

王洪波,杨永政,谢志成,等. 基于 Res-Inception 的农作物病虫害识别技术[J]. 江苏农业科学,2024,52(20):181-189.  
doi:10.15889/j.issn.1002-1302.2024.20.022

# 基于 Res-Inception 的农作物病虫害识别技术

王洪波, 杨永政, 谢志成, 郝志宏, 王春光

(内蒙古农业大学机电工程学院, 内蒙古呼和浩特 010018)

**摘要:**针对现有视觉识别技术对于农作物病虫害识别存在实际农业生产中识别效果不佳的问题,研究提出了一种结合 ResNet 和 Inception 2 种模型优点的新构架 Res-Inception 块。Res-Inception 块中采取了 ResNet 中的残差结构使得模型可以有效应对深度过深造成的过拟合和模型退化的问题;Res-Inception 块中的卷积层采用 Inception 模型中的并行联结策略,将传统的  $3 \times 3$  卷积核由并行的  $1 \times 3$ 、 $3 \times 1$  卷积核代替,在简化模型参数数量的同时使得模型获得了更强的多尺度特征提取能力;最后通过迁移学习使模型拥有高效的学习能力。在训练过程中将公开数据集 PlantVillage 中的多种作物病虫害作为预训练样本,通过迁移学习后对 PlantVillage 中 6 种番茄病虫害图像进行识别,模型对于训练集中病虫害的检测准确率达到 99.1%,验证集的检测准确率达到 98.9%,平均  $F_1$  分数达到 98.82%。通过与 VGG-16、ResNet34、ResNet50 等检测模型在 PlantVillage 数据集中的 6 种番茄病虫害识别测试中,本模型的检测准确率远高于这些模型;并且通过对比采用迁移学习前后的模型检测能力,验证了本研究提出的模型可以有效解决模型过拟合问题。本研究提出的 Res-Inception 块在有效解决了现有模型过拟合及模型退化问题的同时提高了模型的实际检测效果,该模块可为农业生产中病虫害识别模型的轻量化提供新思路,助力模型在实际农业生产中的应用。

**关键词:**农作物病虫害;迁移学习;ResNet;Inception;图像识别

**中图分类号:**S126;TP391.41 **文献标志码:**A **文章编号:**1002-1302(2024)20-0181-09

病虫害是影响农作物产量的主要原因之一,它的出现常常呈无时序性、暴发性的特点,且对农作物的危害是持续性的。因此当病虫害发生时若未能及时对其进行有效防控将会降低农作物的产量,甚至会直接影响到农业经济的发展<sup>[1]</sup>。因此,对农作物病虫害的防控是稳定农业经济、稳定农民收入的重要手段,对民生有着至关重要的意义。

据 2022 年全国农作物重大病虫害发生趋势预报,有多种主要粮食农作物遭受着严重的病虫害侵蚀,其中水稻遭受病害程度比 2021 年和 2016—2020 年均值分别增加 13.6% 和 7.1%,而小麦比 2021 年和 2020 年均值分别增长 4.8% 和 4.2%<sup>[2]</sup>。因此可以看出,现阶段需要行之有效的农作物病虫害防治手段来减少农业生产中的损失。

我国现阶段在农作物病虫害防治上主要依靠个人经验进行防治。依靠个人经验通常受限于个体文化水平,从而对病虫害认知不足,或是因为个

人疏忽,造成未能及时发现病虫害和阻止病害的扩大,导致农作物受到严重的损失。此外,在农作物病虫害防治上忽视引进现代科技手段,造成当地农业技术人员未能及时掌握农作物的生长状态,而对农作物病虫害趋势的判断产生影响<sup>[3]</sup>。由于现阶段农作物病虫害防治的缺陷,导致很多农户对农药的使用产生较大的依赖性,农药的滥用对种植土壤产生严重的不良影响,且农产品的安全性大幅降低<sup>[4]</sup>。因此,使用更为科学有效的技术手段,及时发现农作物病虫害并治理,对减少农作物损失,建立更加健康的农业经济环境至关重要。

## 1 国内外研究现状

随着深度学习在各行业上的成熟应用,不少学者开始将深度学习引入到农业生产中,有关农作物病虫害识别的深度学习方法不断被证明了其可行性。深度学习模型常因为图像质量不均衡而影响识别精度。Xin 等通过 DCNN(深度卷积神经网络)对 Google 数据库中的病虫害图像实现了多质量等级作物病害和病害影像分类,并通过 YOLO v4 对质量等级分类后的图像进行测试验证<sup>[5]</sup>。

