

刘 虎,霍欣浩,何琴英,等. 基于改进 MobileNet v3Small 的花生叶部病害轻量化识别研究[J]. 江苏农业科学,2025,53(12):207-215.  
doi:10.15889/j.issn.1002-1302.2025.12.029

# 基于改进 MobileNet v3Small 的花生叶部病害 轻量化识别研究

刘 虎,霍欣浩,何琴英,张泽豪,张道德

(湖北工业大学/湖北省农业机械工程研究设计院,湖北武汉 430068)

**摘要:**为了对花生叶部病害进行正确的诊断与有效的治疗来提高花生的产量,使用深度学习进行及时的轻量化识别与检测,在 MobileNet v3Small 模型的基础上提出一种新的改进方法,即使用 SimAM 注意力机制替换原模型中的 SE 注意力机制,并使用迁移学习对花生叶部病害进行轻量化识别;然后将 PlantVillage 数据集作为源域进行预训练,并将预训练得到的共享参数迁移到改进的模型上进行微调优化,最终将采集到的花生叶部病害数据集作为目标域进行试验测试。试验结果表明,通过迁移学习,改进后的 MobileNet v3Small 模型识别准确率达到 99.5%,比原模型提高 2.25 个百分点,参数量减少 30.07%,内存减少 2.33 MB。使用 Grad-CAM 完成热力图可视化,对比发现,SimAM 注意力机制比原 SE 注意力机制以及其他 2 种注意力机制生成的热力图和原图像中病斑的位置、颜色相似度更高,表明本研究所用方法可以更好地采集花生叶部病害的特征。从各个评价指标来看,本研究提出的方法在花生叶部病害识别上适配度更高、更轻量化,可以更好地在真实场景下进行花生叶部病害识别,可为花生生产种植上提供有效帮助,助力发展智慧农业。

**关键词:**花生叶部病害;迁移学习;轻量化卷积神经网络;SimAM 注意力机制

**中图分类号:**S126;TP391.41 **文献标志码:**A **文章编号:**1002-1302(2025)12-0207-09

花生是我国重要的农作物和油料来源,属豆科草本植物,在全世界范围内被广泛种植。我国花生的种植地区较多,总面积达 465 万  $\text{hm}^2$ ,总产量位居世界第一,在我国农业产业结构中占有重要地位<sup>[1]</sup>。花生叶部病害会严重影响花生的产量和质量,其中以叶斑病为主。据调查,我国花生叶部病害主要有褐斑病<sup>[2]</sup>、黑斑病、网斑病、焦斑病、锈病、炭疽病等,其中褐斑病、黑斑病、网斑病、焦斑病较为严重<sup>[3]</sup>。

花生叶部病害属于植物病害表型。植物表型是指植物的外形特征,受自身基因和环境影响,决定农作物的产量。传统的植物表型研究过于依靠人工观察、测量以及专家的经验判断,效率较低<sup>[4-5]</sup>。较为传统的机器学习又严重依赖特征提取,普遍适应性较差。深度学习是近年来图像识别领域重要的技术手段,利用深度学习技术对花生叶部病害图像进行识别,可以更有效地对表型数据进

行分类和识别。

轻量化神经网络<sup>[6-8]</sup>识别方法能够快速、准确地识别花生叶部病害。常见的轻量化神经网络模型有 SqueezeNet<sup>[9]</sup>、MobileNet<sup>[10]</sup>、EfficientNet<sup>[11]</sup>等。本研究选择的网络是 MobileNet 系列中的 MobileNet v3Small 模型,MobileNet v3<sup>[12]</sup>是一种效率高的轻量化卷积神经网络,该模型结合了 MobileNet v1 和 MobileNet v2 模型的优势,并进一步提高了模型的精度。MobileNet v3 模型有 2 种模式,分别是 Large 和 Small,它们的整体结构一致,区别在于基本单元 bottleneck 的数量以及内部参数设置,Small 版本适用于移动设备等资源受限的场景,因此本研究选用 MobileNet v3Small 模型。

本研究提出一种用于花生叶部病害识别和检测的轻量化卷积神经网络 MobileNet v3Small-SAM,该网络在 MobileNet v3Small 模型的基础上使用 SimAM(SAM)注意力机制进行改进,以提高识别精度,减少参数量和计算量,使其适合在资源受限的设备上应用。此外,使用迁移学习将 PlantVillage 数据集上预训练的特征及参数迁移到该网络中,以便于在花生叶部病害数据集上进行识别和检测。

收稿日期:2024-05-07

基金项目:湖北省农机装备补短板项目(编号:HBSNYT202220)。

作者简介:刘 虎(1986—),男,湖北荆州人,博士,讲师,主要研究方向为智能农机装备研发。E-mail:liuhumaster@163.com。

# 1 基于 MobileNet v3Small - SAM 的花生叶部病害识别系统框架及实现

## 1.1 系统框架

MobileNet v3Small - SAM 模型主要通过使用 SimAM 注意力机制替换原有的 SE 注意力机制来提高模型的性能,具体来说,重新定义 1 个新的卷积块,基于 MobileNet v3Small 中的原始结构,将其中的 SE 模块替换为 SimAM 模块。与 SE 注意力机制相比,SimAM 注意力机制不涉及压缩和激励操作,具

