

基于改进 YOLO v8 的轻量化稻瘟病孢子检测方法

罗斌^{1,2} 李家超^{1,2} 周亚男² 潘大字² 黄硕²

(1. 新疆农业大学机电工程学院, 乌鲁木齐 830052; 2. 北京市农林科学院智能装备技术研究中心, 北京 100097)

摘要: 稻瘟病由稻瘟病孢子通过空气进行传播,严重影响水稻产量,因此,稻瘟病孢子的检测对于稻瘟病早期诊断与防治具有重要作用。针对现有方法存在检测速度慢的问题,本研究基于 YOLO v8 模型提出了一种稻瘟病孢子检测方法 RBS-YOLO。首先,该算法在主干网络中引入 PP-LCNet 轻量化网络结构,减少模型每秒浮点运算次数并降低模型内存占用量,其次在颈部网络中引入高效多尺度注意力模块(Efficient multi-scale attention module, EMA),并将原损失函数改进为 WIOU 损失函数,提高了模型识别稻瘟病孢子的精确率与平均精度均值。改进后的 RBS-YOLO 模型精确率与平均精度均值分别为 97.3% 和 98.7%,满足稻瘟病孢子的检测需求,模型内存占用量与每秒浮点运算次数分别为 3.46 MB、 5.2×10^9 ,同 YOLO v8n 相比分别降低 41.8% 与 35.8%。RBS-YOLO 模型与当前主流的 YOLO v5s、YOLO v7、YOLO v8n 模型对比,每秒浮点运算次数分别降低 67.3%、95.1%、35.8%。研究结果表明 RBS-YOLO 模型能够满足稻瘟病孢子实时检测的需求,且有利于部署到移动端。

关键词: 稻瘟病孢子; 目标检测; YOLO v8; 轻量化; 注意力机制

中图分类号: TP391.41

文献标识码: A

文章编号: 1000-1298(2024)11-0032-07

OSID:



Lightweight Rice Blast Spores Detection Method Based on Improved YOLO v8

LUO Bin^{1,2} LI Jiachao^{1,2} ZHOU Ya'nan² PAN Dayu² HUANG Shuo²

(1. College of Mechanical and Electrical Engineering, Xinjiang Agricultural University, Urumqi 830052, China

2. Intelligent Equipment Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China)

Abstract: Rice blast is one of the most serious diseases of rice. It is caused by blast fungus and occurs in different growth stages of rice. The spores of blast can be transmitted through air, which seriously affects food production security. Therefore, the identification of blast spores plays an important role in the early diagnosis and control of rice blast. Based on the YOLO v8 model, an RBS-YOLO method for the detection of rice blast spores was proposed. Firstly, the algorithm introduced the PP-LCNet lightweight network in the backbone network, which used DepthSepConv as the basic block and reduced the computational effort of the model and the size of the model weight file, but hardly increased the inference time. Secondly, the efficient multi-scale attention module was introduced into the neck network, which reshaped some channels into batch dimensions and grouped the channel dimensions into multiple sub-features, so that the spatial semantic features were evenly distributed in each feature group. The information of each channel can be effectively preserved and the computational overhead can be reduced. Finally, the loss function of YOLO v8n was changed to WIOU loss function, which can reduce the impact of low-quality samples on the model during training. WIOU used dynamic non-monotone focusing mechanism to evaluate the quality of the anchor frame, and used gradient gain, which ensured the high-quality effect of the anchor frame and reduced the influence of harmful gradients. The accuracy and mean accuracy of model identification of rice blast spores were improved. The accuracy and average accuracy of the improved RBS-YOLO model were 97.3% and 98.7%, respectively, meeting the demand for the detection of rice blast spores. The weight file size and computation amount were 3.46 MB and 5.2×10^9 , respectively, which were 41.8% and 35.8% lower than that of YOLO v8n. In order to verify the detection performance of RBS-YOLO, under the same training environment and parameter configuration, the improved model was compared with the YOLO v5s, YOLO v7 and the original

收稿日期: 2023-12-06 修回日期: 2024-01-22

基金项目: 国家重点研发计划项目(2022YFD2002301)

作者简介: 罗斌(1981-),男,副研究员,主要从事农业智能装备研究,E-mail: luob@nrcita.org.cn

YOLO v8n model, and the computational load was reduced by 67.3%, 95.1% and 35.8%, respectively. Model weight file sizes were reduced by 10.14 MB, 67.84 MB, and 2.49 MB, respectively. The results showed that RBS - YOLO can meet the demand of real-time detection of rice blast spores, which was conducive to deployment to mobile terminals.

