

基于二阶段深度模型的马铃薯晚疫病严重程度分级研究

袁培森¹ 董孟键¹ 谢小军¹ 谈钊汐^{2,3} 杨羽佳^{2,3} 何 骋^{2,3}

(1. 南京农业大学人工智能学院, 南京 211800; 2. 南京农业大学植物保护学院, 南京 211800;
3. 农林生物安全全国重点实验室, 南京 211800)

摘要: 晚疫病是马铃薯生长过程中最具灭绝性危害的病害, 精确量化马铃薯晚疫病严重程度是开展晚疫病防控的数据基础。传统的量化方式极度依赖于人工对马铃薯离体叶片面积及病斑面积的统计计算来划分严重等级, 但面对海量病害叶片的图像数据时, 人工量化的效率和准确度均难以满足实验需求。为解决上述问题, 本研究提出一种二阶段深度学习模型 YOLO – PIDNet, 对马铃薯晚疫病的严重等级进行批量自动分级。模型第 1 阶段使用改进后的 YOLO v8n 模型对图像中每枚马铃薯离体叶片进行分割和定位, 模型第 2 阶段使用改进后的 PIDNet 模型对图像中每枚马铃薯离体叶片上的晚疫病病斑进行精准分割, 计算图像中每枚离体叶片上病斑区域像素点数量和该离体叶片区域像素点数量的百分比, 依照晚疫病严重程度分级标准自动划分病害严重等级。测试结果显示方法第 1 阶段模型的 mAP₅₀₋₉₅、内存占用量、浮点运算量和帧率分别为 95.82%、6.8 MB、7.8 × 10⁹ 和 142.08 f/s, 第 2 阶段模型的像素准确率、Dice 系数和平均交并比分别为 99.70%、0.843 3 和 74.55%。上述结果表明, 本研究提出的二阶段模型可以实现对马铃薯离体病叶快速、有效地分割与分级, 具有轻量化、可迁移性高的特点, 可为马铃薯晚疫病精准防治提供技术支撑。

关键词: 马铃薯晚疫病; 二阶段模型; 深度学习; 病害严重程度分级; 离体叶片

中图分类号: TP391 文献标识码: A 文章编号: 1000-1298(2026)19-0336-10

OSID:



Severity Evaluation of Potato Late Blight Based on Two-stage Depth Modeling

Yuan Peisen¹ Dong Mengjian¹ Xie Xiaojun¹ Tan Yixi^{2,3} Yang Yujia^{2,3} He Cheng^{2,3}

(1. College of Artificial Intelligence, Nanjing Agricultural University, Nanjing 211800, China
2. College of Plant Protection, Nanjing Agricultural University, Nanjing 211800, China
3. State Key Laboratory of Agricultural and Forestry Biosecurity, Nanjing 211800, China)

Abstract: Late blight is the most devastating disease in potato production, and precise quantification of its severity level serves as the data foundation for disease control. Traditional quantification of potato detached leaf area and lesion spot area relies heavily on manual statistics and calculations to determine disease severity levels. However, when dealing with a massive amount of disease leaf image data, manual quantification falls short in both efficiency and accuracy, failing to satisfy experimental requirements. To address these challenges, a two-stage deep learning model named YOLO – PIDNet was proposed for automated batch severity grading of potato late blight. Stage 1 employed an enhanced YOLO v8n model to achieve segmentation and localization of individual detached potato leaves. Stage 2 employed an improved PIDNet architecture to achieve precise segmentation of late blight lesions on each leaf. The model calculated the pixel ratio between lesion areas and total leaf regions, automatically classifying disease severity according to standardized criteria. Experimental results demonstrated that the stage 1 model achieved 95.82% mAP₅₀₋₉₅ with 6.8 MB parameter size, 7.8 × 10⁹ FLOPs computational complexity, and 142.08 f/s inference speed. The stage 2 model attained 99.70% pixel accuracy, 0.843 3 Dice coefficient, and 74.55% mean intersection over union. The above experimental results indicate that the two-stage model proposed in this study can achieve rapid and effective segmentation and classification of

the detached diseased potato leaves. It is lightweight and highly transferable, and can provide technical support for the precise control of late blight for potatoes.

Key words: potato late blight; two-stage model; deep learning; disease severity grading; detached leaf

0 引言

马铃薯是我国继小麦、玉米和水稻之后的第四大主粮,是关涉我国粮食安全的农作物之一^[1]。2023 年我国马铃薯种植面积约为 $4.459 \times 10^6 \text{ hm}^2$,马铃薯全年产量为 $1.906 \times 10^7 \text{ t}$ ^[2]。然而,马铃薯作物最容易受到各种疾病的影响,导致产量和质量的显著损失。马铃薯晚疫病是我国马铃薯生产过程中第一大病害^[3],是目前阻碍马铃薯产业发展的最大障碍之一。早期发现并准确量化马铃薯晚疫病严重程度在晚疫病的防控中尤为重要,基于量化数据预测预报晚疫病发生情况并指导农户精准施药,不仅可以阻止损失扩大,显著提高马铃薯的产量与品质,还能避免用药过度带来的环境污染,符合我国“减药增效,绿色防控”的防控策略。因此,如何快速、精准地量化马铃薯晚疫病严重程度已经成为研究和应用领域中备受瞩目的课题^[4-7]。

