

doi:10.6041/j.issn.1000-1298.2022.03.025

基于轻量级残差网络的植物叶片病害识别

李书琴 陈 聰 朱 彤 刘 磊

(西北农林科技大学信息工程学院, 陕西杨凌 712100)

摘要: 针对基于卷积神经网络的植物叶片病害识别方法存在网络参数众多、计算量大且复杂的问题,结合植物叶片病害特征,提出了一种基于轻量级残差网络(Scale-Down ResNet)的植物叶片病害识别方法。网络基于Residual Network(ResNet),通过缩减网络卷积核数目和轻量级残差模块(SD-BLOCK),在大幅减少网络参数、降低计算复杂度的同时保持了低识别错误率,然后加入Squeeze-and-Excitation模块进一步降低识别错误率。在PlantVillage数据集上的实验表明,在网络参数量 8×10^4 ,计算量MFLOPs为55的情况下,模型识别错误率为0.55%。当参数量达到 2.8×10^5 ,计算量MFLOPs为176时,模型识别错误率为0.32%,低于ResNet-18,并且参数量约为其1/39,计算量约为其1/10。相比MobileNet V3和ShuffleNet V2,所提网络模型更为轻量,识别错误率更低。同时网络在自建苹果叶片病害数据集上获得了1.52%的低识别错误率。

关键词: 植物叶片; 病害识别; ResNet; Squeeze-and-Excitation network; 轻量级网络

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2022)03-0243-08

OSID: 

Plant Leaf Disease Identification Based on Lightweight Residual Network

LI Shuqin CHEN Cong ZHU Tong LIU Bin

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

Abstract: The plant leaf disease recognition method based on convolutional neural network has the problem of numerous network parameters, large amount of calculation and complexity. To solve this problem, combined with the characteristics of plant leaf diseases, a plant leaf disease recognition method based on lightweight residual network (Scale-Down ResNet) was proposed. The network was based on Residual Network (ResNet), by reducing the number of convolution kernels and the network module of SD-BLOCK, the network parameters and computational complexity were greatly reduced, while the recognition error rate was kept low. Then the Squeeze-and-Excitation module was added to further reduce the recognition error rate. Experiments on the PlantVillage data set showed that when parameters were 8×10^4 and calculation amount MFLOPs was 55, the recognition error rate of model was 0.55%. When parameters reached 2.8×10^5 and calculation amount MFLOPs was 176, the recognition error rate of model was 0.32%, which was lower than that of ResNet-18, and the parameter was about 1/39 of ResNet-18 and the amount of calculation was about 1/10 of ResNet-18. Compared with MobileNet V3 and ShuffleNet V2, the proposed network model was lighter and had lower recognition error rate. At the same time, the low recognition error rate of 1.52% was obtained on self built apple leaf disease data set.

Key words: plant leaf; disease identification; ResNet; Squeeze-and-Excitation network; lightweight network

0 引言

植物病害问题与人们的生产生活密切相关^[1-3]。在植物生长过程中,容易受到天气、环境、微生物、病毒和细菌等影响而产生各种病害。植株

叶片是病症最常出现的部位,由于病害种类较多且部分病害特征相似,仅靠种植者肉眼观察和经验判断不能及时诊断病害类型,导致植物病害越来越严重,造成巨大损失。因此,快速准确地确定病害类型是防治植物病害的关键点。

收稿日期: 2021-03-23 修回日期: 2021-05-08

基金项目: 国家重点研发计划项目(2020YFD1100601)、陕西省重点研发计划项目(2021NY-138)和中央高校基本科研业务专项资金项目

作者简介: 李书琴(1965—),女,教授,博士生导师,主要从事农业信息化与智能信息系统研究,E-mail: lsq_cie@nwsuaf.edu.cn

传统病害识别算法^[4-6]主要通过人工提取研究对象图像特征进行分析研究,取得了一定的研究成果。郑建华等^[7]通过融合葡萄病叶的RGB颜色矩、HSV颜色直方图特征、GLCM纹理特征、HOG特征,利用支持向量机算法对3种病害识别准确率达到93.41%。郭小清等^[8]选择HSV模型中的4维H分量等量分割波段作为颜色特征,基于灰度差分统计的均值、对比度和熵3维特征作为纹理特征,通过粒子群算法优化支持向量机参数,获得了90%番茄叶片病害识别准确率。然而,人工提取的特征包含一定程度的主观性,无法确定最佳和鲁棒的特征,且植物病害通常表现为纹理、形状和颜色等多种复合特征,这为传统植物叶片病害识别算法带来了巨大的挑战,也影响了识别的效果。

深度学习的出现,为病害识别提供了新的方法。卷积神经网络不依赖特定特征,得到广泛应用。基于卷积神经网络的植物叶片病害识别方法^[9-11]具有识别准确率高的优点,但也存在网络参数众多,计算量大且复杂的问题,实用性较差。因此越来越多的学者将目光转向轻量级植物叶片病害识别网络的研究。孙俊等^[12]通过批归一化和全局池化改进卷积神经网络获得了99.56%识别准确率,参数内存需求2.6 MB。刘洋等^[13]采用MobileNet V1^[14]在PlantVillage数据集获得了95.02%的准确率,参数内存需求17.1 MB。贾鹤鸣等^[15]运用深度可分离卷积,全局平均池化,批归一化改进VGG网络,改进后的网络识别精度为99.43%,内存占用空间为6.47 MB。可以看出上述研究只是运用或改进卷积神经网络,未能针对病害特征进一步分析,虽然取得了较好的结果,但模型仍有提升的空间。

