

doi:10.6041/j.issn.1000-1298.2023.S2.036

# 基于深度学习的农作物病虫害检测算法综述

慕君林<sup>1</sup> 马 博<sup>1</sup> 王云飞<sup>1</sup> 任 卓<sup>1</sup> 刘双喜<sup>1,2</sup> 王金星<sup>1,3</sup>(1. 山东农业大学机械与电子工程学院, 泰安 271018; 2. 山东省农业装备智能化工程实验室, 泰安 271018;  
3. 山东省园艺机械与装备重点实验室, 泰安 271018)

**摘要:** 农作物病虫害对农业产量和品质影响巨大。数字图像处理技术在农作物病虫害识别中发挥重要作用。深度学习在该领域取得显著突破,效果优于传统方法。深度学习方法的特征提取能力更强,能准确捕捉细微特征,提高检测精度和可靠性。深度学习为农业提供了有力支持。本研究综述了基于深度学习的农作物病虫害检测研究,从分类网络、检测网络和分割网络3方面进行了概述,并对每种方法的优缺点进行了总结,同时比较了现有研究的性能。在此基础上,进一步探讨了基于深度学习的农作物病虫害检测算法在实际应用中面临的难题,并提出了相应的解决方案和研究思路。最后,对基于深度学习的农作物病虫害检测技术的未来趋势进行了分析和展望。

**关键词:** 农作物病虫害; 数字图像处理; 深度学习; 病虫害检测算法

中图分类号: TP391 文献标识码: A 文章编号: 1000-1298(2023)S2-0301-13

## Review of Crop Disease and Pest Detection Algorithms Based on Deep Learning

MU Junlin<sup>1</sup> MA Bo<sup>1</sup> WANG Yunfei<sup>1</sup> REN Zhuo<sup>1</sup> LIU Shuangxi<sup>1,2</sup> WANG Jinxing<sup>1,3</sup>(1. College of Mechanical and Electronic Engineering, Shandong Agricultural University, Taian 271018, China  
2. Shandong Provincial Engineering Laboratory of Agricultural Equipment Intelligence, Taian 271018, China  
3. Shandong Provincial Key Laboratory of Horticultural Machinery and Equipment, Taian 271018, China)

**Abstract:** Crop diseases and pests have a significant impact on agricultural yield and quality. Digital image processing technology plays an important role in identifying crop diseases and pests. Deep learning has achieved significant breakthroughs in this field, with better results than traditional methods. The issue of crop pest and disease detection was defined. The deep learning method had stronger feature extraction ability, which can accurately capture subtle features, improve detection accuracy and reliability. Deep learning provided strong support for agriculture. The research of crop pest detection based on deep learning was summarized from three aspects: classful network, detection network and segmentation network, the advantages and disadvantages of each method were summarized, and the performance of existing research was compared. On this basis, the challenges that deep learning based crop disease and pest detection algorithms may face in practical applications were further explored, and corresponding solutions and research ideas were proposed. These findings and reflections had important guiding significance for promoting the development of crop pest detection technology in practical applications. Finally, the future trends of crop disease and pest detection based on deep learning were analyzed and prospected.

**Key words:** crop diseases and pests; digital image processing; deep learning; disease and pest detection algorithm

收稿日期: 2023-05-20 修回日期: 2023-08-24

基金项目: 国家自然科学基金项目(32071908)和国家苹果产业技术体系项目(CARS-27)

作者简介: 慕君林(1977—),男,博士生,主要从事图像处理与深度学习算法研究,E-mail: 804875699@qq.com

通信作者: 王金星(1970—),男,教授,博士生导师,主要从事智能农业装备与技术研究,E-mail: jinxingw@163.com

## 0 引言

农作物病虫害检测是机器视觉领域极其重要的研究内容,利用机器视觉设备获取图像来判断是否存在农作物病虫害。传统病虫害监测依赖昆虫专家或技术人员进行人工识别,其主观性强且劳动强度大。随着带有摄像头和互联网功能的机器视觉设备的普及,计算机视觉技术为现代农作物病虫害自动监测提供了新途径,大大提高了监测效率<sup>[1-2]</sup>。

病虫害智能监测(SPM)是病虫害综合治理(IPM)中新兴的科学领域<sup>[3]</sup>,融合了人工智能(AI)技术。其目标是通过整合物联网(IoT)、大数据和AI等现代技术,实现农作物主要病虫害的智能采集,提升病虫害监测预警能力。具体实现步骤包括自动采集病虫害数据、远程传输、基于机器视觉的病虫害识别和精准决策,最终形成病虫害监测预警模型。机器视觉的病虫害识别是监测的关键步骤,直接影响着病虫害监测预警模型的准确性。

在传统的基于机器视觉的农作物病虫害检测方法中,通常使用传统图像处理算法或人工设计特征加分类器,这些方法依赖不同病虫害的不同特征来设计检测方案。然而,在自然环境下,场景中的光照等条件的变化会对检测结果产生严重影响,同时还面临着病虫害与背景对比度低等挑战,因此传统的基于机器视觉的病虫害检测方法难以取得良好的检测识别效果<sup>[4]</sup>。

近年来,深度学习模型,尤其是以卷积神经网络(CNN)和Transformer为代表的模型,在计算机视觉(CV)领域取得了多项成功应用,包括交通检测<sup>[5]</sup>、医学图像分割识别<sup>[6]</sup>、表情识别<sup>[7]</sup>、人脸识别<sup>[8]</sup>、行人检测<sup>[9]</sup>等。这些成功应用也促进了基于深度学习的农作物病虫害检测方法在实际农业中的应用。国内外已经开发了许多基于深度学习的农作物病虫害检测小程序和APP软件。因此,这些方法不仅在学术研究上具有重要价值,而且在市场应用上有着广阔的前景。

鉴于基于深度学习的农作物病虫害检测方法目前缺乏全面详细的讨论,本文总结并梳理2015—2023年的相关文献,以帮助研究人员系统地了解该领域的相关方法和技术。本文首先给出农作物病虫害检测问题的定义,然后重点详细阐述基于深度学习的图像识别技术,随后根据网络结构分析基于深度学习的农作物病虫害检测方法,包括分类、检测和分割网络。最后探讨基于深度学习的农作物病虫害检测可能面临的挑战,并提出可能的解决方案。最后,对未来的研究重点和发展方向进行展望。

## 1 农作物病虫害检测问题定义

农作物病虫害是指在农作物、园艺农作物或其他农作物中,由细菌、病毒、真菌、寄生虫等病原体或害虫引起的疾病或伤害。这些病原体和害虫可以侵害农作物的根、茎、叶、花、果实等部位,导致农作物生长发育受阻,产量下降,甚至导致农作物死亡。农户和园艺工作者通常会采取措施来预防、监测和治理农作物病虫害,以保护农作物的健康和增加产量。

### 1.1 农作物病虫害检测定义

农作物病虫害检测是一种利用各种技术手段和设备,对农作物进行监测和识别,以检测是否存在病害或虫害的过程<sup>[10]</sup>。这种检测旨在早期发现和诊断农作物病虫害,以便及时采取控制措施,减少农作物损失,提高农作物产量和质量。农作物病虫害检测可以通过人工观察、传统方法,或者结合机器视觉。基于机器视觉的农作物病虫害检测的要求可以分为3个不同的层次,即分类任务、定位任务、分割任务。在计算机视觉中的分类任务,给出其所属类别的标签,这个阶段的任务可以称为分类,只给出病虫害的类别信息;计算机视觉中的定位任务,如图1a所示,这个阶段的定位是严谨的,这个阶段不仅获取图像中存在哪些虫害类型,还给出了它们的具体位置,虫害所在位置用矩形框标出;计算机视觉中的分割任务,如图1b所示,将虫害与背景逐个像素分离,进一步得到虫害的长度、面积、位置、密集程度等一系列信息,可辅助更高级别的虫害严重程度等级评估。