Key words: rice blast spores; target detection; YOLO v8; lightweight; attention mechanism

0 引言

水稻是我国最主要的粮食作物之一,全国有超过 60% 的人口以稻米为主食,水稻产量对于我国粮食安全至关重要^[1]。然而,水稻每年都会受到各种细菌、真菌和病毒病害的影响^[2],导致水稻产量下降。稻瘟病是最严重的水稻病害之一,由稻瘟病菌引起,发生于水稻的不同生长阶段,稻瘟病孢子可借助空气传播,防治难度大^[3-4]。目前,稻瘟病防治策略主要为喷洒农药和种植抗稻瘟病品种^[5]。但农药过度使用不仅增加生产成本,而且也对生态环境造成破坏。并且,稻瘟病菌复杂性和变异性导致不同水稻种植地区病原菌种群结构存在较大差异,抗稻瘟病品种只适合在有限地区种植几年^[6]。因此,实现稻瘟病孢子检测和计数,尽早地发现稻瘟病,对于稳定和提高水稻产量具有重要意义。

传统的孢子检测主要是由操作员在显微镜下对孢子进行计数,需要耗费大量的时间和精力。为实现孢子快速、精准、早期检测,学者提出了多种研究方法实现病菌孢子检测,例如分子生物学技术、微流控生物传感器技术等^[7-8]。然而,这些方法都耗时且需要昂贵的检测设备。随着计算机视觉技术的发展,图像处理技术与机器学习方法被应用于孢子检测研究。LEI 等^[9]基于形态特征和面积,通过数字图像处理技术,结合 K-均值聚类算法,实现小麦条锈病菌夏孢子的识别和计数。YANG 等^[10]提出距离变换-高斯滤波-分水岭算法分离稻瘟病孢子,该方法能够有效、快速地检测稻瘟病孢子。齐龙等^[11]通过 Canny 算子与形态特征对稻瘟病孢子进行分类,并通过改进分水岭算法对粘连孢子进行分离,实现稻瘟病孢子的自动检测与计数。虽然图像处理与传统机器学习技术在孢子检测研究中取得了一定成果,但是此方法只适用于背景简单且拥有明显特征的孢子检测。在复杂背景下识别特征不明显的孢子仍是一个具有挑战性的课题。

深度学习是机器学习的一个子领域,它可以自动从原始数据中学习特征,对高维特征进行多层卷积处理,大大提高了基于视觉的检测精度,具有较强的鲁棒性。近年来,深度学习技术已经广泛应用于农业领域^[12-15],显微镜成像技术与深度学习技术结

合,可以实现两者都无法单独完成的任务^[16],具有鲁棒性强、准确率高等优点。ZHANG 等^[17]将注意力机制模块和自适应特征融合机制融入到 YOLO 的特征金字塔结构中,实现复杂田间环境下小麦赤霉病孢子自动化检测。LI 等^[18]在骨干网络中引入多头自注意力机制,并结合加权双向特征金字塔网络 (Weighted bidirectional feature pyramid network),利用轻量级网络构造 GhostCSP,对颈部进行优化,最终实现黄瓜灰霉病孢子的自动检测。乔琛等^[19]在 YOLO v5 模型基础上,将原来的 C3 模块替换为 C3_Faster,并在主干网络中加入 NAM 注意力机制模块,实现对黄瓜霜霉病菌孢子的定量检测。

本文提出一种基于改进 YOLO v8 的稻瘟病孢子检测模型,将其命名为 RBS - YOLO。该算法首先引入 PP - LNet 轻量级网络降低模型每秒浮点运算次数。在颈部网络中引入高效多尺度注意力模块,并将 CIoU 损失函数改进为 WIOU 损失函数,有效降低模型每秒浮点运算次数,减少对模型检测精度的影响。最后通过消融试验与对比试验验证模型有效性,为水稻稻瘟病早期自动化防控提供理论基础。

1 材料和方法

1.1 图像数据采集

水稻稻瘟病病原菌为稻梨孢菌,试验菌株为 Guy11,从南京农业大学植物保护学院获得。将试验菌株接种至马铃薯葡萄糖琼脂培养基上,置于 28℃ 恒温培养箱中在黑暗环境下培养 7 d,培养基表面生成一层灰色霉菌。然后向马铃薯葡萄糖培养基中加入无菌水,并用移液枪反复冲洗表面菌丝。最后用纱布过滤菌丝,得到稻瘟病孢子悬浮液。使用配有 TP605100A 型工业相机的 MSD100 - 9 型显微镜捕获稻瘟病孢子显微图像,并通过 ImageView 图像采集软件显示在计算机上,如图 1 所示。显微镜使用 10 倍物镜,工业相机传感器尺寸为 0.4 英寸,靶面对角线为 7 mm,可捕获分辨率为 2 592 像素 × 1 944 像素的显微图像。将稻瘟病孢子悬浮液滴在载玻片中央,盖上盖玻片,并用上述设备捕获图像,最终共得到 1 000 幅稻瘟病孢子显微图像。

