doi:10.6041/j.issn.1000-1298.2025.01.035

基于改进 DeblurGANv2 模型的小麦条锈菌夏孢子离焦模糊显微图像复原方法

雷　雨[1,2]　陈　旭[1]　阮　超[1,2]　钱海明[3]　李劲松[3]　黄林生[1,2]　赵晋陵[1,2]

(1. 安徽大学互联网学院, 合肥 230601;
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. 天地信息网络研究院(安徽)有限公司, 合肥 230088)

摘要: 针对复杂工况下孢子捕捉设备显微成像易出现离焦模糊导致高频信息缺失和夏孢子边缘模糊等问题,提出了一种改进 DeblurGANv2 模型的小麦条锈菌夏孢子离焦模糊显微图像复原方法。首先,在 DeblurGANv2 模型特征融合模块后设计引入一个自底向上的 5 层特征增强模块,缩短浅层特征向深层特征的传播路径,增强不同尺度特征信息的相互融合,提升模型对高频和孢子边缘等信息的复原效果;同时,在特征提取主干网络部分引入卷积注意力机制(Convolutional block attention module,CBAM),在空间和通道 2 个维度增加夏孢子特征信息权重,提升模型对夏孢子的特征表达能力,丰富复原图像中夏孢子细节信息;最后,选取 4 种主流目标检测模型 YOLO v5、Faster-R CNN、CenterNet 和 YOLO v8 对复原前后的图像进行夏孢子检测,对比改进 DeblurGANv2 复原模型对检测性能的影响。试验结果表明,改进后 DeblurGANv2 复原模型均方误差、峰值信噪比和结构相似性指标分别为 0.0014、28.88 dB、0.966,相较于原始 DeblurGANv2 模型性能分别提升 17.65%、3.29%、0.35%;4 种目标检测模型在结合改进 DeblurGANv2 复原模型去模糊后,检测性能指标均有不同程度提升,其中结合改进 DeblurGANv2 复原的 YOLO v8 模型性能表现最优,精确率、召回率、平均精度均值分别为 96.1%、95.1%、97.7%,与直接使用 YOLO v8 检测模型相比,分别提升 3.0、5.0、23.6 个百分点,验证了本文提出的改进 DeblurGANv2 复原模型可复原出显微图像中离焦模糊夏孢子信息,显著提升了夏孢子目标检测模型检测性能,为气传小麦条锈菌夏孢子检测提供了技术支持。

关键词: 小麦条锈菌; 显微图像; 离焦模糊; 孢子检测; 图像复原; 特征融合

中图分类号: S435.121.4+2; TP391.4　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)01-0366-11　　**OSID**:

Restoration of Defocused Blurred Microscopic Images of Urediniospores of Wheat Stripe Rust Based on Improved DeblurGANv2 Model

LEI Yu[1,2]　CHEN Xu[1]　RUAN Chao[1,2]　QIAN Haiming[3]　LI Jinsong[3]　HUANG Linsheng[1,2]　ZHAO Jinling[1,2]

(1. *School of Internet*, *Anhui University*, *Hefei* 230601, *China*
2. *National Engineering Research Center for Agro-Ecological Big Data Analysis and Application*, *Anhui University*, *Hefei* 230601, *China*
3. *Institute of Space Integrated Ground Network* (*Anhui*) *Co.*, *Ltd.*, *Hefei* 230088, *China*)

Abstract: Due to the shallow depth of field inherent in optical microscopic imaging of micron-scale spores, defocused blurred images frequently occur, resulting in the loss of high-frequency information and blurred edges of urediniospores. Defocus deblurring restoration is crucial for the subsequent accurate detection of spore targets, making it a critical technical foundation for the early prevention and control of airborne wheat stripe rust. To address the issues of high-frequency information loss and blurred edges of urediniospores caused by defocused blurring in microscopic imaging of spore capturing devices under complex conditions, an improved DeblurGANv2 method for deblurring microscopic images of urediniospores was proposed. Firstly, a bottom-up five-level feature enhancement module after the feature

收稿日期: 2024-09-29　修回日期: 2024-10-28

基金项目: 国家自然科学基金项目(32301701)、安徽省高等学校科学研究项目(2022AH050085)、合肥市自然科学基金项目(202309)、合肥市关键共性技术研发"揭榜挂帅"项目(GJ2022QN06)和河南省重点研发专项(241111110800)

作者简介: 雷雨(1990—),男,讲师,博士,主要从事气传真菌孢子智能检测与应用研究,E-mail: leiyu@ahu.edu.cn

通信作者: 赵晋陵(1981—),男,教授,博士生导师,主要从事农业病虫害及遥感解析研究,E-mail: zhaojl@ahu.edu.cn

fusion module of DeblurGANv2 was introduced, which shortened the propagation path from shallow features to deep features, enhancing the mutual fusion of features at different scales and improving the model's ability to restore high-frequency and spore edge features. Simultaneously, the convolutional block attention module (CBAM) was incorporated into the feature extraction backbone network, increasing the weight of urediniospore feature information in both spatial and channel dimensions, enhancing the model's capacity to express urediniospore features and enriching the detail information in the restored images. Finally, four mainstream object detection models, including YOLO v5, Faster-R CNN, CenterNet, and YOLO v8 were employed to detect urediniospores in images before and after restoration, comparing the impact of the improved DeblurGANv2 model on detection performance. The experimental results indicated that the improved DeblurGANv2 restoration model achieved mean squared error (MSE), peak signal-to-noise ratio (PSNR), and structural similarity (SSIM) values of 0.001 4, 28.88 dB, and 0.966, respectively, representing improvements of 17.65%, 3.29%, and 0.35% over the original DeblurGANv2 model, respectively. Furthermore, the four object detection models exhibited varying degrees of performance enhancement when combined with the improved DeblurGANv2 model. Among them, the YOLO v8 model, utilizing the improved DeblurGANv2 restoration, demonstrated the best performance, with precision (P), recall (R), and mean average precision (mAP@0.5) values of 96.1%, 95.1%, and 97.7%, respectively, an increase of 3.0, 5.0, and 23.6 percentage points compared with that using the YOLO v8 detection model directly. This validated the effectiveness of the proposed improved DeblurGANv2 model in recovering defocused and blurred spore information in microscopic images, significantly enhancing the detection performance of spore detection models and providing technical support for the airborne detection of urediniospores.

