

章广传,李 彤,高 泉,等. 融合迁移学习和知识蒸馏的轻量级马铃薯叶片病害识别模型的构建方法[J]. 江苏农业科学,2024,52(4):197-206.
doi:10.15889/j.issn.1002-1302.2024.04.030

融合迁移学习和知识蒸馏的轻量级马铃薯叶片病害识别模型的构建方法

章广传^{1,3},李 彤³,高 泉^{2,3},叶 荣³,何 云^{2,3}

(1. 云南农业大学机电工程学院,云南昆明 650000; 2. 云南农业大学大数据学院,云南昆明 650000;

3. 云南省作物生产与智慧农业重点实验室,云南昆明 650000)

摘要:轻量级深度学习模型常被部署于移动端或物联网端,以实现算力资源受限条件下马铃薯病害的识别。但轻量级模型网络层数较少,模型特征提取能力有限,无法实现相似表型特征的精确提取。为解决上述问题,提出一种轻量级残差网络模型的构建方法,该方法融合迁移学习和知识蒸馏策略训练模型,在教师模型上使用迁移学习策略缩短教师模型的训练时间,并将 ResNet18 模型进行模型剪枝,使用降采样的方法提高模型识别准确率,最终在保证轻量化的前提下,实现对马铃薯叶片病害类别的精准识别。在马铃薯叶片数据集上进行试验,结果表明,本研究方法构建的轻量级模型的识别准确率相较于 Resnet18 提高 1.55 百分点,模型大小缩小 49.18%;相较于目前农作物病害识别领域,常用的轻量级模型 MobileNetV3 在模型大小相近的情况下,识别准确率提高 2.91 百分点。该模型能够满足大部分实际应用下的场景,可为部署在物联网和移动端设备上的模型提供参考。

关键词:马铃薯;病害识别;轻量级模型;迁移学习;知识蒸馏

中图分类号:TP391.41 **文献标志码:**A **文章编号:**1002-1302(2024)04-0197-09

马铃薯是全世界最重要的粮食作物之一,而中国是世界马铃薯总产量最多的国家。马铃薯病害一直是马铃薯生产中的痛点问题,严重影响我国现代化农业发展和农民增收增收。马铃薯病害的及时识别和防治,对于保障马铃薯的产量和质量具有重要意义^[1]。传统的病害识别主要依靠人工观察和检测,存在效率低、准确率低、成本较高等问题。彭学文等研究发现,只有 21% 的农民能够依靠自身知识积累识别出农作物的病害^[2]。我国传统农业正在向现代化智慧农业转化,智慧农业依托农业大数据,集物联网、传感器、云计算等多种新兴技术为一体,实现农业生产中的智能感知、监测、预警、分析等,并提供精准决策^[3]。

在 21 世纪初,大多数研究者在处理农作物病害

分类问题时,首先是对图像进行预处理,如灰度变换、图像增强等,然后进行特征提取,送入分类器进行病害识别^[4-5]。此阶段,大多数研究者将 BP 神经网络、SVM、贝叶斯判别法作为识别病害的分类器^[6]。Prabhakar 等对植物病害程度进行划分,然后使用 ResNet-101 模型进行识别,最终在测试集上的识别准确率达到 94.6%^[7]。王东方等提出基于迁移学习改进 ResNeXt-101 模型,用于不指定农作物种类的病害检测分类,在重构的 AI Challenger 2018 农作物病害数据集上,将该模型与 VGG-16、GoogleNet、ResNet-50、DenseNet-121 卷积神经网络模型进行比较,结果表明在相同试验条件下,对不同作物不同病害分类的平均准确率达到 98%,分类效果优于其他模型^[8]。杜甜甜等针对受害程度识别不准确的问题,引入有效通道注意力机制用以提高模型的特征提取能力,在模型的分层引入多尺度特征融合策略,用以提高模型对细粒度特征的分类能力,使用深度迁移学习来优化模型的整体性能,加快模型的收敛速度,提高模型的泛化能力,试验表明 RegNet 网络模型在作物病害损害水平数据集上的准确率达到 94.5%^[9]。上述这些研究应用的模型都属于复杂网络模型,具有学习能力强、特征提取能力强等特点,缺点是消耗大量的算力资

收稿日期:2023-07-24

基金项目:国家自然科学基金(编号:32101611);云南省基础研究计划(编号:202101AU070096);云南省重大科技专项计划(编号:202202AE090021、202302AE090020);省部共建云南生物资源保护与利用国家重点实验室开放课题(编号:GZKF2021009)。

作者简介:章广传(1998—),男,安徽铜陵人,硕士研究生,主要研究方向为数字农业。E-mail:1535797658@qq.com。

通信作者:何 云,博士,讲师,主要研究方向为软件工程、数字农业。E-mail:heyun@ynau.edu.cn。

源,不适宜部署在算力资源有限的移动端或物联网端设备上。

为了实现农作物图像识别模型在移动端或物联网端的应用,研究人员尝试引入轻量级深度学习模型。鲍文霞等利用深度语义分割网络 U-Net 对大田环境下的小麦图像进行分割,设计结构较为简单的多路卷积神经网络,分别提取麦穗图像 RGB 3 个通道的特征,迁移学习 CDCNNv2 模型对农作物病害的严重程度进行识别,识别效果达到 94.51%^[10]。余小东等采用迁移学习方式并结合深度学习,分别与使用迁移学习的 ResNet-50、Xception、VGG16、VGG19、DenseNet-121、CDCNNv2 模型进行对比试验,结果表明基于残差网络(ResNet-50)的 CDCNNv2 算法效果最优,通过联合损失函数的多路卷积神经网络,在大田复杂背景下对麦穗赤霉病的识别精度达到 90.5%^[11]。Pujari 等通过将提取的粮食作物叶片真菌病害的 LBP 特征送入神经网络而进行病害分类^[12]。You 等提出一种微调的 GoogleNet 模型,以处理农田场景所呈现的复杂背景^[13]。轻量级模型对相似表型特征的识别能力较低,但轻量级模型存在参数量小、运行成本低、运算耗时少等特性,因此能够被快速部署到移动端设备。目前马铃薯叶片病害主要是早疫病和晚疫病,叶片病斑具有分布杂乱、面积小、相似度高且形状各异等特点,现有的轻量级模型难以实现马铃薯叶片病害的高精度实时分类识别。

