

吴建军, 赵惠圆, 祝玉华. 葡萄叶片病害智能检测技术研究进展[J]. 江苏农业学报, 2026, 42(4): 842-854.

doi: 10.3969/j.issn.1000-4440.2026.04.021

葡萄叶片病害智能检测技术研究进展

吴建军^{1,2,3}, 赵惠圆^{1,2}, 祝玉华^{1,2}

(1. 河南工业大学信息科学与工程学院, 河南 郑州 450001; 2. 河南工业大学粮食信息处理与控制教育部重点实验室, 河南 郑州 450001; 3. 国家粮食和物资储备局科学研究院, 北京 100037)

摘要: 葡萄叶片病害严重威胁葡萄产业可持续发展, 传统人工诊断存在主观性强、效率低、时效性差等问题, 难以满足现代农业发展需求。葡萄叶片病害智能检测早期主要基于支持向量机、K近邻、随机森林等传统机器学习算法, 识别准确率从60%逐步提升至85%~90%。卷积神经网络通过Inception模块、残差连接、密集连接等架构创新, 有效解决了多尺度特征提取难题, 模型识别精度稳定在95%以上。YOLO算法历经从YOLOv1至YOLOv12的迭代演进, 通过融合注意力机制、轻量化网络、特征金字塔等策略, 将平均检测精度提升至90%~98%, 同时将模型大小压缩至个位数MB量级, 实现了精度与效率的协同优化。此外, 本文分析了PlantVillage、AI Challenger 2018等公开数据集的不足, 针对数据规范性和标注一致性问题提出改进建议。

关键词: 葡萄; 病害; 智能检测; 深度学习; 卷积神经网络; YOLO算法

中图分类号: S663.1 **文献标识码:** A **文章编号:** 1000-4440(2026)04-0842-13

Research progress on intelligent detection technology for grape leaf diseases

WU Jianjun^{1,2,3}, ZHAO Huiyuan^{1,2}, ZHU Yuhua^{1,2}

(1. College of Information Science and Engineering, Henan University of Technology, Zhengzhou 450001, China; 2. Key Laboratory of Grain Information Processing and Control, Ministry of Education, Henan University of Technology, Zhengzhou 450001, China; 3. Academy of National Food and Strategic Reserves Administration, Beijing 100037, China)

Abstract: Grape leaf diseases pose a severe threat to the sustainable development of the grape industry. Traditional manual diagnosis is plagued by strong subjectivity, low efficiency and poor timeliness, making it difficult to meet the development needs of modern agriculture. In the early stage, intelligent detection of grape leaf diseases was mainly based on traditional machine learning algorithms such as support vector machines, K-nearest neighbors and random forests, with the recognition accuracy gradually rising from 60% to 85%–90%. Convolutional neural networks have effectively addressed the challenge of multi-scale feature extraction through architectural innovations including Inception modules, residual connections and dense

connections, enabling the model recognition accuracy to stabilize at over 95%. The YOLO algorithm has undergone iterative evolution from YOLOv1 to YOLOv12. By integrating strategies such as attention mechanisms, lightweight networks and feature pyramids, it has raised the mean detection accuracy to 90%–98% and simultaneously compressed the model size to the single-digit MB level, achieving the coordinated optimization of accuracy and efficiency.

收稿日期: 2025-10-23

基金项目: 国家重点研发计划项目(2022YFD2100202、2018YFD040-1404)

作者简介: 吴建军(1976-), 男, 河南温县人, 博士, 教授, 研究方向为计算机科学与技术、粮食信息处理等。(E-mail) 13939003632@163.com

通讯作者: 赵惠圆, (E-mail) 1272887985@qq.com

In addition, this paper analyzes the shortcomings of public datasets such as PlantVillage and AI Challenger 2018, and puts forward improvement suggestions for the problems of data standardization and annotation consistency.

Key words: grape; disease; intelligent detection; deep learning; convolutional neural network; YOLO algorithm

葡萄是全球种植规模仅次于柑橘的第二大果树作物,在农业经济体系中占据重要地位^[1]。经国际葡萄与葡萄酒组织(OIV)统计,2024年全球葡萄种植面积达 7.30×10^6 hm²,年产量稳定在 7.0×10^7 t以上,葡萄酒产量约 2.3×10^{10} L^[2]。作为全球主要的葡萄生产国之一,中国经过近40年的持续发展,已在葡萄栽培规模、品种结构、标准化生产和精准管理等方面取得了显著进步,不仅在国际鲜食葡萄产业中占据主导地位^[3],也成为世界葡萄生产大国之一^[4]。然而,产业规模的持续扩大也使得病害防治面临日益严峻的挑战。

病害是制约葡萄产业持续发展的关键因素^[5]。葡萄生长周期长、叶片面积大、对环境变化敏感,容易受到多种病原菌的侵染。生产上常见的叶部病害超过20种,其中霜霉病、白粉病、黑腐病、褐斑病危害尤为突出^[6-7]。霜霉病因其潜育期短、繁殖迅速、传播范围广,在适宜温湿条件下易暴发流行,在流行年份,其导致的产量损失可达30%~80%,严重威胁葡萄产业的经济效益^[8-9]。鉴于病害的严重危害,农业农村部已将葡萄霜霉

病、白粉病、灰霉病、炭疽病(图1)等列为重点防治对象^[10]。目前化学农药仍是病害防治的主要手段,果农年均施药15~20次,农药投入成本占生产成本的15%~25%^[11]。然而,过度依赖化学防治不仅增加生产成本,还引发农药残留、环境污染、病原菌抗药性等问题^[12]。因此,建立精准高效的病害检测技术,推动农药减量使用,已成为葡萄产业绿色发展的重要方向。

实现精准高效的病害防治,首要前提是准确、及时的病害诊断。传统葡萄病害诊断主要依赖专家经验或果农肉眼识别,这种方法存在以下局限:一是需要扎实的植物病理学基础和丰富的实践经验,且人工检查耗时费力,诊断效率低,难以实现大面积快速筛查;二是诊断结果过于主观,一致性较差,尤其在病害初期,容易漏判不明显的症状,错过最佳防治时机;三是专业技术人员严重不足,导致人力成本较高^[13]。随着葡萄种植规模化程度提高,传统诊断方法已无法满足现代精准农业对病害快速、准确、大规模监测的迫切需求。




图1 常见的葡萄叶片病害

Fig.1 Common grape leaf diseases

深度学习等人工智能技术为作物病害智能诊断带来突破。相较于传统方法,深度学习方法能够有效克服主观性强、效率低等局限,显著提高病害检测与识别的准确性^[14]。计算机视觉技术能够自动提取和分析图像中的视觉特征,实现病害特征的客观量化评估;机器学习算法通过对大量标注样本进行训练,构建病害特征与类型之间的映

射关系^[15];卷积神经网络凭借其强大的特征学习能力,在图像识别任务中取得突破性进展^[16]。这些技术的融合应用,推动了基于图像的作物病害自动检测的实现。

葡萄叶片病害智能检测研究对智慧农业的发展具有重要意义。在理论层面,该研究涉及计算机视觉、模式识别、农业信息学等多学科知识,拓展了人

工智能在农业领域的应用范围与深度。从应用层面看,该技术能够实现作物病害的早期预警,为精准施药提供科学依据,并有助于构建区域性监测网络,有效降低防治成本,提升农产品质量安全水平。

基于此,本文基于机器学习和深度学习的葡萄叶片病害检测方法的研究成果,系统分析各类算法的原理、改进策略及应用效果,探讨数据集构建、评价指标等核心技术问题,总结当前研究成果与面临的主要挑战,并对未来发展趋势进行展望。

