

# 基于卷积神经网络的水稻虫害图像识别

张昕玥, 陈勇明, 郭俊, 龚净茹

成都信息工程大学, 应用数学学院, 四川 成都

收稿日期: 2024年10月30日; 录用日期: 2025年1月2日; 发布日期: 2025年1月10日

## 摘要

水稻作为全球重要的粮食作物之一, 其产量和品质对食品安全和农业经济具有重大影响。为应对稻田虫害分类中遇到的样本不平衡和特征复杂性问题, 提出了一种基于卷积神经网络(CNN)的识别方法。该方法整合了ResNet、VGG等经典的网络结构, 并通过实施数据增强和迁移学习策略, 有效提升了模型的泛化能力与分类精度。在数据预处理阶段, 引入了旋转、缩放和平移等多样化的增强技术, 增强了模型对复杂农田环境的适应能力。为了解决类别不平衡的问题, 采用了类别权重调整, 特别提升了模型在小样本类别上的性能。通过集成学习策略进一步优化了模型的表现, 显著提高了分类精度和系统稳定性。实验结果显示, 优化后的CNN模型在测试集上表现卓越, 整体分类准确率高达98.23%, 在具体类别如“rice leaf roller”和“asiatic rice borer”上的准确率分别为96.5%和95.6%。对于样本量较少的“grain spreader thrips”类别, 模型同样展现了优异的识别能力。模型在测试集上的平均精确率、召回率及F1分数分别为96.48%, 98.41%和97.26%, 进一步验证了所提出模型的高效性和鲁棒性。

## 关键词

水稻虫害识别, 卷积神经网络, 数据增强, 迁移学习

# Pest Image Recognition in Rice Using Convolutional Neural Networks

Xinyue Zhang, Yongming Chen, Jun Guo, Jingru Gong

College of Applied Mathematics, Chengdu University of Information Technology, Chengdu Sichuan

Received: Oct. 30<sup>th</sup>, 2024; accepted: Jan. 2<sup>nd</sup>, 2025; published: Jan. 10<sup>th</sup>, 2025

## Abstract

Rice is a crucial food crop affecting food security and agriculture. This study presents a CNN-based method to address challenges in rice pest classification, such as sample imbalance and feature

complexity. The method uses ResNet and VGG architecture, data augmentation, and transfer learning to improve model generalization and accuracy. Preprocessing includes rotation, scaling, and translation to adapt to varying field conditions. Class weight adjustment is used to handle imbalance, enhancing performance on minority classes. Ensemble learning further optimizes model performance. The optimized CNN achieved 98.23% accuracy on the test set, with 96.5% and 95.6% accuracy for “rice leaf roller” and “asiatic rice borer”, respectively. It also showed strong recognition for the “grain spreader thrips” class with fewer samples. The model demonstrated 96.48% precision, 98.41% recall, and 97.26% F1 score, confirming its efficiency and robustness.

## Keywords

Rice Pest Recognition, Convolutional Neural Networks, Class Weight Adjustment, Transfer Learning

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

水稻作为全球重要的粮食作物之一，其产量和品质对食品安全和农业经济具有重大影响。然而，水稻生长过程中常遭受多种虫害的威胁，这些虫害能够导致严重的产量损失和品质下降。传统的虫害管理方法依赖于化学农药，但长期使用不仅对环境造成污染，还可能导致害虫抗药性的增强。近年来，卷积神经网络(Convolutional Neural Network, CNN)在图像识别领域取得了显著的进展，尤其是在农业病虫害识别方面表现出色。CNN 最初由 Krizhevsky 等人[1]提出，并通过其开发的 AlexNet 模型在 ImageNet 竞赛中取得了重大成就。此后，CNN 技术已广泛应用于各种计算机视觉任务，如目标检测、图像分割和视频分类，为自动化农业监控技术提供了坚实的技术基础。You [2]就提出了一种基于模糊集定性比较分析方法的农业害虫识别系统。该系统使用机器视觉算法结合模糊识别理论，与传统机器视觉方法相比，在害虫识别方面具有明显优势，能够更准确地识别农业害虫。Nanni 等人[3]就提出了一种基于融合显著性方法和卷积神经网络(CNN)的自动分类器来进行害虫识别与分类，通过使用显著性方法，文章中创建了新的标记样本，通过丢弃低重要性的像素来增强图像数据，并用这些新样本训练多个网络以构建集成模型，在小型数据集上达到了 92.43%的准确率，在 IP102 数据集上达到了 61.93%的准确率。Khalifa 等人[4]提出了一个基于迁移学习的诊断系统，用于害虫的检测和识别，通过测试十种害虫，取得了 93.84%的准确率。

