

DOI: 10.13733/j.jcam.issn.2095-5553.2025.12.012

徐鹏, 周纯华, 赵鑫, 等. 基于改进 ResNet34 的水稻叶片病害识别模型[J]. 中国农机化学报, 2025, 46(12): 86-93

Xu Peng, Zhou Chunhua, Zhao Xin, et al. Rice leaf disease recognition model based on improved ResNet34 [J]. Journal of Chinese Agricultural Mechanization, 2025, 46(12): 86-93

基于改进 ResNet34 的水稻叶片病害识别模型*

徐鹏¹, 周纯华², 赵鑫¹, 吴青雷³

(1. 山西铁道职业技术学院, 太原市, 030013; 2. 山西农业大学信息科学与工程学院, 山西晋中, 030800;
3. 太原理工大学计算机科学与技术学院, 太原市, 030024)

摘要: 水稻叶片病害会对水稻产量造成严重影响, 及时准确地识别病害至关重要。卷积神经网络在图像识别领域表现出色, 但对于水稻叶片病害识别任务, 现有的 CNN 模型存在特征提取能力不足的问题。为此, 提出一种基于改进 ResNet34 的水稻叶片病害识别模型, 通过引入非局部注意力机制和深度可分离卷积层, 增强模型的特征提取能力。非局部注意力机制有效聚焦于图像中与病害相关的关键区域, 提升模型对病害特征的敏感性; 深度可分离卷积层则显著减少模型参数量, 同时保持特征提取的性能。通过在水稻叶片病害数据集上与 ResNet34、ResNet101、VGG16、VGG19、MobileNetV2、Swin Transformer 等主流算法对比, 验证所提算法的有效性。与 ResNet34 模型相比, 改进后算法的准确率提高 5.6%, 召回率提高 4.8%, F1 分数提高 5.2%。此外, 对改进后算法的鲁棒性进行评估, 结果表明, 该算法对图像旋转、缩放和噪声具有良好的鲁棒性。

关键词: 水稻叶片病害; 深度可分离卷积层; 非局部注意力机制; 深度学习; 卷积神经网络

中图分类号: S511; S435.11; TP391.4 **文献标识码:** A **文章编号:** 2095-5553 (2025) 12-0086-08

Rice leaf disease recognition model based on improved ResNet34

Xu Peng¹, Zhou Chunhua², Zhao Xin¹, Wu Qingle³

(1. Shanxi Railway Vocational and Technical College, Taiyuan, 030013, China;

2. College of Information Science and Engineering, Shanxi Agricultural University, Jinzhong, 030800, China;

3. School of Computer Science and Technology, Taiyuan University of Technology, Taiyuan, 030024, China)

Abstract: Rice leaf diseases can seriously affect rice yield, so it is very important to identify rice leaf diseases timely and accurately. Convolutional neural networks perform well in the field of image recognition, but for rice leaf disease recognition task, the existing CNN model has the problem of insufficient feature extraction ability. In this paper, a rice leaf disease recognition model based on improved ResNet34 is proposed. The feature extraction capability of the model is enhanced by introducing non-local attention mechanism and deep separable convolution layer. The non-local attention mechanism effectively focuses on the key areas related to the disease in the image, which improves the sensitivity of the model to the disease features. The depth separable convolution layer significantly reduces the number of model parameters while maintaining the performance of feature extraction. The effectiveness of the proposed algorithm is verified by comparing it with ResNet34, ResNet101, VGG16, VGG19, MobileNetV2 and Swin Transformer on rice leaf disease data set. Compared to the ResNet34 model, the algorithm improved accuracy by 5.6%, recall rate by 4.8%, and F1 score by 5.2%. In addition, the robustness of the algorithm is evaluated, and the results show that the algorithm has good robustness to image rotation, scaling and noise.

Keywords: rice leaf disease; deep separable convolution layer; non-local attention mechanism; deep learning; convolutional neural networks

收稿日期: 2024 年 4 月 18 日 修回日期: 2024 年 8 月 16 日

* 基金项目: 国家自然科学基金 (61901292)

第一作者: 徐鹏, 男, 1990 年生, 山西沁水人, 硕士, 讲师; 研究方向为人工智能技术应用。E-mail: xupeng@sxtczy.cn

0 引言

水稻作为全球主要的粮食作物之一,其健康生长对于保障世界粮食安全至关重要^[1]。然而,水稻叶片病害,如稻瘟病和白叶枯病,会严重影响水稻的产量和质量^[2]。因此,开发有效的水稻叶片病害识别方法,对于防治病害、减少损失具有重大意义^[3]。