1 基于机器学习的葡萄叶片病害检测方法

随着计算机视觉和机器学习算法日趋成熟,基于数字图像处理的病害识别技术迅速发展,推动了作物病害识别由传统经验判断向智能化方向转变^[17]。

1.1 基于支持向量机(SVM)的方法

在葡萄叶片病害识别中,传统机器学习算法展现出良好的实用性。支持向量机(SVM)在处理高维数据中具有优秀的分类性能,已成为作物病害识别领域的主流算法之一。田有文等^[18]提出一种基于支持向量机的葡萄病害识别方法,具体操作为:先对采集到的病害图像进行降噪处理,采用统计模式识别方法和数学形态学方法完成病斑分割和特征提取,最后利用支持向量机方法进行识别,该方法识别效果优于神经网络。Padol等^[19]进一步构建了基于支持向量机的葡萄叶片病害识别系统,采用K-means聚类算法实现病斑区域分割,结合病斑的颜色和纹理特征等多维度信息,识别准确率达到88.89%。采用径向基函数作为核函数的SVM模型,在处理病害特征的非线性映射时展现出良好性能。Li等^[20]针对葡萄霜霉病和白粉病的识别问题,从初始特征集中筛选出31个关键特征,构建的SVM分类模型在训练集上实现了100%的识别准确率,在测试集上对葡萄霜霉病和白粉病的识别准确率分别达到90.00%和93.33%。

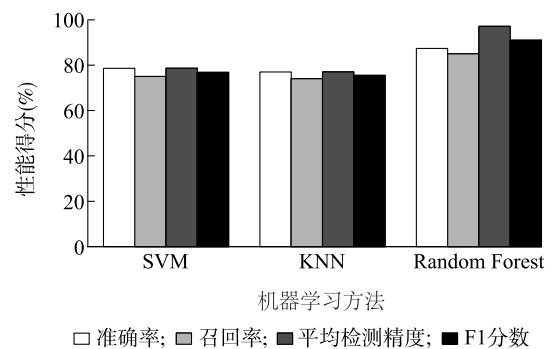
1.2 基于K近邻算法(KNN)的方法

K近邻算法(KNN)原理简洁且无需显式训练过程,在实时病害检测场景中具有独特优势。Vaishnave等^[21]将KNN应用于作物叶片病害分类。K值的选取及距离度量方式的设计是影响

KNN分类性能的关键因素,常用的距离度量方式包括欧氏距离和曼哈顿距离。针对病害症状边界模糊的问题,研究者引入模糊集理论对传统KNN进行改进,通过为样本赋予隶属度权重增强分类边界的鲁棒性^[22]。在葡萄叶片病害识别中,改进后的模糊KNN识别准确率可达到98.38%,显著优于传统KNN^[23]。

1.3 基于随机森林(Random Forest)的方法

随机森林作为集成学习的典型代表算法,通过构建多个弱分类器并采用投票机制进行决策融合,有效提升了模型的泛化能力和稳定性。Ngugi等^[24]对比了多种机器学习算法在作物病害检测任务中的表现,随机森林表现最优,测试准确率达到97.12%(图2)。在作物叶片病害识别研究中,随机森林方法准确率达到87.43%,其准确率低于CNN(97.89%),但明显高于SVM(78.61%)和KNN(76.96%)^[25]。这些结果表明,随机森林方法能够较好处理高维特征空间,具备较强的抗过度拟合能力,并能提供特征重要性评估。为提升模型性能,Chaudhary等^[26]提出一种改进的随机森林框架,通过优化决策树数量、最大深度参数以及特征子空间采样策略,进一步提升了多类别葡萄叶片病害的识别精度,为复杂农业场景下的病害识别提供了技术方案^[27]。Wang等^[28]应用主成分分析降低特征维度,并结合反向传播神经网络(BPNN)识别葡萄病害,对葡萄白粉病、霜霉病等病害的识别准确率达到90.40%。



SVM:支持向量机;KNN:K近邻算法;Random Forest:随机森林。

图2 机器学习方法性能对比

Fig.2 Performance comparison of machine learning methods

综上所述,基于机器学习的葡萄叶片病害检测方法已形成较为完善的技术体系。该领域经历了从

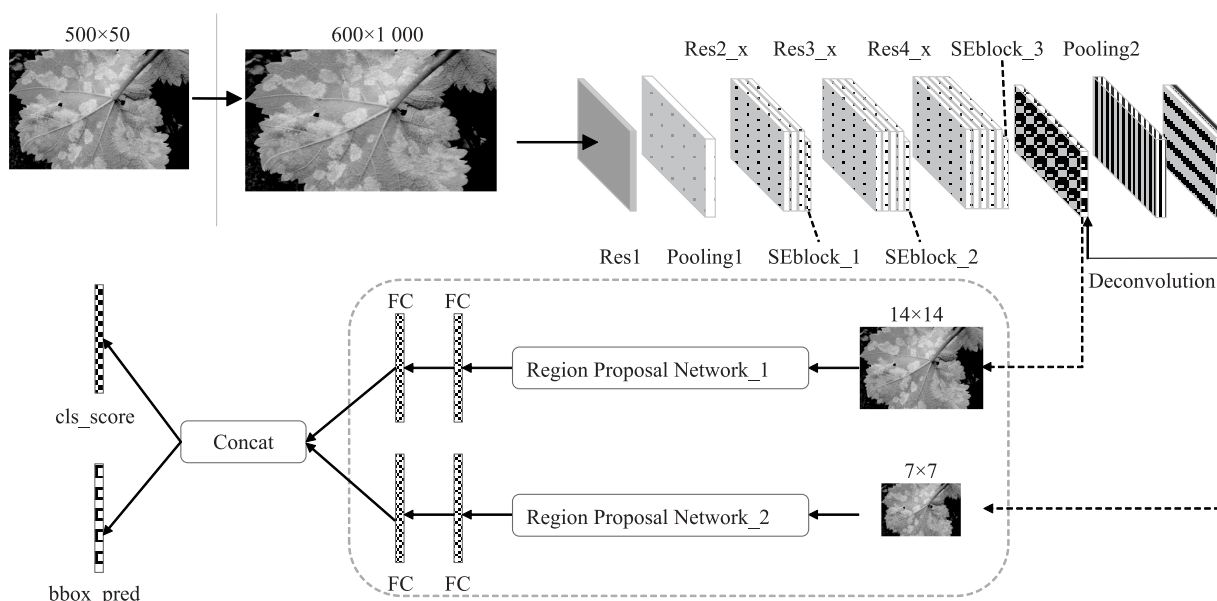
单一分类器向集成学习演进、从人工特征提取向自动特征提取发展的过程,模型在准确性、鲁棒性和实用性方面均有显著提升。但传统机器学习方法仍存在特征工程依赖性强、复杂背景下检测精度有限等问题,深度学习方法快速发展为解决这些问题提供了新的途径。

2 基于深度学习的葡萄叶片病害检测方法

2.1 基于卷积神经网络(CNN)的葡萄叶片病害检测

传统病害检测方法存在耗时较长和主观性强的

问题^[15]。随着计算机视觉与深度学习技术的发展,卷积神经网络(图3)在计算机视觉领域得到广泛应用^[29],该卷积神经网络凭借其强大的特征提取能力,能够从原始图像中直接学习层次化的特征表示,克服了传统机器学习算法对手工特征工程的依赖,目前已成为农作物病害检测和分类中最具代表性的技术之一^[30]。这种端到端的学习模式在葡萄叶片病害检测任务中展现出显著优势,为病害早期预警及精准防治提供技术支持。



Res1:参差块1;Pooling1:池化层1;Res2_x:参差块2;SEblock_1:SE通道注意力模块1;Res3_x:参差块3;SEblock_2:SE通道注意力模块2;Res4_x:参差块4;SEblock_3:SE通道注意力模块3;Pooling2:池化层2;Deconvolution:反卷积;Region Proposal Network_1:区域提议网络1;Region Proposal Network_2:区域提议网络2;FC:全连接层;Concat:拼接操作;cls_score:分类分数;bbox_pred:边界框预测。

图3 卷积神经网络(CNN)架构
Fig.3 Convolutional neural network (CNN) architecture

在葡萄叶片病害识别的早期研究中,经典CNN架构被广泛应用。在模型融合方面,Ji等^[15]提出了UnitedModel融合框架,该框架通过集成多个异构CNN模型实现特征空间互补,在葡萄病害分类任务中识别精度达到96.58%。Liu等^[31]构建107366张标注图像的葡萄叶片病害数据集,并对比不同网络架构的性能,结果表明,ResNet-34通过残差连接机制取得了94.89%的识别准确率,GoogLeNet通过多尺度特征提取策略取得了94.25%的识别准确率,而参数量较大的VGG-16识别准确率仅为88.96%。

