面向小麦病害的轻量化 TLeaf-YOLOv8 检测算法

张渝曼， 裴树军
（哈尔滨理工大学 计算机科学与技术学院，哈尔滨 150080）

摘 要：针对因小麦叶片病害识别精度不高而出现的漏检和错检等问题，提出一种 TLeaf-YOLOv8 算法来检测小麦叶片病害。首先，在主干网络中使用设计的 RCS-OSA 模块代替 C2f 模块，通过重参数化卷积增强模型对叶片病害的特征提取能力。然后，在颈部设计了一种灵活卷积 AKConv 替换标准 Conv，可根据不同的数据集和目标灵活调整卷积核的大小和形状，在保证检测精度的同时有效降低了模型的参数量。最后，通过添加小目标检测层，减少小目标常出现的漏检或检测效果不佳的情况，同时引入 LSKA 注意力机制，避免小目标特征消失在冗余信息中。在数据集 WheatLeafNet 上进行模型验证，结果表明：改进模型（TLeaf-YOLOv8）的 $\alpha_{mAP0.5}$ 比原模型提高 1.9 个百分点；模型参数量及模型大小相较于原始网络模型分别有所降低，在提高检测精度的同时达到了轻量化的目标。

关键词：叶片病害；小目标检测；YOLOv8；RCS-OSA；可变核卷积
DOI：10.15938/j.jhust.2026.04.007
中图分类号：TP391.4 **文献标志码**：A **文章编号**：1007-2683(2026)04-0069-13

TLeaf-YOLOv8 Detection Algorithm for Wheat Disease

ZHANG Yuman， PEI Shujun
（School of Computer Science and Technology, Harbin University of Science and Technology, Harbin 150080, China）

Abstract: To address the issues of low accuracy in wheat leaf disease identification, such as missed and false detections, a TLeaf-YOLOv8 algorithm is proposed for detecting wheat leaf diseases. Firstly, the RCS-OSA module is introduced to replace the C2f module in the backbone network, enhancing feature extraction for leaf diseases through reparameterized convolution. Then, a flexible convolution AKConv is designed in the neck, which can adjust the size and shape of convolution kernels flexibly according to different datasets and targets, ensuring detection accuracy while effectively reducing the model's parameter volume. Finally, a small target detection layer is added to address the frequent missed detections or poor detection effects of small targets, and the LSKA attention mechanism is introduced to prevent the disappearance of small target features in redundant information. The model is validated on the self-made dataset WheatLeafNet, and the results show that the mAP@0.5% of the improved model (TLeaf-YOLOv8) is 1.9 percentage points higher than that of the original model; the model parameter volume and model size are reduced by 0.3G and 1.1MB respectively compared to the original network model. While improving detection accuracy, the goal of lightweighting is achieved.

Keywords: leaf disease; small target detection; YOLOv8; RCS-OSA; variable kernel convolution

收稿日期：2024-09-05
基金项目：国家自然科学基金(60572153)；黑龙江省教育厅计划项目(11541040).
作者简介：张渝曼(2001—)，女，硕士研究生.
通信作者：裴树军(1969—)，男，教授，硕士研究生导师，E-mail：peisj@sina.com.

0 引 言

随着现代农业技术的快速发展,作物生长状态的实时监测和精准管理成为提高作物产量和质量的关键[1]。小麦作为全球重要的粮食作物之一,其生长监测、产量预测及田间管理优化具有重要意义[2]。小麦在生长过程中容易受到多种病害的侵袭,如叶锈病、白粉病和锈病等,这些病害不仅影响小麦的生长,还会显著降低产量和品质,甚至在严重情况下导致绝收[3]。

随着科技的发展,小麦病害检测与防治越来越趋向于规模化和智能化,深度学习技术已在目标检测领域被广泛应用[4]。与传统的目标检测算法相比,深度卷积神经网络(convolutional neural network, CNN)具有强大的特征学习能力,可从海量的训练数据中自主挖掘多层次的特征表达[5-6]。这种技术可以解放劳动力、准确识别,为农业叶片病害治理提供有效且迅捷的帮助。因此,利用计算机视觉技术对小麦病害进行识别,对提高小麦农田的生产力具有非常重要的意义[7]。基于卷积神经网络的目标检测算法主要分为两类:一类是两阶段检测算法R-CNN(region-based convolutional neural network)和Faster R-CNN(faster region-based convolutional neural network)[8-9]。两阶段检测算法包括2个步骤:第一阶段生成候选区域,选择潜在的物体位置;第二阶段对这些候选区域进行分类和边界框回归,精确定位并识别物体类别。另一类是单阶段检测算法YOLO(you only look once)和SSD(single shot detector),通过直接在输入图像上同时进行物体定位和分类[10-16],大幅简化了检测过程。相比于两阶段检测算法,单阶段算法速度更快,但通常在检测小物体或处理复杂背景时精度较低。例如,TANG 等[17]提出了使用PLPNet的基于图像的精确番茄叶病检测方法,使用了可切换空洞卷积和反卷积的邻近特征聚合网络,该网络解决了疾病类间相似性的问题。实验结果表明:PLPNet在自建数据集上平均精度达到了94.5%。李超炜等[18]通过添加SE-ResNet模块,改进SPP层的网络结构来改进传统的YOLOv5网络,实验结果表明:SER-DC YOLO比YOLOv5模型在精度上提高了3.52%,平均精度均值提高了7.19%。DEB 等[19]提出名为LC-Net的新型CNN模型,结合叶片局部特征和全局图像信息,在公开测试集上的叶片计数精确率优于现有技术。YIGIT 等[20]利用神经网络和支持向量机(support vector machine, SVM)设计了一种植物叶片的自动识别器,SVM模型识别准确率为92.91%。MADEC 等[21]利用无人机和深度学习技术,对大田小麦病害进行大规模监测,展示了高效的实时检测能力。但是深度学习模型对大量高质量标注数据的依赖性较强,获取这些数据的成本较高。

为提升多变田间环境下小麦叶片多病害共存场景的检测精度与检测效率,本研究采用了YOLOv8模型,以更高的检测精度、更少的参数和更小巧的模型尺寸为特点。对YOLOv8算法进行改进,主要贡献有以下几点:

1)利用可变核卷积AKConv替换颈部网络中的部分标准卷积,允许卷积核具有任意数量的参数和采样形状;突破了传统卷积局限于固定局部窗口和固定采样形状的限制,使卷积操作可更加精准地适应不同数据集和不同位置的目标。

2)在主干网络中使用设计的RCS-OSA模块代替C2f模块,通过重参数化卷积来增强模型对叶片病害的特征提取能力,并进行多层次的特征融合,有助于捕获丰富的语义信息。

3)引入LSKA注意力机制,在不需要显著增加模型的参数量和计算开销的同时,避免小目标特征消失在冗余信息中,降低模型过拟合的风险。

4)小目标常出现漏检或检测效果不佳的问题,通过添加小目标检测层,可以更精确地捕捉目标的边缘和细节信息,从而提高检测的精度。

1 相关工作

1.1 YOLOv8算法的应用

YOLOv8的核心思想是在单个神经网络中实现目标的定位和分类,从而大大提高了检测速度和实时性。与其他目标检测算法相比,YOLOv8在处理高分辨率图像和小目标检测方面具有显著优势,这对于小麦病害检测来说尤为重要。小麦病害通常表现为叶片上的小斑点或变色区域,这些病变区域在图像中往往占据较小的比例,处理这类小目标容易出现漏检或误检的情况。YOLOv8的模型结构包括骨干网络(Backbone)、颈部网络(Neck)和检测头(Head)。骨干网络通过引入残差连接和密集连接,增强了特征表示能力。残差连接的引入使得深层网

