

doi:10.6041/j. issn. 1000-1298. 2023. 04. 030

基于改进 ResNet18 的苹果叶部病害多分类算法研究

姜红花¹ 杨祥海¹ 丁睿柔¹ 王东伟² 毛文华³ 乔永亮⁴

(1. 山东农业大学信息科学与工程学院, 泰安 271018; 2. 青岛农业大学机电工程学院, 青岛 266109;

3. 中国农业机械化科学研究院集团有限公司, 北京 100083; 4. 悉尼大学工学院, 悉尼 2006)

摘要: 针对传统苹果叶部病害分类方法精准性差、效率低等问题, 提出了一种基于改进 ResNet18 的苹果叶部病害多分类算法。通过在原始 ResNet18 网络的基础上增加通道与空间注意力机制分支, 强化网络对叶部病害区域的特征提取能力, 提高病害的识别精度和实时性。为更好地引导网络学习到零散分布的病害斑点的特征, 引入特征图随机裁剪分支, 不仅实现有限样本空间的扩充, 还进一步优化网络结构, 提高训练速度。试验以苹果 5 类常见的叶部病害(黑星病、黑腐病、雪松锈病、灰斑病、白粉病)为主要研究对象, 并与主流分类算法模型进行对比。试验结果表明, 所提 ResNet18 - CBAM - RC1 模型病害分类准确率可达 98.25%, 高于 ResNet18 (93.19%) 和 VGG16 (96.13%), 能够有效提取叶片病害特征, 增强对多类病害的识别, 提高识别准确率。此外, 模型内存占用量仅为 37.44 MB, 单幅图像推理时间为 9.11 ms, 可满足嵌入式设备上果园病害识别的实时性要求。

关键词: 苹果叶部病害; ResNet18; 注意力机制; 随机裁剪; 深度学习

中图分类号: TP181 文献标识码: A 文章编号: 1000-1298(2023)04-0295-09

OSID:



Identification of Apple Leaf Diseases Based on Improved ResNet18

JIANG Honghua¹ YANG Xianghai¹ DING Ruirou¹ WANG Dongwei² MAO Wenhua³ QIAO Yongliang⁴

(1. College of Information Science and Engineering, Shandong Agricultural University, Taian 271018, China

2. College of Mechanical and Electrical Engineering, Qingdao Agricultural University, Qingdao 266109, China

3. Chinese Academy of Agricultural Mechanization Sciences Group Co., Ltd., Beijing 100083, China

4. Faculty of Engineering, The University of Sydney, Sydney 2006, Australia)

Abstract: Aiming at the problem that the traditional apple leaf disease classification method has poor accuracy and low efficiency, which affects prevention and cure effect, an improved ResNet18 algorithm was proposed. By adding the branch of channel and spatial attention mechanism to the original ResNet18, the feature extraction ability of the network for leaf disease regions was strengthened to improve the disease recognition accuracy and real-time performance. In addition, to better guide the network to learn the features of sporadically distributed disease spots, the feature map random cropping branch was introduced, which not only achieved the expansion of the limited sample space, but also further optimized the network structure and improved the training speed. The experiment was conducted with five common types of apple foliar diseases (black star, black rot, cedar rust, gray spot, and powdery mildew) as the main research objects and compared with the mainstream classification algorithm models for analysis. The experimental results showed that the disease classification accuracy of the proposed ResNet18 - CBAM - RC1 model can reach 98.25%, which was higher than that of ResNet18 (93.19%) and VGG16 (96.13%), and can effectively extract leaf disease features, enhance the recognition of multiple types of diseases, and improve the real-time recognition capability and accuracy. In addition, the model size was only 37.44 MB and the inference time of a single image was 9.11 ms, which can meet the real-time requirements of orchard disease recognition on embedded devices and provide information support for disease prevention and control in digital orchards.

Key words: apple leaf diseases; ResNet18; attention mechanism; random clipping; deep learning

收稿日期: 2022-08-03 修回日期: 2022-09-23

基金项目: 山东省农业重大应用技术创新项目(SD2019NJ001)和山东省重大科技创新工程项目(2019JZZY010716)

作者简介: 姜红花(1971—), 女, 教授, 主要从事物联网与自动控制研究, E-mail: j_honghua@sda.edu.cn

通信作者: 乔永亮(1988—), 男, 副研究员, 博士, 主要从事农业机器人、人工智能和智能检测研究, E-mail: y.qiao@acfr.usyd.edu.au

0 引言

中国是世界最大的苹果生产区,苹果产量位居世界第一^[1]。然而,苹果病害频发带来的减产问题制约我国苹果产业的发展^[2]。目前,我国苹果病害诊断方法大多为以果农和专家经验为主,虽然较为通用,但在可靠性和时效性方面有所欠缺,难以满足苹果病害防治的需要^[3]。随着信息技术的发展,以机器视觉和深度学习为基础的病害识别方法已逐渐成为苹果病害识别的研究方向。

