

doi:10.6041/j.issn.1000-1298.2023.12.029

# 基于红外热成像和改进 YOLO v5 的作物病害早期识别

韩 鑫<sup>1</sup> 徐衍向<sup>1</sup> 封润泽<sup>1</sup> 刘天旭<sup>1</sup> 白京波<sup>2</sup> 兰玉彬<sup>1</sup>

(1. 山东理工大学农业工程与食品科学学院, 淄博 255000; 2. 山东思远农业开发有限公司, 淄博 255000)

**摘要:** 为实现作物病害早期识别, 本文提出一种基于红外热成像和改进 YOLO v5 的作物病害早期检测模型, 以 CSPD – arknet 为主干特征提取网络, YOLO v5 stride – 2 卷积替换为 SPD – Conv 模块, 分别为主干网络中的 5 个 stride – 2 卷积层和 Neck 中的 2 个 stride – 2 卷积层, 可以提高其准确性, 同时保持相同级别的参数大小, 并向下阶段输出 3 个不同尺度的特征层; 为增强建模通道之间的相互依赖性, 自适应地重新校准通道特征响应, 引入 SE 机制提升特征提取能力; 为减少模型计算量, 提高模型速度, 引入 SPPF。经测试, 改进后 YOLO v5 网络检测性能最佳, mAP 为 95.7%, 相比 YOLO v3、YOLO v4、SSD 和 YOLO v5 网络分别提高 4.7、8.8、19.0、3.5 个百分点。改进后模型相比改进前对不同温度梯度下的作物病害检测也有提高, 5 个梯度 mAP 分别为 91.0%、91.6%、90.4%、92.6% 和 94.0%, 分别高于改进前 3.6、1.5、7.2、0.6、0.9 个百分点。改进 YOLO v5 网络内存占用量为 13.755 MB, 低于改进前基础模型 3.687 MB。结果表明, 改进 YOLO v5 可以准确快速地实现病害早期检测。

**关键词:** 红外热成像; 深度学习; 病害早期识别; YOLO v5

中图分类号: S22 文献标识码: A 文章编号: 1000-1298(2023)12-0300-08

**OSID:**

## Early Identification of Crop Diseases Based on Infrared Thermography and Improved YOLO v5

HAN Xin<sup>1</sup> XU Yanxiang<sup>1</sup> FENG Runze<sup>1</sup> LIU Tianxu<sup>1</sup> BAI Jingbo<sup>2</sup> LAN Yubin<sup>1</sup>

(1. College of Agricultural Engineering and Food Science, Shandong University of Technology, Zibo 255000, China

2. Shandong Siyuan Agricultural Development Co., Ltd., Zibo 255000, China)

**Abstract:** To achieve early detection of crop diseases, a crop disease early detection model was proposed based on infrared thermal imaging and improved YOLO v5. The CSPD – arknet was used as the main feature extraction network, and the YOLO v5 stride – 2 convolution was replaced by the SPD – Conv module, which were respectively the five stride – 2 convolution layers in the main network and the two stride – 2 convolution layers in the Neck. This can improve its accuracy while maintaining the same level of parameter size and outputting three different scales of feature layers in the downstream stage. In order to enhance the interdependence between modeling channels, channel feature responses were adaptively recalibrated and SE mechanism was introduced to enhance feature extraction ability. In order to reduce model calculation and improve model speed, SPPF was introduced. After testing, the improved YOLO v5 algorithm had the best detection performance with an mAP of 95.7%, which was respectively 4.7 percentage points, 8.8 percentage points, 19.0 percentage points, and 3.5 percentage points higher than that of YOLO v3, YOLO v4, SSD, and YOLO v5 networks. Compared with the improved network before improvement, it also improved the detection of crop diseases under different temperature gradients. The mAP of five gradients were 91.0%, 91.6%, 90.4%, 92.6%, and 94.0%, which were higher than those before improvement by 3.6 percentage points, 1.5 percentage points, 7.2 percentage points, 0.6 percentage points, and 0.9 percentage points, respectively. The size of the improved YOLO v5 model

收稿日期: 2023-05-25 修回日期: 2023-09-02

基金项目: 山东省引进顶尖人才“一事一议”专项(鲁政办字[2018]27号)、山东临淄设施蔬菜科技小院项目(教育部教研厅函[2022]7号)、山东理工大学研究生教育质量提升计划项目(研究生函[2022]26号)和山东理工大学本科教学研究与改革项目(教务函[2022]80号)

作者简介: 韩鑫(1979—), 男, 教授, 博士生导师, 主要从事作物病害检测预警研究, E-mail: sdtu\_hanxin@163.com

通信作者: 兰玉彬(1961—), 男, 教授, 博士生导师, 主要从事智慧农业应用技术研究, E-mail: ylan@sdtu.edu.cn

was 13.755 MB, which was lower than 3.687 MB of the basic network before the improvement. The results showed that improving YOLO v5 can accurately and quickly detect early diseases, which can provide certain technical support for the development of early disease detection instruments.