对马铃薯离体叶片晚疫病严重等级快速、精确判别是量化其严重程度的核心^[8]。传统的马铃薯叶片晚疫病等级判别极度依赖人工统计与计算,通常需要投入大量人力物力,且大量数据的人工分析极易造成统计误差从而影响最终结果。因此,亟需开发量化马铃薯晚疫病严重程度的创新技术,实现病害严重等级的快速、批量和精准分级,进而指导精准施药,最终实现减药增效的绿色防控策略^[9-10]。随着计算机技术的发展,传统机器学习和深度学习在农业领域得到广泛应用^[11-12]。

目前对植物病害程度的研究大多数基于深度学习^[13-15]。Li 等^[16]提出实例分割、分类、语义分割模型的框架,以实现复杂背景下马铃薯叶片病害的分割与检测。第 1 阶段利用 Mask R-CNN 模型对复杂背景下的马铃薯叶片进行分割,第 2 阶段使用 VGG16 分类模型对分割后的叶片进行病害分类,第 3 阶段应用 UNet 语义分割模型对已分类的叶片进行病斑区域分割。通过将这 3 个阶段的模型相结合,实现对马铃薯叶片病害的精准分割与检测;胡耀华等^[17]采用 374~1 018 nm 高光谱成像技术,对 48 个晚疫病菌接种马铃薯离体叶片及 12 个对照样本进行 7 d 时序监测,结合 ENVI 平台提取光谱特征,经移动平均平滑、导数处理及光谱变换优化数据后构建 LS-SVM 模型。结果显示,原始光谱与光谱变换模型的病害识别率达 94.87%。

已有研究大多数是针对单个叶片病害程度分级的研究,因此本文提出二阶段模型来批量划分图像中多枚马铃薯离体叶片的晚疫病严重等级。模型第 1 阶段采用改进的 YOLO v8n 模型,分割与定位图像中的马铃薯叶片,得到图像中每枚马铃薯叶片的像素点数量和位置信息;第 2 阶段采用改进的 PIDNet 模型,分割图像中的病斑区域,再根据第 1 阶段模型获取的叶片位置信息得到每枚马铃薯叶片上病斑区域的像素点数量。将晚疫病像素点数量和叶片像素点数量的比值作为马铃薯晚疫病严重程度的判定依据,对照马铃薯晚疫病分级标准,进而得到图像中每枚离体叶片的晚疫病严重等级。

1 材料与方法

1.1 数据集采集

本文所用的马铃薯叶片图像数据均为实验室背景条件下的离体叶片,图像数据来源于山东省德州市的实验园区。本文采集了费乌瑞特、青薯 9 号、克新 1 号等多个马铃薯品种的健康叶片样本。在实验室进行晚疫病接种处理,后续使用 RGB 相机进行图像采集,光照为室内光源,包含不同晚疫病程度下的马铃薯叶片图像,格式为 JPG,分辨率为 2 736 像素 × 3 648 像素。共采集 500 幅原始图像,从中选取 300 幅图像作为实验数据。马铃薯数据集图像示例如图 1 所示。




图 1 部分马铃薯数据集图像

Fig. 1 Partial images of potato dataset

1.2 数据增强

使用 Labelme 标注工具对两阶段模型所需要的图像数据分别标注^[18],第 1 阶段数据标注工作是沿马铃薯叶片边缘对叶片进行标注,第 2 阶段数据标注工作是沿晚疫病边缘进行标注。马铃薯叶片标注和晚疫病标注结果如图 2 所示。

针对数据集少、样本分布不均匀等问题,通常对




图 2 马铃薯图像标注
Fig. 2 Potato image annotations

数据集集中的样本进行数据增强以扩充数据集图像的数量,实现更复杂的数据描述,提高模型分割的精度。样本分布不均衡主要表现为图像中有效目标区域过少,这会导致模型过度关注背景特征而忽视病害区域。通过裁剪病斑密集区域可提升有效区域占比,从而改善模型对关键特征的捕捉能力。常见的数据扩充方法有水平翻转、旋转、缩放、剪裁、添加噪声等^[19]。本文数据增强采用随机旋转、水平镜像翻转、垂直镜像翻转、添加噪声以及缩放的方式。第 1 阶段数据增强后的扩展数据集包含 1 644 幅马铃薯叶片图像,将第 1 阶段图像数据集按照比例 4:1 划分为训练集与测试集;第 2 阶段数据增强后的扩展数据集包含 450 幅马铃薯叶片图像,同样将第 2 阶段图像数据集按照比例 8:2 划分为训练集与测试集。

数据增强后的马铃薯图像示例如图 3 所示。虽然 MixUp^[20]、CutMix^[21] 和 PuzzleMix^[22] 可用于组合多个图像以创建新的训练数据集,但是这些方法并不适用于实例级别,对实例分割和语义分割任务的作用有限。

2 YOLO – PIDNet 模型

2.1 YOLO v8n 与 PIDNet 模型结合

本文模型由两阶段深度学习模型组成,结合实




图 3 数据增强结果示例
Fig. 3 Example of data augmentation results

际情况中推理性能的要求,调整模型网络结构和更改特征提取网络,从而达到提升分割准确率以及缩短分割时间的目的。第 1 阶段使用改进后的 YOLO v8n 模型,第 2 阶段使用改进后的 PIDNet 模型,本文 YOLO – PIDNet 模型整体架构如图 4 所示。