体来说,SimAM 模块的加入无需向原始模型网络添加参数,而是推断特征图的 3D 注意力权重,这样没有额外的参数加入网络,不会增加网络的复杂度,从而使结构更加轻量化。图 1 为本研究所搭建的 MobileNet v3Small - SAM 花生叶部病害识别整体结构,其中实线框部分为使用 SAM 注意力机制改进后的 Bottleneck 结构,该模型的主要创新点在于使用 SAM 注意力机制取代 SE 注意力机制,无需向原始模型网络添加参数,可以减少参数量,降低模型复杂度,进一步提高模型的泛用性。

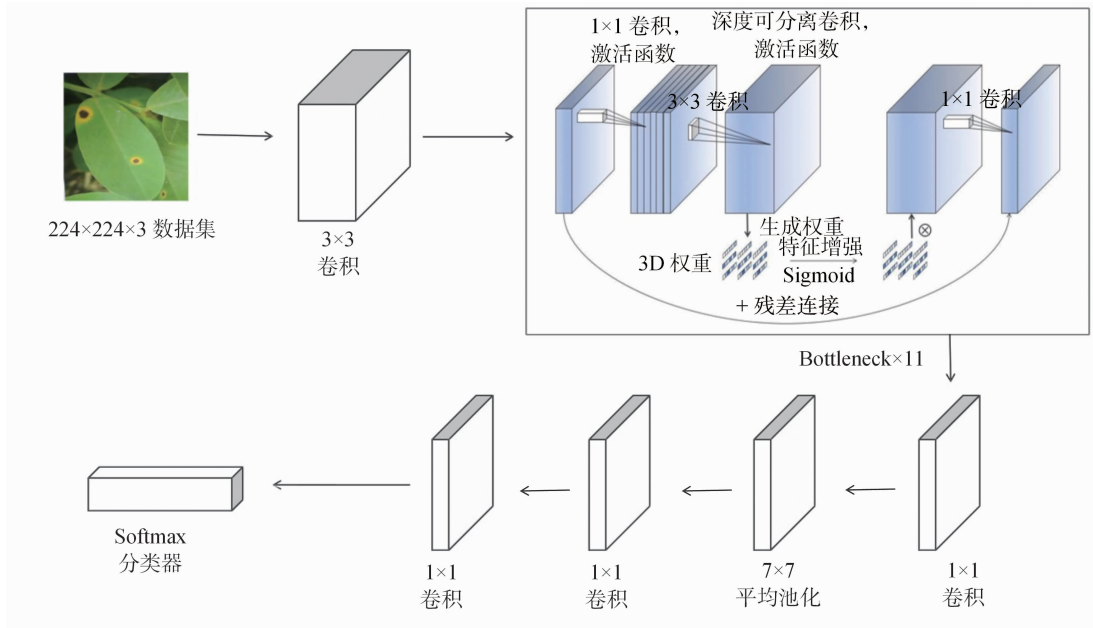


图1 MobileNet v3Small-SAM 的整体结构

## 1.2 MobileNet v3Small

MobileNet v3Small 是 MobileNet v3 的较小版本,适用于要求更低计算成本和内存占用的场景,通过精心设计的网络结构和轻量化的神经网络层,可以更快、更高效地进行图像分类和目标检测。

1.2.1 MobileNet v3Small 网络结构 由表 1 可知, MobileNet v3Small 模型的网络结构分为 3 部分,其中第 1 部分包括 1 个  $3 \times 3$  的卷积层和 1 个批归一化层,用于特征提取和标准化处理;第 2 部分由 11 个深度可分离卷积层和 1 个逐点卷积层组成,实现特征扩展和提取,并有效减少参数和计算量;第 3 部分包含 1 个平均池化层和 2 个全连接层,用于进一步压缩特征并映射到输出类别,同时计算分类概率。MobileNet v3Small 模型的设计注重在移动设备和嵌入式设备上的执行效率,采用深度可分离卷积和逐点卷积等技术,实现了高效的特征提取和分类。

表 1 MobileNet v3Small 特征提取网络的参数

| 参数         | 输入尺寸                       | 输出尺寸                             |
|------------|----------------------------|----------------------------------|
| Input      | —                          | $224 \times 224 \times 3$        |
| Conv       | $224 \times 224 \times 3$  | $112 \times 112 \times 16$       |
| Bottleneck | $112 \times 112 \times 16$ | $56 \times 56 \times 16$         |
| Bottleneck | $56 \times 56 \times 16$   | $28 \times 28 \times 24$         |
| Bottleneck | $28 \times 28 \times 24$   | $28 \times 28 \times 24$         |
| Bottleneck | $28 \times 28 \times 24$   | $14 \times 14 \times 40$         |
| Bottleneck | $14 \times 14 \times 40$   | $14 \times 14 \times 40$         |
| Bottleneck | $14 \times 14 \times 40$   | $14 \times 14 \times 40$         |
| Bottleneck | $14 \times 14 \times 40$   | $14 \times 14 \times 48$         |
| Bottleneck | $14 \times 14 \times 48$   | $14 \times 14 \times 48$         |
| Bottleneck | $14 \times 14 \times 48$   | $7 \times 7 \times 96$           |
| Bottleneck | $7 \times 7 \times 96$     | $7 \times 7 \times 96$           |
| Bottleneck | $7 \times 7 \times 96$     | $7 \times 7 \times 96$           |
| Conv       | $7 \times 7 \times 96$     | $7 \times 7 \times 576$          |
| Pool       | $7 \times 7 \times 576$    | $1 \times 1 \times 576$          |
| Conv       | $1 \times 1 \times 576$    | $1 \times 1 \times 576$          |
| Conv       | $1 \times 1 \times 576$    | $1 \times 1 \times 1 \times 024$ |