本研究提出一种融合迁移学习和知识蒸馏的轻量级马铃薯叶片病害识别模型的构建方法,能够构建出一个高精度的轻量级病害图像识别模型。与现有的复杂网络模型相比,该模型具有较少的模型参数,更适宜在移动设备或物联网端部署;与现有的轻量级模型相比,该模型能够实现更高的识别准确率。将该模型部署于移动端,可以实现马铃薯叶片病害的及时发现和诊断,降低病害导致的经济损失。

1 相关知识

1.1 ResNet 基础模型

ResNet 模型是深度残差模型^[14],可以将残差模块理解为一个子网络,通过堆叠子网络搭建一个很深的网络模型;网络越深,所能获取的信息越多,特征也越丰富。随着网络的不断加深,造成梯度爆炸和梯度消失等问题,优化效果反而变差,测试数据

和训练数据的准确率随之降低^[15]。对输入数据和中间层的数据进行归一化操作,这种方法可以保证网络在反向传播中采用随机梯度下降(stochastic gradient descent,SGD),从而让网络达到收敛^[16]。但这个方法仅对几十层的网络有用,当网络再加深时,归一化操作的效果便微乎其微了。针对退化现象,He 等提出 ResNet 网络通过“快捷连接(shortcut connection)”构造残差模块^[14],包括一个卷积层拟合和 Shortcut 恒等映射,定义残差模块学习的特征 $H(x)$ 如公式(1)所示。

$$H(x) = F(x) + x. \quad (1)$$

1.2 迁移学习

迁移学习(transfer learning)的目的是应用已有的知识来更好地解决新问题。迁移学习能加快模型的训练速度,增强模型的鲁棒性^[17-19]。将 ImageNet 数据集训练 ResNet101 模型的参数和权重迁移至预训练模型,选择合适的层数冻结参数,重新训练未冻结网络,更新网络权值,浅层卷积层提取基础特征,比如边缘、轮廓等基础特征;深层卷积层提取抽象特征,比如整个叶片等;全连接层根据特征组合进行评分分类^[20]。对于微调模型而言,选择一个合适的层数进行冻结就显得尤为重要,冻结层过少,模型训练仍需要大量时间,会导致算力资源的浪费;冻结层过多,微调模型不易收敛,导致模型泛化能力弱。

1.3 知识蒸馏

深度学习在计算机视觉、语音识别、自然语言处理等众多领域中均体现了令人难以置信的性能。但是,大多数模型在计算上过于复杂,无法在物联网和移动端设备上运行。轻量级模型能够完成一些实时性任务,但难以完成更深层次的特征分析。因此,引用知识蒸馏策略将大模型中提取的深层特征知识迁移到轻量级模型。知识蒸馏的本质属于迁移学习的范畴,其主要思路是将已经训练完善的模型作为教师模型,通过控制温度 T 从教师模型的输出结果中“蒸馏”出“知识”用于学生模型的训练,并希望轻量级模型能够学到教师模型的“知识”,达到和教师模型相同的表现;这里的“知识”在狭义上的解释是教师模型的输出中包含的某种相似性,这种相似性能够被用作迁移并辅助其他模型的训练^[21]。知识蒸馏策略训练模型可以提升模型精度,若目前网络模型 A 的精度较低,那么可以先训练一个更高精度的模型 B,通常模型 B 的参数量较多,训

练时间较长,然后用这个训练好的模型 B 对模型 A 进行知识蒸馏策略训练,得到一个高精度的模型 A^[22]。

2 本研究方法

马铃薯叶片病害识别属于细粒度图像识别任务。为了更精准地识别马铃薯病害叶片的病斑特征及病害程度,本研究方法引入迁移学习训练

ResNet101 复杂模型,构建轻量级网络作为学生模型。构建轻量级网络时,利用降采样的方法提高模型对图像的利用率,从而提高模型的识别准确率;利用模型剪枝的方法减小模型的大小,以便部署在物联网和移动设备上。将迁移学习后的 ResNet101 模型利用知识蒸馏策略训练本研究构建的轻量级模型 ResNet13,得到高精度轻量级模型(图 1,黑框白字为重点研究内容)。

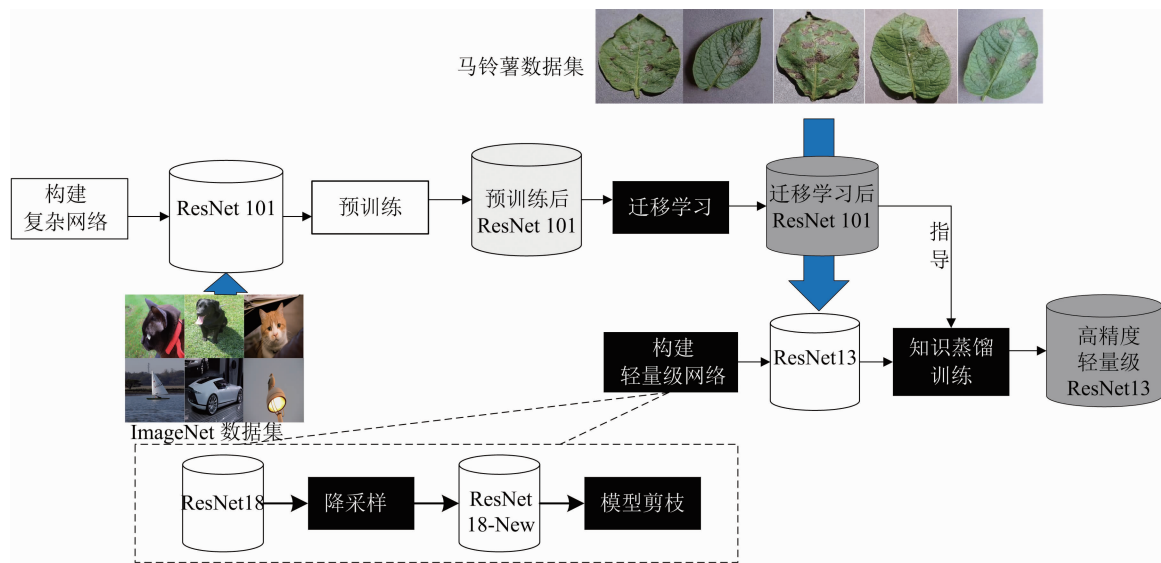


图 1 本研究方法的主要结构

2.1 基于迁移学习的 ResNet101 教师模型训练

由于马铃薯叶片病害病斑之间的相似度较高,需要对同一类病害进行更为细致的划分,对模型的特征提取能力要求较高。教师模型是知识蒸馏的关键因素之一,教师模型的识别准确率将直接影响最终的识别精度;而一般复杂网络提取特征更为深层,识别准确率高但训练时间久,因而引入迁移学习加速模型训练。构建复杂网络 ResNet101 模型,在 ImageNet 数据集上预训练,将其参数和权重迁移至预训练模型,利用上述的微调模型重新训练部分网络,获取马铃薯数据集的特征。

