

徐振南,王建坤,胡益嘉,等. 基于 MobileNetV3 的马铃薯病害识别[J]. 江苏农业科学,2022,50(10):176-182.

doi:10.15889/j.issn.1002-1302.2022.10.028

基于 MobileNetV3 的马铃薯病害识别

徐振南¹,王建坤¹,胡益嘉¹,张智聪¹,赵旭东¹,杨琳琳^{1,2},李文峰^{1,2}

(1. 云南农业大学机电工程学院,云南昆明 650201; 2. 云南省作物生产与智慧农业重点实验室,云南昆明 650201)

摘要:针对传统卷积神经网络在马铃薯叶部病害识别中结构复杂、参数庞大,难以实现在移动设备上的良好应用的问题,提出一种基于轻量级卷积神经网络和迁移学习的马铃薯叶部病害识别方法。首先,采集马铃薯叶部病害图像样本,再运用 GrabCut 算法进行图像分割;再基于 MobileNetV3 构建病害识别基础模型,并通过调整模型结构及宽度系数 α 等方式对模型进行优化,最后运用迁移学习的方式将预训练参数迁移至优化模型进行训练。结果表明,该方法对马铃薯健康、晚疫病、早疫病、炭疽病及其他病害叶部图像识别准确率为 98.00%,模型权重仅为 0.68 MB,识别速率为 0.014 s/幅。本研究结果可为马铃薯叶部病害识别在移动设备上应用的实现提供理论支持。

关键词:马铃薯;叶部病害;GrabCut;MobileNetV3;迁移学习;小样本

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 1002-1302(2022)10-0176-07

马铃薯是我国四大粮食作物之一,目前,已知马铃薯病害有 100 余种,其中晚疫病和早疫病造成的危害最为严重,马铃薯早疫病发病严重时减产可达 30% 以上^[1],晚疫病则可造成高达 80%~100% 的减产^[2]。传统马铃薯病害识别通常为专家直接对患病部位进行观察,如晚疫病发病初期在叶尖或叶缘有水浸状绿褐色斑点^[3]。该方法具有较高的准确率,但效率较低,且受限于专家数量,难以实现有效推广。

由于计算机智能识别技术在对农业病害进行检测识别时,具有无损、快速的特点^[4],故被广泛应用于病害识别。赵建敏等用 8 层 CNN + softmax 分层卷积神经网络模型识别了简单背景单一病斑^[5];孙文杰等使用一种基于 VGGNet - BiLSTM 的算法实现了对桃树叶部病害图像的识别^[6];谢裕睿等通过

构造恒等残差块和卷积残差块来搭建 20 层的 ResNet 模型识别了 5 种常见烟草病害^[7]。上述研究在图像识别领域取得了良好效果,但其所采用的模型存在深度及参数过大等不足。目前,农业病害识别趋向于模型结构小型化、实用化,以期更好地实现其在移动端的应用。杨森等提出一种基于轻量卷积网络的马铃薯外部缺陷无损分级方法,识别准确率为 96.04%^[8]。刘洋等基于 MobileNet 与 InceptionV3 提出 2 种轻量级卷积神经网络作物病害分类模型^[9]。以上研究表明,轻量级卷积神经网络模型在减少网络参数数量的同时,可保证较高的识别准确率,适用于移动端。

本研究提出一种基于 MobileNetV3 优化和迁移学习方法的马铃薯叶部病害图像识别方法,并从训练、测试准确率及损失函数、模型权重和识别速率等方面对模型进行评估,为开发移动端的马铃薯害智能识别系统提供模型构建技术支持。

1 图像数据集及预处理

1.1 试验数据

图像数据采集点为云南省昭通市,为体现样本

收稿日期:2021-08-17

基金项目:国家自然科学基金(编号:31860331);云南省科技厅重大专项(编号:2018ZJ001);云南省智慧农业重点实验室基金。

作者简介:徐振南(1997—),男,浙江金华人,硕士研究生,研究方向为智能检测及自动控制。E-mail:872137530@qq.com。

通信作者:杨琳琳,博士,副教授,研究方向为智能检测及自动控制。E-mail:29545343@qq.com。

[9] Szpara M L, Tafuri Y R, Parsons L, et al. A wide extent of inter-strain diversity in virulent and vaccine strains of alphaherpesviruses [J]. PLoS Pathogens, 2011, 7(10): e1002282.

