

唐义声, 姜新华, 于晓芳, 等. 基于 WPM-YOLO11 的玉米叶片病害检测方法[J]. 江苏农业学报, 2026, 42(2): 264-272.

doi: 10.3969/j.issn.1000-4440.2026.02.005

## 基于 WPM-YOLO11 的玉米叶片病害检测方法

唐义声<sup>1,2</sup>, 姜新华<sup>1,2</sup>, 于晓芳<sup>3</sup>, 高聚林<sup>3</sup>, 胡健<sup>1,2</sup>, 张子汉<sup>1,2</sup>, 翟成璐<sup>4</sup>

(1. 内蒙古农业大学计算机与信息工程学院, 内蒙古 呼和浩特 010018; 2. 内蒙古自治区农牧业大数据研究与应用重点实验室, 内蒙古 呼和浩特 010018; 3. 内蒙古农业大学农学院, 内蒙古 呼和浩特 010018; 4. 内蒙古自治区教育考试院, 内蒙古 呼和浩特 010011)

**摘要:** 玉米作为全球重要的粮食作物, 其产量与质量易受多种叶片病害影响。针对玉米病害病斑边缘模糊、小目标检测困难等问题, 本研究提出基于 YOLOv11m 改进的 WPM-YOLO11 模型。该模型引入风车状方向卷积 (Windmill convolution) 模块以增强边缘与方向特征提取能力, 设计多尺度增强并行注意力 (MSEPA) 模块提升多尺度信息融合效率。数据集构建涵盖感染褐斑病、普通锈病、南方锈病、花叶病、北方枯叶病、灰斑病、圆斑病的玉米叶片及健康玉米叶片, 结果表明, WPM-YOLO11 模型交并比阈值为 0.50 的平均精度均值 ( $mAP_{50}$ ) 和交并比阈值为 0.50~0.90 的平均精度均值 ( $mAP_{50:95}$ ) 分别达到 93.7% 和 78.5%, 整体性能优于 YOLOv11m 及其他主流模型。本研究为玉米病害智能识别提供了技术方案, 对智慧农业病害监测与精准防治具有重要意义。

**关键词:** 玉米叶片病害; 目标检测; YOLOv11; 多尺度特征融合; 注意力机制

**中图分类号:** S435.131 **文献标识码:** A **文章编号:** 1000-4440(2026)02-0264-09

## A maize leaf disease detection method based on WPM-YOLO11

TANG Yisheng<sup>1,2</sup>, JIANG Xinhua<sup>1,2</sup>, YU Xiaofang<sup>3</sup>, GAO Julin<sup>3</sup>, HU Jian<sup>1,2</sup>, ZHANG Zihan<sup>1,2</sup>, ZHAI Chengjun<sup>4</sup>

(1. College of Computer and Information Engineering, Inner Mongolia Agricultural University, Hohhot 010018, China; 2. Inner Mongolia Key Laboratory of Agricultural and Animal Husbandry Big Data Research and Application, Hohhot 010018, China; 3. College of Agronomy, Inner Mongolia Agricultural University, Hohhot 010018, China; 4. Education Examinations Authority of Inner Mongolia Autonomous Region, Hohhot 010011, China)

**Abstract:** As a globally important food crop, maize is vulnerable to various leaf diseases that affect its yield and quality. To address issues such as blurred edges of maize lesions and difficulties in small target detection, this study proposed the WPM-YOLO11 model improved based on YOLOv11m. The model introduced a windmill convolution module to enhance the ability of edge and directional feature extraction, and designed a multi-scale enhanced parallel attention (MSEPA) module to improve the efficiency of multi-scale information fusion. The constructed dataset included maize leaves infected with brown spot, common rust, southern rust, mosaic disease, northern leaf blight, gray leaf spot, circular spot, as

收稿日期: 2025-06-18

基金项目: 内蒙古自然科学基金项目 (2023LHMS06017、2024LHMS06021); 国家自然科学基金项目 (62061037、31960494); 内蒙古自治区科技攻关计划项目 (2020GG0169); 内蒙古自治区科技重大专项 (2021ZD0003)

作者简介: 唐义声 (1998-), 男, 辽宁辽阳人, 硕士研究生, 研究方向为模式识别与智能信息处理。(E-mail) easontown@foxmail.com

通讯作者: 姜新华, (E-mail) jiangxh@imau.edu.cn

well as healthy maize leaves. The results showed that the mean average precision at an intersection over union (IoU) threshold of 0.50 ( $mAP_{50}$ ) and the mean average precision at IoU thresholds from 0.50 to 0.90 ( $mAP_{50:95}$ ) of the WPM-YOLO11 model reached 93.7% and 78.5%, respectively, and its overall performance was superior to that of YOLOv11m and other mainstream models. This study provides a technical solution for the intelligent identification of maize diseases, and is of great significance for

disease monitoring and precise control in smart agriculture.

