

DOI: 10.13733/j.jcam.issn.2095-5553.2025.04.016

刘宇平, 刘程飞, 赵平伟. 基于DeepLabv3—Faster—R—CNN的水稻叶片病害检测方法[J]. 中国农机化学报, 2025, 46(4): 108—113, 132

Liu Yuping, Liu Chengfei, Zhao Pingwei. Detection method of rice leaf disease based on DeepLabv3—Faster R—CNN [J]. Journal of Chinese Agricultural Mechanization, 2025, 46(4): 108—113, 132

基于 DeepLabv3—Faster R—CNN 的水稻叶片 病害检测方法*

刘宇平¹, 刘程飞², 赵平伟³

(1. 山西工程科技职业大学计算机工程学院, 山西晋中, 030619; 2. 太原理工大学信息与计算机学院, 太原市, 030024; 3. 山西农业大学信息科学与工程学院, 山西晋中, 030800)

摘要: 在农业生产中需要尽早准确地检测和识别水稻叶片病害。为减小水稻叶片病害识别中背景噪声的影响并提高病害检测的准确度, 提出一种基于 DeepLabv3—Faster R—CNN 网络的水稻叶片病害检测方法。待检测的水稻叶片图像首先经过 DeepLabv3 网络进行图像分割, 获得背景和叶片分割的初步结果, 再把经过背景分割的叶片图像中叶片部分还原进行检测, 从而规避背景部分噪声对检测结果的影响。检测部分主要由 Faster R—CNN 网络实现, 结合特征金字塔和 CBAM 方法, 提高模型对多尺度水稻叶片病害目标的检测能力。通过公开数据集训练模型, 得到该方法对白叶枯病、稻瘟病、褐斑病和黄矮病的平均检测准确率达到 98.1%。

关键词: 水稻叶片; 病害检测; 深度学习; 图像分割; 目标检测

中图分类号: S435.11; TP391.4 **文献标识码:** A **文章编号:** 2095-5553 (2025) 04-0108-07

Detection method of rice leaf disease based on DeepLabv3—Faster R—CNN

Liu Yuping¹, Liu Chengfei², Zhao Pingwei³

(1. School of Computer Engineering, Shanxi Vocational University of Engineering and Technology, Jinzhong, 030619, China; 2. School of Information and Computer Science, Taiyuan University of Technology, Taiyuan, 030024, China; 3. School of Information Science and Engineering, Shanxi Agricultural University, Jinzhong, 030800, China)

Abstract: The early and accurate detection and identification of rice leaf diseases are necessary in agricultural production. In order to reduce the impact of background noise on the identification of rice leaf diseases and improve the accuracy of disease detection, a rice leaf disease detection method based on the DeepLabv3—Faster R—CNN network is proposed in this study. The rice leaf image to be detected is first subjected to image segmentation by using the DeepLabv3 network, so as to obtain preliminary results of background and leaf segmentation. Then, the leaf part of the image, which has undergone background segmentation, is restored for detection, thereby avoiding the influence of background noise on the detection results. The detection part is mainly implemented by the Faster R—CNN network, and by combining the feature pyramid and the CBAM (Convolutional Block Attention Module) method, the model's ability to detect multi-scale rice leaf disease targets is improved. By training the model on a public dataset, the proposed method in this study achieves an average detection accuracy of 98.1% for white leaf spot, blast disease, brown spot disease and yellow stunt disease.

Keywords: rice leaf; disease detection; deep learning; image segmentation; object detection

0 引言

水稻作为全球重要的粮食作物之一, 其产量和质

量对全球粮食安全至关重要。水稻叶片病害是一种常见的生产障碍, 会导致产量下降和质量降低。因此, 及早、准确地检测和识别水稻叶片病害对于实现高产高

收稿日期: 2023年10月26日 修回日期: 2024年2月18日

* 基金项目: 国家自然科学基金资助项目(31671571)

第一作者: 刘宇平, 男, 1978年生, 山西大同人, 硕士, 讲师; 研究方向为计算机应用技术、交通机电工程等。E-mail: srmndhdhll2023@163.com

