎秆训练集增强图像
Fig. 3 Data augmentation of stem training set

模型训练与评价使用 Intel Core i7-13650HX 处理器、24 GB 内存以及 NVIDIA RTX 4060 显卡的计算平台(联想 Legion Y7000 IRX9),在 Windows 11 操作系统下,基于 Python 3.10 与 PyTorch 2.2.0 深

度学习框架(配合 CUDA 12.2 与 OpenCV 4.6),完成日光温室基质栽培番茄茎秆图像数据集网络训练(迭代次数设为 50)。训练完成后的模型转换为“.blob”固件格式,依托内置 Intel Myriad X VPU(算力 4 TOPS)的 OAK-D 相机,在 DepthAI Gen2 开发框架下利用 Python 脚本实现端侧实时分割与推理。

在开源平台 Roboflow 上,对碳素标记点附近的茎段边缘实施添加多边形注释进行手动分割。生成的掩膜文件以“.PNG”格式保存,原始图像与标注图像如图 4 所示。




图 4 原始图像及标注图像

Fig. 4 Original and annotated images

1.2 基于骨架线法的茎粗测量方法

提出了一种融合双目视觉、图像分割与骨架线法的作物茎粗测量方法,整体运行依托 OAK-D 相机与主机协同完成,工作流程如图 5 所示。




图 5 茎粗测量流程

Fig. 5 Workflow of stem-diameter measurement

1.2.1 双目深度图获取

双目立体视觉通过计算左右视图的像素视差,并结合相机参数解算目标的真实物理深度。预先基于标准棋盘格法完成相机标定^[15],依托相机内置的 VPU,在边缘端处理图像,实时输出高精度深度图。

1.2.2 图像分割模型

针对温室环境复杂的背景噪声与非目标枝叶干扰,选取具备多尺度上下文融合能力的 DeepLabV3 + 模型执行茎部图像分割任务,网络结构如图 6 所

示^[16-17]。轻量化主干网络选用 MobileNetV2,以满足农业现场边缘设备的高效推理需求。




图 6 DeepLabV3 + 网络结构

Fig. 6 DeepLabV3 + network architecture

1.2.3 分割模型轻量化

为解决 DeepLabV3 + 模型参数量过大导致 OAK-D 相机边缘设备推理帧率低的问题,引入基于批量归一化(BN)层缩放因子 γ 的通道剪枝策略^[18]。

如图 7 所示,通过在损失函数内施加针对 γ 的 L1 正则化惩罚项,网络得以产生结构性稀疏,使低贡献度通道的 γ 逐渐向零收敛。在此稀疏化特性的基础上,算法全局评估各通道的激活强度,直接剔除 γ 趋近于零的冗余通道及其关联连接,进而大幅压缩模型参数规模与计算负载。




图 7 剪枝过程示意图

Fig. 7 Schematic of pruning process

为弥补通道剪枝导致的局部边缘特征丢失,将剪枝后的精简网络在原始番茄数据集上微调 50 轮。该参数自适应恢复机制能够引导网络利用剩余的高效通道重新拟合数据分布,有效弥补性能损耗。

1.2.4 基于骨架线的宽度检测算法

为获取茎秆的精确几何尺寸,对轻量化 DeepLabV3 + 输出的二值化分割掩膜(分辨率为 1 920 像素×1 080 像素)进行骨架化处理^[19-21]。基于骨架线法的宽度检测见图 8。

根据得到的茎部区域宽度像素数与深度图像结合计算茎粗,计算式为

$$S_d = \frac{2D \tan\left(\frac{1}{2}\theta\right)}{R} P \tag{1}$$




图 8 基于骨架线法的宽度检测示意图

Fig.8 Schematics of width detection using skeleton line method

式中 S_d ——茎粗,mm
 θ ——相机水平视场角, (°)
 D ——通过深度图获得的目标区域深度,mm
 R ——分割掩膜水平分辨率,像素
 P ——通过骨架线法获得的茎部区域宽度像素,像素

1.3 评价指标

(1)模型分割性能:选用精确率、召回率、F1 分数与交并比(IoU) [22] 作为核心测试指标。受温室边缘计算的物理算力约束,进一步将浮点运算量(FLOPs)、参数量、模型内存占用量以及推理帧率(FPS)纳入考量。