传统的支持向量机和BP神经网络识别准确率分别为67.82%和57.93%,这一对比充分体现了深度学习学习方法在复杂病害识别任务中的优势。

针对葡萄叶片病害在不同尺度下的形态差异,研究者们提出了多种创新架构。Liu等^[31]提出密集连接Inception卷积神经网络(DICNN),通过结合Inception模块与密集连接机制,增强了对多尺度病害特征的代表能力,同时缓解了梯度消失问题,该模型在测试集上实现了97.22%的分类准确率,较GoogLeNet和ResNet-34分别提升了2.97个百分点和2.55个百

分点。在实时监测方面,Xie等^[16]提出Faster DR-IACNN检测框架,该框架融合了Inception-v1多路径卷积、Inception-ResNet-v2残差连接以及SE-blocks通道注意力机制,在葡萄叶片病害检测中平均精度达到81.1%,且检测速率达到15.01 FPS,满足田间实时监测需求。DeepLeaf算法^[32]则采用模块化设计,引入模糊优化技术对CNN超参数进行自适应调整,使模型能够根据不同病害特征动态调节网络配置,在葡萄叶枯病、黑腐病识别中表现出色。

农业生产环境中,计算资源有限,这推动了轻量化网络的发展。Tang等^[33]提出融合通道注意力的紧凑型CNN架构,采用深度可分离卷积和通道剪枝技术,在保持99.14%识别准确率的同时,将模型大小从227.5 MB压缩至4.2 MB,显著提升了模型在移动设备上的部署能力。Chen等^[34]将轻量级MobileNet架构与SE注意力模块结合,通过对通道特征响应进行自适应重标定,使模型能够聚焦于与病害相关的关键特征区域,在保持计算效率的同时提升了细粒度分类的准确性。为提升模型在真实场景下的泛化能力,Wang等^[35]基于ImageNet预训练模型进行领域自适应微调,并结合实验室标准化图像与田间复杂环境图像进行联合训练,有效提升了模型的泛化能力。

近年来,Transformer架构凭借其强大的全局建模能力逐步应用于作物病害识别领域。Swinv2-Base等基于自注意力机制的模型在PlantVillage数据集上实现了100%的分类准确率,展现出Transformer架构在捕获图像全局依赖关系方面的优势^[36]。Yu等^[37]提出了融合卷积特征交互的Swin Transformer网络(ST-CFI),该网络通过引入跨阶段残差连接(RCBS)和ResNet残差卷积分支,将残差卷积模块与层次化Transformer结构深度融合,从而增强了模型对复杂环境中病害特征的识别能力。Hu等^[38]提出FOTCA混合架构,该架构利用自适应傅里叶神经算子(AFNO)融合Transformer与CNN,通过频域特征增强策略,有效整合了CNN的局部特征提取能力与Transformer的全局建模能力,在复杂田间环境下实现了对叶片病害的准确识别。

近年来,视觉-语言大模型的快速发展为农业病虫害的智能检测开辟了新的方向。Zhang等^[39]针对田间复杂环境,提出了面向开放场景的小麦病害视觉大语言模型,有效提升了模型的鲁棒性。Yan

等^[40]提出的CDIP-ChatGLM3双模型框架,通过融合计算机视觉与语言模型技术,同步生成病害识别结果与防治方法。

在葡萄叶片病害检测领域,深度学习技术已取得显著进展,但仍面临诸多挑战。首先,数据类别不均衡问题突出,罕见病害样本的不足严重制约了模型整体性能。尽管已有数据增强、生成对抗网络和代价敏感学习等方法,但在极端不平衡场景下难以保证模型识别精度。Wang等^[41]提出的基于掩码自编码器(MAE)的自监督学习框架,为解决标注数据不足问题提供了新思路。其次,田间环境非常复杂,光照变化、叶片遮挡、背景噪声和病害症状的动态演变均会影响模型检测效果。在有限标注样本条件下,Sharma等^[42]构建的半监督集成学习框架将模型检测精度提升了18.03%。

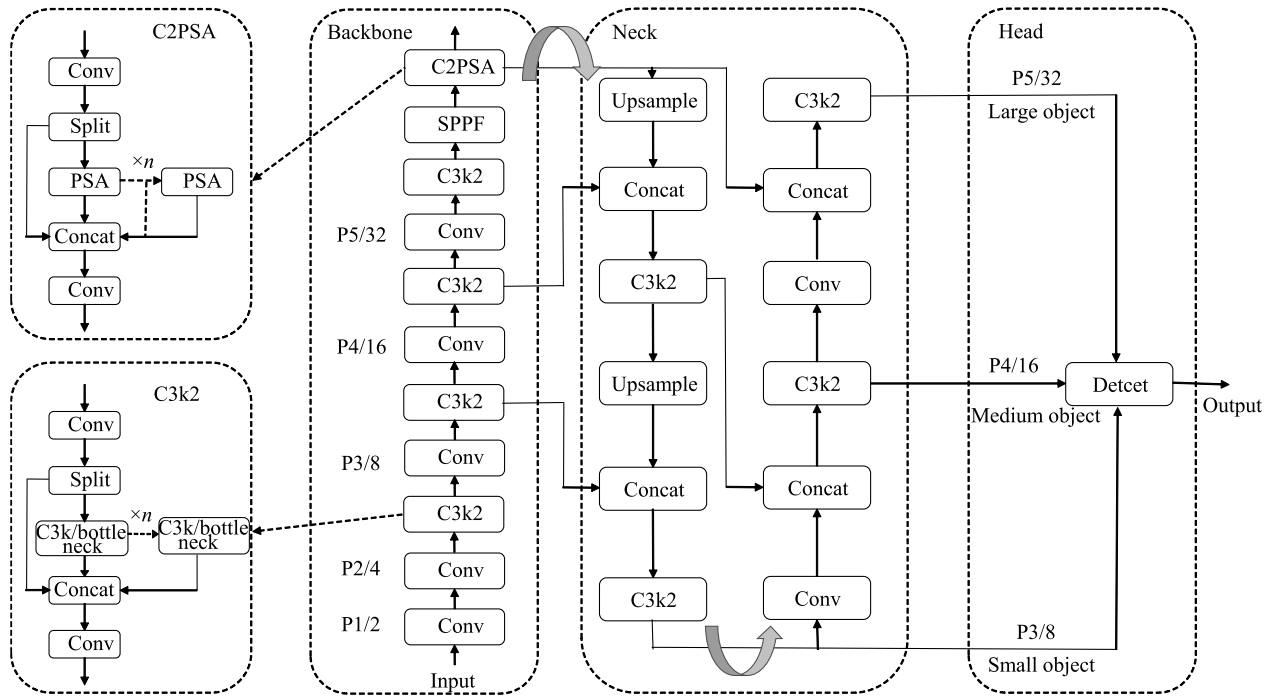
2.2 基于YOLO算法的葡萄叶片病害检测

YOLO系列算法作为单阶段目标检测的代表性算法兼具优异的实时性和准确性,在农业病害检测领域得到广泛应用。以YOLOv11算法为例,其网络结构如图4所示。

YOLO算法在葡萄叶片病害检测中具有明显优势^[43],其端到端的检测框架能够直接从原始图像中提取病害特征并完成定位与分类,避免了传统两阶段检测算法的计算冗余^[44]。同时,其统一的网络架构可同时输出多个边界框和类别概率,显著提升了检测效率。在实际应用层面,YOLO算法能够在保持较高精度的同时能够满足田间实时监测的需求,为精准农业提供了技术支持^[45]。

然而,葡萄叶片病害检测仍面临诸多挑战,包括病斑形态多样、尺度差异显著、早期症状不明显、复杂背景干扰等。原始YOLO算法在处理小尺度病斑和复杂背景干扰时存在一定局限性。为此,研究者们针对葡萄叶片病害的特点对算法进行了改进,主要集中在网络轻量化、注意力机制引入和损失函数优化等方面。表1总结了基于YOLO算法的葡萄叶片病害检测算法的主要改进方法。

