doi:10.6041/j.issn.1000-1298.2026.13.025

# 基于改进 YOLO v10s 的温室黄瓜病害识别方法

何　斌[1,2]　刘豪杰[1]　高刘宝[1]　任心玥[1]　樊永鹏[3]

(1.西北农林科技大学水利与建筑工程学院,陕西杨凌 712100;
2.西北农林科技大学旱区农业水土工程教育部重点实验室,陕西杨凌 712100;
3.宝鸡市农业技术推广服务中心,宝鸡 721001)

**摘要**:为了进一步提高温室黄瓜病害的识别精度,本文提出一种基于改进 YOLO v10s 的模型。首先,在主干网络引入 ResNet50 网络,增强网络的深度,提升模型的表达能力;其次,在颈部添加 CSPPC 卷积神经网络结构,在减少计算冗余的同时增强模型对不完整或遮挡数据的特征提取能力;同时引入 NAM 注意力机制,提升模型对关键信息的关注能力,避免传统注意力机制中的复杂计算,实现高效的特征增强,最终形成黄瓜病害检测模型 RCN。实验结果表明,RCN 模型的精确率、召回率、mAP@0.5、mAP@0.5:0.95 分别达到了 95.0%、98.1%、98.3%、70.4%,相比于 YOLO v10s 分别提升了 4.3、7.4、2.9、5.3 个百分点,改进效果明显。与主流模型相比,RCN 模型效果更优,能够满足检测需求,为温室黄瓜病害的识别提供了一种更优解,对于温室黄瓜病害的防治具有重要意义。

**关键词**:黄瓜病害;YOLO v10s;注意力机制;CSPPC;ResNet50

**中图分类号**:S24　　**文献标识码**:A　　**文章编号**:1000-1298(2026)13-0304-08　　**OSID**:

# Method for Identifying Cucumber Diseases in Greenhouses Based on Improved YOLO v10s

He Bin[1,2]　Liu Haojie[1]　Gao Liubao[1]　Ren Xinyue[1]　Fan Yongpeng[3]

(1. *College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi* 712100, *China*
2. *Key Laboratory of Agricultural Soil and Water Engineering in Arid Areas, Ministry of Education, Northwest A&F University, Yangling, Shaanxi* 712100, *China*
3. *Baoji City Agricultural Technology Extension Service Center, Baoji* 721001, *China*)

**Abstract**: Aiming to further improve the speed and accuracy of cucumber disease recognition in greenhouses, a model based on an improved YOLO v10s was proposed. Firstly, the ResNet50 network was integrated into the backbone network to enhance the network depth, through which the model's expressive capability was significantly improved. Subsequently, a CSPPC convolutional neural network structure was added to the neck, where computational redundancy was reduced while the feature extraction ability for incomplete or occluded data was strengthened. Simultaneously, the NAM attention mechanism was incorporated to amplify attention to critical information, avoiding complex computations in traditional attention mechanisms and achieving efficient feature enhancement, ultimately forming the RCN model for cucumber disease detection. Experimental results demonstrated that the RCN model achieved precision, recall, mAP@0.5, and mAP@0.5:0.95 rates of 95.0%, 98.1%, 98.3%, and 70.4%, respectively, representing improvements of 4.3, 7.4, 2.9, and 5.3 percentage points compared with the baseline YOLO v10s, with significant enhancements observed. Ablation studies revealed that the integration of the ResNet50 network contributed most significantly to accuracy improvement, with all proposed modifications collectively enhancing the recognition precision of the YOLO v10s model. Comparative evaluations revealed that the RCN model exhibited superior performance relative to mainstream models, meeting detection requirements and providing an optimized solution for cucumber disease recognition in greenhouse environments. This approach was validated as holding substantial significance for the prevention and control of cucumber diseases in agricultural systems.

