

## 基于多尺度特征融合的轻量化苹果叶部病理识别

王等准<sup>1,2</sup>, 李飞<sup>1,2</sup>, 严春雨<sup>1,2</sup>, 刘瑞欣<sup>1,2</sup>, 闫建伟<sup>3</sup>, 张文勇<sup>4</sup>, 谢本亮<sup>1,2\*</sup><sup>1</sup>贵州大学大数据与信息工程学院, 贵州 贵阳 550025;<sup>2</sup>半导体功率器件可靠性教育部工程研究中心, 贵州 贵阳 550025;<sup>3</sup>贵州大学机械工程学院, 贵州 贵阳 550025;<sup>4</sup>贵州大学计算机科学与技术学院, 贵州 贵阳 550025

**摘要** 苹果叶部病害的发生极大地影响了苹果的品质和产量,对病害的监测是确保苹果产业健康发展的重要措施。在 ResNet 结构基础上,提出了一种基于多尺度特征融合的轻量化病害识别模型。首先,采用特征融合机制,提取并融合网络高低维特征,加强卷积层之间语义信息的传递,增强识别细微病斑的能力。其次,加入多尺度深度可分离卷积,利用多尺度卷积核结构对不同尺度的病害特征进行提取,提高特征的丰富度,同时约束模型的参数量。最后,为验证所提模型的有效性,采用一个包含 5 种苹果叶部病害数据集进行了实验。实验结果表明,该模型取得了 98.05% 的识别准确率,模型参数量和计算量仅为 4.02 MB 和 0.92 GB,与其他模型相比同样具有优势,可为农业自动化精准识别病虫害提供新的方案。

**关键词** 图像处理; 深度学习; 病害识别; 多尺度; 轻量化; ResNet

中图分类号 TP181;S432;TP391.41

文献标志码 A

DOI: 10.3788/LOP212261

## Lightweight Apple-Leaf Pathological Recognition Based on Multiscale Fusion

Wang Dengzhun<sup>1,2</sup>, Li fei<sup>1,2</sup>, Yan Chunyu<sup>1,2</sup>, Liu Ruixin<sup>1,2</sup>, Yan Jianwei<sup>3</sup>,  
Zhang Wenyong<sup>4</sup>, Xie Benliang<sup>1,2\*</sup><sup>1</sup>College of Big Data and Information Engineering, Guizhou University, Guiyang 550025, Guizhou, China;<sup>2</sup>Semiconductor Power Device Reliability Engineering Research Center of the Ministry of Education, Guiyang 550025, Guizhou, China;<sup>3</sup>School of Mechanical Engineering, Guizhou University, Guiyang 550025, Guizhou, China;<sup>4</sup>School of Computer Science and Technology, Guizhou University, Guiyang 550025, Guizhou, China

**Abstract** The occurrence of apple leaf diseases has a significant impact on apple quality and yield. Disease monitoring is therefore an important measure to ensure the healthy development of the apple industry. Based on the ResNet structure, a lightweight disease recognition model based on multiscale feature fusion is proposed. First, the feature fusion mechanism is used to extract and fuse the high-dimensional and low-dimensional features of the network, strengthen the transmission of semantic information between convolution layers, and enhance the ability to distinguish subtle lesions. Next, multiscale depth separable convolution is added to extract disease features of different scales by using multi-scale convolution kernel structure, which improves the richness of features and restricts the parameters of the model. Finally, a dataset containing five kinds of apple leaf diseases is used to verify the effectiveness of the proposed method. The experimental results show that the recognition accuracy of the model is 98.05%, and that the number and calculation of the model network are only 4.02 MB and 0.92 GB, respectively. Compared with other models, it also has advantages, and can provide a new scheme for the accurate identification of diseases and pests in agricultural automation.

**Key words** image processing; deep learning; disease identification; multiscale; lightweight; ResNet

收稿日期: 2021-08-16; 修回日期: 2021-10-12; 录用日期: 2021-11-15; 网络首发日期: 2021-12-01

基金项目: 国家自然科学基金(61562009)、贵州大学人才引进科研项目(贵大人基合字(2015)29号)、半导体功率器件教育部工程研究中心开放基金项目(ERCMEKFJJ2019-(06))、贵州科技计划项目(黔科合成果[2019]4279号,黔科合平台人才[2019]5616号)、国家重点研发计划课题(2021YFD1100307)

通信作者: \*blxie@gzu.edu.cn

# 1 引言

我国是世界上最大的苹果生产国和消费国之一<sup>[1]</sup>,而苹果叶部病害问题关乎苹果的品质和产量,是当前苹果产业健康发展面临的主要挑战<sup>[2]</sup>。及时准确地识别苹果叶部病害并进行防治,能够有效地提高苹果产量<sup>[3]</sup>。随着社会科技的进步,机器视觉的发展和计算机数据处理能力的不断提升<sup>[4]</sup>,机器学习技术<sup>[5]</sup>在图像处理方面的优势,为苹果叶部病理识别提供了新的解决方案。

从已有研究看,传统的植物叶部病虫害识别一般通过叶部病斑的颜色、纹理、边缘等特征进行分类<sup>[6]</sup>。吴露露等<sup>[7]</sup>采用色度学模型、边缘提取和形态学等图像处理方法对叶瘟病斑进行识别,准确率达到了 90.26%。Padol 等<sup>[8]</sup>采用 K-means 算法提取病虫害区域,以颜色和纹理作为特征输入,结合支持向量机(SVM)分类方法,对两种葡萄叶片病害的识别准确率达 88.89%。张云龙等<sup>[9]</sup>采用改进的 Mean-shift 算法分割病害图像病斑,获取病虫害图像的颜色特征和差直方图,结合 SVM 分类方法,对 3 种苹果叶部病害的识别率达 96%。以上方法虽取得了不错的效果,但传统方法选取特征依赖于设计者的经验,而且受光照变化、背景噪声、目标形态多样性等因素的影响较大,难以设计出适应性好、稳定性高的特征提取模型<sup>[10]</sup>。