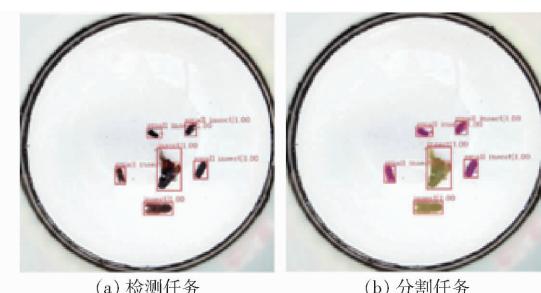


图1 虫害检测示意图

Fig. 1 Schematics of pest detection

虽然病虫害检测3阶段的功能要求和目标不同,但实际上,3阶段是相互包容、可以相互转换的。例如,第2阶段的定位任务包含了第1段的分类任务过程,第3阶段的分割任务可以完成第2阶段的定位任务。因此,本文研究的问题统称为农作物病虫害检测。

虫害或病害在植物上可能具有相同的表征,此外,还存在其他因素引起的表征,这些表征与病虫害

所产生的相似。因此,单纯通过基于机器视觉的病虫害检测技术很难将它们区分开。为了进一步区分它们,需要添加其他类型的传感器。例如,若虫害或病害在植物上具有相似的表征,需要添加传感器进一步检测是否存在细菌或真菌,从而精确判断。

## 1.2 与传统农作物病虫害检测方法的比较

为了更好地说明基于深度学习的虫害检测方法的特点,根据文献[11–15],从本质、方法、所需条件3方面与传统的虫害检测方法进行对比,详细比较结果见表1。

**表 1 基于深度学习的虫害检测方法与传统方法对比**

**Tab. 1 Comparison between deep learning based pest detection methods and traditional methods**

传统的图像处理方法		深度学习方法
本质	手动设计虫害特征 + 分类器	从大量数据中自动学习特征
方法	图像分割方法: 阈值分割; Sobel、Roberts、Prewitt 边缘检测 特征提取方法: SIFT、HOG、形状、颜色和纹理特征提取方法 分类方法: SVM、BP、贝叶斯	CNN、Transformer
所需条件	相对苛刻的成像环境, 虫害与环境高对比度	充足的学习数据和高性能计算单元

基于深度学习的病虫害识别技术与传统病虫害识别方法相比不需要提取具体的虫害特征,只通过迭代学习获取虫害图像的全局和上下文特征,具有较强的鲁棒性和较高的识别度、准确性。

## 2 基于深度学习的图像识别技术

### 2.1 深度学习技术

深度学习通过模拟人脑神经网络的结构和功能,利用大规模数据和强大的计算能力,使计算机能够从数据中学习并进行模式识别和决策<sup>[16]</sup>。

#### 2.1.1 深度学习理论

深度学习核心思想是构建多层次的神经网络模型,通过逐层的特征提取和抽象,实现对数据的高级表示和理解。这些神经网络包含输入层、隐藏层和输出层。隐藏层可以有多个,并且每一层都由许多神经元组成。每个神经元接收来自上一层神经元的输入,并通过激活函数对输入进行加权和激活,然后将结果传递给下一层神经元。深度学习的关键在于通过层层的特征学习来提取数据的高级表示。较低层次的特征能够捕获底层的简单模式,而较高层次的特征则可以捕获更抽象和复杂的模式。利用反向传播算法,神经网络可以根据预测误差来调整权重,从而逐渐优化学到的特征表示。深度学习依赖于大量标注数据进行训练,通过在大规模数据上进行

训练,神经网络能够学习到更准确和泛化的模式。数据量越大,深度学习模型的性能通常会越好。

深度学习克服了传统算法依赖人工设计特征的缺点,受到越来越多研究者的关注。深度学习的基本思想和方法在许多领域取得了重大突破,如图像识别、语音识别、自然语言处理等,成为人工智能领域的重要技术手段<sup>[17]</sup>。

传统的人工设计特征的图像分类识别方法只能提取底层特征,难以提取深层次复杂的图像特征信息<sup>[18]</sup>。而深度学习方法可以解决这个瓶颈。它可以直接对原始图像进行无监督学习,获得低级特征、中间特征和高级语义特征等多级图像特征信息。传统的病虫害检测算法主要采用人工设计特征的图像识别方法,难度大,不能自动从原始图像中学习和提取特征。而深度学习可以自动从大数据中学习特征,无需人工操作。该模型由多层组成,具有良好的自主学习能力和特征表达能力,能够自动提取图像特征进行图像分类识别。所以,深度学习在虫害图像识别领域可以发挥很大的作用。

#### 2.1.2 深度神经网络模型

目前,深度学习方法已经发展出许多著名的深度神经网络模型。深度信念网络(Deep belief networks, DBN)<sup>[19]</sup>,是由多层受限玻尔兹曼机(Restricted Boltzmann machines, RBMs)组成的深度神经网络模型。它在无监督学习中表现出色,常用于特征学习和生成模型。卷积神经网络(Convolutional neural networks, CNN)<sup>[20]</sup>,主要应用于图像识别和计算机视觉任务。CNN包含卷积层、池化层和全连接层,能够自动学习图像中的特征和模式。递归神经网络(Recurrent neural networks, RNN)<sup>[21]</sup>,具有循环连接的神经网络,适用于序列数据建模,如语言模型和机器翻译。RNN能够处理具有时间依赖性的数据。长短时记忆网络(Long short-term memory, LSTM),是一种特殊类型的RNN,通过门控单元的设计来解决传统RNN中的梯度消失问题,适用于处理长序列和捕捉长期依赖关系。生成对抗网络(Generative adversarial networks, GAN)<sup>[22]</sup>,是由生成器和判别器组成的对抗性模型。生成器试图生成与真实样本相似的样本,而判别器则尝试区分生成样本和真实样本。GAN可用于生成逼真的图像、音频和文本等。注意力机制(Attention mechanism),引入注意力机制的模型能够动态地关注输入数据中的重要部分。例如,注意力机制在机器翻译中广泛应用,能够根据源语言句子的不同部分对目标语言句子进行更准确的翻译;残差神经网络(Residual neural networks, ResNet)通过

引入残差连接(Residual connections)解决了深度神经网络中的梯度消失和退化问题。ResNet在图像分类等任务中表现出色。近年来,最流行的深度学习框架是深度卷积神经网络。

## 2.2 卷积神经网络

卷积神经网络(Convolutional neural networks,CNN),是一种特殊类型的神经网络,如图2所示,主要用于图像处理、计算机视觉和模式识别任务。它通过卷积层、池化层和全连接层的组合,能够自动提取图像中的特征并进行分类。输入层的功能为接收原始图像或图像的预处理结果作为输入;卷积层为卷积神经网络的核心部分。它由多个卷积核组成,每个卷积核通过与输入图像进行卷积操作,提取图像的局部特征。卷积操作可以捕捉到图像中的边缘、纹理和其他局部特征;池化层用于降低卷积层输出的空间尺寸,减少参数数量,并提取出特征的主要

部分。最常用的池化操作是最大池化(Max pooling),它在每个区域中选择最大值作为输出。池化操作还可以增加模型的平移不变性,使得模型对输入的微小平移具有鲁棒性;全连接层将池化层输出的特征图转化为一维向量,并通过神经元的连接权重进行分类。全连接层的神经元与上一层中的所有神经元相连,这使得网络可以学习到更高级别的特征和模式。输出层通常采用Softmax函数来计算每个类别的概率分布,用于分类问题的多类别预测。对于二分类问题,输出层可以使用Sigmoid函数。

卷积神经网络的结构通常由多个卷积层、池化层和全连接层堆叠而成,形成深层网络。通过层层堆叠和参数的学习,CNN可以自动学习到数据中的特征和模式,并在图像分类、目标检测、图像生成等任务中取得出色的性能。