为进一步提升轻量级植物病害识别网络性能,结合植物病害特征,本文提出一种基于轻量级残差网络的植物叶片病害识别方法,通过缩减ResNet-18^[16]卷积核数目和轻量级残差模块(SD-BLOCK),在减少参数、降低计算复杂度的同时提取多种病害特征,保持低识别错误率。然后加入SE^[17]模块,增强网络病害特征提取能力,降低网络识别错误率,从而构建轻量级残差网络(Scale-Down ResNet,SDResNet)。

1 轻量级植物叶片病害识别

1.1 ResNet

分析植物病害颜色、纹理、轮廓等特征可知,不同植物病害特征,同一植物不同病害特征表现出一定的相似性,区分难度较大。Residual Network^[16](ResNet)运用了残差学习的思想,增加了网络的深

度,进而提升了网络病害特征提取能力,被广泛应用于病害识别^[18-20]。ResNet主要由一系列残差模块(图1)组成。一个残差模块可以表示为

$$X_{L+1} = X_L + F(X_L, W_L) \quad (1)$$

式中 X_L, X_{L+1} ——第 $L, L+1$ 层特征图

W_L ——第 L 层卷积参数

F ——卷积运算函数

即将网络映射 $H(X_L, W_L) := X_L + 1$ 转变为 $X_L + F(X_L, W_L)$, 叠加的卷积层只需要拟合 $F(X_L, W_L)$ 函数。这种转变使深层网络更容易优化。假设网络学习的 X_L 是最优的, 网络更深层的卷积将权重置为0便能达到最佳性能。若最优结果接近 X_L , 更深的卷积层则只需要微调, 而不是学习一个新的映射。

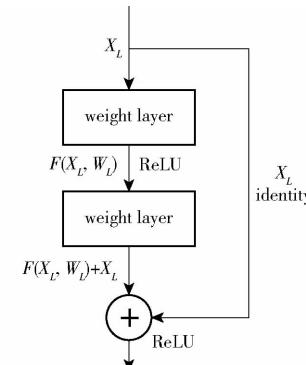


图1 残差模块

Fig. 1 Residual module

残差结构实现简单,如图1所示,在网络中构建恒等连接即可,这使得网络底层和深层中的信息可以快捷传递,在一定程度上解决了深层网络信息丢失、损耗和梯度爆炸与消失问题,提升了深层网络的性能。

1.2 轻量级残差模块

1.2.1 分组卷积

分组卷积采用split-transform-merge^[21]思想,在减少参数和计算量的同时提高了网络识别精度。通过这种卷积方式可以得到关注点不同的特征图,互为补充,更完整地表示图像特征。同时分组卷积增加了卷积核之间的对角相关性,减少了参数,可以缓解过拟合,类似于正则。分组卷积计算过程如图2所示,分组卷积对输入特征图分解,然后在各个分组上进行卷积计算。由于卷积的输入通道数减少,相应也减少了参数和计算量,减为原来的 $1/G$, G 为分组数。

1.2.2 深度可分离卷积

深度可分离卷积将标准卷积分为2部分,深度卷积和逐点卷积。深度卷积是分组卷积的极致版,即分组数等于通道数,常设置较大的卷积核,用来获取空间信息。逐点卷积即 1×1 卷积用于融合通道

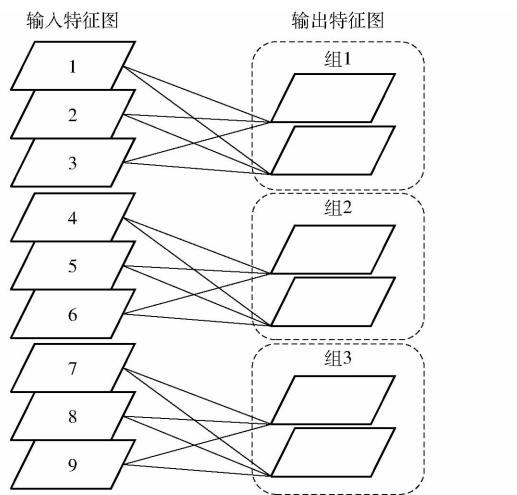


图 2 分组卷积

Fig. 2 Group convolution

信息。这种卷积方式大大减少了计算量。假设输入特征图尺寸为 $D_F \times D_F \times M$, 输出特征图尺寸为 $D_F \times D_F \times N$, 卷积核的尺寸为 $D_K \times D_K$, 则标准卷积的计算量为 $D_K^2 MND_F^2$, 深度卷积的计算量为 $D_K^2 MD_F^2$, 逐点卷积的计算量为 MND_F^2 , 因此深度可分离卷积计算量相比标准卷积计算量为

$$\frac{D_K^2 MD_F^2 + MND_F^2}{D_K^2 MND_F^2} = \frac{1}{N} + \frac{1}{D_K^2} \quad (2)$$