早期病害图像分类以传统机器学习为主,经过图像预处理、图像分割和特征(人为选择和设计的特征)提取后,再通过特定的机器学习算法(如BP神经网络和支持向量机等)训练其对特定特征向量的分类能力,从而达到识别病害图像的目的^[4-6]。ZHANG等^[7]利用HSI(色调、饱和度和强度)、YUV和灰度模型提取颜色、纹理和形状等38个特征,利用支持向量机分类器对苹果白粉病、花叶病和锈病等3种病害进行判别,识别准确率达到90%以上。魏丽冉等^[8]通过在Lab彩色空间模型下的分量a、b进行叶片分割并提取特征,然后采用K均值聚类方法增强分割聚类效果,最后采用基于核函数的支持向量机对4种病害进行检测识别分类,识别准确率达89.5%。司永胜等^[9]使用遗传算法优化的支持向量机对苹果苦痘病和碰伤进行识别,总体识别准确率高于93%。然而早期机器学习识别方法需要研究者掌握充分的相关领域知识,对试验条件有较为严格的要求,需要经过复杂的特征选取与设计工作,普适性较低,较难进行有效推广和应用。

深度学习以人工神经网络作为载体,通过无监督学习逐层训练,使用有监督反向传播算法进行调优,提高了识别精度^[10-12]。与机器学习相比,深度学习采用自监督方式完成特征向量学习,无需人工干涉,解决了人为设计变量特征带来的复杂试验成本问题,克服了机器学习方法受限于专业知识的弊端;另一方面,深度学习实现了特征提取与分类的一体化,消除了机器学习方法分阶段式组合训练带来的时间开销,便于改进优化^[13-15]。鲍文霞等^[16]利用选择性核卷积模块和平均池化层改造VGG16网络,对苹果叶部病斑进行识别,准确率达到94.70%。张善文等^[17]使用全局池化层改进深度卷积神经网络,并通过添加规则项改进Softmax分类器,对5种苹果病害分类准确率达95%以上。于雪莹等^[18]针对苹果病斑区域小易受背景干扰的问题,提出了一种基于混合注意力机制的残差网络,通过在残差网络中嵌入串联的通道注意力模块和空间注

意力模块,最终模型识别准确率高达95.5%。王细萍等^[19]基于卷积网络和时变冲量学习提出了苹果病变图像识别的方法,对病变类别分类准确率高达97.45%。然而,上述研究提出的病害识别模型复杂,参数多,实时性差,且在复杂苹果叶部病害背景下,识别表现不稳定,难以推广使用。

ResNet系列网络能实现训练速度和网络深度的平衡,尤其是具有代表性的ResNet18,网络层数适中,收敛速度快,在分类等任务中应用广泛。针对苹果病害分类任务规模相对较小且实时性要求高的需求,本文选用ResNet18作为骨干网络,在保证病害特征提取能力的同时使网络有较快的训练和推理速度。另外,针对苹果叶部病害病斑区域小且零星分散问题,引入通道注意力与空间注意力模块来加强网络对苹果叶部病害病斑区域的注意力,有效提取不同发病程度及发病面积的叶片病害特征,提高识别准确率。与此同时,为提升模型识别实时性,减少训练参数,提升训练速度,引入随机裁剪分支来进一步优化网络,增强网络对病害区域的表征能力。

1 材料和方法

1.1 试验材料

以黑星病、黑腐病、雪松锈病、灰斑病和白粉病5类常见苹果叶部病害为研究对象。考虑到5种病害发病时间差异性,分别于2020年9—11月、2021年6—11月在山东农业大学南校国家苹果示范基地、山东农业大学本部和山东省果树研究所共实地采集3 000幅苹果叶病害图像。与此同时,为丰富数据集,来自PlantVillage公开苹果数据集的1 479幅图像也用于本试验。5种苹果叶部病害图像示例如图1所示。



图1 苹果叶部病害种类

Fig. 1 Image example of apple leaf disease

1.2 苹果叶部病害分类模型

本研究所提的改进型ResNet18,主要包含三大模块:①ResNet18作为骨干网络模块,负责特征提取和信息传递。②通道注意力与空间注意力模块来加强网络对苹果叶部病害病斑区域的注意力。③随机裁剪分支模块,可减少训练参数、优化网络。

1.2.1 ResNet18骨干网络

为保证苹果病害分类任务的高准确率和实时

性,选取网络层数适中,收敛速度快,能够平衡训练速度和网络深度的 ResNet18 作为骨干网络,在保证病害特征提取能力的同时使网络有较快的训练速度和推理速度。ResNet18 骨干网络结构图如图 2 所示,输入网络为一幅 256×256 的三通道 RGB 图像,输出为 5,对应 5 种苹果叶部病害类别。苹果叶部

病害图经卷积层进行特征提取和降采样后得到一个 $N \times 5 \times 8 \times 8$ (N 为一个 mini-batch 尺寸) 大小的特征图。随后,通过一个尺寸为 8×8 的自适应平均池化层,将特征图继续降采样为 $N \times 5 \times 1 \times 1$,最后将该提取到的病害特征输入 Softmax 分类器计算病害类别预测概率。ResNet18 网络结构参数如表 1 所示。