1.2.2 Bottleneck 结构 MobileNet v3Small 的核心在于 Bottleneck 层,由图 2 可知,Bottleneck 层的主要结构为深度可分离卷积、SE 注意力机制模块和残差连接。深度可分离卷积利用 DepthwiseConv2D 和 Conv2D 对特征图的每个通道进行轻量化过滤器卷

积和融合操作,可显著减少参数量,使网络模型更轻量化。SE 注意力机制模块通过压缩特征图的空间维度和激励全局描述符,自适应地调整每个特征通道的权重,提高模型的性能和泛化能力,嵌入到 Bottleneck 层,以增强表征能力。




图2 Bottleneck 的结构

残差连接通过将某些层的输入直接添加到较深层的输出中,促进梯度的反向传播,减轻梯度消失和爆炸问题,Bottleneck 层中的残差连接提高了训练速度和稳定性,同时保留了重要信息。

由此可知,Bottleneck 层中的深度可分离卷积、SE 注意力机制模块、残差连接主要在于提高模型的代表能力、感受野和稳定性。

### 1.3 注意力机制改进

SimAM 是一种轻量化的自注意力机制,与现有的通道和空间注意力模块相比,通过特征层中的特征映射推断 3D 注意力权重(即考虑空间和通道维度),而不在原始网络中添加参数<sup>[13-15]</sup>。对比 SE

结构,SAM 模块结合了通道和空间维度,避免了压缩和激励操作,不另外产生参数,可减少内存占用,从而更加轻量化。由图 3 可知,SE 结构包含压缩和激励 2 个操作。

由图 4 可知,SimAM 的网络结构与 Transformer 类似,但是在计算注意力权重时使用的是线性层而不是点积,可以将其中任何一个中间特征张量作为输入,转化输出为相同大小,含有增强表征作用的特征张量。SimAM 模块主要用于增强 MobileNet v3Small 网络的特征表示能力,并减少参数量,增加轻量化。

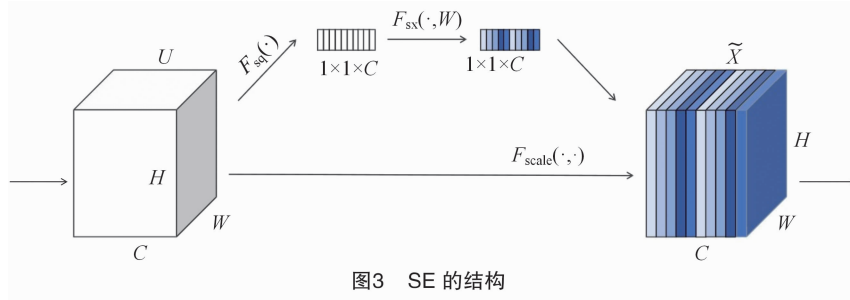


图3 SE 的结构

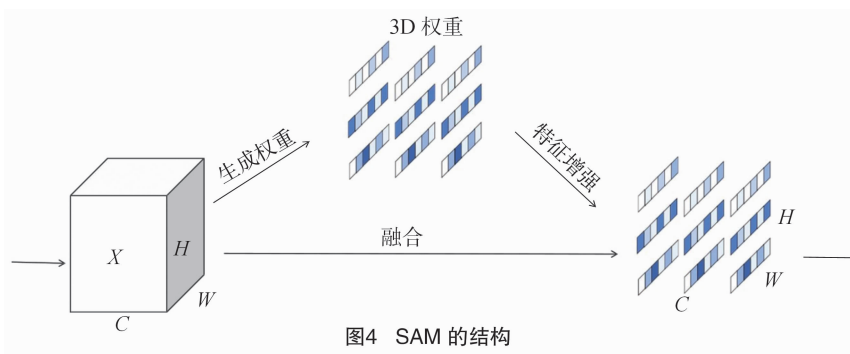


图4 SAM 的结构

SimAM 模块在神经科学理论的基础上,提出一个统一权重注意力模块,使每个神经元被分配 1 个唯一权重<sup>[16]</sup>,然后评估神经元的重要性,以便于实现更好的注意力性能。统一权重注意力模块包括空域抑制,即激活的神经元会抑制其他神经元活动,可通过计算目标神经元与其他神经元之间的线性可分度来发现具有空域抑制效应的重要神经元。根据这种神经科学研究方法,为这些神经元确定能量函数。简单起见,采用二值标签,并添加正则项,定义能量函数,最终公式如下:

$$e_i(w_i, b_i, y, x_i) = \frac{1}{M-1} \sum_{i=1}^{M-1} [-1 - (w_i x_i + b_i)]^2 + [1 - (w_i t + b_i)]^2 + \lambda w_i^2.$$

