

基于改进 MobileNet – V2 的轻量化苹果叶片病害识别

李梅¹ 郑浩宇² 毛锐¹ 王美丽¹

(1. 西北农林科技大学信息工程学院, 陕西杨凌 712100; 2. 西北农林科技大学农学院, 陕西杨凌 712100)

摘要: 针对苹果叶片病害识别中计算资源消耗与识别准确度之间不平衡问题,提出了一种改进 MobileNet – V2 卷积神经网络模型。采用数据增强技术扩展图像样本的多样性,增加了模型泛化能力;引入迁移学习策略,通过预训练和冻结部分层参数,减少了训练时间和计算资源的消耗;通过进一步引入分组卷积、通道注意力机制中的压缩与激励模块(Squeeze-and-excitation, SE)和权重剪枝策略,优化了模型特征提取能力,提高了模型计算效率和准确率。实验结果表明,模型优化后,准确率为99.1%,较原 Mobile – V2 模型高5.9个百分点,较 ResNet50、VGG16 和 Xception 等传统卷积神经网络模型分别提升4.6、9.4、4.0个百分点。模型平均精确率为98.9%,平均召回率为98.75%,F1 分数为98.82%,参数量仅为 4.06×10^6 。模型在实际部署上也能实现快速、准确的病害检测,单幅图像平均推理时间为507 ms,具备实用价值和推广潜力,为农业智能化发展提供了参考。

关键词: 苹果; 病害识别; 数据增强; 卷积神经网络; 通道注意力; 程序实时推理

中图分类号: TP389.1 文献标识码: A 文章编号: 1000-1298(2026)08-0246-10

OSID:



Lightweight Apple Leaf Disease Recognition Based on Improved MobileNet – V2

LI Mei¹ ZHENG Haoyu² MAO Rui¹ WANG Meili¹

(1. College of Information Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

2. College of Agronomy, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: An improved MobileNet – V2 convolutional neural network model was proposed, aiming at addressing the balance between computational resource consumption and recognition accuracy in apple leaf disease identification. Firstly, data augmentation techniques were employed to expand the diversity of image samples, thereby enhancing the model's generalization ability. Next, a transfer learning strategy was introduced, where pretraining and freezing some layer parameters reduced training time and computational resource consumption. The model further optimized feature extraction capability by incorporating group convolutions, a squeeze-and-excitation (SE) module from the channel attention mechanism, and weight pruning strategies, which enhanced both computational efficiency and accuracy. Experimental results demonstrated that, after optimization, the model achieved an accuracy of 99.1%, surpassing the value of the original MobileNet – V2 model by 5.9 percentage points, and outperforming traditional convolutional neural network models, like ResNet50, VGG16, and Xception by 4.6, 9.4, and 4.0 percentage points, respectively. The model's average precision was 98.9%, average recall was 98.75%, and F1 score was 98.82%, with only 4.06×10^6 parameters. In practical deployment, the model achieved fast and accurate disease detection, with an average inference time of 507 ms per image, demonstrating its practical value and potential for widespread application, offering insights for the development of smart agriculture.

Key words: apple; disease identification; data augmentation; convolutional neural network; channel attention; real-time program inference

收稿日期: 2025 – 08 – 29 修回日期: 2025 – 10 – 17

基金项目: 国家自然科学基金面上项目(32472966)、陕西省重点研发计划项目(2025NC – YBXM – 117)和陕西省秦创原“科学家 + 工程师”队伍建设项目(2025QCY – KXJ – 070)

作者简介: 李梅(1981—),女,副教授,博士,主要从事机器学习与数据挖掘及其在农业中的应用研究,E-mail: limei@nwsuaf.edu.cn

0 引言

随着全球人口的增加及可耕作地域的减少,农业面临的挑战日益严峻^[1]。苹果作为全球重要的水果之一,其生产现状直接影响着农业经济的稳定与发展。随着全球气候变化和环境压力的增加,我国苹果生产面临着新的挑战,如水资源短缺、病虫害频发等^[2]。因此,提升苹果生产的现代化水平,尤其是在病虫害智能诊断和精准防控方面,成为了保障苹果产业可持续发展的关键。

传统的病害检测方法依赖具有鉴别病害能力的专家在田间或者实验室内进行人工鉴别,这种劳动密集型方法不仅效率低,还通常会具有较高的人为识别错误率,成本高^[3]。随着机器学习的发展,农作物病害自动化检测拥有了更高效的方法。机器学习模型通过从图像中提取典型特征,对相应的特征进行分类,从而实现作物病害自动识别。然而,这类机器学习的方法虽然足够简洁,取得了较好的识别效果^[4],但特征选择方式太过单一,可能无法完全表达作物完整病害信息,易忽略各类病害图像空间细节,从而导致其在应对复杂田间环境下的叶片病害自动检测时表现出较差的鲁棒性^[5]。

