

冯伟, 赵霞. 基于改进 YOLO11 模型的棉花叶片病害检测[J]. 江苏农业学报, 2026, 42(3): 521-530.
doi: 10.3969/j.issn.1000-4440.2026.03.010

基于改进 YOLO11 模型的棉花叶片病害检测

冯伟, 赵霞

(甘肃农业大学信息科学技术学院, 甘肃 兰州 730070)

摘要: 为提升 YOLO11 模型检测棉花叶片病害的性能, 本研究以 YOLO11 模型为基准模型, 引入多尺度边缘增强模块 (Multi-scale edge enhancement module, MEEM) 替代原模型中 C3k2 模块, 在 C2PSA 模块中增加凝聚注意力机制 (Condensed attention, CA), 采用动态特征融合 (Dynamic feature fusion, DFF) 替代颈部网络中特征融合模块 (Contat) 构建改进 YOLO11 模型, 增强模型对检测目标复杂细节和边缘特征提取以及小目标识别和多尺度特征融合能力, 并用 Kaggle 平台、谷歌和百度搜索工具获得的棉花病害图像数据进行模型检测性能比较。结果表明, 改进 YOLO11 模型对棉花叶片病害的检测准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比基准模型 (YOLO11 模型) 提高 6.1 个百分点、2.5 个百分点、4.5 个百分点、2.5 个百分点, 浮点运算量、参数量分别增加 34.92% 和 26.74%。与 YOLOv5、YOLOv8n、YOLOv10n 等模型相比, 改进 YOLO11 模型虽然参数量和浮点运算量较高, 但其检测准确率、召回率、平均精度均值更高。改进 YOLO11 模型能显著提高棉花叶片卷叶病、灰霉病、叶斑病、萎蔫病的检测效果, 且对枯萎病和健康叶片均保持较高的检测精度。本研究结果对棉花病害的自动化精准检测、预警防治以及棉花安全生产具有重要作用。

关键字: 棉花; 叶片病害; YOLO11 模型; 多尺度特征融合; 注意力机制; 动态特征融合

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 1000-4440(2026)03-0521-10

Cotton leaf disease detection based on an improved YOLO11 model

FENG Wei, ZHAO Xia

(College of Information Science and Technology, Gansu Agricultural University, Lanzhou 730070, China)

Abstract: In order to improve the performance of the YOLO11 model in detecting cotton leaf diseases, this study used the YOLO11 model as the benchmark model, introduced a multi-scale edge enhancement module (MEEM) to replace the original C3k2 module, and added a condensed attention (CA) mechanism in the C2PSA module. The improved YOLO11 model was constructed by replacing the feature fusion module (Contat) with dynamic feature fusion (DFF), thereby enhancing its ability in extracting complex details and edge features of the target, recognizing small objects, and fusing multi-scale features. The cotton disease image data obtained by Kaggle platform, Google and Baidu search tools were used to compare the model detection performance. The results showed that the detection accuracy, recall rate, mean average precision (mAP_{50}) and $mAP_{50:95}$ of the optimized model for cotton leaf diseases were 6.1 percentage points, 2.5 percentage points, 4.5 percentage points and 2.5 percentage points higher than those of the benchmark model, respectively. The floating point operations and parameter count increased by 34.92% and 26.74%, respectively. Compared with YOLOv5,

收稿日期: 2025-05-13

基金项目: 甘肃省自然科学基金项目 (24JRRA656)

作者简介: 冯伟 (1996-), 男, 河南信阳人, 硕士研究生, 主要从事深度学习和目标检测研究。(E-mail) 1807208292@qq.com

通讯作者: 赵霞, (E-mail) 58892778@qq.com

YOLOv8n, YOLOv10n and other models, although the improved YOLO11 model had higher parameter count and floating point operations, its detection accuracy, recall rate and average accuracy were higher. The improved model significantly improved the detection performance of cotton leaf curl, gray mold, leaf spot and wilt diseases, and the

detection accuracy of *Fusarium* wilt and healthy leaves remained high. The results of this study play an important role in the automatic and accurate detection, early warning and control of cotton diseases and the safe production of cotton.

Key words: cotton; leaf disease; YOLO11 model; multi-scale feature fusion; attention mechanism; dynamic feature fusion

棉花是重要的经济作物之一,在纺织、化工等诸多领域有着广泛的应用^[1]。病虫害是棉花安全生产的重要限制因子,严重影响棉花产量和品质,给棉花产业带来重大损失^[2]。叶片病害是棉花生产中常见的病害类型,准确快捷地识别与检测棉花叶片病害类型对病害预警防治、棉花安全生产至关重要^[3]。