络的训练变得更加容易,解决了深层网络中的梯度消失问题。密集连接在每一层都连接到前面所有层的输出,进一步加强了特征的传递和复用。在卷积层和池化层的设计上也进行了优化,采用了更多的 3×3 卷积核和较小的池化步长,保持了高分辨率的特征图,同时减少了计算复杂度。颈部网络通常包括特征金字塔网络(feature pyramid network,FPN)和路径聚合网络(path aggregation network,PAN)。FPN 通过自上而下的路径,将高层语义特征逐级融合到低层特征中,增强了多尺度目标的检测能力。而 PAN 则通过自下而上的路径,进一步加强特征融合,使得不同层级的特征互相补充,提升了特征表达的丰富度和准确性。头部网络是进行目标检测的最终阶段,它的主要作用是接收来自颈部网络的多尺度特征,并生成目标分类和定位的最终输出。YOLOv8 的头部网络通常由多个卷积层和输出层组成,这些层根据不同的特征层进行处理,以预测每个特征图上的边界框、类别概率和目标置信度。

在农业作物病害轻量化检测研究领域,针对主流模型在端侧部署中精度和效率失衡的问题,已有学者围绕 YOLO 系列基础模型展开优化探索。如邓伟豪等[22]提出基于 YOLOv8n 的 Lighter-Faster-YOLO算法,该算法采用 DSPConv 替换 C2f 模块内的标准卷积以减少特征冗余,使用 EMA 模块替换 SPPF前的 C2f 模块提升模型性能,并通过 HS-FPN 重构颈部网络,强化多尺度特征融合。在葡萄叶片病害检测任务中,该算法性能较优,参数量与计算量较 YOLOv8n 分别降低 66.34%、35.80%,且优于 Faster R-CNN 等主流算法,更易端侧部署。但该算法存在局限性,模块通用性与可解释性不足,未验证跨作物病害适配性,实验仅针对葡萄病害,缺乏复杂场景鲁棒性测试,端侧部署的推理速度、功耗等实测指标也未明确,虽为农业轻量化检测提供思路,但仍需进一步完善。

1.2　小目标检测

在农业叶片病害检测场景中,小目标检测特指针对早期病害斑点、微小病斑或稀疏分布的病害区域的识别任务,这类病害目标通常仅占叶片图像总面积的 0.1% 至 5%,尺寸多在 10×10 至 32×32 像素之间,比如小麦早期锈病孢子堆、葡萄霜霉病初期小点状病斑,这类微小病灶的精准识别是实现叶片病害早发现、早防治的关键技术支撑。

这类小目标病害存在显著的检测难点,一方面,早期病斑纹理简单,颜色与健康叶片差异微弱,自身判别性特征稀疏。在卷积神经网络的下采样过程中,浅层提取的边缘、纹理特征易丢失,深层特征图中病斑特征更趋模糊,模型难以捕捉有效信息;另一方面,叶片表面的脉络纹理、绒毛,或田间拍摄时的杂草阴影、土壤反光等背景干扰,与小尺度病斑在特征维度高度相似,易造成误检或漏检。例如,小麦叶片的细脉络与早期叶斑病斑点,在低分辨率特征图中易被模型混淆。

为解决叶片病害小目标检测难题,现有研究多结合农业场景特性优化方案。在网络结构上,YE 等[23]通过设计浅层特征强化模块,比如保留高分辨率浅层特征并与深层特征融合,避免病斑细节信息丢失。在数据处理上,ZHAN 等[24]针对小目标病斑设计局部裁剪增强,从原始叶片图像中裁剪包含病斑的局部区域并放大,提升小目标在训练样本中的占比。在注意力机制应用上,杨锋等[25]引入病斑区域引导注意力,通过叶片形态先验,比如叶片边缘、脉络分布约束注意力权重,使模型优先聚焦可能存在小病斑的区域,减少背景干扰。这些优化方向不仅能提升早期小尺度病害的检测精度,更能为作物病害的预防性治理提供技术支持,降低病害扩散带来的产量损失。

2　YOLOv8 算法改进策略

为了提升小麦叶片病害的识别精度和技术效率,本文引入基于 TLeaf-YOLOv8 的小麦病害检测模型,网络结构如图 1 所示。

主要改进如下:引入 AKConv 轻量级网络架构,可根据不同的数据集和目标灵活调整卷积核的大小和形状,在保证检测精度的同时有效降低了模型的参数量;设计全新模块 RCS-OSA(RCS-one shot aggregation)来提高网络在处理密集连接时的效率;引入 LSKA 注意力机制,不需要显著增加模型的参数量和计算开销,使模型能够提取更丰富的叶片病害特征信息;小麦叶片病害多为小目标,增加小目标检测层,提升对小目标的检测能力。在 TLeaf-YOLOv8 模型中,AKConv、RCS-OSA 与 LSKA 模块通过顺序堆叠和跨层增强的协同机制实现高效特征处理。在骨干网络 Backbone 中,经 Conv 模块完成基础特征提取后,RCS-OSA 模块与 AKConv 模块依次堆叠形成递进式特征提取链路。其中,RCS-OSA 模块凭借

通道混洗与重参数化技术,在降低计算开销的同时,完整保留小麦病害的细粒度特征。AKConv 模块则对其输出的特征图进行自适应尺度特征提取,显著增强不同大小病害的特征区分度。与此同时,LSKA 模块以跨层增强的方式嵌入 Backbone 末端,通过大核可分离卷积捕捉病害区域与背景的长距离依赖关系,对病害特征进行加权强化,有效抑制土壤、杂草等背景干扰。经多模块协同处理的特征图最终分流至各尺度检测层,为多尺度小麦病害检测提供了层次丰富、辨识度高的特征支撑。

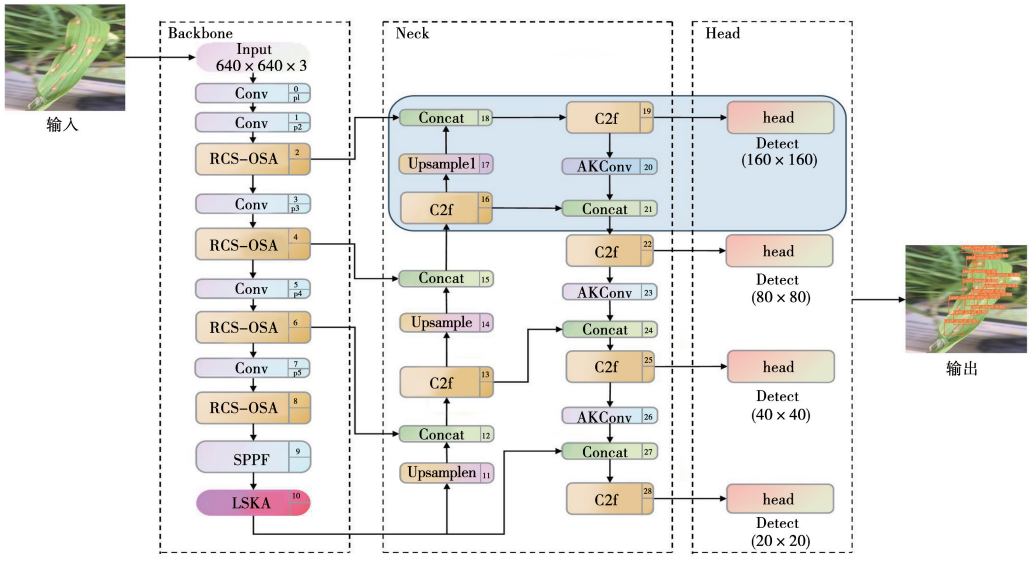

图 1 TLeaf-YOLOv8 模型结构

Fig. 1 Model structure of TLeaf-YOLOv8

2.1 AkConv 轻量级网络架构

可变核卷积(alterable kernel convolution, AKConv)主要提供一种灵活的卷积机制,允许卷积核具有任意数量的参数,使得其可以根据实际需求调整大小和形状,从而更有效地适应目标变化。图 2 为 AkConv 设计核心,由图可见,输入图像具有维度(C,H,W),其中 C 为通道数,H 和 W 分别为图像的高度和宽度,N 为卷积核大小。接下来,给出了卷积核的初始采样形状,这一步是 AKConv 特有的,然后使用 Conv2d 对输入图像执行卷积操作,通过学习得到的偏移量来调整初始采样形状,允许卷积核形状动态调整以适应图像的特征。之后,根据调整后的采样形状对特征图进行重采样,重采样后的特征图经过重塑、再次卷积、标准化,最后通过激活函数 SiLU输出最终结果。