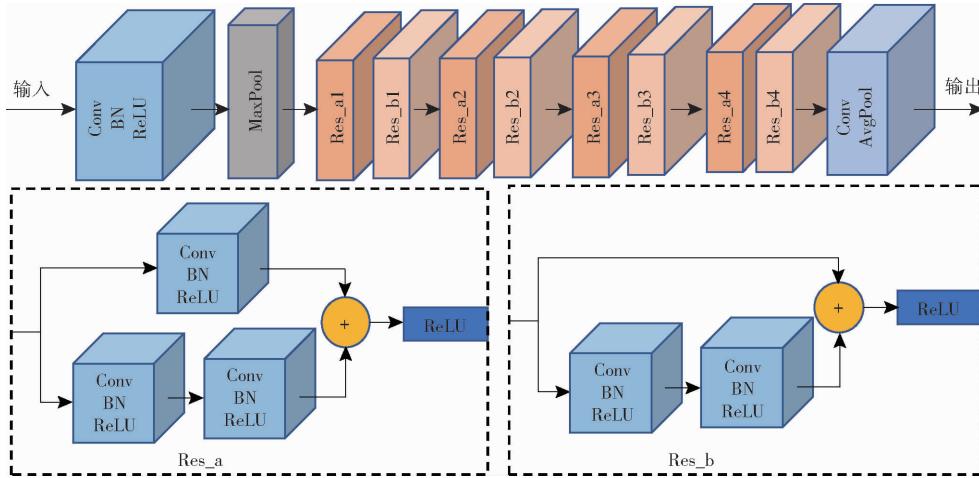


图 2 ResNet18 骨干网络

Fig. 2 ResNet18 backbone network

表 1 ResNet18 网络结构参数

Tab. 1 ResNet18 network structure parameters

层类型	输出尺寸
Convolution	$64 \times 128 \times 128$
MaxPool	$64 \times 64 \times 64$
Res_a1	$64 \times 64 \times 64$
Res_b1	$64 \times 64 \times 64$
Res_a2	$128 \times 32 \times 32$
Res_b2	$128 \times 32 \times 32$
Res_a3	$256 \times 16 \times 16$
Res_b3	$256 \times 16 \times 16$
Res_a4	$512 \times 8 \times 8$
Res_b4	$512 \times 8 \times 8$
ConvAvgPool	$5 \times 1 \times 1$

1.2.2 通道与空间注意力机制模块

针对苹果叶部病害病斑在整张叶片上分散且区域小的问题,在 ResNet18 骨干网络基础上,引入了通道注意力与空间注意力模块来加强网络对苹果叶部病害病斑区域的注意力,有效提取不同发病程度及发病面积的叶片病害特征,提高识别准确率。注意力机制采用 WOO 等^[20]提出的 CBAM 注意力机制模块。CBAM 是一个轻量级注意力模块,由通道注意力与空间注意力两部分组成,几乎能够嵌入到任何一个卷积神经网络中,不仅引入的运算量和参数量近似可忽略不计,还可大幅提高模型性能^[21~22]。针对苹果叶部病斑区域大小不一,CBAM 注意力机制关注的是叶片图像中对病害识别有意义的特征部分^[23]。

CBAM 的通道注意力部分通过全局最大池化和全局平均池化两种方式来获取不同的苹果叶片病害特征信息。针对输入 $C \times H \times W$ 的特征,先分别进行全局最大池化和全局平均池化得到 2 个 $C \times 1 \times 1$ 的通道描述,接着再将 2 个特征图输入 1 个 2 层的神经网络,2 个特征图共享这个两层神经网络。然后对这两个特征图相加得到的新特征图,经过一个 Sigmoid 激活函数之后得到通道权重系数,最后再将通道权重系数与模块的输入特征相乘即可得到缩放后的苹果叶片图像新特征作为空间注意力模块的输入特征。

CBAM 的空间注意力部分输入是通道注意力模块的输出特征。然后进行一个通道维度的最大池化和平均池化得到两个 $1 \times H \times W$ 的空间描述,再将 2 个描述按照通道拼接在一起,经过一个 7×7 的卷积层和一个 Sigmoid 激活函数得到空间权重系数,最后将空间权重系数与其输入特征相乘得到缩放后苹果叶片图像的新特征,新特征局部细节更加丰富。

通道注意力和空间注意力可以通过并联或者串联顺序的方式组合在一起,但是发现串联顺序组合并且将通道注意力模块放在空间注意力模块之前可以取得更好的效果,图 3 为通道注意力在前,空间注意力在后的串联顺序组合方式。

1.2.3 随机裁剪分支模块

为增强对不同病斑位置、大小和不同病害程度的特征提取能力,引入随机裁剪分支进一步优化网

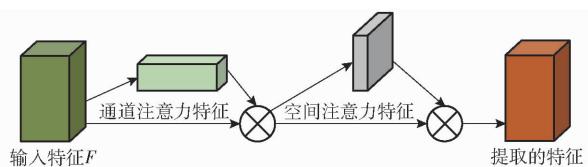


图 3 通道注意力与空间注意力在 CNN 中的连接方式

Fig. 3 Connection mode of channel attention and spatial attention in CNN

络,增强网络对病害区域的表征能力,提升模型识别实时性,减少训练参数,提高训练速度。

苹果叶部病害局部特征可以表示整幅图像的病害类别,且这些局部特征分布于图像的不同位置,因此可以随机选取一块中间特征来分类。这样不仅能够进行数据集增广,扩充样本,还可更好地引导网络学习到零散分布的病害斑点特征。

本研究设计的随机裁剪分支直接嵌入骨干网络中,并对骨干网络提取的中间特征进行随机裁剪。随机裁剪分支由 2 个 Conv - BN - ReLU 和 1 个自适应平均池化层组成,前向运算时从前一层提取到的特征图中随机裁剪一个大小 $s \times s$ 苹果叶片图像的特征块并输入网络模块。

