

基于 YOLOv8-FECA 的密集场景下小麦赤霉病孢子目标检测

张东彦^{1,2}, 高 玥², 程 涛¹, 胡根生², 杨 雪³,
乔红波⁴, 郭 伟⁴, 谷春艳^{3*}

(1. 西北农林科技大学机械与电子工程学院, 杨凌 712100; 2. 安徽大学, 农业生态大数据分析与应用技术
国家地方联合工程研究中心, 合肥 230601; 3. 安徽省农业科学院植物保护与农产品质量安全研究所,
合肥 230605; 4. 河南农业大学信息与管理科学学院, 郑州, 450002)

摘 要: 针对小麦赤霉病孢子图像中密集分布小目标的漏检错检问题, 该研究设计了一种针对该场景下小目标检测模型 YOLOv8-FECA。以 YOLOv8 为基准模型, 先添加新的小目标检测层, 以此增强网络对更小目标语义信息的捕捉以及提高其特征描述的准确性; 其次, 构建融合特征的焦点注意力机制 (focal efficient channel attention module, FECA) 以实现对小目标和密集分布目标的关注; 再次, 引入 Wise-IoU Loss 与 DFL Loss 结合作为边界框的回归损失, 提高模型的收敛能力以及对边界框预测的准确性; 最后, 在不同密集场景和不同光线环境下验证了模型的鲁棒性。结果表明, 优化后模型 YOLOv8-FECA 相比 YOLOv8 在孢子数据集中的平均检测精度均值 mAP@0.5 提高了 4.3%, 达到 96.8%, 且改进模型的检测效率也达到实时检测要求。该研究设计的 YOLOv8-FECA 网络模型在保持高性能的同时能够有效提升密集场景小目标检测的精度, 为其他作物病害孢子的检测提供了新思路。

关键词: 小麦赤霉病; 孢子; 密集场景; 小目标检测; YOLOv8; 显微图像

doi: 10.11975/j.issn.1002-6819.202406149

中图分类号: S126

文献标志码: A

文章编号: 1002-6819(2024)-21-0127-10

张东彦, 高玥, 程涛, 等. 基于 YOLOv8-FECA 的密集场景下小麦赤霉病孢子目标检测[J]. 农业工程学报, 2024, 40(21): 127-136. doi: 10.11975/j.issn.1002-6819.202406149 <http://www.tcsae.org>
ZHANG Dongyan, GAO Yue, CHENG Tao, et al. Detection of wheat scab spores in dense scene based on YOLOv8-FECA[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(21): 127-136. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202406149 <http://www.tcsae.org>

0 引 言

小麦赤霉病, 又称麦穗枯、烂麦头或红麦头, 具有间歇性暴发且可防不可治的特点。它不仅是全球性的重大病害, 也是影响中国粮食作物生产安全最严重的病害之一, 被列为国家一类农作物病害^[1]。近年来, 受到气候及农耕方式的影响, 中国麦区赤霉病的流行频率逐渐上升^[2]。赤霉病的主要发生地从原来的长江中下游流域麦区逐步扩展至黄河南部, 同时西北麦区也显著加剧^[3]。在一般的流行年份中, 由此导致的产量损失大约占总产量的 15%, 大流行年份可能导致小麦绝收^[4-5]。此外, 感染赤霉病的谷粒会生成一系列有害毒素, 其中包括脱氧雪腐镰刀菌烯醇等化合物, 这些毒素的存在会污染小麦, 对小麦品质和食品安全构成严重威胁^[6]。

小麦赤霉病主要由禾谷镰刀菌 (*Fusarium graminearum*, fg) 和亚洲镰刀菌 (*Fusarium asiaticum*, fa) 诱发, 也被称

为镰孢菌, 这种真菌能产生大量的孢子, 通过风、水、农机具等途径在田间传播。镰孢菌孢子的传播是小麦赤霉病传播和感染的关键环节。因此, 及早准确地检测病原菌孢子浓度对实现小麦赤霉病的早期预警、保护小麦产量和品质、保障食品安全具有重要意义。

传统的病原菌孢子检测方法, 如显微镜观察和培养基分离, 通常耗时且技术要求高, 这对于快速响应和处理大范围作物病害传播构成了挑战^[7-8]。随着人工智能技术的发展, 尤其是计算机视觉和深度学习的进步, 为高效准确识别病原菌孢子提供了一种新方法, 有助于实现对病害发生发展的 24 h 内实时连续监控, 揭示病害发生的环境因素和传播规律, 为病害的预防和控制提供数据支持, 有助于制定更有效的农业管理和防控策略^[9]。李小龙等^[10]基于最近邻插值法的缩放处理、基于 K-means 聚类算法的分割处理、形态学操作修饰和分水岭分割等一系列的处理, 实现小麦条锈病夏孢子的自动计数和标记。齐龙等^[11]提出一种改进分水岭算法对稻瘟病菌孢子自动检测和计数, 通过经典的图像处理提取了椭圆度、复杂度和最小外接矩形宽度等形状特征参数。

尽管传统的图像处理方法已经取得了一定的进展, 但需要手动选择和设计孢子特征, 还需要领域专家的知识 and 经验。当前热门的深度学习则通过深层神经网络自动学习特征, 不需要手动提取特征, 能够更有效地从数

收稿日期: 2024-06-21 修订日期: 2024-07-31

基金项目: 国家自然科学基金面上项目 (42271364); 河南省重点研发专项 (241111110800); 安徽省农业科技成果转化应用专项 (2024ZH004)

作者简介: 张东彦, 博士, 教授, 博士生导师, 研究方向为农业人工智能。

Email: hello-lion@hotmail.com

*通信作者: 谷春艳, 副研究员, 研究方向为农作物病害诊断、鉴定及防控。Email: guchunyan0408@163.com

据中学习和提取高级特征^[12]。雷雨等^[13]针对小麦条锈病真菌夏孢子自动检测存在严重的误检和漏检问题,提出一种基于改进 CenterNet 的小麦条锈病菌夏孢子自动检测方法,其识别精度达到了 98.77%。LIANG 等^[14]采用改进 U-net 对小麦白粉病孢子进行分割计数,达到了 91.4% 的准确率,但图片中孢子数太少,不适用于多孢子粘连计数。YUAN 等^[15]提出了一种基于“主干-FPN-头”整体架构赤霉病孢子检测方法 SporeDet,但其目的仅是为了检测出赤霉病孢子,并未考虑影响其检测效果的因素,其最优平均检测精度为 88%。

鉴于田间赤霉病孢子图像中存在孢子种类多、目标小、背景复杂以及存在密集和遮挡的环境特点,已有模型未考虑复杂密集场景下的孢子图像进行模型构建。同时,本研究对象赤霉病孢子从相对角度看属于小目标问题^[16-18],在进行目标检测时存在一定检测难度。针对以上研究背景,本研究设计了一种密集场景小目标检测模型 YOLOv8-FECA,目的是减少和避免孢子检测的错检漏检问题,以实现小麦赤霉病孢子在密集场景下的小目标检测优化,从而为田间小麦赤霉病孢子的自动检测及赤霉病的早期预警提供技术支持。

1 材料与数据

1.1 孢子图像采集

试验所使用的小麦赤霉病孢子显微图像均在安徽省农业科学院植保所实验室拍摄。孢子悬浮液的制作步骤如下:抽取并切碎在马铃薯葡萄糖琼脂(potato dextrose agar, PDA)培养基上培养的菌丝块,放入装有马铃薯葡萄糖肉汤培养基(potato dextrose broth, PDB)的透明培养瓶中,置于 28℃ 恒温摇床中充分震荡,培养一定生长时间后制备所需的小麦赤霉病孢子悬浮液。试验选用引起小麦赤霉病的两种主要镰刀型病原菌(亚洲镰刀菌和禾谷镰刀菌),分别记作 fa 和 fg。此外,试验还引入多种杂菌孢子(如茄镰刀菌、梨孢镰刀菌、炭疽孢菌和多毛孢菌等)以模拟真实田间环境,提升数据集复杂度。这些杂菌孢子在形态上与镰刀菌孢子相似,但在颜色、大小、形状上存在细微差异。图 1 展示了多类混合孢子显微图像。