式中: $w_i$  为目标神经元变换时的权重; $b_i$  为目标神经元变换时的偏置参数; $t$  为特征张量  $X$  的目标神经元,  $X = \in R^{C \times H \times W}$ ,  $C, H, W$  分别为特征张量  $X$  的通道数、高度和宽度; $x_i$  为特征张量  $X$  的其他神经元; $i$  为通道神经元索引; $M$  为每个通道神经元个数,  $M = H \times W$ ;  $\lambda$  为正则项。

上述公式具有如下解析解:

$$w_i = -\frac{2(t - u_i)}{(t - u_i)^2 + 2\sigma_i^2 + 2\lambda};$$

$$b_i = -\frac{1}{2}(t + u_i)w_i.$$

$$\text{式中: } u_i = \frac{1}{M-1} \sum_{i=1}^{M-1} x_i; \sigma_i^2 = \frac{1}{M-1} \sum_{i=1}^{M-1} (x_i - u_i)^2.$$

因此,最小能量可以通过如下公式得到:

$$e_i^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t - \hat{u})^2 + 2\hat{\sigma}^2 + 2\lambda}.$$

$$\text{式中: } \hat{u} = \frac{1}{M} \sum_{i=1}^M x_i; \hat{\sigma}^2 = \frac{1}{M} \sum_{i=1}^M (x_i - \hat{u})^2.$$

神经元的重要性随着花生叶部病害特征图目标神经元与周围神经元差异性的增加而增加。因此,神经元的权重可以通过  $\frac{1}{e_i^*}$  得到。按照注意力机制的定义,需要对特征进行增强处理,具体为

$$\tilde{X} = \text{sigmoid}\left(\frac{1}{E}\right) \otimes X.$$

式中: $E$  为花生叶部病害图像特征图的所有神经元集合;  $\otimes$  为 Hadamard 乘积;  $X$  为特征图的特征张量。

#### 1.4 迁移学习

本研究使用 MobileNet v3Small - SAM 模型进行迁移学习<sup>[17-19]</sup>,并将其应用于花生叶部病害图像的

识别。PlantVillage 数据集与花生叶部病害数据集相似,因此本研究选用该数据集,并通过数据增强处理提高模型训练效果,然后通过迁移学习来识别花生叶部病害。

图 5 为花生叶部病害迁移学习示意,本研究利用 PlantVillage 数据集作为预训练的源域,将模型权重等内容转移至针对花生叶部病害数据集的改进模型上,借助先验知识,有效地处理相应的识别任务。在花生叶部病害图像的训练过程中,对模型参数进行微调,以获得最终的花生叶部病害识别模型。对花生叶部病害数据集进行训练计算,将收集到的数据导入分类器,并对病害类型进行预测。最后,通过将网络数据转换为适用于花生叶部病害分类任务的 4 种输出,实现对花生叶部病害的精确检测。

## 2 试验设计

### 2.1 试验环境

硬件环境为 Intel® Core™ i5 - 13400F CPU @ 2.50 GHz; 内存 32 GB; GeForce RTX4060 GPU 8 GB。软件环境为 Windows 10 操作系统、Python 3.9、Anaconda 3.0、opencv - python 4.8.1.78、torch 2.1.1 + cu118。在实现模型的搭建和训练过程中选择批次大小为 64,学习率初始值设为 0.001,优化器为 Adam,训练轮数为 100,试验于 2023 年 11 月份在湖北工业大学实验室进行。

### 2.2 数据集

本研究使用的 4 类花生叶部病害数据集采集于河南省光山县多户农户种植花生的花生地,在病斑或纹理特征上有明显的区别,包括斑点颜色、形状、布局等方面。选择这 4 类花生叶部病害作为研究对象是因为它们对花生产量造成的损失较大,同时也是普遍发生且较为严重的叶部病。研究这些病害有助于改进病害防治策略,保障花生的生长。该花生叶部病害数据集包含 800 幅数字图像,其中包括褐斑病、黑斑病、网斑病和焦斑病。表 2 是花生叶部病害图像数据集信息,按照 9 : 1 划分为训练集、测试集,图像数量分别为 720、80 幅。

图 6 为花生叶部病害数据集中不同病害的示例。

迁移学习数据集是从 PlantVillage 数据集中选取的 10 类数据。PlantVillage 数据集包含来自世界各地的数万幅农作物图像,其中包括多种常见作