1.2.4 融合注意力机制与随机裁剪分支

为提高苹果叶部病害的识别准确率,将注意力

机制与随机裁剪分支融合到 ResNet18 网络。

为更好地利用不同层次的特征信息,在 ResNet18 骨干网络中嵌入 2 个特征图随机裁剪分支,2 个分支分别接在 Res_a2 和 Res_a3 之后得到 ResNet18 - RC, 分别用于随机裁剪苹果叶片图像浅层和深层特征。2 个分支裁剪得到的特征经全局池化之后同网络最后输出的特征进行求和,最后输入 1 个卷积层进行预测。由于 Res_a2 和 Res_a3 的特征图尺寸分别为 64×64 和 32×32 , 所以随机裁剪分支设置 24×24 和 12×12 两个裁剪尺寸。此外,为了使两个分支输出的特征图能够同骨干网络输出的特征图相加,其输出特征图通道数都与骨干网络进行了统一。两个分支的输入通道数分别为 128 和 256,而输出通道数都为 512。

CBAM 注意力机制的添加有两种不同策略,不同添加位置会导致网络所提取到的叶部病害特征有一定的差异性。如果在每两个残差块之后接一个 CBAM 模块可得到 ResNet18 - CBAM - RC1 网络模型,其网络结构及其参数如图 4 所示;直接在 ResNet18 网络最后一个卷积层之前放置 CBAM 模块可得到 ResNet18 - CBAM - RC2 网络模型,其网络结构及其输出特征维度如图 5 所示。

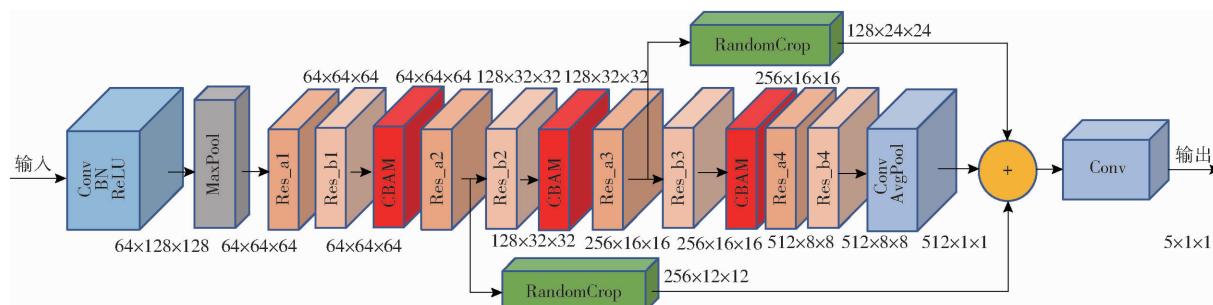


图 4 ResNet18 - CBAM - RC1 网络结构

Fig. 4 ResNet18 - CBAM - RC1 network structure

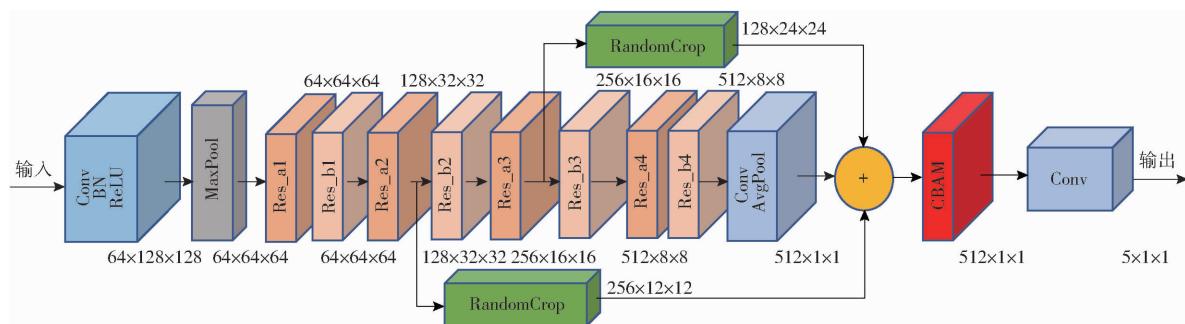


图 5 ResNet18 - CBAM - RC2 网络结构

Fig. 5 ResNet18 - CBAM - RC2 network structure

2 基于改进 ResNet18 的苹果叶部病害分类试验

2.1 试验数据集

苹果叶部病害图像共 4 479 幅,随机选择 3 479

幅图像(776 幅黑星病,789 幅黑腐病,776 幅雪松锈病,817 幅白粉病,321 幅灰斑病)作为训练集,剩余 1 000 幅图像(224 幅黑星病,211 幅黑腐病,224 幅雪松锈病,235 幅白粉病,106 幅灰斑病)作为测试集。图像输入网络之前统一缩放到 256 像素 ×

256 像素, 像素归一化到 0~1 之间, 并进行均值为 0.5、标准差为 0.5 的标准化操作。

2.2 试验平台及训练参数

本研究训练所用工具包版本和硬件环境参数为 PyTorch 1.5.0, CUDA 11.2, Python 3.6, 系统为 Windows 10 专业版, GPU 为 NVIDIA GTX1080Ti, 显卡内存 11 GB, CPU 为 i7-1170。