(2)茎粗测算精度:针对每组试验 5 次测量结果,分别求取均值、中值及绝对偏差,并引入决定系数(R^2)、均方根误差(RMSE)与平均绝对误差(MAE)综合量化提取误差。

2 结果与讨论

2.1 模型性能试验

为全面评估所提轻量化 DeepLabV3 + 模型在番茄茎秆分割任务中的综合表现,选取原模型 DeepLabV3 +、经典轻量化网络 PSPNet [23]、高精度分割算法 U - Net [24] 以及实时分割算法 BiSeNetV2 [25] 进行性能对比分析。各模型在训练集与验证集上损失值变化曲线如图 9 所示。

由图 9a 可知,模型训练阶段,轻量化 DeepLabV3 + 展现出高效的特征学习能力,首轮训练损失值仅为 0.071,并以最快速度逼近收敛下限。这一表现证实通道剪枝并未削弱网络对底层物理特征的提取效能。

由图 9b 可知,轻量化 DeepLabV3 + 验证阶段首轮误差低至 0.049 8,并在整个迭代周期内维持极低的误差基线。在收敛后期(30 ~ 50 轮)的局部放大区域,面对温室侧枝严重遮挡等高难度样本时,轻量化 DeepLabV3 + 模型与 U - Net、BiSeNetV2 均不可避免地触发单轮次尖峰跳变。相比之下,本文模型凭借自适应纠错机制迅速响应,于下一轮次实现损




图 9 不同模型损失值变化曲线

Fig.9 Loss curves for different models

失值回落,最终极度平稳地收敛于 0.006 6。可见本文模型在大幅削减参数冗余后,依然对复杂的农业现场干扰保持卓越的鲁棒性。

验证集 IoU 动态曲线直观反映了各模型对番茄茎秆的分割精度。如图 10 所示,迭代初期,U - Net 与 PSPNet 首轮 IoU 为 0,存在显著的冷启动认知困难;而轻量化 DeepLabV3 + 依托优化架构,首轮 IoU 即高达 53.90%,并在第 5 轮迅速突破 80%,展现出极强的温室背景剥离与目标适应能力。在训练中后期,模型逼近拟合极限,轻量化 DeepLabV3 + 在第 37 轮遭遇高难度样本干扰,IoU 短暂回落至 82.40%。然而,相较于 U - Net 在第




图 10 不同模型验证集上茎秆 IoU 变化曲线

Fig.10 IoU curves of stem segmentation on validation set for different models

41、42 轮 (至 84.70%) 的剧烈震荡,本文模型迅速激活特征补偿机制,在 2 轮训练后重回 90% 以上,最终收敛于 92.36%,在第 49 轮达峰值 (92.51%)。可见,结构化剪枝不仅大幅剔除了计算冗余,更完整保留了网络对复杂农业现场的高精细分割与抗干扰能力。

由表 1 可知,U-Net 虽分割精度最高,但帧率低,

无法满足端侧实时分割需求。轻量化 DeepLabV3 + 模型通过结构化剪枝展现了卓越的压缩效率,参数量、模型内存占用量与浮点运算量较原网络均大幅缩减。在 OAK - D 端侧,轻量化 DeepLabV3 + 帧率为 5.50 f/s,尽管不及 BiSeNetV2 凭借双分支拓扑结构帧率 (7.71 f/s),但在大幅削减资源占用前提下,本模型 IoU、F1 分数与 BiSeNetV2 相当。

表 1 不同分割模型性能比较结果

Tab.1 Performance comparison of different segmentation models

模型	主干网络	浮点运算量	模型内存 占用量/MB	参数量	帧率/ (f·s ⁻¹)	交并比/ %	精确率/ %	召回率/ %	F1 分 数/%
DeepLabV3 +	MobileNetV2	5.068×10^{10}	29.58	1.335×10^7	1.85	92.40	95.71	96.39	96.05
U-Net	Native CNN	4.379×10^{11}	61.91	3.104×10^7	0.31 (OOM ^b)	93.48	96.23	97.03	96.63
PSPNet	MobileNetV2	5.013×10^{9a}	30.98	1.416×10^7	6.63	85.38	92.83	90.83	91.82
BiSeNetV2	Dual-branch	1.689×10^{10}	2.30	1.150×10^6	7.71	92.60	96.25	96.06	96.16
轻量化 DeepLabV3 +	MobileNetV2	1.342×10^{10}	4.03	1.480×10^6	5.50	92.51	96.03	96.19	96.11