定义 1: ResNet101 模型为一个由 101 层 (Layer) 组成的复杂网络模型,则有 $Model_{ResNet101} = \{Layer_1, Layer_2, Layer_3, \dots, Layer_{101}\}$, $Tacc_i$ 为冻结 $Layer_1 \sim Layer_i$ 层的识别准确率。本研究将 ResNet101 模型的 $Layer_1 \sim Layer_6$ 这 6 个卷积层冻结,训练模型记录模型识别准确率为 $Tacc_6$,依次增加冻结卷积层数,直到冻结 $Layer_m$ 的 $Tacc_m$ 低于冻结 $Layer_{m-1}$ 的 $Tacc_{m-1}$,保存冻结 $Layer_{m-1}$ 的权重

$weight_{m-1}$,用于后续研究。迁移学习流程如图 2 所示, m 初始值等于 7。

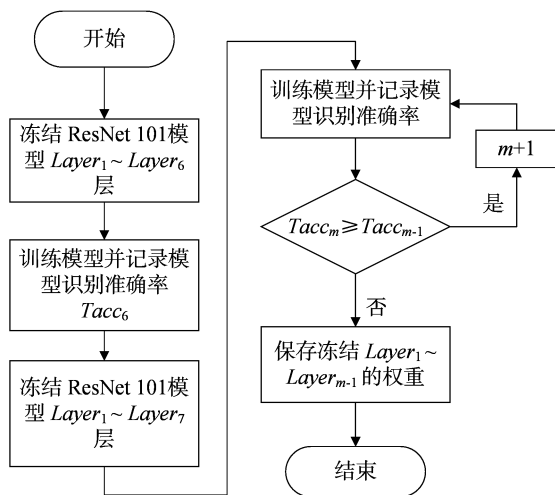


图 2 迁移学习流程图

2.2 基于降采样和模型剪枝的轻量级学生模型构建

马铃薯叶片病害的识别模型通常部署于移动

端和物联网端,在算力有限的情况下要达到精准识别,模型要求参数小、识别速率快等。本研究提出一种轻量级模型的构建方法,利用降采样提高模型的识别准确率,并利用模型剪枝压缩模型的大小。

2.2.1 降采样 每个残差模块的第 1 个 conv 都有 1 个下采样的步骤,Input 数据后经历 1 个步长为 2、1×1 的卷积,将特征图的尺寸减小为原来的一半,导致特征图的一部分信息不被利用,对马铃薯病害叶片图像特征的提取效果影响较大。为提升残差模块的特征提取能力,将下采样步骤下移至 3×3 的卷积去完成(图 3-a、图 3-b)。卷积核在移动过程中能覆盖整张图像,从而避免信息的大量流失,将重构的模型命名为 ResNet18-New、ResNet101-New。公式(2)中,输出尺寸为输入尺寸的 1/2,与原始残差模块输出尺寸保持一致。

$$Output = \frac{Input - K + 2 \times P}{s + 1} \quad (2)$$

式中:Output 表示输出尺寸;Input 表示输入尺寸;K 表示卷积核尺寸;P 表示边缘填补大小,等于 1,s 表示步距,为 2。

2.2.2 模型剪枝 深度学习模型从卷积层到全连接层存在大量冗余的参数,复杂结构带来一系列的问题:对于层数和神经元数量较多的深层网络模型,计算延迟难以达到应用的标准,尤其是对于一些实时任务。本研究针对 ResNet18 网络进行模型剪枝^[23],使模型轻量化,更利于部署在移动端。由图 3-c 可见,将网络中部分卷积核进行重构并删除冗余的卷积核,新网络依据网络层数命名为 ResNet13。模型剪枝后的卷积核如表 1 模型 ResNet13 所示。

