

基于改进卷积神经网络的田间水稻叶片病害图像识别方法研究

李宛玉^{1,2} 赵嫚^{1,2} 贺珂^{1,2}

LI Wanyu ZHAO Man HE Ke

摘要

水稻叶片病害特征复杂多样,不同病害在不同环境下表现出的特征差异较大。对于一些具有特殊纹理或细节特征的病害图像,传统的卷积神经网络由于卷积核固定,缺乏自适应调整能力,难以全面、精准地提取这些关键特征。一旦面对新的、未曾见过的病害特征,其识别性能会大幅下降。为此,文章提出了一种基于改进卷积神经网络的田间水稻叶片病害图像识别方法。通过构建多样数据集,平滑锐化图像,引入自适应卷积策略实现全面提取特征。同时结合加权交叉熵损失函数与XGBoost,最终实现病害图像识别。实验结果表明,该方法能准确识别绝大多数样本,且错误归类率低,展现了较好的识别准确性和泛化能力。

关键词

改进卷积神经网络;田间水稻叶片;病害图像;图像识别;病害特征

doi: 10.3969/j.issn.1672-9528.2025.08.005

0 引言

农作物病害是影响农业生产的重要因素,其准确识别对保障农作物产量和质量至关重要。传统的病害识别方法主要依赖人工经验,不仅识别效率低,且易受主观因素影响,难以满足现代农业生产的快速响应需求。随着计算机视觉和深度学习技术的不断发展,基于图像识别的病害诊断方法逐渐成为研究热点。陈诗瑶等人^[1]利用Bagging算法生成训练子集,引入SE、CA注意力机制改进ResNet152、DenseNet121和MobileNetv3模型,并通过加权平均集成这些模型,实现叶片病害图像识别。但不同病害在不同环境特征差异大,模型难以全面精准提取关键特征,在复杂场景下识别效果欠佳。马超伟等人^[2]使用PP-LCNet替换YOLOv8骨干网络,并引入DepthSepConv、全局注意力机制、CARAFE模块及Wise-IoU损失函数,优化模型参数量、特征融合、重要特征提取及边界框回归性能,实现叶片病害图像识别。但该方法面对水稻叶片病害图像特殊纹理和细节特征,难以灵活调整,降低识别精度。李云红等人^[3]通过优化CycleGAN网络结构生成高质量、高复杂度样本图像,并构建M-ConvNext网络融合多尺度特征信息,实现苹果叶片病害图像识别。然而,固定的网络结构无法自动聚焦到特定尺度提取和融合特殊纹理

特征,导致这些关键特征在融合中被忽略或提取不完整,影响识别准确性。梁佳慧等人^[4]利用3种图像设备获取小麦病害图,分割得单病斑图后提取特征,构建病害识别模型。但病害形态多变,固定分割算法难准确分割特殊病斑,易丢失关键特征,导致相似但特征不同的病害难以识别。基于此,本文开展基于优化卷积神经网络的田间水稻叶片病害图像识别技术研究。

1 构建田间水稻叶片病害图像数据集

在自然情况下,不同病害类型的样本数量往往不均衡,健康叶片图像远多于病害叶片。为平衡不同类型数据,本研究从稻田实地及互联网收集大量水稻叶片图片,涵盖不同光照、角度及背景^[5]。经筛选,选定6000张图片为初始数据集,包括1000张健康叶片和5000张病害叶片(白叶枯病、稻瘟病、褐斑病)。图1展示了田间水稻叶片病害与健康叶片图像。



(a) 健康叶 (b) 白叶枯病 (c) 稻瘟病 (d) 褐斑病

图1 田间水稻叶片病害图像和健康叶片图像

2 平滑锐化处理病害图像

田间图像常含椒盐噪声,掩盖病害特征,且病害特征细微、图像模糊。本研究采用中值滤波与高频增强滤波处理图像,使其更易于特征提取,提升模型识别能力,提高病害图

1. 郑州经贸学院大数据与人工智能学院 河南郑州 450000

2. 河南省多模态感知与智能交互技术工程研究中心

河南郑州 450000

[基金项目] 校级教学改革项目(jg2432);校级青年科研基金项目(QK2216)