表2总结了近年来YOLO系列算法在葡萄叶片病害检测方面的应用进展。从性能指标来看,改进后的YOLO算法平均检测精度普遍在90%以上,其中EBS-YOLOv7算法和基于GhostNetV2改进的YOLOv8算法表现最为突出,平均精度均值(mAP)分别达到98.3%和98.2%。



Input: 输入; Backbone: 主干网络; Neck: 颈部网络; Head: 头部网络; Conv: 卷积层; C3k2: 特征提取模块; SPPF: 空间金字塔池化模块; C2PSA: 融合跨阶段部分连接和空间注意力机制的模块; Upsample: 上采样层; Concat: 拼接层; Detectet: 检测头; Split: 分割操作; PSA: 空间注意力机制; C3k/bottleneck: 瓶颈模块; Output: 输出; P1/2: 第1层特征图; P2/4: 第2层特征图; P3/8: 第3层特征图; P4/16: 第4层特征图; P5/32: 第5层特征图; $\times n$: 模块被重复执行 n 次; Large object: 大目标检测; Medium object: 中目标检测; Small object: 小目标检测。

图4 YOLOv11 网络结构
Fig.4 YOLOv11 network structure

表1 用于葡萄叶片病害检测的YOLO算法的改进方法

Table 1 Improved methods of YOLO algorithms for grape leaf disease detection

基础算法	骨干网络替换	添加注意力机制	优化损失函数	其他改进	改进后算法	参考文献
YOLOv3	ShuffleNetv2 替换骨干网络	CBAM	-	FPN 加入小目标检测层	YOLO-SL	[46]
YOLOv4	Dense-CSPDarkNet53 替换骨干	-	-	SPP 增强感受野, 优化激活函数	改进 YOLOv4	[47]
YOLOv4	PSA 模块替代 3x3 卷积	CA	-	-	YOLOv4-PSA-CA	[48]
YOLOv5n	Slimming 剪枝压缩	-	WIoU	CARAFE 上采样	改进 YOLOv5n	[49]
YOLOv5s	MobileNetV3 替换骨干	CA	WIoU	-	改进 YOLOv5s	[50]
YOLOv5s	-	RFACConv+CBAM	WIoU	-	YOLOv5s-RCW	[51]
YOLOv7	加入 P2 层和新检测头	改进 CA	Focal-SIoU	-	YOLOv7-PC	[52]
YOLOv7	EfficientNet 替换骨干	BiFormer	Siou	-	EBS-YOLOv7	[53]
YOLOv8	C2f 替换为 C2_P	EMA	EIoU	BiFPN 结构	EBP-YOLOv8	[54]
YOLOv8s	DSConv 引入骨干末端	GAM	Focal-EIoU	增加小目标检测头	改进 YOLOv8s	[55]
YOLOv8n	C2f_MS-Block 替代 C2f	CBAM	-	-	CMS-YOLOv8n	[56]
YOLOv8	GhostNetV2 骨干网络	GAM	Focal-EIoU	SPPFCSPC 池化模块	GhostNetV2-YOLOv8	[57]
YOLOv8n	-	SimAM	NWDLoss	SiLU 激活函数	YOLOv8n-Grape	[58]
YOLOv9	-	-	Powerful-IoU v2	-	改进 YOLOv9	[59]
YOLOv11n	RepConv HGNetv2 替换骨干	LSKA (LSPF 模块)	-	Slim-neck 架构, LSCSBND (检测头)	改进 YOLO11n	[60]

CBAM: 卷积块注意力模块; CA: 通道注意力机制; WIoU: 加权损失函数; RFACConv + CBAM: 加权卷积与 CBAM 结合; 改进 CA: 改进的通道注意力机制; Focal-SIoU: 焦点定位损失函数; BiFormer: 双重注意力机制; EMA: 指数移动平均; Siou: 尺度 IoU 损失函数; GAM: 全局注意力机制; SimAM: 简单注意力机制; LSKA: 可学习空间知识注意力; EIoU: 扩展 IoU 损失函数; NWDLoss: 新型权重损失函数; Powerful-IoU v2: 强大的 IoU v2 损失函数; FPN: 特征金字塔网络; SPP: 空间金字塔池化; CARAFE: 内容感知特征重组; BiFPN: 双向特征金字塔网络; SPPFCSPC: 空间金字塔池化与跨阶段部分连接结合的模块; SiLU: Sigmoid 线性单元; Slim-neck: 一种轻量化的颈部网络架构; LSCSBND: 改进后的检测头。

表 2 YOLO 系列算法在葡萄叶片病害检测中的性能对比
Table 2 Performance comparison of YOLO-series algorithms in grape leaf disease detection

算法	准确率 (%)	召回率 (%)	平均精度均值 (%)	参考文献
改进 YOLOv3 (YOLO-SL)	-	86.6	90.4	[46]
改进 YOLOv4	-	-	91.5	[47]
改进 YOLOv4 (YOLOv4-PSA-CA)	82.04	84.24	84.07	[48]
改进 YOLOv5n	-	-	94.1	[49]
改进 YOLOv5s	97.6	96.6	97.6	[50]
YOLOv5s-RCW	86.8	83.8	87.6	[51]
YOLOv7-PC	89.3	90.6	93.8	[52]
EBS-YOLOv7	97.4	96.2	98.3	[53]
EBP-YOLOv8	-	-	95.4	[54]
改进 YOLOv8s	-	-	90.9	[55]
CMS-YOLOv8n	-	-	91.8	[56]
GhostNetV2-YOLOv8	98.7	97.3	98.2	[57]
YOLOv8n-Grape	85.0	84.8	90.4	[58]
YOLOv9	-	-	92.7	[59]
RLSL-YOLO11	82.8	76.1	83.1	[60]

综上所述,相较于传统 CNN 方法,YOLO 算法在

表 3 卷积神经网络 (CNN) 与 YOLO 算法的对比

Table 3 Comparison of convolutional neural network (CNN) and YOLO algorithm

对比维度	CNN	YOLO
任务类型	图像分类,输出病害类别	目标检测,同时输出病害位置与类别
训练数据需求	仅需图像类别标注,标注成本较低	需边界框标注,标注成本较高
小目标检测能力	对全局特征敏感,小病斑易被忽略或误判	通过多尺度检测头设计提升对小目标的检测效果
检测精度	可达 97.0%~100.0%,Swinv2-Base 达 100.0%	可达 83.0%~98.0%,EBS-YOLOv7 达 98.3%
推理速度	推理速度较慢,难以满足实时需求	实时性强,适合田间在线监测
模型大小	参数量大	参数量适中
部署成本	需要较高算力支持,边缘部署困难	轻量化模型易于部署于移动端和嵌入式设备
鲁棒性	对背景噪声敏感,需要图像预处理或图像分割	端到端检测对背景干扰有一定鲁棒性,但复杂遮挡场景仍会影响检测效果
典型应用场景	实验室病害分类、病害类型鉴定	田间实时监测、无人机巡检、智能植保作业

注意力机制是增强模型特征表征能力的重要技术,已在葡萄叶片病害检测中得到广泛应用。不同类型的注意力机制在计算效率、特征增强方式及适用场景上存在显著差异。表 4 对现有研究中常用的注意力机制进行了对比。

葡萄叶片病害检测领域展现出独特优势。一方面,其检测速度快、定位准确,适用于田间实时监测;另一方面,通过对网络结构、注意力机制和损失函数的改进,有效提升了 YOLO 算法在复杂田间环境下的检测精度与鲁棒性,实现了精度与速度的平衡。该技术为葡萄叶片病害的早期诊断提供了技术支持。

未来研究可进一步探索 YOLO 与 Transformer 架构的融合,以及面向边缘设备的极致轻量化设计。如 Alzahrani 等^[61]提出 Swin-YOLO-SAM 框架,集成 Swin Transformer、YOLOv12 和 SAM-2.1,实现枣椰叶片病害的自动识别与分割。Li 等^[62]将 DETR 检测框架应用于植物病害识别,实现了端到端的检测范式革新。