**Key words:** infrared thermography; deep learning; early disease detection; YOLO v5

## 0 引言

农作物病害是作物生产中十分严重的自然灾害之一,每年微生物的感染都会造成巨大的经济损失。因此作物病害的早期识别尤为重要<sup>[1]</sup>。作物病害的侵染分为侵入前期、侵入期、潜育期和发病期 4 个时期。潜育期作物开始表现明显的症状,但肉眼无法观察到,因此需要在潜育期进行作物的早期病害检测。

作物感染病害的传统检测方法包括专家鉴定法、分离培养检测法和血清检测法<sup>[2]</sup>。前者容易造成主观误判,后两者会对作物的结构造成破坏。红外热图像具有分辨率差、对比度低、后续特征提取难度大和信息难以完整提取等缺点。随着人工智能的发展,机器视觉等越来越多被应用于农业领域<sup>[3]</sup>。现代图像增强技术越来越多地结合机器学习技术,通过与可见光图像融合,提出相对应的网络等方法来达到提高图像的目标表征、增强场景理解的效果<sup>[4]</sup>。

研究发现,利用红外热成像技术可在接种细菌后 3~4 d 且肉眼无法观测时检测到葡萄霜霉病斑;通过红外热成像仪检测冬油菜感染病菌后的变化,发现染病叶片比健康叶片温度高 3.5°C。即使在大面积种植时,也能发现染病区域温度的明显差异<sup>[5]</sup>。研究发现利用高分辨率红外视频摄像机,可检测到叶片感染病害部分的温度高于正常部分 0.3~0.4°C<sup>[6]</sup>;利用红外热成像进行番茄叶片性状的早期检测,发现感染叶片生理变化与温度变化呈正相关,可在接种后 3 d 检测出感染番茄花叶病的番茄叶片温度比正常叶片高 0.5~1.2°C<sup>[7]</sup>;可利用红外热成像识别出受到条锈病侵染但未显症的小麦植株<sup>[8]</sup>。

FAROKHZAD 等<sup>[9]</sup>使用热像仪和加热箱获取热图像,研究处于不同阶段(感染后 1~7 d)的健康马铃薯块茎和被茄花镰刀菌污染的块茎温度,找到最佳热成像条件,通过线性和二次判别分析方法提取并分类了一些温度统计特征。结果表明,二次判别分析可以对不同时期的健康块茎和污染块茎进行分类,准确率高达 98.5%。KHEIRALIPOUR 等<sup>[10]</sup>使用热成像、二次判别分析(QDA)和人工神经网络(ANN)方法对开心果的真菌感染与黄曲霉进行分

类,发现使用 ANN 和 QDA 方法区分健康开心果和受污染开心果的准确率分别为 97.70% 和 99.00%。CHELLADURAI 等<sup>[11]</sup>研究了使用红外热成像系统识别储存小麦真菌感染的可行性,以及受灰曲霉群、黑曲霉和青霉属感染的散装小麦籽粒的热图像。并通过线性判别分析(LDA)和二次判别分析(QDA)开发了四向和成对分类模型。成对的 LDA 和 QDA 分类模型对健康样本的最大准确率均为 100%,对受感染样本的准确率分别超过 97% 和 96%。RAZA 等<sup>[12]</sup>提出了一种将红外热图像、可见光图像数据与深度信息相结合、可用于远程检测感染番茄白粉病植物的机器学习系统。

为节约人力,进一步提高目标检测速度和准确性,本文提出一种红外热成像技术和深度学习相结合的病害检测方法,研究基于改进 YOLO v5 的番茄病害早期检测模型,使用 SPD - Conv 模块替换 YOLO v5 stride=2 卷积,将 SPP 模块替换为 SPPF,引入 SE 注意力机制和 SPD Conv 来处理低分辨率和小物体。

## 1 模型训练与检测试验

### 1.1 数据集制备

为对多种病害进行全面检测,本研究以番茄为载体。通过对番茄白粉病、烟草花叶病等的研究,对比多种病害的早期红外热图像特点,即部分病害早期红外热图像下为升温斑点状,确定了对叶片进行轻微的温度变化的方式进行病斑制作并进一步完成了数据集的拍摄和制作,以番茄叶片作为媒介来进行病害检测。图 1 所示叶片图像采集自淄博市临淄区思远农业试验基地,拍摄设备为固定式长波红外热像仪 VarioCAMHD head880。图像焦距为 26 mm,分辨率为 1 024 像素 × 768 像素。拍摄时间为 2022 年 11 月,拍摄时间段为 09:00—11:00 和 15:00—17:00。用三脚架固定仪器的位置定点拍摄,设备距离采摘叶片 20~30 cm。图 2 为健康、病斑和

