乔世成,党珊珊,何海祝,等.基于卷积神经网络的农作物病害检测研究综述[J].山西农业大学学报(自然科学版),2025,45(2):113-127.
Qiao S C, Dang S S, He H Z, et al. A review of crop disease detection research based on convolutional neural networks[J]. Journal of Shanxi Agricultural University(Natural Science Edition), 2025,45(2):113-127.
doi: 10.13842/j.cnki.issn1671-8151.202406015

基于卷积神经网络的农作物病害检测研究综述

乔世成,党珊珊,何海祝,关强,王郝日钦,路扬

(内蒙古民族大学 计算机科学与技术学院,内蒙古 通辽 028043)

摘　要:我国是农业大国,拥有广大的农作物种植面积和丰富的农业资源。然而,近年来,农作物病害问题日益严重。农作物病害不仅直接影响产量和质量,还会造成农民的经济损失,威胁粮食安全和生态环境,对我国农业可持续发展构成了巨大威胁。因此,对农作物病害的精准检测是提高我国农业发展的关键因素。随着深度学习的不断发展,无损检测技术已得到广泛应用,利用卷积神经网络进行农作物病害的精准检测成为近年来研究的热点。卷积神经网络具有较好的图像检测与识别能力,能够适应多种病害类型,实现高效、准确的大规模检测,被广泛应用于农作物病害的精准检测中。本文首先介绍了卷积神经网络结构;然后探讨了几种典型的检测农作物病害的卷积神经网络模型;其次分析了其它神经网络研究情况并进行总结;重点讨论了目前基于小样本学习、小目标检测、网络轻量化改进的卷积神经网络热点研究问题;之后对未来农作物病害检测所面临的挑战和展望进行了总结,如针对数据集标注困难、模型缺乏泛化能力、小样本小目标数据集识别精度较低等问题,提出了建立更高质量的农作物病害数据集、优化小样本小目标数据集下的网络模型结构以及对农作物病害无损检测进行实时监测与预警等研究展望,以期为不断推进农业技术创新和应用、为我国农作物病害的精准检测研究提供参考依据。

关键词:卷积神经网络; 小样本; 小目标; 轻量化
中图分类号:S126　　**文献标识码**:A　　**文章编号**:1671-8151(2025)02-0113-15

A review of crop disease detection research based on convolutional neural networks

Qiao Shicheng, Dang Shanshan, He Haizhu, Guan Qiang, Wang Haoriqin, Lu Yang

(*College of Computer Science and Technology, Inner Mongolia Minzu University, Tongliao 028043, China*)

Abstract: China is a major agricultural country with extensive crop cultivation areas and abundant agricultural resources. However, in recent years, crop disease problems have become increasingly severe, directly affecting yield and quality, causing economic losses for farmers, and posing threats to food security and the ecological environment. These issues have significantly hindered the sustainable development of agriculture in China. Therefore, precise detection of crop diseases is a key factor in enhancing agricultural development in China. With the continuous development of deep learning, non-destructive detection technologies have been widely applied. The use of convolutional neural networks (CNNs) for accurate crop disease detection has become a hot research topic in recent years. CNNs exhibit strong capabilities in image detection and recognition, can adapt to various types of diseases, and enable efficient and accurate large-scale detection, making them widely applicable in the precise detection of crop diseases. This paper first introduces the structure of convolutional neural networks, then explores several typical convolutional neural network models for crop disease detection, and summarizes other neural network research. The paper focuses on current hot research topics in CNNs based on small-sample learning, small target detection, and network lightweight improvements. Additionally, it summarizes the challenges and future prospects for crop disease detection, including the difficul-

收稿日期:2024-06-07　　**修回日期**:2024-11-22
基金项目:国家自然科学基金(62162049);内蒙古民族大学博士科研启动基金(BS658)
作者简介:乔世成(ORCID:0000-0001-8731-9417),博士,副教授,研究生导师,研究方向:智能检测与控制。E-mail::qiaosjo@imun.edu.cn

ties in dataset annotation, lack of model generalization ability, and low recognition accuracy for small-sample and small-target datasets. It proposes research directions such as establishing higher-quality crop disease datasets, optimizing network model structures for small-sample and small-target datasets, and conducting real-time monitoring and early warning for non-destructive crop disease detection. These insights aim to continuously promote agricultural technology innovation and application, providing a reference for precise detection research of crop diseases in China.

Keywords: Convolutional neural network, Small sample, Small target, Lightweight

我国气候地理环境优越,光热水资源充足,适合农作物的生长,然而优越的气候环境也为病菌的生长繁殖提供了有利条件,因此农作物病害问题成为了制约农业发展的关键因素[1]。由于病虫害具有分布广、种类多等特征,农民在病害的防治方面难以采取高效措施,农作物的病害问题日益加重[2]。农作物病害主要特点包括症状多样、传播速度快、病原体种类多、受气候和环境影响大、病害间相似性高等。传统的农作物病害检测方法包括人工判别和理化指标检测。其中,人工判别需依靠专家的肉眼进行判断,对于早期病害的检测具有一定难度,存在主观性强、不易量化、耗费时间且检测效率低等问题。理化指标检测又具有破坏性,该方法预处理繁琐、检测周期长且理化指标需要测试人员具备较高的专业知识[3]。针对传统检测方法的弊端,无损检测技术是一种在不破坏被检测对象的情况下进行检测的方法,已经在农作物病害检测领域得到了广泛应用。在无损检测的数据处理中,基于卷积神经网络的方法应用最为广泛,以其识别准确性高、鲁棒性强、泛化性好等优点被应用到农作物病害检测的各个方面。

针对以上研究,本文系统性地综述了卷积神经网络模型在农作物病害检测领域的研究进展,分析了其它神经网络研究情况并进行总结,重点阐述了基于小样本学习、小目标检测、网络轻量化改进的卷积神经网络热点研究问题,最后对未来农作物病害检测所面临的挑战和展望进行了讨论,有利于推动农作物病害检测的发展。

1 卷积神经网络结构

卷积神经网络(Convolutional Neural Networks, CNN)是深度学习模型中的经典算法之一,其核心思想是通过卷积、池化等操作来提取图像特征信息,然后将特征映射到高维空间,再由全连接层对特征进行分类或回归。卷积神经网络通过训练大量数据来提高模型的检测能力,被广泛应用于农作物病害检测、实时预警和其它计算机视觉任务中。典型的卷积神经网络包括输入层、卷积层、激活层、池化层、全连接层和输出层,其结构如图1所示。

输入层用于接收输入图像,其大小与输入图像大小相同。卷积层是卷积神经网络的核心层,输入层特征图进入卷积层后,会与卷积核进行卷积运算,从而提取图像的局部特征。靠前的卷积层主要提取出低层次的图像特征,靠后的卷积层提取出的是更加复杂的图像特征[4]。卷积主要分为一维、二维和三维卷积,应用于不同的数据类型,图像识别与目标检测领域常使用二维;文本、语言等时序数据常使用一维[5];三维卷积常用于处理视频序列或三维医学图像等[6]。激活层通常是指应用的激活函数,其作用是引入非线性特性、决定神经元的输出敏感度、帮助模型梯度传播。早期的非线性激活函数包括Sigmoid函数[7]和Tanh函数[8],目前激活函数主要为ReLu函数[9]。池化层是卷积神经网络中常用的一层,主要作用是对特征图进行降维处理,在保留主要特征的同时减少参数,提高模型泛化能力。池化操作分为平均值池化和最大值池化,对于图像处理问题,采用最大值池化的模型性能更好[10]。全连接层实现对模型提取的高级特征进行映射,输入的特征经过全连接层会被拉伸为一维数组,实现整合卷积层或者池化层中具有类别区分性的局部信息,从而有利于特征的组合[11]。全连接层将输入的特征向量与权重矩阵相乘,再加上偏置项,最后经过激活函数映射到最终的输出值。全连接层计算公式如下:

$$y_{w,b}(x)=f\left\{\sum_{i=1}^{n} w_i x_i + b_i\right\}$$

式中,w_i是全连接层中的权重系数,x_i是上一层第i个神经元的值,b_i是全连接层的偏置量。输出层位于卷积神经网络模型末端,用于输出经卷积神经网络计算得到的数值,做好最后目标结果输出。