[10] 杨永能. 种公猪精液携带 6 种繁殖障碍性病原状况调查[J]. 中国猪业, 2019, 14(5): 75-78.

[11] Ye C, Zhang Q Z, Tian Z J, et al. Genomic characterization of

emergent pseudorabies virus in China reveals marked sequence divergence: Evidence for the existence of two major genotypes [J]. Virology, 2015, 483: 32-43.

[12] 杨涛涛, 赵 墩, 刘崇灵, 等. 湖南省 4 株伪狂犬病病毒的分离鉴定及其免疫与毒力相关基因的序列分析 [J]. 中国畜牧兽医, 2016, 43(1): 50-57.

多样性,选用不同品牌手机、相机进行拍摄,拍摄角度、时间、地点等多样化。此外,通过互联网公开数据集收集部分样本,收获马铃薯健康叶部图像 39 幅、晚疫病 61 幅、早疫病 50 幅、炭疽病 54 幅以及其他病害 33 幅,总计获得叶部图像 237 幅,部分原始图像如图 1 所示。

1.2 滤波去噪

实际拍摄所得图像通常会存在不同数量的噪声,这些噪声会对图像识别造成一定干扰。因此,为有效过滤图像中椒盐噪声等噪声信息,采用均值滤波、高斯滤波以及中值滤波方式对图像进行图像平滑滤波处理,处理后部分图像示例如图 2 所示。




图1 马铃薯叶部病害样本示例



图2 滤波处理样本示例

1.3 图像分割

由于部分图像拍摄时背景相对复杂,会对病害识别造成一定干扰,因此运用 GrabCut 算法对部分背景相对复杂的样本进行图像分割,提取害病叶片图像,削弱背景影响。GrabCut 算法于 2004 年由 Rother 等提出,其通过图像中所蕴含的纹理(颜色)信息以及边界(反差)信息,仅需少量的用户交互操作,再结合图像处理算法,即可取得良好的分割结

果^[10],具体如图 3 所示。



图3 GrabCut 算法分割提取图像

1.4 图像增强

在对样本图像特征信息进行收集时,通过多种方式对原始数据进行数据增广,可提升模型泛化能力,提高模型的鲁棒性^[11]。对于数据集的数据分布,扩充后数据集中各类训练样本数量相同、分布均匀,这使得模型对于各类别的学习过程不会偏向某一类或某几类,所得模型泛化能力较强^[12]。因此,要对分割后的数据集进行一定程度的数据扩充。

首先,将分割后数据集按照 8 : 2 的比例随机划分训练集和测试集。其次,通过旋转、水平翻转、平移、对比度增强、改变色度的方式增强图像数据,将划分后的数据集扩充至每类 200 张,共 1 000 张图片,扩充后训练集和测试集比例仍为 8 : 2。为探究图像分割对识别效果的影响,不分割原始图像重复上述操作建立数据集。图像分割并增强后部分示例如图 4 所示。

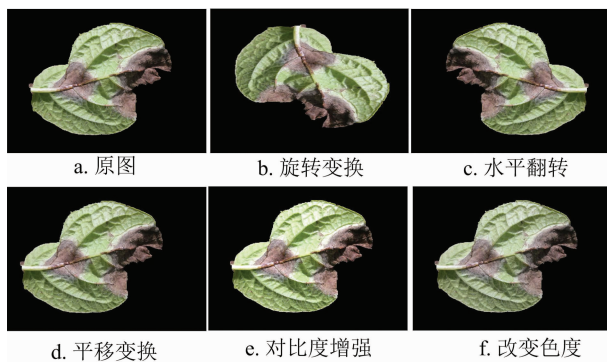


图4 晚疫病原图及增强后图像

因采集工具多样,故原始图像分辨率不统一,在训练前将图像进行归一化、标准化处理。将训练集图片随机大小、随机长宽比进行裁剪,再重置图片为 224×224 像素;重置测试集图片为 256×256 像素,再中心裁剪为 224×224 像素,最后将图片统一转化成 tensor 张量并进行标准化处理。