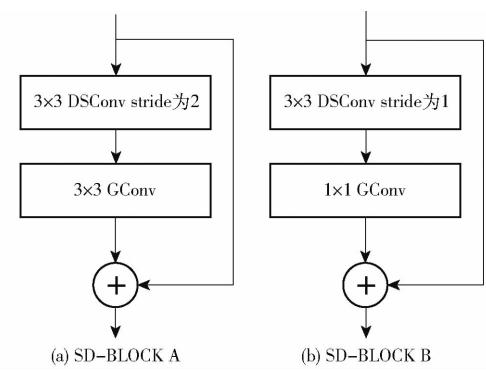
由式(2)可知, 如果卷积核尺寸为 3×3 ($D_K = 3$), 由于输出通道数 N 很大, 深度可分离卷积大约是标准卷积计算量的 $1/9$ 。MobileNet V1^[14] 将标准卷积替换为深度可分离卷积, 精度却没有损失太多, 证明了深度可分离卷积强大的特征提取能力。

1.2.3 轻量级残差模块结构

轻量级残差模块 (SD - BLOCK) 主要运用了深度可分离卷积和分组卷积。首先 2 种卷积方式搭配使用大幅减少了网络参数, 降低了计算量。同时 2 种卷积方式都构建了多条卷积路径, 并且深度卷积不会扰乱分组卷积的分组。植物病害往往表现为颜色、纹理、形状等复合特征。通过不同卷积路径得到的特征图关注的主要特征不同, 互为补充, 进而提取了多种的病害特征, 增强了网络病害识别能力。同时分组卷积存在各分组信息无法交互的问题, 而逐点卷积可以融合通道信息, 解决了此问题。如图 3 所示, DSConv 代表深度可分离卷积, GConv 表示分组卷积, SD - BLOCK 有 2 种不同结构, 结构 A (图 3a) 用于特征图减半, 结构 B (图 3b) 使用 1×1 卷积进一步减少参数。

1.3 SE 模块

SE^[17] (Squeeze-and-Excitation) 模块是一个轻量级的通道注意力模块, 可以使模型注意到重要的病害特征, 同时弱化其他干扰因素, 提升模型病害识别



(a) SD - BLOCK A (b) SD - BLOCK B

图 3 SD - BLOCK 模块

Fig. 3 SD - BLOCK module

能力。SE 模块由 Squeeze 和 Excitation 2 部分构成。

由于卷积计算只在局部接受域上, 无法获取更多的上下文信息。为解决这个问题, Squeeze 部分使用了全局平均池化获取通道维度的上下文信息。单通道特征图 u 的上下文信息 z 的计算公式为

$$z = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W u(i,j) \quad (3)$$

式中 H ——特征图高度

W ——特征图宽度

Excitation 部分主要目的是学习通道之间的相关性。为了做到这一点, 要满足 2 个条件: ①必须有极强的学习能力, 可以学习通道之间的非线性关系。②学习到的应是非互斥关系, 以确保对多个通道增加注意力。同时为了限制模型的复杂度, Excitation 部分构建了一个 2 层瓶颈状的全连接网络。具体计算公式为

$$s = \sigma(W_2 \delta(W_1 Z)) \quad (4)$$

$$(W_1 \in \mathbf{R}^{(C/r) \times C}, W_2 \in \mathbf{R}^{C \times C/r})$$

式中 δ ——ReLU 函数 C ——通道数

σ ——Sigmoid 函数

W_1 ——第 1 层网络的参数

W_2 ——第 2 层网络的参数

r ——中间全连接层的缩减参数

Z ——所有通道的上下文信息

s ——通道注意力信息

融合 SE 模块的残差模块结构如图 4 所示, SE 模块加入到残差模块的卷积层之后。在卷积层之后先使用全局平均池化聚合特征图的信息。然后送入两层全连接网络中学习各通道权重, 进而与输入特征图相乘重新调整网络特征。最后和初始特征图相加实现残差学习。

1.4 轻量级残差网络结构

轻量级残差网络 (Scale-Down ResNet, SDResNet) 模型总体结构如表 1 所示, 表中 RE - BLOCK 代表原残差模块。

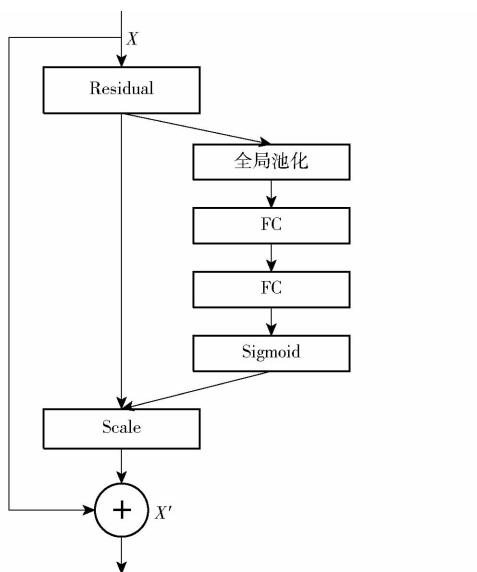


图 4 SE - ResNet 模块

Fig. 4 SE - ResNet module

表 1 轻量级残差网络结构

Tab. 1 Scale-Down ResNet structure

输出特征图尺寸/ (像素 × 像素)	计算	SE	卷积核数目
112 × 112	7×7 conv stride 为 2	-	12/16/24
56 × 56	3×3 max pool stride 为 2 RE - BLOCK × 2	✓	12/16/24
28 × 28	RE - BLOCK × 2	✓	24/32/48
14 × 14	SD - BLOCK × 2	✓	48/64/96
7 × 7	SD - BLOCK × 2	✓	96/128/192
1 × 1	average pool, num-d fc, softmax		

