

doi:10.6041/j.issn.1000-1298.2024.03.027

# 基于 SimAM – ConvNeXt – FL 的茶叶病害小样本分类方法研究

田甜 程志友 鞠薇 张帅

(安徽大学互联网学院, 合肥 230039)

**摘要:**为实现茶叶病害精准分类,针对茶叶病害图像分类中小样本问题及类别分布不均的问题,提出了一种基于迁移学习的 SimAM – ConvNeXt – FL 模型的病害图像分类方法。首先在 ConvNeXt 模型中加入 SimAM 模块,以加强复杂特征的提取。其次针对样本分布不均问题,将 Focal Loss 函数作为训练过程中的损失函数,通过增加数量较少样本的权重来减小样本分布不均的影响。最后使用 SimAM – ConvNeXt – FL 模型对 Plant Village 数据集训练,将训练得到的参数迁移到实测的茶叶病害图像上并进行微调,减少过拟合带来的影响,设置消融实验证明模型改进的有效性,并与不同分类模型(AlexNet、VGG16、ResNet34 模型)分别进行对比实验。实验结果表明,SimAM – ConvNeXt – FL 模型识别效果最佳,准确率达 96.48%,SimAM – ConvNeXt – FL 模型较原 ConvNeXt 模型在茶煤病、茶藻斑病、茶炭疽病、健康叶片和茶白星病的 F1 值分别提高 4.46、3.76、0.43、0.22、5.23 个百分点。结果表明本文提出的模型具有较高的分类准确率与较强的泛化性,可推进茶叶病害分类工作发展。

**关键词:**茶叶病害; 图像分类; 小样本; 迁移学习; ConvNeXt

中图分类号: TP751; TP183 文献标识码: A 文章编号: 1000-1298(2024)03-0275-07

OSID:



## Small Sample Classification of Tea Diseases Based on SimAM – ConvNeXt – FL

TIAN Tian CHENG Zhiyou JU Wei ZHANG Shuai

(School of Internet, Anhui University, Hefei 230039, China)

**Abstract:** In order to realize accurate classification of tea diseases, a disease image classification method based on SimAM – ConvNeXt – FL model of migration learning was proposed to address the small sample problem and uneven distribution of categories in tea disease image classification. Firstly, an SimAM module was added to the ConvNeXt model to enhance the extraction of complex features. Secondly, to address the problem of uneven sample distribution, the Focal Loss function was used as the loss function in the training process, and the effect of uneven sample distribution was reduced by increasing the weights of a smaller number of samples. Finally, the SimAM – ConvNeXt – FL model was used to train the Plant Village dataset, and the parameters obtained from the training were migrated to the measured tea leaf disease images and fine-tuned to reduce the impact of overfitting, and ablation experiments were set up to prove the validity of the model improvement, and comparison experiments were carried out with the different classification models AlexNet, VGG16, and ResNet34 models comparison experiments were conducted respectively. The experimental results showed that the SimAM – ConvNeXt – FL model had the best recognition effect, with an accuracy of 96.48%, and the F1 values of the SimAM – ConvNeXt – FL model compared with the original ConvNeXt model for tea coal disease, tea phoma, tea anthracnose, healthy leaves, and tea white star disease were improved by 4.46 percentage points, 3.76 percentage points, 0.43 percentage points, 0.22 percentage points, and 5.23 percentage points respectively. The results showed that the model proposed had high classification accuracy and strong generalizability, which can promote the development of tea disease classification.

**Key words:** tea disease; image classification; small sample; transfer learning; ConvNeXt

收稿日期: 2023-08-03 修回日期: 2023-11-01

基金项目: 国家自然科学基金项目(61672032)