深度学习模型可以通过逐层非线性变换提供丰富的判别特征,省略了复杂的图像预处理和特征提取操作<sup>[11]</sup>,现已广泛应用于农作物病害诊断中。黄林生等<sup>[12]</sup>提出了一种多尺度注意力残差网络模型,该模型在 8 种农作物病害数据集上的平均识别准确率达到 95.62%。何欣等<sup>[13]</sup>在设计葡萄叶片病害图像识别模型时引入多尺度卷积以改变 ResNet 底层对不同尺度特征的响应,结合 SENet 提升网络的特征提取能力,病害识别准确率达 90.83%。郭小清等<sup>[14]</sup>设计了一种基于 AlexNet 的基

础模型,该模型通过不同尺度卷积核提取特征实现多感受野识别,并部署于 Android 系统,其对番茄病害图像识别准确率达 89.2%。张宁等<sup>[15]</sup>提出了 AT-InceptionV3 卷积神经网络,结合多尺度卷积和注意力机制模块提高番茄叶部病害的表征能力,该模型在 5 种番茄常见叶片图像分类准确率达到 98.4%。陆仲达等<sup>[16]</sup>提出了一种双分支网络的苹果叶部病理识别方法,该方法采用不同的空洞卷积核大小进行图片的多尺度提取特征提取,并引入通道、高度、宽度多维注意力机制,病害识别准确率达 97.66%。王健等<sup>[17]</sup>提出了一种基于深度可分离卷积的苹果叶病理识别方法,该方法以 MobileNets\_V2 为基础模型,采用概率数据增强、迁移学习等方法进行重新建模,在目标设备上识别准确率达 85.96%。

多尺度特征融合可以增加网络的深度与宽度,在计算机视觉任务上都有优秀的识别效果<sup>[18-20]</sup>,但也会导致模型复杂度升高、检测速度降低。使用轻量级模型时,虽然模型复杂度较低、参数量较少,但是检测能力又有所欠缺。因此,本文提出了一种基于多尺度特征融合的轻量化模型。首先,在深度残差网络(ResNet)<sup>[21]</sup>的基础上,依次建立多级别特征映射,将网络中深层语义信息与浅层细节信息进行融合,提高模型对小尺寸病斑识别准确性。其次,利用多尺度卷积核( $3 \times 3, 5 \times 5, 7 \times 7$ )组合改进残差网络,解决病害特征提取尺度单一、信息丰富度不足的问题。实验结果表明,该模型具有较小的计算量与参数量,并取得了较好的识别效果,为模型部署于硬件条件受限的情况下提供了有效的技术手段。

## 2 苹果叶部病理识别模型

### 2.1 整体网络模型构建

所提基于多尺度特征融合的轻量化模型整体架构如图 1 所示,整个架构由残差特征提取网络、多尺度特

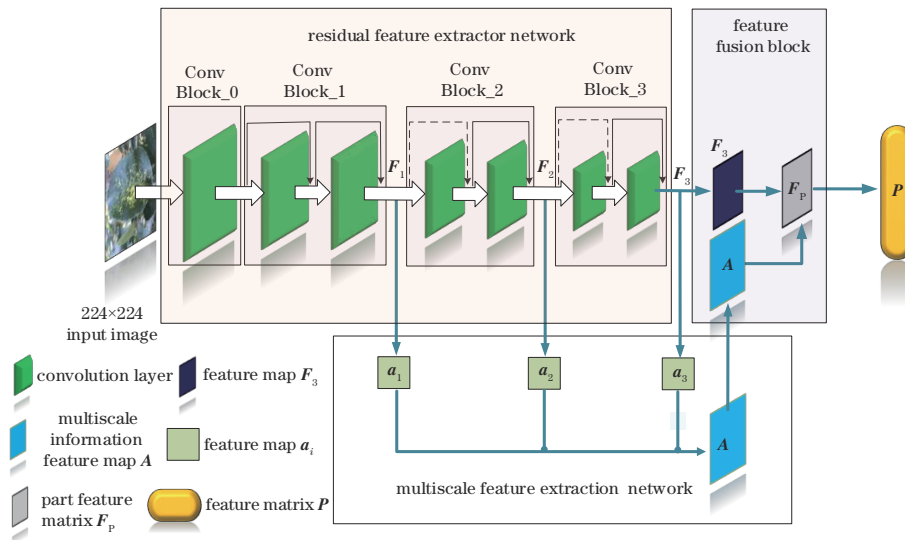


图 1 整体模型架构

Fig. 1 Total model architecture

征提取网络、特征融合模块和特征矩阵  $P$  等 4 部分组成。ResNet 能够堆叠成不同网络层数, 常见的有 18 层的 ResNet18、50 层的 ResNet50 及 101 层的 ResNet101 等。首先, 因为本研究的病害数据集规模较小, 所以不需要过多层次的残差网络, 否则模型在训练中容易出现过拟合现象。其次, 模型部署到移动设备时, 缺乏高性能计算单元, 难以完成复杂的参数运算。因此, 选择 ResNet18 为模型特征提取主干网络并进行以下修改: 1) 利用多尺度深度可分离卷积堆叠残差块 Conv Block1\_3 替换原主干网络堆叠残差块; 2) 删除原主干网络最后一个堆叠残差块; 3) 通过多尺度特征提取网络、特征融合模块获取融合后的特征图, 并送入全局平均池化层 (GAP) 获取特征矩阵  $P$ 。