质水稻的栽培至关重要。

近年来,深度学习技术已经在水稻叶片病害检测领域引起广泛关注。这些方法能够自动从图像中提取特征,并通过训练来识别不同类型的病害。例如,Pallathadka 等^[1]提出一个基于机器学习的叶病分类和检测框架,使用了 SVM、贝叶斯框架和 CNN,并使用 PCA 算法进行特征提取,完成水稻叶片病害的分类和检测。Jhatial 等^[2]使用 YOLOv5 模型对水稻叶片病害进行检测。Pothen 等^[3]使用 Otsu 的方法对白叶枯病、叶黑穗病和褐色斑点病的图像进行分割,同时利用局部二进制模式(LBP)和定向梯度直方图(HOG)来分离各种特征,在支持向量机的辅助下对病害特征进行分类。浙江大学也进行了一系列关于水稻叶片病害检测的研究工作^[4]。此外,东北农业大学采用深度学习技术结合传统图像处理方法,致力于不同水稻品种和病害类型的检测,并开发用于水稻叶片病害自动检测的软件系统^[5]。

水稻叶片最常见的病害包括白叶枯病、稻瘟病、褐斑病和黄矮病等^[6]。为有效地识别植物叶片的病害,实验室更倾向于研究视觉上可观察到的水稻植株病害模式。在这一背景下,本文的研究旨在进一步提高水稻叶片病害检测的准确性和鲁棒性,以应对传统方法中常见的背景噪声问题。

当涉及水稻叶片病害检测时,背景部分的噪声常对最终的检测结果产生显著的负面影响。为应对这一问题,本文采用一种基于 DeepLabv3—Faster R—CNN 网络的检测方法。首先,待检测的水稻叶片图像经过 DeepLabv3 网络进行图像分割,该过程产生背景和叶片的初步分割结果;然后,通过从经过背景分割的叶片图像中还原出叶片部分,消除背景部分的干扰,从而提高检测结果的准确性和可靠性。此外,本方法的检测部分主要采用 Faster R—CNN 网络,并结合特征金字塔方法,为研究提供一种强大的病害检测工具,能够更好地理解和分析水稻叶片图像中的细节,提高病害检测系统对不同类别病害的检测能力。

1 材料与方法

1.1 数据获取

使用公开的 Rice Leaf Disease Image Samples 数据集^[6]训练网络模型,该数据集包含 5 932 个数字图像,包括 4 种水稻叶病:白叶枯病、稻瘟病、褐斑病和黄矮病,4 种水稻叶病的叶片图像数量比例基本相同。在使用数据集进行试验前将所有图像尺寸调整为 300 像素×300 像素。另外,4 种类别水稻叶片病害的图像均使用 Labelimg 图形注释工具,在每张图像上的

叶片病害区域用一个矩形边界框进行标识,并记录相应的病害类别标签。

1.2 数据增强

为尽可能地扩充数据集以增加图像多样性,从而在试验中验证所提方法具有鲁棒性,数据集通过几种常用的方法进行数据增强,如图 1 所示。

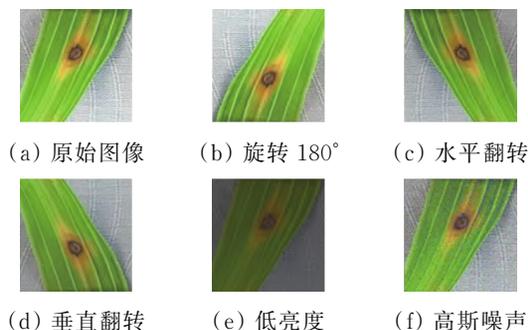


图 1 图像增强

Fig. 1 Image enhancement

数据增强的方法分别包括旋转 180°、水平翻转、垂直翻转、低亮度和添加高斯噪声。经过数据增强,数据集图像数量增加至 35 592 张图像,再将整个数据集划分为训练集、验证集和测试集,其比例为 80%、10%、10%。

1.3 Faster R—CNN 网络

本文提出的方法整体网络结构如图 2 所示。Faster R—CNN 算法是一种常用于目标检测类研究的深度学习方法,采用 Faster R—CNN 网络作为对水稻叶片病害进行检测的主体模块。Faster R—CNN 的主要组成部分包括骨干网络、区域建议网络(RPN)、ROI 池化、分类和回归网络^[7]。这些组件在整个检测过程中密切合作。骨干网络扮演特征提取的角色,负责从输入图像中提取有关水稻叶片病害的信息。首先,选择 ResNet 作为骨干网络,其通常是作为预训练的卷积神经网络,以确保有效的特征提取。其次,RPN 是 Faster R—CNN 的关键组件,负责生成候选目标区域^[8]。RPN 通过滑动窗口机制在特征图上提出多个可能包含目标的候选区域。这些提议区域将在后续的处理中被检测模型进一步评估。为确保候选区域具有一致的输入尺寸,使用 ROI 池化方法。ROI 池化将每个提议区域重新缩放到与特征图相同的尺寸,从而实现对不同大小区域的统一处理。区域建议网络会对这些候选区域进行分类和边界框回归来识别和定位图像中的目标。在一张包含多种病害的图像中,Faster R—CNN 会尝试对每个病害区域进行检测,并输出相应的边界框和类别标签,这意味着模型可以标识并定位图像中的多个病害区域,提供每个区域的位置信息和对应的病害类别。最后,Faster R—CNN 的分类和回归模块用于实现目标的分类和位置