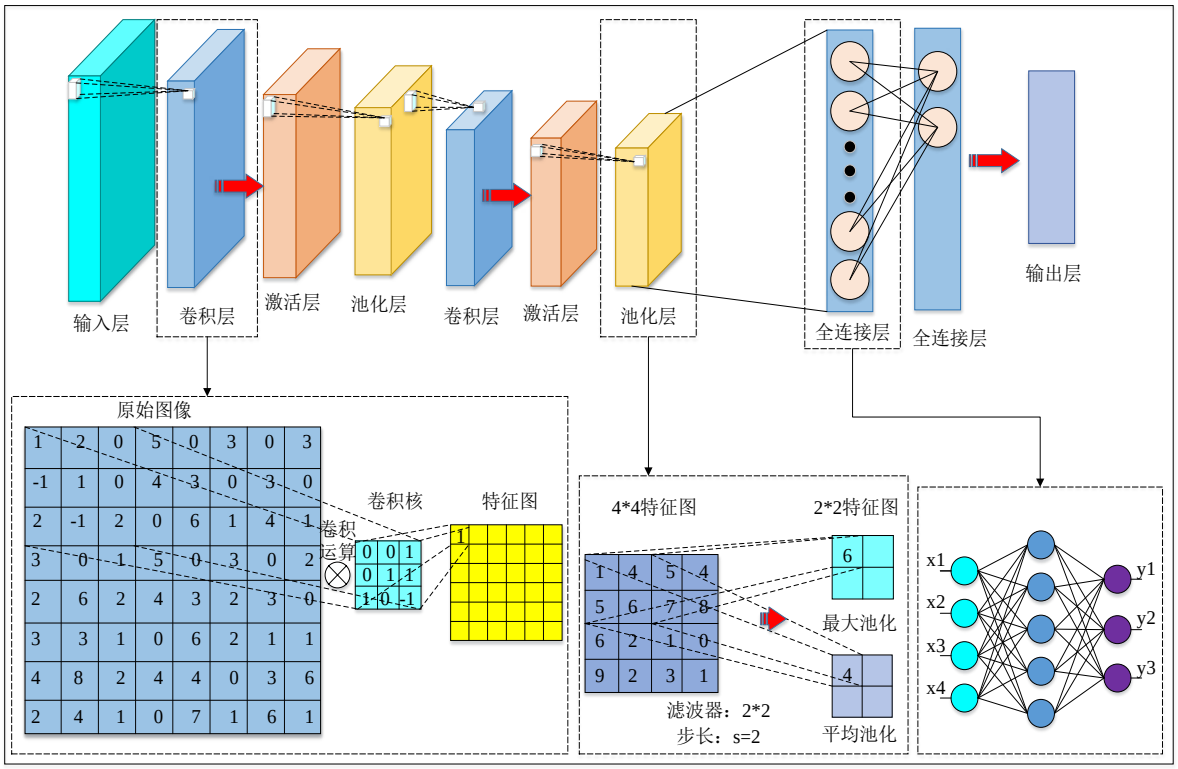

图1　典型的卷积神经网络结构

Fig.1　Typical convolutional neural network structure

2　典型卷积神经网络模型

2.1　AlexNet

AlexNet网络模型是由Alex、Hinhton在图像识别大赛中提出的,一共有8层,前5层为卷积操作层,后3层为全连接层。它是一个较LeNet模型更深更宽的升级版本,奠定了卷积神经网络在图像分类算法中的核心地位。网络首次引入ReLu激活函数,训练速度比之前快了几倍,模型使用多个GPU进行训练,采用了卷积和池化层的堆叠结构,引入了Dropout正则化技巧缓解过拟合现象,提高了模型的泛化能力。Guo等[12]基于AlexNet构建了Multi-Scale AlexNet模型,用于番茄叶部病害图像检测,其准确率达92%以上,检测效果如图2所示。Lü等[13]在原AlexNet网络的基础上,融合拓展卷积和多尺度卷积提高特征提取能力,网络识别能力得到了极大提高。李云昊等[14]基于改进的AlexNet模型对13种常见苜蓿病害进行识别,模型识别总体精度也达到了72%。同时,Verma等[15]利用AlexNet对葡萄植株受病害感染的严重情况进行等级分类,最后通过分析F1值、召回率和ROC曲线等数据来分析网络的性能。在此基础上,Wagle等[16]利用AlexNet对PlantVillage数据集中的9种植物进行检测和分类,然后将该模型用于番茄植物叶片的病害分类,取得了很好的效果。Elmitwally等[17]使用AlexNet模型对3种水稻植物叶片病害进行检测,实现了对水稻叶片病害更精确、更快速的识别分类。从以上研究可见,AlexNet具备强大的图像特征提取能力,适合大规模数据集处理且在迁移学习方面表现良好,广泛适用于农作物病害的检测任务。

由于实际农田环境中背景复杂,农作物病害特征不易提取,原始AlexNet模型又具有大量的参数和较大的模型体积,这在资源受限的设备上应用时检测精度不高。为了适应农作物病害检测的特定需求,研究者们对AlexNet进行了改进。例如,通过去除局部响应归一化层、修改全连接层、设置不同尺寸的卷积核来提取更丰富的特征,从而提高了模型对病害图像的识别能力。

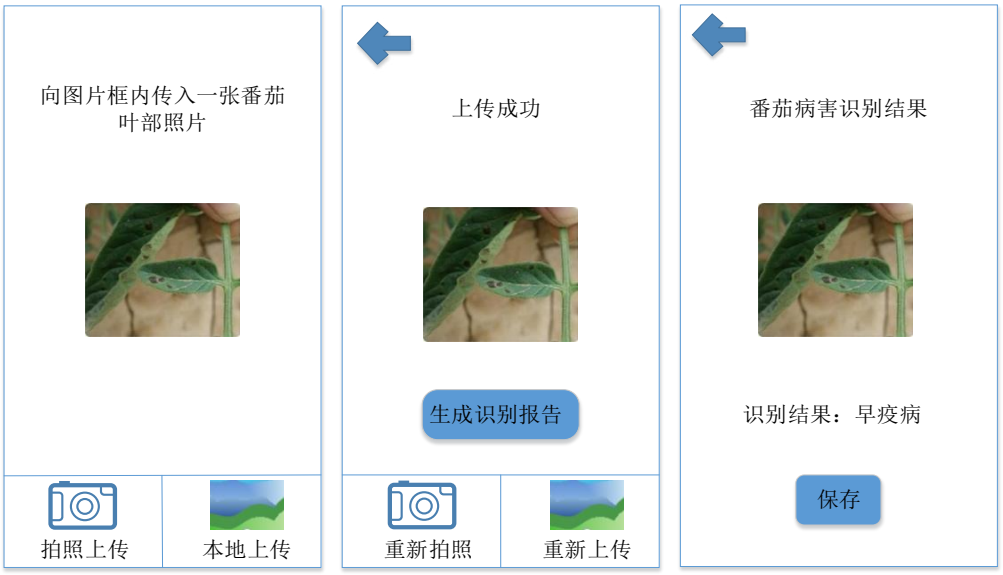

（a）识别系统首页 （b）识别界面 （c）识别结果

图2 番茄叶部病害检测系统界面

Fig.2 Tomato leaf disease detection system interface

2.2 VGGNet

VGGNet网络由Simonyan和Zisserman[18]于2014年提出。VGG版本常用的有VGG16和VGG19网络，模型主要贡献是提出了使用更小的卷积核(3*3)和池化核(2*2)来代替较大的卷积核和池化核，这种设计使得网络更深、参数量更少，从而提高了效率和准确率。相较于使用单一大卷积核进行卷积操作，较小的卷积核可以在很大程度上减少卷积操作产生的计算量，同时多个小卷积核的堆叠也提升了网络模型精度，优化了后续网络模型的性能。Simonyan等[18]使用小卷积核(3*3)架构实现卷积滤波，将网络参数增加到16～19层，从而实现对现有技术的改善。Yan等[19]使用Adam算法对VGG16模型进行优化，并将其用于苹果叶片病害的分类中。李森等[20]利用AlexNet和VGG模型对黄瓜和水稻病害进行特征提取，模型识别准确率提高到了98.33%。同样的，Wang等[21]通过VGG16，VGG19，ResNet50，InceptionV3对苹果灰斑病叶片进行分级，结果表明VGG16识别效果最好。Chew等[22]融合VGG16和迁移学习对香蕉、玉米、豆类等粮食作物进行分类，模型在测试集上F1指标达到了86%。Qiu等[23]基于VGG网络对水稻病害进行识别，设置不同的学习率对网络参数实施微调，模型平均正确率为97.19%。研究表明，利用VGG网络能够准确地检测出农作物病害，为实现自动检测病害提供了新方法。