近年来,随着深度学习技术的发展,卷积神经网络(CNN)已被广泛应用于图像识别任务,并在多个领域取得显著成果^[4]。在农业领域,CNN 的应用也展现出巨大的潜力,尤其是在病虫害检测和分类方面^[5-7]。然而,传统的 CNN 模型在处理水稻叶片病害图像时,往往受限于其特征提取能力,导致识别精度不足^[8]。陆煜等^[9]提出一种基于 CNN 的轻量级水稻叶片病害识别模型,在公共数据集中进行验证,展现出相对较好的性能。杨波等^[10]针对 YOLOv5 模型在水稻病害叶片检测方面计算复杂度高、计算速度慢的问题,提出一种基于改进 SPP—x 的 YOLOv5 模型水稻病害叶片识别检测方法,结果显示,改进后的模型单张图像检测时间为 0.34 s,效果良好,能够有效辅助水稻病害识别。为快速、准确、有效地识别细菌性条斑病早期症状,袁培森等^[11]提出基于随机森林算法的水稻细菌性条斑病识别方法,利用光谱成像技术获取该病害的高光谱数据,通过多元散射校正减少和消除噪声及基线漂移对光谱数据的不利影响。章广传等^[12]提出一种轻量级残差网络模型构建方法,融合迁移学习和知识蒸馏策略进行模型训练。该方法在教师模型上使用迁移学习策略缩短训练时间,并对 ResNet18 模型进行剪枝,使用降采样的方式提高模型识别准确率。最终在保证模型轻量化的前提下,实现对马铃薯叶片病害类别的精准识别。该模型能够满足大部分实际应用场景需求,为部署在物联网和移动设备上的模型提供参考。

上述模型虽然能够学习深层特征,但在处理复杂的农业图像时,其特征提取能力可能不足。水稻叶片病害图像通常包含微妙的纹理和颜色变化,这些细节对于病害识别至关重要,但可能超出现有模型标准层的捕捉能力。其中,ResNet34 模型包含较多的参数,这不仅增加计算负担,也可能导致过拟合,特别是在数据量有限的情况下^[13]。对于需要在资源受限的环境中部署的应用,如移动设备或边缘计算设备,模型轻量化是必要的。标准的 ResNet34 模型没有集成非局部注意力机制,这意味着其不能主动关注图像中的关键区域。在水稻叶片病害识别任务中,能够聚焦于病害特征的区域对于提高识别精度非常重要^[14]。

针对上述问题,本文提出一种基于改进

ResNet34 的水稻叶片病害识别算法。通过引入非局部注意力机制,有效提升模型在病害特征提取方面的能力,使其能够聚焦于图像中与病害相关的关键区域,从而提高识别准确率。采用深度可分离卷积层,显著减少模型参数量,提升计算效率,同时兼顾模型复杂度和特征提取效率。

1 试验数据

1.1 图像数据

首先,在水稻田内实际拍摄获取大量的水稻叶片图像,包括健康和各种病害的叶片。这些图像能够真实反映水稻叶片在不同光照、角度、背景下的情况,有助于增强模型的泛化能力和鲁棒性。其次,通过互联网收集更多的水稻叶片图像来扩充数据集。这样不仅可以提高数据集的多样性,也有助于提升模型的准确性和稳定性。最后,经过筛选,选取 5 000 张相关的图像作为初始数据集。这些图像包括 1 000 张健康叶片和 4 000 张病害叶片,病害叶片根据 4 种疾病类型(水稻纹枯病、稻瘟病、白叶枯病、细菌性条斑病)进行分类。图 1 为水稻叶片的图像数据集的可视化效果。这些图像覆盖了水稻叶片的主要特征和病害类型,有利于提升模型的识别和分类能力。

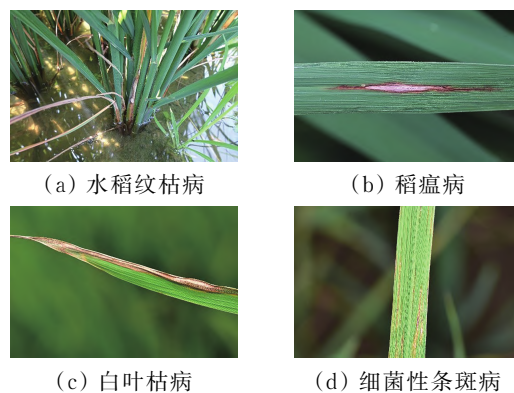


图 1 水稻叶片病害数据集可视化

Fig. 1 Visualization of rice leaf disease data set

1.2 水稻叶片病害类型

水稻叶片的常见病害包括纹枯病、稻瘟病、白叶枯病和细菌性条斑病^[15]。水稻纹枯病主要影响叶鞘和叶片,病斑初期呈暗绿色水浸状,后期变为灰白色半透明状。稻瘟病根据感染时期和部位的不同,分为苗瘟、叶瘟、节瘟、穗颈瘟和谷粒瘟。白叶枯病叶片最易感染,全生育期都可能受害,尤其是苗期和分蘖期。细菌性条斑病主要侵害叶片,病斑初为暗绿色水浸状,迅速扩展为黄褐色细线或短虚线状条斑。这些病害对水稻的生长有严重影响,需要采取适当的防治措施来管理^[16]。疾病的名称和主要特征的总结如表 1 所示。