作者简介: 田甜(1998—),女,硕士生,主要从事深度学习和机器学习等研究,E-mail: y21301044@stu.ahu.edu.cn

通信作者: 鞠薇(1986—),女,讲师,博士,主要从事机器视觉等研究,E-mail: 20029@ahu.edu.cn

## 0 引言

随着全球化贸易的不断加深,茶叶需求量日益增长<sup>[1]</sup>。然而,由于长期暴露于病原菌(如以菌丝体)而引起的茶叶病害在全球范围内导致了重大的产量损失<sup>[2-4]</sup>。茶叶病害早期诊断可减少茶叶产量损失<sup>[5]</sup>,传统的茶园病害检测方法主要依靠目视检查、人工检查和实地抽样,主观且耗时<sup>[3-6]</sup>。机器学习方法已广泛应用于植物叶片病害的分类识别<sup>[7-9]</sup>,主要有支持向量机(Support vector machines, SVM)和反向传播神经网络(Back propagation neural network, BPNN)。SUN等<sup>[10]</sup>采用简单线性迭代聚类(Simple linear iterative cluster, SLIC)算法获取超像素块,借助SVM对超像素块进行分类,对分类后的超像素块进行形态学和代数运算修复,得到了茶树叶片病害图像显著性图。实验结果表明,该方法在视觉效果和质量评价指标上优于其他3种基于简单线性迭代聚类(SLIC)的算法。然而,与传统的机器学习方法相比,深度卷积神经网络(Deep convolutional neural network, DCNN)的准确性较高。目前,深度神经网络已被广泛用于植物叶片的分类和鉴定。孙道宗等<sup>[11]</sup>在YOLO v4的基础上加入MobileNetv2和深度可分离卷积(Depthwise separable convolution, DSC)并引入卷积注意力模块,将改进后的YOLO v4模型与原YOLO v4模型以及其他目标检测模型对茶叶病害识别效果进行对比实验,结果表明改进的YOLO v4模型平均精度达到93.85%。由于茶叶病害图像采集受时间和地点的影响,因此目前采集到的数据集大多为茶叶病害小样本数据集。而深度神经网络模型通常需要大量的标记样本来达到最佳性能,使用小样本训练深度神经网络模型会导致过拟合问题,降低收敛速度<sup>[12-15]</sup>。因此针对小样本数据的算法也被逐渐应用。王艳玲等<sup>[16]</sup>以番茄叶片病害图像为数据集,使用AlexNet网络模型进行基于迁移学习的图像分类。结果表明,该算法平均准确率提高5.6%。

本文提出一种SimAM-ConvNeXt-FL模型。首先对茶叶病害图像进行数据增强扩展;其次将SimAM<sup>[17]</sup>网络融入ConvNeXt<sup>[18]</sup>网络,以提高网络模型的特征辨别能力;然后将训练过程中的损失函数改为Focal Loss<sup>[19]</sup>函数,通过增加数量较少样本的权重来减少样本分布不均的影响;最后基于迁移学习框架,使用SimAM-ConvNeXt-FL模型在Plant Village公开数据集上进行训练,并进行参数微调,以期在样本较少及分布不均场景下实现SimAM-ConvNeXt-FL模型对茶叶病害精准分类。

## 1 数据和方法

### 1.1 茶叶病害图像数据集

#### 1.1.1 自建数据集

本文采集的茶叶病害图像来源区域是福建省南安罗山国有林场( $24^{\circ}50'N, 118^{\circ}16'E$ ),属闽东南山地丘陵地形,如图1所示。林场主要种植铁观音茶叶,每年产量约 $6.5 \times 10^4$  t,在国际出口贸易中,占据全国总量的50%,是当地非常稳定的支柱型产业。茶叶病害图像由佳能相机进行采集。本文采集的茶叶病害包括茶煤病、茶藻斑病、茶炭疽病和茶白星病,并采集健康茶叶作对比,共采集1392幅图像。图2为采集到的茶叶样本图像。每类茶叶图像数量及比例分布情况如表1所示。



图1 罗山国有林场

Fig. 1 Luoshan state owned forest farm



图2 茶叶样本图像

Fig. 2 Images of tea sample

表1 各类茶叶样本图像数量

Tab. 1 Number of tea sample images

病害类型	茶煤病	茶藻斑病	茶炭疽病	健康茶叶	茶白星病
图像数量/幅	111	221	667	300	93
占比/%	7.97	15.88	47.92	21.55	6.68

#### 1.1.2 公开数据集

Plant Village<sup>[20]</sup>数据集包含54 303幅图像,涵盖14种作物,共分为38类。其中包括26种病害叶片以及12种健康叶片。

#### 1.1.3 数据增强

由于采集到的病害图像数据样本较少并且分布不平衡,训练过程容易出现过拟合的趋势,因此本文实验使用数据增强方法,生成新的训练样本,以增加模型的泛化能力。实验使用Python中的数据增强模块Augmentor,采用了剪裁、旋转、亮度变换,并使用高斯模糊变换。数据增强后数据样本共6 960幅,增强图像样本如图3所示。