在农作物病虫害图像识别技术中,常用静止图

收稿日期:2023-11-18

基金项目:内蒙古自治区科技创新引导项目(编号:Kej1-202205)。

作者简介:王洪波(1978—),男,内蒙古呼和浩特人,博士,教授,硕士生导师,从事智能农业装备研究。E-mail:wanghb@imau.edu.cn。

像来进行识别,因视频难以获得有清晰病害特征的图像,给农作物病虫害图像识别技术在实际应用上带来了很大的挑战。Li 等设计了一种视频检测系统,使用视频帧提取模块获得可以用于农作物病虫害识别的图像,再使用 Faster-RCNN 作为图像检测器将视频抽帧器获得的图像进行检测,最后再将各帧重新合成视频<sup>[6]</sup>。该系统的设计者用多种水稻病斑图像验证了该系统的可行性。由于大规模的架构对算力有一定的要求,运算成本较高,并不适用于装载在移动设备上,尤其是在农业生产上,需要一个规模较小的识别模型满足搭载移动端上。Rahman 等提出了一种两阶段小型 CNN 模型,相较于近些年出现的大规模识别模型在水稻病虫害识别上同样有着很好的表现,为田间农作物病虫害自动检测设备提供了有价值的理论基础<sup>[7]</sup>。Liu 等构建了真实自然环境下番茄病虫害数据集,并使用图像金字塔来优化 YOLO v3 的特征层,实现了对番茄病虫害的多尺度特征检测,能够准确地标记出病虫害的位置和类别<sup>[8]</sup>。

由于农作物病虫害图像受到拍摄环境、取像设备、图像质量不一等的影响,常无法建立大型数据集用于训练,而数据集的规模较小常常容易造成模型过拟合的问题。范春全等通过收集数据集,利用基于 ResNet50 的迁移学习模型在样本较少的情况下完成识别,并建立二分类模型进行数据过滤,以防止非水稻病虫害图片被识别为水稻病虫害的不合理情况,准确率可达 95.23%<sup>[9]</sup>。吴建宇针对 38 类农作物病虫害分别使用 AlexNet 与 GoogLeNet 模型对数据集进行训练和验证,结果显示其准确率分别为 80.1% 与 85.1%,由于 GoogLeNet 层数较深,考虑到使用数据集不大,可能产生较为严重的过拟合现象,并提出在 AlexNet 网络模型层上添加 GoogLeNet 所运用的 Inception 模块,结果显示其准确率达到 91.72%,有很好的效果,对于农作物病虫害多分类问题的解决有较大意义<sup>[10]</sup>。赵立新等通过公开数据集 PlantVillage 作为预训练样本,对仿照 AlexNet 搭建的识别模型进行预训练,使用预训练模型对 6 种棉花病虫害图像进行识别,并且与 SVM、BP 神经网络、VGG-16、Inception-v2 等经典模型相比较准确率有大幅度提升,解决了数据样本不够庞大时欠拟合的问题<sup>[11]</sup>。黄双萍等自制水稻穗瘟病数据集,并使用 GoogLeNet 模型检测水稻穗瘟病,准确率达到了 92%<sup>[12]</sup>。刘永波等利用 Triplet loss 双卷积神经网络结构学习玉米图像特征,再使用

SIFT 算法提取图像纹理细节,最后通过 Softmax 分类器对玉米病害进行分类,并在训练时利用迁移学习,准确率达到 90% 以上<sup>[13]</sup>。龙满生等主要针对油茶病害识别任务,通过迁移经典的 AlexNet 卷积神经网络模型学习得到的知识,实现对油茶病害的准确识别<sup>[14]</sup>。Jiang 等通过对多种水稻叶病斑图像预处理获得图像在 R、G、B、H、S、I、Y、Cb 和 Cr 9 个颜色分量的灰度图像,并使用 CNNs 对其提取病害形状和颜色特征,再将卷积得到的特征作为多类 SVM 的输入方向去进行分类任务,替代了常用的 Softmax 分类器,提高了模型的泛化能力和鲁棒性,提供了一种将传统机器学习与深度学习相结合用于农作物病虫害识别的新思路<sup>[15]</sup>。

## 2 试验数据的准备与数据集的搭建

### 2.1 数据集的建立

使用公开数据集 PlantVillage 数据集作为训练样本,选取其中 6 种番茄病虫害图像作为目标数据集,选取 4 种与番茄病虫害相似的病虫害叶片图像作为源数据集用于预训练<sup>[16-17]</sup>。目标数据集 6 种番茄病虫害叶片图像分别为番茄细菌性斑疹病 2 032 张、番茄早疫病 904 张、番茄晚疫病 1 813 张、番茄煤霉病 856 张、番茄斑枯病 1 496 张、番茄褐斑病 1 676 张,将上述 6 种病虫害叶片图像按照种类打上标签,其中番茄细菌性斑疹病标签为 a,番茄早疫病标签为 b,番茄晚疫病标签为 c,番茄煤霉病标签为 d,番茄斑枯病标签为 e,番茄褐斑病标签为 f,如图 1 所示。将 8 777 张番茄病虫害叶片随机打乱并按照 7:2:1 划分成训练集、验证集、测试集。

选取 PlantVillage 数据集中苹果黑腐病 621 张、樱桃白粉病 1 052 张、玉米灰斑病 513 张、马铃薯早疫病 1 000 张共 4 种病虫害叶片图像,作为预训练的源数据集;同样将上述图像按种类打上标签,苹果黑腐病标签为 a,樱桃白粉病标签为 b,玉米灰斑病标签为 c,马铃薯早疫病标签为 d,如图 2 所示,并随机打乱,将源数据集中的所有图像用于预训练。