Key words: wheat stripe rust; microscopic image; defocused blurring; spore detection; image deblurring; feature fusion

0　引言

条锈病是小麦生产中的毁灭性病害[1],而中国是全球小麦条锈病最大的流行区域[2-3]。条锈病病原真菌夏孢子(*Puccinia striiformis* f. sp. *tritici*)借助风力传播可迁移至数千公里外,最后通过风或雨滴将其沉积到小麦叶面上[4]。夏孢子的远距离跨区域气流传播特性,使其能在相对短时间内引发异地大规模流行,严重暴发时甚至会完全摧毁作物[5]。因此,跨麦区不同生长环境下空气中条锈菌夏孢子的准确在线检测能够快速获取夏孢子信息,进而形成便捷高效的反馈机制,为小麦条锈病研究与防治提供准确可靠的基础数据与技术手段,将有效地避免由条锈病引发的小麦减产。

近年来计算机视觉技术在气传真菌孢子检测领域取得了较大进展[6-9],随着人工智能发展,深度学习技术逐渐应用到小麦条锈病菌夏孢子[10]、赤霉病禾谷镰刀菌孢子[11-12]、水稻稻瘟病菌孢子[13]、黄瓜霜霉病菌和灰霉病菌孢子[14-16]等农作物真菌孢子自动检测,提出的算法模型为孢子高精度检测提供了有效手段。但上述研究对模型输入图像的清晰度有较高要求,孢子显微图像数据集亦多在实验室环境下显微镜上采集并剔除模糊图像,较少涉及到针对显微成像放大后的孢子离焦模糊图像进行有效处理和准确检测。随着光电自动化技术的发展,以载玻片为载体结合光学显微成像的智能孢子捕捉仪相继出现,逐步从需要人工参与的传统捕捉仪迈向无人式的智能化监测终端,如托普云农公司开发的一体化智能孢子捕捉仪,实现了野外田间孢子显微图像的智能在线采集。根据夏孢子的气传特性,文献[17]研制了一种孢子智能在线监测终端,实现了无需人工参与的夏孢子智能监测。但受高倍率光学显微成像景深小的固有局限特性限制,终端需要执行多点位置的图像自动拍摄,才能反映出整个载玻片区域的真实捕捉情况。由于复杂工况下智能孢子捕捉设备上的显微成像模块在拍摄载玻片不同点的成像焦平面不完全一致,从而出现离焦模糊现象,导致显微图像中易出现高频信息缺失和夏孢子边缘模糊,严重影响孢子检测的准确率。因此,亟待使用合适的模糊复原算法进行显微图像去离焦模糊处理,对于后续夏孢子目标高精度检测具有重要意义。

由于传统图像去模糊方法需对模糊核进行估计,较难去除非均匀模糊且耗时较长,设计的复原算法往往泛化能力不足[18]。近年来,通过卷积网络学习清晰图像和模糊图像间的映射关系,无需对模糊核进行估计,基于端到端的深度学习复原方法实现图像去模糊逐渐成为研究热点[19]。NAH 等[20]提出了一种端到端的多尺度卷积去模糊网络模型

DeepDeblur,其利用“由粗到细”的思想从低分辨率图像向高分辨率图像逐步完成图像的复原任务,但该方法的卷积操作容易造成图像中的高频信息丢失,复原图像中缺少丰富的纹理细节信息。TAO 等[21]提出了一种多尺度递归去模糊网络(Scale-recurrent network-deblurNet, SRNDeblurNet),其利用多尺度递归结构进行逐层图像恢复,从低分辨率到高分辨率逐步细化图像细节,重建复杂场景中的运动模糊,该网络通过不同尺度共享参数,可大幅减少训练参数量,有效提升了图像去模糊的效率,减少了计算开销。生成对抗网络因其能保留图像中丰富的细节、创造出和真实图像十分接近的图像等特点亦被广泛应用于各种场景图像去模糊任务中。KUPYN 等[22]提出了去模糊生成对抗网络(Deblurring generative adversarial networks, DeblurGAN),对模糊程度较低的图像表现出较好的去模糊性能,但当输入图像的模糊程度过高时复原图像的质量不理想。因此,KUPYN 等[23]在 DeblurGAN 基础上提出了改进型去模糊生成对抗网络(Deblurring generative adversarial networks - v2, DeblurGAN - v2),其在生成器中引入特征金字塔网络[24]提升特征提取能力,设计的双尺度判别器亦能指导生成器生成更细腻的清晰图像,同时以轻量级网络 MobileNet - v2[25]作为骨干网络,使模型速度得到较大提升。蔡舒平等[26]针对果园目标检测时相机抖动以及物体相对运动导致检测图像模糊的问题,提出一种将 DeblurGAN - v2 去模糊网络和 YOLO v5s 目标检测网络相融合的去模糊识别深度网络,用于检测识别果园模糊场景图像中的障碍物,极大程度解决了输入模糊图像造成的漏检和误检问题。以上研究表明基于端到端的深度学习复原方法取得了较好的去模糊效果,但针对孢子离焦显微图像复原研究较少,由于夏孢子边缘纹理细节较为丰富且在图像中像素占比较低,若直接使用上述原始算法去离焦模糊仍存在特征丢失及复原效果不佳等问题。

为解决上述问题,本文以自制的孢子捕捉设备采集的小麦条锈菌夏孢子显微图像为研究对象,提出一种改进 DeblurGANv2 模型的小麦条锈菌夏孢子离焦模糊显微图像复原方法。该方法首先在 DeblurGANv2 模型中设计引入 5 层特征增强模块,增强不同尺度特征信息的相互融合,提升模型对高频和孢子边缘等信息的复原效果;其次引入卷积注意力机制,提升模型对夏孢子的特征表达能力,丰富复原图像中夏孢子细节信息;最后选取当前主流目标检测模型对复原前后的图像进行夏孢子检测,对比改进 DeblurGANv2 复原模型对检测性能的影响,以期为野外复杂工况下的气传小麦条锈菌夏孢子高精度检测提供技术支持。

1 显微图像采集与数据集制作

1.1 试验材料与孢子捕捉设备

供试小麦条锈菌夏孢子于西北农林科技大学小麦抗病种质资源创制与利用研究中心东南窑低温温室内繁育得到,其他所用材料有凡士林、载玻片和洗耳球,孢子捕捉设备采用在文献[17]研究基础上研制开发的性能更强的气传真菌孢子和气象因子智能监测终端,如图 1 所示。



(a) 智能监测终端三维设计图 (b) 智能监测终端实物图 (c) 孢子捕捉及显微图像采集模块 (d) 夏孢子显微图像采集流程图

图 1 气传真菌孢子、气象因子智能监测终端和显微图像采集流程图

Fig. 1 Intelligent monitoring terminal for airborne fungal spores and meteorological factors and microscopic image acquisition flowchart

1. 箱体 2. 工控机 3. 蓄电池 4. 吸风风机 5. 孢子捕捉及显微图像采集模块 6. 进风口 7. 温湿度传感器 8. 风向传感器 9. 风速传感器 10. 降雨量传感器 11. 太阳能电池板 12. 载玻片片仓模块 13. 涂刮凡士林模块 14. 显微图像采集模块 15. 风道负压孢子捕捉模块 16. 载物台