表1 水稻叶片病害特征分析

Tab. 1 Analysis of rice leaf disease characteristics

病害类别	主要特征
水稻纹枯病	叶鞘底部出现椭圆形暗绿色水渍状病斑,扩大为云纹状
稻瘟病	幼苗上小的坏死病斑,老植株上病害症状出现在叶片、节、颈部和稻穗上
白叶枯病	叶片干枯,秕实率增加,米质松散,千粒重降低
细菌性条斑病	叶面初期细小水渍状短条斑,发展成纵条斑,严重时全叶枯黄

2 水稻叶片识别模型

2.1 模型概述

所提出的水稻叶片病害识别算法是基于改进的 ResNet34 模型^[17],该模型结合非局部注意力机制和深度可分离卷积层,以提高对水稻叶片病害图像的特征提取能力,详细参数如表 2 所示,算法流程如

表2 模型参数设置

Tab. 2 Model parameter settings

网络层	输出大小	12层	34层	50层	101层	152层
卷积 1	112×112	7×7, 64, 3×3 最大池化				
卷积 2×	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
卷积 3×	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$
卷积 4×	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 3$
卷积 5×	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
浮点运算次数		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	1.13×10^{10}




图2 基本算法流程

Fig. 2 Flow chart of the basic algorithm

ResNet34 模型的核心思想是引入残差块,使得网络可以通过学习输入与输出之间的残差来训练^[17]。这样做的目的是解决随着网络深度增加而出现的训练困难,即所谓的退化问题。残差块的基本单元是一个由 2 个 3×3 卷积层组成的结构,每个卷积层后面跟着一个批量归一化层和 ReLU 激活函数。残差块的输出 y 计算如式(1)所示。

图 2 所示。其中,浅蓝色模块(代表输入或早期特征)直接连接到紫色模块(代表后期特征)的箭头,紫色模块接收来自主路径和残差连接的输入,这表示特征的融合。非局部注意力机制可以帮助模型集中关注图像中的重要部分,即与病害诊断密切相关的区域。而深度可分离卷积层则是一种有效的网络结构优化手段,它能够在减少模型参数和计算量的同时,保持甚至提升特征提取性能。运行流程:(1)数据预处理:对输入的水稻叶片图像进行标准化处理,包括调整图像大小、归一化像素值等。(2)特征提取:图像数据通过改进的 ResNet34 模型进行前向传播,利用深度可分离卷积层和非局部注意力机制提取关键特征。(3)分类器:提取的特征被送入分类器,分类器根据特征对病害类型进行分类。(4)输出结果:模型输出每种病害的概率分布,根据最高概率确定图像的病类型。

$$y = F(x, \{W_i\}) + x \quad (1)$$

式中: x ——输入特征;

$F(x, \{W_i\})$ ——卷积层的输出;

W_i ——卷积层的权重集合。

跳跃连接的目的是将输入 x 直接添加到卷积层的输出上。如果输入和输出的维度不一致,跳跃连接会通过一个 1×1 卷积操作来调整维度,如式(2)所示。

$$y = F(x, \{W_i\}) + W_s x \quad (2)$$

式中: W_s ——用于维度匹配的 1×1 卷积核的权重。

2.2 非局部注意力机制层

非局部注意力机制在图像识别任务中的主要作用是使模型能够集中资源和计算能力于图像中最相关的部分^[18]。在水稻叶片病害识别的场景中,这意味着模

型将主要关注那些可能表明病害存在的区域,如斑点、变色或其他异常特征。这样做可以提高模型的准确性和效率,因为其不需要处理图像中与任务无关的信息。

在改进的 ResNet34 模型中,非局部注意力机制的引入旨在增强模型对水稻叶片病害图像中关键特征的识别能力。非局部注意力机制可视化如图 3 所示。给定一个输入特征图 $X \in R^{C \times H \times W}$,其中 C 是通道数, H 和 W 分别表示高度和宽度,可以计算自注意力权重矩阵 $A \in R^{N \times N}$,其中 $N=H \times W$ 是特征图的总像素数,计算如式(3)所示。

$$A_{ij} = \frac{1}{Z} \exp \frac{Q_i \cdot K_j}{\sqrt{d_k}} \quad (3)$$

式中: Q_i, K_j ——特征图中位置 i 和 j 处的查询和键向量;

d_k ——注意力头的维度;