### 2.2 基于图像增广的图像预处理方法

大型数据集是成功应用深度神经网络的先决条件,一个大型数据集可以在一定程度上减小模型的过拟合。建立一个大型数据集会在图像采集、图像标注、图像预处理上花费过多的精力,而数据集过小会导致规模较大的模型严重过拟合。为了可以将小型数据集用于模型训练引入了图像增广的



图1 番茄病虫害叶片展示




图2 4 种病虫害叶片展示

方法来对图像进行预处理,以缓解数据集较小导致模型过拟合的问题。图像增广在对训练图像进行一系列的随机变化之后,生成相似但不同的训练样本,从而扩大了训练集的规模。此外,应用图像增广的原因是随机改变训练样本可以减少模型对某些属性的依赖,从而提高模型的泛化能力和鲁棒性。例如,可以以不同的方式裁剪图像,使感兴趣的对象出现在不同的位置,减少模型对于对象出现位置的依赖。还可以调整亮度、颜色等因素来降低模型对颜色的敏感度。以其中一张番茄早疫病叶子为例,对其进行随机翻转、裁剪、更改色调、对比度、亮度、饱和度,效果如图 3 所示。

### 3 模型设计

#### 3.1 Res-Inception 块

ResNet 模型主要是由能够实现“shortcut connections”的残差块来进行残差映射,以此来消除

网络过深时引起的退化问题<sup>[18-20]</sup>。残差块如图 4 所示,图中虚线框内的堆积层将原始输入  $x$  拟合出残差映射  $f(x) - x$ ,并进行权重和偏置参数设置为 0 的加权运算,得到新的恒等运算  $F(x)$ ,这样把上一层产生的输出添加到下一层,既不会添加额外的参数,也没有增加计算的复杂性<sup>[21]</sup>。

Inception 块是构成 GoogLeNet 的卷积块,实现了网络并行连结的功能<sup>[22-23]</sup>。Inception 块是一种由多种滤波器组合而成的构架,如图 5 所示。图中所示 Inception 块是由 4 条路径从不同层面对图像抽取信息,最后在输出通道上进行维度连结。这种多滤波器组合的构架实现了对不同滤波器进行不同的参数配置以及设置不同大小的滤波器尺寸,以此实现对图像多范围的细节识别。