从图 1a 可以看出，智能监测终端主要包含孢子捕捉及显微图像采集模块、气象因子监测模块和太阳能供电系统。该终端采用 PCX－9068 型嵌入式工控机为终端处理核心，能自动完成推取载玻片、涂刮凡士林、空中孢子捕捉、孢子显微图像和气象因子数据采集、载玻片回收等智能连续作业。此外，太阳能供电系统提供充足能源，可实现在野外环境下长时间稳定工作，智能监测终端实物图如图 1b 所示。显微镜头采用海康 MV－CE120－10UC 型 1 200 万像素 CMOS 工业相机，显微镜头连接镜筒和物镜可采集放大 200 倍、分辨率为 4 000 像素 ×3 036 像素的孢子显微图像，显微图像采集模块如图 1c 所示。

1.2　夏孢子显微图像采集

将智能监测终端放置于野外小麦田中以最大可能还原小麦真实生长环境。采用洗耳球在终端进气口上方附近处缓慢地吹出新鲜的条锈菌夏孢子并扩散至空气中。吸风风机会使捕捉风道内形成负压，以将进气口上方夹杂着夏孢子的空气吸入到风道内，并随气流到达下方的风箱内。涂刮有黏性凡士林的载玻片会将夏孢子粘附住，最后终端内显微图像采集模块自动完成对载玻片上孢子的不同位置多点拍摄。具体夏孢子显微图像采集流程如图 1d 所示。试验所用图像样本于 2024 年 5 月 1—10 日拍摄。该智能监测终端通过步进电机驱动模块每轮输出不同脉冲数，以矩形阵列点采集方式拍摄载玻片中部 50 mm ×25 mm 区域内显微图像。采集前手动调焦并固定焦距，每轮可拍摄 50 幅显微图像，孢子捕捉时间为 1 h，每天采集 5 轮，10 d 采集 50 轮共 2 500 幅显微图像，其中部分含有夏孢子的显微图像样本如图 2 所示。

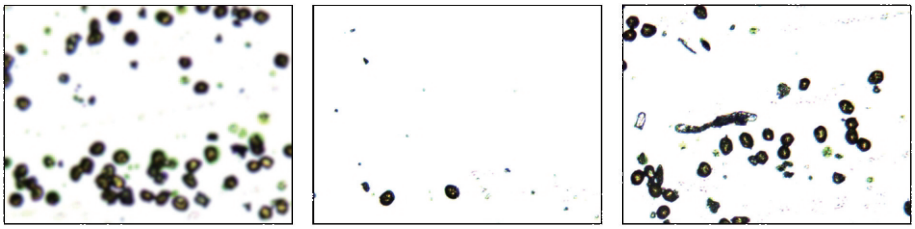

(a) 夏孢子离焦模糊显微图像　(b) 较少量夏孢子清晰显微图像　(c) 含杂质的夏孢子清晰显微图像

图 2　小麦条锈菌夏孢子显微图像样本

Fig. 2　Microscopic image samples of urediospores of wheat stripe rust

根据显微图像特点分析可得，由于野外环境复杂工况下终端上的显微成像模块在拍摄载玻片不同点的成像焦平面不完全一致，显微图像会出现离焦模糊现象，如图 2a 所示；同时，由于显微放大 200 倍后成像视野小，有大量图像内只有少量夏孢子或无夏孢子现象，如图 2b 所示；由于野外小麦复杂的生长环境，有部分图像背景中会出现灰尘等杂质，如图 2c 所示。经统计，剔除无夏孢子显微图像后，总计获取 500 幅清晰的夏孢子显微图像作为复原模型训练的初始数据集，获取 200 幅离焦模糊夏孢子显微图像用于后续模型实际验证。

1.3　数据集构建与预处理

夏孢子离焦模糊显微图像会出现高频信息缺失和夏孢子边缘模糊现象，使用生成对抗网络的模糊复原算法去模糊对后续夏孢子目标检测尤为重要。为提高模型泛化性，缓解因数据不足导致过拟合问题，随机对清晰夏孢子显微图像使用添加高斯噪声、角度变换、镜像变换、对比度变化等数据增强方法中的一种或几种，将初始数据集由 500 幅图像丰富扩充至 2 000 幅图像。然而，训练生成对抗网络模型需要匹配一致的清晰–模糊显微图像对作为训练集，而在成像放大 200 倍视野下自动获取一组图像内容完全一样的模糊–清晰图像难度过大，所以在此类试验中一般采用由清晰图像合成与之相对应的模糊图像方式来构建模型训练所需数据集。

本研究采用高斯模糊算法合成与清晰夏孢子显微图像相匹配的模糊图像。首先采用预设的正方形高斯核与清晰图像进行步长为 1 的卷积操作，接着根据不同模糊核得到模糊程度不同的夏孢子显微图像。上述步骤中，正方形高斯核边长为 N，N 取值范围为 16 ~ 100，高斯核中每个元素 $G(x,y)$ 计算公式为

$$G(x,y)=\frac{1}{2\pi\sigma^2}\mathrm{e}^{-\frac{x^2+y^2}{2\sigma^2}} \tag{1}$$

式中　σ——标准方差

x、y——对应当前位置到卷积核中心的整数距离

通过随机取值得到不同的高斯核边长 N 值，将扩充后的 2 000 幅清晰图像与不同 N 值的高斯模糊核进行卷积计算，得到对应清晰图像的 2 000 幅不同模糊程度的模糊图像，最终基于合成方法得到 2 000 对相互匹配的清晰–模糊夏孢子显微图像作为模型试验数据集，清晰–模糊夏孢子显微图像示例如图 3 所示。从图 3b 可看出，合成模糊图像与真实的离焦模糊图像较为相似，均具有高频和孢子边缘等信息缺失的特点，满足模型训练需求。将构建的清

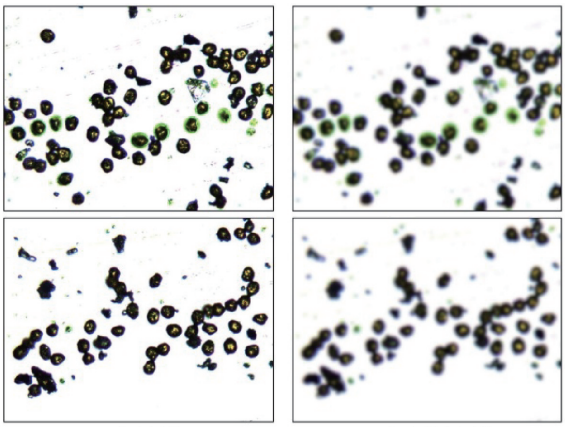

(a) 清晰图像 (b) 合成模糊图像

图 3 清晰-模糊夏孢子显微图像示例

Fig. 3 Examples of clear - blur microscopic image of urediospores

晰-模糊夏孢子显微图像数据集按照比例 6∶2∶2 划分为训练集、验证集和测试集,其中训练集为 1 200 对、验证集为 400 对、测试集为 400 对。

2 夏孢子离焦模糊显微图像复原方法

近年来,深度学习已在孢子检测领域取得了较大进展,但对输入图像清晰度有较高要求,在实际应用中对离焦模糊孢子检测鲁棒性不高,以 GAN 为典型代表的生成模型去离焦模糊能够有效提高后续孢子目标检测精度。基于 DeblurGANv2 模型的生成模型具有保留图像中丰富细节、创造出和真实图像十分接近的图像等优点,具有高效复原模糊夏孢子的潜力。鉴于此,本研究选择 DeblurGANv2 模型进行夏孢子离焦模糊复原方法的研究。