近年来,随着深度学习技术的突破,尤其是卷积神经网络^[6] (Convolutional neural network, CNN) 在图像识别领域的应用,为高效、自动化的作物病害识别提供了新的技术途径^[7]。CNN 能够不局限于单一的典型特征,通过局部感受野机制捕捉图像中的局部特征,如边缘、角点等,然后逐层抽象这些局部特征,形成更复杂的高级表示。许多优秀的卷积神经网络模型,如 MobileNet^[8]、AlexNet^[9] 和 GoogLeNet^[10]等,都利用 CNN 的独特优势,在图像识别方向上大放异彩。在作物病害识别领域,许多学者基于这些模型进行研究,取得了较好效果^[11-12]。

文献[13-16]大都需要高度计算的方法应用于大量的植物疾病识别问题,这样具有可靠的结果。尽管如此,现有研究在准确率和运行效率方面仍存在一定局限。现有模型往往难以兼顾识别准确率与运算效率,这些方法大多依赖于庞大的模型结构和高性能计算资源,限制了其在资源受限设备上的部署与推广^[17]。

此外,尤其是在近几年的研究中,在面对具有高度变异性和细粒度差异的图像时,研究并未充分探讨模型对不同病害间细粒度特征差异的辨别能力^[18]。众多结果表明,即使是最先进的模型也难以在轻量化同时保持高准确性和高效率^[19]。

为解决上述问题,考虑到 MobileNet - V2 模型的优点,保持其轻量化的优势进行优化,本文提出一种高效的轻量级卷积神经网络框架。再通过后续集成 SE 模块和迁移学习策略,提升模型在苹果叶片病害数据集上的表现。基于此,本研究提出一种基于改进 MobileNet - V2 的轻量级卷积神经网络框架,以实现苹果叶片病害精准、高效识别。依托 MobileNet - V2 模型轻量化优势进行结构优化,集成 SE 模块强化细粒度病害特征提取能力,结合迁移学习策略以提升模型泛化性能;引入剪枝策略精简模型结构,在保证识别准确率的前提下降低模型复杂度与运算开销;基于苹果叶片病害数据集开展训练与验证,验证该轻量化高准确率改进方法的有效性,以期苹果病害智能诊断技术的田间部署与推广提供技术支撑。

1 实验材料

1.1 概述

合适的图像采集策略和充足的图像样本对于精确地进行作物病害的分类与识别十分重要。本研究通过在实验室环境和自然环境中采集图像,旨在构建能够反映自然生长条件和真实应用场景的数据集,以支持病害识别模型的开发和验证。

苹果是中国北部等地广泛种植的重要经济作物。苹果叶片因其病害表现典型、数据易于获取且具有高技术应用价值,非常适合作为农作物图像识别的研究对象^[20]。苹果树在其生长周期中易受到多种病原体的影响,这些病害的发生与季节变化、环境湿度、温度及光照条件密切相关。黑腐病、褐斑病、花叶病、黑星病和锈病在近来苹果的农业种植过程中普遍存在,这 5 种病害会造成较为严重的经济损失^[21]。针对上述需求,采集苹果种植过程中具有代表性的 5 类叶部病害样本及健康对照组,通过拍摄多时段光照变化、不同气象条件的农田环境,最终形成苹果叶片病害图像数据库。

1.2 材料采集

供实验的苹果叶片图像主要采自我校苹果实验示范站,实验站分布于咸阳市乾县、宝鸡市千阳县等地。站内采集图像 2 325 幅,占比 69%。1 094 幅图像获取于 Kaggle 官方网站,占比 31%,以保持各类病害原始图像数量差距的平稳。采集工作使用 ABM 500GE/BB 500GE 型彩色数码相机,拍摄距离为 10 ~ 15 cm。图像涵盖苹果不同生长期,时间段囊括上午、下午、傍晚,并分别在晴天、阴天和下雨后进行。实验共采集在苹果不同生长期下的黑腐病、褐斑病、花叶病、黑星病、锈病和健康叶片彩色图像,

形成苹果叶片病害数据集。数据集统一规范为 512 像素 × 512 像素标准尺寸,共包含 3 419 幅苹果叶片病害及健康叶片图像,领域内专家对数据集进行了标签分类与评估,确保数据集的有效性。

图 1 展示了数据集中具有代表性的叶片病害图像,大部分图像为田间实地拍摄,确保数据集泛化能力。除此之外,所有图像都确保单叶片单病害,使得利用图像特征的识别更准确高效。




图 1 苹果不同生长期下病害图像

Fig. 1 Apple disease images at different growth stages

1.3 数据增强

对数据集进行合适处理能够有效提升 CNN 模型识别效率、训练性能和收敛速度^[22]。对数据集进行了归一化操作以及数据扩增,旨在为模型训练效率奠定基础。图 2 为对数据集进行亮度与角度调整后的结果。数据增强可提高模型对图像的泛化能力,能够模拟田间实地种植环境光照、角度等因素。