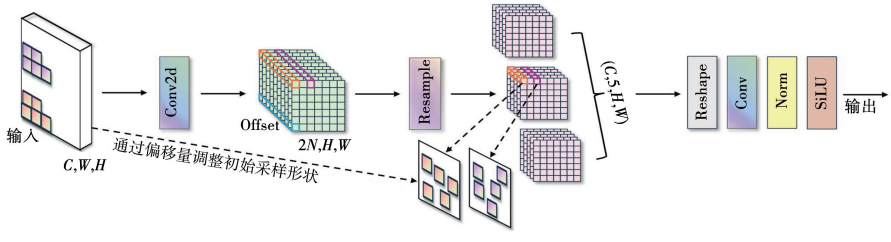

图 2 AkConv 设计核心

Fig. 2 The design core of AKConv

AKConv 中的灵活卷积核设计是 1 种创新的机制,旨在使卷积网络更加具有适应性和效率性。传统的卷积核通常具有固定的尺寸和形状,例如 3 ×3 或 5 ×5 的方形网格,而 AKConv 的核心原理是允许卷积核具有任意数量的参数。处理不同的图像和目标时,AKConv 的卷积核可自动调整其采样形状,通过引入新的坐标生成算法实现。该算法可为不同大小和形状的卷积核生成初始采样坐标,这些坐标不再是固定不变的,而是可以根据图像中的特征和目标动态变化。为了更好地适应图像中目标的大小和

形状变化,AKConv 会根据目标的特点调整卷积核的采样位置,这种调整是通过添加偏移量来实现的,使得卷积操作的灵活性和适应性更强,如图 3 所示。偏移量的计算公式如式(1)~(2)所示,输入图像为 $\boldsymbol{X}\in\boldsymbol{R}^{H\times W\times C}$,卷积核中心坐标为$(x_0,y_0)$,则采样点偏移量通过两层全连接网络预测得到。式中:$\boldsymbol{f}(x_0,y_0)$为卷积核中心位置的特征向量;$\boldsymbol{W}_1$,$\boldsymbol{W}_2$ 为全连接层权重矩阵;$\boldsymbol{b}_1$,$\boldsymbol{b}_2$ 为全连接层偏置项;σ 为 Sigmoid 激活函数;S_x,S_y 为偏移量的缩放因子;(i,j)为卷积核内采样点的相对坐标。

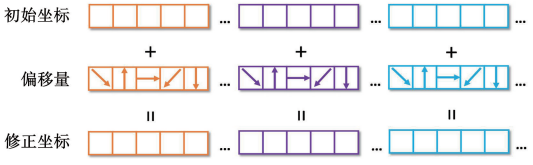

图 3　适应性采样位置调整

Fig. 3　Adaptive sampling position adjustment

$$\Delta x_{i,j}=\sigma(\boldsymbol{W}_1\boldsymbol{f}(x_0,y_0)+\boldsymbol{b}_1)S_x \tag{1}$$

$$\Delta y_{i,j}=\sigma(\boldsymbol{W}_2\boldsymbol{f}(x_0,y_0)+\boldsymbol{b}_2)S_y \tag{2}$$

AKConv 的卷积核大小可以是任意的,随着大小的增加,其初始卷积采样形状变得更加多样化,甚至可以达到无限种变化。采样点数量设为 3×3,共 9 个采样点,兼顾特征提取精度与计算效率;卷积核大小范围为 3×3 至 7×7,根据目标尺度动态调整,小尺度病害对应 3×3 核,大尺度病害对应 7×7 核;卷积核动态调整步长为 2,即根据目标尺寸自适应选择 3×3、5×5 或 7×7 核。为实现卷积核的动态适配,AKConv 通过全局平均池化提取输入特征图的全局信息,再结合卷积核中心位置的局部特征向量共同预测卷积核参数,使卷积核可根据不同区域病害目标的大小与形状实时调整,进而增强对多尺度病害的特征捕捉能力。以 5×5 卷积核为例,本研究设计了多种差异化的初始采样形状,如图 4 所示。通过定量实验,将传统固定形状卷积核与这 5 种不同初始采样形状的卷积核在实际病害检测任务中进行性能对比,结果展示了各类卷积核对模型检测精度的影响,证明采用多样化采样形状的卷积核在提升小麦病害检测性能方面具有显著优势。

为了验证不同卷积核形状对性能的影响,消除其他改进部分的干扰,只针对卷积核进行对比实验,以 mAP@0.5、mAP@0.5:0.95、参数量、模型尺寸作为评价指标,结果如表 1 所示。

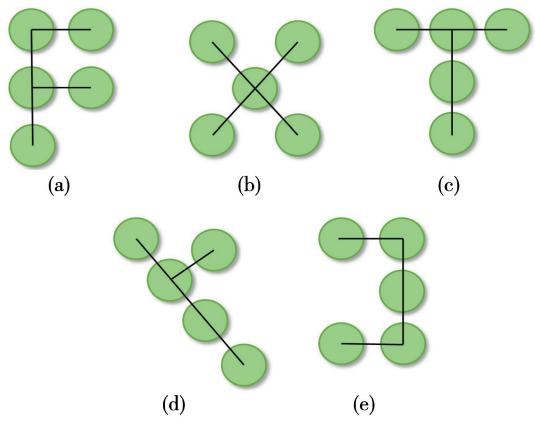

图 4　初始采样形状

Fig. 4　Initial sampling shape

表 1　卷积核形状性能的对比实验

Tab. 1　Comparative experiment of convolution kernel shape performance

序号	卷积核形状	$\alpha_{\text{mAP0.5}}$/%	$\alpha_{\text{mAP0.5:0.95}}$/%	参数量/M	模型尺寸/MB
0	original_conv	94.9	77.8	3.3	7.4
1	Fig.4(a)	95.3	78.5	3.0	6.0
2	Fig.4(b)	95.2	78.2	3.0	6.0
3	Fig.4(c)	95.2	78.1	3.0	6.0
4	Fig.4(d)	95.3	78.1	3.0	6.0
5	Fig.4(e)	95.3	77.9	3.0	6.0

2.2　LSKA 注意力机制

卷积核大小的增加导致计算量和内存呈二次增长。为了解决该问题,本文算法模型设计了大可分离核注意力(large separable kernel attention,LSKA),在降低计算和内存成本的同时,保持了高效的图像处理能力。LSKA 是继 LKA 后改进的注意力模块,其结构图如图 5 所示。首先,它将 1 个大的 2D 核分解成水平和垂直的 2 个 1D 核,这样的分解大幅降低了参数数量和计算复杂度。在进行卷积操作时,LSKA 先使用 1 个 1D 核对输入进行水平方向上的卷积,然后使用另一个 1D 核进行垂直方向上的卷积,这两步卷积操作串联执行,从而实现了与原始大尺寸 2D 核相似的效果。

朴素的 2D 大核深度卷积(DW-Conv)与 1×1 卷积结合。给定 1 个输入特征映射 $\boldsymbol{F}\in\boldsymbol{R}^{\mathrm{C}\times\mathrm{H}\times\mathrm{W}}$,$\boldsymbol{Z}_C$ 为大小为 $k\times k$ 的核 $\boldsymbol{K}$ 与输入特征映射 $\boldsymbol{F}$ 进行卷积得到的深度卷积的输出,如式(3)所示。然后,对深度卷积的输出进行 1×1 核卷积,如式(4)所示。

