

# 基于改进 YOLO v8s 的小麦小穗赤霉病检测研究

时雷<sup>1,2</sup> 杨程凯<sup>1</sup> 雷镜楷<sup>1</sup> 刘志浩<sup>1</sup> 王健<sup>1</sup> 席磊<sup>1,2</sup> 熊蜀峰<sup>1</sup>

(1. 河南农业大学信息与管理科学学院, 郑州 450046; 2. 河南粮食作物协同创新中心, 郑州 450046)

**摘要:** 为实现大田复杂背景下小麦小穗赤霉病快速准确识别, 构建了包含冬小麦开花期、灌浆期和成熟期3个生育期共计640幅的小麦赤霉病图像数据集, 并提出一种基于改进YOLO v8s的小麦小穗赤霉病识别方法。首先, 利用全维动态卷积ODConv替换主干网络中的标准Conv, 提高网络对目标区域特征的提取; 然后, 在Neck网络使用改进Efficient RepGFPN特征融合网络实现低层特征与高层语义信息的融合, 使模型能够提取更丰富的特征信息; 最后, 采用EIoU损失函数替换CIOU损失函数, 加快模型收敛速度, 进一步提高模型准确率, 实现对小麦小穗赤霉病的快速、准确识别。在自建的数据集上进行模型验证, 结果表明, 改进模型(OCE-YOLO v8s)对小麦小穗赤霉病的检测精度达到98.3%, 相比原模型提高2个百分点; 与Faster R-CNN、CenterNet、YOLO v5s、YOLO v6s、YOLO v7模型相比分别提高36.2%、25.7%、2.1%、2.6%、3.9个百分点。提出的OCE-YOLO v8s模型能有效实现小麦小穗赤霉病精确检测, 可为大田环境下农作物病虫害实时监测提供参考。

**关键词:** 小麦赤霉病; 目标检测; YOLO v8; 全维动态卷积; Neck网络; EIoU

中图分类号: TP391.41 文献标识码: A 文章编号: 1000-1298(2024)07-0280-10

OSID:



## Wheat Spikelet Detection of Fusarium Head Blight Based on Improved YOLO v8s

SHI Lei<sup>1,2</sup> YANG Chengkai<sup>1</sup> LEI Jingkai<sup>1</sup> LIU Zhihao<sup>1</sup> WANG Jian<sup>1</sup> XI Lei<sup>1,2</sup> XIONG Shufeng<sup>1</sup>

(1. College of Information and Management Science, Henan Agricultural University, Zhengzhou 450046, China

2. Collaborative Innovation Center of Henan Grain Crops, Zhengzhou 450046, China)

**Abstract:** To achieve rapid and accurate identification of fusarium head blight on wheat spikelets in complex field background, a wheat fusarium head blight image dataset comprising a total of 640 images across three growth stages: flowering, grain filling, and ripening of winter wheat was constructed. Additionally, a wheat spikelet fusarium head blight recognition method based on an improved YOLO v8s model was proposed. Firstly, using the omni-dimensional dynamic convolution (ODConv) to replace the standard convolution in the backbone network enhanced the network's extraction of features from target regions and suppressed interference from cluttered background information. Secondly, an improved Efficient RepGFPN feature fusion network was utilized in the neck network to integrate low-level features with high-level semantic information, enabling the model to extract richer feature information. Lastly, the enhanced intersection over union (EIoU) loss function was employed instead of the complete intersection over union (CIOU) loss function to accelerate model convergence speed and further improve model accuracy, thus achieving rapid and accurate identification of fusarium head blight on wheat spikelets. Model validation on a self-built dataset revealed that the improved model (OCE-YOLO v8s) achieved a detection accuracy of 98.3% for fusarium head blight on wheat spikelets, which was an improvement of 2 percentage points compared with the original model. Compared with Faster R-CNN, CenterNet, YOLO v5s, YOLO v6s, and YOLO v7 models, the OCE-YOLO v8s model achieved improvements of 36 percentages, 25.7 percentages, 2.1 percentages, 2.6 percentages, and 3.9 percentages, respectively.

收稿日期: 2024-03-31 修回日期: 2024-05-13

基金项目: 国家自然科学基金项目(31501225)、河南省科技研发计划联合基金项目(222301420113)、河南省自然科学基金项目(232300420186)和河南省科技攻关项目(242102111193)

作者简介: 时雷(1979—), 女, 教授, 博士, 主要从事智慧农业和数据挖掘研究, E-mail: shilei@henau.edu.cn

通信作者: 熊蜀峰(1980—), 男, 副教授, 博士, 主要从事机器学习和大数据处理研究, E-mail: xsf@whu.edu.cn

The OCE – YOLO v8s model effectively met the requirements for precise detection of fusarium head blight on wheat spikelets and could provide valuable insights for real-time monitoring of crop diseases and pests in complex backgrounds of field environments.

**Key words:** fusarium head blight; object detection; YOLO v8; ODConv; Neck network; EIoU

## 0 引言

小麦是我国的主要粮食作物之一,在国家粮食安全体系构建中发挥着重要作用<sup>[1-2]</sup>。小麦赤霉病是由多种镰刀菌引起的全球小麦生产中最广泛和最具破坏力的病害之一<sup>[3-4]</sup>,严重时会减产 80% ~ 90%,甚至颗粒无收,且赤霉病产生的次生代谢产物均为毒素,人畜误食后严重危害健康。因此在小麦生长过程中实现赤霉病发生发展的及时准确监测,进而采取有效的防治措施,对确保小麦优质、高效、安全生产具有重要意义。此外从 GB/T 15796—2011《小麦赤霉病测报技术规范》中了解到,统计小麦赤霉病病小穗数是获取赤霉病病情严重度的重要依据,且是研究小麦抗性育种(抗赤霉病)的重要指标。因此,实现对小麦小穗赤霉病的检测有利于评估病害对小麦产量和质量的影响,指导农户和相关人员采取相应的控制和管理措施。

目前针对小麦小穗赤霉病识别的方法主要有人工田间目视调查、高光谱成像等。基于人工目视调查的方法耗时耗力,且不利于大规模调查防治;高光谱成像技术因其抗干扰能力强、检测速度快等特点广泛应用于作物病害检测领域<sup>[5-7]</sup>,结合光谱分析与图像处理技术<sup>[8]</sup>,可以精确地识别出小麦赤霉病籽粒。文献[9]利用高光谱成像技术与机器学习方法结合提出一种小麦赤霉病籽粒识别算法,可以快速、准确地实现对小麦赤霉病籽粒的识别;文献[10]结合高光谱成像技术和图像处理方法建立了小麦赤霉病籽粒识别模型,识别准确率达到 90% 以上,能够较好地识别小麦赤霉病籽粒。上述方法虽然能达到较高的识别精度,但高光谱成像仪较为昂贵且笨重,难以在田间进行实时检测。

