

doi:10.6041/j.issn.1000-1298.2022.09.028

# 基于 SCResNeSt 的低分辨率水稻害虫图像识别方法

曾伟辉<sup>1,2</sup> 张文凤<sup>1,3</sup> 陈 鹏<sup>1,3</sup> 胡根生<sup>3</sup> 梁 栋<sup>1,3</sup>

(1. 安徽大学互联网学院, 合肥 230039; 2. 科大国创软件股份有限公司中央研究院, 合肥 230088;

3. 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)

**摘要:** 针对稻田自然环境下害虫移动, 难以近距离拍摄高质量图像, 导致在现有识别模型检测时无法达到满意识别精度的问题, 提出了一种基于 SCResNeSt 的低分辨率水稻害虫图像识别方法。首先, 使用增强型超分辨率生成对抗网络(ESRGAN)对低分辨率图像进行数据增强, 解决低分辨率水稻害虫有效信息少的问题; 其次构建了 SCResNeSt 网络, 使用 3 个连续的  $3 \times 3$  卷积层替换 ResNet50 中第 1 个  $7 \times 7$  卷积, 以减少计算量; 使用自校准卷积替代第 2 层卷积层中的  $3 \times 3$  卷积, 通过内部通信显式地扩展每个卷积层的视场, 获取害虫图像的部分背景信息, 从而丰富输出特征; 在主干网络中使用 ResNeSt block(Split-attention network block)进一步提升图像中害虫信息获取的准确性。最终, 将优选模型移植到手机端, 开发了轻量化的移动端水稻害虫识别系统。实验结果表明, 与现有方法对比, ESRGAN 数据增强方法可以恢复真实的作物害虫信息, SCResNeSt 模型有效提高了水稻害虫的识别性能, 识别精度达到 91.20%, 比原始 ResNet50 网络提高 3.2 个百分点, 满足野外实际场景下的应用需求。本研究为水稻害虫智能化识别和防治提供了技术基础。

**关键词:** 水稻害虫图像; 低分辨率; SCResNeSt; 卷积神经网络; 识别系统

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2022)09-0277-09

OSID: 

## Low-resolution Rice Pest Image Recognition Based on SCResNeSt

ZENG Weihui<sup>1,2</sup> ZHANG Wenfeng<sup>1,3</sup> CHEN Peng<sup>1,3</sup> HU Gensheng<sup>3</sup> LIANG Dong<sup>1,3</sup>

(1. School of Internet, Anhui University, Hefei 230039, China

2. Central Research Institute, Guo Chuang Software Co., Ltd., University of Science and Technology of China, Hefei 230088, China

3. National Engineering Research Center for Agro-Ecological Big Data Analysis and Application,  
Anhui University, Hefei 230601, China

**Abstract:** It was difficult to take high-quality images when pests were still and in close distance in the natural environment of rice field, which led to the problem that satisfactory identification accuracy could not be achieved when using the actual environmental identification model detection. A low-resolution rice pest image recognition method based on self-calibrated convolutions and ResNeSt block for ResNet50 (SCResNeSt) was proposed. Firstly, the enhanced super-resolution generative adversarial networks (ESRGAN) super partition network was used to enhance the data of low-resolution images to solve the problem of less effective information about rice pests. In SCResNeSt network, three consecutive  $3 \times 3$  convolutional layers were used to replace the first  $7 \times 7$  convolutional layer to reduce the computational cost. Using self-calibrated convolution instead of the  $3 \times 3$  convolution in layer 2, through internal communication, the field of view of each convolutional layer was explicitly extended to obtain part of the background information of pest images, to enrich the output features. The split-attention network block (ResNeSt block) was used in the backbone network to further improve the accuracy of obtaining pest information in the image. Finally, the optimized model was deployed on the mobile terminal, and a lightweight mobile rice pest identification system was developed. The experimental results showed that compared with the existing methods, the ESRGAN model could recover the real information about crop pests, and the SCResNeSt model could effectively improve the performance of rice pest identification, the

收稿日期: 2022-04-09 修回日期: 2022-06-23

基金项目: 安徽省自然科学基金面上项目(2108085MC95)、安徽省科技重大专项(202003a06020016)、安徽省高校自然科学研究项目(KJ2020ZD03、KJ2020A0039)、农业生态大数据中心开放项目(AE202004)和安徽省现代农业产业技术体系建设专项资金项目

作者简介: 曾伟辉(1982—), 女, 讲师, 博士, 主要从事计算机视觉和模式识别研究, E-mail: whzeng@ahu.edu.cn

通信作者: 陈鹏(1978—), 男, 教授, 博士生导师, 主要从事机器视觉、智慧机器人应用及农业信息技术研究, E-mail: pchen@ahu.edu.cn

accuracy can reach 91.20%, which showed that the depth model could accurately identify rice pest types. The research result can provide an important technical basis for the intelligent identification and control of rice pests, and it would improve the level of rice production informatization.

