

复杂背景农作物病害图像识别研究

叶中华 赵明霞 贾璐

(中国农业大学信息与电气工程学院, 北京 100083)

摘要: 目前大部分对农作物病害识别的研究都是基于公开数据集进行的,而这些公开数据集大多是简单背景的单一病害图像,当在真实农业生产环境中应用时,往往无法满足需求。本研究采用 AlexNet、DenseNet121、ResNet18、VGG16 模型在自行构建的复杂背景农作物图像数据集 2 和公开的简单图像背景数据集 1 上进行对比实验,结果表明在数据集 1 上取得了较好的效果,平均识别准确率基本都达到 90% 左右,而在数据集 2 上模型的识别效果普遍较差。为此本文在数据集 2 上采用 SSD 目标检测模型,实现对复杂背景农作物图像病害区域的预测,实验结果表明,最终模型在测试集的平均精度均值达到 83.90%。

关键词: 深度学习; 卷积神经网络; 农作物病害; 图像识别; SSD 目标检测模型

中图分类号: TP391.4 文献标识码: A 文章编号: 1000-1298(2021)S0-0118-07

Image Recognition of Crop Diseases in Complex Background

YE Zhonghua ZHAO Mingxia JIA Lu

(College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: China has always been a large agricultural country, and agricultural production has always occupied an important position. However, crops have caused huge losses due to the invasion of diseases and pests every year. Therefore, it is of great significance to study how to accurately identify crop diseases. At present, most of the research on crop disease recognition is based on public data sets, and most of these public data sets are single disease images with simple background, which often cannot meet the needs when applied in the real agricultural production environment. AlexNet, DenseNet121, ResNet18 and VGG16 models were used to conduct comparative experiments on the self constructed crop image dataset 2 with complex background and the dataset 1 with open simple image background. The results showed that good results were achieved on dataset 1, and the average recognition accuracy basically reached about 90%, while the recognition effect of the model on dataset 2 was generally poor. Therefore, further relevant experiments were taken. SSD target detection model was used on data set 2 to predict the disease area of crop image with complex background. The experimental results showed that the mAP value of the final model in the test set reached 83.90%. In the future, it would be continued to optimize the algorithm to achieve high recognition accuracy for disease images with complex background, and then apply the model to the online agricultural question answering platform to realize the intelligence and efficiency of the platform.

Key words: deep learning; convolutional neural network; crops disease; image recognition; SSD target detection model

0 引言

近年来,互联网和计算机技术发展迅速,机器学习和深度学习等技术更是取得了突破性的发展,目

前已经被应用到农作物病害识别和防治等多个领域^[1-7]。我国是一个农业大国,农业生产一直占据着比较重要的地位,因此将深度学习等技术高效地应用在农作物病害识别领域,将有十分积极的意义。

目前已经有许多研究者在该领域进行研究和探索,SLADOJEVIC 等^[8]提出了一种模型,实验证明他们构建的模型可以识别 13 种作物病害,并且可以将作物的病害叶片与周围的环境分隔出来。田凯等^[9]以深度学习技术和图像处理技术为基础,对茄子褐纹病害提出了一种识别方法,经实验测试发现准确率达到 90%。孙俊等^[10]对卷积神经网络进行优化,得出一种新的病害识别方法,实验结果表明该方法的准确率接近 95%。AGARWAL 等^[11]提出了一个简化的卷积神经网络模型,然后在公开的数据集 PlantVillage 进行测试,实验结果显示提出的模型比传统的机器学习方法具有更好的效果,最终测试准确率达到了 98.4%。丁永军等^[12]使用不同等级的噪声对模型抗噪能力进行测试,最终证明卷积胶囊网络的性能好于卷积神经网络模型,它在实际的农业生产中可以更好地识别病害。贾建楠等^[13]使用边缘滤波检测法以及大津算法对黄瓜病害叶片的病灶部分进行分割,实现了对黄瓜病害进行有效的识别和诊断。LIU 等^[14]构建了一个具有 271 个植物病害类别和 220 592 幅图像的大规模植物病害数据集,并且提出了一种新的病害识别框架,实验结果表明该方法在数据集上具有良好的效果。

以上研究所采用的数据集大部分是为实验单独采集的数据集,图像规范,背景清晰简单,在实际应用存在局限性。实际的农业生产环境中,农民拍摄农作物图像往往是比较随意的,存在背景复杂多变,病虫害位置不居中等问题,所以基于简单背景病害图像很难满足实际农业生产需求,本文就此问题展开实验。