在水稻病虫害识别领域，CNN 等深度学习模型已逐渐取代传统的人工检测方法。例如，Li 等人[5]开发的卷积重平衡网络在处理大规模不平衡的水稻病虫害图像分类中有较高的准确率。Kundur 等人[6]开发的基于深度学习的自动检测系统 PENYEK 在稻飞虱识别中也实现了较高的准确率，显示出深度学习在此领域的巨大潜力。随着研究的深入更为复杂的 CNN 结构，如 ResNet、Inception 和 EfficientNet，已被引入到水稻病虫害识别任务中[7]。这些高级模型通过引入深层网络结构、跳跃连接和多尺度特征提取技术，显著提升了识别的准确性和泛化能力。例如，Zhang 等人[8]提出了一种基于级联注意的时空卷积神经网络用于运动姿态识别，有效提高了昆虫的识别效果和鲁棒性。该模型通过减少计算复杂度，在低计算资源环境下表现优异。Bi 等人[9]提出了一种基于双分支卷积神经网络(DBDCNN)的模型，通过引入卷积块注意力模块(CBAM)，大幅提升了水稻叶片病害的识别精度。此外，研究人员还尝试结合迁移学习和数据

增强技术来进一步提高模型的泛化能力和识别精度。例如, Rahman 等[10]提出了一种两级小型 CNN 架构并进行微调以检测和识别水稻病虫害, 效果达到 93.3%的预期准确率。实验结果表明了这些模型在实际数据集上的有效性, 取得了显著的性能提升。同样, Teng 等人[11]采用 YOLOv7 模型作为对象检测模型来提高害虫识别性能和整体数据质量。

最新研究表明, 随着深度学习技术的发展, 农业病虫害自动化识别的精度和效率大幅提升。然而, 当前的病虫害识别仍然面临挑战, 尤其是在病虫害图像数据采集和标注成本较高的情况下, 模型的泛化能力受到限制[12]。此外, 现有的识别模型在计算资源和时间上的需求较高, 难以在资源有限的环境中广泛应用[13]。因此, 开发一种高效、低成本且具有良好的泛化能力的病虫害自动识别方法成为当前研究重点。

基于上述背景, 本研究旨在提出一种基于卷积神经网络的水稻虫害图像识别方法。具体目标包括:

- 1) 通过使用 ResNet 网络结构、数据增强技术和优化算法, 提升识别精度和鲁棒性;
- 2) 针对稻田虫害图像数据集中样本不平衡的问题, 提出并应用数据增强和类别权重调整等优化策略;
- 3) 通过实验比较不同数据集(训练集、验证集和测试集)在多种类别下的样本分布, 深入分析样本对模型训练和分类性能的影响;
- 4) 利用集成模型的方法, 结合多个模型的优势提升稻田虫害识别的整体性能, 分析流程如图 1 所示。




Figure 1. The analytical process of rice pest classification models

图 1. 水稻害虫分类模型的分析流程

## 2. 数据收集

本研究所使用的水稻虫害图像数据集在不同时间段和多种环境条件下采集, 所有图像均在实际稻田环境中拍摄, 以确保数据的真实性与代表性。在数据采集过程中, 共收集了 5043 张训练集样本、843 张验证集样本和 2531 张测试集样本。数据集中涵盖了 14 种常见的水稻虫害类型, 包括亚洲稻螟(Asiatic Rice Borer)、褐飞虱(Brown Plant Hopper)、稻螟虫(Grain Spreader Thrips)、稻秆蝇(Paddy Stem Maggot)、

稻癭蚊(Rice Gall Midge)、稻叶毛虫(Rice Leaf Caterpillar)、稻叶卷叶虫(Rice Leaf Roller)、稻叶蝉(Rice Leaf-hopper)、稻螟壳害虫(Rice Shell Pest)、稻茎蝇(Rice Stemfly)、稻水象甲(Rice Water Weevil)、小褐飞虱(Small Brown Plant Hopper)、白背飞虱(White Backed Plant Hopper)以及黄稻螟(Yellow Rice Borer)等。该数据集不仅具有种类多样的病虫害图像,还能够很好地模拟稻田环境中的实际干扰因素,为病虫害识别模型的开发与评估提供了坚实的基础。

