doi:10.6041/j.issn.1000-1298.2026.12.007

基于改进 YOLO 11 的烟苗垄作行导航线提取方法

张秀丽[1]　胡　阔[1]　仝振伟[1]　周　林[1]　周培林[1]　刘剑君[2]　陈　永[1]
(1.河南农业大学机电工程学院,郑州 450002;2.中国烟草总公司河南省公司,郑州 450046)

摘要:针对团棵期前烟苗在田间视觉导航中检测准确率低、模型参数量大等问题,本文提出一种基于改进 YOLO 11 的垄作物行导航线提取方法,有效压缩模型规模并提升田间移动平台作业导航精度。面向烟苗目标检测任务,设计 NewBlock 模块并引入 LightAttention 机制,分别强化 YOLO 11 主干网络特征提取能力与轻量化性能,提升检测效果。构建 BiFPN_ADown 融合结构替代 Neck 中 PANet 结构,实现参数压缩与特征保持平衡。采用 Canny 边缘检测算法提取烟苗外接轮廓计算其生理学质心,结合最小二乘法实现作物行导航线精确拟合。消融试验结果表明,改进模型精确率、召回率和平均精度分别提高 3.9、0.8、1.9 个百分点,计算量降低 47.62%。作物垄上导航线拟合验证结果表明,平均角度误差与距离误差分别为 0.91°与 11.78 像素。在复杂农田环境下,本文算法综合性能优异,可有效平衡检测速度与精度,为烟草及其他垄作物田间机器人视觉导航提供了新思路。

关键词:烟苗;垄作行检测;导航线提取;改进 YOLO 11;边缘检测
中图分类号:TP391.41　　**文献标识码**:A　　**文章编号**:1000-1298(2026)12-0080-10　　**OSID**:

Extraction Method of Navigation Lines for Tobacco Seedling Ridged Rows Based on Improved YOLO 11

ZHANG Xiuli[1]　HU Kuo[1]　TONG Zhenwei[1]　ZHOU Lin[1]　ZHOU Peilin[1]　LIU Jianjun[2]　CHEN Yong[1]
(1. *College of Mechanical and Electrical Engineering, Henan Agricultural University, Zhengzhou* 450002, *China*
2. *Henan Provincial Tobacco Company of CNTC, Zhengzhou* 450046, *China*)

Abstract: Aiming to address the problems of low detection accuracy and large model parameter size in field visual navigation for tobacco seedlings before the rosette stage, a ridge crop row navigation line extraction method was proposed based on an improved YOLO 11. This approach effectively compressed the model size and enhanced the navigation precision of field mobile platforms. To address the tobacco seedling target detection task, a NewBlock module was designed and a LightAttention mechanism was introduced to respectively enhance the feature extraction capability and lightweight performance of the YOLO 11 backbone network, thereby improving detection performance. The BiFPN_ADown fusion structure was constructed to replace the PANet in the Neck, achieving a balance between parameter compression and feature preservation. The Canny edge detection algorithm was employed to extract the external contours of tobacco seedlings and calculate their centroids. Subsequently, combined with the least squares method, precise fitting of the crop row navigation lines was achieved. The ablation experiment results demonstrated that the improved model achieved increases of 3.9, 0.8, and 1.9 percentage points in precision, recall, and mean average precision, respectively, while reducing computational complexity by 47.62%. Validation results for crop ridge navigation line fitting indicated an average angle error of 0.91° and a distance error of 11.78 pixels. In complex farmland environments, the proposed algorithm exhibited superior comprehensive performance by effectively balancing detection speed and accuracy, providing a solution for the visual navigation of field robots in tobacco and other ridge crop operations.

Key words: tobacco seedlings; row detection; navigation line extraction; improved YOLO 11; edge detection

收稿日期:2025-12-15　修回日期:2026-01-27
基金项目:河南省科技攻关项目(242102110349)、河南省自然科学基金项目(252300421922)和中国烟草总公司河南省公司重大科技专项(2024410000240026)
作者简介:张秀丽(1973—),女,教授,博士生导师,主要从事智能农业装备研究,E-mail:zhangxiuli619@126.com
通信作者:陈永(1987—),男,副教授,博士,主要从事智能农业机械设计研究,E-mail:chenyong@henau.edu.cn

0　引言

烟草作为我国重要的经济作物，在农业经济中占据关键地位，种植规模庞大，产业影响力深远。随着精准农业的发展，农业机械自动导航是精准农业应用的热门核心技术之一，是实施精准农业的基础[1-2]。在烟草田间管理除草环节，精准的导航线可保障机器在田间跨垄稳定穿行，提升作业效率，减少人工干预成本。

高垄阔叶类烟草作物垄形复杂、行内结构差异显著，使得团棵期前烟苗精准行线提取研究相对不足。农业机器人导航方法包括全球导航卫星系统（GNSS）、机器视觉系统和激光雷达系统[3]。GNSS 导航在大田作业中具有较好的全局一致性，但在烟田垄作环境下易受植株遮挡和地形起伏影响，难以准确反映实际垄行结构；激光雷达虽可获取高精度三维信息，但成本较高，且在植株密集或多尘环境下可能受到一定干扰[4]。相较于依赖绝对定位信息或高精度传感的传统导航方案，基于视觉的导航线提取通过直接感知作物行结构，可实现相对位置约束下精细行间导航，在复杂田间环境中具备更好的适应性和垄行精细对准能力。为提升团棵期前烟苗农业机械化水平，亟待开发一种能够适应作物早期生长特性、且对环境干扰具有强鲁棒性的智能视觉导航算法，实现垄作物行导航线精准提取。

基于机器视觉的导航线提取分为传统色彩空间特征的提取方法和深度卷积神经网络的自动特征学习方法两大类[5]。传统机器视觉方法多通过颜色分量、光谱特征或形态学特征差异实现作物与背景的区分[6-7]。在图像处理方法中，作物与背景的区分通常依赖归一化差值植被指数（NDVI）或颜色分量、光谱特征差异构建二值化特征图，并结合 Otsu 阈值分割或粒子群优化算法实现有效分割[8]。为应对不同光照条件对特征提取的影响，部分研究通过改进 ExG 算法进行作物分割或结合图像 RGB 色彩特征的方法，提高了特征提取在光照变化条件下鲁棒性[9-10]。导航线拟合方法常用最小二乘法、霍夫变换或水平条带投影法，霍夫变换计算量大且多直线场景下准确率较低[11]，水平条带投影法在作物高度不一致时易产生偏差。杨洋等[12]基于车轮前方动态 ROI 及最小二乘法提取导航线。GONG 等[13]利用根茎特征结合霍夫变换，提升了复杂环境下分割精度。传统特征提取算法主要聚焦于低维特征，难以充分捕捉图像中复杂的结构和语义信息，在光照变化、叶片交错及背景干扰等复杂环境下，上类方法鲁棒性亦显不足。为可靠提取作物定位点，计算机视觉与深度学习技术在农业领域得到广泛应用[14]。基于深度学习的目标检测算法可以分为两大类：两阶段算法和单阶段算法[15]。卷积神经网络（Convolutional neural network，CNN）常作为特征提取网络被嵌入到单阶段或两阶段目标检测框架中，用于学习图像中目标的深层次特征表示[16-17]，在准确性和鲁棒性方面都远胜传统图像处理方法。单阶段算法，也称为基于回归的物体检测算法，包括 SSD、YOLO 系列和 RetinaNet[18]。近年来，研究多采用 R-CNN 及 U-Net 等卷积神经网络的方法以提升复杂环境下目标识别能力与抗干扰性能[19-21]。为进一步满足导航作业实时性需求，具有检测速度优势的 YOLO 等单阶段算法也逐渐成为主流，广泛应用于菠萝、玉米、葡萄等不同作物的田间场景进行特征点定位及性能检测[22-24]。然而，现有模型在提升精度的同时往往伴随着巨大的计算冗余，导致在算力受限的嵌入式终端上，难以实现轻量化架构、高检测精度与实时推理之间的理想平衡。