卷积神经网络与 YOLO 算法虽同属深度学习技术体系,但两者在设计目标与应用场景上存在显著差异。融合 Transformer^[37]后,基于传统 CNN 的分类模型识别精度可达 99%,但计算复杂度高、实时性弱。而 YOLO 算法系列端到端的统一检测框架,在兼顾精度的同时显著提升了处理速度,其轻量化改进版本更易于部署至边缘设备,从而更好地契合精准农业对实时响应的需求。卷积神经网络与 YOLO 算法的对比如表 3 所示。

3 数据集

3.1 葡萄叶片病害数据集现状

高质量标注数据集是葡萄叶片病害智能检测模型训练和评估的基础,其规模、多样性与标注精度直

接影响模型的性能和泛化能力。然而,当前葡萄叶片病害检测领域面临数据资源匮乏的困境,现有公开数据集在样本数量、场景覆盖和标注规范等方面

存在明显不足,制约了检测模型的进一步发展。本文对主要公开数据集进行了系统梳理,总结其特征、优势与局限性。

表 4 不同注意力机制在葡萄叶片病害检测中的性能对比

Table 4 Performance comparison of different attention mechanisms in grape leaf disease detection

注意力机制	关键技术	优点	缺点	适用场景	平均精度均值(%)
SE ^[34]	对通道维度进行全局平均池化后,通过全连接层学习通道权重	计算成本低,纹理特征增强效果好	空间信息丢失严重,导致目标定位精度下降	轻量化模型、通道特征增强需求场景	93.6
CA ^[48,50,52]	分别沿高度和宽度方向编码位置信息	能够保留位置信息,对方向性病斑检测能力强	对不规则形状适应性较弱,结构复杂度较高	移动端部署、小目标检测任务	97.6
CBAM ^[46,36]	串联通道注意力与空间注意力模块	通用性强,特征增强效果显著	密集目标干扰下注意力易分散,模块顺序影响最终效果	需要精确定位的病斑检测场景	91.8
GAM ^[55,57]	全局注意力机制,实现跨通道和空间的信息交互	在复杂背景下鲁棒性强	计算成本高,实时性受限	复杂背景下的病害检测任务	98.2
BiFormer ^[53]	采用双层路由注意力机制	全局特征捕获能力强,检测精度高	参数量大,易过拟合,边缘部署困难	大规模数据集、高精度检测要求场景	98.3
SimAM ^[58]	基于神经元重要性的无参数注意力机制	不增加参数,适合轻量化部署	特征增强能力有限	资源极度受限的边缘设备	90.4
LSKA ^[60]	基于大核可分离卷积的注意力机制	大感受野,参数效率高	对小目标检测效果提升有限	需要大感受野的检测任务	83.1

SE:SE 注意力机制;CA:通道注意力机制;CBAM:卷积块注意力机制;GAM:全局注意力机制;BiFormer:双重注意力机制;SimAM:简单注意力机制;LSKA:大型可分离核注意力机制。

PlantVillage 数据集是植物病害识别领域最具代表性和影响力的数据集之一^[36,63],包含 14 种作物共 54 306 张图像,其中葡萄图像 4 062 张,涵盖黑腐病、褐斑病、霜霉病和健康叶片 4 种类别,所有图像统一处理为 256×256 像素分辨率。该数据集具有标注质量高、类别分布均衡的优点,但样本采集环境高度标准化,缺少自然光照变化、复杂背景干扰等田间实际条件。在真实田间场景中,基于该数据集训练的模型准确率下降 30%~40%^[64]。AI Challenger 2018 数据集包含约 3 000 张葡萄病害图像,涵盖 7 种病害类型,来源多样^[65-66],但存在严重的类别不平衡问题,部分罕见病害样本不足 100 张,严重制约了模型对罕见病害的识别能力。土耳其团队构建的 Grapevine Leaves Image Dataset 包含葡萄品种信息^[67],有助于研究不同品种间的病害表现差异,但样本规模仅 500 张,难以满足深度神经网络的训练需求。

为弥补现有数据集的不足,近年来研究者构建了一系列更具针对性的葡萄病害数据集。Alessandrini 等^[68]构建了葡萄叶片埃斯卡病害数据集。Özacar 等^[69]开发的 Hermos 数据集包含针对白粉病、枯枝病和霜霉病等常见病害样本。Dharrao

等^[70]于 2023-2025 年采集了 2 726 张高质量葡萄叶片病害图像,涵盖霜霉病、白粉病和细菌性叶斑病,因数据集图像清晰、标注精确,使应用该数据库的 ResNet-18 模型分类准确率达 96%。

尽管国际公开数据集为算法研究提供了基础,但由于葡萄品种、种植环境、病害类型存在地域差异,这些数据集难以直接用于国内农业研究。为此,国内研究机构构建了更符合本地需求的数据集。田琪^[71]基于深度学习技术构建了田间葡萄霜霉病数据集。何欣等^[72]构建了多尺度葡萄病害图像数据集,以适应不同拍摄距离的识别需求。刘易雪等^[73]采用无人机遥感技术获取大尺度葡萄病害数据,为规模化种植区的病害监测提供了新途径。虽然这类自建数据集较好地契合本地种植条件和病害特征,却普遍缺乏统一的图像采集规范和标注标准,导致不同研究之间的数据集难以进行横向比较,模型性能评估也缺乏客观一致的依据,在一定程度上限制了相关技术的标准化发展与应用推广。

表 5 总结了上述主要葡萄叶片病害数据集的关键特征。从表中可以看出,现有数据集呈现出明显的规模差异和功能分化:PlantVillage 等早期数据集规模较大但场景单一,近期的数据集针对性强但样

本量有限, Gawande Dataset 等多维度数据集尚未公开完整信息。

表 5 葡萄叶片病害数据集对比

Table 5 Comparison of grape leaf disease datasets

数据集名称	来源	规模	类别数	主要病害	文献
PlantVillage	公开	4 062	4	黑腐病、褐斑病、霜霉病、健康叶片	[36]、[63]
AI Challenger 2018	公开	3 000	7	黑腐病、褐斑病、轮斑病等	[65]、[66]
Esca Disease Dataset	公开	1 770	2	葡萄叶片埃斯卡病、健康叶片	[68]
Hermos Dataset	公开	914	4	白粉病、枯枝病、霜霉病	[69]
Niphad Grape Leaf Disease Dataset	公开	2 726	4	霜霉病、白粉病、细菌性叶斑病	[70]

3.2 数据标准化与样本扩增

针对现有数据集标准化程度不足的问题, 建立规范的数据采集和标注流程至关重要。采集环节应遵循以下标准化要求: 硬件配置方面, 使用 1.200×10^7 像素及以上的成像设备, 以确保图像质量; 拍摄参数方面, 将拍摄距离控制在 $20 \sim 50$ cm, 以保证病斑细节清晰可辨; 场景覆盖方面, 应涵盖不同光照条件和拍摄角度, 并记录拍摄时间、地点、品种等完整元数据; 样本分布方面, 按 $3:4:3$ 的比例采集轻度感染图像、中度感染图像、重度感染图像, 这种比例符合病害发展的自然分布规律。

在数据标注环节, 采用多级审核机制以确保质量。具体流程为: 第一级由经过统一培训和考核合格的标注员完成初级标注; 第二级由农学专业研究生进行中级审核, 重点核查标注的准确性和一致性; 第三级由植物保护领域专家最终确认。对于目标检测任务, 需精确标注病斑的边界框坐标, 标注信息应涵盖病害类型、严重程度、标注置信度等多维度属性。对于标注存在争议的样本, 可组织专家组讨论直至达成一致意见^[74-75]。

在数据采集和标注流程规范化的基础上, 数据

增强技术为进一步扩充样本规模、提升模型泛化能力提供了有效途径^[76]。传统数据增强方法包括几何变换(旋转 $\pm 45^\circ$ 、水平/垂直翻转、缩放 $0.8 \sim 1.2$ 倍)、颜色变换(亮度、对比度、饱和度调整 $\pm 20\%$)、噪声添加(高斯噪声、椒盐噪声)和局部遮挡模拟等, 可在一定程度上扩充训练样本, 提高模型的鲁棒性^[77]。针对叶片病害的特点, 研究者还探索了病斑扩展模拟、叶片纹理合成等定制化增强策略, 以更真实地模拟病害发展过程和叶片形态变化。基于生成对抗网络(GAN)的数据合成技术能够学习真实病害图像的分布特征, 生成逼真的病害样本, 不仅缓解了罕见病害与新发病害样本不足的问题, 也为小样本学习乃至零样本学习场景开辟了新思路^[78]。