传统的棉花叶片病害检测主要依赖人工经验,缺乏标准化的技术支撑体系,效率低下、主观性强^[4]。随着计算机视觉和深度学习技术的快速发展,基于图像识别技术进行作物病害检测逐渐成为研究热点。戴硕等^[5]基于 ShuffleNet v2 模型及选择性核注意力(SK-Attention)模块,自动调整卷积核大小,降低图像复杂背景对棉花病虫害检测的影响。周淋芋等^[6]基于优化的 MobileNet V3 模型和迁移学习技术,提升了棉花病虫害数据集不足背景下的模型检测准确率。Gao 等^[7]采用 Transformer 技术和知识图谱的边缘计算方法,加强对复杂背景中微小目标的特征提取,有效提高了棉花病虫害特征识别精度。Shao 等^[8]在 CANet 模型中引入感受野空间通道(RFSC)模块及精确坐标注意力(PCA)机制,再采用改进的柯尔莫哥洛夫阿诺德网络(KAN)进行分类,解决在复杂环境下棉花叶片病害识别率低的问题。Qiu 等^[9]在 SpemNet 模型中引入高效多尺度注意力(EMA)模块和堆叠补丁嵌入(SPE)模块,增强了模型局部特征学习和多尺度信息整合的能力,解决传统可视化 Transformer 模型在局部特征学习困难和多尺度特征整合不足的问题。王中璞等^[10]在 YOLO v5 模型中引入多维协作注意力(MCA)机制,并结合 GIoU 损失函数与自适应锚框算法,提高了模型对棉花中杂质的检测能力。郭文娟等^[11]在 YOLOX-S 和 YOLOv7 模型中引入压缩-激励模块(SE)、卷积注意力模块(CBAM)和高效通道注意力(ECA)模块,加强模型对棉花叶片病害特征提取能力,降低了模型的漏检率。朱莉^[12]在 YOLOv5s 模型中引入 SE 机制、减少 C3 模块、采用 Ghost 卷积层,增强模型的特征提取和特征融合能力,实现更高

效的棉籽分类与筛选。张楠楠等^[13]在 YOLOv7 模型中引入 CBAM 注意力机制,提升了模型对棉花叶片病虫害相似特征的识别能力。Ma 等^[14]在 YOLOv7x 模型中引入可变形注意力(DA)机制、归一化 Wasserstein 距离(NWD),并用动态检测头(DyHead)替换原有检测头,提高了模型对低质量棉花影像中病虫害检测的性能。Feng 等^[15]在 YOLOv8n 模型中对卷积层进行优化处理并引入 CBAM 注意力机制,提出一种自然环境中轻量化棉花病害检测模型 LCDDN-YOLO,较好地解决了相似病虫害的特征提取与识别。

上述研究在小目标检测与多尺度特征融合方面取得了一定成效,但在检测目标形态结构变化特征、目标细节和边缘特征提取以及作物叶片遮挡和特征相似的病害等背景下的作物叶片病害检测方面还存在一定不足。为实现复杂场景下棉花叶片病害特征的精准提取及病害类型识别,本研究以 YOLO11 模型为基准模型,通过引入多尺度边缘增强模块(Multi-scale edge enhancement module, MEEM)、凝聚注意力机制(Condensed attention, CA)及动态特征融合(Dynamic feature fusion, DFF)模块,增强模型对多尺度边缘信息和细节提取能力,有效聚焦小目标特征以及推测被遮挡部分的特征,促进多尺度特征的高效融合,构建棉花叶片病害检测的优化 YOLO11 模型,并以 Kaggle 平台、谷歌(Google)和百度(Baidu)搜索工具获得的棉花病害图像数据对模型检测性能进行比较,以期建立棉花叶片病害的高效精准检测技术,促进棉花的安全生产。

1 材料与方法

1.1 数据集

本研究采用的棉花叶片病害图像数据集来源于 Kaggle 平台(<https://www.kaggle.com/>)、谷歌(<https://www.google.com/>)及百度(<https://www.baidu.com/>)等搜索引擎,共 3 600 张,包括棉花枯萎病(Blight)、卷叶病(Curl)、灰霉病(Grey mildew)、叶斑病(Leaf spot)、萎蔫病(Wilt)等 5 种病害叶片及

健康(Healthy)叶片图像(图 1)。为确保检测模型的鲁棒性和泛化能力,降低模型训练产生的过拟合现象,利用随机旋转、翻转、裁剪等数据增强技术^[16-17],对数据集进行扩充,以实现不同类型样本

数量基本均衡。研究中通过数据增强技术得到不同类型图像 573 张,最后将全部的 4 173 张图像划分为训练集、测试集和验证集,相应的图像数量分别为 3 708 张、233 张、232 张。




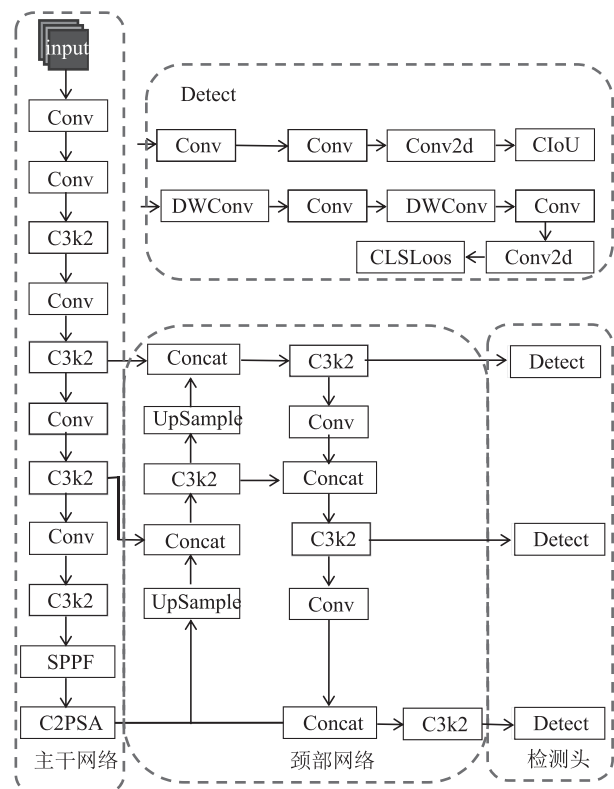
图 1 不同类型棉花病害叶片样本示意图

Fig.1 Schematic diagram of cotton leaf samples showing symptoms of different types of diseases