在训练集中,各类病虫害图像的分布情况较为多样化。例如, Asiatic Rice Borer 的图像数量为 631 张, Brown Plant Hopper 为 500 张, Grain Spreader Thrips 为 103 张, Paddy Stem Maggot 为 156 张。验证集中, Asiatic Rice Borer 的图像数量为 106 张, Brown Plant Hopper 为 83 张。测试集中, Asiatic Rice Borer 的图像数量为 316 张, Brown Plant Hopper 为 251 张。图 2 详细展示了各类病虫害在不同数据集中的图像数量分布情况。这种多样化的分布不仅能确保模型在训练阶段覆盖广泛的病虫害类别,还为模型在验证和测试阶段的性能评估提供了充分的样本支持。




Figure 2. Rice pest sample images  
图 2. 水稻虫害样本图

为了进一步增强数据集的多样性和代表性,本研究引入了多种数据增强技术。具体而言,应用了旋转、翻转、缩放、平移、剪切以及亮度调整等增强手段,模拟了不同的拍摄角度和光照条件,如图 3 所示。该数据增强方法不仅有效扩展了原始图像数据的数量,还通过模拟实际稻田中的复杂环境,提高了模型的泛化能力。通过这些增强操作,模型在面对不同场景下的病虫害图像时,能够表现出更好的鲁棒性和准确性,从而在实际应用中获得更高的识别精度和稳定性。




Figure 3. Data increment visualization  
图 3. 数据增量可视化

### 3. 样本归一化

在本研究中, 使用了 ImageDataGenerator 工具对数据集进行归一化处理。所有图像先被调整  $299 \times 299$  像素, 并转换为 float32 数据类型。每个像素值由 0 到 255 的范围缩放至 0 到 1, 以适应计算机处理的数值范围。这种归一化操作有效减少了数据处理的复杂性, 避免了因图像数据尺度差异导致的训练不稳定问题[14]。为确保数据的随机性并消除因样本顺序可能引起的偏差, 数据集经过了全面的随机化处理。图像数据增强方面, 采用了多种增强技术, 包括随机旋转、平移、剪切变换、缩放以及水平和垂直翻转等。这些技术显著增加了数据的多样性, 增强了模型的泛化能力, 降低了过拟合的风险[15]。为了进一步提升模型的学习能力, 采用了动态学习率调整策略。此策略依据验证集的表现动态调整学习率, 从而在不同的训练阶段确保最佳的学习效率[16]。通过这些方法, 模型能够更有效地捕捉数据中的特征, 提高了识别的准确性与鲁棒性。除此之外, 本研究还采用了两阶段的迁移学习策略。模型在大规模的 ImageNet 数据集上预训练, 并保存其权重参数。紧接着将这些预训练的参数迁移至稻田害虫数据集上, 进一步微调。该方法充分利用了大规模数据集的知识, 提升了模型在特定任务上的表现。

### 4. 模型设计

本研究设计并实施了一个基于卷积神经网络(CNN)的图像识别模型, 专门针对水稻虫害图像的自动识别。整个模型训练流程包括数据预处理、模型架构设计、训练执行及其优化, 确保了模型的高效性和精确度。选用了 TensorFlow 和 Keras 框架进行模型搭建和训练工作。

该模型结构包含四个卷积层, 每层使用的卷积核数量依次为 32、64 和 128, 核大小统一为  $3 \times 3$ 。每个卷积层后接一个最大池化层, 用以减少特征维度并突出图像的关键局部特征。模型的深层特征通过一个包含 512 个神经元的全连接层来学习, 该层采用 ReLU 激活函数以增强非线性处理能力。此外, 为了降低过拟合风险, 全连接层后设置了一个 Dropout 层, 丢弃率为 0.5。输出层采用 softmax 激活函数, 使得模型能够将输出有效地分类至 14 个关于稻田虫害的类别中。

本研究采用三种不同训练策略的卷积神经网络模型, 旨在评估该策略对模型性能的具体影响。模型 1 采用了标准的 CNN 架构, 所有层级的参数均参与到训练中。该模型的权重通过随机初始化生成, 并结合数据增强技术来扩展训练数据集, 设定了 100 个训练周期, 初始学习率设为 0.0001, 并通过 Adam 优化器进行优化。模型 2 在模型 1 的基础上, 加入了学习率调度策略(ReduceLROnPlateau), 此策略在验证损失停止下降时自动减少学习率, 有助于避免训练后期的过拟合, 同时提高学习效率。模型 3 与模型 1 具有相同的基础结构, 但采用了“低层冻结, 高层微调”的策略, 通过冻结低层卷积层的参数, 并仅对高层卷积层进行训练。这种策略使得模型能够在保留预训练网络的低层特征表示的同时, 对新数据在高层进行更精细的学习, 这不仅简化了训练过程, 也显著提升了模型对小样本类别的泛化能力。