**Key words:** image of rice pests; low-resolution; SCResNeSt; convolutional neural network; identification system

## 0 引言

近年来,随着全球气候变暖等生态环境的变化,我国农作物受灾程度逐年加深,损失逐年加重。水稻是我国主要粮食来源,其生长受各种害虫影响,害虫监测识别是防灾减灾工作的关键任务之一<sup>[1]</sup>。由于水稻害虫种类繁多,人工识别任务繁重,无法及时对虫害进行有效防控,导致农作物大量减产。在野外环境下如获取较高分辨率的害虫图像数据,需采用相机拍摄害虫静态图像。但野外环境下,水稻害虫易动,导致获取的害虫图像往往不清晰、分辨率低,且部署在真实的农田里的摄像头密度稀疏,使害虫难以被有效地识别和监视。故无法轻易获得足够的高分辨率图像进行识别,这严重影响了识别性能<sup>[2]</sup>。因此提高低分辨率水稻害虫图像的识别精度,可加强对害虫的及时诊断和有效防控,对于减少经济损失、控制农药滥用、保证粮食安全具有重要意义<sup>[3]</sup>。

随着计算机视觉技术的发展,国内外学者对害虫识别已经取得了一定的进展。自 KRIZHEVSKY 使用 AlexNet<sup>[4]</sup>模型在 ILSVRC (ImageNet large-scale visual recognition challenge)<sup>[5]</sup>中应用开始,深度学习<sup>[4, 6]</sup>在全世界掀起了研究热潮,显著提高了识别害虫攻击和控制虫害风险的效率<sup>[7-11]</sup>。目前在水稻病虫害图像识别研究方面,大部分是针对噪声小、遮挡不严重和分辨率高的公开数据集害虫图像进行识别和模型构建<sup>[12-18]</sup>,但将此模型直接迁移用来识别实际情况下噪声大、分辨率低的虫害图像时会存在泛化能力弱的问题,准确率和鲁棒性无法达到应用需求。因此,对获取的低分辨率害虫图像进行恢复和高分辨率处理是提高病虫害识别精度的关键。

在低分辨率图像识别领域中,DAI 等<sup>[19]</sup>针对低分辨率害虫图像的识别任务,使用超分的方法,提出了一种具有四次注意和残差密集融合机制的生成性对抗网络 (GAN),用于低分辨率害虫图像的变换。该方法在图像重建方面更强大,处理后的图像分类准确率得到大幅提高。ZHU 等<sup>[20]</sup>提出了一种注意力感知增强网络 (APEN) 的创新框架,它以端到端的方式集成了感知增强和注意力机制,用于低分辨率图像分类。WEN 等<sup>[21]</sup>设计了一个基于增强型超分辨率生成对抗网络 (ESRGAN) 的作物病害分类网

络,使用微调的 ESRGAN 模型恢复真实的作物信息,提高作物病害分类的准确性。目前在水稻病虫害图像识别研究方面,大部分是对超分网络进行改进,针对低分辨率的害虫图像识别和分类算法较少,且大部分是对公开数据集进行识别和模型构建,并未开发相对应的应用终端。因此,开发针对普通用户的低分辨率害虫图像智能识别系统应用终端,对于提升水稻生产信息化水平具有重要意义。

针对稻田自然环境下难以在害虫静止且近距离时拍摄高质量图像,导致识别模型对实际获取的较低分辨率害虫图像识别精度较低,本文对低分辨率 (Low-resolution, LR) 图像进行剪裁处理,构建并训练 ESRGAN<sup>[22]</sup> 网络以生成与原始图像相当的超分辨率 (Super-resolution, SR) 图像。为进一步提高水稻害虫识别的准确率,本文提出一种基于 SCResNeSt (Self-calibrated convolutions and ResNeSt block for ResNet50) 的低分辨率水稻害虫识别网络。最后利用智能手机开发平台 (Android Studio 软件) 对优选模型进行移植,开发针对普通用户的低分辨率害虫智能识别应用系统。

## 1 数据采集与识别方法

### 1.1 数据来源

本研究中水稻害虫图像主要来源于安徽省农业科学院试验田收集的数据集<sup>[23]</sup>,数据采集地点为安徽省合肥市庐江县白湖振兴农场 (31.242326°N, 117.564381°E),所有图像均采用数码相机(如佳能、尼康)或移动设备拍摄。为了消除光照变化的潜在负面影响,所有图像都在田间采用均匀照明设置进行预处理,从中选取 7 种常见的水稻害虫图像(水稻二化螟、稻纵卷叶螟、稻二星蝽、黑尾叶蝉、稻棘缘蝽、稻赤斑沫蝉、稻绿蝽)。此外,也使用佳能 EOS80D 型彩色数码相机拍摄了部分田间水稻害虫图像来提高数据集的多样性,数据采集地点为安徽省芜湖市无为县襄安镇 (31.200738°N, 117.805038°E),拍摄时间为 2020 年 8 月 7 日。所用完整数据集采集地点既有试验田,又有自然大田环境,采集的数据包含水稻害虫幼虫和成虫的不同形态数据,以使得训练所得模型更能适应于对实际环境害虫图像的识别。害虫图像示例如图 1a 所示,水稻害虫幼虫和成虫的不同形态图像示例如图 1b 所示。



图 1 各类水稻害虫示例

Fig. 1 Examples of selected various rice pests

由于获取的原始数据数量少且类别不均衡,直接用来训练则容易导致模型过拟合。稻赤斑沫蝉、稻绿蝽数据较多,分别有 156、175 幅图像,约为前 5 种害虫(水稻二化螟、稻纵卷叶螟、稻二星蝽、黑尾叶蝉、稻棘缘蝽)数据量的 3 倍。基于前期研究发现,只对水稻二化螟、稻纵卷叶螟、稻二星蝽、黑尾叶蝉、稻棘缘蝽 5 种水稻害虫图像进行角度旋转和对称翻转扩增(图 2),而稻赤斑沫蝉、稻绿蝽保持原本数量不变时,网络模型能训练获得更优性能,有效缓解数据不均衡问题,充分发挥数据作用。各类别水稻害虫的原始训练样本数、扩充后的训练样本数及测试样本数,如表 1 所示。



