

方晓捷,严李强,张福豪,等. 基于深度学习的农作物图像识别的发展[J]. 江苏农业科学,2024,52(20):18-24.

doi:10.15889/j.issn.1002-1302.2024.20.003

基于深度学习的农作物图像识别的发展

方晓捷,严李强,张福豪,高心雨

(西藏大学信息科学技术学院,西藏拉萨 850000)

摘要:农作物图像识别是一项重要的农业技术,它能够通过分析农田中的图像数据来快速、准确地识别不同作物的生长状态和健康状况。随着深度学习技术的快速发展,基于深度学习的农作物图像识别研究取得了显著的进展。梳理近年来该领域的研究进展,总结不同深度学习模型在农作物图像识别任务中的应用。首先,回顾农作物图像识别技术的发展进程,从基于特征选择的传统方法到近年来基于深度学习的方法;其次,讨论神经网络、生成对抗网络、目标检测、知识蒸馏等深度学习算法在农作物图像识别中的应用,包括对不同农作物品种、病虫害和生长阶段的识别;最后,分析该领域存在的问题与挑战,并提出未来可探索的研究方向,进而为农业科技的进一步发展提供参考,促进农作物图像识别技术的应用和推广,推动我国农业生产的智能化和可持续发展。

关键词:深度学习;农作物图像识别;卷积神经网络;目标检测

中图分类号:S126;TP391.41 **文献标志码:**A **文章编号:**1002-1302(2024)20-0018-07

我国是世界上最大的农业国之一,拥有丰富的农作物资源。根据地理和气候条件的不同,各地域的农作物种植模式也不尽相同。在南方地区,水稻是主要的粮食作物;北方地区以小麦为主要粮食作物,油菜籽、大豆和玉米是主要的油料和饲料作物,棉花则是重要的纺织原料。此外,番茄、花生、甘蔗、葡萄、苹果等也得到广泛种植^[1]。我国农业不断发展创新,致力于提高农作物品质和产量,农业技术的应用和农作物图像识别等领域的研究也日益重要。随着农业科技的快速发展和农业生产的转型升级,农作物图像识别在智能农业领域扮演着越来越重要的角色。传统的农作物图像识别方法主要依赖于手工设计的特征提取和分类算法,这种方法的局限性和瓶颈逐渐显现出来^[2]。近年来,深度学习的兴起给农作物图像识别带来了突破性的改变。这些新技术不仅可以自动提取和学习图像中的特征,还具有优秀的分类性能,可以大幅提升农作物图像识别的精度和效率^[1-2]。本研究通过总结基于深度学习的农作物图像识别的发展,探讨其在解决农作物管理过程中实际问题的潜力和应用,

进而促进对农作物图像识别技术的深入理解,为未来的研究和应用提供指导和参考,推动智能农业的发展,并最终提高农业生产效益和可持续发展水平。

1 农作物图像识别的发展进程

20 世纪 80 年代,美国率先提出“精确农业”的构想,并在此后多年的实践中成为“精确农业”绩效最好的国家,这为“智慧农业”奠定了良好的发展基础^[3]。国内由于图像识别技术不够成熟,农作物图像识别一直处于较低水平。直到 2010 年左右,随着计算机视觉和深度学习等技术的快速发展,农作物图像识别开始成为一个热门研究领域,其通过分析和识别农作物图像,实现对农作物生长状态、病害检测和农田管理等方面的有效监测和诊断。

传统的机器视觉技术对农作物图像识别需要进行繁琐的预处理,不仅耗时长,还增加了建模工作量,识别效果不够精确。随着科技的发展,2006 年 Hinton 等提出“深度学习”的概念,并在之后的研究中逐步发展了基于深度学习的各种模型和算法^[4]。近年来,研究人员利用深度学习进行农作物图像识别,相较于之前的识别方法,可以直接将图像输入到网络中,自动逐层提取高级视觉特征,不仅更快速准确,还减少了人工设计特征产生的不完备性。随着网络结构的不断改进,在卷积神经网络的基础上,衍生出多种不同网络深度的卷积神经网络模型,如 GoogLeNet、VGGNet、Resnet、YOLO、Faster

收稿日期:2023-11-23

基金项目:中央引导地方科技发展资金(编号:XZ202101YD0014C)。

作者简介:方晓捷(1998—),女,安徽滁州人,硕士研究生,主要从事农作物图像识别研究。E-mail:fangxiaojie2021@163.com。

通信作者:严李强,硕士,教授,主要从事智能控制研究。E-mail:158201730@qq.com。

R-CNN 等,这些改进在目标检测、图像识别中具有较好的效果^[5]。

2 基于深度学习的图像识别技术

2.1 卷积神经网络

作为深度学习的代表算法之一,卷积神经网络(convolutional neural networks, CNN)是一类包含卷积计算且具有深度结构的前馈神经网络。CNN 的设计灵感来自于生物学中视觉皮层对视觉信息处