像识别精度和可靠性。

针对田间水稻叶片病害图像数据集中的图像，尤其是叶片部分所捕获的病害细节，平滑处理采用中值滤波技术，该技术通过局部中值替代传统局部平均值的方法，有效消除椒盐噪声等干扰因素，避免了图像转换至频域的复杂性^[6]。原始图像信号由病害特征信号 $f(x, y)$ 与噪声信号 $E(x, y)$ 混合而成：

$$g(x, y) = f(x, y) + E(x, y) \quad (1)$$

经过中值滤波技术处理后，病害图像中的噪声得到显著抑制，图像表达式更新为：

$$\bar{g}(x, y) = \frac{1}{D} \sum_{(i,j) \in C} g(x, y) = \frac{1}{D} \sum_{(i,j) \in C} f(i, j) + \frac{1}{D} \sum_{(i,j) \in C} E(i, j) \quad (2)$$

式中： D 表示噪声方差缩减的比例系数。

为进一步突出病害特征，病害图像的锐化处理引入了高频增强滤波器。该滤波器由 3 个关键组件构成：全通滤波器 $H(\alpha)$ 、低频衰减滤波器 $H_L(u, v)$ 与高频衰减滤波器 $H_H(u, v)$ 。理想高通滤波器的传递函数为：

$$H(u, v) = H(\alpha) + H_L(u, v)H_H(u, v) \quad (3)$$

$$H(u, v) = \begin{cases} 0, & D(u, v) \leq D_{0H} \\ \sqrt{1 - \alpha}, & D(u, v) > D_{0H} \end{cases}$$

通过设计的传递函数，专注于强化图像中特征鲜明的边缘和纹理信息，同时有效抑制了低频干扰，为后续的特征提取和病害识别提供更为可靠的基础。

3 基于改进卷积神经网络提取病害图像特征

水稻叶片病害特征多变，传统卷积神经网络固定卷积核影响特征提取。本研究引入自适应卷积策略，使网络能根据图像特征自适应调整，更准确捕捉病害特征^[7]。该改进卷积神经网络策略的核心在于自适应卷积过程，包含 3 个关键步骤：分离、选择与融合。

在分离阶段，采用多个尺寸各异的卷积核来对输入的病害图像特征执行卷积操作，这一过程的示意图如 2 所示。

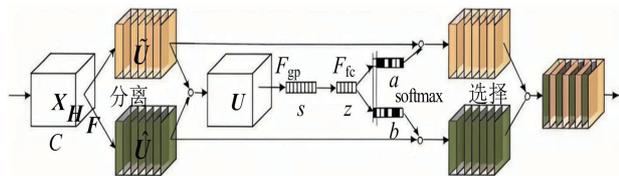


图 2 卷积示意图

对输入特征 X 分别执行 5×5 和 3×3 的卷积操作，以获取丰富的特征向量，计算公式为：

$$\hat{U} \in \mathbf{R}^{H \times W \times C} \quad (4)$$

式中： C 表示通道数量； H 表示特征空间高度； W 表示特征空间宽度。

将这些特征信息传递给下一个卷积层，并对分离阶段所得的特征执行像素级别的融合操作，表达式为：

$$U = \tilde{U} + \hat{U} \quad (5)$$

融合后的特征通过全局平均池化进一步提取关键信息。特征维度 s_c 由 U 的 c 维度特征平均池化得到，表达式为：

$$s_c = F_{gp}(U_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U_c(i, j) \quad (6)$$