孢子显微图像由 Leica MC190 HD 显微镜数码摄像头拍摄。该设备配有 1000 万像素的相机,通过与 LAS 软件搭配使用,提供高质量和高色彩保真度的图像。在拍摄过程中,使用无菌滴管吸取适量稀释后的孢子悬浮液,滴在干净的载玻片中央,用盖玻片覆盖,再将其置于显微镜载物台。先用低倍镜确定目标区域,再选择 40×10 倍放大倍数,调整图像焦距和曝光参数,借助 LAS 软件寻找清晰稳定的小麦赤霉病孢子群后进行拍摄。最终,采集到 7043 张混合真菌孢子显微图像(分辨率为 1600×1200 像素),并结合植保专家知识制作了赤霉病孢子显微图像数据集,包含复杂背景、多类别孢子密集分布和遮挡图像等,用于训练和验证模型的检测能力和鲁棒性。

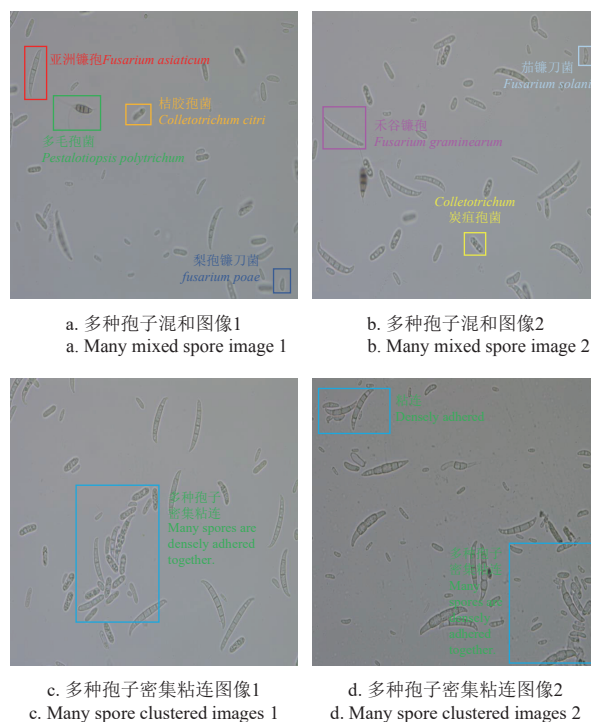


图 1 多类混合孢子显微图像 (40×10 倍)

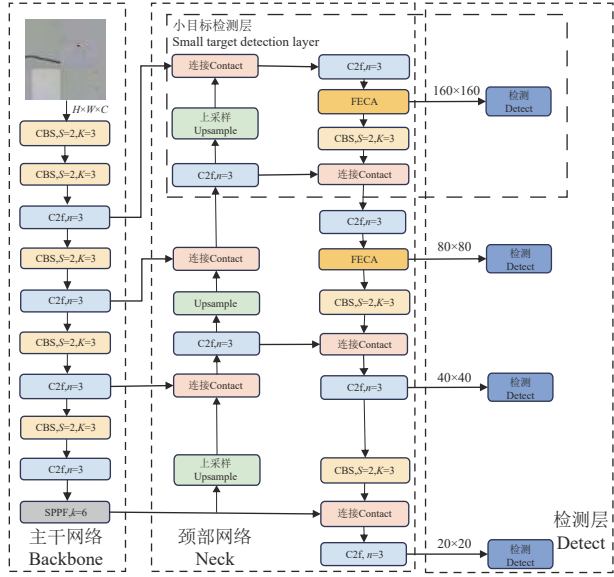
Fig.1 Microscopic image of different mixed spores (40 × 10 times)

1.2 孢子数据集扩充及划分

为了防止网络训练过程中发生过拟合现象,提升网络泛化性和检测性能,本研究对采集的原始数据集随机进行了基于常规和图像混叠两种方式的数据增强,通过模拟田间环境和实际检测环境下的各种光照、角度以及噪声因素进行数据预处理,最终将数据集扩大至原来的两倍。常规的数据增强方式包含图形的翻转、多角度旋转、随机裁剪、引入高斯噪声和亮暗变换等。基于图像混叠的数据增强包括 Mosaic 数据增强和 Mixup 数据增强。经扩充后共得到 14086 幅显微孢子图像,然后按照 8:1:1 的比例将数据集划分成训练集(11268 幅)、测试集(1409 幅)及验证集(1409 幅)。同时利用 Labelme 工具对数据进行标注,标签分别为 fa(亚洲镰孢)和 fb(禾谷镰孢)。

2 方法

针对小目标检测以及目标在密集场景检测中存在的识别率低等问题,设计了一种孢子图像目标检测模型 YOLOv8-FECA(图 2)。首先添加新的小目标检测层,以增强网络对小孢子目标语义信息的捕捉以及提高其特征描述的准确性;其次,构建融合特征的焦点注意力机制(focal efficient channel attention module, FECA)以实现对孢子小目标和密集分布目标的关注;再次,引入 Wise-IoU Loss 与 DFL Loss 结合作为边界框的回归损失,提高模型的收敛能力以及对边界框预测的准确性。最后在小麦赤霉病孢子显微数据集上与多种模型进行对比试验,在不同密集场景和不同光线环境下进行模型鲁棒性验证,评估 YOLOv8-FECA 改进模型的性能。



注: H 表示输入图像高度, W 表示输入图像宽度, C 表示输入图像通道数, S 表示网络中某一层的步幅, K 表示卷积核大小, n 表示表示某个层或模块中要使用的卷积核或滤波器的数量。CBS 表示逐行批量归一化和规模转移。C2f 表示“Channel to Feature”的转化, 用于提升特征提取能力。SPPF 表示空间金字塔池融合模块。Upsample 表示上采样。 k 表示一个相对的尺度参数, 用于控制池化层的输出尺寸和结构。FECA 表示基于 CBAM 和 ECA 注意力机制改进的焦点注意力机制。

Note: H represents the height of the input image, W represents the input image, C represents the number of input image channels, S represents the stride of a layer in the network, K represents the size of the convolution kernel, n represents the number of convolution kernel or filter to be used in a layer or module. CBS stands for Channel-wise Batch Normalization and Scale Shift. C2f represents the transformation of "Channel to Feature", which is used to improve feature extraction capability. SPPF represents the Spatial Pyramid Pooling Fusion module. Upsample represents upsampling. k represents a relative scale parameter to control the output size and structure of the pooling layer. FECA represents an improved focus attention mechanism based on CBAM and ECA attention mechanisms.