1.2 YOLO11 模型

YOLO11 模型是 Ultralytics 公司 2024 年 9 月推出的最新版本目标检测模型,由主干网络、颈部网络和检测头 3 部分组成^[18](图 2)。其中,主干网络由常规卷积(Conv)、C3k2 模块、快速空间金字塔池化(SPPF)组件、C2PSA 注意力机制等 4 个主要模块组成^[19],其融合了轻量级卷积结构和高效的注意力机制,可以在减少计算量的同时,增强对图像特征的提取能力。颈部网络由上采样(UpSample)、融合(Concat)、C3k2 模块组成^[20],保留了特征金字塔网络(FPN)及路径聚合网络(PAN)结构,将 C2f 模块替换成 C3k2 模块^[21],这样能够根据检测目标的大小和特征选择合适的尺度进行特征融合,促进浅层和深层信息之间的融合,显著提升小目标的检测效果^[22]。检测头由常规卷积(Conv)、深度可分离卷积(DWConv)^[23]和二维卷积层(Conv2d)组成^[24],负责检测对象分类和定位,可以在不同的场景下自动调整检测策略,突出目标特征,从而提高检测精度。

YOLO11 模型具有高效的目标检测能力,采用端到端的设计,通过一次前向传播完成目标的定位和分类,将目标检测任务转化为回归问题^[25]。但在检测目标较小、图像背景复杂的情况下,YOLO11 模型对检测目标可能存在特征提取不充分、特征融合不够灵活等问题,导致检测精度有待提高。因此,为提升 YOLO11 模型对棉花叶片病害检测的精度与准确性,本研究对 YOLO11 模型进行了一定的改进,改进后的模型结构如图 3 所示。改进措施主要体现在以下三个方面:一是利用多尺度边缘增强模块(MEEM)替换原模型的 C3k2 组件,保留原组件的输入输出通道匹配和残差连接逻辑,确保特征流转



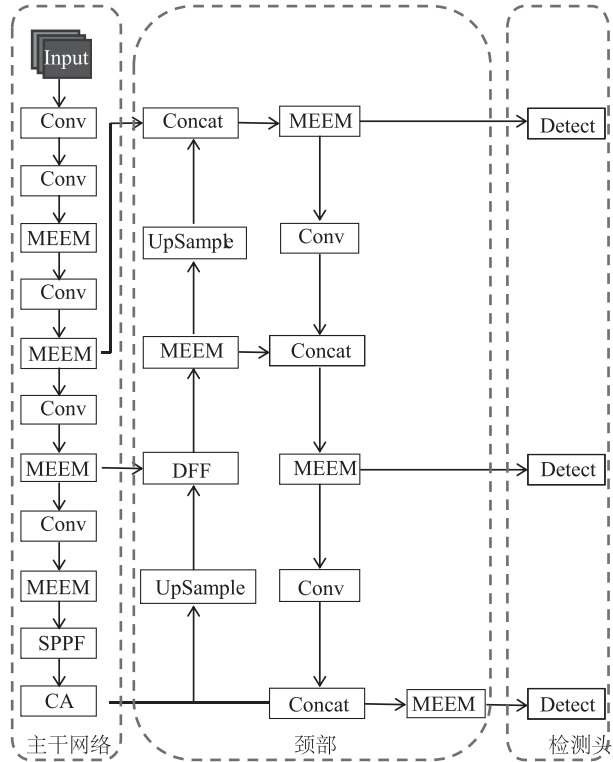
Input: 输入数据; Conv: 卷积; C3k2: 特征卷积模块; SPPF: 快速空间金字塔池化; C2PSA: 注意力机制特征处理模块; Concat: 特征拼接; UpSample: 最近邻上采样; Detect: 检测头; Conv2d: 二维卷积层; CIoU: 完全交并比; DWConv: 深度可分离卷积; CLSLoss: 分类损失函数。

图 2 YOLO11 模型结构

Fig.2 YOLO11 model architecture

的连续性,提升对特征轮廓的提取能力;二是在 C2PSA 模块分支特征处理流程中引入凝聚注意力(CA)机制,增强对通道维度关键特征的捕捉能力;三是利用 DFF 模块对颈部网络中与主干网络 C3k2

组件输出端直接相连的深层 Concat 组件进行替换, 输入输出通道数与原 Concat 组件一致, 以维持颈部特征融合的维度兼容性, 另一串联的浅层 Concat 组件维持原始结构, 避免对其他特征流路径造成不必要的干扰, 确保颈部网络功能的稳定性。



Input: 输入数据; Conv: 卷积; MEEM: 多尺度边缘增强模块; SPPF: 快速空间金字塔池化; CA: 凝聚注意力机制; UpSample: 最近邻上采样; Concat: 特征拼接; DFF: 动态特征融合; Detect: 检测头。