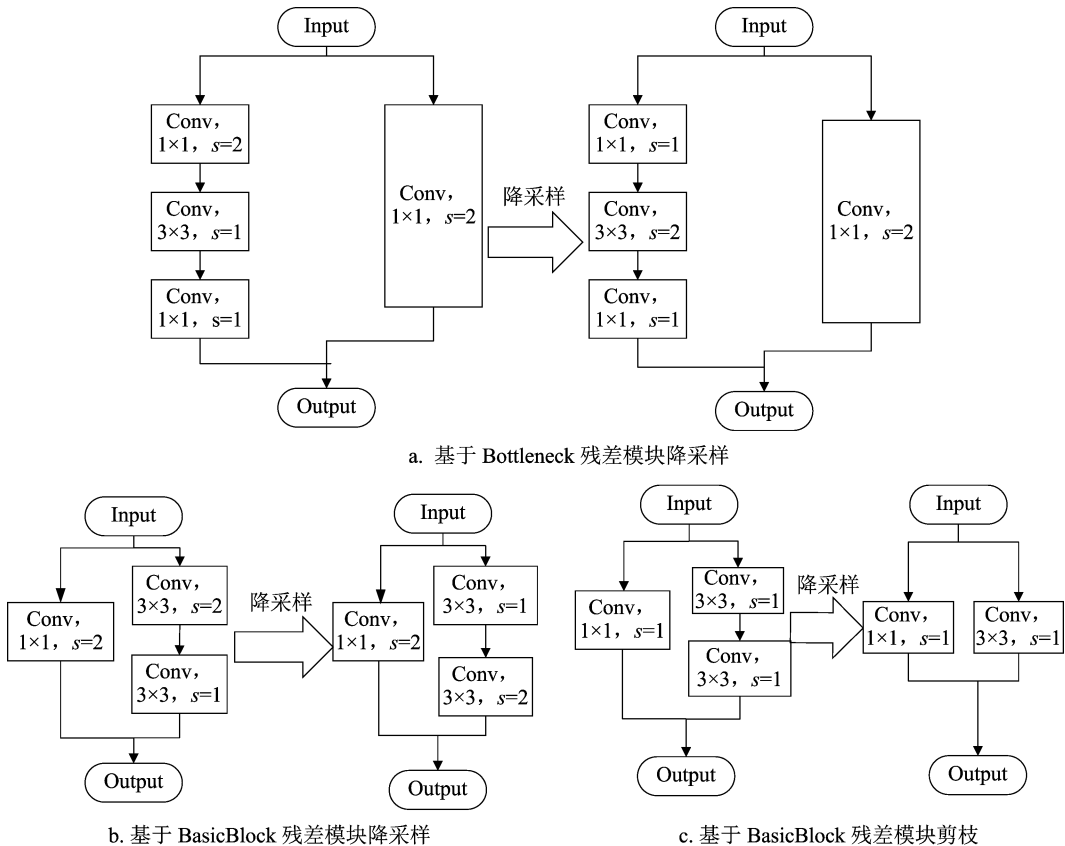


图3 残差模块

2.3 基于知识蒸馏策略的轻量级学生模型训练

由于马铃薯叶片病斑呈分布杂乱、面积小、相似度高且形状各异等特点,浅层网络模型难以实现马铃薯叶片病害高精度实时分类。利用高精度教师模型 ResNet101,使用知识蒸馏策略训练学生模

型,其中教师模型是“知识”的输出者,学生模型是“知识”的接受者。Hinton 等称之为嵌入在教师模型的“暗知识”,也就是在蒸馏阶段需要迁移到学生模型的暗知识^[22]。本研究方法采用的知识蒸馏过程分为 2 个阶段(图 4)。

表 1 各模型卷积核对比

层数	各模型卷积核		
	ResNet13	ResNet18	ResNet101
Layer1	$(3 \times 364) \times 2$ 3×364	$(\frac{3 \times 364}{3 \times 364}) \times 2$	$(\frac{1 \times 164}{3 \times 364} \times 3)$ $(\frac{1 \times 1256}{1 \times 1256}) \times 3$
Layer2	$\frac{3 \times 3 \times 218}{3 \times 3 \times 218}$ $\frac{3 \times 3 \times 218}{3 \times 3 \times 218}$	$(\frac{3 \times 3 \times 218}{3 \times 3 \times 218}) \times 2$	$(\frac{1 \times 1 \times 218}{3 \times 3 \times 218}) \times 4$ $(\frac{1 \times 1 \times 512}{1 \times 1 \times 512}) \times 4$
Layer3	$\frac{3 \times 3 \times 256}{3 \times 3 \times 256}$ $\frac{3 \times 3 \times 256}{3 \times 3 \times 256}$	$(\frac{3 \times 3 \times 256}{3 \times 3 \times 256}) \times 2$	$(\frac{1 \times 1 \times 256}{3 \times 3 \times 256}) \times 23$ $(\frac{1 \times 11 \times 024}{1 \times 11 \times 024}) \times 23$
Layer4	$\frac{3 \times 3 \times 512}{3 \times 3 \times 512}$	$(\frac{3 \times 3 \times 512}{3 \times 3 \times 512}) \times 2$	$(\frac{1 \times 1 \times 512}{3 \times 3 \times 512}) \times 3$ $(\frac{1 \times 12 \times 047}{1 \times 12 \times 047}) \times 3$

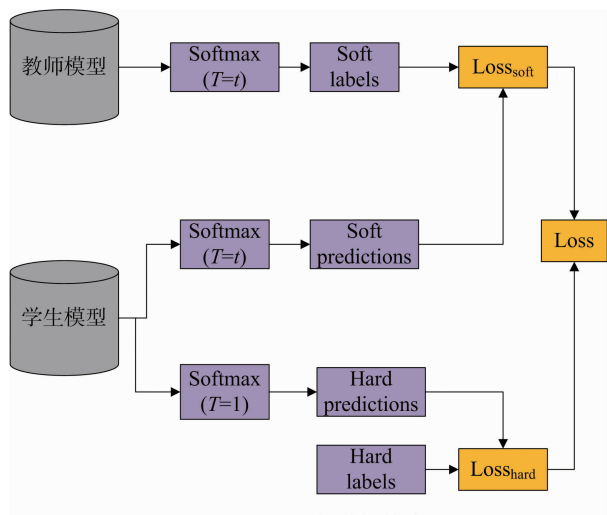


图 4 知识蒸馏策略

教师模型训练:训练教师模型 ResNet101,教师模型相对复杂,模型识别准确率高。在温度为 T 的时候,根据教师模型的 SoftMax 与学生模型的 SoftMax 计算 $Loss_{hard}$ 。

学生模型训练:知识蒸馏策略训练学生模型,学生模型参数量较小,模型结构相对简单。在温度

为 1 的时候,根据学生模型的 SoftMax、Hard labels 计算 $Loss_{hard}$,利用知识蒸馏策略训练学生模型,将教师模型 ResNet101 中学习到的“知识”传授给学生模型,从而提升学生模型的识别效率。

$Loss$ 计算公式如下:

$$Loss = \beta T^2 L_{soft} + \alpha L_{hard} \quad (3)$$

式中: L_{soft} 表示学生模型与教师模型的损失函数。其定义表达式如下:

$$L_{soft} = - \sum_j p_j^T \lg q_j^T \quad (4)$$

其中: $p_j^T = \frac{e^{\frac{v_j}{T}}}{\sum_k e^{\frac{v_k}{T}}}$; $q_j^T = \frac{e^{\frac{u_j}{T}}}{\sum_k e^{\frac{u_k}{T}}}$

式(3)中: L_{hard} 表示学生模型与真实样本标签的损失函数。其定义表达式如下:

$$L_{hard} = - \sum_j c_j \lg q_j^1 \quad (5)$$

其中: $q_j^1 = \frac{\exp(u_j)}{\sum_k \exp(u_k)}$; v_j 表示教师模型在第 j 个类别的 logit; u_j 表示学生模型在第 j 个类别的 logit; p_j^T 表示教师模型在温度 T 下 SoftMax 输出在第 j 类上的值; q_j^T 表示学生模型在温度 T 下 SoftMax 输出在第 j 类上的值; N 表示总标签数量; α 、 β 为蒸馏超参数; T 表示温度。

