doi:10.6041/j.issn.1000-1298.2026.18.026

基于多尺度超分辨率生成对抗网络的水稻病害识别方法

苑迎春[1,2]　马小赫[1]　贾　佳[1]　陈聪聪[3]　张龙超[1]

(1.河北农业大学信息科学与技术学院,保定 071001;2.农业遥感应用河北省工程研究中心,保定 071001;
3.河北农业大学园艺学院,保定 071001)

摘要:针对水稻病害识别过程中受采集条件限制导致图像分辨率较低、病斑细节缺失,从而影响识别精度的问题,本文提出了一种基于多尺度超分辨率生成对抗网络的水稻病害识别方法(ESRG_E)。该方法在超分辨率重建网络(ESRG)中,首先,设计了动态多尺度残差嵌套块(DMS-RRDB),其中动态多尺度机制增强网络对不同尺度病斑结构的表征能力,残差嵌套结构提升高频细节的重建能力;其次,设计并行双窗口自注意力模块(PDSA),通过设置窗口不同尺寸,以增强病斑区域特征的聚焦能力和空间结构一致性,从而突出关键病斑结构;此外,引入双感知损失函数(DP Loss),以强化重建结果的判别性约束,缓解传统损失函数导致的过度平滑问题。最后,将超分辨率重建网络与识别性能较优的 EfficientNet 分类网络相结合,以提升病害识别精度。试验结果表明,在图像超分辨率重建方面,峰值信噪比(PSNR)和结构相似性指数(SSIM)平均分别提升 1.43 dB 和 0.035;将超分辨率重建网络与多种分类模型结合后,其准确率均高于低分辨率输入,平均提升 6.3 个百分点。在模型对比试验中,本文方法水稻病斑识别准确率较其他模型提升 1.28 个百分点,最终达到 97.6%。本文方法提升了低分辨率水稻病害图像重建质量与识别性能,为复杂田间环境下水稻病害智能监测提供了技术支撑。

关键词:水稻病害识别;超分辨率重建;生成对抗网络;注意力机制;动态多尺度

中图分类号:TP391　　**文献标识码**:A　　**文章编号**:1000-1298(2026)18-0311-11　　**OSID**:

Rice Disease Recognition Method Based on Multiscale Super-resolution Generative Adversarial Network

Yuan Yingchun[1,2]　Ma Xiaohe[1]　Jia Jia[1]　Chen Congcong[3]　Zhang Longchao[1]

(1. *College of Information Science and Technology*, *Hebei Agricultural University*, *Baoding* 071001, *China*
2. *Hebei Engineering Research Center for Agricultural Remote Sensing Application*, *Baoding* 071001, *China*
3. *College of Horticulture*, *Hebei Agricultural University*, *Baoding* 071001, *China*)

Abstract: Aiming at the problem that low image resolution and missing lesion details caused by limited acquisition conditions in rice disease recognition degraded the recognition accuracy, a rice disease recognition method was proposed based on a multi-scale super-resolution generative adversarial network (ESRG_E). In the proposed method, a super-resolution reconstruction network (ESRG) was firstly constructed by designing a dynamic multi-scale residual-in-residual dense block (DMS-RRDB), in which the dynamic multi-scale mechanism enhanced the representation ability for lesion structures at different scales, while the residual-in-residual architecture improved the reconstruction of high-frequency details. Then, a parallel dual-window self-attention module (PDSA) was introduced, where different window sizes were adopted to strengthen the focus on lesion regions and maintain spatial structural consistency, thereby highlighting key lesion structures. In addition, a dual-perceptual loss function (DP Loss) was employed to enhance discriminative constraints on the reconstructed results and alleviate the over-smoothing problem caused by traditional loss functions. Finally, the super-resolution reconstruction network was combined with the EfficientNet classification network with superior recognition performance to further improve disease identification accuracy. Experimental results showed that, in terms of image super-resolution reconstruction, the peak signal-to-noise ratio (PSNR) and structural similarity index (SSIM) were improved by an average of 1.43 dB and 0.035, respectively. When combined with various classification models, the reconstructed images achieved higher recognition accuracy than low-resolution

收稿日期:2026-02-07　修回日期:2026-04-23

基金项目:河北省高等学校科学研究项目(CYZD2026004)

作者简介:苑迎春(1970—),女,教授,博士生导师,主要从事智能信息处理与大数据技术研究,E-mail:nd_hd_yyc@163.com

inputs, with an average improvement of 6.3 percentage points. In comparative experiments, the proposed method improved rice lesion recognition accuracy by 1.28 percentage points over other models, reaching 97.6%. The proposed method significantly enhanced the reconstruction quality and recognition performance of low-resolution rice disease images, providing technical support for intelligent monitoring of rice diseases in complex field environments.

Key words: rice disease recognition; super-resolution reconstruction; GAN; attention mechanism; dynamic multi-scale

0 引言

水稻作为我国主要粮食作物之一[1],其病害的精准识别对保障粮食安全具有重要意义。随着农业信息化与智能化的发展,基于深度学习的图像识别方法因具备较强的特征学习能力[2],已广泛应用于水稻病害识别任务[3-4]。其中,卷积神经网络在高分辨率病斑图像中表现出良好的识别性能[5-8]。

然而,在实际田间采集条件下,受成像距离、设备性能及环境因素等影响,获取的水稻病害图像往往分辨率较低,病斑细节模糊,导致识别性能下降[9-11]。为此,研究者引入超分辨率重建技术,通过提升图像质量以增强病害识别效果。Yamamoto 等[12]首先将深度学习超分辨率方法应用于植物病害识别任务,利用超分辨率卷积神经网络(Super-resolution convolutional neural network,SRCNN)对番茄病害图像进行重建,有效恢复细节并提升识别性能。Wang 等[13]基于 GAN 提出生成对抗分类网络(Generative adversarial classified network,GACN),通过生成高分辨率合成图像缓解病害数据不平衡问题,从而提高分类性能。Maqsood 等[14]采用超分辨率生成对抗网络(Super-resolution generative adversarial network,SRGAN)重建低分辨率小麦黄锈病图像,并结合卷积神经网络进行分类,使准确率由 75% 提升至 83%。Zha 等[15]提出一种基于改进增强超分辨率生成对抗网络(Enhanced super-resolution generative adversarial network,ESRGAN)的轻量级超分辨率网络,实现番茄叶病害图像的高效重建,并与 VGG16 结合获得较高分类性能。综上,基于生成对抗网络的超分辨率方法在提升低分辨率植物病害图像重建质量和识别性能方面取得了显著进展。但在边缘细节与结构信息重建上仍存在不足,难以充分保留关键病斑特征,从而制约了其在复杂田间环境下的病害识别性能提升。

为提升生成对抗网络在图像重建任务中的性能,已有研究围绕网络结构与特征建模方式提出了多种改进策略,主要集中在注意力机制引入与多尺度特征建模 2 个方面:①文献[16-17]通过将注意力机制引入超分辨率生成器,增强网络对长程依赖关系和上下文信息的建模能力。②文献[18-20]通过在生成器或判别器中引入多尺度结构,增强模型对不同尺度信息的表达能力。然而,在植物病害图像中,不同尺度病斑特征对分类判别的贡献存在显著差异,仅依赖注意力机制或仅依赖多尺度建模,均难以同时突出对病害识别具有关键作用的病斑区域并保持病斑结构特征的完整表达。