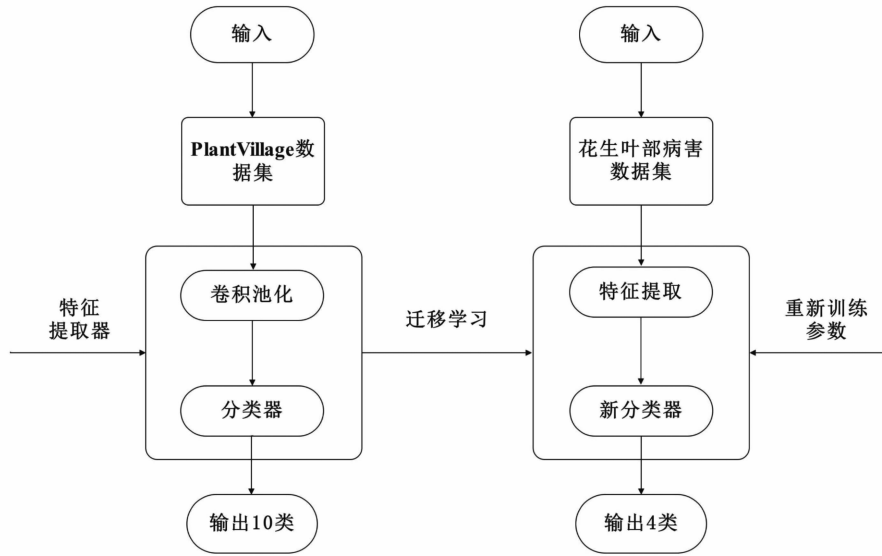


图5 花生叶部病害迁移学习示意

表 2 花生叶部病害图像数据集分布

| 序号 | 病害名称 | 训练集 (幅) | 测试集 (幅) |
|----|------|---------|---------|
| 1  | 褐斑病  | 180     | 20      |
| 2  | 黑斑病  | 180     | 20      |
| 3  | 焦斑病  | 180     | 20      |
| 4  | 网斑病  | 180     | 20      |

表 3 PlantVillage 图像数据集样本分布

| 序号 | 病害名称   | 训练集 (幅) | 测试集 (幅) |
|----|--------|---------|---------|
| 1  | 苹果疮痂病  | 900     | 100     |
| 2  | 苹果黑腐病  | 900     | 100     |
| 3  | 苹果桧胶锈病 | 900     | 100     |
| 4  | 苹果健康   | 900     | 100     |
| 5  | 蓝莓健康   | 900     | 100     |
| 6  | 马铃薯早疫病 | 900     | 100     |
| 7  | 马铃薯健康  | 900     | 100     |
| 8  | 马铃薯晚疫病 | 900     | 100     |
| 9  | 草莓健康   | 900     | 100     |
| 10 | 草莓叶焦病  | 999     | 110     |




图6 花生叶片数据集病害示例

物,如苹果、水稻、小麦、马铃薯、草莓等以及这些作物所患的多种疾病。表3为试验所用到的10类图像以及数量。数据集共有10109幅图片,按照9:1划分为训练集、测试集,图片数量分别9099、1010幅。

图7为PlantVillage数据集中10种不同类别的示例。

### 2.3 性能评估指标

本研究选择准确率、精确率、召回率和  $F_1$  分数作为评价指标。对于分类评价指标来说,准确率用于评估预测正确的比例,精确率用于评估预测正例的查准率,召回率用于评估真正例的查全率,数值越趋近1越能表示模型的优越性。

## 3 试验结果与分析

### 3.1 训练集和测试集实验结果

图8为非迁移学习下,4种网络在花生叶部病害表型训练集上测试的交叉熵损失函数曲线。本研究所用方法 MobileNet v3Small - SAM 的损失值下降迅速且平滑稳定,第1轮(训练轮数为1)到第20轮损失值快速下降,第20轮后开始缓慢下降,最终稳定在0.06左右。MobileNet v3Small 网络的损失



图7 PlantVillage 迁移学习数据集示例

值下降比较平缓,慢于其他网络模型。MobileNet v3Small - CBAM 网络损失值下降速度与本研究所用方法基本一致,训练第 20 轮后逐渐趋于平稳,偶有细微波动。MobileNet v3Small - ECA 的损失值呈现 3 种趋势,从训练第 1 轮到第 20 轮迅速下降,第 20 轮到第 40 轮下降平缓,第 40 轮后逐渐平稳。在训练集上跑的 4 种神经网络模型中,本研究所用方法表现最好,整体上比其他 3 个网络模型下降效果明显且平稳;其次是 MobileNet v3Small - CBAM 网络,最差是 MobileNet v3Small。




图8 非迁移学习网络在训练集上的损失值变化曲线

图 9 为迁移学习后,4 种网络模型在训练集上的损失值,本研究所用方法 MobileNet v3Small - SAM、MobileNet v3Small - CBAM 和 MobileNet v3Small - ECA 模型几乎存在一样的下降趋势,在训练轮数为 10 后损失值下降趋势开始趋于平滑且逐渐稳定,而 MobileNet v3Small 的损失值在训练轮数为 20 后才开始平稳下来。

对比图 8 和图 9 可知,网络模型通过迁移学习学习到了很好的特征点,使损失值下降速度更快、更平滑稳定。

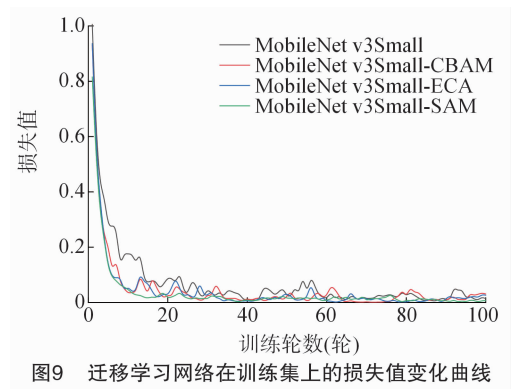


图9 迁移学习网络在训练集上的损失值变化曲线

图 10 为非迁移学习下,4 种网络在测试集上的准确率曲线,本研究所用方法 MobileNet v3Small - SAM、MobileNet v3Small - CBAM 和 MobileNet v3Small - ECA 模型准确率变化趋势几乎一样,在训练第 1 轮(训练轮数为 1)到第 30 轮之间快速上升,第 30 轮后趋于稳定。最后阶段本研究所用方法的准确率略高,为 97% 左右,但不够平稳,具有细微波动。MobileNet v3Small 的准确率上升缓慢,同时准确率也最低,最后阶段为 95% 左右。