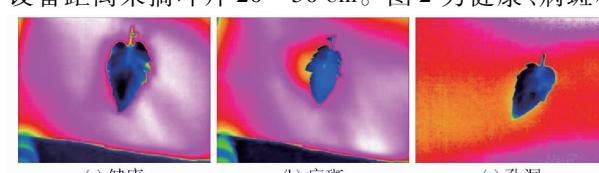


图 1 采集叶片的不同状态

Fig. 1 Different states of acquisition blade

孔洞叶片线温分布图。采用温度为30℃的玻璃棒轻点叶片形成温度梯度模拟病斑,使用针状物进行孔洞处理获取孔洞叶片,共拍摄1300幅图像。

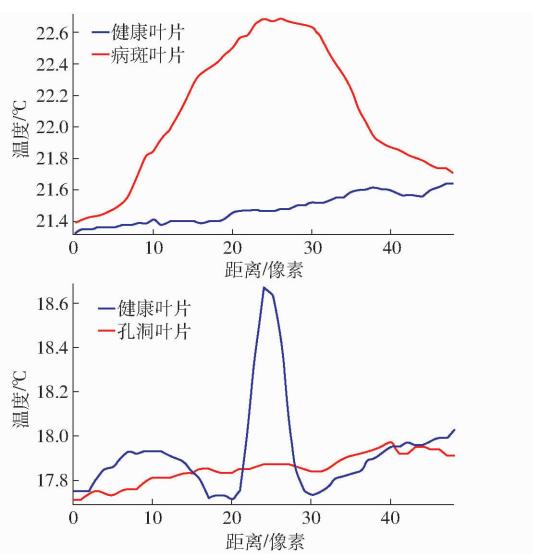


图2 不同状态叶片的线温分布图

Fig. 2 Linear temperature distributions of leaves in different states

由于环境及分辨率的影响,选取1000幅图像进行数据集制作。拍摄的每幅图像基本包含多个影响因素。在训练深度网络模型时,为保证图像验证模型的鲁棒性、数据的多样性,增强网络的泛化能力,降低数据量过少而使训练网络产生过拟合的可能性<sup>[13~14]</sup>,本研究使用数据增强方法对原始图像进行数据扩展。利用平移、旋转、镜像、添加噪声等方法,最终得到5480幅有效图像来制作数据集,如图3所示。将5480幅番茄病害红外热图像按照比例8:1:1划分为训练集4384幅、测试集548幅、验证集548幅。

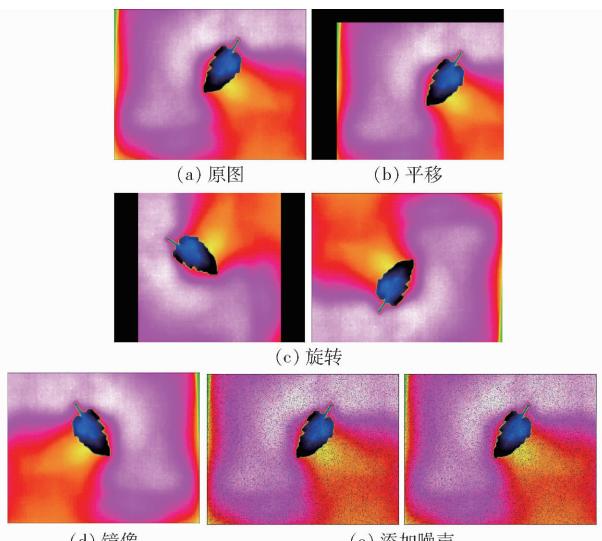


图3 番茄叶片数据增强示例

Fig. 3 Examples of tomato leaf data augmentation

## 1.2 图像增强处理

在实验室环境下,红外图像采集的过程中仍有许多不可控的因素,红外图像的质量容易受到干扰。这些干扰造成的噪声容易淹没图像特征,降低对比度和清晰度,以及造成边缘出现锯齿等问题。从而导致难以对图像进行准确地识别。同时,大棚中叶片在正常工作中受到光照和温度等不同因素的影响,温度没有明显的变化,因此在红外热成像图上部分像素值与周围像素值基本相似,造成边界模糊和缺乏细节信息等问题。为获得准确表达实际信息的红外图像,成功进行后期图像分析和识别,需要消除无关信息的干扰。本研究通过降噪和增强等图像预处理方法对图像进行增强,可以提取其中的有效信息并提高其可检测性。

选用图像间结构相似度(SSIM)、峰值信噪比(PSNR)和可学习感知图像块相似度(LPIPS)作为评价指标。综合考虑实际预处理图像效果和评价指标,从表1中选取最优的预处理算法。结果表明,高斯滤波的PSNR、SSIM和LPIPS均为最优,因此本研究采用高斯滤波对训练集图像进行降噪处理。此选择综合考虑图像质量的各个方面,旨在达到最佳降噪效果。

表1 不同降噪方式的图像品质评价指标

Tab. 1 Comparison of image quality evaluation parameters with different denoising methods

降噪方式	PSNR	SSIM	LPIPS
blur	30.031 526	0.915 889	0.050 481
高斯滤波	48.337 411	0.993 530	0.003 168
median	35.572 005	0.907 675	0.095 195
L-Mean	35.746 753	0.959 370	0.066 560

由表2可知,不同病害使用红外热成像所表现的温差不同,为验证目标检测网络在不同温差下病斑叶片的检测精度,提高病害早期检测在不同温度梯度下的识别率,本研究将采集到的病斑图像按照不同温度梯度进行分类,分为5个等级,分别为0~0.2℃、0.2~0.4℃、0.4~0.6℃、0.6~0.8℃、大于

表2 不同病害早期与正常叶片的温差

Tab. 2 Temperature difference between early and normal leaves of different diseases ℃

病害种类	温差
尖孢镰刀菌 <sup>[4]</sup>	0.5
油菜菌核病 <sup>[5]</sup>	3.5
番茄花叶病 <sup>[15]</sup>	0.5~1.2
烟草花叶病 <sup>[16]</sup>	-0.5~1.3
黄瓜霜霉病 <sup>[17]</sup>	1.0
小麦条锈病 <sup>[18]</sup>	0.26

0.8℃, 如图 4 所示, 用以验证在不同温度梯度下的目标检测网络性能, 进一步提早发现作物病害。

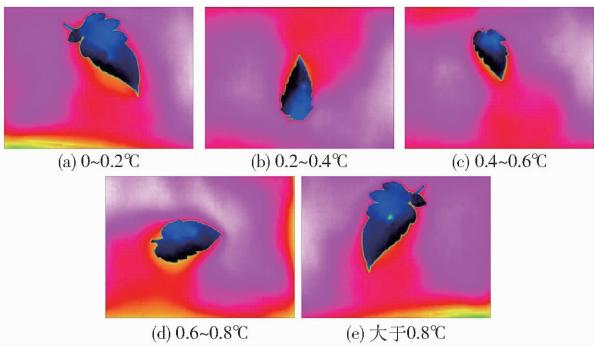


图 4 不同温度梯度的番茄叶片红外热图像

Fig. 4 Infrared thermal image of tomato leaves with different temperature gradients