由于VGGNet的计算复杂度和参数量较大，直接应用于资源受限的设备上可能会遇到挑战。为了解决这个问题，研究者提出了轻量化的VGG-Net模型，通过适当的网络结构调整和优化，VGG-Net可以有效地用于识别和分类农作物病害，从而帮助提高农业生产的效率和质量，降低了模型的计算复杂度且提高了运行速度。

2.3 ResNet

在ResNet未出现之前，人们普遍认为模型的网络层数越深，模型提取特征的能力越好，但事实并非如此，随着网络层数的加深，有可能造成梯度消失或梯度爆炸等问题，甚至可能引起网络退化。2015年，何恺明等[24]提出了残差网络ResNet，成功的解决了网络加深造成的一系列问题，该模型核心结构就在于引入了残差模块，给非线性的卷积层增加直连边促进信息传播，使高层的梯度能直接回传回来，解决了深层网络梯度消失的问题。何欣等[25]利用多尺度残差神经网络对葡萄叶片进行识别，引入多尺度卷积来提高识别准确率。Zhang等[26]利用改进的ResNet网络对番茄叶片病害进行识别，然后在Plant Village数据集上进行验

证,模型识别准确率达到了97.28%。Xing等[27]对比6种典型网络模型对12 561张病虫害图像进行识别,改进后DenseNet模型识别准确率最高。Wang等[28]使用ResNeXt模型来解决玉米病害斑点较小难以提取特征的问题,模型识别准确率为90.22%。Khan等[29]利用ResNet-34网络对5种苹果树叶片进行病虫害特征识别,模型取得了97.18%的准确率。Zhang等[30]在ResNet网络中加入注意力机制对小麦不完善粒识别,模型识别准确率高达97.5%。以上研究表明,应用ResNet网络检测农作物病害时,模型准确率随着深度的加深而得到提升,模型检测精度更高、效果更好。ResNet在农作物病害检测领域的应用展现了其强大的识别能力和高效的处理速度。通过结合现代Web技术,ResNet模型可以被集成到用户友好的系统中,为农作物病害的快速识别和管理提供有力的工具。未来的研究可以探索进一步优化模型训练速度,以及将模型应用于实时视频分析,以实现更及时的病害预警和防治。

2.4　GoogleNet

GoogleNet网络由Google团队于2014年提出,网络结构为多层串并联,网络主体卷积部分中使用5个模块,每个模块间使用大小为3*3,步长为2的最大池化层来降低输出维度。GoogLeNet不仅着力于深化网络结构,而且还引进了1个崭新的基础构架Inception网络模型,从而增加卷积神经网络的深度和宽度。Mohanty等[31]利用PlantVillage数据集训练GoogLeNet模型,实验表明当训练数据和测试数据比例为8:2时,GoogLeNet网络上平均的检测准确率最高,模型在苹果叶片上的激活可视化结果如图3所示。Fu等[32]使用GoogLeNet网络对苹果、柠檬、橙子、石榴、西红柿和彩色辣椒进行分类,通过试验,测试准确率为96%。Yang等[33]在Inception模块中加入ECA注意力机制来对水稻叶部病害进行检测,模型平均准确率达到了99.58%。GoogleNet能够检测图像中的多尺度特征,Afzaal等[34]利用机器视觉和深度学习的方法来识别田间马铃薯植株,将病害图像分为3类,模型准确地对不同阶段的马铃薯早疫病进行了分类。以上研究表明,通过GoogleNet模型对农作物病害进行检测,模型识别准确率更高、效果更好。GoogleNet的高效率使得它适用于实时或近实时的农作物病害检测系统,这对于快速响应和处理农作物病害至关重要,可以减少潜在的损失。GoogleNet通过其独特的Inception模块和高效的网络设计,在农作物病害检测领域展现出了良好的应用潜力。它能够有效地处理和识别农作物病害图像,为农业生产提供技术支持,有助于提高作物产量和质量,减少由病害引起的损失。随着深度学习技术的不断发展,未来GoogleNet及其变体在农作物病害检测中的应用将更加广泛和深入。

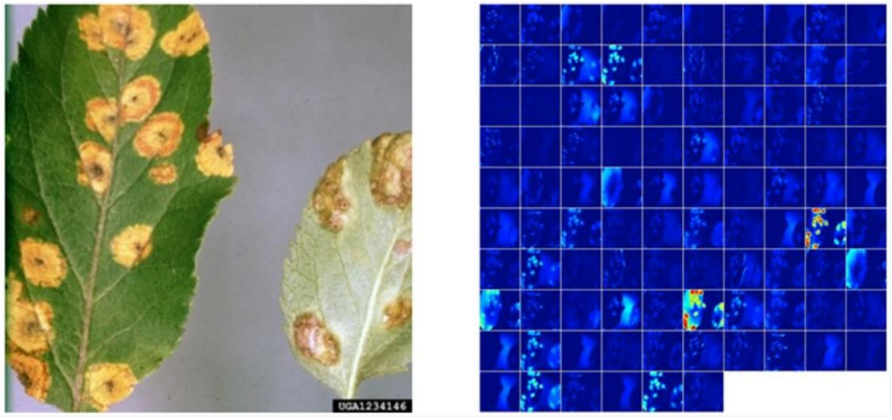

图3　苹果叶片病害激活可视化

Fig.3　Visualization of apple leaf disease activation

2.5　MobileNet

MobileNet网络模型[35]是由Google在2017年针对手机或者嵌入式设备而提出的,是一种用于移动设备的轻量型卷积神经网络,在资源受限的环境下可实现高效的图像分类和目标检测。MobileNet系列中主要包含MobileNetV1、Mobile-

NetV2、MobileNetV3。其中MobileNetV2因其网络参数量少、计算成本低、模型性能好等优点而被广泛应用。MobileNet主要创新之处是提出了深度可分离卷积,可以在减少参数量的同时保持较好的准确率。Selvaraj等[36]基于MobileNetV1、ResNet50和InceptionV2模型对香蕉病虫害进行检测,模型准确率可达90%以上,检测效果如图4所示。Elfatimi等[37]通过轻量级网络MobileNetV2对大豆病害进行识别,然后利用深度可分离卷积来压缩模型,从而实现参数量降低的效果。Chen等[38]将迁移学习引入到预训练的MobileNetV2中来提高小病灶特征的学习能力,模型达到了99.71%的平均识别准确率。Li等[39]使用轻量级MobileNetV2检测苹果叶部病害,模型对少量数据集分类准确率有较大提升,对大的数据量准确率仍有待提高。与此同时,Bi等[40]使用MobileNet模型对苹果叶片病害进行检测,达到了低成本、稳定、高精度的效果。Singh等[41]使用多个预训练模型来识别椰子树疾病,结果表明MobileNet的识别精度为82.10%,优于其它经典的CNN模型识别精度。Bi等[42]改进MobilenetV3模型来识别玉米叶部病害,在开源数据集上准确率也达到了98.23%。以上研究表明,MobileNet模型已被广泛应用于农作物病害检测中,其主要优势在于轻量级结构和高效的性能,通过引入深度可分离卷积,MobileNet能够大幅减少模型参数和计算量,同时保持较高的识别精度。此外,MobileNet还采用了倒残差结构,这有助于模型更好地捕捉图像特征,并提高特征提取的效率。未来的研究可以进一步探索如何提高模型的泛化能力和实时性能,以便更好地适应实际的农业生产环境。



图4 香蕉病害检测效果图

Fig.4 Banana disease detection effect

2.6 对比与总结

本文对典型卷积神经网络模型的结构特点、模型优缺点、研究对象、病害类型进行了简单对比,结果如表1所示。

3 其它神经网络研究情况

3.1 前馈神经网络(FNN)

前馈神经网络(Feedforward Neural Network,FNN)是最早发明的简单人工神经网络,网络信息从输入层开始输入,每层的神经元接收前一级输入并输出到下一级。前馈神经网络在农业病害检测领域的应用非常广泛,其主要作用是通过分析大量的农业数据和图像,自动识别作物病害,提高病害检测的准确性和效率。BP神经网络是前馈神经网络中特殊的一类,使用反向传播算法来更新网络的权重,从而最小化损失函数。如黄林生