注：“✓”表示使用，“-”表示不使用。

模型以 ResNet - 18 为基础,首先缩减卷积核的数目,去除网络冗余。本研究构建了 3 个模型 SDResNet - 1、SDResNet - 2 和 SDResNet - 3,卷积核的数目分别设置为(12, 24, 48, 96)、(16, 32, 64, 128)和(24, 48, 96, 192)。考虑到底层提取的特征对网络识别精度至关重要,SDResNet 保留了网络底层的原残差模块,使用标准卷积提取底层特征,提高了网络的性能。因为经过缩减后网络底层特征通道数已足够小,所以这样做并没有带来过多的参数和计算量。网络深层特征通道数仍比较大,SDResNet 使用 SD - BLOCK 减少了大部分参数和计算量,同时保持了低识别错误率。最后网络融合了 SE 注意力模块,进一步提升了网络性能。

2 实验数据集及处理

2.1 PlantVillage 数据集

本研究数据集选用 PlantVillage 工程(www.plantvillage.org)面向所有用户开放的植物病害图像数据库^[22],它包含 26 类植物患病叶片图

像和 12 类植物健康叶片图像,共 54 306 幅。数据库中的图像均是在室内拍摄,拍摄规范,背景简单。数据集详情如表 2 所示。实验将图像统一到 224 像素 × 224 像素,然后按照 4:1 划分得到训练集和测试集。

表 2 PlantVillage 数据库图像信息

Tab. 2 Image information of PlantVillage

植物名称	病害名称	图像数量
苹果	疮痂病	630
	黑腐病	622
	锈病	275
	健康叶	1 645
	蓝莓	1 502
	健康叶	843
樱桃	斑枯病	1 771
	白粉病	1 052
	灰斑病	513
	锈病	1 192
	健康叶	1 162
	枯叶病	985
玉米	黑腐病	1 180
	锈病	1 383
	健康叶	423
	叶枯病	1 076
	健康叶	5 090
	细菌性斑点病	2 297
葡萄	晚疫病	1 909
	叶霉病	592
	轮斑病	1 404
	二斑叶螨病	1 676
	花叶病	373
	细菌性斑点病	2 127
辣椒	黄曲叶病	5 357
	细菌性斑点病	997
	健康叶	1 478
	南瓜	1 835
	白粉病	1 109
	叶焦病	456
草莓		

2.2 苹果叶片病害数据集

苹果叶片病害数据集包含 4 种苹果叶片病害图像和 1 种健康苹果叶片图像,叶片病害分别是黑星病、褐斑病、锈病、花叶病。数据集图像主要来自 Kaggle 竞赛和田间采集,共有 2 276 幅原始图像。与 PlantVillage 数据集不同,该数据集中所有病害叶片图像均为自然光照下拍摄且背景复杂。为均衡各类别图像,对部分类别采用随机旋转、亮度调整、对比度增强、翻转操作扩充数据集,扩充后的数据集共有 2 973 幅图像,每个类别约有 600 幅图像。图 5 给出了苹果叶片病害数据集中 5 个类别的样例。同样,实验将图像调整到 224 像素 × 224 像素,训练集和测试集的比例为 4:1。

3 实验与结果分析

3.1 实验平台和实验参数设置

本研究实验环境配置如表 3 所示,训练 epoch 设置为 60,学习率初始值为 0.1,epoch 为 45 时设置为 0.01,epoch 为 55 时设置为 0.001。batch 设置为 128。

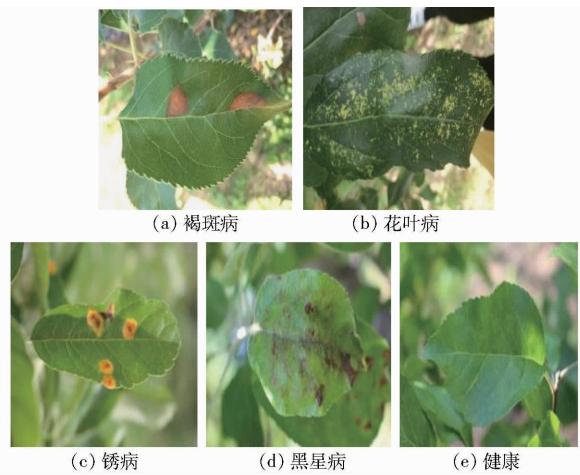


图 5 苹果叶片病害数据集样本

Fig. 5 Examples of apple leaf disease data set

表 3 实验环境配置

Tab. 3 Experimental environment configuration

实验环境	配置参数
操作系统	Ubuntu 16.04
GPU	GeForce GTX TITAN X
深度学习框架	Tensorflow-GPU 1.12.0
编程语言	Python 3.6
GPU 加速库	CUDA 9.2、CUDNN 7.6