2.1 改进 DeblurGANv2 模型构建

DeblurGANv2 模型[23]由生成器和判别器两部分组成。生成器部分由特征提取主干网络、特征融合模块和图像复原模块组成。特征提取主干网络采用轻量化 MobileNet - v2 结构,具有更快的提取速度;特征融合模块采用特征金字塔(Feature pyramid network, FPN)结构,通过融合不同尺度的特征图,丰富了特征图中的高层语义信息和低层结构信息;图像复原模块由卷积层和上采样层组成,同时通过跳跃连接引入输入图像,指导复原出清晰图像。判别器部分利用双尺度判别器进行判别,采用局部判别器 patchGAN 对图像块进行判别的同时,引入全局判别器对图像整体进行判别,结合局部和全局判别器可使 DeblurGANv2 模型能更好地处理图像中更大更复杂的真实模糊。在 DeblurGANv2 模型训练过程中,首先,生成器输入待复原的模糊图像,生成相对应的复原清晰图像;接着,判别器输入来自生成器的复原清晰图像和真实清晰图像,判断两者是生成的还是真实的。生成器和判别器之间相互对抗,当判别器无法做出正确判断时训练完成,生成的复原清晰图像最为真实可信,此时生成器即可作为最终的图像复原生成模型。

虽然原始 DeblurGANv2 模型能较好地权衡速度与生成效果,但其在复原夏孢子离焦模糊显微图像时会出现高频和孢子边缘等细节信息复原不理想的问题,原始生成器采用 FPN 进行特征融合会增加浅层特征图的传播路径,导致浅层特征传递到深层时发生特征丢失的问题,同时自顶向下的融合方式也会使浅层特征无法影响到深层特征。因此本研究在特征融合模块后设计增加一个自底向上的 5 层特征增强模块,与 FPN 组成“双塔结构”,缩短浅层特征向深层特征的传播路径,增强不同尺度特征信息的相互融合,提升模型对高频和孢子边缘等信息的复原效果。此外,在特征提取主干网络部分引入卷积注意力机制(Convolutional block attention module, CBAM),其在空间和通道 2 个维度增加夏孢子特征信息的权重,提升模型对夏孢子的特征表达能力,丰富复原图像中夏孢子的细节信息。改进后 DeblurGANv2 模型夏孢子离焦模糊显微图像复原模型结构如图 4 所示。

2.2 特征增强模块

在主干网络进行特征提取时,浅层特征图中包含了更多的夏孢子特征信息,仅采用 FPN 进行特征融合会增加网络深度,导致浅层特征图传播到深层时发生特征丢失问题,同时 FPN 自顶向下的融合方式也会使浅层特征无法影响到深层特征。因此,设计了一个自底向上 5 层特征增强模块(图 4),单层特征增强融合方式如图 5 所示。从图 5 可看出,当 $i=1$ 时,FPN 最浅层特征图 P_1 横向连接为增强模块中最底层特征图 N_1,最底层特征图 N_1 经过一个步长为 2 的 3×3 的卷积下采样运算得到分辨率减半的特征图 N_2',此时其与 FPN 输出特征图 P_2 的分辨率相等,将特征图 N_2' 和 P_2 进行逐像素相加后再经过一个 3×3 卷积得到增强模块的 N_2 层特征图,计算公式为

$$N_{i+1}=N_i \oplus D_S(P_i) \quad (i=1,2,3,4) \tag{2}$$

式中 $\oplus$——逐像素相加操作符

D_S——下采样操作函数

P_i——特征金字塔输出的特征图

按照获取 N_2 层特征图的方法循环 3 次,依次得到增强模块 $N_3 \sim N_5$ 层特征图,如图 4 所示。最终以 $N_1 \sim N_5$ 5 个特征图作为特征融合模块输出特征图,代替原始 FPN 输出的 5 个尺度特征图输入给图像复原模块。

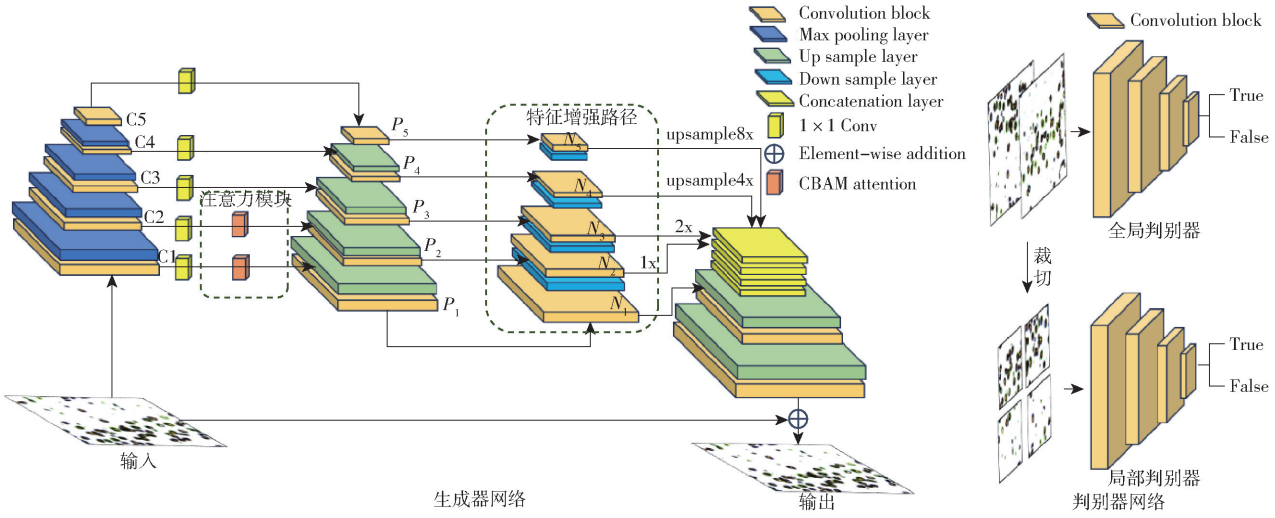

图 4　改进 DeblurGANv2 模型的夏孢子离焦模糊显微图像复原模型结构

Fig. 4　Restoration model structure of urediospore defocus blurred microimages based on improved DeblurGANv2