1 实验数据与预处理

1.1 数据来源

共采用 2 类农作物病害数据集,一类是图像背景较为简单的数据集 1,另一类是图像背景较为复杂的数据集 2。其中数据集 1 来源于网络搜集的公开数据集,该数据集共有 535 幅图像,主要包括苹果的健康图像 117 幅、黑腐病 141 幅、桧胶锈病 136 幅、黑星病 141 幅等 4 种病害数据,如图 1 所示。通过 Python 语言编写爬虫程序,以抓取在线农业问答平台数据为研究基础,将该平台上问答板块用户上传的图像作为数据集 2 的来源,该数据集一共包括 312 幅草莓图像,主要包括炭疽病 77 幅、白粉病 75 幅、虫害 82 幅、根腐病 78 幅共 4 种病害图像,如图 2 所示。

1.2 数据预处理

对以上两个数据集进行预处理操作。对于数据

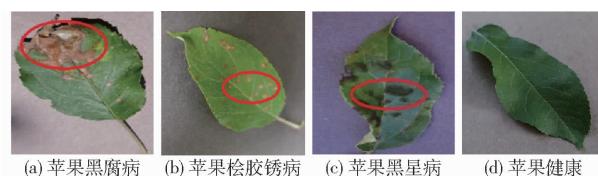


Fig. 1 简单背景下数据集 1 样本图像

Fig. 1 Sample images of dataset 1 under simple background



Fig. 2 复杂背景下数据集 2 样本图像

Fig. 2 Sample images of dataset 2 under complex background

集 1,因为其来源于网络搜集的公开数据集,其图像背景较为单一简单,噪声较少,所以本文只对其进行数据增强和标签归类的预处理,不再对其做其他方面的处理。对于数据集 2,该数据集来源于抓取在线农业问答平台的数据,利用编写的爬虫程序可以批量采集到大量的图像数据,但是由于农技问答平台上的图像数据大部分为人们用手机或者其他工具随机拍摄的图像,其背景较为复杂且存在着较大的随机噪声,为此采集到图像数据集以后,需要手动对所有图像进行人工筛选,剔除无法使用以及无关的图像,然后再根据专家的回复和建议为图像数据手动贴上病害的类别标签,最后对其进行数据增强,以扩充数据集。

1.3 数据增强

对数据集 1 和数据集 2 进行离线数据增强^[15]操作:

(1) 统一缩放:由于采集到的图像数据的尺寸存在很大的随机性,大小各不相同,故在模型训练之前,通过编写脚本程序,对所有的图像尺寸统一缩放到模型所需的输入大小。

(2) 随机旋转:图像本身的信息不会发生任何变化,只是对图像的位置和方向进行一定的改变,即对原有的图像进行一个随机角度旋转。这可很好地模拟拍摄工具不同角度拍摄的情况。

(3) 随机翻转:按一定概率随机对所有图像数据沿着水平方向或者垂直方向进行翻转,该操作不会丢失图像本身的信息,可以模拟拍摄工具在不同角度拍摄的图像。

(4) 亮度增强:对所有图像进行随机亮度增强,这可以模拟农作物在不同光照情况下的场景。

(5) 对比度增强:对所有图像进行随机对比度增强,从某种程度上来说,可以增加病害区域与健康区域的差别,同时也可以模拟农作物在不同的光照

强度下的场景。

对以上的数据集1和数据集2按照比例7:3分别划分为训练集和测试集,最终经过以上的数据增强操作后,数据集1的训练集数据增加到2140幅图像,数据集2的训练集数据增加到1085幅图像。

2 模型原理

2.1 图像识别模型改进

由于本文实验所用的数据集1和数据集2规模不大,所以为了防止模型训练过程中出现过拟合的情况,将把迁移学习技术应用到模型的训练中,这样模型训练之前就有了预训练的权重,其收敛速度也会变得更快。在本研究中,使用ImageNet^[16]数据集上预训练的AlexNet、DenseNet121、ResNet18、VGG16模型预训练权重。ImageNet是一个规模十分庞大的图像数据库,它收集了超过1500万幅的图像,其涵盖的图像类别大约有22000种,所以用它来预训练模型将会有很大的帮助。

2.1.1 AlexNet模型

AlexNet^[17]深度神经网络模型是2012年ISLVR C比赛的冠军,它的分类精度较传统的方法相比提高了很多。该模型的主要优势在于它首次提出采用GPU搭建程序运行环境,这可以很好地加速网络的训练,其次是该模型提出了使用ReLU激活函数,在一定程度上可以弥补之前的Sigmoid和tanh激活函数的梯度消失和梯度爆炸的问题,同时在网络的全连接层中引入了Dropout机制,以减少模型训练中过拟合的情况。本文中将修改AlexNet模型分类层的网络结构,使其适应于本研究中的病虫害图像识别任务。