图 2 数据增强图像示例

Fig. 2 Examples of data augmentation images

在预处理阶段,主要采用 2 种方式优化数据集。首先通过归一化处理将图像数据映射到统一量纲范围,有利于模型稳定学习特征。该图像归一化后像素值 x' 计算式为

$$x' = \frac{x_i - \mu}{\sigma}$$

式中 x_i ——图像特定颜色通道像素值
 μ 、 σ ——图像该通道像素值均值、标准差

其次,对原始图像进行亮度调节和随机旋转,这种数据增强技术通过模拟田间拍摄时的光影变化和植株不同生长姿态,显著提升模型在复杂环境中的适应性检测能力。图像亮度调整可通过随机增减像素 RGB 值实现^[23],亮度调整计算式为

$$V = V_0(1 + d)$$

式中 d ——亮度因子

V_0 ——初始 RGB 值

V ——调整后 RGB 值

图像旋转原理为图像中所有像素围绕图像中心旋转一定角度。两点坐标计算式为

$$\begin{cases} x_0 = r\cos\alpha \\ y_0 = r\sin\alpha \end{cases}$$

$$\begin{cases} x = r\cos(\alpha - \theta) = x_0\cos\theta + y_0\sin\theta \\ y = r\sin(\alpha - \theta) = -x_0\sin\theta + y_0\cos\theta \end{cases}$$

式中 $P_0(x_0, y_0)$ ——图像任意点

θ ——旋转角度, (°)

$P(x, y)$ —— P_0 逆时针旋转 θ 后的坐标

r —— P_0 到旋转中心距离

α —— P_0 与 x 轴夹角

镜像翻转原理是以图像中心的垂直线为轴,交换图像中的所有像素。设图像宽为 w ,图像中任意一点坐标为 (x_0, y_0) ,在镜像对称后该点坐标为 $(w - x_0, y_0)$ 。

将增强后数据集按照比例 7 : 2 : 1 划分为训练集、验证集和测试集,训练集用于让模型在计算机上进行训练,同时自动通过验证集对比模型训练效果,最后将测试集作为未曾见过的病害图像测试模型的准确度。表 1 为数据集样本统计结果。

表 1 实验数据分布

Tab. 1 Experimental data distribution

病害类别	原始图像数量	增强后图像数量			
		训练集	验证集	测试集	总计
健康叶片	645	3 612	1 032	516	5 160
黑腐病	621	3 477	993	498	4 968
褐斑病	435	2 436	696	348	3 480
花叶病	375	2 100	600	300	3 000
锈病	713	3 993	1 141	570	5 704
黑星病	630	3 528	1 008	504	5 040
总计	3 419	19 146	5 470	2 736	27 352

2 模型结构

2.1 MobileNet - V2

MobileNet^[24]是一种针对移动设备和嵌入式平台优化的轻量级卷积神经网络模型,其核心目标是以极低的计算量和内存占用量提供高效的特征提取

能力。这使得 MobileNet 成为资源受限场景中极具竞争力模型之一,特别适用于农业病害识别、嵌入式视觉检测等实际应用中需要高效率 and 低功耗的任务^[25]。

GoogLeNet、ResNet 等传统深层网络虽通过增加网络层数有效提高了分类和特征提取的能力,但随之而来的参数爆炸和计算成本让其难以适配移动端环境^[10]。MobileNet - V2 的设计理念不仅局限于简单的轻量化优化,更在特征提取能力与计算效率之间建立了一种全新的平衡。其结构参数如表 2 所示,针对移动设备和嵌入式平台的需求,MobileNet - V2 提出了融合深度可分离卷积 (Depthwise separable convolution)、倒置残差模块 (Inverted residual block) 与线性瓶颈 (Linear bottleneck) 三者的模块化设计,有效缓解了模型体积庞大、特征损失严重以及推理效率低等问题^[26]。

表 2 MobileNet - V2 结构参数

Tab.2 Structure parameters of MobileNet - V2 model

输入尺寸	操作	<i>c</i>	<i>n</i>	<i>s</i>
224 ² × 3	Conv2d	32	1	2
112 ² × 32	Bottleneck	16	1	1
112 ² × 16	Bottleneck	24	2	2
56 ² × 24	Bottleneck	32	3	2
28 ² × 32	Bottleneck	64	4	2
14 ² × 64	Bottleneck	96	3	1
14 ² × 96	Bottleneck	160	3	2
7 ² × 160	Bottleneck	320	1	1
7 ² × 320	Conv2d	1 820	1	1
7 ² × 1 280	Avgpool		1	
1 × 1 × 1 280	Conv2d	<i>k</i>		

注:*c* 为通道维度,*n* 为重复次数,*s* 为模型卷积核步长。Conv 为标准卷积运算,Bottleneck 为线性瓶颈模块,Avgpool 为全局平均池化,*k* 为分类任务的类别数。

目前,经过多轮更新,已有 MobileNet - V2、MobileNet - V3 等多个版本。尽管 MobileNet - V3 作为 MobileNet - V2 的改进版本,MobileNet - V3 在结构上引入了多项创新,然而这些改进在农业研究中的适配性仍需权衡。在田间多光谱图像处理或温室

低功耗设备部署时,MobileNet - V2 的规则模块化设计更易通过通道剪枝或 8 - bit 量化实现模型压缩,同时避免因硬件不兼容导致的推理延迟^[27]。此外,在数据稀缺的农业场景中,MobileNet - V2 的稍大模型容量反而有助于避免过拟合,而 V3 通过 NAS 压缩的轻量级结构可能因信息表达能力受限,难以应对作物品种分类或病害细粒度识别等复杂任务^[28]。因此,最终选择 MobileNet - V2 作为识别模型,在保留 MobileNet - V2 规则模块化设计的基础上,针对性地进行了模型优化。