### 2.2 多尺度特征提取网络

模型中的深层特征具有更强的语义信息, 但是分辨率较低, 对细节的感知能力较差。浅层特征分辨率更高, 包含更多位置、细节、低层次的信息, 在对锈病和灰斑病等细小密集类型病害检测时细节信息往往不可忽略。为此, 所提模型依次建立多级别的特征映射, 将浅层特征与深层特征相互融合, 利用多尺度特征提取器从单分辨率特征图中获取语义信息, 构建具有细粒度特征和丰富语义信息的特征表示, 使融合后的特征具有更强的描述性, 更有利于图像的分类, 其结构如图 2 所示。通过主干网络可获取  $F_1$ 、 $F_2$ 、 $F_3$  等 3 种不同尺度的特征图 (feature map), 其大小分别为  $64 \times 56 \times 56$ 、 $128 \times 28 \times 28$ 、 $256 \times 14 \times 14$ 。首先, 采用  $1 \times 1$  卷积 ( $1 \times 1$  Conv) 从单分辨率特征图中挤出信息, 并将浅层特征图通道数与深层特征图转化到相同的维数, 在后续的实验讨论了不同输出维数的识别效果。其次, 因为深层特征图与浅层特征图具有不同的分辨率, 所以在融合前需要对浅层特征图进行最大池化下采样操作降低分辨率, 使其与深层特征图分辨率保持一致, 图中

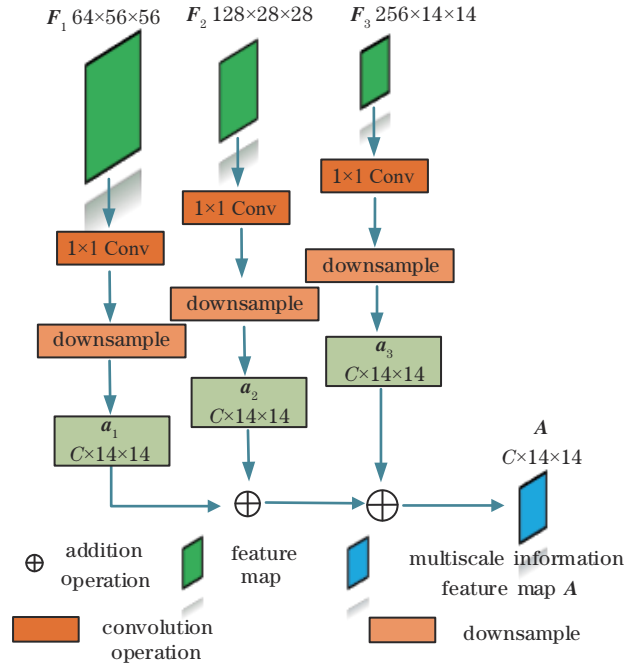


图 2 多尺度特征提取网络

Fig. 2 Multiscale feature extraction network

$a_1$ 、 $a_2$ 、 $a_3$  即为经过以上操作所获取的特征图。最后, 将  $a_1$ 、 $a_2$ 、 $a_3$  在对应通道上进行加法运算, 可得到多尺度信息特征图  $A$ 。加法运算的具体方法为将特征向量  $V_1 \in \mathbf{R}^m$ 、 $V_2 \in \mathbf{R}^m$  在同一维度上进行叠加, 融合的特征向量  $V = [V_1 + V_2]^m$ 。

### 2.3 特征融合模块

特征融合模块结构如图 3 所示。首先, 将多尺度信息特征图  $A$  的每一个通道与  $F_3$  特征图相乘, 得到多个部分融合特征图 ( $F_{P_i}$ ), 使  $F_3$  特征图每个通道产生特征信息偏差功能, 每个通道尽可能关注有价值的细粒度特征。其次, 为避免模型过拟合, 通过全局平均池化

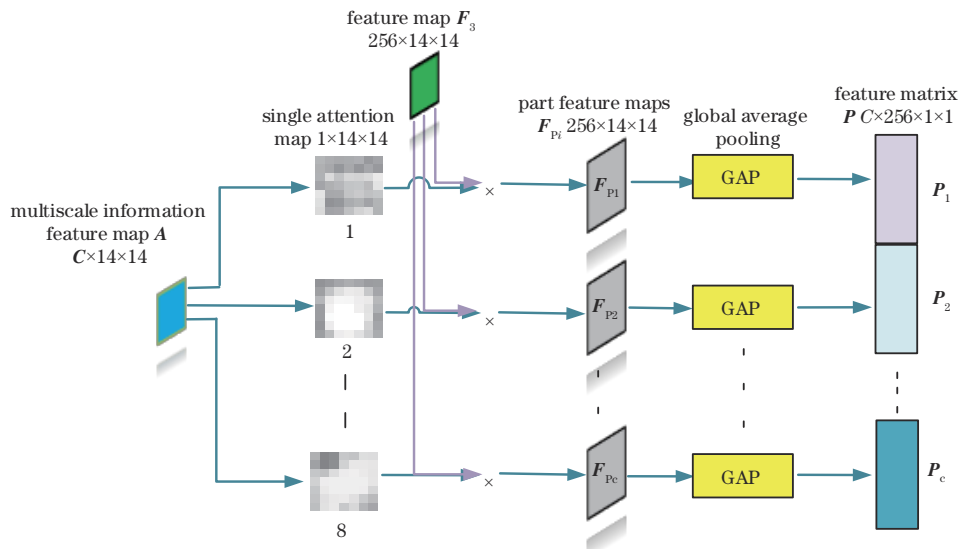


图 3 特征融合模块

Fig. 3 Feature fusion block

层将  $F_p$  化为  $256 \times 1 \times 1$  维的预测向量。最后,将各预测向量经过拼接生成  $C \times 256 \times 1 \times 1$  的维特征矩阵  $P$  送入分类层,使用 Softmax 损失函数和随机梯度下降方法进行优化,获取最终分类结果。向量拼接 (Concat) 的具体方法为将特征向量  $V_1 \in \mathbf{R}^m$ 、 $V_2 \in \mathbf{R}^n$  在对应维度上进行拼接,融合的特征向量  $V = [V_1 + V_2]^{(m+n)}$ 。 $F_{pj}$  的表达式为