综上，为提升高垄作物烟苗在复杂环境下行线识别精度，本文基于前期研究[25-26]，提出一种改进 YOLO 11 的目标检测网络结构，并通过边缘轮廓分割获取作物几何特征信息进行导航线提取。通过优化后网络结构降低计算资源并增强对环境变化的适应性，同时构建基于 Canny 边缘检测算法和多角度评估作物垄行中心线后处理框架，应对田间作物静态偏差等复杂场景，以期实现精准、快速提取烟苗垄行导航线，为团棵期前烟苗精准行线检测提供技术参考。

1　材料与方法

1.1　图像采集

烟苗图像采集于河南省许昌市河南农业大学烟草试验田，田间采用垄作模式，垄距为 1.1～1.3 m，株距为 0.5～0.6 m。田间移动平台以跨垄方式行驶获取移栽后烟苗图像，具体布置如图 1 所示。图像采集设备包括 Intel RealSense D455 型深度相机（Intel Corp.，美国）和 iPhone 15 型智能手机（Apple Inc.，美国），数据存储与处理由惠普 Pavilion 15-eg 系列便捷式计算机（HP Inc.，美国）完成。采集设备安装在田间移动平台前端中心位置，通过伸缩杆与 C 形夹固定。相机安装高度为 1.45～1.55 m，光轴与水平方向夹角设为 40°～50°，可保证单帧图像覆盖行驶垄上 4～6 株烟苗，并将观测范围控制在 3 垄以内，从而兼顾行结构提取精度与干扰目标抑制。该采集模式下，行驶垄中心线被定义为导航基准线，用于后续路径规划与跟踪控制。本文方法仅使用

RGB 图像作为算法输入，不区分具体采集设备来源。

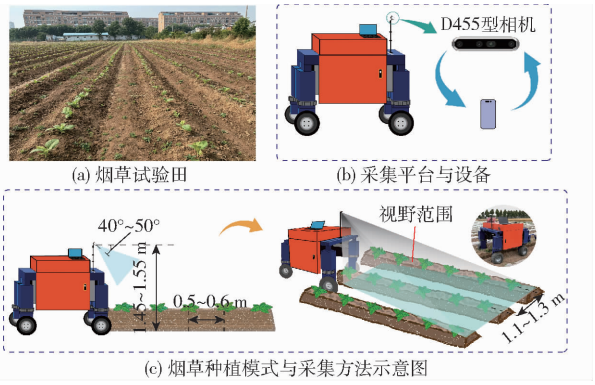


图 1 图像采集过程

Fig. 1 Image acquisition process

1.2 数据集构建

为构建用于训练并验证团棵期前烟苗生长阶段智能识别模型的高质量标注图像数据集，将数据集聚焦于大田移栽后还苗期和伸根期 2 个阶段的烟苗，此阶段是杂草竞争加剧且适合田间作业平台操作的有效作业窗口。采集的烟苗涵盖移栽后还苗期、伸根期、杂草、光线干扰和覆膜等场景，共获取 1 200 幅不同类型的原始图像，数据集如图 2 所示。

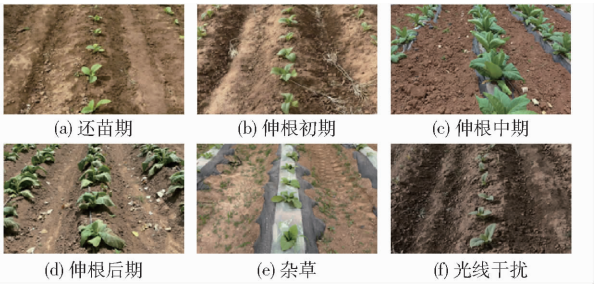


图 2 图像数据集构建

Fig. 2 Image dataset construction

为了增强数据集泛化能力并防止过拟合，通过垂直镜像、旋转变换、平移变换、亮度调整等扩展图像至 6 500 幅（训练集 5 200 幅，验证集 1 300 幅），并使用 Labelimg 应用程序对数据集进行标记，将其导出为 YOLO 训练所需的文本格式。

2 基于改进 YOLO 11 烟苗检测模型

2.1 YOLO 11 模型

在现有深度学习方法中，具有代表性的单阶段检测算法 YOLO 11 在常见场景下实现了速度和精度平衡，延续了分尺度设计的思路，依据深度与宽度差异采用动态缩放策略构建 n、s、m、l、x 5 个规格，其中 YOLO 11n 为最轻量化版本，兼具响应速度与部署友好性[27]，其亚尺度设计提供的轻量化多尺度特征提取能力，完美满足团棵期前烟苗检测准确性、速度和边缘计算部署的综合要求。

YOLO 11 延续经典的端到端架构，包含输入端、骨干网络（Backbone）、颈部（Neck）与检测头（Head）等组件，并在模块层级进行多项关键改进。相较于 YOLO v10 与 YOLO v8 等系列，YOLO 11 引入了紧凑卷积核 C3k2 模块（Compact3 × 3 Kernel Module，C3k2），C3k2 模块基于传统 C3 模块改进设计，通过结合可变卷积核（例如 3 × 3、5 × 5 等）和通道分离策略，提供了更强大的特征提取能力，尤其适用于更复杂场景和深层次的特征提取任务。

2.2 改进 YOLO 11 模型

为适应复杂环境背景下团棵期前烟苗识别与检测任务，以 YOLO 11n 为基础模型，首先在网络多个层级，将 C3k2 模块中 Bottleneck 卷积模块替换为设计的 NewBlock 模块，可在保证性能的同时增强特征提取能力，提升复杂背景下烟苗检测效果。其次，将颈部网络中 PANet 结构替换为 ADown 模块结合 BiFPN 结构的形式，该结构在传统特征金字塔网络（FPN）基础上进行优化，能够在降低特征图空间分辨率的同时保留更多语义信息，并避免传统池化或固定步长卷积造成的信息丢失。通过压缩模型参数量，进一步提高模型识别效率。通过引入 NewBlock 与 BiFPN_ADown 模块，提出的改进 YOLO 11 网络模型（NB－YOLO 11）结构如图 3 所示。