2.1.2 VGG16模型

VGG16^[18]模型主要由13个卷积层和3个全连接层构成,该模型中的网络有一些卷积层后还会再连接一个最大池化层。同时为了防止梯度消失或者梯度爆炸的问题,该网络的激励函数也采用了ReLU。该模型的主要亮点在于通过堆叠多个小卷积核来替换之前大尺度的卷积核,在一定程度上可以很好地减少模型的参数,节省模型的训练时间。为了满足文中四分类病害图像的要求,对模型分类层的网络结构进行修改。

2.1.3 ResNet18模型

ResNet18^[19]网络模型中提出了残差块的结构。在该结构中引入“跳链接”,将输入X与残差块的输出直接相加,这里以数学公式的形式定义残差块的输出为

$$Y_{\text{output}} = G(X, \{W_i\}) + X \quad (1)$$

式中 Y_{output} ——输出 W_i ——权重

$G(X, \{W_i\})$ ——网络学习的残差映射

通过这个残差模块可以解决训练过程中的梯度弥散和梯度爆炸问题,这也是该模型的主要优势之一。同时该模型丢弃了Dropout机制,使用BatchNormalization来加速训练。在本文中修改了模型分类层的网络结构以适用于农作物病害图像的分类。

2.1.4 DenseNet121模型

DenseNet121^[20]卷积神经网络模型借鉴了ResNet网络的构造核心理念,网络的每一层输出都直接通过“跳链接”连接到后面的每一层,也就是说每一层接受前面所有层的输出,是一种比较紧密连接的卷积神经网络结构。它可以缓解由于网络层数太深而带来的梯度消失或者梯度爆炸的问题,提高了模型的鲁棒性。本文中构建了121层的DenseNet121模型,同时对其网络的分类输出层进行修改,使其适合本文的病害分类任务。

2.2 四分类函数

为了适应本文的病害四分类的目标任务,将上述4个深度卷积神经网络模型的分类器改进为4目标的Softmax分类器。Softmax分类器可以接受神经网络全连接层的特征矩阵,适合多分类目标任务的处理,它将输出的各个种类转换成[0,1]之间的数值,并且满足所有的分类概率值的和为1。下面以神经网络第*i*个节点输出为例,给出Softmax函数的数学公式定义

$$\text{Softmax}(z_i) = \frac{e^{z_i}}{\sum_{c=1}^C e^z c} \quad (2)$$

式中 z_i ——第*i*个节点的输出值

c ——计数变量

C ——输出节点的个数,即分类的类别个数

通过以上函数变换后就可以将多分类的输出值转换为范围在0~1之间的概率分布。

2.3 病害目标检测模型

本文采用one-stage算法SSD^[21](Single shot multibox detector)实现对农作物图像中病害区域的检测,它的最大优势之一是模型的速度较快,它的核心思想是在输入图像不同的区域位置上进行密集抽样,抽样时通常也会采用不同尺寸的长宽比进行,然后利用主干特征提取网络(backbone)提取特征,最后进行分类和回归,实现对图像中目标区域的定位和分类。

2.4 超参数设置

2.4.1 图像分类模型

模型的超参数设置对实验结果以及模型的泛化

能力都是至关重要的。通过实验测试对比不同参数下的模型性能,最终对学习率、Batch_size、Epoch、损失函数和优化器等参数加以设置。

学习率是模型训练中十分重要的一个参数,如果学习率设置的过小将会导致梯度更新较慢,使网络训练的时间较长,若设置的过大可能将会导致网络无法收敛,所以这个参数设置是否合理将会直接影响模型的泛化能力。在本文中借助 Pytorch 深度学习框架中 torch.optim.lr_schedule 类下的 scheduler.step()方法来动态调整学习率。

模型训练的 Epoch 和批训练样本数据的 Batch_size 设置是否合理也将直接影响到模型的收敛速度和泛化能力。通过多次对比实验发现,设置每个批次训练样本的 Batch_size 为 32,模型训练 Epoch 为 30 比较合适。

为了适应要解决的病害识别多分类问题,实验中选择交叉熵损失函数(CrossEntropyLoss())和随机梯度下降算法优化器(Stochastic GradientDescent, SGD)。在 Pytorch 中 nn.CrossEntropyLoss() 的计算公式为

$$\text{Loss}(X, \text{Class}) = -\lg \left(\frac{e^{x[\text{Class}]}}{\sum_i e^{x[i]}} \right) = -X[\text{Class}] + \lg \left(\sum_i e^{x[i]} \right) \quad (3)$$

式中 X ——模型的预测输出向量

Class ——实际真实的标签

2.4.2 目标检测模型

在实验中对目标检测模型的学习率也采用 torch.optim.lr_schedule 类下的 scheduler.step()方法来动态调整学习率。主干特征提取网络采用预训练模型的权重进行加速训练,在训练的周期迭代中采取冻结策略,设置 Freeze_Epoch 参数,在前 Freeze_Epoch 周期内对主干特征网络的权重层进行冻结训练,防止训练初期权重被破坏,在 Freeze_Epoch 周期之后进行解冻训练,这样可以加速模型的收敛。