$$F_{pj} = A_j * F_3, j = 1, 2, \dots, 8, \quad (1)$$

式中: $A_j$ 表示多尺度信息特征图  $A$  中的第  $j$  个单分辨率特征图; $*$ 表示对应元素相乘。

### 2.4 多尺度深度可分离卷积

由于标准卷积 (Conv) 的卷积核作用于输入特征图的每个通道,计算量较大。深度可分离卷积是一种可分解的卷积结构,能够将标准化卷积分解为深度卷积和逐点卷积<sup>[22]</sup>。运算时先通过深度卷积操作对每一

个输入特征通道进行卷积,然后利用逐点卷积对深度卷积的输出进行组合,这种将卷积分解的过程可以有效降低模型参数规模与计算量。基于此,本研究提出了一种多尺度深度可分离卷积 (Mu-ds Conv),利用  $3 \times 3$ 、 $5 \times 5$ 、 $7 \times 7$  卷积核相互组合获得不同尺度的卷积核组,小的卷积核对局部特征更敏感,大的卷积核能捕获较大的感受野。该方法不仅可以减少模型参数量,同时也能增强模型非线性映射能力,使网络能够学习更高层次的多输入通道特征,提高模型精度。该卷积方法包括多尺度深度卷积和逐点卷积:多尺度深度卷积利用大小不同的卷积核对输入特征图进行单独卷积,并将卷积结果 Concat 连接;利用  $1 \times 1$  逐点卷积对多尺度深度卷积的输出进行组合,得到一系列新的特征输出。图 4 对比了两种卷积操作的差异,图 4(a) 为标准卷积图,图 4(b) 为多尺度深度可分离卷积。

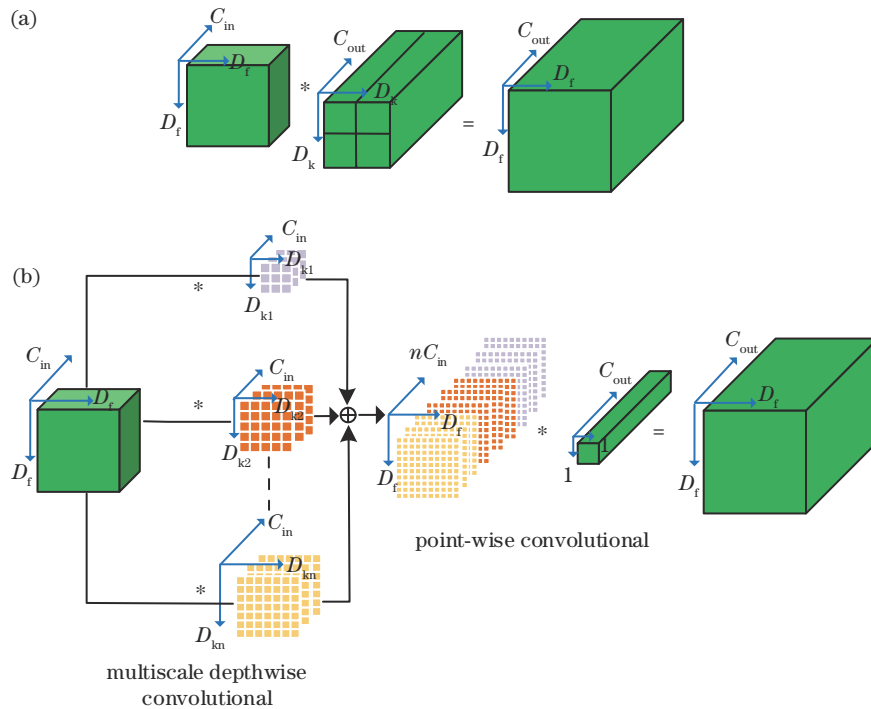


图 4 标准卷积与多尺度深度可分离卷积对比。(a)标准卷积;(b)多尺度深度可分离卷积

Fig. 4 Comparison between standard convolution and multiscale depth separable convolution. (a) Standard convolution; (b) multiscale depthwise separable convolution

假设输入特征图有  $C_{in}$  个通道,输出特征图有  $C_{out}$  个通道,输入输出特征图大小都为  $D_f \times D_f$ ,卷积核尺寸为  $D_k \times D_k$ 。则标准卷积与多尺度深度可分离卷积的计算量  $l_1$ 、 $l_2$  分别为

$$l_1 = D_f \times D_f \times C_{in} \times C_{out} \times D_k \times D_k, \quad (2)$$

$$l_2 = C_{in} \left( \sum_{t=1}^n D_f \times D_f \times D_{kt} \times D_{kt} + n \times D_f \times D_f \times C_{out} \right), \quad (3)$$

式中: $D_{kt}$ 表示第  $t$  个多尺度卷积核尺寸; $n$ 表示卷积核个数。

多尺度深度可分离卷积与标准卷积的计算量之

比为

$$\frac{l_2}{l_1} = \frac{C_{in} \left( \sum_{t=1}^n D_f \times D_f \times D_{kt} \times D_{kt} + n \times D_f \times D_f \times C_{out} \right)}{D_f \times D_f \times C_{in} \times C_{out} \times D_k \times D_k} = \frac{\sum_{t=1}^n D_{kt} \times D_{kt}}{C_{out} \times D_k \times D_k} + \frac{n}{D_k + D_k}. \quad (4)$$