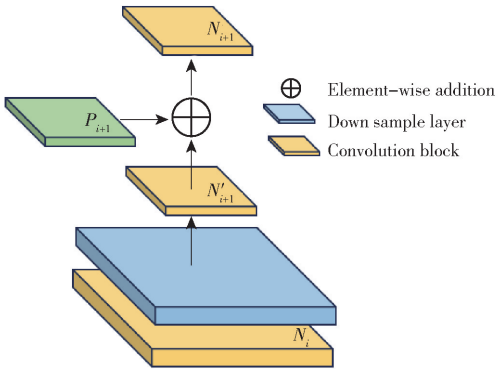

图 5　单层的特征增强融合方式

Fig. 5　Single-layer feature enhancement fusion method

2.3　CBAM 注意力机制

由于夏孢子体积较小，在图像中像素占比较低，因此在含有最多夏孢子纹理特征的 2 个较大尺度特征图中引入 CBAM 卷积注意力机制（图 4），来提升模型对夏孢子小目标特征表达能力，丰富复原图像中夏孢子细节信息。CBAM 是一种轻量级的注意力模块，其在空间维度和通道维度上分别计算注意力特征图，并与原始输入特征图相乘，增加特征图中重要信息的权重，具体结构如图 6 所示。

在通道维度上，对输入的夏孢子特征图在空间上进行平均池化和最大池化，在每个通道上，它的空间信息被压缩为一个单独的值，从而实现对全局空间信息压缩和提取，可以将特征图上的信息集中在通道上，强调重要通道信息，抑制不重要通道信息。

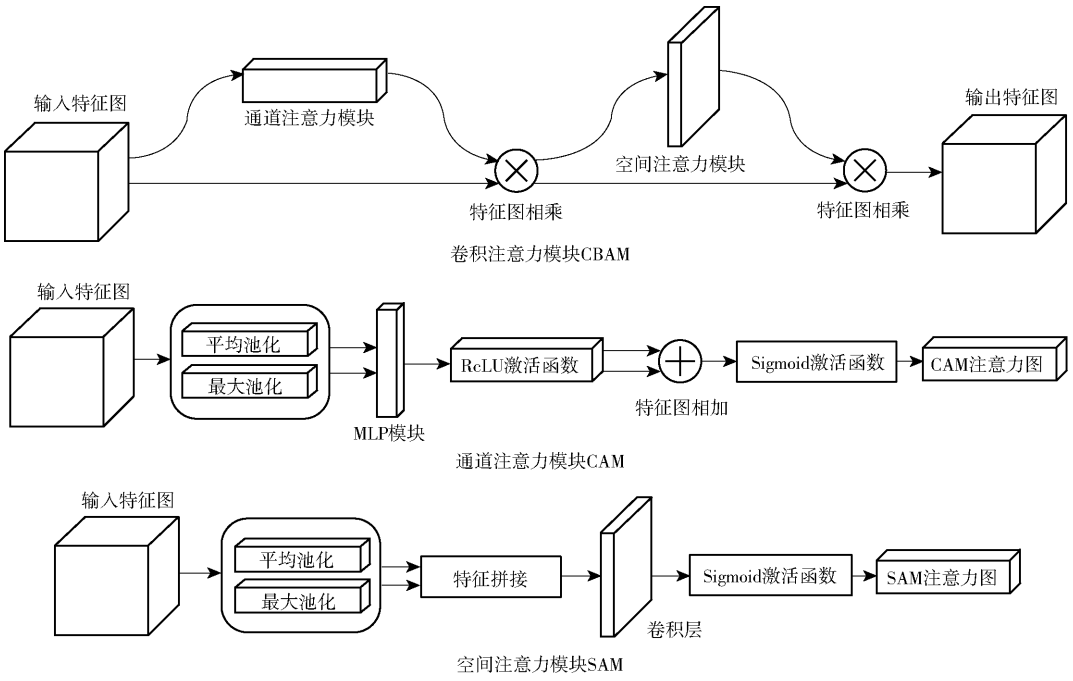

图 6　CBAM 注意力机制

Fig. 6　CBAM attention mechanism

在空间维度上,对输入的夏孢子特征图在通道上进行平均池化和最大池化,可以将输入特征图通道维度压缩为 1,使获得的特征信息全部分布在一个通道上,再将通过卷积层的输出通过 Sigmoid 函数生成权重向量,强调夏孢子目标的位置信息。

2.4 试验环境与参数设置

本研究试验模型算法基于 PyTorch 1.12.1 深度学习框架搭建,操作系统为 Windows 11(x64),CPU 型号为 AMD Ryzen 9 5950X,GPU 为 2 块 NVIDIA RTX 3090,内存 128 GB,使用 CUDA 11.3 版本进行 GPU 加速。所有对比算法均在相同的环境下运行,每批次处理样本数量为 8,迭代次数为 250,优化器采用 Adam,初始学习率设置为 1×10^{-4},从第 50 轮次后逐渐衰减为 1×10^{-7}。

2.5 复原模型评价指标

为验证模型图像去模糊性能,采用均方误差(MSE)、峰值信噪比(PSNR)、结构相似性(SSIM)指标和模型内存占用量作为评价指标。其中,均方误差为复原图像和真实图像的像素值之间的平均平方差,MSE 值越小表示复原图像的质量更高,更接近于真实图像;峰值信噪比计算复原图像中噪声所占比例,PSNR 值越高,表示噪声的比例越小,图像质量越高;结构相似性从亮度相似性、对比度相似性和结构相似性 3 个方面综合评价图像质量,用像素均值作为亮度的度量、像素标准差作为对比度的度量、像素协方差作为结构相似程度的度量,SSIM 取值范围为(-1,1),其值越大表示复原图像的质量更高,更接近于真实图像。

3 结果与分析

3.1 不同复原模型试验性能对比

为验证本研究模型相比当前主流去模糊复原模型的优越性,以均方误差、峰值信噪比、结构相似性、模型内存占用量为评价指标,将本研究模型与 DeblurGAN[22]、DeblurGANv2[23]、SRN-DeblurNet[27]、Deepdeblur[20]模型在相同计算平台和同一夏孢子显微图像数据集下进行复原对比试验,试验结果如表 1 所示。

通过表 1 可知,改进 DeblurGANv2 复原模型在均方误差、峰值信噪比和结构相似性均最优,分别为 0.001 4、28.88 dB、0.966,与原始 DeblurGANv2 模型相比,改进模型增加了特征增强模块和 CBAM 注意力机制,虽然模型内存占用量相比原始 DeblurGANv2 模型略有增加,但在均方误差、峰值信噪比和结构相似性分别提升 17.65%、3.29%、0.35%,均优于原始模型;与 DeblurGAN、SRN-DeblurNet 和 Deepdeblur 模型相比,本研究提出的改进 DeblurGANv2 复原模型在均方误差、峰值信噪比和结构相似性均实现不同程度的领先,同时模型内存占用量更小。通过以上分析,本文模型在多个指标方面均展现出了优越性,具有良好的综合性能,更适用于孢子显微图像去模糊任务。