在实验中测试发现,批训练数据 Batch_size 为 16 比较合适。同时本文优化器选择 Adam 优化算法,它一般适用于非凸优化问题,并且计算速度较快,对内存的需求也比较少。

2.5 评价指标

2.5.1 图像分类模型评价指标

对于图像分类模型将从平均识别准确率和模型训练及测试过程中平均损失值两方面进行评价。

(1) 模型平均识别准确率: 它是指对于一批数据中模型预测正确的样本个数占这批数据中全部观测值总数的百分比。结合本文要解决的目标问题,

公式定义为

$$P_i = \frac{T_i}{T_i + F_i} \times 100\% \quad (4)$$

式中 P_i ——第 i 类病害的识别准确率

T_i ——第 i 个类别病害中预测正确的样本个数

F_i ——第 i 个类别病害中预测错误的样本个数
最后,对得到的每种病害的识别准确率求平均,进而得到平均识别准确率 \bar{P} ,这里采用平均准确率可以较好的评价不同模型对于 4 种病害的识别精度。

(2) 模型的平均损失值: 在模型的训练和测试中,计算模型预测的类别标签与真实类别标签的平均损失值,这里采用交叉熵损失函数进行计算,并绘制出损失值的变化曲线。通过观察损失值的变化情况,确定模型的训练过程是否收敛。

2.5.2 目标检测模型评价指标

平均精度均值(mean average precision, mAP): 它常常作为目标检测算法模型的评价指标,在模型运行时会对每张图像标上多个预测框,这个数量会超过真实框的数量,通过设置交并比的阈值,来判断预测框预测的正确与否,接着在不同的查全率水平下对查准率求平均值,即可得到单个类别的平均精确率(AP),然后对所有的类别取平均就可以得到多类别的平均精度均值,它可以较好地评价目标检测模型的性能。

平均损失值: 目标检测模型的损失分为定位区域损失和类别损失,通过绘制模型训练过程中的平均损失值变化曲线可以确定模型的收敛情况。

3 实验

3.1 病害识别模型性能对比实验

在设置相同的实验环境和模型参数的条件下,用上述 4 种图像识别模型分别在简单图像背景的农作物病害数据集 1 和复杂图像背景的农作物病害数据集 2 上实验。本实验对所有的模型进行 30 个周期的迭代,在每一次的迭代过程中,分别计算模型在训练集和测试集上的平均损失值和准确率,通过记录每个模型在测试集上的表现,对其准确率最高的模型权重进行保存。在简单图像背景数据集 1 上的实验结果如图 3 所示。

从图 3 中可以看出 AlexNet 模型大概在迭代 6 个周期后逐渐收敛,DenseNet121 大约在训练 5 个周期时基本收敛,ResNet18 迭代 5 个周期后损失值也基本收敛,VGG16 在第 7 个周期以后渐渐收敛,同时可以发现,4 个模型在训练时 ResNet18 的损失值下降最快,大约在迭代 5 个周期时就取得了较低的损失值(0.259),而 DenseNet121 模型损失值下降

