DOI:10.11721/cqnuj20260305

基于深度学习的农作物病害识别研究进展*

吕 佳[1,2], 李世成[1]
(1. 重庆师范大学 计算机与信息科学学院; 2. 重庆市数字农业服务工程技术研究中心, 重庆 401331)

摘要:农作物病害会严重威胁全球粮食安全,及时准确地识别病害是实现有效防控的前提。深度学习技术在病害识别领域的应用发展迅速,但系统性综述相对有限。本文旨在全面梳理基于深度学习的农作物病害识别研究进展,为相关领域的深入研究提供参考。系统回顾了基于深度学习的农作物病害识别研究相关成果,介绍了基本原理与评价指标,总结了常用数据集与预处理方法,从图像分类、目标检测和图像分割这 3 个方面详细梳理了相关工作,分析了当前面临的挑战并展望了未来研究方向。在图像分类方面,卷积神经网络与 Transformer 架构已被广泛应用于病害识别,通过引入注意力机制、多尺度特征融合及迁移学习等策略,缓解了复杂背景干扰与细粒度病害混淆问题。在目标检测方面,双阶段与单阶段算法围绕候选区域定位和边界框预测,实现了病斑位置与类别的同时判定,基于 Transformer 的检测方法进一步加强了复杂背景与密集遮挡条件下的全局关系建模。在图像分割方面,UNet 和 DeepLab 系列方法确立了分割基础框架,Transformer 与混合架构改善了不规则病斑图像的分割效果。轻量化网络设计降低了计算资源消耗,为移动端部署创造了条件。深度学习技术在农作物病害识别领域已取得显著进展,但在跨场景泛化和实时性等方面仍面临挑战。未来可从提升泛化能力、轻量化设计、多模态融合及应用转化等方向深化,推动技术实用化。

关键词:农作物病害识别;深度学习;图像分类;目标检测;图像分割
中图分类号:TP183 **文献标志码**:A **文章编号**:1672-6693(2026)03-0086-23

农作物病害是指农作物在生长发育过程中受到生物或非生物因素影响而引起的一类异常生理状态,通常表现为叶片变色、出现斑点、枯萎等症状,会严重影响农作物的正常生长,进而导致产量和品质下降,最终造成严重的经济损失[1-2]。联合国粮食及农业组织的统计数据显示,全球每年因病害造成的农作物产量损失超过 30%,经济损失更是高达 2 200 亿美元[3]。在中国,农作物病害防控形势同样严峻。根据全国农业技术推广服务中心在 2025 年的预测,当年主要粮食作物重大病害将达 1.68 亿公顷次,较 2024 年增加 6.2%[4],这就对国家粮食安全保障提出了更高要求。

及时准确地识别病害是实现有效防控的前提。病害发生早期往往症状隐蔽,不易察觉;而当病斑明显、易于辨认时,通常已进入快速扩散阶段,此时防治难度明显增加且效果有限[5]。因此,早期精准识别病害能够为及时诊断与科学防治提供依据,从而有效降低农作物的产量损失风险[6]。随着精准农业的发展,病害智能识别技术的应用对推进农业现代化、保障国家粮食安全具有重要意义[7]。发展快速、准确的病害智能识别技术,已成为提升病害防控效率、促进农业可持续发展的关键环节。

传统的农作物病害识别主要依赖人工目视诊断和实验室检测。人工目视诊断方法虽然直观,但存在效率低、主观性强、依赖专家经验等局限,难以满足大规模生产的实时监测需求[8]。实验室检测方法(如显微镜检查、酶联免疫吸附测定和聚合酶链式反应等)虽然准确度高,但需要耗时采集样本,且检查的准确性依赖于实验室设备好坏和专业人员水平高低,所以检测周期较长、成本较高,难以实现田间大规模快速筛查[9]。基于数字图像处理和传统机器学习的自动识别方法在一定程度上提高了识别效率,但这类方法依赖于手工设计的特征表示(如颜色特征、纹理特征和形状特征等),在面对复杂多变的田间环境和相似病害症状时,往往难以准确捕捉病害的判别性特征,识别准确率较低,泛化能力有限,难以满足实际生产应用的需求[10]。

随着计算机视觉技术的快速发展,深度学习方法为农作物病害的自动化识别提供了新的解决方案[11]。与传

* **收稿日期**:2026-02-03 **修回日期**:2026-04-09 **网络出版时间**:2026-05-29T09:51
资助项目:重庆市高校创新研究群体项目(No. CXQT20015);重庆市中小学创新人才培养工程项目(No. CY250504);重庆师范大学研究生科研创新项目(No. YKC26050)
第一作者简介:吕佳,女,教授,博士,研究方向为机器学习、数据挖掘及数字农业,E-mail:lvjia@cqnu.edu.cn
网络出版地址:https://link.cnki.net/urlid/50.1165.N.20260528.1703.002

统方法相比,以卷积神经网络(convolutional neural network,CNN)[12]为代表的深度学习方法能够通过端到端的学习方式,自动从原始图像中学习多层次、多尺度的特征表示,有效捕捉病害的复杂模式,并明显提升了识别精度和鲁棒性[13]。针对不同的识别粒度和应用需求,相关研究主要涵盖了图像分类、目标检测和图像分割 3 类核心任务,分别实现了从整体诊断到精准定位再到像素级精细分析的不同层次识别目标,为农作物病害的智能诊断提供了多样化的技术路径[14]。

尽管关于该领域的研究发展迅速,但系统性的综述分析仍相对有限,全面梳理和总结现有研究成果对于把握领域发展脉络、揭示研究热点与前沿趋势具有重要意义。基于此,本文系统综述了基于深度学习的农作物病害识别研究进展,首先介绍深度学习病害识别的基本原理与评价指标,然后总结领域内常用的公共数据集,继而分别从图像分类、目标检测和图像分割 3 个方面详细回顾相关研究工作,最后分析当前面临的挑战并对未来研究方向进行展望,以期为该领域的深入研究提供参考。

1　基本原理

基于深度学习的农作物病害识别通常遵循数据驱动的端到端学习范式,核心流程包括数据集构建、数据预处理、模型设计、模型训练和模型评估等环节[15],如图 1 所示。

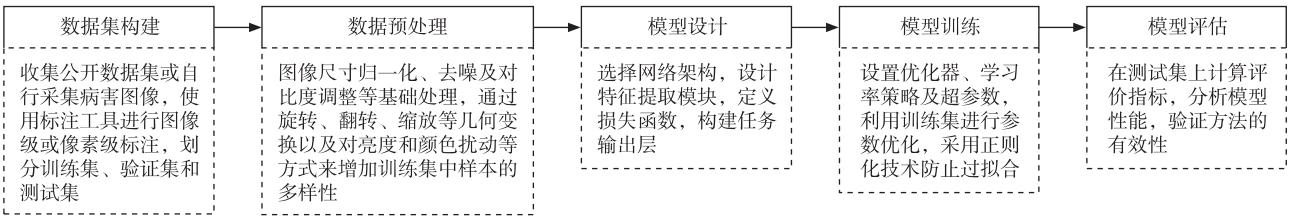

图 1　基于深度学习的农作物病害识别核心流程

Fig. 1　Core workflow of crop disease recognition based on deep learning

具体而言,深度学习模型的训练首先需要构建包含病害图像及标注信息的数据集。原始图像通常需要经过归一化处理以加速模型收敛,并通过数据增强等操作来提高模型的泛化能力。在模型训练阶段,通过反向传播算法和基于梯度的优化方法不断更新参数,使损失函数逐步收敛,从而学习到用于病害识别的判别性特征表示。训练完成后,在独立的测试集上评估模型性能。

关于农作物病害识别的研究主要涵盖了图像分类、目标检测和图像分割 3 类核心任务,尽管这 3 类任务的识别目标存在差异,但均遵循上述数据驱动的基本流程,主要区别体现在模型架构设计以及评价指标体系等方面。

1.1　任务定义

1.1.1　图像分类

图像分类任务是指对输入图像赋予预定义类别标签的过程。在农作物病害识别中,该任务旨在判定病害图像的具体类别。形式上,给定一幅农作物病害图像 I,$I\in\mathbf{R}^{H\times W\times 3}$,其中 H 和 W 分别表示图像的高度和宽度。模型需要预测此图像所属类别,即 $y\in C$,类别集合 C 由 N 个预定义类别组成,且 $C=\{c_1,c_2,\cdots,c_N\}$,通常包括健康类别以及若干种病害类别。模型输出为类别概率分布向量,即 $\boldsymbol{p}=[p_1,p_2,\cdots,p_N]$,其中 p_i 表示图像属于类别 c_i 的预测概率,满足 $\sum_{i=1}^{N}p_i=1$,最终预测类别 y 取概率最大的类别,即 $y=\arg\max_{c_i\in C}p_i$。该任务将整幅图像作为分析单元,侧重于判断农作物整体的健康状况及病害类型,适用于农作物病害的初步筛查和整体诊断场景。

1.1.2　目标检测

目标检测任务是在图像分类的基础上进一步要求对感兴趣目标的空间位置进行精确定位。在农作物病害识别中,该任务不仅需要识别图像中存在的病害类别,还需要确定每个病斑区域在图像中的具体位置。形式上,给定输入图像 I,$I\in\mathbf{R}^{H\times W\times 3}$,模型需要输出一组检测结果 $B=\{b_1,b_2,\cdots,b_M\}$,其中 M 为检测到的目标数量。每个检测框 b_j 包含 3 个要素,$b_j=(b_j^{\text{box}},c_j,s_j)$:边界框 $b_j^{\text{box}}=(x_j,y_j,w_j,h_j)$ 表示第 j 个病斑区域的空间位置,其中 x_j,y_j 取自框的中心坐标(x_j,y_j),w_j,h_j 分别为框的宽度和高度;类别标签 c_j 表示该区域的病害类型,$c_j\in C$;置信度分数 s_j 表示模型对该检测结果的确信程度,$s_j\in[0,1]$。目标检测任务通过同时输出位置和类别信息,能够实现对图像中多个病斑的精确识别与定位,适用于需要统计病斑数量、分析病害分布等精细化诊断场景。

1.1.3 图像分割

图像分割任务是在像素级别上对图像进行语义理解,旨在为每个像素分配具体的类别标签。在农作物病害识别中,该任务需要精确勾勒出病斑区域的边界轮廓,实现对病害区域的逐像素标注。形式上,给定输入图像 I,$I\in\mathbf{R}^{H\times W\times 3}$,模型需要输出预测的分割图 S,$S\in\{0,1,\cdots,N\}^{H\times W}$。分割图中每个位置的值 $S_{h,w}$ 表示该位置像素的类别标签,$h\in\{1,\cdots,H\}$,$w\in\{1,\cdots,W\}$;标签值 0 通常表示背景类别,$\{1,\cdots,N\}$表示 N 种病害类别。该任务将图像划分为若干个语义一致的区域,每个区域对应特定的病害类型或健康组织。与目标检测仅提供矩形框粗略定位相比,图像分割能够获得病斑的精确形状、面积和边界信息,适用于病害严重程度评估、病斑面积量化以及病害发展趋势分析等需要精细形态信息的应用场景。

1.2 评价指标

不同任务的性能评估侧重点有所差异。图像分类任务以准确率(accuracy)、精确率(precision)、召回率(recall)和 F1 分数(F1-score)等指标评估分类性能;目标检测任务需兼顾定位精度与分类准确性,常用交并比(intersection over union)、平均精度均值(mean average precision)等指标;图像分割任务则侧重像素级评估,主要采用像素准确率(pixel accuracy)、Dice 系数(Dice coefficient)等指标。表 1 归纳了 3 类任务常用的评价指标及计算方法。

表 1 3 类任务常用的评价指标

Tab. 1 Common evaluation metrics for the three types of tasks

评价指标	常用缩写	符号	计算公式	适用任务	说明
准确率	Acc	x_{Acc}	$\frac{N_{\mathrm{TP}}+N_{\mathrm{TN}}}{N_{\mathrm{TP}}+N_{\mathrm{TN}}+N_{\mathrm{FP}}+N_{\mathrm{FN}}}$	分类、检测	正确预测占总样本的比例
精确率	P	P	$\frac{N_{\mathrm{TP}}}{N_{\mathrm{TP}}+N_{\mathrm{FP}}}$	分类、检测、分割	预测为正类中实际为正类的比例
召回率	R	R	$\frac{N_{\mathrm{TP}}}{N_{\mathrm{TP}}+N_{\mathrm{FN}}}$	分类、检测、分割	实际正类中被正确预测的比例
$F1$ 分数	F1	$F1$	$\frac{2\times P\times R}{P+R}$	分类、检测、分割	精确率和召回率的调和平均
交并比	IoU	J	$\frac{N_{\mathrm{TP}}}{N_{\mathrm{TP}}+N_{\mathrm{FP}}+N_{\mathrm{FN}}}$	检测、分割	预测区域与真实区域的重叠程度
平均交并比	mIoU	$\overline{J}$	$\frac{1}{N}\sum_{i=0}^{N}J_i$	分割	各类别 IoU 的平均值
平均精度	AP	A	$\int_0^1 P(R)\mathrm{d}R$	检测	精确率-召回率曲线下面积
平均精度均值	mAP	$\overline{A}$	$\frac{1}{N}\sum_{i=0}^{N}A_i$	检测	多类别 AP 的平均值
像素准确率	PA	a_{pix}	$\frac{\sum_{i=0}^{N}p_{i,i}}{\sum_{i=1}^{N}\sum_{j=0}^{N}p_{i,j}}$	分割	正确分类像素占总像素的比例
平均像素准确率	mPA	$\overline{a}_{\mathrm{pix}}$	$\frac{1}{N+1}\sum_{i=0}^{N}\frac{p_{i,i}}{\sum_{j=0}^{N}p_{i,j}}$	分割	各类别像素准确率的平均值
Dice 系数	Dice	D	$\frac{2\times N_{\mathrm{TP}}}{2\times N_{\mathrm{TP}}+N_{\mathrm{FP}}+N_{\mathrm{FN}}}$	分割	预测与真实的重叠相似度