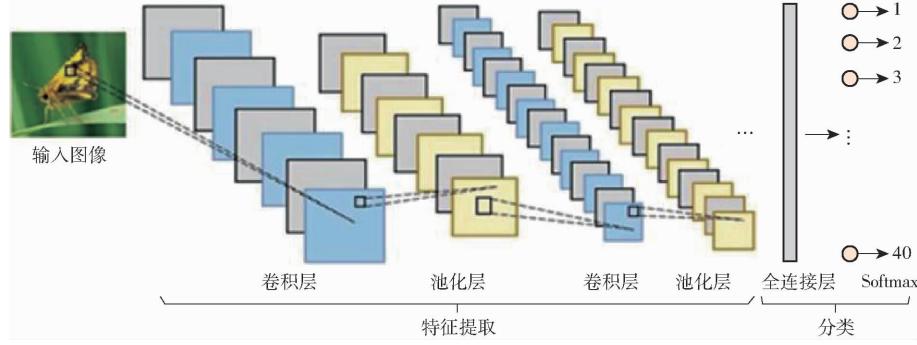


图2 卷积神经网络结构

Fig. 2 Convolutional neural network structure

## 2.3 Transformer 深度学习模型

Transformer是一种在自然语言处理(NLP)领域取得重大突破的深度学习模型,由VASWANI等<sup>[23]</sup>于2017年首次提出。Transformer模型在NLP任务中取代了传统的循环神经网络(RNN)和卷积神经网络(CNN),成为当前最常用的NLP模型之一。Transformer的设计主要基于注意力机制(Attention mechanism),它能够在处理输入序列时,更加关注与当前任务相关的部分,从而有效捕捉长距离的依赖关系。相比于RNN和CNN,Transformer能够并行处理序列数据,具有更好的训练速度和并行计算能力。Transformer的核心组件包括:自注意力机制(Self-Attention),编码器-解码器架构(Encoder-decoder architecture),多头注意力机制(Multi-head attention),前馈神经网络(Feed-forward neural networks)。

Transformer模型在NLP任务中取得了许多重要的成果,包括机器翻译、文本生成、情感分析、命名实体识别等。其优势在于能够处理长文本序列,同

时具备较强的表达能力和泛化能力。

## 2.4 用于深度学习的开源工具

深度学习常用第三方开源工具有TensorFlow<sup>[24]</sup>、Torch/PyTorch<sup>[25]</sup>、Caffe<sup>[26]</sup>、Theano<sup>[27]</sup>、Keras<sup>[28]</sup>、MXNet<sup>[29]</sup>、Chainer<sup>[30]</sup>、CNTK<sup>[31]</sup>等,如表2所示。常用的深度学习第三方开源工具,如Torch/PyTorch和TensorFlow,均支持跨平台运行,包括Linux、Windows、iOS、Android等。它们具有出色的扩展性,支持大量第三方库和深度网络结构。尤其在GPU上训练大型CNN网络时,它们表现出最快的训练速度。这些工具为深度学习研究和应用提供了强大的支持,推动了深度学习技术的快速发展与广泛应用。

## 3 基于深度学习的农作物病虫害检测

由于实现的目标与计算机视觉任务完全一致,只是检测对象不同,所以基于深度学习的农作物病虫害检测方法可以看作是深度学习在农业领域的应用。根据网络结构与功能不同,网络可以分为分类

表 2 深度学习常用第三方开源工具

Tab. 2 Common third-party open-source tools for deep learning

框架	发布时间	维护组织	底层语言	接口语言
Caffe	2013-09	BVLC	C++	C++/Python/Matlab
TensorFlow	2015-09	Google	C++/Python	C++/Python/Java
PyTorch	2017-01	Facebook	C/C++/Python	Python
MXNet	2015-05	DMLC	C++	C++/Python/Julia/R
Keras	2015-03	Google	Python	Python
Paddlepaddle	2016-08	Baidu	C++/Python	C++/Python
CNTK	2014-07	Microsoft	C++	C++/Python/C/Java
Theano	2007-09	MILA	Python	C++/Python
Chainer	2015-06	Preferred Networks	Python/Numpy	Python

网络、检测网络和分割网络。

### 3.1 农作物病虫害分类网络

基于深度学习的虫害分类网络是利用深度学习技术来实现对虫害图像进行自动化分类的方法。这些网络主要用于识别和区分不同类型的虫害,如昆虫、螨虫、虫害病菌等,以帮助农户和专家及时采取措施保护作物。虫害分类网络通常基于卷积神经网络(CNN),这是一类特别擅长处理图像数据的深度学习模型。CNN通过多个卷积层和池化层来逐步提取图像的特征,从而将图像的高级抽象表示转化为更易于分类的特征向量。在虫害分类任务中,CNN可以自动学习虫害图像中的特征,包括虫害的形状、纹理、颜色等,从而实现对不同虫害类型的区分。

由于在真实环境中虫害在形状、大小、纹理、颜色、背景、布局和成像光照等方面存在着巨大的差异,使自然环境下的农作物虫害识别成为一项艰巨的任务。由于CNN强大的特征提取能力,使基于CNN分类网络已成为最常用的虫害分类网络;现有的病虫害分类网络大多使用计算机视觉中的成熟网络结构,包括AlexNet<sup>[32]</sup>、GoogleLeNet<sup>[33]</sup>、VGGNet<sup>[33]</sup>、ResNet<sup>[34]</sup>、Inception V4<sup>[35]</sup>、DenseNets<sup>[36]</sup>、MobileNet<sup>[37]</sup>和SqueezeNet<sup>[38]</sup>等。直接使用网络进行病虫害分类是CNN最早应用于虫害检测的常用方法,据现有研究工作的特点,可以进一步细分为原始图像分类、定位感兴趣区域(ROI)后分类和多类别分类。

#### 3.1.1 原始图像分类

直接将采集到的完整农作物病虫害图像放入网络进行学习训练。LI等<sup>[39]</sup>利用ResNet18对果灰斑病、黑星病、雪松锈病和健康叶片的数据集来研究苹果叶部病害的识别和分类,获得了98.5%的准确率。THENMOZHI等<sup>[40]</sup>提出了一种有效的深度CNN模型,并使用迁移学习对预训练模型进行微调。在3个公共昆虫数据集上对昆虫物种进行分类,准确率分别为96.75%、97.47%和95.97%。

#### 3.1.2 获取 ROI 后分类

对于获取的整幅图像,需关注固定区域内是否存在虫害以及病变,所以研究者往往会提前获取感兴趣区域(ROI),然后将ROI输入到网络中来判断虫害与病变的类别。SARDOGAN等<sup>[41]</sup>用一种基于卷积神经网络(CNN)模型和学习矢量量化(LVQ)算法的分类方法对番茄叶病进行检测,平均准确率达到86%。

#### 3.1.3 多类别分类

当待分类的病虫害类数超过2类时,常规的虫害分类网络与原图像分类方法相同,即网络的输出节点为虫害数量和害虫种类加一。然而,多类别分类方法往往使用一个基本网络对不同种类虫害样本进行分类,然后在同一个网络上共享特征提取部分来修改或增加虫害种类的分类分支。这种方法相当于为后续的多目标虫害分类网络准备了一个预训练权重参数,该权重参数是通过不同虫害样本之间的二元训练得到。温长吉等<sup>[42]</sup>通过一种名为PestNet的基于区域的端到端方法检测58万幅害虫图像,其中包括16类害虫,平均精度达到75.46%。

综上所述,基于分类网络的方法在实践中得到了广泛的应用,许多学者对病虫害的分类进行了应用研究,不同的方法具有各自的优点与缺点。

### 3.2 农作物病虫害检测网络

在计算机视觉领域,目标定位是最基本的任务之一,也是与传统意义上的病虫害检测最为接近的任务。其主要目的是确定对象在图像中的准确位置,并同时给出其所属类别信息。目前,基于深度学习的目标检测方法不断更新迭代。一般来说,基于深度学习的病虫害检测网络可以分为:以Faster R-CNN<sup>[43]</sup>为代表的两阶段网络;SSD<sup>[44]</sup>和YOLO系列<sup>[45-47]</sup>。两个网络的主要区别在于两阶段网络需要先生成一个可能包含虫害的候选框,然后进一步执行虫害检测过程。而单阶段网络直接使用网络中提取的特征来预测虫害与病变的位置和类别。

### 3.2.1 基于两阶段的病虫害检测网络

两阶段检测网络(Faster R-CNN)的基本过程如图3所示(图3紫色虚线内为两阶段检测网络):首先通过主干网络得到输入图像的特征图,然后使用RPN计算anchor box confidence并得到proposal。然后,将ROIpooling后proposal区域的特征图输入到网络中,微调初始检测结果,最终