3 试验与分析

3.1 试验准备

为加强模型的鲁棒性,数据集不仅需要简单背景的试验数据,还需要有复杂背景的实况数据。本研究数据集由 AI Challenger 2018 竞赛数据集和 PlantVillage 数据集构成,包含健康马铃薯叶片、马铃薯早疫病一般类别叶片、马铃薯早疫病严重类别叶片、马铃薯晚疫病一般类别叶片、马铃薯晚疫病严重类别叶片(图 5)。




图 5 马铃薯病害示例

试验时间为 2023 年 3—6 月,试验地点为云南农业大学云南省作物生产与智慧农业重点实验室。

试验数据集中马铃薯叶片病害图片数量有限,且各类别样本数分布不均,为了增强病害图像的多样性

和模型的泛化能力,选择数据增强方法扩大数据集。数据增强技术包含了多种变换方法,包括颜色的数据增强(色彩饱和度、对比度、亮度)、PCA处理、镜像变换等。试验使用Python中的PTL模块,对部分样本不足的试验数据图像进行水平翻转,增强模型鲁棒性及适应性;针对数据集中部分病害,使用垂直翻转使数据增强。为使模型训练更有效率,将本研究数据集中所有图像统一调整为224像素×224像素,在马铃薯病害类别中使用数据集标签0、1、2、3、4,分别代表健康马铃薯叶片、马铃薯早疫病一般类别叶片、马铃薯早疫病严重类别叶片、马铃薯晚疫病一般类别叶片、马铃薯晚疫病严重类别叶片。根据数据增强后的图像将数据集划分为训练集、测试集、验证集,其比例为8:1:1。通过测试集测试模型的识别准确率。数据集的各类样本统计结果见表2。

表2 马铃薯叶片病害数据集 个

类别名称	原始数据集	数据增强后			
		训练集	验证集	测试集	总计
健康	1 430	1 145	142	143	1 430
早疫病一般	203	650	81	81	812
早疫病严重	510	817	101	102	1 020
晚疫病一般	251	804	100	100	1 004
晚疫病严重	446	714	89	89	892
总计	2 840	4 130	513	515	5 158

本研究采用Pytorch作为马铃薯病害识别模型搭建和训练平台,计算机环境为Windows10系统,CPU型号为AMD Ryzen 7 4800H,GPU型号为NVIDIA GeForce RTX 2060。

试验选择 $1e-3$ 作为初始学习率,设置批尺寸大小为32,使用自适应学习率优化算法Adam默认框架参数。蒸馏超参数设置为 $\alpha=0.3$ 、 $\beta=0.7$,蒸馏温度默认设置为 $T=10$ 。

3.2 试验验证问题

为验证本研究方法的有效性,主要验证如下几个问题(research question,RQ)。

RQ1:基于迁移学习能否提高教师模型的训练效果;

RQ2:基于知识蒸馏技术能否提高轻量级模型的识别准确率;

RQ3:基于降采样和模型剪枝的模型构建方法能否进一步提高轻量级的模型性能;

RQ4:知识蒸馏温度对模型的影响;

RQ5:本研究方法构建的轻量级模型与农作物病害常用的模型相比性能如何。

3.3 模型评价指标

选取准确率(Accuracy,Acc)、精确率(Precision,P)、平均召回率(Recall,R)、特异度(Specificity,S)、迭代时间(iterate time)、模型大小(model size)作为评价指标衡量模型的性能。

准确率指模型能够正确识别所有样本(N)中的正确样本的比例。公式如下:

$$Acc = \frac{1}{4} \sum_{i=0}^4 \frac{TP_i}{N} \times 100\% \quad (6)$$

精确率指某一类的预测正确的样本中真正正确样本的比例。公式如下:

$$P = \frac{1}{4} \sum_{i=0}^4 \frac{TP_i}{TP_i + FP_i} \times 100\% \quad (7)$$

召回率指某一类正确样本中的被预测正确的样本所占比例。公式如下:

$$R = \frac{1}{4} \sum_{i=0}^4 \frac{TP_i}{TP_i + FN_i} \times 100\% \quad (8)$$

特异度指某一类反例的样本中被预测为反例样本所占比例。公式如下:

$$S = \frac{1}{4} \sum_{i=0}^4 \frac{TN_i}{TN_i + FP_i} \times 100\% \quad (9)$$

3.4 基于迁移学习能否提高教师模型的训练效果

为验证迁移学习能否提高教师模型的训练效果,设置第1组消融试验,通过引入迁移学习对ResNet101模型性能进行提升(图6、表3)。其中,ResNet101-TL代表引入迁移学习以后的教师模型。

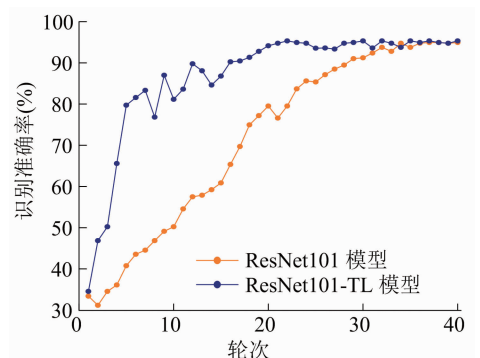


图6 迁移学习对 ResNet101 模型训练的影响

表3 迁移学习试验结果

迁移学习	模型	准确率 (%)	模型大小 (MB)	迭代时间 (s)
×	ResNet101	94.95	162	84
√	ResNet101-TL	95.34	162	29

将 ResNet101 模型的前 3 个 Layer 层冻结, 不参与参数更新; 利用迁移学习策略训练 ResNet101 - TL 模型, 与未采用迁移学习策略训练 ResNet101 模型相比, 加快模型收敛速度; 在第 20 轮迭代时, 模型就处于收敛状态, ResNet101 在第 34 轮迭代才达到收敛状态。同时, ResNet101 - TL 模型相比 ResNet101 减少了 65.48% 的迭代时间, 并提高 0.39 个百分点的识别准确率, 较为明显地减少了模型训练时间。在教师模型训练时引用迁移学习, 可增加模型的鲁棒性。