为了验证改进方法的有效性, 将所提苹果叶部病害分类算法与其他主流网络模型进行对比测试。试验中 6 个对比模型分别为: VGG16、ResNet18、骨干网络为 ResNet18 且添加了 CBAM 注意力机制的 ResNet18-CBAM 模型、骨干网络为 ResNet18 且添加了随机裁剪分支的 ResNet18-RC 模型, 以及两种骨干网络为 ResNet18 且同时添加 CBAM 注意力机制与随机裁剪的 ResNet18-CBAM-RC1 和 ResNet18-CBAM-RC2。各分类模型在训练时除了网络结构不同外, 训练数据集、预处理等皆保持一致。所有分类模型皆采用随机梯度下降法 SGD 优化器进行优化, 动量取 0.9, 权重衰减系数设置为 0.0005。网络训练初始学习率为 0.01, 且每训练 100 000 步将学习率降低为原来的 1/10, 设定最大训练步数为 200 000。

苹果叶部病害分类任务使用与 Softmax 等分类器结合的损失函数——交叉熵损失函数。与 SVM 分类器不同, Softmax 分类器并非直接对图像类别打分, 而是给每个类别估算出一个概率, 即预测输入图像属于每个类别的概率, 作用就是将每个类别所对应的输出分量归一化, 使各个分量的和为 1。Softmax 的概率计算式为

$$S_i = \frac{e^{y_i}}{\sum_{j=1}^C e^{y_j}} \quad (1)$$

式中 S_i —Softmax 概率函数

y_i —目标属于第 i 类的真实概率

C —总类别数

交叉熵损失函数是图像分类(包括像素级分类, 如语义分割、关键点检测等)中最常使用的一种损失函数, 其计算公式为

$$L_c = - \sum_{i=1}^K y_i \lg p_i \quad (2)$$

式中 L_c —交叉熵损失函数

K —总类别数

p_i —网络预测的目标属于类别 i 的概率

2.3 评价指标

试验在分类测试图像上分别测试模型在各类别上的准确率 A_{cc} 、召回率 R 、精度 P 、F1 值、单幅图像

推理时间和模型内存占用量。

3 试验结果分析

3.1 损失函数

在训练期间各网络损失曲线情况如图 6 所示。

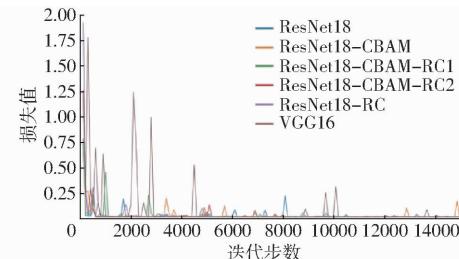


图 6 各分类模型在训练期间的损失曲线

Fig. 6 Training loss curves of each classification model

由图 6 可知, 骨干网络为 ResNet18 的模型相对更加稳定一些, 且添加了 CBAM 模块和随机裁剪分支的模型在训练期间表现更好。而 VGG16 相较于其他网络更加不稳定, 不仅有较大的损失, 震荡幅度也较大, 直到 10 000 步之后才开始稳定。

3.2 不同算法模型对比

不同苹果叶部病害分类模型的结果及平均单幅图像的推理时间如表 2 所示。

表 2 不同模型评估标准对比

Tab. 2 Comparison of evaluation criteria of different models

模型	召回率/%	精度/%	准确率/%	F1 值/%	时间/ms	模型内存占用量/MB
VGG16	96.13	96.24	96.13	96.08	7.21	128.68
ResNet18	93.19	93.37	93.19	93.21	6.82	24.77
ResNet18-CBAM	95.23	95.15	95.23	95.16	9.18	25.89
ResNet18-RC	97.34	97.28	97.34	97.28	7.01	37.19
ResNet18-CBAM-RC1	98.25	98.52	98.25	98.32	9.11	37.44
ResNet18-CBAM-RC2	97.69	97.62	97.69	97.65	8.01	38.13

从表 2 可以看出, 所提出的在 ResNet18 中添加 CBAM 和随机裁剪 ResNet18-CBAM-RC1 和 ResNet18-CBAM-RC2 模型, 对苹果叶部病害的分类精度分别为 98.52% 和 97.62%, 优于原始的 ResNet18 (93.73%)。与此同时, 也可以发现 ResNet18-RC 的准确率比 ResNet18-CBAM 高 2.11 个百分点, 这是由于 ResNet18-RC 网络的随机裁剪部分既能使网络将注意力放到叶部的病斑特征上, 还能起到随机数据集增广的效果, 因此总体上能更好提取叶部病害的相关特征, 从而提升模型的病害分类效果。

将 CBAM 模块和随机裁剪分支结合的两种网

络都比只有 1 种模块的准确率高,且 ResNet18 – CBAM – RC1(CBAM 模块放在每两个残差块之后)的苹果叶部病害分类的精度和召回率分别为 98.52% 和 98.25%,都高于 ResNet18 – CBAM – RC2。本文苹果叶部病害分类对比试验中,所提出的 ResNet18 – CBAM – RC1 和 ResNet18 – CBAM – RC2 模型内存占用量也都低于 40 MB,准确率都高于 VGG16、ResNet18 和 ResNet18 – CBAM,且单幅图像推理时间也比 ResNet18 – CBAM 少。上述结果进一步表明,所提苹果叶部病害分类模型具有轻量化、实时性强且容易在嵌入式设备上部署的优点。