图 2 YOLOv8-FECA 网络结构

Fig.2 YOLOv8-FECA network structure

2.1 添加小目标检测层

在 YOLOv8 网络中, 经过特征融合后的检测层通过输出多种尺寸的特征图实现对检测对象中不同尺寸大小目标的检测。原模型的输入图像大小为 640×640 , 其检测层最终输出 20×20 、 40×40 和 80×80 三个不同尺寸的特征图。其中, 尺寸较大的特征图具有较小的感受野, 包含更多关于目标位置和局部特征的细节, 适合用于检测小目标; 尺寸较小的特征图具有较大的感受野, 有丰富的语义信息但局部特征细节不够明显, 适合用于检测大目标^[19]。原始 YOLOv8 网络输出的最大的特征图尺寸为 80×80 , 即最小的检测尺度仅为 80×80 , 该特征图在检测每一个网格时的感受野为 8×8 。这种较大的下采样倍数会容易导致小目标的特征信息丢失过多, 难以被较深的特征图捕获, 如果此时网格内需要检测的目标所具备特征信息的宽度和高度在原始图像中像素均小于 8, 该网络就难以对其进行准确的识别和检测。因此, 原始的 YOLOv8 模型在小目标检测方面的性能仍有一定的提升空间。

为了提高小目标检测的精度, 本研究对原始 YOLOv8 网络结构进行改进, 如图 2, 虚线框即为所添加的小目标检测层。在原网络模型的基础上, 通过主干 P2 层设置

特征图流出, 增加一层特征图尺寸为 160×160 的小目标检测层, 其中包含引入的额外检测头和补充的特征融合层, 以此增强网络对更小目标的语义信息和特征表达能力和检测效果。

首先将 Backbone 中的第五层的 80×80 尺度特征层与 Neck 中的上采样特征层继续向上堆叠, 经过 C2f 和上采样处理后得到包含小目标特征信息的深层语义特征层, 继续与 Backbone 中的第 3 层的浅层位置特征层进行堆叠, 补充完善 160×160 尺度融合特征层对小目标语义特征以及位置信息的表达能力, 最后经过 C2f 送至 Head 中的一个额外的解耦头 (Decoupled Head)。值得注意的是, 在融合特征前加入了焦点注意力机制模块 FECA, 对 C2f 层提取的特征进行增强。Head 部分的补充, 使得小目标的特征信息通过 Head 结构继续沿着下采样路径传递到其他 3 个尺度特征层, 从而加强网络的特征融合能力, 提升小目标的检测精度。

通过引入额外的解耦头实现更深层次的特征传递和特征融合效果, 可以扩大赤霉病孢子的检测范围、检测精度, 使得网络更加精确识别显微图像中小尺寸的孢子目标, 有效降低小目标由于背景复杂或粘连等影响因素导致的漏检以及误检^[17-18]。

2.2 融合特征的焦点注意力机制

注意力机制是一种帮助网络模型对输入数据以不同权重作重要度区分学习的方法, 在计算机视觉领域特别在目标检测任务中获得了广泛应用^[21-23]。通过引入注意力机制, 网络依据输入的不同特征图的重要程度赋予不同权重, 将更多的注意力聚焦于对当前任务更关键和有用的空间区域^[24], 帮助模型更好地理解图像中的目标信息的同时抑制对其他无关信息的关注度, 从而提高模型的检测性能和任务处理的效率和准确率, 也可以避免和缓解过拟合情况的发生, 在一定程度上提高了模型的鲁棒性^[25]。

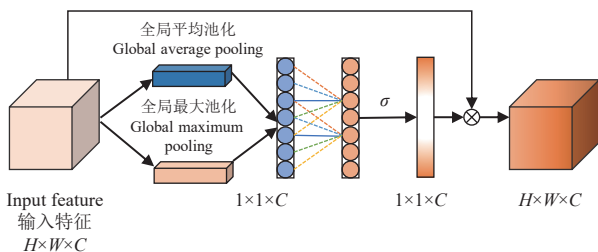
由于真实田间里小麦赤霉病孢子的环境复杂, 本研究孢子数据集为模仿田间环境, 在试验设计中引入多种杂菌并在数据采集后加入多种噪声模拟真实田间的复杂环境干扰, 所以数据集中需要检测的孢子目标有着背景复杂以及小目标孢子密集分布居多的特点, 易导致模型的检测效率低下从而影响检测性能。引入注意力机制可以使模型更加关注图像中的检测目标相关信息, 同时抑制无关的特征, 因此在进行赤霉病孢子检测时, 希望通过添加注意力机制使得已有的原始网络模型可以在目标密集的情况下着重关注孢子信息且减少关注无关的背景信息, 使得密集场景下的小目标检测取得良好识别效果。

CBAM 和 ECA 注意力机制模块在目标检测中得到广泛使用。WOO 等^[26]提出的 CBAM(convolutional block attention module)通过空间和通道的双重注意力机制获得了很好的性能, 但是有较大的计算负担, 导致计算成本增加过多, 不够轻量化。CBAM 包含两个模块, 第一个为通道模块, 第二个为空间模块, 两者串行组成。CBAM 采用全连接层, 大大增加了参数数量、结构复杂度

和计算成本。为了避免模型的过度拟合并减少计算, WANG 等^[27] 提出一个轻量级和低复杂度的高效通道注意力模块 (efficient channel attention, ECA)。ECA 去除降维操作, 通过一维卷积实现跨通道交互的信息, 模型复杂度低, 但是使用的通道信息较少, 在密集场景中的效果较差^[25-26]。

基于上述两种注意力机制所具有的优缺点, 为提高检测模型对数据集中小目标孢子的特征表达能力, 结合 CBAM 网络中通道注意力机制以及 ECA 网络结构进行改进, 并在算法模型中引入了一种基于 CBAM 和 ECA 注意力机制改进的焦点注意力机制 FECA (focal efficient channel attention)。标准 ECA-Net 采用全局平均池化来实现下采样, 在池化的过程中对每一个特征图取均值, 一定程度上会损失部分信息^[30]。为解决这一问题, 参考 CBAM 通道注意力机制, 对 ECANet 进行改进, 将特征压缩过程中使用的全局平均池化 (global average pooling, GAP) 替换为全局最大池化 (获取整张特征图的特征最大值) 与全局平均池化 (计算整张特征图的特征平均值) 组成的全局混合池化, 构成混合池化高效焦点注意力机制模块 FECA (focal efficient channel attention module), FECA 的网络结构如图 3。

从图 3 可以看出, 在 FECA 中, 输入特征图被分为两个分支, 其中一个分支用来计算通道维度的注意力权重, 在这部分中, 输入的特征图分别经过全局平均池化 (全局特征灵敏度高) 和全局最大池化 (局部特征灵敏度高) 进行 Squeeze 操作, 得到具有全局感受野的特征, 随后经自适应一维卷积跨通道交互后相加, 实现信息融合, 再经 Sigmoid 激活函数得到通道维度的注意力权重, 与另一分支的输入特征图相乘, 可放大有效特征, 抑制无效特征, 实现通道维度的特征选择。FECA 中以全局最大池化与全局平均池化组成的全局混合池化替代原有的全局平均池化, 包含了局部细粒度和全局粗粒度的交互, 可以减少下采样过程中的信息丢失, 得到更精确的通道维度注意力权重^[31]。



注: σ 为 Sigmoid 函数。
Note: σ is the Sigmoid function.

图 3 焦点注意力机制 FECA 网络结构图

Fig.3 Focus attention mechanism FECA network structure

在 YOLOv8 网络中, 处于主干网络与预测输出头之间的 Neck 端起到了重要的连接作用, 由于 Neck 端自底向上, 自上而下的特殊构造, 不同尺度的特征在这里进行充分融合, 为之后预测的奠定基础, 所以 Neck 端的网络结构极大影响了算法性能。因此本文选择在 YOLOv8n

的 Neck 端添加 FECA 注意力模块。具体添加位置是在 80×80 和 160×160 两个检测层中的 PAN-FPN 下采样阶段的 C2f 模块与 CBS 模块卷积之间, 即在融合特征前都加入此模块。在优化后的模型中, 融合特征前进行特征注意加强操作, 模型可以更加注重小目标信息对目标的关注, 提升小目标的识别及定位精度。

2.3 损失函数优化

原始 YOLOv8 算法模型的损失函数由分类损失和回归损失共同组合而成。回归损失采用 CIOU Loss+ DFL Loss 两部分加权组成, 其中, CIOU (complete intersection over union) Loss 是对边界框的损失进行计算, 它加入了纵横比的损失计算, 但是在纵横交并比描述的相对值方面存在一定的模糊, 没有考虑数据集样本本身的平衡问题^[32], DFL (distribution focal loss) 在计算损失时仅将锚框向着标注框进行回归, 不能确定锚框与标注框的包含关系。原损失函数强化边界框损失的拟合能力, 但欠缺对数据集本身标注示例质量的考虑, 易导致一些低质量标注对检测性能有很大的影响^[33]。