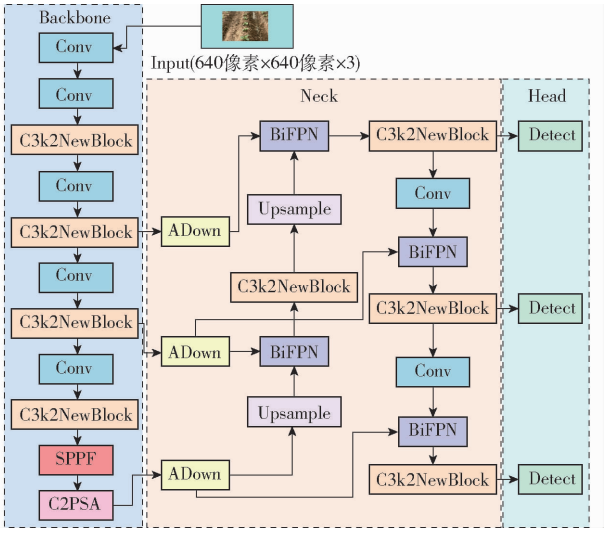


图 3 NB－YOLO 11 模型结构

Fig. 3 Structure diagram of NB－YOLO 11 model

2.3 C3k2NewBlock 模块

在 YOLO 11 网络中，原有骨干网络采用的 C2f 模块被 C3k2 模块替代，C3k2 对 CSPBottleneck 结构进行优化，通过引入并行卷积结构替代单一卷积层，以提升特征提取效率并降低计算开销，结构如图 4 所示。该模块采用不同尺度的卷积核组合，在保持较小感受野的同时增强对局部细节的建模能力，从

而对复杂背景和目标边界区域表现出更高的特征表达精度。C3k2 由 2 个级联的 3×3 卷积构成，在减少网络层数的同时有效避免信息损失，显著降低模型参数量并增强梯度流动效率，实现检测精度与推理速度之间的更优平衡。

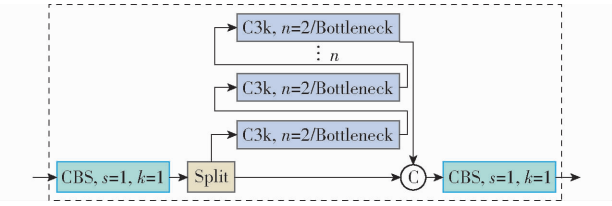


图 4　C3k2 模块

Fig. 4　C3k2 module

考虑烟苗在光照等复杂田间环境中感知叶片细节特征不高且计算资源受限的问题，本文设计融合注意力模块 NewBlock 对 YOLO 11 模型进行改进。由于 YOLO 11 系列模型 C3k2 模块中原有 Bottleneck 卷积参数量较大，为提高模型性能的同时并减少模型参数量，设计 NewBlock 模块替换原 Bottleneck 模块，结构如图 5 所示。

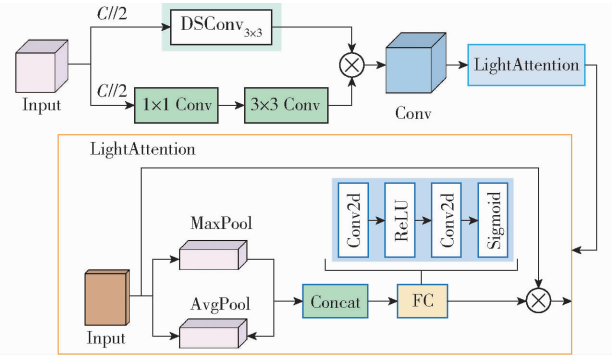


图 5　NewBlock 模块结构示意图

Fig. 5　NewBlock module structure diagram

设计的 NewBlock 模块共有上下 2 个分支，2 个分支对输入特征分别进行等通道数划分，下分支为密集卷积路径，采用 1×1 卷积进行通道降维后接 3×3 卷积扩大感受野，这种差异化结构组合既能捕获植物的细节特征又能感知更大范围的上下文信息。上分支是深度可分离卷积分支，此分支中每个通道只需与 1 个滤波器进行卷积，而不像传统卷积那样每个通道都需与所有滤波器进行卷积，这样残差连接设计可在提高精度的同时降低计算量。该过程计算式为

$$X_1 X_2 = \mathrm{Split}(X) \quad (X_1, X_2 \in \mathbf{R}^{\frac{C_1}{2}\times H\times W}) \tag{1}$$

$$F_1 = \mathrm{Conv}_{3\times 3}(\mathrm{Conv}_{1\times 1}(X_1)) \tag{2}$$

$$F_2 = \mathrm{ReLU}(\mathrm{BN}(\mathrm{DSConv}_{3\times 3}(X_2))) \tag{3}$$

$$F_{\mathrm{fuse}} = F_1 + F_2 \tag{4}$$

$$F_{\mathrm{exp}} = \mathrm{Conv}_{1\times 1}(F_{\mathrm{fuse}}) \tag{5}$$

式中　C_1——输入通道数

X——特征图

H——特征图像素高

W——特征图像素宽

$\mathbf{R}$——实数集

$\mathrm{Split}(x)$——切分操作函数

F_1——密集卷积路径提取特征

F_2——深度卷积路径提取特征

F_{exp}——扩展后特征

$\mathrm{Conv}_{k\times k}$——$k\times k$ 标准卷积

$\mathrm{DSConv}_{3\times 3}$——3×3 深度可分离卷积

BN——批次归一化

$\mathrm{ReLU}(x)$——激活函数

对于式(3)，$\mathrm{DSConv}_{3\times 3}$后隐含逐点卷积和残差连接公式部分。

此外，在 Conv 卷积层引入 LightAttention 轻量化注意力机制，通过平均池化(AvgPool)和最大池化(MaxPool)的结果拼接后经过 2 个卷积层生成注意力权重，然后与输入相乘，这样可通过卷积特征通道之间的相互依赖性来提高网络表示能力，提升复杂背景下烟苗检测效果。

2.4　BiFPN_ADown 融合结构

为进一步减少模型参数量并防止信息丢失，在 YOLO 11 的 Neck 部分引入 BiFPN_ADown 结构替代原 PANet 结构。BiFPN 双向特征金字塔网络是一种高效的多尺度特征融合网络，通过自上而下与自下而上的双向信息流实现跨尺度特征集成。通过去冗余节点、增加共层连接及双向路径迭代，不仅简化网络结构、减少参数量，还引入可学习权重动态调整不同特征，提升融合适应性与有效性。ADown 模块作为 YOLO v9 的 1 个下采样模块，可通过调整卷积核大小、步长及通道融合策略，在降低特征图空间分辨率的同时保留更多语义信息，从而避免传统池化或固定步长卷积带来的信息丢失。

