

# 浅谈CNN在柑橘病虫害识别预警中的应用

李海清

重庆三峡学院计算机科学与工程学院, 重庆

收稿日期: 2026年1月10日; 录用日期: 2026年2月7日; 发布日期: 2026年2月24日

## 摘要

基于深度可分离卷积与CBAM注意力机制协同优化的改进ResNet34模型, 在柑橘病虫害智能识别任务中实现了高精度、高效率与轻量化的统一。该模型通过引入深度可分离卷积有效降低了计算复杂度与参数量, 同时结合CBAM模块的通道与空间注意力机制, 自适应聚焦病虫害关键特征区域, 显著提升了模型的表征能力与判别力。实验表明, 该识别系统在自建柑橘病虫害数据集上平均精确度可达96%, 在保证实时性的同时, 大幅压缩了模型体积, 为移动端与边缘计算设备部署提供了可行的技术方案, 具备较强的实际应用价值与推广潜力。

## 关键词

柑橘病虫害识别, 深度可分离卷积, 轻量化

## A Brief Discussion on the Application of CNN in Citrus Disease and Pest Identification and Early Warning

Haiqing Li

School of Computer Science and Engineering, Chongqing Three Gorges University, Chongqing

Received: January 10, 2026; accepted: February 7, 2026; published: February 24, 2026

## Abstract

Based on the collaborative optimization of depthwise separable convolution and CBAM attention mechanism, the improved ResNet34 model achieves a unification of high precision, high efficiency, and lightweight in the intelligent recognition task of citrus diseases and pests. By introducing depthwise separable convolution, the model effectively reduces computational complexity and the number of parameters, while the channel and spatial attention mechanisms of the CBAM module

**adaptively focus on key feature regions of diseases and pests, significantly enhancing the model's representational capability and discriminative power. Experiments demonstrate that the recognition system achieves an average precision of up to 96% on a self-built citrus disease and pest dataset. While ensuring real-time performance, the model size is substantially compressed, providing a feasible technical solution for deployment on mobile and edge computing devices, with strong practical application value and promotion potential.**

## Keywords

**Citrus Disease and Pest Identification, Depthwise Separable Convolution (DSC), Lightweight**

Copyright © 2026 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

柑橘作为全球重要的水果之一，广泛种植于热带和亚热带地区，具有较高的营养价值，是仅次于小麦、大豆、棉花、玉米的第五大贸易农产品，其产量为 1.24 亿吨[1]，同时在农业生产、经济发展、生态环境保护等方面都具有重要意义。其种植能够为农民提供稳定的收入来源，特别是在柑橘主产区，柑橘种植常常是农民的重要经济支柱，有效推动了当地的扶贫工作和乡村振兴[2] [3]。农民能够通过种植柑橘改善生活条件，增强社会稳定。柑橘种植不仅是农业生产的重要组成部分，还对全球食品供应链、农业发展、区域经济发展以及生态环境保护等方面有深远的影响。

而导致柑橘品质和产量不佳的原因通常主要受自然因素、种植技术、病虫害控制和后期管理等多个环节影响。柑橘病虫害是影响柑橘种植业的重要因素之一，柑橘病虫害造成的影响[4]主要有三类：一是会直接影响柑橘的品质和产量；二是增加生产成本并减少收入，造成巨大的经济损失；三是生态环境与农业可持续发展问题。所以在柑橘生产过程中，科学、系统的病虫害防治措施不仅可以减少柑橘病虫害的发生、确保柑橘高品质，还能提高生产效率、减少化学农药的使用，从而促进农业的可持续发展[5]。

## 2. 研究现状

卷积神经网络(CNN)是一类深度学习模型，专门用于处理具有类似网格结构的数据，如图像和视频，与传统的特征提取方法不同[6] [7]，CNN 无需手动提取特征。近年来，CNN 不仅在传统的计算机视觉任务如图像分类、物体检测[8]、语义分割等中取得了巨大成功，还在医疗图像分析[9]、自动驾驶、金融数据分析、智能安防等领域得到了广泛应用。尤其是在目标检测和语义分割等任务中，CNN 取得了重要进展。