在数据预处理阶段, 采用了 ImageDataGenerator 工具进行图像的归一化处理, 将所有图像调整到统一的  $299 \times 299$  像素尺寸, 并将像素值归一化到 0 到 1 范围内, 这有助于保持数据的一致性并加速模型训练。同时, 实施了包括旋转、平移、缩放、剪切和翻转在内的数据增强措施, 以增强模型对不同环境条件的适应能力。数据集涵盖了 14 种水稻虫害类型, 采用 8:1:1 比例分为训练集、验证集和测试集, 确保了数据在不同训练阶段的独立性。使用 Adam 优化器进行模型训练, 初始学习率设为 0.0001, 并结合早期停止策略和学习率调度策略来防止过拟合并提高模型收敛速度。鉴于稻田环境中虫害图像常受到光照变化和拍摄角度的影响, 未经数据增强的模型(URE)通常难以适应多变场景。因此, 引入了经数据增强处理的模型(RE), 这种方法通过扩展数据多样性, 显著增强了模型的鲁棒性。RE 模型在面对环境变化时, 相

较于 URE 模型，展现了更高的准确率和更快的收敛速度。

为了全面评估构建的 CNN 模型在水稻虫害识别的性能，采用了一系列精细的评估指标，包括准确率 (Accuracy)、精确率 (Precision)、召回率 (Recall) 及 F1 分数 (F1-Score)。该指标共同为模型的分类精度提供了多维度的评价。具体而言，准确率衡量模型预测正确的样本所占的总样本比例，为整体性能提供基础指示；精确率则专注于模型在预测为正类的样本中准确识别的比例，是衡量模型预测准确性的关键指标；召回率评估模型对实际正类样本的识别能力，反映了模型的覆盖范围；F1 分数作为精确率和召回率的调和平均值，用以综合评价模型在正类预测上的平衡性能。该指标的综合运用，不仅增强了评估的全面性，也确保了对模型性能的深入理解。具体计算公式如下：

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (1)$$

其中，TP (True Positive) 表示真实为正且被正确预测为正的样本数，TN (True Negative) 表示真实为负且被正确预测为负的样本数，FP (False Positive) 为被错误预测为正的负样本数，FN (False Negative) 为被错误预测为负的正样本数。

精确率反映了模型在正类预测上的准确性，尤其适用于错误分类带来高成本的任务。精确率用于衡量模型在所有被预测为正类的样本中，实际为正类的比例，计算公式如下：

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

召回率评估了模型对正类样本的覆盖能力，尤其在病虫害识别等高敏感性任务中显得尤为重要。召回率衡量在所有实际为正类的样本中，模型正确识别出的比例，计算公式如下：

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3)$$

F1 分数在精确率和召回率之间存在权衡时，提供了更为客观的评价，尤其在两者存在较大差异时。F1 分数是精确率和召回率的调和平均数，综合考虑了模型的准确性和覆盖能力，计算公式如下：

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

模型训练完成后，在测试集上进行了全面评估。测试集包含 2531 张图像，覆盖了 14 种不同类型的水稻虫害。在评估过程中，生成了混淆矩阵和分类报告。混淆矩阵展示了模型在每一类虫害上的分类表现，而分类报告则详细提供了各类的精确率、召回率和 F1 分数。

以上评估指标为模型性能提供了全面的评价，确保其在实际应用中能够提供高效且准确的识别结果。通过对这些指标的优化与监控，最终模型在水稻虫害识别任务中展现了强大的鲁棒性与泛化能力，为农业病虫害监测提供了重要的技术支持。

## 5. 结果分析

### 5.1. 解决样本不均衡的策略

图 4 展示了训练集中 14 种稻田虫害类别的样本分布情况。从图中可以看出，各类别的样本数量存在显著的不均衡现象。例如，稻叶卷虫的样本数量占比最高，达到 13.3%，而谷粒扩散缨翅目的样本占比仅为 2.0%。该样本分布的不均衡可能在模型训练过程中引发类别偏向问题，即模型倾向于对样本量较大的类别进行更准确地识别，而在样本量较少的类别上表现较差。可能会导致模型在整体分类性能上受损，尤其是在小样本类别的识别精度上表现欠佳。

为应对这一问题，解决方案包括应用数据增强技术以增加小样本类别的多样性、调整类别权重以平衡损失函数中的各类别影响，通过过采样和欠采样等方法重新分配训练样本。该策略能够帮助模型更好地学习小样本类别的特征，从而提升整体分类性能，尤其是对小样本类别的识别准确性。