采集显微图像时,图像质量会受到光照、对焦等问题的影响,本研究采用随机颜色增强、随机对比度




图1 稻瘟病孢子图像采集系统

Fig.1 Blast spore image acquisition system

1. 计算机 2. 图像采集软件界面 3. 显微镜 4. 工业相机

增强、随机高斯模糊的数据增强方式对数据集进行扩充,最终得到 4 000 幅稻瘟病孢子显微图像。使用图像注释工具 LabelImg 标注图像中的稻瘟病孢子,每幅图像会自动生成一个包含目标类别信息和位置信息的 txt 文件。扩充后的数据按照 8:1:1 的比例划分为训练集、验证集、测试集,最终得到训练集、验证集、测试集图像数量为 3 200、400、400 幅。

1.2 YOLO v8 模型

YOLO (You only look once)^[20],指只需要浏览一次就可以识别出图中物体的类别和位置,它是一种典型的单阶段检测算法,使用锚框、分类和回归对目标进行定位。与 R-CNN、Fast R-CNN、Mask R-CNN 等两阶段算法相比^[21-23],该算法具有更好的实时性和更快的检测速度。2023 年 1 月 YOLO v8 正式发布,提供了一个全新的 SOTA (State-of-the-art result) 模型,检测精度得到了很大提高。YOLO v8 是 Ultralytics 团队在 YOLO v5 的基础上,引入新的改进模块,进一步提升了模型检测性能。YOLO v8 网络模型主要包括输入端 (Input)、主干网络 (Backbone)、颈部网络 (Neck) 和头部网络 (Head)。

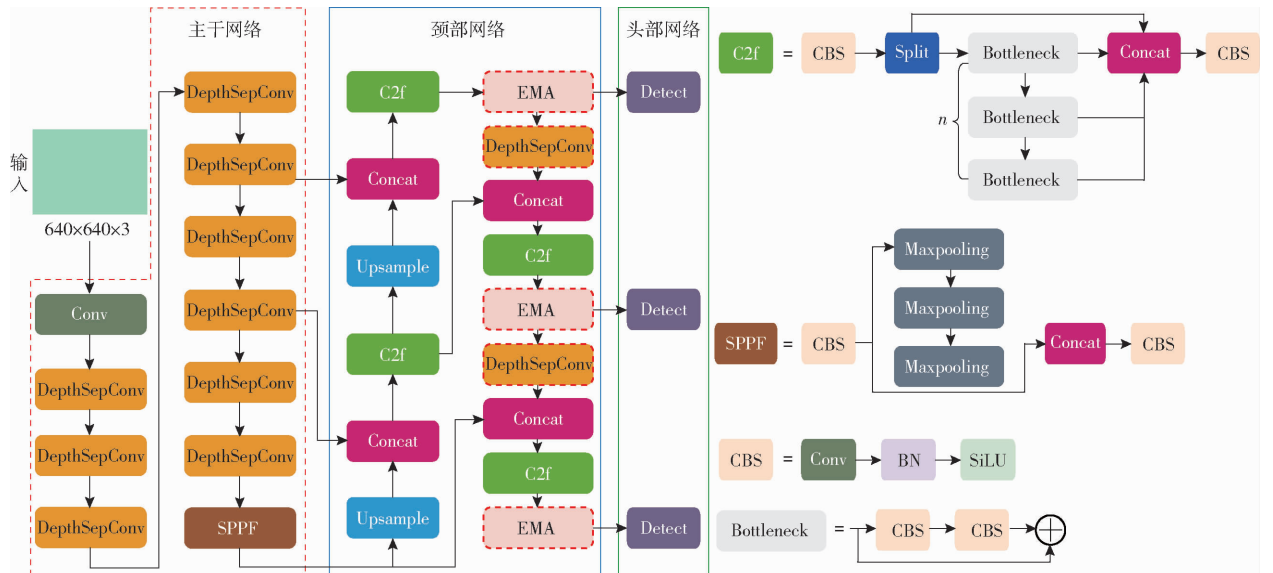


图2 RBS-YOLO 模型结构图

Fig.2 RBS-YOLO model structure

具体改进为使用 C2f 模块替换主干网络的 C3 模块;头部网络使用解耦头将分类与检测进行分离,将目标检测方法由 Anchor-Based 替换为 Anchor-Free;回归损失函数在原来 CIUO 的基础上加入分布式聚焦损失函数 (DIOU)。