2.2 模型优化设计

2.2.1 改进的 MobileNet - V2 结构

针对苹果叶片病害识别中轻量化、高效的深度学习需求,在 MobileNet - V2 的基础上进行了一系列适配性优化与改进,旨在提升模型特征提取能力与推理效率。

图 3 (SE 表示添加的 SE 模块)展示了改进后的倒置残差与线性瓶颈单元结构,在 3 × 3 深度卷积和 1 × 1 逐点卷积之间,插入 SE 模块,通过引入通道注意力机制,网络能够更加关注具有高表征能力的特征通道,从而进一步提升特征表示的准确性。针对计算效率和模型压缩的需求,在倒置残差模块中加入分组卷积 (Group convolution) 和权重剪枝策略 (Weight pruning),以降低计算复杂度并减少参数量。

这一系列优化使得改进 MobileNet - V2 在资源受限设备上表现出色,能够满足实时、低延迟的应用需求。图 4 为改进 MobileNet - V2 模型结构,其中 3 × 3 与 1 × 1 表示卷积核尺寸,224 × 224 × 3 表示模型输入的规范尺寸,BN 表示 MobileNet 线性瓶颈结构。

2.2.2 分组卷积

为进一步提升模型的效率并减小计算复杂度,引入分组卷积^[29]。其核心思想是将输入特征图在通道维度上进行分组处理,每一组通道独立进行卷积操作,最后将各组的输出进行合并。通过减少卷




图 3 改进后的倒置残差与线性瓶颈单元

Fig.3 Improved inverted residual with linear bottleneck unit




图 4 改进的 MobileNet - V2 模型结构

Fig. 4 Improved MobileNet - V2 model structure

积操作的计算量和参数量,能够在不显著降低性能的情况下,显著提升模型的效率。通过使用 $G = 4$ 的分组卷积,模型能够显著减少参数量和计算量,同时保持较高的模型性能。

分组卷积将输入特征图 X 划分为 G 个组,其中每个组包含 C_{in}/G 个通道。对于每一组,使用尺寸为 $K \times K$ 的卷积核进行卷积操作,最终得到的输出特征图通过逐组拼接的方式合并。假设每个组的输出为 $Y^{(g)}$,则整体输出为

$$Y = \text{Concat}(Y^{(1)}, Y^{(2)}, \dots, Y^{(G)}) \tag{5}$$

其中 $Y^{(g)} = W^{(g)} X^{(g)}$
式中 $Y^{(g)}$ ——第 g 组卷积输出
 $W^{(g)}$ ——第 g 组卷积核

2.2.3 SE 模块

通过调整 SE 模块的插入位置与压缩比,避免对农业图像中噪声干扰的过度响应,同时增强对病害关键特征的敏感性。这一改进在保持 V2 原有优势的同时,有效提升了分类准确率,尤其适用于农业

数据中样本稀缺或类别边界模糊的场景^[30]。

如图 5 (其中 $W、H$ 分别表示输入特征图宽度、高度,FC 为全连接层,ReLU 为激活函数)所示,将 SE 注意力模块集成到 MobileNet - V2 网络的倒置残差结构中,嵌入在深度可分离卷积至 1×1 卷积核之后。SE 模块基本工作流程可分为 3 个主要步骤:特征预处理、生成通道权重以及对特征进行重标定。由图 4 可以看出,整个过程在模型 Layer 3 ~ 17,共 8 个残差块层级上进行嵌入。

首先,输入特征图 X 通过深度可分离卷积进行处理,得到输出 X_{dw} 。在网络的卷积层输出特征图之后,对卷积层输出特征实施全局平均池化,即

$$z_c = \frac{1}{HW} \sum_{h=1}^H \sum_{w=1}^W X_{dw}(c, h, w) \tag{6}$$

式中 z_c ——通道 c 池化后通道统计量
 $X_{dw}(c, h, w)$ ——特征图在通道 c 与空间位置 (h, w) 的像素响应

然后,再使用 2 层全连接层网络学习通道权重,对特征图 X_{dw} 进行通道注意力机制的加权。第 1 层使用 ReLU 作为激活函数,第 2 层通过 Sigmoid 函数将输出权重映射到 $[0, 1]$ 之间。这个过程实际上是通过神经网络动态地学习每个通道的重要性,并根据通道重要性生成相应的权重,即

$$s_c = \sigma_1(M_2 \delta(M_1 z_c)) \tag{7}$$

式中 s_c ——每个通道注意力权重向量
 $M_1、M_2$ ——2 个全连接层权重矩阵
 $\delta、\sigma_1$ ——ReLU 与 Sigmoid 激活函数

最终,生成的权重逐元素相乘,对原始特征图执行逐通道自适应加权处理,并将输入与注意力加权后的特征图进行逐元素残差链接,实现关键特征通道的强调。

通过这种方式嵌入 SE 模块,能够有效增强网络的表达能力,使得模型具有更好的适应性。尤其在轻量级网络 MobileNet - V2 中,SE 模块的嵌入可使模型在保持计算复杂度平稳的同时,显著提升性能。