Z ——归一化因子,确保注意力权重的和为 1。

然后,使用注意力权重矩阵来计算自注意力特征图 $Y \in R^{C \times H \times W}$,计算如式(4)所示。

$$Y_i = \sum_{j=1}^N A_{ij} V_j \quad (4)$$

式中: V_j ——位置 j 处的值向量。

非局部注意力机制引入更大的感受野,使得每个位置可以关注到更远的位置。权重矩阵的计算如式(5)所示。其中, Q_i 和 K_j 的计算方法与自注意力相同。

$$B_{ij} = \frac{1}{Z} \exp \left(\frac{Q_i \cdot K_j}{\sqrt{d_k}} + g(x_i, x_j) \right) \quad (5)$$

$$g(x_i, x_j) = \gamma f(x_i)^T h(x_j) \quad (6)$$

式中: B_{ij} ——最终的注意力权重;

$g(x_i, x_j)$ ——捕捉非局部关系的函数;

$f(\cdot), h(\cdot)$ ——线性变换函数;

γ ——可训练的标量参数。

非局部注意力特征图 Y_i' 的计算与自注意力类似,如式(7)所示。

$$Y_i' = \sum_{j=1}^N B_{ij} V_j \quad (7)$$

通过这种方式,模型可以在后续层中更加关注那些具有更高注意力分数的区域,从而提高对病害特征的识别能力。




图 3 非局部注意力机制

Fig. 3 Non-local attention mechanism

2.3 深度可分离卷积层

深度可分离卷积通过将标准卷积分解为 2 个较小的操作,显著减少模型的参数量和计算复杂度^[19]。这种方法不仅减少模型的大小和训练时间,而且还保持特征提取的能力,如图 4 所示。在水稻叶片病害识别等任务中,这使得模型能够更快地训练,并且在资源受限的设备上运行,同时仍然保持高准确率。

深度卷积对输入特征图的每个通道分别应用一个卷积核。假设输入特征图 F 的尺寸为 $H' \times W' \times M$,其中 H' 和 W' 分别是高度和宽度, M 是通道数。深度卷积的操作可以表示为

$$D_m(i, j) = \sum_{k, l} F_m(i+k, j+l) \cdot K_m(k, l) \quad (8)$$

式中: $D_m(i, j)$ ——深度卷积后的特征图在位置 (i, j) 的值;

F_m ——输入特征图的第 m 个通道;

K_m ——应用于该通道的卷积核;


k, l ——卷积核的空间维度。

逐点卷积是一个 1×1 的卷积,其跨越所有通道对深度卷积的结果进行组合。如果深度卷积的输出 D 的尺寸为 $H \times W \times M$,逐点卷积的操作可以表示为

$$P_n(i, j) = \sum_m D_m(i, j) \cdot L_n(m) \quad (9)$$

式中: $P_n(i, j)$ ——逐点卷积后的特征图在位置 (i, j) 的值;

L_n ——第 n 个 1×1 卷积核。



(a) 原始网络层

(b) 深度可分离卷积层

图 4 两种网络层的区别

Fig. 4 Differences between the two network layers

3 试验结果与分析

3.1 测试环境配置

中央处理器:选用性能卓越的 Intel® Core™ i9-8750 CPU,主频达到 2.20 GHz,具备六核心的处理能力,为复杂计算提供强大动力。

操作系统:运行在最新的 Windows 11 操作系统上,保证系统的稳定性和安全性,同时提供良好的用户体验。配备 NVIDIA GeForce RTX3060 显卡,拥有 8 GB 的显存,能够高效处理图形和图像相关任务,特别适合深度学习模型的运算需求。

环境管理工具:通过 Anaconda 3 进行 Python 环境

的创建和管理,选择 Python 3.9 作为主要的编程工具,确保试验过程中的高效和一致性。试验参数如表 3 所示。

表 3 试验参数设置

Tab. 3 Experimental parameter settings

参数	数值/类型	参数	数值/类型
优化器	Adam	批量大小	32
学习率	0.001	损失函数	交叉熵损失
学习率衰减	0.97		

3.2 图像数据预处理

图像预处理的目的是改善图像数据的质量,以便于后续的分析 and 处理。针对水稻图像数据的预处理,以提高机器学习模型在水稻图像分析任务中的性能。采用亮度调整、色调调整、旋转和剪裁操作,能够有效增强数据的多样性和泛化能力,如图 5 所示。