表1　卷积神经网络模型结构对比结果

Table 1　Convolutional neural network model structure comparison results

模型结构 Model structure	网络结构特点 Network architecture characteristics	优点 Advantages	缺点 Disadvantages	研究对象 Research object	病害类型 Disease type	参考文献 References
AlexNet	共8层,前5层是卷积层,后3层为全连接层,结构简单,计算简单	使用层叠的卷积层,使用Dropout抑制过拟合,引入Relu激活函数,多GPU训练,灵活的卷积核数	准确率不高,训练速度慢,需要更多的计算资源	番茄,苜蓿,葡萄,水稻	斑点病,斑枯病,黄曲病,疫病,花叶病,轮斑病,叶枯病,叶斑病,锈病,霜霉病,白粉病,褐斑病,黄斑病,炭疽病,黄萎病,病毒病,潜叶病,叶黑穗病	[14－17,21,43－46]
VGGNet	由13/16个卷积层组成,结构简洁,实用性和拓展性好	拥有更少的参数量,更多的非线性变换,准确率较高	训练时间太长,需要大量GPU支持,文件体积极大	苹果,黄瓜,水稻,香蕉,玉米,豆类	疮痂病,斑病,锈病,纹枯病,稻瘟病,叶枯病,稻曲病,白粉病,霜霉病,黑腐病,稻穗病,枯萎病	[18－23,45－46]
ResNet	50层网络,提出Residual模块,使用BN加速训练,引入全局平均池化	结构清晰,训练速度快,拓展性强,更少的参数,准确性更高	训练时间过长,且残差不能完全解决梯度消失、网络退化的问题	葡萄,番茄,玉米,苹果,小麦	褐斑病,黑痘病,黄叶病,毛毡病,叶斑病,枯萎病,疫病,叶霉病,病毒病,卷曲病,炭疽病,溃疡病,黑霉病,灰斑病,锈病,疮痂病,白粉病,花叶病,黑星病,链格孢病	[25－29,45－46]
GoogleNet	22层网络,模块化结构,方便添加与修改	多尺度特征提取,计算资源利用率高,准确率高	网络结构复杂,训练时间较长,难以可视化和解释	苹果,柠檬,橙子,石榴,西红柿,辣椒,水稻,马铃薯	黑星病,链格孢病,花叶病,褐斑病,白粉病,贝氏萎缩线虫病,叶枯病,斑点病,枯萎病	[18,31－34,47]
MobileNet	多个卷积层,参数量小,计算成本低	运行速度十分迅速,适合移动端设备,模型性能好	提取特征能力较弱,训练速度受带宽影响	香蕉,大豆,苹果,椰子树,玉米	枯萎病,茎病,束顶病,叶斑病,锈病,疮痂病,环腐病,茎出血病,叶枯病,灰斑病	[36－37,39－42]

等[48]利用BP神经网络方法构建小麦条锈病的2种监测模型,结果表明宽波段结合红边波段植被指数的监测总体精度优于仅基于宽波段植被指数的模型。黄亮等[49]利用BP神经网络实现双孢蘑菇多酚氧化酶的检测,结果表明隐含层神经元节点数为14的模型建模效果最好,预测集总体判别率可达到94.737%。邢瑜琪等[50]采用逐步回归分析方法,进一步构建基于BP算法的小麦赤霉病发病预测模型,实现了对江苏姜堰和张家港地区病穗率预测准确度100%的效果。

综上所述,前馈神经网络在农作物病害检测中可通过不断优化权重,提高检测的准确性和可靠性。通过合理应用和改进模型结构,该网络将在农作物病害检测中发挥独特优势,提高检测的准确性和效率。

3.2　循环神经网络(RNN)

循环神经网络(Recurrent Neural Network,RNN)是一类用于处理序列数据的神经网络架构,网络具有循环连接能力,能够捕捉输入数据之间的时间依赖性。在农作物病害检测中,RNN可以通过分析时间序列数据(如环境数据、作物生长数据等),提供更精准的病害预测和检测。如Nandhini等[51]提出了一种名为G-RecConNN的模型,该模型将图像作为部分或整体,结合RNN和CNN来检测早期的香蕉树病害。来纯晓等[52]将循环神经网络和卷积神经网络相结合对小麦抗寒性进行预测,试验采用SMOTE技术以均衡样本,模型准确率可达73.28%,Kappa系数为0.595 6。Chawla等[53]通过将MobileNet与LSTM、BiLSTM和GRU等RNN架构相集成,捕获秋葵黄脉花叶图像中的时间依赖关系和顺序模式,结果表明,

MobileNet模型与所有3个RNN相结合,其准确率可达到99.27%。Chaitanya等[54]使用RNN和DNN组成的混合深度神经网络与递归神经网络(HDNN-RNN)来检测植物病害,并对HDNN-RNN进行参数优化,模型获得了96.47%的精度和准确率。

以上研究表明,循环神经网络使用LSTM和GRU,可以有效解决长时间序列数据的处理问题,提供准确的病害预测和检测结果。在智能农业、精准农业等领域,RNN将为农作物病害防控提供强有力的技术支持。

3.3 生成对抗网络(GAN)

生成对抗网络(Generative Adversarial Network, GAN)是一类由Ian Goodfellow等人提出的深度学习模型,旨在通过生成高质量的合成数据来增强模型的训练数据集,从而提高病害检测的性能。网络由生成器(Generator)和判别器(Discriminator)2部分组成,这2个网络相互对抗,通过博弈论的思想来进行训练。Tao等[55]通过附加1个分类器C来构造半监督学习方法(GANC),模型可生成与真实疾病图像数据分布相似的新的无标记图像,并在预测集中获得84.06%的准确率。Zhang等[56]通过将GAN模型添加到注意力提取模块中来建立Tranvolution架构,并与CNN合并,模型精密度可达51.7%、召回率为48.1%。Li等[57]使用辅助分类器生成对抗网络(ACGAN)和迁移学习的方法来对复杂背景下农田玉米叶病进行检测,准确率高达98.84%。Haruna等[58]利用风格生成对抗网络自适应判别器增强(SG2-ADA)和拉普拉斯滤波方法来合成水稻叶病数据,并结合增强快速RCNN和SSD来检测水稻叶病,精确度可达49%,召回率为14%。

以上研究通过改进GAN架构和训练方法,可以在实际应用中克服其训练不稳定和计算成本高等问题,充分发挥其数据增强和图像生成的优势,提高检测的全面性、准确性和鲁棒性,为智能农业和精准农业的发展提供有力支持。未来可将GAN与半监督学习、多模态数据相结合,从而实现对病害的实时检测与跨区域检测。总体而言,生成对抗网络在农作物病害检测方面有着巨大的潜力,可以通过多种方式提高检测的准确性、效率和实时性,从而在农业生产中发挥重要作用。

3.4 长短时记忆网络(LSTM)

长短时记忆网络(Long Short-Term Memory, LSTM)是一种改进的循环神经网络,专门用于处理具有时间序列的数据任务,比如文本翻译、文本转语音等。LSTM有效捕捉时间序列数据中的长短期依赖关系,进而对病害进行预测和检测,因此被广泛应用于时间序列预测、自然语言处理和语音识别等领域。如陈智超等[59]采用双向长短期记忆网络提出了一种Bi-LSTM和多尺度卷积神经网络相结合的番茄病害检测模型,该模型可以更好地捕捉双向信息的反馈,使上下文信息更具有连续性,试验结果在验证集上准确率可达98.16%。类似的,Patil等[60]通过优化CNN和LSTM模型,提出了一种基于混合分类器的高效深度学习方法来对番茄作物叶片病害进行检测,模型在学习百分比(LP)中获得的结果为90%,远远优于其它LP获得的结果。徐胜勇等[61]基于Self-Attention-BiLSTM网络,构建了一种图谱特征融合的氮磷钾含量检测方法,结果表明,西瓜苗氮磷钾的R^2分别为0.961、0.954、0.958,实现了很好的建模效果。Maginga等[62]利用卷积神经网络和长短期记忆模型,设计了CNN-LSTM混合模型用于玉米病害的实时检测,试验表明,模型在识别超声发射异常方面准确率可达99.98%。