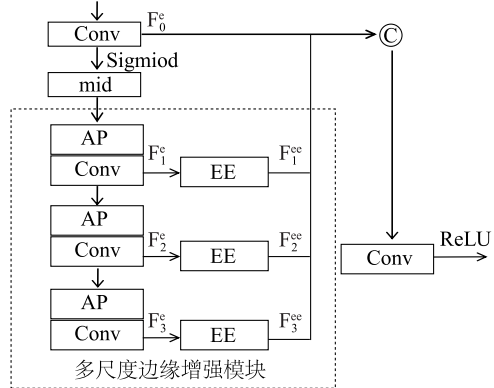
图 3 改进后的 YOLO11 模型结构

Fig.3 Improved YOLO11 model architecture

1.3 模型改进

1.3.1 多尺度边缘增强模块 多尺度边缘增强模块 (MEEM) 处理特征流程^[26] 如图 4 和图 5 所示。输入特征图经 1×1 卷积处理后, 基于 Sigmoid 激活函数引入非线性, 软化特征分布, 避免梯度消失, 调制边缘权重, 得到初始边缘特征 mid, 再对特征图进行平均池化 (AP) 和 1×1 卷积处理, 分 3 步提取不同尺度边缘信息, 每次处理都是先对前一步特征值进行 1×1 卷积, 再通过平均池化来扩大视野, 提升小尺度边缘细节特征和大尺度全局特征的提取准确性, 进而得到局部平均特征; 再采用边缘增强 (Edge-


eEnhancer) 处理, 进行边缘信息和复杂细节特征的多次增强, 计算每个尺度特征与经过平均池化后的特征之间差值, 得到不同尺度特征, 按通道进行拼接, 1×1 卷积将通道数 ($2C$) 恢复为 C , 再利用 ReLU 函数恢复到输入维度, 保留非线性, 增强对特征图的分辨能力。田间环境下, 棉花叶片病害检测常面临光照不均、土壤背景、叶片相互遮挡等复杂情景干扰^[27], 导致病害特征被弱化或掩盖, 因此传统的方法难以捕捉细微边缘特征, 而 MEEM 采用多尺度边缘增强机制, 对棉花叶片病害图像的特点进行优化, 有效提升模型对不同分辨率下病害区域边缘、不同细节层次病斑轮廓的感知能力, 显著提升对叶斑病、萎蔫病的检测精度, 为棉花病害的早期诊断和精准防治提供有力支持。



Conv: 卷积; Sigmoid: 激活函数; AP: 平均池化; EE: 边缘增强器; ReLU: 线性整流函数; $F_0^c, F_1^c, F_2^c, F_3^c$: 初次边缘增强; $F_1^{ee}, F_2^{ee}, F_3^{ee}$: 再次边缘增强; \odot : 特征拼接。

图 4 多尺度边缘增强模块流程

Fig.4 Multi-scale edge enhancement module processing flow



AP: 平均池化; F_1^c : 初次边缘增强; F_1^{ee} : 再次边缘增强; F_1^{edge} : 残差边缘计算。

图 5 边缘增强流程

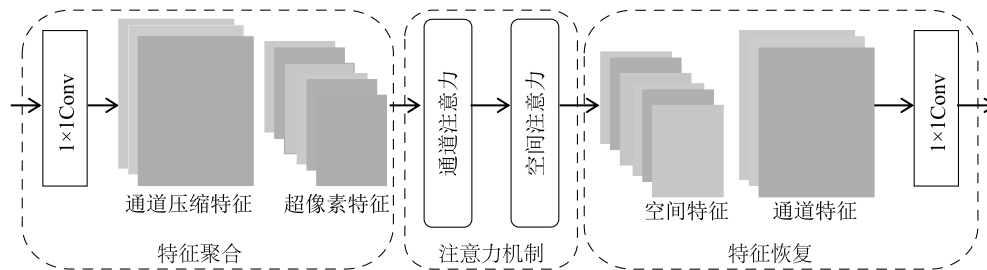
Fig.5 Edge enhancement process

边缘增强的设计原理在于通过动态适配池化窗口与残差计算策略, 精准强化不同病害的关键特征。

采用较小池化窗口(3×3)捕捉低光照度下病斑边缘色差微变,避免强光干扰,采用较大池化窗口(7×7)穿透局部遮挡,分析叶片纹理与土壤粗糙质感的边缘差异;并通过残差边缘计算强化病斑边界对比度,精准捕捉高频边缘信息,使模型更准确地识别病害的边界与形态。

1.3.2 CA 机制 凝聚注意力(CA)机制结构如图6所示。CA 主要包括特征聚合与恢复、通道和空间注

意力两部分^[28]。在棉花叶片病害检测场景下,病害特征分散在不同的通道和不同的空间位置,CA 机制通过对特征图的通道和空间维度进行加权,能够精准聚焦于与叶片病害相关的稀疏病斑像素;结合特征压缩与恢复操作整合多尺度信息,并通过分组卷积、通道重排等轻量化设计降低计算成本,提升对棉花叶片病害特征的检测能力。



Conv:卷积。

图6 凝聚注意力(CA)机制结构图

Fig.6 Structure diagram of condensed attention (CA) mechanism

在特征聚合时,将输入特征图通过1×1卷积层进行通道降维,得到通道压缩特征,利用通道分组卷积(GroupConv)沿空间维度聚合,降低计算复杂度,避免全局计算成本过高等问题,平衡精度与效率,得到超像素特征。通过通道维度的自注意力,增强与颜色、纹理相关通道的敏感度权重,突出关键通道的特征响应,抑制无关特征信息;通过空间注意力权重强化病斑与周围像素的差异,确定病害区域,区分正常与病变组织。空间特征则是将高维特征压缩到低维,并通过分组卷积(GroupConv)和像素重组(PixelShuffle)降低空间分辨率,聚焦病斑的微小孔洞、水渍状斑点等局部细节,然后通道特征恢复原始空间分辨率和通道数,同时残差连接整合原始特征与注意力增强后的特征,避免信息丢失,再经过1×1的通道卷积重新恢复空间特征和通道特征,让其输入的特征信息与输出的特征信息通道数与分辨率相同。