随着深度学习的不断发展,卷积神经网络在图像识别领域取得了一定的成果<sup>[11-13]</sup>。在农林业方面,学者也对此进行了深入的研究<sup>[14-16]</sup>。文献[17]提出一种基于深度学习的番茄病害识别方法,对 5 种番茄叶片病害进行检测,平均识别准确率可达 97.29%;文献[18]提出一种 CNN 和 BiLSTM 相结合的水稻病害识别方法,实验结果表明平均识别精度达到 99.38%;文献[19]提出一种改进 MobileNetV3Small 模型,对 PlantVillage 数据集上水稻病害进行识别,在非迁移学习下,识别准确率达到

97.47%。以上研究实现了简单背景下作物病害识别,并取得了较好的检测结果。

但大田环境下背景通常复杂,难以实现高精度的检测。鉴于此,文献[20]以 YOLOX 模型为基础,提出一种基于改进 YOLOX 的木薯叶病害检测模型,来解决田间环境下叶片遮盖和背景复杂等因素引起的木薯叶病害识别困难的问题,检测精度达到 93.53%;文献[21]针对玉米作物病虫害目标检测中由于图像背景复杂、无关因素干扰较多而导致的对病虫害目标检测效果不理想等问题,提出一种基于 YOLO v5s 改进模型的玉米作物病虫害检测方法,平均精度达到 90.1%。然而,大田环境下拍摄的图像同样受到外界光照条件的影响,因此,针对以上问题,本文以大田复杂环境下不同光照条件的小麦小穗赤霉病为研究对象,基于 YOLO v8s 模型提出一种改进的赤霉病检测方法,使用全维动态卷积替换主干网络中的标准卷积,增强模型对小麦小穗的特征提取能力,利用改进 Efficient RepGPN 网络融合多尺度特征,增强模型泛化能力,并将 CIoU 损失函数替换为 EIoU,提高模型识别精度,以期为小麦赤霉病小穗检测计数和赤霉病害病情监测提供技术基础。

## 1 小麦赤霉病图像数据集建立

### 1.1 数据来源

本研究数据采集于河南农业大学国家小麦工程技术研究中心基地( $35^{\circ}01'N, 113^{\circ}40'E$ )。试验田区域分为多个种植小区域,将小麦试验品种进行秋播,每个品种 2 行,随机排列。品种包括宁麦 9 号、扬麦 158、苏麦 3 号与周麦 18,致病菌为禾谷镰刀菌。数据采集时间为 2022 年 5 月 2—15 日和 2023 年 5 月 11—24 日,拍摄角尽可能为  $90^{\circ}$ ,拍摄小麦穗部侧面,尽量保证所获得的图像中只有一株麦穗。拍摄设备为智能手机,图像格式为 JPG,尺寸为 1 200 像素  $\times$  1 600 像素,部分图像为 1 920 像素  $\times$  1 920 像素。经过对原始图像的筛选,在剔除冗余与模糊图像后,整理得到 640 幅麦穗图像,其中遮荫条件下 489 幅,光照条件下 151 幅。部分数据集样本示例如图 1 所示。

### 1.2 数据标注和划分

在训练模型前,需要对数据集中的图像进行人



图 1 不同光照条件下小麦赤霉病图像

Fig. 1 Images of wheat FHB under different light conditions

工标注,标注工具使用 LabelImg 工具。在标注时,首先定义标注对象类别,将图像中的健康小穗定义为 HS,病小穗定义为 DS,然后使用外接矩形框框选目标,并选择适当的标签进行标注。在标注完成后,LabelImg 会将每个图像的标注信息保存为 XML 文件,由于 YOLO 模型需要的标注格式为 TXT 文件,因此,在完成标注后,还需要将 XML 格式的文件转化为 TXT 格式的文件。在将 640 幅小麦小穗图像标注完成后,将其按 8:1:1 的比例随机划分为训练集、验证集、测试集。训练集图像 512 幅,验证集图像 64 幅,测试集图像 64 幅。其中训练集用于训练目标检测模型,验证集用于评估模型的性能,测试集用于测试模型对赤霉病患病小穗的计数效果,同时也用于预测小麦赤霉病病情严重度。

## 2 小麦小穗赤霉病检测模型

### 2.1 YOLO v8 模型

YOLO v8 是 YOLO 系列<sup>[22-24]</sup>最新模型,与前几代 YOLO 模型相比,进一步提高了其检测性能。YOLO v8 网络主要由输入端( Input 层)、主干网络

(Backbone 层)、颈部网络( Neck 层)和输出端( Head 层)4 部分组成。Input 层的作用是将图像数据输入到模型中,Backbone 层的作用是对输入图像进行特征提取,Neck 层的作用是对主干网络提取特征进行融合,Head 层的作用是对特征进行预测,得到目标位置信息和类别信息。

YOLO v8 属于单目标检测网络,根据模型尺寸的不同,分为 YOLO v8n、YOLO v8s、YOLO v8m、YOLO v8l、YOLO v8x,这 5 个模型的深度和宽度依次增加,检测精度逐渐提升,但训练花费时间也依次提高。本研究结合农业实际生产情况,选用 YOLO v8s 模型作为基准模型,在保证检测精度的同时,又兼顾了识别速度,可以满足小麦赤霉病实时检测的要求。

### 2.2 OCE – YOLO v8s 模型

为提高对大田环境下小麦小穗赤霉病的识别效果,本文在 YOLO v8s 模型基础上加以改进,首先使用全维动态卷积 ODConv 替换主干网络中的普通卷积,降低模型计算量的同时提高模型识别精度,其次在模型 Neck 层使用 C-Efficient RepGFPN 网络提高模型特征融合能力,从而提高模型对小麦小穗赤霉病的识别准确率,最后更换损失函数为 EIoU 损失函数,进一步提高模型收敛速度和准确率,最终得到改进的 OCE – YOLO v8s 模型。改进模型网络结构如图 2 所示。

#### 2.2.1 ODConv 全维动态卷积

对于大田复杂背景下小麦小穗赤霉病识别,提高模型精度的关键在于抑制杂乱背景信息的干扰,使模型关注于小麦小穗特征的提取,全维动态卷积 ODConv<sup>[25]</sup>是通过并行策略采用多维注意力机制沿核空间的 4 个维度学习卷积核的动态卷积,不仅考虑输入通道维度、输出通道维度和空间维度,还考虑