为进一步研究模型对不同病害的分类差异,各类型样本的分类召回率、精度和 F1 值如表 3 所示。

表 3 不同模型召回率、精度和 F1 值对比

Tab. 3 Comparison of recall, precision and F1 values of different models

病害	模型	召回率	精度	F1 值
黑星病	VGG16	94.67	95.89	95.28
	ResNet18	93.89	97.92	95.86
	ResNet18 – CBAM	96.04	96.31	96.17
	ResNet18 – RC	98.11	98.12	98.11
	ResNet18 – CBAM – RC1	100	100	100
	ResNet18 – CBAM – RC2	97.63	98.52	98.07
黑腐病	VGG16	100	96.22	98.07
	ResNet18	82.32	87.23	84.70
	ResNet18 – CBAM	94.15	88.19	91.07
	ResNet18 – RC	91.88	95.83	93.81
	ResNet18 – CBAM – RC1	100	92.59	96.15
	ResNet18 – CBAM – RC2	94.29	95.38	94.83
雪松锈病	VGG16	90.08	100	94.78
	ResNet18	100	98.04	99.01
	ResNet18 – CBAM	97.96	100	98.97
	ResNet18 – RC	100	100	100
	ResNet18 – CBAM – RC1	100	100	100
	ResNet18 – CBAM – RC2	100	100	100
灰斑病	VGG16	97.83	100	98.90
	ResNet18	92.21	83.64	87.72
	ResNet18 – CBAM	90.10	93.75	91.89
	ResNet18 – RC	98.32	92.45	95.29
	ResNet18 – CBAM – RC1	91.26	100	95.43
	ResNet18 – CBAM – RC2	98.33	94.20	96.22
白粉病	VGG16	98.07	89.11	93.38
	ResNet18	97.53	100	98.75
	ResNet18 – CBAM	97.92	97.50	97.71
	ResNet18 – RC	98.40	100	99.19
	ResNet18 – CBAM – RC1	100	100	100
	ResNet18 – CBAM – RC2	98.22	100	99.10

从叶部病害识别类别上看,所提模型 ResNet18 – CBAM – RC1 对黑星病、黑腐病、雪松锈病和白粉病

的分类精度都高于 90%,特别是对部分病害如黑星病、雪松锈病和白粉病的分类精度达到 100%。灰斑病的分类召回率为最低,可能是由于灰斑病的外在视觉特征不明显导致的。另外,在训练集中灰斑病样本的数量不到其他类别的一半,且有些灰斑病被错分成了黑腐病,进而导致大部分模型在黑腐病上的精度略低于其他类别。

总体上看,ResNet18 – CBAM – RC1 除了在灰斑病上的分类召回率较低之外,在其他病害类别上的召回率都较高。所改进的 ResNet18 – CBAM – RC1 有效提升了病害分类的准确性,为精准病害控制提供了关键信息支撑。

3.3 分类结果展示

图 7 为基于 ResNet18 – CBAM – RC1 网络模型的苹果叶部病害分类结果样例。尽管大部分的病害叶片可以被正确判定,仍有部分叶片灰斑病被错误分类为黑腐病。通过分析得出灰斑病被错误分类为黑腐病的可能原因,一方面是由于灰斑病数据集较少,导致样本不均衡;另一方面因为灰斑病与黑腐病在叶片发病时期病斑呈暗褐或灰白色、圆形不规则、边缘明显、病斑中散发小黑点,特征都较为相似,由于算法限制无法较好地分辨,所以改进模型预测时部分灰斑病被预测为黑腐病。

为进一步了解各类病害的识别情况,6 种分类网络对 5 类病害的分类准确率如图 8 所示。而且标出各模型将某个病害类别识别为其他类别的比例,其更加清晰地展示了各模型的错分情况。和前面分析的一致,错误较明显的是灰斑病分类成黑腐病,同时除了 ResNet18 – CBAM – RC1 之外,其他模型都有将黑星病错分成黑腐病的情况。可以看出改进的模型算法有效降低了病害误识率。

4 结论

(1) 针对苹果叶部病害病斑较小,病斑在整幅叶片上分散的问题,引入通道注意力和空间注意力机制模块强化了网络在主要病害区域的注意力,提高了识别率。

(2) 添加随机裁剪分支增强对不同病斑位置、大小和不同病害程度的特征提取能力,不仅实现了有限样本空间的扩充,还进一步优化网络结构,提高了训练速度。

(3) 利用构建的苹果病害数据集对 ResNet18 – CBAM – RC1 网络及其他 5 种模型进行训练测试。试验结果表明 ResNet18 – CBAM – RC1 网络分类模型取得平均准确率最高,为 98.25%,高于 ResNet18 (93.19%) 和 VGG16 (96.13%)。表明



图 7 基于 ResNet18 - CBAM - RC1 网络模型的苹果叶部病害分类结果

Fig. 7 Classification results of apple leaf diseases based on ResNet18 - CBAM - RC1 network model

实际标签

		预测标签			
		雪松 锈病	黑腐病	黑星病	白粉病
实际标签	黑星病	94.67%	1.74%		3.59%
	黑腐病		100%		
雪松锈病	黑星病	1.94%		90.08%	7.98%
	黑腐病				
灰斑病	黑星病	2.17%		97.84%	
	黑腐病				
白粉病	黑星病	1.93%			98.07%
	黑腐病				