为弥补上述不足,研究者将多尺度特征建模与注意力机制相结合,以实现对关键判别信息的动态聚焦。Yin 等[21]基于改进的 ESRGAN 设计了多尺度特征提取与通道注意力相结合的超分辨率重建方法,通过多尺度特征融合与特征权重自适应调节,有效提升了高频细节的恢复效果。李义等[22]提出融合多尺度特征提取与坐标注意力的 GAN 超分辨率模型,结合多感受野残差结构与注意力机制,有效提升图像细节恢复与结构还原能力。上述研究表明,多尺度结构与注意力机制的结合能够显著提升生成对抗网络在高频细节恢复和结构建模方面的能力,有效增强超分辨率重建图像的视觉质量。

尽管注意力机制与多尺度结构已被应用于超分辨率重建并取得一定进展,但针对复杂田间环境下的水稻病害图像,现有方法仍存在不足:图像易受到光照变化、背景干扰及成像距离等因素影响,导致病斑细节模糊,关键特征难以稳定恢复;不同病害在尺度和形态上差异显著,现有方法多采用固定结构,缺乏对多尺度病斑特征的自适应建模能力,难以兼顾细粒度纹理恢复与整体结构表达。在此情况下,现有方法难以同时实现整体结构保持与关键病斑细节增强,从而限制了重建质量的进一步提升。

针对上述问题,以 ESRGAN 和 EfficientNet 为基础,本文提出一种基于动态多尺度超分辨率生成对抗网络的水稻病害识别模型(Enhanced super-resolution GAN EfficientNet-based model,ESRG_E),以期实现低分辨率条件下水稻叶片病害图像的高质量重建与精准识别。

1 试验数据

1.1 数据来源

所使用数据集由 4 种常见水稻病害和健康叶片

构成，均来源于公开平台 Kaggle 网站（https://www.kaggle.com），由研究人员采集并整理后向公众开放。数据集包含水稻（Oryza sativa）的叶片图像，涵盖 4 类常见病害以及健康样本，包含 1 548 幅白叶枯病图像（Bacterial blight）、1 440 幅稻瘟病图像（Blast）、1 600 幅褐斑病图像（Brown spot）、1308 幅条纹矮缩病（Tungro）图像和 450 幅健康叶片图像（Healthy），图像分辨率为 300 像素 ×300 像素或以上。

1.2　数据集构建与降质处理

在图像超分辨率任务中，需要成对的高分辨率图像（High resolution，HR）和低分辨率图像（Low resolution，LR）。试验将数据集图像调整为 256 像素 ×256 像素的 HR 图像，然后将其通过 Bicubic 插值法、添加高斯噪声、JPEG 压缩等方法[23]进行降质处理模拟真实场景下的低分辨率图像，调整尺寸为 64 像素 ×64 像素，如图 1 所示。最终形成 2 500 对 LR 和 HR 图像，按比例 3∶1∶1划分为训练集、验证集和测试集。

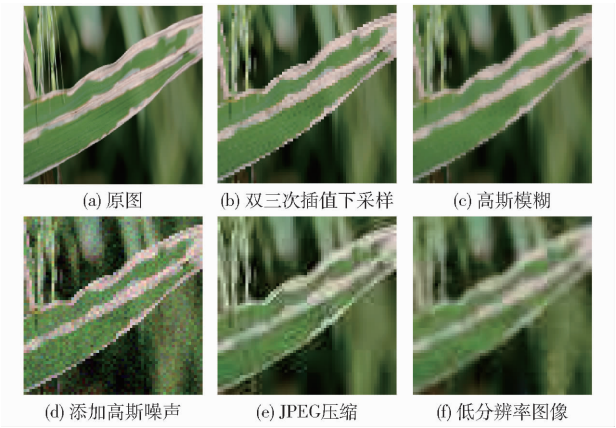

图 1　高分辨率图像降质效果

Fig. 1　High-resolution image degradation effects

2　基于多尺度超分辨率重建的水稻病害识别模型

针对水稻病害图像采集时受设备条件限制导致分辨率较低，难以满足高效精准识别的问题，设计了一种基于多尺度的超分辨率生成对抗网络的水稻病害识别模型（ESRG_E），模型整体结构如图 2 所示，

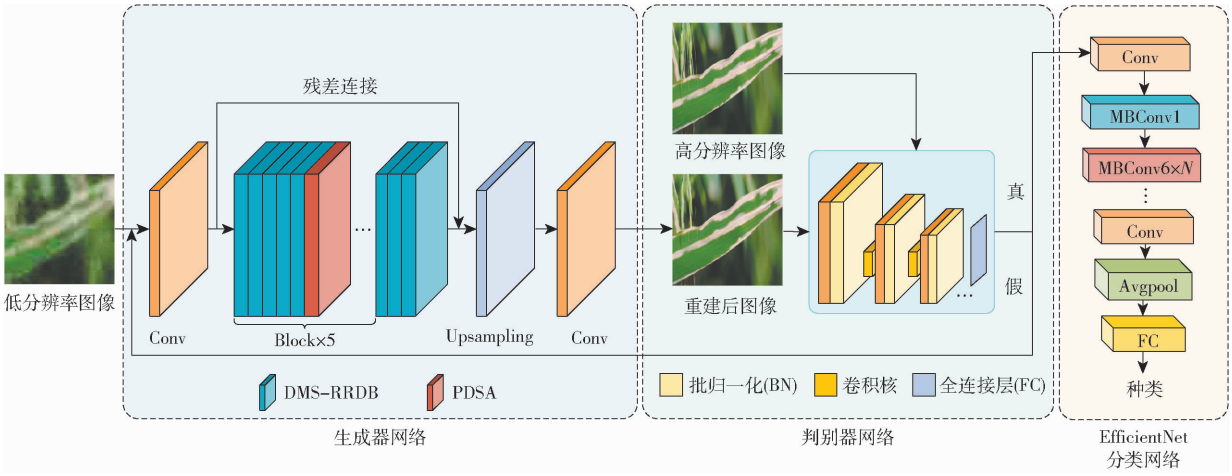

图 2　ESRG_E 模型结构

Fig. 2　ESRG_E model structure

主要由超分辨率重建网络和分类网络 2 部分组成。

在超分辨率重建网络（Enhanced super-resolution GAN，ESRG）上，以 ESRGAN[24]为基础进行改进。针对不同类型水稻病斑呈现出尺度差异大、局部纹理复杂的特点，在生成器中设计动态多尺度残差嵌套块（Dynamic multi-scale Residual-in-Residual block，DMS－RRDB），增强不同尺度病斑特征的表达能力和高频细节重建能力；同时，考虑到病斑区域在图像中分布不均且易受背景干扰，在网络中以固定间隔引入并行双窗口自注意力机制（Parallel dual-window self-attention module，PDSA）模块，增强病斑区域特征的聚焦能力与空间结构一致性。此外，为缓解传统超分辨率损失函数导致的过度平滑问题，引入双感知损失函数（Dual Perceptual Loss，DP Loss）对训练过程进行约束，引导生成图像保留更有利于后续分类的判别信息。