双焦点损失 (DFL Loss) 缓解了分类和语义分割中的类不平衡问题。此损失函数的灵感来自焦点损失 (focal loss) 函数的特性, 该函数加剧了数据点的损失, 在预测输出和实际输出之间产生较大差异。因此, 如果由于类不平衡或其他一些原因, 数据点难以分类, FL 使神经网络更多地关注该数据点以及类似的数据点。DFL 采用了这一思路, 并通过增强梯度条件提高了 FL 的性能。

DFL 采用点到边界框四条边的距离作为回归的目标。通常真实的目标分布在标注位置附近, 因此 DFL 通过显式的增大最靠近标签 y 的两个点的概率, 使网络较快定位到标签 y 附近的值。

DFL Loss 定义如式 (1):

$$\text{DFL}(S_i, S_{i+1}) = -((y_{i+1} - y) \log(S_i) + (y - y_i) \log(S_{i+1}))$$

$$\text{DFL}(S_i, S_{i+1}) = -((y_{i+1} - y) \log(S_i) + (y - y_i) \log(S_{i+1})) \quad (1)$$

其中 S_i 表示模型对第 i 类的预测概率或预测值。 S_{i+1} 表示模型对第 $i+1$ 类的预测概率或预测值。 y_i 表示第 i 类的真实标签值, 通常为 0 或 1。 y_{i+1} 表示第 $i+1$ 类的真实标签值。 y 表示样本的真实类别。

但 DFL 在计算损失时仅将锚框向着标注框进行回归, 不能确定锚框与标注框的包含关系, 在实际应用时容易出现目标检测定位不准确的问题。

针对传统 IoU 对检测结果进行评估时的偏差问题, Wise-IoU 通过考虑预测框和真实框之间的区域来对 IoU 进行加权, 构造了基于注意力的边界框损失^[34]。通过聚焦系数的计算方法来附加聚焦机制, 以实现动态聚焦的边界框回归损失。因此, 本研究引入 Wise-IoU Loss^[35] 代替 CIOU Loss 来计算标注框与锚框的重叠损失, 并与以焦点损失 (focal loss, FL)^[36] 改进的分布式聚焦损失函数 (distributed focal loss, DFL) 结合作为最终的边界框回归损失, 增强模型的收敛能力, 以实现更好的边界框预

测回归效果^[34]。

Wise-IoU Loss 定义如式 (2)：

$$L_{\text{WIoU}} = 1 - \frac{\sum_{i=1}^n w_i \text{IoU}(b_i, g_i)}{\sum_{i=1}^n w_i} \quad (2)$$

其中 n 表示物体框的数量, b_i 指第 i 个物体框的坐标, g_i 指第 i 个物体的真实标注框的坐标, w_i 表示权重值, $\text{IoU}(b_i, g_i)$ 表示第 i 个物体框与真实标注框之间的 IoU 值。

结合上述两个损失后得到的最终回归损失 L_{reg} 如式 (3)：

$$L_{\text{reg}} = \lambda \cdot \text{DFL} + \mu \cdot L_{\text{WIoU}} \quad (3)$$

权重系数 λ 和 μ 的确定参考了 YOLOv8 的回归损失权重设置。高 IoU 值对于目标的准确定位和检测非常重要, 因此需要较大权重; DFL 在模型训练中容易导致过拟合问题, 从而影响模型的泛化能力, 因此需要较小权重。因此, 通过相关试验分析, 取 $\lambda=1/6$, $\mu=5/6$ 。结合后的回归损失使得模型的训练效率得到提升。

2.4 模型评价指标

本研究使用平均精度均值 mAP(mean Average Precision)、准确率 P (Precision)、召回率 R (Recall)、检测帧率 (FPS, frames per second) 等作为模型的评价指标。其中, mAP 是检测目标精度值 AP 的均值, 而准确率和召回率为相互矛盾的指标, 故选用 mAP 对两者进行综合考虑, mAP 值越大代表该算法综合性能更好。在本文中该指标表示所有种类孢子平均的检测精度。mAP@0.5 是 IoU 阈值等于 0.5 时所有类别的平均检测精度。mAP@0.5:0.95 表示 IoU 阈值以 0.05 作为步长的所有检测精度的平均值。FPS 为检测帧率, 用于衡量算法检测速度^[37]。各指标的计算式如下：

$$P = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (4)$$

$$R = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (5)$$

$$\text{AP} = \int_0^1 P(R) dR \quad (6)$$

$$\text{mAP} = \frac{1}{n} \sum_{i=1}^n \text{AP}_i, \text{mAP} = \frac{1}{n} \sum_{i=1}^n \text{AP}_i \quad (7)$$

式中 P 代表模型预测正确的部分占整体预测结果的比例, 具体来说, 即模型正确识别的孢子数量占其识别出的孢子总数量的百分比。 R 是指预测正确的正样本数占实际总正样本的比例, 即模型正确预测的孢子数量占所有孢子总数的百分比。TP 是数据集中被正确分类的实际样本对象的数量, FP 是被检测模型误检的样本对象数量, FN 是检测模型中被漏掉的样本数。

3 结果与分析

3.1 试验设置

硬件环境配置方面, CPU 为 Intel Core i7-11700K @ 3.60 GHz, GPU 为 NVIDIA GeForce RTX 3080TI, 主机内存为 128 GB, 显存为 8 GB。软件环境设置方面, 使

用 64 位 Windows 10 操作系统, 使用的编程语言为 Python3.8, 使用 CUDA 11.7 完成计算加速, 采用深度学习框架 Pytorch 2.0.1 进行训练。

试验中具体训练参数设置如下, 输入图像的分辨率 (image_size) 大小为 640×640 像素, 初始学习率 (learning_rate) 定为 0.01, 批尺寸 (batch_size) 设置为 16, 迭代次数 (epochs) 调整为 300。

3.2 YOLOv8 基准模型对比试验

YOLOv8 提供 5 种不同大小的模型, 包括 YOLOv8n、YOLOv8s、YOLOv8 m、YOLOv8l、YOLOv8x。这些模型在大小、速度和精度上有所不同, 以满足不同应用场景的需求。由于 YOLOv8x 模型体量大、速度较慢, 无法满足低成本、高精度嵌入式田间孢子捕捉仪所需的轻量化模型迁移和应用需求, 故本研究对比了另外 4 种模型在检测时的网络深度、网络宽度、准确率 (P)、召回率 (R)、mAP 以及模型参数量大小, 具体试验结果如表 1。

由表 1 可以看出, 随着网络深度和宽度的增加, 模型参数的数量随之增加, 对应模型的准确率、召回率有所提高。YOLOv8n 作为以上 4 种网络中最轻量型的网络, 其模型的参数量最小, 只有 5.2 MB, 检测精度虽然相对最低但 mAP@0.5 仍达到了 92.5%。虽然 YOLOv8l 的 mAP@0.5 达到了 95.1%, 但模型参数量增加到了 56.7 MB, 这种大幅度参数量的增加在实际检测中会造成检测推理时间的增加。考虑到实际使用中计算资源的消耗和快速检测的应用需求, 且通过适当改进也可以优化和提升网络模型的检测能力, 因此本研究最终选择兼具识别精度和识别速度的 YOLOv8n 作为改进的基线模型进行相应试验。

表 1 YOLOv8 模型试验结果
Table 1 Experimental results of YOLOv8 model

模型名称 Model	网络深度 Network depth	网络宽度 Network width	平均精 度均值 mAP@ 0.5/%	平均精 度均值 mAP@0 .5:0.95 /%	准确率 P /%	召回率 R /%	参数量 Parameters /MB
YOLOv8n	0.33	0.25	92.5	75.7	92.9	87.3	5.2
YOLOv8s	0.33	0.50	93.8	80.8	94.4	88.0	11.1
YOLOv8 m	0.67	0.75	94.7	84.6	95.4	89.0	31.2
YOLOv8l	1.00	1.00	95.1	85.2	95.5	89.7	56.7