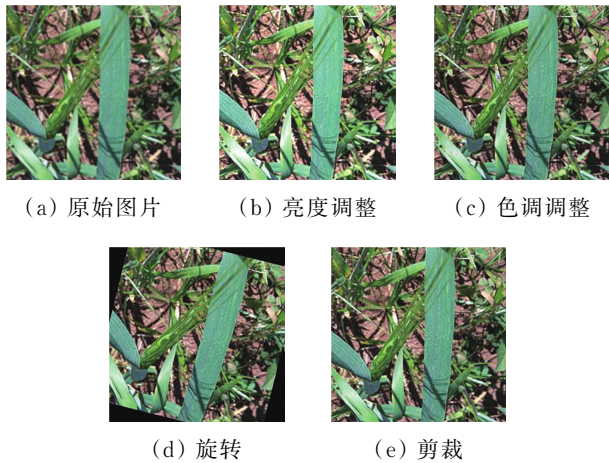


图 5 数据增强

Fig. 5 Data enhancement

3.3 评价指标

采用精确率 P 、召回率 R 、 $F1$ 分数和准确率 Acc 评估模型的性能。此外,为全面衡量模型对各类别的识别平衡性,还对改进 ResNet34 模型的平均精度进行计算。指标计算如式(10)~式(13)所示。

$$P = \frac{TP}{TP + FP} \quad (10)$$

$$R = \frac{TP}{TP + FN} \quad (11)$$

$$F1 = 2 \left(\frac{P \times R}{P + R} \right) \quad (12)$$

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (13)$$

式中: TP ——真阳性;

TN ——真阴性;

FP ——假阳性;

FN ——假阴性。

3.4 试验结果

图 6 可视化改进后模型在训练集和测试集上不同

批次的损失变化,图 7 可视化改进后模型在训练集和测试集上不同批次的准确率变化。在训练集上,准确率逐渐提高至 0.98,反映模型有效学习了训练数据的特征和规律;同时,损失持续降低至 0.1,说明预测误差不断减小,分类性能得到提升。在测试集上,准确率逐步增加至 0.95,体现模型较强的泛化能力,能适应新的数据输入;损失持续降至 0.1,表明模型避免过拟合,保持良好的稳定性。




图 6 训练损失可视化

Fig. 6 Training loss visualization




图 7 训练准确率可视化

Fig. 7 Visualization of training accuracy

表 4 对比了不同模型在训练集和测试集上的平均识别准确率,所提出的改进 ResNet34 模型取得最佳表现,在训练集和测试集的准确率分别达 0.96 和 0.95,显示该模型出色的泛化能力和预测性能。

表 4 平均识别准确率对比

Tab. 4 Comparison of average recognition accuracy

模型	训练集准确率	测试集准确率
CNN	0.82	0.83
ResNet34	0.86	0.86
ResNet101	0.90	0.87
VGG16	0.92	0.90
VGG19	0.93	0.92
MobileNetV2	0.94	0.89
Swin Transformer	0.95	0.93
改进 ResNet34	0.96	0.95

值得重点关注的是,与其他单一 CNN 模型(如 ResNet34、ResNet101、VGG16、VGG19、MobileNetV2、Swin Transformer)相比,改进后模型能够更有效降低过拟合风险。过拟合一直是深度学习模型面临的挑战,会导致模型过于专注于训练数据,而在新数据上的

泛化能力下降。

采用数据增强的方法,通过对图像进行翻转、锐化、柔化等变换操作,扩大数据集的规模和多样性,从而减少模型对噪声和异常值的敏感性。表 5 对比了不同类型下的识别准确率,可以看出,数据增强确实对改进 ResNet34 模型的准确率产生一定提升作用。在使用数据增强后,训练集和测试集的准确率分别提高 0.03 和 0.04,达到 0.96 和 0.95。这表明通过数据增强,模型能够更好地适应不同的数据变化,避免出现拟合或欠拟合的情况。数据增强赋予了模型更强的泛化能力,使其在面对多样化的数据时也能保持较高的识别精度,进一步提升模型的实用性和鲁棒性。

表 5 不同数据类型的识别准确率对比

Tab. 5 Comparison of recognition accuracy of different data types

类型	训练集准确率	测试集准确率
原始数据	0.93	0.91
数据增强	0.96	0.95

混淆矩阵是一种评估分类模型性能的有效工具,将模型对每个类别的预测结果与实际结果进行对比。矩阵的行代表实际类别,列代表预测类别。位于对角线上的元素表示模型正确预测的样本数,而非对角线上的元素则表示模型错误预测的样本数。图 8 可视化了 ResNet34、VGG19、Swin Transformer 和改进后模型在水稻叶片病害识别任务上的混淆矩阵。