上述 3 个模块针对水稻病害图像中尺度变化显著、局部特征易弱化以及判别信息不足等问题形成协同机制。DMS－RRDB 侧重于提升多尺度结构信息的表达能力；PDSA 进一步强化关键病斑区域的特征响应并保持空间一致性；DP Loss 则从语义层面约束重建方向，使生成结果更具判别性。三者相互配合，共同提升重建图像对下游病害识别任务的适配性与整体性能。

在此基础上，低分辨率图像（LR）经超分辨率重建后与真实高分辨率图像（HR）共同参与判别器对

抗训练,判别通过的重建结果进一步用于病害分类,未通过的样本则反向约束生成网络的优化过程[25]。

在识别模型(ESRG_E)中,重建后的高质量病斑图像被输入至 EfficientNet 网络[26]。该网络能够更准确地捕捉病害的显著特征[27],实现对不同类型水稻病害的高精度识别。

2.1 动态多尺度残差嵌套块(DMS-RRDB)

针对水稻病害图像中病斑尺度差异显著、细节纹理模糊的问题,借鉴残差密集块(Residual-in-residual dense block,RRDB)思路,引入动态多尺度特征建模机制,设计了一种动态多尺度残差嵌套块(DMS-RRDB),整体结构如图 3 所示。

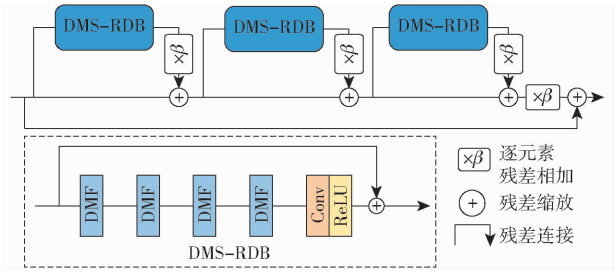

图 3 DMS-RRDB 结构

Fig. 3 DMS-RRDB structure

DMS-RRDB 采用残差嵌套结构,通过在模块内部引入局部残差连接并在外部构建整体残差路径,提升高频细节的重建能力,以解决病斑细节纹理模糊的问题。在此基础上,模块内部级联多个动态多尺度残差块(DMS-RDB),并在每个 DMS-RDB 中引入动态多尺度特征融合模块(Dynamic multi-scale feature fusion,DMF),通过增强网络对不同尺度病斑结构的表征能力,以解决病斑尺度差异显著的问题。

通过将动态多尺度机制与残差嵌套结构相结合,DMS-RRDB 能够在保证训练稳定性的同时,实现病斑高频细节与多尺度结构信息的协同增强,提升细微病变区域结构整体重建效果[28]。

DMF 模块具体结构如图 4 所示,模块采用多分支多尺度卷积结构,通过并行设置实现不同尺度特征的同步提取,从而增强网络对不同尺寸病斑目标及其细节信息的表征能力。在此基础上,DMF 引入门控生成器(Gate Generator)机制,根据输入特征自适应生成各尺度分支的融合权重,并通过 Softmax 函数进行归一化,以实现多尺度特征动态加权融合。

设输入特征图为

$$X \in \mathbf{R}^{B\times C\times H\times W} \tag{1}$$

式中 B——批大小 C——通道数

H、W——空间尺寸,取 64

DMF 模块通过并行多尺度卷积提取不同感受野的特征,分别采用 3×3、5×5 卷积及扩张卷积,其中各分支输出特征在通道数与空间尺寸上保持一致,得到多尺度特征表示为

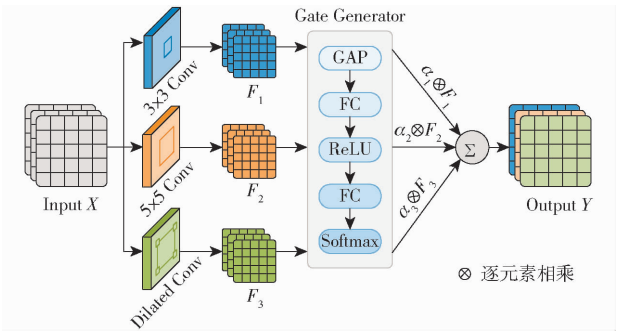

图 4 动态多尺度特征融合模块

Fig. 4 Dynamic multi-scale feature fusion module

$$F_k = f_k(X) \quad (k=1,2,3) \tag{2}$$

式中 $f_k(\cdot)$——对应尺度的卷积运算

为自适应调节不同尺度特征的贡献比例,引入门控生成器。首先对各分支特征进行全局平均池化,获得全局上下文描述,即

$$\boldsymbol{g}_k = \mathrm{GAP}(F_k) \in \mathbf{R}^{B\times C} \tag{3}$$

式中 GAP——全局平均池化

随后将各尺度全局特征进行拼接,并通过 2 层全连接网络与 ReLU 激活,得到各尺度的注意力权重,即

$$\alpha = \mathrm{Softmax}(\mathrm{FC}_2(\mathrm{ReLU}(\mathrm{FC}_1(\boldsymbol{g}_1,\boldsymbol{g}_2,\boldsymbol{g}_3)))) \tag{4}$$

式中 $\boldsymbol{g}_1$、$\boldsymbol{g}_2$、$\boldsymbol{g}_3$——不同尺度的全局特征向量

$\mathrm{ReLU}(\cdot)$——输出特征映射中元素位置

$\mathrm{Softmax}(\cdot)$——输入特征映射通道数

$\mathrm{FC}_1(\cdot)$——第 1 层全连接层

$\mathrm{FC}_2(\cdot)$——第 2 层全连接层

最后,根据生成的权重对多尺度特征进行加权融合,得到 DMF 模块输出为

$$Y = \sum_{k=1}^{3} \alpha_k F_k \tag{5}$$

通过上述机制,DMF 模块能够根据输入特征自适应分配不同尺度信息的权重,从而增强网络对不同尺度病斑区域细节与复杂纹理的表征能力。本质上,该过程是一种由输入驱动的多尺度特征选择策略,通过对不同感受野特征的自适应选择,实现对小尺度斑点与大尺度条状病斑的差异化建模。

2.2 并行双窗口自注意力机制(PDSA)

在引入 DMS-RRDB 模块后,重建后水稻病害图像的病斑细节得到明显增强,但仍存在关键病斑结构难以突出的问题。为解决上述问题,引入并行双窗口自注意力机制(PDSA)。

PDSA 将输入特征映射划分为 2 种不同尺寸的

局部窗口，即小窗口（8 × 8 分块）与大窗口（16 × 16 分块），并分别输入至 2 个并行分支中独立进行自注意力计算[29]。窗口尺寸的选择综合考虑了输入特征图分辨率及计算开销，较小窗口能够提升局部建模能力，但过小会限制上下文信息；较大窗口有助于增强全局感知，但会显著增加计算复杂度。因此，选取 8 和 16 作为窗口尺度，在保证建模能力的同时兼顾计算效率。

小窗口分支侧重于增强病斑区域特征的局部聚焦能力，使病斑在局部区域内更加清晰可辨；大窗口分支通过建模更大范围的空间依赖关系，用于强化病斑结构的整体一致性。二者协同作用，使关键病斑结构在重建结果中更加突出，如图 5 所示。