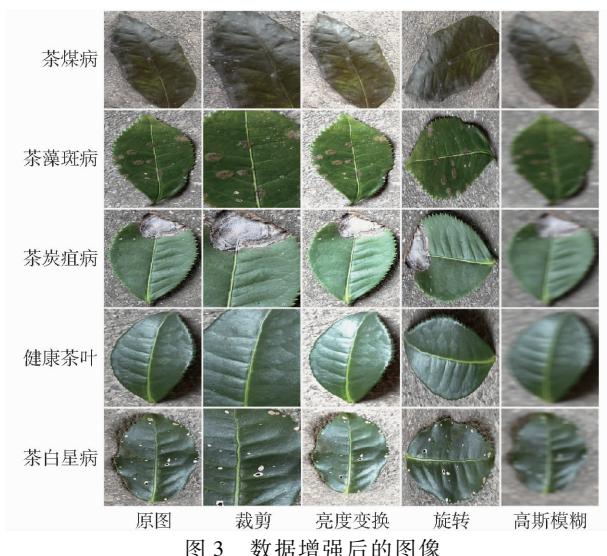


图 3 数据增强后的图像

Fig. 3 Images after data enhancement

## 1.2 实验方法

### 1.2.1 SimAM 网络

SimAM 能够在不向原始模型添加参数的情况下推断出卷积层中特征映射的三维注意力权重,使模型学习更多深层特征。SimAM 通过最小能量函数估计单个神经元的重要性,计算出每个神经元的权重,以测量目标神经元和其他神经元之间的线性可分性。第  $k$  个神经元的最小能量函数  $e_k^*$  计算式为

$$e_k^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t_k - \hat{u})^2 + 2\hat{\sigma}^2 + 2\lambda} \quad (1)$$

式中  $\lambda$ ——正则项

$t_k$ ——输入特征图在单个通道上的第  $k$  个神经元

$\hat{u}$ ——所有神经元在单个通道上的均值

$\hat{\sigma}^2$ ——所有神经元在单个通道上的方差

$e_k^*$  越小表示能量越低,神经元  $k$  与周围神经元区别越大,对视觉处理也越重要。因此,每个神经元重要性可由  $1/e_k^*$  得到。输出特征图  $\tilde{X}$  计算式为

$$\tilde{X} = \text{sigmoid}\left(\frac{1}{E}\right) X \quad (2)$$

式中  $E$ ——所有神经元最小能量函数集合

$X$ ——输入特征图输入值

sigmoid 激活函数的目的是限制  $E$  值。

SimAM 模块如图 4 所示,图中  $C, H, W$  分别为特征图的通道数、高度、宽度,输入特征图经过  $H \times W$  个 SimAM 注意力模块后,通过式(2)计算得到最终的输出特征图。

### 1.2.2 改进的 SimAM - ConvNeXt 网络模型

ConvNeXt 模型是对经典 ResNet 模型进行调整,将 Swin Transformer 模型的一些最新思想引入到

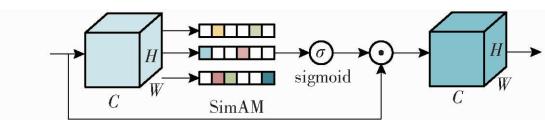


图 4 SimAM 模块

Fig. 4 SimAM module

ResNet 模块中得到的新模型。ConvNeXt Block 中的深度可分离卷积将标准的卷积操作分解为两步:深度卷积和逐点卷积。深度卷积首先对输入的每个通道(深度)进行独立的卷积操作,然后再使用逐点卷积将上一步的结果进行融合。而 SimAM 模块通过对不同位置或通道的特征赋予不同的权重,使网络可以更加关注重要的信息。因此在每个 Block 的深度可分离卷积后加入 SimAM 注意力模块,可以更好 地捕捉输入的空间特征,并且在学习过程中更加关注重要的信息。通过引入 SimAM 网络,模型可以自适应地调整每个位置的感受野,从而提升网络的感知能力和泛化性能,改进后的模型结构如图 5 所示。

### 1.2.3 Focal Loss 函数

茶叶病害图像采集难度大,且各类病害出现的地点及时间不易捕捉,因此本次实验病害图像数据分布极不平衡。针对这一问题,本文将训练的损失函数改为 Focal Loss 函数,最终将改进后的网络模型称为 SimAM - ConvNeXt - FL。Focal Loss 函数是为了解决类别之间存在极端不平衡的问题。它是通过减小数量较多样本的权重和增加数量较少样本的权重来减少类别不平衡的影响。其计算式为

$$F_L(p_t) = -\alpha_t(1-p_t)^\gamma \text{lb} p_t \quad (3)$$

式中  $p_t$ ——模型的预测置信度得分

$\alpha_t$ ——平衡正样本和负样本重要性指标

$\gamma$ ——聚焦参数

$F_L()$ ——Focal Loss 函数

### 1.2.4 基于迁移学习的病害分类模型

深度学习的预测精度是建立在其庞大的数据集训练上的,这一条件经常限制了神经网络的使用,尤其是数据样本较少时,神经网络的效果较差甚至产生过拟合现象。迁移学习通过将源领域中的知识和经验应用到目标领域中来解决数据稀缺、标注成本高和模型泛化能力差等问题,从而加速学习过程和提高学习性能。首先用一个在大型公开数据集上训练过的网络,转移网络内部层的预训练参数到小数据集,对没有转移参数的层训练时进行参数微调<sup>[21]</sup>。