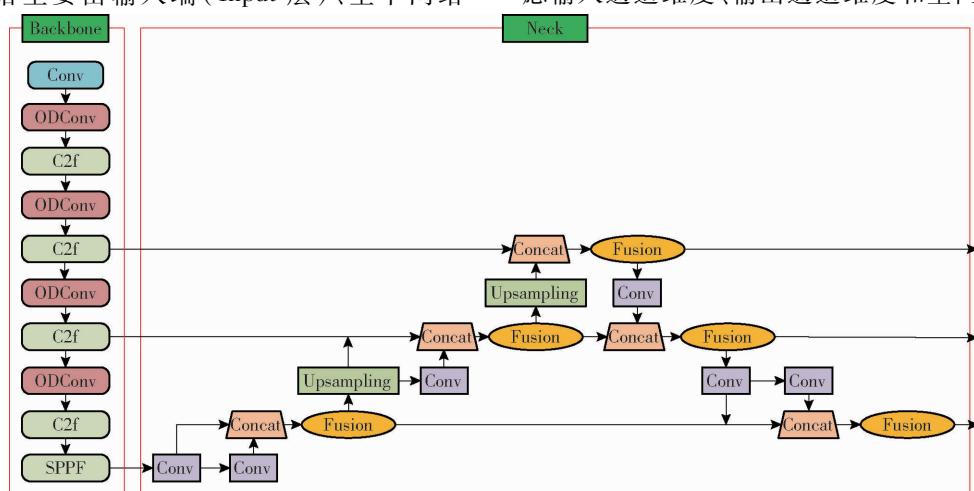


图 2 OCE – YOLO v8s 模型

Fig. 2 OCE – YOLO v8s model

卷积核形状和尺寸,可以增强模型对小麦小穗特征的关注程度,从而提高模型识别准确率。

图 3 为 ODConv 卷积的结构图。首先将输入特征  $X$  通过全局平均池化层 (Global average pooling, GAP) 压缩为长为  $c_{in}$  的特征向量, 压缩后的特征向量再由一个全连接层 (Fully connected layers, FC) 和修正线性单元 (Rectified linear unit, ReLU) 处理, 其中 FC 层以 1/16 的压缩率将特征向量映射到低维空间, 以此简化动态卷积的复杂性, ReLU 激活函数将特征向量中的负值置零。最后创建 4 个头部分支, 每个分支包括一个全连接层和一个 Softmax 函数或 Sigmoid 函数, 然后生成 ODConv 卷积模块的 4 类注意力。

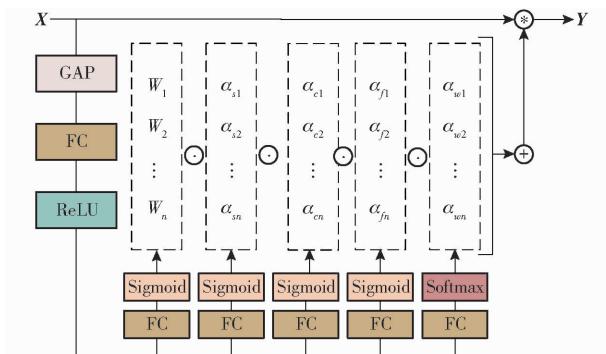


图 3 ODConv 卷积结构

Fig. 3 ODConv convolutional structure

图 4 展示了这 4 种类型的注意力乘以卷积核的过程。图 4a 为 ODConv 沿空间维度的卷积注意力运算过程,  $\alpha_{si}$  对卷积核  $W_i$  在空间维度上的每个位置赋予不同的注意力权重, 使模型更关注输入图像的空间位置信息, 在空间维度上捕捉小麦赤霉病图像中目标特征的空间分布和形态特征; 图 4b 为 ODConv 沿输入通道维度的卷积注意力运算过程,  $\alpha_{ci}$  对卷积核  $W_i$  每个输入通道的卷积滤波器赋予不同的注意力权重, 使模型更加专注不同通道之间的特征关系, 帮助模型更好地提取和组合不同通道的信息, 使模型更关注小麦小穗赤霉病图像中的特定颜色通道或纹理特征, 从而适应不同光照条件下的小麦赤霉病数据; 图 4c 为 ODConv 沿输出通道维度的卷积注意力运算过程,  $\alpha_{fi}$  对卷积核  $W_i$  每个输出通道的卷积滤波器赋予不同的注意力权重, 使模型在不同输出通道之间进行更有针对性的特征选择, 对光照条件变化引起的不同病征做出响应, 从而增强模型对于健康小穗和病小穗不同类别特征的提取能力; 图 4d 为 ODConv 沿卷积核核空间维度的卷积注意力运算过程,  $\alpha_{wi}$  对整个卷积核赋予不同的注意力权重, 使模型可以更加全局地调节卷积操作, 适应不同大小和形状的赤霉病病斑, 从而能够更好地捕获

输入数据的整体特征。4 种注意力机制相互配合补充, 使模型在不同维度上对各个输入数据产生不同维度的影响, 从而更好地捕获小麦小穗关键特征和上下文信息, 提高模型性能和泛化能力。本研究使用全维动态卷积 ODConv 替换主干网络中的普通卷积, 保证模型充分提取小麦小穗赤霉病特征, 提高检测精度。

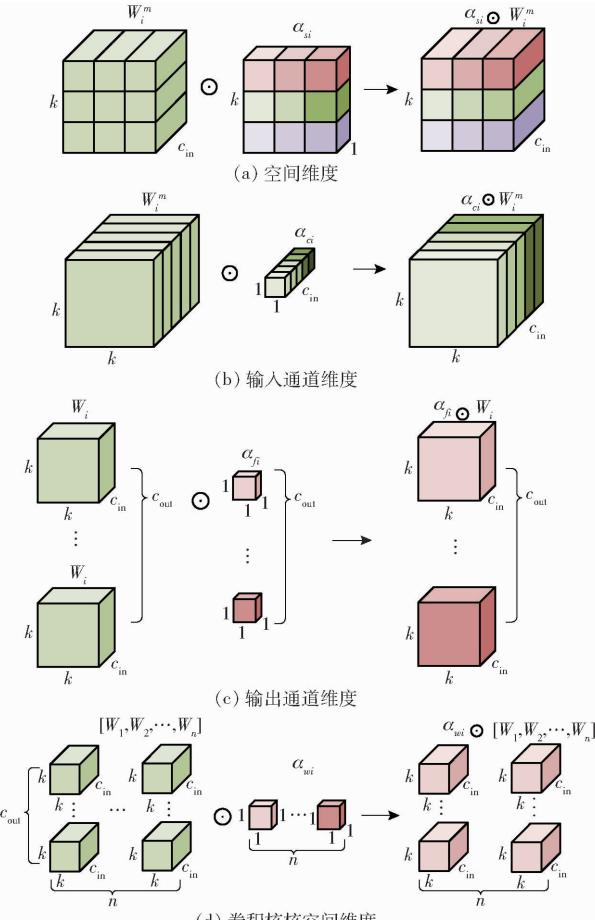


图 4 ODConv 沿 4 种维度的卷积运算过程

Fig. 4 ODConv along four dimensions convolution operation process

## 2.2.2 改进 Efficient RepGFPN 网络

传统的 FPN<sup>[26]</sup> 通过自顶向下的路径来融合多尺度特征, 但计算成本增加。BiFPN<sup>[27]</sup> 通过删除只有一个输入边的节点, 并在同一级别上添加跳过链路来提升模型性能。GFPN<sup>[28]</sup> 能够充分交换高级语义和低级空间信息, 实现更好的性能。但 GFPN 不同尺度的特征共享统一的通道, 且 Queen – Fusion 带来了大量额外的上采样和下采样运算。Efficient RepGFPN<sup>[29]</sup> 则解决了上述问题。Efficient RepGFPN 在特征融合中采用不同尺度特征图具有不同通道维度的设置来控制计算成本, 能够有效捕捉到小麦赤霉病图像中不同尺度的特征; 另外在保证实时检测的前提下, 删除 Queen – Fusion 中的额外上采样操