3.5 基于知识蒸馏技术能否提高轻量级模型的识别准确率

为验证知识蒸馏技术能否提高轻量级模型的识别准确率, 设置第 2 组消融试验, 通过引入知识蒸馏技术对 ResNet18 模型进行训练, 训练结果如图 7、表 4 所示。其中 ResNet18 - KD 代表引入蒸馏策略训练后的模型。

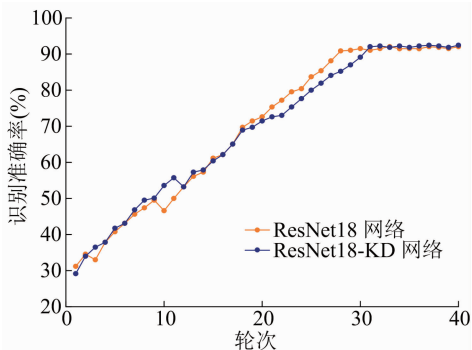


图7 知识蒸馏策略对 ResNet18 模型的提升

表 4 知识蒸馏试验结果

知识蒸馏	模型	准确率 (%)	迭代时间 (s)
×	ResNet18	92.04	25
√	ResNet18 - KD	92.45	25

通过引入知识蒸馏策略训练模型, 将进行迁移学习的教师模型 ResNet101 的权重指导训练学生模型 ResNet18, 模型在识别准确率上提升了 0.41 个百分点; 在学生模型训练时引用知识蒸馏策略训练模型, 提高了模型识别准确率, 增加了模型的泛化能力。

3.6 基于降采样和模型剪枝的模型构建方法能否进一步提高轻量级学生模型性能

为验证本研究提出的模型构建方法能否提高轻量级模型的性能, 设置 2 组对比试验。

第 1 组试验, 对比模型降采样能否提高轻量级

学生模型性能。模型降采样的优势在于能够较好地保留低层次的信息和完整的图像信息。本研究将下采样步骤下移至 3×3 的卷积去完成, 从而避免信息的大量流失。只有 $Layer_2$ 、 $Layer_3$ 、 $Layer_4$ 的第 1 个 Basic Block 进行下采样, $Layer_1$ 没有下采样。模型降采样试验结果如表 5 第 1、第 2 行所示。

表 5 模型降采样与模型剪枝试验结果

模型	准确率 (%)	模型大小 (MB)	迭代时间 (s)
ResNet18	92.04	42.7	25
ResNet18 - New	92.23	42.7	26
ResNet13	91.85	21.7	17

第 2 组试验, 对比模型剪枝能否提高轻量级学生模型性能。为了使 ResNet18 模型更加轻量化, 针对 ResNet18 模型的卷积核进行重构与删除, 将新网络依据网络层数命名为 ResNet13 模型。改进后的网络性能如表 5 第 3 行所示。通过模型剪枝使网络模型准确率达到 91.85%, 仅比 ResNet18 模型降低了 0.19 个百分点, 而模型大小缩减了将近一半, 仅为 21.7 MB。改进后的模型在识别马铃薯叶片病害时表现更优, 混淆矩阵如图 8 所示。




图8 ResNet13 模型混淆矩阵

3.7 蒸馏温度对模型的影响

知识蒸馏中温度系数的选择是知识迁移效果的决定性因素, 知识蒸馏通过对输出进行修改, 增加一个温度系数 T , 随着温度系数 T 增大, 通过 softmax 函数得到的概率分布就变得更加软化, 提供更多的信息。采用 ResNet13 模型作为学生模型识别马铃薯病害叶片, 教师模型 ResNet101 将学习的“暗知识”迁移至学生模型 ResNet13。图 9 为不同蒸馏温度下学生模型 ResNet13 的识别准确率, 随着蒸馏温度的增大, 模型识别准确率总体呈上升趋势

势;在蒸馏温度为 15 时,识别准确率达到最高(93.59%);识别准确率超过 ResNet18 模型 1.55 百分点。随着蒸馏温度 T 继续增大,模型识别准确率保持不变。




图9 蒸馏温度与 NesNet13 模型识别准确率

3.8 本研究方法构建的轻量级模型与农作物病害常用的模型性能对比

利用本研究构建的马铃薯数据集,使用农作物

病害识别领域常用的模型 ResNet101、VGG - 16、AlexNet、ResNet50、ResNet18 以及轻量级模型 MobileNetV3、本研究方法构建的轻量级模型 ResNet13,完成 50 次迭代后的识别效果如表 6 所示,混淆矩阵如图 10 所示。通过模型识别准确率判断模型的泛化能力,通过迭代时间、模型内存占用量来判断模型在移动端的推理速度和模型的复杂度。

在不考虑算力需求基础上,ResNet101 在识别效果上最优,无论是迭代时间和模型内存占用量均优于 VGG - 16。VGG - 16 模型较大,为 512.0 MB。本研究构建的轻量级模型 ResNet13 在参数量上都远低于 ResNet101、VGG16、ResNet50 等大模型。在模型大小仅有 21.7 MB 的情况下,ResNet13 模型的识别准确率分别比 Alex Net 模型高 1.94 百分点、比 ResNet18 模型高 1.55 百分点。而相比于农作物病害识别的常用模型 MobileNet v3,ResNet13 模型大 0.6 MB,准确率高 2.91 百分点(表 6)。

表 6 模型性能对比

模型	准确率 (%)	精确率 (%)	召回率 (%)	特异率 (%)	迭代时间 (s)	模型大小 (MB)
ResNet101	94.95	94.51	94.38	98.76	84	162.0
VGG - 16	94.17	94.11	93.60	98.58	135	512.0
Alex Net	91.65	92.66	91.22	97.94	28	55.6
ResNet50	93.98	93.60	93.92	98.52	48	90.0
ResNet18	92.04	91.52	91.34	98.02	25	42.7
MobileNet v3	90.68	89.98	89.88	97.70	16	21.1
ResNet13	93.59	93.44	92.80	98.38	17	21.7