由于茶叶病害数据采集难度大,因此当前没有茶叶病害的大型公开数据集。本文基于迁移学习框架,使用 SimAM - ConvNeXt - FL 模型,首先在 Plant Village 公开数据集上进行训练,然后对最后一层分

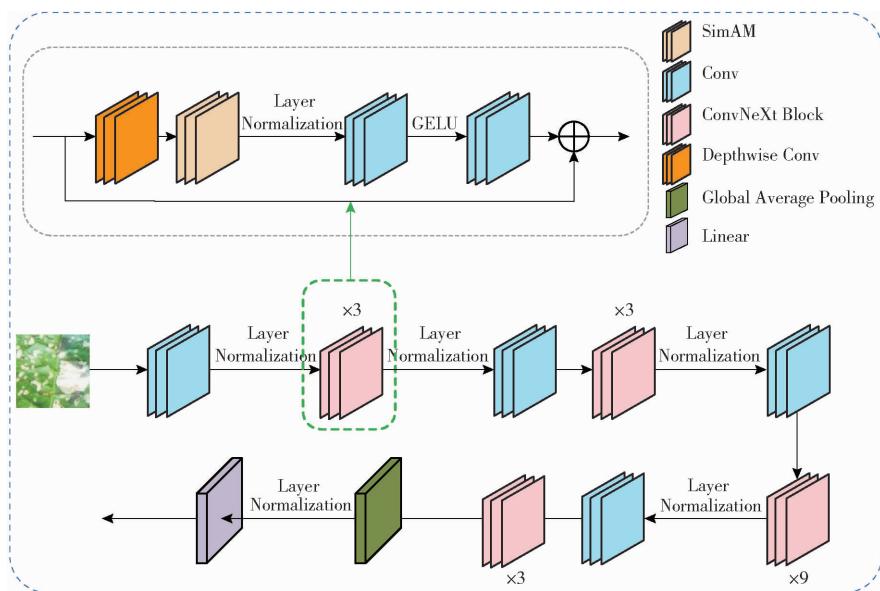
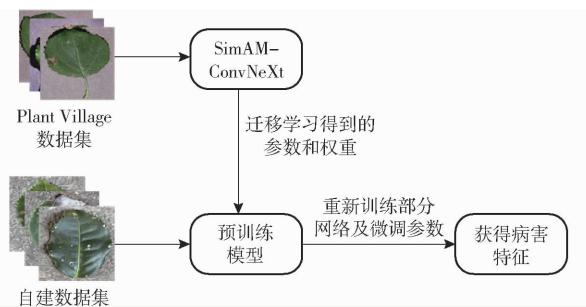


图 5 SimAM - ConvNeXt 模型

Fig. 5 SimAM - ConvNeXt model

类层训练并进行参数微调,同时将剩余初始层的参数冻结为预训练值,提高模型识别准确率。网络迁移过程如图 6 所示。

图 6 网络迁移过程  
Fig. 6 Network migration process

## 2 结果与分析

### 2.1 评价指标

采用准确率和 F1 值作为病害分类的评价指标。

### 2.2 模型学习率调优

学习率作为深度神经网络训练中一个重要的超参数,对网络模型的性能影响很大<sup>[22]</sup>。学习率控制每个参数更新的幅度。如果学习率过大,则更新范围过大,梯度会收敛于最优值之间。如果学习率过低,相应的收敛速度就会过慢,为了得到最优值会消耗更多的时间<sup>[23]</sup>。因此,设置不同学习率对 SimAM - ConvNeXt - FL 模型进行训练,以获得最合适的学习率。

首先将 SimAM - ConvNeXt - FL 模型在 Plant Village 数据集上训练,得到的权重文件迁移到茶叶病害数据集上。然后将茶叶病害数据集以比例 16:4:5 划分为训练集、验证集和测试集。实验使用