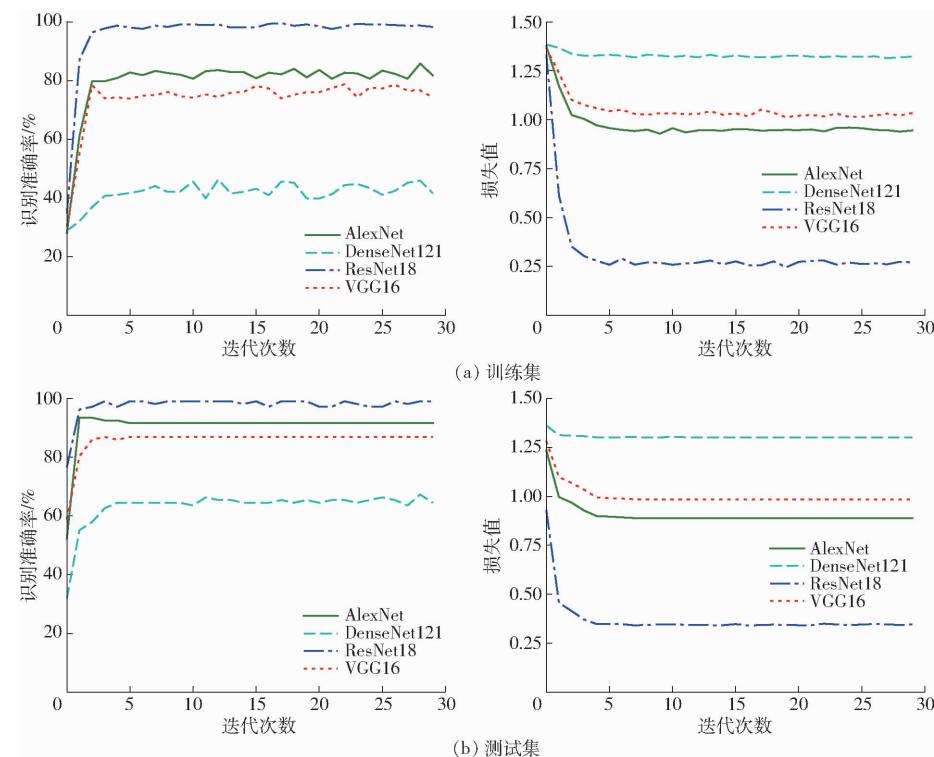


图 3 简单图像背景病害数据集 1 上的实验结果

Fig. 3 Experimental results on simple image background disease data set 1

较为缓慢,整体表现效果弱于其他的模型。

对自行构建的复杂背景农作物图像数据集 2 进行对比实验,其实验条件与在数据集 1 中的实验条件相同,实验结果如图 4 所示。

从图 4 中可以得出,在复杂背景的数据集 2 中

AlexNet 网络大概在迭代 7 个周期以后逐渐收敛; DenseNet121 网络损失值下降最为缓慢,在训练 6 个周期以后损失值基本收敛;ResNet18 网络损失值下降最为迅速,在迭代 5 个周期以后模型基本收敛,且损失值降到了 0.316;VGG16 网络在训练到大约第

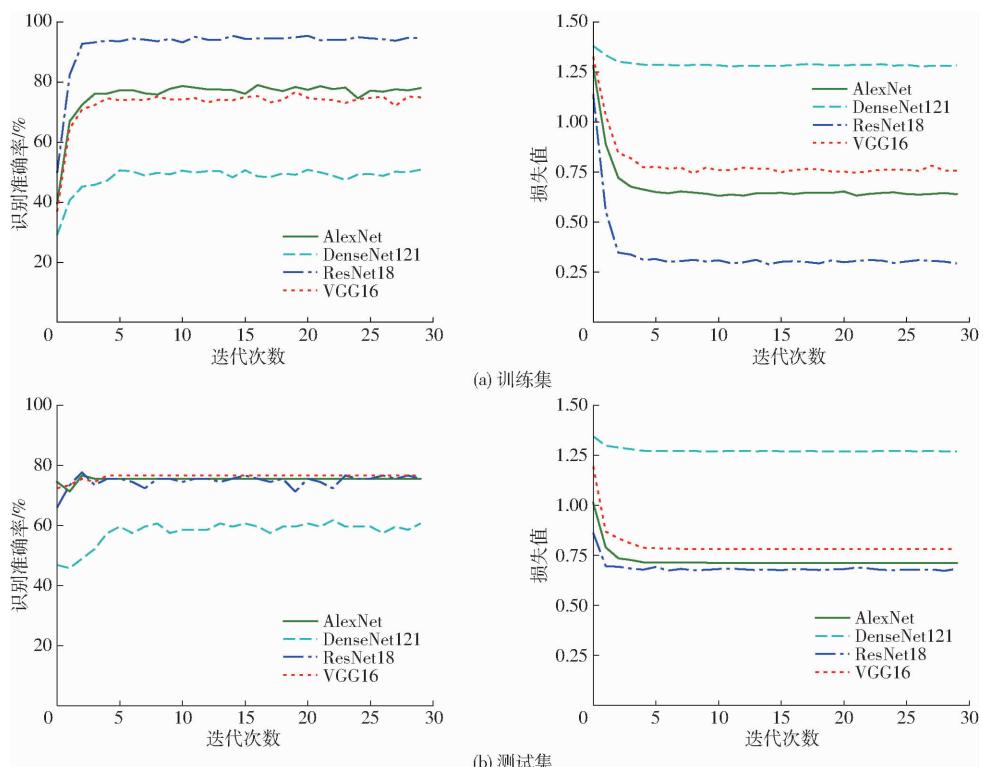


图 4 复杂图像背景病害数据集 2 上的实验结果

Fig. 4 Experimental results on complex image background disease data set 2

8个周期以后,损失值基本收敛。纵观各个模型损失值变化曲线和准确率变化曲线,可以发现,在复杂背景图像下农作物数据集2中的准确率和模型的效果都要弱于在简单背景图像下数据集1中的效果。同时利用上述实验过程中保存的模型最佳权重参数,测试各个模型在数据集1和数据集2测试集上的每种病害的识别准确率和平均识别准确率,在数据集1测试集上的实验结果如表1所示。