**Key words:** maize leaf disease; object detection; YOLOv11; multi-scale feature fusion; attention mechanism

玉米是全球最重要的粮食作物之一。在整个生长周期内,玉米易受多种叶部病害侵扰,严重影响其产量与品质<sup>[1]</sup>。由于病害种类繁多,部分病害形态特征相似,人工识别存在效率低下、准确性不足等问题<sup>[2]</sup>。近年来,为实现病害的精准识别和智能监测,基于图像的作物病害识别研究逐渐兴起<sup>[3-4]</sup>,代表性模型包括 AlexNet<sup>[5]</sup>、GoogleNet<sup>[6]</sup>、ResNet<sup>[7]</sup>、MobileNet<sup>[8]</sup>、Swin Transformer<sup>[9]</sup>等。

YOLO 系列模型凭借其端到端设计、实时性强与检测精度高等优势,被广泛用于农作物病虫害识别。Timilsina 等<sup>[10]</sup>在 YOLOv8 模型中引入多尺度注意力机制与轻量化模块,增强了对玉米叶片图像中小病斑区域的检测能力,平均精度均值(*mAP*)达 91.3%。Meng 等<sup>[11]</sup>结合多尺度可变核卷积(MK-Conv)结构与选择性核(SK)注意力机制,提出 YOLO-MSM模型,该模型在南方锈病与灰斑病检测中表现优异。Li 等<sup>[12]</sup>基于 YOLOv8s 模型引入 Ghost 模块,将模型体积压缩至 9.6 MB,同时使其检测准确率保持在 91.7%。Nakatumba-Nabende 等<sup>[13]</sup>将 YOLOv10 模型结合 Transformer 结构与可解释人工智能(XAI),实现对非洲地区田间主要病害的精准识别,并将该模型成功部署至移动终端。

YOLO 系列模型在玉米病害检测中已取得较好效果,但现有研究多集中于单一典型病害,对多种类病害同步检测能力不足;模型改进主要聚焦于颈部结构优化,对骨干网络特征提取能力关注较少。本研究拟构建基于 YOLOv11m 的改进算法,通过增强病斑边缘轮廓与对小目标感知能力,提升模型对多尺度纹理特征的建模效果,以实现玉米叶片多病害的精准识别。

## 1 材料与方 法

### 1.1 数据集构建

本研究所用数据集来源于 PlantVillage、CD&S<sup>[14]</sup>、Kaggle 的作物病害数据集。经整合后形成初始图像库。采用 LabelImg 工具对图像进行人工标注。如表 1 所示,为提升数据多样性,通过亮度调整、缩放、平移、旋转和对比度增强等方式对图像进行扩增。最终构建的数据集共计 10 580 张图像,按 8 : 1 : 1 的比例划分为训练集(8 464 张)、验证集

(1 058 张)和测试集(1 058 张)。

表 1 数据增强方法

Table 1 Data augmentation methods

采用方法	参数
iaa.Invert	0.5
iaa.Fliplr	0.5
iaa.Multiply	(0.8,1.2)
iaa.GaussianBlur	$\sigma = (0, 3.0)$
iaa.ContrastNormalization	(0.7,1.3)
iaa.Affine(translate_px)	{"x":15,"y":15}
iaa.Affine(scale)	(0.8,1.2)

iaa:图像增强;Invert:反转;Fliplr:左右翻转;Multiply:亮度调整(像素乘法);GaussianBlur:高斯模糊;ContrastNormalization:对比度调整;Affine:仿射变换;translate\_px:像素平移;scale:缩放比例; $\sigma$ :标准差;x,y:横向、纵向。

如表 2 所示,本研究构建的数据集包含 8 类图像,分别为感染褐斑病、普通锈病、南方锈病、花叶病、北方枯叶病、灰斑病、圆斑病的玉米叶片及健康玉米叶片。数据来源于真实田间环境,各类别图像的病斑呈现自然状态下分布不平衡。例如,锈病叶片上病斑密集且数量较多,而北方枯叶病叶片病斑数量较少且较大。

表 2 数据集信息

Table 2 Dataset information

图像类别	图像数量(张)	标注框数量(个)
褐斑病	3 225	23 616
普通锈病	1 314	6 648
南方锈病	469	40 473
花叶病	1 137	10 746
北方枯叶病	2 076	4 401
灰斑病	1 368	14 928
圆斑病	1 711	13 061
健康	1 098	6 864

### 1.2 玉米叶片病害识别模型 WPM-YOLO11 构建

1.2.1 基础模型 YOLO 系列模型因其端到端架构与高效的检测性能,在农业病虫害识别领域得到了广泛应用。相比于前期版本,YOLOv11 模型的计算复杂度进一步降低,对多尺度目标的特征提取能力

增强,并且模型的可控性与实际部署灵活性提高。研究结果表明,在 COCO 数据集上,YOLOv11m 模型取得了更高的平均精度均值,且与 YOLOv8m 相比

参数量显著减少,计算效率显著提升<sup>[15]</sup>。如表 3 所示,YOLOv11m 的各项指标综合表现较好,因此被选作基准模型。

表 3 不同 YOLO 模型对玉米叶片病害检测性能对比

Table 3 Comparison of detection performance of different YOLO models for maize leaf diseases