注:a:由于 PSPNet 的结构特性,其浮点运算量是在输入分辨率 384 像素×384 像素统计所得;其余模型均统一在分辨率 512 像素×512 像素进行评估。b:端侧帧率测试基于 OAK - D (Myriad X VPU) 硬件,OOM 指显存溢出导致推理停滞。

2.2 茎秆分割模型性能评估

选取直立、弯曲与倾斜 3 种典型姿态番茄茎秆图像进行定性分割 (图 11)。各模型均能实现目标区域的基础识别,但轻量化 DeepLabV3 + 的掩膜形

态与人工标注真值实现高度吻合。无论植株处于何种生长姿态,该模型均能准确还原其物理轮廓。这种高保真的二维分割结果有效排除了背景干扰,为规避骨架线分支误判及实现高精度双目测算茎粗奠




图 11 不同分割模型茎秆分割效果

Fig.11 Stem segmentation results of different models

定了可靠基础。

2.3 茎粗测量精度

为检验算法在实际温室环境中测量性能,选取直立、弯曲和倾斜 3 种典型生长姿态的番茄茎秆进行测试,实际处理效果如图 12 所示。

由图 12 可知,目标茎秆主体区域被清晰、完整地剥离,而背景中无关枝叶几乎未被误判。模型精准识别了绝大部分真实茎秆像素,漏检率极低,充分

说明该分割算法能有效抑制复杂环境噪声。

骨架线提取结果表明,主骨架线精准定位于轮廓中央,仅 2 端出现少量分叉,主要是由于不规则轮廓在端点处闭合角度较小,导致算法发生局部形态误判。

结合茎秆区域宽度像素分布图可知,茎秆中段的稳定宽度数据占据绝对主导,而 2 端异常较小的宽度占比极低,表明骨架线法有效克服了端点畸变




图 12 茎秆处理效果

Fig. 12 Results of stem processing

的干扰,能准确提取茎秆主体真实宽度。

融合双目视觉、图像分割与骨架线提取技术构建了测量算法,依据式(1)对 10 组番茄茎秆茎粗进行计算。算法计算值与游标卡尺实测真值结果如表 2 所示。计算所得番茄茎粗均值和中值 R^2 分别为 0.987 和 0.990, RMSE 分别为 0.195 mm 和 0.152 mm, MAE 分别为 0.184 mm 和 0.136 mm。实现对番茄茎粗的非接触式精准无损检测,验证所提茎粗测量方法的有效性。

表 3 为 3 种不同姿态下,算法计算值(均值、中值)与茎粗真值及绝对误差。对于直立与倾斜茎秆,均值计算能保持较高的贴合度;但在处理弯曲茎秆时,由于局部非规则形变易引入极端像素干扰,均值绝对误差扩大至 0.5 mm。采用中值策略能有效滤除这类结构噪声,将绝对误差回落至 0.3 mm。

值得注意的是,实际测量精度受物距影响显著。在分辨率 1 920 像素×1 080 像素下,当目标茎秆与

表 2 茎粗算法计算值与真值

Tab. 2 Calculated and ground truth values of

stem diameter					
mm					
序号	真值	算法计算 均值	均值绝对 误差	算法计算 中值	中值绝对 误差
1	5.6	5.5	0.1	5.5	0.1
2	6.5	6.3	0.2	6.4	0.1
3	7.6	7.4	0.2	7.5	0.1
4	8.5	8.3	0.2	8.3	0.2
5	9.7	9.6	0.1	9.6	0.1
6	10.1	10.2	0.1	10.1	0.1
7	11.7	11.4	0.3	11.5	0.3
8	12.5	12.2	0.3	12.2	0.3
9	13.6	13.4	0.2	13.5	0.2
10	14.2	14.3	0.1	14.3	0.1

表 3 3 种姿态茎粗算法计算值与真值

Tab. 3 Calculated and ground truth values of

stem diameter under three postures					
mm					
茎秆 姿态	真值	算法计算 均值	均值绝对 误差	算法计算 中值	中值绝对 误差
直立	9.7	9.5	0.2	10.1	0.4
弯曲	8.7	8.2	0.5	9.0	0.3
倾斜	10.2	9.9	0.3	10.4	0.3