定位。分类器确定每个提议区域是否包含水稻叶片病害,而回归器精确定位病害的位置。这两个子模块在联合工作下产生最终的检测结果,包括目标的类别标签和边界框坐标。Faster R—CNN 的端到端的训练过程使其能够同时执行目标提议和目标检测,具备出色的准确性和效率。

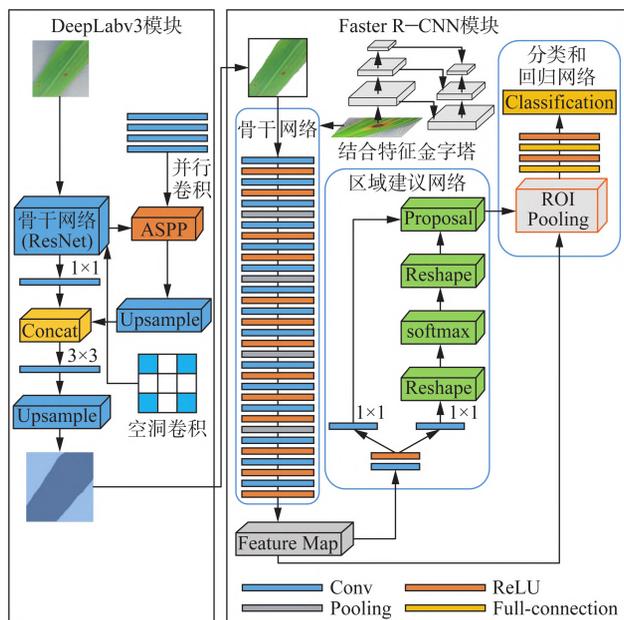


图2 基于深度学习的水稻叶片病害检测模型
Fig. 2 Rice leaf disease detection model based on deep learning

1.4 DeepLabv3 网络

尽管 Faster R—CNN 等卷积神经网络可以实现初步的水稻叶片病害检测,但准确率并不令人满意,难以直接应用于农业生产工作。尤其是对于具有复杂背景的水稻叶片图像,算法常把背景中与病害部分相似噪声错误地识别为病害。为降低背景噪声对检测结果的影响,提出一种创新的检测方法,即先对水稻叶片图像进行背景分割,提取叶片部分的信息并去除背景部分,继而使用目标检测网络对叶片中包含的病害信息进行检测。

使用 DeepLabv3 网络来分割待检测的水稻叶片图像的背景和叶片部分,DeepLabv3 网络主要包含骨干网络、ASPP 模块、Decoder 模块和输出层^[9]。选用 ResNet^[10]作为骨干网络,其用于从输入图像中提取特征,并使用空洞卷积(Atrous Convolution)来增大感受野^[11],使得网络可以有效地处理多尺度信息,提高分割精度。其中,空洞卷积是一种可以在增加感受野的同时保持特征图的尺寸不变,从而代替下采样和上采样操作的卷积方式。其实现方式是通过在卷积核元素之间加入一些空格来扩大卷积核的过程,空洞卷积与传统卷积的对比如图 3 所示。

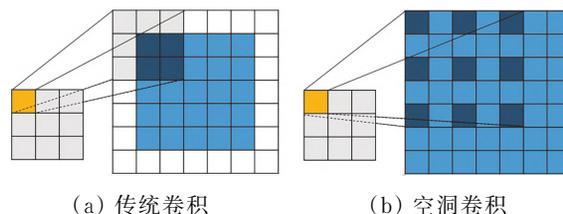


图3 传统卷积和空洞卷积

Fig. 3 Traditional convolutions and empty convolutions

加入空洞之后的实际卷积核尺寸与原始卷积核尺寸之间的关系如式(1)所示。

$$K = k + (k - 1)(a - 1) \quad (1)$$

式中: k ——原始卷积核大小;

a ——卷积扩张率(dilation rate);