得到病变的定位和分类结果。因此,根据虫害检测的特点,常用的方法往往对主干结构或其特征图、anchor ratio、ROIpooling和损失函数进行改进。2020年,ZHANG等<sup>[48]</sup>提出了一种基于在线硬样本挖掘和残差网络的害虫分类识别方法,精度提升约5%,并且网络具有更强的小目标检测能力。

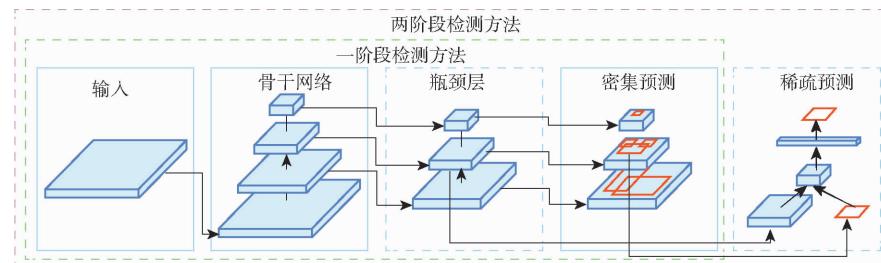


图3 检测网络结构图

Fig. 3 Detection network structure diagram

### 3.2.2 基于一阶段的病虫害检测网络

一阶段目标检测算法去掉了区域建议阶段,直接将检测头(Detection head)添加到主干网络中进行分类和回归,从而大大提高了检测网络的推理速度,其结构如图3所示(图3绿色虚线内为一阶段检测网络)。单阶段检测网络分为SSD和YOLO两种,它们都以整幅图像作为网络的输入,并在输出层直接返回bounding box的位置和所属的类别。SSD选择VGG16作为网络的主干,并增加了一个特征金字塔网络来获取不同层的特征并进行预测。YOLO则将检测任务视为回归问题,利用全局信息直接预测物体的边界框和类别,实现单个CNN网络的端到端检测。YOLO可以实现全局优化,在满足更高准确率的同时大大提高检测速度。XUE等<sup>[49]</sup>通过集成了自注意力和卷积注意模块的YOLO v5检测茶树叶病害和害虫,精度达到82.6%。柳春源等<sup>[50]</sup>通过改进的YOLO v5检测农田害虫图像,最高平均精度达到80.91%。

除此之外,还有许多关于利用检测网络识别病虫害的研究<sup>[50-53]</sup>。随着检测网络的发展,未来会有更多的新检测模型应用于农作物病虫害检测。综上所述,在当前注重检测精度的虫害检测领域,较多使用基于两阶段的模型;而在追求检测速度的病虫害检测领域,则较多使用基于一阶段的模型。

另外,有一个误解,即检测网络可以代替分类网络。实际上,检测网络的任务是解决农作物虫害的定位问题,而分类网络的任务是判断农作物病虫害的类别。虽然检测网络在隐藏信息中包含了类别信息,即需要事先知道需要定位的病虫害的类别信息,并提前给出相应的标注信息来判断其位置。然而,

在现实世界中,很多情况下并不能唯一地反映虫害类别的独特性,只能回答“什么样的虫害可能在什么地方”,因此分类网络的介入是必要的。因此,检测网络不能代替分类网络。

### 3.3 农作物病虫害分割网络

分割网络在农作物病虫害检测任务中起到了关键作用,它可以将图像分割成包含病虫害的区域和正常区域,实现语义或实例级别的分割。通过分割网络的处理,可以准确地识别每个像素点所属的类别,从而得到病虫害区域和正常区域的详细信息。除了虫害区域的定位,分割网络还能提供位置、类别以及相应的几何属性,例如病虫害的长度、宽度、面积、轮廓和中心等。通过获取这些几何属性,可以更深入地了解病虫害的形态特征,进一步分析和诊断病虫害的严重程度和传播情况。分割网络的应用极大地提高了农作物病虫害检测的准确性和细节表现,为农业生产提供了更精确的信息和决策支持。分割网络可以分为:全卷积网络(FCN)<sup>[54]</sup>和Mask R-CNN<sup>[55]</sup>、Transformer<sup>[23]</sup>。

#### 3.3.1 基于FCN的农作物病虫害分割网络

FCN是一种用于语义分割任务的深度学习模型。在传统的深度学习模型中,通常会通过多层全连接神经网络来处理输入数据,但这样的模型无法处理输入数据的尺寸变化。FCN则采用全卷积神经网络的结构,使得输入可以是任意尺寸的图像,并且输出也是对应尺寸的分割结果。FCN主要用于像素级别的语义分割,即将图像中的每个像素分为不同的类别,如人、车、树等。它将传统的全连接层替换为全卷积层,在特征提取过程中可以保留输入图像的空间信息。而在输出层,通过逐像素分类来

获得每个像素点的分类标签。基于 FCN 网络结构的差异,病虫害分割方法可分为常规 FCN、U-Net<sup>[56]</sup>和 SegNet<sup>[57]</sup>。GONG 等<sup>[58]</sup>提出了一种基于全卷积网络(FCN)的水稻害虫自动识别和分类算法。该方法集成了条件随机场(CRF)模块,用于昆虫轮廓细化和边界定位,最后,提出了一种引入注意机制(ECA)的新颖的 DenseNet 框架,专注于提取昆虫边缘特征以进行有效的水稻害虫分类。所提出的模型在自定义数据集上进行测试,最终识别准确率为 98.28%,分割精度达到 95.13%。

U-Net 不仅是经典的 FCN 结构,由 OLAF 等于 2015 年提出,它得名于其网络结构的 U 形状,由编码器(下采样路径)和解码器(上采样路径)两部分组成,是典型的 encoder-decoder 结构。其特点是引入了跳层连接,将编码阶段的特征图与解码阶段的特征图融合,有利于分割细节的恢复,优于现有的 K-means、Random-forest 和 GBDT 方法。U-Net 方法可以在复杂背景下对病灶区域进行分割,在样本较少的情况下仍具有较好的分割精度和分割速度。ZHANG 等<sup>[59]</sup>构建一种改进的 U-Net(MU-Net)用于农作物病叶图像分割,该网络使用 2 个 Respath 替代 2 个 skip 连接来改善收缩路径和扩展路径之间相应特征信息的转换,最终分割精度达到

95.13%。

SegNet 是一种用于语义分割任务的深度学习模型,于 2015 年提出。SegNet 采用编码器-解码器的网络架构。编码器部分由多个卷积层和池化层组成,用于提取图像的高级特征。解码器部分则通过转置卷积(反卷积)操作将编码器输出的特征图恢复到原始输入图像的尺寸。SegNet 在语义分割任务上取得了优异的性能,特别是在医学图像分割等领域具有很好的应用前景。由于其较低的计算成本和简单有效的设计,SegNet 在一些资源有限的场景中得到了广泛应用。然而,SegNet 也可能因为其相对较简单的结构而在复杂场景下面临性能限制,因此在实际应用中需要根据任务需求进行选择。KERKECH 等<sup>[60]</sup>提出了一种无人机图像分割方法,使用 SegNet 对可见光和红外图像进行分割,该方法对葡萄藤和叶子的检出率分别为 92% 和 87%。

### 3.3.2 基于 Mask R-CNN 的农作物病虫害分割网络

Mask R-CNN 是一种用于目标检测和实例分割的深度学习模型,由 HE 等于 2017 年提出。Mask R-CNN 是对 Faster R-CNN 的扩展,它在目标检测的基础上,增加了对每个检测到的目标实例进行像素级别的分割,从而实现了实例分割任务,其结构如图 4 所示。