模型名称	精确率 (%)	召回率 (%)	$mAP_{50}$ (%)	$mAP_{50:95}$ (%)	网络层数	参数量 (M)	浮点运算量 (G)
YOLOv5m	81.8	79.4	84.6	54.6	363	22.18	53.1
YOLOv6m	76.1	73.9	78.4	47.0	297	51.29	158.8
YOLOv7m	85.0	84.0	87.5	58.6	415	37.20	105.4
YOLOv8m	84.4	86.3	89.6	65.1	319	23.27	68.1
YOLOv9m	85.4	85.4	89.3	65.0	627	16.78	61.4
YOLOv10m	80.0	81.2	84.8	56.4	498	16.58	64.5
YOLOv11m	85.2	86.1	89.8	66.3	409	20.11	68.5
YOLOv12m	80.7	82.0	85.5	57.3	292	20.20	68.1

YOLOv5~YOLOv12:第 5~第 12 版本 YOLO;m:中等尺寸模型。 $mAP_{50}$ :交并比阈值为 0.50 的平均精度均值; $mAP_{50:95}$ :交并比阈值为 0.50~0.90 的平均精度均值。

1.2.2 模型改进 为提升模型对多种病害的识别精度与特征表达能力,本研究基于 YOLOv11m,提出 WPM-YOLO11 模型,其结构如图 1 所示。首先,针对传统卷积提取病斑边缘、形状、分布等特征能力有限的问题,提出风车状方向卷积(Windmill convolution)模块。该模块通过多分支动态扩张与方向感知机制,增强模型对病斑边缘轮廓的敏感性,提升特征提取的准确性与判别力。其次,为加强模型在复杂背景及多种病害共存情况下的识别能力,设计了多尺度增强并行注意力(MSEPA)模块。该模块融合多尺度特征提取与并行注意力机制,兼顾全局感受野与局部细节响应,从而增强模型对病斑形态、纹理及空间分布差异的特征学习能力,有效提升模型对多类病害的识别精度。

1.2.3 Windmill convolution 模块 在玉米叶片病害图像中,病斑通常呈现一定程度的中心对称性,且区域内纹理与颜色具有方向一致性。病斑的边界形态直接影响检测框的宽度和高度,而病斑的几何中心则决定了标注框的中心坐标 $(x,y)$ 。因此,病斑边缘轮廓与中心位置对于目标定位与识别至关重要。Yang 等<sup>[16]</sup>提出风车状卷积(Pinwheel-shaped convolution)模块,旨在通过风车状卷积结构缓解传统卷积感受野有限与方向敏感性不足的问题。然而,该模块在结构设计中未能充分突出卷积中心在特征聚焦与空间定位中的作用,限制了其在目标边界对齐

任务中的性能。基于此,本研究提出改进的风车状方向卷积模块,结构如图 2 所示。该模块在保留多方向感受野布局的基础上,增强了对中心区域特征的建模能力,从而显著提升了模型对病斑空间结构、边缘轮廓和细节纹理的感知与表达能力,为病害区域的精确检测提供了更优的卷积基础。

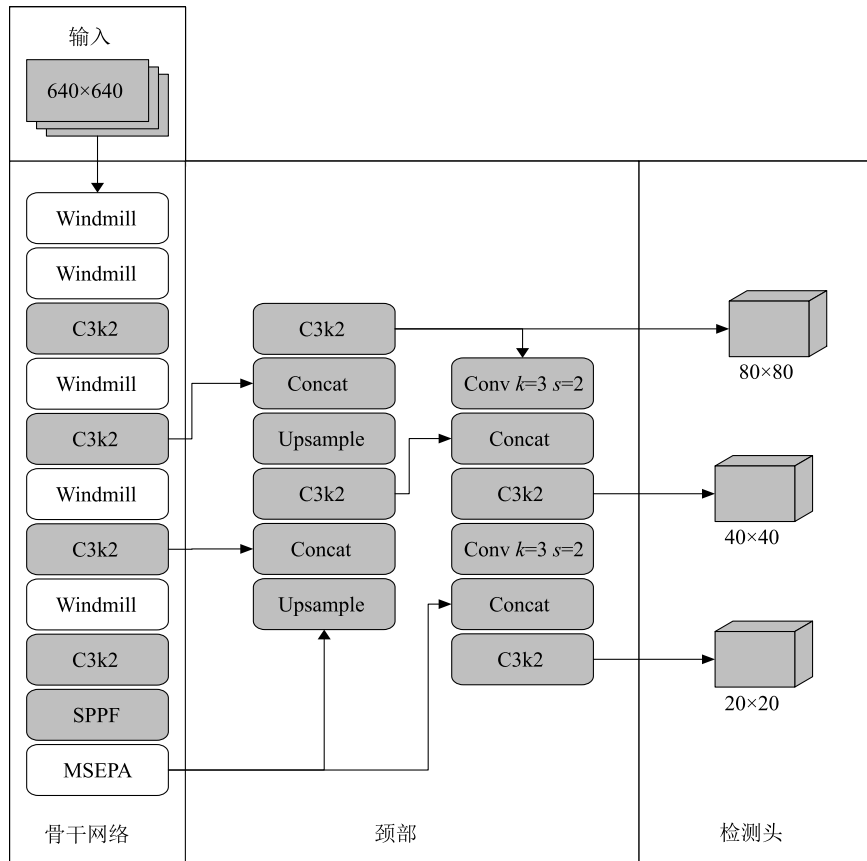
Windmill convolution 模块运行过程如下:

第一步,边缘特征获取。首先对输入特征图 $X \in R^{B \times C \times H \times W}$ ( $R$ 为实数集, $B$ 为批次大小, $C$ 为通道数, $H$ 为高度, $W$ 为宽度)分别施加 4 种非对称填充方式,分别为左-上(3,1)、上-右(1,3)、右-下(3,1)、下-左(1,3)。随后采用 2 个共享卷积模块提取水平和垂直方向特征,得到 4 路输出特征 $Y_{u0}$ 、 $Y_{u1}$ 、 $Y_{h0}$ 、 $Y_{h1}$ ,并拼接成风车状方向特征图。

第二步,特征融合与增强。拼接后的特征图经 1 个卷积层进一步提取方向特征。为保留原始特征的表达能,设计 1 条下采样通道:对输入特征  $X$  进行  $2 \times 2$  卷积操作,形成残差路径特征  $X'$ 。将融合特征与残差通道特征拼接,输入至 1 个  $3 \times 3$  卷积中完成整体特征输出。Windmill convolution 模块的整体输出表达式为:

$$Y = \text{Con}_{v_{3 \times 3}} \{ \text{Concat} [ \text{Cat} ( Y_{u0}, Y_{u1}, Y_{h0}, Y_{h1} ), X' ] \}$$

式中, $\text{Con}_{v_{3 \times 3}}$ : $3 \times 3$  卷积操作;Concat:通道拼接;Cat: $Y_{u0}$ 、 $Y_{u1}$ 、 $Y_{h0}$ 、 $Y_{h1}$  特征集合。



Windmill:风车状方向卷积;C3k2:特征提取模块;SPPF:空间金字塔池化模块;MSEPA:多尺度增强并行注意力模块;Conv:卷积; $k$ :卷积核尺寸; $s$ :步长;Concat:特征融合模块;Upsample:上采样。

图1 WPM-YOLO11 模型结构

Fig.1 Architecture of the WPM-YOLO11 model

1.2.4 MSEPA 模块 在玉米叶片病害识别任务中,不同病害类型的形态特征存在显著差异,给模型的特征提取与病害区域聚焦带来挑战。针对该问题,本研究基于 MixDehazeNet 中增强并行注意力机制(EPA)模块的设计思路<sup>[17]</sup>,设计了 MSEPA 模块,以增强网络对多尺度结构特征与空间显著区域的表达能力,其结构如图3所示。

MSEPA 模块的运行过程如下:

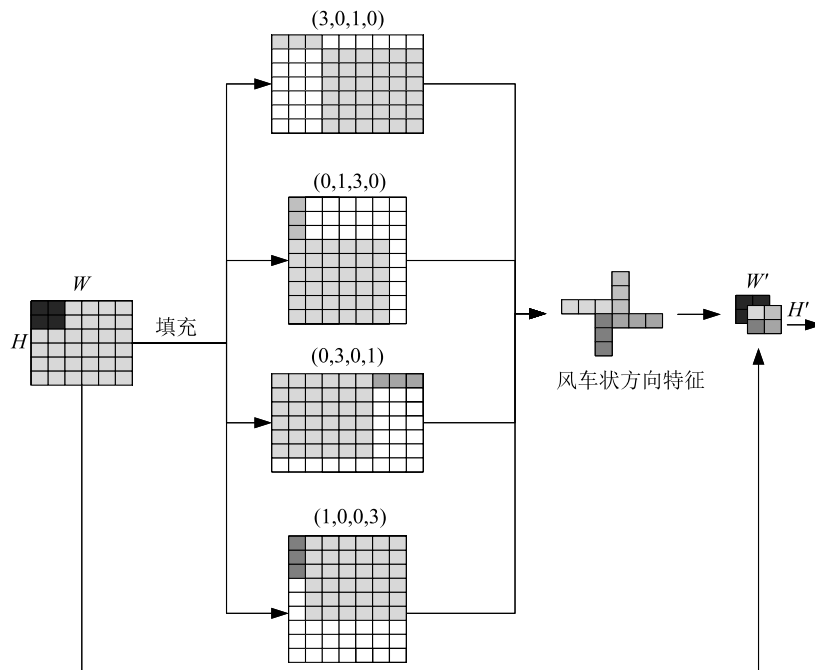
第一步为多尺度卷积特征提取。输入特征图经批量归一化处理,依次通过 $1 \times 1$ 卷积与 $5 \times 5$ 卷积进行通道维度调整和初步特征融合。随后构建3组并行的深度可分离卷积模块,分别为  $DWConv1(x)$ ,  $DWConv7(x)$ ,  $DWConv13(x)$ ,将其输出特征在通道维度拼接后,输入至多层感知机(MLP)网络进行特征压缩与融合,得到第一阶段输出特征  $X'$ ,表达式为:

$$X' = X + \text{MLP} \{ \text{Cat} [ DWConv1(x), DWConv7(x), DWConv13(x) ] \}$$

第二步为并行注意力融合增强。如图4所示,在上述融合特征基础上,模型引入了像素注意力、通道注意力与简单像素注意力3种并行注意力机制。其中,像素注意力模块通过非线性映射生成像素级位置敏感性权重图  $PA(x)$ ,增强模型对病斑区域的定位能力,输出记为  $F_p = PA(x) \odot x$ 。通道注意力模块采用高效通道注意力机制(ECA)模块提取通道维度上的全局重要特征,突出不同通道对特定病害类型的表征差异,输出记为  $F_c = CA(x) \odot x$ 。简单像素注意力模块由局部卷积通路  $Wv(x)$ 与全局门控通路  $Wg(x)$ 构成,可突出病斑的局部显著纹理特征,适配边缘清晰的病害目标,输出记为  $F_s = Wv(x) \odot Wg(x)$ 。将上述3种注意力机制的输出在通道维度上进行拼接,随后通过第2个多层感知机进行特征压缩与融合,得到最终增强后的特征输出:

$$Y = X' + \text{MLP} [ \text{Cat} ( F_s, F_c, F_p ) ]$$

该模块能够有效结合局部纹理信息与全局空间



$W'$ 、 $W$ :宽度; $H'$ 、 $H$ :高度。

图2 风车状方向卷积模块结构

Fig.2 Structure of the windmill convolution module

语义,提升模型对病斑大小、形态及其空间分布的判别能力,显著增强模型在尺度多变、边界模糊的病害识别任务中的鲁棒性。

### 1.3 试验平台与参数设置

模型训练在 Windows 11 操作系统下完成。硬件配置为: AMD Ryzen 95900HX 处理器(搭载 Radeon Graphics 显卡,主频 3.30 GHz), 32 GB 内存, NVIDIA GeForce RTX 3080 Laptop 显卡(显存 16 GB)。软件环境为: CUDA 11.8, Python 3.7.16, PyTorch 1.13.1 深度学习框架。试验参数设置如下: 输入图像分辨率为  $640 \times 640$  像素, 批量大小为 16, 初始学习率为 0.01, 采用随机梯度下降(SGD)优化器, 动量参数为 0.937, 权重衰减系数为 0.005。

### 1.4 模型评价指标

为客观评价模型性能,本研究选取目标检测领域通用指标进行综合评估,包括精确率、召回率、交并比阈值为 0.50 的平均精度均值( $mAP_{50}$ )、交并比阈值为 0.50~0.90 的平均精度均值( $mAP_{50:95}$ )、参数量以及浮点运算量等。

## 2 结果与分析

### 2.1 模型训练


如图 5 所示,训练前 50 轮内,各指标数值快速

上升,此后趋于平稳,表明模型拟合良好、收敛稳定。

如图 6 所示,模型对多数病斑目标检测准确,但在图像边界及叶片边缘区域,因受病斑形态模糊、形状不规则等因素影响,仍存在漏检现象。综上,模型训练的收敛特性与可视化检测结果相符,表明其具备较好的检测能力。