2 马铃薯叶部病害识别模型

2.1 MobileNetV3 网络模型

卷积神经网络由 AlexNet^[13] 到 VGGNet^[14],再到 GoogleNet^[15]、ResNet^[16],网络性能不断提升,但

网络也是不断加深,由此引发效率问题,该问题一定程度上决定着 CNN 在实际生活中的应用。谷歌于 2017 年提出 MobileNets 模型^[17],于 2019 年提出 MobileNetV3 模型^[18],其基本网络单元如图 5 所示。




图5 MobileNetV3 网络单元

由图 5 可知,相较于 ResNet 模型,该模型运用了 MobileNetV2 模型^[19]中的倒置残差结构(inverted residuals),该结构先升维,深度可分离卷积后再降维,深度可分离卷积主要起减少网络参数,加快运行速度的作用^[20]。在此之上,还根据 Mnas Net(谷歌提出的一种移动平台感知神经网络结构搜索)^[21]引入基于压缩奖惩(squeeze and excitation, SE)结构的轻量级注意力模型,SE 结构能通过训练过程在特征图上自行分配权重,使网络从全局信息出发选择性地放大有价值的特征通道并抑制无用的特征通道^[22]。

此外,相较于 EfficientNet 模型^[23],MobileNetV3 加入一种新的激活函数 Hard - swish,如公式(1)所示。

$$h - swish[x] = x \frac{\text{ReLU}(x + 3)}{6} \quad (1)$$

式中: x 为输入;ReLU 为 ReLU 激活函数。

MobileNetV3 模型识别准确率高、尺寸小,适用于移动端,但目前将其用于作物病害识别研究较少,为实现将马铃薯叶部病害识别模型应用于移动端的任务,要对该模型部分网络结构进行修改。该模型可分为 MobileNetV3 - Large 和 Small,因本研究针对小样本数据集进行研究,故选用 MobileNetV3 - Small 网络,具体结构如表 1 所示。

2.2 模型改进设计

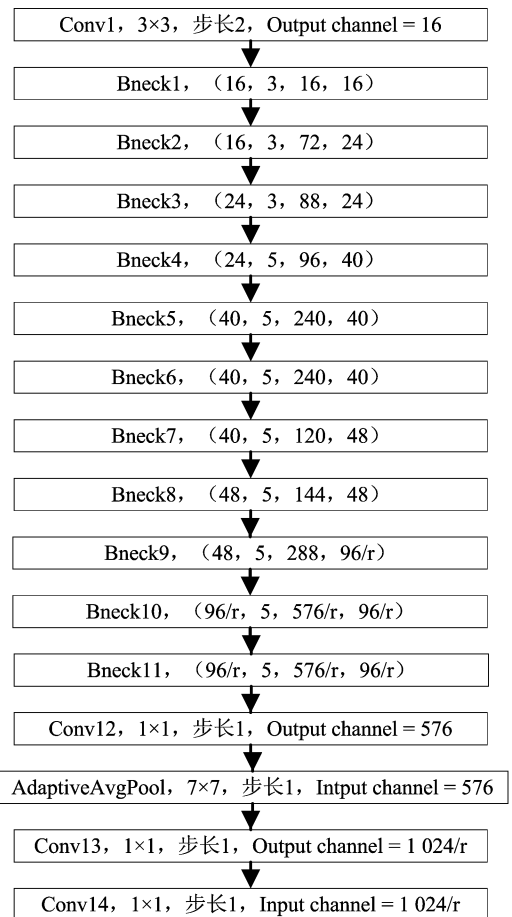
由于需要识别的叶片类型为 5 类,因此将表 1 中最后一个卷积层输出通道数由 1 000 修改为 5,将此模型记作 MobileNetV3 - S0,并以此模型作为后续改进的基础模型。

为减少模型参数并保持其在马铃薯叶片数据集上的性能,基于 MobileNetV3 - S0 进行修改:将超参数 reduce_divider 由 1 调整为 4,修改后网络结构如图 6 所示,并将该模型命名为 MobileNetV3 - S1。