第 1 阶段模型任务是分割与定位图像中的马铃薯离体叶片,得到图像中每枚叶片的像素点数量和位置信息,实现量化马铃薯离体叶片晚疫病严重程度的第一步。在第 1 阶段改进后的 YOLO v8n 模型中,主干网络的作用是提取图像核心特征,图像由 FasterNet^[23] 嵌入层卷积模块进行卷积,实现高效的推理速度;嵌入高效通道注意力^[24] (Efficient channel attention, ECA) 机制,提取前面阶段的重要特征信息,再经过快速空间金字塔池化 (Spatial pyramid pooling faster, SPPF),实现局部特征和全局特征融合;进而输入到颈部网络,在颈部网络将上、下不同卷积层得到的特征图融合,提升网络分割能力;在头部网络中保留原始模型的分割头,最后输出分割结果。

第 2 阶段模型任务是分割图像中的晚疫病区域,并根据第 1 阶段模型获取的离体叶片位置信息,判断病斑所属叶片。马铃薯图像输入到第 2 阶段模型,在改进后的 PIDNet^[25] 模型中,对输入的马铃薯叶片图像进行 3 次卷积下采样,获取分辨率为原始




图 4 YOLO – PIDNet 模型整体架构图

Fig. 4 Overall architecture diagram of YOLO – PIDNet model

图像分辨率 1/8 的有效特征图,该特征图作为 PID 三支结构输入。其中,比例分支 P 旨在解析和保留高分辨率特征图中的细节信息,并通过 Pag 模块与积分分支 I 进行交互,同时将特征图输出至 S-Head 以计算模型损失。积分分支 I 则负责聚合局部和全局上下文信息,以捕获远距离依赖。RAD 模块对分辨率为原始图像分辨率 1/8 的特征图进行 3 次下采样,得到分辨率为原始图像分辨率 1/64 的特征图,在第 2 次和第 3 次下采样过程中,与比例分支 P 中的 Pag 模块进行交互。微分分支 D 负责提取高频特征以预测边界区域,并通过特征图相加的方式与积分分支 I 进行信息融合。最终,PID 三支的输出通过 Bag 注意力引导模块进行特征融合,得到模型的最终输出。

经过上述 2 个阶段,得到图像中每枚马铃薯离体叶片像素点数量和该离体叶片上晚疫病病斑像素点数量,计算马铃薯图像中每枚叶片的病斑区域与叶片区域的像素点数量百分比,对照马铃薯晚疫病严重等级表,模型最终输出图像中每枚叶片的晚疫病严重等级。

2.2 YOLO v8n 模型改进

YOLO 系列算法是单阶段目标检测算法的代表,在目标检测任务中取得多次 SOTA 表现,同样在实例分割任务中也取得不错的成绩。YOLO v8n 模型^[26]是 YOLO 系列中轻量级版本,所需计算资源少,更容易在移动端部署,故本文选择改进 YOLO v8n 作为第 1 阶段模型。

在第 1 阶段,由于马铃薯图像所包含的背景单一,干扰信息较少,YOLO v8n 模型可以很好地分割出图像中的每枚叶片。但存在计算复杂度高、体积大、检测速度慢等问题。故采用减小模型体积、降低模型计算复杂度等思路进行改进。改进后的 YOLO v8n 模型如图 4 中第 1 阶段部分所示,本文改进重

- 点如下:
- (1)用 FasterNet 轻量级网络结构改进主干特征提取网络,解决检测速度慢和模型计算量大这 2 个关键问题。
 - (2)将损失函数替换为 MPDIoU,解决原 YOLO v8n 模型中 CIoU 损失函数的局限性。
 - (3)在骨干网络中引入 ECA,增强模型对马铃薯叶片特征的提取能力,提高检测精度。

2.2.1 FasterNet 轻量网络结构

在神经网络中,卷积操作用于提取图像特征,而卷积神经网络中多层卷积结构的叠加会提升模型的复杂度。研究证明,降低这种复杂度,有助于去除特征中的冗余和干扰信息,从而对实例分割任务的精度提升具有积极作用。GhostNet^[27]、ShuffleNets^[28]以及 MobileNets^[29]模型,便是借助深度卷积和分组卷积来提取空间特征的。上述 2 种卷积虽然可以降低模型浮点运算量,但这些操作符合带来内存访问量增加的弊端。

为进一步提高马铃薯叶片的分割速度,基于 FasterNet 轻量级网络结构重构主干特征提取网络。FasterNet 推出一种全新的部分卷积 (Partial convolution, PConv)。PConv 仅在部分输入通道上有规则地施加常规卷积,而不会对其他通道造成干扰。并且在 PConv 的基础上,还附加一个逐点卷积 (Pointwise convolution, PWConv),以此来充分且高效地利用所有通道信息。每个 FasterNet Block 都配备一个 PConv 层,其后连接着 2 个 PWConv 层或是 1 个 1 × 1 卷积层。它们协同构成反向残差块的架构,其中间层具备拓展后的通道数量,同时为反复利用输入特征,还增设快捷连接。基于 FasterNet Block 构建而成的 FasterNet 轻量级结构,在分类、分割、检测等多个领域都展现出卓越的性能,FasterNet Block 结构见图 5。