### 2.2 不同深度学习模型对玉米病害检测性能的对比

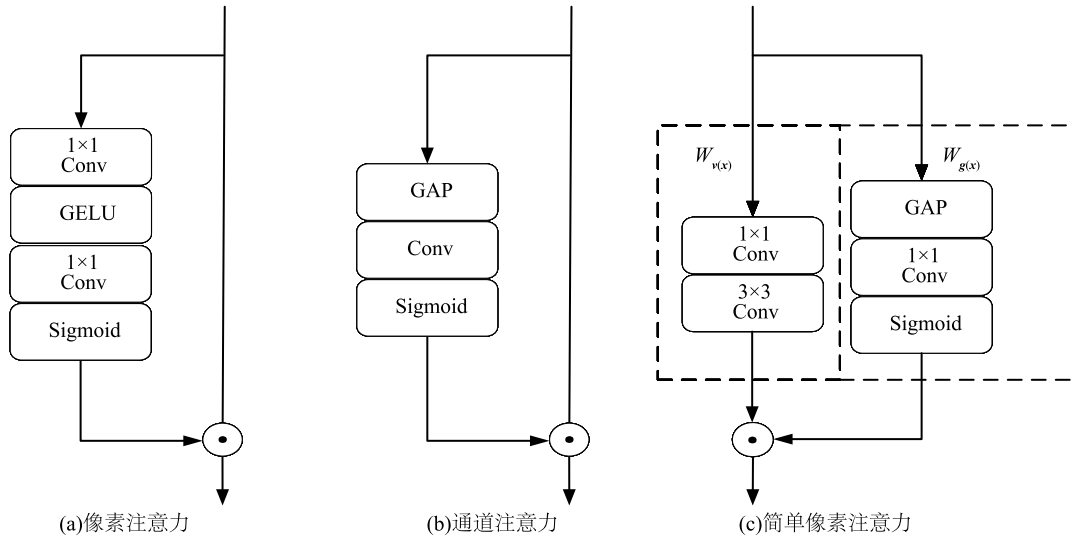
为评估 WPM-YOLO11 模型性能,将其与 Faster R-CNN、RT-DETR 及 YOLO-SDW 等模型在玉米叶片病斑检测任务中的表现进行对比分析。如表 4 所示, Faster R-CNN<sup>[18]</sup> 作为双阶段检测算法,在任务中检测精度较低。RT-DETR<sup>[19]</sup> 基于 Transformer 结构,检测性能优于 Faster R-CNN,但其网络结构复杂、参数量大,训练与部署成本较高。YOLO-SDW<sup>[20]</sup> 作为轻量化改进模型,参数量和浮点运算量较小,但其  $mAP_{50:95}$  与 RT-DETR 相当,表明对小目标病斑与复杂纹理特征的提取能力有限。本研究构建的 WPM-YOLO11 模型各项指标综合表现最好,在保持较高检测精度的同时兼具良好的鲁棒性,具备实际应用潜力。



Conv:卷积;Batch Norm:批量归一化;DWConv:深度可分离卷积;GELU:激活函数;⊕:Concat 模块(特征融合模块);⊕:逐元素加法。

图3 MSEPA 模块结构


Fig.3 Structure of the MSEPA module



Conv:卷积;GELU:激活函数;Sigmoid:激活函数;GAP:全局平均池化;⊙:对应元素乘法;\$W\_{v(x)}\$:局部卷积通路;\$W\_{g(x)}\$:全局门控通路。

图4 像素注意力机制、通道注意力机制和简单像素注意力机制

Fig.4 Pixel attention mechanism, channel attention mechanism and simple pixel attention mechanism



$mAP_{50}$ :交并比阈值为 0.50 时的平均精度均值。

图5 WPM-YOLO11 模型精确率、召回率与交并比阈值为 0.50 的平均精度均值 ( $mAP_{50}$ ) 指标变化曲线

Fig.5 Variation curves of precision, recall, and the mean average precision at an intersection over union threshold ( $mAP_{50}$ ) for the WPM-YOLO11 model

### 2.3 Windmill convolution 模块与 MSEPA 模块的性能检测

本研究设置消融试验验证 Windmill convolution 模块与 MSEPA 模块的有效性。如表 5 所示,与

YOLOv11m 模型相比,YOLOv11m+Windmill convolution 模型  $mAP_{50}$ 、 $mAP_{50:95}$  分别提高 0.3 个百分点和 0.6 个百分点,精确率与召回率分别提高 0.1 个百分点和 0.6 个百分点,表明该模块对小目标及边缘




图 6 WPM-YOLO11 模型对玉米病害实际检测结果

Fig.6 Practical detection results of the WPM-YOLO11 model for maize diseases

表 4 不同深度学习模型对玉米病害的检测性能对比

Table 4 Comparison of detection performance of different deep learning models for maize diseases

模型名称	精确率 (%)	召回率 (%)	$mAP_{50}$ (%)	$mAP_{50:95}$ (%)	网络层数	参数量 (M)	浮点运算量 (G)
Faster R-CNN	49.4	70.3	63.9	31.3	40	136.90	402.0
RT-DETR	82.1	80.5	84.7	51.7	681	32.97	108.3
YOLO-SDW	78.5	80.0	83.6	51.7	327	42.90	47.2
WPM-YOLO11	91.5	90.8	93.7	78.5	367	45.86	151.8

$mAP_{50}$ : 交并比阈值为 0.50 的平均精度均值;  $mAP_{50:95}$ : 交并比阈值为 0.50~0.90 的平均精度均值。

特征提取具有增强作用。与 YOLOv11m 模型相比, YOLOv11m+MSEPA 模型  $mAP_{50}$  与  $mAP_{50:95}$  分别提高 1.5 个百分点和 2.6 个百分点, 精确率与召回率分别提高 0.4 个百分点和 2.4 个百分点, 表明该模块有效提升了模型对多尺度与纹理特征的表达能力, 且计算效率较高。同时引入 Windmill convolution 模块和 MSEPA 模块的 WPM-YOLO11 模型性能最佳, 与 YOLOv11m 模型相比, WPM-YOLO11

模型  $mAP_{50}$ 、 $mAP_{50:95}$  分别提高 3.9 个百分点和 12.2 个百分点, 精确率与召回率分别提高 6.3 个百分点和 4.7 个百分点。虽然 WPM-YOLO11 模型参数量与浮点运算量较大, 但综合考虑模型性能, 其计算量在可接受范围内。综上, Windmill convolution 与 MSEPA 模块在特征提取和空间感知方面具有互补性, 二者协同可显著提升模型检测精度与鲁棒性。