理的模拟。卷积神经网络的主要优势是利用卷积和池化操作的局部感知能力,减少参数数量,并通过共享权重提取平移不变的特征^[6]。这使得 CNN 在图像识别、语义分割等计算机视觉任务中具有良好的效果和广泛的应用。卷积神经网络主要由卷积层、池化层、分类输出层构成,它们分别负责提取图像的局部特征、降低特征维度、进行最终分类或预测^[7](图 1)。

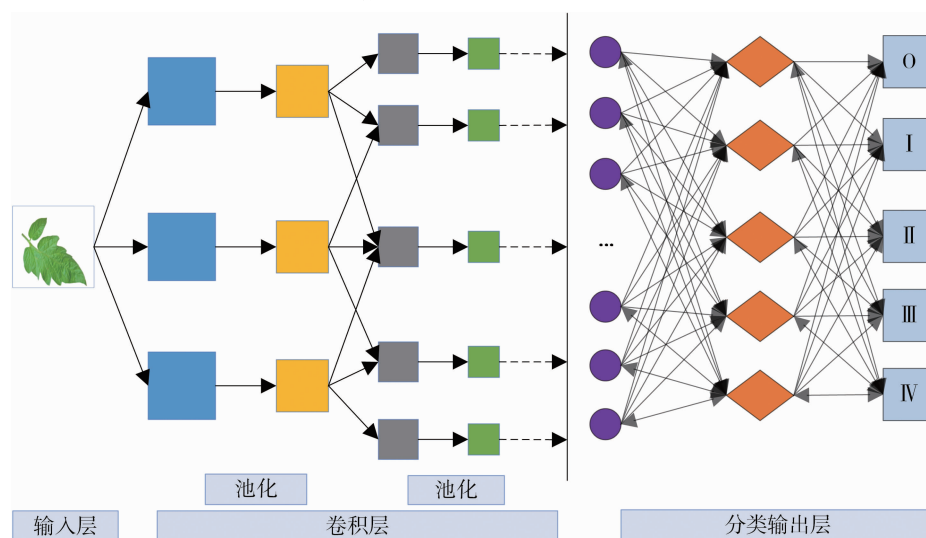


图1 卷积神经网络结构

在图像识别中常用的卷积神经网络模型有 LeNet、AlexNet、GoogLeNet、VGGNet、ResNet 等。郭小燕等采用 VGG16 作为嵌入单元提取虫害样本特征与类别特征,解决植物虫害小样本分类问题^[8];廖露等针对传统水稻病害分类方法效率低、准确度不高等问题,提出一种联合 VGG19 卷积神经网络和迁移学习模型的水稻病害图像分类方法,正确率达到 99% 以上^[9];Nandi 等使用 ResNet 对 14 个不同品种的植物叶片图像组成的数据集进行识别任务,准确率高达 99.53%^[10];李玉芳通过改造 GoogLeNet 的 Inception 模块,减少网络中的 Inception 模块数量,结果显示,改造后的分类网络在 9 分类的农作物病害分类中的精度达到 98.4%^[11]。

2.2 基于单双阶段的目标检测算法

在图像识别技术中,目标检测是一项重要任务,用于在图像中定位和分类出不同类别的目标物体。目标检测算法可以根据其基本思想和实现方式分为单阶段和双阶段目标检测算法^[1]。双阶段目标检测方法的提出主要是为了解决准确度的问题。在传统方法中,通常使用滑动窗口的方式进行

目标识别,但这种方法效率较低,且容易产生大量的冗余计算,双阶段方法通过引入候选框生成的策略,能够更准确地定位和分类目标,且具有较高的检测精度。但双阶段目标检测算法的速度相对较慢,并不适用于一些实时应用场景。因此,单阶段目标检测方法的提出是为了解决速度问题。单阶段目标检测方法通过在不同尺度的特征图上进行目标预测,可以在 1 次前向传递中同时完成检测任务,从而实现实时目标检测的需求,是端到端的过程^[12](表 1)。