图 5 FasterNet Block 轻量网络结构图

Fig. 5 FasterNet Block lightweight network architecture

2.2.2 MPDIoU 损失函数

YOLO v8 源代码中所用的损失函数是 CIoU^[30],CIoU 只考虑重叠面积、中心点距离以及纵

横比这 3 个几何因素。在实例分割过程中,并未考虑决定模型精度的另一重要因素:边界框 (Bounding box),这会造成模型精度不高和收敛速度较慢的现象。

为了解决上述问题,本文使用 MPDIoU 损失函数^[31]来替代原始的损失函数。MPDIoU 是一种基于最小点距离的边界框相似度比较度量,其中包含现有损失函数中考虑的所有相关因素,例如重叠或非重叠面积、中心点距离以及宽度和高度的偏差,同时简化计算过程,减少无用损失,使模型将注意力更多地聚焦在马铃薯叶片位置,可以有效提高模型分割精准度,同时还可以加快模型收敛速度,提升实例分割的速度。

MPDIoU 损失函数通过最小化预测边界框和真实边界框之间的左上和右下点距离,充分挖掘水平矩形的几何特征,有效提高边界框回归性能。计算公式为

$$L_{\text{MPDIoU}} = 1 - \text{IoU} + \frac{d_{\text{top}}^2}{w^2 + h^2} + \frac{d_{\text{bottom}}^2}{w^2 + h^2} \quad (1)$$

$$d_{\text{top}}^2 = (x_1^{\text{gt}} - x_1^{\text{pre}})^2 + (y_1^{\text{gt}} - y_1^{\text{pre}})^2 \quad (2)$$

$$d_{\text{bottom}}^2 = (x_2^{\text{gt}} - x_2^{\text{pre}})^2 + (y_2^{\text{gt}} - y_2^{\text{pre}})^2 \quad (3)$$

式中 d_{top} ——实际框左上点与右下点的欧氏距离
 d_{bottom} ——预测框左上点与右下点的欧氏距离

w, h ——输入图像的宽度、高度

IoU ——交并比

$x_1^{\text{gt}}, x_2^{\text{gt}}, y_1^{\text{gt}}, y_2^{\text{gt}}$ ——实际标注边界框的坐标信息

$x_1^{\text{pre}}, x_2^{\text{pre}}, y_1^{\text{pre}}, y_2^{\text{pre}}$ ——预测边界框的坐标信息

2.2.3 高效通道注意力

ECA^[24]是一种通道注意力机制的实现形式,是基于压缩和激励(Squeeze and excitation, SE)注意力机制的扩展,用于增强卷积神经网络对各个通道的重要性判断。SE 模块中的通道注意力通过全连接层来计算,而 ECA 则采用更简单、更高效的方式。

在骨干网络中嵌入 ECA 模块可以提升特征提取能力。ECA 模块提出跨通道交互,学习相邻的 k 个通道之间的信息,相比于对角矩阵可以更好地学习通道间的信息,相比于普通的 $C \times C$ 全矩阵,可以减少参数量,其中 C 表示通道。在 ECA 模块中,特征图首先进行全局平均池化,得到一个 $1 \times 1 \times C$ 的向量,对其进行卷积,维持其维数不变化,最后将得到向量映射到 0 到 1 之间的小数作为通道权重,与原特征图进行相乘。ECA 模块中 k 取 5 是基于通道数自适应计算得出,能在保持较低计算量的同时有效捕获通道间关系,ECA 模块结构如图 6 所示,图中 H 与 W 分别表示高度与宽度。

2.3 PIDNet 模型改进

本文选取三支网络结构的 PIDNet 模型^[25]进行改进,作为第 2 阶段模型,用于分割马铃薯叶片图像中的晚疫病病斑区域。经研究,二分支网络架构




图 6 ECA 注意力机制

Fig. 6 ECA attention mechanism

在实时语义分割任务中展现出其高效性和有效性。然而,直接融合高分辨率细节和低频上下文会出现细节特征容易被周围上下文信息淹没的问题。这种现象限制现有二分支模型分割准确性的提升。为解决上述问题,PIDNet 网络设计 3 个互补的分支,比例分支 P 在高分辨率特征图中解析和保存细节信息,积分分支 I 在局部和全局聚合上下文信息来解析长距离依赖,微分分支 D 提取高频特征来预测边缘区域。

在 PIDNet 算法中,输入图像先是经过 3 次卷积结构进行下采样,输出原分辨率 1/8 的特征图,目的是为得到高级语义信息,方便后续对马铃薯图像像素精确解析,PIDNet 模型的积分分支 I 负责下采样过程的特征图信息提取,从原图分辨率的 1/8 逐步下采样到原图像分辨率的 1/64。在此期间,并没有进行特征增强操作,由此导致特征图在下采样过程中损失局部信息,导致模型精度下降。为了在特征图下采样过后保留局部细节信息,本文提出通道注意力机制、残差连接和深度分离可卷积相结合的 RAD 模块,用于提高分割精度。

RAD 模块的设计思路:深度神经网络模型的训练过程中,随着网络层数的加深,会出现梯度消失问题^[32],导致模型不稳定现象,故引入残差连接^[33];深度可分离卷积^[34]的设计,可使每个通道分别计算输出。因此可以对每个通道的特征图进行局部注意力关注,用于减少注意力机制模块带来的计算成本增加,达到轻量化的效果。此外,较大的 5×5 卷积核在深层网络中拥有较大的感受野,更易于收集图像大范围内的信息,RAD 结构如图 7 所示。