(a) VGG16

		预测标签			
		雪松 锈病	黑腐病	黑星病	白粉病
实际标签	黑星病	93.89%	3.55%	2.56%	
	黑腐病		82.32%		17.68%
雪松锈病	黑星病			100%	
	黑腐病				
灰斑病	黑星病		7.79%		92.21%
	黑腐病				
白粉病	黑星病	2.47%			97.53%
	黑腐病				

(b) ResNet18

		预测标签			
		雪松 锈病	黑腐病	黑星病	白粉病
实际标签	黑星病	96.04%	1.86%		2.10%
	黑腐病		94.15%		5.85%
雪松锈病	黑星病	2.04%		97.96%	
	黑腐病				
灰斑病	黑星病	9.90%		90.10%	
	黑腐病	2.08%			97.92%
白粉病	黑星病				
	黑腐病				

(c) ResNet18-CBAM

		预测标签			
		雪松 锈病	黑腐病	黑星病	白粉病
实际标签	黑星病	100%			
	黑腐病		100%		
雪松锈病	黑星病			100%	
	黑腐病				
灰斑病	黑星病		8.74%		91.26%
	黑腐病				
白粉病	黑星病				100%
	黑腐病				

(e) ResNet18-CBAM-RC1

		预测标签			
		雪松 锈病	黑腐病	黑星病	白粉病
实际标签	黑星病	97.63%	2.37%		
	黑腐病		94.29%		5.71%
雪松锈病	黑星病			100%	
	黑腐病				
灰斑病	黑星病		1.67%		98.33%
	黑腐病	1.78%			98.22%
白粉病	黑星病				
	黑腐病				

(f) ResNet18-CBAM-RC2

图 8 不同模型病害分类准确率对比

Fig. 8 Comparison of recognition accuracy of six types of models

改进模型具有高准确率和较高的泛化能力。此外,模型内存占用量仅为 37.44 MB,单幅图像推理

时间为 9.11 ms,可满足嵌入式设备上果园病害识别的实时性要求。

参 考 文 献

- [1] 胡清玉,胡同乐,王亚南,等.中国苹果病害发生与分布现状调查[J].植物保护,2016,42(1):175–179.
HU Qingyu, HU Tongle, WANG Ya'nan, et al. Survey on the occurrence and distribution of apple diseases in China [J]. Plant Protection, 2016, 42(1): 175 – 179. (in Chinese)
- [2] 何自芬,黄俊璇,刘强,等.基于非对称混洗卷积神经网络的苹果叶部病害分割[J].农业机械学报,2021,52(8):221–230.
HE Zifan, HUANG Junxuan, LIU Qiang, et al. High precision identification of apple leaf diseases based on asymmetric shuffle convolution [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(8): 221 – 230. (in Chinese)
- [3] 刘斌,贾润昌,朱先语,等.面向移动端的苹果叶部病虫害轻量级识别模型[J].农业工程学报,2022,38(6):130–139.
LIU Bin, JIA Runchang, ZHU Xianyu, et al. Light weight identification model for apple leaf diseases and pests based on mobile terminals [J]. Transactions of the CSAE, 2022, 38(6): 130 – 139. (in Chinese)
- [4] ISLAM M, DINH A, WAHID K, et al. Detection of potato diseases using image segmentation and multiclass support vector machine[C]// Electrical & Computer Engineering. IEEE, 2017.
- [5] SHRIVASTAVA V K, PRADHAN M K, MINZ S, et al. Rice plant disease classification using transfer learning of deep convolution neural network[J]. International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences, 2019, 3(6): 631 – 635.
- [6] ZHANG Zhou, WANG Peng, YAO Zhifeng, et al. Early detection of downy mildew on grape leaves using multicolor fluorescence imageing and model SVM[J]. Spectroscopy and Spectral Analysis, 2021, 41(3):828 – 834.
- [7] ZHANG Chuanlei, ZHANG Shanwen, YANG Jucheng, et al. Apple leaf disease identification using genetic algorithm and correlation based feature selection method[J]. International Journal of Agricultural and Biological Engineering, 2017, 10(2): 74 – 83.
- [8] 魏丽冉,岳峻,李振波,等.基于核函数支持向量机的植物叶部病害多分类检测方法[J].农业机械学报,2017,48(增刊): 166 – 171.
WEI Liran, YUE Jun, LI Zhenbo, et al. Multi-classification detection method of plant leaf disease based on kernel function SVM [J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 166 – 171. (in Chinese)
- [9] 司永胜,曹珊珊,张晓雪,等.基于 CT 图像的苹果苦痘病与磕碰伤识别[J].农业机械学报,2021,52(10):377 – 384.
SI Yongsheng, CAO Shanshan, ZHANG Xiaoxue, et al. Recognition of apple bitter pit and bruise based on CT image [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(10): 377 – 384. (in Chinese)
- [10] BARANWAL S, KHANDELWAL S, ARORA A. Deep learning convolutional neural network for apple leaves disease detection [J]. Social Science Electronic Publishing, 2019(1): 260 – 267.
- [11] RAGHUNATH D, CHAITANYA M, SANDHYA M, et al. Deep learning model for plant disease detection[J]. International Journal of Recent Technology and Engineering, 2020, 9(1): 750 – 754.
- [12] 姜红花,张传银,张昭,等.基于 Mask R – CNN 的玉米田间杂草检测方法[J].农业机械学报,2020,51(6):220 – 228,247.
JIANG Honghua, ZHANG Chuanyin, ZHANG Zhao, et al. Detection method of corn weed based on Mask R – CNN [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(6): 220 – 228, 247. (in Chinese)
- [13] 翟肇裕,曹益飞,徐焕良,等.农作物病虫害识别关键技术研究综述[J].农业机械学报,2021,52(7):1 – 18.
ZHAI Zhaoyu, CAO Yifei, XU Huanliang, et al. Review of key techniques for crop disease and pest detection [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 1 – 18. (in Chinese)
- [14] CHAO Xiaofei, SUN Guoying, ZHAO Hongke, et al. Identification of apple tree leaf diseases based on deep learning models [J]. Symmetry, 2020, 12(7): 1065.
- [15] ZHONG Yong, ZHAO Ming. Research on deep learning in apple leaf disease recognition[J]. Computers and Electronics in Agriculture, 2020, 168: 105146.
- [16] 鲍文霞,吴刚,胡根生,等.基于改进卷积神经网络的苹果叶部病害识别[J].安徽大学学报(自然科学版),2021,45(1): 53 – 59.
BAO Wenxia, WU Gang, HU Gensheng, et al. Apple leaf disease recognition based on improved convolutional neural network [J]. Journal of Anhui University(Natural Science Edition), 2021, 45(1): 53 – 59. (in Chinese)
- [17] 张善文,张晴晴,李萍.基于改进深度卷积神经网络的苹果病害识别 [J].林业工程学报,2019, 4(4): 107 – 112.
ZHANG Shanwen, ZHANG Qingqing, LI Ping. Apple disease identification based on improved deep convolutional neural network [J]. Journal of Forestry Engineering, 2019, 4(4): 107 – 112. (in Chinese)
- [18] 于雪莹,高继勇,王首程,等.基于生成对抗网络和混合注意力机制残差网络的苹果病害识别[J].中国农机化学报,2022,43(6):166 – 174.
YU Xueying, GAO Jiayong, WANG Shoucheng, et al. Apple disease recognition based on Wasserstein generative adversarial networks and hybrid attention mechanism residual network [J]. Journal of Chinese Agricultural Mechanization, 2022, 43 (6):