3.2 评价指标

本研究选用识别错误率、网络参数量和每秒百万次浮点运算(MFLOPs)作为评价网络的指标。

3.3 损失函数曲线

图 6 为 SDResNet-1、SDResNet-2 和 SDResNet-3 的损失函数曲线。由图 6 可以看出,模型收敛迅速,可以很好地拟合病害特征。这使得 SDResNet-3 模型在训练 3 轮后识别错误率低于 10%,训练 5 轮后识别错误率低于 5%。分析原因,模型运用残差学习的思想,加入了恒等连接,使网络更容易优化。并因此构建了更深的网络,提高网络拟合病害特征的能力。

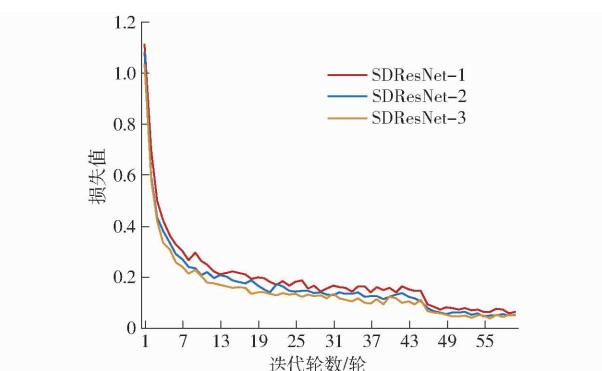


图 6 损失函数曲线

Fig. 6 Loss function curves

3.4 卷积神经网络实验对比

为更好地评价所提网络的性能,选取现有优异

的图像识别模型 ResNet-18、ShuffleNet V2^[23] 和 MobileNet V3^[24] 与 SD-ResNet 在 PlantVillage 数据集进行实验对比。MobileNet V3 出自 Google AI,是最近发布的轻量级网络架构。ShuffleNet V2 是旷视科技推出的最新轻量级网络架构,相关论文收录在 ECCV 中。

实验结果如表 4 所示,按计算量正序排列。从识别错误率分析,SDResNet-3 取得了最优的结果,甚至超过 ResNet-18,而前者是后者参数量和计算量的几十分之一。这是因为针对植物叶片病害识别问题,SDResNet 继承了 ResNet 优异的残差结构,在几乎不影响性能的情况下,合理去除了更多的参数和计算量。针对植物叶片病害特征使用 SD-BLOCK 提取了多种病害特征,使用 SE 模块关注到重要的病害特征,提升了网络性能。与其他轻量级网络相比,SDResNet-3 在计算量略小于 MobileNet V3 情况下,识别错误率低于后者。SDResNet-2 在计算量小于 ShuffleNet V2 1x 情况下,识别错误率低于后者。SDResNet-1 在计算量略大于 ShuffleNet V2 0.5x 情况下,识别错误率明显低于后者。MobileNet V3 和 ShuffleNet V2 并未就植物叶片病害特征针对性处理,使其无法更好地提取病害特征,影响了网络精度。

表 4 卷积神经网络实验结果

Tab. 4 Convolution neural network experiments

模型	识别错误率/%	参数量	MFLOPs
ShuffleNet V2 0.5x	0.94	3.80×10^5	40
SDResNet-1	0.55	8.00×10^4	55
SDResNet-2	0.44	1.40×10^5	89
ShuffleNet V2 1x	0.55	1.29×10^6	145
SDResNet-3	0.32	2.80×10^5	176
MobileNet V3	0.41	4.22×10^6	218
ResNet-18	0.33	1.12×10^7	1 800

3.5 缩减卷积核数目实验

为确定缩减卷积核数目对 ResNet-18 网络性能的影响程度,研究构建不同的残差块卷积核数的模型进行实验。模型 1 卷积核数为(12, 24, 48, 96),模型 2 卷积核数为(16, 32, 64, 128),模型 3 卷积核数为(24, 48, 96, 192),分别对应 SDResNet-1、SDResNet-2、SDResNet-3 残差块卷积核数目。实验结果如表 5 所示。

由表 5 可知,缩减后的模型在网络参数与计算量大幅减少的同时,识别错误率并没有显著上升,仍维持在较低水平,这很大程度上得益于残差结构的设计,构建了较深的网络,增强了病害特征提取能力。缩减后的模型依然能很好地拟合植物病害特

表 5 缩减卷积核数目实验结果

Tab. 5 Reduce convolution kernel experiment

模型	卷积核数目	识别错误率/%	参数量	MFLOPs
ResNet-18	(64, 128, 256, 512)	0.33	1.12×10^7	1 800
模型 1	(12, 24, 48, 96)	0.61	4.00×10^5	81
模型 2	(16, 32, 64, 128)	0.57	7.10×10^5	135
模型 3	(24, 48, 96, 192)	0.52	1.60×10^6	281

征,具有更少的参数和计算量,但识别错误率相比 ResNet-18 仍有不足。同时可以看出,不同的缩减模型,具有不同的性能,总体上随着卷积核数目的增长,模型识别错误率也在下降,并逐渐逼近原网络,但同时也可以看出随着网络性能的提升,通过单纯增加卷积核数目来降低识别错误率的代价高昂,因此本研究选择了 SD-BLOCK 和 SE 模块提升网络的性能。