双目相机距离为 0.2 ~0.5 m 时,单像素对应的三维物理尺寸为 0.2 ~0.5 mm。随着物距增加,三维映射精度呈下降趋势。经测算,当物距增加至 1 m 时,单像素所代表的实际物理误差将放大至约 1 mm。为保障农业现场的高精度测量,严格控制相机与目标作业距离是关键物理约束条件。此外,当前研究尚未在温室巡检机器人等移动场景下开展大规模测试,需进一步提升算法在动态巡检作业中鲁棒性,从而适应更复杂的连续作业环境。

3 结束语

提出了一种面向嵌入式 VPU 的番茄茎秆轻量化在线分割方法。依托 OAK-D 端侧算力,轻量化 DeepLabV3+ 展现出极佳精度与推理速度平衡,验证了轻量化网络在农业边缘计算场景中的部署潜力。构建的“二维骨架线-三维区域深度”融合算法能精准计算茎秆真实物理尺寸,测量 RMSE 低至 0.195 mm,有效规避了非规则轮廓对宽度计算的干扰。

参 考 文 献

[1] 朱磊,江伟,孙伯颜,等. 基于神经辐射场的苗期作物三维建模和表型参数获取[J]. 农业机械学报, 2024, 55(4): 184-192, 230.
Zhu Lei, Jiang Wei, Sun Boyan, et al. Three-dimensional reconstruction and phenotype parameters acquisition of seeding vegetables based on neural radiance fields[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(4):