式中： F_{gp} 表示特征提取函数。

在自适应卷积过程之后，执行全局平均池化操作，将特征图转换为尺寸固定的特征向量：

$$z = F_{fc}(s) = \delta[B(W_s)] \quad (7)$$

式中： F_{fc} 表示全局平均池化操作函数； δ 表示激活函数； B 表示批量归一化； z 表示紧凑特征； W_s 表示特征图向量。

为确定降维后的特征向量维度大小，引入了衰减比参数 r ，计算公式为：

$$d = \max(C/r, L) \quad (8)$$

经过 Softmax 层处理后，采用注意力机制生成注意力向量^[8]。这些注意力向量与对应的权重矩阵和卷积核进行加权求和操作，得到最终的输出特征 V ：

$$V = [V_1, V_2, V_3, \dots, V_c] \quad (9)$$

式中： $V_c \in \mathbf{R}^{C \times d}$ ，计算公式为：

$$V_c = a_c \cdot \tilde{U}_c + b_c \cdot \hat{U}_c \quad (10)$$

$$a_c + b_c = 1$$

式中： a_c 、 b_c 分别表示 a 和 b 的第 c 个元素； a 、 b 分别表示 \tilde{U} 和 \hat{U} 的平滑注意力向量。

4 实现田间水稻叶片病害图像识别

尽管改进的卷积神经网络在特征自适应提取上有优势，但单独使用在某些复杂或细微的病害特征处理和分类的全面性上存在不足。结合 XGBoost，可以利用其强大的特征组合能力和非线性建模能力，进一步挖掘和利用深度特征模型提取的特征信息，提高识别性能。在训练过程中，通过计算损失函数对模型参数的梯度，利用梯度下降算法逐步调整参数，使模型的预测结果与真实标签之间的差异最小化，从而增强模型的识别性能和准确性。

面对新的病害叶片病害图像，设计加权交叉熵损失函数来训练并更新模型参数，专门应对样本不平衡或部分域特征不稳定的问题。假设有 N 个样本，每个样本属于 M 个类别中的一个，加权交叉熵损失函数可以定义为：

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^M w_c y_{ic} \ln p_{ic} \quad (11)$$

式中： y_{ic} 表示属于第 c 个类别的第 i 个样本； w_c 表示第 c 个类别的权重； p_{ic} 表示第 i 个样本被深度特征模型预测为第 c 个类别的概率。

为最小化加权交叉熵损失函数，采用梯度下降算法来更新水稻叶片病害图像识别模型的参数^[9]。该模型由两部分组成：深度特征模型部分和 XGBoost 部分。整个模型的输出可以表示为：

$$p_{ic} = \sigma[f_c(x_i; \theta) + g_c(x_i; T)] \quad (12)$$

式中： f_c 表示深度特征模型的输出函数，该函数负责提取图像中的病害特征； σ 表示 sigmoid 函数； g_c 表示 XGBoost 部分的输出函数，该函数利用深度特征模型提取的特征进行进一步的分类决策。

为更新深度特征模型部分的参数 θ ，需要计算损失函数对 θ 的梯度：

$$\frac{\partial L}{\partial \theta} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^M w_c y_{ic} \frac{\partial \ln p_{ic}}{\partial \theta} \quad (13)$$

由于损失函数通过 sigmoid 函数与深度特征模型的输出相连，因此可利用链式法则来计算梯度：

$$\frac{\partial \ln p_{ic}}{\partial \theta} = \frac{1}{p_{ic}} \frac{\partial p_{ic}}{\partial \theta} = \frac{1}{p_{ic}} \frac{\partial p_{ic}}{\partial f_c} \frac{\partial f_c}{\partial \theta} = p_{ic}(1 - p_{ic}) \frac{\partial f_c}{\partial \theta} \quad (14)$$

为了更新 XGBoost 部分的参数 T ，需要计算损失函数对 T 的梯度：

$$\frac{\partial L}{\partial T} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^M w_c y_{ic} \frac{\partial \ln p_{ic}}{\partial T} \quad (15)$$

利用链式法则，可以得到：

$$\frac{\partial \ln p_{ic}}{\partial T} = \frac{1}{p_{ic}} \frac{\partial p_{ic}}{\partial T} = \frac{1}{p_{ic}} \frac{\partial p_{ic}}{\partial g_c} \frac{\partial g_c}{\partial T} = p_{ic}(1 - p_{ic}) \frac{\partial g_c}{\partial T} \quad (16)$$