- 166 – 174. (in Chinese)
- [19] 王细萍, 黄婷, 谭文学, 等. 基于卷积网络的苹果病变图像识别方法 [J]. 计算机工程, 2015, 41(12): 293 – 298.
WANG Xiping, HUANG Ting, TAN Wenxue, et al. Apple lesion image recognition method based on convolutional network [J]. Computer Engineering, 2015, 41(12): 293 – 298. (in Chinese)
- [20] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C] // Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 – 19.
- [21] 刘斌, 徐皓玮, 李承泽, 等. 基于快照集成卷积神经网络的苹果叶部病害程度识别 [J]. 农业机械学报, 2022, 53(6): 286 – 294.
LIU Bin, XU Haowei, LI Chengze, et al. Apple leaf disease identification method based on snapshot ensemble CNN [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6): 286 – 294. (in Chinese)
- [22] 王美华, 吴振鑫, 周祖光. 基于注意力改进 CBAM 的农作物病虫害细粒度识别研究 [J]. 农业机械学报, 2021, 52(4): 239 – 247.
WANG Meihua, WU Zhenxin, ZHOU Zuguang. Fine-grained identification research of crop pests and diseases based on improved CBAM via attention [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(4): 239 – 247. (in Chinese)
- [23] CHEN J, ZHANG D, ZEB A, et al. Identification of rice plant diseases using lightweight attention networks [J]. Expert Systems with Applications, 2021, 169: 114514.

(上接第 294 页)

- [23] QIN Z, ZHANG P, WU F, et al. FeaNet: frequency channel attention networks [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 783 – 792.
- [24] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C] // Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3 – 19.
- [25] LI Y, CHEN Y, WANG N, et al. Scale-aware trident networks for object detection [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 6054 – 6063.
- [26] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1 – 9.
- [27] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: a metric and a loss for bounding box regression [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 658 – 666.
- [28] GOYAL P, DOLLÁR P, GIRSHICK R, et al. Accurate, large minibatch sgd: training imagenet in 1 hour [J]. arXiv preprint arXiv:1706.02677, 2017.
- [29] ZHANG S, CHI C, YAO Y, et al. Bridging the gap between anchor-based and anchor-free detection via adaptive training sample selection [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 9759 – 9768.
- [30] ZHANG H, CHANG H, MA B, et al. Dynamic R – CNN: towards high quality object detection via dynamic training [C] // Proceedings of the European Conference on Computer Vision, 2020: 260 – 275.
- [31] WU Y, CHEN Y, YUAN L, et al. Rethinking classification and localization for object detection [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10186 – 10195.
- [32] ZHANG H, WU C, ZHANG Z, et al. ResNest: split-attention networks [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 2736 – 2746.
- [33] SANDLER M, HOWARD A, ZHU M, et al. MobileNet v2: inverted residuals and linear bottlenecks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510 – 4520.
- [34] WANG Q, WU B, ZHU P, et al. ECA – Net: efficient channel attention for deep convolutional neural networks [C] // Proceeding of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11531 – 11539.