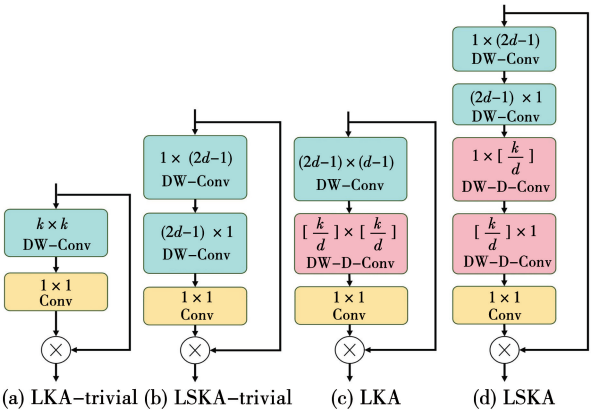

图 5 LSKA 结构

Fig. 5 LSKA structure

最后,输出 $\bar{\boldsymbol{F}}_C$ 为注意映射 $\boldsymbol{A}_C$ 与输入特征映射 $\boldsymbol{F}_C$ 的 Hadamard 乘积,如式(5)所示(* 和⊗分别为卷积和 Hadamard 积):

$$\boldsymbol{Z}_C = \sum_{H,W} \boldsymbol{K}_{C,k\times k} * \boldsymbol{F}_C \tag{3}$$

$$\boldsymbol{A}_C = \boldsymbol{K}_{1\times 1} * \boldsymbol{Z}_C \tag{4}$$

$$\bar{\boldsymbol{F}}_C = \boldsymbol{A}_C \otimes \boldsymbol{F}_C \tag{5}$$

串联的水平和垂直 1D 大核深度卷积与 1×1 卷积结合。包括标准深度卷积(DW-Conv)、扩张深度卷积(DW-D-Conv)和 1×1 卷积。$\bar{\boldsymbol{Z}}_C$ 表示核大小为 $(2d-1)\times(2d-1)$ 的深度卷积的输出,定义如式(6)所示,捕获了局部空间信息,并补偿了后续核大小为 $(\lfloor \frac{k}{d} \rfloor \times \lfloor \frac{k}{d} \rfloor)$ 的扩张深度卷积的网格效应(d 为膨胀率,$\lfloor . \rfloor$为向下取整操作):

$$\bar{\boldsymbol{Z}}_C = \sum_{H,W} \boldsymbol{K}_{C,(2d-1)\times(2d-1)} * \boldsymbol{F}_C \tag{6}$$

$$\boldsymbol{Z}_C = \sum_{H,W} \boldsymbol{K}_{C,[\frac{k}{d}]\times[\frac{k}{d}]} * \bar{\boldsymbol{Z}}_C \tag{7}$$

$$\boldsymbol{A}_C = \boldsymbol{K}_{1\times 1} * \boldsymbol{Z}_C \tag{8}$$

$$\bar{\boldsymbol{F}}_C = \boldsymbol{A}_C \otimes \boldsymbol{F}_C \tag{9}$$

将 LSKA 的前两层分解为 4 层,每层由 2 个 1D 卷积层组成,定义如下:

$$\bar{\boldsymbol{Z}}_C = \sum_{H,W} \boldsymbol{K}_{C,(2d-1)\times 1} * \left(\sum_{H,W} \boldsymbol{K}_{C,1\times(2d-1)} * \boldsymbol{F}_C\right) \tag{10}$$

$$\boldsymbol{Z}_C = \sum_{H,W} \boldsymbol{K}_{C,[\frac{k}{d}]\times 1} * \left(\sum_{H,W} \boldsymbol{K}_{C,1\times[\frac{k}{d}]} * \bar{\boldsymbol{Z}}_C\right) \tag{11}$$

$$\boldsymbol{A}_C = \boldsymbol{K}_{1\times 1} * \boldsymbol{Z}_C \tag{12}$$

$$\bar{\boldsymbol{F}}_C = \boldsymbol{A}_C \otimes \boldsymbol{F}_C \tag{13}$$

2.3 RCS-OSA 模块

RCS-OSA 模块是由 RCS-YOLO 提出的结构。RCS(reparameterize convolution based on channel shuffle)结合了通道混洗,通过重参数化卷积来增强网络的特征提取能力,同时保持通道间的信息交换,降低计算复杂性。OSA(one-shot aggregation)模块旨在提高网络处理密集连接时的效率。

RCS 分为训练阶段(图 6(a))和推理阶段(图 6(b))。在训练阶段,输入经过通道分割,一部分输入经过 RepVGG 块,另一部分保持不变。然后,通过 1×1 卷积和 3×3 卷积处理,将 RepVGG 块的输出与另一部分的输入进行通道混洗和连接,最后进行输出。在推理阶段,原来的多分支结构被重参数化简化为 1 个单一的 3×3RepConv 块,利用多分支结构学习的丰富特征表示,在推理时简化为单一分支,降低计算复杂度。

OSA 凭借聚合不同感受野特征的核心机制,大幅增强网络对不同尺度目标的敏感性,为模型精准检测提供关键支撑。其优势主要体现在两方面:一是精准检测层面,既能敏锐捕捉早期微小病斑的边缘、纹理等细微信息,从根源上避免因感受野不足导致的漏检问题,又能完整提取大面积病害的整体形态特征,灵活适配病害大小差异,进一步提升检测精度;二是效率优化层面,网络最后部分仅需进行一次特征聚合操作,无需重复开展特征计算与存储,在保障检测效果的前提下,显著降低计算资源消耗,提升网络的计算效率与能源利用率,实现性能与成本的高效平衡。

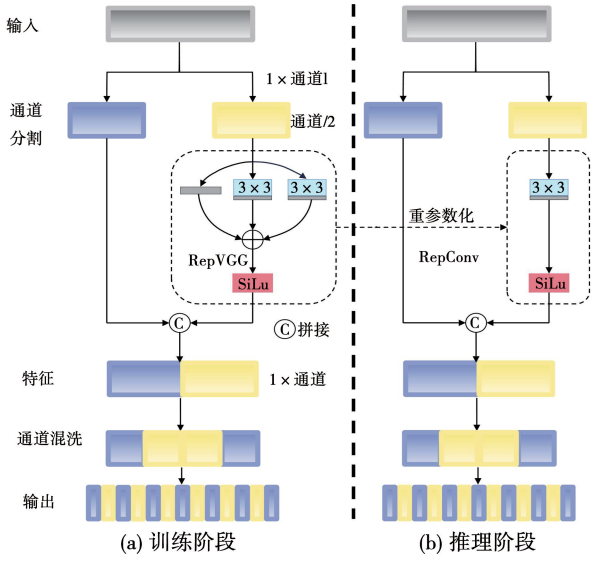

图 6 RCS 结构

Fig. 6 RCS structure

在 RCS-OSA 模块中,输入被分为两部分,一部分特征直接通过,另一部分通过堆叠的 RCS 模块进行处理。处理后的特征与直接通过的特征,在通道混洗后合并,如图 7 所示。

为验证 RCS-OSA 模块在特征融合方面的独特性能优势,在添加小目标检测层的基础上,将其与多

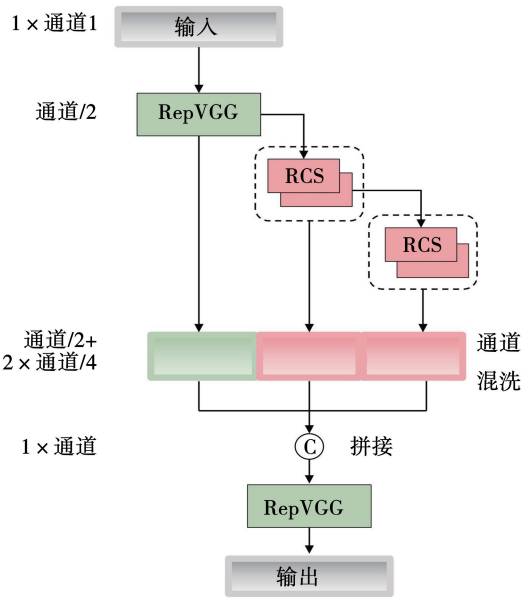

图 7　RCS-OSA 结构

Fig. 7　RCS-OSA structure

种现有方法进行了对比分析,包括 C2f、CspNet、ELAN、C2f-Faster、C2f _ DWRSeg、C2f _ DCNv4 和 C3Ghost。通过对比实验,评估了各模块在特征提取效率、计算复杂度及模型性能上的差异,从而更全面地展示 RCS-OSA 模块在提升特征聚合能力方面的显著优势。实验结果如表 2 所示。