学习率分别为 0.01、0.001 和 0.0001, 衰减率为 0.05 的 AdamW 优化器, 训练包括 100 个周期, 使用批量大小(batch size)为 32 的超参数调优。测试集上的实验结果如图 7 所示。由图 7 可知, 当学习率设置为 0.001 时, SimAM - ConvNeXt - FL 模型效果最好。

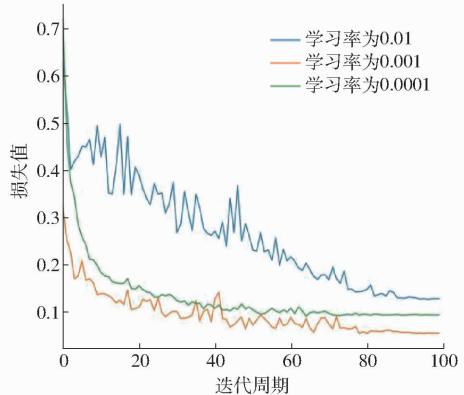
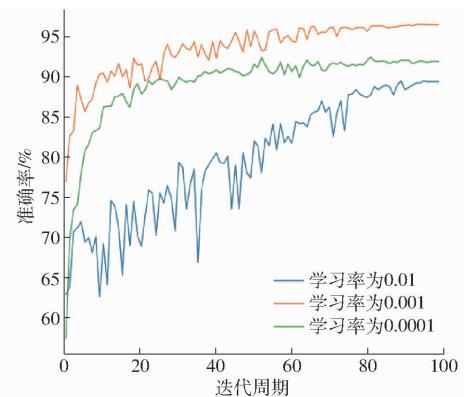


图 7 不同学习率的准确率和损失值曲线

Fig. 7 Accuracy and loss value graphs for different learning rates

### 2.3 消融实验

为了验证改进后的 SimAM - ConvNeXt - FL 模

型性能, 使用 0.001 的学习率分别对 ConvNeXt 模型、SimAM - ConvNeXt 模型和 SimAM - ConvNeXt - FL 模型进行消融实验。实验结果如图 8 及表 2 所示。根据图 8 可得, 3 个模型在 80 个迭代周期左右完全收敛。在测试集中, SimAM - ConvNeXt - FL 的准确率最高, 为 96.48%, SimAM - ConvNeXt 的准确率为 95.83%, ConvNeXt 的准确率最低, 为 94.97%。由表 2 可知 SimAM - ConvNeXt 模型较 ConvNeXt 模型在茶煤病、茶藻斑病、茶炭疽病、健康叶片和茶白星病的 F1 值分别提高 0.84、1.58、0.02、1.68、3.40 个百分点, 证明了在 ConvNext 的 Block 中加入 SimAM 注意力模块, 可以有效提取更多深层特征; 同时, SimAM - ConvNeXt - FL 较 SimAM - ConvNeXt 模型对数量较少的茶煤病、茶藻斑病和茶白星病分类的 F1 值分别提高 3.62、2.18、1.83 个百分点, 而对健康叶片分类的 F1 值降低 1.46 个百分点, 证明了通过使用 Focal Loss 函数, 可以缓解样本分布不均带来的影响, 提高了总体准确度。

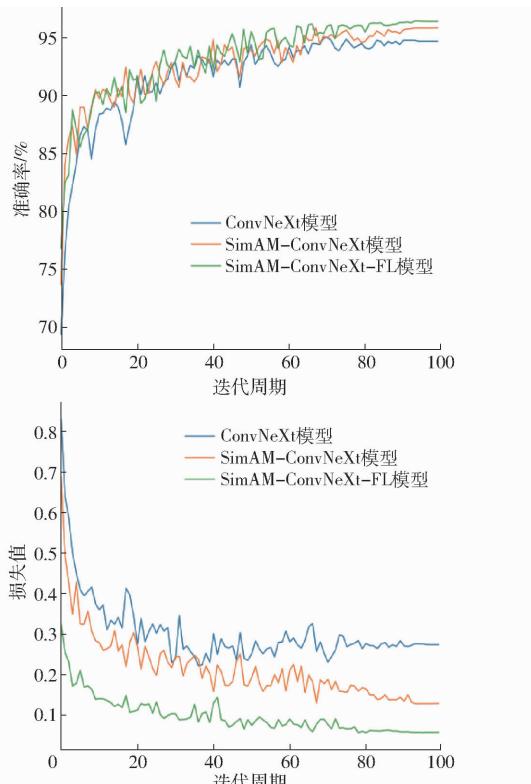


图 8 不同模型的准确率和损失值曲线

Fig. 8 Accuracy and loss value graphs for different models

表 2 不同模型分类 F1 值

Tab. 2 Classification results of different models %

模型	茶煤病	茶藻斑病	茶炭疽病	健康叶片	茶白星病
ConvNeXt	89.76	93.78	97.16	94.60	88.76
SimAM - ConvNeXt	90.60	95.36	97.18	96.28	92.16
SimAM - ConvNeXt - FL	94.22	97.54	97.59	94.82	93.99