图 5 SE 模块嵌入倒置残差块

Fig. 5 SE block embedded in inverted residual block

2.2.4 模型轻量化

虽在模型中引入上述改进策略能够提升模型的识别准确率,但也无法避免模型结构网络复杂度的增加。为了提高模型的泛化能力,减少对大量标注数据的依赖,同时加快训练过程并提升识别准确率,采用迁移学习的方法进行模型训练。首先在公开的 ImageNet 数据集上进行预训练,以获取通用的特征表示,然后将预训练模型的参数迁移至目标任务中。在具体实现过程中,冻结了预训练模型的卷积层参数,仅对最后的全连接层进行微调,以适应目标数据集的特性^[31]。

为了消除上采样过程中引发的特征重叠效应,还引入了权重剪枝^[32]。通过分析不同权重的影响力,为每层设定了剪枝阈值,并逐步去除对模型输出贡献较小的权重。对于神经网络中的每个权重 w_i (i 表示神经元索引),通常使用其绝对值来衡量该权重的重要性。为了合理设定每层的剪枝阈值,采用基于权重分布直方图的量化分析方法。通过交叉实验验证不同剪枝比例对模型性能的影响,并选择阈值为 20%,以平衡计算效率与精度表现,获得最佳的剪枝效果。绝对值处于阈值以下的权重视为“贡献较小”,予以剪除。设定阈值 θ 后,剪枝删除所有满足条件的权重。每次剪枝后,通过梯度下降法对剪枝后网络进行微调,恢复精度,即

$$w_{k+1} = w_k - \eta \nabla_w L(w_k)$$

(8)

式中 w_k ——第 k 步权重
 η ——学习率
 $\eta \nabla_w L(w_k)$ ——损失函数在权重上的梯度

3 实验环境与参数

3.1 实验环境

实验在 Windows 11 64 位操作系统上进行,使用 PyTorch 3.8 版本的深度学习框架,并结合 CUDA 10.0,支持 GPU 进行模型高速训练。实验所使用的计算机配备了 AMD Ryzen 7 5800H 处理器,基础频率 3.2 GHz,具有 32 GB DDR4 3 200 MHz 内存,并搭载 NVIDIA RTX 3070 显卡,显存 8 GB,以确保训练过程的高效性和性能。

3.2 模型参数

数据集按比例 7:2:1 划分为训练集、验证集和测试集,用于模型的训练、验证及评估。模型全连接层设定为 6(与识别类别数相同),输入图像尺寸均调整为 224 像素 × 224 像素。批处理大小 (Batch size) 设定为 128,训练 70 轮次后趋于收敛。

表 3 为优化器验证结果(准确率)。通过逐个

优化器的学习率实验对比,模型最终使用识别准确率最高且稳定的 Adam 优化器,初始学习率为 0.1,学习率衰减值为 0.1,权重衰减值为 0.001,动量值为 0.9。

表 3 优化器学习率试验结果

Tab.3 Results of optimizer learning rate experiments

%

优化器	学习率			
	0.000 01	0.000 1	0.001	0.01
Adam	91.6	98.3	99.0	99.0
SGD	38.3	77.6	76.3	98.6
RMSprop	92.3	98.4	98.9	98.7
Adadelta	85.0	39.9	63.7	96.9
Momentum SGD	80.9	95.7	98.4	99.3

4 结果与讨论

4.1 评价指标

选用准确率 (Accuracy)、精确率 (Pricision)、召回率 (Recall)、F1 分数 (F1 score)、参数数量和迭代速度作为评价指标。

4.2 模型训练结果

图 6a 直观揭示了模型训练过程中预测性能的优化轨迹。从图 6a 可看出,模型训练初期的准确率迅速提升,并紧接着逐步稳定提高识别能力。具体来看,随着训练轮次增加,模型的准确率在训练前几轮呈明显上升趋势,表明模型在较短时间内能有效且迅速地捕捉到数据的潜在特征表示。随着训练推进,准确率在约 20 轮时逐渐趋于平稳,进入收敛阶段,并在约 25 轮训练后开始稳定在 98.5% 以上,最终在训练结束时达到 99.1%。结果表明,模型既具备精确识别任务特征的能力,又能保持较高的预测稳定性,展现出了优异的泛化性能,保证了在新数据环境中的自适应调整能力。

此外,模型在整个训练过程中未出现明显振荡,反映了数据集划分的合理性和训练策略的有效性,说明训练过程中模型的学习过程是稳定的。模型的权重剪枝和迁移学习的引入不仅优化了模型的结构,减少了冗余计算,还加强了模型对新数据的适应性,在实际任务中的稳定识别能力有效提升。

为进一步评估模型收敛情况,图 6b 为训练损失 (Training loss) 与验证损失 (Validation loss) 的变化趋势。由图 6b 可以观察到,训练损失与验证损失曲线呈同步递减态势,并最终进入收敛状态。模型训练初期,损失值较高,说明模型尚未学习到有效特征,而随着训练轮次的累积,损失逐步下降,表明了模型网络逐步捕获任务特征的学习动态。训练损失