图10 非迁移学习网络在测试集上的准确率曲线

图 11 为迁移学习后,4 种网络在测试集上的准确率曲线,4 种网络模型的准确率上升趋势大致相同,其中 MobileNet v3Small - SAM 的准确率一直保持最高,最后阶段为 99.5% 左右,而且上升速度最快且平稳;而 MobileNet v3Small - CBAM 模型的准确率上升速率相对比较缓慢,但仍具有较高的准确率,最后稳定在 98%。

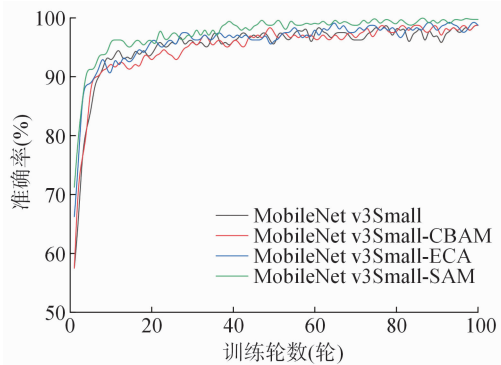


图 11 迁移学习网络在测试集上的准确率曲线

对比图 10 和图 11 可知,迁移学习可以大幅度提高模型的学习能力以及学习速率,进一步提高模型的适配度。

### 3.2 结果对比

在深度学习模型的设计中,参数量和模型内存占用量都是非常重要的指标。模型参数量的增加,会增大模型的存储空间和计算复杂度,从而降低模型的实际应用价值。因此,设计一个参数量少、模型内存占用量小、性能表现良好的模型是非常有必要的。对比表 4 列出的 4 个模型可以发现,本研究所用方法 MobileNet v3Small - SAM 在保证性能的情况下,比原模型减少约 30.07% 的参数量和 2.33 MB 的内存大小。这意味着在进行花生叶部病害识别时,可以通过更少的存储空间来运行模型,同时与另外 2 种模型相比,参数量和内存大小都是最小的,表明 MobileNet v3Small - SAM 是一个在参数量和模型内存占用量 2 个方面都具有一定优势的模型。

表 4 模型参数量以及模型大小对比

| 模型                       | 参数量       | 内存大小 (MB) |
|--------------------------|-----------|-----------|
| MobileNet v3Small - SAM  | 1 060 316 | 42.69     |
| MobileNet v3Small        | 1 516 338 | 45.02     |
| MobileNet v3Small - CBAM | 1 216 711 | 44.47     |
| MobileNet v3Small - ECA  | 1 060 343 | 43.28     |

表 5 主要列出在非迁移学习下,本研究所用方法 MobileNet v3Small - SAM 以及 MobileNet v3Small、MobileNet v3Small - CBAM 和 MobileNet v3Small - ECA 模型在测试集上的分类评价指标。从表 5 中可以看出,本研究所用方法在精确率、召回率和  $F_1$  分数上均优于其他 3 种模型,表现最好。

表 5 非迁移学习下分类评价指标

| 模型                       | 精确率 (%) | 召回率 (%) | $F_1$ 分数 (%) |
|--------------------------|---------|---------|--------------|
| MobileNet v3Small - SAM  | 66.96   | 97.50   | 79.38        |
| MobileNet v3Small        | 64.46   | 95.00   | 76.97        |
| MobileNet v3Small - CBAM | 65.00   | 96.25   | 77.61        |
| MobileNet v3Small - ECA  | 65.81   | 96.25   | 78.00        |

本研究所用方法在测试集上比 MobileNet v3Small 模型精确率、召回率、 $F_1$  分数上分别提升 2.50、2.50、2.41 个百分点。在 4 个模型中,MobileNet v3Small 各项评价指标均最低,但也具有较好的分类能力。另外 2 种模型各项评价指标基本一致,有细微的差距。

表 6 主要列出在迁移学习下,本研究所用方法以及另外 3 种模型在测试集上的各项评价指标。从表中对比看出,本研究所用方法在精确率、召回率、 $F_1$  分数上都高于其他 3 种模型,具有最好的表现。

表 6 迁移学习下分类评价指标

| 模型                       | 精确率 (%) | 召回率 (%) | $F_1$ 分数 (%) |
|--------------------------|---------|---------|--------------|
| MobileNet v3Small - SAM  | 67.52   | 99.75   | 80.20        |
| MobileNet v3Small        | 65.00   | 97.50   | 78.00        |
| MobileNet v3Small - CBAM | 66.38   | 98.75   | 79.40        |
| MobileNet v3Small - ECA  | 66.94   | 98.75   | 79.80        |

本研究所用方法比原始模型 MobileNet v3Small 在精确率、召回率、 $F_1$  分数上分别提升 2.52、2.25、2.20 百分点。

对比表 5 和表 6 可得,本研究所用方法通过迁移学习比非迁移学习在测试集上的评价指标精确率、召回率、 $F_1$  分数上分别提高 0.56、2.25、0.82 百分点。