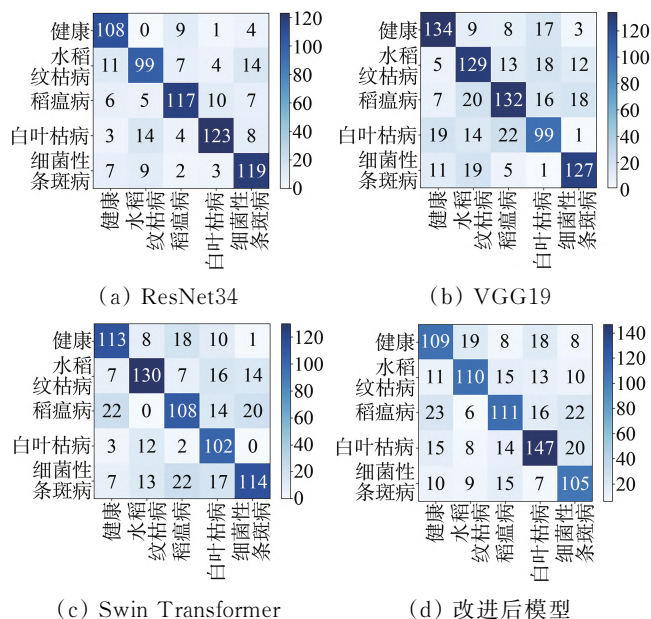


图 8 水稻叶片病害的混淆矩阵

Fig. 8 Confusion matrix of rice leaf diseases

从图 8 可以看出,改进 ResNet34 模型在水稻叶片病害任务上表现出较高的准确率和较低的误差率。对角线上的元素值均在 100 以上,说明改进 ResNet34 模型能够正确识别大部分样本。而非对

角线上的元素值均在 10 以下,表明改进 ResNet34 模型很少将某个类别误判为其他类别。这些数据充分反映改进后模型在水稻叶片病害识别方面的出色性能。

为全面评估模型的性能,通过混淆矩阵计算精确率、召回率和 F1 分数等指标。从表 6 可以看出,每个类别的这些指标值都接近或达到 1,这说明模型在各个类别上的表现都十分优秀,没有明显的偏差或不平衡现象。精确率反映模型对正确结果的预测能力,召回率反映模型捕捉目标结果的能力,而 F1 分数则兼顾精确率和召回率,是综合评价的权衡指标。如此高的评分充分证明改进后模型在水稻叶片病害识别任务上的卓越性能,能够准确全面地识别出各种病害类型。

表 6 改进后模型性能评估

Tab. 6 Performance evaluation of the improved model

病害类别	精确率	召回率	F1 分数
健康	0.98	0.97	0.98
水稻纹枯病	0.96	0.97	0.98
稻瘟病	0.99	0.98	0.98
白叶枯病	0.97	0.96	0.98
细菌性条斑病	0.99	0.97	0.99

为进一步验证所提出的基于改进 ResNet34 的水稻叶片病害识别算法的有效性,设计一系列消融实验。在水稻叶片病害数据集上进行测试,选择 4 种模型配置进行比较:(1)基础模型(ResNet34):不引入任何改进,仅使用原始的 ResNet34 模型;(2)引入深度可分离卷积层:在 ResNet34 的基础上,替换部分卷积层为深度可分离卷积层;(3)引入非局部注意力机制:在 ResNet34 的基础上,引入非局部注意力机制;(4)改进后模型:同时引入深度可分离卷积层和非局部注意力机制。消融实验结果如表 7 所示。

表 7 消融实验结果

Tab. 7 Results of ablation experiment

模型	准确率	召回率	F1 分数	参数量/M
ResNet34	0.86	0.83	0.84	17
ResNet34+深度可分离卷积层	0.91	0.86	0.88	18.5
ResNet34+非局部注意力机制	0.90	0.87	0.88	19
改进模型	0.96	0.94	0.95	20.5

从表 7 可以看出,引入深度可分离卷积层和非局部注意力机制显著提升模型性能。原始 ResNet34 模型的准确率为 0.86,而改进后的模型准确率提升至 0.96,召回率和 F1 分数也有相应提高。参数量从 17 M 增加到 20.5 M,虽然理论上深度可分离卷积可有效减少模型参数量,但在本文中,仅在部分高维特征层中引入该结构。为保持特征图维度一致性和梯度稳

定性,在深度可分离卷积层前后增加了通道调整的 1×1 卷积与BN层。因此,虽然计算复杂度有所下降,但总体参数量略有上升,从17 M增加到18.5 M,再加上非局部注意力模块后达到20.5 M。结果表明,所提出的模型通过结合深度可分离卷积层的轻量化计算优势和非局部注意力机制的特征增强能力,在保持较低计算复杂度的同时获得显著的性能增益,在轻量化计算与特征表达能力之间取得了较好的平衡,有效地提升水稻叶片病害识别的准确性和鲁棒性。