表 1 不同复原模型试验结果性能对比

Tab.1 Comparison of performance between different restoration model experiments

模型	均方误差	峰值信噪比/dB	结构相似性	模型内存占用量/MB
DeblurGAN	0.001 8	26.65	0.958 7	43.52
DeblurGANv2	0.001 7	27.96	0.962 6	12.86
SRN-DeblurNet	0.006 2	21.46	0.897 6	31.52
Deepdeblur	0.001 6	27.72	0.954 1	44.83
改进 DeblurGANv2	0.001 4	28.88	0.966 0	14.36

3.2 不同注意力机制试验性能对比

为了验证所选取的 CBAM 注意力机制加入特征提取模块的有效性,将改进后模型中的注意力机制分别替换为 CA[28]、ECA[29]、SENet[30] 注意力模块,试验结果如表 2 所示。

表 2 不同注意力机制试验结果性能对比

Tab.2 Performance comparison of experimental results of different attention mechanisms

注意力机制	均方误差	峰值信噪比/dB	结构相似性	模型内存占用量/MB
无	0.001 7	27.96	0.962 6	12.86
CA	0.001 5	28.30	0.965 5	13.02
ECA	0.001 6	27.88	0.964 2	13.41
SENet	0.001 8	27.13	0.960 3	13.13
CBAM	0.001 4	28.88	0.966 0	14.36

由表 2 可知,添加不同注意力机制后,复原模型性能均有提升,虽然本研究添加 CBAM 注意力机制后模型内存占用量增加最大,但 CBAM 注意力机制在均方误差、峰值信噪比和结构相似性均表现出了最佳性能,与 CA、ECA、SENet 注意力机制对比,均方误差分别下降 6.67%、12.50%、22.22%,峰值信噪比分别提升 2.05%、3.59%、6.45%,结构相似性分别提升 0.05%、0.19%、0.59%。综合对比不同注意力机制的各项性能,表明本研究选择添加 CBAM 注意力机制作为提高复原模型特征表达能力的方案更为合理。

3.3 消融试验性能对比

为更直观展现特征增强模块和 CBAM 注意力机制对 DeblurGANv2 模型的不同影响,本消融试验采用上述夏孢子显微图像数据集,在原始模型上分别加入特征增强模块和 CBAM 注意力机制,对比其

试验结果，如表 3 所示。

表 3　消融试验结果性能对比

Tab. 3　Performance comparison of experimental results of ablation models

特征增强模块	CBAM	均方误差	峰值信噪比/dB	结构相似性	模型内存占用量/MB
×	×	0.001 7	27.96	0.962 6	12.86
√	×	0.001 4	28.51	0.965 6	14.34
×	√	0.001 6	28.09	0.963 5	13.12
√	√	0.001 4	28.88	0.966 0	14.36

注：“√”表示添加该模块，“×”表示未添加该模块。

由表 3 可看出，在原始模型分别添加特征增强模块和 CBAM 注意力机制后，复原模型性能均得到一定程度提升。添加特征增强模块后，相较原始 DeblurGANv2 模型，均方误差下降 17.65%，峰值信噪比提升 3.29%，结构相似性提升 0.35%，说明特征增强模块有效增强了不同尺度特征信息的相互融合，提升了模型对高频和孢子边缘等信息的复原效果；添加 CBAM 注意力机制后，相较原始模型，均方误差下降 5.88%，峰值信噪比提升 0.47%，结构相似性提升 0.09%，说明 CBAM 注意力机制可增加模型对夏孢子的特征表达能力，丰富了复原图像中夏孢子的细节信息。

3.4　复原模型对夏孢子检测性能影响对比

为了进一步验证提出的改进 DeblurGANv2 复原模型的有效性，选取 4 种主流目标检测模型 YOLO v5、Faster－R CNN、CenterNet 和 YOLO v8 对复原前后的图像进行夏孢子检测，比较其对检测性能的影响。本研究对上述 2 000 幅清晰夏孢子图像利用 LabelImg 软件完成人工标注，构建夏孢子检测模型数据集，并以比例 7∶2∶1 划分为训练集、验证集和测试集。在相同试验条件下，选取精确率(Precision，P)、召回率(Recall，R)和平均精度均值(mAP@0.5)作为检测模型性能的评价指标。其中，精确率表示预测正确的样本数占预测为正样本数的比例；召回率表示预测正确的样本数占实际为正样本数的比例；mAP@0.5 表示置信度设为 0.5 时 PR 曲线与坐标轴所围成区域的面积。不同模型在相同测试集上对夏孢子的检测结果如表 4 所示。

从表 4 可看出，4 种目标检测模型在检测前采用改进 DeblurGANv2 复原模型去模糊后，检测性能指标均有不同程度提升。其中，YOLO v5 在精确率、召回率、平均精度均值分别提升 1.4、2.1、18.5 个百分点；Faster－R CNN 分别提升 17.9、17.2、17.3 个百分点；结合改进 DeblurGANv2 复原的 CenterNet 模型检测性能表现较优，3 项评价指标分别为 95.1%、94.4%、97.1%，与直接使用 CenterNet 检测模型相比分别提升 2.3、2.2、25.3 个百分点；结合改进 DeblurGANv2 复原的 YOLO v8 模型检测性能表现最优，3 项评价指标分别为 96.1%、95.1%、97.7%，与直接使用 YOLO v8 检测模型相比分别提升 3.0、5.0、23.6 个百分点。综上表明，本文提出的改进 DeblurGANv2 复原模型可以复原出显微图像中离焦模糊夏孢子信息，显著提升了夏孢子目标检测模型检测性能。

表 4　不同模型夏孢子检测结果性能对比

Tab. 4　Performance comparison of different models for detection of urediospores　%

模型	精确率	召回率	平均精度均值
YOLO v5	92.9	92.1	79.1
复原＋YOLO v5	94.3	94.2	97.6
Faster－R CNN	77.6	71.5	75.2
复原＋Faster－R CNN	95.5	88.7	92.5
CenterNet	92.8	92.2	71.8
复原＋CenterNet	95.1	94.4	97.1
YOLO v8	93.1	90.1	74.1
复原＋YOLO v8	96.1	95.1	97.7

为更直观地对比不同模型检测效果，选取 YOLO v8 模型、较优的复原＋CenterNet 模型、最优的复原＋YOLO v8 模型进行可视化结果对比，如图 7 所示。其中，图 7a 为直接使用 YOLO v8 模型的夏孢子检测结果，由于未使用复原模型进行去模糊处理，显微图像存在一定程度的离焦模糊，使得图像中的高频信息和夏孢子边缘特征丢失严重，从而导致检测结果中存在严重的夏孢子漏检情况；图 7b 为使用改进 DeblurGANv2 复原＋CenterNet 模型的检测结果，相较于直接使用 YOLO v8 模型，夏孢子检测结果得到了一定改善，但仍存在部分误检和漏检问题；图 7c 为改进 DeblurGANv2 复原＋YOLO v8 模型的夏孢子检测结果，相较于直接使用 YOLO v8 模型，改进 DeblurGANv2 复原模型使离焦模糊图像中的高频信息和夏孢子边缘得到有效复原，复原图像中包含了更多夏孢子特征信息，使得漏检问题得到大幅改善，整体夏孢子检测表现最优。