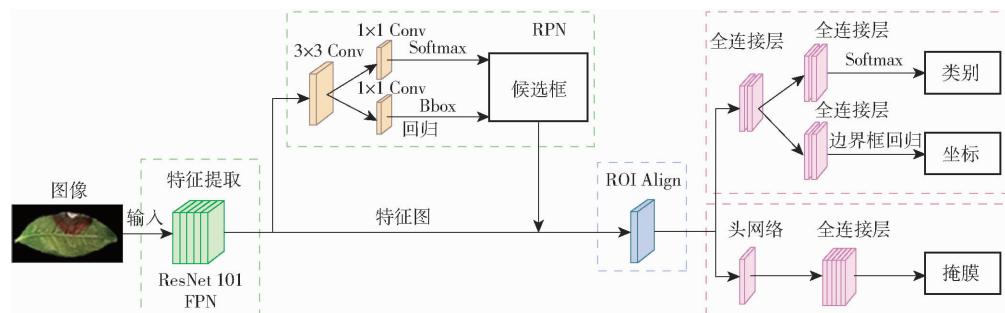


图 4 Mask R-CNN 网络模型图

Fig. 4 Mask R-CNN network model diagram

Mask R-CNN 被认为是一种基于检测和分割网络的多任务学习方法。当同一类型的多个虫害有粘连或重叠时,实例分割可以将单个虫体分开,并进一步统计虫害的数量。然而,语义分割通常将同一类型的多个病变视为一个整体。一些研究将 Mask R-CNN 框架与目标检测网络结合起来进行虫害检测。2021 年,AFZAAL 等<sup>[61]</sup>通过使用以 ResNet 主干网络的 Mask R-CNN 对 7 种复杂背景条件的草莓病害进行检测,最终平均精度达到 82.43%。

### 3.3.3 基于 Transformer 的农作物病虫害分割网络

Transformer 是一种革命性的深度学习模型,由 VASWANI 等于 2017 年首次提出。它在自然语言处理(NLP)和其他序列数据任务中取得了重大突破。

Transformer 的设计主要基于注意力机制(Attention mechanism),它能够在处理输入序列时,更加关注与当前任务相关的部分,从而有效捕捉长距离的依赖关系。相比于传统的循环神经网络(RNN)和卷积神经网络(CNN),Transformer 能够并行处理序列数据,具有更好的训练速度和并行计算能力。Transformer 模型在 NLP 任务中取得了许多重要的成果,包括机器翻译、文本生成、情感分析、命名实体识别等。其优势在于能够处理长文本序列,同时具备较强的表达能力和泛化能力,成为了现代 NLP 的重要基石。除了 NLP,Transformer 的思想也被应用到其他领域,如图像生成和语音识别等任务。2022 年,GUO 等<sup>[62]</sup>提出基于 Swin Transformer 的分割方

法,该方法成功地分割了各种情况下的害虫,包括阴影、重叠以及叶子和树枝遮挡的害虫,能够在复杂的自然环境中准确分割害虫,最终分割精度达到87.23%。

### 3.4 现有算法的性能比较

深度学习算法在农作物病虫害检测上表现出色,相比传统的图像处理和特征提取方法,它能够自动学习图像中的关键特征,更好地捕捉农作物病虫害的细微特征。卷积神经网络(CNN)是最常用的深度学习模型,通过卷积层、池化层和全连接层实现图像分类。另外,循环神经网络(RNN)可处理时序数据,适用于农作物生长过程中的图像序列。Transformer模型使用自注意力机制处理序列数据,在农作物病虫害检测中展现出优越的性能,更好地理解图像全局上下文。目标检测模型如Faster R-CNN、YOLO和SSD能同时检测并定位图像中的多个病虫害目标。深度学习算法的性能受数据规模和计算资源影响,合理选择适用的模型、数据增强和模型优化等关键因素有助于提高农作物病虫害检测的效果。

## 4 农作物病虫害检测关键技术问题

### 4.1 农作物病虫害小数据集检测问题

目前,深度学习方法广泛应用于各种计算机视觉任务,其中农作物病虫害检测是农业领域的具体应用之一。然而,农作物虫害检测面临一个重要挑战,即样本规模较小的问题。相比于公开可用的大规模标注库,自行收集农作物虫害数据样本困难且费时,导致数据集规模有限,标注数据的过程也相对耗费人力和时间。因此,小样本问题成为目前农作物病虫害检测领域的主要限制因素。对于小样本的问题,目前有3种不同的解决方案。

#### 4.1.1 数据扩增

深度学习数据扩增(Data augmentation)是一种常用的数据增强技术,旨在通过对原始数据进行变换和扩展,生成更多样化、更丰富的训练数据,从而提升深度学习模型的泛化能力和性能。数据扩增是深度学习模型训练的关键组成部分。优化后的数据扩增策略可有效提高农作物病虫害检测效果。病虫害图像扩增最常用的方法是对原始病虫害样本进行镜像、旋转、平移、滤波、对比度调整等图像处理操作,获取更多的样本。此外,生成对抗网络(生成对抗网络)(GANs)<sup>[63]</sup>和变分自动编码器(VAE)<sup>[64]</sup>可以生成更多样化的样本,丰富有限的数据集。GANDHI等<sup>[65]</sup>使用生成对抗网络(GAN)来增加有限数量的可用本地图像,并通过智能手机应用程序

中部署的卷积神经网络(CNN)模型完成分类任务。

#### 4.1.2 迁移学习

迁移学习(Transfer learning)是一种机器学习技术,其核心思想是将已经在一个任务上训练好的模型的知识迁移到另一个相关任务上,从而加快新任务的学习过程和提升性能。在传统机器学习中,每个任务通常需要独立地进行数据收集、特征提取和模型训练。然而,某些任务的数据量较少,模型难以充分训练,或者需要大量计算资源。这时,迁移学习可以通过利用其他任务已经学到的知识来帮助新任务。迁移学习在计算机视觉、自然语言处理和语音识别等领域广泛应用。它不仅可以提高模型的泛化能力,还可以节省训练时间和资源。在对参数进行微调或修改成分后,可将其应用于农作物病虫害检测,从而降低模型训练的成本,使卷积神经网络适应小样本数据。LIU等<sup>[66]</sup>基于VGG16和Inception-ResNet-v2迁移学习网络构建相应的害虫图像识别和分析模型,然后,利用集成算法的思想,将两个改进的CNN系列害虫图像识别和分析模型有效融合,提高了模型对农作物害虫识别和分类的准确性,该方法对害虫识别的准确率为97.71%。THENMOZHI等<sup>[40]</sup>提出了一种高效的深度CNN模型,并应用迁移学习来微调预训练模型,提出的模型中分析了超参数的有效性以提高准确性。在NBAIR(40类)昆虫数据集、Xie1(24类)昆虫数据集和Xie2(40类)昆虫数据集上最高分类精度为96.75%、97.47%、95%。

#### 4.1.3 合理的网络结构设计

通过设计合理的网络结构,可以大大减少对样本数量的需求。ZHANG等<sup>[67]</sup>结合3种颜色分量构建了农作物叶片病害识别的三通道卷积神经网络模型。每个通道TCCNN分量由3幅彩色RGB叶片病害图像组成。LIU等<sup>[68]</sup>提出了一种改进的识别葡萄叶片病害的CNN方法。该模型采用深度可分卷积代替标准卷积来减少过拟合和参数数量。针对不同大小的葡萄叶片病变,将初始结构应用于模型,提高多尺度特征提取能力。与标准的ResNet和GoogLeNet结构相比,该模型具有更快的收敛速度和更高的训练精度。该算法的识别准确率为97.22%。

### 4.2 农作物小目标病虫害检测与细粒度的识别问题

#### 4.2.1 早期发现小目标病虫害

准确的早期病虫害发现对于提高农作物产量至关重要。然而,实际农作物病虫害早期识别面临挑战,尤其是小尺寸对象容易被忽略,复杂背景和低分

分辨率图像可能导致错误检测。为了解决这些问题,改进方向和策略被提出来提高小目标检测性能。其中包括引入注意机制,增强对小目标的关注和响应;采用超分辨率技术提高图像质量;使用多尺度特征融合来更全面地表示目标和背景;以及数据增强增加模型泛化能力。这些措施将有助于更好地实现农作物病虫害的早期发现和识别,提高农作物产量,降低损失,为农业生产带来更大的效益。

注意机制的运用使资源配置更加合理。注意机制的本质是快速找到感兴趣的区域忽略不重要的信息。通过学习农作物病虫害图像的特征,采用加权系数加权求和法进行特征分离,对图像中的背景噪声进行抑制。具体来说,注意机制模块可以获得显著图像,将目标与背景隔离,利用 Softmax 函数对特征图像进行操作,并将其与原始特征图像结合得到新的融合特征,达到降噪的目的。在未来农作物病虫害早期识别的研究中,可以利用注意力机制有效地选择信息,将更多的资源分配到感兴趣的区域,实现更准确的检测。HU 等<sup>[69]</sup>提出一种深度神经网络 YOLO - GBS,融合全局上下文(GC)注意力机制,在复杂背景下寻找目标,充分利用全局上下文信息的自注意力机制,对包含 Crambidae 的昆虫数据集进行实验,其中主要包括夜蛾科、斑蛾科和飞虱科,所提出模型的平均 mAP 高达 79.8%。