表 7 列出在非迁移学习下本研究所用方法的各分类评价指标,本研究所用方法在识别花生叶部黑斑病时,表现出较高的精确率,同时召回率也是较高的,表明该网络模型几乎捕捉了全部实际情况。较

表 7 非迁移学习下本研究所用方法的各分类评价指标

| 病害类别 | 精确率 (%) | 召回率 (%) | $F_1$ 分数 (%) |
|------|---------|---------|--------------|
| 褐斑病  | 88.89   | 80.00   | 84.21        |
| 黑斑病  | 100.00  | 90.00   | 94.74        |
| 焦斑病  | 83.33   | 100.00  | 90.90        |
| 网斑病  | 90.00   | 90.00   | 90.00        |

高的  $F_1$  分数说明精确率和召回率的平衡具有较好的鲁棒性。在识别花生叶部焦斑病过程中,相对较高的召回率反映该网络模型对分类类别的覆盖能力很强,虽然精确率较低,但偏高的  $F_1$  分数表明精确率和召回率的调和程度很好。在花生叶部网斑病的识别任务上,精确率、召回率和  $F_1$  分数基本一样,突显出该网络模型在此类病害的识别上具有较好的稳定性。对花生叶部褐斑病的识别也具有较高的精确率,较低的召回率可能是受到图像背景的影响,以及其他分类样本的误分类。

表 8 列出迁移学习后各分类各项评价指标,本研究所用方法在花生叶部黑斑病和焦斑病的识别上各项指标都达到了 100%,表示该网络模型几乎完全正确地提取到类别的特征点,捕获几乎所有实际情况特征。在花生叶部褐斑病和网斑病的识别过程中,各项指标均高于 95%,反映该模型具备较好的性能。

表 8 迁移学习下本研究所用方法的各分类评价指标

| 病害类别 | 精确率 (%) | 召回率 (%) | $F_1$ 分数 (%) |
|------|---------|---------|--------------|
| 褐斑病  | 95.24   | 100.00  | 97.56        |
| 黑斑病  | 100.00  | 100.00  | 100.00       |
| 焦斑病  | 100.00  | 100.00  | 100.00       |
| 网斑病  | 100.00  | 95.00   | 97.43        |

### 3.3 特征可视化网络

Grad-CAM<sup>[20]</sup> 是一种可视化深度神经网络中处理特征图的重要技术,能够更好地理解模型在分类过程中的注意力集中情况。为了更好地展示 SAM 模块的处理效果,图 12 展示了 4 类花生叶部病害图像的 Grad-CAM 类激活映射可视化示例。

卷积层通过计算生成特征图对比其他层更能有效地反映目标类别的特征性,故选择网络特征层的最后一层卷积作为目标层进行计算。从热力图(图 12)中可以直观地看出,本研究所用方法中的

SAM 注意力机制比 SE、CBAM 和 ECA 等 3 种注意力机制生成的热力图,在病斑的颜色以及位置上与原始图像的一致性最好,表明本研究所用方法的网络可以更好地提取花生叶部病害的特征点。