PIDNet 模型中的积分分支 I 共进行 3 次 2 倍下采样,下采样会损失局部信息,因此改进思路是分别在 3 次下采样之后都加入 RAD 模块,用于增强模型的图像特征表达能力。

3 实验与结果分析

3.1 评价指标

第 1 阶段模型选择平均精度均值(Mean average precision, mAP),评价精度分割效果。使用浮点运算量(Floating-point operations per second, FLOPs)、




图 7 RAD 模块
Fig. 7 RAD module

帧率 (Frames per second, FPS) 和内存占用量来评价模型的计算复杂度、处理速度和模型大小。

第 2 阶段模型选择像素准确率 (Pixel accuracy, PA)、平均交并比 (Mean intersection over union, MIoU) 和 Dice 系数评价模型分割性能。

3.2 马铃薯叶片晚疫病严重程度计算公式

科研人员需要计算马铃薯叶片图像中每枚离体叶片的病害严重程度并作记录,以病斑面积占叶片面积的比值作为划分晚疫病严重等级的标准,计算公式为

$$P = \frac{S_{\text{Disease}}}{S_{\text{Leaf}}} \times 100\%$$
 (4)

式中 P ——病斑占叶片比例, %
 S_{Disease} ——病斑像素点数量
 S_{Leaf} ——叶片像素点数量

3.3 分割结果及分析

本文模型所采用的训练及测试硬件配置如下: CPU 为 i5 - 13400f, 内存 32 GB, 显卡为 NVIDIA

RTX4060 8 GB 显存, 操作系统为 Windows 10, CUDA 版本 11.3, Python 版本 3.7, Pytorch 版本 1.12.0。

为避免超参数对实验结果产生影响, 本文将各网络模型超参数进行统一设置, 经过多次实验, 最终选定学习率为 10^{-4} , 训练轮次 300, 批处理大小 4, 优化器采用 SGD。

为验证 YOLO - PIDNet 模型对马铃薯晚疫病病害具有较好的分割和分级效果, 本文实验分别在第 1 阶段和第 2 阶段进行消融实验和对比实验。模型默认将训练效果最好的文件保存为最终的权重文件, 用于测试。

3.3.1 第 1 阶段实验结果

第 1 阶段的任务是分割与定位图像中的每枚马铃薯离体叶片。为验证 YOLO v8n 模型各个部分的改进对初始算法的影响, 在保持训练参数一致的情况下对模型进行训练和测试, 设计消融实验与对比实验。

如表 1 消融实验结果所示, 第 1 阶段模型评价指标 mAP_{50-95} 、内存占用量、浮点运算量和帧率分别为 95.82%、6.8 MB、 7.8×10^9 和 142.08 f/s。与原 YOLO v8n 相比, 第 1 阶段模型的各个指标均有提升, mAP_{50-95} 和帧率分别提高 0.16 个百分点和 14.33 f/s, 同时内存占用量和浮点运算量分别为原 YOLO v8n 模型的 58.12% 和 71.56%。FasterNet 是轻量级网络结构, 显著提高推理速度, 通常会出现模型精度降低的现象。故只使用 FasterNet 替换原 YOLO v8n 模型的主干网络时, mAP_{50-95} 、内存占用量降低, 帧率提高。实验结果表明, 第 1 阶段模型在减小内存占用量和计算复杂度的同时, 有效提高模型的精度和处理速度, 可以部署在资源受限的硬件上。

表 1 第 1 阶段模型消融实验结果
Tab.1 Ablation result of stage 1 model

模型	模块			$mAP_{50-95}/\%$	内存占用量/ MB	浮点运算量	帧率/(f·s ⁻¹)
	FasterNet	MPDIoU	ECA				
YOLO v8n				95.66	11.7	1.09×10^{10}	127.75
YOLO v8n - FasterNet	✓			95.59	6.8	7.8×10^9	140.22
YOLO v8n - MPDIoU		✓		95.88	11.7	1.09×10^{10}	128.98
YOLO v8n - ECA			✓	95.76	11.7	1.09×10^{10}	132.72
第 1 阶段模型	✓	✓	✓	95.82	6.8	7.8×10^9	142.08

注: ✓表示采用此模块。

为了保证实验公平性, 选取模型体量相当且代码开源的 YOLO 系列算法, 在构建的马铃薯叶片数据集上进行训练, 并保持实验环境和训练参数一致, 不同模型的对比结果如表 2 所示。由表 2 对比实验结果可知, 第 1 阶段模型综合表现高于后续的 SOTA

模型 YOLO v9t。

图 8 为第 1 阶段模型与原 YOLO v8n 模型精确率变化曲线, 由图 8 可以看出, 在前 30 个迭代周期中 2 个模型之间的精确率相差较大, 在 30 个迭代周期之后逐渐趋于平稳并且差距减小, 最终第 1 阶段

表 2 第 1 阶段不同模型对比结果

Tab.2 Comparative results of stage 1 different models

模型	mAP ₅₀₋₉₅ /	内存占用	浮点运算	帧率 /
	%	量 / MB	量	(f·s ⁻¹)
YOLO v8n	95.66	11.7	1.09 × 10 ¹⁰	127.75
YOLO v5n	94.28	9.8	1.19 × 10 ¹⁰	120.38
YOLO v9t	95.72	11.9	5.32 × 10 ¹⁰	61.10
第 1 阶段模型	95.82	6.8	7.8 × 10 ⁹	142.08