#### 4.2.2 细粒度的识别问题

农作物病虫害检测面临 3 个主要挑战:①类内差异较大,即属于同一类的农作物病虫害在视觉特征上差异较大,由于光照、遮挡等因素导致样本差异。②类间存在模糊性,不同类的对象可能具有相似性,导致细粒度识别问题。③背景干扰使得现实世界中农作物病虫害很难出现在整洁背景中,增加了检测的难度<sup>[70]</sup>。

为了应对这些挑战,研究者提出了不少改进方法。例如,通过引入注意机制、提高模型特征提取能力、使用更适合复杂背景下的激活函数和损失函数等,来增强模型对复杂背景的识别效果。同时,对于类内差异大的问题,使用多尺度特征融合提高模型的泛化能力。另外,数据增强也是解决小样本问题的有效手段,通过扩充训练数据,提高模型的鲁棒性和准确性。ZHANG 等<sup>[71]</sup>提出一种基于改进 YOLOX 的实时高性能检测模型。该模型在 YOLOX 中引入了 Efficient Channel Attention (ECA)、hard - Swish 激活函数、Focal Loss 函数,提高了模型提取图像特征的能力,增强复杂背景下棉花病虫害检测效果,平均精度达到 94.60%。

通过引入注意机制是提高病虫害识别精度的重

要手段。通过融合通道注意力和空间注意力这种方法,在病虫害识别领域取得了显著的进展。通道注意力机制使模型能够动态地分配不同通道的权重,从而更加关注对于病虫害识别具有重要贡献的特征,从而提高了模型的特征提取能力。而空间注意力机制则有助于在图像中定位病虫害的精确位置,通过对图像不同区域的加权,使模型更加关注病虫害可能出现的区域,进一步提升了识别精度。这种融合注意力机制的优势在于,它能够充分利用通道信息和空间信息的互补性,实现更准确的病虫害识别。通过联合考虑不同通道的特征和图像不同位置的特征,模型能够更好地理解图像的语义信息,从而对于复杂的农作物病虫害场景作出更精准的判断。

### 4.3 光照变化和遮挡影响下的检测性能问题

#### 4.3.1 光照变化对农作物病虫害检测的影响

过去的农作物病虫害图像采集主要集中在室内灯箱环境中。虽然这种方法可以有效消除外界光线干扰,简化图像处理过程,但与真实自然光下采集的图像存在较大差异。自然光的变化非常动态,而相机能够接受的动态光源范围是有限的,一旦超出或低于这个范围,图像颜色可能会失真。此外,由于图像采集时视角和距离的不同,农作物病虫害的表现特征发生较大变化,给准确识别带来了很大挑战。

为了解决这些问题,对农作物病虫害的采集和识别应当更加接近真实自然光下的情况。可以选择在户外或农田中进行图像采集,以更好地反映农作物病虫害在实际生长环境下的表现。此外,在采集图像时要注意保持一致的视角和距离,以减小表观特征的变化。对于动态光照,可以考虑使用高动态范围(HDR)技术或其他曝光调整方法来获取更准确的图像信息。

此外,还可以通过引入更多的样本来增加数据多样性,采用数据增强技术来提高模型的泛化能力。同时,结合迁移学习等方法,可以将室内灯箱采集的数据与真实自然光下采集的数据相结合,提高模型在真实场景下的识别效果。通过这些措施,可以更好应对自然光变化和视角差异带来的困难,提高农作物病虫害识别的精确度和鲁棒性。

#### 4.3.2 遮挡对农作物病虫害检测的影响

目前,大多数农作物病虫害识别研究都集中在简单背景下进行,避免了复杂环境的干扰。这些研究通常采用直接截取感兴趣区域的方法,但很少考虑遮挡问题。因此,在遮挡条件下的农作物病虫害识别精度较低,实际应用受到很大限制。遮挡问题在真实自然环境中很常见,包括由于叶片姿态变化引起的叶片遮挡、分支遮挡、外部光照引起的光遮挡

以及不同遮挡类型引起的混合遮挡。在遮挡条件下,特征缺失和噪声重叠是农作物病虫害识别的难点,不同程度的遮挡影响识别算法的准确性,导致误检和漏检问题。

近年来,随着深度学习算法在受限条件下的成熟,一些研究者开始研究遮挡条件下的农作物病虫害识别<sup>[72]</sup>,并取得了重要进展,为其在真实场景中的应用奠定了基础。然而,遮挡问题是随机且复杂的,现有的基础框架训练难度较大,仍对硬件设备性能有较高依赖。因此,需要加强基础框架的创新和优化,包括设计更轻量级的网络架构。同时,需要加强对生成对抗网络(GAN)等方法的探索,在保证检测准确性的同时,降低模型训练的难度。GAN在处理姿态变化和复杂背景方面有优势,但其设计还不成熟,容易出现训练困难和模型不稳定的问题。因此,需要加强对网络性能的探索,使模型的质量更容易量化和可控。

综上所述,解决遮挡条件下的农作物病虫害识别问题需要不断创新和优化现有算法,并加强对轻量级网络架构和GAN等方法的研究。

#### 4.4 农作物病虫害检测速度问题

深度学习算法在农作物病虫害检测任务中相较于传统方法表现更出色,然而其计算复杂度较高。为了获得较高的检测精度,深度学习模型需要充分学习图像的特征,这导致计算量的增加,从而降低了检测速度,难以满足实时性的需求。因此,为了保证检测速度,通常需要减少模型的计算量。然而,这种减少计算量的做法可能导致模型训练不足,进而造成错误检测或漏检。

因此,设计一种既能保证检测精度又能保证检测速度的高效算法变得尤为重要。在实际研究中,需要找到一个平衡点,既能确保模型足够复杂以学习图像的细微特征,又能尽量减少计算量以提高检测速度。这可以通过采用轻量级网络结构、优化计算流程、减少冗余参数等方式来实现。此外,数据增强、迁移学习和模型蒸馏等技术也可以用来提高模型的性能并加速模型训练过程。

在面对计算复杂度和检测速度之间的折衷时,还可以考虑使用硬件加速器如GPU、TPU等来提高深度学习算法的运行速度。此外,针对不同场景和任务需求,可以采取不同的策略,例如对于实时性要求较高的场景,可以选择牺牲一定的检测精度来获得更快的检测速度。

总体来讲,解决深度学习算法在农作物病虫害检测中的计算复杂度和检测速度之间的平衡问题是一个具有挑战性的任务。需要综合考虑多种因素,

并采用合适的方法和技术来优化模型性能,以实现既精确又高效的农作物病虫害检测算法。

基于深度学习的农作物病虫害检测方法在农业应用中包括3个主要环节:数据标注、模型训练和模型推理。在实时农业应用中,模型推理越来越受到重视。目前,大多数农作物病虫害的检测方法都集中在识别的准确性上。很少有人关注模型推理的效率。RAHMAN等<sup>[73]</sup>提出了一种两级小型CNN架构,并与MobileNet、NasNet Mobile和SqueezeNet等最先进的内存高效CNN架构进行了比较。实验结果表明,该模型在保持93.3%的精度的同时,将模型尺寸缩小了99%,适合在资源受限的移动设备上进行作物病害的实时诊断。

### 5 结论与未来发展方向

#### 5.1 结论

深度学习在农作物病虫害检测领域表现出卓越的性能,相较于传统图像处理和特征提取方法,其自动学习图像特征的能力能更准确地捕捉农作物病虫害的微小特征,从而显著提高了检测的准确性和可靠性。卷积神经网络(CNN)作为主流网络,以其卓越的图像处理能力成为该领域的主要选择。通过利用预训练的CNN模型并进行微调,能够在农作物病虫害检测任务中取得优异的表现,验证其在图像分类任务上的优异性能。同时,强调大规模且高质量的数据集对于深度学习模型的训练至关重要,充足的训练数据有助于提升模型的泛化能力和准确性。数据增强技术在此过程中也发挥重要作用,它能有效增加数据样本,提高模型对不同变体的适应性。综上所述,深度学习在农作物病虫害检测领域展现出强大的潜力和广阔的应用前景,为农业生产提供了重要的技术支持和解决方案。与传统的图像处理方法相比,基于深度学习的病虫害检测方法将病虫害检测统一为端到端特征提取,具有广阔的发展前景和巨大的潜力。虽然农作物病虫害检测技术发展迅速,但已经从学术研究向农业应用过渡,距离在真实自然环境中成熟应用还有一定的距离,仍需解决一些问题。