大量研究表明,增加深度神经网络的规模并不一定能直接提升其性能,反而会对训练模型带来许多问题,如梯度爆炸、梯度消失、网络退化等。此外






图3 番茄早疫病叶子随机翻转、裁剪、更改色调、对比度、亮度、饱和度的图像增广

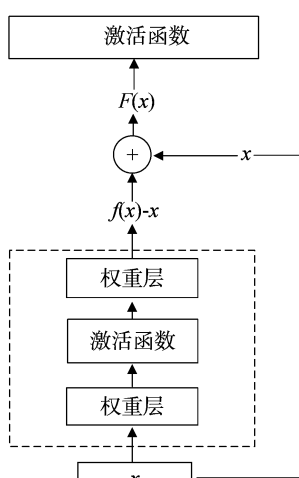


图4 残差块

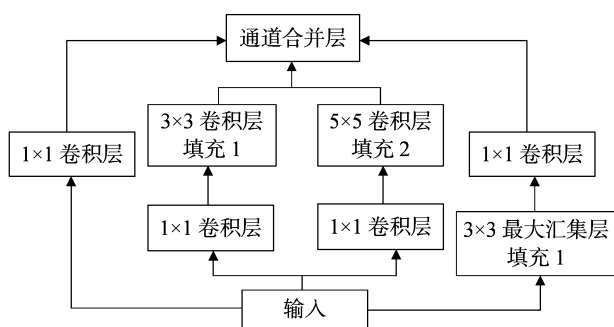


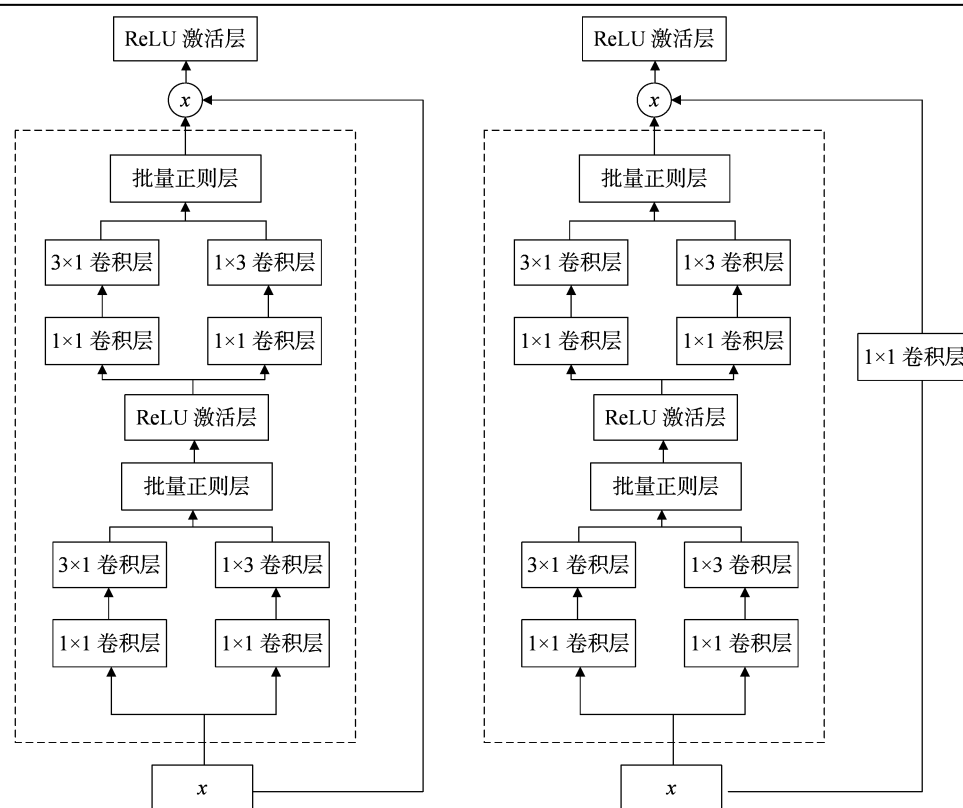
图5 Inception 块

更大的规模通常意味着更多的参数,这使得扩大后的网络更容易出现过拟合,尤其是在数据集样本数量较小的情况下。统一增加网络规模同样是对计算资源使用的急剧增加,这造成了规模过大的模型难以部署在实际农业生产当中。然而神经网络构架过小,对图像细节识别的能力较差,在面对复杂数据集下识别的效果常常不能满足实际农业生产需求。因此,为了在实际农业生产当中能够部署的

需求,需要实现一种既深度合适又能有高识别能力的农作物病虫害识别模型。根据需求,本研究提出了一种新构架——Res-Inception 块,作为神经网络的基本块来构成一个新的识别模型。Res-Inception 块同时实现了残差块的快捷连接功能以及 Inception 块的并路连结功能。结合 ResNet 以及 Inception 2 种深度学习模型的优点设计了一种识别模型,来应对模型变深时引起的退化等问题以及多范围多层次对图像进行细节识别。

Res-Inception 块由 2 条并行路径以及 1 条快捷连接通道组成,Res-Inception 块与残差块类似,同样是以是否在快捷连接通道上加  $1 \times 1$  的卷积层来区分 2 种块,Res-Inception 块结构如图 6 所示。

由图 6 可以看出,2 条并行路径都使用了  $1 \times 1$  卷积层,该卷积层主要是用来控制通道数,从而控制模型的复杂性。因此我们不仅可以一定程度上增加模型的深度,还可以增加模型的宽度,却不会有明显的性能损失。在  $1 \times 1$  卷积层之后分别是窗口大小为  $3 \times 1$  以及  $1 \times 3$  的卷积层,通过不同大小窗口的卷积层来对输入进行不同范围的提取。经过卷积层提取的输出作为新的输入进入批量正则化层,批量正则化层是对输入进行小批量统计数据归一化,以此来加快深层网络的收敛速度以及减少过拟合。激活层使用 ReLU 函数作为激活函数来实现数据线性到非线性的转化。2 条路径在对数据进行激活后,投入到通道合并层上进行对输出通道维度上的连结。对连结的输出,再次经过  $3 \times 1 (1 \times 3)$  卷积层、批量正则化层、激活层以及通道合并层对其进行进一步的细化提取。原始输入通过快捷连接通道叠加到经过 2 次卷积等操作的新输出上,实现了残差映射防止以 Res-Inception 块搭建的模型出现梯

图6 包含以及不包含  $1 \times 1$  卷积层的 Res-Inception 块

度消失、梯度爆炸、退化等问题。这个包含原始特征以及提取得到新特征的输出作为新的输入用于下一步的训练。

### 3.2 搭建模型

参照 ResNet50, 使用 Res-Inception 块设计一个新的模型, 模型由 b1 ~ b6 6 个部分构成, 如图 7 所示。其中 b1 作为模型的输入层, 由  $7 \times 7$  的卷积层、批量归一层、ReLU 激活层和最大池化层构成。b2 ~ b5 作为特征提取层, 是由多个参数不同的 Res-Inception 块所构成, 构成 b2 ~ b5 的 Res-Inception 块数量分别为 3、4、6、3 个。b6 作为模型的输出层, 是由 1 个全局平均池化层、1 个展开层、1 个全连接层所构成。各层输入通道数、输出通道数、步频和填充等详细参数见表 1。

### 3.3 基于迁移学习的试验方法

为了解决数据集样本数量不充足时带来的模型过拟合问题, 除了使用图像增广的方法对图像进行预处理外, 本研究引入了迁移学习。迁移学习不同于对直接从开始训练的方法, 而是搭建用于预训练源模型以及最后用于识别的目标模型<sup>[24-25]</sup>。迁移学习是使用预训练数据集对源模型先进行预训练获得参数, 将获得的所有参数赋予到目标模型上,