3.5　复原模型实际应用验证对比

为了进一步检验改进 DeblurGANv2 复原模型在采集的真实离焦模糊夏孢子显微图像上的有效性，本试验采用智能监测终端采集的上述 200 幅夏孢子离焦模糊显微图像进行夏孢子目标检测实际应用验证。将真实的离焦模糊图像分别直接输入 YOLO v8 模型和性能表现最优的改进 DeblurGANv2 复原＋YOLO v8 模型进行夏孢子检测性能对比，检测结果如表 5 所示。

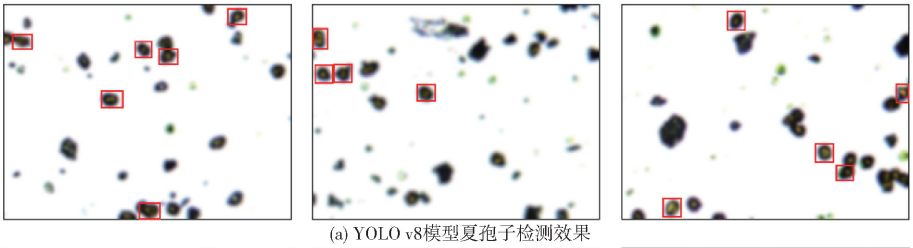

(a) YOLO v8模型夏孢子检测效果

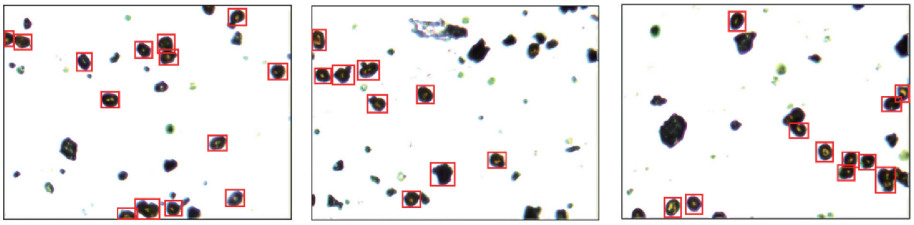

(b) 改进DeblurGANv2复原+CenterNet模型夏孢子检测效果

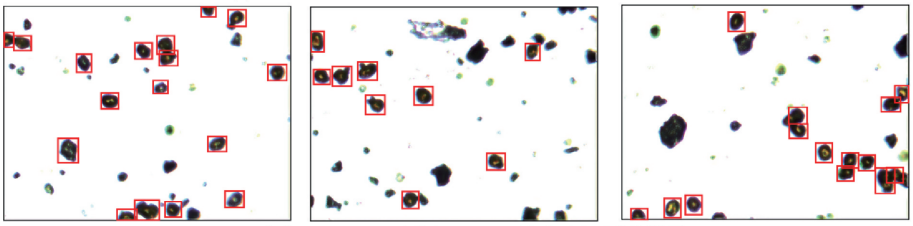

(c) 改进DeblurGANv2复原+YOLO v8模型夏孢子检测效果

图 7 不同夏孢子检测模型可视化结果对比

Fig. 7 Comparison of visualization results of different models for urediospore detection

表 5 真实离焦模糊图像夏孢子检测结果性能对比

Tab. 5 Spore detection results of different models

%

模型	精确率	召回率	平均精度均值
YOLO v8	92.6	87.5	73.3
复原 + YOLO v8	95.6	94.3	97.1

由表 5 可知,提出的改进 DeblurGANv2 复原 + YOLO v8 模型方法在真实离焦模糊图像数据集上的精确率、召回率及平均精度均值分别为 95.6%、94.3%、97.1%,与直接使用 YOLO v8 检测模型相比,精确率、召回率、平均精度均值分别提升 3.0、6.8、23.8 个百分点,各项指标均显著提升,表明本文使用的人工合成离焦模糊接近真实模糊情况,使用合成离焦模糊数据集训练的模型在处理真实离焦模糊显微图像时表现出较高的检测性能。

图 8 为真实离焦模糊显微图像夏孢子可视化检测效果图,从图 8a 可看出,将 YOLO v8 直接应用于真实离焦显微图像的夏孢子检测时,由于图像中存在一定程度的离焦模糊,使得高频信息和夏孢子边缘特征等信息丢失严重,导致严重的夏孢子漏检问题,整体检测效果不佳,用本文提出的改进 DeblurGANv2 复原 + YOLO v8 模型方法检测时,复原模型使离焦模糊图像中的高频信息和夏孢子边缘得到有效复原,漏检问题得到大幅改善,整体检测结

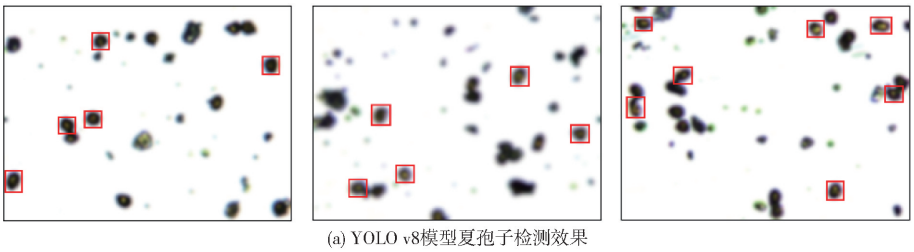

(a) YOLO v8模型夏孢子检测效果

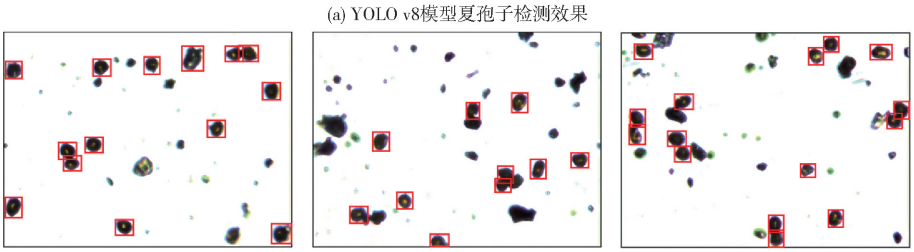

(b) 改进DeblurGANv2复原+YOLO v8模型夏孢子检测效果

图 8 真实离焦模糊显微图像夏孢子可视化检测效果

Fig. 8 Application of real defocus blur microimage visualization for urediospore detection