K ——经过扩展后实际卷积核大小。

在骨干网络之后,DeepLabv3 使用 ASPP(空间金字塔池化)模块对特征图进行多尺度特征提取。ASPP 模块包括多个并行的卷积层,每个卷积层使用不同大小的空洞卷积核对特征图进行卷积,以捕捉不同尺度的上下文信息。这样的设计能够捕捉不同尺度的上下文信息,有助于提高分割的精度。此外,ASPP 模块的并行卷积操作,使网络能够同时考虑不同尺度下的上下文信息,从而增强对目标的识别能力^[12]。在 ASPP 模块之后,Decoder 模块对特征图进行上采样和融合操作,以获得更精细的语义分割结果。Decoder 模块包括一个上采样层和一个融合层,其中上采样层将特征图上采样到与输入图像大小相同的尺寸,融合层将上采样后的特征图与骨干网络中的低级特征进行融合,以提高语义分割的精度。DeepLabv3 的最后一层使用一个 1×1 的卷积层将特征图转换为与类别数相同的通道数,以获得每个像素点对应的类别标签。这一步骤生成每个像素点对应的类别标签,从而完成待检测水稻叶片图像的背景和叶片分割。经过 DeepLabv3 网络分割待检测叶片图像的可视化结果如图 4 所示。

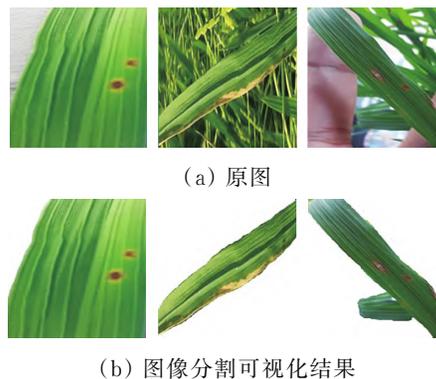


图4 水稻叶片图像分割可视化结果

Fig. 4 Visualization results of rice leaf image segmentation

1.5 卷积块注意力模块

为进一步提升病害检测模块的准确性和鲁棒性,在

Faster R—CNN 模型的基础上,结合 CBAM(卷积块注意力模块)。这是一种广泛应用于计算机视觉任务的注意力机制,主要作用是自动学习在不同通道和空间维度上的注意力分布,以提高特征图的质量和重要性^[13]。CBAM 主要由通道注意力(Channel Attention)和空间注意力(Spatial Attention)组成,如图 5 所示。通道注意力的目标是为每个通道分配一个权重。常见的方法是使用全局平均池化(GAP)和全局最大池化(GMP)。

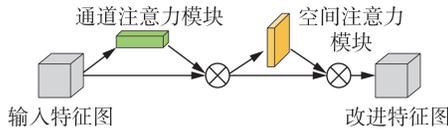


图 5 CBAM 结构示意图

Fig. 5 Schematic diagram of CBAM structure

对于输入特征图 F 的大小为 $H \times W \times C$ (其中 H 和 W 是高和宽, C 是通道数), 则

$$F_{\text{GAP}}(c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F(i, j, c) \quad (2)$$

$$F_{\text{GMP}}(c) = \max_{i,j} F(i, j, c) \quad (3)$$

其中 $F_{\text{GAP}}(c)$ 、 $F_{\text{GMP}}(c)$ 分别为全局平均池化和全局最大池化的特征图。使用一个或两个全连接层来学习通道间的关系,并得到权重。空间注意力的目标是为特征图的每个位置分配一个权重,这通常是通过使用一个小的卷积核(例如 5×5)来实现。

$$M = \sigma[W_k \times (F_{\text{GAP}} + F_{\text{GMP}})] \quad (4)$$

式中: M ——权重;

W_k ——卷积核;

σ ——sigmoid 激活函数。

最后使用这些权重来更新原始特征图,对于空间注意力

$$F' = F \times M \quad (5)$$

对于通道注意力

$$F' = F \times C' \quad (6)$$

式中: C' ——学习到的通道权重。

在水稻叶片病害检测过程中, CBAM 模块被嵌入到 Faster R—CNN 网络中,通过学习在特征图的不同通道上分配不同的权重,以强调对于水稻叶片病害检测而言更为重要的特征。CBAM 通过增强感兴趣的特征通道,提高特征图的质量,对于从输入图像中提取更有代表性的特征非常重要,有助于更准确地检测病害。CBAM 还可以减少特征图中的冗余信息,使网络更专注于关键特征,有助于提高计算效率,减少不必要的计算开销。总之, CBAM 注意力机制在水稻叶片病害检测中的作用是增强关键特征的表达,减少冗余信息,从而提高检测性能和效率,这使得本文的病害检测系统更具适应性和精确性。