根据式(4)可知:当使用 1 个  $3 \times 3$  的卷积核时,若输入输出通道为 64,多尺度深度可分离卷积的计算量为传统卷积的 0.126;若使用  $(3 \times 3, 5 \times 5)$  卷积组,该方法计算量为标准  $3 \times 3$  卷积的 0.281。改进残差块结构

如图 5 所示,将残差块(Conv Block1\_3)中主干网络原  $3 \times 3$  标准卷积(Conv  $3 \times 3$ )替换为多尺度深度可分离卷积( $3 \times 3, 5 \times 5$ ) (Mu-ds Conv  $3 \times 3, 5 \times 5$ )。

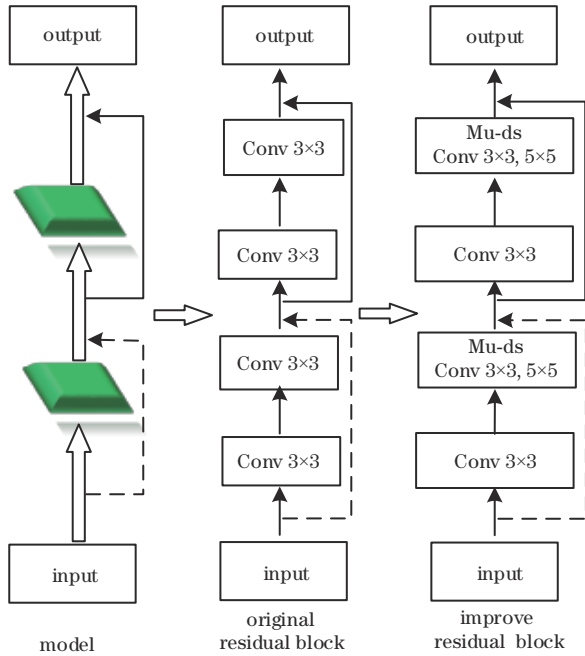


图 5 原残差块和改进残差块对比

Fig. 5 Comparison between original residual block and improved residual block

### 3 实验设计与结果分析

#### 3.1 实验数据来源与处理

所用数据集由西北农林科技大学制作,在不同天气情况下,采集多个苹果实验站户外数据<sup>[23]</sup>。对原始病害图像进行旋转、垂直镜像、锐度、亮度等调整操作扩充后,数据集共包含 5 种病害类型,其中花叶病 4875 张、褐斑病 5655 张、锈病 5694 张、灰斑病 4810 张、斑点落叶病 5343 张,图像示例如图 6 所示。为提高模型泛化能力,实验时随机选择 60% 样本作为训练集,20% 作




图 6 苹果叶部病害图像。(a)花叶病;(b)褐斑病;(c)锈病;(d)灰斑病;(e)斑点落叶病  
Fig. 6 Images of apple leaf disease. (a) Mosaic; (b) brown\_spot; (c) rust; (d) grey\_spot; (e) alternaria\_boltch

为验证集,20% 作为测试集。数据集分布情况如表 1 所示。首先,按照标签对数据集图片进行分类处理。其次,将图像大小调整到 224 pixel  $\times$  224 pixel。最后,为促进神经网络快速收敛,在对图像进行批量化与标准化处理<sup>[24]</sup>后将数据输入网络。

表 1 数据集分布  
Tabel 1 Dataset distribution

Diseases category of apple leaf	Training set	Validation set	Test set
Mosaic	2918	978	978
Brown_spot	3379	1138	1138
Rust	3497	1098	1098
Grey_spot	2886	995	995
Alternaria_boltch	3210	1066	1066
Total	15827	5275	5275

#### 3.2 实验环境与评价指标

实验环境配置如表 2 所示,根据现有硬件设备可承载的运算能力,选择的优化算法为随机梯度下降(SGD),为防止出现局部最优解,批量大小设为 128,每次参数更新后学习率权重衰减系数设为 0.001,最大迭代次数设为 100,模型采用交叉熵损失函数计算损失值。使用保留最佳训练模型方法,在训练过程中每训练一个 Epoch,使用验证集测试一次准确率,并保存验证过程中性能最佳的模型,训练完成后将性能最佳的训练权重载入模型获取测试集检测结果。

表 2 实验环境配置

Tabel 2 Experimental environment configuration

Operating system	Ubuntu 18. 0
GPU	NVIDIA Tesla V100
Deep learning framework	Pytorch-GPU-1. 7. 1
Programing language	Python 3. 8. 2
GPU Acceleration library	CUDA10. 2, CUDNN8. 0

#### 3.3 量化评价指标

评价一个模型的性能有多种方法,本研究主要考虑到准确率与模型部署于移动设备中的相关问题,使用了以下 3 种评价方式对模型性能进行评估。

平均识别准确率(Arc)是正确分类的样本数和样本总数之比:

$$R_{Arc} = \sum_{i=1}^n \frac{N_{TP_i}}{N_{TP_i} + N_{FP_i}} \times 100\%, \quad (5)$$

式中:  $N_{TP_i}$ 、 $N_{FP_i}$  分别表示测试集中第  $i$  类病害样本预测正确和预测错误的样本数;  $n$  表示总的病害类数。

模型网络计算复杂度常用浮点运算数(FLOPs)表示,浮点运算数可理解为计算量,可以用来衡量算法或模型的复杂度,FLOPs 越小时,表示模型所需计算量越小,运行速度越快。嵌入式设备软硬件环境配置较低,较小的计算量可以减小病害检测时间。