3.6 SD-BLOCK 和 SE 模块影响实验

将轻量级残差模块 SD-BLOCK 和 SE 模块加入到网络中以探讨他们对网络性能的影响。模型 1~3 与 3.5 节定义相同。不同的分组数和 SE 参数对不同模型的影响不同,本文通过实验选取最优参数值,将 3 个模型的分组卷积参数依次设置为 12、8、12,SE 参数依次设置为 3、4、6。

实验结果如表 6 所示,单独加入 SD-BLOCK 的模型相比缩减模型(模型 1~3)参数减少了绝大部分,计算量明显下降。SD-BLOCK 对模型识别错误率的影响不同。因为模型 1 加入 SD-BLOCK 后变得极小,影响了识别错误率,但仍保持了低识别错误率,与原模型仅相差 0.11 个百分点。模型 2 较大,加入 SD-BLOCK 后,识别错误率已与原模型相差不大。模型 3 更大,加入 SD-BLOCK 后,识别错误率降低了 0.05 个百分点。这是因为植物病害往

表 6 SD-BLOCK 和 SE 模块影响实验结果

Tab. 6 SD-BLOCK and SE influence experiment

模型	识别错误率/%	参数量	MFLOPs
模型 1	0.61	4.0×10^5	81
模型 1 + SD-BLOCK	0.72	7.0×10^4	55
模型 1 + SE	0.58	4.2×10^5	82
模型 1 + SD-BLOCK + SE	0.55	8.0×10^4	55
模型 2	0.57	7.1×10^5	135
模型 2 + SD-BLOCK	0.58	1.2×10^5	89
模型 2 + SE	0.49	7.3×10^5	135
模型 2 + SD-BLOCK + SE	0.44	1.4×10^5	89
模型 3	0.52	1.6×10^8	281
模型 3 + SD-BLOCK	0.47	2.5×10^5	176
模型 3 + SE	0.38	1.62×10^6	281
模型 3 + SD-BLOCK + SE	0.32	2.8×10^5	176

往表现为颜色、纹理、形状等复合特征,SD-BLOCK 构建了多条卷积路径,通过不同卷积路径得到的特征图关注的主要特征不同,互为补充,进而提取了多种病害特征,增强了网络病害识别能力。

单独加入 SE 模块的模型相比缩减模型参数和计算量增加微乎其微,识别错误率却明显下降,低于缩减模型。说明 SE 是高效的提升网络性能的方法。植物叶片病害具有颜色、纹理、轮廓等多种多样的特征,SE 模块的注意力机制使网络可以增强重要的特征,提升了网络的性能。相比单独加入 SD-BLOCK 的模型,这种模型识别错误率更低,但拥有更多的参数和计算量。

同时加入 SD-BLOCK 和 SE 模块的网络即 SDResNet 综合性能最优,既减少了参数量和计算量,又降低了识别错误率。SD-BLOCK 减少了模型大部分参数量和计算量,同时提取了众多的病害特征,而 SE 会增强重要的病害特征,两者相互配合,提升了网络性能。

3.7 与其他植物病害识别方法的对比

PlantVillage 数据集是公开数据集,众多的学者基于此研究植物叶片病害识别。为准确评估所提模型的性能,与近期植物病害识别方法进行比较。由于各个研究的评价指标不同,在原有评价指标的基础上添加了参数内存需求,它表示存储网络参数所需的空间大小。由表 7 可知,SDResNet 在网络参数量和参数内存需求远低于其他方法情况下,识别错误率更低。SDResNet-2 在网络参数量和参数内存需求大幅减少的情况下,识别错误率仍低于或等于其他方法。说明针对植物叶片病害识别,基于残差结构搭建深而窄的网络,并辅以轻量级的注意力模块,更为高效。

表 7 植物病害识别方法实验对比

Tab. 7 Experimental comparison of plant disease identification methods

模型	识别错误率/%	参数量	参数内存需求/MB	MFLOPs
SDResNet-1	0.55	8.0×10^4	0.32	55
SDResNet-2	0.44	1.4×10^5	0.55	89
SDResNet-3	0.32	2.8×10^5	1.05	176
文献[12]	0.44		2.60	
文献[13]	4.98		17.10	
文献[15]	0.57	1.69×10^6	6.47	
文献[25]	1.80	1.47×10^7		
文献[26]	1.66	5.40×10^5		

3.8 苹果叶片病害数据集实验

为探讨所提方法在不同植物叶片病害数据集的效果。在自建苹果叶片病害数据集上进行实验,同

样与 MobileNet V3、ShuffleNet V2 1x 和 ResNet - 18 对比。考虑到苹果叶片数据集图像较少且背景复杂, 实验将训练 epoch 增大到 100, 以使模型更好地收敛。训练学习率初始值为 0.1, epoch 为 60 时设置为 0.01, epoch 为 90 时设置为 0.001。分析表 8 实验数据可知, 复杂背景会影响植物叶片病害的识别效果, 网络识别错误率整体升高。相比轻量级网络 ShuffleNet V2 1x 和 MobileNet V3, SDResNet 模型的识别错误率明显下降, 其中 SDResNet - 3 模型取