图 6 改进的 MobileNet-V2 模型训练结果
Fig.6 Training results of improved MobileNet-V2 model

表 4 改进的 MobileNet-V2 模型消融实验
Tab.4 Ablation experiment of improved MobileNet-V2 model

CBAM 模块	SE 模块	分组卷积	准确率/%	平均精确率/ %	平均召回率/ %	F1 分数/ %	参数量	迭代速度/ (次·s ⁻¹)
✓	✓		93.20	92.75	92.15	92.45	4.20 × 10 ⁶	3.22
			97.70	97.60	97.05	97.33	4.57 × 10 ⁶	2.43
			97.30	97.05	96.85	96.95	4.39 × 10 ⁶	2.89
✓	✓	✓	94.10	93.85	93.20	93.53	3.83 × 10 ⁶	3.31
		✓	96.20	96.15	95.85	96.00	4.28 × 10 ⁶	2.74
		✓	99.10	98.90	98.75	98.82	4.06 × 10 ⁶	3.02

注:✓ 表示使用此模块(方法)。

块或 CBAM 模块都能对模型性能产生积极影响。

值得注意的是,当 SE 模块和分组卷积同时应用时,模型准确率达到 99.10%,表明两者结合可发挥更大优势,从而提高模型整体性能。在参数量方面,尽管加入了 SE 模块,模型参数量保持在合理范围,且相较于基准模型和分组卷积模型,二者结合 的模型不仅准确率最高,参数量也得到了有效控制。

在迭代速度方面,采用分组卷积的模型比基准模型更优秀。而引入 SE 模块后,由于其额外的计算操作,迭代速度有所降低。在二者结合后,迭代速度为 3.02 次/s,尽管计算效率有所下降,但与获得的高准确率相比,这一变化是可接受的,尤其是考虑到在实际应用中,准确率提升远远大于推理时间微小增加。

综合各项指标和对比结果,SE 模块和分组卷积

和验证损失之间的差距较小,表明模型未出现明显的过拟合现象,表明模型优化策略有效减少了冗余参数,提升了模型泛化能力^[33]。

后续将进一步阐述优化后模型的优势,并与包括原版 MobileNet-V2 在内的其他主流方法进行对比分析,以验证优化方法的有效性 with 实用性。

4.3 消融实验

为评估 SE 模块和分组卷积对模型性能的影响,进行了消融实验,具体对比了基准模型、单独使用 SE 模块和分组卷积、以及两者结合的模型性能。在模型进一步优化中,还尝试了 CBAM (Convolutional block attention module) 模块的引入,CBAM 模块通过通道注意力机制和空间注意力机制自动聚焦于关键特征。结果如表 4 所示。

由表 4 可看出,SE 模块和分组卷积的引入均有效提高了模型的识别准确率和其他性能指标。单独使用 CBAM 模块也显著提高了模型的准确率,然而,尽管 CBAM 在准确率上有所提升,其参数量相对较高,迭代速度相对较低,导致模型在推理时效率明显下降,对于没有极高精细度要求的农业场景识别不够适配。在基准模型基础上,单独使用 SE 模

的结合在提高模型性能方面表现最为优秀,在后续试验中,将均采用该组合策略进行对比。

4.4 模型对比

4.4.1 对比实验

在相同实验环境下,对比改进的 MobileNet-V2 模型与多个经典卷积神经网络,包括原 MobileNet-V2^[24]、ResNet50^[34]、VGG16^[35]和 Xception^[36],以评价不同模型在图像分类任务中的能力与性能。通过实验验证,进一步分析优化模型在特定应用场景下的有效性。图 7 为模型的识别准确率曲线,表 5 展示了各模型的详细实验数据结果。

通过与 MobileNet-V2、ResNet50、VGG16 和 Xception 等模型进行性能对比(尤其与 MobileNet-V2 对比),改进的 MobileNet-V2 在多个关键性能指标上展现出显著优势。从准确率来看,改进的




图 7 各模型识别准确率迭代曲线

Fig.7 Iterative curves of recognition accuracy for each model

表 5 各模型对比实验结果

Tab.5 Comparative experimental results of each model

模型	准确率/%	平均精确率/%	平均召回率/%	F1 分数/%	参数量	迭代速度/ (次·s ⁻¹)
改进的 MobileNet - V2	99.10	98.90	98.75	98.82	4.06 × 10 ⁶	3.02
MobileNet - V2	93.20	92.75	92.15	92.45	4.20 × 10 ⁶	3.22
ResNet50	94.50	93.80	93.10	93.45	2.35 × 10 ⁷	1.83
VGG16	89.70	89.35	88.90	89.12	1.39 × 10 ⁸	1.07
Xception	95.10	94.60	94.35	94.48	1.98 × 10 ⁷	2.47

精度,从而使得改进的 MobileNet - V2 在实际应用中更具优势,特别是在计算资源受限环境中。与 VGG16 的高参数量相比,改进的 MobileNet - V2 具有更高的效率和灵活性。