1.6 特征金字塔

在水稻叶片病害检测工作中,除背景噪声的影响,不同尺度的病害特征同样是一个核心挑战。为确保网络模型在各种尺度上都有出色的检测表现,采纳特征金字塔方法。特征金字塔方法是一种经典而有效的处理多尺度信息的技术^[14]。

在实际应用中,水稻叶片上的病害可能呈现出多种尺度和大小。对于尺寸较小或简单的目标,浅层特征图可以捕捉到足够的信息,实现有效检测。当目标更为复杂或尺寸更大时,即便已经采用方法去除背景噪声,仍需从深层特征图中获取更精细、更丰富的特征来确保预测的准确性。其允许在不同的尺度下提取并融合特征,从而更好地捕捉各种尺度的病害细节,如图 6 所示。

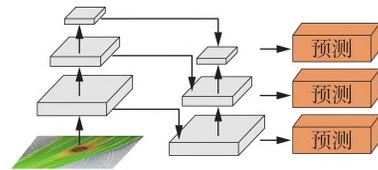


图 6 特征金字塔结构

Fig. 6 Feature pyramid structure

特征金字塔构建的核心思想:从深层特征开始,逐步进行上采样,并与浅层特征进行结合。特征金字塔网络可以分为 2 个主要部分:(1)基于主干网络的卷积层进行前向传播计算,通过结合不同尺度的特征图生成一个新的、更丰富的特征图。表示为 $F_d = \text{Conv}_{\text{deep}}(I)$, F_d 表示深层特征图, I 代表输入图像。(2)关注特征的上采样和融合。从深层特征开始进行上采样,得到 $U_d = \text{Upsample}(F_d)$, 这些上采样后的特征与浅层特征进行结合,形成一个更加鲁棒的特征表示,即 $P = U_d + F_s$, P 代表融合后的特征图, F_s 表示浅层特征图。

特征金字塔的主要目的就是从中层到浅层形成一系列融合的特征图 P_i , 如式(7)所示。

$$P_i = U_{d-i} + F_{s-i} \quad (7)$$

以 Faster R—CNN 为基础,构建特征金字塔网络以更好地实现病害检测。具体来说,特征金字塔网络主要分为 2 个部分:(1)基于主干网络的卷积层进行前向传播运算,将不同尺度的特征图组合为新的特征图。(2)基于卷积网络产生的原始特征图,从深层到浅层进行上采样,并建立新的特征图序列,使得具有深层特征信息的特征图获得更高的分辨率,进一步增强图像特征。

1.7 损失函数

对于 DeepLabv3—Faster R—CNN 模型,在 DeepLabv3 网络模块和 Faster R—CNN 网络模块,使用不同的损失函数来分别实现对应模块对于水稻叶片病害检测目标的特定功能。其中,DeepLabv3 网络模

块使用二进制交叉熵损失函数,如式(8)所示。

$$L_1 = -[y \log \hat{y} + (1 - y) \log (1 - \hat{y})] \quad (8)$$

式中: y ——样本的标签,正类和负类分别为 1 和 0;

\hat{y} ——预测值, $\hat{y} = P(y = 1|x)$ 。

Faster R—CNN 网络模块使用 Smooth L_1 损失函数,如式(9)所示。

$$L_2 = \frac{1}{n} \sum_{i=1}^n \begin{cases} 0.5(x - y)^2 & \text{if } |x - y| < 1 \\ |x - y| - 0.5 & \text{otherwise} \end{cases} \quad (9)$$

2 试验

2.1 试验环境

试验在一台搭载 Windows 10 的笔记本电脑上完成,深度学习框架为 pytorch,运行环境为 CUDA 11.3 和 CuDNN 7.6.3,电脑的硬件环境为 NVIDIA GeForce RTX 3060 显卡及 Intel 酷睿 i7 11800H。编译环境和语言分别为 Pycharm 和 python 3.8。

2.2 模型训练

在模型训练过程中,使用 28 473 张包含 4 种水稻叶片病害的图像作为训练集以及 7 118 张图像作为验证集。训练参数方面, $batch\ size$ 设置为 16,初始学习率设置为 0.02,在训练过程中学习率会逐渐降低以获得更精细的检测结果。图 7 为随训练过程的损失下降曲线图,在 60 个 $epoch$ 以后,损失下降趋于平缓,在 120 个 $epoch$ 以后,模型趋于收敛。