果得到较大程度提升，表明本文提出的改进 DeblurGANv2 模型的夏孢子离焦显微图像复原方法鲁棒性强，能有效提升夏孢子检测精度。

4　结论

（1）针对复杂工况下孢子捕捉设备显微成像易出现离焦模糊导致高频信息缺失和夏孢子边缘模糊等问题，本文提出了一种基于改进 DeblurGANv2 模型的小麦条锈菌夏孢子离焦显微图像复原模型，能够复原出显微图像中离焦模糊夏孢子信息。首先，在 DeblurGANv2 特征融合模块后设计增加一个自底向上的 5 层特征增强模块，增强不同尺度特征信息的相互融合，提升了模型对高频和孢子边缘等信息的复原效果；其次，在特征提取主干网络部分引入 CBAM 注意力机制，在空间和通道 2 个维度增加孢子特征信息的权重，提升了模型对夏孢子的特征表达能力，丰富了复原图像中夏孢子细节信息。

（2）改进后的 DeblurGANv2 复原模型均方误差、峰值信噪比和结构相似性分别为 0.001 4、28.88 dB、0.966，相较于原始 DeblurGANv2 模型分别提升 17.65%、3.29%、0.35%；4 种目标检测模型在结合改进 DeblurGANv2 复原模型去模糊后，夏孢子检测性能指标均有不同程度的提升，其中，结合改进 DeblurGANv2 复原的 YOLO v8 模型性能表现最优，精确率、召回率、平均精度均值分别为 96.1%、95.1%、97.7%，与直接使用 YOLO v8 检测模型相比分别提升 3.0、5.0、23.6 个百分点，验证了本文提出的改进 DeblurGANv2 复原模型可以复原出显微图像中离焦模糊夏孢子的信息，显著提升了夏孢子目标检测模型的检测性能，为气传小麦条锈菌夏孢子检测提供了有效技术支持。

参　考　文　献

[1] CHEN X M. Pathogens which threaten food security: *Puccinia striiformis*, the wheat stripe rust pathogen[J]. Food Security, 2020, 12(2): 239 – 251.

[2] 刘万才, 王保通, 赵中华,等. 我国小麦条锈病历次大流行的历史回顾与对策建议[J]. 中国植保导刊, 2022, 42(6): 21 – 27,41.
LIU Wancai, WANG Baotong, ZHAO Zhonghua, et al. Historical review and countermeasures of wheat stripe rust epidemics in China[J]. China Plant Protection, 2022, 42(6): 21 – 27,41. (in Chinese)

[3] ZHAO J, KANG Z. Fighting wheat rusts in China: a look back and into the future[J]. Phytopathology Research, 2023, 5(1): 1 – 30.

[4] CHEN W Q, WELLINGS C, CHEN X M, et al. Wheat stripe (yellow) rust caused by *Puccinia striiformis* f. sp. *tritici*[J]. Molecular Plant Pathology, 2014, 15(5): 433 – 446.

[5] XU X M, MA L J, HU X P. Overwintering of wheat stripe rust under field conditions in the northwestern regions of China[J]. Plant Disease, 2019, 103(4): 638 – 644.

[6] 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.
LI Xiaolong, MA Zhanhong, SUN Zhenyu, et al. Automatic counting for trapped urediospores of *Puccinia striiformis* f. sp. *tritici* based on image processing[J]. Transactions of the CSAE, 2013, 29(2): 199 – 206. (in Chinese)

[7] 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 CSAE, 2015, 31(12): 186 – 193. (in Chinese)

[8] 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.

[9] WANG Y F, DU X X, MA G X,et al. Classification methods for airborne disease spores from greenhouse crops based on multifeature fusion[J]. Applied Sciences, 2020, 10(21): 7850.

[10] 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)

[11] ZHANG D Y, ZHANG W H, 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.

[12] ZHANG D, ZHANG W, CHENG T, et al. Segmentation of wheat scab fungus spores based on CRF_ResUNet plus[J]. Computers and Electronics in Agriculture, 2024, 216: 108547.

[13] ZHOU H, LAI Q, HHUANGG Q, et al. Automatic detection of rice blast fungus spores by deep learning-based object detection: models, benchmarks and quantitative analysis[J]. Agriculture, 2024, 14(2): 290.

[14] 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. 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)

[15] LI K Y, ZHU X Y, QIAO C, et al. The gray mold spore detection of cucumber based on microscopic image and deep learning [J]. Plant Phenomics, 2023, 5: 0011.

[16] ZHU X, CHEN F, QIAO C, et al. Cucumber pathogenic spores' detection using the GCS-YOLOv8 network with microscopic images in natural scenes[J]. Plant Methods, 2024, 20(1): 131.

[17] 雷雨, 姚志凤, 何东健. 小麦条锈病菌夏孢子显微图像远程采集系统设计与试验[J]. 农业机械学报, 2018, 49(11): 39-47.
LEI Yu, YAO Zhifeng, HE Dongjian. Design and experiment of micro-image remote acquisition system of uredinispores of *Puccinia striiformis* f. sp. *tritici*[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(11): 39-47. (in Chinese)

[18] 胡张颖, 周全, 陈明举, 等. 图像去模糊研究综述[J]. 中国图象图形学报, 2024, 29(4): 841-861.
HU Zhangying, ZHOU Quan, CHEN Mingju, et al. Survey of image deblurring[J]. Journal of Image and Graphics, 2024, 29(4): 841-861. (in Chinese)

[19] XIANG Y W, ZHOU H, LI C Y, et al. Deep learning in motion deblurring: current status, benchmarks and future prospects [J/OL]. Visual Computer, 2024: 1-27. https://web of science. clarivate. cn/wos/alldb/full-relord/WOS:001320081400002.

[20] NAH S, KIM T H, LEE K M. Deep multi-scale convolutional neural network for dynamic scene deblurring[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 257-265.

[21] TAO X, GAO H Y, SHEN X Y, et al. Scale-recurrent network for deep image deblurring[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 8174-8182.

[22] KUPYN O, BUDZAN V, MYKHAILYCH M, et al. DeblurGAN: blind motion deblurring using conditional adversarial networks[C]//31st IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 8183-8192.

[23] KUPYN O, MARTYNIUK T, WU J, et al. DeblurGAN-v2: deblurring (orders-of-magnitude) faster and better[C]//Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2019: 8877-8886.

[24] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//30th IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 936-944.

[25] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]//31st IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 4510-4520.

[26] 蔡舒平, 潘文浩, 刘慧, 等. 基于 D2-YOLO 去模糊识别网络的果园障碍物检测[J]. 农业机械学报, 2023, 54(2): 284-292.
CAI Shuping, PAN Wenhao, LIU Hui, et al. Orchard obstacle detection based on D2-YOLO deblurring recogntion network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 284-292. (in Chinese)

[27] TAO X, GAO H, SHEN X, et al. Scale-recurrent network for deep image deblurring[C]//31st IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 8174-8182.

[28] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 13708-13717.

[29] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 11534-11542.

[30] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.