4.4.2 混淆矩阵

混淆矩阵不仅能帮助识别出模型的强项,还能揭示模型的不足之处,从而为后续的优化提供指

导^[37]。为更全面地展示改进的 MobileNet - V2 模型在苹果叶片病虫害图像分类任务中的卓越性能,各模型识别混淆矩阵如图 8 所示,其中 BR 表示黑腐病、BS 表示褐斑病、H 表示健康叶片、MS 表示花叶病、RS 表示锈病、SC 表示黑星病。

从图 8 可看出,模型在特征提取方面有着良好表现,捕捉到各类病虫害关键特征,并在分类上取得




图 8 各模型识别混淆矩阵对比

Fig.8 Comparison of confusion matrices for various model recognitions

较高的准确性。特别是在引入 SE 模块和分组卷积后,模型整体表现得到了显著提升,这种组合策略在提高分类准确率和模型效率方面的优势尤为突出。基于这些观察,未来将继续使用这一优化方案进一步对比验证。

综合来看,改进的 MobileNet - V2 保证了轻量化与高效性能。在保证高准确率的同时,优化了模型的复杂度,使得在计算资源有限的条件下,依然能够进行高效的叶片病害识别任务。因此,本文模型在实际应用中,尤其是在资源的受限环境下,具有足够的应用潜力。

4.5 模型检验

4.5.1 模型部署

为了检验模型实际应用识别效果,将训练好的模型封装部署于一个图形用户界面程序,使用者能够自由选取待检测图像,便捷地进行病害检测。模型部署不仅提高了模型的易用性,还大大降低了用户的操作复杂性,确保了模型能够在不同环境中被广泛应用。

程序设计架构如图 9a 所示,展示了整个流程的基本框架和各模块之间的交互关系。




图 9 模型部署与程序设计

Fig. 9 Model deployment and program design

选择 1 幅花叶病的叶片病害图像进行检测,图 9b 为程序识别结果显示界面。由图 9b 可看到,改进的模型成功被调用,输出准确的病害类别,用时仅 507 ms,在实时检测中是可接受的。

4.5.2 模型泛化能力

为进一步检验模型识别与泛化能力,从公开数据集上搜集了与本研究数据集不同的健康叶片、黑腐病、褐斑病图像各 100 幅,3 种病害图像准确率、精确率与召回率结果如表 6 所示。结果表明,改进的模型不仅能够有效识别本研究数据集中的苹果叶片病虫害图像,而且在面对与训练数据来源不同、具有一定差异性的公开数据集时,依然能够保持分类性能。

表 6 模型泛化能力评估

Tab. 6 Model generalization ability evaluation %			
参数	健康叶片	黑腐病	褐斑病
准确率	98.90	98.30	99.60
精确率	98.55	97.90	99.15
召回率	98.10	97.45	98.80

5 结论

(1) 针对苹果叶片病害识别问题,提出了一种改进的 MobileNet - V2 卷积神经网络模型,模型通过引入 SE 模块和分组卷积,优化计算效率和特征提取能力,改进的模型准确率提升 5.9 个百分点,F1 分数提升 6.4 个百分点。

(2) 模型采用迁移学习和权重剪枝策略,在较少训练数据下准确率达到 99.1%,而权重剪枝有效减少了模型参数量,仅为 4.06×10^6 ,提升了运行效率。

(3) 改进的模型不仅在本研究所使用数据集上表现出色,还在外部数据集上展现出较好的识别准确性,证明了其在面对不同数据源时依然能够保持泛化能力。在资源受限农业环境下,改进的模型具备较高应用潜力,能够为其他农作物病害检测研究以及轻量化、便携式检测设备提供相关参考。

参 考 文 献

[1] SCHNEIDER U A, HAVLÍK P, SCHMID E, et al. Impacts of population growth, economic development, and technical change on global food production and consumption[J]. Agricultural Systems, 2011, 104(2): 204 - 215.

[2] 门小鹏, 许雪峰, 王玉斌, 等. 我国苹果生产的现状、问题与发展对策[J]. 农村实用技术, 2022(1): 25 - 27, 59.

[3] ADEEL A, KHAN M A, AKRAM T, et al. Entropy-controlled deep features selection framework for grape leaf diseases recognition[J]. Expert Systems, 2022, 39(7): e12569.

[4] HASAN R I, YUSUF S M, RAHIM M S M, et al. Automatic clustering and classification of coffee leaf diseases based on an extended kernel density estimation approach[J]. Plants-Basel, 2023, 12(8): 1603.

[5] LI Z B, GUO R H, LI M, et al. A review of computer vision technologies for plant phenotyping[J]. Computers and Electronics in Agriculture, 2020, 176: 105672.

[6] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2014: 580 - 587.

[7] ATTRI I, AWASTHI L K, SHARMA T P, et al. A review of deep learning techniques used in agriculture[J]. *Ecological Informatics*, 2023, 77: 102217.

[8] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[J]. *arXiv:1704.04861*, 2017.

[9] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]// *Advances in Neural Information Processing Systems 25 (NIPS 2012)*, 2012: 1097 – 1105.

[10] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]// *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2015: 1 – 9.

[11] DANIYA T, VIGNESHWARI S. A novel Moore-Penrose pseudo-inverse weight-based deep convolution neural network for bacterial leaf blight disease detection system in rice plant[J]. *Advances in Engineering Software*, 2022, 174: 103363.