注:N_{TP},N_{TN},N_{FP},N_{FN} 分别表示真正例、真负例、假正例、假负例;$p_{i,j}$ 表示真实类别为 i,被预测为类别 j 的像素数;N 表示病害类别数。对于图像分类任务,指标基于样本级别计算;对于目标检测任务,通常以 $J\geqslant 0.5$ 为阈值来判定检测正确性;对于图像分割任务,指标在像素级别计算。

2　数据集与数据预处理

2.1　数据集

高质量、多样化的数据集是农作物病害识别研究的基础[16]。目前,该领域公开数据集根据任务类型和标注方式主要分为 3 类。图像分类数据集提供图像级的病害类别标签,其中 PlantVillage[17]是应用最广泛的基准数据集,包含多种农作物的健康与病害样本;Plant Pathology 2020 则聚焦于真实田间场景,提供了包含复杂背景及多病害混合的高质量图像,常被用于评估模型在自然环境下的识别能力。目标检测数据集包含病害目标的边界框标注,其中 PlantDoc 和 FieldPlant 这 2 个数据集均来自真实田间拍摄,前者涵盖多种农作物和病害类型,后者针对特定农作物提供了更精细的标注。图像分割数据集包含像素级的精细掩码标注,其中 PlantSeg 适用于评估模型的精细分割能力;Leaf Disease Segmentation 则聚焦于病害区域图像的二分类分割,适用于评估模型对病变区域的识别能力。表 2 列出了上述常用的农作物病害图像识别数据集的详细信息。

表 2　常用农作物病害图像识别数据集详细信息

Tab. 2　Detailed information of commonly used datasets for crop disease recognition

数据集名称	任务类型	图像数量/张	病害类别数	图像来源
PlantVillage	分类	54 303	38	实验室拍摄
Plant Pathology 2020	分类	3 642	4	田间拍摄
PlantDoc	检测	2 598	27	网络收集
FieldPlant	检测	5 170	27	田间拍摄
PlantSeg	分割	11 400	115	网络收集
Leaf Disease Segmentation	分割	588	2	田间拍摄

2.2　数据预处理

农作物病害图像在采集过程中受设备、环境等因素影响,存在尺寸不统一、数值范围有差异以及样本数量有限等问题,往往难以直接用于模型训练[18]。数据预处理则通过标准化输入格式、扩充样本多样性等方式来弥补这些不足,主要包括基础图像标准化和数据增强这 2 类技术。

基础图像标准化包括统一图像尺寸和数值归一化。尺寸统一确保批量数据能够输入神经网络,通常将图像调整为 224×224 或 256×256 等固定尺寸。归一化处理将像素值映射到统一的数值范围以加速模型收敛,常用方法包括将像素值缩放至[0,1]区间或进行零均值标准化。数据增强技术通过对原始图像施加变换生成新样本,以此扩充训练集并提高模型鲁棒性。其中:几何变换包括随机旋转、水平/垂直翻转、缩放和裁剪等操作,模拟不同拍摄角度和距离;颜色变换通过调整亮度、对比度和饱和度,模拟不同光照条件。在此基础上,引入随机噪声注入和图像模糊技术可有效增强模型对成像质量下降的抗干扰能力[19]。近些年来,被广泛应用的随机擦除、混合增强(Mixup)及剪切混合增强(CutMix)等图像混合策略,则通过模拟局部遮挡或融合多样本特征,进一步提升了模型在复杂田间场景下的泛化表现[20]。图 2 为常用数据增强方法的示例。

3　基于图像分类的农作物病害识别研究进展

准确判别病害类型是实现科学防治的前提。图像分类方法将病害图像映射为预定义的类别标签,实现对病害种类的自动识别。基于图像分类的农作物病害识别主要采用 CNN 和视觉 Transformer(vision transformer,ViT)[21-22]2 类模型,通过自动学习图像的特征表示,捕获病害的颜色、形状、纹理等判别性信息,从而实现对病害类型的准确识别。本节将从经典网络架构应用、复杂场景优化和轻量化部署 3 个方面对图像分类方法在农作物病害识别中的研究进展进行系统梳理。

3.1　经典网络架构在农作物病害分类中的应用

在农作物病害识别研究的初期,工作主要集中于验证经典网络架构在病害分类任务中的有效性。研究者广泛采用 VGGNet[23]、ResNet[24]和 ViT 等在通用视觉识别任务中已被验证有效的架构,在病害图像数据集上进行训练和评估,建立了该领域的性能基准。这些早期研究不仅验证了深度神经网络对病害图像特征学习的有效

性,也为后续的模型优化和改进奠定了基础。

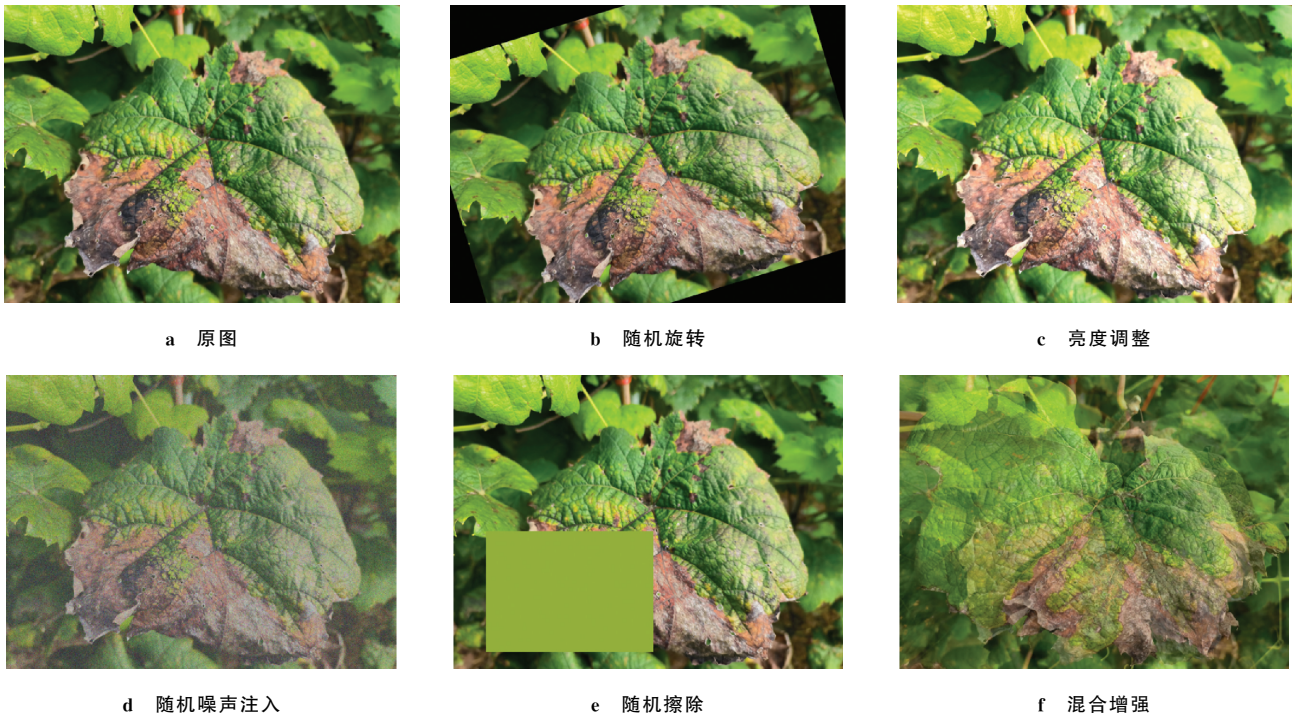

图2 常用数据增强方法的示例

Fig. 2 Examples of common data augmentation methods

作为CNN的早期代表,AlexNet被成功应用于特定农作物的病害识别研究,验证了深度学习方法的可行性[25]。Kawasaki等人[26]构建了一个黄瓜叶片病害图像数据集,利用AlexNet架构对黄瓜的2种常见病害及健康叶片进行分类,在不需要复杂预处理的情况下,模型的识别准确率达到了94.90%,证明了CNN在农作物病害特征提取上的潜力。随着网络深度的增加,VGGNet因具有规整的结构而被应用于多种农作物的病害特征提取。Rangarajan等人[27]采用VGG16模型对番茄的6种病害和1种健康叶片进行分类实验。在包含13 262张图像的数据集上,VGG16模型成功提取了病斑的关键纹理特征,最终在测试集上达到了97.29%的分类精度。ResNet的出现解决了深层网络的退化问题,迅速成为病害识别领域的主流基准模型。Upadhyay等人[28]将ResNet-50架构应用于水稻叶片病害的分类研究,针对水稻褐斑病、叶黑粉病及白叶枯病这3种常见病害进行训练。实验结果显示,凭借残差连接带来的深层特征提取能力,该模型在公开数据集上的识别准确率达到了99.70%,有效证明了深层网络在区分相似病理特征方面的优越性。DenseNet通过密集连接机制改变了特征传递的方式,也被广泛应用于农业场景[29]。Waheed等人[30]在玉米叶片病害识别研究中采用了DenseNet-121架构。该研究针对玉米的3种常见病害进行分类,所采用的DenseNet模型在保证较高参数利用率的同时,达到了98.06%的识别准确率,验证了密集连接结构在病害特征复用方面的有效性。EfficientNet系列模型通过复合缩放策略优化了网络性能,在多类病害识别中表现优异[31]。Atila等人[32]系统评估了EfficientNet架构在PlantVillage数据集上的表现,该数据集涵盖了番茄、马铃薯等14种农作物的55类病害及健康图像。实验结果表明,EfficientNet-B5模型在未进行复杂调优的情况下,能有效捕捉多种农作物的细微病斑特征,且在测试集中识别准确率高达99.91%,证明了该架构在处理大规模多类别农作物数据时的卓越性能。作为纯CNN的最新代表,ConvNeXt架构近些年来也开始被应用于病害识别任务[33]。Li等人[34]将ConvNeXt模型引入玉米病害分类中,在包含3类玉米病害和健康样本图像的数据集上进行了测试。实验表明,ConvNeXt凭借卷积的强大特征提取能力有效地捕捉到叶片的病理特征,在测试集上取得了98.81%的准确率。

除了经典的CNN架构,ViT及它的变体作为计算机视觉领域的另一类重要范式,近些年来也开始在农作物病害分类中展现出独特的应用价值。与CNN侧重于局部特征提取的归纳偏置不同,ViT架构引入了自注意力(self-attention)机制,能够从图像的全局视角直接建模像素间的长距离依赖关系,为病害特征的解析提供了全新

的维度。ViT 是将 Transformer 架构直接应用于图像识别的代表性工作。Abbas 等人[35]探讨了 ViT 在番茄叶片病害分类中的表现,在包含 10 类番茄病害及健康样本图像的数据集上,ViT 模型凭借对叶片整体形态与病斑分布的全局感知能力,实现了 97.11%的准确率,表明在数据量充足时,全局语义建模能有效辅助病害的精准判定。为了进一步融合局部与全局特征,Swin Transformer 采用了层级式构建和移位窗口(shifted window)机制[36]。这种设计既保留了 Transformer 的全局视野,又具备了类似 CNN 的多尺度特征提取能力。Demir 等人[37]将 Swin Transformer 应用于农作物病害的自动化诊断研究,针对 PlantVillage 数据集中的多种农作物病害进行了广泛测试。实验结果表明,该模型能够有效建立病斑特征与多层次上下文信息的语义关联,在复杂类别下的分类准确率达到了 99.20%,验证了层级 Transformer 架构在精细化农业视觉识别中的适用性与高效性。针对 Transformer 模型训练对数据规模的依赖,Data-efficient Image Transformers(DeiT)给出了一种基于知识蒸馏的训练策略,使得该模型在农业小样本数据上也能高效收敛[38]。Sun 等人[39]在番茄病害图像识别研究中采用了 DeiT 架构,针对番茄早疫病、晚疫病及黄化曲叶病毒病等常见病害进行了分类实验。面对病斑特征相似度高且训练样本有限的挑战,DeiT 通过引入蒸馏令牌从教师网络中提取隐性知识,有效提升了模型的特征提取效率与泛化性能,最终在 PlantVillage 数据集上实现了 98.20% 的识别准确率。此外,Pyramid Vision Transformer(PVT)优化了特征图的生成方式,采用了金字塔结构以降低计算复杂度[40]。Chang 等人[41]提出了一种基于 PVT 架构的农作物病害识别方法,并在包含多种农作物病害图像的数据集上进行了验证。该研究利用 PVT 特有的空间缩减注意力(spatial-reduction attention)机制生成多分辨率特征图,有效平衡了计算成本与细微病斑特征的保留,在测试集上的平均识别准确率达到了 93.83%,证明了 PVT 架构在农业视觉任务中具有兼顾高效性与高精度的潜力。

经典网络架构在不同农作物病害分类任务中的应用情况及性能表现总结见表 3。

表 3　经典网络架构在不同农作物病害分类任务中的应用情况及性能表现

Tab. 3　Applications and performance of classical architectures across multiple crop disease classification tasks