表 5 消融试验结果

Table 5 Ablation experiment results

模型名称	精确率 (%)	召回率 (%)	$mAP_{50}$ (%)	$mAP_{50:95}$ (%)	网络层数	参数量 (M)	浮点运算量 (G)
YOLOv11m	85.2	86.1	89.8	66.3	409	20.11	68.5
YOLOv11m+Windmill convolution	85.3	86.7	90.1	66.9	365	31.11	147.0
YOLOv11m+MSEPA	85.6	88.5	91.3	68.9	321	34.58	78.0
YOLOv11m+Windmill convolution+MSEPA	91.5	90.8	93.7	78.5	367	45.86	151.8

Windmill convolution: 风车状方向卷积; MSEPA: 多尺度增强并行注意力;  $mAP_{50}$ : 交并阈值为 0.50 的平均精度均值;  $mAP_{50:95}$ : 交并阈值为 0.50~0.90 的平均精度均值。

## 2.4 YOLOv11m 模型与 WPM-YOLO11 模型对玉米各种病害检测性能对比

如表 6 所示, WPM-YOLO11 模型对多数玉米病害的检测精度均有提升。针对边缘不规则的褐斑病, 与 YOLOv11m 模型相比, WPM-YOLO11 模型  $mAP_{50:95}$  提升 22.5 个百分点, 表明 Windmill convolution 模块增强了边缘与纹理特征提取能力。对于边缘清晰、斑块分散的普通锈病, 与 YOLOv11m 模型相比, WPM-YOLO11 模型  $mAP_{50:95}$  提高 11.7 个百分点, 表明 MSEPA 模块有效增强了空间与上下文特征建模能力。对于健康叶片, 与 YOLOv11m 模型相比, WPM-YOLO11 模型  $mAP_{50}$ 、 $mAP_{50:95}$  分别提

高 3.1 个百分点和 10.6 个百分点。对于病斑特征复杂的花叶病、灰斑病和北方枯叶病, 与 YOLOv11m 模型相比, WPM-YOLO11 模型各项性能指标均显著提升。花叶病在玉米叶片上呈密集条带状斑纹, 与 YOLOv11m 模型相比, WPM-YOLO11 模型  $mAP_{50:95}$  提升 16.2 个百分点, 表明模型对连续性特征与纵向结构感知能力增强。对于纹理清晰的灰斑病与病斑较大的北方枯叶病, 与 YOLOv11m 模型相比, WPM-YOLO11 模型  $mAP_{50:95}$  分别提升 10.8 个百分点和 9.6 个百分点。对于病斑密集的南方锈病, 与 YOLOv11m 模型相比, WPM-YOLO11 模型  $mAP_{50:95}$  提高 5.0 个百分点。

表 6 YOLOv11m 模型与 WPM-YOLO11 模型对各玉米各种病害检测性能对比

Table 6 Comparison of detection performance between YOLOv11m and WPM-YOLO11 models for each maize disease

类别	模型	精确率 (%)	召回率 (%)	$mAP_{50}$ (%)	$mAP_{50:95}$ (%)
褐斑病	YOLOv11m	81.5	82.8	83.8	50.6
	WPM-YOLO11	91.1	89.3	93.4	73.1
普通锈病	YOLOv11m	85.1	87.1	92.9	80.2
	WPM-YOLO11	94.6	94.6	96.8	91.9
南方锈病	YOLOv11m	85.5	78.3	86.6	54.5
	WPM-YOLO11	80.6	83.6	88.8	59.5
花叶病	YOLOv11m	81.9	84.1	86.8	61.8
	WPM-YOLO11	91.7	91.7	92.8	78.0
北方枯叶病	YOLOv11m	92.5	94.7	95.4	84.3
	WPM-YOLO11	96.4	95.5	97.4	93.9
灰斑病	YOLOv11m	86.0	86.2	91.3	65.3
	WPM-YOLO11	92.6	88.3	93.2	76.1
圆斑病	YOLOv11m	83.4	83.3	85.2	50.1
	WPM-YOLO11	87.6	85.3	87.7	60.8
健康	YOLOv11m	85.5	92.0	96.0	83.8
	WPM-YOLO11	97.6	98.1	99.1	94.4
全部	YOLOv11m	85.2	86.1	89.8	66.3
	WPM-YOLO11	91.5	90.8	93.7	78.5