表 2　特征融合模块的对比实验结果

Tab. 2　Comparative experiment results of feature fusion module

特征融合模块	$\alpha_{mAP0.5}$	$\alpha_{mAP0.5:0.95}$	V_{FPS} /(帧·s^{-1})	算力 /(10^9 s^{-1})
C2f	95.8	78.6	151.5	12.7
CSPNet	94.9	77.0	120.4	10.2
ELAN	96.0	78.2	159.8	13.3
C2f_Faster	95.6	78.0	160.2	10.8
C2f_DWRSeg	96.1	78.5	167.7	14.5
C2f_DCNv4	95.6	76.9	164.1	12.1
C3Ghost	95.9	79.0	169.2	11.4
本文模块	96.4	79.4	177.2	15.9

2.4　小目标检测层

传统的 YOLOv8 模型在处理小目标时使用 3 种不同尺寸的特征图进行目标检测。将输入图像 640×640 划分为固定大小的网格,每个网格单元只能检测感受野内的目标特征。其中:80×80 像素的特征图用于检测像素大小在 8×8 以上的目标;40×40 像素的特征图用于检测像素大小在 16×16 以上的目标;20×20 像素的特征图用于检测像素大小在 32×32 以上的较大目标。然而,当小麦病害目标尺寸小于像素大小时,模型难以提取到所有病害信息,所以在多尺度特征图上引入了更细粒度的网格划分,大小为 160×160。通过减少每个网格单元的尺寸,增加感受野的密度。

首先,将 Backbone 网络的第 4 层特征,即 80×80 尺寸的特征图,与 Neck 部分的上采样特征进行拼接,经过 C2f 层和上采样处理,构建了 1 个深层的语义特征层,该层富含小目标特征信息,有效地增强了网络对小目标的语义理解。然后,将这些深层语义特征与 Backbone 的第 2 层浅层语义特征进行拼接,即 160×160 尺寸的特征图,以形成更加完整的特征融合。最后,引入了额外的解耦头到 Head 部分。其中:新增 160×160 检测层的步长设为 2,该参数通过权衡特征图分辨率与网络感受野大小确定,既保证小目标特征的细节保留,又能覆盖足够的上下文信息;特征层通道数设为 256,与 TLeaf-YOLOv8 骨干网络输出的浅层特征通道数保持一致,确保特征融合的兼容性。该检测层配置 3 个 anchor 框,基于 WheatLeafNet 数据集中小目标病害样本的边界框尺寸统计结果聚类得到,anchor 尺寸分别为(12,16)、(19,36)、(40,28)。该设计贴合小麦早期病害斑点的尺寸分布,可提升小目标匹配效率。

3　实验设计与结果分析

3.1　WheatLeafNet 数据集

为了研究自然条件下复杂背景的小麦叶片病害的识别方法,本研究使用了 WheatLeafNet 数据集。该数据集从 Kaggle、OpenDatalab 和 Roboflow 等公开数据集平台获得,是研究小麦叶片病害识别方法中常用的图像数据集,涵盖正常叶片及常见的叶片病害类型,包括细菌叶斑病、褐斑病和叶瘤病等病害。

数据集通过 Canon EOS R5 相机与 DJI Mavic 3 无人机完成图像获取,其中相机配备 50mm 焦距镜头、f/2.8 光圈,专门用于近距离叶片特写拍摄,无人机则负责采集田间群体植株图像。拍摄场景充分覆盖自然光照、弱光照及逆光条件,自然光照时段选取晴天上午 9 时至 11 时与下午 2 时至 4 时,弱光照包含阴天与傍晚场景,以确保数据对实际田间光照变化的鲁棒性。拍摄时间聚焦小麦拔节期至灌浆

期,此阶段为小麦病害高发期,病斑形态、颜色等病害特征表现更为典型。图像分辨率方面,相机采集图像为5 184 ×3 456像素,无人机采集图像为4 000 ×3 000像素。标注过程采用 LabelImg 工具,标注格式为 YOLO 格式,以 txt 文件存储标注信息,内容包含目标类别索引、归一化处理后的边界框中心坐标及边界框宽高。标注规则明确,单叶片单病害区域标注单个边界框以覆盖完整病斑区域,单叶片多病害混合感染区域则分别标注不同病害对应的边界框并明确类别。

为了提升数据质量和模型性能,对数据集进行了严格的标准化处理,包括删除模糊、过暗或过曝的低质量样本,并统一将所有图像调整为固定尺寸640 ×640 像素,以确保数据的一致性和规范性。此外,为增强模型对复杂场景的适应能力,采用了多种数据增强技术,如图像旋转、翻转、缩放、亮度调整和随机裁剪等操作,使模型能够更好地学习和应对多样化的实际场景变化。经过标准化处理和数据增强,最终构建的数据集包含6 715张高分辨率图像,并按 8∶1∶1 的比例划分为训练集、验证集和测试集。为避免类别不平衡对模型性能的负面影响,各类别的样本数量保持相对均衡,确保了模型的学习公平性与稳定性。具体数据集各类样本划分如表 3 所示,数据集样本中健康叶片和各类病害叶片示例如图 8 所示。

表 3 每个类别包含的图片数

Tab. 3 Number of images per category

序号	类别	图片数量
1	叶瘤病 Leaf_smut	1 746
2	细菌叶斑病 Bacteria_Leaf_Blight	1 663
3	褐斑病 Brown_Spot	1 708
4	正常叶片 Leaf_Normal	1 598
5	总计	6 715



(a) 叶瘤病



(b) 细菌叶斑病



(c) 褐斑病



(d) 正常叶片

图 8 数据集示例图

Fig. 8 Dataset example diagram

3.2 实验环境

本文的实验环境搭建在服务器上,硬件配置如下:Intel(R) Xeon(R) Gold 5320 CPU @ 2.20 GHz,NVIDIA A40 显卡,48 GB 内存,1 TB 固态硬盘,编程语言为 Python3.8,CUDA11.3 版本,深度学习框架平台为 Pytorch1.12.1 版本。

3.3 实验指标

本实验定量评价选取的指标包括:召回率(R)、平均准确率(α_{AP})、平均精度均值(α_{mAP})、参数量、算力(每秒浮点运算次数,GFLOPs)、每秒检测图片的帧数 V_{FPS},其公式如下:

$$P=\frac{TP}{TP+FP} \tag{14}$$

$$R=\frac{TP}{TP+FN} \tag{15}$$

$$\alpha_{AP}=\int_0^1 P(R)\,dR \tag{16}$$

$$\alpha_{mAP0.5}=\frac{1}{C}\sum_{c=1}^{C}\alpha_{AP_c} \tag{17}$$

$$\alpha_{mAP0.5:0.95}=\frac{1}{10}\alpha_{mAP0.5}+\frac{1}{10}\alpha_{mAP0.55}+\cdots+\frac{1}{10}\alpha_{mAP0.95} \tag{18}$$

式中:TP(true positive)为模型交并比 IOU≥设定阈值时正确检测到的目标物体的数目;FP(false positive)为模型 IOU < 设定阈值时错误检测到的不存在的目标物体的数目;FN(false negative)为模型未检测到的实际存在的目标物体的数目;C 为类别的总数;α_{AP_c}为第 c 个类别的平均精度。

3.4 消融实验

为了验证本文模型改进的有效性,以原始模型 YOLOv8n 为基准模型,通过多个改进模块不同的组合方式进行消融实验,一共验证 6 组网络,并以 P、R、$\alpha_{mAP0.5}$、$\alpha_{mAP0.5:0.95}$、参数量、算力、V_{FPS}、模型尺寸作为评价指标,结果如表 4 所示。

表 4　消融实验结果

Tab. 4　Ablation experiment results

小目标检测层	AKConv	RCS-OSA	LSKA	P /%	R /%	$\alpha_{mAP0.5}$ /%	$\alpha_{mAP0.5:0.95}$ /%	V_{FPS} /(帧·s^{-1})	参数量 /M	算力 /(10^9 s^{-1})	模型尺寸 /MB
×	×	×	×	93.9	89.2	94.9	77.8	159.8	3.3	8.2	7.4
✓	×	×	×	94.5	89.8	95.8	78.6	151.5	2.9	12.7	6.4
✓	×	×	✓	95.3	91.8	96.7	79.5	107.1	3.0	12.5	6.4
✓	×	✓	×	94.9	90.3	96.4	79.4	177.2	7.2	15.9	13.3
✓	✓	✓	×	94.3	90.1	96.1	79.3	169.7	3.5	12.5	7.0
✓	✓	✓	✓	96.1	90.5	96.8	79.6	138.6	3.0	12.5	6.3