4 结论

为了能够在移动端准确且快速地识别马铃薯叶片病害,本研究针对马铃薯叶片病斑分布杂乱、面积小、相似度高且形状各异等特点,提出一种融合迁移和知识蒸馏的轻量级马铃薯叶片病害识别模型构建方法。首先构建马铃薯叶片数据集,利用数据增强技术扩充数据集,提高模型的鲁棒性;其次,利用下采样推迟和模型剪枝进一步压缩模型,减小模型的大小,使其便于部署在物联网和移动端设备上;最后,利用迁移学习训练教师模型,加快教师模型的迭代,再利用知识蒸馏技术指导模型训练,提高模型的识别准确率,对试验结果进行分析,得出以下结论。

(1)模型剪枝通过对卷积核的重构,减少模型的大小,本研究构建的 ResNet13 模型大小仅为

21.7 MB,识别准确率达到 91.85%,相比于 ResNet18 模型大小缩减了 49.18%,在减小模型大小的同时其识别准确率仅降低 0.19 百分点,可以部署在算力资源有限的物联网和移动端设备上;

(2)试验表明,模型下采样推迟能充分利用图像信息,不会造成图像的信息流失,能提高模型识别准确率;消融试验表明,在相同的试验条件下,知识蒸馏策略训练模型能有效提高模型识别准确率;

(3)蒸馏温度对模型影响的试验表明,当蒸馏温度 T 为 15 时,模型识别准确率达到 93.59%,识别效果达到最优。

本研究提出一种轻量级残差网络模型构建方法,融合迁移学习和知识蒸馏,构建出 ResNet13 模型,实现模型的高精度化和轻量化,且满足移动设备的实时性与高精度性需求,在马铃薯叶片病害识别方面具有优越性能,可为农作物病

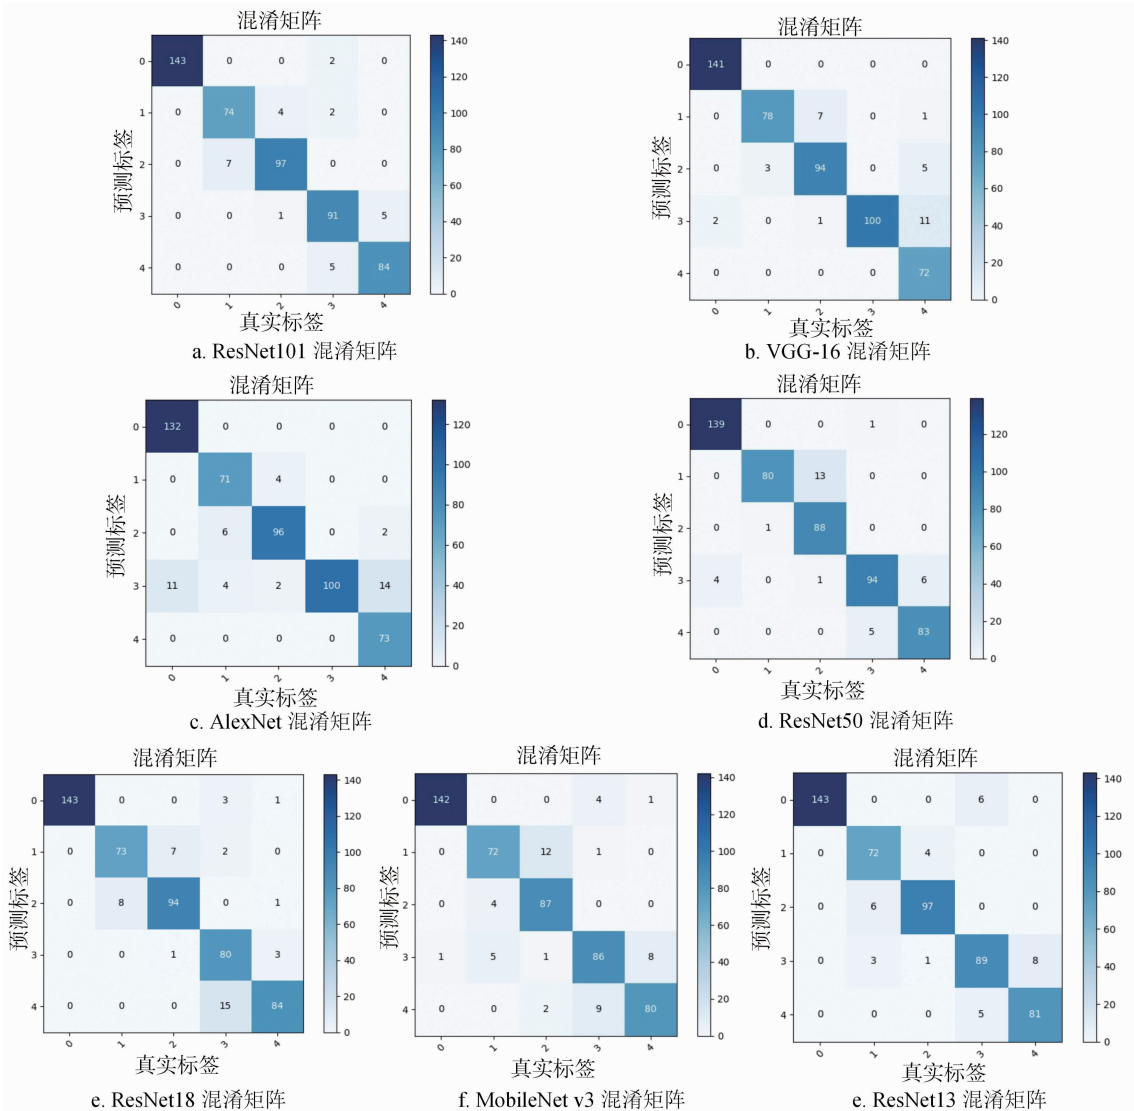


图10 各模型的混淆矩阵

害识别模型部署在物联网和移动端设备上提供新的方法和思路。

参考文献:

- [1] 党满意, 孟庆魁, 谷芳, 等. 基于机器视觉的马铃薯晚疫病快速识别[J]. 农业工程学报, 2020, 36(2): 193-200.
- [2] 彭学文, 朱杰华. 河北省马铃薯真菌病害种类及分布[J]. 中国马铃薯, 2008, 22(1): 31-33.
- [3] 张萌, 钱蓉, 朱静波, 等. 农作物害虫图像识别研究进展与展望[J]. 安徽农业科学, 2018, 46(34): 11-12, 15.
- [4] 周竹, 黄懿, 李小昱, 等. 基于机器视觉的马铃薯自动分级方法[J]. 农业工程学报, 2012, 28(7): 178-183.
- [5] 王晓峰, 黄德双, 杜吉祥, 等. 叶片图像特征提取与识别技术的研究[J]. 计算机工程与应用, 2006, 42(3): 190-193.
- [6] 马玲. 基于深度学习的苹果叶面病害识别方法研究[D]. 西安: 西京学院, 2021.
- [7] Prabhakar M, Purushothaman R, Awasthi D P. Deep learning based