图 8 第 1 阶段精确率变化曲线

Fig.8 Precision variation curves in stage 1

模型精确率高于原 YOLO v8n 模型。

图 9 为第 1 阶段模型与原 YOLO v8n 损失变化曲线,2 个模型的损失值在训练刚开始大幅度下降且在 30 个迭代周期之后逐渐趋于平稳。与原 YOLO v8n 模型相比,第 1 阶段模型损失函数曲线较为平滑且损失值较低。




图 9 第 1 阶段损失值变化曲线

Fig.9 Loss value variation curves in stage 1

图 10 为不同模型的马铃薯离体叶片分割效果,图中,蓝色像素点表示马铃薯叶片区域。在同一实验环境下,第 1 阶段模型与 YOLO v5n、YOLO v8n 和 YOLO v9t 模型相比,分割效果有细微提升,可以较为完整地叶片进行分割,且分割轮廓较为平滑。

本文第 1 阶段模型精准地分割马铃薯图像中的每枚离体叶片,得到每枚叶片的像素点数量和位置信息,为每枚叶片晚疫病严重程度的分级提供基础。而 YOLO v5n、YOLO v8n 和 YOLO v9t 模型由于特征提取网络结构的不同,分割速度较慢并且模型体量




图 10 马铃薯叶片分割结果

Fig.10 Potato leaf segmentation results

较大,不利于部署在移动端上,不能实时量化晚疫病病害的严重等级。

3.3.2 第 2 阶段实验结果

第 2 阶段任务是分割马铃薯叶片图像中晚疫病病斑,并根据第 1 阶段马铃薯叶片位置信息判断病斑所属马铃薯叶片。

为验证在积分分支 I 中添加 RAD 模块对初始算法的影响,在保持训练参数一致的情况下对原 PIDNet 算法和添加 RAD 模块的 PIDNet 算法进行测试。为保证实验结果公平,同时对比 DeepLabV3 + 和 U-Net 模型,在构建的马铃薯叶片晚疫病数据集上进行训练,结果如表 3 所示。

表 3 第 2 阶段不同模型对比结果

Tab.3 Comparative results of stage 2 different models

模型	像素准确率 / %	Dice 系数	平均交并比 / %
PIDNet	99.63	0.801 9	69.38
DeepLabV3 +	98.95	0.689 4	68.84
U-Net	97.76	0.706 1	69.52
第 2 阶段模型	99.70	0.843 3	74.55

从表 3 中可以看出,第 2 阶段模型评价指标像素准确率、Dice 系数和平均交并比分别为 99.70%、0.843 3 和 74.55%,均优于其他模型。与原 PIDNet 模型相比,分别提升 0.07 个百分点、0.041 4 和 5.17 个百分点。证明 RAD 模块在下采样过程中能够有效保留关键特征,从而提升像素分类的精度。像素准确率高于平均交并比的原因在于像素准确率直接体现分类像素的准确性,而平均交并比在计算时更侧重于综合考虑分类错误的情况后再进行平均。

在图 11 损失值变化曲线中,第 2 阶段模型与原 PIDNet 模型的损失值在训练刚开始大幅度下降且在 80 个迭代周期之后逐渐趋于平稳,与原 PIDNet

模型相比,改进后模型的损失函数曲线更加平滑且损失值较低。




图 11 第 2 阶段损失值变化曲线

Fig. 11 Loss value variation curves in stage 2

图 12 为不同模型的晚疫病病斑分割结果,颜色比较深的区域是病斑,浅色区域是接种晚疫病留下的水渍。DeepLabV3 + 和 U - Net 模型对病斑边缘的分割效果不理想,会将健康区域和浅色水渍区域误认为病斑区域。原 PIDNet 模型将图像背景误认为病斑,第 2 阶段模型可以精准分割马铃薯叶片上的病斑。




图 12 晚疫病病斑分割结果

Fig. 12 Segmentation results of late blight lesions

在第 2 阶段,根据第 1 阶段马铃薯叶片位置信息,可以得到每枚叶片上病斑的像素点数量。依据公式(4)得到病斑像素数占叶片总像素数的百分比,对照马铃薯晚疫病分级标准表,即可得出图像中每枚叶片的晚疫病严重等级。

3.3.3 马铃薯晚疫病分级标准

马铃薯晚疫病分级指标标准依据国家农药田间药效试验准则(一)和植保专家的参考意见综合制定,一共包含 6 个等级,具体等级标准如表 4 所示。

当病害等级为 0,则认为马铃薯叶片为健康叶

表 4 马铃薯晚疫病病害分级标准

Tab.4 Potato late blight severity grading standard

病害等级	病斑面积占叶片比例/%
0	0
1	(0,5]
2	(5,20]
3	(20,50]
4	(50,66]
5	(66,100]

片,此时植株的抗病能力强;当病害等级为 1 时,植株轻微染病,但对植株自身的生长无较大影响,抗病能力较强;当病害等级为 2 与 3 时,植株染病面积增大,光合作用效果轻微下降,生成养分略微减少,此时植株抗病能力下降,表现性状为感病;当病害等级为 4 时,光合作用效果下降明显,生成养分减少,表现性状为感病;病害等级为 5 时,叶片面积的 2/3 以上被病斑占据,叶片基本无法进行光合作用,且通过药物治疗无法治愈。