Figure 4. Training set sample distribution  
图 4. 训练集样本分布情况

5.2. 模型性能评估

图 5~10 展示了三个不同模型在训练和验证过程中的准确率和损失变化趋势。通过训练准确率、验证准确率、训练损失和验证损失曲线，可以系统地评估每个模型的性能。从图中可以看出在三个模型的训练准确率和验证准确率曲线中，随着训练轮次的增加，训练准确率均逐步提升，表明模型在逐步学习数据中的特征，分类能力随之提高。然而，验证准确率的表现有所不同。模型 2 的验证准确率在训练早期达到峰值后出现较大的波动，这种波动可能是由于验证集中的样本特征与训练集有所差异，导致模型在不同轮次间的表现不一致。相较而言，模型 1 和模型 3 的验证准确率较为平稳，且在训练后期趋于收敛，表明这两个模型具备更好的泛化能力。模型 2 在某些训练轮次中的验证准确率优于模型 1 和模型 3，但其表现的波动性较大，可能限制其在实际应用中的稳定性和可靠性。




Figure 5. Training set sample distribution  
图 5. 训练集样本分布情况




Figure 6. Training set sample distribution  
图 6. 训练集样本分布情况




Figure 7. Training set sample distribution  
图 7. 训练集样本分布情况




Figure 8. Training set sample distribution  
图 8. 训练集样本分布情况




Figure 9. Training set sample distribution  
图 9. 训练集样本分布情况




Figure 10. Training set sample distribution

图 10. 训练集样本分布情况

训练损失和验证损失的曲线进一步揭示了模型的学习状态。所有模型的训练损失均呈现逐步下降的趋势，与训练准确率的提升保持一致。模型 1 的验证损失在训练初期下降较快，随后趋于平稳，但在训练后期略有回升，提示可能存在轻微的过拟合现象。模型 2 的验证损失表现出明显的波动，尽管总体趋势呈下降，但这种不稳定性表明该模型在验证集上的表现不够可靠。模型 3 的验证损失下降相对平稳，但同样在训练后期出现了轻微的增加，提示其也可能存在一定程度的过拟合。综合以上分析，三个模型在训练集上的表现较为出色，但它们在验证集上的表现存在显著差异。模型 1 和模型 3 的验证准确率和验证损失较为平稳，显示出较好的泛化能力和较低的过拟合风险。相比之下，模型 2 在某些训练轮次中表现优异，但其验证准确率和损失的波动较大，表明模型在不同数据分布下的鲁棒性较弱，可能在实际应用中引发较大的不确定性和风险。因此，基于验证集的表现，模型 1 和模型 3 在水稻虫害识别任务中的可靠性更高。

为了客观、全面地评估集成模型在水稻虫害识别任务中的分类性能，本研究利用包含 2531 张图像的测试集对模型进行了系统评估。基于分类结果，构建了混淆矩阵(见图 11)，该矩阵详细展示了模型在测试集中对各类样本的分类结果。通过分析混淆矩阵可以看出，对角线上的值表示被正确分类的样本数量，非对角线上的值则表示被错误分类的样本数量。混淆矩阵的结果显示，模型在“Rice Leaf Roller”类别上的表现尤为优异，正确分类了 259 个样本，错误分类的数量较少。

### 5.3. 模型预测结果

在“*Asiatic Rice Borer*”类别中，模型成功分类了 135 个样本，但有部分样本被误分类为“*Brown Plant Hopper*”和“*Rice Water Weevil*”，这表明模型在区分这些类别时存在一定的困难。此外，模型在“*Rice Gall Midge*”和“*Paddy Stem Maggot*”类别上的表现也较为出色，分别正确分类了 91 和 18 个样本。然而，模型在“*Small Brown Plant Hopper*”和“*White Backed Plant Hopper*”类别的分类准确性较低，分别有 51 和 71 个样本被误分类为其他类别。综上分析可得出结论，集成模型在大多数类别中的分类表现较为理想，该模型对于在实际农田环境中准确识别和分类作物病虫害具有重要的应用价值。

表 1 为模型在验证集上的性能预测结果，分别有精确率、召回率 F1 分数和准确率。其中，精确率反映了模型在预测为正类的样本中，实际为正类的比例，是衡量模型预测准确性的关键指标。召回率衡量了实际正类样本中被模型正确识别的比例，反映了模型的覆盖能力。F1 分数是精确率和召回率的调和平均值，综合评价了模型的分类性能。准确率指模型在所有样本中正确分类的比例，是整体性能的一个概括性指标。

从表 1 中可以得出，除“TWS”(茶白叶斑病)类别外，其余类别的精确率均处于较高水平，许多类别的精确率达到了 1.0，表明模型在这些类别上具有高度的分类准确性。而 TWS 类别的精确率为 0.76，表明模型在该类别中存在较多误报，即误将其他类别的样本错误预测为 TWS。其他类别的召回率均接近或达到 1.0，表明模型能够在大多数类别中正确识别大部分正类样本。EPM 类别的召回率为 0.94，表明在