- 184–192, 230. (in Chinese)
- [2] 苗艳龙, 彭程, 高阳, 等. 基于地基激光雷达的玉米株高与茎粗自动测量研究[J]. 农业机械学报, 2021, 52(增刊1): 43–50.
Miao Yanlong, Peng Cheng, Gao Yang, et al. Automatic measurement of plant height and stem thickness of maize based on terrestrial laser scanning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(S1): 43–50. (in Chinese)
- [3] 杨建儒, 谭凯, 张卫国, 等. 地面激光雷达点云数据中滩涂湿地禾本科植物的茎叶分离方法[J]. 中国激光, 2022, 49(13): 122–130.
Yang Jianru, Tan Kai, Zhang Weiguo, et al. Stalk and leaf separation for poaceae in mudflats and wetlands using TLS data[J]. Chinese Journal of Lasers, 2022, 49(13): 122–130. (in Chinese)
- [4] Vázquez-Arellano M, Paraforos D S, Reiser D, et al. Determination of stem position and height of reconstructed maize plants using a time-of-flight camera[J]. Computers and Electronics in Agriculture, 2018, 154: 276–288.
- [5] Zhou J, Cui M, Wu Y, et al. Detection of maize stem diameter by using RGB–D cameras' depth information under selected field condition[J]. Frontiers in Plant Science, 2024, 15:1371252.
- [6] 刘泽, 赵泽川, 许彤, 等. 考虑全生长周期的吊蔓西瓜表型识别方法研究[J]. 农业机械学报, 2025, 56(3): 119–128.
Liu Ze, Zhao Zechuan, Xu Tong, et al. Phenotypic identification method for whole growth cycle of hanging watermelon[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 119–128. (in Chinese)
- [7] 陈金成, 潘峰, 王佰伟, 等. 基于 RGB–D 相机的苹果疏果期幼果与果柄识别定位方法[J]. 农业机械学报, 2026, 57(5): 177–185.
Chen Jincheng, Pan Feng, Wang Baiwei, et al. Recognition and localization method of young fruit and fruit stalk in apple fruit thinning period based on RGB–D cameras[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(5): 177–185. (in Chinese)
- [8] 张云鹤, 乔晓军, 王成, 等. 基于机器视觉的作物茎秆直径变化测量仪研发[J]. 农机化研究, 2011, 33(12): 158–160.
Zhang Yunhe, Qiao Xiaojun, Wang Cheng, et al. Development of diameter micro-variation measurement instrument for plant stem based on machine vision technology[J]. Journal of Agricultural Mechanization Research, 2011, 33(12): 158–160. (in Chinese)
- [9] 吴艳娟, 王健, 王云亮. 基于骨架提取算法的作物茎秆识别与定位方法[J]. 农业机械学报, 2022, 53(11): 334–340.
Wu Yanjuan, Wang Jian, Wang Yunliang. Crop stem recognition and localization method based on skeleton extraction algorithm [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(11): 334–340. (in Chinese)
- [10] 左昊轩, 黄祺成, 杨佳昊, 等. 基于双目视觉和改进 YOLOv8 的玉米茎秆宽度原位识别方法[J]. 智慧农业(中英文), 2023, 5(3): 86–95.
Zuo Haoxuan, Huang Qicheng, Yang Jiahao, et al. In situ identification method of maize stalk width based on binocular vision and improved YOLOv8[J]. Smart Agriculture, 2023, 5(3): 86–95. (in Chinese)
- [11] 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.
- [12] 范翔宇, 李玥, 魏霖静, 等. 面向收割机影像的轻量化 DeepLabV3+ 胡麻倒伏识别方法[J]. 农业工程学报, 2025, 41(18): 212–219.
Fan Xiangyu, Li Yue, Wei Linjing, et al. Detecting flax lodging from harvester images using lightweight DeepLabV3+[J]. Transactions of the CSAE, 2025, 41(18): 212–219. (in Chinese)
- [13] Hai T, Wang W, Yan F, et al. A deep learning-based approach to apple tree pruning and evaluation with multi-modal data for enhanced accuracy in agricultural practices[J]. Agronomy, 2025, 15(5): 1242.
- [14] Gu J, Zhang T, Ma Z, et al. Measurement and prediction of facility tomato ripening period based on YOLOv11–Seg and LSTM–MHA[J]. Measurement, 2025, 256: 118237.
- [15] 李翔, 梁文宏, 赵文森, 等. 红外相机双目立体视觉系统标定方法[J]. 红外技术, 2025, 47(11): 1365–1371.
Li Xiang, Liang Wenhong, Zhao Wensen, et al. Calibration method for infrared camera binocular stereo vision system[J]. Infrared Technology, 2025, 47(11): 1365–1371. (in Chinese)
- [16] Chen L C, Zhu Y K, George P, et al. Encoder-Decoder with atrous separable convolution for semantic image segmentation[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 801–818.
- [17] Lu Y, Chen J Y, Wu B, et al. A method for locating soil monitoring points in greenhouse cultivation based on DeeplabV3+[J]. Science Progress, 2026, 109(1): 00368504261427079.
- [18] Liu Z, Li J, Shen Z, et al. Learning efficient convolutional networks through network slimming[C]//2017 IEEE International Conference on Computer Vision (ICCV), 2017.
- [19] Wang Y, Liu Q, Yang J, et al. A method for tomato plant stem and leaf segmentation and phenotypic extraction based on skeleton extraction and supervoxel clustering[J]. Agronomy, 2024, 14(1): 198.
- [20] Qi Yikai, Zhou Yang, Xiang Longbin. An automated skeleton extraction method for 3D point-cloud phenotyping of Schima Superba seedlings[J]. PLOS One, 2025, 20(9): e0329715.
- [21] Xu C, Huang T, Niu Z, et al. A skeleton-based method of root system 3D reconstruction and phenotypic parameter measurement from multi-view image sequence[J]. Agriculture, 2025, 15(3): 343.
- [22] Chen X, Duan Q, Wu R, et al. Segmentation of lung computed tomography images based on SegNet in the diagnosis of lung cancer[J]. Journal of Radiation Research and Applied Sciences, 2021, 14(1): 396–403.
- [23] Qiu H, Yang J, Jiang J, et al. Mob-ppsp: modified MobileNet–V2 network for real-time detection of tomato diseases[J]. Journal of Real-Time Image Processing, 2024, 21(5): 181.
- [24] Ronneberger O, Fischer P, Brox T. U–Net: convolutional networks for biomedical image segmentation[M]// Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Cham: Springer International Publishing, 2015: 234–241.
- [25] Yu C, Gao C, Wang J, et al. BiSeNet V2: bilateral network with guided aggregation for real-time semantic segmentation[J]. International Journal of Computer Vision, 2021, 129(11): 3051–3068.