## 2.4 模型对比实验

混淆矩阵是评价图像分类结果的有效方法之一<sup>[24]</sup>。为了验证本文改进模型网络性能较之前的经典分类模型 AlexNet、VGG16、ResNet34 得到了提升, 在本文的茶叶病害测试集上分别建立各个模型的混淆矩阵, 结果如图 9 所示。根据图 9a 可得, 茶煤病和茶藻斑病以及茶白星病和茶炭疽病较相似。AlexNet 模型将较多的茶煤病识别为茶藻斑病, 将较多茶白星病识别为茶炭疽病。而 SimAM - ConvNeXt - FL 模型相较于 AlexNet 模型, 将茶煤病识别为茶藻斑病的出错数量由 16 幅降为 2 幅, 茶白星病识别为茶炭疽病的出错数量由 11 幅降为 1 幅, 证明了本文改进模型的性能较好。

为了证明本文模型优于现有分类模型的性能, 在茶叶病害测试集上分别对比了基于 AlexNet、VGG16、ResNet34 经典分类模型的准确率。由表 3 可以看出, 本文改进 SimAM - ConvNeXt - FL 模型准确率最高, 为 96.48%, 分别高于 AlexNet、VGG16、ResNet34 模型 10.06、7.18、3.38 个百分点, SimAM - ConvNeXt 模型较原 ConvNeXt 模型提高 0.86 个百分点, SimAM - ConvNeXt - FL 模型较 SimAM - ConvNeXt 模型提高 0.65 个百分点, 原因是 SimAM 模型提高了通道间特征信息交互, 有效识别更深层的特征信息, 同时使用 Focal Loss 损失函数可以有效缓解样本分布不均的影响。

Grad - CAM 是一种强调输入图像中每个类别识别区域的方法。它可以帮助理解 CNN 的学习过程和可视化内部表征<sup>[25]</sup>。图 10 为 SimAM - ConvNeXt - FL 模型在特征提取过程中利用 Grad - CAM 技术生成的 4 幅可视化特征图。由图 10 可以看出, 前面的 SimAM - Block 块关注了较少病害特征, 直到 Conv4\_x 网络层, 堆叠了 15 个 SimAM - Block, 提取病害特征逐渐明显。这是因为所有 SimAM - ConvNeXt - FL 模型的 Block 块都加入了 SimAM 注意力, 随着 Block 块的增加, 提取病害特征的能力随之增加。因此整个模型的性能得到提升。但随机场景下图像也存在更多的非病害特征干扰, 因此后续需要对网络进行深入改进以适应各种背景。

## 3 结论

(1) 通过 ConvNeXt、SimAM - ConvNeXt 和 SimAM - ConvNeXt - FL 3 种模型的消融实验可以看出, SimAM - ConvNeXt 模型比 ConvNeXt 模型准确率提高 0.86 个百分点, SimAM - ConvNeXt - FL 模型比 SimAM - ConvNeXt 模型提高 0.65 个百分点。