在赤霉病孢子数据集上使用 YOLOv8n 检测部分结果如图 4。

测试结果表明, 当孢子目标存在密集或遮挡情况时极易发生漏检或者误检问题。区域内孢子密集程度较高或杂菌孢子密集时, 模型检测精度较低且易发生漏检; 当孢子之间出现明显遮挡, 即目标孢子的大部分面积被附近孢子遮挡时, 原始模型存在将两个目标孢子识别为一个目标孢子的问题, 该种场景下易造成孢子检测难度增大从而检测精度明显下降。

具体来说, 图 4 中处于暗环境和干扰环境下的第三行图像的所有原始标签均被模型正确检测, 且置信度大多保持在 0.6 以上, 说明模型有较高的检测准确度和较好的鲁棒性, 能够适应多种噪声干扰下的孢子小目标检

测，可以作为本研究的基准模型。而当图像出现密集分布时，检测中易发生漏检和误检现象；当环境受到高斯噪声干扰时，检测图像出现部分孢子目标的误检；当目标处于遮挡干扰时，原始模型的检测易发生孢子目标的

漏检。基于以上漏检和误检问题，通过优化网络结构等方法，对基准模型 YOLOv8n 进行优化改进，改善小麦赤霉病孢子在密集、遮挡场景中的漏检和误检问题，提出具有更高检测能力的赤霉病孢子检测模型。

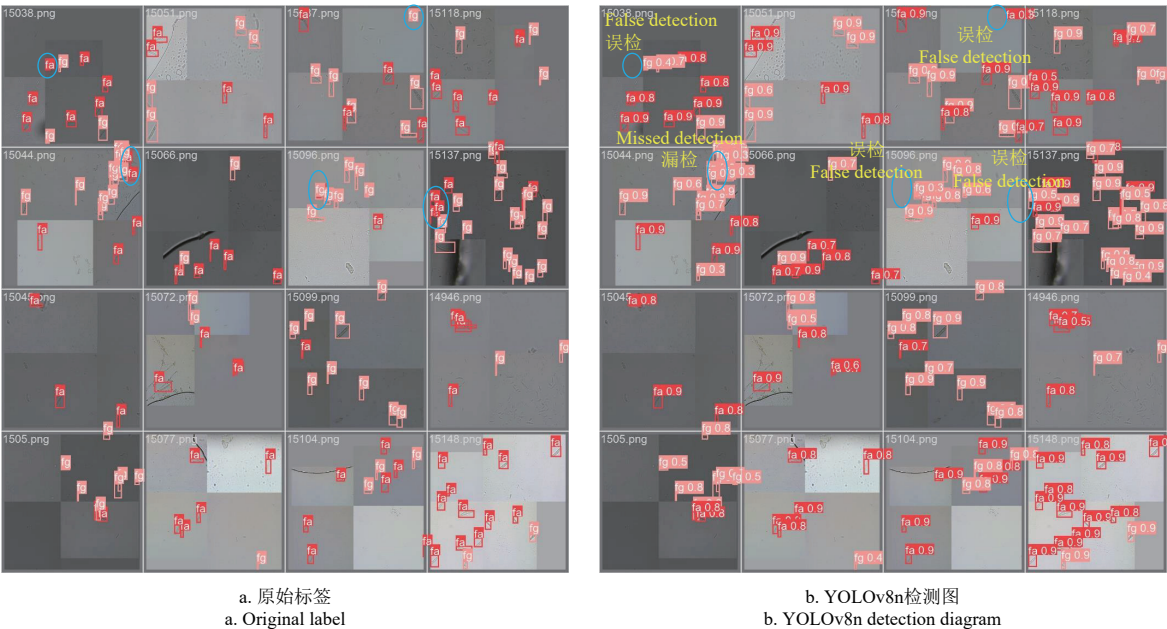


图 4 YOLOv8n 检测效果
Fig.4 YOLOv8n detection effect

3.3 注意力机制性能对比试验

为验证所设计的焦点注意力机制 FECA 的有效性，设计对比试验分析不同注意力机制嵌入模型后评价指标及检测速度的变化情况。各试验均采用相同的软硬件环境及相同的孢子数据集，以 YOLOv8n 为基线模型，分别在网络的同一位置引入 ECA、CBAM 和 FECA 3 种注意力机制进行对比，试验具体结果见表 2。

表 2 不同注意力机制试验结果

模型名称	平均精度均值	平均精度均值	准确	召回	检测帧率
Model	mAP@ 0.5/%	mAP@0.5:0.95/%	率 P/%	率 R/%	FPS/(帧·s ⁻¹)
YOLOv8n	92.5	75.7	92.9	87.3	134
+ECA	92.7	75.4	93.3	89.1	131
+CBAM	93.0	76.1	94.5	86.0	127
+FECA	93.2	77.3	93.6	88.4	129

从表 2 分析可得，引入不同的注意力机制后，3 种模型的 mAP@.5 值均有所提高，其中 FECA 的提升最为显著，相比原始模型的 mAP@0.5 和 mAP@0.5:0.95 分别提升了 0.76% 和 2.1%，加入 ECA 模块后的 mAP@0.5:0.95 有小幅下降。除了加入 CBAM 后模型召回率有所下降，其他各模型的 P 值和 R 值都有所提升。其中，CBAM 在精确率上提升最大，ECA 在召回率上提升最大，说明 CBAM 在提高模型预测准确性方面表现较好，而 ECA 在提高模型覆盖所有正样本的能力方面表现较好。另外，各模型的帧率值均有所下降，这是因为注意力机制会增加模型的计算复杂度，但总体的下降幅度并不大且均满足实时检测要求，三者之间的差异也较小。

综上所述，加入焦点注意力 FECA 后模型计算速度降低不明显，而精度得到较大提升，说明 FECA 能够更好地帮助模型提取目标的特征信息进行目标识别。因此，FECA 注意力机制在 YOLOv8n 模型中的嵌入是有效的，在保持模型实时性的同时能够有效提高小麦赤霉病孢子目标的检测精度。

3.4 消融试验

为了验证本研究算法改进模块的有效性，以原始模型 YOLOv8n 为基线模型，通过多个改进模块不同的组合方式进行消融试验。消融试验结果如表 3。

表 3 消融试验

模型名称	平均精度均	平均精度均值	准确	召回
Model	值	mAP@0.5:0.95 /%	率	率
YOLOv8n	92.5	75.7	92.9	87.3
+小目标检测层	93.3	76.8	93.1	88.1
+FECA	94.1	77.4	93.6	88.4
+ Wise-IoU Loss+				
DFL Loss	92.9	76.4	92.2	89.0
+ FECA+ Wise-IoU Loss +				
DFL Loss	94.4	79.0	93.8	91.4
YOLOv8-FECA	96.8	82.0	95.5	91.1

注：YOLOv8-FECA 为同时引入 FECA 注意力机制、小目标检测层和 Wise-IoU Loss。

Note : YOLOv8-FECA introduces FECA attention mechanism, small target detection layer and Wise-IoU Loss at the same time.