以上研究表明,在农作物病害检测中,使用LSTM可进行实时数据分析。在未来的研究中,通过合理应用和改进网络模型,可提高检测的准确性和鲁棒性,为智能农业和精准农业的发展提供有力支持。

3.5 自编码器

自编码器(Autoencoder)通过编码器和解码器结构实现特征提取和降维,常用于数据降噪和异常检测。模型能够去除冗余信息,对农作物病害图像进行降噪处理,从而提升图像质量和检测准确性。如Bedi等[63]提出了一种基于卷积自动编码器网络和卷积神经网络的植物病害自动检测混合模型,该模型被应用于利用叶片图像检测桃树中存在的细菌性斑点病,达到了99.35%的训练准确率和98.38%的测试准确率。林芬芳等[64]采用堆栈稀疏自编码器提取小麦赤霉病的光谱特征,并结合Softmax分类器和偏最小二乘回归方法构建严重度判别和预测模型,试验结果表明,双层

SSAE模型均方误差更低且各个病害等级的特征差异明显。Cui等[65]采用离散小波变换对图像进行初步降维,在编码器中分别从空间和通道2个方向推导特征图,然后将其压缩到潜在空间进行分类,模型对玉米病害的平均准确率可达99.44%,训练时间为123 s。Agrawal等[66]将栈式自编码器和ResNet50网络级联,提出了一种新的用于水稻病害自动化检测的混合模型,模型准确率可高达97%。

以上研究表明,在农作物病害检测中,自编码器能够用于图像数据的降维、特征提取、数据生成以及异常检测等。通过合理应用和改进自编码器技术,可以在农作物病害检测中充分发挥其优势,提升图像质量和特征提取效果,为智能农业和精准农业的发展提供技术支持。

3.6　对比与总结

本文对经典神经网络模型的优缺点进行了简单对比,结果如表2所示。

表2　经典神经网络模型的优缺点对比结果

Table 2　Comparative results of advantages and disadvantages of classical neural network models

方法 Methods	优点 Advantages	缺点 Disadvantages
卷积神经网络(CNN)	自动学习特征,特征提取能力强,参数共享,空间不变性,实时检测,大规模图像数据,准确率高,鲁棒性强。	需要大量标注的数据集,计算资源需求高,易出现过拟合,缺乏时序信息处理能力,解释性差,时间序列数据处理较差,病害检测细微变化的敏感度较低。
前馈神经网络(FNN)	结构简单,易于实现和训练,自动化程度高,支持多种数据类型,准确率高,易扩展。	训练时间长,数据需求量大,易出现过拟合,缺乏时序信息处理能力,易受环境和图像影响。
循环神经网络(RNN)	可处理时间序列数据,动态信息整合能力强,适用于多种传感器的连续数据输入。	计算复杂度高,易出现梯度消失和梯度爆炸,数据需求量大,模型调参难度高,易出现过拟合。
生成对抗网络(GAN)	提取高维特征,少样本学习,模型鲁棒性较高。	训练难度大,计算资源需求高,模型复杂,不适用于所有病害类型。
长短时记忆网络(LSTM)	可处理复杂时间序列数据,具有记忆和遗忘机制,较强的鲁棒性,梯度稳定,训练过程高效,适应性强,多模态数据融合,动态信息处理。	训练时间长,模型复杂度高,数据需求量大,参数调优困难,计算资源需求高,易过拟合。
自编码器(Autoencoder)	提取高维特征,可用于异常检测,图像降噪,数据重建,适用于无监督学习。	训练复杂性高,易过拟合,数据需求量大,解释性差,有限的判别能力。

4　热点研究分析

4.1　小样本学习

卷积神经网络在处理大规模数据集时表现出色,但在小样本学习(Few-shot Learning, FSL)场景中,如何有效利用有限的作物病害数据进行准确学习成为了一个挑战。目前,在农作物病害检测中,由于数据采集成本高、病害种类繁多,往往难以获得大量的标注数据[67]。针对农作物病害的小样本学习,研究者们采用了多种策略和技术来提高模型的检测精度,主要有生成对抗网络、算法改进、数据增强、迁移学习和多模态信息融合等技术。其中,基于迁移学习的农作物病害检测效果较好,可直接在ImageNet上预训练网络,然后利用迁移学习来实现小样本下的网络训练。Hu等[68]使用数据增强和迁移学习建立卷积神经网络模型,优化后的模型对玉米病害的平均识别准确率达到了97.6%。Xu等[69]提出了一种小样本学习的双分支多尺度关系网络,该模型有效融合了不同层次和多尺度的特征。Nayak等[70]提出了一种不使用任何对抗样本的鲁棒小样本学习,通过自蒸馏实现高层特征匹配,模型在投影梯度下降和最先进的自动攻击上分别获得了60.55%和62.05%的对抗准确率。Xu等[71]提出了一种名为COR相关引导的特征增强方法,利用基类的弱监督为新类生成改进的特征,使得小样本学习对支持数据的选择不太敏感。Walsh等[72]利用视觉转换器和掩膜自编码器,提出了一种新颖、完全自监督的小样本学习技术,可以实现对领域外的类进行识别。

研究表明,在农作物病害检测领域,卷积神经网络在小样本学习场景中具有强大的特征提取能

力和适应性,能够有效识别不同类型的病害特征。由于病害样本稀缺和类别不平衡等因素,CNN可能面临过拟合、缺乏泛化性和计算成本高等问题。卷积神经网络在小样本学习农作物病害识别中展现出了潜力。通过迁移学习、有效的特征提取与分类器设计、数据增强和正则化技术的结合,可以在有限的数据集上实现准确的农作物病害检测。未来的研究可以进一步探索如何提高模型的泛化能力和实时性能,以便更好地适应实际的农业生产环境。

4.2 小目标检测

实际农业生产中,农作物病害的特征(如斑点、叶片变色、纹理差异等)往往不明显,相比于整个图像,目标的占比非常低且农作物病害图像数据集存在样本分布不均的问题,因此大多数模型仍然无法实现对小目标病害的精准检测。小目标在MSCOCO数据集中被定义为尺寸小于32*32像素的物体,因图像所占用的像素较少,随着网络层数增加,携带的有用信息也相对较少,在多次下采样后分辨率降低特征信息减弱,会出现小目标病害区域的检测效果不佳[73]。为了解决这一问题,研究者们采用了数据增强技术,如旋转、翻转、裁剪等,以扩充数据集并提高模型的泛化能力[74]。Fu等[75]使用YOLov4提取香蕉果实的深层特征,该模型可以准确检测出不同大小的香蕉,结果表明该模型表现出比YOLov3更好的检测速度和准确性。Zhao等[76]针对自然环境中草莓病害图像背景复杂、病斑小等特点,提出了一种新的Faster R_CNN架构,模型平均检测时间仅为229 ms。Lim等[77]提出了一种通过拼接多尺度特征的小目标检测方法,该方法有效提升了小目标检测在低分辨率场景下的准确率。Yang等[78]提出了一种名为QueryDet的小目标检测算法,该算法先使用低分辨率图计算目标的粗位置,然后通过稀疏引导在高分辨率特征图上计算精确结果。赵春江等[79]采用Prim最小生成树对番茄花束区域图像进行识别优先级排序,然后按序将其输入到改进的网络中,从而实现不同花期的精准辨识检测,试验结果表明,平均检测精度达到了82.79%,平均单张检测时间为12.54 ms。针对小目标学习中的样本不平衡问题,研究者们改进了损失函数。例如,焦点损失函数(Focal Loss)被用来减轻易分类样本对损失的贡献,从而使模型更加关注难分类的小目标病害样本[80],这种改进有助于提升模型在小目标学习任务中的性能。

研究表明,卷积神经网络在小目标学习农作物病害方面展现出了巨大的潜力和价值。通过数据增强、网络结构优化、损失函数改进等策略,模型能够更有效地识别和分类农作物病害,为农业生产提供了有力的技术支持。未来的研究将进一步推动这一领域的发展,以实现更精准、更智能的农业病害管理。

