

基于YOLOv8S的棉花叶病害识别与多功能机器人系统设计

赵露茜, 吴芳玲, 王晨旭*, 武佳瑶

辽宁科技大学电子与信息工程学院, 辽宁 鞍山

收稿日期: 2026年4月23日; 录用日期: 2026年5月22日; 发布日期: 2026年5月29日

摘要

针对棉花叶病害检测中病斑尺度差异大、背景干扰复杂、小目标易漏检及精度与效率难以平衡的问题, 文章对YOLOv8s模型进行了改进, 构建了YOLOv8s-MSFDS模型。在主干网络中引入MKC-Block模块替换原C2f结构, 结合多尺寸卷积核与动态蛇形卷积, 提升多尺度病斑特征提取能力; 在特征融合层引入频率-空间注意力模块FSA与并行位置感知注意力机制, 强化病斑边缘细节特征, 增强抗干扰能力; 在检测头部分引入多尺度通道注意力模块MTA-Net, 优化小目标检测精度并降低冗余计算。实验结果表明, 相较于原始YOLOv8s模型, YOLOv8s-MSFDS模型的精确率、召回率、平均精度均值(mAP)分别达91.9%、87.9%、85.1%, 参数量仅为5.9 MB, 在Jetson Nano平台上推理速度达4.99 FPS, 满足实时检测需求。模型在保持轻量化的同时实现了更高的检测精度, 有效平衡了性能与效率。搭载于基于ROS构建的履带式机器人平台后, 在田间真实场景下表现出良好的泛化性与鲁棒性, 可为棉花叶病害智能监测提供硬件与算法一体化的技术支撑。

关键词

棉花叶病害检测, YOLOv8s, MKC-Block模块, 注意力机制, 履带式机器人, ROS

Design of Multifunctional Robot System for Cotton Leaf Disease Identification Based on Improved YOLOv8S

Luxi Zhao, Fangling Wu, Chenxu Wang*, Jiayao Wu

School of Electronic and Information Engineering, University of Science and Technology Liaoning, Anshan Liaoning

*通讯作者。

文章引用: 赵露茜, 吴芳玲, 王晨旭, 武佳瑶. 基于YOLOv8S的棉花叶病害识别与多功能机器人系统设计[J]. 计算机科学与应用, 2026, 16(5): 514-524. DOI: 10.12677/csa.2026.165202

Abstract

Aiming at the problems of large-scale variation of disease spots, complex background interference, easy missed detection of small targets, and difficulty in balancing accuracy and efficiency in cotton leaf disease detection, the YOLOv8s model was improved in multiple dimensions to construct the YOLOv8s-MSFDS model for cotton leaf disease detection. The MKC Block module was introduced into the backbone network to replace the original C2f structure, and combined with multi-size convolution kernels and dynamic snake convolution to improve the model's ability to extract features of multi-scale disease spots. The frequency-spatial attention module FSA and parallel position-aware attention mechanism were introduced into the feature fusion layer to strengthen the expression of edge detail features of disease spots and enhance the model's anti-interference ability in complex field backgrounds. The multi-scale channel attention module MTA-Net was introduced in the detection head to optimize the detection accuracy of small target disease spots and reduce redundant computation, which was adapted to the inference requirements of the hardware end. The experimental results showed that compared with the original YOLOv8s model, the precision, recall, and mean average precision (mAP) of the YOLOv8s-MSFDS model reached 91.9%, 87.9%, and 85.1%, respectively, with only 5.9 MB of parameters, and the inference speed reached 4.99 FPS on the Jetson Nano edge computing platform, meeting the demand of real-time field detection. While maintaining lightweight, the model achieved improved detection accuracy and effectively balanced detection performance and computational efficiency. After being mounted on the tracked robot platform built based on ROS, it exhibited good generalization and robustness in real field scenarios, which can provide integrated hardware and algorithm technical support for the intelligent monitoring of cotton leaf diseases.