作,能够更高效地进行特征融合和处理;在特征融合中,用 CSPNet 替换原始的基于  $3 \times 3$  卷积的特征融合,CSPNet 能够有效地交换高级语义信息和低级空间信息,从而提升网络对小麦赤霉病的识别精度;然后再通过引入重新参数化机制和高效层聚合网络(ELAN)的连接来升级 CSPNet,进一步提升网络的性能和精度,使模型能够更准确地检测小麦赤霉病。Efficient RepGFPN 网络结构如图 5 所示。

Fusion Block 是 Efficient RepGFPN 网络的主要融合模块,首先对输入的特征图进行 Concat 操作,然后分别通过  $1 \times 1$  卷积进行通道降维,再使用多个 Rep  $3 \times 3$  卷积和  $3 \times 3$  卷积进行特征变换,同时多

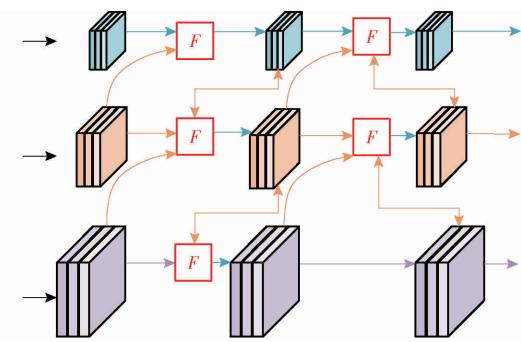


图 5 Efficient RepGFPN 网络结构

Fig. 5 Efficient RepGFPN network structure

个层输出,最后通过 Concat 操作得到最终的输出。Fusion Block 模块结构如图 6 所示。

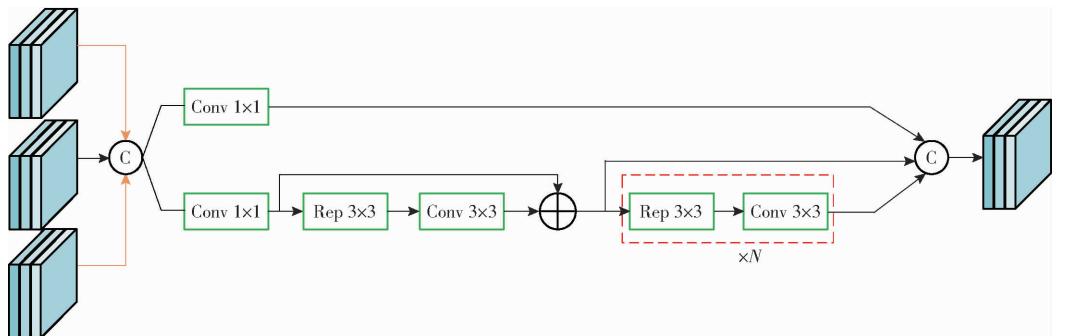


图 6 Fusion Block 网络结构

Fig. 6 Fusion Block network structure

为了更好地将主干网络输出特征层与 Efficient RepGFPN 网络进行融合,提高模型对目标特征的检测能力,本文在主干网络输出的特征图送入 Efficient RepGFPN 之前加入一个  $1 \times 1$  卷积,引入更多的灵活性和非线性表达能力,提高网络对小麦小穗赤霉病特征的识别,进而提高模型识别准确率,改进后的 Efficient RepGFPN 网络命名为 C-Efficient RepGFPN。C-Efficient RepGFPN 网络结构如图 7 所示。

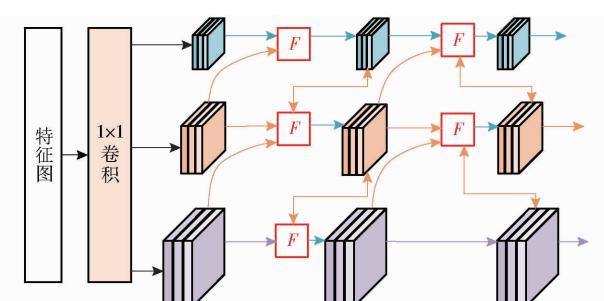


图 7 C-Efficient RepGFPN 网络结构

Fig. 7 C-Efficient RepGFPN network structure

### 2.2.3 EIoU 损失函数

YOLO v8 原损失函数为 CIoU 损失函数<sup>[30]</sup>,CIoU 损失函数仅能反映目标框长宽比的差异,并不是长宽分别与其置信度的真实差异,从而阻止了模型优化相似性。因此为了提升模型精度,用

EIoU<sup>[31]</sup>损失函数替换 CIoU 损失函数。

EIoU 损失值  $L_{\text{EIoU}}$  共由 3 部分相加而成:交并比(IoU)损失值  $L_{\text{IoU}}$ 、预测框与真实框的中心点距离损失值  $L_{\text{dis}}$ 、高宽损失值  $L_{\text{asp}}$ ,其计算公式为

$$\begin{aligned} L_{\text{EIoU}}(b, b^{gt}) &= L_{\text{IoU}} + L_{\text{dis}} + L_{\text{asp}} = \\ &1 - \text{IoU}(b, b^{gt}) + \frac{\rho^2(b, b^{gt})}{c^2} + \frac{\rho^2(w, w^{gt})}{c_w^2} + \frac{\rho^2(h, h^{gt})}{c_h^2} \end{aligned} \quad (1)$$

式中  $b, b^{gt}$ ——预测框、真实框中心点坐标  
 $\rho^2$ ——相应计算元素中心点欧氏距离  
 $c$ ——最小外接框最短对角线长度  
 $w, w^{gt}, h, h^{gt}$ ——预测框宽度、真实框宽度、预测框高度、真实框高度  
 $c_w, c_h$ ——最小外接框宽度、高度

EIoU 损失函数考虑目标边界框的精确性和位置信息,能够更好地衡量检测框与真实目标之间的重叠程度,由于 EIoU 损失函数更加关注目标的精确位置和形状,能够更好地捕捉到小尺度目标的细节信息,因此对小麦赤霉病这样的小尺度目标检测效果更优。