表 1 MobileNetV3 - Small 网络结构

| 操作 | 输入通道数 | 输入大小 | 激活函数 | 步长 |
|--------------------|-------|-----------|------|----|
| Conv2d | 3 | 224 × 224 | HS | 2 |
| Bneck, 3 × 3 | 16 | 112 × 112 | RE | 2 |
| Bneck, 3 × 3 | 16 | 56 × 56 | RE | 2 |
| Bneck, 3 × 3 | 24 | 28 × 28 | RE | 1 |
| Bneck, 5 × 5 | 24 | 28 × 28 | HS | 2 |
| (Bneck, 5 × 5) × 3 | 40 | 14 × 14 | HS | 1 |
| Bneck, 5 × 5 | 48 | 14 × 14 | HS | 1 |
| Bneck, 5 × 5 | 48 | 14 × 14 | HS | 2 |
| (Bneck, 5 × 5) × 2 | 96 | 7 × 7 | HS | 1 |
| Conv2d, 1 × 1 | 96 | 7 × 7 | HS | 1 |
| Avg Pooling, 7 × 7 | 576 | 7 × 7 | | 1 |
| Conv2d, 1 × 1, NBN | 576 | 1 × 1 | HS | 1 |
| Conv2d, 1 × 1, NBN | 1 000 | 1 × 1 | | 1 |

注:NBN 表示不使用 BN 结构;HS 表示 Hard - swish 激活函数;RE 表示 ReLU 激活函数。



图中(16, 3, 16, 16)表示输入通道数,卷积核大小, bneck 模块倒残差结构升维后通道数及输出通道数,其他 bneck 模块同上。自适应平均池化中的 7×7 和卷积层 1、12、13、14 中的 3×3 和 1×1 代表卷积核大小

图6 MobileNetV3-S1 模型

由图 6 可知,超参数 $reduce_divider$ 将影响 $bneck$ 模块 9 的输出通道数, $bneck$ 模块 10、11 的输入、输出以及 $bneck$ 内倒残差结构进行升维后的通道数,其表现如下述公式所示。

$$Final\ Output = Output / reduce_divider. \quad (2)$$

式中: $Final\ Output$ 为最终输出通道数; $Output$ 为输出通道数。

深度学习的网络深度过深将带来梯度不稳定,网络退化等问题。因此,为选择合适的模型深度,对 MobileNetV3-S1 进行如下操作:移除 $bneck$ 模块 6~8,将 $bneck$ 模块 9 的输入通道数由 48 缩减为 40,并将 $bneck$ 模块 9~11 的输出通道数由 96 缩减为 48,并将改动后模型命名为 MobileNetV3-S2,详见图 7。

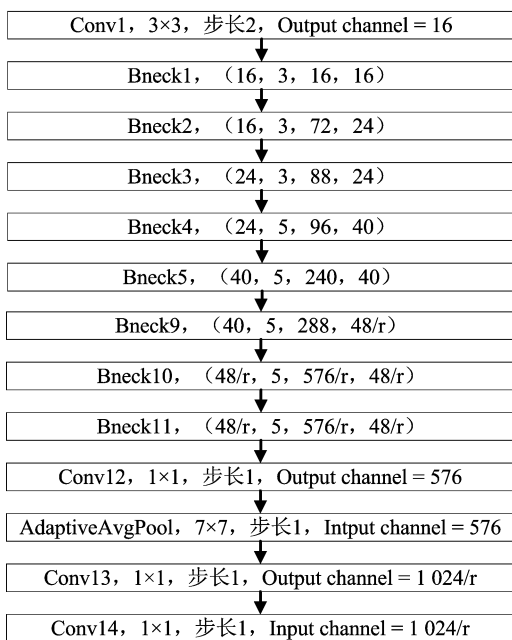


图7 MobileNetV3-S2 模型

图像输入分辨率、网络的深度以及宽度 3 个参数的合理化配置对网络性能具有一定的影响。宽度大而深度较浅的网络很难学习到更深层次的特征。故在降低网络深度的同时,有必要进一步调整网络宽度。对 MobileNetV3-S2 进行如下操作:将超参数宽度系数 α 由默认的 1 改为 0.5;为进一步降低网络深度和计算成本,减少参数量:移除 $bneck$ 模块 5,最终将该模型命名为 MobileNetV3-S3,详见图 8。

考虑到数据集相对较小,直接用于网络训练将产生过拟合或准确率较低等问题。迁移学习可以考虑到大部分数据和任务间的相关性,将使用其他大批量数据训练所得模型来训练新数据,从而减少