注:“✓”表示使用该模块,“×”表示未使用该模块。

由表 4 可见,添加了小目标检测层的模型相比原始的 YOLOv8n 模型,P、R、$\alpha_{mAP0.5}$、分别提高了 0.6%、0.6%、0.9%;在添加了小目标检测层和 LSKA 注意力机制后,参数量和模型尺寸分别降低了 0.3 M 和 1 MB,P、R、$\alpha_{mAP0.5}$ 分别提高了 1.4%、2.6%、1.8%;添加了小目标检测层和重参数化卷积模型 RCS-OSA 后,检测精度和检测效率皆有所提升,其中 P、R、$\alpha_{mAP0.5}$、V_{FPS} 分别提高了 1%、1.1%、1.5%、17.4 帧·s^{-1};添加了小目标检测层、轻量化卷积 AKConv 和 RCS-OSA 的模型相比只添加小目标检测层和 RCS-OSA 的模型,在参数量、算力、模型尺寸上分别降低了 3.7 M、3.4 GFLOPs、6.3 MB,同时与 YOLOv8n 模型相比 P、R、$\alpha_{mAP0.5}$、V_{FPS} 分别提升了 0.4%、0.9%、1.2%、9.9 帧·s^{-1}。实验结果表明:本文改进后的 TLeaf-YOLOv8 模型相比于原始的 YOLOv8n 网络模型,虽然 V_{FPS} 有所降低,但是在 P、R、$\alpha_{mAP0.5}$ 上分别提高了 2.2%、1.3%、1.9%,并且模型参数量和模型尺寸分别降低了 0.3 M 和 1.1 MB,证明了本文改进算法的有效性。模型训练过程中损失性能指标变化如图 9 所示。

在消融实验中,不同层次的特征图所提取的特征具有显著差异。浅层的特征图通常侧重于捕捉图像中的基本信息,如边缘、纹理和简单形状等,这些特征范围较大且相对完整。而随着网络层次的加深,特征图提取的内容逐渐变得更加抽象和复杂,这些特征通常更为细致且局部化,能够描述更高层次的语义信息。为了进一步验证这些特征的作用,本文对中间特征图进行可视化,如图 10 所示。

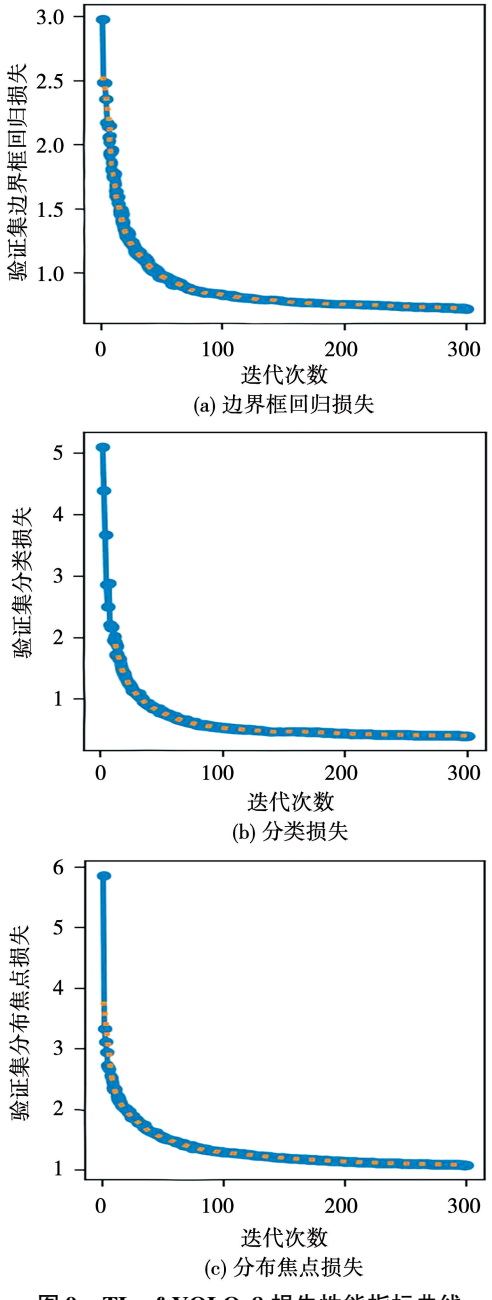

图 9　TLeaf-YOLOv8 损失性能指标曲线

Fig. 9　Loss performance index curve of TLeaf-YOLOv8

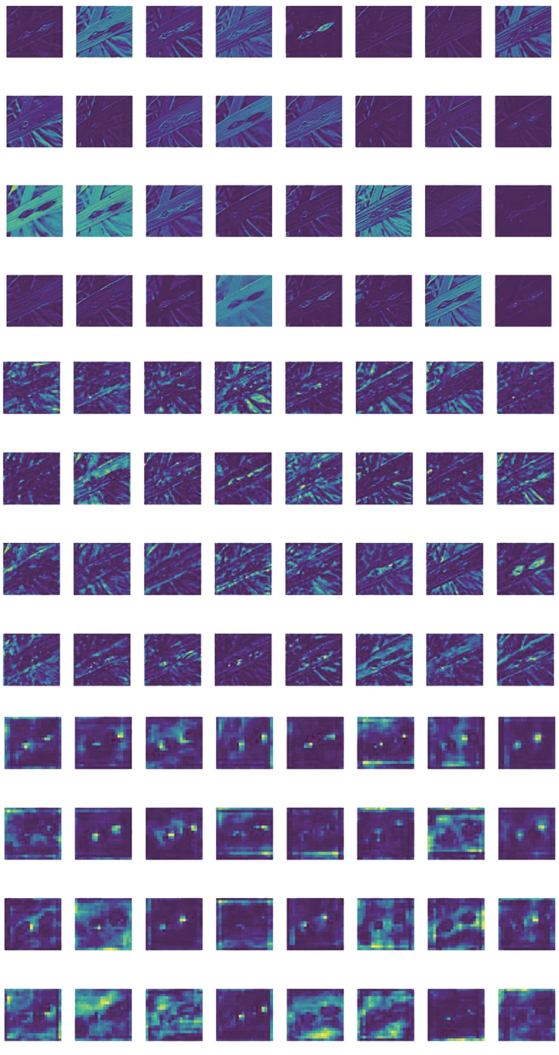

图 10 特征图可视化

Fig. 10 Feature map visualization

3.5 对比实验

为了验证本文改进算法 TLeaf-YOLOv8 在叶片病害检测中的性能优势,将其与当前流行的叶片病害检测模型进行比较,实验结果如表 5 所示。以 $\alpha_{\text{mAP0.5}}$、$\alpha_{\text{mAP0.5:0.95}}$、$V_{\text{FPS}}$、模型尺寸作为评价指标,将本文算法与 Faster R-CNN、YOLOv3、YOLOv4、YOLOX-s、YOLOv5n、YOLOv7、YOLOv8n、文[26]、文[27]算法在相同的 WheatLeafNet 数据集上进行对比实验。

由表 5 实验结果可知,本文提出的 TLeaf-YOLOv8 算法相较于其他主流的目标检测算法具有最高的检测精度,且模型尺寸与检测速度分别达到了 6.3 MB 和 138.6 帧·s^{-1},可以较好地适用于复杂田地环境中叶片病害的目标检测任务。其中,与检测精度最接近的 YOLOv8n 算法相比,本文所提的改进算法在模型尺寸不变的基础上,$\alpha_{\text{mAP0.5}}$ 提升了 1.9 个百分点,具有明显的体量优势和检测精度优势。

表 5 WheatLeafNet 数据集的对比实验结果

Tab. 5 Comparative experiment results of WheatLeafNet dataset

序号	算法模型	$\alpha_{\text{mAP0.5}}$	$\alpha_{\text{mAP0.5:0.95}}$	V_{FPS}	模型尺寸/MB
0	Faster RCNN	82.2	64.6	32.3	113.0
1	YOLOv3	85.3	66.3	66.8	18.6
2	YOLOv4	89.2	70.1	114	24.9
3	YOLOX-s	91.3	75.0	129.8	33.2
4	YOLOv5n	93.2	76.9	109.4	13.7
5	YOLOv7	92.0	75.7	121.2	19.0
6	YOLOv8n	94.9	77.8	159.8	7.4
7	文[26]	95.5	78.1	98.2	8.7
8	文[27]	94.7	77.1	117.0	13.8
9	本文算法	96.8	79.6	138.6	6.3