试验结果显示，在 YOLOv8n 的基础上仅添加小目标检测层后，mAP@0.5 和 mAP@0.5:0.95 分别提升 0.8% 和 1.1%，精确率和召回率也有所提高，表明添加小目标检测层有助于模型更好地识别和定位较小的目标，对于

小麦赤霉病孢子这类小目标的检测是有益的。当在基线模型上仅添加 FECA 注意力机制时, $mAP@0.5$ 和 $mAP@0.5:0.95$ 分别提升了 1.6% 和 1.7%, 精确率和召回率分别提高了 0.7%、1.1%。说明焦点注意力机制 FECA 的引入使得模型能够在特征提取过程中关注更重要的区域, 从而提高了整体的检测性能, 特别是在 $mAP@0.5:0.95$ 这一更严格的指标上表现较好。当使用 Wise-IoU Loss 和 DFL Loss 的组合替换原有的损失函数后, $mAP@0.5$ 、 $mAP@0.5:0.95$ 分别提升了 0.4%、0.7%, 且召回率也有所提高, 表明引入 Wise-IoU Loss 有助于模型更准确地计算边界框的损失, 使模型在数据集上有更好的检测性能^[38]。同时引入 FECA 注意力机制、Wise-IoU Loss 和 DFL Loss 时, 模型的 $mAP@0.5$ 和 $mAP@0.5:0.95$ 分别提升了 1.9% 和 3.3%, 表明该模块的组合是有效的, 改进后的模块能够提升模型的检测性能。

YOLOv8-FECA 模型通过综合上述改进策略, 性能显著提升。与基线模型 YOLOv8n 相比, $mAP@0.5$ 、 $mAP@0.5:0.95$ 、精确率和召回率分别提升了 4.3%、6.3%、2.6%、3.8%, 表明 YOLOv8-FECA 的各模块组合在小麦赤霉病孢子检测任务上具有更高的准确性和可靠性。

综上所述, 通过消融试验验证了添加小目标检测层、FECA 注意力机制以及使用 Wise-IoU Loss 代替 CIoU Loss 等改进策略的有效性。这些改进不仅单独提升了模型的性能, 而且在组合使用时产生了更好的效果, 试验结果也表明了 YOLOv8-FECA 是一种具有较好检测性能的小麦赤霉病孢子检测模型。

3.5 不同模型对比试验

由于小麦赤霉病真菌孢子目标较小且真实田间环境中常常存在孢子密集分布的情况, 本研究设计了 YOLOv8-FECA 结构网络, 用来强化小目标密集分布时识别效果较差的情况。为了评估检测模型在主流网络中的性能, 验证本研究算法 YOLOv8-FECA 相比当前热门的目标检测模型的优越性, 将本文提出的网络结构与 YOLO 系列网络、SSD 网络以及具有代表性的双阶 Faster-RCNN 目标检测网络进行试验对比 (统一的配置以及相同的数据集), 检测结果如表 4。

表 4 不同模型检测结果对比

Table 4 Comparison of detection results of different models

模型名称 Model	评价指标 Evaluating indicator				
	平均精度均值 $mAP@0.5:0.95$	平均精度均值 $mAP@0.5:0.95$	准确率 $P/\%$	召回率 $R/\%$	检测帧率 $FPS/(\text{帧} \cdot s^{-1})$
YOLOv5s ^[39]	93.9	75.4	88.1	78.0	122
YOLOv7-tiny ^[40]	91.5	69.3	83.0	85.8	93
YOLOv8n ^[41]	92.5	75.7	92.9	87.3	134
SSD ^[42]	79.6	60.2	79.7	75.0	55
Faster-RCNN ^[43]	82.3	69.8	81.4	79.3	43
YOLOv8-FECA	96.8	82.0	95.5	91.1	106

试验结果表明, 在性能表现方面, 与其他主流目标检测模型相比, YOLOv8-FECA 在 $mAP@0.5$ 、 $mAP@0.5:0.95$ 、精确率和召回率上均表现最佳, 虽然在检测帧率

指标上相比 YOLOv5s 和 YOLOv8n 略低, 但相差不大, 基本满足模型实时检测要求。这进一步证明了改进策略的有效性以及新模型在赤霉病孢子小目标检测任务上的优越性。综上所述, 经过改进的 YOLOv8-FECA 模型在保持实时检测速度的同时, 显著提升了检测精度, 表现出了更强的检测性能。

3.6 模型鲁棒性检验

为了对模型鲁棒性进行验证, 本研究在不同密集场景和不同光线环境下孢子检测结果进行可视化。选取了小麦赤霉病孢子数据集中常见的密集分布场景, 作为展示 YOLOv8n 和 YOLOv8-FECA 在密集和暗光线情况下的检测效果对比。

在图 5 中, 孢子处于密集场景时, 在背景和杂菌干扰下原模型在处于区域边缘以及孢子密集分布区域都发生一定程度的孢子目标漏检, 而改进后的 YOLOv8-FECA 模型对于该种场景下的孢子目标均能准确检出且相比原模型在同种目标的检测上有更高的检测置信度, 说明改进后的模型能够有效改善孢子的漏检问题且有更高的检测精度。

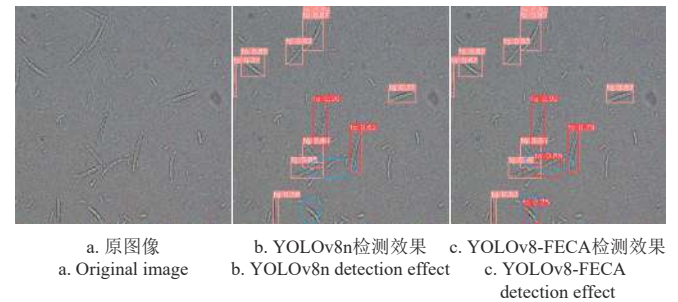


图 5 密集场景下模型改进前后检测效果对比

Fig.5 Comparison of detection effects before and after model improvement in dense scenarios

在图 6 暗光线环境下, 小目标的检测由于视线较暗更加困难。如图 6a 的中心区域由于孢子分布位置较为密集, 在视线较暗和噪声干扰下, 原模型未能识别出中心密集区域孢子目标, 在改进后的模型识别中, 中心区域密集分布的孢子均被识别, 且相同孢子的检测置信度相比原模型都有所提升, 说明改进后模型在暗环境中也具有良好的检测效果, 具有鲁棒性, 能够适应不同光线环境下的孢子检测。

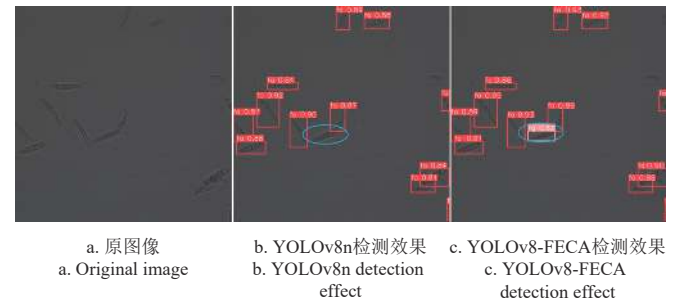


图 6 暗环境下模型改进前后检测效果对比

Fig.6 Comparison of detection effect before and after model improvement in dark environment

4 讨 论

4.1 与先进的小目标检测网络对比

本研究以 YOLOv8n 为基准模型, 先添加新的小目标检测层, 以此增强网络对更小目标语义信息的捕捉以及提高其特征描述的准确性; 其次构建融合特征的 FECA 焦点注意力机制以实现对小目标和密集分布目标的关注; 再者, 引入 Wise-IoU Loss 与 DFL Loss 结合作为边界框的回归损失, 进一步提高模型的收敛能力以及对边界框预测的准确性。孙俊等^[44]针对重叠、遮挡等果园复杂环境下的苹果果实小目标, 提出一种基于改进 RetinaNet 的检测网络, 首先在骨干网络中嵌入 Res2Net 模块, 提升多尺度特征提取能力, 其次采用 BiFPN 网络, 实现加权双向特征融合, 提高小目标和遮挡目标的检测精度, 最后结合 Focal Loss 和 EIoU Loss, 优化分类和回归任务, 提升检测准确率。与本研究提出的网络模型 YOLOv8-FECA 对比, YOLOv8-FECA 处理速度快, 更加适合需要实时处理的应用场景, 且 YOLO 系列网络结构简单更易改造, 具有较高的通用性。李辉等^[45]针对水下小目标检测的难题, 提出了一种融合多尺度特征和多重注意力的两阶段检测方法。该方法通过改进多尺度特征提取和融合, 增强目标特征; 构建多重注意力网络, 挖掘深层特征信息和隐藏信息; 并采用自适应均衡采样。与本研究提出的网络模型 YOLOv8-FECA 对比, YOLOv8-FECA 在网络中可以直接预测目标的类别和位置, 省去了区域提议的步骤, 可以大大提高检测速度, 更符合农业生产中检测实时性要求高的场景, 在小目标检测上具有显著优势。