表1 数据集1测试集上不同模型的识别准确率

Tab. 1 Recognition accuracy of different models on

test set in dataset 1 %

模型	黑腐病	桧胶锈病	健康	黑星病	平均值
AlexNet	96.552	96.429	71.429	93.103	89.378
DenseNet121	86.207	78.571	33.333	82.759	70.218
ResNet18	100	96.429	90.476	96.552	95.864
VGG16	100	96.429	66.667	93.103	89.050

从表1中可以看出,在数据集1测试集上,ResNet18模型表现最好,平均准确率达到了95.864%,其中除了DenseNet121模型表现较弱以外,其他模型的表现也比较出色,平均准确率都接近于90%。同时发现在以上的模型中,对于数据集1中苹果健康叶片的识别准确率较低一些,通过分析原始的公开数据集可以推测产生这种情况的主要原因是:首先这个公开数据集都是苹果的叶片数据,并无果实病害数据,然而这些叶片之间本身存在很大的相似性,其次是由于很多病害在发病早期和健康的叶片相比并没有太大的区别,即使是人工也很难辨别,只有等到发病中晚期才会形成明显的病害区域或者病斑,所以才会导致其识别准确率较低的情况。

在数据集2测试集上得出每种病害的识别准确率和平均识别准确率,实验结果如表2所示。

表2 数据集2测试集上不同模型的识别准确率

Tab. 2 Recognition accuracy of different models on

test set in dataset 2 %

模型	炭疽病	白粉病	虫害	根腐病	平均值
AlexNet	62.069	82.143	57.143	72.414	68.442
DenseNet121	34.483	28.571	66.667	65.517	48.810
ResNet18	51.724	89.289	61.905	65.517	67.108
VGG16	48.276	82.143	76.190	68.966	68.894

从表2中可以看出,在设置相同的实验环境和模型参数的条件下,4个模型在复杂背景下的数据集2的测试集上平均准确率都较低,模型整体性能都较差。其中AlexNet和VGG16模型表现稍好,但在测试集上的平均准确率也仅仅达到了68.442%和68.894%,而DenseNet121模型表现效果最差,平均识别准确率仅有48.810%。

综上所述,对比4个模型分别在数据集1和数据集2中的性能表现,可以发现模型在简单图像背景下的数据集1中表现效果都比较出色,在测试集上的平均识别准确率基本都可以达到接近90%的精度,其中ResNet18平均识别准确率更是达到了95.864%,然而在设置相同的实验环境和模型参数的条件下,4个模型对复杂图像背景下的数据集2都表现出较差的效果,最高的平均识别准确率也仅仅只有68.894%。

3.2 病害目标检测实验结果

在上述实验中,发现4种图像识别模型对简单背景图像的农作物有较好的识别准确率,然而对复杂背景的农作物图像却表现出较低的准确率,故本文在复杂图像背景的数据集2中,采用目标检测算法SSD模型,实现对农作物病害区域的检测。设置总的迭代周期为60轮,得出实验结果如图5所示。

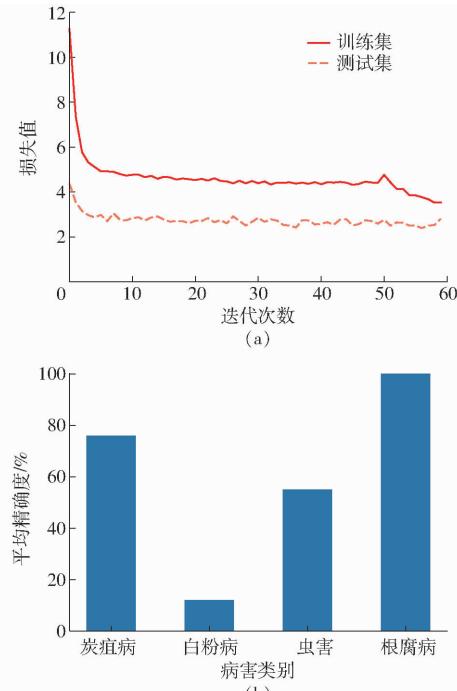


图5 复杂图像背景农作物数据集2上的实验结果
(迭代60轮)

Fig. 5 Experimental results on complex image background crop data set 2 (60 iterations)

从图5a中可以发现,当迭代60轮时,模型的收敛效果并不理想,取训练过程中最佳的模型权重在测试集上实验,结果如图5b所示,发现模型的性能较差,对4种病害的平均精度均值只有60.90%。再次进行实验,设置总的迭代周期为100轮,得出结果如图6所示。