图9为改进后算法在不同病害(水稻纹枯病、稻瘟病、白叶枯病、细菌性条斑病)上的检测效果。可以看出,改进后算法不仅成功捕捉到了每种病害的关键特征区域,还能够准确检测出叶片上的其他病害,进一步证明非局部注意力机制的有效性。在不同背景复杂度的图像中,算法依然能够稳定地进行检测,表明其具有较强的鲁棒性。特别是对于需要识别精细结构的病害(如细菌性条斑病),改进后算法表现出色,证明深度可分离卷积在减少参数量的同时,仍能保持卓越的特征提取能力。

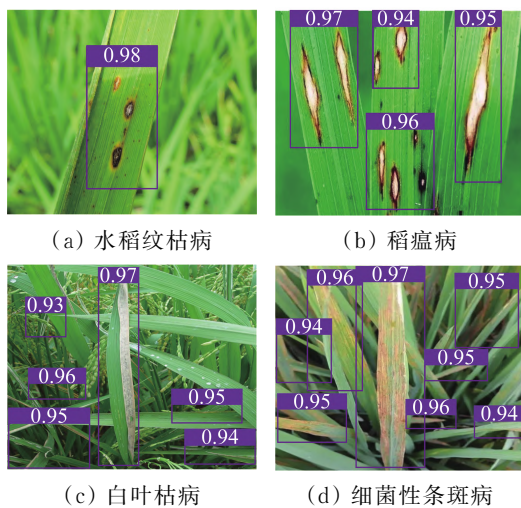


图9 改进后算法检测效果可视化

Fig. 9 Visualization of the detection effect of the improved algorithm

4 结论

1) 针对水稻叶片病害识别中特征提取不充分和模型复杂度较高的问题,提出一种基于改进ResNet34的病害识别算法。该算法以ResNet34为基础架构,创新性地引入非局部注意力机制,旨在捕捉病斑特征图中的长距离依赖关系,从而增强模型对关键病害区域的全局感知能力。同时,通过集成深度可分离卷积层,在保证识别精度的前提下有效降低模型的参数量与计算复杂度,为算法在移动或嵌入式设备上的部署提供可能性。

2) 为验证所提算法的有效性,在公开的水稻叶片病害数据集上进行一系列详尽的试验。结果表明,该模型表现出卓越的性能,其总体识别准确率达到0.96,召回率和F1分数也分别达到0.94和0.95的优异水平。这些关键性能指标充分证实,经过改进的模型不仅能够精准地区分不同类型的水稻病害,还展现高效、可靠的识别能力,显著优于部分传统的识别方法。

3) 为评估模型在实际复杂环境中的应用潜力,还进行鲁棒性分析。结果显示,该算法对于常见的图像扰动,如不同角度的旋转、尺寸缩放以及噪声干扰等,均表现出强大的适应性和稳定性,确保在非理想拍摄条件下的识别效果。综上,所提出的改进算法为实现自动化、高精度、高效率的水稻叶片病害检测提供一种有效的技术方案,具有重要的理论价值和广阔的农业应用前景。

参 考 文 献

- [1] 赵辉,李建成,王红君,等.基于改进YOLOv3的水稻叶片病害检测[J].湖南农业大学学报(自然科学版),2024,50(1):100-106.
Zhao Hui, Li Jiancheng, Wang Hongjun, et al. The detection of rice leaf diseases based on improved YOLOv3 [J]. Journal of Hunan Agricultural University (Natural Science Edition), 2024, 50(1): 100-106.
- [2] 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.
- [3] Bari B S, Islam M N, Rashid M, et al. A real-time approach of diagnosing rice leaf disease using deep learning-based Faster R-CNN framework [J]. PeerJ Computer Science, 2021, 7: e432.
- [4] 杨非凡,徐伟诚,陈盛德,等.融合Focal Loss与典型卷积神经网络结构的水稻病害图像分类[J].江苏农业科学,2023,51(14):198-204.
Yang Feifan, Xu Weicheng, Chen Shengde, et al. Rice disease image classification based on fusion of Focal Loss and typical convolutional neural network structure [J]. Jiangsu Agricultural Sciences, 2023, 51(14): 198-204.
- [5] 严陈慧子,田芳明,谭峰,等.基于改进YOLOv4的水稻病害快速检测方法[J].江苏农业科学,2023,51(6):187-194.
Yan Chenhuizi, Tian Fangming, Tan Feng, et al. Rapid detection method of rice diseases based on improved