3.3.4 本文模型分级结果

YOLO - PIDNet 模型最终分级结果的准确率,是指正确分级病害等级的叶片数量占实际属于该病害等级的叶片总数量的百分比。本文以第 2 阶段数据集的测试集来测试马铃薯晚疫病分级结果,共 90 幅图像,包含 1 416 枚马铃薯叶片。将模型预测叶片的病害严重程度与人工标注叶片的严重程度进行比较,计算出本文模型对于病害等级划分的准确率,经测试晚疫病严重等级分级结果如表 5 所示。本研究提出的模型在处理 90 幅图像时,帧率达到 48.91 f/s。

表 5 YOLO - PIDNet 模型最终分级结果

Tab.5 Final grading results of YOLO - PIDNet model

病害等级	马铃薯叶片数量	晚疫病正确分级数量	准确率/%
0	473	456	96.41
1	306	281	91.83
2	173	142	82.08
3	198	162	81.82
4	100	82	82.00
5	166	163	98.19

由表 5 可知,对病害等级 5 级的分级准确率最高,为 98.19%,对病害等级 3 级的分级准确率最低,为 81.82%,基本满足科研需求。等级 2、等级 3 和等级 4 准确率低主要由样本类别分布不均衡,中等病害样本较少导致。此外,第 2 阶段模型存在将背景纹理误判为病斑的问题。如图 13 所示,模型将原始图像左下角红框内的背景错误识别为病斑,主要原因是该区域与病斑区域高度相似。




图 13 误将背景纹理识别为病斑

Fig. 13 Errors in identifying background texture as disease spots

4 结论

(1)本文提出基于两阶段模型的马铃薯晚疫病严重等级量化方法。第 1 阶段模型分割马铃薯图像中每枚叶片区域,得到每枚叶片的像素点数量,并实

现对马铃薯叶片的定位。第 2 阶段模型分割图像中晚疫病病斑区域,根据叶片位置信息得到每枚叶片上晚疫病区域的像素点数量,计算病斑区域像素点数量与马铃薯叶片区域像素点数量的百分比,依据马铃薯晚疫病分级标准,最终得到图像中每枚马铃薯叶片的晚疫病严重程度。

(2)充分利用 YOLO v8n 与 PIDNet 模型的优点,并分别对 YOLO v8n 模型与 PIDNet 模型进行改进,使得模型在面对较复杂目标时仍具备较好的分割效果。第 1 阶段模型对叶片的分割效果有所提升,指标 mAP_{50-95} 、内存占用量、浮点运算量和帧率分别为 95.82%、6.8 MB、 7.8×10^9 和 142.08 f/s。同样第 2 阶段模型对病斑的分割效果也有提升,像素准确率、Dice 系数和平均交并比分别为 99.70%、0.843 3 和 74.55%,较原 PIDNet 模型提升 0.07 个百分点、0.041 4 和 5.17 个百分点。

参 考 文 献

[1] 杨雯婷,王克秀,唐铭霞,等. 马铃薯新品种‘川芋 62’的选育[J]. 中国马铃薯, 2025,38(5):414–418.
Yang Wenting,Wang Kexiu,Tang Mingxia, et al. Selection and breeding of new table potato variety ‘Chuanyu 62’[J]. Chinese Potato Journal, 2025,38(5):414–418. (in Chinese)

[2] 国家统计局. 中国统计年鉴[M]. 北京:中国统计出版社,2023.

[3] 田峰奇,王路遥,董莎萌. 马铃薯与致病疫霉互作研究进展与展望[J]. 植物保护, 2023,49(5):89–110.
Tian Fengqi,Wang Luyao,Dong Suomeng. Recent research progresses and outlook on interaction between potato and late blight[J]. Plant Protection,2023,49(5):89–110. (in Chinese)

[4] 王艳平,谢婉莹,陈佳,等. 马铃薯晚疫病综合防治措施[J]. 中国马铃薯, 2023,37(2):158–166.
Wang Yanping,Xie Wanying,Chen Jia, et al. Integrated control measures of potato late blight[J]. Chinese Potato Journal, 2023,37(2):158–166. (in Chinese)

[5] Sun H G, Song X Y, Guo W, et al. Potato late blight severity monitoring based on the relief-mRmR algorithm with dual-drone cooperation[J]. Computers and Electronics in Agriculture, 2023,215:1–12.

[6] Dong S M, Zhou S Q. Potato late blight caused by phytophthora infestans: from molecular interactions to integrated management strategies[J]. Journal of Integrative Agriculture, 2022,21(12):3456–3466.

[7] 何铭,徐建飞,金黎平. 2023 年马铃薯遗传育种研究进展[C]//第二十五届中国马铃薯大会, 2024:115–122.

[8] Hou B R, Hu Y H, Zhang P, et al. Potato late blight severity and epidemic period prediction based on Vis/NIR spectroscopy[J]. Agriculture, 2022,12(7):1–17.

[9] 翟肇裕,曹益飞,徐焕良,等. 农作物病虫害识别关键技术研究综述[J]. 农业机械学报, 2021,52(7):1–18.
Zhai Zhaoyu,Cao Yifei,Xu Huanliang, et al. Review of key techniques for crop disease and pest detection[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021,52(7):1–18. (in Chinese)

[10] 袁培森,欧阳柳江,翟肇裕,等. 基于 MobileNetV3Small-ECA 的水稻病害轻量级识别研究[J]. 农业机械学报, 2024, 55(1):253–262.
Yuan Peisen,Ouyang Liujiang,Zhai Zhaoyu, et al. Lightweight identification of rice diseases based on improved ECA and MobileNetV3Small[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(1):253–262. (in Chinese)

[11] Patil S, Shrikant D, Bodhe S. Leaf disease severity measurement using image processing[J]. International Journal of Engineering and Technology, 2011,3(5):297–301.