4.3 网络轻量化改进

实际农业生产中,模型部署在移动设备上,资源受限的问题尤为突出,如何保持检测精度的同时降低模型复杂度是一个挑战。卷积神经网络以其具有自动提取图像特征、泛化能力强、识别准确率高等特点被广泛应用于农作物病害检测方面[81]。为了实现对不同农作物病害的精准检测,学者们致力于对现有卷积神经网络结构进行轻量化设计。轻量化CNN模型的设计旨在减少模型的参数数量和计算复杂度,从而使得模型能够在计算资源受限的设备上高效运行。轻量化CNN模型的设计通常遵循以下原则:减少参数数量、提高计算效率和保持识别精度。Ding等[82]使用增加CBAM模块和随机裁剪分支分别对ResNet18网络进行改进,模型对苹果叶病分类准确率达到了95.2%、97.2%。Radosavovic等[83]利用网络搜索技术,提出了RegNet网络模型,模型搭配不同步长的卷积层,实现了在图像分类上的更高性能。Li等[84]提出了一种基于深度学习的自定义视频检测模型,可在视频中对病害进行实时检测,改进后模型的准确率更高,效果更好。Rashid等[85]利用卷积神经网络对马铃薯叶片中的病害进行早、中、晚分类,模型有效预防了马铃薯叶片病害的大规模爆发。Paymode等[86]对葡萄和番茄叶片图像进行增强并对VGG模型设置超参数,改进后模型准确率分别为98.4%和95.7%。Tang等[87]将轻量化网络ShuffleNet用于诊断葡萄病害,取得了99.14%的准确率。Zhang等[88]提出了一种基于空洞卷积的残差网络来识别6类害虫,该网络通过引入空洞卷积来进一步提高残差网络的感受野。

研究表明,通过精心设计的网络结构和优化算法,轻量化模型能够在保持高识别精度的同时,

实现在资源受限设备上的高效运行。未来的研究可以进一步探索如何结合更先进的网络结构和优化技术,以实现更轻量、更高效、更准确的农作物病害检测模型。

5　挑战和展望

尽管卷积神经网络在农作物病害无损检测领域取得了显著进展,但仍面临着一些挑战,如数据标注困难、模型泛化能力不足、小样本小目标数据集识别精度低等。未来,需要进一步努力解决这些挑战,推动卷积神经网络在农作物病害无损检测领域的进一步应用和发展。具体而言,可以从以下几个方面进行探讨:

数据集和标注:建立更大规模、更多样化、高质量、开放的农作物病害数据集。规范农作物病害图像数据库,利用机器学习和众包的方法进行自动化标注来提高标注的一致性。通过与迁移学习相结合来提高模型的泛化能力和检测准确度。加强农业、计算机科学等多领域的协作研究,推动技术创新和应用,促进多学科合作。

病害症状多样性:不同类型的病害可能表现出相似的症状,使得图像特征会有雷同现象。同一种病害在不同生长阶段也会有不同的症状,需要模型能够准确检测出这些变化。农作物发病早期病害特征不明显且会受到多种病毒的感染,导致症状复杂,这些都会影响模型的学习能力。通过采用多尺度特征提取技术、大规模数据进行训练、多任务学习、数据预处理技术等,卷积神经网络能够更好地应对农作物病害检测中症状多样性带来的挑战。

环境因素的干扰:温度、湿度、光照等自然环境可能会影响作物的生长状态,导致正常植株与病害植株在外观上差异不大,这给病害检测带来了挑战。农田环境中可能有杂草、土壤、其它农作物或杂物的干扰,这些背景信息都会影响模型的判断能力。通过数据预处理、多光谱或高光谱技术、领域自适应技术、多模态信息融合等技术,可以帮助模型更好地应对这些环境变化,提升病害检测的鲁棒性和准确性。

拍摄设备的限制:无人机、手机、摄像机等不同设备拍摄的图像在分辨率、色彩、噪声等方面可能存在显著差异。不同的拍摄角度、距离的远近也会导致作物病害特征表现不同。通过旋转、缩放、色彩调整等数据增强技术模拟各种外部因素,使模型对不同角度、不同背景的图像更具鲁棒性。

模型优化:探索新的网络架构、损失函数和训练方法,提高卷积神经网络在农作物病害检测中的性能表现,优化小样本、小目标数据集下的网络模型结构。例如通过迁移学习、数据增强等技术来改善模型的训练效果。

算法改进:提高算法对小样本、小目标数据集的检测精度,建立基于小病斑的农作物病害检测算法和基于小算力边缘平台的实时病害检测算法,减少数据依赖性,降低对计算资源的需求量,减少冗余,提高算法精度。

实时应用:将卷积神经网络技术与无人机、机器人、智能农机等现代农业工具结合,提高其在移动应用端、嵌入式设备上的检测精度。利用GPU、TPU等硬件加速器,提高模型的推理速度和效率,高效定位病害区域并进行严重程度评估,实现实际环境中农作物病害无损检测的实时监测与预警,从而提高农业生产的效率和质量。如通过剪枝、量化和蒸馏等方法对模型进行压缩和加速,以满足实时检测的需求。

多模态信息融合:研究如何将多种信息源(如图像、光谱、温度等)融合到卷积神经网络中。利用深度学习模型进行深度数据融合,引入注意力机制优化融合算法,提高病害检测的准确性、鲁棒性,使模型更适用于不同环境条件下的农作物病害识别,提高农业生产效率,优化农业资源配置。

可解释性和可迁移性:进一步研究卷积神经网络模型的可解释性,使其能够解释农作物病害检测的决策过程,增强模型的可信度和可靠性。同时,提高模型的可迁移性,使其能够适应不同地区、不同作物的病害检测需求。

通过不懈努力和持续探索,卷积神经网络在农作物病害无损检测领域将会发挥越来越重要的作用,为实现农业智能化、精准化提供有力支持,促进农业可持续发展和粮食安全保障。

6　结语

综上所述,卷积神经网络在农作物病害检测

领域已经取得了显著的进展,但仍需面对和解决一系列挑战。未来的研究需继续优化模型结构,构建更高质量的数据集,提高模型的泛化能力和迁移能力,并探索新的技术和方法,以实现更准确、更高效的农作物病害检测。

参 考 文 献

[1]Carlson G A. A decision theoretic approach to crop disease prediction and control [J]. American Journal of Agricultural Economics, 1970, 52(2): 216-223.

[2]Al H H, Bani A S, Reyalat M, et al. Fast and accurate detection and classification of plant diseases [J]. International Journal of Computer Applications, 2011, 17(1): 31-38.

[3]乔世成,田有文,何宽,等.水果病虫害无损检测技术研究进展[J].食品科学,2019,40(11):227-234.
Qiao S C, Tian Y W, He K, et al. Recent progress in technologies for non-destructive detection of fruit diseases and pests[J]. Food Science, 2019, 40(11): 227-234.

[4]Zhang X H, Qiao Y, Meng F F, et al. Identification of maize leaf diseases using improved deep convolutional neural networks [J]. IEEE Access, 2018, 6: 30370-30377.

[5]Wan X K, Jin Z Y, Wu H B, et al. Heartbeat classification algorithm based on one-dimensional convolution neural network [J]. Journal of Mechanics in Medicine and Biology, 2020, 20(7): 2050046.

[6]Gao W W, Li X F, Wang Y W, et al. Medical image segmentation algorithm for three-dimensional multimodal using deep reinforcement learning and big data analytics[J]. Frontiers in Public Health, 2022, 10: 879639-879639.

[7]Sergio Rodrigues P, Wachs Lopes G, Morello Santos R, et al. A q-extension of sigmoid functions and the application for enhancement of ultrasound images[J]. Entropy, 2019, 21(4): 430-430.

[8]Li Y N. Performance evaluation of Tanh and AWBM rainfall-runoff models [J]. IOP Conference Series: Earth and Environmental Science, 2021, 768(1): 012048.

[9]Nair V, Hinton G E. Rectified linear units improve restricted boltzmann machines[C]//Proceedings of the 27th international conference on machine learning (ICML-10). 2010: 807-814.

[10]Scherer D, Müller A, Behnke S. Evaluation of pooling operations in convolutional architectures for object recognition [M]//Lecture Notes in Computer Science. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010: 92-101.

[11]Sainath T N, Kingsbury B, Mohamed A R, et al. Improvements to deep convolutional neural networks for LVCSR [C]//2013 IEEE workshop on automatic speech recognition and understanding. IEEE, 2013: 315-320.

[12]Guo X Q, Fan T J, Shu X. Tomato leaf diseases recognition based on improved multi-scale AlexNet[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(13): 162-169.