架构类型	参考文献	农作物	病害类型	网络架构	x_{Acc}
CNN 架构	[26]	黄瓜	花叶病毒病、褐斑病	AlexNet	94.90%
	[27]	番茄	细菌性斑点病、早疫病、晚疫病、叶霉病、斑枯病、红蜘蛛损伤、靶斑病、黄化曲叶病毒病、花叶病	VGGNet	97.29%
	[28]	水稻	褐斑病、叶黑粉病、白叶枯病	ResNet	99.70%
	[30]	玉米	灰斑病、普通锈病、北方叶枯病	DenseNet	98.06%
	[32]	多农作物	涵盖番茄、苹果、葡萄等常见农作物病害	EfficientNe	99.91%
	[34]	玉米	北方叶枯病、普通锈病、灰斑病	ConvNeXt	98.81%
Transformer 架构	[35]	番茄	细菌性斑点病、早疫病、晚疫病、叶霉病、斑枯病、红蜘蛛损伤、靶斑病、黄化曲叶病毒病、花叶病	ViT	97.11%
	[37]	多农作物	涵盖番茄、马铃薯等常见农作物病害	Swin Transformer	99.20%
	[39]	番茄	早疫病、晚疫病、黄化曲叶病毒病	DeiT	98.20%
	[41]	多农作物	涵盖水稻、小麦、卷心菜和咖啡叶等常见农作物病害	PVT	93.83%

3.2　复杂场景下的分类性能优化

经典 CNN 架构与 Transformer 架构验证了深度学习在农作物病害特征提取中的有效性,为该领域的快速发展提供了关键支撑。但在田间实际应用中,由于背景环境复杂、光照条件多变以及病害症状差异细微,直接应用通用模型往往难以达到理想的识别效果[42]。为了适应真实场景的识别需求,相关研究主要聚焦于网络结构的针对性优化设计与学习策略的改进,致力于增强模型对关键病理特征的捕捉能力,从而提升模型在复杂环境下的鲁棒性与准确率。

3.2.1　网络结构的优化设计

网络结构的优化旨在通过引入特定的功能模块或调整连接方式,强化模型对病害判别性特征的提取能力,同时抑制无关背景信息的干扰。针对田间图像背景复杂且病斑特征易被掩盖的问题,研究者通过引入注意力机

制来实现对关键特征区域的自适应聚焦。Yang等人[43]通过优化特征通道的交互策略,构建了基于改进通道注意力的aECAnet,在低计算成本下有效增强了模型对病害特征的响应能力。为了进一步挖掘多层次的病理信息,PPLC-Net被设计用于在不同特征层级上进行动态加权,利用多级注意力机制抑制田间背景噪声,从而辅助模型更精准地定位病害区域[44]。随着对识别精度要求的提升,双重注意力机制的应用展现出独特的优势。Deng等人[45]提出的DAMSLNet集成了双重注意力模块,通过同时捕捉空间与通道维度的关键特征,强化了模型对微小及多变病斑的感知能力,从而在复杂背景下实现了更高的识别准确率。

除注意力机制外,构建多尺度特征融合网络是解决病害发展不同阶段病斑尺寸差异巨大的核心策略。经典的CNN常通过改进特征金字塔或多分支结构来整合不同感受野的信息。Lin等人[46]提出的CAMFFNet模型引入多尺度特征融合模块,通过整合不同深度的特征图,有效减少了特征提取过程中的病害信息丢失,提升了模型在复杂田间环境下的分类准确率。Luo等人[47]与Liu等人[48]也分别针对苹果和玉米病害,通过在不同深度的特征图之间建立跨层连接或构建多分支结构,实现了对小病斑细节纹理与大病斑语义轮廓的同步捕捉,明显降低了误判率。

随着计算机视觉技术的发展,多尺度融合策略逐渐向跨域结合与频域分析方向演进。Zeng等人[49]较早探索了将self-attention引入CNN,并利用self-attention捕捉全局依赖的能力补充卷积的局部性。在此基础上,Zhao等人[50]与Xu等人[51]进一步构建了混合网络架构,前者结合自注意力分支捕捉长距离依赖,后者则设计了对称多尺度卷积Transformer网络,通过对称结构在多个尺度上交互的特征,实现了对复杂病害形态的精细化捕捉。此外,Panchananam等人[52]引入小波变换技术,设计了WaveletFusion模型,利用小波分解提取图像的多尺度频域特征,为病害特征的精细化表达提供了新的维度。

3.2.2 学习策略与训练机制

除了模型结构的改进,优化训练策略与学习范式也是提升复杂场景下病害识别性能的关键路径。针对实验室数据与田间数据分布不一致导致的域偏移问题,迁移学习与域适应技术被广泛采用。程超等人[53]针对苹果叶部病害识别中的跨域挑战,提出了一种基于自监督域自适应的网络框架。该方法在特征对齐的基础上引入了自监督辅助任务,通过挖掘目标域数据的内在结构信息,有效缓解了因环境差异导致的特征分布不匹配问题。为了更精确地度量分布差异,Tunio等人[54]引入Wasserstein距离进行对抗性域自适应训练,结合Transformer和CNN,明显增强了模型在不同光照和背景条件下的鲁棒性。此外,Yang等人[55]面对田间样本稀缺的挑战,提出了一种跨域小样本学习方法,通过构建元学习任务并在源域与目标域之间进行特征对齐,实现了在仅有极少量田间参考样本条件下的高精度病害识别。

损失函数的优化设计则是解决农作物病害数据中类别不平衡及相似病害混淆的有效手段。Xu等人[56]在草莓病害识别研究中引入焦点损失(focal loss)替代传统交叉熵损失,通过动态降低易分样本权重,迫使模型关注那些难以区分的病害特征,有效解决了正负样本比例失衡问题。为了进一步增强特征在特征空间中的判别力,Zhu等人[57]针对相似病害特征易混淆的难题,提出了一种嵌入Transformer的CNN模型,并引入中心损失(center loss)作为惩罚项优化训练过程。通过最小化类内特征距离并扩大类间差异,该策略有效提升了模型对外观相似病害的区分能力,在PlantVillage数据集上达到了99.62%的识别准确率。

随着自监督学习的发展,对比学习(contrastive learning)作为一种新兴范式,开始被用于提升病害特征的判别。杨新宇等人[58]提出了一种基于对比学习的农作物叶片病害识别方法,通过构造大量正负样本对进行预训练,引导模型在无标签数据中学习更具鲁棒性的特征表示,实验表明该策略能有效改善模型在复杂背景干扰下的特征聚类效果,优于传统的监督学习方法。

近些年来针对不同复杂农业场景所提出的优化策略及优化效果的相关研究归纳见表4。

3.3 轻量化网络设计与移动端部署

农作物病害的自动化识别在实际应用中需要部署于移动设备或边缘计算平台,这类设备的算力与存储资源受限,对模型的计算效率与参数规模提出了严格约束。为满足实时诊断与便携部署的需求,研究者主要通过网络结构优化与模型压缩技术,构建兼具高识别精度与低计算开销的轻量化模型。

针对经典轻量化架构的优化是当前的主流研究方向。Zhu等人[59]在玉米病害识别任务中,提出了一种改进的MC-ShuffleNetV2模型,通过引入混合通道注意力机制并优化ShuffleNetV2的通道混洗操作,在保持极低参数量的同时提升了特征提取的有效性。针对特定农作物特征的挖掘,黄铝文等人[60]构建了一种融合二维离散小

波变换与 MobileNetV3 的轻量级网络,利用小波变换在频域上的稀疏表示特性,有效降低了冗余信息的干扰,实现了对茶叶病害的高效识别。

表 4　针对不同复杂农业场景所提出的优化策略及优化效果

Tab. 4　Optimization strategies and their effects for different complex agricultural scenarios

面向场景	核心方法	参考文献	优化效果
复杂背景干扰	改进通道注意力	[43]	增强通道特征敏感度,降低背景噪声干扰
	多级注意力机制	[44]	通过多层级动态加权实现病斑精准定位
	双重注意力机制	[45]	强化空间与通道特征捕捉,提升微小病斑识别率
病斑尺寸差异大	多尺度特征融合	[46]	融合多深度特征,减少病害关键信息丢失
	跨层连接与多分支	[47]	保留小病斑细节与大病斑语义,降低误判
病斑形态复杂	自注意力与卷积融合	[49]	补充卷积局部性不足,捕捉全局依赖
	对称多尺度卷积 Transformer	[51]	多尺度特征交互,精细化捕捉复杂形态
	小波变换融合	[52]	提取多尺度频域特征,增强决策透明度
跨域分布不一致	自监督域自适应	[53]	利用自监督信号辅助特征对齐,提升跨域鲁棒性
	对抗性域自适应	[54]	精确度量分布差异,增强复杂条件鲁棒性
田间样本稀缺	跨域小样本学习	[55]	通过元学习与特征对齐实现少样本高精度识别
类别不平衡	Focal Loss	[56]	增加难分样本权重,缓解正负样本失衡问题
相似病害混淆	Center Loss	[57]	最小化类内距离,增强特征空间的判别紧凑性
特征判别力不足	对比学习	[58]	利用无标签数据增强特征在复杂背景下的聚类能力

除了对现有架构的微调,在探索新型轻量化设计范式方面也取得了进展。Feng 等人[61]提出了一种各向同性轻量化 CNN,摒弃了复杂的下采样与多分支结构,仅通过堆叠简单的各向同性模块便实现了优异的性能,极大地降低了模型部署的工程难度。Pal 等人[62]则进一步关注了轻量化模型的可信度,设计了一种兼具高效性与可解释性的 CNN 模型,在实现快速病害诊断的同时,利用类激活映射技术可视化病斑关注区域,为移动端应用提供了直观的决策依据。

在模型压缩方面,知识蒸馏技术成为进一步缩减模型体积的关键手段。Zhang 等人[63]提出了一种融合张量特征与知识蒸馏的病害识别方法,通过构建高性能的教师网络引导轻量级学生进行网络训练,使小模型能够模仿大模型的特征分布。实验表明,该策略在大幅减少模型参数与计算开销的情况下,依然保持了与大型网络相当的识别精度,为资源受限场景下的病害智能诊断提供了高效的解决方案。

3.4　小结与对比

总体来看,基于图像分类的农作物病害识别研究经历了从经典网络架构应用到复杂田间场景优化,再到轻量化部署探索的发展过程。经典模型为病害分类提供了较稳定的特征提取基础,在公开数据集上取得了较高识别精度,但对复杂背景、光照变化和相似病害细粒度差异的适应性仍有限。围绕真实田间环境开展的注意力机制、多尺度特征融合、迁移学习、域适应和对比学习等研究,进一步提升了模型对关键病理特征的表达能力,但这类方法往往对数据质量与训练策略较为敏感,模型复杂度也随之增加。轻量化设计则提高了移动端和边缘设备部署的可行性,但在计算开销受限条件下,模型对复杂背景、小病斑和细微差异特征的表征能力仍容易下降。这也说明,基于图像分类的农作物病害识别研究虽然在受控条件下已取得较好进展,但在真实农业场景中,面对跨地域环境变化、复杂背景干扰以及相似病害的细粒度识别需求时,仍难以同时兼顾模型鲁棒性、识别精度与部署效率。

4　基于目标检测的农作物病害识别研究进展

在农作物病害的智能诊断体系中,图像分类任务主要关注整幅图像的类别判定,而目标检测则进一步实现了对病害区域的定位与病斑范围的初步判断。与依赖手工特征的传统检测方法不同,基于深度学习的目标检测算法采用端到端的特征学习方式,能够自动提取病斑的高层语义特征并回归空间坐标,有效提升了在复杂田间

环境下的检测鲁棒性。

当前,基于深度学习的目标检测算法已成为精准农业领域的研究热点。根据参考文献[64]并结合相关研究进展整理绘制了图3,可以看出,该领域的发展历程经历了从早期的R-CNN系列[65]到YOLO系列[66],再到近些年来基于Transformer的检测范式的演进。根据模型架构与检测流程的差异,现有主流算法通常被划分为双阶段、单阶段以及基于Transformer的目标检测算法3类。其中,双阶段目标检测算法以R-CNN系列为代表,通过引入区域生成网络(regional proposal network,RPN)生成高质量候选框,优先保障检测精度;单阶段目标检测算法以YOLO和SSD系列[67]为代表,摒弃了候选框生成步骤,直接对目标进行密集预测,在推理速度与实时性方面占据优势;而基于Transformer的目标检测算法则通过引入自注意力机制,摆脱了对先验框的依赖,为解决密集遮挡下的病害检测提供了新的解决思路。

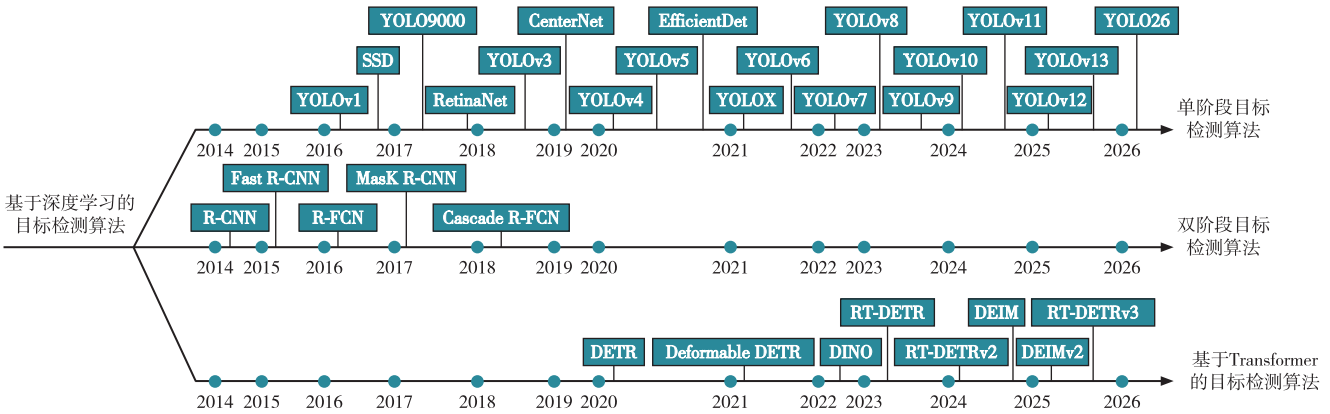

图3 基于深度学习的目标检测算法发展历程

Fig. 3 Development of deep learning object detection algorithms

4.1 双阶段目标检测算法的研究与应用

双阶段目标检测算法主要通过RPN生成候选框,随后对候选区域进行分类与回归,其中具有代表性的算法包括Faster R-CNN[68]和Mask R-CNN[69]。由于该算法采用了先提取后精修的策略,在处理背景复杂或目标密集的农业场景时,通常能表现出较高的检测精度。