3　模型评价

3.1　试验配置

试验在搭载 Intel(R)Core(TM) i7－14700k 处理器(8 核心，3.40 GHz)、NVIDIA GeForce RTX 4060 Ti 显卡和 64 GB 内存的 Windows 11 64 位系统上进行。软件平台采用 Visual Studio Code，软件环境采用 Python 3.10 和 PyTorch 2.0 深度学习框架，CUDA 版本为 12.6。训练过程采用 SGD 优化器，批量大小(Batch size)为 32，数据加载采用多进程方式，加载进程数设置为 12，初始学习率 0.001，训练轮数设置为 200。

3.2 性能评估

为量化评估改进后模型性能，采用精确率（Precision）、召回率（Recall）、平均精度均值（Mean average precision，mAP）、浮点数运算量和参数量作为主要评价指标。平均精度均值[28-29]包括边界框检测的 mAP50（交并比阈值为 0.5 时平均精度均值）和 mAP50-95（交并比阈值为 0.5～0.95 时平均精度均值）。

3.3 消融试验

为系统验证自主设计模块和改进结构的有效性，进行消融试验。以 YOLO 11 为基准模型将改进模块和结构按序叠加，设置消融试验对 4 组网络性能进行验证，分别为 YOLO 11 模型、NewBlock 模块替换、BiFPN_ADown 结构替换以及 NB-YOLO 11 模型，结果如表 1 所示。由表 1 可知，本文模型多个指标得到有效提升。

表 1 消融试验结果

Tab. 1 Ablation experiment results

模型	精确率/%	召回率/%	mAP50/%	mAP50-95/%	参数量	浮点数运算量
YOLO 11	89.5	90.6	95.3	70.2	2.58×10^6	6.3×10^9
YOLO 11 + NewBlock	92.5	93.4	97.3	77.6	2.26×10^6	5.7×10^9
YOLO 11 + BiFPN_ADown	90.7	89.5	95.2	72.1	1.86×10^6	3.6×10^9
YOLO 11 + NewBlock + BiFPN_ADown	93.4	91.4	97.2	79.0	1.68×10^6	3.3×10^9

图 6 为不同改进模块精确率变化曲线。由表 1 可知，引入 NewBlock 模块后，模型对细节特征与大范围上下文信息的表征能力得到增强，在 LightAttention 轻量化机制的协同作用下，模型精确率提升 3.0 个百分点。仅集成 BiFPN_ADown 结构可在保持其它指标基本不变的前提下显著降低参数量和计算成本。进一步结合 NewBlock 模块与 BiFPN_ADown 结构，实现了更高效的特征变换与精简的信息流路径，增强了双向跨尺度连接，使模型对正类样本分类更准确，并消除基线模型中冗余组件。虽然召回率和 mAP50 略有下降，但 mAP50-95 提升 1.4 个百分点，并使得精确率再提升 0.9 个百分点，参数量减小至 1.68×10^6，浮点数运算量减小至 3.3×10^9，相比原模型浮点运算量几乎减小一倍。消融试验结果表明，各改进模块协同作用显著提升了烟苗检测性能，有效验证了改进效果。

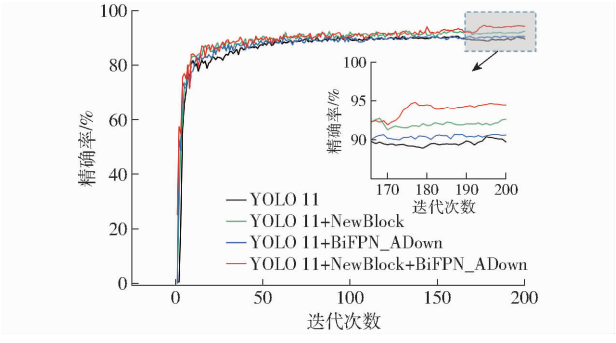


图 6 消融试验精确率变化曲线

Fig. 6 Changes in accuracy of ablation study experiment

3.4 性能试验

选取不同类型 YOLO 系列模型进行性能试验，包括小型网络 YOLO v5s、轻量级网络 YOLO v8n、小型网络 YOLO v9s，以及最新架构的 YOLO v10n 与 YOLO 11，表 2 为性能试验结果。由表 2 可知，在引入 NewBlock 模块和融合结构 BiFPN_ADown 后，

表 2 模型性能试验结果

Tab. 2 Model performance comparison

模型	精确率/%	召回率/%	mAP50/%	参数量	浮点数运算量	帧率/(f·s^{-1})
YOLO v5s	88.7	90.4	95.1	9.11×10^6	2.38×10^{10}	156.6
YOLO v8n	90.1	88.5	94.0	3.01×10^6	8.10×10^9	161.3
YOLO v9s	90.3	89.0	94.6	7.16×10^6	2.67×10^{10}	71.1
YOLO v10n	89.4	87.6	91.5	2.71×10^6	6.50×10^9	137.0
YOLO 11	89.5	90.6	95.3	2.58×10^6	6.30×10^9	134.3
NB-YOLO 11	93.4	91.4	97.2	1.68×10^6	3.30×10^9	75.8

NB-YOLO 11 模型精确率比上述模型分别提升 4.7、3.3、3.1、4.0、3.9 个百分点；召回率分别提升 1.0、2.9、2.4、3.8、0.8 个百分点；mAP50 分别提升 2.1、3.2、2.6、5.7、1.9 个百分点；参数量和浮点数运算量相较于其他系列模型均为最低，显著优于其他模型。NB-YOLO 11 模型在检测速度方面较基准模型略有下降，但其推理帧率仍可达 75.8 f/s，能够满足复杂田间环境下团棵期前烟苗目标检测任务对实时性的要求。综上所述，在保证高精度检测性能前提下，NB-YOLO 11 模型有效降低了计算复杂

度与模型参数规模，提升了模型部署灵活性，更适合应用于计算资源受限的边缘设备平台。

由于团棵期前烟苗导航作业极易受到光照和杂草影响，且在伸根期各烟苗之间存在局部叶片互相遮挡的情况，针对上述典型特征构建 4 组代表性田间场景进行性能验证，分别为：第 1 组强光条件、第 2 组弱光条件、第 3 组杂草干扰条件以及第 4 组株间遮挡条件。在统一置信度阈值为 0.5 条件下，各 YOLO 系列模型在不同田间场景中检测结果如图 7 所示。