[13]Lü M J, Zhou G X, He M F, et al. Maize leaf disease identification based on feature enhancement and DMS-robust alexnet[J]. IEEE Access, 2020, 8: 57952-57966.

[14]李云昊,李仲贤,伏帅,等.基于AlexNet的栽培苜蓿病害识别[J].草业学报,2023,32(12):104-114.
Li Y H, Li Z X, Fu S, et al. Identification of cultivated alfalfa diseases based on AlexNet [J]. Acta Prataculturae Sinica, 2023, 32(12): 104-114.

[15]Verma S, Chug A, Singh A P. Impact of hyperparameter tuning on deep learning based estimation of disease severity in grape plant [M]//Advances in Intelligent Systems and Computing. Cham: Springer International Publishing, 2019: 161-171.

[16]Wagle S A, Harikrishnan R, Ali S H M, et al. Classification of plant leaves using new compact convolutional neural network models[J]. Plants, 2021, 11(1): 24-24.

[17]Sabri Elmitwally N, Tariq M, Adnan Khan M, et al. Rice leaves disease diagnose empowered with transfer learning [J]. Computer Systems Science and Engineering, 2022, 42(3): 1001-1014.

[18]Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [J]. Arxiv preprint arxiv: 1409.1556,2014.

[19]Yan Q, Yang B H, Wang W Y, et al. Apple leaf diseases recognition based on an improved convolutional neural network [J]. Sensors, 2020, 20(12): 3535.

[20]李淼,王敬贤,李华龙,等. 基于CNN和迁移学习的农作物病害识别方法研究[J]. 智慧农业,2019,1(3):46-55.
Li M, Wang J X, Li H L, et al. Method for identifying crop disease based on CNN and transfer learning [J]. Smart Agriculture, 2019, 1(3): 46-55.

[21]Wang G, Sun Y, Wang J X. Automatic image-based plant disease severity estimation using deep learning [J]. Computational Intelligence and Neuroscience, 2017, 2017: 2917536.

[22]Chew R, Rineer J, Beach R, et al. Deep neural networks and transfer learning for food crop identification in UAN images [J]. Drones, 2020, 4(1): 7.

[23]Qiu J, Lu X L, Wang X X, et al. Research on rice disease identification model based on migration learning in VGG network[J]. IOP Conference Series: Earth and Environmental Science, 2021, 680(1): 012087.

[24]He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2016: 770-778.

[25]何欣,李书琴,刘斌.基于多尺度残差神经网络的葡萄叶片病害识别[J].计算机工程,2021,47(5):285-291,300.
He X, Li S Q, Liu B. Identification of grape leaf diseases based on multi-scale residual neural network [J]. Computer Engineering, 2021, 47(5): 285-291, 300.

[26]Zhang K K, Wu Q F, Liu A W, et al. Can deep learning identify tomato leaf disease? [J]. Advances in Multimedia,

2018, 2018: 6710865.

[27]Xing S L, Lee M, Lee K K. Citrus pests and diseases recognition model using weakly dense connected convolution network[J]. Sensors, 2019, 19(14): 3195-3195.

[28]Wang G W, Wang J X, Yu H Y, et al. Research on identification of corn disease occurrence degree based on improved ResNeXt network [J]. International Journal of Pattern Recognition and Artificial Intelligence, 2022, 36(2): 2250005.

[29]Khan A I, Quadri S M K, Banday S. Deep learning for apple diseases: classification and identification [J]. International Journal of Computational Intelligence Studies, 2021, 10(1): 1.

[30]Zhang W W, Ma H M, Li X H, et al. Imperfect wheat grain recognition combined with an attention mechanism and residual network[J]. Applied Sciences, 2021, 11(11): 5139-5139.

[31]Mohanty S P, Hughes D P, Salathé M. Using deep learning for image-based plant disease detection[J]. Frontiers in Plant Science, 2016, 7: 1419.

[32]Fu Y S, Song J, Xie F X, et al. Circular fruit and vegetable classification based on optimized GoogLeNet [J]. IEEE Access, 2021, 9: 113599-113611.

[33]Yang L, Yu X Y, Zhang S P, et al. GoogLeNet based on residual network and attention mechanism identification of rice leaf diseases[J]. Computers and Electronics in Agriculture, 2023, 204: 107543.

[34]Afzaal H, Farooque A A, Schumann A W, et al. Detection of a potato disease (early blight) using artificial intelligence[J]. Remote Sensing, 2021, 13(3): 411-411.

[35]Howard A G, Zhu M L, Chen B, et al. Mobilenets: efficient convolutional neural networks for mobile vision applications [J]. Arxiv preprint arxiv: 1704.04861, 2017.

[36]Selvaraj M G, Vergara A, Ruiz H, et al. AI-powered banana diseases and pest detection [J]. Plant Methods, 2019, 15(1): 92.

[37]Elfatimi E, Eryigit R, Elfatimi L. Beans leaf diseases classification using MobileNet models [J]. IEEE Access, 2022, 10: 9471-9482.

[38]Chen J D, Zhang D F, Suzauddola M, et al. Identifying crop diseases using attention embedded MobileNet-V2 model[J]. Applied Soft Computing, 2021, 113: 107901.

[39]Li L L, Zhang S J, Wang B. Apple leaf disease identification with a small and imbalanced dataset based on lightweight convolutional networks[J]. Sensors, 2021, 22(1): 173.

[40]Bi C K, Wang J M, Duan Y L, et al. MobileNet based apple leaf diseases identification [J]. Mobile Networks and Applications, 2022, 27(1): 172-180.

[41]Singh P, Verma A, Alex J S R. Disease and pest infection detection in coconut tree through deep learning techniques[J]. Computers and Electronics in Agriculture, 2021, 182: 105986.

[42]Bi C G, Xu S Z, Hu N, et al. Identification method of corn leaf disease based on improved Mobilenetv3 model [J]. Agronomy, 2023, 13(2): 300-300.

[43]Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.

[44]Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.

[45]Xu Y L, Zhao B, Zhai Y T, et al. Maize diseases identification method based on multi-scale convolutional global pooling neural network[J]. IEEE Access, 2021, 9: 27959-27970.

[46]Pham T N, Tran L V, Dao S V T. Early disease classification of mango leaves using feed-forward neural network and hybrid metaheuristic feature selection[J]. IEEE Access, 2020, 8: 189960-189973.

[47]Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE, 2015: 1-9.

[48]黄林生,江静,黄文江,等.Sentinel-2影像和BP神经网络结合的小麦条锈病监测方法[J].农业工程学报,2019,35(17):178-185.

Huang L S, Jiang J, Huang W J, et al. Wheat yellow rust monitoring method based on Sentinel-2 image and BPNN model[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35(17): 178-185.

[49]黄亮,魏萱,陈子涵,等.基于优化SVM和BP神经网络检测双孢蘑菇早期病害[J].福建农林大学学报(自然科学版),2022,51(6):857-864.

Huang L, Wei X, Chen Z H, et al. Detection of early disease of Agaricus bisporus based on optimized SVM and BP neural network [J]. Journal of Fujian Agriculture and Forestry University (Natural Science Edition), 2022, 51(6): 857-864.

[50]邢瑜琪,周佳,黄卫利,等.基于BP神经网络的稻麦轮作区小麦赤霉病预测模型[J].西北农业学报,2023,32(11):1842-1848.

Xing Y Q, Zhou J, Huang W L, et al. Prediction model of Fusarium head blight in rice-wheat rotation area based on BP neural network [J]. Acta Agriculturae Boreali-occidentalis Sinica, 2023, 32(11): 1842-1848.

[51]Nandhini M, Kala K U, Thangadarshini M, et al. Deep Learning model of sequential image classifier for crop disease detection in plantain tree cultivation [J]. Computers and Electronics in Agriculture, 2022, 197: 106915.

[52]来纯晓,李艳翠.基于CNN-RNN的小麦抗寒性分类模型[J].东北农业科学,2023,48(04):117-121.

Lai C X, Li Y C. A CNN-RNN-based classification model for cold resistance in wheat[J]. Journal of Northeast Agricultural Sciences, 2023, 48(04): 117-121.

[53]Chawla T, Mittal S, Azad H K. MobileNet-GRU fusion for optimizing diagnosis of yellow vein mosaic virus[J]. Ecological Informatics, 2024, 81: 102548.