训练步骤,缩短训练时间,并增加数据量,从而降低过拟合程度^[24]。故将在公开数据集 PlantVillage 上进行预训练的模型参数,迁移至马铃薯叶部病害识别模型,缩短模型训练时间,提高模型泛化性。

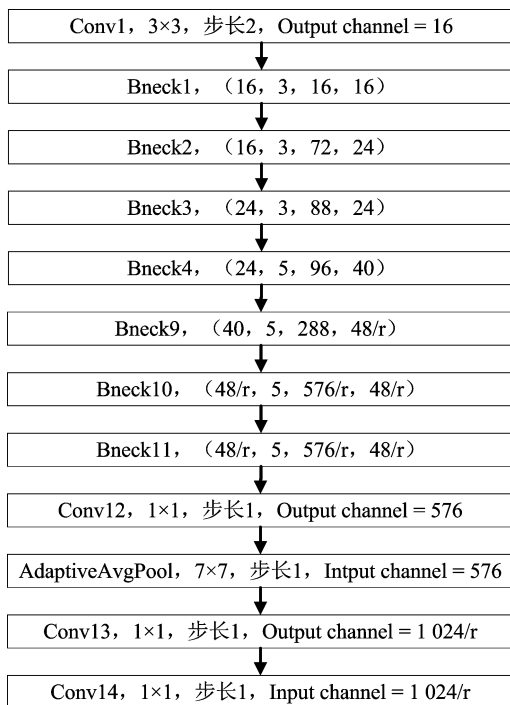


图8 MobileNetV3-S3 模型

3 结果与分析

3.1 试验环境与相关参数设置

试验软件环境为 Windows10 操作系统,使用 python3.8.5 编程语言,以 Pytorch 作为深度学习开源框架,CUDA11.0 编程平台。试验硬件环境为 16 GB 内存,NVIDIA GeForce RTX2060 显卡,搭载 Intel® Core™i7-10875H@5.10 GHz CPU 处理器。

在训练前,将样本数据分为多个批次 (Batch),综合考虑样本数量及计算机的硬件环境,本研究在试验过程中将 Batch 大小设置为 32,模型迭代次数 (Epoch) 设为 100 次。

3.2 试验设计

综合考虑硬件设备性能及训练效果,在相同条件下对同一模型进行训练,包括采用 2 种不同的迁移学习训练方式(只训练全连接层与训练全部层)、不同学习率、3 种不同滤波方式对图像数据进行处理以及图像分割与否等情况进行试验,同时在相同条件下对不同网络模型进行训练对比试验。

3.3 模型性能的影响因素分析

3.3.1 学习率对模型性能的影响 进行深度学习

模型训练时,学习率是最影响模型性能的超参数之一^[25],学习率过大将导致模型不收敛,过小将导致模型收敛过慢或者无法学习。因此,通过试验选取适用于 MobileNetV3-S0 的学习率。试验选用单纯图像增强后数据集,以训练全部层的迁移学习方式,将学习率设置为 0.01、0.001 和 0.000 1 进行讨论。

由图 9-a 可知,相较于 0.01 和 0.000 1 的学习率,学习率为 0.001 时,模型训练准确率最高。交叉

熵损失函数常用于评估模型预测值与真实值的不一致程度,交叉熵损失函数越小,模型的鲁棒性越好。由图 9-b 可知,学习率为 0.001 训练时,交叉熵损失函数均低于其他学习率时的交叉熵损失函数,且模型训练准确率与交叉熵损失函数收敛速度最快。因此,综合考虑训练时模型平均识别准确率与交叉熵损失函数,后续试验中取 0.001 学习率及未分割增强后数据集完成模型训练与测试。