4.2 未来研究计划

改进后的网络在小目标的识别与定位上取得更高准确率, 虽然模型的计算量相比原模型有所增加, 但通过此改进获取的更多小目标特征信息极大提升了本模型在孢子数据集中对小目标的检测能力。尽管现有模型已满足实时检测要求, 但还可以进一步优化模型推理速度的方法, 如模型压缩和量化, 以在更高的帧率下进行实时检测, 以期田间孢子捕捉仪的模型迁移和应用提供重要的模型支持。

5 结 论

本研究提出了一种改进的 YOLOv8 模型, 用于小麦赤霉病孢子的快速检测, 提出了在原模型中增加小目标检测层、引入焦点注意力机制 (focal efficient channel attention, FECA) 和 WIoU 损失函数。通过试验验证, 改进模型的平均检测精度和检测效率均得到了有效提升, 相比 YOLOv8 在孢子数据集中的平均精度均值 mAP@0.5 提高了 4.3%, 达到 96.8%, 其中 FECA 对提高召回率和抑制背景噪声具有显著作用, 改进后的模型显著提升了在复杂环境和密集目标场景下的小目标检测能力。综上, 本研究为实现田间赤霉病孢子的自动检测及病害早期预警提供了一种高效且准确的方法, 为精准农业和病害防控提供了有力的技术支持。

[参 考 文 献]

- [1] CHENG T, ZHANG D, GU C, et al. YOLO-CG-HS: A lightweight spore detection method for wheat airborne fungal pathogens[J]. *Computers and Electronics in Agriculture*, 2024, 227: 109544.
- [2] ZHANG H, VAN DER LEE T, WAALWIJK C, et al. Population analysis of the fusarium graminearum species complex from wheat in China show a shift to more aggressive isolates[J]. *PLoS ONE*, 2012, 7(2): e31722.
- [3] 刘杰, 曾娟, 黄冲, 等. 2024 年全国农作物重大病虫害发生趋势预报[J]. *中国植保导刊*, 2024, 44(1): 37-40.
- [4] LIU Jie, ZENG Juan, HUANG Chong, et al. Forecast of the occurrence trend of major crop diseases and insect pests in China in 2024[J]. *China Plant Protection Guide*, 2024, 44(1): 37-40. (in Chinese with English abstract)
- [5] MUSTAFA G, ZHENG H, KHAN I H, et al. Enhancing fusarium head blight detection in wheat crops using hyperspectral indices and machine learning classifiers[J]. *Computers and Electronics in Agriculture*, 2024, 218: 108663.
- [6] BAO W, LIU W, YANG X, et al. Adaptively spatial feature fusion network: an improved UAV detection method for wheat scab[J]. *Precision Agriculture*, 2023, 24(3): 1154-1180.
- [7] JIA L J, TANG H Y, WANG W Q, et al. A linear nonribosomal octapeptide from Fusarium graminearum facilitates cell-to-cell invasion of wheat[J]. *Nature Communications*, 2019, 10(1): 922.
- [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.
- [9] YANG Ning, WANG Pan, ZHANG Rongbiao, et al. Photoelectric detection method for false smut spore based on enrichment microfluidic chip[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2017, 33(20): 161-168. (in Chinese with English abstract)
- [10] 杨宁, 陈驰原, 李国晓, 等. 基于衍射重构技术的作物真菌病害孢子微型检测装置[J]. *农业机械学报*, 2019, 50(4): 42-48.
- [11] YANG Ning, CHEN Chiyuan, LI Guoxiao, et al. Micro detection device for fungal spores of crops based on diffraction reconstruction[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2019, 50(4): 42-48. (in Chinese with English abstract)
- [12] 杨宁, 张天伟, 张钊源, 等. 水稻病害孢子多光谱衍射识别与病害源定位方法研究[J]. *农业机械学报*, 2023, 54(4): 250-258.
- [13] YANG Ning, ZHANG Tianwei, ZHANG Zhaoyuan, et al. Multispectral diffraction identification of rice disease spores and localization method of disease source[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(4): 250-258. (in Chinese with English abstract)
- [14] 李小龙, 马占鸿, 孙振宇, 等. 基于图像处理的小麦条锈病菌夏孢子模拟捕捉的自动计数[J]. *农业工程学报*, 2013, 29(2): 199-206.
- [15] LI Xiaolong, MA Zhanhong, SUN Zhenyu, et al. Automatic counting for trapped urediospores of Puccinia striiformis fsp. tritici based on image processing[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2013, 29(2): 199-206. (in Chinese with English abstract)
- [16] 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 for spores of rice blast based on micro image processing[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2015, 31(12): 186-193. (in Chinese with English abstract)
- [12] 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.
- CHEN Qiao, HAN Mengyao, GAO Wei, et al. Quantitative detection of cucumber downy mildew spores at multi-scale based on faster-NAM-YOLO[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(12): 288-299. (in Chinese with English abstract)
- [13] 雷雨, 周晋兵, 何东健, 等. 基于改进 CenterNet 的小麦条锈病菌夏孢子自动检测方法[J]. *农业机械学报*, 2021, 52(12): 233-241.
- LEI Yu, ZHOU Jinbing, HE Dongjian, et al. Automatic Detection method for urediniospores of wheat stripe rust based on improved centerNet model[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(12): 233-241. (in Chinese with English abstract)
- [14] LIANG X, WANG B. Wheat powdery mildew spore images segmentation based on U-Net[J]. *Journal of Physics: Conference Series*, 2020, 1631(1): 012074.
- [15] YUAN J, HUANG Z, ZHANG D, et al. SporeDet: A Real-Time Detection of Wheat Scab Spores[M]//HUANG D S, PREMARATNE P, JIN B, et al. *Advanced Intelligent Computing Technology and Applications: volume 14087*. Singapore: Springer Nature Singapore, 2023: 531-543.
- [16] XU X, ZHANG H, MA Y, et al. TransDet: Toward effective transfer learning for small-object detection[J]. *Remote Sensing*, 2023, 15(14): 3525.
- [17] YU B, LI Z, CAO Y, et al. YOLO-MPAM: Efficient real-time neural networks based on multi-channel feature fusion[J]. *Expert Systems with Applications*, 2024, 252: 124282.
- [18] YANG T, TONG C. Real-time detection network for tiny traffic sign using multi-scale attention module[J]. *Science China Technological Sciences*, 2022, 65(2): 396-406.
- [19] 付锦霖, 张自嘉, 孙伟, 等. 改进 YOLOv8 的航拍图像小目标检测算法[J]. *计算机工程与应用*, 2024, 60(6): 100-109.
- FU Jinyi, ZHANG Zijia, SUN Wei, et al. Improved YOLOv8 small target detection algorithm in aerial images[J]. *Computer Engineering and Applications*, 2024, 60(6): 100-109. (in Chinese with English abstract)
- [20] ZHAO C, GUO D, SHAO C, et al. SatDetX-YOLO: A more accurate method for vehicle target detection in satellite remote sensing imagery[J]. *IEEE Access*, 2024, 12: 46024-46041.
- [21] YI H, LIU B, ZHAO B, et al. Small object detection algorithm based on improved YOLOv8 for remote sensing[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2024, 17: 1734-1747.
- [22] BRAUWERS G, FRASINCAR F. A general survey on attention mechanisms in deep learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(4): 3279-3298.
- [23] XUE J, ZHENG T, HAN J. Exploring attention mechanisms based on summary information for end-to-end automatic speech recognition[J]. *Neurocomputing*, 2021, 465: 514-524.
- [24] JOHN D, ZHANG C. An attention-based U-Net for detecting deforestation within satellite sensor imagery[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2022, 107: 102685.
- [25] GUO M H, LIU Z N, MU T J, et al. Beyond self-attention: external attention using two linear layers for visual tasks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022: 1-13.
- [26] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[EB/OL]. arXiv:2018[2024-06-14] <http://arxiv.org/abs/1807.06521>.
- [27] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[EB/OL]. arXiv, 2020[2024-06-14]. <http://arxiv.org/abs/1910.03151>.
- [28] ZHENG Z, WANG P, REN D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. *IEEE Transactions on Cybernetics*, 2022, 52(8): 8574-8586.
- [29] 彭红星, 徐慧明, 刘华鼎. 基于改进 ShuffleNet V2 的轻量化农作物害虫识别模型[J]. *农业工程学报*, 2022, 38(11): 161-170.
- PENG Hongxing, XU Huiming, LIU Huanai. Lightweight agricultural crops pest identification model using improved ShuffleNet V2[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2022, 38(11): 161-170. (in Chinese with English abstract).
- [30] DONG H, ZHU B, ZHANG X, et al. Use data augmentation for a deep learning classification model with chest X-ray clinical imaging featuring coal workers' pneumoconiosis[J]. *BMC Pulmonary Medicine*, 2022, 22(1): 271.
- [31] 杜守航, 李炜, 邢江河, 等. 基于 FM-UNet++ 和高分二号卫星影像的露天矿区范围变化检测[J]. *煤田地质与勘探*, 2023, 51(7): 130-139.
- DU Shouhang, LI Wei, XING Jianghe, et al. Change detection of open-pit mines based on FM-UNet++ and GF-2 satellite images[J]. *Coal Geology & Exploration*, 2023, 51(7): 130-139. (in Chinese with English abstract)
- [32] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism[EB/OL]. arXiv, 2023[2024-06-14]. <http://arxiv.org/abs/2301.10051>.
- [33] HOSANG J, BENENSON R, DOLLAR P, et al. What makes for effective detection proposals?[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(4): 814-830.
- [34] DUAN Z, XIE T, WANG L, et al. Microalgae detection based on improved YOLOv5[J]. *IET Image Processing*, 2024: ipr2.13119.
- [35] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(2): 318-327.
- [36] LI X, WANG W, WU L, et al. Generalized focal loss: Learning qualified and distributed bounding boxes for dense object detection[EB/OL]. arXiv, 2020[2024-06-14]. <http://arxiv.org/abs/2006.04388>.
- [37] 郑俊键, 兰玉彬, 熊万杰, 等. 基于 YOLOv5s 改进模型的小白菜虫害识别方法[J]. *农业工程学报*, 2024, 40(13): 124-133.
- ZHENG Junjian, LAN Yubin, XIONG Wangjie, et al. Method for identification of Pak choi pests and diseases based on improved YOLOv5s[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2024, 40(13): 124-133. (in Chinese with English abstract).
- [38] 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): 187-195.
- 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 (Transactions of the CSAE)*, 2024, 40(5): 187-195. (in Chinese with English abstract).
- [39] LIU J, LIU Z. YOLOv5s-BC: An improved YOLOv5s-based method for real-time apple detection[EB/OL]. arXiv, 2023[2024-07-24]. <http://arxiv.org/abs/2311.05811>.
- [40] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[EB/OL]. arXiv 2022[2024-07-24]<http://arxiv.org/abs/2207.02696>.
- [41] LANG K, CUI J, YANG M, et al. A Convolution with transformer attention module integrating local and global features for object detection in remote sensing based on YOLOv8n[J]. *Remote Sensing*, 2024, 16(5): 906.
- [42] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multiBox Detector[EB/OL]. 2016[2024-07-24]<http://arxiv.org/abs/1512.02325>.
- [43] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks[EB/OL]. arXiv, 2016[2024-07-24]<http://arxiv.org/abs/1506.01497>.
- [44] 孙俊, 钱磊, 朱伟栋, 等. 基于改进 RetinaNet 的果园复杂环境下苹果检测[J]. *农业工程学报*, 2022, 38(15): 314-322.
- SUN Jun, QIAN Lei, ZHU Weidong, et al. Apple detection in complex orchard environment based on improved RetinaNet[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2022, 38(15): 314-322. (in Chinese with English abstract)
- [45] 李辉, 王晓宇, 刘云, 等. 融合多尺度特征和多重注意力的水下目标检测[J]. *农业工程学报*, 2022, 38(20): 129-139.
- LI Hui, WANG Xiaoyu, LIU Yun, et al. Detecting underwater objects using multi-scale features fusion and multiple attention[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2022, 38(20): 129-139. (in Chinese with English abstract)