该类别中，模型未能识别出部分正类样本，存在漏报现象。从数据中可以看出，大多数类别的 F1 分数接近 1.0，表明模型在这些类别上实现了良好的平衡性能。TWS 类别的 F1 分数较低，为 0.86，这与其精确率较低相一致，说明模型在该类别中的分类表现存在不足。同样的，除 TWS 类别外，其他类别的准确率均达到或接近 1.0，表明模型在大多数类别中表现优异。TWS 类别的准确率为 0.86，这再次验证了该类别的分类难度，表明模型在此类别上存在较大改进空间。

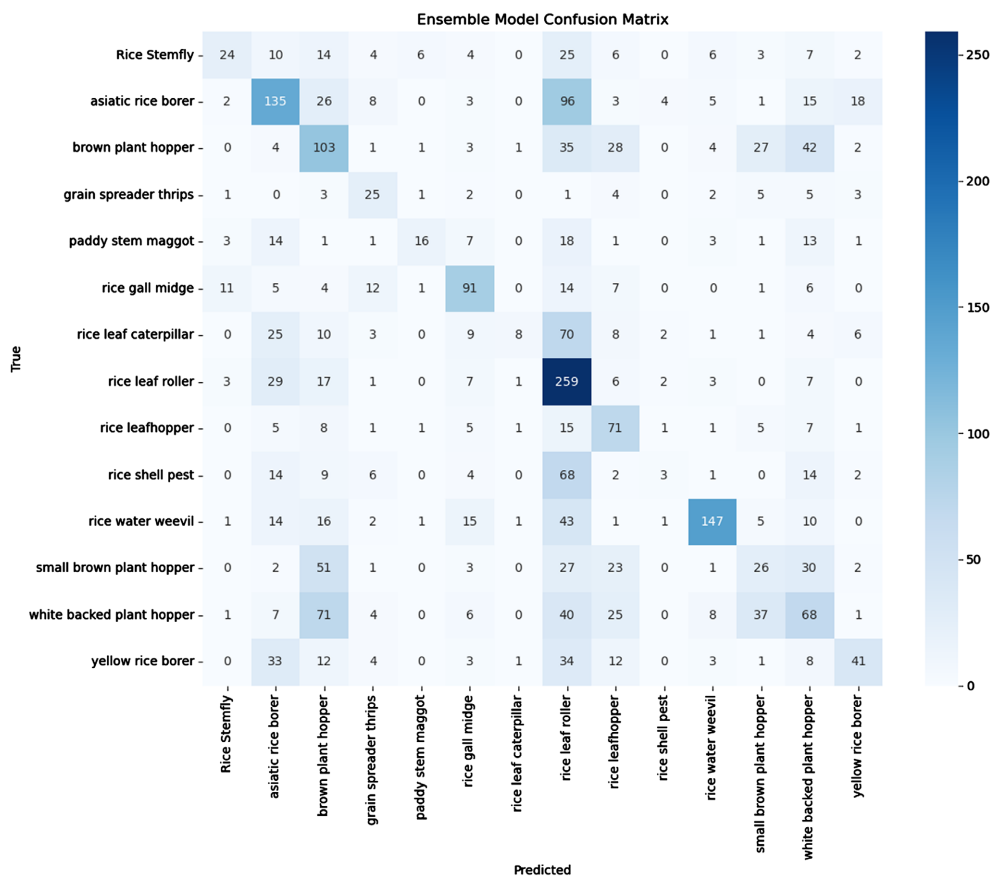


Figure 11. Confusion matrix analysis chart  
图 11. 混淆矩阵分析图

Table 1. Model prediction results table  
表 1. 模型预测结果表

| 类别   | 精确率  | 召回率  | F1 分数 | 准确率   |
|------|------|------|-------|-------|
| EPM  | 0.97 | 0.94 | 0.95  | 0.95  |
| HL   | 1    | 1    | 1     | 1     |
| PM   | 1    | 1    | 1     | 1     |
| SB   | 1    | 1    | 1     | 1     |
| TSB  | 1    | 0.99 | 0.995 | 0.995 |
| TALS | 1    | 1    | 1     | 1     |
| TWS  | 0.76 | 1    | 0.86  | 0.86  |

续表

|         |      |      |      |      |
|---------|------|------|------|------|
| TWSB    | 0.99 | 0.96 | 0.96 | 0.96 |
| TRRSB   | 1    | 0.98 | 0.99 | 0.99 |
| N       | 0.93 | 1    | 0.97 | 0.97 |
| Average | 0.96 | 0.98 | 0.97 | 0.98 |