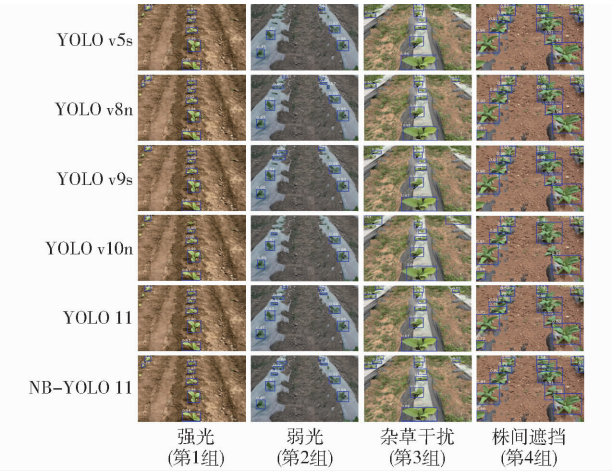


图 7　代表性模型实际检测效果

Fig. 7　Actual detection effect of representative models

由图 7 可知，第 1 组中，YOLO v5s、YOLO v9s、YOLO v10n 和 YOLO 11 在强光下对小尺度目标特征表征能力不足；第 2 组中，YOLO v5s 和 YOLO v10n 出现明显漏检，其他系列在检测效果上达到较为理想的水平；第 3 组中，YOLO v5s、YOLO v8n 和 YOLO v9s 在杂草干扰下对小目标烟苗识别能力受限，YOLO v10n 出现聚类错误。第 4 组中，YOLO v5s、YOLO v8n 和 YOLO v10n 在叶片局部遮挡下，对单株烟苗的分离能力不足，YOLO 11 在个别遮挡区域存在过拟合识别现象。相比之下，NB-YOLO 11 在上述 4 组中均保持了较为稳定的检测性能，能够有效降低漏检与聚类现象，尤其在株间遮挡条件下表现出更强的单株分离能力，检测结果在定位精度和置信度稳定性方面均优于其他模型。

4　烟苗行株系检测

4.1　实例级轮廓提取

基于团棵期前烟苗的形态学特征，采用改进 YOLO 11 模型对单株烟苗进行目标检测，并在检测框约束下开展实例级轮廓提取，以获取其空间位置与几何特征。YOLO 输出用于目标定位的检测框中心，本质为外接矩形中心，易受叶片舒展、局部遮挡及背景冗余区域影响，难以准确表征植株真实生理中心。针对上述局限，在检测框内部引入 Canny 边缘检测算子计算像素梯度幅值进行轮廓分割的方法[30]，对单株烟苗冠层投影进行刻画，并据此计算逼近生理学中心的几何质心。不同于直接采用 YOLO-Seg 模型，本文方法在 YOLO 检测框约束下对单株目标进行局部轮廓分析，有效降低像素级标注成本与模型复杂度，在保证定位精度的同时兼顾实时性与鲁棒性，更适用于复杂田间环境下视觉感知任务。

烟苗边缘检测及轮廓提取过程如图 8 所示。在 YOLO 检测框限定的局部区域内，结合 HSV 颜色空间中烟苗鲜绿色特征对 H 通道进行阈值约束，采用 Canny 边缘检测算子提取烟苗边缘信息并经过形态学处理，从而有效抑制土壤、枯叶、阴影及垄间杂草等背景干扰，获得连续且稳定的作物最大外接轮廓，图中最大外接轮廓计算式为

$$C_{\max} = \operatorname{argmax}(A(C_i)) \quad (C_i \in C) \tag{6}$$

其中

$$C = \operatorname{findContours}(M) \tag{7}$$

$$A = \frac{1}{2}\left| \sum_{i=1}^{k-1} (x_i y_{i+1} - x_{i+1} y_i) + (x_k y_1 - x_1 y_k) \right| \tag{8}$$

式中　C——所有连通域集合

findContours——查找二值图像中轮廓边界函数

M——二值掩码

x_i——轮廓上第 i 个点像素横坐标

y_i——轮廓上第 i 个点像素纵坐标

k——轮廓上顶点数

A——烟苗某部分像素轮廓面积

$C_{\max}$——最大轮廓

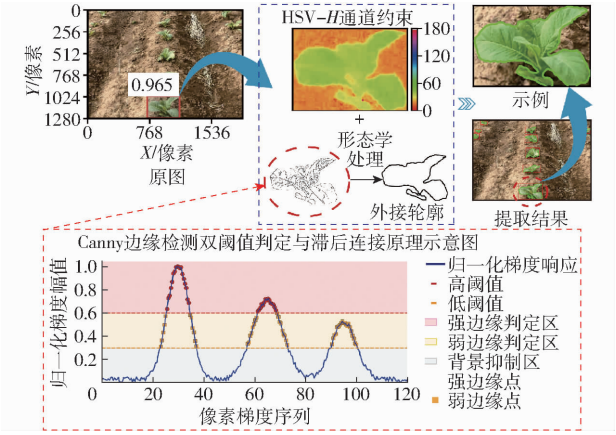


图 8　烟苗边缘检测及轮廓提取过程

Fig. 8　Edge detection and contour extraction process for tobacco seedlings

Canny 算子通过双阈值策略判定梯度幅值：大

于高阈值的像素为强边缘，小于低阈值的像素被抑制，介于两者的弱边缘仅在与强边缘连通时保留，从而在抑制噪声的同时保持轮廓连续性，为最大外接轮廓提取提供稳定结构基础。

4.2 特征点提取

为实现导航线精确预测，需在烟苗轮廓分割的基础上确定其中心位置。基于烟苗最大外接轮廓计算质心，以更准确表征该时期烟苗生理学中心，保障导航线拟合精度，提取流程如图 9 所示。首先对原始 RGB 图像进行边缘检测获取外接轮廓，再通过边界追踪生成连续轮廓点集，最终基于轮廓点坐标计算质心位置。设某一轮廓点集 C_{set} 为

$$C_{set} = \{P_1, P_2, \cdots, P_n\} \tag{9}$$

其中 $P_i = (x_i, y_i)$ 表示第 i 个轮廓点像素坐标。质心计算基于图像矩理论，物理意义为轮廓形状质量中心。首先，通过边缘检测获取烟苗轮廓点集 C_{set} 确定目标的几何边界，则该区域零阶矩 M_{00}（区域面积）可表示为

$$M_{00} = \sum_x \sum_y I(x, y) \tag{10}$$

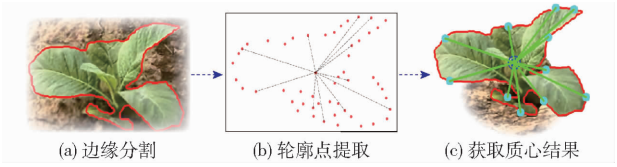


图 9 质心点提取过程

Fig. 9 Center of mass point extraction process

当零阶矩阶数为 $m + n = 1$ 时，称为一阶几何矩，用于质心计算。m 表示零阶矩在 x 方向（列方向）的阶数，n 表示零阶矩在 y 方向（行方向）的阶数。一般几何矩定义为

$$M_{mn} = \sum_x \sum_y x^m y^n I(x, y) \tag{11}$$

其中 $I(x, y)$ 为像素灰度，对于一阶几何矩，有

$$M_{10} = \sum_x \sum_y xI(x, y) \tag{12}$$

$$M_{01} = \sum_x \sum_y yI(x, y) \tag{13}$$

最终质心点坐标 (C_x, C_y) 由一阶几何矩与零阶矩比值确定，即

$$\begin{cases} C_x = \dfrac{M_{10}}{M_{00}} \\ C_y = \dfrac{M_{01}}{M_{00}} \end{cases} \tag{14}$$

该方法通过遍历所有轮廓点累计一阶几何矩值，充分利用形状全局几何特性。相较于单纯坐标均值法，一阶几何矩方法对不规则轮廓具有更强适应性，能准确反映烟苗生物力学平衡中心。图像中提取的轮廓点和质心点如图 10 所示，红色点为轮廓特征点，白色点为质心点，从图 10 可看出提取的质心点与作物生理学中心点分布相对一致。