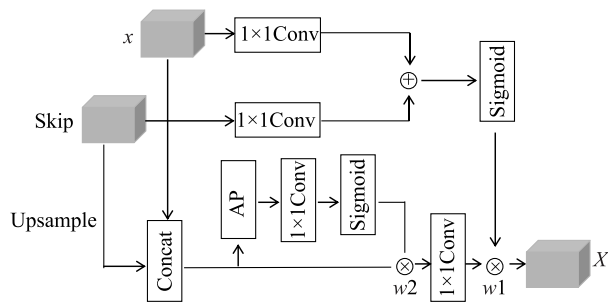
1.3.3 动态特征融合 传统的特征融合方法,常常因忽略不同病害特征的显著差异性,导致难以准确区分症状相似病害,进而造成病害的识别精度不高。而动态特征融合(Dynamic feature fusion, DFF)模块采用全局上下文注意力和局部特征注意力,计算两次注意力权重而实现对融合特征的自适应调

整,兼顾全局依赖与局部细节,有效提升对卷叶病、叶斑病、萎蔫病等不同病害特征信息检测的准确性,避免因特征混淆而导致的误判或漏检,从而显著提高棉花叶片病害检测的可靠性和实用性。动态特征融合结构如图7所示。

通过上采样(Upsample)操作调整复杂环境下获取的特征图尺寸,使特征图尺寸与输入特征图一致,两者融合后的特征图通过全局平均池化(AP)操作,将叶片的整体信息进行整合,然后通过1×1卷积操作提取与病害相关的全局特征,利用Sigmoid激活函数生成注意力权重,快速定位到叶片病害整体区域,同时考虑叶片整体的色泽和形态变化,再通过对全局注意力进行加权,可以突出显示病害区域,抑制无关信息,使得模型对叶片整体的色泽和形态变化更加敏感。进一步对原始特征图和上采样后的特征图,应用1×1卷积处理后经过Sigmoid激活函数生成注意力权重,细化空间位置的权重分配,增强对关键区域的敏感度,最后得到动态特征融合后的特征图,保留叶片纹理、褶皱程度和叶脉颜色等细微特征,进而提升对特征图识别的准确性。

1.4 模型对棉花叶片病害的识别性能比较

为评估改进模型对棉花叶片病害识别效果,本研究首先进行了模型改进方案的消融试验(表1)。



x : 输入特征图; Conv: 卷积; Sigmoid: 激活函数; Upsample: 上采样; Concat: 特征拼接; AP: 平均池化; Skip: 跳跃连接; w_1 、 w_2 : 分配权重; X : 输出特征图。

图 7 动态特征融合结构图

Fig.7 Structure diagram of dynamic feature fusion

然后,将改进后的模型与其他 YOLO 系列目标检测模型 YOLOv5、YOLOv6、YOLOv8n、YOLOv10n 进行棉花叶片病害检测性能比较。最后,比较了 YOLO11 和改进模型对不同棉花叶片病害检测性能和可视化差异,以验证改进模型在棉花叶片病害检测中的优势。

表 1 消融试验方案设计

Table 1 Design of ablation experiments

| 方案 | 多尺度边缘增强模块(MEEM) | 凝聚注意力(CA)机制 | 动态特征融合(DFE)模块 |
|------|-----------------|-------------|---------------|
| 方案 0 | - | - | - |
| 方案 1 | √ | - | - |
| 方案 2 | - | √ | - |
| 方案 3 | - | - | √ |
| 方案 4 | √ | √ | - |
| 方案 5 | √ | - | √ |
| 方案 6 | - | √ | √ |
| 方案 7 | √ | √ | √ |

√表示采用该改进措施;-表示不采用该改进措施。

1.5 试验环境

本研究模型的开发环境为 PyCharm,操作系统 Windows11,PC 内存 16 GB,显卡 NVIDIA GeForce RTX 4060,深度学习框架 PyTorch 2.0.1,工具包 NumPy 库、Pandas 库等,编程语言 Python 3.10。模型训练参数如下:初始学习率 0.01,迭代次数 200 次,批量大小 16,多线程 8,权值衰减率 0.000 5,图像大小 640×640。

1.6 模型评价指标

本研究利用准确率(P)、召回率(R)、平均精度

(AP)、平均精度均值(mAP)等指标评价模型的性能,算法如下:

$$P = \frac{TP}{TP+FP} \quad (1)$$

$$R = \frac{TP}{TP+FN} \quad (2)$$

$$AP = \int_0^1 P(R) dR \quad (3)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

式中: TP 为被正确预测棉花叶片病害的正样本数量, FP 为被错误预测棉花叶片病害的负样本数量, FN 为被错误预测棉花叶片病害的正样本数量, P 和 R 分别为精确率和召回率, AP 为平均精度, mAP 为平均精度均值。

2 结果与分析

2.1 消融试验结果

不同改进模块对 YOLO11 模型检测棉花叶片病害性能的影响如表 2 所示。从表中可以看出,利用 MEEM 模块替换主干网络 C3k2 模块后(方案 1),模型对棉花叶片病害检测的准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比基准模型提高 3.2 个百分点、0.2 个百分点、0.7 个百分点、1.5 个百分点,浮点运算量、参数量分别增加 20.63% 和 9.30%,说明改进措施能有效捕捉到图像的复杂细节和边缘信息,提升对检测目标的定位能力。将 CA 机制嵌入到基准模型 C2PSA 模块后(方案 2),模型对棉花叶片病害检测的准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比基准模型提高 3.0 个百分点、2.0 个百分点、1.8 个百分点、1.9 个百分点,浮点运算量无变化,参数量减少 1.55%,说明轻量化参数在多尺度特征融合机制中,能有效降低小目标在融合过程中的特征信息衰减,及因分辨率降低导致的信息丢失。将 DFE 模块嵌入到 C3k2 模块与上采样(Upsample)连接的融合模块(Concat)中(方案 3),模型对棉花叶片病害检测的准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比基准模型提高 3.1 个百分点、2.2 个百分点、1.9 个百分点、1.5 个百分点,浮点计算量、参数量分别增加 15.87% 和 18.99%,说明光照不足、相似特征以及复杂场景干扰下,DFE 模块促进多尺度特征融合。采用 MEEM 和 CA 机制后(方案 4),模型对棉花叶片