2.2.1 双阶段目标检测 双阶段目标检测算法是指将目标检测问题拆分为 2 个阶段进行处理。第一阶段是目标建议生成,它生成一组候选目标框;第二阶段是目标框分类和细化,它对候选目标框进行分类和位置精修。双阶段目标检测算法通常具有更高的准确性,但计算代价也更高^[2]。其中几个常见的双阶段目标检测算法包括:R-CNN(region-based convolutional neural networks),它首先生成一组候选框,再通过卷积神经网络提取每个框中的特征,最后进行分类和边界框回归;FastR-CNN 通过

表 1 单双阶段目标检测的优缺点比较

算法属性	单阶段目标检测	双阶段目标检测
优点	①算法结构简单,实现和部署相对容易 ②处理速度较快,适用于实时应用和移动设备 ③能够快速捕捉到小型和移动的目标	①准确率较高,能够更好地定位和分类目标 ②对于复杂场景中的目标,具有更好的识别能力
缺点	①准确率较低,容易产生较高的误检率 ②对于复杂场景中的目标,定位和分类的精度相对较差	①算法结构相对复杂,实现和部署相对困难 ②处理速度较慢,不适合实时应用和资源受限环境 ③对于小型和移动的目标,识别效果相对较差

引入感兴趣区 RoI(region of interest)池化操作,将整个图像转化为特征图,可以提高目标检测的速度和准确性;Faster R - CNN 引入区域建议网络 RPN

(region proposal network),用于生成候选目标框,再通过共享卷积层提取特征并进行框的分类和精修(图 2)。

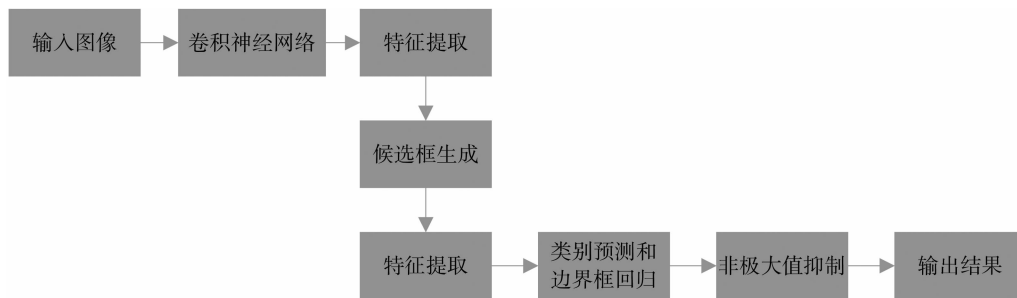


图2 双阶段目标检测流程

Widiyanto 等使用 Faster R - CNN 模型进行训练,可以通过番茄图像中的颜色来识别番茄成熟度,其检测平均精确度高达 98.7%^[13];岑霄对 Faster R - CNN 加以改进,提出融合空洞卷积和特征金字塔网络的 Faster R - CNN 模型来检测柑橘害虫类别,对比原模型,准确率提高至 91.72%^[14];刘闾宇等在基于 Faster R - CNN 检测结构的基础上,改进检测结构中区域建议网络,提高建议区域质量,该方法对自然条件下多姿态葡萄叶片检测精度更高^[15-17];刘亚恒利用 Faster R - CNN 模型并加以改进,骨干网络为 ResNet - 50,将特征金字塔网络与骨干网络相结合,搭建苹果叶部病害的检测模型^[18];赵越等认为,Faster R - CNN 和 VGG16 组合的结构对马铃薯叶片病害识别取得了较高的精度,检测精度高达 99.5%,明显优于 YOLO v3、YOLO v4 网络^[19]。

2.2.2 单阶段目标检测 单阶段目标检测算法是指直接从输入图像中预测目标位置和类别的算法。它将目标检测问题视为一个回归问题,并使用一个网络结构来直接回归目标的边界框和类别概率。单阶段目标检测算法一般具有简单、快速的特点^[2]。其中几个常见的单阶段目标检测算法包括:YOLO(you only look once)系列,它们通过将图像分

为不同的网格单元,每个单元预测目标的边界框和类别概率;SSD(single shot multi box detector)使用多尺度卷积特征图来预测不同大小的目标,通过在不同层级进行预测来提高检测的准确性;Retina Net 通过使用一种称为 Focal Loss 的损失函数来解决目标检测中类别不平衡的问题,可以提高小目标检测的精度(图 3)。