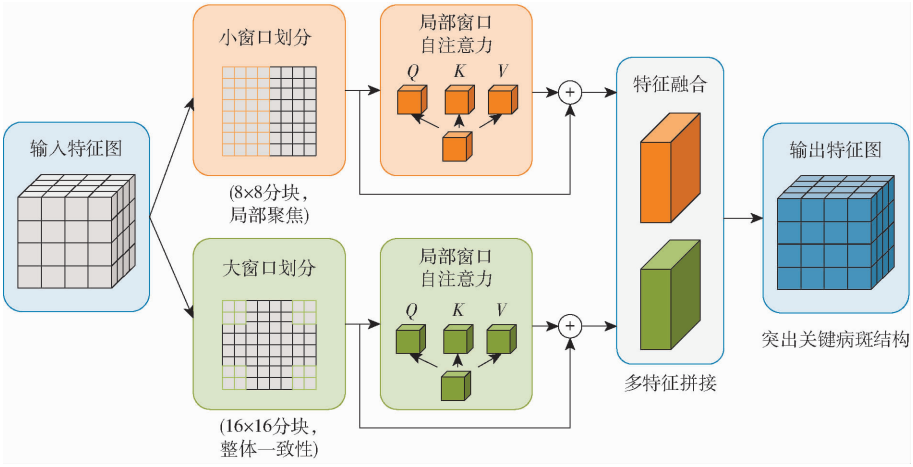

图 5　并行双窗口自注意力机制

Fig. 5　Parallel dual-window self-attention mechanism

输入特征映射为 $\boldsymbol{X}_o \in \mathbf{R}^{N\times d}$，对于任一尺度分支，其注意力计算过程可表示为

$$\boldsymbol{X}_{\text{out}} = \text{MSA}(\boldsymbol{X}_o\boldsymbol{W}_Q, \boldsymbol{X}_o\boldsymbol{W}_K, \boldsymbol{X}_o\boldsymbol{W}_V) \tag{6}$$

式中　$\boldsymbol{W}_Q$——查询（Query）线性映射矩阵

$\boldsymbol{W}_K$——键（Key）线性映射矩阵

$\boldsymbol{W}_V$——值（Value）线性映射矩阵

$\boldsymbol{X}_{\text{out}}$——输出特征矩阵

$\boldsymbol{X}_o$——输入特征矩阵

MSA（·）——多头自注意力

其中，$\boldsymbol{W}_Q, \boldsymbol{W}_K, \boldsymbol{W}_V \in \mathbf{R}^{d\times d}$ 且可在双窗口分支间共享或独立设置以平衡性能与效率。

两分支输出经融合函数 $F_{\text{agg}}(\cdot)$ 进行整合，并通过残差连接增强梯度传播稳定性，得到最终输出特征，即

$$X_{PDSA} = F_{\text{agg}}(X_s', X_l') + \boldsymbol{X}_o \tag{7}$$

式中　X_s'——小窗口分支输出特征

X_l'——大窗口分支输出特征

$F_{\text{agg}}(\cdot)$——融合函数

X_{PDSA}——最终输出特征

通过将小窗口的局部聚焦能力与大窗口的结构建模能力进行残差融合，PDSA 能够同时兼顾病斑聚焦与结构一致性约束，使关键病斑结构在重建结果中更加清晰且连贯。

2.3　损失函数

由于传统超分辨率损失函数优化目标和水稻病害识别任务需求不一致，易导致重建结果过度平滑的问题，所以在 ESRGAN 的基础上改进了损失函数设计。传统 ESRGAN 模型的生成器损失 L_G 通常由 3 部分组成：像素损失 L_{pixel}、感知损失 L_{per} 和对抗损失 L_{adv}。综合形式为

$$L_G = L_{\text{pixel}} + \lambda_{\text{per}}L_{\text{per}} + \lambda_{\text{adv}}L_{\text{adv}} \tag{8}$$

式中　λ_{per}——感知损失权重系数

λ_{adv}——对抗损失权重系数

传统感知损失仅基于 VGG 网络的特征空间计算差异，能够提升图像的主观质量，但在农业病害图像中常出现细节模糊或病斑纹理失真的问题。

为更全面地度量图像的视觉差异，采用 Song 等[30]提出的双感知损失（DP Loss），同时利用 VGG19 与 ResNet50 2 种特征空间的特征映射，从而在优化过程兼顾低层纹理细节与高层结构语义。

DP Loss 定义为

$$L_{\text{DP}} = \alpha \| \phi_{\text{VGG}}(I_{SR}) - \phi_{\text{VGG}}(I_{HR}) \|_1 + \beta \| \phi_{\text{Res}}(I_{SR}) - \phi_{\text{Res}}(I_{HR}) \|_1 \tag{9}$$

式中　$\phi_{\text{VGG}}(\cdot)$——VGG19 特征映射

$\phi_{\text{Res}}(\cdot)$——ResNet50 特征映射

α——VGG19 损失权重系数

β——ResNet50 损失权重系数

I_{SR}——超分辨率重建图像

I_{HR}——真实高分辨率图像

与传统 VGG 感知损失相比，DP Loss 在重建过程中能同时关注病斑区域的局部纹理和整体形态，显著减少过度平滑现象，并提升模型对复杂病斑纹

理的恢复能力。

所以生成器总损失函数定义为

$$L_G = L_{\text{pixel}} + \lambda_{\text{DP}} L_{\text{DP}} + \lambda_{\text{adv}} L_{\text{adv}} \tag{10}$$

式中 λ_{DP}——双感知损失权重系数

通过引入 DP Loss,模型在病斑区域的纹理恢复与边缘重建方面均取得显著提升,同时保持良好的全局结构一致性。

3 结果与分析

在 Intel(R) Core(TM) i9 - 12900K 处理器、32 GB 内存及 NVIDIA GeForce RTX3090 显卡的硬件环境下进行试验。软件环境为 Windows 10 操作系统,开发工具为 PyCharm,编程语言为 Python 3.8,深度学习框架采用 PyTorch 1.10.0。网络训练使用 Adam 优化器[31],Batch size 为 4,初始学习率为 1×10^{-4},迭代次数为 5 000,输入的水稻病斑 LR 图像尺寸为 64 像素 ×64 像素,输出的重建 HR 图像尺寸为 256 像素 ×256 像素[32]。

3.1 ESRG 模型重建效果

3.1.1 重建性能定量分析

为验证本文方法的图像分辨率重建效果,采用 Bicubic、SRGAN、ESRGAN、SEAM - ESRGAN、MFRSCN、SwinIR 以及 Stable Diffusion-based SR(SD - SR)等典型超分辨率方法作为对比基线,进行对比试验。评价指标为峰值信噪比(PSNR,单位为 dB)和结构相似性(SSIM),结果如图 6 所示。

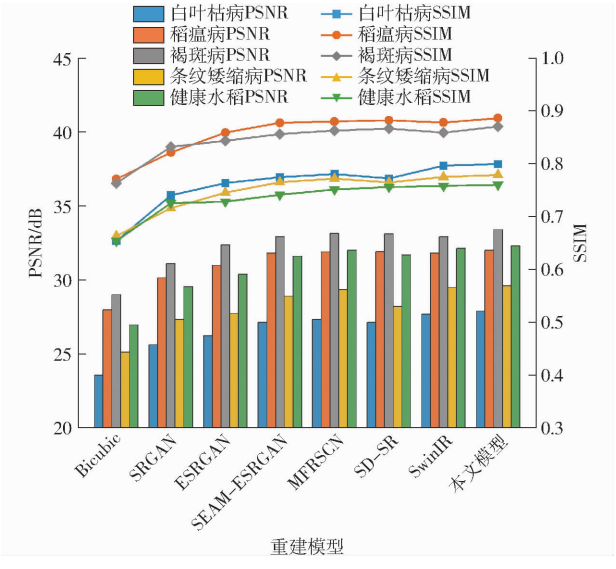

图 6 不同重建模型在水稻叶片图像中 PSNR/SSIM 结果

Fig. 6 Results of PSNR and SSIM among different reconstruction models for rice leaf images