表 6 对比了不同数据增强方法的效果。从数据增强效率看, GAN 合成可将样本量提升 400%, 远超传统方法; 从模型性能看, GAN 合成使基础模型准确率从 85.3% 提升至 93.5%, 提升幅度达 8.2 个百分点; 从鲁棒性看, GAN 合成的样本多样性更高, 能够更好地应对真实场景的复杂变化。这些结果表明, 深度学习驱动的数据合成技术在数据增强中具有显著优势。

表 6 数据增强方法对比

Table 6 Comparison of data augmentation methods

增强方法	参数设置	样本量增幅	准确率提升(%)	计算成本	适用场景
无增强(基础模型)	-	-	-	-	-
几何变换	旋转 $\pm 45^\circ$ 、水平/垂直翻转、缩放 $0.8 \sim 1.2$ 倍	$\times 4.0$	5.9	低	角度视角变化
颜色空间变换	亮度、对比度、饱和度调整 $\pm 20\%$	$\times 3.0$	4.4	低	光照条件变化
噪声添加	高斯噪声、椒盐噪声	$\times 2.0$	3.6	低	成像质量下降
局部遮挡模拟	随机擦除、Cutout	$\times 2.8$	5.1	低	叶片遮挡场景
GAN 合成	StyleGAN、DCGAN	$\times 5.0$	8.2	高	罕见病害样本扩充

GAN: 生成对抗网络; Cutout: 裁剪; DCGAN: 深度卷积生成对抗网络; StyleGAN: 风格生成对抗网络。

综上所述,高质量数据集是葡萄叶片病害智能检测技术发展的基础。当前该领域在数据资源建设方面主要面临以下挑战:一是公开数据集资源匮乏且场景覆盖单一,难以支撑模型在复杂田间环境中有效应用;二是数据集类别不平衡问题突出,罕见病害样本严重不足;三是数据采集和标注缺乏统一标准,导致不同研究的结果难以相互比较,试验过程也较难复现。此外,数据隐私保护、版权归属不明确以及缺乏标准化的共享机制等现实问题,也在一定程度上制约了高质量数据集的开放共享与协同建设。

未来研究应着力于制定并推广数据采集与标注的标准化规范,积极推动数据资源的开放共享,加快构建涵盖不同品种、生育阶段及环境条件的综合性基准数据集。同时,应充分利用数据增强与合成技术,并融合迁移学习、小样本学习等方法,以提升模型在数据有限场景下的性能表现,从而推动葡萄叶片病害智能检测技术向实用化与规模化方向稳步发展^[79]。

4 总结与展望

葡萄叶片病害智能检测技术逐步从传统图像处理技术到深度学习技术演进。CNN和YOLO算法的应用将病害识别准确率从60%~70%提升至95%以上,部分优化算法准确率可达98%~99%^[36]。注意力机制、特征金字塔、轻量化网络显著降低了模型参数和计算复杂度,使模型规模从百位数MB压缩至个位数MB量级^[80]。Fusion Transformer YOLO等融合Transformer架构的轻量化模型在葡萄病害实时检测任务中展现出优异性能^[81]。基于YOLOv8改进的SerpensGate模型,通过引入动态蛇形卷积和空间金字塔池化结构,有效提升了在复杂田间环境下的病害检测精度^[82]。

然而,该技术的产业化仍面临诸多挑战。数据资源方面,高质量标注样本获取困难,公开数据集场景单一,罕见病害样本严重不足;技术性能方面,现有模型在应对复杂多变的田间实际场景时,仍表现出泛化能力与鲁棒性的不足,且对早期病害检测能力有限;应用推广方面,模型决策过程缺乏可解释性,且部署成本较高、操作流程复杂,一定程度上制约了该技术在实际生产中的普及。

研究者不断探索将葡萄病害智能检测与无人

机、物联网以及智能施药设备深度融合。Manoj等^[83]提出了AgroVisionNet方法,采用CNN-Transformer混合网络融合无人机图像与田间物联网传感器数据,实现视觉与环境信息的协同决策,该模型可部署于边缘设备。Nyakuri等^[84]研发了一种便携式物联网设备,搭载Raspberry Pi5系统并集成Tiny-LiteNet轻量化模型,实现98.6%的病害检测准确率,推理时间仅80 ms。Ibrahim等^[85]构建了AI-IoT智能灌溉系统,该系统将ResNet50模型部署于Raspberry控制器,实现了植物病害识别与自动化喷药的闭环控制,准确率达99.8%,实现了病害检测与精准施药协同作业。边缘计算与多模态数据融合技术的应用正推动葡萄病害智能检测从实验室走向实际生产。

面向未来,该技术领域将呈现四大发展趋势。一是多模态信息融合,通过整合可见光、多光谱、高光谱、热成像等多源数据,结合气象、土壤、历史病害等信息,构建综合诊断体系^[86]。视觉-语言大模型的快速发展为农业智能诊断开辟了新的路径,Lu等^[87]提出的多模态Transformer模型,通过融合图像、文本和传感器数据实现了农业病害的高精度检测与智能交互问答。二是小样本和零样本学习技术应用,通过元学习、迁移学习、自监督预训练等方法解决罕见病害样本不足的问题,Mamun等^[88]系统综述了自监督学习在植物病害检测中的应用进展。三是可解释人工智能的发展,Hernández等^[89]的研究结果表明,通过注意力可视化、特征归因分析等技术可提升模型诊断过程的透明度^[80]。四是融入智能化植物保护管理体系,与精准施药、智能灌溉等技术联用,构建“监测-诊断-预警-防治-评估”全流程闭环系统。

作为智慧农业的重要组成部分,葡萄叶片病害智能检测技术正处于从技术积累向产业应用转化的关键时期,推动这一进程需要持续优化算法,突破数据质量、环境适应性等核心技术难题;深化产学研用协作,加快科技成果转化;建立并完善覆盖数据采集、模型评估与系统部署的标准化体系;降低技术使用门槛,开发便捷易用的产品。这些技术的协同推进将有效缓解过度施药和农药残留等问题,从而保障葡萄产业健康发展,减少对化学农药的依赖,提升果品质量安全、推动农业绿色转型,为农业现代化和乡村振兴提供科技支撑。

参考文献:

- [1] PENG J B, WANG X C, WANG H, et al. Advances in understanding grapevine downy mildew: from pathogen infection to disease management[J]. *Molecular Plant Pathology*, 2024, 25(1): e13401.
- [2] International Organisation of Vine and Wine. 2024 world wine production[R/OL]. (2024-11-29)[2025-10-23]. <https://www.oiv.int>.
- [3] 刘崇怀. 我国葡萄产业的现状、问题与建议[N]. *农民日报*, 2024-11-11.
- [4] 刘柯含, 张芮, 高彦婷, 等. 中国葡萄产业现状分析及其发展对策[J]. *中国果树*, 2024(7): 132-138.
- [5] RICCIARDI V, CRESPIAN M, MADDALENA G, et al. Novel loci associated with resistance to downy and powdery mildew in grapevine[J]. *Frontiers in Plant Science*, 2024, 15: 1386225.
- [6] 农业农村部. 2023年全国葡萄病害防控技术方案[EB/OL]. (2023-03-06)[2025-10-23]. <http://www.moa.gov.cn/>.
- [7] DAGOSTIN S, SCHÄRER H J, PERTOT I, et al. Are there alternatives to copper for controlling grapevine downy mildew in organic viticulture? [J]. *Crop Protection*, 2011, 30(7): 776-788.
- [8] 董小圆. 葡萄霜霉病的发生规律与防治措施[J]. *果农之友*, 2022, 35(6): 55-57.
- [9] 褚芳玲. 基于国家植保监测数据填报的葡萄霜霉病发生规律分析[J]. *河北农业*, 2025(7): 99-101.
- [10] 全国农业技术推广服务中心. 2023年全国葡萄病害防控技术方案[R]. 北京: 农业农村部, 2023.
- [11] 云南省科技厅. 绿色防控关键技术应用助力云南低纬高原葡萄产业发展[EB/OL]. (2024-09-18)[2025-09-29]. <https://kjt.yn.gov.cn>.
- [12] 张仙, 胡西洲, 彭西甜, 等. 2022年湖北地区市售葡萄中农药残留特征及膳食暴露风险评估[J]. *食品工业科技*, 2023, 44(19): 313-319.
- [13] 慕君林, 马博, 王云飞, 等. 基于深度学习的农作物病害检测算法综述[J]. *农业机械学报*, 2023, 54(增刊2): 301-313.
- [14] 周月. 基于深度学习的葡萄病害识别[D]. 杭州: 浙江农林大学, 2024.
- [15] JI M M, ZHANG L, WU Q F. Automatic grape leaf diseases identification via UnitedModel based on multiple convolutional neural networks[J]. *Information Processing in Agriculture*, 2020, 7(3): 418-426.
- [16] XIE X Y, MA Y, LIU B, et al. A deep-learning-based real-time detector for grape leaf diseases using improved convolutional neural networks[J]. *Frontiers in Plant Science*, 2020, 11: 751.
- [17] DOLATABADIAN A, NEIK T X, DANILEVICZ M F, et al. Image-based crop disease detection using machine learning[J]. *Plant Pathology*, 2025, 74(1): 18-38.
- [18] 田有文, 李天来, 李成华, 等. 基于支持向量机的葡萄病害图像识别方法[J]. *农业工程学报*, 2007, 23(6): 175-180.
- [19] PADOL P B, YADAV A A. SVM classifier based grape leaf disease detection[C]//CCTA. IEEE. 2016 Conference on Advances in Signal Processing (CASP). Pune: IEEE, 2016.
- [20] LI G L, MA Z H, WANG H G. Image recognition of grape downy mildew and grape powdery mildew based on support vector machine[C]//CCTA. Conference on Computer and Computing Technologies in Agriculture. Berlin: Springer, 2012.
- [21] VAISHNNAVE M P, DEVI K S, SRINIVASAN P, et al. Detection and classification of groundnut leaf diseases using KNN classifier[C]//IEEE. 2019 IEEE International Conference on System, Computation, Automation and Networking. Pondicherry: IEEE, 2019.
- [22] SOWMYA M, SUBRAMANI B. Disease detection on plant leaf using K-means segmentation with fuzzy logic SVM algorithm[J]. *International Journal of Health Sciences*, 2022, 6(S2): 4749-4756.
- [23] DHAWARE C G, WANJALE K H. A modern approach for plant leaf disease classification which depends on leaf image processing [C]//IEEE. 2017 International Conference on Computer Communication and Informatics. Coimbatore: IEEE, 2017.
- [24] NGUGI H N, AKINYELU A A, EZUGWU A E. Machine learning and deep learning for crop disease diagnosis: performance analysis and review[J]. *Agronomy*, 2024, 14(12): 3001.
- [25] HATUWAL B, SHAKYA A, JOSHI B. Plant leaf disease recognition using random forest, KNN, SVM and CNN[J]. *Polibits*, 2021, 62: 13-19.
- [26] CHAUDHARY A, KOLHE S, KAMAL R. An improved random forest classifier for multi-class classification[J]. *Information Processing in Agriculture*, 2016, 3(4): 215-222.
- [27] GEETHA V, PUNITHA A, ABARNA M, et al. An effective crop prediction using random forest algorithm[C]//IEEE. 2020 International Conference on System, Computation, Automation and Networking. Pondicherry: IEEE, 2020.
- [28] WANG G, SUN Y, WANG J X. Automatic image-based plant disease severity estimation using deep learning[J]. *Computational Intelligence and Neuroscience*, 2017, 2017: 2917536.
- [29] 张一帆. 基于卷积神经网络的果蔬叶片病害检测研究[D]. 淮南: 安徽理工大学, 2025.
- [30] 肖小梅. 基于深度学习的水稻害虫图像识别研究[D]. 南昌: 江西农业大学, 2022.
- [31] LIU B, DING Z F, TIAN L L, et al. Grape leaf disease identification using improved deep convolutional neural networks[J]. *Frontiers in Plant Science*, 2020, 11: 1082.
- [32] TALAAT F M, SHAMS M Y, GAMEL S A, et al. DeepLeaf: an optimized deep learning approach for automated recognition of grapevine leaf diseases [J]. *Neural Computing and Applications*, 2025, 37(15): 8799-8823.
- [33] TANG Z, YANG J L, LI Z, et al. Grape disease image classification based on lightweight convolution neural networks and channel-wise attention [J]. *Computers and Electronics in Agriculture*, 2020, 178: 105735.