### 1.3 模型训练

在每个循环中, 每个循环标注一个学习集合的损失值, 每个循环包含一个校验组损失值和循环中损失值。损失值变化曲线见图 5, 总共训练 300 轮。最后 150 轮中, 选用检验集合损失最小的模型用于随后的分析训练。

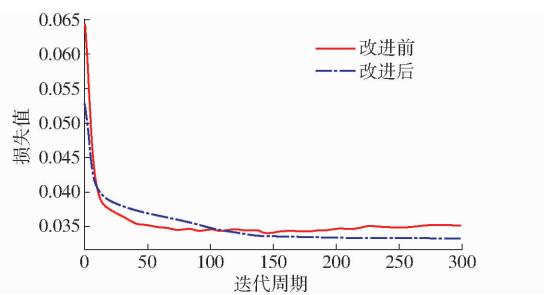


图 5 改进前后模型损失值变化曲线

Fig. 5 Change curves of model loss value before and after improvement

### 1.4 评价指标

采用精确率( $P$ )、召回率( $R$ )、平均精度均值(mAP)3 个指标对早期病害检测模型进行评价。

### 1.5 试验设置

试验在 Windows 10 操作系统下进行, 处理器为 Intel(R) Xeon(R) W-2275 CPU @ 3.30 GHz, 显卡为 NVIDIA GeForce RTX 3090。深度学习框架采用 PyTorch 1.13, 编程平台为 PyCharm, 编程语言为 Python 3.9, 所有对比模型均在相同环境下运行, 试验参数如表 3 所示。

## 2 作物病害检测模型改进

### 2.1 YOLO v5 网络

图 6 中, Backbone 为 YOLO v5 的主干特征提取网络, 根据其结构称为 CSPD-arknet<sup>[19-20]</sup>。在进行图像处理时, 首先使用 CSPD-arknet 模型进行特征提取。另外, 为加强特征提取, 使用特征金字塔网络

表 3 试验参数设置

Tab. 3 Test parameter setting

参数	数值
学习率	0.001
迭代周期	300
批量大小	32
IOU 阈值	0.5
目标类别数	4

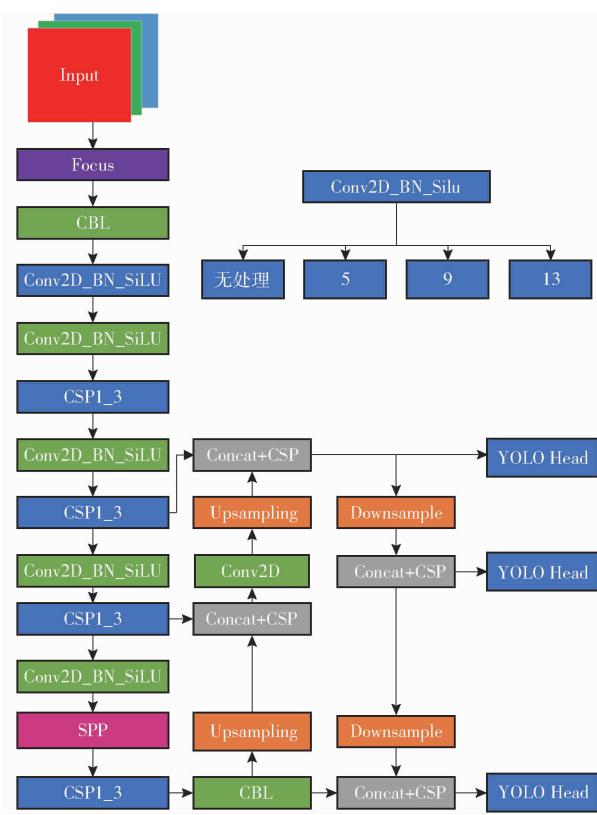


图 6 YOLO v5 目标检测网络

Fig. 6 YOLO v5 target detection network

(FPN) 对主干部分获得的 3 个有效特征层进行特征融合, 以结合不同尺度的特征信息。YOLO Head 通过 CSPD-arknet 和 FPN, 获得 3 个加强过的效果特征层, 对特征点进行判断, 判断特征点是否有物体与其对应。分类和回归在一个  $1 \times 1$  卷积里实现。对于 1 幅图像, 卷积核从图像最前端, 从左往右, 从上往下, 以一个像素或指定一个像素的间距依次滑过图像的每一个区域。

### 2.2 改进 YOLO v5 网络

为实现番茄早期病害红外热成像检测, 提出一种基于改进 YOLO v5 的番茄病害早期检测模型, 结构如图 7 所示。以 CSPD-arknet 为主干特征提取网络, YOLO v5 stride=2 卷积替换为 SPD-Conv 模块<sup>[21]</sup>, 分别为主干网络中 5 个 stride=2 卷积层和 Neck 中 2 个 stride=2 卷积层, 可以提高其准确性, 同时保持相同级别的参数大小, 并向下阶段输出 3 个不同尺度的特征层<sup>[22]</sup>。为增强建模通道之间