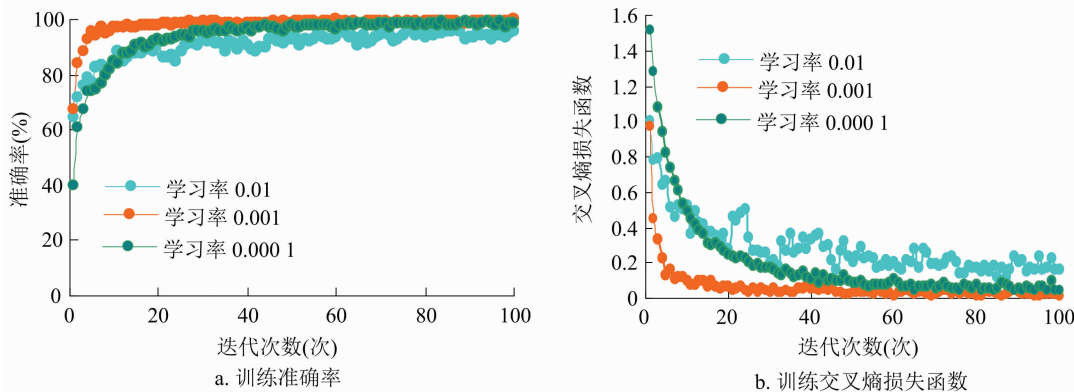


图9 MobileNetV3-S0 网络在不同学习率下的准确率与损失函数对比

3.3.2 迁移学习方式对模型性能的影响

MobileNetV3-S0 模型,在不采用迁移学习和采用 2 种不同(只训练全连接层与训练全部层)迁移学习

方式时,模型训练准确率和交叉熵损失函数变化如图 10-a、图 10-b 所示。




图10 MobileNetV3-S0 网络在不同训练方式下的训练准确率和交叉熵损失

从图 10 可知,MobileNetV3-S0 在运用 3 种不同方式训练过程中,采用迁移学习训练的模型收敛速度和训练准确率明显高于不采用迁移学习的模型,交叉熵损失函数则明显低于不采用迁移学习的模型。

同时,观察图 10 中曲线变化可知,在经过 50 次左右迭代训练后,训练准确率和交叉熵损失函数逐渐趋于稳定,其中,采用训练全部层方式的模型准确率最高,交叉熵损失函数最小,基本降到 0.1 以下,且交叉熵损失函数波动最小。这说明采用训练全部层的迁移学习方式对模型性能的提升最大。

3.3.3 滤波方式对识别准确率的影响 将原始数据集分别经过均值滤波、高斯滤波和中值滤波这 3 种滤波方式处理并通过图像增强后,依次放入模型中进行训练与测试,其所得识别准确率如表 2 所示。由表 2 可知,除经过中值滤波处理的数据集训练准确率与原始数据集一致外,其余滤波方式下的训练准确率均略有下降。同时,3 种经滤波处理的数据集测试准确率相较于原始数据集均有所降低,其中表现最好的中值滤波方式仍降低了 1.00 百分点。这说明,虽然滤波处理可以去除图像中干扰识别效

果的噪声,但同时也对图像本身的部分特征信息造成了一定影响。因此,仍选择经过图像增强但未滤波图像数据集用于模型的训练。

表 2 同一条件不同滤波方式下的识别准确率

| 滤波方式 | 训练准确率 (%) | 测试准确率 (%) |
|------|-----------|-----------|
| 均值滤波 | 99.63 | 92.50 |
| 高斯滤波 | 99.63 | 92.50 |
| 中值滤波 | 99.75 | 94.50 |
| 未滤波 | 99.75 | 95.50 |

3.3.4 模型性能对比 运用 ResNet18、EfficientNet - B0 和 MobileNetV3 - S0 这三种模型进行对比训练和测试,结果(表 3)表明,MobileNetV3 - S0 模型的训练识别准确率分别仅比 EfficientNet - B0 和 ResNet - 18 高出 1.26 和 0.12 百分点,测试识别准确率则是比 ResNet - 18 高 1.50 百分点,比 EfficientNet - B0 低 4.00 百分点。

表 3 同一条件不同模型权重大小、识别速率及准确率

| 模型 | 权重 (MB) | 识别速率 (s) | 训练准确率 (%) | 测试准确率 (%) |
|-------------------|---------|----------|-----------|-----------|
| ResNet - 18 | 44.59 | 0.962 | 99.63 | 94.00 |
| EfficientNet - B0 | 20.17 | 0.986 | 98.49 | 99.50 |
| MobileNetV3 - S0 | 9.70 | 0.052 | 99.75 | 95.50 |

虽然 MobileNetV3 - S0 的测试准确率略低于 EfficientNet - B0,但同时由表 3 可分析出,ResNet18、EfficientNet - B0 的权重参数分别为 MobileNetV3 - S0 的 4.60 倍和 2.08 倍,反之 MobileNetV3 - S0 的识别速率则是 ResNet18、EfficientNet - B0 的 18.50 倍和 18.96 倍。