图 10 提取的轮廓特征点和质心点

Fig. 10 Extracted contour feature points and centroid points

4.3 烟苗行导航线拟合与检测效果

针对烟苗行呈近线性分布特点，采用最小二乘法对烟苗行进行直线拟合，实现导航线精确提取，并为作物行检测与效果分析提供基础。以团棵期前烟苗田间环境和拍摄角度为基础，验证本文方法在强光、弱光、杂草干扰及株间遮挡等典型条件下的有效性。图 11 为作物外接轮廓提取、特征点提取、烟苗质心定位及基于最小二乘法拟合的导航线。结果表明，基于改进 YOLO 11 对烟苗轮廓提取并计算质心的方法能够稳定实现作物行检测与导航线提取，具有较强抗干扰能力和环境适应性。

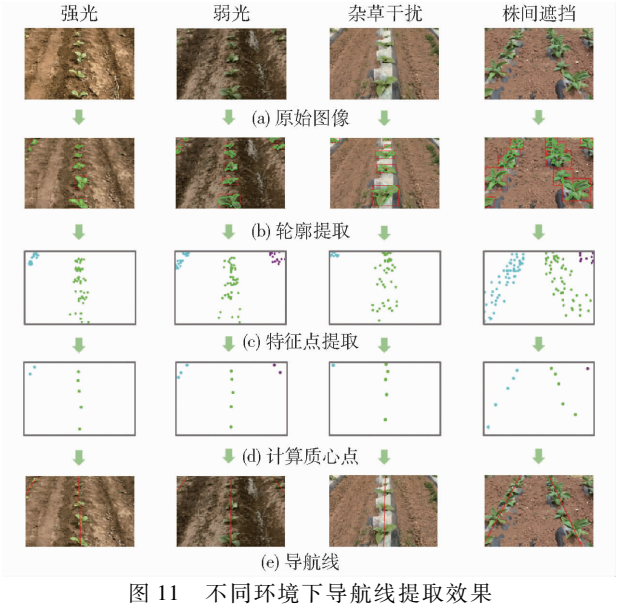


图 11 不同环境下导航线提取效果

Fig. 11 Line extraction results in different environments

在烟田环境中，地面起伏、机械振动及垄行不齐等因素易导致相机在图像采集时产生偏航角。为确保本文方法在实际应用中的稳健性，需验证对非零偏航角图像的适应能力。图 12 为图像在 10°、20°和 −30°旋转时导航线检测效果。由图 12 可以看出，图像旋转并未对导航线提取结果造成显著偏差。因此，本文基于质心提取垄上导航线的方法具备良好的鲁棒性，能够适应团棵期前烟苗图像中一定范围

内偏航角变化。

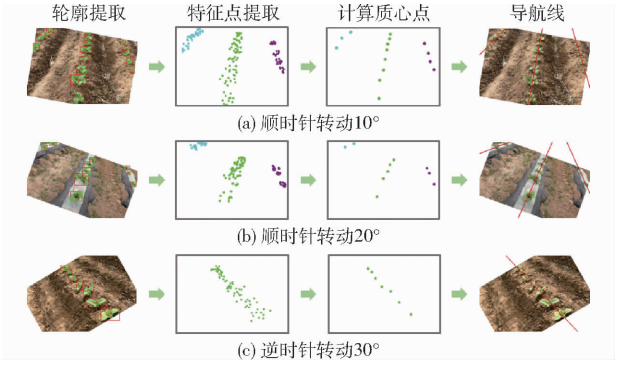


图 12　不同偏航角下导航线提取效果

Fig. 12　Line extraction results at different yaw angles

4.4　导航线评价标准与结果分析

为验证导航线拟合精度，采用基于角度与距离的综合评价方法对预测与理想导航线之间的偏差进行有效评估。如图 13 所示，在检测界面建立像素坐标系，用于计算 2 条直线误差。经拟合的导航线有 2 种情况，预测导航线与理想导航线相交，如图 13a 所示，预测导航线与理想导航线平行，如图 13b 所示，红色线表示预测导航线，黑色线表示理想导航线。点 A 与点 B 分别为理想与预测导航线在图像上边缘的交点，点 C 与点 D 则分别为两条线和图像下边缘的交点。将理想导航线两端点到预测导航线的距离记为 d_1 和 d_2，取其平均值 d 反映预测导航线与理想导航线之间的距离像素误差（两线平行时距离 $d_3 = d$），θ 表示两线夹角，计算角度误差。

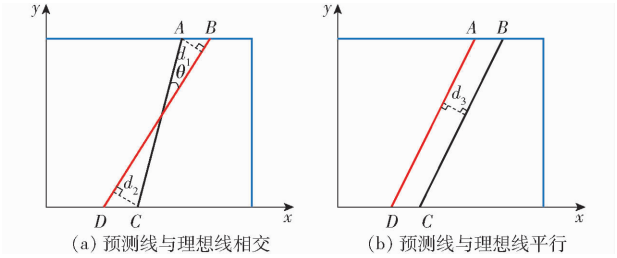


图 13　评价方法示意图

Fig. 13　Evaluation method diagrams

为验证本文方法高效性，抽取 120 幅团棵期前烟苗 4 种类型图像设计质心拟合与检测框中心拟合试验，并从角度误差和距离误差 2 个维度对性能进行对比。表 3 为 2 种方法在不同条件下导航线预测结果。由表 3 可知，检测框中心点拟合各组平均角度误差均不超过 2.27°，平均角度误差为 1.75°，平均距离误差为 18.28 像素；而质心点拟合的各组平均角度误差不大于 1.55°，平均角度误差为 0.91°，平均距离误差为 11.78 像素。相比检测框中心点拟合，质心点拟合在平均角度误差上降低 0.84°，平均距离误差减少 6.50 像素，表明本文方法具有更高的预测精度。YANG 等[31]在其研究环境下评估的玉米作物行拟合方法中，Hough 变换和最小二乘法角度误差拟合精度分别为 5.76° 和 3.56°。YU 等[32]研究表明，特定条件下导航线距离误差为 14.5 像素。尽管不同研究在试验环境设置、数据集特性选择以及评价体系构建等方面存在差异，导致各研究结果不具备直接横向比较的条件，但这些研究结果仍具有一定的参考价值。

表 3　不同方法角度与像素误差

Tab. 3　Angle and pixel errors of different methods

方法	分组	角度误差/(°)	d_1/像素	d_2/像素	d/像素
中心	强光	1.01	8.85	14.42	11.64
	弱光	1.76	11.00	25.00	18.00
	杂草干扰	1.95	22.99	19.99	21.49
	株间遮挡	2.27	16.00	27.99	22.00
质心	强光	0.46	11.64	16.34	13.99
	弱光	0.68	8.20	5.80	7.00
	杂草干扰	0.96	12.58	9.67	11.13
	株间遮挡	1.55	13.01	17.01	15.01