Detection of wheat scab spores in dense scene based on YOLOv8-FECA

ZHANG Dongyan^{1,2}, GAO Yue², CHENG Tao¹, HU Gensheng², YANG Xue³,
QIAO Hongbo⁴, GUO Wei⁴, GU Chunyan^{3*}

(1. College of Mechanical and Electronic Engineering, Northwest A & F University, Yangling 712100, China; 2. National Engineering Research Center for Agro-Ecological Big Data Analysis & Application, Anhui University, Hefei 230601, China; 3. Institute of Plant Protection and Agro-products Safety, Anhui Academy of Agricultural Sciences, Hefei 236065, China; 4. College of Information and Management Science, Henan Agricultural University, Zhengzhou 450002, China)

Abstract: Wheat scab is one of the most serious diseases that threaten global wheat production. The primary causal agents can be from the fungi *Fusarium graminearum* and *Fusarium asiaticum*. The *Fusarium* spores can be disseminated in the transmission and infection of wheat scab. Consequently, the early and precise identification of pathogen spore concentrations is of paramount importance to prompt the detection of wheat scab, particularly for the high wheat yield and quality, as well as food safety. Conventional techniques, such as microscopic observation and medium isolation, have posed a great challenge to the rapid response and the transmission of large-scale crop disease, due to time-consuming and sophisticated technical expertise. Furthermore, there are missed and erroneous detections of densely distributed small targets in scab spore images. In this study, a small target detection model, YOLOv8-FECA was developed to overcome this challenge. Firstly, a small target detection layer with a feature map size of 160×160 was added to the original YOLOv8 baseline model. The network was then improved to capture the semantic information of small targets, in order to enhance the accuracy of feature description. Secondly, a focus attention mechanism, FECA, was designed to combine the CBAM and ECA modules. This module was then added at the neck end of the network to reduce information loss during downsampling. Ultimately, Wise-IoU Loss and DFL Loss were integrated as the regression loss for the bounding box, in order to enhance the convergence and the precision of bounding box estimation. The experimental results demonstrate that the small target detection layer was added to introduce the focus attention mechanism, compared with the original YOLOv8 baseline model. Wise-IoU Loss and DFL were also introduced after Loss improvement. The average detection accuracy of the new YOLOv8-FECA on spore data set mAP@0.5 and mAP@0.5:0.95 increased by 4.3% and 6.3%, respectively, compared with the benchmark model YOLOv8n. In terms of performance, the YOLOv8-FECA model was improved in both accuracy and recall, compared with the YOLOv8n. The improved model demonstrated an elevated degree of accuracy and comprehensiveness in identifying the wheat scab spores, with an increase of 2.6% in Precision and 3.8% in Recall. There was a decrease in the frame rate per second (FPS) of YOLOv8-FECA, compared with YOLOv8n (from 134 to 106). Nevertheless, a high detection speed was achieved among performance indicators. The YOLOv8-FECA successfully improved the detection accuracy during real-time detection, where mAP @ 0.5 reached 96.8 %. The robustness of the model was verified as well. The results demonstrated that the accurate detection of spores was achieved even in challenging scenarios, such as the high spore density and low light conditions. Moreover, compared with the prevalent target models, including YOLOv5s, YOLOv7-tiny, SSD network, and the exemplar two-stage Faster-R-CNN, YOLOv8-FECA exhibited superior performance, in terms of mAP. The new model was superior in detecting small targets, such as scab spores. This finding can provide technical support to the automatic detection of wheat scab spores in the field, especially for the early warning of scab.

Keywords: wheat scab; spores; intensive scene; small target detection; YOLOv8; microscopic image