为了验证改进模型的泛化性能,令该算法在苹果叶片病害数据集和无人机采集数据集 PDT 进行检测。苹果病害数据集包括锈病、黑星病、白粉病和褐斑病 4 种病害,共5 133张图片。无人机采集数据集 PDT 涵盖了健康和受病虫害影响的松树图像,共5 775张图片。改进后的 TLeaf-YOLOv8 算法与传统算法对比结果如表 6 ~ 7 所示。

表 6 苹果病害数据集对比实验

Tab. 6 Comparative experiments of apple disease dataset

序号	算法模型	$\alpha_{\text{mAP0.5}}$	$\alpha_{\text{mAP0.5:0.95}}$	V_{FPS}	模型尺寸/MB
0	YOLOX-s	90.2	73.9	130.2	40.3
1	YOLOv5n	92.1	75.8	117.3	15.4
2	YOLOv7	90.9	74.6	126.5	19.8
3	YOLOv8n	93.8	76.7	142.6	6.9
4	本文算法	95.7	78.5	139.8	7.0

表 7 无人机 PDT 数据集对比实验

Tab. 7 Comparative experiment of UAV PDT dataset

序号	算法模型	$\alpha_{\text{mAP0.5}}$	$\alpha_{\text{mAP0.5:0.95}}$	V_{FPS}	模型尺寸/MB
0	YOLOX-s	81.3	62.2	92.1	55.9
1	YOLOv5n	85.4	65.3	90.5	20.8
2	YOLOv7	88.7	69.2	110.6	23.4
3	YOLOv8n	91.9	70.1	103.5	8.2
4	本文算法	93.9	71.8	98.7	8.5

在对比实验中,加入了复杂田间环境下的真实场景应用案例以验证模型的实用性。在苹果病害数据集中存在训练样本较少且分布不均的问题,使得模型在训练过程中容易记住训练数据的特征,导致泛化能力不足,无法在测试数据上取得理想表现。在日后工作中将在以下方向改进实验方法:通过过采样或欠采样等技术,平衡不同类别的样本分布,避免模型过度偏向某些类别;采用预训练模型进行预训练,并在苹果病害数据集上进行微调,利用大规模数据集的知识提升小样本数据集的表现。

综上所述,本文提出的 TLeaf-YOLOv8 算法在保证模型轻量化的同时具有最高的检测精度,进一步证明了本文算法的优越性。

3.6　算法验证

为直观验证改进算法的检测性能优势,表 8 呈现了原图、YOLOv8 基准算法与本文提出的 TLeaf-YOLOv8 改进算法在小麦叶片病害检测中的可视化对比结果。实验聚焦褐斑病、叶瘤病和叶斑病 3 类典型病害,对应划分为 A 组、B 组、C 组开展测试,充分覆盖田间叶片遮挡、光照不均和背景干扰等复杂实际场景。

多维度比对可见,原始 YOLOv8 算法在部分场景中存在病灶定位偏差、识别精度不高和轻微病害漏检等问题,复杂环境下检测稳定性不足;而 TLeaf-YOLOv8 算法凭借针对小麦叶片特征优化的网络结构与较强的特征提取能力,在病害区域精准定位、微小病灶识别和相似病害区分上表现突出,既能捕捉叶片病害的细粒度纹理与颜色差异,又能根据病斑大小动态适配特征提取范围,避免因病斑尺度不一导致的识别偏差。另一方面,通过聚焦关键病害区域、过滤背景冗余信息,减少杂草阴影等干扰因素引发的错检,同时,强化模型对早期微小病斑的特征留存与细节提取能力,解决传统算法对小尺度病灶的漏检难题。在实际检测中,该算法不仅能让边界框更紧密贴合病灶实际轮廓,精准定位病害区域,还可有效检出传统算法易遗漏的微小病斑,显著降低相似病害的误判率,整体识别准确率远超基准算法。

表 8　小麦叶片病害检测效果对比图

Tab. 8　Comparison chart of wheat leaf disease detection effects

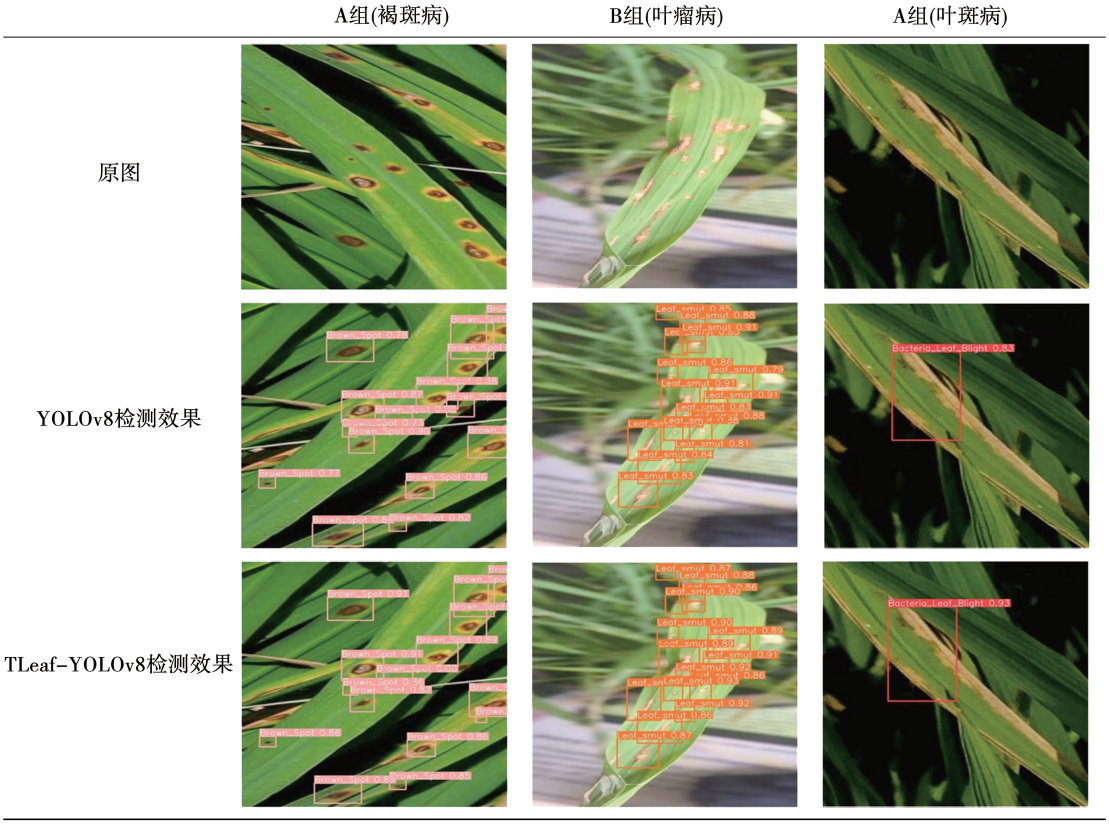

4 结 语

本文提出轻量的 TLeaf-YOLOv8 网络模型对复杂田地环境的小麦叶片病害进行检测和识别,在主干网络引入 RCS-OSA 模块有助于模型更好地捕捉病害特征,进一步提高了识别的精度;颈部网络应用了 AKConv 卷积模块,根据目标特点灵活调整卷积核大小和形状,在保证检测精度的同时有效降低了模型的参数量。同时,添加了小目标检测层;引入 LSKA 注意力机制优化了小目标的特征提取,避免小目标特征在冗余信息中丢失。改进的 TLeaf-YOLOv8 网络模型在精确率及 $\alpha_{mAP0.5}$ 相比于原始网络模型均有所提升,且网络的参数量及模型尺寸相较于原始网络模型分别有所降低。本研究开发的模型在识别3种主要的小麦病害方面表现优异,但鉴于小麦病害种类的多样性及虫害的普遍性,未来的研究将扩展病害样本库并纳入虫害样本,增强识别能力并实现实时监测。

参 考 文 献:

[1] JIN Y, LIU J, et al. Development Status and Trend of Agricultural Robot Technology[J]. International Journal of Agricultural and Biological Engineering, 2021, 14(4): 1.