Faster R-CNN作为该领域的经典架构,被广泛应用于各类作物的病害检测研究中。针对早期病害特征不明显的问题,Bari等人[70]构建了一种基于Faster R-CNN的实时诊断框架,通过优化RPN网络的参数设置,实现了对水稻叶片病害的高精度识别。为了进一步提升模型对细微病斑的特征提取能力,Zhang等人[71]提出了一种多特征融合的Faster R-CNN模型,通过引入多层特征金字塔结构,整合了深层语义信息与浅层纹理细节,有效改善了对大豆叶片病害的检测效果。在此基础上,Gong等人[72]针对苹果叶片病害检测,设计了一种改进的特征提取网络,通过引入注意力机制强化了模型对病斑区域的关注度,在复杂自然背景下实现了高精度的病害定位。

针对不同农作物生长环境的特殊性,研究者们对Faster R-CNN进行了针对性改良。He等人[73]提出的MFaster R-CNN模型,通过改进卷积层的连接方式,增强了对玉米叶片病害的多尺度感知能力。邓炜航等人[74]在马铃薯病害检测中引入了可变形卷积,以适应病斑形态的不规则变化,有效降低了漏检率。此外,谢家兴等人[75]针对荔枝病虫害检测中存在的遮挡与光照干扰问题,通过优化非极大值抑制(non-maximum suppression,NMS)算法,提升了模型在密集果园环境下的检测鲁棒性。李子茂等人[76]则将深度学习应用于月季多叶片场景,验证了Faster R-CNN在复杂背景下对多目标病虫害的并发检测能力。

Mask R-CNN在Faster R-CNN的基础上增加了掩码预测分支,虽然主要用于实例分割,但是引入的RoI Align机制也能有效提升目标检测的定位精度。Li等人[77]结合小波变换与Mask R-CNN,构建了F-RNet模型,利用频域信息增强了对微小病虫害症状的识别能力。王金星等人[78]在有关苹果园害虫识别的研究中,利用Mask R-CNN的多任务损失函数辅助检测分支训练,有效解决了害虫与背景颜色相近而产生的误检难题。为了满足实时处理需求,Rehman等人[79]提出了一种并行处理框架,通过迁移学习优化Mask R-CNN的特征提取网络,实现了苹果叶片病害的快速诊断。Bondre等人[80]进一步探讨了Mask R-CNN在多种农作物病害识别中的通用性,验证了该模型的多任务架构能够通过引入像素级监督信号,辅助主干网络提取更精细的病理特征,从

而提供比传统检测模型更高置信度的病害定位结果,适用于需要精细化管理的农业场景。

虽然上述双阶段目标检测算法在农作物病害识别领域已经取得了较好的研究进展,并且验证了深度学习方法的有效性,但是两步式的检测流程不可避免地带来了较高的计算开销与推理延迟。传统的 Faster R-CNN 与 Mask R-CNN 等模型参数量庞大,难以满足现代智慧农业对实时监测及移动端部署的应用需求。为了解决计算效率瓶颈,兼顾检测速度与精度的单阶段目标检测算法逐渐成为该领域的研究主流。

4.2　单阶段目标检测算法的研究与应用

单阶段目标检测算法省略了候选区域生成步骤,直接在特征图上进行密集的类别划分与边界框回归,从而大幅提高了检测效率。该类算法中,除了主流的 YOLO 系列外,SSD 与 RetinaNet 也是该领域的代表性算法,被广泛应用于各类农作物病害的实时监测研究中[81]。

SSD 算法利用多尺度特征图进行检测,能够兼顾不同大小病斑的识别需求。针对移动端部署对模型体积的限制,Sun 等人[82]在苹果叶片病害检测中提出了 MEAN-SSD 模型,利用轻量化卷积模块替换传统骨干网络,在保证实时性的同时,实现了对苹果斑点落叶病等病害的高效识别。李大华等人[83]针对柑橘病害检测,构建了一种基于改进 SSD 的轻量化模型,通过引入深度可分离卷积并优化特征金字塔结构,有效降低了计算量,使该模型适用于柑橘果园的便携式检测设备。此外,为了进一步提升 SSD 对复杂背景下小目标病斑的特征提取能力,Tian 等人[84]提出了 VMF-SSD 算法,设计了一种基于视觉空间的特征融合模块,明显增强了模型对苹果叶片细微病变的定位精度。Guo 等人[85]在棉花病害检测中也采用改进的 SSD 架构,通过优化先验框的尺度设置,提升了模型对棉花叶斑病等不规则病斑的适应性。

RetinaNet 算法则通过引入焦点损失函数,有效解决了单阶段检测中正负样本比例严重失衡的问题。Bao 等人[86]针对茶叶病害识别提出了 AX-RetinaNet 模型,该模型在 RetinaNet 骨干中嵌入了注意力机制,通过自适应加权抑制背景噪声,明显提升了茶饼病、茶炭疽病等常见病害的检测准确率。Sankareshwaran 等人[87]进一步将元启发式优化算法与 AX-RetinaNet 相结合,用于水稻病害检测,通过优化超参数配置,使模型在处理多变光照和复杂田间背景时表现出更强的鲁棒性。

尽管 SSD 和 RetinaNet 在一定程度上平衡了检测速度与精度,但随着农业场景对实时推理性能与跨场景泛化能力的要求不断提升,这 2 类算法架构的局限性日益凸显。相比之下,YOLO 系列算法凭借持续的架构优化与良好的工程实践能力,逐渐成为单阶段目标检测领域的主流方法。

YOLO 系列算法的核心思想是将目标检测任务转化为回归问题,通过单一神经网络直接实现从图像像素到边界框坐标与类别概率的端到端预测。该类算法将输入图像划分为若干网格单元,每个单元独立负责预测目标的位置与类别,从而省去了复杂的区域候选生成步骤。这种设计在大幅降低计算复杂度的同时,明显提升了模型的推理速度与全局感知能力。YOLO 系列算法通过持续的架构迭代,在特征提取效率、多尺度融合机制及损失函数设计等方面不断优化,在农作物病害检测领域得到了广泛应用。

YOLOv3 作为该系列的经典版本,奠定了单阶段检测在农业领域的应用基础。Liu 等人[88]针对番茄灰斑病的早期识别,提出了一种基于 MobileNetv2 替换 YOLOv3 骨干网络的轻量化模型,在保证检测精度的同时,大幅降低了模型参数量,使模型更适于移动端部署。针对复杂自然环境下多尺度目标的感知难题,另一项关于番茄病害的研究则采用了密集连接结构对 YOLOv3 进行优化,通过增强特征传递效率,有效提升了模型在不同光照与背景条件下的检测鲁棒性[89]。

随着 YOLOv5 的发布,灵活的模型缩放策略使之成为近些年来应用最为广泛的基准模型。针对蔬菜病害检测中存在的漏检问题,Li 等人[90]提出了一种改进的 YOLOv5 模型,通过引入注意力机制与多尺度特征融合,有效提升了模型对细微病斑的感知能力。在特定作物场景下,郑争兵等人[91]针对柑橘叶片病害中的小目标检测难题,设计了一种结合坐标注意力机制的改进 YOLOv5 模型,有效改善了对早期微小病斑的定位精度。为了适应资源受限的硬件环境,侯鹏飞等人[92]基于 YOLOv5n 构建了轻量化的辣椒病害检测模型,通过剪枝与结构重参数化技术,在保持高精度的同时实现了极致的推理速度。此外,Dai 等人[93]在马铃薯病害识别中引入了混合数据增强策略与压缩激活机制,进一步增强了模型在数据稀缺条件下的泛化性能。

YOLOv8 引入了 Anchor-free 检测头与 C2f 模块,进一步推高了检测性能的上限。侯文慧等人[94]针对番茄叶片病害图像模糊的问题,创新性地结合了超分辨率增强技术与改进 YOLOv8 算法,通过重建低分辨率图像细节,实现了对模糊病斑的高精度检测。Chen 等人[95]则提出了一种名为 YOLOv8-ACCW 的轻量级葡萄叶片病

害检测方法,利用自适应上下文卷积加权模块优化特征提取过程,有效平衡了检测速度与精度。甄元元等人[96]也基于YOLOv8对葡萄病害进行了深入研究,验证了该架构在复杂果园背景下的优越表现。

YOLOv11架构在推理效率与特征表征能力上实现了进一步提升,在精细化病害诊断任务中应用效果良好。Zhang等人[97]构建了ESM-YOLOv11框架,不仅实现了花生叶斑病的实时检测,还通过引入严重度量化模块,完成了对病害发生程度的精准评估。Tang等人[98]针对番茄早疫病的分级检测需求,设计了YOLOv11-AIU轻量化模型,在保证分级准确率的同时大幅降低了计算成本。此外,He等人[99]提出的YOLOv11-RCDWD模型与曾昆峰等人[100]构建的轻量化茶叶病害检测模型,均展示了YOLOv11在玉米与茶叶等大田农作物检测中的高效性与适用性。

上述YOLO系列算法在农作物病害检测任务中的研究进展总结见表5。

表5 YOLO系列算法在农作物病害检测任务中的研究进展

Tab. 5 Research progress of YOLO series algorithms in crop disease detection

文献年份	农作物	参考文献	基础模型	改进方法
2020	番茄	[88]	YOLOv3	MobileNetv2替换骨干网络,引入深度可分离卷积降低参数量
2020	番茄	[89]	YOLOv3	引入DenseNet密集连接结构,优化多尺度预测分支
2022	蔬菜	[90]	YOLOv5	引入CBAM注意力机制抑制背景,改进PANet结构增强小目标融合
2025	柑橘	[91]	YOLOv5	嵌入坐标注意力模块,设计微小目标检测层
2025	辣椒	[92]	YOLOv5	结合Ghost模块进行模型剪枝,利用结构重参数化加速推理
2022	马铃薯	[93]	YOLOv5	采用混合数据增强策略,引入压缩激活机制优化通道权重
2025	番茄	[94]	YOLOv8	融合超分辨率重建网络,利用GAN生成细节增强特征
2024	葡萄	[95]	YOLOv8	设计自适应上下文卷积加权模块,替换C2f以减少冗余计算
2025	花生	[96]	YOLOv11	集成ESM严重度量化模块,构建检测与分级联合任务分支
2025	番茄	[97]	YOLOv11	设计AIU轻量化上采样算子,优化检测头以适应多级病害分类
2025	玉米	[98]	YOLOv11	引入RCDWD密集连接模块,增强特征复用与梯度传播效率
2025	茶叶	[99]	YOLOv11	采用轻量化GSConv卷积,结合Slim-neck架构降低计算复杂度

4.3 基于Transformer的目标检测算法的研究与应用

尽管以CNN为基础的检测算法在农业领域取得了广泛应用,但受限于卷积操作的局部感受野,在处理密集遮挡或大尺度病斑时往往难以捕捉全局上下文信息。近些年来,以DETR[101]为代表的Transformer架构通过引入自注意力机制,实现了从图像到目标集合的端到端预测,为解决复杂农业场景下的病害检测难题提供了新的范式。

针对原始DETR模型收敛速度慢及小目标检测精度低的问题,研究者重点探索了多尺度特征融合与结构优化策略。Yang等人[102]在水稻叶片病害检测中构建了一种改进的检测Transformer,通过引入多尺度注意力模块,增强了模型对稻瘟病等细微病斑的感知能力。Song等人[103]提出的ADAM-DETR模型进一步设计了自适应特征融合机制,通过动态调整不同层级的特征权重,有效解决了水稻病害检测中因病斑尺度变化剧烈导致的漏检问题。

为了克服Transformer计算复杂度高、推理延迟大的瓶颈,RT-DETR[104]成为当前该领域的研究热点,此模型在保持全局建模优势的同时,还实现了实时检测。针对柑橘黄龙病的早期识别问题,Huangfu等人[105]提出了HHS-RT-DETR方法,利用混合编码器增强特征表达,明显提升了模型在自然果园环境下的鲁棒性。Sun等人[106]在茄子病虫害检测中引入改进的RT-DETR,通过优化注意力机制与匹配策略,有效应对了复杂田间背景下的目标混淆难题。在葡萄与番茄病害检测方面,林文庆等人[107]与刘慧等人[108]分别针对RT-DETR进行了轻量化改进,通过剪枝与结构重组,在保证精度的前提下大幅降低了模型参数量,使模型更适于移动端部署。Bian等人[109]则进一步结合多尺度特征融合技术,提升了RT-DETR在番茄叶片复杂背景下的抗干扰能力。