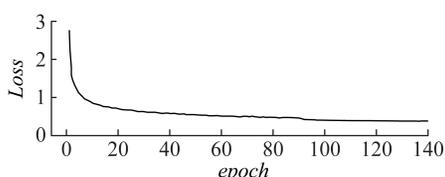


图 7 损失曲线
Fig. 7 Loss curve

2.3 评价指标

为对模型的性能进行定量评估,采用准确率(P)、召回率(R)和平均精度均值(mAP)作为评价指标。交并比(IoU)表示模型所预测的检测框与真实(ground truth)的检测框的交集与并集之间的比例。通常情况下, IoU 的结果是两个检测框交集像素数与它们的并集像素数之比。当 IoU 大于设定的阈值(一般为 0.7)时,通常认为检测结果是正确的,否则被视为错误的检测。

对于分类问题,预测结果通常被分为 4 个类别:真正例(TP)、真反例(TN)、假正例(FP)、假反例(FN)。具体而言, TP 表示模型正确预测为目标样本的数量, FP 表示模型错误地将非目标样本预测为目标样本的数量, TN 表示模型正确预测为非目标的样本数量, FN 表示

模型错误地将目标样本预测为非目标的样本数量。基于这 4 个类别的关系,可以定义两个关键指标:准确率(P)和召回率(R),其中准确率表示模型正确预测为目标样本与模型总共检测出的目标样本之间的比值,而召回率表示模型正确预测为目标样本与总共应该检测出的目标样本之间的比值^[15],这 2 个指标可以帮助量化评估模型的性能,计算如式(10)和式(11)所示。

$$P = \frac{TP}{TP + FP} \quad (10)$$

$$R = \frac{TP}{TP + FN} \quad (11)$$

召回率和准确率通常呈相互对立的关系,提高准确率往往会降低召回率,反之亦然。在目标检测任务中, $P-R$ 曲线被用来反映模型在所有样本上的准确率和召回率之间的权衡关系。 $P-R$ 曲线通常以准确率为纵轴、召回率为横轴,通过绘制多组不同召回率和准确率值的坐标,展示模型在不同工作点下的性能表现。然而, $P-R$ 曲线并不能提供目标检测模型的准确率的具体数值。为定量衡量算法的性能,通常使用平均精度 AP 作为指标。 AP 是召回率从 0~1 范围内对准确率的积分,即 $P-R$ 曲线下的面积。 AP 的数值越接近 1,表示检测的精度越高,模型的性能越好,而 mAP 则衡量所有类别上的检测结果性能,所有类别上 AP 的平均值。

$$AP = \int_0^1 P(R) dR \quad (12)$$

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} \quad (13)$$

式中: N ——类别总数。

2.4 可视化试验结果

经过训练使得模型收敛后用未参与训练过程的测试集对模型的性能进行验证结果表明,模型对于白叶枯病、稻瘟病、褐斑病和黄矮病的检测准确率分别达到 98.1%、98.9%、97.1% 和 98.2%,平均准确率为 98.1%。水稻叶片病害检测的部分可视化结果如图 8 所示。

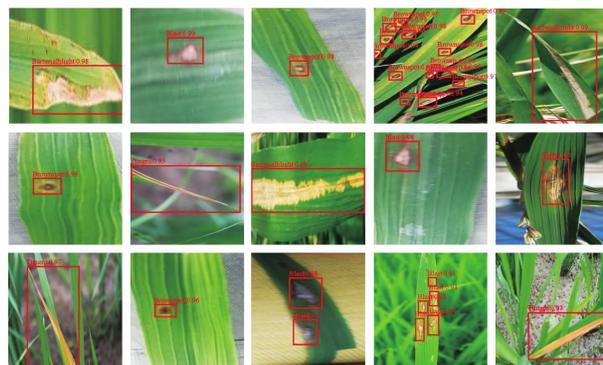


图 8 水稻叶片病害检测的可视化结果
Fig. 8 Visualization results of rice leaf disease detection

该方法处理待检测图像平均时间为 108 ms, 可以满足实际生产应用中对于检测速度的需求。试验结果表明, 绝大部分包含水稻叶片病害的图像可以通过本文提出的模型实现病害检测, 有效降低背景噪声对检测结果的影响, 较大地提高病害检测的准确率。

2.5 消融试验

提出一种基于 DeepLabv3 分割背景的 Faster R—CNN 网络模型, 为验证其可以更有效地对水稻叶片病害进行检测, 分别对加入 DeepLabv3 网络、引入特征金字塔、加入卷积块注意力模块, 进行 4 组消融试验验证。试验结果如表 1 所示。