图 2 数据扩充示意图

Fig. 2 Data expansion diagram

表 1 害虫种类和样本数量

Tab. 1 Species and sample quantities of rice pests

害虫名称	训练集	数据扩充	测试集
水稻二化螟	48	384	11
稻纵卷叶螟	48	384	12
稻二星蝽	43	344	11
黑尾叶蝉	48	384	12
稻棘缘蝽	53	424	13
稻赤斑沫蝉	125	125	31
稻绿蝽	140	140	35
总数	505	2 185	125

包含两种:数量较多的高质量害虫图像数据(高清、正面、无背景或者背景简单等)和少量的低分辨率害虫图像数据,这将导致数据集出现数据质量不均衡问题,可能会使网络识别模型过于关注学习高质量水稻害虫图像的特征,忽略了低分辨率水稻害虫的特征学习,故本文采用三次插值算法(Bicubic interpolation)进行 4 倍下采样获取低分辨率水稻害虫图像。图像模糊和有效像素少是稻田自然环境下水稻虫害识别精度低的主要原因。因此,对获取的低分辨率虫害图像进行恢复和高分辨率预处理是提高虫害识别精度的关键。

## 1.2 低分辨率水稻害虫图像预处理

增强型超分辨率生成对抗网络(Enhanced super-resolution generative adversarial networks, ESRGAN)是一种能够在单幅图像超分辨率期间生成真实感纹理的算法,其删除了生成网络中的所有批归一化(BN)层,并引入了多级残差密集连接模块(RDDB)将多层残差网络和密集连接相结合,该结构具有更深的层次和更加复杂的结构,同时提升了特征表达能力,能够有效提高模型性能,提高图像分辨率,ESRGAN 比 SRGAN 方法在更逼真、更自然的纹理上获得了更好的视觉质量。因此,本文采用 ESRGAN 超分网络对低分辨率害虫图像进行超分处理,首先输入图像,图像被输送到具有  $3 \times 3$  滤波器内核的卷积层,Leaky ReLU 作为激活函数。RRDB 由密集块和具有 5 个卷积层的多级残差网络组成,连接到第一个卷积层。RRDB 可以放大网络容量,在 RRDB 组之后添加了另一个具有  $3 \times 3$  内核和 64 个特征图的卷积层,以整合特征并匹配数据维度。两个上采样层的比例因子设置为 2,以实现 4 倍上采样因子的超分辨率(SR)图像。其他卷积层与第一个相同,只是最后一个卷积层有 3 个特征。ESRGAN 算法流程如图 3 所示,使用

经过图像数据统计分析,现有水稻害虫数据集

ESRGAN 算法对水稻害虫图像进行超分处理的效果,如图 4 所示。

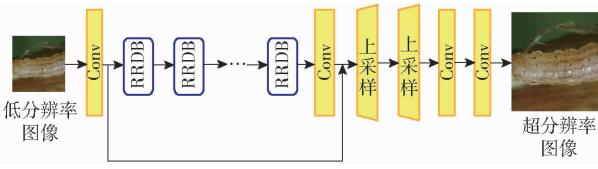


图 3 ESRGAN 网络

Fig. 3 Network of ESRGAN

Android Studio 软件对优选模型进行移植,开发水稻害虫识别系统。

### 1.3.1 网络模型整体架构

本文提出了一种以 ResNet50<sup>[24]</sup>为主干网络的融合自校准卷积和注意力机制的识别网络 (SCResNeSt),该网络首先使用 3 个连续的  $3 \times 3$  卷积层,替换 ResNet50 中的第 1 个  $7 \times 7$  卷积层,它们具有相同的感受野大小,并且计算量更小;采用自校准卷积 (Self-calibrated convolutions, SCC)<sup>[25]</sup> 替代第 2 层卷积层中的  $3 \times 3$  卷积,通过内部通信显式地扩展每个卷积层的感受野,获取害虫图像的部分背景信息。最后通过堆叠多个 ResNeSt block (Split-attention network block) 层,使网络可以跨不同的特征图组提取到具有高区分度的精细特征。改进的 SCResNeSt 网络整体框架结构如图 5 所示。

### 1.3.2 自校准卷积模块

由于所用的水稻害虫图像中不同害虫所侵害水稻的位置不同,如水稻二化螟幼虫蛀入稻茎后剑叶尖端变黄;稻棘缘蝽、稻二星蝽和稻绿蝽吸食主秆、叶穗部汁液,造成秕粒;稻纵卷叶螟、黑尾叶蝉和稻赤斑沫蝉主要危害水稻叶片,所以在利用害虫的图像特征的同时,结合受害位置的信息更有利水稻害虫图像的识别。自校准卷积操作相比传统的卷积,首先每个空间位置不仅可以考虑周边信息,而且可以对通道间的依赖性进行建模。其次,自校准卷积以异构的方式利用卷积滤波器的不同部分。自校准卷积操作过程如图 6 所示。

其中输入  $X$  的大小为  $C \times H \times W$ ,将  $X$  拆分为 2 个大小为  $C/2 \times H \times W$  的  $X_1, X_2$ ,然后将  $X_1, X_2$  输