由表 4 可知,MobileNetV3 - S1 模型相比较于 MobileNetV3 - S0 模型,权重减小 7.39 MB,测试准确率下降 1.00 百分点,这说明调整超参数 reduce_divider 可以较大程度地减小模型权重,但同时会损失一定准确率。而 MobileNetV3 - S2 相较于 MobileNetV3 - S1,权重缩减 0.51 MB,测试准确率升高 2.50 百分点,说明基于 MobileNetV3 - S1 降低模型深度,不但能减小模型权重,还有助于提高测试准确率。MobileNetV3 - S3 的权重比 MobileNetV3 - S2 减少了 1.12 MB,测试准确率降低 0.50 百分点,由此可知,在降低模型深度的同时,减小模型宽度,可进一步减少模型冗余参数,但会损失一定的准确率。

因模型结构不同于 MobileNetV3 - S0,因此对于 MobileNetV3 - S3,0.001 的学习率可能不是最佳学

表 4 改进模型参数及性能

| 模型 | 权重 (MB) | 测试准确率 (%) | 识别速率 (s) |
|------------------|---------|-----------|----------|
| MobileNetV3 - S0 | 9.70 | 95.50 | 0.052 |
| MobileNetV3 - S1 | 2.31 | 94.50 | 0.038 |
| MobileNetV3 - S2 | 1.80 | 97.00 | 0.028 |
| MobileNetV3 - S3 | 0.68 | 96.50 | 0.014 |

习率。故再进行对比试验,由表 5 可知,在 3 种学习率中,最适合 MobileNetV3 - S3 的仍是 0.001。

综上所述,相比 MobileNetV3 - S2,MobileNetV3 - S3 的识别准确率略有下降,但比 MobileNetV3 - S0 提升了 1.00 百分点,且 MobileNetV3 - S3 的权重仅为 MobileNetV3 - S0 的 7.01%,对单张图片识别速率也略有提升。因此,以 MobileNetV3 - S3 作为最终的马铃薯叶部病害识别模型。

表 5 不同学习率下 MobileNetV3 - S3 识别准确率

| 学习率 | 训练准确率 (%) | 测试准确率 (%) |
|--------|-----------|-----------|
| 0.01 | 98.75 | 92.50 |
| 0.001 | 99.25 | 96.50 |
| 0.0001 | 95.63 | 94.00 |

3.3.5 图像分割对识别效果的影响 将运用 GrabCut 算法对部分背景相对复杂图像进行图像分割,提取图像后再进行图像增强,所得数据集输入 MobileNetV3 - S3 中。由表 6 可知,经过 GrabCut 算法分割后数据集训练准确率降低了 0.50 百分点,但是测试准确率却提升了 1.50 百分点。由此可知,运用 GrabCut 算法进行图像分割,有助于进一步提高病害叶片的识别准确率。故最终选用经 GrabCut 算法图像分割扩充后的数据集。

表 6 同一条件下图像分割前后识别准确率

| 数据集 | 训练准确率 (%) | 测试准确率 (%) |
|--------------------|-----------|-----------|
| 图像增强后数据 | 99.25 | 96.50 |
| GrabCut 算法分割并增强后数据 | 98.75 | 98.00 |

4 结论与讨论

本研究针对马铃薯病害快速准确实时识别的需求,建立包含马铃薯健康、晚疫病、早疫病、炭疽病及其他病害共 5 种马铃薯叶部图像数据集。对该数据集运用 GrabCut 算法进行图像分割并进行图像增强操作,在对 MobileNetV3 - Small 模型进行优化

后,基于优化后模型和迁移学习方式训练,并与 ResNet18、EfficientNet - b0 这 2 种网络模型进行对比试验。根据试验结果得出如下结论:(1)采用迁移学习的方式在提高模型的识别准确率的同时降低了模型的交叉熵损失函数,增强了模型稳定性。而这 2 种迁移学习训练方式,从识别率和损失函数收敛 2 个方面来看,训练全部层的方式更优。(2)基于 MobileNetV3 - Small 改进所得模型 MobileNetV3 - S3,采用 0.001 的学习率和训练全部层的迁移学习方式,对仅进行图像增强的数据集训练后所得测试准确率最高为 96.50%,比 MobileNetV3 - S0 高出 1.00 个百分点。在运用 GrabCut 算法分割图像后,模型测试准确率提升至 98.00%。(3) MobileNetV3 - S3 权重大小为 0.68 MB, MobileNetV3 - S0 权重为其 14.26 倍。MobileNetV3 - S3 模型测试准确率虽略低于 EfficientNet - B0,但其识别速率为后者的 70.43 倍,且其权重仅为后者的 3.37%,有利于马铃薯病害识别在移动端的实现。