表 1 消融试验及结果
Tab. 1 Ablation experiment and results %

模型	DeepLabv3	特征金字塔	CBAM	P	R	mAP
	—	—	—	90.2	91.4	91.0
	✓	—	—	94.7	95.6	95.2
Faster R—CNN	—	✓	—	90.8	91.2	93.0
	—	—	✓	91.9	90.3	93.4
	✓	✓	✓	98.7	97.0	98.1

根据表 1 的结果, 当仅添加 DeepLabv3 时, mAP 从 91.0% 提高到 95.2%, 提升 4.2%, 这表明先进行图像分割提取叶片部分并去除背景噪声对提高模型的性能具有积极影响。而单独特征金字塔后, mAP 达到 93.0%, 也进一步提高了模型的性能, 表明多尺度的特征提取有助于提高病害检测的准确率。加入 CBAM 后, mAP 显著提高到 93.4%, 提升 2.4%, 表明多尺度的注意力机制对于改进模型性能非常有效。将这 3 个改进模块都结合应用到模型中后, 模型的 mAP 达到 98.1%, 相对于原始的 Faster R—CNN 模型提升 7.1%, 进一步证明通过图像分割去除背景噪声及多尺度特征提取和融合的组合对于模型性能的提升至关重要。

2.6 对比试验

为全面评估基于 DeepLabv3 分割背景的 Faster R—CNN 网络模型的性能, 在相同数据集和相同硬件环境下, 与多种主流的基于深度学习的目标检测模型进行对比试验。对比模型包括 YOLOv3、YOLOv5、SSD、RetinaNet、Cascade R—CNN 模型。试验结果如表 2 所示。试验结果表明, DeepLabv3—Faster R—CNN 网络结构对于水稻叶片病害检测具有显著的效果提升, 在检测精度方面明显超出传统的 YOLOv5 和 SSD 等一系列常用于目标检测项目的模型。尤其在处理具有复杂的背景、不同尺度的病害目标和模糊病害特征方面, 提出的算法具有极高的检测准确度。尽管提出的方法需要通过先图像分割后病害检测的方式, 通过

2 个子网络模型才能输出检测结果, 导致算法运行时间稍长, 但整体试验结果充分证明所提方法在水稻叶片病害检测场景中的有效性和优越性。

表 2 对比试验及结果
Tab. 2 Comparative experiments and results

模型	P/%	R/%	mAP/%	运行时间/ms
DeepLabv3—Faster R—CNN	98.7	96.0	98.1	108
YOLOv3	90.3	91.0	90.4	37
SSD	89.4	91.2	90.0	28
Cascade R—CNN	91.4	93.0	92.1	94
YOLOv5	91.2	92.3	92.1	24
RetinaNet	92.9	94.7	93.4	33

3 结论

1) 针对水稻叶片病害检测中准确率较低、背景噪声影响较大的问题, 提出一种基于 DeepLabv3—Faster R—CNN 的水稻叶片病害检测方法。主要的检测流程: 首先将待检测的水稻叶片图像先经过 DeepLabv3 网络进行图像分割, 将包含噪声的背景部分和包含病害信息的叶片部分进行分割; 再将经过背景分割的叶片图像中叶片部分还原, 通过这种方式去除不包含有效信息的背景部分, 从而大幅度减小背景部分噪声对检测结果的影响。检测部分基于 Faster R—CNN 框架实现, 并通过结合特征金字塔和 CBAM 方法, 提高模型对于多尺度水稻叶片病害目标的检测能力。

2) 通过公开数据集训练模型至收敛并验证模型的检测能力。试验结果表明, 所提出的方法对于常见的水稻叶片病害平均准确率达到 98.1%, 证明基于深度学习的水稻叶片病害检测方法可以更准确地诊断常见的水稻叶片病害, 且抗噪声能力更强。

参 考 文 献

- [1] Pallathadka H, Ravipati P, Sajja G S, et al. Application of machine learning techniques in rice leaf disease detection [J]. Materials Today: Proceedings, 2022, 51: 2277—2280.
- [2] Jhatial M J, Shaikh R A, Shaikh N A, et al. Deep learning-based rice leaf diseases detection using YOLOv5 [J]. Sukkur IBA Journal of Computing and Mathematical Sciences, 2022, 6(1): 49—61.
- [3] Pothen M E, Pai M L. Detection of rice leaf diseases using image processing [C]. 2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC). IEEE, 2020: 424—430.
- [4] 朱素素. 基于高光谱成像技术的水稻主要病害早期检测及其模型构建[D]. 杭州: 浙江大学, 2022.