Keywords

Cotton Leaf Disease Detection, Yolov8s, MKC Block Module, Attention Mechanism, Tracked Robot, ROS

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

棉花作为全球重要的经济作物，其叶片病害的准确识别与及时防控对保障棉花产量和品质具有重要意义。然而传统人工检测方式效率低下，且现有深度学习模型在检测精度与轻量化之间难以取得平衡，无法满足移动平台实时监测的需求。

近年来，基于 YOLOv8s 的农作物病虫害识别研究已成为智慧农业领域的热点，众多学者围绕模型轻量化、多尺度特征提取、注意力机制、损失函数优化以及实际部署等方面开展了大量工作。文献[1]针对大豆叶病害检测，通过 CycleGAN、CBAM 注意力与局部判别器改进 Retinex-Net 增强网络，并采用 ShuffleNetv2 + SE 构建主干、FasterNet Block 替换 C2f 模块、融合 Alpha-EIoU 损失函数，在提升低光照图像质量的同时实现了模型轻量化与高精度检测。文献[2]在茶叶病虫害检测中将主干替换为 FasterNet，引入 CBAM 模块并改用 WIoU 损失，改进后的 YOLOv8s-CFW 模型提高了对重叠目标的检

测能力。文献[3]面向航拍小目标检测,通过添加小目标检测头、引入 PPA 注意力、X-DySample 动态采样有效解决了小目标漏检问题。文献[4]针对棉田害虫检测设计 Star-YOLO 模型,采用 StarNet 主干、星型运算构建 Star-C2f 模块、提出轻量化检测头 ESCDH。文献[5]在小麦赤霉病检测中引入 ShuffleNetv2 + SE 构建主干,增强了对小病斑的识别能力。文献[6]针对玉米病虫害引入 FasterNet 替换 C2f、头部嵌入 RFB-Net、改用 SIoU 损失,验证了算法的实用性。文献[7]面向棉叶病害提出 MN-YOLO 模型,在 YOLOv12n 主干末端引入多尺度简单注意力 MSSimAM,采用自适应阈值焦点损失 ATFL,实现检测与诊断一体化。

然而,在棉花叶病害检测任务中,病斑尺度差异大、背景干扰复杂、小目标易漏检以及检测精度与效率难以平衡等问题仍制约实际应用。为此,本文提出 YOLOv8s-MSFDS (Multi-Scale Feature Dynamic Selection)多尺度特征动态选择模型。该模型在主干网络(Backbone)中引入融合多尺寸卷积核与动态蛇形卷积的 MKC-Block 模块(Multi-Scale Kernel Convolution Block with Dynamic Snake Convolution),提升多尺度病斑特征提取能力;在特征融合层(Neck)嵌入频率-空间注意力模块(Frequency-Spatial Attention, FSA)与并行位置感知注意力机制,强化病斑边缘细节特征并增强抗干扰能力;在检测头(Head)引入多尺度通道注意力网络(Multi-Scale Channel Attention Network, MTA-Net),优化小目标检测精度并降低冗余计算。实验结果表明, YOLOv8s-MSFDS 在保持轻量化的同时实现了更高检测精度,并成功部署于基于 ROS 的履带式机器人平台,在田间真实场景下表现出良好的泛化性与鲁棒性,为棉花叶病害智能监测提供了一体化技术支撑。

2. 核心算法与原理

2.1. YOLOv8s-MSFDS 模型

YOLOv8s-MSFDS 模型以轻量级网络 YOLOv8s 为基础框架进行改进,模型结构如图 1 所示。整个模型主要分为四部分:输入端、主干网络、特征融合层和检测头,在主干网络中引入 MKC-Block 模块,在特征融合层嵌入频率-空间注意力模块,在检测头引入多尺度通道注意力网络,优化精度减少计算。



Figure 1. YOLOv8s-MSFDS model architecture diagram

图 1. YOLOv8s-MSFDS 模型结构图

2.2. 多尺度通道注意力网络

针对棉花病斑在不同病种和发展阶段下呈现出尺寸多样、形态复杂等特点。传统网络在单一尺度下提取的特征往往难以兼顾小目标与大范围病斑区域,容易导致信息丢失,影响整体检测效果。受病害检测领域文献[8]的启发,本文设计了多尺度通道注意力网络(MTA-Net),该网络通过对不同尺度的特征图进行加权处理,引导模型重点关注与目标区域相关的高价值特征,从而提升病斑区域的感知能力。