图7 搭建模型结构

输出层除外, 而目标模型通过使用目标数据集训练, 对其余各层获得的参数进行微调以获得最佳的参数, 输出层则是从头开始训练使输出的类别与数据集中样本的类别相匹配<sup>[26]</sup>。

将迁移学习应用到用 Res-Inception 块搭建的模型上。使用提前搭建好的源数据集作为预训练数据集, 对其进行预处理, 固定输入的通道以及像素尺寸, 图像增广, 将预处理完的源数据集投入到用 Res-Inception 块搭建的模型上进行预训练。将

表 1 由 Res-Inception 块构成的网络架构

块	网络架构	输出尺寸
b1	卷积层: $7 \times 7, p=3, s=2$ , 输出通道数: 76 批量正则化, ReLU 激活函数 最大池化层: $3 \times 3, p=1, s=2$	$56 \times 56$
b2	$\left[ \begin{array}{l} \text{卷积层: } 1 \times 1, p=0, s=1, \text{输出通道数: } 64 \\ \text{卷积层: } 3 \times 1, p=(1,0), s=1, \text{输出通道数: } 38; \text{卷积层: } 1 \times 3, p=(0,1), s=1, \text{输出通道数: } 38 \\ \text{卷积层: } 1 \times 1, p=0, s=1, \text{输出通道数: } 64 \\ \text{卷积层: } 3 \times 1, p=(1,0), s=1, \text{输出通道数: } 38; \text{卷积层: } 1 \times 3, p=(0,1), s=1, \text{输出通道数: } 38 \end{array} \right] \times 3$	$56 \times 56$
b3	$\left[ \begin{array}{l} \text{卷积层: } 1 \times 1, p=0, s=1, \text{输出通道数: } 64 \\ \text{卷积层: } 3 \times 1, p=(1,0), s=1, \text{输出通道数: } 52; \text{卷积层: } 1 \times 3, p=(0,1), s=1, \text{输出通道数: } 52 \\ \text{卷积层: } 1 \times 1, p=0, s=1, \text{输出通道数: } 64 \\ \text{卷积层: } 3 \times 1, p=(1,0), s=1, \text{输出通道数: } 52; \text{卷积层: } 1 \times 3, p=(0,1), s=1, \text{输出通道数: } 52 \end{array} \right] \times 4$	$28 \times 28$
b4	$\left[ \begin{array}{l} \text{卷积层: } 1 \times 1, p=0, s=1, \text{输出通道数: } 184 \\ \text{卷积层: } 3 \times 1, p=(1,0), s=1, \text{输出通道数: } 132; \text{卷积层: } 1 \times 3, p=(0,1), s=1, \text{输出通道数: } 132 \\ \text{卷积层: } 1 \times 1, p=0, s=1, \text{输出通道数: } 184 \\ \text{卷积层: } 3 \times 1, p=(1,0), s=1, \text{输出通道数: } 132; \text{卷积层: } 1 \times 3, p=(0,1), s=1, \text{输出通道数: } 132 \end{array} \right] \times 6$	$14 \times 14$
b5	$\left[ \begin{array}{l} \text{卷积层: } 1 \times 1, p=0, s=1, \text{输出通道数: } 469 \\ \text{卷积层: } 3 \times 1, p=(1,0), s=1, \text{输出通道数: } 256; \text{卷积层: } 1 \times 3, p=(0,1), s=1, \text{输出通道数: } 256 \\ \text{卷积层: } 1 \times 1, p=0, s=1, \text{输出通道数: } 469 \\ \text{卷积层: } 3 \times 1, p=(1,0), s=1, \text{输出通道数: } 256; \text{卷积层: } 1 \times 3, p=(0,1), s=1, \text{输出通道数: } 256 \end{array} \right] \times 3$	$7 \times 7$
b6	$1 \times 1$ 全局平均池化层输出向量长度: 512, 全连接层输出长度: 6, Softmax 回归	$1 \times 1$

预训练好的 pre-Res-Inception 模型参数保存并固定到未经训练的新的 Res-Inception 模型上, 使用提前搭建好的目标数据集并进行相同的预处理操作, 投入到模型中训练对模型各层参数微调, 修改输出层输出数与目标数据集样本类别数相同并从头开始训练。