- YOLOv4 [J]. *Jiangsu Agricultural Sciences*, 2023, 51(6): 187–194.
- [6] 卫雅娜, 王志彬, 乔晓军, 等. 基于注意力机制与 EfficientNet 的轻量化水稻病害识别方法[J]. *中国农机化学报*, 2022, 43(11): 172–181.
- Wei Yana, Wang Zhibin, Qiao Xiaojun, et al. Lightweight rice disease identification method based on attention mechanism and EfficientNet [J]. *Journal of Chinese Agricultural Mechanization*, 2022, 43(11): 172–181.
- [7] 刘拥民, 胡魁, 聂佳伟, 等. 基于 MSDB—ResNet 的水稻病虫害识别[J]. *华南农业大学学报*, 2023, 44(6): 978–985.
- Liu Yongmin, Hu Kui, Nie Jiawei, et al. Rice disease and pest identification based on MSDB—ResNet [J]. *Journal of South China Agricultural University*, 2023, 44(6): 978–985.
- [8] Yang L, Yu X, Zhang S, et al. Stacking-based and improved convolutional neural network: A new approach in rice leaf disease identification [J]. *Frontiers in Plant Science*, 2023, 14: 1165940.
- [9] 陆煜, 俞经虎, 朱行飞, 等. 基于卷积神经网络的轻量级水稻叶片病害识别模型[J]. *江苏农业学报*, 2024, 40(2): 312–319.
- Lu Yu, Yu Jinghu, Zhu Xingfei, et al. A lightweight rice leaf disease recognition model based on convolutional neural network [J]. *Jiangsu Journal of Agricultural Sciences*, 2024, 40(2): 312–319.
- [10] 杨波, 何金平, 张立娜. 基于改进 SPP—x 的 YOLOv5 神经网络水稻叶片病害识别检测[J]. *中国农机化学报*, 2023, 44(9): 190–197.
- Yang Bo, He Jinping, Zhang Lina. Identification and detection of rice leaf diseases by YOLOv5 neural network based on improved SPP—x [J]. *Journal of Chinese Agricultural Mechanization*, 2023, 44(9): 190–197.
- [11] 袁培森, 曹益飞, 马千里, 等. 基于 Random Forest 的水稻细菌性条斑病识别方法研究[J]. *农业机械学报*, 2021, 52(1): 139–145, 208.
- Yuan Peisen, Cao Yifei, Ma Qianli, et al. Identification method of rice bacterial leaf streak based on Random Forest [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2021, 52(1): 139–145, 208.
- [12] 章广传, 李彤, 高泉, 等. 融合迁移学习和知识蒸馏的轻量级马铃薯叶片病害识别模型的构建方法[J]. *江苏农业科学*, 2024, 52(4): 197–206.
- Zhang Guangchuan, Li Tong, Gao Quan, et al. Construction of a lightweight potato leaf disease recognition model based on transfer learning and knowledge distillation [J]. *Jiangsu Agricultural Sciences*, 2024, 52(4): 197–206.
- [13] 李涵, 唐友, 辛鹏, 等. 基于改进 ResNet34 的玉米病害分类研究[J]. *无线互联科技*, 2023, 20(13): 127–130.
- Li Han, Tang You, Xin Peng, et al. Research on maize disease classification based on improved ResNet34 [J]. *Wireless Internet Technology*, 2023, 20(13): 127–130.
- [14] 彭勇, 乔印虎, 姚杰. 基于改进的 ResNet34 网络模型的苹果叶病害识别[J]. *安徽工程大学学报*, 2022, 37(6): 51–57.
- Peng Yong, Qiao Yinhu, Yao Jie. Apple leaf disease identification based on improved ResNet34 network model [J]. *Journal of Anhui University of Engineering*, 2022, 37(6): 51–57.
- [15] Stephen A, Punitha A, Chandrasekar A. Designing self attention-based ResNet architecture for rice leaf disease classification [J]. *Neural Computing and Applications*, 2023, 35(9): 6737–6751.
- [16] Simhadri C G, Kondaveeti H K. Automatic recognition of rice leaf diseases using transfer learning [J]. *Agronomy*, 2023, 13(4): 961.
- [17] Nawaz M, Nazir T, Javed A, et al. A robust deep learning approach for tomato plant leaf disease localization and classification [J]. *Scientific Reports*, 2022, 12(1): 18568.
- [18] 肖天赐, 陈燕红, 李永可, 等. 基于改进通道注意力机制的农作物病害识别模型研究[J]. *江苏农业科学*, 2023, 51(24): 168–175.
- Xiao Tianci, Chen Yanhong, Li Yongke, et al. Study on crop disease identification model based on improved channel attention mechanism [J]. *Jiangsu Agricultural Sciences*, 2023, 51(24): 168–175.
- [19] 姜晟久, 钟国韵. 基于可分离扩张卷积和通道剪枝的番茄病害分类方法[J]. *江苏农业科学*, 2024, 52(2): 182–189.
- Jiang Shengjiu, Zhong Guoyun. Tomato disease classification method based on separable dilated convolution and channel pruning [J]. *Jiangsu Agricultural Sciences*, 2024, 52(2): 182–189.