叶中华等采用 SSD 算法对自建数据集进行复杂背景下的作物病害检测,检测平均精度为 83.90%^[20];俞佩仕设计基于残差网络的水稻纹枯病病斑 SSD 检测算法,为了提高网络提取特征的能力,将 VGG16 网络替换为 ResNet50,实现了水稻纹枯病的病害检测,检测精度高达 81.2%^[21];李康顺等提出一种基于卷积注意力机制改进的 YOLOX - Nano 智能检测与识别模型,大大提高了病害检测的精度^[22];Agbulos 等利用 YOLO 算法成功识别水稻叶片是否患有褐斑病或叶瘟病^[23];Mohandas 等提出 YOLO v4 - tiny 模型,用于检测番茄、草莓、马铃薯、豆类和芒果的相关病害,精度高且耗时短^[24];公徐路等提出一种基于 YOLO v5s 的苹果叶片小目标病害轻量化检测方法,将 YOLO v5s 的骨干网络更改为 ShuffleNet v2 轻量化网络,引入 CBAM 注意力模块使模型关注苹果叶片小目标病害,提高苹果叶

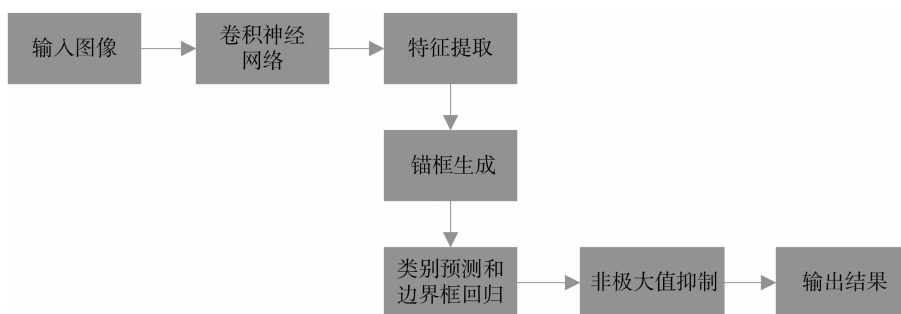


图3 单阶段目标检测流程

片病害检测精度,该方法对小目标的检测准确率提高了3百分点^[25]。

2.3 生成对抗网络

生成对抗网络 (generative adversarial network, GAN) 是一种深度学习模型,由生成器(generator)和判别器(discriminator)2个互相竞争的神经网络组成。生成器的目标是从随机噪声中生成与训练数据相似的新样本。它将随机噪声作为输入,并通过一系列的转换层逐渐生成逼真的样本图像。生成器的目标是尽可能地欺骗判别器,使其将生成器生成的样本误认为是真实的;判别器的任务是将生成

器生成的样本与真实样本区分开来。它接收生成器生成的样本和真实样本作为输入,并输出1个概率值来表示输入样本是真实样本的可能性。判别器的目标是有效识别生成器生成的假样本,并准确地区分真实样本和生成的样本^[26]。通过不断地竞争和训练,生成器逐渐提升生成样本的质量,而判别器则逐渐提高区分真实和生成样本的能力。当生成器和判别器达到平衡时,生成器可以生成与训练数据相似的逼真样本,且判别器无法准确区分真实和生成的样本^[27](图4)。

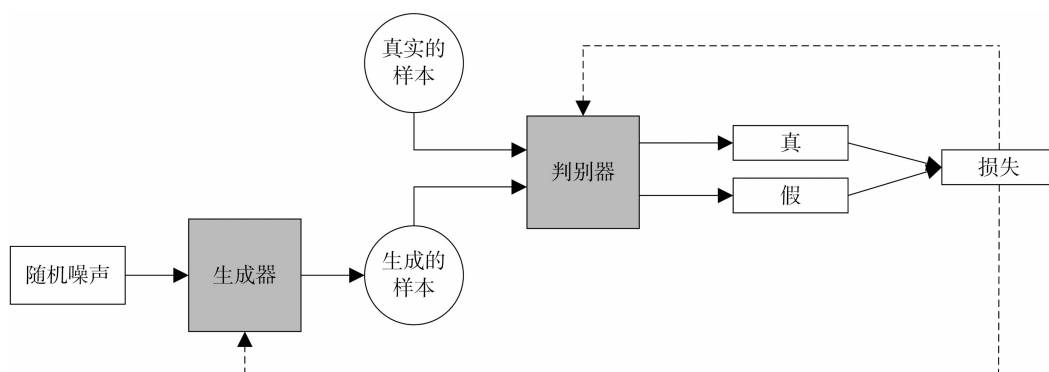


图4 生成对抗网络结构

Sharma 等针对没有广泛的数据集可用于训练模型问题,训练了3种算法,以手动收集的芒果叶数据集为输入创建1个全新的数据集,再将Wasserstein生成对抗网络(WGAN)、深度卷积生成对抗网络(DCGAN)以及生成对抗网络(GAN)等3种算法进行比较,以找到产生新数据集的最佳算法,结果表明,WGAN算法能得到最好的图像质量^[28];Kamohara等提出一种无监督学习方法的对抗性生成网络GANomaly,使用未标记的健康叶片图像作为训练数据,结果表明,该模型可以减少诊断的时间成本,且各评价指标都较好^[29];Ramadan等使用SRGAN作为一种水稻病害数据增强方法,获得新的数据集,且新创建的数据集在分类模型上准