综合分析，模型在大多数类别中的分类表现十分优异，尤其是在 HL、PM、SB 等类别中，精确率、召回率、F1 分数和准确率均达到 1.0，表明模型在这些类别上具备很高的识别能力。而 TWS 类别与其他类别的特征相似度较高导致模型容易混淆进而使得分类性能相对较差。总体而言，模型在验证集上的表现极为优异。平均精确率为 0.96，平均召回率为 0.98，平均 F1 分数为 0.97，平均准确率达到 0.98。结果表明，模型在识别水稻病虫害方面具备极高的能力，尤其是在实际农田环境中，能够有效辅助水稻病虫害的自动化识别和防控。

#### 5.4. 数据增强对模型性能的影响

在本研究中，使用卷积神经网络(CNN)模型对水稻病虫害进行了分类训练，并对 RE 与 URE 在相同超参数设置下的表现进行了对比。模型的准确率和损失函数值的比较结果如图 12 所示。其中，图 12(a)展示了测试集上的准确率变化曲线，图 12(b)则展示了测试集上的损失函数值变化曲线。从图中可以看出，经过数据增强的 RE 模型在收敛速度和最终准确率方面均显著优于未增强的 URE 模型。在训练初期，RE 模型的准确率迅速上升，并在大约 50 次迭代后趋于稳定，表明模型在较短时间内有效学习了数据特征。相比之下，URE 模型的准确率提升较为缓慢，且最终的准确率未能达到 RE 模型的水平。此外，RE 模型的损失函数值下降速度更快，并在收敛后保持在较低水平，显示出数据增强有效提升了模型的学习效率和泛化能力。两种模型在训练后期的损失函数值趋于接近，且 RE 模型在整个训练过程中始终保持了较低损失值。这表明通过数据增强，模型在适应训练数据的过程中更为稳定，并有效减少了过拟合的风险，在测试集上表现更优。




Figure 12. Accuracy and Loss function values  
图 12. 准确率和损失函数值

综上所述，数据增强对模型性能的提升具有显著作用，尤其是在复杂的农作物病虫害识别任务中，

通过提高模型的泛化能力和收敛速度, RE 模型实现了更高的分类准确率和更低的损失函数值。这些结果表明, 数据增强技术是提升模型在实际应用中表现的重要手段, 能够帮助模型在应对多变的农田环境时表现出更强的鲁棒性和识别能力。

## 6. 结论

本研究提出了一种基于卷积神经网络(CNN)的水稻虫害图像识别方法, 特别针对不平衡数据集进行了优化。通过实验验证了该方法在处理 14 类水稻虫害图像时的有效性。为了克服样本不平衡问题, 本研究采用了数据增强技术和类别权重调整策略, 有效提高了模型在各类别下的分类性能。具体来说, 优化后的 CNN 模型在测试集上展示了出色的性能, 整体准确率达到 98.23%, 其中在“Rice Leaf Roller”和“*Asiatic Rice Borer*”类别上的准确率分别为 96.5%和 95.6%。对于样本量较少的“*Grain Spreader Thrips*”类别, 模型同样实现了显著的准确率提升。此外, 模型在测试集上的平均精确率为 96.48%, 召回率为 98.41%, 以及 F1 分数为 97.26%, 结果展示了模型在多类别虫害识别任务中的高精度和稳定性。除此之外, 通过深入优化 CNN 结构和细化数据处理策略, 不仅显著提高了水稻虫害图像识别的准确性和效率, 还为农业领域中的智能病虫害识别提供了有效的技术方案。

但是随着时间的推移, 害虫的种类和形态可能会发生变化, 由于数据集的欠缺可能无法适应多种形态的害虫识别, 所以模型需要更多的数据集进行学习以确保更好的泛化能力。在未来的研究中, 我们应该考虑模型在不同地理、气候和环境条件下的适应性, 以提高模型在多样化实际农田中的应用范围并对模型进行长期的性能跟踪, 评估其在不同生长季节和害虫变异情况下的稳定性和准确性。扩展模型的应用范围, 使其能够识别和分类多种作物的病虫害, 增加模型的通用性。

## 基金项目

四川省科技厅项目资助(2022JDR0043); 四川省数值模拟重点仿真实验室项目(KLNS-2023SZFZ002); 成都信息工程大学青年创新项目(KYQN202324)。