- assessment of disease severity for early blight in tomato crop[J]. Multimedia Tools and Applications, 2020, 79(39): 28773-28784.
- [8] 王东方, 汪军. 基于迁移学习和残差网络的农作物病害分类[J]. 农业工程学报, 2021, 37(4): 199-207.
- [9] 杜甜甜, 南新元, 黄家兴, 等. 改进 RegNet 识别多种农作物病害受害程度[J]. 农业工程学报, 2022, 38(15): 150-158.
- [10] 鲍文霞, 孙庆, 胡根生, 等. 基于多路卷积神经网络的大田小麦赤霉病图像识别[J]. 农业工程学报, 2020, 36(11): 174-181.
- [11] 余小东, 杨孟辑, 张海清, 等. 基于迁移学习的农作物病虫害检测方法研究与应用[J]. 农业机械学报, 2020, 51(10): 252-258.
- [12] Pujari J D, Yakkundimath R, Byadgi A S. Image processing based detection of fungal diseases in plants[J]. Procedia Computer Science, 2015, 46: 1802-1808.
- [13] You N S, Dong J W. Examining earliest identifiable timing of crops using all available Sentinel 1/2 imagery and Google Earth Engine[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 161: 109-123.

亢洁,刘佳,刘文波,等. 基于多感受野与多尺度融合的草莓病害分割算法[J]. 江苏农业科学,2024,52(4):206-215.

doi:10.15889/j.issn.1002-1302.2024.04.031

基于多感受野与多尺度融合的草莓病害分割算法

亢洁,刘佳,刘文波,夏宇,李亦轩,王佳乐

(陕西科技大学电气与控制工程学院,陕西西安710021)

摘要:针对草莓病害在区域分割时存在背景复杂、目标较小导致难以被有效分割等问题,提出一种基于多感受野与多尺度融合的草莓病害分割算法。首先搭建了U-Net基础模型,使用结合注意力机制与残差网络的主干特征提取网络(CBAM-ResNet50)替代U-Net中的主干特征提取网络VGG16,一方面来加强目标区域的表征能力,抑制背景区域,以此实现复杂背景下的病害区域分割问题;另一方面通过残差减少梯度消失,提升模型的收敛速度;接着在特征融合层,设计基于3D无参注意力机制(SimAM)的多尺度自适应特征融合模块,通过邻近特征信息弥补当前层特征的信息丢失,以此提升小目标的检测能力;最后在网络底层设计基于膨胀卷积的多感受野模块,通过不同膨胀率的膨胀卷积来增加特征的全局感受野以实现整体分割区域的感知。结果表明,本研究提出的方法mPA达90.30%,相比于标准U-Net模型提高了7.13个百分点,本研究提出的方法能更好地对复杂背景下及小目标病害进行精准分割。

关键词:草莓病害分割算法;U-Net;注意力机制;多尺度融合;多感受野

中图分类号:TP391.41 **文献标志码:**A **文章编号:**1002-1302(2024)04-0206-10

草莓病害图像分割是病害检测和病害类型识别方法中的一个重要步骤,其分割效果直接影响到后续的检测和识别结果。由于草莓病害图像的形状和颜色复杂、多样、无规律且多变,图像分割技术能还原病害不规则分布区域,为后续病害类型识别与病害诊断提供有效依据,具有重要意义^[1-3]。之

前草莓病害检测主要为传统人工检测,需要消耗大量的人力物力,且容易受到检测人员主观因素的影响,检测效率低,所以实现病害检测的自动化具有很高的研究价值和应用前景^[4-7]。

随着计算机视觉的发展,基于数字图像处理的目标检测方法被应用于农作物病害检测中。孙俊等改进OTSU(大津法—最大类间方差)算法,利用粒子群优化算法寻找最优阈值并用于生菜叶片分割^[8]。Zhang等提出利用K-means(K均值聚类)算法对图像进行分割处理,从分割图像中提取PHOG(pyramid histogram of oriented gradient)特征识别病害从而达到分割效果^[9-10]。Ma等提出了一种利用综合颜色特征进行蔬菜病害叶斑分割的方法,

收稿日期:2023-03-30

基金项目:国家自然科学基金(编号:62203285);陕西省自然科学基金基础研究计划(编号:2022JQ-181);西安市科技计划(编号:23NYGG0070)。

作者简介:亢洁(1973—),女,陕西渭南人,博士,副教授,硕士生导师,主要从事机器视觉、智慧农业方面的研究。E-mail:kangjie@sust.edu.cn。

[14] 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 (CVPR). Las Vegas, NV, USA. IEEE, 2016:770-778.

[15] 彭宁. 基于改进的Faster R-CNN的车牌识别技术研究[D]. 哈尔滨:哈尔滨理工大学,2021.

[16] 周婕,马明栋. 基于改进的ResNet网络的人脸表情识别[J]. 计算机技术与发展,2022,32(1):25-29.

[17] Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.

[18] 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.

[19] 孙俊,朱伟栋,罗元秋,等. 基于改进MobileNet-v2的田间农作物叶片病害识别[J]. 农业工程学报,2021,37(22):161-169.

[20] 刘冰. 面向小样本的特定标识检测[D]. 天津:中国民航大学,2019.

[21] 邵仁荣,刘宇昂,张伟,等. 深度学习中知识蒸馏研究综述[J]. 计算机学报,2022,45(8):1638-1673.

[22] Hinton G, Vinyals O, Dean J. Distilling the knowledge in a neural network[EB/OL]. 2015; arXiv:1503.02531. <https://arxiv.org/abs/1503.02531.pdf>.

[23] Frankle J, Carbin M. The Lottery Ticket Hypothesis: Finding Sparse, Trainable Neural Networks[DB/OL]. USA: Cornell University, 2018. [2023-07-24]. arXiv:1803.03635.