根据梯度下降法则，可以得到参数更新公式：

$$\begin{aligned} \theta &= \theta - \alpha \frac{\partial L}{\partial \theta} \\ T &= T - \alpha \frac{\partial L}{\partial T} \end{aligned} \quad (17)$$

式中： α 表示学习率。

通过反复迭代训练过程，直到损失函数收敛，即可得到一个训练好的模型。该模型结合了深度特征模型的自适应特征提取能力和 XGBoost 的强大分类性能，能够准确地识别田间水稻叶片的病害图像。

5 实验与分析

5.1 实验测试平台

实验在某地农田水稻研究所开展，其测试平台配置详情

如表 1 所示。

表 1 实验平台配置

序号	项目	参数
1	中央处理器	I7-8700 k
2	操作系统	Windows 11
3	显卡	NVIDIA GeForce RTX2060
4	内存	8 GB
5	系统架构	64 位
6	训练环境	Anaconda3
7	编程语言	Python 3.7
8	深度学习框架	PyTorch 1.4

5.2 图像数据预处理

基于上述实验平台设置，为验证本文提出的识别方法的有效性，对图像数据实施多样化预处理。包括随机旋转图像与添加噪声等操作，以增强数据集的丰富性，如图 3 所示。

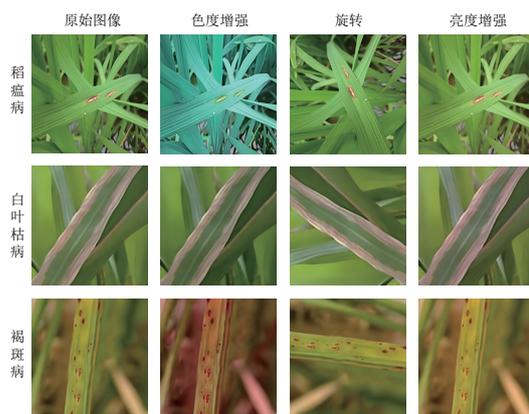


图 3 病害样本不同方式扩充效果图

利用 LabelImg 工具，按照 PASCAL VOC 2007 作为统一标注标准，对处理后的数据集进行详细标注，确保数据的一致性与兼容性。通过随机分配函数，将数据集按 4:1 的比例分割为训练集和测试集，以满足模型训练与验证需求。

5.3 评价指标

以准确率 A 作为衡量方法性能的主要评价指标。为全面评估模型对不同病害类别的识别均衡性，还引入平均精度作为辅助指标。准确率 A 的计算公式为：

$$A = \frac{TP + FN}{TP + TN + FP + FN} \quad (18)$$

式中：TP 表示正确识别的病害叶片数量；TN 表示正确识别的健康叶片数量；FP 表示错误地将健康叶片识别为病害的数目；FN 表示未能识别出的病害叶片数。这些指标共同构成了评估该方法性能的综合体系。

5.4 评估指标分析

基于改进卷积神经网络的田间水稻叶片病害图像识别方

法，其评估指标表现如图 4 所示。

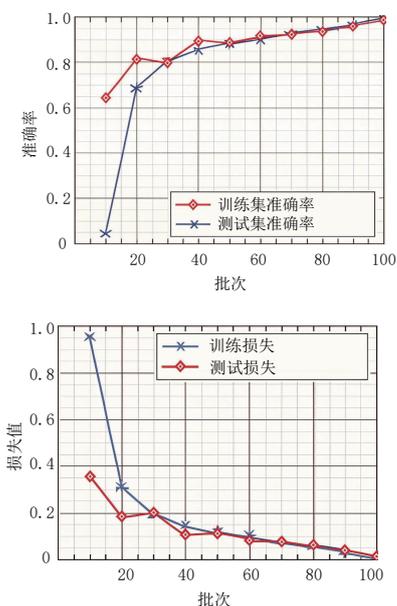


图 4 训练准确率和损失可视化

该方法提升训练集准确率至 0.98，测试集准确率至 0.96，得益于丰富数据集和自适应卷积策略。训练集和测试集损失值大幅下降，证实策略有效，有效减少预测偏差，提升识别精度。