病害检测的准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比基准模型提高 3.8 个百分点、0.2 个百分点、2.0 个百分点、0.2 个百分点,浮点运算量、参数量分别增加 19.05% 和 7.75%。采用 MEEM 和 DFF 模块后(方案 5),模型对棉花叶片病害检测的准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比基准模型提高 3.4 个百分点、1.3 个百分点、2.4 个百分点、0.7 个百分点,浮点运算量、参数量分别增加 34.92% 和 28.29%。采用 CA 机制和 DFF 模块后(方案 6),模型对棉花叶片病害检测的准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比基准模型提高 3.0 个百分

点、3.7 个百分点、2.7 个百分点、1.9 个百分点,浮点运算量、参数量分别增加 15.87% 和 17.44%,该方案能有效促进模型精度与推理效率的协同增益。综合利用 3 个优化措施后(方案 7),模型对棉花叶片病害检测的准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比基准模型提高 6.1 个百分点、2.5 个百分点、4.5 个百分点、2.5 个百分点,浮点运算量、参数量分别增加 34.92% 和 26.74%。上述结果说明,改进模型虽然增加了参数量和浮点运算量,但模型对棉花病害检测的准确率、召回率、平均精度均值均得到大幅增加,模型更好地实现轻量化与高效性、高检测精度的平衡。

表 2 消融试验结果

Table 2 Results of ablation experiments

| 方案 | 准确率 (%) | 召回率 (%) | 平均精度均值 mAP_{50} (%) | 平均精度均值 $mAP_{50:95}$ (%) | 浮点运算量 (G) | 参数量 (M) |
|------|---------|---------|-----------------------|--------------------------|-----------|---------|
| 方案 0 | 87.4 | 72.5 | 80.6 | 68.8 | 6.3 | 2.58 |
| 方案 1 | 90.6 | 72.7 | 81.3 | 70.3 | 7.6 | 2.82 |
| 方案 2 | 90.4 | 74.5 | 82.4 | 70.7 | 6.3 | 2.54 |
| 方案 3 | 90.5 | 74.7 | 82.5 | 70.3 | 7.3 | 3.07 |
| 方案 4 | 91.2 | 72.7 | 82.6 | 69.0 | 7.5 | 2.78 |
| 方案 5 | 90.8 | 73.8 | 83.0 | 69.5 | 8.5 | 3.31 |
| 方案 6 | 90.4 | 76.2 | 83.3 | 70.7 | 7.3 | 3.03 |
| 方案 7 | 93.5 | 75.0 | 85.1 | 71.3 | 8.5 | 3.27 |

方案 0~方案 7 见表 1。

2.2 不同模型对棉花叶片病害检测性能比较

不同模型对棉花叶片病害检测结果如表 3 所示。从表可以看出,改进 YOLO11 模型对棉花叶片病害检测的准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比 YOLOv5 模型提高 7.5 个百分点、1.8 个百分点、4.4 个百分点、3.7 个百分点,浮点运算量和参数量分别增加 19.72% 和 30.28%。改进 YOLO11 模型对棉花叶片病害检测的准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比 YOLOv6 模型提高 1.1 个百分点、5.3 个百分点、5.6 个百分点、3.4 个百分点,浮点运算量和参数量分别减少 27.97% 和 22.70%。改进 YOLO11 模型对棉花叶片病害检测的准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比 YOLOv8n 模型提高 8.6 个百分点、0.9 个百分点、5.5 个百分点、2.3 个百分点,浮点运算量和参数量分别增加 4.94% 和 8.64%。改进 YOLO11 模型对棉花叶片病害检测的准确率、

召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比 YOLOv10n 模型提高 2.3 个百分点、4.1 个百分点、4.6 个百分点、3.3 个百分点,浮点运算量和参数量分别增加 3.66% 和 21.11%。从上述结果可以看出,与其他模型相比,改进 YOLO11 模型虽然参数量和浮点运算量较高,但其具有更高的检测准确率、召回率及平均精度均值,所以改进 YOLO11 模型适合应用于棉花叶片病害的轻量化实时检测。

2.3 YOLO11 模型和改进 YOLO11 模型对不同病害的检测性能

YOLO11 模型和改进 YOLO11 模型对不同病害的检测性能如表 4 所示。改进 YOLO11 模型对棉花枯萎病、卷叶病、灰霉病、叶斑病、萎蔫病及健康叶片的检测平均精度均值 mAP_{50} 分别比原始模型(YOLO11 模型)增加 0.9 个百分点、1.9 个百分点、13.6 个百分点、3.4 个百分点、3.9 个百分点、3.0 个百分点。改进 YOLO11 模型对棉花卷叶病、灰霉病、叶斑