### 3.4 试验环境与评价指标

本研究用于训练、验证、测试模型的处理器的 Intel® Core™ i5-10200H CPU, 频率 2.40 GHz, 内存大小 16 GB, GPU 为 NVIDIA GeForce RTX3060, 显存大小为 6 GB, 开发环境为 Python 3.9, Pytorch 深度学习框架, CUDA 11.6, Windows 11 64 位操作系统。固定训练参数, 训练周期 (epoch) 为 60, 学习率为 0.001, 批量大小 (batch size) 为 56, 选用随机梯度 (SGD) 下降优化器作为梯度更新方式<sup>[27-29]</sup>。在模型训练验证阶段采用模型对训练集的准确率 (Accuracy) 和对验证集的准确度作为评价指标。在模型测试阶段, 使用模型对测试集进行预测, 并以各番茄病虫害的精确率 (Precision)、召回率 (Recall)、 $F_1$  分数 ( $F_1$ -Score), 作为评价指标, 各评价指标公式如下所示:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}; \quad (1)$$

$$Precision = \frac{TP}{TP + FP}; \quad (2)$$

$$Recall = \frac{TP}{TP + FN}; \quad (3)$$

$$F_1 \text{ 分数} = \frac{2}{\frac{1}{Precision} + \frac{1}{Recall}}。 \quad (4)$$

式中:  $TP$  为真正例;  $TN$  为真负例;  $FN$  为假负例;  $FP$  为假正例。

## 4 结果与分析

### 4.1 基于 Res-Inception 块搭建的模型训练结果及分析

模型的大小与复杂度通常由参数量和计算量来衡量。参数量较大通常意味着模型能学习到更多的特征, 参数量越大同时意味着要占用更多的存储空间, 然而模型学习到的特征并非每个都有意义, 经常会出现特征冗余的情况, 因此为了保证模型的部署, 需要模型实现以更少的参数量达到更好的识别效果。计算量过大意味着需要更多的计算资源, 会导致训练时间加长以及需要更强大的硬件进行训练和推理, 因此为减少模型的训练成本计算量同样不能过大。基于 Res-Inception 块搭建的模型以及 VGG-16、ResNet34、ResNet50 3 种常用于农

作物病害识别成熟模型的数量和计算量如表 2 所示。基于 Res-Inception 块搭建的模型的数量为 34.90 MB, 计算量为 2.19 GFLOPs, 均低于其他模型。

表 2 各模型参数数量与计算量

模型	参数数量 (MB)	计算量 (GFLOPs)
本研究模型	34.90	2.19
VGG-16	526.00	15.50
ResNet34	80.60	3.68
ResNet50	88.52	5.38

对提前搭建好的番茄细菌性斑疹病、番茄早疫病、番茄晚疫病、番茄煤霉、番茄斑枯病、番茄褐斑病 6 种番茄病虫害训练数据集即目标数据集进行图像预处理, 然后直接投入到基于 Res-Inception 块搭建的模型以及 VGG-16、ResNet34、ResNet50 3 种常用于农作物病虫害识别成熟模型中进行训练, 训练准确率、验证准确率如表 3 所示<sup>[30]</sup>。

表 3 各模型训练结果

模型	训练准确率 (%)	验证准确率 (%)
本研究模型	95.7	90.9
VGG-16	94.2	90.8
ResNet34	92.9	91.2
ResNet50	95.7	91.5

由表 3 可以看出, 4 种模型均存在一定的过拟合, 其中本研究模型训练准确率为 95.7%, 远高于验证准确率 90.9%, 过拟合程度比较严重, 说明数据集规模大小与模型规模不匹配。VGG-16 训练准确率与验证准确率错误率分别为 5.8%、9.2%, 该模型在识别 6 种番茄病虫害数据集上的表现并不能满足实际农业生产上的需求, 且训练准确率与验证准确率相差 3.4 百分点, 过拟合程度同样严重。ResNet34 训练准确率与验证准确率分别为 92.9%、91.2%, 相差不大, 过拟合程度较小, 但是识别准确率过低。ResNet50 2 个识别准确率相差 4.2 百分点, 同样有十分严重的过拟合问题。

损失曲线如图 8 所示, 未经迁移学习的各原始模型在损失函数收敛上都是在 40~50 个周期时趋于平稳。由 Res-Inception 块构成的模型虽然前期收敛速度较快但仍在 40 个周期后趋于平稳, 且相较于 VGG-16 损失值略高。

综上所述, 4 种模型的构架相对于数据集较为复杂, 模型的深度意味着拟合复杂特征的能力, 模




图8 各模型损失曲线

型深度相较于数据集大小太深, 模型规模与数据集规模不匹配, 导致模型出现过拟合现象。因此通过引入迁移学习的方法进一步降低模型过拟合问题。

#### 4.2 基于迁移学习的训练结果及分析

将提前搭建好用于迁移学习的源数据集进行图像预处理后投入到基于 Res-Inception 块搭建的模型、VGG-16、ResNet34 和 ResNet50 中进行预训练, 得到 pre-Res-Inception、pre-VGG-16、pre-ResNet34 和 pre-ResNet50 4 个预训练模型, 再将经过同样图像预处理操作的目标数据集投入其中进行迁移学习, 训练准确率、验证准确率如表 4 所示。对比表 3 和表 4 可以得出, 经迁移学习的 4 个模型不仅过拟合问题显著降低, 且识别效果也有所提升。本研究模型训练准确率达到 99.1%, 验证准确率达到 98.9%, 不仅对 6 种番茄病虫害的识别精度有所提升, 且过拟合问题基本解决。而其余 3 个模型虽识别效果也均有提升, 但是识别准确率普遍不高, 对识别 6 种番茄病虫害的能力有所欠缺, 不符合实际生产需求。对比本研究模型经迁移学习前后损失函数收敛情况如图 9 所示, 经迁移学习后损失函数收敛速度大幅提升, 在 20 个周期时经迁移学习的本模型损失函数趋于平稳, 且损失值也远小于未经迁移学习的本模型。