混淆矩阵在本研究方法中，用其对比模型预测结果与实际结果。该矩阵行表示实际病害类别，列表示模型预测的病害类别。对角线上数值体现模型正确识别的样本数量，非对角线上数值反映模型预测错误的样本数量，实验结果如图 5 所示。

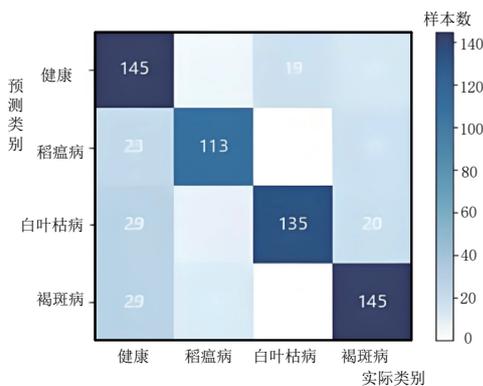


图 5 水稻叶片的混淆矩阵

由图 5 可知，本研究方法在水稻叶片病害识别中准确性高、误差率低。对角线上数值超 100，非对角线上数值低于 30，由此表明该方法识别准确且误归类率低。自适应卷积策略提升特征提取效率与准确性，混淆矩阵证实方法有效，应用前景广阔。

6 结语

本文研究了优化卷积神经网络识别水稻叶片病害，构建

全面数据集。通过结合中值滤波平滑与高频增强处理，以及引入自适应卷积机制，显著增强了模型对复杂病害特征的自适应提取能力。该方法不仅提升了病害识别的准确性，还增强了模型对新病害特征的泛化能力。未来，研究工作将聚焦于精简数据预处理步骤及开发更轻量级的模型架构，以期提高病害识别的实时响应速度。

参考文献：

- [1] 陈诗瑶, 孔淳, 冯峰, 等. 一种基于改进卷积神经网络的葡萄叶片病害集成识别方法 [J]. 山东农业大学学报 (自然科学版), 2024, 55(6): 950-960.
- [2] 马超伟, 张浩, 马新明, 等. 基于改进 YOLOv8 的轻量化小麦病害检测方法 [J]. 农业工程学报, 2024, 40(5): 187-195.
- [3] 李云红, 张蕾涛, 李丽敏, 等. 基于 CycleGAN-IA 方法和 M-ConvNext 网络的苹果叶片病害图像识别 [J]. 农业机械学报, 2024, 55(4): 204-212.
- [4] 梁佳慧, 蒋倩, 王红丽, 等. 基于机器学习的不同信源小麦叶部病害单病斑图像识别 [J]. 植物病理学报, 2023, 53(5): 905-921.
- [5] 孔江波, 朱贺, 张延文, 等. 基于实例置信度推断的半监督小样本植物病害图像识别 [J]. 江苏农业科学, 2022, 50(12): 229-237.
- [6] 林建吾, 张欣, 陈孝玉龙, 等. 基于轻量化卷积神经网络的番茄病害图像识别 [J]. 无线电工程, 2022, 52(8): 1347-1353.
- [7] 李子茂, 徐杰, 郑禄, 等. 基于改进 DenseNet 的茶叶病害小样本识别方法 [J]. 农业工程学报, 2022, 38(10): 182-190.
- [8] 李辉, 罗敏, 岳佳欣. 基于计算机视觉技术的水稻病害图像识别研究进展 [J]. 湖北农业科学, 2022, 61(4): 9-15.
- [9] 陈诗瑶, 孔淳, 冯峰, 等. 一种基于改进 ResNet18 神经网络的苹果叶片病害识别方法 [J]. 山东农业科学, 2024, 56(10): 174-180.

【作者简介】

李宛玉 (1999—), 女, 河南南阳人, 硕士, 助教, 研究方向: 计算机视觉及图像处理。

赵媛 (1993—), 女, 河南新乡人, 硕士, 助教, 研究方向: 计算机应用。

贺珂 (1982—), 女, 河南南阳人, 硕士, 副教授, 研究方向: 大数据可视化。

(收稿日期: 2025-01-17 修回日期: 2025-06-19)