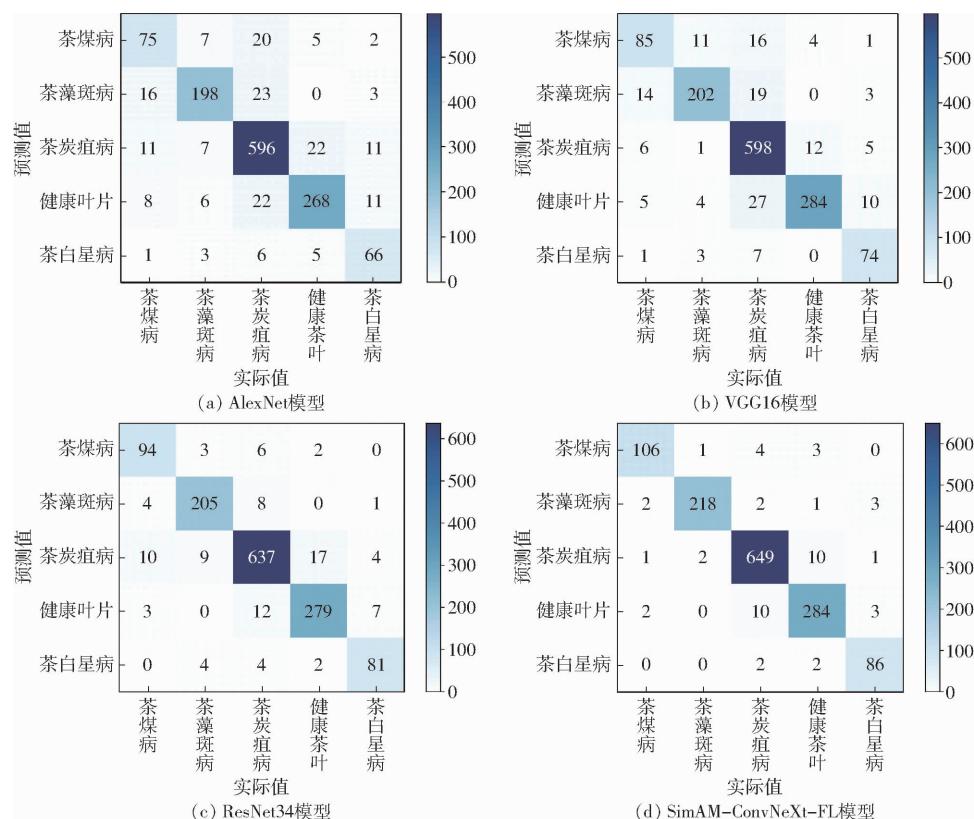


图 9 不同模型的混淆矩阵

Fig. 9 Confusion matrices for different models

表 3 不同训练网络下的评价结果

Tab. 3 Evaluation results of different training networks

模型	测试集准确率				
	%				
AlexNet	86.42				
VGG16	89.30				
ResNet34	93.10				
ConvNeXt	94.97				
SimAM - ConvNeXt	95.83				
SimAM - ConvNeXt - FL	96.48				

证明加入 SimAM 模块对特征通道间的关系进行建模,能够有效提高 ConvNeXt 模型对病害特征的识别准确率;并且利用 Focal Loss 函数缓解样本分布不均的问题。

(2)通过与 AlexNet、VGG16、ResNet34 分类模型的混淆矩阵及准确率对比,本文提出的 SimAM - ConvNeXt - FL 模型极大地改善了样本类别之间易混淆的问题,准确率较 AlexNet、VGG16、ResNet34

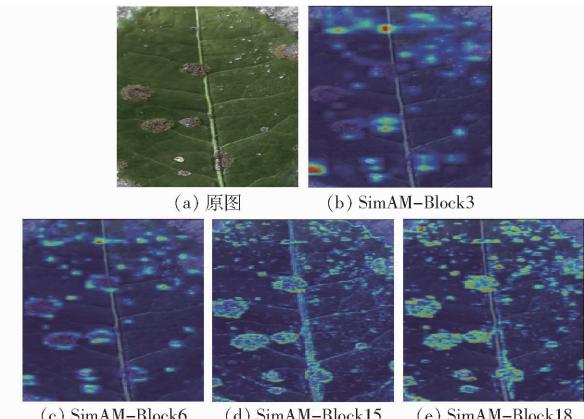


图 10 不同网络位置的特征提取图

Fig. 10 Feature extraction plots for different network locations

模型分别增长 10.06、7.18、3.38 个百分点;由 Grad - CAM 技术生成的可视化特征图说明了模型提取病害特征能力得到提升,证明了 SimAM - ConvNeXt - FL 模型具有较优性能。

## 参 考 文 献

- [1] TRUONG V L, JEONG W S. Antioxidant and anti-inflammatory roles of tea polyphenols in inflammatory bowel diseases [J]. Food Science and Human Wellness, 2022, 11(3): 502 - 511.
- [2] XIE S, WANG C, WANG C, et al. Online identification method of tea diseases in complex natural environments [J]. IEEE Open Journal of the Computer Society, 2023, 4: 62 - 71.
- [3] ZOU X, REN Q, CAO H, et al. Identification of tea diseases based on spectral reflectance and machine learning [J]. Journal of Information Processing Systems, 2020, 16(2): 435 - 446.