2 RBS-YOLO 检测模型

现有的基于深度学习的卷积神经网络具有较高的检测精度,但模型的计算复杂度高、体积大、检测速度慢。为减小模型和体积以及降低模型计算复杂度,在 YOLO v8 的主干网络中引入 PP-LCNet 轻量化网络结构^[24]。其次,在颈部网络中引入高效多尺度注意力模块 (Efficient multi-scale attention module, EMA)^[25],并将 CIUO 损失函数替换为 WIOU 损失函数^[26],用于提高模型的检测精度。改进后的 YOLO v8 模型命名为 RBS-YOLO,模型结构如图 2 (图中 Conv 为卷积,DepthSepConv 为深度分离可卷积,SPPF 为池化层,Concat 为特征拼接层,Upsample 为上采样层,Split 为分割操作,Maxpooling 为最大池化层,BN 为批量归一化,SiLU 为激活函数)所示。

2.1 PP-LCNet

PP-LCNet 是百度提出的一种基于深度学习加速库 (MKLDNN) 的轻量级卷积神经网络。该网络可以在不增加推理时间的情况下,进一步提升模型性能,PP-LCNet 的网络参数如表 1 (Conv2D 为二维卷积,GAP 为全局平均池化,NBN 表示批量归一化)所示。该网络使用深度分离可卷积模块 (DepthSepConv) 作为基本块,如图 3 (图中 D-Conv 为逐通道卷积,BN 为批量归一化,H-Swish 为激活函数,SE 为注意力机制,P-Conv 为逐点卷积)所示。

该模块由深度卷积、逐点卷积以及 SE (Squeeze-and-excitation) 模块组成^[27-28]。将基础网络中的激活函数由 ReLU 替换为 H-Swish, 模型性能得到提高, 但几乎不增加推理时间。

表 1 PP-LCNet 网络参数

Tab.1 PP-LCNet network parameters

输入	操作	步长	卷积核尺寸	SE
$224^2 \times 3$	Conv2D	2	3×3	×
$112^2 \times 6$	DepthSepConv	1	3×3	×
$112^2 \times 32$	DepthSepConv	2	3×3	×
$56^2 \times 64$	DepthSepConv	1	3×3	×
$56^2 \times 64$	DepthSepConv	2	3×3	×
$28^2 \times 128$	DepthSepConv	1	3×3	×
$28^2 \times 128$	DepthSepConv	2	3×3	×
$14^2 \times 256$	$5 \times$ DepthSepConv	1	5×5	×
$14^2 \times 256$	DepthSepConv	2	5×5	√
$7^2 \times 512$	DepthSepConv	1	5×5	√
$7^2 \times 512$	GAP	1	7×7	×
$1^2 \times 512$	Conv2D, NBN	1	1×1	×

注：“√”表示使用此模块，“×”表示不使用此模块。下同。



图 3 深度分离可卷积模块

Fig. 3 Deep separation convolution module

2.2 EMA 模块

在颈部网络的 C2f 模块后加入跨空间学习的高效多尺度注意模块 (EMA), 如图 4 (“//”表示将通道数 C 划分为 G 组) 所示。对于任何给定的输入特征图, EMA 将其划分为跨通道维度方向的 G 个子特征, 用于学习不同的语义, 并使用 3 个平行的路径提取分组特征图的注意力权重, 如图 4 (X Avg Pool 为沿水平方向平均池化, Y Avg Pool 为沿垂直方向平均池化, Sigmoid 为激活函数, Softmax 为归一化指数函数) 所示。其中在两个 1×1 分支中采用一维全局平均池化操作分别对两个空间方向的通道进行编码, 在 3×3 分支中仅堆叠一个 3×3 卷积核以捕获多尺度特征。将 G 组重新整形和置换到批处理维度中, 并将输入张量重新定义。一方面, 将两个编码特征沿图像高度方向连接起来, 并使其共享相同的 1×1 卷积, 将 1×1 卷积的输出分解为两个向量之后, 采用两个非线性 Sigmoid 函数来拟合线性卷积的二维二项分布。另一方面, 3×3 分支经由 3×3 卷积捕获局部跨通道交互以扩大特征空间。然后, 利用二维全局平均池化在 1×1 与 3×3 分支的输出中编码全局空间信息。为了有效计算, 在二维全局平均池化的输出处采用二维高斯映射的自然非线性函数 Softmax 以拟合线性变换。最后, 将生成的两