作为Transformer检测范式的最新演进,基于DINO[110]与DEIM[111]架构的研究展示了在特征去噪与早期微小病害识别方面的潜力。Li等人[112]提出的PL-DINO模型利用去噪锚框训练策略,增强了模型对农作物叶片

病害特征判别的稳定性,在多种农作物数据集上取得了优于传统 CNN 的效果。Shen 等人[113]则针对松材线虫病的早期监测,构建了基于 DEIM 的轻量化检测框架 LE-PWDNet,通过强化特征交互与精细化定位能力,实现了对早期微小病变的高精度捕捉。

4.4　小结与对比

不同目标检测算法在检测精度、推理速度和场景适应性等方面表现出不同特点。双阶段方法更强调病斑定位精度,在复杂背景、遮挡较强和病斑边界不清晰的场景中表现较为稳定,为农业病害检测提供了重要基础,但模型结构较复杂,计算开销和推理延迟较大。随着田间实时监测需求的增强,研究重点逐渐转向以 YOLO 系列为代表的单阶段方法,这类方法在检测速度和实时性方面更具优势,更适用于田间快速监测和移动端部署,但在小病斑、密集病斑和复杂背景条件下仍较易出现漏检和误检。近些年来,基于 Transformer 的检测方法在全局上下文信息建模和密集遮挡场景处理中展现出较大潜力,但对训练数据、计算资源和模型优化策略的要求更高。整体而言,相关研究已有效提升了农作物病害目标检测的定位与诊断能力,但在真实农业场景下,对小目标病斑的稳定识别、复杂背景干扰的有效抑制以及实时部署能力仍有待进一步提升。

5　基于图像分割的农作物病害识别研究进展

在农作物病害的智能诊断体系中,图像分割技术通过对图像进行像素级的类别判定,能够精确勾勒出病害区域的形态边界与空间分布,为病情程度的量化评估、病斑面积的精准测算以及施药区域的精细化定位提供了更加细粒度的技术支撑[114]。与以边界框形式标注病害位置的检测任务不同,分割任务关注的是图像中病斑的真实轮廓与像素级归属,这种精细化的表征方式更适用于需要准确评估病害侵染范围、计算叶片受损比例或进行变量喷施等应用需求[115]。

传统的图像分割方法主要依赖于颜色空间变换、边缘检测与阈值分割等手工特征设计策略,但在面对光照变化、叶片遮挡以及病斑与背景颜色相近等复杂田间环境时,这类方法的适用性较为有限[116]。深度学习技术的发展为农作物病害图像分割任务带来了新的解决方案。基于 CNN 的分割模型通过端到端的特征学习方式,能够自动提取病斑的多层次语义特征并实现像素级的精准分类,明显提升了分割算法在复杂场景下的鲁棒性与泛化能力[117]。

当前,基于深度学习的图像分割算法在农作物病害识别领域已积累了丰富的研究成果。早期研究主要集中于基于 CNN 的分割方法,通过编码器—解码器结构与多尺度特征融合机制实现病斑图像的精确分割,并针对农作物图像的特殊性进行了系列改进。随着 Transformer 架构在计算机视觉领域的成功应用,研究者们开始探索将自注意力机制引入分割模型,以增强模型对全局上下文信息的捕获能力,这类混合架构方法为解决病斑形态不规则、背景干扰复杂等挑战提供了新的技术路径。近些年来,轻量化网络设计致力于提升模型计算效率以满足移动端与边缘计算平台的部署需求,因此受到了广泛关注。此外,基于新型特征表示或计算范式的分割方法也逐渐应用于该领域,为农作物病害图像分割提供了更多技术选择。

5.1　基于 CNN 的分割方法

基于 CNN 的分割方法通过端到端的特征学习方式,实现了对农作物病害区域的像素级精准识别。这类方法以编码器—解码器结构为主流架构,通过逐层下采样提取高层语义特征,再经由上采样路径恢复空间分辨率,从而获得与输入图像尺寸相等的分割结果。根据网络架构设计的差异,当前研究主要集中于以 UNet[118]为代表的对称式编解码网络以及基于 DeepLab 系列[119]的空洞卷积金字塔结构这 2 类方法。

UNet 凭借编码器—解码器对称结构与跳跃连接机制,能够有效融合浅层纹理细节与深层语义信息,在农作物病害图像分割任务中得到了广泛应用。针对复杂背景下病斑边缘模糊与小目标检测困难等问题,研究者对 UNet 架构进行了多方面改进。Wang 等人[120]提出的 RAAWC-UNet 通过引入残差注意力模块与空洞空间金字塔池化,结合权重压缩损失函数,有效解决了前景背景像素比例失衡问题。在葡萄黑腐病和水稻叶瘟病的图像分割研究中,茹佳棋等人[121]和邓阳君等人[122]分别提出了改进的 UNet++与 VCDM-UNet 模型,前者通过重新设计跳跃连接结构并融合多尺度特征降低了计算复杂度,后者则将 VGG16 作为骨干网络并引入坐标注意力机制,明显提升了对不规则病斑图像的分割精度。Singh 等人[123]的研究进一步表明,通过合理应用 Dropout、批归一化等正则化技术,标准 UNet 架构也能在叶片病害图像分割任务中表现出较强的泛化能力。

DeepLab 系列算法通过引入空洞卷积与空间金字塔池化机制,在保持计算效率的同时实现了多尺度上下文

信息的聚合。针对黄瓜病害严重程度评估,Li 等人[124]在 DeepLabV3+的空洞空间金字塔池化模块中嵌入混合注意力机制,自适应调整不同尺度特征的权重分配,实现了病害严重程度的自动估计。Zhu 等人[125]则针对复杂场景下苹果叶片病害设计了双阶段 DeepLabV3+架构,首先通过引入感受野模块和反向注意力模块的网络从复杂环境中提取叶片,随后利用调整了空洞卷积率的网络对病斑图像进行精细分割,并提出自适应损失函数以平衡不同病斑尺度下的图像分割误差,该方法在光照变化与叶片遮挡场景下表现出较强的鲁棒性。

除了上述主流架构以外,其他 CNN 分割方法在病害识别中同样具有良好表现。Yuan 等人[126]提出的 DSCA-PSPNet 在金字塔场景解析网络基础上引入了动态空间-通道注意力模块,通过联合建模空间位置与特征通道间的依赖关系,有效抑制了背景杂草与土壤的干扰,提升了复杂环境下的分割精度。Saleem 等人[127]针对芒果叶片病害提出的全卷积网络 FrCNnet,通过直接学习像素级特征实现了 99.2%的分割准确率。Nibret 等人[128]则采用 SegNet 语义分割架构实现了芝麻叶片从背景中的图像分割,通过中值滤波与对比度拉伸等预处理技术增强了图像质量,为后续的病害像素级分类奠定了基础。

5.2 基于 Transformer 与混合架构的分割方法

CNN 在局部特征提取方面具有明显优势,但在处理背景高度相似或形态极度不规则的病斑时,受限于有限的感受野,往往难以捕获全局上下文信息。近些年来,Transformer 架构凭借强大的长距离依赖建模能力,为农作物病害图像的精准解析提供了新的技术路径。为了兼顾局部纹理细节与全局语义信息的提取,研究者们通过构建 CNN 与 Transformer 的混合架构,或针对农业场景特征对 Transformer 结构进行定制化改进,有效弥补了单一架构的局限性。

在架构融合的探索中,如何实现 2 种特征的深度协同是研究的核心问题。Yan 等人[129]针对棉花叶片图像分割提出了一种复合骨干架构(CoAtNet),通过并行整合 Swin Transformer 的长程建模能力与 CNN 的空间特征提取,有效改善了对细长叶柄等微小结构的识别精度。Fang 等人[130]则进一步构建了双向注意力融合网络(BAF-Net),利用双向交互机制引导空间与语义特征在层级间进行动态校准,在辣椒病斑图像分割中实现了位置与形态的精准对应。此外,Gangwar 等人[131]将 Transformer 引入 DeepLabV3+,设计了 TransDeepLab,不仅在番茄病害图像分割上表现稳健,还将该架构延伸至严重程度分级与产量损失估算,验证了混合架构在全流程智慧农业诊断中的应用价值。

针对病斑边缘模糊、尺度差异大等问题,一系列更具针对性的模块化方案被相继提出。考虑到病斑边缘往往承载重要的病理信息,吕佳等人[132]在葡萄病害图像分割中提出了一种多尺度交叉融合解码器,设计了 MCBNet,通过专门的边缘分支与多尺度交叉融合机制,提升了对病变区域轮廓的图像分割精度。针对病斑尺寸分布不均的问题,Zhang 等人[133]提出了跨分辨率 Transformer(CRFormer),利用跨分辨率自注意力机制实现不同尺度特征的深度挖掘,有效改善了对小病斑的检测性能。在水稻病害图像分割中,Dai 等人[134]则通过改进的人工免疫系统优化算法对网络超参数进行自动化优化,进一步提升了模型对细微点状病斑的识别效率。

此外,为了实现从实验室研究到真实生产环境的有效迁移,研究者们开始关注模型在复杂田间背景下的鲁棒性与泛化能力。Yang 等人[135]针对番茄病害图像分割提出了融合对抗网络 FATDNet,利用对抗学习机制增强模型对杂草、地膜等干扰信号的抑制能力,使分割结果在极端光照和遮挡环境下保持稳定。针对高质量标注数据获取困难的问题,Wang 等人[136]提出了 CRE 模型,采用自监督预训练策略,通过在大规模通用植物感染数据集上进行掩码图像建模,使模型在无标注阶段即可学习普适的植物生理结构特征,降低了下游分割任务对标注样本的依赖。这些研究推动了基于 Transformer 的分割技术向更精准、更稳健、更易于实际部署的方向发展。

5.3 轻量化与新型架构的探索

为了满足农作物病害自动诊断在移动设备与边缘计算平台的部署需求,研究者在提升模型精度的同时,持续探索降低计算复杂度的有效途径。与此同时,频域特征利用、状态空间模型以及通用模型迁移等新型建模范式也逐渐应用于农作物病害图像分割任务,为解决现有方法在复杂场景下的局限性提供了新的技术手段。

在轻量化设计方面,为满足移动设备的算力限制,Zhang 等人[137]提出了 UPFormer 模型,通过 U 型感知结构优化 Transformer 的计算流程,在保证田间葡萄叶片病害图像分割精度的前提下降低了参数量与推理时间。Li 等人[138]则通过改进 DeepLabV3+架构,利用轻量化骨干网络实现了水稻叶斑病图像的快速分割。为了进一步支持精准的农作物病害实时监测,Zhao 等人[139]与 Safran 等人[140]分别探索了面向自然场景的实时分割网络,通过优化网络结构实现了对病害严重程度的快速估计。

频域特征的引入为复杂背景下的病害识别提供了新的视角。传统空间域方法在处理高频噪声或细节纹理时存在一定局限，而频域分析能够有效分离不同频率成分的图像特征。Xiang 等人[141]提出了 DWTFormer 架构，利用离散小波变换将频域与空间域特征进行深度融合，增强了对番茄病害特征的表征能力。类似地，Li 等人[142]设计的 FA-Unet 通过集成频域特征提取模块，提升了果树叶片病害识别的准确性。此外，研究表明在频域空间进行特征表征能够增强模型在小样本场景下的泛化能力。

近期，以 Mamba 为代表的状态空间模型因线性计算复杂度和长程依赖建模能力，开始被应用于计算机视觉领域[143]。Zhang 等人[144]提出了首个专门用于葡萄叶片病害图像分割的 Mamba 架构即 GMamba，通过设计 Co-SSM 模块，将 SSM 的全局扫描能力与卷积的局部特征提取相结合，在黑腐病等细微病斑的识别上表现出色，同时避免了 Transformer 自注意力机制计算量大的问题。Anandhajothi 等人[145]构建了 Vision Mamba-TDL-Seg 框架，通过高效的全局建模实现了对植物病害诊断与扩散趋势的估计。

此外，通用模型在农业场景中的适配应用也成为研究方向之一。Li 等人[146]提出的 EMSAM 通过对 Segment Anything Model(SAM)[147]进行多尺度增强，改善了原模型在处理多尺度、细微叶片病斑图像时的分割效果，提升了模型在复杂背景下的零样本分割性能。这些技术的应用，不仅提升了农作物病害识别的精度与效率，也为构建适用于田间环境的实时诊断系统提供了技术支撑。

5.4　小结与对比

表 6 总结了当前农作物病害识别中典型的深度学习分割方法及应用局限。综合现有研究，不同类型的病害图像分割方法在病斑边界刻画、复杂背景适应和计算开销等方面表现出不同特点。以 UNet 和 DeepLab 系列为代表的 CNN 方法在病斑区域提取和像素级识别方面较为成熟，为后续研究提供了稳定基础，但在病斑边缘模糊、形态不规则和小病斑分散等场景下，仍容易受到复杂背景干扰。Transformer 及混合架构增强了对全局上下文信息的利用，在复杂背景下的不规则病斑图像分割和边界优化方面表现出更大潜力，但对标注数据、训练成本和计算资源的要求也更高。轻量化设计以及频域特征、状态空间模型和通用模型迁移等方法，则进一步拓展了病害图像分割在移动端部署和跨场景应用中的可能性，但在资源受限条件下，病斑边界细节保留、分割稳定性以及对不同农作物和成像条件的适应能力仍有不足。总体上，现有研究已提高了病害区域图像分割的精细程度，但像素级标注成本较高、病斑与健康组织过渡不清、复杂田间背景干扰较强以及分割结果与病情量化评估和精准施药等实际环节衔接不足，仍是当前应用中需要解决的问题。