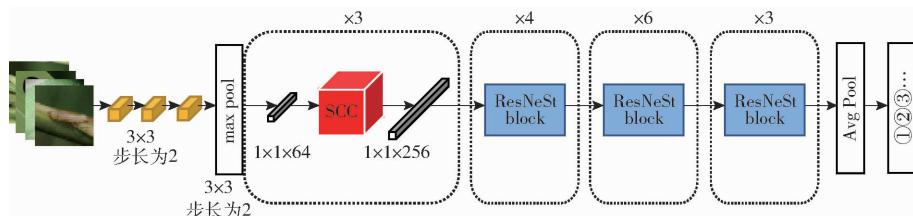


图 5 SCResNeSt 网络整体框架结构图

Fig. 5 SCResNeSt overall network framework structure diagram

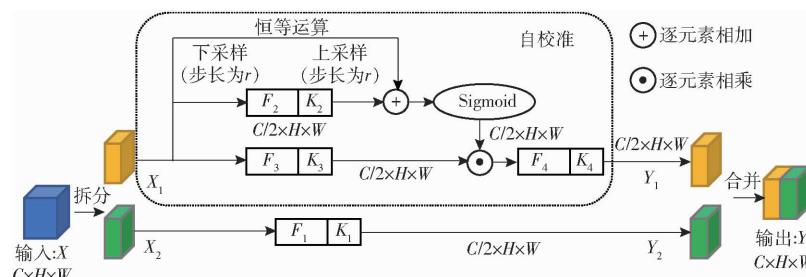


图 6 自校准卷积操作过程图

Fig. 6 Self-calibrated convolution operation process diagram

入用于收集不同类型的上下文信息的特殊路径中。在第 1 个路径中,利用  $\{K_2, K_3, K_4\}$  对  $X_1$  进行自校准操作,得到  $Y_1$ 。对于给定的输入  $X_1$ ,先进行卷积核大小为  $r \times r$  和步长为  $r$  的平均池化。

$$T_1 = \text{AvgPool}_r(X_1) \quad (1)$$

式中  $X_1$ —拆分后输入

$T_1$ —池化后输出

$\text{AvgPool}_r$ —步长为  $r$  的平均池化

再用  $K_2$  对  $T_1$  进行特征转换

$$X'_1 = \text{Up}(F_2(T_1)) = \text{Up}(T_1 K_2) \quad (2)$$

式中  $K_2$ —第 2 个卷积核

$F_2$ —第 2 个卷积运算函数

$X'_1$ —特征转换后输出

$\text{Up}$ —双线性插值运算函数

其中,  $\text{Up}$  将  $F_2(T_1)$  从小比例特征空间映射到原始特征空间。校准操作可以表述为

$$Y'_1 = F_3(X_1) \text{Sigmoid}(X_1 + X'_1) \quad (3)$$

其中  $F_3(X_1) = X_1 K_3$

式中  $K_3$ —第 3 个卷积核

$Y'_1$ —逐元素相乘后的输出

$F_3$ —第 3 个卷积运算函数

校准后最终输出为

$$Y_1 = F_4(Y'_1) = Y'_1 K_4 \quad (5)$$

式中  $K_4$ —第 4 个卷积核

$F_4$ —第 4 个卷积运算函数

$Y_1$ —校准后的输出

在第 2 条路径中,执行一个简单的卷积运算

$$Y_2 = F_1(X_2) = X_2 K_1 \quad (6)$$

式中  $K_1$ —第 1 个卷积核

$X_2$ —拆分后输入

$F_1$ —第 1 个卷积运算函数

$Y_2$ —卷积后输出

其目的是保留原始空间上下文信息。然后将两个中间输出  $Y_1, Y_2$  串联在一起作为输出  $Y$ 。因此,变换过程中的每个空间位置都可以通过自校准卷积操作融合 2 个不同空间的信息,这大大增加了卷积层的感受野<sup>[26]</sup>,从而使特征表示更具判别性。为更直观地展示感受野的增加,实验部分将展示网络热力图。

### 1.3.3 ResNeSt block

SCResNeSt 网络中使用的 ResNeSt block 可实现跨功能图组之间的关联,通过以 ResNet 样式堆叠 ResNeSt block<sup>[27]</sup>,每个块都将特征图沿通道维数分为几组和更细粒度的子组或分割,其中,每个组的特征表示是通过其分割表示的加权组合确定(图 7)所示。

改进的 SCResNeSt 网络中使用的 ResNeSt block

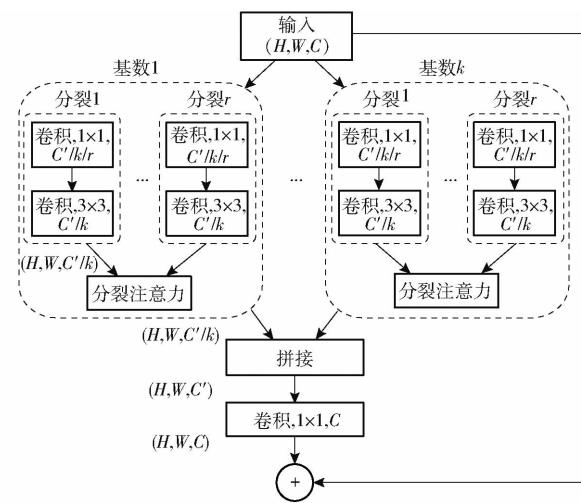


图 7 ResNeSt 块

Fig. 7 ResNeSt block

特征被分组再拆分,同一层中多个卷积核分支可以分别提取特征使得网络提取的特征更为多样。首先将输入特征分为  $k$  组(沿通道数划分),将得到的特征图组称为基数组,这个  $k$  组特征层和卷积核的操作是相对独立的操作。并引入了一个新的基数超参数  $r$ ,它表示基数组内的分裂数,每一个基数组内的分裂数均相同,因此特征组的总数为

$$G = kr \quad (7)$$

式中  $k$ —分组数  $r$ —超参数

$G$ —特征组总数

然后将基数组的特征沿通道维度连接起来,Split-Attention 块与标准残差块一样,其最终输出是使用快捷连接生成的,输入和输出特征图形状相同,再通过 Concatenate 函数进行数组拼接,然后用一个  $1 \times 1$  的卷积转换成与输入特征图相同大小的图,最后将其与输入特征图进行相加。