综上所述,将基于 GrabCut 算法分割图像所建数据集,结合基于 MobileNetV3 - Small 改进的模型 MobileNetV3 - S3,运用迁移学习方式训练所得识别模型,在马铃薯叶部病害识别上,具有准确率高、识别快、权重小等特点。该方法为实现马铃薯叶部病害识别在移动端的良好应用提供了可行性。

参考文献:

- [1]肖金钟. 马铃薯生产中的常见病害[J]. 现代园艺, 2020, 43(18):37-40.
- [2]范子耀,王文桥,孟润杰,等. 7 种杀菌剂对马铃薯早疫病菌室内毒力及田间防效[J]. 农药, 2011, 50(7):531-533.
- [3]王秀鹏. 马铃薯常见病害识别及防治技术[J]. 种子科技, 2018, 36(6):101, 103.
- [4]边柯橙,杨海军,路永华. 深度学习在农业病虫害检测识别中的应用综述[J]. 软件导刊, 2021, 20(3):26-33.
- [5]赵建敏,李艳,李琦,等. 基于卷积神经网络的马铃薯叶片病害识别系统[J]. 江苏农业科学, 2018, 46(24):251-255.
- [6]孙文杰,牟少敏,董萌萍,等. 基于卷积循环神经网络的桃树叶部病害图像识别[J]. 山东农业大学学报(自然科学版), 2020, 51(6):998-1003.
- [7]谢裕睿,苗晟,张铄,等. 基于残差神经网络的烟草病害识别研究[J]. 现代计算机, 2020(30):27-31.
- [8]杨森,冯全,张建华,等. 基于轻量卷积网络的马铃薯外部缺陷无损分级[J]. 食品科学, 2021, 42(10):284-289.
- [9]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.
- [10]Rother C, Kolmogorov V, Blake A. "GrabCut": interactive foreground extraction using iterated graph cuts [J]. ACM Transactions on Graphics, 2004, 23(3):309-314.
- [11]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.
- [12]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.
- [13]Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6):84-90.
- [14]Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J]. Computer Science, 2014, 52(3):1-14.
- [15]Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition. June 7-12, 2015, Boston, MA. IEEE, 2015:1-9.
- [16]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. Las Vegas: IEEE, 2016:770-778.
- [17]Howard A G, Zhu M L, Chen B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [EB/OL]. [2021-08-17]. <https://arxiv.org/abs/1704.04861>.
- [18]Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3 [C]//Proceeding of the IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2019:1314-1324.
- [19]Sandler M, Howard A, Zhu M, et al. MobileNetV2 inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018:4510-4520.
- [20]刘梦伦,赵希梅,魏宾. 基于 MobileNet V2 - ELM 的肝硬化识别[J]. 青岛大学学报(自然科学版), 2019, 32(4):17-21.
- [21]Tan M X, Chen B, Pang R M, et al. MnasNet: platform-aware neural architecture search for mobile [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 15-20, 2019, Long Beach, CA, USA. IEEE, 2019:2815-2823.
- [22]Hu J, Shen L, Sun G, et al. Squeeze-and-excitation networks [C]//Proceeding of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Piscataway: IEEE, 2018:7132-7141.
- [23]Tan M X, Le Q V. EfficientNet: rethinking model scaling for convolutional neural networks [C]//36th International Conference on Machine Learning (ICML 2019). Los Angeles: Proceeding of Machine Learning Research, 2019:6105-6114.
- [24]米硕,孙瑞彬,李欣,等. 迁移学习在卷积神经网络中的应用[J]. 中国新通信, 2018, 20(7):121.
- [25]冯晓,李丹丹,王文君,等. 基于轻量级卷积神经网络和迁移学习的小麦叶部病害图像识别[J]. 河南农业科学, 2021, 50(4):174-180.