[12] THAKUR P S, SHEOREY T, OJHA A. VGG – ICNN: a lightweight CNN model for crop disease identification[J]. *Multimedia Tools and Applications*, 2023, 82(1): 497 – 520.

[13] KRISHNAMOORTHY N, PRASAD L V N, KUMAR C S P, et al. Rice leaf diseases prediction using deep neural networks with transfer learning[J]. *Environmental Research*, 2021, 198: 111275.

[14] WEI J P, AS'ARRY A, REZALI K A M, et al. A review of YOLO algorithm and its applications in autonomous driving object detection[J]. *IEEE Access*, 2025, 13: 93688 – 93711.

[15] YANG S X, ZHANG L C, LIN J W, et al. LSGNet: a lightweight convolutional neural network model for tomato disease identification[J]. *Crop Protection*, 2024, 182: 106715.

[16] 张帅杰, 陈思思, 戴丹, 等. 基于密集卷积网络的甘薯黑斑病害程度分类[J]. *中国农业大学学报*, 2025, 30(4): 51 – 66.

[17] ZHANG Shuaijie, CHEN Sisi, DAI Dan, et al. Classification of sweet potato black spot disease severity using dense convolutional networks[J]. *Journal of China Agricultural University*, 2025, 30(4): 51 – 66. (in Chinese)

[17] LI X P, ZHANG Y C, PENG Y H, et al. VLDNet: an ultra-lightweight crop disease identification network[J]. *Agriculture-Basel*, 2023, 13(8): 1482.

[18] ZHU D J, TAN J B, WU C, et al. Crop disease identification by fusing multiscale convolution and vision transformer[J]. *Sensors*, 2023, 23(13): 6015.

[19] TONMOY M R, HOSSAIN M M, DEY N, et al. MobilePlantViT: a mobile-friendly hybrid ViT for generalized plant disease image classification[J]. *arXiv Preprint, arXiv:2503.16628*, 2025.

[20] MOHANTY S P, HUGHES D P, SALATHÉ M. Using deep learning for image-based plant disease detection[J]. *Frontiers in Plant Science*, 2016, 7: 215232.

[21] LIANG X F, ZHANG R, GLEASON M L, et al. Sustainable apple disease management in China: challenges and future directions for a transforming industry[J]. *Plant Disease*, 2022, 106(3): 786 – 799.

[22] QI C, SANDRONI M, WESTERGAARD J C, et al. In-field classification of the asymptomatic biotrophic phase of potato late blight based on deep learning and proximal hyperspectral imaging[J]. *Computers and Electronics in Agriculture*, 2023, 205: 107585.

[23] LIU B, DING Z, ZHANG Y, et al. Kiwifruit leaf disease identification using improved deep convolutional neural networks[C]// *2020 IEEE 44th Annual Computers, Software, and Applications Conference (COMPSAC)*. IEEE, 2020: 1267 – 1272.

[24] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]// *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2018: 4510 – 4520.

[25] BARMAN U, CHOUDHURY R D, SAHU D, et al. Comparison of convolution neural networks for smartphone image based real time classification of citrus leaf disease[J]. *Computers and Electronics in Agriculture*, 2020, 177: 105661.

[26] SRINIVASU P N, SIVASAI J G, IJAZ M F, et al. Classification of skin disease using deep learning neural networks with MobileNet V2 and LSTM[J]. *Sensors*, 2021, 21(8): 2852.

[27] PENG H X, XU H M, SHEN G J, et al. A lightweight crop pest classification method based on improved MobileNet – V2 model[J]. *Agronomy-Basel*, 2024, 14(6): 1310.

[28] MAICAN E, IOSIF A, MAICAN S. Precision corn pest detection: two-step transfer learning for beetles (coleoptera) with MobileNet – SSD[J]. *Agriculture-Basel*, 2023, 13(12): 2309.

[29] LEE Y, PARK J, LEE C O. Two-level group convolution[J]. *Neural Networks*, 2022, 154: 323 – 332.

[30] NOBI M M U, RIFAT M, MRIDHA M F, et al. GLD – Det: guava leaf disease detection in real-time using lightweight deep learning approach based on MobileNet[J]. *Agronomy-Basel*, 2023, 13(9): 2314.

[31] QIAN Q, QIN Y, LUO J, et al. Deep discriminative transfer learning network for cross-machine fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2023, 186: 109863.

[32] ZIV Y, GOLDBERGER J, RAVIV T R. Stochastic weight pruning and the role of regularization in shaping network structure[J]. *Neurocomputing*, 2021, 462: 555 – 567.

[33] LIANG C, ZHANG H X, YUAN D F, et al. A novel CNN training framework: loss transferring[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2020, 30(12): 4611 – 4625.

[34] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2016: 770 – 778.

[35] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. *arXiv Preprint, arXiv: 1409.1556*, 2014.

[36] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]// *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2017: 1251 – 1258.

[37] FAWCETT T. An introduction to ROC analysis[J]. *Pattern Recognition Letters*, 2006, 27(8): 861 – 874.