### 2.3 试验设置

本研究所有试验均使用 PyTorch 作为深度学习

模型框架, GPU 为 NVIDIA GeForce RTX3090, 迭代次数为 150, 批量大小设置为 32, 优化器使用 AdamW 优化器, 初始学习率为 0.01, 动量为 0.937, 权值衰减为 0.0005。

## 2.4 评价指标

为了衡量网络模型对小麦小穗赤霉病的检测性能, 将识别精确率、召回率、平均检测精度 (Average precision, AP) 和平均精度均值 mAP (Mean average precision, mAP) 作为评价指标<sup>[32]</sup>。

## 3 结果与分析

### 3.1 加入 ODConv 对模型的影响

ODConv 能使模型更关注小麦小穗特征的提取, 提高检测精度。为探究 ODConv 在网络结构中的位置与模型性能的关系, 设置 3 组试验, 试验 1 为只替换主干网络中的 Conv, 试验 2 为只替换 Neck 网络中的 Conv, 试验 3 为将主干网络和 Neck 网络中的 Conv 都替换, 如表 1 所示。

从表 1 中可以看出, 在 Backbone 中替换 ODConv 的模型, 其 mAP 高于在 Neck 网络替换

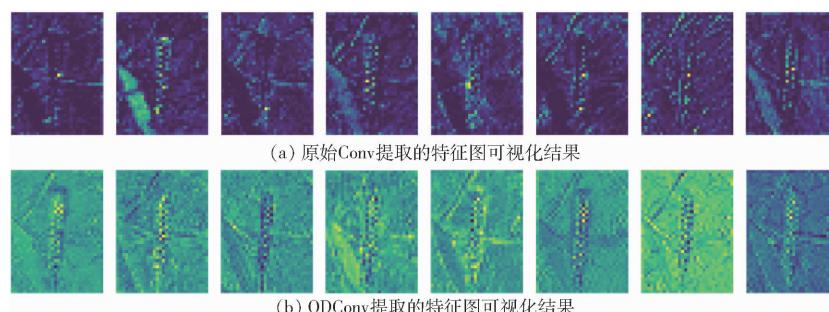


图 8 特征可视化结果

Fig. 8 Feature visualization result

### 3.2 不同损失函数对识别结果的影响

为验证不同损失函数对本文模型检测结果的影响, 使用 CIoU、DIoU、WIoU 和 EIoU 共 4 种损失函数来进行对比试验, 结果如表 2 所示。

表 2 不同损失函数对识别结果的影响

Tab. 2 Effect of different loss functions on

recognition results %

损失函数	精确率	召回率	mAP	%
CIoU	91.9	94.0	96.3	
DIoU	93.3	94.0	97.3	
WIoU	92.3	93.4	96.6	
EIoU	94.1	93.8	97.6	

从表 2 中可以看出, 使用 EIoU 损失函数在本文数据集上取得了最好的效果, 精确率、召回率和 mAP 均为最高, mAP 较 CIoU、DIoU、WIoU 损失函数分别高 1.3、0.3、1 个百分点。原因在于 EIoU 损失

表 1 ODConv 对模型的影响

Tab. 1 Effect of ODConv on model

试验编号	位置	精确率	召回率	mAP	%
1	Backbone	95.0	94.7	98.3	
2	Neck	94.0	94.6	97.7	
3	Backbone + Neck	93.7	95.0	98.0	

ODConv 的模型,而在将主干网络和 Neck 网络中的 Conv 都替换之后, mAP 低于试验 1 的结果, 原因在于 ODConv 在主干网络中更好地学习了图像低级和中级特征, 因此在替换 Conv 层时可以提升模型性能。然而, Neck 网络通常负责更高级的特征提取和检测, 需要更复杂的特征表示来实现目标检测任务, ODConv 在 Neck 中无法充分适应特定任务的特征提取要求, 导致性能下降。

图 8b 为将主干网络的第 5 层的 Conv 替换为 ODConv 的特征图可视化结果, 图 8a 为原始 Conv 提取的特征图可视化结果。从图中可以看出, 在将 Conv 替换为 ODConv 后, 提取出的特征图其特征更为明显, 进一步验证了 ODConv 有利于模型性能的提高。

函数能够更准确地衡量检测框与真实目标之间的重叠度, 尤其在边界框预测不准确或目标尺寸较小时, 相比于其他损失函数, EIoU 能够更准确地评估边界框的匹配程度, 使得模型在检测小麦小穗赤霉病等小目标时具有更好的性能和鲁棒性。

### 3.3 加入 $1 \times 1$ 卷积对模型的影响

本文在主干网络输出的特征图送入 Efficient RepGFPN 之前加入一个  $1 \times 1$  卷积, 为验证加入  $1 \times 1$  卷积对模型性能的影响, 设计两组试验, 结果如表 3 所示。

表 3  $1 \times 1$  卷积对模型的影响

Tab. 3 Effect of  $1 \times 1$  convolution on model

模型	精确率/召回率/mAP/计算量			
	%	%	%	
Efficient RepGFPN	94.6	93.6	97.8	$1.22 \times 10^{10}$
C-Efficient RepGFPN	94.6	95.6	98.0	$1.23 \times 10^{10}$

通过表3可以看出,在特征图送入Efficient RepGFPN网络之前加入 $1 \times 1$ 卷积,模型在计算量略有增加的情况下,模型的召回率提高了2.0个百分点,mAP提高了0.2个百分点,原因在于 $1 \times 1$ 卷积可以对输入特征图的每个像素进行线性组合,从而引入非线性变换,有助于模型学习更复杂的特征,从而通过计算量较少的方式提高模型对小麦小穗赤霉病的检测能力,提高模型检测精度。

### 3.4 消融试验

为验证本研究提出的改进算法的性能,设置5组对比消融试验,结果如表4所示。

表4 消融试验结果

Tab. 4 Results of ablation experiment %

试验 编号	ODConv	C-Efficient RepGFPN	EIoU	精确率	召回率	mAP
1	×	×	×	91.9	94.0	96.3
2	√	×	×	92.7	94.4	96.9
3	×	√	×	94.6	95.6	98.0
4	×	×	√	94.1	93.8	97.6
5	√	√	√	95.0	94.7	98.3

注:√表示基线模型采用此模块;×表示基线模型未采用此模块。

由表4中试验2与试验1的结果对比可知,主干网络使用全维动态卷积ODConv替换普通卷积Conv后,模型的精确率、召回率均有提升,mAP提高0.6个百分点,说明嵌入全维动态卷积的模型通过学习4个维度的注意力提高了模型的识别准确率;通过试验3与试验1的结果对比可知,采用C-Efficient RepGFPN结构进行特征融合后,模型的mAP为98.0%,比原模型提高1.7个百分点,说明该特征融合结构能够更好地融合高级语义信息和低级空间信息,从而提高模型对小麦小穗赤霉病特征的提取;通过试验4与试验1的结果对比可知,用EIoU损失函数替换CIoU损失函数后,模型的mAP提高1.3个百分点,能有效提高检测准确率。由试验5最终改进结果与试验1的结果对比可知,最终改进模型OCE-YOLO v8s的精确率较原模型提高3.1个百分点,召回率提高0.7个百分点,mAP提高2.0个百分点,能够有效提高模型对小麦小穗赤霉病的识别。