[12] 胡秋霞,田杰,何东健,等. 基于改进型 C-V 模型的植物病斑图像分割[J]. 农业机械学报, 2012,43(5):157–161.
Hu Qixia,Tian Jie,He Dongjian, et al. Segmentation of plant lesion image using improved C-V model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2012,43(5):157–161. (in Chinese)

[13] Li K Y, Song Y Z B, Zhu X Y, et al. A severity estimation method for lightweight cucumber leaf disease based on DM-BiSeNet[J]. Information Processing in Agriculture, 2025,12(1):68–79.

[14] Wspanialy P, Moussa M. A detection and severity estimation system for generic diseases of tomato greenhouse plants[J]. Computers and Electronics in Agriculture, 2020,178:1–9.

[15] 杜鹏飞,黄媛,高欣娜,等. 基于语义分割的复杂背景下黄瓜叶部病害严重程度分级研究[J]. 中国农机化学报,

- 2023,44(11):138–147.
- Du Pengfei,Huang Yuan,Gao Xinna, et al. Research on cucumber leaf disease severity classification in complex background based on semantic segmentation[J]. Journal of Chinese Agricultural Mechanization, 2023,44(11):138–147. (in Chinese)
- [16] Li X D, Zhou Y H, Liu J Y, et al. The detection method of potato foliagediseases in complex background based on instance segmentation and semantic segmentation[J]. Frontiers in Plant Science, 2022,13:1–13.
- [17] 胡耀华, 平学文, 徐明珠, 等. 高光谱技术诊断马铃薯叶片晚疫病的研究[J]. 光谱学与光谱分析, 2016,36(2):515–519.
- Hu Yaohua,Ping Xuewen,Xu Mingzhu, et al. Detection of late blight disease on potato leaves using hyperspectral imaging technique[J]. Spectroscopy and Spectral Analysis,2016,36(2):515–519. (in Chinese)
- [18] Russell B C, Torralba A, Murphy K P, et al. LabelMe: a database and web-based tool for image annotation[J]. International Journal of Computer Vision, 2008,77:157–173.
- [19] 冯晓硕, 樾沈, 王冬琦. 基于图像的数据增强方法发展现状综述[J]. 计算机科学与应用, 2021,11(2):1–13.
- Feng Xiaoshuo,Yue Shen,Wang Dongqi. A survey on the development of image data augmentation[J]. Computer Science and Application,2021,11(2):1–13. (in Chinese)
- [20] Zhang H Y, Cisse M, Dauphin Y N, et al. Mixup: beyond empirical risk minimization[PP/OL]. V1. arXiv(2017–10–25) [2025–02–03]. <https://arxiv.org/abs/1710.09412>.
- [21] Yun S, Han D, Chun S, et al. CutMix: regularization strategy to train strong classifiers with localizable features[C] // Proceedings of the IEEE International Conference on Computer Vision, 2019:6023–6032.
- [22] Kim J H, Choo W, Song H O. Puzzle mix: exploiting saliency and local statistics for optimal mixup[C] // International Conference on Machine Learning, 2020:5275–5285.
- [23] Chen J R, Kao S, He H, et al. Run, don't walk: chasing higher flops for faster neural networks[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023:12021–12031.
- [24] Wang Q L, Wu B G, Zhu P F, et al. ECA–Net: efficient channel attention for deep convolutional neural networks[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020:11534–11542.
- [25] Xu J C,Xiong Z X,Bhattacharyya S P. PIDNet: a real-time semantic segmentation network inspired by PID controllers[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023:19529–19839.
- [26] Varghese R, Sambath M. YOLO v8: a novel object detection algorithm with enhanced performance and robustness[C] // International Conference on Advances in Data Engineering and Intelligent Computing Systems, 2024:1–6.
- [27] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020:1–10.
- [28] Zhang X Y, Zhou X Y, Lin M X, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018:6848–6856.
- [29] Howard A G, Zhu M L, Chen B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[PP/OL]. V1. arXiv(2017–04–17) [2025–02–21]. <https://arxiv.org/abs/1704.04861>.
- [30] 刘忠, 卢安舸, 崔浩, 等. 基于改进 YOLO v8 的轻量化荷叶病虫害检测模型[J]. 农业工程学报, 2024,40(19):168–176.
- Liu Zhong,Lu Ange,Cui Hao, et al. Lightweight model for detecting lotus leaf diseases and pests using improved YOLO v8 [J]. Transactions of the CSAE, 2024,40(19):168–176. (in Chinese)
- [31] Ma S L, Xu Y. MPDIoU: a loss for efficient and accurate bounding box regression[PP/OL]. V1. arXiv(2023–07–14) [2025–03–03]. <https://arxiv.org/abs/2307.07662>.
- [32] Xavier G, Yoshua B. Understanding the difficulty of training deep feedforward neural networks[C] // Proceedings of the Thirteen International Conference on Artificial Intelligence and Statistics,2010:249–256.
- [33] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C] // IEEE Conference on Computer Vision,2017:764–773.
- [34] Chollet F. Xception: deep learning with depthwise separable convolutions[C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017:21–26.