#### 5.2 农作物病虫害检测的未来发展方向

未来农作物病虫害检测领域可以重点关注以下几个方面:

(1)针对小样本问题的解决方案:针对农作物病虫害数据集小样本和类别不平衡的特点,进一步研究如何在少量样本下构建更准确和鲁棒的模型,提高模型在小样本情况下的泛化能力。

(2)多模态数据融合:将不同传感器获得的多

模态数据如红外图像、遥感数据和声音等,与图像数据进行融合,以提供更全面的信息,进一步提高农作物病虫害检测的精确性。

(3)可解释性和可迁移性:加强对深度学习模型的可解释性研究,使其更易于被农户和专家理解和接受。同时,探索提高模型可迁移性的方法,使已

训练的模型能够迁移到其他相关任务中,扩展应用范围。

(4)弱监督和无监督学习:研究如何利用弱监督学习和无监督学习技术,以减少对标注数据的需求,提高模型的效率和泛化能力,降低数据采集成本。

## 参 考 文 献

- [1] DOMINGUSE T, BRANDAO T, FERREIRA J C. Machine learning for detection and prediction of crop diseases and pests: a comprehensive survey[J]. *Agriculture*, 2022, 12(9):1350.
- [2] KARTIKEYAN P, SHRIVASTAVA G. Review on emerging trends in detection of plant diseases using image processing with machine learning[J]. *International Journal of Computer Application*, 2021, 975: 8887.
- [3] 郭予元. 我国IPM研究进展回顾及对21世纪初发展目标的设想[J]. *植物保护*, 1998(1):35–38.  
GUO Yuyuan. Review of IPM research progress in China and assumption of development goals for the early 21st century [J]. *Plant Protection*, 1998(1):35–38. (in Chinese)
- [4] LIU S, QIAO Y, LI J, et al. An improved lightweight network for real-time detection of apple leaf diseases in natural scenes [J]. *Agronomy*, 2022, 12(10):2363.
- [5] 党倩. 基于深度卷积神经网络的交通标志识别[D]. 西安:陕西师范大学, 2016.  
DANG Qian. Traffic sign recognition based on deep convolutional neural network [D]. Xi'an: Shaanxi Normal University, 2016. (in Chinese)
- [6] CHEN J, LU Y, YU Q, et al. Transunet: transformers make strong encoders for medical image segmentation [J]. arXiv preprint arXiv:2102.04306, 2021.
- [7] SINGH S, NASOZ F. Facial expression recognition with convolutional neural networks[C]//2020 10th Annual Computing and Communication Workshop and Conference (CCWC), Las Vegas, 2020: 0324–0328.
- [8] WANG H, GUO L. Research on face recognition based on deep learning[C]//2021 3rd International Conference on Artificial Intelligence and Advanced Manufacture (AIAM), Manchester, 2021: 540–546.
- [9] 罗浩, 姜伟, 范星, 等. 基于深度学习的行人重识别研究进展[J]. *自动化学报*, 2019, 45(11): 2032–2049.  
LUO Hao, JIANG Wei, FAN Xing, et al. Research progress in pedestrian re-recognition based on deep learning[J]. *Journal of Automation*, 2019, 45(11): 2032–2049. (in Chinese)
- [10] AFIFI A, ALHUMAMI A, ABDELWAHAB A. Convolutional neural network for automatic identification of plant diseases with limited data[J]. *Plants*, 2021, 10(1):28.
- [11] 王聃, 柴秀娟. 机器学习在植物病害识别研究中的应用[J]. *中国农机化学报*, 2019, 40(9): 171–180.  
WANG Dan, CHAI Xiujuan. Application of machine learning in plant disease recognition research [J]. *Journal of Chinese Agricultural Mechanization*, 2019, 40(9): 171–180. (in Chinese)
- [12] GANATRA N, PATEL A. A multiclass plant leaf disease detection using image processing and machine learning techniques [J]. *International Journal on Emerging Technologies*, 2020, 11(2): 1082–1086.
- [13] KAUR P, GAUTAM V. Plant biotic disease identification and classification based on leaf image: a review [C/OL] // Proceedings of 3rd International Conference on Computing Informatics and Networks. Lecture Notes in Networks and Systems. Springer, Singapore. [https://doi.org/10.1007/978-981-15-9712-1\\_51](https://doi.org/10.1007/978-981-15-9712-1_51).
- [14] 邵明月, 张建华, 冯全, 等. 深度学习在植物叶部病害检测与识别的研究进展[J]. *智慧农业*, 2022, 4(1):29–46.  
SHAO Mingyue, ZHANG Jianhua, FENG Quan, et al. Research progress in deep learning for detecting and recognizing plant leaf diseases[J]. *Smart Agriculture*, 2022, 4(1):29–46. (in Chinese)
- [15] PRAKASH R M, SARASWATHY G P, RAMALAKSHMI G, et al. Detection of leaf diseases and classification using digital image processing[C]//2017 International Conference on Innovations in Information, Embedded and Communication Systems (ICIECS), Coimbatore, 2017:1–4.
- [16] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks science[J]. *Science*, 2006, 313:504–507.
- [17] 罗会兰, 陈鸿坤. 基于深度学习的目标检测研究综述[J]. *电子学报*, 2020, 48(6): 1230–1239.  
LUO Huilan, CHEN Hongkun. A review of research on object detection based on deep learning [J]. *Acta Electronica Sinica*, 2020, 48(6): 1230–1239. (in Chinese)
- [18] CAYIR A, YENIDOGAN I, DAG I. Feature extraction based on deep learning for some traditional machine learning methods [C]//2018 3rd International Conference on Computer Science and Engineering (UBMK), Sarajevo, Bosnia and Herzegovina, 2018:494–497.
- [19] HUA Y, GUO J H, ZHAO H. Deep belief networks and deep learning[C]//Proceedings of 2015 International Conference on