的相互依赖性,自适应地重新校准通道特征响应,引入SE机制提升特征提取能力。为减少模型计算量,提高模型速度,引入SPPF。

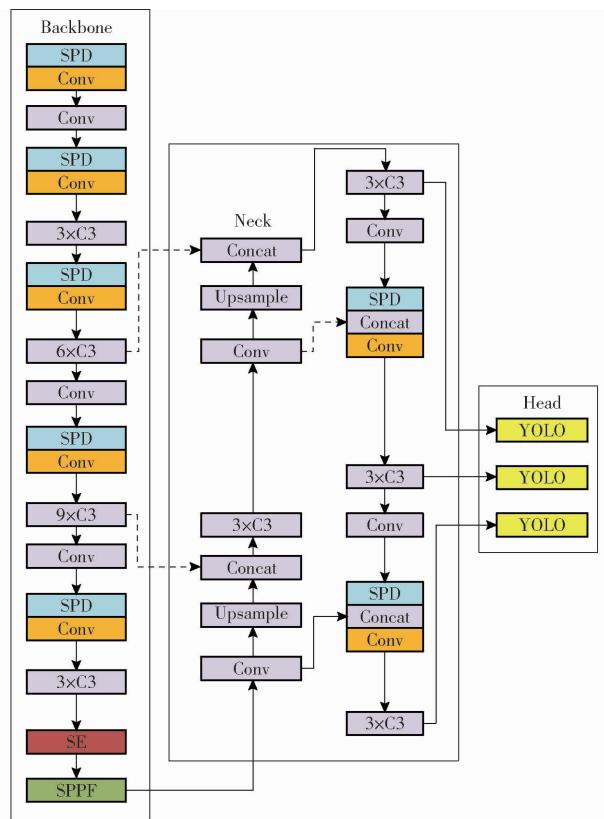


图 7 改进 YOLO v5 目标检测网络

Fig. 7 Improved YOLO v5 target detection network

## 2.2.1 引入 SE 注意力机制的特征融合网络

为加强通道与图像特征之间的联系并进行有效建模,SENet 使用特征重标注技术来学习每个通道的权重。图 8 为 SE 结构图,通过这种方式,SENet 能够挖掘出图像中的有效特征并抑制无效特征<sup>[23]</sup>,从而提高模型对图像的表征能力和准确性。SENet 不同于通过聚合空间和特征维度上的信息来获得全局感知等主流方法,而是通过挖掘特征通道之间的关系来提高网络性能。这种方法使得模型能够自主学习不同通道上特征的重要程度,从而达到提高网络性能的目的。

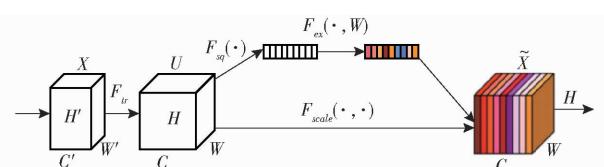


图 8 SE 结构图

Fig. 8 SE structure diagram

## 2.2.2 引入 SPD - Conv 模块的低分辨率模块

针对图像分辨率较低或对象较小的困难任务,YOLO v5 网络性能迅速下降的问题,引入 SPD - Conv 模块。图 9 为 scale 为 2 时的 SPD - Conv 示意图。

CNN 体系结构<sup>[24]</sup>中一个有缺陷但却很常见的设计,即使用 strided convolution 和池化层<sup>[25]</sup>,这导致了细粒度信息的丢失和较低效率的特征表示学习。引入 SPD - Conv,以取代每个 strided convolution 和每个池化层。SPD - Conv 由 space-to-depth (SPD) 层和 non-strided convolution (Conv) 层组成,可以应用于大多数 CNN 架构。

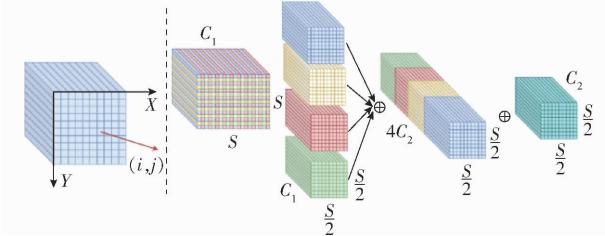


图 9 scale 为 2 时的 SPD - Conv 示意图

Fig. 9 Schematic of SPD - Conv when scale was 2

## 2.2.3 网络结构轻量化设计

SPPF 模块主要由不同的池化操作组成,它将得到的不同尺度的特征图和全局特征图进行特征融合,从而极大丰富特征图的表现能力,并有助于对不同尺度的目标进行检测,如图 10 所示。尽管 SPPF 模块可以提高检测精度<sup>[26]</sup>,但同时也会增加网络参数数量并降低推理速度。因此,为解决此问题,将 SPPF 模块中并联的 3 个池化层改为串联的 3 个 5 × 5 的最大池化层。从原理表明 SPPF 模块对于检测精度的提高有正向作用,但会导致网络参数变多和推理时间下降。

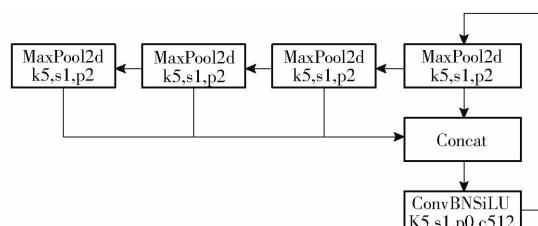


图 10 SPPF 模块

Fig. 10 SPPF module

## 2.3 消融试验

为更好地展示本文所提出改进模块对检测性能的影响,验证方法的优势,设计了消融试验。使用相同数据集对 5 组网络进行测试,试验结果如表 4 所示。

表 4 的对比结果显示,使用基础网络结合 SE 注意力机制模块可以让深度学习模型更智能地学习图像、语音等复杂数据的特征。通过挖掘特征通道间的关系,该方法使模型能够自主学习不同通道上特征的重要程度,从而提高模型的准确率和鲁棒性。试验结果表明,此方法可以显著提高对番茄病害的 3 种状态检测性能,mAP 提高 1.3 个百分点,这表明