6　总结与展望

本文系统回顾了基于深度学习的农作物病害识别研究进展，分析了从图像分类、目标检测到图像分割三大核心任务的技术演变与应用现状。总体而言，深度学习技术凭借端到端的特征学习能力，在鲁棒性与泛化性方面较传统手工特征提取方法有所改进，为农作物病害的智能诊断提供了技术支撑。

针对病害种类的识别判定需求，经典的 CNN 与新兴的 Transformer 架构已形成较为完善的分类框架。相关研究通过引入注意力机制、多尺度特征融合以及迁移学习策略，在一定程度上缓解了复杂背景干扰、细粒度病害混淆及小样本训练等问题。而在病害位置的精准定位与计数方面，以 YOLO 系列为代表的单阶段算法与以 Faster R-CNN 为代表的双阶段算法，在检测速度与精度之间形成了不同的权衡方案，基于 Transformer 的端到端检测范式则为解决密集遮挡与长距离语义依赖问题提供了新的技术路径。针对病害区域像素级分割的需求，以 UNet 和 DeepLab 系列为代表的 CNN，通过编码器—解码器结构与空洞空间金字塔池化机制，确立了分割任务的基础框架。随后的研究引入 Transformer 架构与混合注意力模型，利用长距离依赖建模能力，改善了对复杂背景下不规则病斑及细微边缘的分割效果，为病害严重程度的量化评估提供了技术支撑。此外，针对农业应用场景的部署需求，轻量化网络设计与模型压缩技术的应用，降低了深度学习模型的计算资源消耗，为移动端与边缘计算设备的实际部署创造了条件。

尽管当前研究在特定数据集与实验条件下已取得一定进展，但综合前文分析可以看出，现阶段基于深度学习的农作物病害识别主要面临以下几方面问题：复杂田间环境下的跨场景泛化能力不足，资源受限条件下的轻量化部署与实时应用仍受限制，高质量标注数据尤其像素级标注获取成本较高，单一可见光图像对病害早期识别和复杂症状判别的信息支撑有限，以及现有研究与区域农业生产场景的结合仍不够紧密。围绕上述问题，未来可从以下几个方面进一步推进：

表6 农作物病害识别中典型的深度学习分割方法及局限性

Tab. 6 Typical deep learning segmentation methods and their limitations in crop disease recognition

方法类型	代表性方法	解决的问题	局限与挑战
多尺度特征融合	RAAWC-UNet[120]、CRFormer[133]	病斑尺度分布不均、小目标病斑图像分割困难、多尺度上下文信息整合	能够兼顾不同尺度病斑特征,但在极早期小病斑、病斑分散或叶片重叠场景下的图像仍易出现漏分割,对不同农作物类型和拍摄条件的适应性也不够稳定
注意力机制	VCDM-UNet[122]、注意力优化 DeepLabV3+[124]、MCBNet[132]	复杂背景干扰抑制、病斑边缘模糊、关键病理区域定位、不规则形态识别	在复杂背景下可强化对病斑区域的响应,但遇到叶脉反光、露滴高光或阴影遮挡时,注意力容易偏向非病斑区域,导致边缘识别不准或离散病斑遗漏
损失函数优化	RAAWC-UNet(权重压缩损失)[120]、双阶段 DeepLabV3+(自适应损失)[125]	前景背景像素比例严重失衡、小病斑易被忽略、不同尺度病斑的图像分割误差平衡	有助于缓解前景背景不平衡,但对病斑边界模糊和标注不一致问题改善有限,尤其在不同农作物和不同季节下病斑面积占比变化较大时,损失项设置仍较依赖经验调整
架构融合	CoAtNet[129]、BAF-Net[130]、TransDeepLab[131]	全局上下文信息捕获不足、局部细节与全局语义的协同、长程依赖建模	兼顾了局部细节与全局语义信息,但对标注数据规模和训练条件要求较高,图像分块或多层特征传递过程中,微小病斑和细边界信息仍可能被削弱
频域特征利用	DWTFormer[141]、FA-Unet[142]	高频噪声抑制、细节纹理提取、小样本场景下的泛化能力增强	在纹理细节提取和部分噪声抑制方面具有优势,但容易受到叶脉纹理、叶缘细碎结构和图像模糊的影响,对主要表现为颜色变化而纹理不明显的病害优势不够突出
鲁棒性增强策略	FATDNet(对抗学习)[135]、CRE(自监督预训练方法)[136]	复杂田间背景干扰、极端光照和遮挡条件、高质量标注数据稀缺	对泥点、水渍和农药残留等真实田间干扰覆盖仍有限,增强鲁棒性的同时可能削弱早期弱病斑
轻量化设计	UPFormer[137]、轻量化 DeepLabv3+[138]、GMamba[144]	移动设备和边缘平台的计算资源约束、实时性要求、推理速度优化	提高了移动端和边缘设备上的部署可行性,但模型压缩后对微小病斑、细边界和弱特征区域的表征能力更易下降,在复杂背景下分割结果稳定性不足
通用模型迁移与适配	EMSAM[146]	多尺度细微病斑图像分割、零样本学习、跨场景泛化能力	拓展了跨场景和零样本应用的可能性,但不同农作物、品种和生育期之间的症状差异较大,实际应用中往往仍需少量目标数据进行调整,非病害因素干扰下也较易误分割

1) 提升跨场景泛化能力。田间环境中的非均匀光照、叶片遮挡、背景干扰以及跨地域作物生长差异,都会导致模型在实际应用中出现性能下降。未来可进一步加强域适应、域泛化和对抗训练等方法研究,并结合植物病理学先验知识优化特征表征,提升模型在跨场景、跨作物和跨区域条件下的稳定识别能力。

2) 推进轻量化部署与实时应用。农业生产中的移动终端、田间传感设备和无人机平台通常受到算力、存储和能耗限制,模型体积与推理延迟仍是制约技术落地的重要因素。未来应继续推进轻量化网络设计、模型剪枝、量化压缩和边缘协同计算等研究,提高模型在资源受限设备上的实时应用能力。

3) 降低高质量标注数据依赖。病害识别尤其是病斑图像分割任务对高质量标注样本依赖较强,而像素级标注成本高、周期长,已成为限制模型性能提升的重要因素。未来可进一步发展自监督学习、半监督学习和主动学

习等方法，充分利用无标注或少标注数据资源，在控制标注成本的同时提升模型训练效率和泛化表现。

4）强化多模态与多源信息融合。单一可见光图像对病害早期生理变化和复杂症状差异的表达能力有限，难以满足早期预警和精细诊断需求。未来可加强可见光、高光谱、热红外影像以及气象、土壤等环境信息的协同融合研究，增强模型对病害早期异常信号和复杂病害类型的识别能力，推动病害识别由被动诊断向主动预警发展。

5）加强面向区域农业场景的应用转化。现有研究多集中于公开数据集或相对受控的实验条件，与真实农业生产场景之间尚存在差距。未来需要在不同农作物、生育期、地域和季节条件下开展系统验证，并推动病害识别模型与农情监测、精准施药和智能农机装备的协同应用。尤其应结合西南地区水稻、玉米、马铃薯、柑橘、辣椒和茶叶等主要农作物，以及山地农业地形起伏大、遮挡多、环境变化快等场景特点，增强相关研究的区域适用性和应用针对性。

参考文献：

[1] Savary S，Willocquet L. Modeling the impact of crop diseases on global food security[J]. Annual Review of Phytopathology，2020，58：313-341.

[2] Zhao Y，Zhu X B，Chen X W，et al. From plant immunity to crop disease resistance[J]. Journal of Genetics and Genomics，2022，49（8）：693-703.

[3] Gai Y P，Wang H K. Plant disease：a growing threat to global food security[J]. Agronomy，2024，14（8）：1615.

[4] 刘杰，卞悦，张熠琀，等. 2025 年全国主要农作物重大病虫害发生趋势及其原因分析[J]. 中国植保导刊，2025，45（2）：26-29.
Liu Jie，Bian Yue，Zhang Yiyang，et al. Analysis of occurrence trends and causes of major crop diseases and pests in China in 2025[J]. China Plant Protection，2025，45（2）：26-29.

[5] Demilie W B. Plant disease detection and classification techniques：a comparative study of the performances[J]. Journal of Big Data，2024，11（1）：5.

[6] Nyawose T，Maswanganyi R C，Khumalo P. A review on the detection of plant disease using machine learning and deep learning approaches[J]. Journal of Imaging，2025，11（10）：326.

[7] Majdalawieh M，Martins C，Radi M，et al. Precision agriculture in the age of AI：a systematic review of machine learning methods for crop disease detection[J]. Smart Agricultural Technology，2025，12：101491.

[8] 吕佳，彭港建，巫若愚. 多分支分组卷积的特征级联农作物病害识别[J]. 重庆师范大学学报（自然科学版），2024，41（5）：115-128.
Lü Jia，Peng Gangjian，Wu Ruoyu. Multi-branch grouping convolution feature cascaded crop disease recognition[J]. Journal of Chongqing Normal University（Natural Science），2024，41（5）：115-128.

[9] Fang Y，Ramasamy R P. Current and prospective methods for plant disease detection[J]. Biosensors，2015，5（3）：537-561.

[10] 于明，郭志永，王岩. 基于计算机视觉的植物病害识别方法综述[J]. 科学技术与工程，2024，24（12）：4811-4823.
Yu Ming，Guo Zhiyong，Wang Yan. Review of computer vision-based plant disease identification techniques[J]. Science Technology and Engineering，2024，24（12）：4811-4823.

[11] Sankaran S，Mishra A，Ehsani R，et al. A review of advanced techniques for detecting plant diseases[J]. Computers and Electronics in Agriculture，2010，72（1）：1-13.

[12] LeCun Y，Bengio Y，Hinton G. Deep learning[J]. Nature，2015，521（7553）：436-444.

[13] Kamilaris A，Prenafeta-Boldú F X. Deep learning in agriculture：a survey[J]. Computers and Electronics in Agriculture，2018，147：70-90.

[14] Kumar D，Kukreja V. Image segmentation，classification，and recognition methods for wheat diseases：two Decades' systematic literature review[J]. Computers and Electronics in Agriculture，2024，221：109005.

[15] Krishna M S，Machado P，Otuka R I，et al. Plant leaf disease detection using deep learning：a multi-dataset approach[J]. J，2025，8（1）：4.

[16] Xu M L，Park J E，Lee J，et al. Plant disease recognition datasets in the age of deep learning：challenges and opportunities[J]. Frontiers in Plant Science，2024，15：1452551.

[17] Hughes D P，Salathe M. An open access repository of images on plant health to enable the development of mobile disease diagnostics[PP/OL]. V2. arXiv（2016-04-12）[2026-04-08]. https://doi.org/10.48550/arXiv.1511.08060.

[18] Ahmad A，Saraswat D，El Gamal A. A survey on using deep learning techniques for plant disease diagnosis and

recommendations for development of appropriate tools[J]. Smart Agricultural Technology, 2023, 3: 100083.

[19] Jang H, Tong F. Improved modeling of human vision by incorporating robustness to blur in convolutional neural networks [J]. Nature Communications, 2024, 15: 1989.

[20] Li L H, Tanone R. Improving robustness using MixUp and CutMix augmentation for corn leaf diseases classification based on ConvMixer architecture[J]. Journal of ICT Research and Applications, 2023, 17 (2): 167-180.

[21] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Advances in Neural Information Processing Systems, 2017, 30: 5998-6008.

[22] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16×16 words: transformers for image recognition at scale[C]//International Conference on Learning Representations (ICLR 2021), 2021.

[23] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[C]//Proceedings of the 3rd International Conference on Learning Representations, 2015: 1-14.

[24] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 770-778.

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

[26] Kawasaki Y, Uga H, Kagiwada S, et al. Basic study of automated diagnosis of viral plant diseases using convolutional neural networks[C]//Bebis G, Boyle R, Parvin B, et al. Advances in visual computing. Cham: Springer, 2015: 638-645.

[27] Rangarajan A K, Purushothaman R, Ramesh A. Tomato crop disease classification using pre-trained deep learning algorithm[J]. Procedia Computer Science, 2018, 133: 1040-1047.

[28] Upadhyay S K, Kumar A. A novel approach for rice plant diseases classification with deep convolutional neural network [J]. International Journal of Information Technology, 2022, 14 (1): 185-199.

[29] Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017: 2261-2269.

[30] Waheed A, Goyal M, Gupta D, et al. An optimized dense convolutional neural network model for disease recognition and classification in corn leaf[J]. Computers and Electronics in Agriculture, 2020, 175: 105456.

[31] TAN M, LE Q. Efficientnet: Rethinking model scaling for convolutional neural networks[C]//International Conference on Machine Learning, 2019: 6105-6114.

[32] Atila Ü, Uçar M, Akyol K, et al. Plant leaf disease classification using EfficientNet deep learning model[J]. Ecological Informatics, 2021, 61: 101182.

[33] Liu Z, Mao H Z, Wu C Y, et al. A ConvNet for the 2020s[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2022: 11966-11976.

[34] Li H, Qi M Y, Du B X, et al. Maize disease classification system design based on improved ConvNeXt[J]. Sustainability, 2023, 15 (20): 14858.

[35] Abbas A, Jain S, Gour M, et al. Tomato plant disease detection using transfer learning with C-GAN synthetic images[J]. Computers and Electronics in Agriculture, 2021, 187: 106279.

[36] Liu Z, Lin Y T, Cao Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2021: 9992-10002.

[37] Demir A, Sarı F, Arzu M, et al. Artificial intelligence-aided diagnosis in agriculture: plant disease classification with vision transformer and CNN models[J]. NATURENGS MTU Journal of Engineering and Natural Sciences Malatya Turgut Ozal University, 2025, 6 (2): 22-31.