- Intelligent Computing and Internet of Things, Harbin, 2015: 1–4.
- [20] LI Z, LIU F, YANG W, et al. A survey of convolutional neural networks: analysis, applications, and prospects [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(12):6999–7019.
- [21] SALEHINEJAD H, SANKAR S, BARFETT J, et al. Recent advances in recurrent neural networks [J]. arXiv preprint arXiv: 1801.01078, 2017.
- [22] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative adversarial networks: an overview [J]. IEEE Signal Processing Magazine, 2018, 35(1):53–56.
- [23] VASWANIA, SHAZER N, PARMAR N, et al. Attention is all you need [C] // Advances in Neural Information Processing Systems 30 (NIPS 2017), 2017.
- [24] TensorFlow [EB/OL]. <https://www.tensorflow.org/>.
- [25] Torch/PyTorch [EB/OL]. <https://pytorch.org/>.
- [26] Caffe [EB/OL]. <http://caffe.berkeleyvision.org/>.
- [27] Theano [EB/OL]. <http://deeplearning.net/software/theano/>.
- [28] Keras [EB/OL]. <https://keras.io/>.
- [29] MXNet [EB/OL]. <https://mxnet.apache.org/>.
- [30] Chainer [EB/OL]. <https://chainer.org/>.
- [31] CNTK [EB/OL]. <https://github.com/microsoft/CNTK>.
- [32] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C] // Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition, Boston, 2015:1–9.
- [33] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. arXiv Preprint, arXiv:1409.1556, 2014.
- [34] XIE S, GIRSHICK R, DOLLAR P, et al. Aggregated residual transformations for deep neural networks [J]. arXiv Preprint, arXiv:1611.05431, 2017.
- [35] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, inception-ResNet and the impact of residual connections on learning [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2016.
- [36] HUANG G, LRJ Z, MAATEN L, et al. Densely connected convolutional networks [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017:226.
- [37] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications [J]. arXiv Preprint, arXiv:1704.04861, 2017.
- [38] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: AlexNet-level accuracy with  $50 \times$  fewer parameters and < 0.5 MB model size [J]. arXiv Preprint, arXiv:1602.07360, 2016.
- [39] LI X, RAI L. Apple leaf disease identification and classification using resnet models [C] // 2020 IEEE 3rd International Conference on Electronic Information and Communication Technology (ICEICT), Shenzhen, 2020: 738–742.
- [40] THENMOZHI K, REDDY U S. Crop pest classification based on deep convolutional neural network and transfer learning [J]. Comput. Electron. Agric., 2019, 164:104906.
- [41] SARDOGAN M, TUNCER A, OZEN Y. Plant leaf disease detection and classification based on CNN with LVQ algorithm [C] // 2018 3rd International Conference on Computer Science and Engineering (UBMK), Sarajevo, Bosnia and Herzegovina, 2018:382–385.
- [42] 温长吉, 王启锐, 陈洪锐, 等. 面向大规模多类别的病虫害识别模型 [J]. 农业工程学报, 2022, 38(8):169–177.  
WEN Changji, WANG Qirui, CHEN Hongrui, et al. A large-scale and multi category model for identifying pests and diseases [J]. Transactions of the CSAE, 2022, 38(8):169–177. (in Chinese)
- [43] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Trans. Pattern Anal. Mach. Intell., 2017, 39(6):1137–1149.
- [44] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector [C] // LEIBE B, MATAS J, SEBE N. Computer Vision-ECCV 2016: 14th European Conference. Springer, Cham, 2016:21–37.
- [45] ORCHI H, SADIK M, KHALDOUN M, et al. Real-time detection of crop leaf diseases using enhanced YOLO v8 algorithm [C] // 2023 IWCMC, Marrakesh, Morocco, 2023:1690–1696.
- [46] 吕宗旺, 金会芳, 鄂彤, 等. 图像处理技术在粮食害虫识别中的应用进展 [J]. 河南工业大学学报(自然科学版), 2021, 42(3):128–137.  
LÜ Zongwang, JIN Huifang, ZHEN Tong, et al. Application progress of image processing technology in identifying grain pests [J]. Journal of Henan University of Technology (Natural Science Edition), 2021, 42(3):128–137. (in Chinese)
- [47] YANG Z, FENG H, RUAN Y, et al. Tea tree pest detection algorithm based on improved Yolov7-Tiny [J]. Agriculture, 2023, 13(5):1031.
- [48] ZHANG M, CHEN Y, ZHANG B, et al. Recognition of pest based on Faster RCNN [C] // Signal and Information Processing, Networking and Computers: Proceedings of the 6th International Conference on Signal and Information Processing, Networking and Computers (ICSINC). Springer Singapore, 2020: 62–69.

- [49] XUE Z, XU R, BAI D, et al. YOLO-tea: a tea disease detection model improved by YOLO v5[J]. *Forests*, 2023, 14(2): 415.
- [50] 柳春源, 陈洪建, 曾小辉, 等. 基于 YOLO-V5 与 ResNet50 的农田害虫检测[J]. *人工智能与机器人研究*, 2022, 11(3): 236–247.
- LIU Chunyuan, CHEN Hongjian, ZENG Xiaohui, et al. Farmland pest detection based on YOLO – V5 and ResNet50 [J]. *Artificial Intelligence and Robotics Research*, 2022, 11(3): 236 – 247. (in Chinese)
- [51] AHMAD I, YANG Y, YUE Y, et al. Deep learning based detector YOLO v5 for identifying insect pests[J]. *Applied Sciences*, 2022, 12(19): 10167.
- [52] KUMAR V S, JAGANATHAN M, VISWANATHAN A, et al. Rice leaf disease detection based on bidirectional feature attention pyramid network with YOLO v5 model[J]. *Environmental Research Communications*, 2023, 5: 065014.
- [53] 徐会杰, 黄仪龙, 刘曼. 基于改进 YOLOv3 模型的玉米叶片病虫害检测与识别研究[J]. *南京农业大学学报*, 2022, 45(6): 1276 – 1285.
- XU Huijie, HUANG Yilong, LIU Man. Research on detection and identification of maize leaf diseases and pests based on improved YOLOv3 model[J]. *Journal of Nanjing Agricultural University*, 2022, 45(6): 1276 – 1285. (in Chinese)
- [54] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. *IEEE Trans. Pattern Anal. Mach. Intell.*, 2015, 39(4): 640 – 651.
- [55] HE K, GKIOXARI G, DOLLAR P, et al. Mask R – CNN[C] // Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961 – 2969.
- [56] RONNEBERGER O, FISCHER P, BROX T. U – Net: convolutional networks for biomedical image segmentation[C] // International Conference on Medical Image Computing and Computer-assisted Intervention. Berlin: Springer, 2015: 234 – 241.
- [57] BADRINARAYANAN V, KENDALL A, CIPOLLA R. Segnet: a deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE Trans. Pattern Anal. Mach. Intell.*, 2019, 39(12): 2481 – 2495.
- [58] GONG H, LIU T, LUO T, et al. Based on FCN and DenseNet framework for the research of rice pest identification methods[J]. *Agronomy*, 2023, 13(2): 410.
- [59] ZHANG S, ZHANG C. Modified U – Net for plant diseased leaf image segmentation[J]. *Computers and Electronics in Agriculture*, 2023, 204: 107511.
- [60] KERKECH M, HAFIANE A, CANALS R. Vine disease detection in UAV multispectral images using optimized image registration and deep learning segmentation approach[J]. *Comput. Electron. Agric.*, 2020, 174: 105446.
- [61] AFZAAL U, BHATTARAI B, PANDEYA Y R, et al. An instance segmentation model for strawberry diseases based on Mask R – CNN[J]. *Sensors*, 2021, 21(19): 6565.
- [62] GUO Y, GAO J, WANG X, et al. Precious tree pest identification with improved instance segmentation model in real complex natural environments[J]. *Forests*, 2022, 13(12): 2048.
- [63] WANG K, GOU C, DUAN Y, et al. Generative adversarial networks: introduction and outwork[J]. *IEEE/CAA Journal of Automatica Sinica*, 2017, 4(4): 588 – 598.
- [64] PU Y, GAN Z, HENAO R, et al. Variational autoencoder for deep learning of images, labels and captions[C] // Advances in Neural Information Processing Systems 29 (NIPS 2016), 2016.
- [65] GANDHI R, NIMBALKAR S, YELAMANCHILI N, et al. Plant disease detection using CNNs and GANs as an augmentative approach[C] // 2018 IEEE International Conference on Innovative Research and Development (ICIRD). IEEE, 2018: 1 – 5.
- [66] LIU Y, ZHANG X, GAO Y, et al. Improved CNN method for crop pest identification based on transfer learning[J]. *Computational Intelligence and Neuroscience*, 2022, 2022: 9709648.
- [67] ZHANG S, HUANG W, ZHANG C. Three-channel convolutional neural networks for vegetable leaf disease recognition[J]. *Cognitive Systems Research*, 2019, 53: 31 – 41.
- [68] LIU B, DING Z, TIAN L, et al. Grape leaf disease identification using improved deep convolutional neural networks[J]. *Frontiers in Plant Science*, 2020, 11: 1082.
- [69] HU Y, DENG X, LAN Y, et al. Detection of rice pests based on self-attention mechanism and multi-scale featurefusion[J]. *Insects*, 2023, 14(3): 280.
- [70] BARBEDO J G A. Factors influencing the use of deep learning for plant disease recognition[J]. *Biosystems Engineering*, 2018, 172: 84 – 91.
- [71] ZHANG Y, MA B, HU Y, et al. Accurate cotton diseases and pests detection in complex background based on an improved YOLOX model[J]. *Computers and Electronics in Agriculture*, 2022, 203: 107484.
- [72] WANG X, LIU J, LIU G. Diseases detection of occlusion and overlapping tomato leaves based on deep learning[J]. *Frontiers in Plant Science*, 2021, 12: 792244.
- [73] 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.