植物病虫害的有效识别与预警技术对于农业生产至关重要，基于图像识别和大数据分析的病虫害识别方法在提高作物健康监控、减少农药使用、提高农业生产效率等方面取得了显著成效。卷积神经网络已成为图像识别的主要工具，能够在大量的图像数据中提取有效特征，准确识别不同种类的病虫害，研究表明，深度学习模型能够达到超过 90% 的准确率。Mohanty [10]等人提出了一种基于深度学习的植物病害检测方法，利用大规模标注数据训练卷积神经网络模型，能够识别多种植物病害，展示了深度学习在农业图像识别中的广泛应用。于雁南[11]等人提出对 ShuffleNet V2 中引入混合注意力模块(MAM)，提升模型对病害特征提取能力，并利用 Ghost 模块优化网络中卷积层，有效降低网络模型参数量和计算成本。

当前研究已证实，深度学习技术显著提升了农业病虫害自动识别的准确性与效率。然而，现有识别系统仍面临若干突出挑战。一方面，病虫害图像数据的采集与标注过程成本高昂、耗时费力，导致模型在有

限标注数据条件下泛化能力不足,难以适应多样化的实际种植环境[12]。另一方面,主流识别模型通常依赖大量计算资源与较长的处理时间,限制了其在边缘设备或资源受限场景中的部署与应用。因此,探索兼顾高效性、低资源消耗与强泛化能力的轻量化病虫害自动识别方法,已成为该领域亟待突破的研究方向。

ResNet 网络因具有残差结构而解决了传统 CNN 中梯度消失和梯度爆炸问题[13],在图像识别应用上具有显著的成果。考虑到病虫害数据集的复杂程度和 ResNet 网络训练代价程度,故本研究选择基于 ResNet34 设计深度学习模型。在 ResNet34 的每个残差块中加入 CBAM 混合注意力机制,先通过通道注意力调整特征图,再通过空间注意力调整已加权的特征图,能更好地提升对决定病虫害识别分类重要特征的关注和抑制不重要特征。采用迁移学习(Transfer Learning)方法,训练改进的 ResNet34 网络提高模型识别精度与速度的问题,建立基于 CBAM 混合注意力机制的图像识别模型,并作为提取图像特征的模型,对模型进行优化,最后获得一个快速且准确柑橘病虫害识别模型。

基于以上背景,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) 神经网络模型的训练依赖于大量的标注数据,而高质量的标注数据在实际应用中往往较为匮乏。为满足实验所需,对柑橘病虫害图像进行收集,筛选与预处理,已获得高质量的模型训练数据。

(2) 利用基于深度学习的 CNN 中 ResNet34 网络,将部分标准  $3 \times 3$  卷积替换为深度可分离卷积,使用数据增强技术和加入 CBAM 注意力机制来优化算法,提升对柑橘病虫害进行精准识别和鲁棒性。

(3) 在(2)的基础上实现一个病虫害识别和预警的柑橘病虫害集成系统并部署到网页端。

### 3. 实验数据和处理

本文实验所需的柑橘病虫害图像,借鉴了 PlantVillage 数据集的构建思路,依据研究的需要,遵循均衡选取原则,从 PlantVillage 数据集中选取了健康叶片以及常见病害叶片图像,具体类别包括:健康柑橘叶、黄龙病叶、溃疡病叶、疮痂病叶和潜叶蛾等五类,共计获得有效图像约 6000 张。在数据划分上,将全部图像按照 8:2 的比例划分为训练集与初始验证集。其中训练集用于模型参数的学习,验证集则用于超参数调优、网络结构调整以及模型效果的初步评估。为确保最终模型评估的客观性,又从 PlantVillage 数据集的柑橘类别中随机抽取约 300 张图像和在柑橘种植地现场利用摄像机拍摄的 300 张图像共 600 张作为独立的测试集,该部分数据不参与任何训练与调优过程,仅用于检验模型的最终泛化能力。对所划分后的训练集图片进行预处理包括剪裁、翻转、缩放、转换张量、标准化、数据增强、归一化等,柑橘病虫害图片数据增强操作如下图 1 所示:



Figure 1. Examples of data augmentation for disease and pest images

图 1. 病虫害图像增强图

### 4. 模型搭建与训练

病虫害识别模型方面,在 PyTorch 中,利用迁移学习方法载入了 ResNet34 模型,并对其进行了训练。CBAM (通道空间混合注意力机制)通过双注意力机制,让网络自动学习到哪些通道和空间位置的特征更重要,从而增强关键特征、抑制无关特征。这有助于模型更聚焦于图像中的关键区域(如目标物体)。DSC (深度可分离卷积)如图 2 所示,是一种高效卷积操作,其核心作用是在大幅减少计算量和参数数量的同时,