MTA-Net 通过多级特征交互与动态注意力机制,将 Backbone 提取的多尺度高维特征高效恢复至原

始空间分辨率，同时增强对病斑细节与全局语义的协同感知能力，如图2所示。MTA-Net 通过以下四个模块级联实现多尺度特征优化。

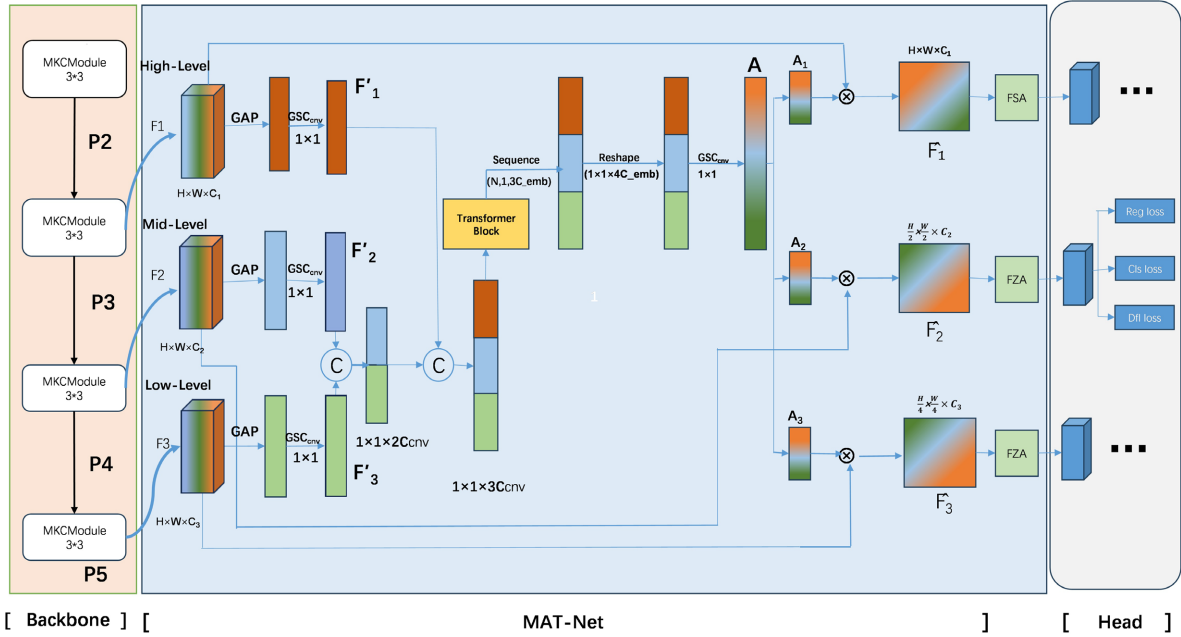


Figure 2. MAT-Net architecture diagram

图2. MAT-Net 结构图

首先，多尺度特征降维单元主要是对不同尺度的特征进行降维，使其适配后续的注意力机制。由于棉花叶片病害的病斑形态多样，因此通过多尺度卷积操作提取不同尺寸的特征图。采用轻量卷积对特征进行降维。通过特征降维可以确保非常细小的病斑能够被有效捕捉，而较大的病斑区域也能得到充分的关注。

设输入特征图集为 $\{F_1, F_2, \dots, F_L\}$ 分别来自主干网络不同阶段。对每个 F_i 执行轻量卷积降维：

$$F'_i = \text{Conv}_{\text{light}}(F_i) \quad (1)$$

其中， $\text{Conv}_{\text{light}}$ 表示轻量卷积操作。

随后，MTA-Net 采用了渐进式通道拼接单元[9]，在传统的网络结构中，不同尺度的特征图通常在解码器部分进行简单拼接。但由于病斑的尺度差异较大，传统的拼接方式容易导致信息丢失或不一致。渐进式通道拼接单元通过逐步拼接多个尺度的特征图来保留各尺度的有效信息。将来自不同尺度的低维特征 $[F'_i, F'_{i+1}, F'_{i+2}]$ 进行拼接，拼接操作按通道维度进行。拼接后输出特征图的维度如式(2)所示：

$$F_{\text{concat}} = [F'_i, F'_{i+1}, F'_{i+2}] \quad (\text{Shape} = 1 \times 1 \times n \times C_{\text{emb}}) \quad (2)$$

其中， C_{emb} 是嵌入通道数， n 是拼接的尺度数，最终拼接后的特征图能融合来自各个尺度的特征信息。

将最低分辨率特征逐步上采样并与下一级特征按通道拼接

$$G_L = F'_L \quad (3)$$

$$G_i = \text{Concat}(F'_i, \text{UpSample}(G_{i+1})), \quad i = L-1, L-2, \dots, 1 \quad (4)$$

其中，UpSample 为双线性插值，Concat 为通道维度拼接，融合了所有尺度的特征。

接着 Transformer 全局建模单元通过自注意力机制对特征之间的关系进行计算, 然后对特征权重进行调整。这种机制在多尺度的病斑检测任务中显得尤为重要, 因为病斑的形态和尺度存在较大差异, 传统方法很难做到细节信息与全局上下文同时处理, 而该模块让模型在检测病斑时将整张叶子上分散的、大小不一的病斑信息全部整合起来, 形成一个全局的、立体的病害特征图, 从而大大提升对复杂病斑形态的识别能力。为了有效地捕捉信息, Transformer 模块通过多头自注意力机制对不同的注意力模式进行并行运算, 通过前馈网络进一步增强特征表现能力。图 3 展示了该单元的结构。