个空间注意力权重与 Sigmoid 函数进行聚合, 计算出每组内的输出特征图。

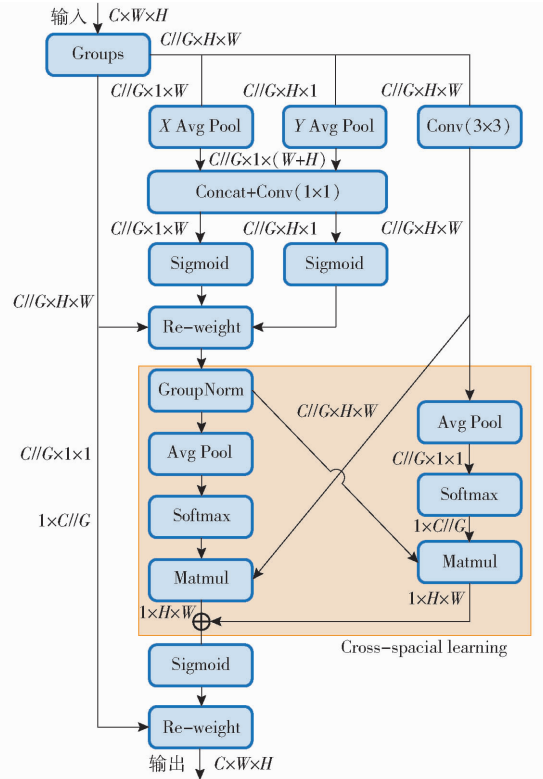


图 4 EMA 结构图

Fig. 4 EMA structure diagram

2.3 WIUO 损失函数

深度学习模型通过损失函数执行梯度下降以优化模型参数, 边界框损失函数作为目标检测损失函数的重要组成部分, 其良好的定义将为目标检测模型带来显著的性能提升。目标检测训练集中含有低质量样本, 如果一味地强化边界框对低质量示例的回归, 显然会影响模型检测性能的提升。WIUO 使用动态非单调聚焦机制对锚框质量进行评估, 并使用梯度增益, 在保证高质量锚框效果的同时减少有害梯度的影响, 可提高模型整体性能。WIUOv1 构造基于注意力的边界框损失, 假设 (x, y) 在目标框的对应位置为 (x_{gt}, y_{gt}) , W_g, H_g 为预测框和真实框的最小外接矩形的宽、高, IOU 为交并比, WIUOv1 公式为

$$L_{WIUOv1} = R_{WIUO} L_{IOU} \quad (1)$$

$$\text{其中 } R_{WIUO} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \quad (2)$$

$$L_{IOU} = 1 - IOU \quad (3)$$

式中 * ——从计算图中分离

为防止低质量样本产生较大的有害梯度, 定义离群度 β 以描述锚框质量, 计算式为

$$\beta = \frac{L_{IOU}^*}{L_{IOU}} \quad (4)$$

对离群度较大的锚框分配较小的梯度增益,并利用离群度与 WIOU_{v1} 构造 WIOU_{v3}, 计算式为

$$L_{WIOUv3} = rL_{WIOUv1} \quad (5)$$

其中
$$r = \frac{\beta}{\delta\alpha^{\beta-\delta}} \quad (6)$$

式中 δ 与 α 是一组超参数,用来控制离群度 β 和梯度增益 r 的映射。

3 结果与分析

3.1 参数配置及评价指标

试验所用操作系统为 Windows 10, CPU 型号为 Intel(R) Xeon(R) Gold 6133 CPU @ 2.50 GHz, GPU 型号为 NVIDIA GeForce RTX 4090, 运行内存为 128 GB, 编程语言为 Python 3.9, 深度学习框架为 Pytorch 2.0.0, CUDA 及 GPU 加速库 cuDNN 版本分别为 11.8 和 8.9.1。训练时图像尺寸调整为 640 像素 \times 640 像素, 初始学习率设置为 0.01, 批量大小设置为 32, 工作线程数设置为 16, 动量设置为 0.937, 迭代次数为 150, 采用随机梯度下降 (Stochastic gradient descent, SGD) 作为优化器。采用精确率 (Precision, P)、平均精度均值 (mean average precision, mAP)、每秒浮点运算次数、模型内存占用量评估模型性能。

3.2 消融试验

以 YOLO v8n 作为基础网络, 并对主干网络、颈部网络及损失函数进行了改进, 为评估这些改进方法的有效性, 采用消融试验进行验证, 试验结果如表 2 所示。从表 2 中可知, 在主干网络中引入 PP-LCNet 轻量化网络结构后, 模型内存占用量与每秒浮点运算次数显著下降, 与 YOLO v8n 相比, 分别下降 2.53 MB 与 3.1×10^9 , 这是因为使用 DepthSepConv 作为主干网络的基本块后, 降低了特征提取过程中产生的参数量, 但参数量降低, 同样也会对特征融合与目标检测产生不良影响, 导致最终模型的精确率与平均精度均值也有所下降。为减小引入轻量化网络结构所带来的精确率与平均精度均值损失, 本研究在 YOLO v8n 颈部网络中引入 EMA 注意力机制模块, 并将边界框损失函数改进为 WIOU, 与轻量化的 YOLO v8 相比, 精确率与平均精度均值分别提高 2.2、0.6 个百分点, 其原因在于 EMA 模块能够捕捉像素级的成对关系, 为高级特征图产生更好的像素级注意力。此外, WIOU 降低了边框对低质量样本的回归, 提高了检测器整体性能。最终改进后的 RBS-YOLO 与 YOLO v8n 相比, 模型内存占用量与每秒浮点运算次数分别下降 41.8% 与 35.8%, 精确率与平均