图 14 为质心提取导航线与 YOLO 检测框中心点提取导航线的效果，黑色线为人工标记理想导航线，蓝色线为基于检测框中心提取的导航线，红色线为基于质心提取的导航线。结果表明，质心导航线拟合更贴合团棵期前烟苗垄行趋势，且在多种复杂

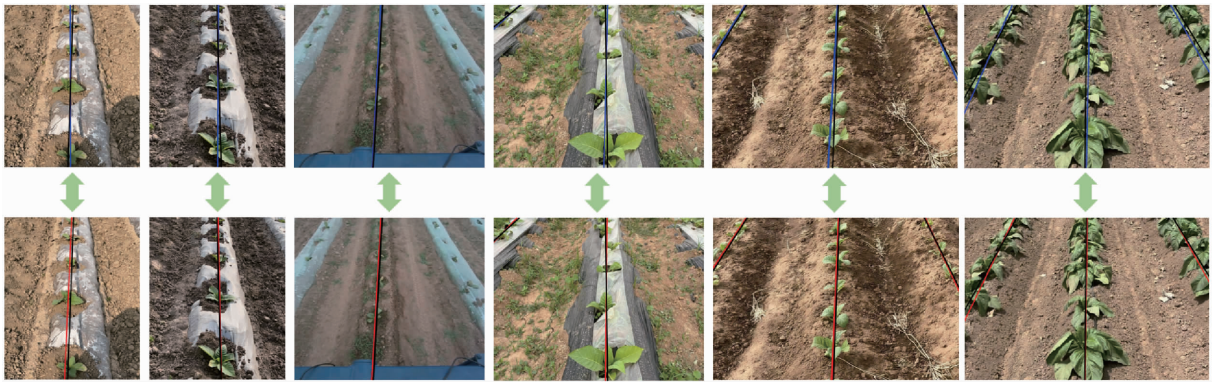


图 14　不同田间情况下导航线提取结果

Fig. 14　Navigation line extraction results under different field conditions

田间条件下均具有更高的适应性和精度,能够更有效地实现垄作物行的精准识别。

4.5 导航线提取时效性

表 4 为模型在不同田间场景下实时性能。采用时间戳记录法,对 GPU 与 CPU 混合处理架构下各处理阶段分别标注精确的开始与结束时间,从而实现对模型推理与后处理过程的微观时间分析。从整体流程来看,模型加载与 GPU 预热阶段分别耗时 124.86、869.71 ms,主要发生在首帧处理阶段,占初始运行时间的较大比例。为减小其对后续实时性能评估的影响,将该部分单独统计,不纳入连续帧处理时间分析。

表 4 不同场景下模型实时处理性能

Tab.4 Real-time processing performance of models across different scenarios

类型	阶段	开始时间戳	结束时间戳	用时/ms
	模型加载	18:53:49.210	18:53:49.334	124.86
	GPU 预热	18:53:49.334	18:53:50.204	869.71
强光	载入图像	18:53:50.226	18:53:50.246	19.93
	目标检测	18:53:50.247	18:53:50.299	51.70
	轮廓提取	18:53:50.300	18:53:50.302	1.52
	计算质心	18:53:50.302	18:53:50.305	3.08
	中心线拟合	18:53:50.305	18:53:50.306	1.58
弱光	载入图像	18:53:51.295	18:53:51.322	27.41
	目标检测	18:53:51.325	18:53:51.372	46.75
	轮廓提取	18:53:51.372	18:53:51.373	1.52
	计算质心	18:53:51.373	18:53:51.374	1.20
	中心线拟合	18:53:51.374	18:53:51.376	1.51
杂草干扰	载入图像	18:53:51.668	18:53:51.700	32.14
	目标检测	18:53:51.701	18:53:51.731	29.77
	轮廓提取	18:53:51.731	18:53:51.733	1.62
	计算质心	18:53:51.733	18:53:51.735	1.68
	中心线拟合	18:53:51.735	18:53:51.737	1.52
株间遮挡	载入图像	18:53:52.473	18:53:52.493	19.80
	目标检测	18:53:52.493	18:53:52.529	36.14
	轮廓提取	18:53:52.529	18:53:52.531	1.53
	计算质心	18:53:52.531	18:53:52.532	1.00
	中心线拟合	18:53:52.532	18:53:52.534	1.52

强光、弱光、杂草干扰及株间遮挡场景下各总处理时间分别用时 77.81、78.39、66.73、59.99 ms。其中,目标检测阶段由 GPU 完成,耗时 29.77 ~ 51.70 ms,而轮廓提取、质心计算及中心线拟合等步骤主要由 CPU 完成,单阶段耗时均控制在 1 ~ 4 ms 范围内。基于分析结果表明,对于光照变化的场景下,目标检测阶段耗时相对增加,主要由于图像对比度变化导致网络特征响应复杂度上升。相比之下,杂草干扰与株间遮挡场景下各阶段耗时分布更为均衡,流程稳定性较高。综上,本文方法能够维持较快的处理速度,满足实时性需求。

5 结论

(1)提出改进的 YOLO 11 模型,设计的 NewBlock 模块解决了深层特征提取能力受限的问题,并引入了轻量化的注意力机制,通过卷积特征通道之间的相互依赖性来提高网络表示能力,提升复杂背景下烟苗检测效果,其模块使精确率达 92.5%,mAP50 达 97.3%。较原始模型提高 3.0、2.0 个百分点。消融试验证实了设计结构的有效性,与 YOLO 11 相比,NB - YOLO 11 在维持其基准性能的同时,获得了更高的检测精度。

(2)模型性能试验结果表明,设计的 BiFPN_ADown 结构在降低参数量上呈显著优势,通过融合的 BiFPN_ADown 结构替换核心结构 PANet 的设计,使得 NB - YOLO 11 模型达到最优平衡,参数量降至 1.68×10^6,浮点数运算量降至 3.3×10^9。在保持模型精度的同时有效降低了计算资源需求。

(3)试验结果表明,基于边缘检测获取外接轮廓计算质心提取导航线的方法,平均角度误差和距离误差分别为 0.91°和 11.78 像素。在复杂农田场景下,该方法能更准确地提取导航线。测试结果表明,该方法能满足团棵期前烟苗在多种条件下的导航预测需求。

参 考 文 献

[1] 刘成良, 贡亮, 苑进, 等. 农业机器人关键技术研究现状与发展趋势[J]. 农业机械学报, 2022, 53(7): 1 - 22.
LIU Chengliang, GONG Liang, YUAN Jin, et al. Current status and development trends of agricultural robots[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(7): 1 - 22. (in Chinese)

[2] 张漫, 季宇寒, 李世超, 等. 农业机械导航技术研究进展[J]. 农业机械学报, 2020, 51(4): 1 - 18.
ZHANG Man, JI Yuhan, LI Shichao, et al. Research progress of agricultural machinery navigation technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4): 1 - 18. (in Chinese)

[3] BAN C, WANG L, CHI R, et al. A Camera - LiDAR - IMU fusion method for real-time extraction of navigation line between maize field rows[J]. Computers and Electronics in Agriculture, 2024, 223: 109114.