表 8 苹果叶片病害数据集实验结果

Tab. 8 Experiment on data set of apple leaf diseases

模型	识别错误率/%	参数量	MFLOPs
SDResNet - 1	2.87	8.0×10^4	55
SDResNet - 2	2.36	1.4×10^5	89
ShuffleNet V2 1x	3.54	1.26×10^6	145
SDResNet - 3	1.52	2.7×10^5	176
MobileNet V3	4.72	4.2×10^6	218
ResNet - 18	2.53	1.118×10^7	1800

得了最低识别错误率 1.52%。原因是 SDResNet 网络底层使用标准卷积, 可以更好地提取病害特征, 尤其在复杂的背景中。同样设计的 ResNet - 18 因为较少的训练数据和大量的参数使得网络过拟合, 识别错误率升高, 但仍低于轻量级网络 ShuffleNet V2 1x 和 MobileNet V3。实验表明, SDResNet 针对不同植物叶片病害数据集均可以获得较好的识别精度。

4 结束语

针对植物叶片病害识别模型参数众多, 计算量大且复杂的问题, 提出一种轻量级植物叶片病害识别网络 SDResNet。SDResNet 基于缩减的 ResNet - 18, 运用 SD - BLOCK, 在大幅减少参数, 降低计算复杂度的同时提取了多种病害特征, 保证了低识别错误率, 加入 SE 模块, 进一步降低了识别错误率。在 PlantVillage 数据集上实验表明, SDResNet 识别错误率略低于 ResNet - 18, 同时参数量约为其 1/39, 计算量约为其 1/10, 具有很强的实用性。

参 考 文 献

- [1] 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 diseases based on kernel function support vector machine[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 166 - 171. (in Chinese)
- [2] 鲍文霞, 赵健, 张东彦, 等. 基于椭圆型度量学习的小麦叶部病害识别[J]. 农业机械学报, 2018, 49(12): 20 - 26.
BAO Wenzhong, ZHAO Jian, ZHANG Dongyan, et al. Wheat leaf disease identification based on elliptic metric learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(12): 20 - 26. (in Chinese)
- [3] 李晓振, 徐岩, 吴作宏, 等. 基于注意力神经网络的番茄叶部病害识别系统[J]. 江苏农业学报, 2020, 36(3): 561 - 568.
LI Xiaozhen, XU Yan, WU Zuohong, et al. Identification system of tomato leaf diseases based on attention neural network[J]. Jiangsu Journal of Agricultural Sciences, 2020, 36(3): 561 - 568. (in Chinese)
- [4] 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 Yunlong, YUAN Hao, ZHANG Qingqing, et al. Identification method of apple leaf diseases based on color feature and difference histogram[J]. Jiangsu Agricultural Sciences, 2017, 45(14): 171 - 174. (in Chinese)
- [5] 张燕, 李庆学, 吴华瑞. 基于核相互子空间法的番茄叶部病害快速识别模型[J]. 智慧农业(中英文), 2020, 2(3): 86 - 97.
ZHANG Yan, LI Qingxue, WU Huarui. Fast identification model of tomato leaf diseases based on kernel mutual subspace method[J]. Smart Agriculture, 2020, 2(3): 86 - 97. (in Chinese)
- [6] 夏永泉, 王兵, 支俊, 等. 基于随机森林方法的小麦叶片病害识别研究[J]. 图学学报, 2018, 39(1): 57 - 62.
XIA Yongquan, WANG Bing, ZHI Jun, et al. Research on wheat leaf disease identification based on random forest method[J]. Journal of Graphics, 2018, 39(1): 57 - 62. (in Chinese)
- [7] 郑建华, 朱立学, 朱蓉. 基于多特征融合与支持向量机的葡萄病害识别[J]. 现代农业装备, 2018(6): 54 - 60.
ZHENG Jianhua, ZHU Lixue, ZHU Rong. Grgrape disease identification based on multi-feature fusion and support vector machine[J]. Modern Agricultural Equipment, 2018(6): 54 - 60. (in Chinese)
- [8] 郭小清, 范涛杰, 舒欣. 基于图像融合特征的番茄叶部病害的识别[J]. 湖南农业大学学报(自然科学版), 2019, 45(2): 212 - 217.
GUO Xiaoqing, FAN Taojie, SHU Xin. Identification of tomato leaf diseases based on image fusion features[J]. Journal of Hunan Agricultural University (Natural Science Edition), 2019, 45(2): 212 - 217. (in Chinese)
- [9] 鲍文霞, 林泽, 胡根生, 等. 基于 RSTCNN 的小麦叶片病害严重度估计[J]. 农业机械学报, 2021, 52(12): 242 - 252, 263.
BAO Wenzhong, LIN Ze, HU Gensheng, et al. Severity estimation of wheat leaf diseases based on RSTCNN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(12): 242 - 252, 263. (in Chinese)
- [10] 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 Zifen, 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)