精度均值分别为 97.3% 与 98.7%, 与 YOLO v8n 相比略有下降。

表 2 消融试验结果

Tab.2 Ablation test result

PP-LCNet	EMA Attention module	WIOU	精确率/%	平均精度均值/%	模型内存占用量/MB	每秒浮点运算次数
×	×	×	98.6	99.2	5.95	8.1×10^9
√	×	×	95.1	98.1	3.42	5.0×10^9
√	√	×	96.7	98.4	3.45	5.2×10^9
√	√	√	97.3	98.7	3.46	5.2×10^9

3.3 不同检测模型综合对比试验

为进一步验证改进后的 RBS-YOLO 模型的检测性能, 将改进的模型与 YOLO v5s、YOLO v7 与原始 YOLO v8n 模型对比, 为保障试验结果的可信度, 所有模型均在相同的训练环境与参数配置下运行, 最终对比结果如表 3 所示。由表 3 可知, 各个模型的精确率和平均精度均值较为接近, YOLO v7 最高, 分别达到 99.4% 和 99.6%, 比本文提出的 RBS-YOLO 仅高出 2.1、0.9 个百分点。但模型内存占用量与每秒浮点运算次数相差巨大, 本文提出的 RBS-YOLO 模型内存占用量仅 3.46 MB, 远小于其他模型, 便于部署到移动端。每秒浮点运算次数直接决定了模型检测速度, RBS-YOLO 的每秒浮点运算次数为 5.2×10^9 , 与 YOLO v5s、YOLO v7 和 YOLO v8n 相比, 分别降低 67.3%、95.1%、35.8%。图 5 (图中黄色方框表示错检, 紫色方框表示漏检) 为 5 个模型对稻瘟病孢子检测的结果, 其中 YOLO v8-PP 表示用 PP-LCNet 替换 YOLO v8n 主干网络模型。分析图 5b 可知, 由于显微图像背景复杂, 且稻瘟病孢子目标较小, YOLO v5s 将形状与稻瘟病孢子相似的杂质错检, 还将受杂质重叠影响的孢子漏检。图 5c 中 YOLO v7 模型也出现了错检现象, 结合其拥有良好的精确率与平均精度均值, 分析其原因为训练过程中出现了过拟合问题。分析图 5d、5e、5f 可知, 进行初步轻量化改进后的 YOLO v8-PP 模型相比于 YOLO v8n 模型检测性能下降, 出现了漏检现象, 而

表 3 不同检测模型综合对比结果

Tab.3 Comprehensive comparison results of different models

模型	精确率/%	平均精度均值/%	模型内存占用量/MB	每秒浮点运算次数
YOLO v5s	94.6	97.7	13.60	1.59×10^{10}
YOLO v7	99.4	99.6	71.30	1.05×10^{11}
YOLO v8n	98.6	99.2	5.95	8.10×10^9
RBS-YOLO	97.3	98.7	3.46	5.20×10^9