### 1.3.4 模型移植

本文构建了一种基于 SCResNeSt 的低分辨率水稻害虫识别网络模型后,利用智能手机开发平台(Android Studio 软件)对优选模型进行移植,开发水稻害虫识别系统。模型移植使用的开发环境为 Android Studio 3.5.2,编程语言采用 Java。由于在 Pytorch 框架下保存的模型权重文件为“.pth”,为了能够利用 Android Studio 更好地将其移植到普通智能手机上,需要将 .pth 文件转换为 .pt 文件,然后再通过 Java 编程实现移植。模型移植流程图如图 8 所示。

如图 8 所示,首先将低分辨率图像利用 ESRGAN 超分算法生成 SR 图像,再将其经过 SCResNeSt 分类网络进行识别,最后再利用水稻害虫智能识别系统对识别结果进行展示,用户可通过察看害虫识别结果,对农作物进行有效分析。

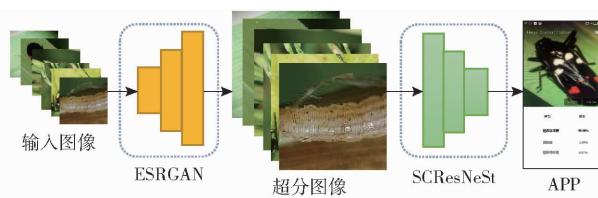


图 8 模型移植流程图

Fig. 8 Model migration flowchart

## 2 实验与结果分析

### 2.1 实验环境及评价指标

本研究使用 Pytorch 框架进行分类网络搭建,模型训练与测试均通过 GPU 加速。模型训练是将 MAX – EPOCH 设置成 30, 分类类别为 7, 最终经过训练得到需要的模型。

采用均方根误差 (Root mean square error, RMSE)、归一化均方根误差 (Normalized root mean square error, NRMSE)、结构相似性 (Structural similarity, SSIM)、峰值信噪比 (Peak signal to noise ration, PSNR) 和信息熵 (Entropy) 评价实验结果。

### 2.2 超分网络实验对比

图像超分方法旨在从相应的 LR 图像中恢复详细的 SR 图像, 实验将 ESRGAN 网络与 FSRCNN<sup>[28]</sup> 和 Bicubic 进行对比以验证其有效性。为了评估生成的 SR 图像质量, 比较了测试图像的 RMSE、NRMSE、SSIM、PSNR 和 Entropy, 结果见表 2。

表 2 超分图像质量评估

Tab. 2 Evaluation of hypersegmentation image quality

模型	RMSE	NRMSE	SSIM	PSNR/dB	Entropy/bit
Bicubic	13.985	0.189	0.689	25.217	7.256
FSRCNN	29.603	0.401	0.762	18.704	1.487
ESRGAN	5.765	0.078	0.905	32.914	7.000

由表 2 可知, ESRGAN 的 SSIM 和 PSNR 图像质量指标高于其他超分网络。ESRGAN 网络中将残差密集块 (RRDB) 中的残差作为基本的网络构建单元而不进行批量归一化。用 GAN 的思想, 令判别器预测相对真实性。利用激活前的特征改善感知损失, 为亮度一致性和纹理恢复提供更强的监控。基于这些改进, ESRGAN 在更逼真、更自然的纹理上获得了更好的视觉质量。

### 2.3 分类网络实验对比

针对低分辨率图像识别应用需求, 按照不同的分辨率及其处理操作, 将训练集和测试集分为 6 种不同情况进行模型训练和测试。

由表 3 可知, 原图 – LR 的分类网络由原图像训练所得, 使用 LR 图像对其进行测试, 并将此设置视为比较基线; LR – LR 的分类网络由 LR 图像进行训

练, 使用 LR 图像对其进行测试, 此设置需要为 LR 图像训练一个额外的网络; 原图 – 原图的分类网络在原图像上进行训练, 并在原图像上进行测试; SR – SR 的分类网络在 SR 图像上进行训练, 并在 SR 图像上进行测试; 原图 + SR – LR 的分类网络在原图像和 SR 图像上进行训练并在 LR 图像上进行测试; 原图 + SR – SR 的分类网络在原图像和 SR 图像上进行训练并在 SR 图像上进行测试。

表 3 训练集和测试集情况

Tab. 3 Training set and test set

序号	1	2	3	4	5	6
训练集	原图	LR	原图	SR	原图 + SR	原图 + SR
测试集	LR	LR	原图	SR	LR	SR

为了展示本研究中分类网络的实验效果, 将 AlexNet、Vgg16<sup>[29]</sup>、ResNet50、ResNet – RS<sup>[30]</sup>、ResNeSt 和改进的 SCResNeSt 网络结合表 3 中的不同训练测试情况进行对比, 水稻害虫分类实验结果如表 4 所示。

表 4 害虫分类准确率

Tab. 4 Accuracy of pest classification %

网络模型	数据集	数据集	数据集	数据集	数据集	数据集
	1	2	3	4	5	6
AlexNet	60.00	29.60	67.20	76.80	63.20	77.60
Vgg16	82.40	79.20	89.60	87.20	74.40	88.80
ResNet – RS	56.00	81.60	87.20	79.20	60.80	84.00
ResNeSt	56.80	86.40	87.20	85.60	75.20	88.00
ResNet50	55.20	71.20	85.60	85.60	72.80	88.00
SCResNeSt	63.20	87.20	92.00	88.00	83.20	91.20

由表 4 可以看出, 在多个网络中, 经过 ESRGAN 网络处理后的 SR 图像的分类精度高于 LR 图像的分类精度, 第 6 种训练测试情况下的准确率达到了接近原图精度, 甚至在 AlexNet、ResNet50、ResNeSt 网络中超过了原图精度。实验结果表明, 经过 ESRGAN 网络处理, 可以使得低分辨率图像得到增强, 解决低分辨率水稻害虫图像有效信息少的问题。