由图 6 可知,本文提出的多尺度超分辨率生成对抗网络(ESRG)在整体性能上优于其他方法。尽管 SwinIR 和 MFRSCN 在部分病害类别上的指标与本文方法较为接近,但本文方法在 PSNR 和 SSIM 上均取得最优结果,平均分别提升 1.43 dB 和 0.035。

从不同病害类别的对比结果来看,本文方法在 5 类水稻图像上均取得最高的 PSNR 和 SSIM。与近年来的方法[33-34]相比,SwinIR 虽整体性能接近,但在病斑尺度较小、纹理结构复杂的稻瘟病和褐斑病图像上,其重建效果仍略低于本文方法。基于扩散模型的 SD - SR 在白叶枯病和条纹矮缩病等病斑结构较大的图像上表现相对较弱。尤其在纹理复杂的白叶枯病图像上,本文方法 PSNR 相较于 MFRSCN 仍提升 0.54 dB。

综上,本文方法能够更有效地抑制噪声和伪影,并提高病斑纹理和结构细节的还原度。这主要得益于 DMS - RRDB 结构的多尺度特征融合能力以及 PDSA 机制对病斑关键区域的有效建模,使重建结果在纹理细节和结构一致性上更加稳定。

3.1.2 重建结果视觉效果

图 7 为典型水稻病害图像在重建前后的视觉效果,其中图 7a 为原始低分辨率图像,图 7c 为本文提出的多尺度超分辨率生成对抗网络重建结果。图中选取白叶枯病、稻瘟病、褐斑病和条纹矮缩病 4 类样本,并对病斑区域进行局部放大。

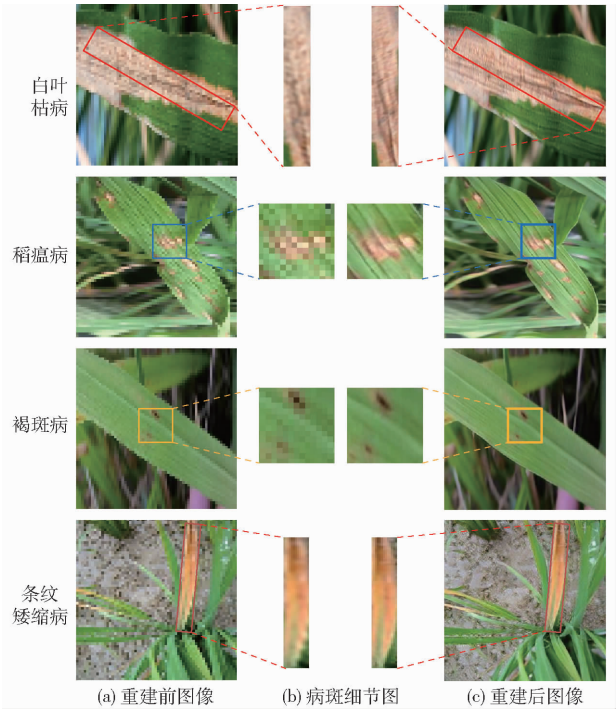

图 7 重建前后视觉效果

Fig. 7 Visual before and after reconstruction

由图 7 可见,小尺度病斑(褐斑病、稻瘟病)通常呈现为面积较小、边缘细碎且对比度较低的斑点结构,其细节恢复主要得益于 DMS - RRDB 中引入的多尺度残差特征融合与 PDSA 机制对局部窗口内

纹理相关性的建模，使网络能够更准确地捕获细粒度病斑边缘和微小纹理变化。相比之下，大尺度或条状病斑（白叶枯病和条纹矮缩病）更强调结构连续性和整体形态一致性，其条斑边界平滑性与颜色过渡效果的提升，则主要归因于多尺度并行特征对宏观结构信息的有效保留，以及 DP Loss 对结构一致性和感知质量的联合约束，从而减少断裂、伪影和颜色失真现象。

3.1.3　真实低分辨率图像重建试验

所用低分辨率图像是通过 Bicubic 插值、噪声叠加和 JPEG 压缩等方式生成，属于人工降质数据。为进一步验证模型在真实场景下的重建性能，从公开网络平台收集 50 幅真实低分辨率水稻病害图像，进行超分辨率重建试验。

试验选用无参考图像质量评价指标 NIQE 和 BRISQUE 对重建结果进行评估，并选取 Bicubic、ESRGAN 和 SwinIR 作为对比模型，不同模型在真实低分辨率图像上重建性能结果如表 1 所示。

表 1　不同模型在真实低分辨率图像上重建性能

Tab. 1　Results of reconstruction performance of different models on real low-resolution images

模型	NIQE	BRISQUE
Bicubic	5.31	42.4
ESRGAN	4.57	38.7
SwinIR	4.42	36.5
ESRG	4.28	33.8

由表 1 可知，本文 ESRG 模型在真实低分辨率图像上 NIQE 和 BRISQUE 最小，表明 ESRG 模型在真实退化条件下仍能有效恢复病斑区域纹理细节并保持较好的结构自然性，所提模型在真实退化与人工退化场景下均具有良好的重建性能与一致性。

3.2　ESRG_E 模型试验结果分析

3.2.1　ESRG_E 模型分类效果

为了验证 ESRG_E 模型的分类效果，选择（GoogLeNet、MobileNetV3、ResNet34）3 种常用的深度学习模型与 EfficientNet 进行试验，将低分辨率和超分辨率图像输入这些分类网络中进行训练，迭代次数为 60，图 8 为不同模型在低分辨率（LR）和超分辨率（SR）图像上的分类准确率。

由图 8 可知，红色区域在各维度上均明显大于蓝色区域，表明基于超分辨率重建后的图像在不同分类网络中均取得了更高的分类准确率。从雷达图覆盖面积来看，SR 对应的红色多边形整体扩展幅度较大，尤其在 EfficientNet 方向上提升最为显著，且接近顶端，准确率达到 97.63%，较低分辨率输入提高 7.20 个百分点，不仅取得了最高的分类准确率，

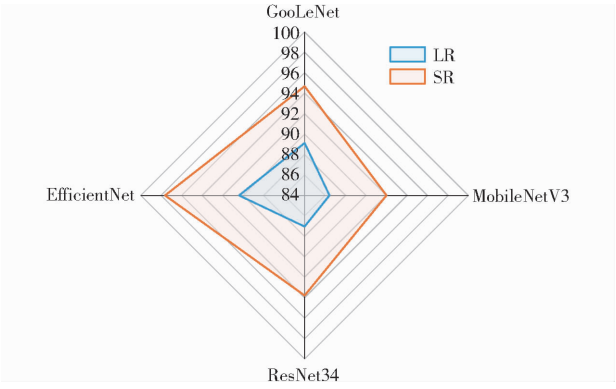

图 8　模型识别性能测试结果

Fig. 8　Model recognition performance test results

同时也是提升幅度最大的网络，体现出其在水稻病害分类任务中的优势。总体来看，将超分辨率网络与不同分类模型结合后，分类准确率平均提升约 6.3 个百分点，验证了该方法在提升水稻病害分类性能方面的有效性。