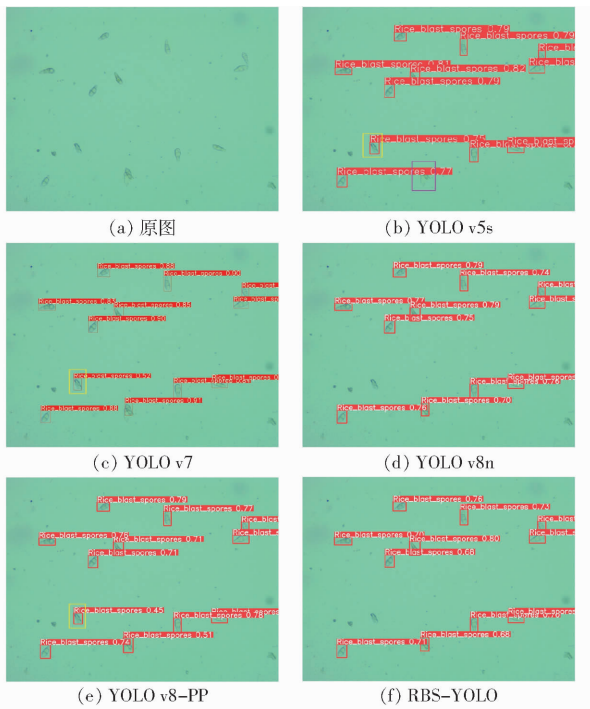


图 5 不同模型检测稻瘟病孢子结果

Fig. 5 Different models used to detect rice blast spores

本文提出的 RBS - YOLO 模型的表现效果与 YOLO v8n 相同,可以识别出全部稻瘟病孢子,仅检测出的目标置信度略有降低,这进一步体现出本文对 YOLO v8 - PP 模型进行的改进十分必要。综上所述,本研究提出的 RBS - YOLO 模型在保证高精度前提下,模型内存占用量最小,每秒浮点运算次数最

少,在稻瘟病孢子识别方面综合性能最好,能够满足实时检测需求,有利于部署到移动端。

4 结论

(1)提出了一种改进的轻量化 YOLO v8 模型 RBS - YOLO,用于稻瘟病孢子检测。该模型将 YOLO v8 原始模型的主干网络替换为轻量级网络 PP - LCNNet。为减轻替换轻量级网络带来的精确率损失,在颈部网络中引入 EMA 注意力机制模块,并将边界框损失函数替换为 WIOU。

(2)设置消融试验来验证各改进模块对模型的影响,由试验结果可知,PP - LCNNet 可显著降低模型内存占用量与每秒浮点运算次数,但同时也会降低模型精确率与平均精度均值,引入 EMA 注意力机制与改进损失函数后,模型精度有所提升,最终改进后的 RBS - YOLO 模型与原始 YOLO v8n 模型相比,模型内存占用量与每秒浮点运算次数分别下降 41.8% 与 35.8%,精确率与平均精度均值略有下降。

(3)在相同训练环境与参数配置下,将改进后模型与 YOLO v5s、YOLO v7、原始 YOLO v8n 模型进行对比试验。结果表明,RBS - YOLO 在保证较高检测精度的前提下每秒浮点运算次数最少,与上述模型相比分别降低 67.3%、95.1%、35.8%。充分证明 RBS - YOLO 能够满足实时检测需求,有利于部署到移动端。

参 考 文 献

- [1] 朱德峰,张玉屏,陈惠哲,等. 中国水稻栽培技术发展展望[J]. 中国稻米,2021,27(4):45-49.
ZHU Defeng, ZHANG Yuping, CHEN Huizhe, et al. Development and prospect of rice cultivation technology in China[J]. China Rice, 2021, 27(4):45-49. (in Chinese)
- [2] 崔金荣,郑鸿,谭建伟,等. 基于智能化技术的水稻常见病害检测研究进展[J]. 智慧农业导刊,2022,2(13):13-15.
CUI Jinrong, ZHENG Hong, TAN Jianwei, et al. Research progress of rice common disease detection based on intelligent technology[J]. Journal of Intelligent Agriculture, 2022, 2(13):13-15. (in Chinese)
- [3] KUMAR S, KASHYAP P L, MAHAPATRA S, et al. New and emerging technologies for detecting *Magnaporthe oryzae* causing blast disease in crop plants[J]. Crop Protection, 2021, 143: 105473.
- [4] 胡小平,户雪敏,马丽杰,等. 作物病害监测预警研究进展[J]. 植物保护学报,2022,49(1):298-315.
HU Xiaoping, HU Xuemin, MA Lijie, et al. Research progress of crop disease monitoring and early warning[J]. Plant Protection Journal, 2022, 49(1):298-315. (in Chinese)
- [5] KE L, XIAO L, BINGKAI L, et al. Diagnosis and application of rice diseases based on deep learning[J]. PeerJ. Computer Science, 2023, 9:e1384.
- [6] 郑盛友. 水稻稻瘟病综合防治技术及其推广策略[J]. 南方农业,2022,16(4):66-68.
ZHENG Shengyou. Technology of rice blast control and its spreading strategy[J]. Southern Agriculture, 2022, 16(4):66-68. (in Chinese)
- [7] SUN G, LIU J, LI G, et al. Quick and accurate detection and quantification of *Magnaporthe oryzae* in rice using real-time quantitative polymerase chain reaction[J]. Plant Disease, 2015, 99(2): 219-224.
- [8] 杨宁,王盼,张荣标,等. 基于富集微流控芯片的稻曲病菌孢子光电检测方法[J]. 农业工程学报,2017,33(20):161-168.
YANG Ning, WANG Pan, ZHANG Rongbiao, et al. Photoelectric detection method for false smut fungal spore based on enrichment microfluidic chip[J]. Transactions of the CSAE, 2017, 33(20):161-168. (in Chinese)
- [9] LEI Y, YAO Z, HE D. Automatic detection and counting of urediniospores of *Puccinia striiformis* f. sp. tritici using spore traps and image processing[J]. Scientific Reports, 2018, 8(1): 13647.