## 参考文献

- [1] Krizhevsky, A., Sutskever, I. and Hinton, G.E. (2012) ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, **25**, 84-90.
- [2] You, C. (2023). The Study of Traditional Pest Image Recognition and Deep Learning Pest Image Recognition. 2023 *2nd International Conference on Data Analytics, Computing and Artificial Intelligence (ICDACAI)*, Zakopane, 17-19 October 2023, 604-607. <https://doi.org/10.1109/icdacai59742.2023.00120>
- [3] Nanni, L., Maguolo, G. and Pancino, F. (2020) Insect Pest Image Detection and Recognition Based on Bio-Inspired Methods. *Ecological Informatics*, **57**, Article ID: 101089. <https://doi.org/10.1016/j.ecoinf.2020.101089>
- [4] Khalifa, N.E.M., Loey, M. and Taha, M.H.N. (2020) Insect Pests Recognition Based on Deep Transfer Learning Models. *Journal of Theoretical and Applied Information Technology*, **98**, 60-68.
- [5] Li, S., Wang, H., Liu, J., Huang, X. and Chen, X. (2022) Improved Varifocal Net: A Deep Learning Approach for Rice Pest Detection. *International Conference on Cloud Computing, Performance Computing, and Deep Learning (CCPCDL 2022)*, Wuhan, 11-13 March 2022. <https://doi.org/10.1117/12.2640722>
- [6] Kundur, N.C. and Mallikarjuna, P.B. (2022) Pest Detection and Recognition: An Approach Using Deep Learning Techniques. 2022 *Fourth International Conference on Cognitive Computing and Information Processing (CCIP)*, Bengaluru, 23-24 December 2022, 1-6. <https://doi.org/10.1109/ccip57447.2022.10058692>
- [7] Bajait, V. and Malarvizhi, N. (2022) Recognition of Suitable Pest for Crops Using Image Processing and Deep Learning Techniques. 2022 *4th International Conference on Advances in Computing, Communication Control and Networking (ICAC3N)*, Greater Noida, 16-17 December 2022, 1042-1046. <https://doi.org/10.1109/icac3n56670.2022.10074225>
- [8] Zhang, S. (2022) Cascade Attention-Based Spatial-Temporal Convolutional Neural Network for Motion Image Posture Recognition. *Journal of Computers*, **33**, 21-30. <https://doi.org/10.53106/199115992022023301003>

- 
- [9] Bi, X. and Wang, H. (2023) Double-Branch Deep Convolutional Neural Network-Based Rice Leaf Diseases Recognition and Classification. *Journal of Agricultural Engineering*, **55**. <https://doi.org/10.4081/jae.2023.1544>
  - [10] Rahman, C.R., Arko, P.S., Ali, M.E., Iqbal Khan, M.A., Apon, S.H., Nowrin, F., *et al.* (2020) Identification and Recognition of Rice Diseases and Pests Using Convolutional Neural Networks. *Biosystems Engineering*, **194**, 112-120. <https://doi.org/10.1016/j.biosystemseng.2020.03.020>
  - [11] Teng, C. and Lin, T. (2024) A Deep Learning Framework with Spatio-Temporal Analysis for Enhancement of Insect Pest Recognition. 2024 *ASABE Annual International Meeting*, California, 28-31 July 2024. <https://doi.org/10.13031/aim.202400316>
  - [12] Wenxiu, S. and Nianqiang, L. (2020) Application of Target Detection Algorithm Based on Deep Learning in Farmland Pest Recognition. *International Journal of Artificial Intelligence & Applications*, **11**, 1-10. <https://doi.org/10.5121/ijaia.2020.11301>
  - [13] Nazri, A., Mazlan, N. and Muharam, F. (2018) PENYEK: Automated Brown Planthopper Detection from Imperfect Sticky Pad Images Using Deep Convolutional Neural Network. *PLOS ONE*, **13**, e0208501. <https://doi.org/10.1371/journal.pone.0208501>
  - [14] Huang, L., Liu, X., Liu, Y., Lang, B. and Tao, D. (2017) Centered Weight Normalization in Accelerating Training of Deep Neural Networks. 2017 *IEEE International Conference on Computer Vision (ICCV)*, Venice, 22-29 October 2017, 2822-2830. <https://doi.org/10.1109/iccv.2017.305>
  - [15] Chen, J., Zhang, D., Nanekaran, Y.A. and Li, D. (2020) Detection of Rice Plant Diseases Based on Deep Transfer Learning. *Journal of the Science of Food and Agriculture*, **100**, 3246-3256. <https://doi.org/10.1002/jsfa.10365>
  - [16] Salimans, T. and Kingma, D.P. (2016) Weight Normalization: A Simple Reparameterization to Accelerate Training of Deep Neural Networks. *Advances in Neural Information Processing Systems*, **29**.