表 4 基于迁移学习各模型训练结果

模型	训练准确率 (%)	验证准确率 (%)
本研究模型 Res-Inception	99.1	98.9
pre-VGG-16	95.7	95.8
pre-ResNet34	94.2	92.6
pre-ResNet50	96.3	95.3

综上所述, 当数据集较小且模型规模较大时, 使用迁移学习对源模型进行预训练, 将得到的参数复制到目标模型并微调, 这种训练模型的方法, 对




图9 经迁移学习前后损失曲线

解决过拟合问题有很大的作用,此外还能够提升一定的识别准确度。

#### 4.3 模型预测结果分析

将基于迁移学习训练完的 Res - Inception 模型和上述试验中表现较好的经迁移学习的 ResNet50 模型对测试集进行预测。测试集各病虫害图像数

量分别为番茄细菌性斑疹病 180 张、番茄早疫病 80 张、番茄晚疫病 160 张、番茄煤霉病 77 张、番茄斑枯病 132 张、番茄褐斑病 148 张,共计 777 张番茄病虫害图像。将 2 个模型的预测值与真实值对比所得混淆矩阵如表 5 和表 6 所示。由混淆矩阵对模型识别各病虫害效果评级,计算精确率、召回率和  $F_1$  分数,如表 7 所示。由表 7 可得,经迁移学习后的 ResNet50 模型,平均精确率为 93.69%,平均召回率为 94.94%, $F_1$  分数平均值为 94.22%。而经迁移学习后的 Res - Inception 模型对各番茄病虫害平均精确率为 98.63%,平均召回率为 99.02%, $F_1$  分数平均值为 98.82%。2 个模型相比之下,经迁移学习后的 Res - Inception 模型比经迁移学习后的 ResNet50 模型,各项评分均有很大提升,且分类性能(按  $F_1$  分数的高低来判别)提升了 4.6 百分点。

表 5 基于迁移学习 Res - Inception 的混淆矩阵

真实标签	预测标签					
	番茄细菌性斑疹病	番茄早疫病	番茄晚疫病	番茄煤霉病	番茄斑枯病	番茄褐斑病
番茄细菌性斑疹病	178	2	0	0	0	0
番茄早疫病	0	79	0	1	0	0
番茄晚疫病	0	0	159	1	0	0
番茄煤霉病	0	0	0	77	0	0
番茄斑枯病	0	0	0	1	130	1
番茄褐斑病	1	0	0	0	1	146

表 6 基于迁移学习 ResNet50 的混淆矩阵

真实标签	预测标签					
	番茄细菌性斑疹病	番茄早疫病	番茄晚疫病	番茄煤霉病	番茄斑枯病	番茄褐斑病
番茄细菌性斑疹病	176	3	0	1	0	0
番茄早疫病	0	78	0	1	0	1
番茄晚疫病	0	0	147	13	0	0
番茄煤霉病	0	7	0	68	2	0
番茄斑枯病	0	0	0	0	127	5
番茄褐斑病	0	1	0	2	0	145

表 7 经迁移学习的 2 个模型对各番茄病虫害识别效果

病害类别	Pre - ResNet50			Pre - Res - Inception		
	精确率(%)	召回率(%)	$F_1$ 分数(%)	精确率(%)	召回率(%)	$F_1$ 分数(%)
番茄细菌性斑疹病	100.00	97.78	98.88	99.44	98.89	99.16
番茄早疫病	87.64	97.50	92.30	97.53	98.75	98.14
番茄晚疫病	100.00	91.88	95.76	100.00	99.38	99.69
番茄煤霉病	80.00	88.31	83.95	96.25	100.00	98.09
番茄斑枯病	98.45	96.21	97.41	99.23	98.46	98.84
番茄褐斑病	96.02	97.97	96.99	99.31	98.64	98.97
平均值	93.69	94.94	94.22	98.63	99.02	98.82



## 5 结论

本研究提出了一个结合 ResNet 和 Inception 2 种模型优点的 Res - Inception 新构架, Res - Inception 块同时实现了残差块的快捷连接功能以及 Inception 块的并路连结功能。使用图像增广对小规模数据集进行图像预处理,提高模型的泛化能力以及鲁棒性。以 Res - Inception 块搭建的模型结合迁移学习方法提升模型的识别效果,降低过拟合。本研究最终模型对 6 种番茄病虫害识别的训练准确率为 99.1%,验证准确率 98.9%。本研究模型对测试集进行预测,对 6 种番茄病虫害平均精确率达到 98.63%,平均召回率达到 99.02%,平均  $F_1$  分数达到 98.82%,各类评价指标均超过现有成熟模型。模型规模适中,训练成本以及占用的计算资源较少,满足实际农业生产的需求,为后续的移动设备搭载识别模型实现智慧农业打下了理论基础。