确率高达94.30%^[30];陶贤鹏提出ViT-PWGAN-GP网络,生成模型利用ViT模块对目标样本的特征空间进行全局特征学习,并逐步提高生成图像的分辨率,结果表明,使用ViT-PWGAN-GP进行图像数据增强对VGG-16、GooLeNet、ResNet-50的水稻病害识别准确率分别提升15.3%、14.7%、14.3%^[31]。

2.4 迁移学习

迁移学习 (transfer learning) 是一种在图像识别技术中广泛应用的方法,它可以将一个任务中学到的知识迁移到另一个相关任务上,以提升性能并加快学习速度。迁移学习利用已经训练好的模型在新任务上进行初始化,然后通过微调模型的参数,

以适应新任务的特性^[32]。

迁移学习通常会有 1 个源域 D_s 、1 个学习任务 T_s 和 1 个目标域 D_t 、1 个学习任务 T_t ，其中源域用 $D_s = \{x_i, y_i\}_i^{N_s}$ 表示， x_i, y_i 分别表示数据样本和对应的类别标签，目标域用 $D_t = \{x_i, y_i\}_i^{N_t}$ 表示，迁移学习的目的就是获取源域 D_s 和学习任务 T_s 中的知识以帮助提升目标域中学习任务 T_t 的完成(图 5)。




图5 迁移学习过程示意

万军杰等探究迁移学习技术和 GoogLeNet 模型相结合的方法，针对果园病虫害样本的识别并对它们的危害程度进行分类研究，得到较高的准确率，平均识别精度达到 99.35%^[33]；Arshad 等为提高植

物叶片病害的检测率，利用 ResNet50 和迁移学习识别马铃薯、番茄和玉米的病害，准确率达到 98.93%^[34]；Song 等针对苹果树病害图像数据集样本量较小的问题，采用迁移学习的思想对网络模型训练过程进行升级，进一步提高了果树病害图像的分类精度^[35]；王大庆等为解决域迁移和过拟合问题，提出一种两阶段迁移学习训练方法，使得玉米叶部病害识别准确率大大提高^[36]；邓朋飞等以提高玉米病害图像的准确率、降低网络参数和模型大小为目的，提出一种结合迁移学习和模型压缩的卷积神经网络用于玉米病害识别，通过迁移学习，平均识别准确率达到 93.38%^[37]。

2.5 知识蒸馏

知识蒸馏(knowledge distillation)是一种常用的图像识别技术，它通过将一个大型、复杂的模型(教师模型)的知识转移给一个较小、简单的模型(学生模型)，以此提升学生模型的性能。知识蒸馏的基本思想是：通过教师模型的输出概率分布，引导学生模型更好地学习，以提高性能。教师模型通常是一个预训练好的复杂模型，可以是一个深层的卷积神经网络。而学生模型是一个较浅的模型，可以是一个浅层的卷积神经网络^[38](图 6)。