### 3.5 不同模型对比试验

为进一步验证模型性能,选取Faster R-CNN、CenterNet和YOLO系列其他模型,如YOLO v5s、YOLO v6s、YOLO v7、YOLO v8s模型进行对比,结果如表5所示。

从表5中可以看出,本研究所提出方法的mAP达98.3%,比Faster R-CNN、CenterNet、YOLO v5s、

表5 不同模型对比结果

Tab. 5 Comparative experiment results with different models

模型	精确率/%	召回率/%	mAP/%	计算量
Faster R-CNN	66.5	46.7	62.3	$3.697 \times 10^{11}$
CenterNet	69.3	61.4	72.6	$7.020 \times 10^{10}$
YOLO v5s	91.8	92.3	96.2	$2.400 \times 10^{10}$
YOLO v6s	93.8	92.1	95.7	$4.420 \times 10^{10}$
YOLO v7	90.5	88.7	94.4	$1.051 \times 10^{10}$
YOLO v8s	91.9	94.0	96.3	$2.840 \times 10^{10}$
OCE-YOLO v8s	95.0	94.7	98.3	$2.580 \times 10^{10}$

YOLO v6s、YOLO v7、YOLO v8s算法分别高36、25.7、2.1、2.6、3.9、2.0个百分点。Faster R-CNN、CenterNet的mAP均较低,且计算量较大;YOLO v5s模型的mAP与YOLO v8s模型相差不大,但其精确率和召回率相对较低;YOLO v6s和YOLO v7模型的mAP相对较低,且计算量大,消耗算力,不适用于移动端等低算力设备;本文所提模型OCE-YOLO v8s拥有最高的mAP、精确率和召回率,且计算量较原YOLO v8s模型有所降低,能够满足实时检测的需求。模型的准确率曲线如图9(图中mAP@0.5表示IoU阈值为0.5时每个类别AP的平均值)所示。

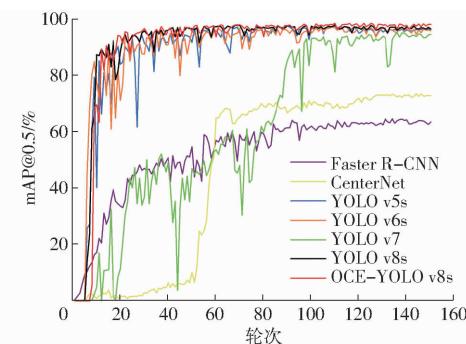


图9 各模型mAP@0.5变化曲线

Fig. 9 mAP@0.5 change curves for each model

为了更直观地比较改进模型与原模型的检测效果,图10展示了测试集上模型改进前、后的检测结果。其中原模型中会出现误检漏检的情况,且置信度低于改进后的模型,而改进后的模型大幅改善了这一问题,验证了本文算法的有效性。综合结果表明,本文所提算法在小麦小穗赤霉病检测上具有较高的精度,能够更好地对小麦小穗赤霉病进行准确检测。

### 3.6 小麦小穗赤霉病计数结果和分析

为衡量OCE-YOLO v8s模型与原YOLO v8s模型在小麦小穗计数结果上的差异,另外选取88幅小麦小穗赤霉病图像作为测试集,加上原来的64幅一共152幅图像,然后将模型改进前、后的预测值和人

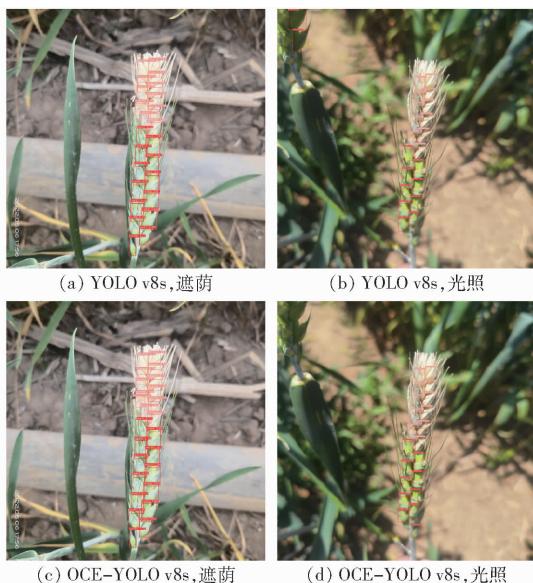


图 10 模型检测结果

Fig. 10 Model detection results

工真实统计值进行统计,并对病小穗数和健康小穗数的预测值和真实值进行线性拟合。从图 11 中可以看出,OCE-YOLO v8s 模型预测病小穗数与拟合线比较接近,原 YOLO v8s 模型预测病小穗数相对分散,表明 OCE-YOLO v8s 模型对病小穗计数的拟合结果优于原模型,OCE-YOLO v8s 模型的决定系数  $R^2$  为 0.969,比原 YOLO v8s 模型的决定系数高 0.036,说明 OCE-YOLO v8s 模型在单幅图像上的病小穗计数预测值与人工统计的真实值之间具有显著的线性相关。

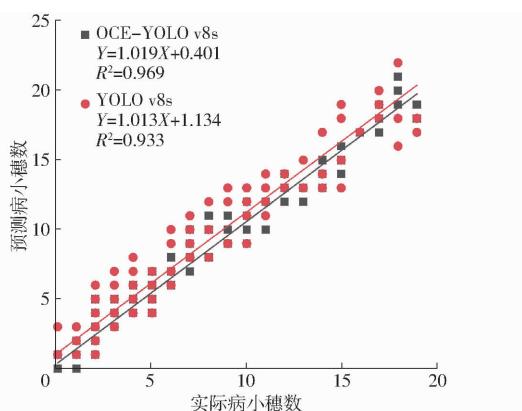


图 11 YOLO v8s 改进前、后的病小穗数拟合结果

Fig. 11 Diseased spikelet fitting results before and after YOLO v8s improvement

表 6 为 YOLO v8s 模型改进前、后的病小穗计数结果评价指标对比。从表 6 中可以看出,OCE-YOLO v8s 模型在病小穗计数上的均方根误差(RMSE)为 1.07,比原 YOLO v8s 模型低 0.81,平均绝对误差(MAE)为 0.73,比原 YOLO v8s 模型低 0.63,说明本文提出的 OCE-YOLO v8s 模型在小麦病小穗计数结果方面优于原 YOLO v8s 模型。