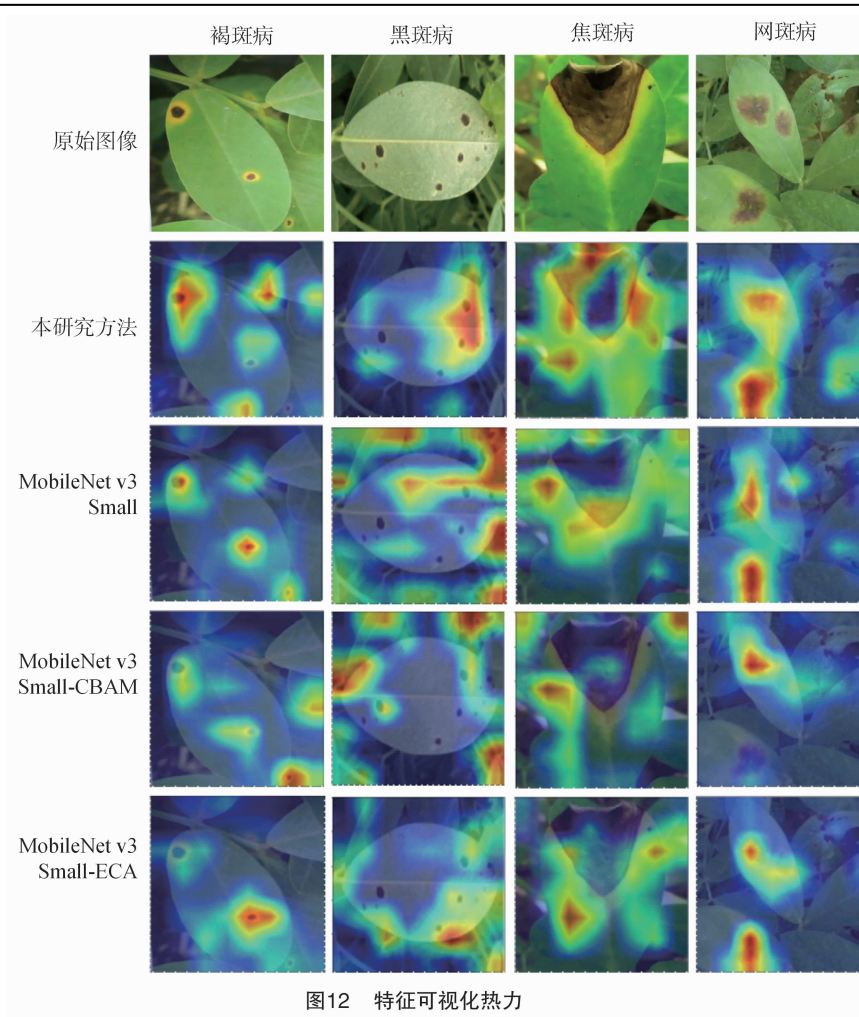
## 4 结论

本研究在原模型 MobileNet v3Small 的基础上,使用 SimAM 注意力机制改进模型。在非迁移学习和迁移学习下,改进后的模型 MobileNet v3Small-SAM 的准确率、精确率、召回率、 $F_1$  分数均高于原模型,并减少了大约 30.07% 的参数数量和 2.33 M 的内存。根据 Grad-CAM 可视化可以看出,相比其他 3 种模型,本研究所用方法在病斑的颜色以及位置上与原始图像更加一致。体现了本研究模型的优越性、泛用性、以及轻量化优势可以更好地在移动端和嵌入式设备上使用。

从多个指标来看,本研究所用方法也会产生误识别问题,主要为相似病害、相似背景以及图像的清晰度造成的误分类问题。但从整体上看,本研究所用方法的网络模型可以更好地提取花生叶部病害的特征点,更加准确稳定地识别检测出花生叶部病害。

### 参考文献:

- [1] 范燕,赵雪飞,刘晓光. 花生叶部病害研究进展[J]. 安徽农业科学,2022,50(14):4-8.
- [2] 张海东,刘晓舟,梁春浩,等. 花生褐斑病生防菌筛选及田间防效评价[J]. 花生学报,2023,52(3):42-47.
- [3] 颜景波,吴占鹏,苏君伟,等. 花生叶部病害防治技术研究[J]. 农业科技通讯,2013(3):123-125.
- [4] 翁杨,曾睿,吴陈铭,等. 基于深度学习的农业植物表型研究综述[J]. 中国科学:生命科学,2019,49(6):698-716.
- [5] 岑海燕,朱月明,孙大伟,等. 深度学习在植物表型研究中的应用现状与展望[J]. 农业工程学报,2020,36(9):1-16.
- [6] 付佐毅,周世杰,李顶根. 轻量级目标识别深度神经网络及其应用[J]. 计算机工程与应用,2020,56(18):131-136.
- [7] 袁培森,欧阳柳江,翟肇裕,等. 基于 MobileNet v3Small-ECA 的水稻病害轻量级识别研究[J]. 农业机械学报,2024,55(1):253-262.
- [8] Feng C G, Jiang M L, Huang Q, et al. A lightweight real-time rice blast disease segmentation method based on DFFANet[J]. Agriculture, 2022, 12(10):1543.
- [9] Iandola F N, Han S, Moskewicz M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size [EB/OL]. (2016-11-04) [2024-05-01]. <https://arxiv.org/abs/1602.07360>.



- [10] Howard A G, Zhu M L, Chen B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [EB/OL]. (2017-04-17) [2024-05-01]. <https://arxiv.org/abs/1704.04861>.
- [11] Tan M M, Le Q. Efficientnet: rethinking model scaling for convolutional neural networks [C]//International Conference on Machine Learning. PMLR, 2019.
- [12] Howard A, Sandler M, Chen B, et al. Searching for MobileNet v3 [C]//IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, 2019:1314-1324.
- [13] 李子茂, 李嘉晖, 尹帆, 等. 基于可形变卷积与 SimAM 注意力的密集柑橘检测算法 [J]. 中国农机化学报, 2023, 44(2): 156-162.
- [14] 田甜, 程志友, 鞠薇, 等. 基于 SimAM-ConvNeXt-FL 的茶叶病害小样本分类方法研究 [J]. 农业机械学报, 2024, 55(3): 275-281.
- [15] 朱传军, 刘荣光, 成佳闻, 等. 基于 SimAM 模块与 ResNet34 网络的混合缺陷检测模型 [J]. 现代制造工程, 2023(2): 1-9.
- [16] Yang L X, Zhang R Y, Li L D, et al. SimAM: a simple, parameter-free attention module for convolutional neural networks [C]//Proceeding of the 38th International Conference on Machine Learning, 2021.
- [17] 苏婷婷, 牟少敏, 董萌萍, 等. 深度迁移学习在花生叶部病害图像识别中的应用 [J]. 山东农业大学学报(自然科学版), 2019, 50(5): 865-869.
- [18] 张红涛, 罗一铭, 谭联, 等. 基于迁移学习和残差网络的谷子病害识别研究 [J]. 河南农业科学, 2023, 52(12): 162-171.
- [19] 郭惠萍, 曹亚州, 王晨思, 等. 基于迁移学习的苹果落叶病识别与应用 [J]. 农业工程学报, 2024, 40(3): 184-192.
- [20] Selvaraju R R, Cogswell M, Das A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization [C]//IEEE International Conference on Computer Vision (ICCV). Venice, 2017: 618-626.