病、萎蔫病及健康叶片的检测准确率分别比原始模型 (YOLO11 模型) 增加 1.7 个百分点、18.4 个百分点、9.6 个百分点、7.4 个百分点、2.1 个百分点,对枯萎病检测准确率下降 2.5 个百分点。改进 YOLO11 模型对棉花卷叶病、灰霉病、叶斑病、萎蔫病及健康叶片的检测召回率分别比原始模型 (YOLO11 模型) 增加 4.6 个百分点、5.9 个百分点、0.7 个百分点、4.2 个百分

点、0.7 个百分点,对枯萎病检测召回率下降 1.3 个百分点。由此可以看出,改进 YOLO11 模型能显著提高棉花叶片卷叶病、灰霉病、叶斑病、萎蔫病的检测效果,且对枯萎病和健康叶片均保持较高的检测精度,说明改进 YOLO11 模型在棉花叶片病害特征提取、复杂环境适应性、多尺度信息融合以及泛化能力等方面均较原始模型 (YOLO11 模型) 有较大提升。

表 3 不同模型对棉花叶片病害的检测性能

Table 3 Detection performance of different models on cotton leaf diseases

| 模型 | 准确率 (%) | 召回率 (%) | 平均精度均值 mAP_{50} (%) | 平均精度均值 $mAP_{50:95}$ (%) | 浮点运算量 (G) | 参数量 (M) |
|-----------|---------|---------|-----------------------|--------------------------|-----------|---------|
| YOLOv5 | 86.0 | 73.2 | 80.7 | 67.6 | 7.1 | 2.51 |
| YOLOv6 | 92.4 | 69.7 | 79.5 | 67.9 | 11.8 | 4.23 |
| YOLOv8n | 84.9 | 74.1 | 79.6 | 69.0 | 8.1 | 3.01 |
| YOLOv10n | 91.2 | 70.9 | 80.5 | 68.0 | 8.2 | 2.70 |
| YOLO11 | 87.4 | 72.5 | 80.6 | 68.8 | 6.3 | 2.58 |
| 改进 YOLO11 | 93.5 | 75.0 | 85.1 | 71.3 | 8.5 | 3.27 |

表 4 YOLO11 模型和改进 YOLO11 模型对 6 种棉花叶片病害检测效果

Table 4 Detection performance of YOLO11 model and improved YOLO11 model on six types of cotton leaf diseases

| 病害种类 | 准确率 (%) | | 召回率 (%) | | 平均精度均值 mAP_{50} (%) | |
|------|-----------|--------------|-----------|--------------|-----------------------|--------------|
| | YOLO11 模型 | 改进 YOLO11 模型 | YOLO11 模型 | 改进 YOLO11 模型 | YOLO11 模型 | 改进 YOLO11 模型 |
| 枯萎病 | 95.9 | 93.4 | 89.0 | 87.7 | 94.0 | 94.9 |
| 卷叶病 | 92.1 | 93.8 | 75.1 | 79.7 | 83.7 | 85.6 |
| 灰霉病 | 69.2 | 87.6 | 52.9 | 58.8 | 60.7 | 74.3 |
| 健康叶片 | 95.9 | 98.0 | 85.2 | 85.9 | 95.6 | 98.6 |
| 叶斑病 | 85.5 | 95.1 | 60.6 | 61.3 | 70.9 | 74.3 |
| 萎蔫病 | 85.5 | 92.9 | 72.2 | 76.4 | 78.9 | 82.8 |

YOLO11 模型和改进 YOLO11 模型对不同病害的可视化检测结果如图 8 所示。从图中可以看出, YOLO11 模型对棉花叶片病害目标的检测已具备一定的有效性,能够识别出主要目标并生成边界框,但在复杂场景下存在部分边界框定位偏差、小目标漏检及检测精度不高的现象。改进 YOLO11 模型对叶片病害目标检测边界框更贴合目标轮廓,漏检率明显降低。对于重叠或密集分布的目标,改进 YOLO11 模型能更清晰地区分目标个体,减少目标框重叠,对目标特征的捕捉更精准。上述结果说明,本研究改进的 YOLO11 模型在特征提取、多尺度目标适配及抗背景干扰等方面的能力得到提高,更能实现

实际场景中棉花叶片病害的高精度检测。

3 结论

本研究在融合 MEEM 模块、CA 机制和 DFF 模块的基础上,对 YOLO11 模型进行优化。优化后的模型对棉花叶片病害的检测准确率、召回率以及平均精度均值 mAP_{50} 、 $mAP_{50:95}$ 分别比原始模型提高 6.1 个百分点、2.5 个百分点、4.5 个百分点、2.5 个百分点,浮点运算量、参数量分别增加 34.92% 和 26.74%。与 YOLOv5、YOLOv6、YOLOv8n、YOLOv10n 等模型相比,改进 YOLO11 模型虽然参数量和浮点运算量较高,但其检测准确率、召回率及

平均精度总体更高。改进后的模型能显著提高棉花叶片卷叶病、灰霉病、叶斑病、萎蔫病的检测效果,且对枯萎病和健康叶片均保持较高的检测精度。改进 YOLO11 模型能更好地实现检测精度和轻量化的统一,为棉花病害的早期预警与精准防治提供可靠的技术支撑。



图8 YOLO11模型和改进YOLO11模型对棉花叶片病害的可视化识别效果

Fig.8 Visual recognition effects of YOLO11 model and improved YOLO11 model on cotton leaf diseases

参考文献:

- [1] 袁雄武. 机采棉除杂场中动力补偿的研究[D]. 阿拉尔:塔里木大学,2023.
- [2] 王晋伟,赵丽红,师勇强,等. 棉花病害全程防治技术研究初报[J]. 中国棉花,2020,47(5):20-22,46.
- [3] 毕君涛. 基于深度学习的棉叶主要病虫害检测方法研究[D]. 阿拉尔:塔里木大学,2023.
- [4] 陈沛沛,戴建国,张国顺,等. 基于模型剪枝的棉花氮素营养水平诊断[J]. 农业工程学报,2024,40(6):277-284.
- [5] 戴 硕,白 涛,李东亚,等. 基于知识蒸馏及改进 ShuffleNet v2的棉花病虫害识别方法[J]. 江苏农业科学,2024,52(15):222-232.
- [6] 周淋芋,周 卫,苏申申,等. 基于 MobileNetV3 的棉花病虫害图像分类算法改进[J]. 现代计算机,2024,30(22):55-60.
- [7] GAO R C, DONG Z C, WANG Y Q, et al. Intelligent cotton pest and disease detection; edge computing solutions with transformer technology and knowledge graphs[J]. Agriculture, 2024, 14(2):247.
- [8] SHAO Y, YANG W Z, WANG J J, et al. Cotton disease recognition method in natural environment based on convolutional neural network[J]. Agriculture, 2024, 14(9):1577.
- [9] QIU K Y, ZHANG Y J, REN Z K, et al. SpemNet: a cotton disease and pest identification method based on efficient multi-scale attention and stacking patch embedding[J]. Insects, 2024, 15(9):667.
- [10] 王中璞,吴正香,张立杰,等. 基于 ZC-YOLO 的棉花杂质检测[J]. 毛纺科技,2024,52(12):95-101.
- [11] 郭文娟,冯 全. 基于改进 YOLO 的棉花叶片病害检测[J]. 干旱地区农业研究,2024,42(6):195-205.
- [12] 朱 莉. 基于改进 YOLOv5 算法模型的棉籽分类筛选系统研究[D]. 阿拉尔:塔里木大学,2024.
- [13] 张楠楠,张 晓,白铁成,等. 基于 CBAM-YOLO v7 的自然环境下棉叶病虫害识别方法[J]. 农业机械学报,2023,54(增刊1):239-244.
- [14] MA Y K, WEI Y J, MA M S, et al. DCP-YOLOv7x; improved pest detection method for low-quality cotton image[J]. Frontiers in Plant Science, 2024, 15:1501043.
- [15] FENG H R, CHEN X Q, DUAN Z Y. LCDDN-YOLO; lightweight cotton disease detection in natural environment, based on improved YOLOv8[J]. Agriculture, 2025, 15(4):421.
- [16] LI J, LI J H, ZHAO X, et al. Lightweight detection networks for tea bud on complex agricultural environment via improved YOLO v4[J]. Computers and Electronics in Agriculture, 2023, 211:107955.
- [17] LIU H, HOU Y S, ZHANG J C, et al. Research on weed reverse detection methods based on improved you only look once (YOLO) v8; preliminary results[J]. Agronomy, 2024, 14(8):1667.
- [18] HE L H, ZHOU Y Z, LIU L, et al. Research on object detection

- and recognition in remote sensing images based on YOLOv11[J]. *Scientific Reports*, 2025, 15(1):14032.
- [19] LI Y J, ZHOU Z F, PAN Y. YOLOv11-BSS; damaged region recognition based on spatial and channel synergistic attention and bi-deformable convolution in sanding scenarios [J]. *Electronics*, 2025, 14(7):1469.
- [20] JI Y P, ZHANG D, HE Y L, et al. Improved YOLO11 algorithm for insulator defect detection in power distribution lines[J]. *Electronics*, 2025, 14(6):1201.
- [21] TANG K, QIAN Y R, DONG H L, et al. SP-YOLO; a real-time and efficient multi-scale model for pest detection in sugar beet fields[J]. *Insects*, 2025, 16(1):102.
- [22] XIONG X R, HE M T, LI T Y, et al. Adaptive feature fusion and improved attention mechanism-based small object detection for UAV target tracking[J]. *IEEE Internet of Things Journal*, 2024, 11(12):21239-21249.
- [23] ALKHAMMASH E H. A comparative analysis of YOLOv9, YOLOv10, YOLOv11 for smoke and fire detection[J]. *Fire*, 2025, 8(1):26.
- [24] SUN W Z, MENG N, CHEN L F, et al. CTL-YOLO; a surface defect detection algorithm for lightweight hot-rolled strip steel under complex backgrounds[J]. *Machines*, 2025, 13(4):301.
- [25] 熊干, 陈慈发, 张上. QMDF-YOLO11: 复杂场景下水稻害虫检测算法[J]. *计算机工程与应用*, 2025, 61(13):113-123.
- [26] GAO S X, ZHANG P P, YAN T Y, et al. Multi-scale and detail-enhanced segment anything model for salient object detection [C//OL]//Association for Computing Machinery. Proceedings of the 32nd ACM international conference on multimedia. Melbourne: ACM, 2024: 9894-9903. <https://doi.org/10.1145/3664647.3680650>.
- [27] ZHANG J H, KONG F T, WU J Z, et al. Automatic image segmentation method for cotton leaves with disease under natural environment[J]. *Journal of Integrative Agriculture*, 2018, 17(8):1800-1814.
- [28] ZHAO H Y, GOU Y B, LI B Y, et al. Comprehensive and delicate: an efficient transformer for image restoration [C]//IEEE. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Vancouver, Canada: IEEE, 2023: 14122-14132.

(责任编辑:石春林)