图 9 为重建前后训练损失曲线。总体来看，2 种情况下训练损失均随迭代次数增加而逐渐下降，并在后期趋于稳定，但重建后模型损失值整体更低。

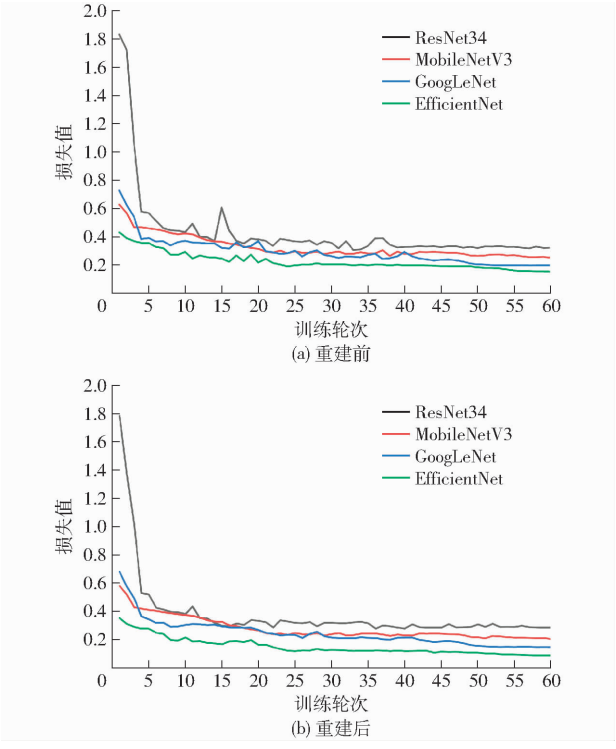

图 9　不同模型验证集损失值变化曲线

Fig. 9　Validation loss curves of different models

从收敛过程分析，重建前各分类网络的训练损失在前 40 轮迭代内仍存在较为明显的波动，而重建后模型在约 30 轮迭代后即可基本保持稳定，收敛速度显著加快。结果表明，超分辨率重建通过提升输入图像质量、降低噪声与不确定性，增强了特征提取

的稳定性,从而加快了模型训练收敛。该结果进一步验证了 ESRG_E 模型在水稻病害分类任务中提升分类性能的有效性。

3.2.2 ESRG_E 模型推理速度

为了验证 ESRG_E 模型的推理效率,本文对模型整体推理阶段的计算开销进行了分析。在整体推理阶段,模型的计算开销主要包括超分辨率重建模块和病害分类模块两部分,因此整体推理时间由图像重建时间与分类时间共同构成。同时,参数量作为衡量模型复杂度的重要指标,能够反映模型的计算与存储开销。因此,本文从推理时间和参数量 2 个方面对模型效率进行综合评估。

为评估分类模块的推理效率,本文在相同硬件环境和测试条件下对 GoogLeNet、MobileNetV3、ResNet34 和 EfficientNet 进行了单幅图像推理时间测试。推理时间分别为 10、8、18、10 ms。总体来看,各分类网络的时间开销均较小。

综合考虑分类精度,本文选取 EfficientNet 作为病害分类网络,并与不同超分辨率重建模型结合,对整体推理时间及模型复杂度进行比较,结果如表 2 所示,其中分类时间固定为 EfficientNet 的单幅推理时间。

表 2 不同方法推理时间及模型复杂度对比

Tab.2 Comparison of inference time and model complexity of different methods

方法	参数量	重建时间/ms	分类时间/ms	总时间/ms
ESRGAN_E	2.11×10^8	48	10	58
SwinIR_E	1.83×10^8	85	10	95
SD-SR_E	1.59×10^9	1 820	10	1 830
MFRSCN_E	2.62×10^8	55	10	65
ESRG_E	2.34×10^8	50	10	60

从表 2 可看出,上述基于超分辨率重建的识别方法,其整体时间开销主要来源于重建阶段。然而,本文提出的 ESRG_E,与 ESRGAN_E 相比整体推理时间上略有增加,与 SwinIR_E 相比参数量增大,仍保持在较低水平。

相比之下,SD-SR_E 由于重建过程更加复杂,导致整体推理时间和参数量显著增加。说明本文方法在提升图像重建质量和分类性能的同时,并未显著增加计算开销,因而更适用于对识别精度要求较高、而对实时性要求相对较低的应用场景。

3.2.3 ESRG_E 模型消融试验

为验证各模块在所构建模型中的有效性,设计 8 组消融试验。模型准确率、精确率、召回率和 F1 值如表 3 所示。

表 3 ESRG_E 模型消融试验结果

Tab.3 Ablation experiment results of ESRG_E model

%

分组	DMS-RRDB	PDSA	DP Loss	准确率	精确率	召回率	F1 值
1	×	×	×	95.8	95.6	95.8	95.7
2	√	×	×	96.7	96.4	96.6	96.5
3	×	√	×	96.6	96.1	96.3	96.2
4	×	×	√	96.2	95.9	96.4	96.2
5	√	√	×	97.2	96.9	96.9	96.9
6	√	×	√	96.9	96.7	97.1	96.9
7	×	√	√	96.8	97.0	96.9	97.0
8	√	√	√	97.6	97.5	97.6	97.5

注:×表示不使用该模块,√表示使用该模块。

在基础模型中,仅采用基础网络结构时,模型性能较低,指标均未超过 96%,表明低分辨率图像的特征信息提取存在一定困难。分别引入 DMS-RRDB、PDSA 或 DP Loss 后,模型性能均得到提升。其中,DMS-RRDB 模块带来的增益最为显著,分类准确率、F1 值分别提升 0.9、0.8 个百分点,表明超分辨率重建能够有效增强病斑细节特征表达;PDSA 模块在细粒度与宏观特征建模方面发挥作用,4 项指标平均提升约 0.6 个百分点;DP Loss 则主要改善精确率与召回率,说明其有助于缓解类别特征分布不均问题。

进一步分析双模块组合结果可以看出,不同模块之间具有良好的互补性,相较于单一模块组合,任意 2 种模块联合使用均可进一步提升模型性能,分类准确率均超过 96.8%,且 F1 值均大于 96.9%,验证了超分辨率重建、注意力机制与改进损失函数在特征增强与判别能力提升方面的协同作用。

在完整模型中,同时引入 DMS-RRDB、PDSA 和 DP Loss 后,模型性能达到最优,指标均超过 97.5%,相较基础模型提升均超过 1.8 个百分点,且较其他组合模型的准确率平均提升约 1.28 个百分点。结果表明,各模块的联合使用能够显著增强水稻病害图像特征的表达能力与识别能力,从而有效提升模型在低分辨率病害图像条件下的分类性能。

为直观展示改进模块对分类效果的影响,图 10 为未引入任何改进模块(消融试验第 1 组)与同时引入全部模块(消融试验第 8 组)的混淆矩阵,其中 0 表示白叶枯病,1 表示稻瘟病,2 表示褐斑病,3 表示条纹矮缩病,4 表示健康水稻。