[54]Chaitanya K P, Posonia A M. Tuned weighted feature fusion with hybridized DNN-RNN framework for plant disease detection and classification[J]. International Journal of Remote Sensing, 2024, 45(5): 1608-1639.

[55]Tao W T, Ma J J, Shi J P, et al. Dual-strategy semi-

supervised learning method based on GAN for recognition of tomato leaf diseases [J]. International Journal of Remote Sensing, 2022, 43(13): 5025-5039.

[56]Zhang Y, Wa S Y, Zhang L X, et al. Automatic plant disease detection based on tranvolution detection network with GAN modules using leaf images [J]. Frontiers in Plant Science, 2022, 13: 875693.

[57]Li E L, Wang L W, Xie Q J, et al. A novel deep learning method for maize disease identification based on small sample-size and complex background datasets [J]. Ecological Informatics, 2023, 75: 102011.

[58]Haruna Y, Qin S Y, Mbyamm Kiki M J. An improved approach to detection of rice leaf disease with GAN-based data augmentation pipeline [J]. Applied Sciences, 2023, 13(3): 1346.

[59]陈智超,汪国强,李飞,等. 基于Bi-LSTM与多尺度神经网络模型的番茄病害识别[J]. 江苏农业科学,2023,51(15): 194-203.
Chen Z C, Wang G Q, Li F, et al. Tomato disease identification based on Bi-LSTM with multi-scale neural network model [J]. Jiangsu Agricultural Sciences, 2023, 51(15): 194-203.

[60]Patil M A, Manohar M. Plant leaf disease classification using optimal tuned hybrid LSTM-CNN model [J]. SN Computer Science, 2023, 4(6): 710.

[61]徐胜勇,刘政义,黄远,等.基于Self-Attention-BiLSTM网络的西瓜种苗叶片氮磷钾含量高光谱检测方法[J].农业机械学报,2024,55(08):243-252.
Xu S Y, Liu Z Y, Huang Y, et al. Research on hyperspectral nondestructive detection method of nitrogen, phosphorus and potassium content in watermelon seedling leaves based on Self-Attention-BiLSTM network [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(08): 243-252.

[62]Maginga T J, Masabo E, Bakunzibake P, et al. Using wavelet transform and hybrid CNN - LSTM models on VOC & ultrasound IoT sensor data for non-visual maize disease detection[J]. Heliyon, 2024, 10(4): e26647.

[63]Bedi P, Gole P. Plant disease detection using hybrid model based on convolutional autoencoder and convolutional neural network [J]. Artificial Intelligence in Agriculture, 2021, 5: 90-101.

[64]林芬芳,陈星宇,周维勋,等.基于堆栈稀疏自编码器的小麦赤霉病高光谱遥感检测[J].作物学报,2023,49(8):2275-2287.
Lin F F, Chen X Y, Zhou W X, et al. Hyperspectral remote sensing detection of Fusarium head blight in wheat based on the stacked sparse auto-encoder algorithm [J]. Acta Agronomica Sinica, 2023, 49(8): 2275-2287.

[65]Cui S D, Su Y L, Duan K B, et al. Maize leaf disease classification using CBAM and lightweight Autoencoder network [J]. Journal of Ambient Intelligence and Humanized Computing, 2023, 14(6): 7297-7307.

[66]Agrawal M, Agrawal S. A novel hybrid approach for rice plant disease detection based on stacked autoencoder and convolutional neural network model [J]. International Journal of Services, Economics and Management, 2023, 14(3): 321-344.

[67]陈冬梅,林佳,王海亮,等.基于多尺度数据集的虫害检测模型[J].农业工程学报,2024,40(5):196-206.
Chen D M, Lin J, Wang H L, et al. Pest detection model based on multi-scale dataset [J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40(5): 196-206.

[68]Hu R J, Zhang S, Wang P, et al. The identification of corn leaf diseases based on transfer learning and data augmentation [C]//Proceedings of the 2020 3rd International Conference on Computer Science and Software Engineering. Beijing China. ACM, 2020: 58-65.

[69]Xu C Y, Wang H, Zhang Y, et al. Dual-branch multi-scale relation networks with tutorial learning for few-shot learning [J]. Applied Sciences, 2024, 14(4): 1599.

[70]Nayak G K, Rawal R, Khatri I, et al. Robust few-shot learning without using any adversarial samples [J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 36(2): 2080-2090.

[71]Xu J, Pan X L, Wang J Q, et al. CORE: correlation-guided feature enhancement for few-shot image classification [J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 36(2): 3098-3110.

[72]Walsh R, Osman I, Abdelaziz O, et al. Fully self-supervised out-of-domain few-shot learning with masked autoencoders[J]. Journal of Imaging, 2024, 10(1): 23.

[73]公徐路,张淑娟.基于改进YOLOv5s的苹果叶片小目标病害轻量化检测方法[J].农业工程学报,2023,39(19):175-184.
Gong X L, Zhang S J. Lightweight detection of small target diseases in apple leaf using improved YOLOv5s [J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39(19): 175-184.

[74]孙丰刚,王云露,兰鹏,等.基于改进YOLOv5s和迁移学习的苹果果实病害识别方法[J].农业工程学报,2022,38(11): 171-179.
Sun F G, Wang Y L, Lan P, et al. Identification of apple fruit diseases using improved YOLOv5s and transfer learning [J]. Transactions of the Chinese Society of Agricultural Engineering, 2022, 38(11): 171-179.

[75]Fu L H, Duan J L, Zou X J, et al. Fast and accurate detection of banana fruits in complex background orchards [J]. IEEE Access, 2020, 8: 196835-196846.

[76]Zhao S Y, Liu J Z, Wu S. Multiple disease detection method for greenhouse-cultivated strawberry based on multiscale feature fusion Faster R_CNN [J]. Computers and Electronics in Agriculture, 2022, 199: 107176.

[77]Lim J S, Astrid M, Yoon H J, et al. Small object detection using context and attention[C]//2021 international Conference on Artificial intelligence in information and Communication (ICAIIC). IEEE, 2021: 181-186.

[78]Yang C, Huang Z H, Wang N Y. QueryDet: cascaded sparse query for accelerating high-resolution small object detection

[C]//Proceedings of the IEEE/CVF Conference on computer vision and pattern recognition. IEEE, 2022: 13668-13677.

[79]赵春江,文朝武,林森,等.基于级联卷积神经网络的番茄花期识别检测方法[J].农业工程学报,2020,36(24):143-152.
Zhao C J, Wen C W, Lin S, et al. Tomato florescence recognition and detection method based on cascaded neural network [J]. Transactions of the Chinese Society of Agricultural Engineering, 2020, 36(24): 143-152.

[80]杨明欣,张耀光,刘涛.基于卷积神经网络的玉米病害小样本识别研究[J].中国生态农业学报(中英文),2020,28(12):1924-1931.
Yang M X, Zhang Y G, Liu T. Corn disease recognition based on the Convolutional Neural Network with a small sampling size[J]. Chinese Journal of Eco-Agriculture, 2020, 28(12): 1924-1931.

[81]Babu D R K, Chaithanya M, Sandhya M, et al. Deep learning model for plant disease detection[J]. International Journal of Recent Technology and Engineering (IJRTE), 2020, 9(1): 750-754.

[82]Ding R R, Qiao Y L, Yang X H, et al. Improved ResNet based apple leaf diseases identification [J]. IFAC-PapersOnLine, 2022, 55(32): 78-82.

[83]Radosavovic I, Kosaraju R P, Girshick R, et al. Designing network design spaces[J]. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2020: 10425-10433.

[84]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.

[85]Rashid J, Khan I, Ali G, et al. Multi-level deep learning model for potato leaf disease recognition [J]. Electronics, 2021, 10(17): 2064-2064.

[86]Paymode A S, Malode V B. Transfer learning for multi-crop leaf disease image classification using convolutional neural network VGG[J]. Artificial Intelligence in Agriculture, 2022, 6: 23-33.

[87]Tang Z, Yang J L, Li Z, et al. Grape disease image classification based on lightweight convolution neural networks and channelwise attention[J]. Computers and Electronics in Agriculture, 2020, 178: 105735.

[88]Zhang Y Y, Zhong W B, Pan H. Identification of stored grain pests by modified residual network [J]. Computers and Electronics in Agriculture, 2021, 182: 105983.

(编辑:韩志强)