模型网络参数量 (Parameters) 是指模型含有参数的多少, 具体包含卷积层与全连接层的参数量。网络参数量不仅直接决定模型文件的大小, 还影响模型推断时对计算机内存的占用量, 运行消耗的内存过大会导致应用启动慢, 后台易杀死等问题, 难以在移动平台应用。

### 3.4 多尺度特征提取输出维度数对比实验

为验证多尺度特征提取输出维度数对模型准确率的影响, 针对输出维度数  $C$  分别取 4、8、16、32 设置对照实验, 实验结果如表 3 所示。从表 3 可以看出: 当输出维度数量为 8 时取得了 97.51% 的平均识别准确率, 相对基础模型 ResNet18 提高了 0.85 个百分点; 对于锈病和灰斑病识别率分别为 97.12% 和 96.39%, 相比基础模型识别准确率分别提高了 2.49 个百分点、2.92 个百分点, 这两种病害均病斑较小且较为密集, 使用多尺度特征提取网络能更好感知病斑区域, 提高

表 3 输出维度数对比实验

Table 3 Output dimension number comparison experiment unit: %

Diseases category of apple leaf	Recognition accuracy of the test set in dataset				
	ResNet18	Map (4)	Map (8)	Map (16)	Map (32)
Mosaic	99.54	99.69	99.90	99.59	99.39
Brown_spot	99.32	99.12	99.21	99.82	99.91
Rust	94.63	95.99	97.12	96.22	95.57
Grey_spot	93.47	95.49	96.39	95.20	95.04
Alternaria_boltch	96.34	94.95	94.93	93.84	94.82
Arc	96.66	97.04	97.51	96.93	96.95

表 4 不同改进策略组合的测试结果

Table 4 Test results of different combinations of improvement strategies units: %

Diseases category of apple leaf	Recognition accuracy of the Validation set in dataset				
	Map(8)	Mu-ds (3×3, 5×5)+Map (8)	Mu-ds (3×3, 7×7)+Map (8)	Mu-ds (5×5, 7×7)+Map (8)	Mu-ds (3×3, 5×5, 7×7)+Map (8)
Mosaic	99.90	99.69	99.80	99.89	99.29
Brown_spot	99.21	99.91	99.38	99.21	99.55
Rust	97.12	97.36	94.77	97.27	94.59
Grey_spot	96.39	96.00	95.80	96.61	95.79
Alternaria_boltch	94.93	93.60	96.63	97.35	97.84
Arc	97.51	97.31	97.25	98.05	97.41

### 3.6 不同识别算法对比实验

为了验证所提算法的有效性, 将其与目前较流行的 AlexNet<sup>[25]</sup>、VGG16<sup>[26]</sup>、ResNet50、Inception\_V4<sup>[27]</sup> 及轻量

网络特征提取能力。综合数据集中各种病害识别效果可知, 当模型引入多尺度融合方法时, 识别准确率均有所提高。当输出维度数为 4、16、32 时, 平均识别准确率分别提高了 0.38 个百分点、0.27 个百分点、0.29 个百分点。

### 3.5 多尺度深度可分离卷积与输出维度数的影响比较实验

为验证不同尺度组合的深度可分离卷积和多尺度融合方法结合对模型性能影响, 同时为增强实验结果的准确性, 将与获得最好识别效果的输出维度数设置了 4 组消融实验, 实验结果如表 4 所示,  $\text{Mu-ds}(n \times n, m \times m)$  表示多尺度深度可分离卷积组合,  $n, m$  为卷积核大小。对于斑点落叶病当使用  $(3 \times 3, 5 \times 5)$  卷积组合时斑点落叶病识别准确率有所下降, 这是该病害形状特别稀疏, 当使用比较小的卷积核时无法表示其完整特征, 导致平均识别准确率有所下降。当选择较大  $(5 \times 5, 7 \times 7)$  卷积组合时, 对斑点落叶病识别效果比原始未使用多尺度卷积提升了 2.42 个百分点, 同时对锈病, 灰斑病识别效果也有略微提升, 该组合模型识别平均识别准确率达 98.05%, 相对于 3 种多尺度深度可分离卷积  $(3 \times 3, 5 \times 5)$ 、 $(3 \times 3, 7 \times 7)$  和  $(3 \times 3, 5 \times 5, 7 \times 7)$  组合分别提高了 0.44 个百分点、0.70 个百分点与 0.54 个百分点。实验结果表明, 多尺度深度可分离卷积代替标准卷积运算的操作也能够一定程度上减少卷积层部分的计算量, 提高识别准确度, 多种卷积核组合的方式使得模型感知不同的特征, 提高网络的特征提取能力。

级 MobliNet\_V2 在测试集中进行了实验对比, 结果如表 5 所示。从表 5 可以看出, 所提算法在测试集中的识别准确率可达 98.05%, 模型参数量相较于 ResNet18 缩小

表 5 不同算法的识别结果对比

Table 5 Comparison of recognition results of different algorithms

Model	Test set accuracy / %	Parameters / MB	Floating Point Operations / GB
ResNet18	96.66	11.18	1.83
ResNet50	96.45	23.52	4.12
AlexNet	95.13	14.6	0.31
VGG16	95.88	72.34	15.44
Inception_V4	97.21	41.15	6.15
MobileNet_V2	96.07	2.23	0.32
Propose Model	98.05	4.02	0.92

约 64%，计算量减小 50% 左右。就网络层数较多的 ResNet50 模型而言，虽然参数量较大，但准确率较 ResNet18 低，说明该模型因数据集规模较小训练中已经出现过拟合现象。相比于准确率较高且同样使用多尺度特征提取的 Inception\_V4 识别准确率提高了 0.8 个百分点，参数量减小 90%。相对于轻量级模型 MobliNet\_V2 而言，虽然该模型复杂度较低但准确较所提模型准