由图 10 可看出,相较于第 1 组基线模型,第 8 组完整模型在各类别上的分类结果更加集中于对角

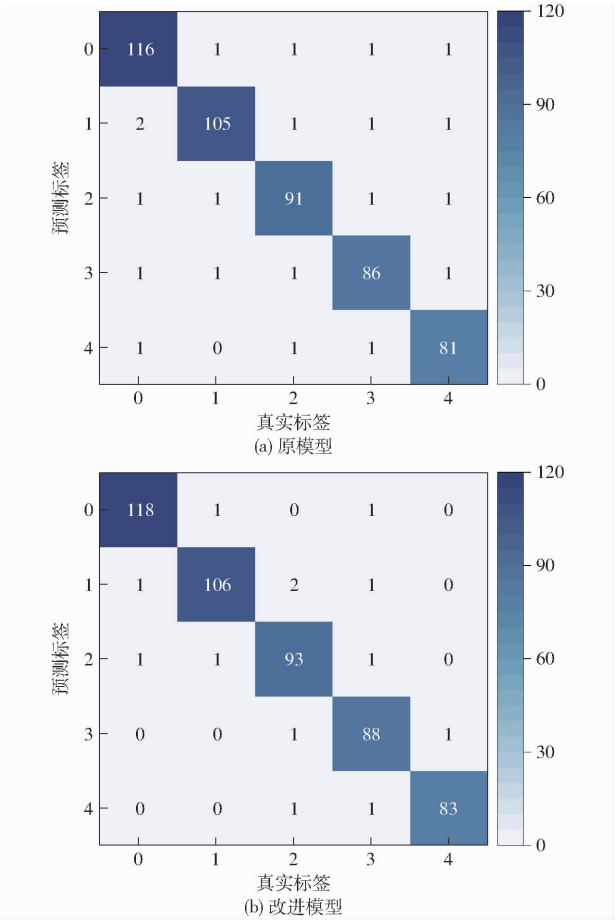

图 10　混淆矩阵结果

Fig. 10　Results of confusion matrices

线，类别间的误分类现象显著减少。尤其在纹理相似类别间，误分类显著减少，表明所提方法有效增强了低分辨率图像的细节表达并提升了特征可分性。进一步支持了消融试验的结论，即各模块均发挥了关键作用。

3.2.4　ESRG_E 可视化分析

为验证本文模型有效性，采用热力图形式，更加直观地体现病斑识别效果，分别给出原图和未经重建网络、经过重建网络病斑图像识别效果，结果如图 11 所示。

热力图颜色区域反映病斑识别效果，颜色表示模型对病斑区域的关注强度，颜色越深表明病斑识别越清晰。由可视化结果可知，重建前图像由于病斑尺度差异较大、部分病斑过于微小以及背景环境复杂等因素，导致分类识别效果较差，热力图整体颜色较浅且有效识别区域较小。当引入本文超分辨率重建网络并输入至分类网络后，4 类病害样本热力图颜色均明显加深，且在重建后的图像标注中可观察到模型能够有效识别重建前未被关注的微小病斑区域。该结果进一步表明，基于 DMS－RRDB 与 PDSA 的超分辨率重建模型在复杂环境和多尺度病

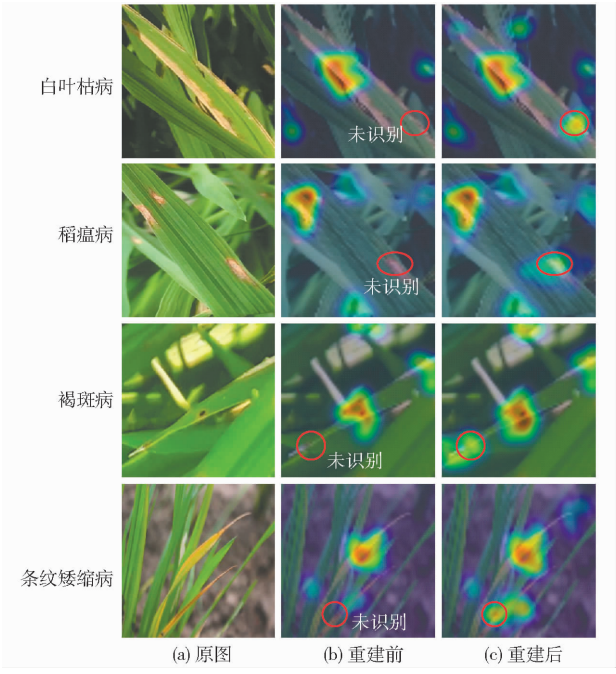

图 11　热力图可视化效果

Fig. 11　Heatmap visualization results

斑重建方面具有良好的可行性，同时验证了其与 ESRG_E 分类网络协同作用下对水稻病斑分类识别性能提升的有效性。

4　结论

（1）提出了一种超分辨率重建网络（ESRG），通过动态多尺度残差嵌套结构与并行双窗口自注意力机制相结合，并引入双感知损失函数，实现了重建图像结构信息与感知细节的整体增强。试验结果表明，该方法在峰值信噪比（PSNR）和结构相似性指数（SSIM）上分别较现有方法提升 1.43 dB 和 0.035，显著改善了病斑图像清晰度与细节表达能力。

（2）在此基础上，将所提 ESRG 模型与分类模型进行融合，构建了 ESRG_E 水稻病害识别模型。在水稻病害识别任务中识别准确率达 97.6%，较其他对比模型提升约 1.28 个百分点，验证了超分辨率重建与分类识别协同优化策略在复杂病斑场景下的有效性。

（3）虽引入超分辨率重建模块会增加一定的计算开销，但经过推理时间试验对比，本文所提方法整体推理时间在可接受范围之内。结合重建效果与识别结果可看出，该模块能够有效提升低分辨率病害图像的细节表达和后续分类性能，因此更适用于对识别精度要求高、实时性要求较低的场景，如病害分析、植保监测统计、农技辅助诊断以及田间图像上传云端后的高精度识别。

参 考 文 献

[1] Mohanty S, Yamano T. Rice food security in India: emerging challenges and opportunities[M]//The Future Rice Strategy for India. London: Academic Press, 2017: 1 - 13.

[2] 孙红,李松,李民赞,等. 农业信息成像感知与深度学习应用研究进展[J]. 农业机械学报,2020,51(5):1 - 17.
Sun Hong, Li Song, Li Minzan, et al. Research progress of image sensing and deep learning in agriculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 1 - 17. (in Chinese)

[3] 黄双萍,孙超,齐龙,等. 基于深度卷积神经网络的水稻穗瘟病检测方法[J]. 农业工程学报,2017,33(20):169 - 176.
Huang Shuangping, Sun Chao, Qi Long, et al. Rice panicle blast identification method based on deep convolution neural network[J]. Transactions of the CSAE, 2017, 33(20): 169 - 176. (in Chinese)

[4] Nagachandrika B, Prasath R, Joe I R P. An automatic classification framework for identifying type of plant leaf diseases using multi-scale feature fusion-based adaptive deep network[J]. Biomedical Signal Processing and Control, 2024, 95: 106316.