保持模型性能，是轻量级神经网络设计的基石。在 ResNet34 模型基础上加入 CBAM 和使用 DSC 代替部分标准  $3 \times 3$  卷积层后构建了 DSCBAM-ResNet34 模型如图 3 所示，并对其进行了训练，在实验过程中，根据损失函数的值，利用反向传播算法计算网络模型中参数的梯度，使用优化器更新网络权重和偏置。

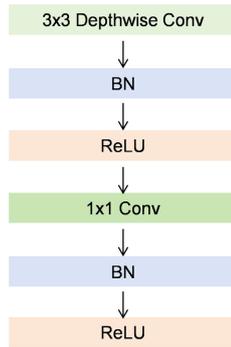


Figure 2. Structure diagram of DSC  
图 2. DSC 结构图

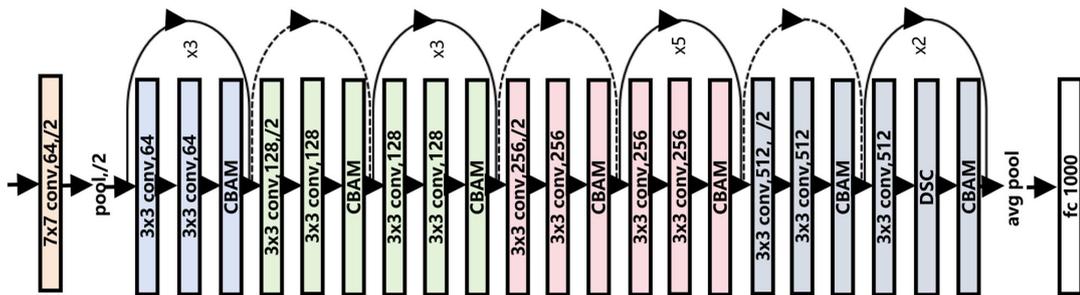


Figure 3. Architecture diagram of the DSCBAM-ResNet34  
图 3. DSCBAM-ResNet34 结构图

进行多次模型训练与验证试验后，得到相对于跟 ResNet34 和 CBAM-ResNet34 模型识别准确率比较，DSCBAM-ResNet34 模型的识别准确率提升了 9%，识别准确率接近于 97%。柑橘病虫害数据集在 Res-Net34、CBAM-Resnet34 和 DSCBAM-ResNet34 中实验过程中的损准确度分别如图 4 所示：

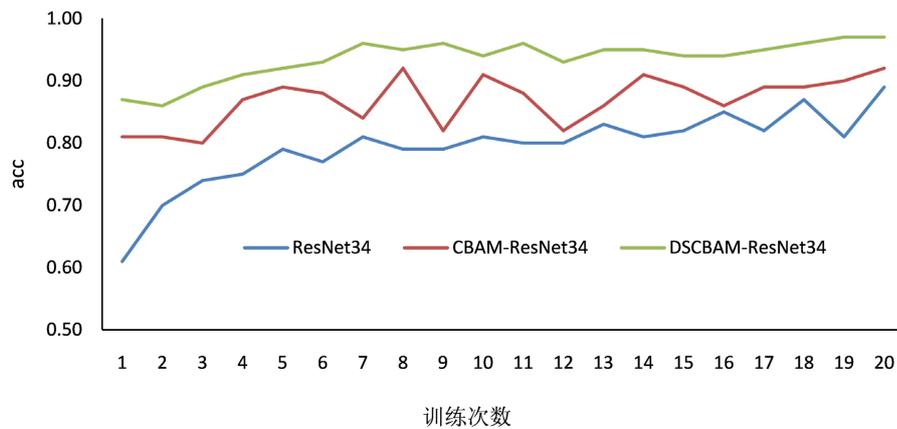
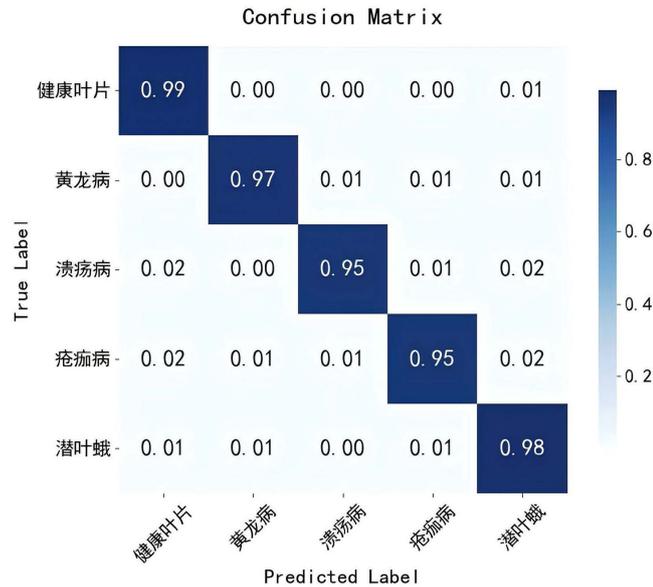