表 4 不同改进模块试验结果对比

Tab. 4 Comparison of results of different improvement experiments

模型	精确率/召回率/		mAP/	模型内存
	%	%	%	占用量/MB
基础网络	91.2	90.9	93.6	17.441
基础网络 + SPPF	96.4	95.5	94.1	13.810
基础网络 + SE	96.5	94.7	94.9	13.819
基础网络 + SE + SPPF	96.3	96.7	95.5	13.819
改进 YOLO v5	96.7	95.9	95.7	13.755

加入注意力机制模块的重要性。同时,使用基础网络加 SPPF 模块的模型也有助于提升总体识别性能,mAP 提高 0.5 个百分点,模型内存占用量降低 20%。同时,使用基础网络加 SE 和 SPPF 模块的模型也有助于提升总体识别性能,mAP 提高 1.9 个百分点。最终,通过基础网络添加 SE、SPD 和 SPPF 模块生成的改进 YOLO v5 模型在番茄病害检测方面表现最佳。相对于基础网络,mAP 提高 2.1 个百分点,改进 YOLO v5 模型的 mAP 精度均高于改进前,如图 11 所示,并且模型内存占用量相比改进前降低 21%,此结果说明使用 SPD 模块适用于分辨率低的红外热图像的番茄病害识别性能最优,这表明模型的设计充分发挥各改进模块的优点,提高了模型的综合检测效果。

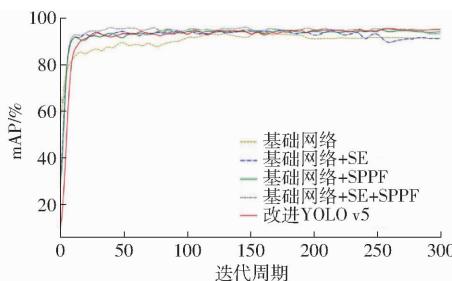


图 11 消融试验中各种网络的 mAP

Fig. 11 The mAP of various networks in ablation test

### 3 结果与分析

#### 3.1 检测结果

为验证改进 YOLO v5 网络检测早期病害的有效性,对测试集中 548 幅叶片图像进行测试。测试结果表明,该方法检测番茄叶片的精确率为 96.7%,召回率为 95.9%,mAP 为 95.7%。

本研究中共训练 300 轮次,网络训练结果如图 12 所示,在模型训练初期,模型学习效率较高,损失值曲线收敛较快,如图 5 所示。当迭代次数达到 150 次左右,模型学习效率逐渐达到饱和,损失值在 0.006 左右波动。

改进 YOLO v5 目标检测网络检测早期病害的效果如图 13 所示,其检测的置信度在检测框上方显

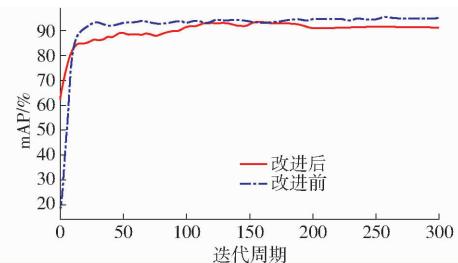


图 12 改进前后模型 mAP 曲线

Fig. 12 The mAP curves of model before and after improvement

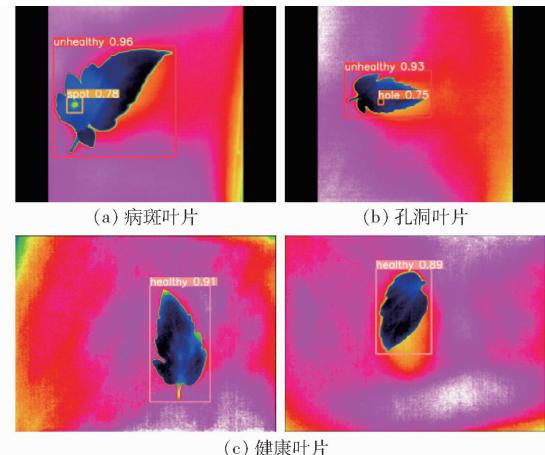


图 13 改进 YOLO v5 模型的可视化检测结果

Fig. 13 Improved visualization of detection results of YOLO v5 model

示,表明该网络可以有效检测出病斑和孔洞。

#### 3.2 不同目标检测模型性能比较

搭建不同的主流目标检测网络的基础网络框架,如 SSD、YOLO v3、YOLO v4 和 YOLO v5,并进行试验评估。最后,将对比不同模型在番茄病害数据集上的检测结果,以此为标准来选择最佳的目标检测网络,如表 5 所示。

由表 5 可知,选用 YOLO v5 模型能够获得最佳的检测性能。SSD 模型在健康叶片和非健康叶片的检测召回率相对较高,但较深的特征提取容易出现过拟合,导致错误识别现象增多,从而影响精度和召回率的平衡。与此相比,YOLO v3、YOLO v4 模型在番茄病害检测的检测精度和召回率的表现明显低于 YOLO v5 模型。YOLO v5 模型之所以能够在番茄病害的检测中表现最佳,是因为将 CSP 结构和 Mosaic 数据增强等模块加入到网络结构中,并使用 Focus 和 FPN + PA Net 等对网络性能进行加强,对后续目标检测和分类起到积极的作用。因此本试验选用 YOLO v5 作为后续试验的基础网络。