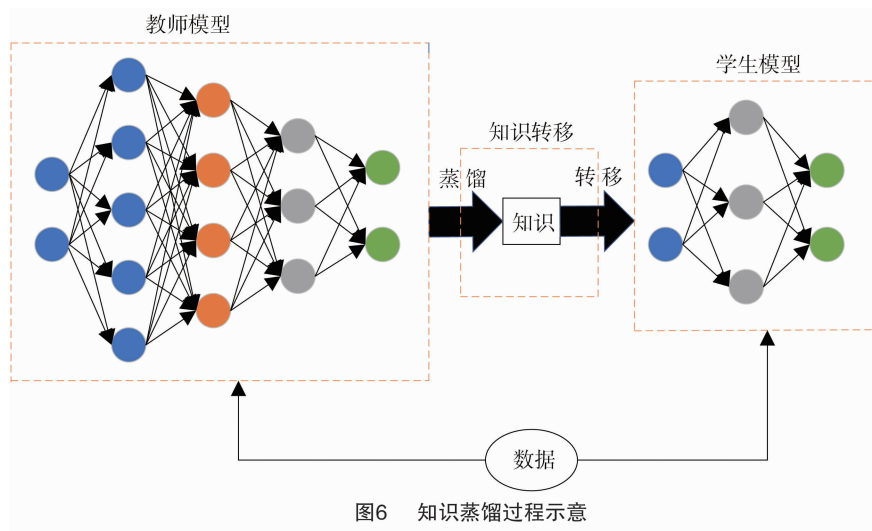


图6 知识蒸馏过程示意

李庆盛提出一种通过知识蒸馏和生成对抗网络相结合的番茄病害图像识别方法，通过生成对抗网络缓解深度学习中数据量不足的问题，并通过知识蒸馏进行模型压缩^[39]；李若曦针对模型轻量化问题，提出一种基于多层次特征迁移和知识蒸馏的病害识别方法，通过中间层和深层知识蒸馏提升预测分类准确率^[40]；Wei 等为了进一步提高模型的准确性，提出一种改进的基于温度衰减的知识蒸馏方

法，在不增加模型参数和计算量的前提下，提高花卉分类的准确率，使其高达 98.76%^[41]；刘媛媛等针对卷积神经网络参数过多，在嵌入式设备上部署具有挑战的问题，提出基于知识蒸馏和模型剪枝的轻量化模型植物病害识别，以 ResNet 为骨干网络，最终模型准确率达到 97.78%，且模型能够移植到 Android 平台上并有效运行^[38]；温钊发等以大田复杂背景为前提，提出一种基于知识蒸馏与 EssNet 的

病害识别方法,实现了病害的高效识别,准确率达到 95.21%,且易于搭载至移动端^[42]。

3 存在的问题

综上所述,针对农作物图像识别问题,各种深度学习模型在试验中均取得了可观的识别准确率。然而,这些模型真正运用在农业生产实践中却面临着以下几个方面的问题。

3.1 样本数据量不足

深度学习方法在农作物图像识别中的应用导致对训练数据量的需求激增。尽管存在一些公开的大型数据集如 Plant Village^[43],但这些数据集的图像多拍摄于受控的实验室环境,样本较简单,无法准确识别实际环境中的各种病害。在实际环境下采集高质量病害样本非常困难,因为病害发生具有随机性,且不同类型病害在不同生长阶段、不同地区表现出的特征均不相同。此外,实验室采集的图片虽然理想,但实际环境下的样本背景复杂,包含土壤、污垢、昆虫等干扰信息,影响模型的分析效果,导致模型在实际应用中的普适性和泛化能力较差^[44]。不同类型病虫害的症状相似性也增加了数据标注的难度,易发生错误标注,从而影响模型的准确性。目前仍然缺乏大规模、多种类、多类型的公开数据库,建立全面且多样性强的实际环境下的数据集需要投入大量人力物力进行监测和拍摄,这是目前深度学习训练面临的重要问题。

3.2 模型性能问题

为了能够捕捉不同病害之间的细微差异,从而提升模型在病害识别中的准确率,通常采用的方法是使用更深层次的卷积神经网络。深层网络具有更多的卷积层,这使得模型能够提取图像中更为抽象和语义更丰富的特征,从而提高对复杂病害的识别精度。例如,更深的网络能够识别更细微的纹理和形状差异,进而更准确地区分相似的病害^[45]。然而,这种方法也带来了显著的挑战。首先,深层网络的计算和训练成本非常高,这不仅需要大量的计算资源,还需要较长的训练时间;其次,深层网络的计算需求往往超出了手持移动设备的处理能力,使得在这些设备上实现实时病害检测变得困难^[46-47]。实时检测要求模型能够迅速处理图像数据并给出结果,但深层网络由于其复杂性,可能导致处理速度变慢,影响应用的实用性和用户体验。因此,如何在提升模型性能和保持实时性之间找到合理的

平衡,将是亟待解决的关键问题。

4 结论与展望

4.1 结论

本研究系统阐述了基于深度学习的农作物图像识别的研究发展。首先介绍农作物图像识别技术的发展进程,再介绍基于深度学习的图像识别的新技术,如 YOLO 系列、生成对抗网络等。综合上述内容,农作物图像识别在传统方法的基础上,通过引入深度学习取得了显著的进展,新型算法的应用使得农作物图像识别能够更准确、更高效地监测不同农作物的生长状态和健康状况。但尽管取得了许多成果,农作物图像识别仍然面临着一些问题与挑战,如数据集的标注困难、模型的泛化能力不足等。因此,今后的研究需要更加关注这些问题,不断改进农作物图像识别技术的可靠性和实用性。