[4] LIU K, YU J, HUANG Z, et al. Autonomous navigation system for greenhouse tomato picking robots based on laser SLAM[J]. Alexandria Engineering Journal, 2024, 100: 208 - 219.

[5] 肖珂, 夏伟光, 梁聪哲. 复杂背景下果园视觉导航路径提取算法[J]. 农业机械学报, 2023, 54(6): 197 - 204, 252.
XIAO Ke, XIA Weiguang, LIANG Congzhe. Visual navigation path extraction algorithm inorchard under complex background [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 197 - 204, 252. (in Chinese)

[6] 张秀丽, 周湘铭, 赵任重, 等. 基于 3 种不同颜色空间的作物行提取方法比较研究[J]. 江苏农业科学, 2023, 51(10):

211 – 219.
[7] CHOI K H, HAN S K, HAN S H, et al. Morphology-based guidance line extraction for an autonomous weeding robot in paddy fields[J]. Computers and Electronics in Agriculture, 2015, 113: 266 – 274.
[8] ZHANG X Y, LI X N, ZHANG B H, et al. Automated robust crop-row detection in maize fields based on position clustering algorithm and shortest path method[J]. Computers and Electronics in Agriculture, 2018, 154: 165 – 175.
[9] 韩长杰, 郑康, 赵学观, 等. 大田甘蓝作物行识别与对行喷雾控制系统设计与试验[J]. 农业机械学报, 2022, 53(6): 89 – 101.
HAN Changjie, ZHENG Kang, ZHAO Xueguan, et al. Design and experiment of row identification and row-oriented spray control system for field cabbage crops[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6): 89 – 101. (in Chinese)
[10] YANG S, MEI S, ZHANG Y. Detection of maize navigation centerline based on machine vision[J]. IFAC – PapersOnLine, 2018, 51(17): 570 – 575.
[11] CHEN J Q, HU Q, WU J H, et al. Navigation path extraction for greenhouse cucumber-picking robots using the prediction point Hough transform[J]. Computers and Electronics in Agriculture, 2021, 180: 105911.
[12] 杨洋, 张博立, 查家翼, 等. 玉米行间导航线实时提取[J]. 农业工程学报, 2020, 36(12): 162 – 171.
[13] GONG J L, WANG X X, ZHANG Y F, et al. Navigation line extraction based on root and stalk composite locating points[J]. Computers and Electrical Engineering, 2021, 92: 107115.
[14] ALROWAILY M A, ALRUWAILI O, ALGHAMD M, et al. Application of extreme machine learning for smart agricultural robots to reduce manoeuvering adaptability errors[J]. Alexandria Engineering Journal, 2024, 109: 655 – 668.
[15] HOU Q, XING J. Kssd: single-stage multi-object detection algorithm with higher accuracy rate[J]. IET Image Processing, 2020, 14(15): 3651 – 3661.
[16] KIM W S, LEE D H, KIM Y J, et al. Path detection for autonomous traveling in orchards using patch-based CNN[J]. Computers and Electronics in Agriculture, 2020, 175: 105620.
[17] WALDNER F, DIAKOGIANNIS F I. Deep learning on edge: extracting field boundaries from satellite images with a convolutional neural network[J]. Remote Sensing of Environment, 2020, 245: 111741.
[18] LIN T, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318 – 327.
[19] 穆龙涛. 全视场猕猴桃果实信息感知与连贯采摘机器人关键技术研究[D]. 杨凌: 西北农林科技大学, 2019.
MU Longtao. Full field of view information perception and integrated picking method for kiwifruit harvesting robot[D]. Yangling: Northwest A&F University, 2019. (in Chinese)
[20] 史慧. 基于深度学习的视觉导航路径检测方法研究[D]. 石河子: 石河子大学, 2024.
SHI Hui. Research on visual navigation path detection method based on deep learning[D]. Shihezi: Shihezi University, 2024. (in Chinese)
[21] DE SILVA R, CIELNIAK G, GAO J. Vision based crop row navigation under varying field conditions in arable fields[J]. Computers and Electronics in Agriculture, 2024, 217: 108581.
[22] LIU T H, ZHENG Y, LAI J S, et al. Extracting visual navigation line between pineapple field rows based on an enhanced YOLOv5[J]. Computers and Electronics in Agriculture, 2024, 217: 108574.
[23] DIAO Z H, GUO P L, ZHANG B H, et al. Navigation line extraction algorithm for corn spraying robot based on improved YOLOv8s network[J]. Computers and Electronics in Agriculture, 2023, 212: 108049.
[24] SAHA S, NOGUCHI N. Smart vineyard row navigation: a machine vision approach leveraging YOLOv8[J]. Computers and Electronics in Agriculture, 2025, 229: 109839.
[25] ZHOU X M, ZHANG X L, ZHAO R Z, et al. Navigation line extraction method for broad-leaved plants in the multi-period environments of the high-ridge cultivation mode[J]. Agriculture, 2023, 13: 1496.
[26] 周林, 张银志, 丁建朋, 等. 曲柄摇杆摆动式烟田株间除草装置的设计与试验[J]. 烟草科技, 2025, 58(11): 83 – 92.
ZHOU Lin, ZHANG Yinzhi, DING Jianpeng, et al. Design and experiment of a crank-rocker oscillating weeding device for tobacco fields[J]. Tobacco Science & Technology, 2025, 58(11): 83 – 92. (in Chinese)
[27] KHANAM R, HUSSAIN M. YOLOv11: an overview of the key architectural enhancements[J]. Computer Vision and Pattern Recognition, 2024, 17(25): 1 – 9.
[28] 任晶秋, 万恩晗, 单蜜, 等. 基于改进 YOLO v8n 网络的番茄成熟度实时检测算法[J]. 农业机械学报, 2025, 56(3): 374 – 382, 450.
REN Jingqiu, WAN Enhan, SHAN Mi, et al. Improved YOLO v8n network for real-time detection of tomato maturity[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 374 – 382, 450. (in Chinese)
[29] 奚小波, 丁杰源, 翁小祥, 等. 基于轻量化 YOLO v5s MCA 的番茄成熟度检测方法[J]. 农业机械学报, 2025, 56(3): 383 – 391, 436.
XI Xiaobo, DING Jieyuan, WENG Xiaoxiang, et al. Tomato maturity detection method based on lightweight YOLO v5s – MMCA[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 383 – 391, 436. (in Chinese)
[30] LI L M, WANG W X, KHATOON A, et al. Road detection by using gradient magnitude image and adaptive thresholding based Watershed[J]. Egyptian Informatics Journal, 2024, 25: 100446.
[31] YANG Y, ZHOU Y, YUE X, et al. Real-time detection of crop rows in maize fields based on autonomous extraction of ROI[J]. Expert Systems with Applications, 2023, 213: 118826.
[32] YU J, ZHANG J, SHU A J, et al. Study of convolutional neural network-based semantic segmentation methods on edge intelligence devices for field agricultural robot navigation line extraction[J]. Computers and Electronics in Agriculture, 2023, 209: 107811.