Transformer 全局建模单元的计算步骤如下:

- 1) 层归一化(LN)与多头自注意力(MSA), 并通过残差连接

$$\hat{X} = \text{LN}(X) + \text{MSA}(\text{LN}(X)) \quad (5)$$

- 2) 再次层归一化与前馈网络(FFN):

$$X_{\text{out}} = \text{LN}(\hat{X}) + \text{FFN}(\text{LN}(\hat{X})) \quad (6)$$

其中多头自注意力的计算公式为:

$$\text{MSA}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (7)$$

Q 、 K 、 V 由输入线性变换生成 d_k 为键向量维度。

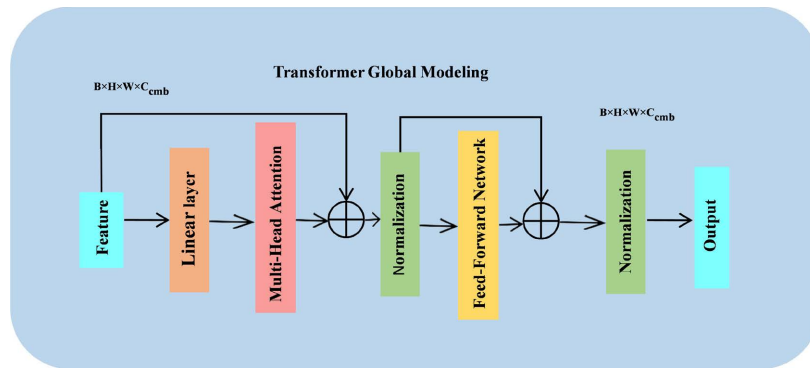


Figure 3. Transformer global modeling unit
图 3. Transformer 全局建模单元

最后动态注意力分割单元利用动态注意力分割法[10], 进一步提高对病斑区域的关注程度。通过动态生成的注意力图能够自动调节注意力权重, 根据当前特征的上下文信息突出病斑区域, 减少对背景的关注。

动态注意力分割单元中, 将 X_{out} 重塑为特征图 T (形状 $C \times H \times W$), 通过 1×1 卷积和 Sigmoid 函数生成动态注意力图 A :

$$A = \sigma(\text{Conv}_{1 \times 1}(T)) \quad (8)$$

然后将各尺度降维后的特征图 F' 上采样至相同尺寸($H \times W$), 并与 A 逐元素加权求和

$$M = \sum_{i=1}^L \text{UpSample}(F'_i, \text{size}=(H, W)) \odot A \quad (9)$$

其中, \odot 表示逐元素相乘。最后 M 经轻量卷积与上采样恢复原始分辨率, 作为 MTA-Net 的输出。

这种融合方式确保了网络在处理细节信息和全局特征时，增强了全局上下对不同尺度病斑的建模能力，有效提高了病斑检测的精度。

2.3. MKC-Block 模块

棉花叶病害在不同品种和发病阶段下，病斑尺度差异显著，小到针尖状的锈斑，大到覆盖叶片大面积的黑斑病。原始 YOLOv8s 主干网络中的 C2f 模块主要依赖标准卷积操作，其固定感受野难以同时兼顾小尺度细节与大尺度全局特征。MKC-Block 模块替换 YOLOv8s 主干网络中的 C2F 模块，显著增强了网络对不同尺度病斑特征的提取能力，能够同时捕捉小病斑和大面积病变区域的特征。MKC-Block 不仅增强了对不同尺度特征的处理能力，还通过可变形卷积使网络能够动态调整卷积核的感受，从而提高了对形态变化目标的适应能力。在 MKC-Block 中，卷积操作的输出 Y 由不同卷积核和输入特征图的卷积计算得出，具体表示为：

$$Y = \sum_{i=1}^n W_i \otimes X_i + b_i \quad (10)$$

其中， W_i 表示不同尺寸的卷积核， X_i 为输入特征图， $*$ 为卷积操作， b_i 为卷积后的偏置项， n 为使用的卷积核数量。多尺度的卷积核能够有效地捕捉不同尺度的病斑特征。

动态蛇形卷积结构示意图如图 4 所示。动态蛇形卷积使用迭代策略，通过自适应调整卷积核的位置，可以有效提取管状结构的局部特征。标准的 2D 卷积坐标表示为 K ，其中心坐标为 $K_i = (x_i, y_i)$ 。 3×3 的标准卷积核(扩张率为 1)，其坐标集合如公式(11)所示：

$$K = \{(x-1, y-1), (x-1, y), \dots, (x+1, y+1)\} \quad (11)$$




Figure 4. Schematic diagram of dynamic snake convolution structure
图 4. 动态蛇形卷积结构示意图