- [34] CHEN J D, ZHANG D F, NANEHKARAN Y A. Identifying plant diseases using deep transfer learning and enhanced lightweight network[J]. *Multimedia Tools and Applications*, 2020, 79(41): 31497-31515.
- [35] WANG P, NIU T, MAO Y R, et al. Fine-grained grape leaf diseases recognition method based on improved lightweight attention network[J]. *Frontiers in Plant Science*, 2021, 12:738042.
- [36] KUNDURACIOGLU I, PACAL I. Advancements in deep learning for accurate classification of grape leaves and diagnosis of grape diseases[J]. *Journal of Plant Diseases and Protection*, 2024, 131(3): 1061-1080.
- [37] YU S, XIE L, DAI L. ST-CFI;swin transformer with convolutional feature interactions for identifying plant diseases[J]. *Scientific Reports*, 2025, 15(1): 25000.
- [38] HU B, JIANG W Q, ZENG J, et al. FOTCA: hybrid transformer-CNN architecture using AFNO for accurate plant leaf disease image recognition[J]. *Frontiers in Plant Science*, 2023, 14:1231903.
- [39] ZHANG K P, MA L, CUI B B, et al. Visual large language model for wheat disease diagnosis in the wild[J]. *Computers and Electronics in Agriculture*, 2024, 227:109587.
- [40] YAN C Q, LIANG Z Y, HAN C, et al. CDIP-ChatGLM3: a dual-model approach integrating computer vision and language modeling for crop disease identification and prescription[J]. *Computers and Electronics in Agriculture*, 2025, 236:110442.
- [41] WANG Y, NI D, HUANG Z Y, et al. A self-supervised learning framework based on masked autoencoder for complex wafer bin map classification[J]. *Expert Systems with Applications*, 2024, 249:123601.
- [42] SHARMA P, SHARMA A. A novel plant disease diagnosis framework by integrating semi-supervised and ensemble learning[J]. *Journal of Plant Diseases and Protection*, 2024, 131:177-198.
- [43] 王鑫杰,王吉平. YOLO 目标检测算法综述[J]. *广西物理*, 2024, 45(2): 50-53.
- [44] 方帅,沈岳,龙强,等. 基于YOLO算法的鸟类检测技术研究综述[J]. *农业与技术*, 2025, 45(3): 56-62.
- [45] 乔世成,赵晨雨,白明宇,等. 基于YOLO算法的农作物病害检测研究进展[J]. *内蒙古农业大学学报(自然科学版)*, 2025, 46(6): 86-93.
- [46] 刘广,胡国玉,古丽巴哈尔·托乎提,等. 基于改进YOLOv3的葡萄叶部病害检测方法[J]. *微电子学与计算机*, 2023, 40(2): 110-119.
- [47] 金彬,解祥新. 基于改进YOLOv4的葡萄叶片病害检测与识别算法[J]. *无线互联科技*, 2023, 20(18): 129-132.
- [48] 雷建云,叶莎,夏梦,等. 基于改进YOLOv4的葡萄叶片病害检测[J]. *中南民族大学学报(自然科学版)*, 2022, 41(6): 712-719.
- [49] 蔡易南,肖小玲. 基于改进YOLO v5n的葡萄叶病害检测模型轻量化方法[J]. *江苏农业科学*, 2024, 52(7): 198-205.
- [50] 岳喜申. 基于改进YOLOv5s的葡萄叶片病害识别方法研究[D]. 阿拉尔:塔里木大学,2024.
- [51] 姜红花,胡芳超,刘志鹏,等. 基于YOLO v5s-RCW的葡萄病害检测方法[J]. *农业机械学报*, 2026, 57(6): 281-289.
- [52] 佟心博. 基于YOLOv7的葡萄叶片病害检测算法研究[D]. 哈尔滨:哈尔滨理工大学,2024.
- [53] 杨宏宇,谢小龙,郭容,等. 基于EBS-YOLO v7的轻量化葡萄病害识别方法[J]. *江苏农业科学*, 2025, 53(5): 165-174.
- [54] 蔺瑶,曾晏林,刘金涛,等. 基于EBP-YOLOv8的葡萄叶片病害检测与识别方法研究[J]. *山东农业大学学报(自然科学版)*, 2024, 55(3): 322-334.
- [55] 张立强,武玲梅,蒋林利,等. 基于改进YOLO v8s的葡萄叶片病害检测[J]. *江苏农业科学*, 2024, 52(21): 221-228.
- [56] 冀常鹏,佐永吉,代巍. 基于CMS-YOLOv8n的葡萄叶片病害检测[J]. *沈阳农业大学学报*, 2025, 56(3): 95-105.
- [57] 张惠莉,代晨龙,任景龙,等. 基于GhostNetV2改进YOLO v8模型的葡萄病害识别方法研究[J/OL]. *农业机械学报*. (2024-08-27) [2025-10-20]. <https://link.cnki.net/urlid/11.1964.S.20240827.0948.004>.
- [58] 范明超,张和群,踪姿艳,等. 基于YOLO v8n-Grape的葡萄叶片病害小目标检测[J]. *江苏农业科学*, 2025, 53(9): 199-207.
- [59] 萧峥嵘,梁焯锋,李菲,等. 基于YOLOv9葡萄病害识别检测算法研究[J]. *现代信息科技*, 2025, 9(4): 64-68, 73.
- [60] 吴世琛,毛玉明,胡慧中,等. 基于改进YOLO11n的葡萄果叶病害检测方法[J]. *农业工程学报*, 2025, 41(14): 140-147.
- [61] ALZHRANI A S, IQBAL A, ZAFAR W, et al. Swin-YOLO-SAM: a hybrid Transformer-based framework integrating Swin Transformer, YOLOv12, and SAM-2.1 for automated identification and segmentation of date palm leaf diseases[J]. *Frontiers in Plant Science*, 2025, 16:1666374.
- [62] 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.
- [63] SHAFIK W, TUFAIL A, DE SILVA LIYANAGE C, et al. Using transfer learning-based plant disease classification and detection for sustainable agriculture[J]. *BMC Plant Biology*, 2024, 24(1): 136.
- [64] NOYAN A. Uncovering bias in the PlantVillage dataset[EB/OL]. (2022-06-09) [2025-10-23]. <https://arxiv.org/abs/2206.04374>.
- [65] YANG B, WANG Z L, GUO J Y, et al. Identifying plant disease and severity from leaves: a deep multitask learning framework using triple-branch Swin Transformer and deep supervision[J]. *Computers and Electronics in Agriculture*, 2023, 209:107809.
- [66] LIANG Q K, SHAO X, HU Y C, et al. PD2SE-Net: computer-assisted plant disease diagnosis and severity estimation network[J]. *Computers and Electronics in Agriculture*, 2019, 157: 518-529.
- [67] KOKLU M, UNLERSEN M F, OZKAN I A, et al. A CNN-SVM study based on selected deep features for grapevine leaves classification[J]. *Measurement*, 2022, 188: 110425.
- [68] ALESSANDRINI M, CALERO FUENTES RIVERA R, FALASCHETTI L, et al. A grapevine leaves dataset for early detection and classification of esca disease in vineyards through machine

- learning[J]. *Data in Brief*, 2021, 35:106809.
- [69] ÖZACAR T, ÖZTÜRK Ö, GÜNGÖR SAVAŞ N. Hermos: an annotated image dataset for visual detection of grape leaf diseases[J]. *Journal of Information Science*, 2024, 50(2):394-403.
- [70] DHARRAO M, ZADE N, KAMATCHI R, et al. Grapes leaf disease dataset for precision agriculture[J]. *Data in Brief*, 2025, 61:111716.
- [71] 田 琪. 基于深度学习的葡萄霜霉病害表型诊断:从实验室到田间的应用[D]. 杨凌:西北农林科技大学, 2025.
- [72] 何 欣, 李书琴, 刘 斌. 基于多尺度残差神经网络的葡萄叶片病害识别[J]. *计算机工程*, 2021, 47(5):285-291, 300.
- [73] 刘易雪, 宋育阳, 崔 萍, 等. 基于无人机遥感和深度学习的葡萄卷叶病感染程度诊断方法[J]. *智慧农业*, 2023, 5(3):49-61.
- [74] SINGH D, JAIN N, JAIN P, et al. PlantDoc: a dataset for visual plant disease detection [EB/OL]. (2019-11-22) [2025-10-23]. <http://arxiv.org/abs/1911.10317>.
- [75] SHOAB M, HUSSAIN T, SHAH B, et al. Deep learning-based segmentation and classification of leaf images for detection of tomato plant disease[J]. *Frontiers in Plant Science*, 2022, 13:1031748.
- [76] ARSENOVIC M, KARANOVIC M, SLADOJEVIC S, et al. Solving current limitations of deep learning based approaches for plant disease detection[J]. *Symmetry*, 2019, 11(7):939.
- [77] 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.
- [78] CHEN Y P, WU Q F. Grape leaf disease identification with sparse data via generative adversarial networks and convolutional neural networks[J]. *Precision Agriculture*, 2023, 24(1):235-253.
- [79] BALAFAS V, KARANTOUMANIS E, LOUTA M, et al. Machine learning and deep learning for plant disease classification and detection[J]. *IEEE Access*, 2023, 11:114352-114377.
- [80] KARIM M J, GONI M O F, NAHIDUZZAMAN M, et al. Enhancing agriculture through real-time grape leaf disease classification via an edge device with a lightweight CNN architecture and Grad-CAM[J]. *Scientific Reports*, 2024, 14:16022.
- [81] LIU Y F, YU Q D, GENG S Z. Real-time and lightweight detection of grape diseases based on Fusion Transformer YOLO [J]. *Frontiers in Plant Science*, 2024, 15:1269423.
- [82] MIAO Y Z, MENG W, ZHOU X Y. SerpensGate-YOLOv8: an enhanced YOLOv8 model for accurate plant disease detection [J]. *Frontiers in Plant Science*, 2024, 15:1514832.
- [83] MANOJ H M, SHANTHI D L, LAKSHMI B N, et al. AI-driven drone technology and computer vision for early detection of crop disease in large agricultural areas [J]. *Scientific Reports*, 2025, 15:32384.
- [84] NYAKURI J P, NKUNDINEZA C, GATERA O, et al. AI and IoT-powered edge device optimized for crop pest and disease detection [J]. *Scientific Reports*, 2025, 15:22905.
- [85] IBRAHIM A S, MOHSEN S, SELIM I M, et al. AI-IoT based smart agriculture pivot for plant diseases detection and treatment [J]. *Scientific Reports*, 2025, 15:16576.
- [86] XIE W J, ZHAO M C, LIU Y, et al. Recent advances in Transformer technology for agriculture: a comprehensive survey [J]. *Engineering Applications of Artificial Intelligence*, 2024, 138:109412.
- [87] LU Y C, LU X Y, ZHENG L P, et al. Application of multimodal transformer model in intelligent agricultural disease detection and question-answering systems [J]. *Plants*, 2024, 13(7):972.
- [88] MAMUN A A, AHMEDT-ARISTIZABAL D, ZHANG M H, et al. Plant disease detection using self-supervised learning: a systematic review [J]. *IEEE Access*, 2024, 12:171926-171943.
- [89] HERNÁNDEZ I, GUTIÉRREZ S, BARRIO I, et al. In-field disease symptom detection and localisation using explainable deep learning: use case for downy mildew in grapevine [J]. *Computers and Electronics in Agriculture*, 2024, 226:109478.

(责任编辑:成纾寒)