本文提出的 SCResNeSt 方法在识别精度方面优于 AlexNet、Vgg16、ResNet50、ResNet – RS、ResNeSt, 在原图数据中可达到 92.00%, 比 Vgg16 高 2.4 个百分点, 比 ResNet50 网络高 6.4 个百分点; 低分辨率图像中的识别精度为 87.20%; 结合超分算法后低分辨率水稻害虫图像的平均识别精度为 91.20%, 相较于 Vgg16 高 2.4 个百分点, 比 ResNet50 网络高 3.2 个百分点, 说明所构建的深度模型能够准确识别水稻害虫类型。

为更直观地展示分类结果, 绘制混淆矩阵, 如

图 9 所示,0 表示水稻二化螟,1 为稻纵卷叶螟,2 为稻二星螟,3 为黑尾叶蝉,4 为稻棘缘蝽,5 为稻赤斑

沫蝉,6 为稻绿蝽。对角线上的元素表示正确分类样本的数量。

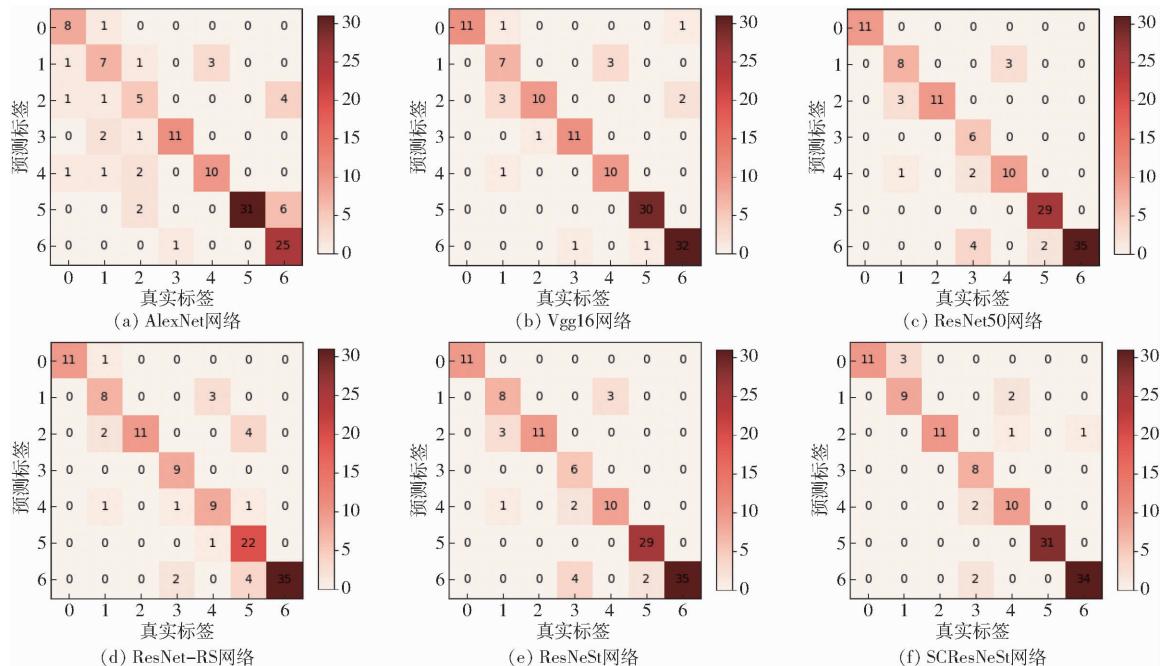


图 9 网络混淆矩阵图

Fig. 9 Network confusion matrices

由 ResNeSt 网络混淆矩阵可知,对于第 0 类和第 2 类样本均分类正确。对于第 1 类、第 3 类、第 4 类和第 5 类,错误预测数为 4 的有 2 个样本。可以看出,分类的主要困难在于类别 1、3、4、5,在 SCResNeSt 网络混淆矩阵中也有相似结果。由 SCResNeSt 的混淆矩阵可知,第 0 类和第 2 类的所有样本均分类正确,其他类的分类正确数量也得到了提升。

## 2.4 消融实验

消融实验结果如表 5 所示。从表 5 可以看出,对数据进行超分辨率增强处理后,利用自校准卷积对水稻害虫进行特征提取,ResNeSt 模块能够获取更多害虫图像的信息,进一步提升了图像中害虫信息获取的准确性。

表 5 消融实验结果

Tab. 5 Results of ablation experiments

主干网络	超分处理	ResNeSt block	SCC	准确率/%
ResNet50				71.20
ResNet50		✓		86.40
ResNet50		✓	✓	87.20
ResNet50	✓			88.00
ResNet50	✓	✓		88.00
ResNet50	✓	✓	✓	91.20

注:✓ 表示识别网络中加入该模块。

由 2.3 节和表 5 可知,对数据进行超分辨率增强处理,可提高网络泛化性,降低了因低分辨率图像所含信息少导致的误分类,大幅度提升了网络分类效果。上述条件下,在 ResNet50 网络中加入

ResNeSt 模块,进一步提升图像中害虫信息获取的准确性。最后再加入自校准卷积,可以看出,准确率提升明显,这是因为不同水稻害虫对应的背景也不同,自校准卷积有效扩大分类网络的感受野,结合受害位置背景的信息,降低了因背景类别复杂导致的误分类,因而所提方法具有较少的误分类,获得了较好的分类结果。