[38] TOUVRON H, CORD M, DOUZE M, et al. Training data-efficient image transformers & distillation through attention [C]//International Conference on Machine Learning, 2021: 10347-10357.

[39] Sun C X, Li Y, Song Z D, et al. Research on tomato disease image recognition method based on DeiT[J]. European Journal of Agronomy, 2025, 162: 127400.

[40] Wang W H, Xie E Z, Li X, et al. Pyramid vision transformer: a versatile backbone for dense prediction without convolutions[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2021: 548-558.

[41] Chang B F, Wang Y C, Zhao X Y, et al. A general-purpose edge-feature guidance module to enhance vision transformers for plant disease identification[J]. Expert Systems with Applications, 2024, 237: 121638.

[42] Liu J, Wang X W, Chen Q, et al. Deep learning method for cucumber disease detection in complex environments for new agricultural productivity[J]. BMC Plant Biology, 2025, 25 (1): 888.

[43] Yang W Q, Yuan Y, Zhang D H, et al. An effective image classification method for plant diseases with improved channel attention mechanism aECAnet based on deep learning[J]. Symmetry, 2024, 16 (4): 451.

[44] Dai G W, Fan J C, Tian Z M, et al. PPLC-Net: neural network-based plant disease identification model supported by weather data augmentation and multi-level attention mechanism[J]. Journal of King Saud University - Computer and Information Sciences, 2023, 35 (5): 101555.

[45] Deng L F, Qin J, Li K, et al. DAMSLNet: dual-attention multi-scale lightweight network for plant disease classification [J]. Engineering Applications of Artificial Intelligence, 2025, 159: 111590.

[46] Lin J W, Chen Y, Pan R Y, et al. CAMFFNet: a novel convolutional neural network model for tobacco disease image recognition[J]. Computers and Electronics in Agriculture, 2022, 202: 107390.

[47] Luo Y Q, Sun J, Shen J F, et al. Apple leaf disease recognition and sub-class categorization based on improved multi-scale feature fusion network[J]. IEEE Access, 2021, 9: 95517-95527.

[48] Liu L L, Qiao S X, Chang J, et al. A multi-scale feature fusion neural network for multi-class disease classification on the maize leaf images[J]. Heliyon, 2024, 10 (7): e28264.

[49] Zeng W H, Li M. Crop leaf disease recognition based on Self-Attention convolutional neural network[J]. Computers and Electronics in Agriculture, 2020, 172: 105341.

[50] Zhao Y, Li Y, Wu N, et al. Neural network based on convolution and self-attention fusion mechanism for plant leaves disease recognition[J]. Crop Protection, 2024, 180: 106637.

[51] Xu C C, Yang T J. A symmetric multi-scale convolutional transformer network for plant disease image classification[J]. Symmetry, 2025, 17 (8): 1232.

[52] Panchananam L S, Chandaliya P K, Akhtar Z, et al. WaveletFusion: enhancing plant leaf disease classification with multi-scale feature extraction and explainable AI[J]. Expert Systems with Applications, 2025, 285: 127947.

[53] 程超，吕佳，范亚洲. 基于自监督域自适应网络的苹果叶部病害识别[J]. 重庆师范大学学报（自然科学版），2024，41 (3)：89-99.
Cheng Chao, Lü Jia, Fan Yazhou. Apple leaf diseases recognition based on deep learning[J]. Journal of Chongqing Normal University (Natural Science), 2024, 41 (3): 89-99.

[54] Tunio M H, Li J P, Zeng X Y, et al. Advancing plant disease classification: a robust and generalized approach with transformer-fused convolution and Wasserstein domain adaptation[J]. Computers and Electronics in Agriculture, 2024, 227: 109574.

[55] Yang S, Feng Q, Zhang J H, et al. From laboratory to field: cross-domain few-shot learning for crop disease identification in the field[J]. Frontiers in Plant Science, 2024, 15: 1434222.

[56] Xu W C, Yan Z. Research on strawberry disease diagnosis based on improved residual network recognition model[J]. Mathematical Problems in Engineering, 2022, 2022: 6431942.

[57] Zhu W D, Sun J, Wang S M, et al. Identifying field crop diseases using transformer-embedded convolutional neural network[J]. Agriculture, 2022, 12 (8): 1-19.

[58] 杨新宇，冯全，张建华，等. 基于对比学习的植物叶片病害识别[J]. 浙江农业学报，2024，36 (1)：215-224.
Yang Xinyu, Feng Quan, Zhang Jianhua, et al. Plant leaf disease identification based on contrastive learning[J]. Acta Agriculturae Zhejiangensis, 2024, 36 (1): 215-224.

[59] Zhu S Q, Gao H T. MC-ShuffleNetV2: a lightweight model for maize disease recognition[J]. Egyptian Informatics Journal, 2024, 27: 100503.

[60] 黄铝文，关非凡，谦博，等. 基于 2D DWT 与 MobileNetV3 融合的轻量级茶叶病害识别[J]. 农业工程学报，2023，39 (24)：207-214.
Huang Lüwen, Guan Feifan, Qian Bo, et al. Recognizing tea diseases with fusion on 2D DWT and MobileNetV3[J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39 (24): 207-214.

[61] Feng W F, Song Q S, Sun G Y, et al. Lightweight isotropic convolutional neural network for plant disease identification [J]. Agronomy, 2023, 13 (7): 1849.

[62] Pal C, Karmakar S, Mukherjee I, et al. A lightweight and explainable CNN model for empowering plant disease diagnosis [J]. Scientific Reports, 2025, 15: 30720.

[63] Zhang X L, Liang K, Zhang Y Y. Plant pest and disease lightweight identification model by fusing tensor features and knowledge distillation[J]. Frontiers in Plant Science, 2024, 15: 1443815.

[64] 朱锐，张家瑜，黄继超，等. 基于卷积神经网络的农作物叶片病害检测研究进展[J]. 农业工程学报，2025，41 (17)：15-28.
Zhu Rui, Zhang Jiayu, Huang Jichao, et al. Research progress of crop leaf disease detection based on convolutional neural network[J]. Transactions of the Chinese Society of Agricultural Engineering, 2025, 41 (17): 15-28.

[65] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2014: 580-587.

[66] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 779-788.

[67] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[C]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Cham: Springer, 2016: 21-37.

[68] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39 (6): 1137-1149.

[69] He K M, Gkioxari G, Dollar P, et al. Mask R-CNN[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2017: 2980-2988.

[70] Bari B S, Islam M N, Rashid M, et al. A real-time approach of diagnosing rice leaf disease using deep learning-based faster R-CNN framework[J]. PeerJ. Computer Science, 2021, 7: e432.

[71] Zhang K K, Wu Q F, Chen Y P. Detecting soybean leaf disease from synthetic image using multi-feature fusion faster R-CNN[J]. Computers and Electronics in Agriculture, 2021, 183: 106064.

[72] Gong X L, Zhang S J. A high-precision detection method of apple leaf diseases using improved faster R-CNN[J]. Agriculture, 2023, 13 (2): 240.

[73] He J, Liu T, Li L J, et al. MFaster R-CNN for maize leaf diseases detection based on machine vision[J]. Arabian Journal for Science and Engineering, 2023, 48 (2): 1437-1449.

[74] 邓炜航，赵胜雪. 基于改进 Faster RCNN 算法的马铃薯叶片病害识别[J]. 农机化研究，2026，48 (7)：109-116.
Deng Weihang, Zhao Shengxue. Potato leaf disease recognition based on improved faster RCNN algorithm[J]. Journal of Agricultural Mechanization Research, 2026, 48 (7): 109-116.

[75] 谢家兴，廖飞，王卫星，等. 基于改进 Faster R-CNN 的荔枝病虫害检测[J]. 华中农业大学学报，2025，44 (1)：62-73.
Xie Jiaxing, Liao Fei, Wang Weixing, et al. Detecting diseases and insect pests in *Litchi* based on improved Faster R-CNN[J]. Journal of Huazhong Agricultural University, 2025, 44 (1): 62-73.

[76] 李子茂，刘恋冬，夏梦，等. 基于深度学习的月季多叶片病虫害检测研究[J]. 中国农机化学报，2021，42 (8)：169-176.
Li Zimao, Liu Liandong, Xia Meng, et al. Detection of rose diseases and insect pests based on deep learning[J]. Journal of Chinese Agricultural Mechanization, 2021, 42 (8): 169-176.

[77] Li H, Shi H T, Du A H, et al. Symptom recognition of disease and insect damage based on Mask R-CNN, wavelet transform, and F-RNet[J]. Frontiers in Plant Science, 2022, 13: 922797.

[78] 王金星，马博，王震，等. 基于改进 Mask R-CNN 的苹果园害虫识别方法[J]. 农业机械学报，2023，54 (6)：253-263.
Wang Jinxing, Ma Bo, Wang Zhen, et al. Pest identification method in apple orchard based on improved mask R-CNN [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54 (6): 253-263.

[79] Rehman Z U, Khan M A, Ahmed F, et al. Recognizing apple leaf diseases using a novel parallel real-time processing framework based on MASK RCNN and transfer learning: an application for smart agriculture[J]. IET Image Processing, 2021, 15 (10): 2157-2168.

[80] Bondre S, Patil D. Crop disease identification segmentation algorithm based on Mask-RCNN[J]. Agronomy Journal, 2024, 116 (3): 1088-1098.

[81] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2017: 2999-3007.

[82] Sun H N, Xu H W, Liu B, et al. MEAN-SSD: a novel real-time detector for apple leaf diseases using improved light-weight convolutional neural networks[J]. Computers and Electronics in Agriculture, 2021, 189: 106379.

[83] 李大华，孔舒，李栋，等. 基于改进 SSD 模型的柑橘叶片病害轻量化检测模型[J]. 浙江农业学报，2024，36 (3)：662-670.
Li Dahua, Kong Shu, Li Dong, et al. Lightweight detection model of *Citrus leaf* disease based on improved SSD[J]. Acta

Agriculturae Zhejiangensis，2024，36 (3)：662-670.

[84] Tian L L，Zhang H X，Liu B，et al. VMF-SSD：a novel V-space based multi-scale feature fusion SSD for apple leaf disease detection[J]. IEEE/ACM Transactions on Computational Biology and Bioinformatics，2023，20 (3)：2016-2028.

[85] Guo W J，，Feng S，et al. Cotton leaf disease detection method based on improved SSD[J]. International Journal of Agricultural and Biological Engineering，2024，17 (2)：211-220.

[86] Bao W X，Fan T，Hu G S，et al. Detection and identification of tea leaf diseases based on AX-RetinaNet[J]. Scientific Reports，2022，12：2183.

[87] Sankareshwaran S P，Jayaraman G，Muthukumar P，et al. Optimizing rice plant disease detection with crossover boosted artificial hummingbird algorithm based AX-RetinaNet[J]. Environmental Monitoring and Assessment，2023，195 (9)：1070.

[88] Liu J，Wang X W. Early recognition of tomato gray leaf spot disease based on MobileNetv2-YOLOv3 model[J]. Plant Methods，2020，16 (1)：83.

[89] Liu J，Wang X W. Tomato diseases and pests detection based on improved yolo V3 convolutional neural network[J]. Frontiers in Plant Science，2020，11：898.

[90] Li J W，Qiao Y L，Liu S，et al. An improved YOLOv5-based vegetable disease detection method[J]. Computers and Electronics in Agriculture，2022，202：107345.

[91] 郑争兵，张义邦，孙璐超，等. 基于改进 YOLOv5 的柑橘叶片病害小目标检测方法[J]. 农业工程学报，2025，41 (21)：203-211.
Zheng Zhengbing，Zhang Yibang，Sun Luchao，et al. Detecting small targets from *Citrus leaf* disease images using improved YOLOv5[J]. Transactions of the Chinese Society of Agricultural Engineering，2025，41 (21)：203-211.

[92] 侯鹏飞，张小栋，唐国伟，等. 基于改进 YOLOv5n 的辣椒病害检测模型研究[J]. 中国农机化学报，2025，46 (10)：218-223.
Hou Pengfei，Zhang Xiaodong，Tang Guowei，et al. Research on pepper disease detection model based on improved YOLOv5n[J]. Journal of Chinese Agricultural Mechanization，2025，46 (10)：218-223.

[93] Dai G W，Hu L，Fan J C. DA-ActNN-YOLOV5：hybrid YOLO v5 model with data augmentation and activation of compression mechanism for potato disease identification[J]. Computational Intelligence and Neuroscience，2022，2022 (1)：6114061.

[94] 侯文慧，龚昌智，曹文昊，等. 基于超分辨率增强与改进 YOLOv8 的番茄叶片病害检测[J]. 农业工程学报，2025，41 (16)：211-220.
Hou Wenhui，Gong Changzhi，Cao Wenhao，et al. Tomato leaf disease detection method based on super-resolution enhancement and improved YOLOv8[J]. Transactions of the Chinese Society of Agricultural Engineering，2025，41 (16)：211-220.

[95] Chen Z X，Feng J J，Zhu K，et al. YOLOv8-ACCW：lightweight grape leaf disease detection method based on improved YOLOv8[J]. IEEE Access，2024，12：123595-123608.

[96] 甄元元，刘平，金雨纯，等. 基于改进 YOLOv8 的葡萄叶片病害检测与识别[J]. 农业工程学报，2025，41 (14)：148-154.
Zhen Yuanyuan，Liu Ping，Jin Yuchun，et al. Grape leaf disease detection and identification based on improved YOLOv8[J]. Transactions of the Chinese Society of Agricultural Engineering，2025，41 (14)：148-154.