4.2 展望

大规模、高质量的农作物图像数据集是农作物图像识别研究的基础。因此,未来应该积极推动数据集的建立和标注工作,特别是针对农作物生长不同阶段和各种生态环境的数据集。未来的研究可以致力于进一步优化农作物图像识别的深度学习模型,通过改进网络结构、损失函数和训练策略等来提升识别的准确性和鲁棒性。

参考文献:

- [1] 郭文娟,冯全,李相周. 基于农作物病害检测与识别的卷积神经网络模型研究进展[J]. 中国农机化学报, 2022, 43(10): 157-166.
- [2] 何潇. 基于深度学习的西瓜叶片病害识别与检测方法研究[D]. 长沙:湖南农业大学, 2021.
- [3] 美国发展“智慧农业”的做法及启示[EB/OL]. (2021-06-26) [2023-11-18]. https://www.sohu.com/na/474158734_121123754.
- [4] 陈桢. 基于深度学习的农作物病害分类算法研究[D]. 济南:齐鲁工业大学, 2022.
- [5] 何雨霜,王琢,王湘平,等. 深度学习在农作物病害图像识别中的研究进展[J]. 中国农机化学报, 2023, 44(2): 148-155.
- [6] 魏花. 基于卷积神经网络的细粒度图像识别关键技术分析与研究[D]. 长春:中国科学院大学(中国科学院长春光学精密机械与物理研究所), 2021.
- [7] 贺晋. 基于卷积神经网络的三种粒度的图像识别模型研究[D]. 北京:北京邮电大学, 2021.
- [8] 郭小燕,尚皓玺. 基于元学习的植物虫害识别原型网络 VGG-ML[J]. 南京农业大学学报, 2024, 47(2): 392-401.
- [9] 廖露,韩春峰,何纯樱. 基于 VGG19 卷积神经网络和迁移学习的水稻病害图像分类方法[J]. 测绘, 2023, 46(4): 153-