本文提出的改进 YOLO v5 模型识别检测方法 mAP 为 95.7%,高于改进前网络 3.5 个百分点。健康叶片检测精确率高于改进前 2.8 个百分点;非

表 5 不同目标检测网络对番茄叶片检测结果

Tab. 5 Different object detection networks result on tomato leaf recognition detection

模型	场景	精确率	召回率	mAP
YOLO v3	健康	95.10	99.10	91.00
	非健康	96.60	98.80	
	病斑	88.10	79.50	
	孔洞	90.10	90.20	
YOLO v4	健康	98.98	100	86.90
	非健康	82.81	61.99	
	病斑	80.00	77.78	
	孔洞	93.00	100	
SSD	健康	76.32	93.55	76.70
	非健康	99.11	97.80	
	病斑	84.28	63.08	
	孔洞	60.00	14.63	
YOLO v5	健康	95.90	96.90	92.20
	非健康	95.30	96.60	
	病斑	90.00	76.70	
	孔洞	89.90	87.50	
改进 YOLO v5	健康	98.70	100	95.70
	非健康	99.60	100	
	病斑	93.80	97.20	
	孔洞	94.20	93.60	

健康叶片检测精确率高于改进前 4.3 个百分点;病斑检测精确率提高 3.8 个百分点;孔洞检测精确率提高 4.3 个百分点。相比改进前,改进 YOLO v5 模型缩短了模型训练的收敛时间,由图 5 和图 12 可知,改进 YOLO v5 模型不仅加快了模型的收敛速度,精确率也有明显提升。证明采用本文所提出的方法对番茄叶片病害检测效果较改进前有明显的改善,改进后的 YOLO v5 模型性能优于改进前模型。

### 3.3 不同温度梯度检测效果分析

将测试集中的 548 幅病斑图像按照不同温度梯度进行分类,利用改进前后两种目标检测模型在相同试验条件下分别对病斑不同温度梯度下的番茄病害图像测试集进行了测试,表 6 为在不同温度梯度下两种目标检测模型检测番茄病害的指标对比。

由表 6 可知,在 0~0.2℃ 范围内,改进 YOLO v5 的 mAP 高于改进前网络 3.6 个百分点;在 0.2~0.4℃ 范围内,改进 YOLO v5 的 mAP 高于改进前网络 1.5 个百分点;在 0.4~0.6℃ 范围内,改进 YOLO v5 的 mAP 高于改进前网络 7.2 个百分点;在 0.6~0.8℃ 范围内,改进 YOLO v5 的 mAP 高于改进前网络 0.6 个百分点;在大于 0.8℃ 范围内,改进 YOLO v5 的 mAP 高于改进前网络 0.9 个百分点。结果表

表 6 改进前后 YOLO v5 模型对应不同温度梯度响应变化指标

Tab. 6 Comparison of YOLO v5 models corresponding to different temperature gradient change indexes before and after improvement

模型	温度梯度/℃	精确率/%	召回率/%	mAP/%
YOLO v5	0~0.2	80.9	97.6	87.4
	0.2~0.4	83.5	78.5	90.1
	0.4~0.6	91.1	92.2	83.2
	0.6~0.8	88.3	95.0	92.0
改进 YOLO v5	>0.8	90.0	93.8	93.1
	0~0.2	90.8	96.1	91.0
	0.2~0.4	91.5	99.2	91.6
	0.4~0.6	94.1	98.8	90.4
	0.6~0.8	95.6	96.0	92.6
	>0.8	93.1	95.8	94.0

明,应用改进 YOLO v5 模型在各个温度梯度下都能更好地实现番茄病害的检测。

## 4 讨论

总结上述红外热成像与机器学习相结合应用于植物病害识别领域的研究,发现尚处于起步阶段,仍存在诸多问题。

红外热图像拍摄困难。红外热图像易受光照、温度、风吹等环境影响,在被测物体和环境的温差很小时,无法准确地获得所需的信息,还容易受到光照、风的影响导致温度分布的变化。现在大多数图像都是在可控且单一背景的环境下拍摄,缺乏泛化性,且红外热图像本身存在灵敏度低和分辨率低等特性,难以保证拍摄的红外热图像的质量,会引起红外图像的错误解读。

训练结果使用的数据量少,训练的模型针对特定场景,缺乏泛化性。深度学习需要大量数据集,拍摄数据集往往有限,且公开的红外热成像数据集类型和数量均较少,难以满足深度学习的要求。

由于红外热成像技术只能生成红外热图像,只针对温度变化的检测,无法明确获取具体病害的类型,还需进行多种作物病害红外热成像试验,将不同病害的温度变化进行进一步细化,以期通过温度变化来精确判断病害种类。

深度学习算法在番茄病叶检测速度方面需要进一步优化。从 YOLO v3 到 SSD 再到 YOLO v5 模型,现有模型对番茄病叶的检测帧率仍较低,在保证检测精度的同时,进一步轻量化,提升模型在移动嵌入式平台的运行速度。

现阶段模型识别准确率低且大多数基于红外热成像的机器视觉(IRMV)还处于实验室测试阶段,

跟实际应用还有很大的差距。随着人工智能的发展,模型的改进带来了识别上巨大的优势,现阶段模型对于小样本数据集的识别精度低,后续则需要对模型进行优化,减少冗余,提高精度。在实际应用阶段,随着计算能力和仪器适配性的不断提高,可以通过跟人机、机器人和嵌入式设备结合来解决实际应用问题。