表 6 病小穗计数结果对比

Tab. 6 Diseased spikelet counting results comparison

模型	$R^2$	RMSE	MAE
YOLO v8s	0.933	1.88	1.36
OCE-YOLO v8s	0.969	1.07	0.73

图 12 为 OCE-YOLO v8s 模型和原 YOLO v8s 模型在测试集上预测的健康小穗数与人工实际统计健康小穗数的拟合结果。从图中可以看出,OCE-YOLO v8s 模型预测的健康小穗数的拟合结果优于原模型,且 OCE-YOLO v8s 模型的决定系数  $R^2$  比原 YOLO v8s 模型高 0.042,表明 OCE-YOLO v8s 模型在单幅图像上的健康小穗计数预测值与人工统计的真实值之间具有显著的线性相关。

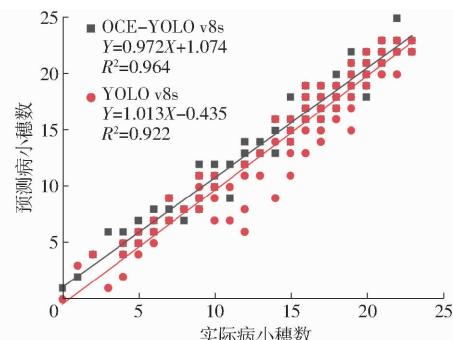


图 12 YOLO v8s 改进前、后的健康小穗数拟合结果

Fig. 12 Healthy spikelet fitting results before and after YOLO v8s improvement

表 7 为 YOLO v8s 模型改进前、后的健康小穗计数结果评价指标对比。从表 7 中可以看出,OCE-YOLO v8s 模型在健康小穗计数上的 RMSE 比原 YOLO v8s 模型低 0.41,MAE 比原 YOLO v8s 模型低 0.17,说明本文提出的 OCE-YOLO v8s 模型在小麦健康小穗计数结果方面优于原 YOLO v8s 模型。

表 7 健康小穗计数结果对比

Tab. 7 Healthy spikelet counting results comparison

模型	$R^2$	RMSE	MAE
YOLO v8s	0.922	1.65	1.08
OCE-YOLO v8s	0.964	1.24	0.91

从 OCE-YOLO v8s 模型对病小穗和健康小穗的预测结果来看,OCE-YOLO v8s 模型对病小穗的计数结果高于对健康小穗的计数结果,原因可能是病小穗与图像背景区别明显,模型对于病小穗的识别结果更好。综合结果表明,OCE-YOLO v8s 模型在病小穗和健康小穗的计数方面均优于原 YOLO v8s 模型,表明 OCE-YOLO v8s 模型在小麦小穗赤霉病计数上有较好的结果,能有效满足对小麦小穗赤霉病的精确检测和计数。

### 3.7 小麦赤霉病病情严重度预测结果

在 GB/T 15796—2011《小麦赤霉病测报技术规范》中,规定小麦赤霉病病情严重度是指病小穗数占全部小穗数的比例,共划分为 5 级。0 级:无病;1 级:病小穗数占全部小穗的 1/4 以下;2 级:病小穗数占全部小穗的 1/4~1/2;3 级:病小穗数占全部小穗的 1/2~3/4;4 级:病小穗数占全部小穗的 3/4 以上。根据改进模型 OCE-YOLO v8s 在 152 幅测试集图像上的计数结果进行病情严重度划分,结果如表 8 所示。

表 8 小麦赤霉病病情严重度预测结果

Tab. 8 Results of wheat FHB severity prediction

病情严重度	0 级	1 级	2 级	3 级	4 级
预测数量	3	75	33	25	16
实际数量	3	78	34	24	13

从表 8 中可以看出,改进模型在测试集的 152 幅小麦小穗赤霉病图像中,预测病情严重度各级别数量与真实级别的数量相差不大,病情严重度主要集中在 1 级,原因在于该试验地块中小麦赤霉病的

产生是使用带致赤霉病菌的微量移液器以单花滴注的方式注入到麦穗中上部(自穗顶端向下第 5 排小穗)的小花内,致使发病小穗主要集中于麦穗上部,因此小麦赤霉病病情严重度主要为 1 级。

### 4 结束语

针对大田复杂背景下的小麦小穗赤霉病小目标检测问题,提出 OCE-YOLO v8s 算法,用全维动态卷积 ODConv 替换 YOLO v8s 特征提取网络中的普通卷积来提高算法精度;使用 C-Efficient RepGFPN 特征融合网络对不同的特征层进行融合,提高模型对小麦小穗赤霉病特征的识别;使用 EIoU 损失函数代替 CIoU 损失函数,进一步提高模型预测准确率。试验结果表明,改进后的算法在小麦小穗赤霉病数据集上的准确率、召回率、mAP 指标上都有所提高,mAP 达到 98.3%,且计算量有所减少。总体来说,改进后的模型在算法计算量降低的前提下,检测准确性更高,有效解决了大田复杂背景下小麦小穗赤霉病小目标检测问题,实现了对小麦小穗赤霉病病情严重度分级。

### 参 考 文 献

- [1] SAVARY S. Plant health and food security[J]. Journal of Plant Pathology, 2020, 102(3): 605–607.
- [2] GRUBER K. Agrobiodiversity: the living library[J]. Nature, 2017, 544(7651): S8–S10.
- [3] GHIMIRE B, SAPKOTA S, BAHRI B A, et al. Fusarium head blight and rust diseases in soft red winter wheat in the southeast United States: state of the art, challenges and future perspective for breeding[J]. Frontiers in Plant Science, 2020, 11: 1080.
- [4] SARI E, KNOX R E, RUAN Y, et al. Historic recombination in a durum wheat breeding panel enables high-resolution mapping of fusarium head blight resistance quantitative trait loci[J]. Scientific Reports, 2020, 10(1): 7567.
- [5] 章海亮,高俊峰,何勇. 基于高光谱成像技术的柑橘缺陷无损检测[J]. 农业机械学报,2013,44(9): 177–181.
- ZHANG Hailiang, GAO Junfeng, HE Yong. Nondestructive detection of citrus defect using hyper-spectra imaging technology [J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(9): 177–181. (in Chinese)
- [6] 褚璇,王伟,张录达,等. 高光谱最优波长选择及 Fisher 判别分析法判别玉米颗粒表面黄曲霉毒素[J]. 光谱学与光谱分析, 2014, 34(7): 1811–1815.
- CHU Xuan, WANG Wei, ZHANG Luda, et al. Hyperspectral optimum wavelengths and Fisher discrimination analysis to distinguish different concentrations of aflatoxin on corn kernel surface[J]. Spectroscopy and Spectral Analysis, 2014, 34(7): 1811–1815. (in Chinese)
- [7] 谢传奇,王佳悦,冯雷,等. 应用高光谱图像光谱和纹理特征的番茄早疫病早期检测研究[J]. 光谱学与光谱分析, 2013, 33(6): 1603–1607.
- XIE Chuanqi, WANG Jiayue, FENG Lei, et al. Study on the early detection of early blight on tomato leaves using hyperspectral imaging technique based on spectroscopy and texture[J]. Spectroscopy and Spectral Analysis, 2013, 33(6): 1603–1607. (in Chinese)
- [8] ZHANG N, PAN Y, FENG H, et al. Development of fusarium head blight classification index using hyperspectral microscopy images of winter wheat spikelets[J]. Biosystems Engineering, 2019, 186: 83–99.
- [9] 刘爽,谭鑫,刘成玉,等. 高光谱数据处理算法的小麦赤霉病籽粒识别[J]. 光谱学与光谱分析,2019,39(11):3540–3546.
- LIU Shuang, TAN Xin, LIU Chengyu, et al. Recognition of fusarium head blight wheat grain based on hyperspectral data processing algorithm[J]. Spectroscopy and Spectral Analysis, 2019, 39(11): 3540–3546. (in Chinese)
- [10] 梁琨,杜莹莹,卢伟,等. 基于高光谱成像技术的小麦籽粒赤霉病识别[J]. 农业机械学报,2016,47(2):309–315.
- LIANG Kun, DU Yingying, LU Wei, et al. Identification of fusarium head blight wheat based on hyperspectral imaging technology[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(2): 309–315. (in Chinese)
- [11] ALQARAGHULI A, OĞUZ A T A. Optimized YOLO v4 algorithm for car detection in traffic flow[J]. Turkish Journal of Science and Technology, 2022, 17(2): 395–403.