2.4. 融合频率 - 空间注意力模块

在棉花叶片病害检测中，病斑通常表现为边缘清晰、纹理突出的区域，其特征多集中于图像的高频部分。若忽视高频信息，模型在处理微小病斑或边缘模糊区域时易出现误判，影响整体检测精度。为了增强网络对病斑区域高频特征的敏感性，提升模型的判别能力，本文引入了频率 - 空间注意力模块[11] (Frequency-Spatial Attention, FSA)。该模块综合考虑图像在频域与空间域的信息，通过融合不同尺度和维度的注意力特征，提升模型在复杂背景下的特征表达能力。FSA 模块的详细结构如图 5 所示。

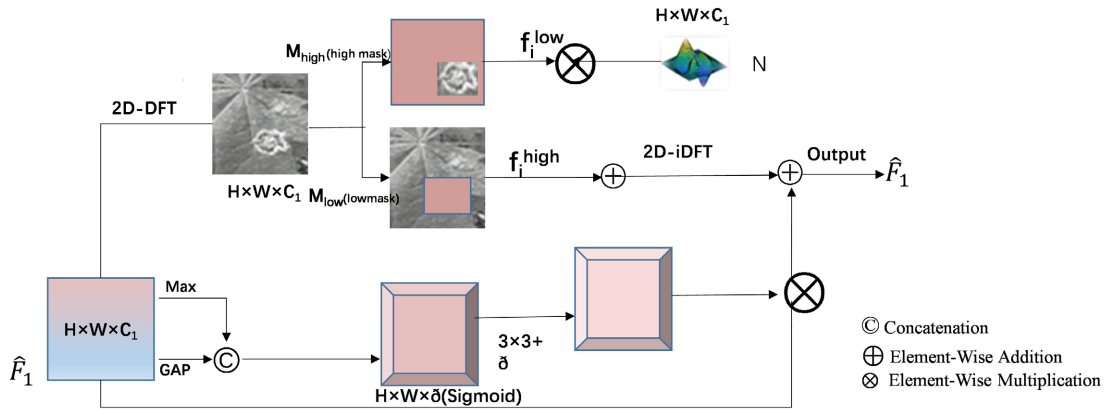


Figure 5. Schematic diagram of the frequency-spatial attention module
图 5. 频率 - 空间注意力模块示意图

频域变换: 给定 MTA-Net 输出的特征图 $\hat{F} \in R^{H \times W \times C}$ (H 、 W 为空间尺寸, C 为通道数), 采用二维离散傅里叶变换(2D-DFT)将其转换到频域, 得到频域特征图 \hat{F} :

$$\hat{F}(u, v) = \sum_{x=0}^{H-1} \sum_{y=0}^{W-1} F(x, y) \cdot e^{-j2\pi\left(\frac{ux}{H} + \frac{vy}{W}\right)} \quad (12)$$

其中, (x, y) 为空间坐标, (u, v) 为频率坐标, j 为虚数单位。该变换将空间域的灰度变化转换为频域中的不同频率分量: 病斑边缘、纹理等高频信息对应较大的 $|\hat{F}(u, v)|$, 而平滑背景对应低频分量。

频域通道注意力: 对于频域特征图 $\hat{F} \in R^{H \times W \times C}$ (复数), 取模后得到实值张量, 然后沿空间维度分别进行全局平均池化(GAP)和全局最大池化(GMP), 得到两个通道维度的向量, 将两个向量分别送入共享的多层感知机输出相加后经过 Sigmoid 激活, 生成频域通道注意力权重:

$$A_{\text{freq}} = \sigma\left(\text{MLP}\left(\text{GAP}\left(|\hat{F}|\right)\right) + \text{MLP}\left(\text{GMP}\left(|\hat{F}|\right)\right)\right) \quad (13)$$

该权重用于强调对病害识别贡献较大的频率通道。

空间域注意力: 同时在空间域上, 对原始输入特征 F 采用空间注意力机制。首先沿通道维度分别计算平均值和最大值, 得到两个单通道特征图:

$$\begin{aligned} s_{\text{avg}} &= \text{GAP}_s(F) \in R^{H \times W} \\ s_{\text{max}} &= \text{GMP}_s(F) \in R^{H \times W} \end{aligned} \quad (14)$$