## 5 结论

(1) 为防止病害干扰试验结果,本研究通过种植番茄进行图像采集。并且为扩充数据集,防止因数据量过少而造成鲁棒性降低,本研究通过拍摄实验室自身种植作物与大棚环境下的番茄植株相结合进行图像采集。利用数据增强方法扩充图像数量,使用 LabelImg 工具进行样本标注,制备了 VOC 格式的番茄叶片红外热成像数据集;此外,为进一步提升病害早期检测水平,对病斑图像通过温度梯度进行

分类。最终通过数据增强优化数据集质量,建立番茄早期病害数据集。

(2) 提出一种改进的 YOLO v5 网络,旨在解决分类识别精度差的问题。改进方法包括引入 SE 注意力机制和 SPD - Conv 来处理低分辨率和小物体,并更换使用 SPPF 的方法。研究 YOLO v3、YOLO v4、SSD、YOLO v5 和改进 YOLO v5 网络在早期病害检测方面的性能表现,结果表明,改进 YOLO v5 网络的 mAP 为 95.7%,相比 YOLO v3、YOLO v4、SSD 和 YOLO v5 网络分别提高 4.7、8.8、19.0、3.5 个百分点。设计消融试验,模型的设计充分发挥了各改进模块的优点,提高了模型的综合检测效果。此外,该网络在检测早期病害时改进模型内存占用量为 13.755 MB,低于改进前基础网络 3.687 MB,识别表现更好,能够更早地发现病害斑点,从而进行相应的病害管理。

## 参 考 文 献

- [1] 魏靖,王玉亭,袁会珠,等. 基于深度学习与特征可视化方法的草地贪夜蛾及其近缘种成虫识别[J]. 智慧农业(中英文), 2020,2(3):75–85.  
WEI Jing, WANG Yuting, YUAN Huizhu, et al. Identification and morphological analysis of adult *Spodoptera frugiperda* and its close related species using deep learning[J]. Smart Agriculture, 2020,2(3):75–85. (in Chinese)
- [2] 张烁,罗其友,马力阳. 我国马铃薯区域格局演变及其影响因素分析[J]. 中国农业大学学报, 2020,25(12):151–160.  
ZHANG Shuo, LUO Qiyou, MA Liyang. Analysis of the evolution of potato regional pattern in China and its influencing factors [J]. Journal of China Agricultural University, 2020,25(12):151–160. (in Chinese)
- [3] 孙红,李松,李民赞,等. 农业信息成像感知与深度学习应用研究进展[J]. 农业机械学报, 2020,51(5):1–17.  
SUN Hong, LI Song, LI Minzan, et al. Research progress of image sensing and deep learning in agriculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020,51(5):1–17. (in Chinese)
- [4] STOLL M, SCHULTZ H R, BERKELMANN-LOEHNERTZ B. Exploring the sensitivity of thermal imaging for *Plasmopara viticola* pathogen detection in grapevines under different water status[J]. Funct. Plant Biol., 2008,35(4):281–288.
- [5] BARANOWSKI P, JEDRYCZKA M, MAZUREK W, et al. Hyperspectral and thermal imaging of oilseed rape (*Brassica napus*) response to fungal species of the genus *Alternaria*[J]. PLoS One, 2015,10(3):e122913.
- [6] 朱旭,马淏,姬江涛,等. 基于 Faster R – CNN 的蓝莓冠层果实检测识别分析[J]. 南方农业学报, 2020,51(6):1493–1501.  
ZHU Xu, MA Hao, JI Jiangtao, et al. Detecting and identifying blueberry canopy fruits based on Faster R – CNN[J]. Journal of Southern Agriculture, 2020,51(6):1493–1501. (in Chinese)
- [7] 郑志强,刘妍妍,潘长城,等. 改进 YOLO v3 遥感图像飞机识别应用[J]. 电光与控制, 2019,26(4):28–32.  
ZHENG Zhiqiang, LIU Yanyan, PAN Changcheng, et al. Application of improved YOLO v3 in aircraft recognition of remote sensing images[J]. Electronics Optics & Control, 2019,26(4):28–32. (in Chinese)
- [8] 郑冠楠,谭豫之,张俊雄,等. 基于计算机视觉的马铃薯自动检测分级[J]. 农业机械学报, 2009,40(4):166–168, 156.  
ZHENG Guannan, TAN Yuzhi, ZHANG Junxiong, et al. Automatic detecting and grading method of potatoes with computer vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2009,40(4):166–168, 156. (in Chinese)
- [9] FAROKHZAD S, MODARESS M A, AHMADI M P, et al. Application of infrared thermal imaging technique and discriminant analysis methods for non-destructive identification of fungal infection of potato tubers [J]. Journal of Food Measurement & Characterization, 2020,14(1):88–94.
- [10] KHEIRALIPOUR K, AHMADI H, RAJABIPOUR A, et al. Classifying healthy and fungal infected-pistachio kernel by thermal imaging technology[J]. International Journal of Food Properties, 2015,18(1):93–99.
- [11] CHELLADURAI V, JAYAS D S, WHITE N D G, et al. Thermal imaging for detecting fungal infection in stored wheat[J]. Journal of Stored Products Research, 2010,46(3):147–149.
- [12] RAZA S E, PRINCE G, CLARKSON J P, et al. Automatic detection of diseased tomato plants using thermal and stereo visible light images[J]. PLoS One, 2015,10(4):e123262.
- [13] 杨晓玲,江伟欣,袁浩然. 基于 YOLO v5 的交通标志识别检测[J]. 信息技术与信息化, 2021(4):28–30.  
YANG Xiaoling, JIANG Weixin, YUAN Haoran. Traffic sign detection and recognition based on YOLO v5[J]. Information Technology & Informatization, 2021(4):28–30. (in Chinese)