确率低了约 2 个百分点。图 7 为所提模型和 ResNet18 的识别准确率和损失值变化曲线。从图中可以看出，所提模型对验证集的认识准确率明显高于 ResNet18，损失值曲线下降速度较快且损失值明显低于 ResNet18，进一步提高了实验的可信度。所提模型相比于其他模型，能够在保证准确率的情况下，具有较低的模型复杂度，为后期模型部署于移动设备中奠定了基础。




图 7 模型识别准确率和损失值变化曲线。(a) 验证集准确率；(b) 验证集损失值

Fig. 7 Variation curve of model recognition accuracy and loss value. (a) Validation set accuracy; (b) validation set loss value

### 3.7 实验结果分析

所提模型应用于苹果叶部病理检测数据集上得出的混淆矩阵如图 8 所示，混淆矩阵包含测试集中预测正确和错误的样本数，横坐标为标签，纵坐标为预测标签，其中 0~4 分别代表斑点落叶病、褐斑病、灰斑病、花叶病。在混淆阵中，主对角线数字为预测正确的样本数，非主对角线均表示预测错误的样本数。由图 8 可知，混淆矩阵中显示测试集上每一类病害的识别准确率和每种类别被分类错误的情况，第 0 类斑点落叶病 (alternaria\_boltch) 和第 4 类灰斑病 (grey\_spot) 的错

误识别率较高。由此可见，对苹果叶部病害识别时，灰斑病和斑点落叶病在识别过程中容易发生混淆。图 9 为这两种病害图像，从图中可以看出，灰斑病的病斑颜色与斑点落叶病的病斑颜色呈现出类似的特征，从而造成识别错误。在后续研究中，一方面可考虑增加病害样本数目，另一方面可提升网络深度和改善特征提取模式，以提高模型的特征提取能力和分辨能力。

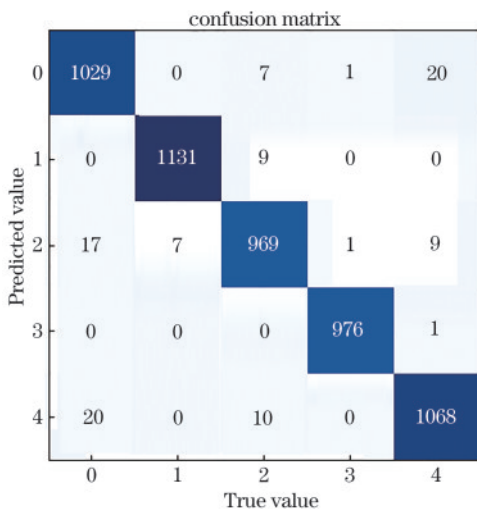


图 8 测试集的混淆矩阵

Fig. 8 Fusion matrix of test set in dataset




图 9 易混淆的 2 种苹果病害叶部图像。(a) 斑点落叶病；(b) 灰斑病

Fig. 9 Confusing leaf images of two apple diseases. (a) Alternaria\_boltch; (b) grey\_spot

## 4 结 论

提出了一种基于多尺度特征融合的轻量化病害识别模型，在获得较好病害识别准确率的同时，约束了模型的参数量。模型首先引入多尺度信息融合机制，构建包含丰富位置信息与语义信息的特征表示，

使模型更多关注特征图的细粒度病害区域,提高模型的判决能力;其次,使用多尺度深度可分离卷积替换标准卷积,在减小模型复杂度的同时提高模型表达能力。与其他卷积神经网络模型的对比试验表明,该模型能较好地平衡识别准确率和模型复杂度,对病害平均识别准确率达 98.05%,为深度学习模型部署于农业嵌入式设备上提供了新的方法。在未来的研究中,其他植物叶片病害数据集的扩展研究也将被考虑在内,测试并改进现有算法,提高模型对于这类问题的泛化能力。