将二者沿通道方向拼接为 $[s_{\text{avg}}, s_{\text{max}}] \in R^{2 \times H \times W}$, 然后通过一个 7×7 卷积层将通道数降为 1, 再经 Sigmoid 激活生成空间注意力图 A_{spa} :

$$A_{\text{spa}} = \sigma\left(\text{Conv}_{7 \times 7}\left([\text{GAP}_s(F); \text{GMP}_s(F)]\right)\right) \quad (15)$$

该注意力图突出病斑所在的空间位置, 抑制背景区域。

注意力特征融合: 将频域注意力加权后的特征与空间注意力加权后的特征进行逐元素相加, 得到最终的增强特征:

$$F_{\text{out}} = \left(\hat{F} \odot A_{\text{freq}}\right) + \left(F \odot A_{\text{spa}}\right) \quad (16)$$

其中, \odot 表示逐元素乘法融合后的 F_{out} , 保留了原始空间结构, 同时增强了高频细节和病斑区域响应。

3. 棉花叶病害识别机器人架构

3.1. 履带式机器人软件环境

3.1.1. 嵌入式软件环境

机器人搭载的嵌入式控制单元，核心是树莓派 4B。基于 Debian 优化开发的嵌入式环境，利用其轻量化、高度定制化的特点，实现传感器数据采集、运动控制和任务调度。

3.1.2. 操作系统环境

机器人搭载的操作系统为 Ubuntu18.04LTS (长期支持版本)，稳定性、安全性和兼容性都十分优秀，特别适合嵌入式设备、工业和机器人平台的应用。该系统具备长期支持特性，确保在实际部署中长期稳定运行，同时兼容主流硬件设备和多种开发框架，满足机器人多模块集成需求。

3.1.3. 视觉处理单元环境

视觉感知模块选用 NVIDIA Jetson Nano B01 当作核心硬件平台，结合 CUDA 和 TensorRT 技术实现深度学习模型的高效推理，Jetson Nano B01 拥有强大的 GPU 加速能力，可实时处理大规模图像数据，并且开展深度学习推理，以此提升目标侦测的精确度与速度。TensorRT 技术对深度学习模型的推理过程进行了优化。在嵌入式设备方面，它借助层融合、精度降级以及动态张量优化等技术手段，使得推理速度得到明显提升，同时延迟也有所降低。

4. 实验与结果

4.1. 数据集

实验数据源自 Kaggle 公开的 6 个棉花病虫害数据集，包含叶斑病、蚜虫病等多种病害类型，原始图像共计 6891 张。为避免环境变化和图像场景单一导致模型过拟合，本文采用尺寸调整、随机几何变换与像素域变换相结合的策略进行数据增强，并引入高斯滤波去除图像噪声。经增强后，数据集样本量扩充至 27,564 张，其中训练集 24,808 张，测试集 2756 张，有效提升了模型在复杂田间环境下的鲁棒性与泛化能力，如图 6 和表 1 所示。

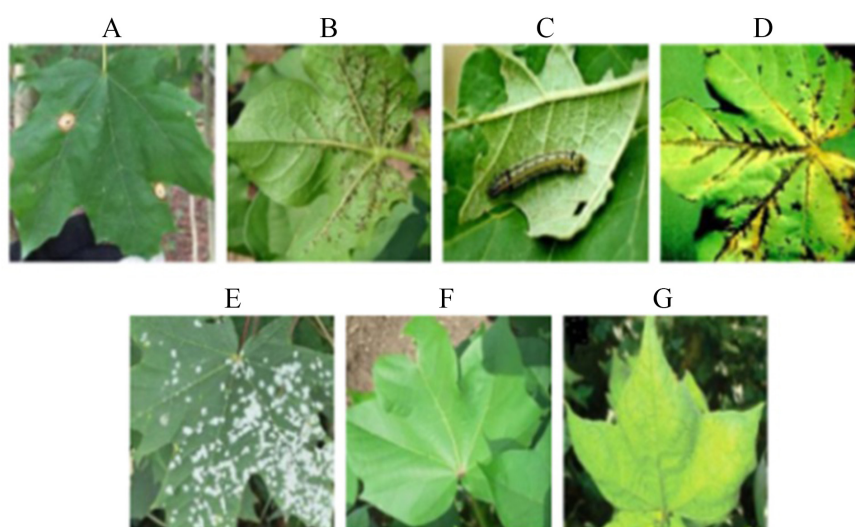


Figure 6. Cotton leaf disease and pest dataset
图 6. 棉花叶片病虫害数据集

Table 1. Summary of the cotton leaf disease and pest dataset**表 1.** 病虫害数据集概括

病害种类	原图像共计	增强后共计	训练集/测试集	标签
叶斑病	860	3440	3096/344	A
蚜虫病	745	2980	2682/298	B
粘虫病	875	3500	2100/350	C
黑斑病	1002	4008	4399/401	D
灰霉病	974	3896	3506/389	E
健康	1545	6180	5562/618	F
叶卷病	890	3560	3204/356	G
总共	6891	27,564	24,808/2756	