(下转第 132 页)

- Agriculture, 2020, 168: 105146.
- [15] Sun H, Xu H, 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.
- [16] 徐艳蕾, 孔朔琳, 陈清源, 等. 基于Transformer的强泛化苹果叶片病害识别模型[J]. *农业工程学报*, 2022, 38(16): 198—206.
- Xu Yanlei, Kong Shuolin, Chen Qingyuan, et al. Model for identifying strong generalization apple leaf disease using Transformer [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2022, 38(16): 198—206.
- [17] Zhu R, Zou H, Li Z, et al. Apple—Net: A model based on improved YOLOv5 to detect the apple leaf diseases [J]. *Plants*, 2023, 12(1): 169.
- [18] Zhu X, Li J, Jia R, et al. Lad—Net: A novel light weight model for early apple leaf pests and diseases classification [J]. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 2023, 20(2): 1156—1169.
- [19] Zhang Y, Zhou G, Chen A, et al. A precise apple leaf diseases detection using BCTNet under unconstrained environments [J]. *Computers and Electronics in Agriculture*, 2023, 212: 108132.
- [20] Jiang Y, Tong W. Improved lightweight identification of agricultural diseases based on MobileNetV3 [C]. *CAIBDA 2022; 2nd International Conference on Artificial Intelligence, Big Data and Algorithms. VDE*, 2022: 1—5.
- [21] Ma N, Zhang X, Zheng H T, et al. Shufflenet v2: Practical guidelines for efficient CNN architecture design [C]. *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018: 116—131.
- [22] Liu Y, Shao Z, Hoffmann N. Global attention mechanism: Retain information to enhance channel-spatial interactions [J]. *arXiv preprint arXiv: 2112.05561*, 2021.
- [23] Wang J, Chen K, Xu R, et al. Carafe: Content-aware reassembly of features [C]. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019: 3007—3016.
- [24] Chen J, 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.
- [25] Yang Q, Duan S, Wang L. Efficient identification of apple leaf diseases in the wild using convolutional neural networks [J]. *Agronomy*, 2022, 12(11): 2784.
- [26] Selvaraju RR, Cogswell M, Das A, et al. Grad—CAM: Visual explanations from deep networks via gradient-based localization [J]. *International Journal of Computer Vision*, 2020, 128(2): 336.
- (上接第 113 页)
- [5] 温鑫. 基于卷积神经网络的水稻叶片病害识别[D]. 哈尔滨: 东北农业大学, 2021.
- [6] Chen J, Zhang D, Nanekaran Y A, et al. Detection of rice plant diseases based on deep transfer learning [J]. *Journal of the Science of Food and Agriculture*, 2020, 100(7): 3246—3256.
- [7] Girshick R. Fast R—CNN [C]. *Proceedings of the IEEE International Conference on Computer Vision*, 2015: 1440—1448.
- [8] Fan Q, Zhuo W, Tang C K, et al. Few-shot object detection with attention-RPN and multi-relation detector [C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 4013—4022.
- [9] Chen L C, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation [J]. *arXiv preprint arXiv: 1706.05587*, 2017.
- [10] Wu Z, Shen C, Van Den Hengel A. Wider or deeper: Revisiting the resnet model for visual recognition [J]. *Pattern Recognition*, 2019, 90: 119—133.
- [11] 孙俊, 何小飞, 谭文军, 等. 空洞卷积结合全局池化的卷积神经网络识别作物幼苗与杂草[J]. *农业工程学报*, 2018, 34(11): 159—165.
- Sun Jun, He Xiaofei, Tan Wenjun, et al. A convolutional neural network combining dilated convolution and global pooling for identifying crop seedlings and weeds [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2018, 34(11): 159—165.
- [12] Sullivan A, Lu X. ASPP: A new family of oncogenes and tumour suppressor genes [J]. *British Journal of Cancer*, 2007, 96(2): 196—200.
- [13] Woo S, Park J, Lee J Y, et al. Cbam: Convolutional block attention module [C]. *Proceedings of the European Conference on Computer Vision (ECCV)*, 2018: 3—19.
- [14] 燕红文, 刘振宇, 崔清亮, 等. 基于特征金字塔注意力与深度卷积网络的多目标生猪检测[J]. *农业工程学报*, 2020, 36(11): 193—202.
- Yan Hongwen, Liu Zhenyu, Cui Qingliang, et al. Multi-target detection based on feature pyramid attention and deep convolutional networks for pigs [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2020, 36(11): 193—202.
- [15] Buckland M, Gey F. The relationship between recall and precision [J]. *Journal of the American Society for Information Science*, 1994, 45(1): 12—19.