- [10] YANG N, QIAN Y, EL-MESERY H S, et al. Rapid detection of rice disease using microscopy image identification based on the synergistic judgment of texture and shape features and decision tree-confusion matrix method[J]. *Journal of the Science of Food and Agriculture*, 2019, 99(14): 6589 – 6600.
- [11] 齐龙, 蒋郁, 李泽华, 等. 基于显微图像处理的稻瘟病菌孢子自动检测与计数方法[J]. *农业工程学报*, 2015, 31(12): 186 – 193.
QI Long, JIANG Yu, LI Zehua, et al. Automatic detection and counting method of blast fungus spores based on microscopic image processing[J]. *Transactions of the CSAE*, 2015, 31(12): 186 – 193. (in Chinese)
- [12] 张俊宁, 毕泽洋, 闫英, 等. 基于注意力机制与改进 YOLO 的温室番茄快速识别[J]. *农业机械学报*, 2023, 54(5): 236 – 243.
ZHANG Junning, BI Zeyang, YAN Ying, et al. Rapid recognition of greenhouse tomato based on attention mechanism and improved YOLO[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(5): 236 – 243. (in Chinese)
- [13] 黄家才, 唐安, 陈光明, 等. 基于 Compact – YOLO v4 的茶叶嫩芽移动端识别方法[J]. *农业机械学报*, 2023, 54(3): 282 – 290.
HUANG Jiakai, TANG An, CHEN Guangming, et al. Mobile end identification method of tea buds based on Compact-YOLO v4[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(3): 282 – 290. (in Chinese)
- [14] 宋怀波, 马宝玲, 尚钰莹, 等. 基于 YOLO v7 – ECA 模型的苹果幼果检测[J]. *农业机械学报*, 2023, 54(6): 233 – 242.
SONG Huaibo, MA Baoling, SHANG Yuying, et al. Detection of young apple fruits based on YOLO v7 – ECA model[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(6): 233 – 242. (in Chinese)
- [15] 赵辉, 黄鏢, 王红君, 等. 基于改进 YOLO v7 的农田复杂环境下害虫识别算法研究[J]. *农业机械学报*, 2023, 54(10): 246 – 254.
ZHAO Hui, HUANG Biao, WANG Hongjun, et al. Research on pest recognition algorithm in farmland complex environment based on improved YOLO v7[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(10): 246 – 254. (in Chinese)
- [16] DE HAAN K, RIVENSON Y, WU Y, et al. Deep-learning-based image reconstruction and enhancement in optical microscopy [J]. *Proceedings of the IEEE*, 2019, 108(1): 30 – 50.
- [17] ZHANG D Y, ZHANG W, CHENG T, et al. Detection of wheat scab fungus spores utilizing the Yolov5 – ECA – ASFF network structure[J]. *Computers and Electronics in Agriculture*, 2023, 210: 107953.
- [18] LI K, ZHU X, QIAO C, et al. The gray mold spore detection of cucumber based on microscopic image and deep learning[J]. *Plant Phenomics*, 2023, 5: 0011.
- [19] 乔琛, 韩梦瑶, 高苇, 等. 基于 Faster – NAM – YOLO 的黄瓜霜霉病菌孢子检测[J]. *农业机械学报*, 2023, 54(12): 288 – 299.
QIAO Chen, HAN Mengyao, GAO Wei, et al. Detection of cucumber downy mildew spores based on Faster – NAM – YOLO [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(12): 288 – 299. (in Chinese)
- [20] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 779 – 788.
- [21] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2014: 580 – 587.
- [22] GIRSHICK R. Fast R – CNN[C]//*Proceedings of the IEEE International Conference on Computer Vision*, 2015: 1440 – 1448.
- [23] HE K, GKIOXARI G, DOLLAR P, et al. Mask R – CNN[C]//*Proceedings of the IEEE International Conference on Computer Vision*, 2017: 2961 – 2969.
- [24] CUI C, GAO T, WEI S, et al. PP – LNet: a lightweight CPU convolutional neural network[J]. *arXiv Preprint*, arXiv:2109.15099, 2021.
- [25] OUANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning[C]//*2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2023: 1 – 5.
- [26] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: boundingbox regression loss with dynamic focusing mechanism[J]. *arXiv Preprint*, arXiv:2301.10051, 2023.
- [27] HOWARD A G, ZHU M, CHEN B, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications [J]. *arXiv Preprint*, arXiv:1704.04861, 2017.
- [28] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 7132 – 7141.