- 157,181.
- [10] Nandi A, Yadav S, Jaiswal Y. Crop disease recognition and diagnosis using Residual Neural Network [C]//2022 International Conference on Advancements in Smart, Secure and Intelligent Computing. Bhubaneswar; IEEE, 2022; 1–6.
- [11] 李玉芳. 基于简化 GoogLeNet 的农作物叶片病害识别系统设计与实现[J]. 信息与电脑(理论版), 2023, 35(9): 179–181.
- [12] 朱东郡. 面向复杂场景图像的目标检测与识别方法研究[D]. 徐州: 中国矿业大学, 2022.
- [13] Widiyanto S, Wardani D T, Wisnu P S. Image – based tomato maturity classification and detection using faster R – CNN method [C]//5th International Symposium on Multidisciplinary Studies and Innovative Technologies. Ankara; IEEE, 2021; 130–134.
- [14] 岑 霄. 融合空洞卷积和特征金字塔的 Faster R – CNN 柑橘害虫检测方法[J]. 中国农学通报, 2023, 39(22): 158–164.
- [15] 刘圆宇, 冯 全, 杨 森. 基于卷积神经网络的葡萄叶片病害检测方法[J]. 东北农业大学学报, 2018, 49(3): 73–83.
- [16] 刘圆宇, 冯 全. 基于卷积神经网络的葡萄叶片检测[J]. 西北大学学报(自然科学版), 2017, 47(4): 505–512.
- [17] 刘圆宇. 基于卷积神经网络的葡萄叶片病害检测方法研究[D]. 兰州: 甘肃农业大学, 2018.
- [18] 刘亚恒. 基于改进 Faster R – CNN 苹果叶部病害检测方法研究[D]. 汉中: 陕西理工大学, 2022.
- [19] 赵 越, 赵 辉, 姜永成, 等. 基于深度学习的马铃薯叶片病害检测方法[J]. 中国农机化学报, 2022, 43(10): 183–189.
- [20] 叶中华, 赵明霞, 贾 璐. 复杂背景农作物病害图像识别研究[J]. 农业机械学报, 2021, 52(增刊1): 118–124, 147.
- [21] 俞佩仕. 水稻茎基部病害图像智能采集与病斑检测系统的设计与实现[D]. 杭州: 浙江理工大学, 2019.
- [22] 李康顺, 杨振盛, 江梓锋, 等. 基于改进 YOLOX – Nano 的农作物叶片病害检测与识别方法[J]. 华南农业大学学报, 2023, 44(4): 593–603.
- [23] Agbulos M K, Sarmiento Y, Villaverde J. Identification of leaf blast and brown spot diseases on rice leaf with YOLO algorithm [C]//7th International Conference on Control Science and Systems Engineering. Qingdao; IEEE, 2021; 307–312.
- [24] Mohandas A, Anjali M S, Rahul Varma U. Real – time detection and identification of plant leaf diseases using YOLO v4 – tiny [C]//12th International Conference on Computing Communication and Networking Technologies. Kharagpur; IEEE, 2021; 1–5.
- [25] 公徐路, 张淑娟. 基于改进 YOLO v5s 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.
- [26] 施扬明. 基于生成对抗网络的弱光图像增强算法研究[D]. 合肥: 中国科学技术大学, 2022.
- [27] 胡潇菡. 基于生成对抗网络的弱监督图像语义分割方法研究[D]. 西安: 西安电子科技大学, 2020.
- [28] Sharma A, Kaur H, Prashar D. Generative adversarial networks based approach for data augmentation in mango leaf disease detection system [C]//12th International Conference on Communication Systems and Network Technologies. Bhopal; IEEE, 2023; 816–821.
- [29] Kamohara Y, Sakuma T, Kato S. Plant disease detection with generative adversarial networks for assisting extension workers [C]//11th Global Conference on Consumer Electronics. Osaka; IEEE, 2022; 840–841.
- [30] Ramadan S T Y, Sakib T, Ul Haque M M, et al. Generative adversarial network – based augmented rice leaf disease detection using deep learning [C]//25th International Conference on Computer and Information Technology. Cox's Bazar; IEEE, 2022; 976–981.
- [31] 陶贤鹏. 基于 WGAN – GP 的水稻图像数据增强方法研究[D]. 大庆: 黑龙江八一农垦大学, 2023.
- [32] 余 胜, 谢 莉. 基于迁移学习和卷积视觉转换器的农作物病害识别研究[J]. 中国农机化学报, 2023, 44(8): 191–197.
- [33] 万军杰, 祁力钧, 卢中奥, 等. 基于迁移学习的 GoogLeNet 果园病虫害识别与分级[J]. 中国农业大学学报, 2021, 26(11): 209–221.
- [34] Arshad M S, Rehman U A, Fraz M M. Plant disease identification using transfer learning [C]//2021 International Conference on Digital Futures and Transformative Technologies. Islamabad; IEEE, 2021; 1–5.
- [35] Song X, Mariano V Y. Image – based apple disease detection based on residual neural network and transfer learning [C]//3rd International Conference on Power, Electronics and Computer Applications. Shenyang; IEEE, 2023; 365–369.
- [36] 王大庆, 禄 琳, 于兴龙, 等. 基于深度迁移学习的 EfficientNet 玉米叶部病害识别[J]. 东北农业大学学报, 2023, 54(5): 66–76.
- [37] 邓朋飞, 官 铮, 王宇阳, 等. 基于迁移学习和模型压缩的玉米病害识别方法[J]. 计算机科学, 2022, 49(增刊2): 444–449.
- [38] 刘媛媛, 王定坤, 邬 雷, 等. 基于知识蒸馏和模型剪枝的轻量化模型植物病害识别[J]. 浙江农业学报, 2023, 35(9): 2250–2264.
- [39] 李庆盛. 基于图像识别与深度学习的农作物病害检测研究[D]. 淄博: 山东理工大学, 2022.
- [40] 李若曦. 农作物病害图像识别与模型轻量化研究[D]. 天津: 河北工业大学, 2022.
- [41] Wei X D, Zhang H Y, Shi C K, et al. A lightweight flower classification model based on improved knowledge distillation [C]//10th Joint International Information Technology and Artificial Intelligence Conference. Chongqing; IEEE, 2022; 2236–2239.
- [42] 温钊发, 蒲 智, 程 曦, 等. 基于知识蒸馏与 EssNet 的田间农作物病害识别[J]. 山东农业科学, 2023, 55(5): 154–163.
- [43] 李子涵, 周省邦, 赵 戈, 等. 基于卷积神经网络的农业病虫害识别研究综述[J]. 江苏农业科学, 2023, 51(7): 15–23.
- [44] 慕君林, 马 博, 王云飞, 等. 基于深度学习的农作物病虫害检测算法综述[J]. 农业机械学报, 2023, 54(增刊2): 301–313.
- [45] 戴久竣. 基于深度学习的农作物叶片病害识别研究[D]. 杭州: 浙江科技学院, 2022.
- [46] 张颖超. 基于深度学习的农作物叶片病害检测识别方法及其应用研究[D]. 石家庄: 河北科技大学, 2021.
- [47] 毛 星, 金 晶, 张 欣, 等. 基于改进 DeepLab v3 + 模型和迁移学习的高分遥感耕地信息提取方法[J]. 江苏农业学报, 2023, 39(7): 1519–1529.