### 参考文献:

- [1] 张玉婷. 农作物病虫害防治工作存在的问题与对策[J]. 乡村科技, 2022, 13(2): 83 - 85.
- [2] 2022 年全国农作物重大病虫害发生趋势预报[J]. 中国植保导刊, 2022, 42(4): 107 - 108.
- [3] 武保华. 农作物病虫害防治中存在的问题及对策[J]. 河北农机, 2023(10): 91 - 93.
- [4] 李爱芳. 农业种植中病虫害危害特点及应对方法[J]. 农业科技与信息, 2021, 8(8): 46 - 47.
- [5] Xin M Y, Wang Y. Image recognition of crop diseases and insect pests based on deep learning[J]. Wireless Communications and Mobile Computing, 2021, 2021(1): 1 - 15.
- [6] Li D S, Wang R J, Xie C J, et al. A recognition method for rice plant diseases and pests video detection based on deep convolutional neural network[J]. Sensors, 2020, 20(3): 578.
- [7] Rahman C R, Arko P S, Ali M E, et al. Identification and recognition of rice diseases and pests using convolutional neural networks[J]. Biosystems Engineering, 2020, 194: 112 - 120.
- [8] Liu J, Wang X W. Tomato diseases and pests detection based on improved YOLO v3 convolutional neural network[J]. Frontiers in Plant Science, 2020, 11: 898.
- [9] 范春全, 何彬彬. 基于迁移学习的水稻病虫害识别[J]. 中国农业信息, 2020, 32(2): 36 - 44.
- [10] 吴健宇. 基于深度卷积神经网络的农作物病虫害识别及实现[D]. 哈尔滨: 哈尔滨工业大学, 2019: 20 - 25.
- [11] 赵立新, 侯发东, 吕正超, 等. 基于迁移学习的棉花叶部病虫害图像识别[J]. 农业工程学报, 2020, 36(7): 184 - 191.
- [12] 黄双萍, 孙超, 齐龙, 等. 基于深度卷积神经网络的水稻穗瘟病检测方法[J]. 农业工程学报, 2017, 33(20): 169 - 176.
- [13] 刘永波, 雷波, 曹艳, 等. 基于深度卷积神经网络的玉米病害识别[J]. 中国农学通报, 2018, 34(36): 159 - 164.
- [14] 龙满生, 欧阳春娟, 刘欢, 等. 基于卷积神经网络与迁移学习的油茶病害图像识别[J]. 农业工程学报, 2018, 34(18): 194 - 201.
- [15] Jiang F, Lu Y, Chen Y, et al. Image recognition of four rice leaf diseases based on deep learning and support vector machine[J]. Computers and Electronics in Agriculture, 2020, 179: 105824.
- [16] Beyer L, Hénaff O J, Kolesnikov A, et al. Are we done with ImageNet? [EB/OL]. 2020; arXiv: 2006. 07159. <http://arxiv.org/abs/2006.07159>.
- [17] Recht B, Roelofs R, Schmidt L, et al. Do ImageNet classifiers generalize to ImageNet? [EB/OL]. 2019; arXiv: 1902. 10811. <http://arxiv.org/abs/1902.10811>.
- [18] He K M, Zhang X Y, Ren S Q, et al. Identity mappings in deep residual networks[C]//European Conference on Computer Vision. Cham: Springer, 2016: 630 - 645.
- [19] Shafiq M, Gu Z Q. Deep residual learning for image recognition: a survey[J]. Applied Sciences, 2022, 12(18): 8972.
- [20] 刘晓峰, 高丽梅. 基于改进空间残差收缩网络模型的农作物病虫害识别[J]. 山东农业大学学报(自然科学版), 2022, 53(2): 259 - 264.
- [21] 刘冬寒. 基于改进深度残差网络的农作物病害识别研究[D]. 杭州: 浙江农林大学, 2021: 17 - 20.
- [22] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception - v4, inception - ResNet and the impact of residual connections on learning[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2017, 31(1): 4278 - 4284.
- [23] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA. IEEE, 2016: 2818 - 2826.
- [24] 樊湘鹏, 许燕, 周建平, 等. 基于迁移学习和改进 CNN 的葡萄叶部病害检测系统[J]. 农业工程学报, 2021, 37(6): 151 - 159.
- [25] 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.
- [26] 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.
- [27] 全卫国, 李敏霞, 张一可. 深度学习优化算法研究[J]. 计算机科学, 2018, 45(增刊2): 155 - 159.
- [28] 贾桐. 深度学习常用优化算法研究[J]. 信息技术与网络安全, 2019, 38(7): 42 - 46.
- [29] 李明, 来国红, 常晏鸣, 等. 深度学习算法中不同优化器的性能分析[J]. 信息技术与信息化, 2022(3): 206 - 209.
- [30] Tammina S. Transfer learning using VGG - 16 with deep convolutional neural network for classifying images[J]. International Journal of Scientific and Research Publications, 2019, 9(10): 143 - 150.