- [4] HU G, WU H, ZHANG Y, et al. A low shot learning method for tea leaf's disease identification[J]. Computers and Electronics in Agriculture, 2019, 163: 104852.
- [5] MUKHOPADHYAY S, PAUL M, PAL R, et al. Tea leaf disease detection using multi-objective image segmentation[J]. Multimedia Tools and Applications, 2021, 80: 753–771.
- [6] 李书琴, 陈聪, 朱彤, 等. 基于轻量级残差网络的植物叶片病害识别[J]. 农业机械学报, 2022, 53(3): 243–250.  
LI Shuqin, CHEN Cong, ZHU Tong, et al. Plant leaf disease identification based on light weight residual network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 243–250. (in Chinese)
- [7] DEEPA N R, NAGARAJAN N. Kuan noise filter with Hough transformation based reweighted linear program boost classification for plant leaf disease detection[J]. Journal of Ambient Intelligence and Humanized Computing, 2021, 12: 5979–5992.
- [8] VALLABHAJOSYULA S, SISTLA V, KOLLI V K K. Transfer learning-based deep ensemble neural network for plant leaf disease detection[J]. Journal of Plant Diseases and Protection, 2022, 129(3): 545–558.
- [9] HARAKANNANAVAR S S, RUDAGI J M, PURANIKMATH V I, et al. Plant leaf disease detection using computer vision and machine learning algorithms[J]. Global Transitions Proceedings, 2022, 3(1): 305–310.
- [10] SUN Y, JIANG Z, ZHANG L, et al. SLIC\_SVM based leaf diseases saliency map extraction of tea plant[J]. Computers and Electronics in Agriculture, 2019, 157: 102–109.
- [11] 孙道宗, 刘欢, 刘锦源, 等. 基于改进 YOLO v4 模型的茶叶病害识别[J]. 西北农林科技大学学报(自然科学版), 2023, 51(9): 145–154.  
SUN Daozong, LIU Huan, LIU Jinyuan, et al. Recognition of tea diseases based on improved YOLO v4 model[J]. Journal of Northwest A&F University(Natural Science Edition), 2023, 51(9): 145–154. (in Chinese)
- [12] WANG P, FAN E, WANG P. Comparative analysis of image classification algorithms based on traditional machine learning and deep learning[J]. Pattern Recognition Letters, 2021, 141: 61–67.
- [13] 李子茂, 徐杰, 郑禄, 等. 基于改进 DenseNet 的茶叶病害小样本识别方法[J]. 农业工程学报, 2022, 38(10): 182–190.  
LI Zimao, XU Jie, ZHENG Lu, et al. Small sample recognition method of tea disease based on improved DenseNet [J]. Transactions of the CSAE, 2022, 38(10): 182–190. (in Chinese)
- [14] TIAN B. Transfer learning based recognition algorithm for common tea disease[C]//Proceedings of the 2nd International Symposium on Artificial Intelligence for Medicine Sciences, 2021: 361–365.
- [15] ATTALLAH O. Tomato leaf disease classification via compact convolutional neural networks with transfer learning and feature selection[J]. Horticulturae, 2023, 9(2): 149.
- [16] 王艳玲, 张宏立, 刘庆飞, 等. 基于迁移学习的番茄叶片病害图像分类[J]. 中国农业大学学报, 2019, 24(6): 124–130.  
WANG Yanling, ZHANG Hongli, LIU Qingfei, et al. Classification of crop diseases based on convolutional neural network [J]. Journal of China Agricultural University, 2019, 24(6): 124–130. (in Chinese)
- [17] YANG L, ZHANG R Y, LI L, et al. Simam: a simple, parameter-free attention module for convolutional neural networks[C]//International Conference on Machine Learning. PMLR, 2021: 11863–11874.
- [18] LIU Z, MAO H, WU C Y, et al. A convnet for the 2020s[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 11976–11986.
- [19] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980–2988.
- [20] MOHAMETH F, BINGCAI C, SADA K A. Plant disease detection with deep learning and feature extraction using Plant Village[J]. Journal of Computer and Communications, 2020, 8(6): 10–22.
- [21] MAQSOOD M, NAZIR F, KHAN U, et al. Transfer learning assisted classification and detection of Alzheimer's disease stages using 3D MRI scans[J]. Sensors, 2019, 19(11): 2645.
- [22] TANG S, ZHU Y, YUAN S. An improved convolutional neural network with an adaptable learning rate towards multi-signal fault diagnosis of hydraulic piston pump[J]. Advanced Engineering Informatics, 2021, 50: 101406.
- [23] YANG L, WANG C. Emotion model of associative memory possessing variable learning rates with time delay [J]. Neurocomputing, 2021, 460: 117–125.
- [24] ALI K, SHAIKH Z A, KHAN A A, et al. Multiclass skin cancer classification using EfficientNets—a first step towards preventing skin cancer[J]. Neuroscience Informatics, 2022, 2(4): 100034.
- [25] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 618–626.