4.2. 模型实际效果(YOLOv8s-MSFDS)

将 YOLOv8s-MSFDS 与原 YOLOv8s 模型在棉花叶片病害检测任务上的效果进行了对比, 结果显示, 在病斑尺度差异大、背景干扰复杂的田间场景下, 原 YOLOv8s 模型存在对小病斑漏检、病斑边缘定位不准确以及背景误检等问题。相比之下, YOLOv8s-MSFDS 模型通过引入融合多尺寸卷积核与动态蛇形卷积的 MKC Block 模块, 有效提升了多尺度病斑特征提取能力, 能够准确识别不同大小的病斑区域; 同时, 在特征融合层嵌入频率-空间注意力 FSA 模块, 强化了病斑边缘细节特征, 使检测框定位更加精准; 多尺度通道注意力 MTA-Net 的引入进一步优化了对小目标病斑的检测精度, 有效降低了漏检与误检。实验结果表明, 本文模型在复杂环境下具有更强的特征表达能力和抗干扰能力, 检测效果显著优于原模型。

4.3. 模型性能评估指标

本文采用准确率、精确率、召回率、F1-score 及 mAP@0.5 综合评价模型检测精度, 其中 mAP@0.5 反映多类别目标在 IoU 阈值为 0.5 时的平均检测性能; 同时, 通过参数量和计算量(FLOPs)衡量模型复杂度和计算效率, 以验证模型在保证高精度的同时具备良好的轻量化与实时性。

4.4. 对比试验

为了证明 YOLOv8s-MSFDS 模型的有效性, 将其与 YOLOv3、YOLOv5s、YOLOv6s、YOLOv7、YOLOv7-tiny、Faster R-CNN、CenterNet 及 YOLOv8 等 8 种经典目标检测算法在自建的棉花叶片病害数据集上进行对比实验, 实验结果如表 2 所示。从表中可以看出, 本文提出的 YOLOv8s-MSFDS 模型在精确率、准确率和召回率上均优于所有对比算法。与基准模型 YOLOv8 相比, 本文模型的精确率提升 4.1 个百分点(达 91.9%), 准确率提升 5.0 个百分点(达 83.6%), 召回率提升 4.0 个百分点(达 87.9%), 充分验证了多尺度特征动态选择机制与频域注意力增强策略的有效性。与轻量级模型 YOLOv5s 相比, 本文模型在召回率和精确率上分别提升 3.7 和 5.3 个百分点, 同时参数量与计算量虽有所增加, 但仍处于可接受范围, 体现了模型在精度与复杂度之间的良好平衡。相较于两阶段检测算法 Faster R-CNN, 本文模型在各项精度指标上均大幅领先, 且模型尺寸仅为 32.3 MB, 远小于 Faster R-CNN 的 333 MB, 显著降低了部署成本。实验结果表明, 本文提出的 YOLOv8s-MSFDS 模型在棉花叶片病害检测任务中具有显著的性能优势, 能够在保持较高计算效率的同时实现更高的检测精度, 为田间实时病害监测提供了可靠的技术方案。

Table 2. Performance comparison of different models**表 2.** 不同模型的性能对比

模型	精确度/%	准确度/%	召回率/%	参数/MB	计算量/FLOPs	模型尺寸/MB
YOLOv3	87.1	79.1	84.1	103.6	282.2	207.8
YOLOv5s	86.6	79.1	84.2	9.1	23.8	18.6
YOLOv6s	87.5	76.5	83.1	16.2	44	32.9
YOLOv7	84.1	79.6	83.4	37.2	105.2	74.9
YOLOv7-tiny	77.7	70.3	73.8	6.0	13.2	12.3
Faster R-CNN	82.3	81.2	80.4	42.4	239.3	333
CenterNet	81.6	80.4	79.1	33.1	186.8	260
YOLOv8	87.8	78.6	83.9	11.1	28.7	22.6
Proposed Method	91.9	83.6	87.9	16.7	36.1	32.3

4.5. 消融实验(YOLOv8s-MSFDS)