Figure 4. Accuracy results diagram  
图 4. 准确率结果图

## 5. 实验结果分析

基于 DSCBAM-ResNet34 的柑橘病虫害识别模型在柑橘病害类别识别上展现了优秀的效果如图 5 所示，其核心优势在于 DSC 模块有效降低了模型复杂度并增强了特征提取效率，而 CBAM 注意力机制则使模型能够精准聚焦于叶片病斑的关键区域，具有兼具高精度与强泛化性的卓越性能。



**Figure 5.** Confusion matrix of disease and pest identification results  
**图 5.** 病虫害识别效果混淆矩阵图

在与 SOTA 轻量化模型的对比实验中，本研究的 DSC-CBAM-ResNet34 模型展现了独特的性能平衡优势，实验如表 1 所示：在保持 96% 高识别精度的同时，其计算复杂度与参数量显著低于原版 ResNet34，并实现了嵌入式设备的实时推理。与 MobileNetV3、ShuffleNetV2 等专为移动端设计的架构相比，本模型在精度上平均领先约 3 个百分点，验证了“深度可分离卷积 + 注意力机制”协同优化策略在农业细粒度视觉任务中的有效性；虽在绝对计算效率上略逊于极致轻量化模型，但在精度 - 速度权衡曲线上找到了更优位置，为对可靠性要求严苛的田间病虫害诊断场景提供了更佳的技术选型方案。

**Table 1.** Comparison between DSCBAM-ResNet34 and other SOTA lightweight models  
**表 1.** DSCBAM-ResNet34 与 SOTA 轻量化模型比较

模型	Acc (%)	Pre (%)	Par (M)	Reca (%)	FLOPs (G)	mAP (%)	Time (ms)	Wei
MobileNetV2	94.2	93.8	3.4	94.0	0.30	93.5	15.2	13.2
ShuffleNetV2	93.8	93.3	2.3	93.5	0.15	92.9	10.1	9.1
GhostNet	95.5	95.2	5.2	95.3	0.14	94.9	12.4	20.3
DSCBAM-ResNet34	96.7	96.0	4.1	95.7	0.25	97.0	18.0	16.0

为验证模型的泛化能力，我们使用上文提到的含 600 张图片的测试集来测试模型性能，在此测试集上，DSCBAM-ResNet34 模型的具体表现如表 2 所示，该模型仍取得了 96.7% 的平均准确率与 95.5% 的宏平均 F1 分数，证明了其强大的泛化性能和实用性。

**Table 2.** Performance of the test set in the improved model**表 2.** 测试集在改进模型中的性能

病虫害类型	图像数量	Acc (%)	Pre (%)	Reca (%)	F1 (%)	AP (%)
健康叶片	180	99.0%	98.3%	99.0%	98.8%	99.1%
黄龙病	120	96.7%	96.5%	94.2%	95.3%	96.0%
溃疡病	110	95.3%	94.8%	96.3%	95.5%	95.9%
疮痂病	100	94.9%	93.1%	92.0%	92.5%	93.3%
潜叶蛾	90	97.8%	97.2%	96.0%	97.5%	97.9%
总计/平均值	600	96.7%	96.0%	95.5%	95.9%	96.4%

## 6. 系统的开发与应用

在已完成实验的基础上, 利用 Pycharm 免费社区版本和 Django 架构完成了柑橘病虫害识别模块的部署。基于 DSCBAM-ResNet34 深度学习模型开发的柑橘病虫害识别预警系统, 是一个集成了人工智能识别、数据管理和智能预警功能的农业数字化平台。系统利用 Django 架构构建了完整的 Web 应用, 能够对上传的柑橘叶片图像进行精准的病虫害智能识别与分类, 支持实时监测和批量处理, 并提供历史数据分析、趋势预警和防治指导, 帮助种植户和农技人员实现病虫害的早期发现、科学诊断和及时干预, 有效提升柑橘种植的智能化管理水平, 系统首页如图 6 所示:

**Figure 6.** Home page of the system**图 6.** 系统首页图

## 7. 结论与展望

本系统通过引入深度可分离卷积与 CBAM 注意力机制的协同架构, 在柑橘病虫害智能识别领域实现了精度、速度与轻量化的三维平衡优化。深度可分离卷积通过解耦空间滤波与通道融合, 大幅降低了模型计算量与参数量, 为移动端部署奠定了效率基础; 而 CBAM 模块则通过通道与空间双重注意力机制, 动态增强病害特征响应, 有效提升了复杂田间环境下的识别鲁棒性。二者协同形成“高效特征提取 - 自适应特征校准”的闭环, 使系统在保持高准确率的同时, 模型体积压缩至传统卷积网络的 30% 以下, 在嵌入式设备上实现亚秒级实时推理。

展望未来, 智能植保系统将沿着三大方向持续演进: 在精准化层面, 多模态融合技术将整合高光谱、热成像等多维数据, 实现病虫害的早期预警与量化诊断; 在普惠化层面, 边缘计算技术的突破将推动

AI 模型向低成本终端下沉,通过自适应压缩与硬件感知优化,构建覆盖田间地头的分布式智能感知网络;在高效化层面,云边端协同架构将打通从数据采集、智能分析到精准执行的闭环,实现植保作业的全流程自动化。这些技术的深度融合,将推动农业生产从传统经验驱动向数据智能驱动转型,为构建资源节约、环境友好的智慧农业体系提供核心支撑,最终形成可复制、可推广的数字农业解决方案。

## 参考文献

- [1] 曾云琦. 中国柑橘历史与文化价值研究[D]: [硕士学位论文]. 福州: 福建农林大学, 2008.
- [2] 郑菡, 马刘洋, 陈昶宇. 农业主导产业发展及对乡村经济与乡村振兴的影响——以忠县柑橘产业为例[J]. 智慧农业导刊, 2024, 4(12): 111-115.
- [3] 福建省漳州市长泰区柑橘产业高质量发展建议[J]. 基层农技推广, 2024, 12(11): 119-123.
- [4] 刘旭, 刘虹伶, 杨永利, 何高春. 四川柑橘树主要病虫害发生危害现状和防控对策[J]. 四川农业科技, 2017(4): 29-31.
- [5] 蒋才旺. 柑橘主要病虫害防治措施分析[J]. 种子科技, 2022, 40(17): 96-98+117.
- [6] Burger, W. and Burge, M.J. (2022) Scale-Invariant Feature Transform (SIFT). In: *Digital Image Processing: An Algorithmic Introduction*, Springer, 709-763.
- [7] Ahonen, T., Hadid, A. and Pietikainen, M. (2006) Face Description with Local Binary Patterns: Application to Face Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **28**, 2037-2041. <https://doi.org/10.1109/tpami.2006.244>
- [8] Redmon, J., Divvala, S., Girshick, R. and Farhadi, A. (2016) You Only Look Once: Unified, Real-Time Object Detection. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 779-788. <https://doi.org/10.1109/cvpr.2016.91>
- [9] Shin, H., Roth, H.R., Gao, M., Lu, L., Xu, Z., Nogues, I., et al. (2016) Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. *IEEE Transactions on Medical Imaging*, **35**, 1285-1298. <https://doi.org/10.1109/tmi.2016.2528162>
- [10] Mohanty, S.P., Hughes, D.P. and Salathé, M. (2016) Using Deep Learning for Image-Based Plant Disease Detection. *Frontiers in Plant Science*, **7**, Article 1419. <https://doi.org/10.3389/fpls.2016.01419>
- [11] Yu, Y.N., Xiong, C.L., Yan, J.C., Mo, Y.B., et al. (2024) Citrus Pest Identification Model Based on Improved ShuffleNet. *Applied Sciences*, **14**, Article 4437. <https://doi.org/10.3390/app14114437>
- [12] Khanramaki, M., Askari Asli-Ardeh, E. and Kozegar, E. (2021) Citrus Pests Classification Using an Ensemble of Deep Learning Models. *Computers and Electronics in Agriculture*, **186**, Article 106192. <https://doi.org/10.1016/j.compag.2021.106192>
- [13] He, K., Zhang, X., Ren, S., et al. (2015) Deep Residual Learning for Image Recognition. CoRR.