## 2.5 热力图可视化

将 SCResNeSt 产生的特征激活热力图与传统的残差网络 ResNet50 和 ResNeSt 的特征激活热力图进行对比,其热力图可视化如图 10 所示。

从图 10 中可以观察到,具有传统卷积的残差网络无法精准捕获整个判别区域,因为它们的卷积层感受野有限。相比之下,自校准卷积有助于模型很好地捕捉整个判别区域。因不同害虫所侵害水稻的位置不同,带有自校准卷积的 SCResNeSt 感受野更大,可以更准确、更完整地定位目标对象,在识别中不仅利用害虫的图像特征,而且通过结合受害位置背景信息更有利害虫识别。

## 2.6 诊断系统的应用

本研究基于 Android Studio 软件,设计完成移动应用 APP。通过有线方式把安装包移至 Android 手机,即完成了基于 Android 手机的自然场景下水稻害虫识别系统的移植。用户可通过手机运行系统,自动打开手机摄像头,将摄像头对准害虫,即可实时采集图像。由手机摄像头采集的每帧图像,分辨率

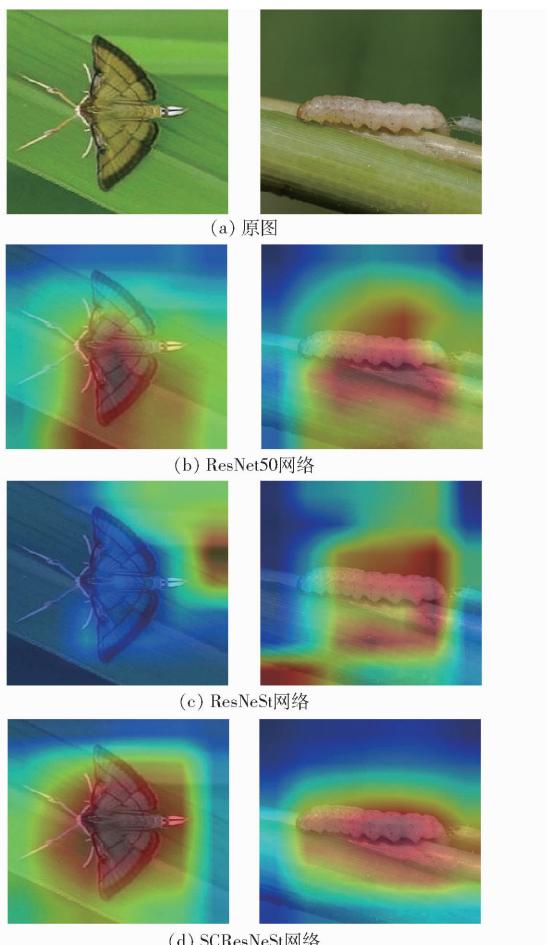


图 10 网络特征激活热力图

Fig. 10 Network features activated thermal map

转换为  $224 \times 224 \times 3$ , 然后经过归一化处理输入部署好的模型中进行识别, 识别结果如图 11 所示。软件界面上半部分为手机摄像头实时采集到的图像, 将每帧图像进行实时显示。界面中展示识别结果, 软件界面下半部分为分类 Top3 的结果, 并按照顺序排列, 左列为分类结果, 右列为分类概率。这种方法为用户提供了一种自行判断害虫的选择, 用户可通过察看害虫识别结果, 对农作物进行有效分析。

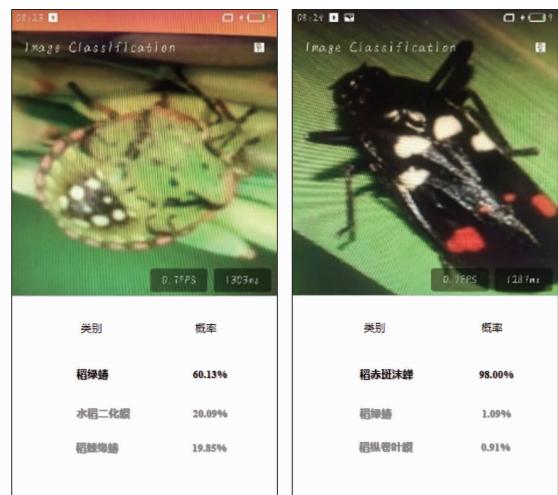


图 11 软件识别结果

Fig. 11 Software identification results

### 3 结论

(1) 为解决实际获取的害虫图像分辨率低而导致识别模型识别精度低的问题, 本研究基于深度学习技术, 首先运用 ESRGAN 超分网络对低分辨率图像进行数据增强, 解决低分辨率水稻害虫图像有效信息少的问题。其次, 为了同时关注到害虫的图像信息和受害位置信息, 在 ResNet50 网络中使用自校准卷积来扩大感受野, 再通过堆叠多个 ResNeSt block, 提升害虫区域的特征权重, 以便提取到具有高区分度的特征, 提升模型的识别精度。在自建的水稻害虫图像数据集对模型进行训练获得水稻害虫识别模型。

(2) 测试结果表明, 本文模型对超分后的低分辨率水稻害虫图像的识别准确率为 91.20%, 相较于 AlexNet、Vgg16、ResNet-RS、ResNeSt 网络提高至少 2.4 个百分点, 比 ResNet50 高 3.2 个百分点。本研究将获取到的模型部署在 Android 手机端, 实际应用程序可用于农作物害虫移动端准确识别。