[5] 崔金荣,魏文钊,赵敏. 基于改进 MobileNetV3 的水稻病害识别模型[J]. 农业机械学报,2023,54(11):217 - 224,276.
Cui Jinrong, Wei Wenzhao, Zhao Min. Rice disease identification model based on improved MobileNetV3[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 217 - 224. 276. (in Chinese)

[6] Sathya K, Rajalakshmi M. RDA-CNN: enhanced super resolution method for rice plant disease classification[J]. Computer Systems Science & Engineering, 2022, 42(1):33 - 47.

[7] Saleem M A, Aamir M, Ibrahim R, et al. An optimized convolution neural network architecture for paddy disease classification[J]. Computers, Materials & Continua, 2022, 71(3):6053 - 6067.

[8] 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)

[9] Wen J, Shi Y, Zhou X, et al. Crop disease classification on inadequate low-resolution target images[J]. Sensors, 2020, 20(16): 4601.

[10] 慕君林,马博,王云飞,等. 基于深度学习的农作物病虫害检测算法综述[J]. 农业机械学报,2023,54(增刊 2):301 - 313.
Mu Junlin, Ma Bo, Wang Yunfei, et al. Review of crop disease and pest detection algorithms based on deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(S2): 301 - 313. (in Chinese)

[11] 管博伦,张立平,朱静波,等. 农业病虫害图像数据集构建关键问题及评价方法综述[J]. 智慧农业(中英文),2023,5(3):17 - 34.
Guan Bolun, Zhang Liping, Zhu Jingbo, et al. The key issues and evaluation methods for constructing agricultural pest and disease image datasets: a review[J]. Smart Agriculture, 2023, 5(3): 17 - 34. (in Chinese)

[12] Yamamoto K, Togami T, Yamaguchi N. Super-resolution of plant disease images for the acceleration of image-based phenotyping and vigor diagnosis in agriculture[J]. Sensors, 2017, 17(11): 2557.

[13] Wang X, Cao W. GACN: generative adversarial classified network for balancing plant disease dataset and plant disease recognition[J]. Sensors, 2023, 23(15): 6844.

[14] Maqsood M H, Mumtaz R, Haq I U, et al. Super resolution generative adversarial network (Srgans) for wheat stripe rust classification[J]. Sensors, 2021, 21(23): 7903.

[15] Zha L, Shi Y, Wen J. A lightweight image super-resolution network based on ESRGAN for rapid tomato leaf disease classification[C]//The International Conference on Image, Vision and Intelligent Systems (ICIVIS 2021), 2022: 97 - 110.

[16] Wang P, Sertel E. Multi-frame super-resolution of remote sensing images using attention-based GAN models[J]. Knowledge-Based Systems, 2023, 266: 110387.

[17] 马铁民,曲浩,高雅,等. 基于超分辨率生成对抗网络的玉米病害分类识别方法[J]. 农业机械学报,2024,55(11):49 - 56,67.
Ma Tiemin, Qu Hao, Gao Ya, et al. Maize disease classification and recognition method based on super-resolution generative adversarial networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 49 - 56,67. (in Chinese)

[18] Yang H, Wei Q, Sang Y. Transform domain based GAN with deep multi-scale features fusion for medical image super-resolution[J]. Electronics, 2025, 14(18): 3726.

[19] Kong Y, Liu S. DMSC-GAN: a c-GAN-based framework for super-resolution reconstruction of SAR images[J]. Remote Sensing, 2023, 16(1): 50.

[20] Ma X, Wang Z, Hu S, et al. Multi-focus image fusion based on multi-scale generative adversarial network[J]. Entropy, 2022, 24(5): 582.

[21] Yin Y, Mu X. Super-resolution reconstruction algorithm based on improved ESRGAN[C]//2023 6th International Conference on Information Communication and Signal Processing (ICICSP). IEEE, 2023: 164 - 171.

[22] 李义,王同喜,向华,等.基于坐标注意力机制的生成对抗网络舰船图像超分辨率重建[J].激光杂志,2025,46(12):149 - 156.
Li Yi, Wang Tongxi, Xiang Hua, et al. Ship image super-resolution reconstruction using generative adversarial network with coordinate attention mechanism[J]. Laser Journal, 2025, 46(12): 149 - 156. (in Chinese)

[23] Umer R M, Micheloni C. Real image super-resolution using GAN through modeling of LR and HR process[C]//2022 18th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS). IEEE, 2022: 1 - 8.

[24] Wang X, Yu K, Wu S, et al. Esrgan: enhanced super-resolution generative adversarial networks[C]// Proceedings of the European Conference on Computer Vision (ECCV) Workshops, 2018.

[25] 侯文慧,龚昌智,曹文昊,等.基于超分辨率增强与改进 YOLO v8 的番茄叶片病害检测[J].农业工程学报,2025,41(16):211 - 220.
Hou Wenhui, Gong Changzhi, Cao Wenhao, et al. Tomato leaf disease detection method based on super-resolution enhancement and improved YOLO v8[J]. Transactions of the CSAE, 2025, 41(16): 211 - 220. (in Chinese)

[26] Tan M, Le Q. Efficientnet: rethinking model scaling for convolutional neural networks[C]// International Conference on Machine Learning. PMLR, 2019: 6105 - 6114.

[27] 姜红花,杨祥海,丁睿柔,等.基于改进 ResNet18 的苹果叶部病害多分类算法研究[J].农业机械学报,2023,54(4):295 - 303.
Jiang Honghua, Yang Xianghai, Ding Ruirou, et al. Identification of apple leaf diseases based on improved ResNet18[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 295 - 303. (in Chinese)

[28] Zhang Y, Li K, Li K, et al. Image super-resolution using very deep residual channel attention networks[C]// Proceedings of the European Conference on Computer Vision (ECCV), 2018: 286 - 301.

[29] Liu X, Liu J, Tang J, et al. CATANet: efficient content-aware token aggregation for lightweight image super-resolution[C]// Proceedings of the Computer Vision and Pattern Recognition Conference, 2025: 17902 - 17912.

[30] Song J, Yi H, Xu W, et al. Dual perceptual loss for single image super-resolution using esrgan[PP/OL]. V1. arXiv(2022 - 01 - 17)[2025 - 12 - 15]. https://doi.org/10.48550/arXiv.2201.06383.

[31] 甘雨,郭庆文,王春桃,等.基于改进 EfficientNet 模型的作物害虫识别[J].农业工程学报,2022,38(1):203 - 211.
Gan Yu, Guo Qingwen, Wang Chuntao, et al. Recognizing crop pests using an improved EfficientNet model[J]. Transactions of the CSAE, 2022, 38(1): 203 - 211. (in Chinese)

[32] 张林鎧,巴音塔娜,曾庆松.基于 StyleGAN2-ADA 和改进 YOLO v7 的葡萄叶片早期病害检测方法[J].农业机械学报,2024,55(1):241 - 252.
Zhang Linxuan, Ba Yintana, Zeng Qingsong. Grape disease detection method based on StyleGAN2-ADA and improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 241 - 252. (in Chinese)

[33] Liang J, Cao J, Sun G, et al. Swinir: image restoration using swin transformer[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 1833 - 1844.

[34] Wang J, Yue Z, Zhou S, et al. Exploiting diffusion prior for real-world image super-resolution[J]. International Journal of Computer Vision, 2024, 132(12): 5929 - 5949.