[97] Zhang Y P，Liu J，Li S Z，et al. ESM-YOLOv11：a lightweight deep learning framework for real-time peanut leaf spot disease detection and precision severity quantification in field conditions[J]. Computers and Electronics in Agriculture，2025，238：110801.

[98] Tang X Y，Sun Z Q，Yang L L，et al. YOLOv11-AIU：a lightweight detection model for the grading detection of early blight disease in tomatoes[J]. Plant Methods，2025，21 (1)：118.

[99] He J，Ren Y，Li W B，et al. YOLOv11-RCDWD：a new efficient model for detecting maize leaf diseases based on the improved YOLOv11[J]. Applied Sciences，2025，15 (8)：4535.

[100] 曾昆峰，张鹏超，王磊，等. 基于改进 YOLOv11n 的轻量化茶叶病虫害识别方法[J]. 农业工程学报，2025，41 (24)：220-229.
Zeng Kunfeng，Zhang Pengchao，Wang Lei，et al. Lightweight method for identifying tea pests and diseases based on an improved YOLOv11n[J]. Transactions of the Chinese Society of Agricultural Engineering，2025，41 (24)：220-229.

[101] Carion N，Massa F，Synnaeve G，et al. End-to-end object detection with transformers[C]//Vedaldi A，Bischof H，Brox T，et al. Computer vision-ECCV 2020. Cham：Springer，2020：213-229.

[102] Yang H, Deng X Q, Shen H, et al. Disease detection and identification of rice leaf based on improved detection transformer[J]. Agriculture, 2023, 13 (7): 1361.

[103] Song H Y, Huang X Y, Wang Z Q, et al. ADAM-DETR: an intelligent rice disease detection method based on adaptive multi-scale feature fusion[J]. Plant Methods, 2025, 21 (1): 108.

[104] Zhao Y A, Lü W Y, Xu S L, et al. DETRs beat YOLOs on real-time object detection[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2024: 16965-16974.

[105] Huangfu Y, Huang Z H, Yang X G, et al. HHS-RT-DETR: a method for the detection of *Citrus greening* disease[J]. Agronomy, 2024, 14 (12): 2900.

[106] Sun H, Fu R, Zhang Z J, et al. Research on eggplant pest and disease detection in complex environments based on improved RT-DETR[J]. BMC Plant Biology, 2025, 25 (1): 1664.

[107] 林文庆，李书琴. 基于改进RT-DETR的葡萄叶片病害检测方法[J]. 农业工程学报，2025，41 (15)：145-154.
Lin Wenqing, Li Shuqin. Grape leaf disease detection method based on improved RT-DETR[J]. Transactions of the Chinese Society of Agricultural Engineering, 2025, 41 (15): 145-154.

[108] 刘慧，王防修，王意，等. 轻量级改进RT-DETR的葡萄叶片病害检测算法[J]. 浙江大学学报（工学版），2026，60 (3)：604-613.
Liu Hui, Wang Fangxiu, Wang Yi, et al. Lightweight improved RT-DETR algorithm for grape leaf disease detection [J]. Journal of Zhejiang University (Engineering Science), 2026, 60 (3): 604-613.

[109] Bian S H, Su S, Zhou J, et al. Multi-scale feature fusion based RT-DETR for tomato leaf disease detection in complex backgrounds[J]. Sensors, 2025, 25 (23): 7275.

[110] ZHANG H, LI F, LIU S, et al. DINO: DETR with improved denoising anchor boxes for end-to-end object detection [C]//International Conference on Learning Representations, 2023.

[111] Huang S H, Lu Z C, Cun X D, et al. DEIM: DETR with improved matching for fast convergence[C]//2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2025: 15162-15171.

[112] Li W, Zhu L Z, Liu J. PL-*DINO*: an improved transformer-based method for plant leaf disease detection[J]. Agriculture, 2024, 14 (5): 691.

[113] Shen Y J, Wang F, Qian J J, et al. LE-PWDNet: a lightweight and enhanced detection framework based on DEIM for early-stage pine wilt disease[J]. Frontiers in Plant Science, 2025, 16: 1701009.

[114] Keshavarzi M, Mesarich C, Bailey D, et al. A review of semantic segmentation methods and their application in apple disease detection[J]. Computers and Electronics in Agriculture, 2025, 237: 110531.

[115] Divyanth L G, Ahmad A, Saraswat D. A two-stage deep-learning based segmentation model for crop disease quantification based on corn field imagery[J]. Smart Agricultural Technology, 2023, 3: 100108.

[116] Mahlein A K. Plant disease detection by imaging sensors - parallels and specific demands for precision agriculture and plant phenotyping[J]. Plant Disease, 2016, 100 (2): 241-251.

[117] Shi T T, Liu Y M, Zheng X Y, et al. Recent advances in plant disease severity assessment using convolutional neural networks[J]. Scientific Reports, 2023, 13: 2336.

[118] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Cham: Springer, 2015: 234-241.

[119] Chen L C, Papandreou G, Kokkinos I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40 (4): 834-848.

[120] Wang J L, Jia J H, Zhang Y K, et al. RAAWC-UNet: an apple leaf and disease segmentation method based on residual attention and atrous spatial pyramid pooling improved UNet with weight compression loss[J]. Frontiers in Plant Science, 2024, 15: 1305358.

[121] 茹佳棋，吴斌，翁翔，等. 基于改进UNet++模型的葡萄黑腐病病斑分割和病害程度分级[J]. 浙江农业学报，2023，35 (11)：2720-2730.
Ru Jiaqi, Wu Bin, Weng Xiang, et al. Disease spot segmentation and disease degree classification of grape black rot based on improved UNet++ model[J]. Acta Agriculturae Zhejiangensis, 2023, 35 (11): 2720-2730.

[122] 邓阳君，王旭，龙陈锋，等. 基于VCDM-UNet的水稻叶瘟病斑分割和病害程度分级[J]. 农业工程学报，2024，40 (23)：

190-198.

Deng Yangjun, Wang Xu, Long Chenfeng, et al. Segmenting and grading the blast disease of rice leaves using VCDM-UNet[J]. Transactions of the Chinese Society of Agricultural Engineering, 2024, 40 (23): 190-198.

[123] Singh G, Al-Huqail A A, Almogren A, et al. Enhanced leaf disease segmentation using U-Net architecture for precision agriculture: a deep learning approach[J]. Food Science & Nutrition, 2025, 13 (7): e70594.

[124] Li K Y, Zhang L X, Li B, et al. Attention-optimized DeepLab V3+ for automatic estimation of cucumber disease severity[J]. Plant Methods, 2022, 18 (1): 109.

[125] Zhu S S, Ma W L, Lu J W, et al. A novel approach for apple leaf disease image segmentation in complex scenes based on two-stage DeepLabv3+ with adaptive loss[J]. Computers and Electronics in Agriculture, 2023, 204: 107539.

[126] Yuan Y J, Yang L N, Chang K, et al. DSCA-PSPNet: dynamic spatial-channel attention pyramid scene parsing network for sugarcane field segmentation in satellite imagery[J]. Frontiers in Plant Science, 2024, 14: 1324491.

[127] Saleem R, Hussain Shah J, Sharif M, et al. Mango leaf disease identification using fully resolution convolutional network [J]. Computers, Materials & Continua, 2021, 69 (3): 3581-3601.

[128] Nibret E A, Mequanenit A M, Ayalew A M, et al. Sesame plant disease classification using deep convolution neural networks[J]. Applied Sciences, 2025, 15 (4): 2124.

[129] Yan J K, Yan T Y, Ye W X, et al. Cotton leaf segmentation with composite backbone architecture combining convolution and attention[J]. Frontiers in Plant Science, 2023, 14: 1111175.

[130] Fang J X, Jiang H T, Zhang S Q, et al. BAF-Net: bidirectional attention fusion network via CNN and transformers for the pepper leaf segmentation[J]. Frontiers in Plant Science, 2023, 14: 1123410.

[131] Gangwar A, Rani G, Singh Dhaka V. Tomato TransDeepLab: a robust framework for tomato leaf segmentation, disease severity prediction, and crop loss estimation[J]. IEEE Access, 2025, 13: 170147-170160.

[132] 吕佳, 胡佳乐. 多尺度交叉融合与边界感知的葡萄叶片病害分割网络[J]. 农业工程学报, 2025, 41 (17): 203-212.
Lü Jia, Hu Jiale. Segmenting grape leaf diseases using multi-scale cross-fusion and boundary-aware network [J]. Transactions of the Chinese Society of Agricultural Engineering, 2025, 41 (17): 203-212.

[133] Zhang X X, Cen C J, Li F, et al. CRFormer: cross-Resolution Transformer for segmentation of grape leaf diseases with context mining[J]. Expert Systems with Applications, 2023, 229: 120324.

[134] Dai W S, Zhu W K, Zhou G X, et al. AISOA-SSformer: an effective image segmentation method for rice leaf disease based on the transformer architecture[J]. Plant Phenomics, 2024, 6: 218.

[135] Yang Z C, Sun L X, Liu Z H, et al. FATDNet: a fusion adversarial network for tomato leaf disease segmentation under complex backgrounds[J]. Computers and Electronics in Agriculture, 2025, 234: 110270.

[136] Wang Z L, Wang R F, Wang M J, et al. Self-supervised transformer-based pre-training method with general plant infection dataset [C]//Lin Z C, Cheng M M, He R, et al. Pattern recognition and computer vision. Singapore: Springer, 2025: 189-202.

[137] Zhang X X, Li F, Zheng H Y, et al. UPFormer: U-sharped Perception lightweight Transformer for segmentation of field grape leaf diseases[J]. Expert Systems with Applications, 2024, 249: 123546.

[138] Li J N, Gao L, Wang X C, et al. Lightweight rice leaf spot segmentation model based on improved DeepLabv3[J]. Frontiers in Plant Science, 2025, 16: 1635302.

[139] Zhao C Y, Li C C, Wang X, et al. Plant disease segmentation networks for fast automatic severity estimation under natural field scenarios[J]. Agriculture, 2025, 15 (6): 583.

[140] Safran M. Real-time plant disease segmentation and identification using deep learning [C]//2023 3rd International Conference on Computing and Information Technology (ICCIT). Piscataway: IEEE, 2023: 377-383.

[141] Xiang Y Y, Gao S, Li X P, et al. DWTFormer: a frequency-spatial features fusion model for tomato leaf disease identification[J]. Plant Methods, 2025, 21 (1): 33.

[142] Li X W, Wu W L, Zhu F H, et al. FA-unet: a deep learning method with fusion of frequency domain features for fruit leaf disease identification[J]. Horticulturae, 2025, 11 (7): 783.

[143] Gu A, Dao T. Mamba: Linear-time sequence modeling with selective state spaces[PP/OL]. V2. arXiv (2024-05-31) [2026-04-08]. https://arxiv.org/abs/2312.00752.

[144] Zhang X X, Mu W S. GMamba: state space model with convolution for Grape leaf disease segmentation[J]. Computers and Electronics in Agriculture, 2024, 225: 109290.

[145] Anandhajothi Nalini R, Ishwarya M, Sinduja K. Vision mamba-TDL-seg framework for intelligent plant leaf disease diagnosis and spread estimation[C]//2025 4th International Conference on Automation, Computing and Renewable Systems (ICACRS). Piscataway: IEEE, 2025: 1071-1076.

[146] Li J L, Feng Q, Zhang J H, et al. EMSAM: enhanced multi-scale segment anything model for leaf disease segmentation [J]. Frontiers in Plant Science, 2025, 16: 1564079.

[147] Kirillov A, Mintun E, Ravi N, et al. Segment anything[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2023: 3992-4003.

Advances in Crop Disease Recognition Based on Deep Learning

LÜ Jia[1,2], LI Shicheng[1]

(1. College of Computer and Information Science, Chongqing Normal University;

2. Chongqing Center of Engineering Technology Research on Digital Agricultural & Service, Chongqing, 401331, China)

Abstract: Crop diseases pose a serious threat to global food security, and timely and accurate identification is essential for effective prevention and control. Deep learning technologies have advanced rapidly in the field of disease recognition, yet systematic reviews remain relatively limited. This paper aims to comprehensively summarize the research progress in crop disease recognition using deep learning, providing reference for further studies in this area. We systematically review relevant research achievements, introduce fundamental principles and evaluation metrics, summarize commonly used datasets and preprocessing methods, and detail existing work from three perspectives—image classification, object detection, and image segmentation. We analyze current challenges and outline future research directions. In image classification, convolutional neural networks (CNNs) and Transformer architectures have been widely applied. By incorporating attention mechanisms, multi-scale feature fusion, and transfer learning, these approaches alleviate issues caused by complex backgrounds and fine-grained disease confusion. In object detection, two-stage and single-stage algorithms enable simultaneous localization of candidate regions and prediction of bounding boxes, allowing joint determination of lesion locations and categories. Detection methods based on Transformers further enhance global relationship modeling under conditions of complex backgrounds and dense occlusions. In the field of image segmentation, UNet and DeepLab series methods have established fundamental frameworks, while Transformers and hybrid architectures have improved segmentation performance for irregular lesion images. Lightweight network designs reduce computational resource consumption, enabling deployment on mobile devices. Deep learning has achieved significant progress in crop disease identification, yet challenges remain in cross-scenario generalization and real-time processing. Future research can advance practical applications by enhancing generalization capability, optimizing lightweight design, integrating multimodal data, and promoting technology transfer.

Keywords: crop disease identification; deep learning; image classification; object detection; image segmentation

(责任编辑 黄 颖)