[2] CHEN P, LI Y, LIU X, et al. Improving Yield Prediction Based on Spatio-temporal Deep Learning Approaches for Winter Wheat: A Case Study in Jiangsu Province, China [J]. Computers and Electronics in Agriculture, 2023, 213: 108201.

[3] NIGAM S, JAIN R, MARWAHA S, et al. Deep Transfer Learning Model for Disease Identification in Wheat Crop [J]. Ecological Informatics, 2023, 75: 102068.

[4] WANG C Y, BOCHKOVSKIY A, LIAO H M. YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-art for Real-time Object Detectors [C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 7464.

[5] HE Y, XIAO L. Structured Pruning for Deep Convolutional Neural Networks: A Survey [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(5): 2900.

[6] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770.

[7] 马超伟, 张浩, 马新明, 等. 基于改进 YOLOv8 的轻量化小麦病害检测方法[J]. 农业工程学报, 2024, 40(5): 187.
MA Chaowei, ZHANG Hao, MA Xinming, et al. Method for the Lightweight Detection of Wheat Disease Using Improved YOLOv8 [J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(5): 187.

[8] SUN P, ZHANG R, JIANG Y, et al. Sparse R-CNN: An End-to-end Framework for Object Detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(12): 15650.

[9] RANE N. YOLO and Faster R-CNN Object Detection for Smart Industry 4.0 and Industry 5.0: Applications, Challenges, and Opportunities [J]. SSRN Electronic Journal, 2023.

[10] CHEN W, LIU M, ZHAO C, et al. MTD-YOLO: Multi-task Deep Convolutional Neural Network for Cherry Tomato Fruit Bunch Maturity Detection[J]. Computers and Electronics in Agriculture, 2024, 216: 108533.

[11] HUO B H, LI C L, ZHANG J W, et al. SAFF-SSD: Self-attention Combined Feature Fusion-based SSD for Small Object Detection in Remote Sensing[J]. Remote Sensing, 2023, 15(12): 3027.

[12] 刘敏, 姜亮, 田杨阳, 等. 基于压缩图像与 YOLOv5 模型的架空输电线路缺陷检测技术[J]. 沈阳工业大学学报, 2025, 47(2): 152.
LIU Min, JIANG Liang, TIAN Yangyang, et al. Effect Detection Technology for Overhead Transmission Lines Based on Compressed Images and YOLOv5 Model[J]. Journal of Shenyang University of Technology, 2025, 47(2): 152.

[13] 金鑫,程凌森,赵亮, 等. 基于改进 YOLOv5 模型的智能变电站目标违规行为检测方法研究[J]. 电测与仪表,2024, 61(8): 179.
JIN Xin, CHENG Lingsen, ZHAO Liang, et al. Research on Intelligent Substation Target Violation Detection Method Based on Improved YOLOv5 Model [J]. Electrical Measurement & Instrumentation, 2024,61(8): 179.

[14] 丁小娜,刘锦博,邓锴,等. 基于 YOLOv8 损失函数改进的密集果蔬目标检测方法[J]. 微处理机,2026,47(2):58.
DING Xiaona, LIU Jinbo, DENG Kai, et al. Dense Fruit

and Vegetable Target Detection Method Based on Improved YOLOv8 Loss Function[J]. Microprocessors, 2026, 47(2): 58.

[15] 张志佳, 范莹莹, 邵一鸣,等. 基于改进 YOLOv3 模型的多类交通标识检测[J]. 沈阳工业大学学报,2023, 45(1): 66.
ZHANG Zhijia, FAN Yingying, SHAO Yiming, et al. Detection of Multi-type Traffic Signs Based on Improved YOLOv3 Model[J]. Journal of Shenyang University of Technology, 2023, 45(1): 66.

[16] 刘甜甜,彭放,卢伟龙,等. 基于 YOLOv7 的智能电网外部安全帽佩戴风险因素识别与检测[J]. 电测与仪表, 2024, 61(12): 42.
LIU Tiantian, PENG Fang, LU Weilong, et al. Identification and Detection of External Risk Factors for Safety Helmet Wearing in Smart Grid Based on YOLOv7 [J]. Electrical Measurement & Instrumentation, 2024, 61(12): 42 .

[17] TANG Z, HE X, ZHOU G, et al. A Precise Image-based Tomato Leaf Disease Detection Approach Using PLPNet [J]. Plant Phenomics, 2023, 5: 42.

[18] 李超炜, 杨晓娜, 赵司琦, 等. 针对宫颈异常细胞检测的 SER-DC YOLO[J]. 哈尔滨理工大学学报, 2024, 29(1): 115.
LI Chaowei, YANG Xiaona, ZHAO Siqi, et al. SER-DC YOLO for the Detection of Abnormal Cervical Cells[J]. Journal of Harbin University of Science and Technology, 2024, 29(1): 115.

[19] DEB M, DHAL K G, DAS A, et al. A CNN-based Model to Count the Leaves of Rosette Plants (LC-Net) [J]. Scientific Reports, 2024, 14: 1496.

[20] YIGIT E, SABANCI K, TOKTAS A, et al. A Study on Visual Features of Leaves in Plant Identification Using Artificial Intelligence Techniques [J]. Computers and Electronics in Agriculture, 2019, 156: 369.

[21] MADEC S, BARET F, DE S B, et al. High-Throughput Phenotyping of Plant Height: Comparing Unmanned Aerial Vehicles and Ground LiDAR Estimates [J]. Frontiers in Plant Science, 2017, 8: 2002.

[22] 邓伟豪, 刘拥民, 徐卓农, 等. 基于 YOLOv8n 的轻量化葡萄叶片病害检测算法[J]. 湖南农业大学学报(自然科学版), 2025, 51(5): 121.
DENG Weihao, LIU Yongmin, XU Zhuonong, et al. Lightweight Detection Algorithm for Grape Leaf Diseases Based on YOLOv8n[J]. Journal of Hunan Agricultural University (Natural Sciences), 2025, 51(5): 121.

[23] YE R, SHAO G Q, HE Y, et al. YOLOv8-RMDA: Lightweight YOLOv8 Network for Early Detection of Small Target Diseases in Tea [J]. Sensors, 2024, 24 (9): 2896.

[24] ZHAN B, XIONG X, LI X, et al. BHC-YOLOV8: Improved YOLOv8-based BHC Target Detection Model for Tea Leaf Disease and Defect in Real-world Scenarios[J]. Frontiers in Plant Science, 2024, 15: 1492504.

[25] 杨锋, 姚晓通. 基于改进 YOLOv8 的小麦叶片病虫害检测轻量化模型[J]. 智慧农业, 2024, 6(1): 147.
YANG Feng, YAO Xiaotong. Lightweighted Wheat Leaf Diseases and Pests Detection Model Based on Improved YOLOv8[J]. Smart Agriculture, 2024, 6(1): 147.

[26] 苏俊楷, 段先华, 叶赵兵. 改进 YOLOv5 算法的玉米病害检测研究[J]. 计算机科学与探索, 2023, 17 (4): 933.
SU Junkai, DUAN Xianhua, YE Zhaobing. Research on Corn Disease Detection Based on Improved YOLOv5 Algorithm[J]. Journal of Frontiers of Computer Science & Technology, 2023, 17(4): 933.

[27] 李小祥, 张洁, 秦柯贝, 等. 基于改进 YOLOv8 的轻量级复杂环境苹果叶片病害检测方法[J]. 南京农业大学学报, 2025, 48(3): 734.
LI Xiaoxiang, ZHANG Jie, QIN Kebei, et al. A Lightweight Method for Apple Leaf Disease Detection in Complex Environments Based on Improved YOLOv8[J]. Journal of Nanjing Agricultural University, 2025, 48 (3): 734.

(编辑:温泽宇)