- [11] 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)
- [12] 孙俊,谭文军,毛罕平,等.基于改进卷积神经网络的多种植物叶片病害识别[J].农业工程学报,2017,33(19):209–215.
SUN Jun, TAN Wenjun, MAO Hanping, et al. Plant disease identification based on improved convolutional neural network [J]. Transactions of the CSAE, 2017, 33(19): 209–215. (in Chinese)
- [13] 刘洋,冯全,王书志.基于轻量级CNN的植物病害识别方法及移动端应用[J].农业工程学报,2019,35(17):194–204.
LIU Yang, FENG Quan, WANG Shuzhi. Plant disease identification method and mobile application based on lightweight CNN [J]. Transactions of the CSAE, 2019, 35(17): 194–204. (in Chinese)
- [14] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [EB/OL]. [2017–04–17]. <https://arxiv.org/abs/1704.04861>.
- [15] 贾鹤鸣,郎春博,姜子超.基于轻量级卷积神经网络的植物叶片病害识别方法[J].计算机应用,2021,41(6):1812–1819.
JIA Heming, LANG Chunbo, JIANG Zichao. Plant leaf disease identification method based on lightweight convolution neural network [J]. Computer Applications, 2021, 41(6): 1812–1819. (in Chinese)
- [16] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.
- [17] JIE H, LI S, GANG S, et al. Squeeze-and-excitation networks [C] // IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 7132–7141.
- [18] 曾伟辉,李森,李增,等.基于高阶残差和参数共享反馈卷积神经网络的农作物病害识别[J].电子学报,2019,47(9):1979–1986.
ZENG Weihui, LI Miao, LI Zeng, et al. Crop disease identification based on high-order residual and parameter shared feedback convolutional neural network [J]. Acta Electronica Sinica, 2019, 47(9): 1979–1986. (in Chinese)
- [19] 刘翱宇,吴云志,朱小宁,等.基于深度残差网络的玉米病害识别[J].江苏农业学报,2021,37(1):67–74.
LIU Aoyu, WU Yunzhi, ZHU Xiaoning, et al. Identification of maize diseases based on deep residual network [J]. Jiangsu Journal of Agricultural Sciences, 2021, 37(1): 67–74. (in Chinese)
- [20] 王春山,周冀,吴华瑞,等.改进Multi-Scale ResNet的蔬菜叶部病害识别[J].农业工程学报,2020,36(20):209–217.
WANG Chunshan, ZHOU Ji, WU Huarui, et al. Identification of vegetable leaf diseases based on Multi-Scale ResNet [J]. Transactions of the CSAE, 2020, 36(20): 209–217. (in Chinese)
- [21] XIE S, GIRSHICK R, DOLLAR P, et al. Aggregated residual transformations for deep neural networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1492–1500.
- [22] HUGHES D P, SALATHE M. An open access repository of images on plant health to enable the development of mobile disease diagnostics [EB/OL]. [2015–11–25]. <https://arxiv.org/abs/1511.08060>.
- [23] MA N, ZHANG X, ZHENG H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design [EB/OL]. [2018–07–30]. <https://arxiv.org/abs/1807.11164v1>.
- [24] HOWARD A, SANDLER M, CHU G, et al. Searching for MobileNet V3 [EB/OL]. [2019–05–06]. <https://arxiv.org/abs/1905.02244v2>.
- [25] DARWISH A, EZZAT D, HASSANIEN A E. An optimized model based on convolutional neural networks and orthogonal learning particle swarm optimization algorithm for plant diseases diagnosis [J]. Swarm and Evolutionary Computation, 2020, 52: 100616.
- [26] KAMAL K C, YIN Z, WU M, et al. Depthwise separable convolution architectures for plant disease classification [J]. Computers and Electronics in Agriculture, 2019, 165: 104948.

(上接第224页)

- [25] 陈超,张志昂,丁丽君.一种改进粒子群优化算法的多机器人地图拼接方法[J].电子技术应用,2020,46(12):139–143.
CHEN Chao, ZHANG Zhiang, DING Lijun. A multi-robot map stitching method based on improved particle swarm optimization algorithm [J]. Application of Electronic Technology, 2020, 46(12): 139–143. (in Chinese)
- [26] 刘正锋,张隆辉,魏纳新,等.环境地图的格栅化及路径规划研究[J].舰船科学技术,2021,43(7):141–145.
LIU Zhengfeng, ZHANG Longhui, WEI Naxin, et al. Research on gridization and path planning of environmental map [J]. Ship Science and Technology, 2021, 43(7): 141–145. (in Chinese)
- [27] 史红玉,刘淑芬.基于Voronoi图的无人机航路改进规划[J].吉林大学学报(理学版),2018,56(4):945–952.
SHI Hongyu, LIU Shufen. Improved planning of UAV route based on Voronoi diagram [J]. Journal of Jilin University (Science Edition), 2018, 56(4): 945–952. (in Chinese)
- [28] 黄辰,费继友,刘洋,等.基于动态反馈A^{*}蚁群算法的平滑路径规划方法[J].农业机械学报,2017,48(4):34–40,102.
HUANG Chen, FEI Jiyu, LIU Yang, et al. Smooth path planning method based on dynamic feedback A^{*} ant colony algorithm [J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(4): 34–40, 102. (in Chinese)
- [29] 劳彩莲,李鹏,冯宇.基于改进A^{*}与DWA算法融合的温室机器人路径规划[J].农业机械学报,2021,52(1):14–22.
LAO Cailian, LI Peng, FENG Yu. Path planning of greenhouse robot based on fusion of improved A^{*} and Dynamic Window Approach [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(1): 14–22. (in Chinese)