为验证各改进模块对模型性能的贡献, 本文设计了消融实验, 结果如表 3 所示。以 YOLOv8s 为基线模型, 逐步引入 MTA-Net、DSConv (MKC Block)和 FSA 模块。实验结果表明, 单独引入 MTA-Net 后, 模型召回率提升 0.9%, 计算量降低至 24.9 GFlops, 验证了多尺度特征融合的有效性; 在此基础上引入 MKC Block, 精确率提升至 81%, 召回率达 85.3%, 表明多核卷积与动态蛇形卷积增强了特征表达能力; 最终引入 FSA 模块后, 模型精确率、准确率和召回率分别达到 91.9%、83.6%和 87.9%, 较基线模型分别提升 4.1、5.0 和 4.0 个百分点, 充分验证了各模块的协同有效性。

Table 3. Performance comparison of different module schemes**表 3.** 不同模块方案的性能对比

MTA	DSConv	FSA	准确率/%	精确度/%	召回率/%	参数量/MB	计算量/GFlops
×	×	×	87.8	78.6	83.9	11.1	28.7
√	×	×	85.9	79.3	84.8	12.1	24.9
√	√	×	87.2	81	85.3	14.4	33.8
√	√	√	91.9	83.6	87.9	16.7	36.1

5. 总结

为应对复杂背景干扰和小目标识别的问题, 本文给出了针对 YOLOv8 网络的改进策略。该策略包括引入多尺度通道注意力(MTA-Net)模块, 通过加权融合不同尺度的特征, 增强模型对病虫害区域的感知能力, 在大小差异较大的病害区域, 检测精度得到了提升。采用频域空间注意力(FSA)机制, 通过离散傅里叶变换(DFT)提取频域特征, 强化模型对病害区域高频信息的感知能力, 提高病害边缘及细节的检测能力。并且结合深度可分离卷积(DSConv)降低模型计算复杂度, 在维持检测精度的状况下, 提高推理速度。实验结果显示, 引入 MTA、MCK 和 FSA 模块之后, 改进模型的准确率实现了从 87.8%到 90.9%的提升。精确度也从 78.6%提高到了 81.6%, 这充分显示出其误检抑制能力得到了提高。召回率提升了 4%, 由 83.9%增长至 87.9%, 这提高了对病虫害区域的全面感知效果。

基金项目

辽宁科技大学大学生创新创业训练计划项目。

参考文献

- [1] 吴亦欣. 基于 Retinex-Net 和 YOLOv8s 的农作物病害检测方法研究[D]: [硕士学位论文]. 南昌: 江西师范大学, 2025.
- [2] 刘睿, 王丽娟, 王秋皓, 等. 基于改进 YOLOv8s 的茶叶病虫害检测[J]. 浙江农业学报, 2025, 37(9): 1933-1942.
- [3] 毛昕蓉, 徐霄. 基于改进 YOLOv8s 的航拍图像小目标检测算法[J]. 微电子学与计算机, 2026, 43(3): 75-87.
- [4] 严哲锐, 陈中举, 李和平, 等. 基于改进 YOLOv8s 的轻量化棉田害虫检测方法[J/OL]. 江苏农业科学, 1-10. <https://link.cnki.net/urlid/32.1214.S.20250407.1258.002>, 2026-03-18.
- [5] 王昊, 于啸. 基于改进 YOLOv8s 的小麦赤霉病害检测研究[J]. 山东农业科学, 2025, 57(8): 149-159.
- [6] 邱加明. 基于改进 YOLOv8s 模型的玉米病虫害识别与检测研究[D]: [硕士学位论文]. 昆明: 云南农业大学, 2024.
- [7] 哈里旦木·阿布都克里木, 张耿荣, 梁宇涵, 等. 面向小目标优化的棉叶病害智能诊断模型[J/OL]. 计算机应用, 1-13. <https://link.cnki.net/urlid/51.1307.TP.20260120.1436.020>, 2026-03-18.
- [8] 刘翠翠. 融合多尺度注意力机制的棉花枯萎病识别算法研究[J]. 现代农业装备, 2025(2): 57-62.
- [9] 朱磊, 等. 基于双通道分类处理的图像拼接方法[J]. 西安工程大学学报, 2025, 39(4): 118-127.
- [10] 房梁, 谢刚, 续欣莹, 等. 融合动态权重与语义筛选的双分支遥感图像语义分割[J]. 计算机工程与应用, 2025, 61(20): 295-305.
- [11] 方智国, 徐诺, 赵发. 基于 FSA-SVM 算法的多时相光学遥感影像地表覆盖分类[J/OL]. <https://link.cnki.net/urlid/34.1300.N.20260312.1128.006>, 2026-05-14.