- [12] 蔡舒平,孙仲鸣,刘慧,等. 基于改进型YOLO v4的果园障碍物实时检测方法[J]. 农业工程学报,2021,37(2):36–43.  
CAI Shuping, SUN Zhongming, LIU Hui, et al. Real-time detection methodology for obstacles in orchards using improved YOLO v4[J]. Transactions of the CSAE, 2021, 37(2): 36–43. (in Chinese)
- [13] YAN B, FAN P, LEI X, et al. A real-time apple targets detection method for picking robot based on improved YOLO v5[J]. Remote Sensing,2021,13(9):1619.
- [14] FERNANDEZ-GALLEGOS J A, KEFAUVER S C, GUTIERREZ N A, et al. Wheat ear counting in-field conditions: high throughput and low-cost approach using RGB images[J]. Plant Methods,2018,14:1–12.
- [15] 王宇歌,张涌,黄林雄,等. 基于卷积神经网络的麦穗目标检测算法研究[J]. 软件工程, 2021,24(8):6–10.  
WANG Yuge, ZHANG Yong, HUANG Linxiong, et al. Research of wheat ear target detection based on convolutional neural network[J]. Software Engineering,2021,24(8):6–10. (in Chinese)
- [16] 许景辉,邵明烨,王一琛,等. 基于迁移学习的卷积神经网络玉米病害图像识别[J]. 农业机械学报,2020,51(2):230–236,253.  
XU Jinghui, SHAO Mingye, WANG Yichen, et al. Recognition of corn leaf spot and rust based on transfer learning with convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(2):230–236,253. (in Chinese)
- [17] 马丽,周巧黎,赵丽亚,等. 基于深度学习的番茄叶片病害分类识别研究[J]. 中国农机化学报,2023,44(7):187–193,206.  
MA Li, ZHOU Qiaoli, ZHAO Liya, et al. Classification and recognition of tomato leaf diseases based on deep learning[J]. Journal of Chinese Agricultural Mechanization,2023, 44(7):187–193,206. (in Chinese)
- [18] 路阳,刘婉婷,林立媛,等. CNN与BiLSTM相结合的水稻病害识别新方法[J]. 江苏农业科学,2023,51(20):211–217.  
LU Yang, LIU Wanting, LIN Liyuan, et al. A new methodfor rice disease identificationby combining CNN and BiLSTM [J]. Jiangsu Agricultural Sciences,2023,51(20):211–217. (in Chinese)
- [19] 袁培森,欧阳柳江,翟肇裕,等. 基于MobileNetV3Small-ECA的水稻病害轻量级识别研究[J]. 农业机械学报,2024,55(1):253–262.  
YUAN Peisen, OUYANG Liujiang, ZHAI Zhaoyu, et al. Lightweight identification of rice diseases based on improved ECA and MobileNetV3Small[J]. Transactions of the Chinese Society for Agricultural Machinery,2024, 55 (1): 253 – 262. ( in Chinese )
- [20] 宋玲,曹勉,胡小春,等. 基于YOLOX的复杂背景下木薯叶病害检测方法[J]. 农业机械学报,2023,54(3):301–307.  
SONG Ling, CAO Mian, HU Xiaochun, et al. Detection of cassava leaf diseases under complicated background based on YOLOX[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(3):301–307. (in Chinese)
- [21] 施杰,林双双,罗建刚,等. 基于YOLO v5s改进模型的玉米作物病虫害检测方法[J]. 江苏农业科学,2023,51(24):175–183.  
SHI Jie, LIN Shuangshuang, LUO Jian'gang, et al. Study on a detection method for crop diseases and insect pests based on YOLO v5s improved model[J]. Jiangsu Agricultural Sciences, 2023,51(24):175 – 183. (in Chinese)
- [22] REDMON J, FARHADI A. Yolov3: an incremental improvement[J]. arXiv preprint arXiv:1804.02767,2018.
- [23] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLO v4: optimal speed and accuracy of object detection[J]. arXiv preprint arXiv:2004.10934,2020.
- [24] ZOU X, WW Z, ZHOU W, et al. YOLOX – PAI: an improved YOLOX, stronger and faster than YOLO v6[J]. arXiv preprint arXiv:2208.13040,2022.
- [25] LI C, ZHOU A, YAO A. Omni-dimensional dynamic convolution[J]. arXiv preprint arXiv:2209.07947,2022.
- [26] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu:IEEE,2017:2117 – 2125.
- [27] TAN M, PANG R, LE Q V. Eficientdet: scalable and efficient object detection[C] // Prceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020:10781 – 10790.
- [28] JIANG Y, TAN Z, WANG J, et al. Giraffedet: a heavy-neck paradigm for object detection[J]. arXiv preprint arXiv:2202.04256, 2022.
- [29] XU X, JIANG Y, CHEN W, et al. Damo-YOLO: a report on real-time object detection design[J]. arXiv preprint arXiv: 2211.15444, 2022.
- [30] WANG X, SONG J. ICIoU: improved loss based on complete intersection over union for bounding box regression[J]. IEEE ACCESS,2021,9:105686 – 105695.
- [31] ZHANG Y F, REN W, ZH Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neuro Computing, 2022 , 506:146 – 157.
- [32] JIANG K L, XIE T Y, YAN R, et al. An attention mechanism-improved YOLO v7 object detection algorithm for hemp duck count estimation[J]. Agriculture,2022,12(10):1659.