$mAP_{50}$ : 交并阈值为 0.50 的平均精度均值;  $mAP_{50:95}$ : 交并阈值为 0.50~0.90 的平均精度均值。

综上,WPM-YOLO11在提升总体检测精度的同时,对边缘模糊、结构不规则、分布细碎等复杂病害类别表现出更强的判别与特征表达能力。

### 3 讨论

集成 Windmill convolution 与 MSEPA 模块后,WPM-YOLO11 模型检测精度、边界感知及多尺度建模能力均得到系统性提升。Windmill convolution 模块增强了对病斑边缘轮廓、小目标结构及方向变化的感知能力,对边界模糊、斑点密集类病害的检测效果改善显著。MSEPA 模块融合多尺度特征通路与三重并行注意力机制,从通道、空间及位置 3 个维度对特征图加权调整,提升了模型对病斑尺度不一、纹理复杂、位置分散等情况的鲁棒性,对具有大尺度条纹或细长形态的病害识别效果突出。尽管 WPM-YOLO11 模型表现良好,但对于南方锈病等极端密集目标的检测效果仍有待优化。未来研究可从以下 2 个方面对模型进一步改进:一是模型轻量化,在保持精度的同时降低参数量与浮点运算量,提升部署效率;二是数据集多样化,通过构建涵盖不同光照、背景干扰的田间数据集,提升模型在实际应用中的适应性。

#### 参考文献:

- [1] 刘杰,卞悦,张熠场,等. 2025 年全国主要农作物重大病虫害发生趋势及其原因分析[J]. 中国植保导刊,2025,45(2):26-29,44.
- [2] 翟肇裕,曹益飞,徐焕良,等. 农作物病虫害识别关键技术研究综述[J]. 农业机械学报,2021,52(7):1-18.
- [3] 周善良,李锐. 基于卷积神经网络的农作物病虫害识别研究综述[J]. 智慧农业导刊,2024,4(17):39-45.
- [4] 谭智峰,贺志磊,张磊,等. 深度学习技术在农作物病虫害识别中的应用综述[J]. 河北农业,2024(1):30-32.
- [5] 张正风,陶佩林. AlexNet-SVM 混合模型对番茄叶部病害的有效诊断[J]. 现代农业科技,2025(9):170-172,178.
- [6] 彭慧琳,李东晖,陈兆中,等. 基于改进 GoogLeNet 的水稻苗期稻瘟病分级检测[J]. 农业工程学报,2025,41(10):204-211.
- [7] 裴文杰,刘拥民,胡魁,等. 面向复杂背景的 CFFA—ResNet 苹果叶片病害识别模型构建[J]. 中国农机化学报,2025,46(6):169-175.
- [8] 王浩宇,胡玉荣,崔艳荣,等. 基于改进 MobileNet v3-small 模型

的苹果叶片病害识别方法[J]. 江苏农业科学,2025,53(5):113-120.

- [9] 陈黎韦,古丽娜孜·艾力木江,伊力亚尔·加尔木哈买提. 基于频域 Swin Transformer 的植物叶片病害识别研究[J]. 中国农机化学报,2025,46(10):128-137.
- [10] TIMILSINA S, SHARMA S, KONDO S. Advancements in maize leaf disease detection, segmentation and classification: a review[J]. Biosystems Engineering,2025,255:104162.
- [11] MENG Y, ZHAN J W, LI K S, et al. A rapid and precise algorithm for maize leaf disease detection based on YOLO MSM[J]. Scientific Reports,2025,15(1):6016.
- [12] LI R J, LI Y D, QIN W B, et al. Lightweight network for corn leaf disease identification based on improved YOLO v8s[J]. Agriculture,2024,14(2):220.
- [13] NAKATUMBA-NABENDE J, MURINDANYI S. Deep learning models for enhanced in-field maize leaf disease diagnosis[J]. Machine Learning with Applications,2025,20:100673.
- [14] AHMAD A, SARASWAT D, GAMAL A E, et al. CD&S dataset: handheld imagery dataset acquired under field conditions for corn disease identification and severity estimation[EB/OL]. (2021-10-22)[2025-03-21]. <https://doi.org/10.48550/arXiv.2110.12084>.
- [15] CHEN R L, ZHOU H B, XIE H, et al. YOLO-CE:an underwater low-visibility environment target detection algorithm based on YOLO11[J]. The Journal of Supercomputing,2025,81(5):723.
- [16] YANG J N, LIU S L, WU J J, et al. Pinwheel-shaped convolution and scale-based dynamic loss for infrared small target detection[J]. Proceedings of the AAAI Conference on Artificial Intelligence,2025,39(9):9202-9210.
- [17] LU L P, XIONG Q, XU B R, et al. MixDehazeNet:mix structure block for image dehazing network[C]//IEEE. Proceedings of the 2024 International Joint Conference on Neural Networks (IJCNN). Yokohama:IEEE,2024.
- [18] REN S, HE K, GIRSHICK R, et al. Faster R-CNN:towards real-time object detection with region proposal networks[C]//Neural Information Processing Systems Foundation. Advances in Neural Information Processing Systems (NeurIPS 2015). New York:Curran Associates, Inc., 2015.
- [19] ZHAO Y, LYU W Y, XU S L, et al. DETRs beat YOLOs on real-time object detection[C]//IEEE/CVF. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2024). Washington:IEEE, 2024.
- [20] YANG H, SHENG S Y, JIANG F, et al. YOLO-SDW:a method for detecting infection in corn leaves[J]. Energy Reports,2024,12:6102-6111.

(责任编辑:成纾寒)