## 参 考 文 献

- [1] 杨军玉, 刘淑香, 胡同乐, 等. 2009 年全国苹果叶部主要病虫害发生及农药使用情况[J]. 中国植保导刊, 2010, 30(10): 25-28, 17.  
Yang J Y, Liu S X, Hu T L, et al. Occurrence of major diseases and insect pests and pesticide use in apple leaves in China in 2009[J]. China Plant Protection, 2010, 30(10): 25-28, 17.
- [2] 田永强. 影响国内外苹果产业发展的几种果实病害[J]. 烟台果树, 2014(4): 40-41.  
Tian Y Q. Several fruit diseases affecting the development of apple industry at home and abroad[J]. Yantai Fruits, 2014(4): 40-41.
- [3] 赵中华, 朱晓明, 刘万才. 我国药用植物病虫害绿色防控面临的挑战和机遇[J]. 中国植保导刊, 2020, 40(9): 103-106, 110.  
Zhao Z H, Zhu X M, Liu W C. Challenges and opportunities for green prevention and control of medicinal plant diseases and pests in China[J]. China Plant Protection, 2020, 40(9): 103-106, 110.
- [4] 何新宇, 赵时璐, 张震, 等. 机器视觉的研究及应用发展趋势[J]. 机械设计与制造, 2020(10): 281-283, 287.  
He X Y, Zhao S L, Zhang Z, et al. Development trend of the research and application of machine vision[J]. Machinery Design & Manufacture, 2020(10): 281-283, 287.
- [5] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [6] Varshney D, Babukhanwala B, Khan J, et al. Machine learning techniques for plant disease detection[C]//2021 5th International Conference on Trends in Electronics and Informatics (ICOEI), June 3-5, 2021, Tirunelveli, India. New York: IEEE Press, 2021: 1574-1581.
- [7] 吴露露, 郑志雄, 齐龙, 等. 基于图像处理的田间水稻叶瘟病斑检测方法[J]. 农机化研究, 2014, 36(9): 32-35.  
Wu L L, Zheng Z X, Qi L, et al. Detection method of rice leaf blast based on image processing[J]. Journal of Agricultural Mechanization Research, 2014, 36(9): 32-35.
- [8] Padol P B, Yadav A A. SVM classifier based grape leaf disease detection[C]//2016 Conference on Advances in Signal Processing (CASP), June 9-11, 2016, Pune, India. New York: IEEE Press, 2016: 175-179.
- [9] 张云龙, 袁浩, 张晴晴, 等. 基于颜色特征和差直方图的苹果叶部病害识别方法[J]. 江苏农业科学, 2017, 45(14): 171-174.  
Zhang Y L, Yuan H, Zhang Q Q, et al. Apple leaf disease identification method based on color feature and difference histogram[J]. Jiangsu Agricultural Sciences, 2017, 45(14): 171-174.
- [10] Radovanović D, Đukanović S. Image-based plant disease detection: a comparison of deep learning and classical machine learning algorithms[C]//2020 24th International Conference on Information Technology (IT), February 18-22, 2020, Zabljak, Montenegro. New York: IEEE Press, 2020.
- [11] Hou X X, Gong Y H, Liu B Z, et al. Learning based image transformation using convolutional neural networks[J]. IEEE Access, 2018, 6: 49779-49792.
- [12] 黄林生, 罗耀武, 杨小冬, 等. 基于注意力机制和多尺度残差网络的农作物病害识别[J]. 农业机械学报, 2021, 52(10): 264-271.  
Huang L S, Luo Y W, Yang X D, et al. Crop disease recognition based on attention mechanism and multi-scale residual network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(10): 264-271.
- [13] 何欣, 李书琴, 刘斌. 基于多尺度残差神经网络的葡萄叶片病害识别[J]. 计算机工程, 2021, 47(5): 285-291, 300.  
He X, Li S Q, Liu B. Identification of grape leaf diseases based on multi-scale residual neural network[J]. Computer Engineering, 2021, 47(5): 285-291, 300.
- [14] 郭小清, 范涛杰, 舒欣. 基于改进 Multi-Scale AlexNet 的番茄叶部病害图像识别[J]. 农业工程学报, 2019, 35(13): 162-169.  
Guo X Q, Fan T J, Shu X. Tomato leaf diseases recognition based on improved Multi-Scale AlexNet[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(13): 162-169.
- [15] 张宁, 吴华瑞, 韩笑, 等. 基于多尺度和注意力机制的番茄病害识别方法[J]. 浙江农业学报, 2021, 33(7): 1329-1338.  
Zhang N, Wu H R, Han X, et al. Tomato disease recognition scheme based on multi-scale and attention mechanism[J]. Acta Agriculturae Zhejiangensis, 2021, 33(7): 1329-1338.
- [16] 陆仲达, 张春达, 张佳奇, 等. 双分支网络的苹果叶部病害识别[J]. 计算机科学与探索, 2022, 16(4): 917-926.  
Lu Z D, Zhang C D, Zhang J Q, et al. Identification of apple leaf disease based on dual branch network[J]. Journal of Frontiers of Computer Science and Technology, 2022, 16(4): 917-926.
- [17] 王健, 刘雪花. 基于深度可分离卷积的苹果叶病理识别[J]. 计算机系统应用, 2020, 29(11): 190-195.  
Wang J, Liu X H. Pathological recognition of apple leaves based on deeply separable convolution[J]. Computer Systems & Applications, 2020, 29(11): 190-195.
- [18] 张志刚, 余鹏飞, 李海燕, 等. 基于多尺度特征引导的细粒度野生菌图像识别[J]. 激光与光电子学进展, 2022, 59(12): 1210016.  
Zhang Z G, Yu P F, Li H Y, et al. Image recognition of



- fine-grained wild bacteria based on multi-scale feature guidance[J]. *Laser & Optoelectronics Progress*, 2022, 59(12): 1210016.
- [19] 邓志良, 李磊. 基于改进残差网络的中式菜品识别模型[J]. *激光与光电子学进展*, 2021, 58(6): 0610019.  
Deng Z L, Li L. Chinese food recognition model based on improved residual network[J]. *Laser & Optoelectronics Progress*, 2021, 58(6): 0610019.
- [20] 李思瑶, 刘宇红, 张荣芬. 多尺度特征融合的细粒度图像分类[J]. *激光与光电子学进展*, 2020, 57(12): 121002.  
Li S Y, Liu Y H, Zhang R F. Fine-grained image classification based on multi-scale feature fusion[J]. *Laser & Optoelectronics Progress*, 2020, 57(12): 121002.
- [21] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [22] Howard A G, Zhu M L, Chen B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[EB/OL]. (2017-04-17)[2021-10-08]. <https://arxiv.org/abs/1704.04861>.
- [23] 王梅嘉. 基于 Android 平台的苹果叶部病害远程识别系统研究[D]. 杨凌: 西北农林科技大学, 2015.  
Wang M J. Research on remote recognition system of apple leaf diseases based on Andorid platform[D]. Yangling: Northwest A & F University, 2015.
- [24] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]//Proceedings of the 32nd International Conference on Machine Learning, July 6-11, 2015, Lille, France. Massachusetts: PMLR.org, 2015, 37: 448-456.
- [25] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [26] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2021-04-05]. <https://arxiv.org/abs/1409.1556>.
- [27] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, inception-Resnet and the impact of residual connections on learning[C]//Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, February 4-9, 2017, San Francisco, California, USA. Menlo Park: AAAI Press, 2017: 4278-4284.