从图6a中发现,模型大概在迭代75个周期时,收敛的效果较好,取此时模型权重文件在测试集上进行实验发现,模型的效果比迭代60个周期时好很

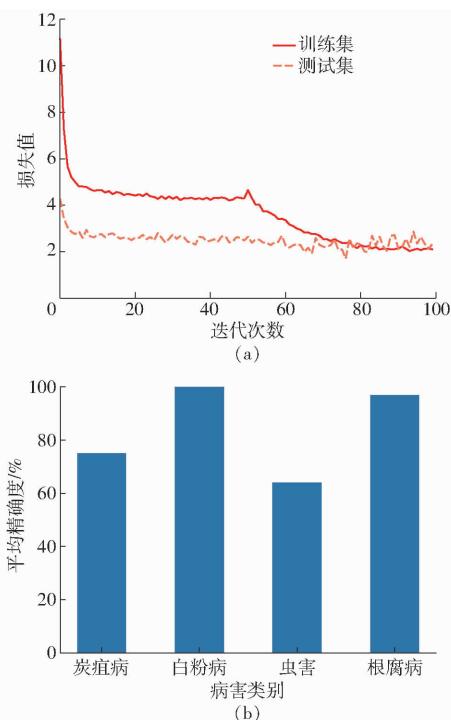


图 6 复杂图像背景农作物数据集 2 上的实验结果
(迭代 100 轮)

Fig. 6 Experimental results on complex image background crop data set 2 (100 iterations)

多,对 4 种病害的平均精度均值达到 83.90%,且单个病害类别的平均精度最低的也达到 64.0%。综

上所述,采用 SSD 目标检测算法模型,在复杂背景图像的农作物数据集 2 上达到了较好的效果。

4 结束语

本文抓取在线农技问答平台的病害图像数据,构建了一个复杂图像背景下的农作物病害数据集 2,并在数据集 2 和公开简单背景下的数据集 1 上进行实验分析。在相同实验条件下,采用 AlexNet、DenseNet121、ResNet18、VGG16 模型在数据集 1 和数据集 2 上分别进行病害识别实验,结果表明,4 个模型基本在数据集 1 中表现均出色,模型的平均识别准确率都接近 90%,其中 ResNet18 的平均识别准确率更是达到 95.864%,但是模型在数据集 2 中的表现整体较差,最高的平均识别准确率只有 68.894%。通过对比实验可以得出,模型在简单背景的病害数据集上表现出较好的实验效果,但是当应对较复杂的图像背景数据时,模型的识别准确率都较差。为此本文又采取了进一步的相关实验,在数据集 2 上采用 SSD 目标检测算法,实现对复杂病害图像病害区域的预测,实验结果发现,当模型迭代约 75 个周期时,取得了较好的模型权重,使用此时训练的模型在测试集上实验,最终模型的平均精度均值达到 83.90%。

参 考 文 献

- [1] 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.
- [2] 许景辉,邵明烨,王一琛,等.基于迁移学习的卷积神经网络玉米病害图像识别[J].农业机械学报,2020,51(2):230–236,253.
XU Jinghui, SHAO Mingye, WANG Yichen, et al. Recognition of corn leaf spot and rust based on transfer learning with convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 230–236, 253. (in Chinese)
- [3] HOSSAIN S M M, DEB K, DHAR P K, et al. Plant leaf disease recognition using depth-wise separable convolution-based models[J]. Symmetry, 2021, 13(3): 511.
- [4] LEE K, SILVA B N, HAN K. Deep learning entrusted to fog nodes (DLEFN) based smart agriculture[J]. Applied Sciences, 2020, 10(4): 1544.
- [5] 袁培森,曹益飞,马千里,等.基于 Random Forest 的水稻细菌性条斑病识别方法研究[J].农业机械学报,2021,52(1): 139–145,208.
YUAN Peisen, CAO Yifei, MA Qianli, et al. Identification method of rice bacterial leaf streak based on Random Forest [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(1): 139–145, 208. (in Chinese)
- [6] 杨森,冯全,张建华,等.基于深度学习与复合字典的马铃薯病害识别方法[J].农业机械学报,2020,51(7):22–29.
YANG Sen, FENG Quan, ZHANG Jianhua, et al. Identification method for potato disease based on deep learning and composite dictionary[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7): 22–29. (in Chinese)
- [7] 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 Wenxia, ZHAO Jian, ZHANG Dongyan, et al. Recognition of wheat leaf diseases based on elliptic metric learning [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(12): 20–26. (in Chinese)
- [8] SLADOJEVIC S, ARSENOVIC M, ANDERLA A, et al. Deep neural networks based recognition of plant diseases by leaf image classification[J]. Comput Intel Neurosc, 2016: 1–11.
- [9] 田凯,张连宽,熊美东,等.基于叶片病斑特征的茄子褐纹病识别方法[J].农业工程学报,2016,32(增刊1):184–189.
TIAN Kai, ZHANG Liankuan, XIONG Meidong, et al. Recognition of phomopsis vexans in solanum melongena based on leaf disease spot features[J]. Transactions of the CSAE, 2016, 32(Supp. 1): 184–189. (in Chinese)