### 参 考 文 献

- [1] SINGH A K, GANAPATHYSUBRAMANIAN B, SARKAR S, et al. Deep learning for plant stress phenotyping: trends and future perspectives [J]. Trends in Plant Science, 2018, 23(10): 883–898.
- [2] 薛金林, 李雨晴, 曹梓建. 基于深度学习的模糊农田图像中的障碍物检测 [J]. 农业机械学报, 2022, 53(3): 234–242. XUE Jinlin, LI Yuqing, CAO Zijian. Obstacle detection based on deep learning for blurred farmland images [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 234–242. (in Chinese)
- [3] PAYMODE A S, MALODE V B. Transfer learning for multi-crop leaf disease image classification using convolutional neural network VGG [J]. Artificial Intelligence in Agriculture, 2022, 6: 23–33.
- [4] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2012, 60: 84–90.
- [5] DENG J, DONG W, SOCHER R, et al. ImageNet: a large-scale hierarchical image database [C] // IEEE Conference on Computer Vision Pattern Recognition, 2009: 248–255.
- [6] LECUN Y, BOSER B, DENKER J, et al. Back propagation applied to handwritten zip code recognition [J]. Neural Computation, 1989, 1: 541–551.
- [7] 翟肇裕, 曹益飞, 徐焕良, 等. 农作物病虫害识别关键技术研究综述 [J]. 农业机械学报, 2021, 52(7): 1–18.

- ZHAI Zhaoyu, CAO Yifei, XU Huanliang, et al. Review of key techniques for crop disease and pest detection [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 1–18. (in Chinese)
- [8] ZHAO Y, SUN C, XU X, et al. RIC-Net: a plant disease classification model based on the fusion of inception and residual structure and embedded attention mechanism [J]. Computers and Electronics in Agriculture, 2022, 193: 106644.
- [9] WEI D, CHEN J, LUO T, et al. Classification of crop pests based on multi-scale feature fusion [J]. Computers and Electronics in Agriculture, 2022, 194: 106736.
- [10] 贾少鹏, 高红菊, 杭潇. 基于深度学习的农作物病虫害图像识别技术研究进展 [J]. 农业机械学报, 2019, 50(增刊): 313–317.  
JIA Shaopeng, GAO Hongju, HANG Xiao. Research progress on image recognition technology of crop pests and diseases based on deep learning [J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(Supp.): 313–317. (in Chinese)
- [11] ZHAO X, ZHANG J, HUANG Y, et al. Detection and discrimination of disease and insect stress of tea plants using hyperspectral imaging combined with wavelet analysis [J]. Computers and Electronics in Agriculture, 2022, 193: 106717.
- [12] CHENG X, ZHANG Y, CHEN Y, et al. Pest identification via deep residual learning in complex background [J]. Computers and Electronics in Agriculture, 2017, 141: 351–356.
- [13] KASINATHAN T, REDDY U S. Crop pest classification based on deep convolutional neural network and transfer learning [J]. Comput. Electron. Agric., 2019, 164: 104906.
- [14] FANG T, CHEN P, ZHANG J, et al. Crop leaf disease grade identification based on an improved convolutional neural network [J]. Journal of Electronic Imaging, 2020, 29(1): 013004.
- [15] LU Y, YI S, ZENG N, et al. Identification of rice diseases using deep convolutional neural networks [J]. Neurocomputing, 2017, 267: 378–384.
- [16] JIANG F, LU Y, CHEN Y, et al. Image recognition of four rice leaf diseases based on deep learning and support vector machine [J]. Comput. Electron. Agric., 2020, 179: 105824.
- [17] IALAM A, ISLAM R, HAQUE S M R, et al. Rice leaf disease recognition using local threshold based segmentation and deep CNN [J]. International Journal of Intelligent Systems and Applications, 2021, 5: 35–45.
- [18] HAIYAN H, CHANG S. Classification of rice diseases and insect pests based on artificial intelligence [C] // 14th International Conference on Measuring Technology and Mechatronics Automation, 2022: 322–325.
- [19] DAI Q, CHENG X, QIAO Y, et al. Agricultural pest super-resolution and identification with attention enhanced residual and dense fusion generative and adversarial network [J]. IEEE Access, 2020: 81943–81959.
- [20] ZHU X, LI Z, LI X, et al. Attention-aware perceptual enhancement nets for low-resolution image classification [J]. Inf. Sci., 2020, 515: 233–247.
- [21] WEN J, SHI Y, ZHOU X, et al. Crop disease classification on inadequate low-resolution target images [J]. Sensors, 2020, 20(16): 4601.
- [22] WANG X, YU K, WU S, et al. ESRGAN: enhanced super-resolution generative adversarial networks [C] // Proceedings of the ECCV Workshops, 2018.
- [23] XIE C, WANG R, ZHANG J, et al. Multi-level learning features for automatic classification of field crop pests [J]. Comput. Electron. Agric., 2018, 152: 233–241.
- [24] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // IEEE Conference on Computer Vision Pattern Recognition, 2016: 770–778.
- [25] LIU J, HOU Q, CHENG M M, et al. Improving convolutional networks with self-calibrated convolutions [C] // IEEE/CVF Conference on Computer Vision Pattern Recognition, 2020: 10093–10102.
- [26] XIE S, GIRSHICK R B, DOLLAR P, et al. Aggregated residual transformations for deep neural networks [C] // IEEE Conference on Computer Vision Pattern Recognition, 2017: 5987–5995.
- [27] ZHANG H, WU C, ZHANG Z, et al. ResNeSt: Split-Attention networks [J]. ArXiv: 2004.08955, 2020.
- [28] DONG C, LOY C C, TANG X. Accelerating the super-resolution convolutional neural network [C] // Proceedings of the ECCV, 2016.
- [29] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. ArXiv: 1409.1556, 2015.
- [30] BELLO I, FEDUS W, DU X, et al. Revisiting ResNets: improved training and scaling strategies [J]. ArXiv: 2103.07579, 2021.