- [D]. Beijing: China Agricultural University, 2018. (in Chinese)
- [19] 韩东海, 刘新鑫, 鲁超, 等. 苹果内部褐变的光学无损伤检测研究[J]. 农业机械学报, 2006, 37(6): 86–88.
HAN Donghai, LIU Xinxin, LU Chao, et al. Study on optical non-destructive detection of internal browning of apples [J]. Transactions of the Chinese Society for Agricultural Machinery, 2006, 37(6): 86–88. (in Chinese)
- [20] 韩东海, 刘新鑫, 赵丽丽, 等. 受损苹果颜色和组织的近红外光谱特性[J]. 农业机械学报, 2003, 34(6): 112–115.
HAN Donghai, LIU Xinxin, ZHAO Lili, et al. Near-infrared spectral characteristics of damaged apple color and tissue [J]. Transactions of the Chinese Society for Agricultural Machinery, 2003, 34(6): 112–115. (in Chinese)
- [21] 孙红, 梁媛媛, 田男, 等. 鲜切果品新鲜度可见/近红外快速检测装置设计与实验[J]. 农业机械学报, 2019, 50(增刊): 393–398.
SUN Hong, LIANG Yuanyuan, TIAN Nan, et al. Design and experiment of visible/near infrared rapid detection device for freshness of fresh-cut fruits [J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50 (Supp.): 393–398. (in Chinese)
- [22] 郭志明, 黄文倩, 陈全胜, 等. 苹果腐心病的透射光谱在线检测系统设计及试验[J]. 农业工程学报, 2016, 32(6): 283–288.
GUO Zhiming, HUANG Wenqian, CHEN Quansheng, et al. Design and test of on-line detection system for apple core rot disease based on transmitted spectrum [J]. Transactions of the CSAE, 2016, 32(6): 283–288. (in Chinese)
- [23] HU Dong, FU Xiaping, HE Xueming, et al. Noncontact and wide-field characterization of the absorption and scattering properties of apple fruit using spatial-frequency domain imaging [J]. Scientific Reports, 2016, 6(1): 1387–1401.
- [24] VANOLI M, RIZZLOL A, GRASSI M, et al. Studies on classification models to discriminate ‘Braeburn’ apples affected by internal browning using the optical properties measured by time-resolved reflectance spectroscopy [J]. Postharvest Biology and Technology, 2014, 91(Supp. C): 112–121.
- [25] BLIZNYUK V V, PARSHIN V A, RZHANOV A G, et al. Determining the rate of degradation of a high-power laser diode from the dependence of the radiation spectrum on variations in the pumping current [J]. Bulletin of the Russian Academy of Sciences: Physics, 2021, 85(2): 184–188.

(上接第 124 页)

- [10] 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. Recognition of multiple plant leaf diseases based on improved convolutional neural network [J]. Transactions of the CSAE, 2017, 33(19): 209–215. (in Chinese)
- [11] AGARWAL M, GUPTA S K, BISWAS K K. Development of efficient CNN model for tomato crop disease identification [J]. Sustainable Computing: Informatics and Systems, 2020, 28: 100407.
- [12] 丁永军, 张晶晶, 李民赞. 基于卷积胶囊网络的百合病害识别研究[J]. 农业机械学报, 2020, 51(12): 246–251, 331.
DING Yongjun, ZHANG Jingjing, LI Minzan. Disease detection of lily based on convolutional capsule network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(12): 246–251, 331. (in Chinese)
- [13] 贾建楠, 吉海彦. 基于病斑形状和神经网络的黄瓜病害识别[J]. 农业工程学报, 2013, 29(增刊1): 115–121.
JIA Jiannan, JI Haiyan. Recognition for cucumber disease based on leaf spot shape and neural network [J]. Transactions of the CSAE, 2013, 29(Supp. 1): 115–121. (in Chinese)
- [14] LIU X, MIN W, MEI S, et al. Plant disease recognition: a large-scale benchmark dataset and a visual region and loss reweighting approach [J]. IEEE Transactions on Image Processing, 2021, 30: 2003–2015.
- [15] TSUCHIYA H, FUKUI S, IWAHORI Y, et al. A method of data augmentation for classifying road damage considering influence on classification accuracy [J]. Procedia Computer Science, 2019, 159: 1449–1458.
- [16] RUSSAKOVSKY O, DENG J, SU H, et al. Imagenet large scale visual recognition challenge [J]. International Journal of Computer Vision, 2015, 115(3): 211–252.
- [17] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25: 1097–1105.
- [18] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C] // International Conference on Learning Representations, 2015.
- [19] HE K, ZHANG X, REINHOLDT S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770–778.
- [20] HUANG G, LIU Z, LAUREENS V, et al. Densely connected convolutional networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700–4708.
- [21] LIU W, NGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C] // European Conference on Computer Vision, 2016: 21–37.