**Key words**: cucumber diseases; YOLO v10s; attention mechanism; CSPPC; ResNet50

收稿日期:2025-05-12　修回日期:2025-05-25

**基金项目**:陕西省科技创新引导专项(2021QFY08-01)

**作者简介**:何斌(1971—),男,副教授,博士,主要从事设施农业工程技术研究,E-mail:ylhebin@nwafu.edu.cn

## 0　引言

我国是黄瓜种植大国，温室黄瓜种植面积位居世界第一，但由于温室内适宜的温度和湿度，使得病害传播速度较快，危害程度较高[1-4]。我国温室黄瓜种植每年因病害问题导致产量损失严重，因此如何快速准确识别黄瓜病害，对于避免黄瓜减产，减少农药滥用十分重要。传统的病害诊断方法依赖于人工观察和经验判断，不仅耗时耗力，而且准确率有限，还会受到个人主观性的影响，难以满足现代农业高效、精准管理的需求。同时，由于智能温室内对温度和湿度的精准调控需求，工作人员难以频繁进入内部进行病害巡检，因此开发一种智能化的病害检测方法具有重要的现实意义。

深度学习技术的发展为温室内黄瓜病害的识别提供了坚实的技术保障，自卷积神经网络(Convolutional neural network，CNN)诞生以来，凭借其强大的自动学习和特征提取的能力，计算机视觉领域迎来了井喷式的发展[5]。目前，学者提出了众多经典模型，如经典的图像分类模型 AlexNet[6] 和用于特征提取的深度卷积神经网络架构 ResNet[7]，早期的双阶段目标检测模型 R－CNN 系列[8-10]，后期的单阶段目标检测模型 YOLO 系列[11-12] 和 SSD[13] 等。

国内外众多学者将目标检测模型用于农业病虫害识别领域，并取得了优异的成果。袁杰等[14] 通过对 YOLO v7 进行改进，对苹果叶片病害的识别准确率达到 89.4%。张立强等[15] 通过对 YOLO v8s 添加注意力机制、动态蛇形卷积、小目标检测探头等措施，实现了对葡萄叶片小型病斑的检测，mAP@0.5 达到了 90.9%。张惠莉等[16] 则提出了一种葡萄叶片识别的新模型 GSGF，该模型基于 YOLO v8 模型，通过对 YOLO v8 进行改进，识别精度和推理时间最高可达到 98.2% 和 43.7 ms。国外也有众多学者将深度学习模型用于农业病虫害识别领域。Son[17] 提出了一种新的注意力增强 YOLO 模型，将一种基于感知特征提取器(ROI)的注意力机制融入 YOLO 模型中，最终通过对叶部斑点的区分实现了叶部病害的高效识别。Mathew 等[18] 通过 YOLO v5 检测田间甜椒细菌性斑病，对比其它 YOLO 模型实现了更高的准确率。Zhang 等[19] 提出了一种多激活函数(MAF)模块优化的卷积神经网络，通过加入该模块，CNN 的性能得到了大幅提升，其中在与 ResNet50 网络的融合中精确率提升了 2.33%。

综上可知，将目标检测模型用于农业病虫害识别领域是可行的，且对于农作物病害的检测都实现了较高的准确率，但平均准确率还有较大的提升空间，因此提高模型的平均准确率以满足实际的应用需求是目标检测模型研究的关键。

为了解决模型平均准确率较低的问题，本文提出一种 RCN 模型，该模型基于 YOLO v10s 改进，在主干网络引入 ResNet50，通过结合归一化技术动态调整特征图的重要性，提升模型对关键信息的关注能力；其次，在颈部添加 CSPPC 网络结构，实现高效多尺度融合特征，通过跨层级拼接保留细节信息，增强模型对小型目标和大型目标的检测能力；同时引入 NAM 注意力机制，通过将归一化层的缩放因子作为注意力权重，避免传统注意力机制中的复杂计算，提升模型对关键特征的聚焦能力，以期大幅提升 YOLO v10s 模型的识别精度。

## 1　模型改进

### 1.1　YOLO v10s 模型

YOLO v10 是清华大学开源的实时端到端目标检测算法，其基于 YOLO v8 进行改进，是新一代的 YOLO 模型，其凭借高效的架构设计、灵活的模型配置、强大的社区生态以及对多场景的适应性，成为新一代 YOLO 模型改进的基准选择。YOLO v10 的模型架构主要由主干网络、颈部、预测头 3 部分组成，其在主干网络上采用增强版的 CSPNet，在保证特征提取能力的基础上，提升了模型的运行速度；颈部运用 PAN 结构汇聚不同尺度的特征，让模型能更好检测不同尺寸的目标；预测头训练时使用一对多预测头提供丰富监督，推理时使用一对一预测头，无需 NMS 操作，减少了推理延迟，使模型能够更快速地给出检测结果。相比于其它 YOLO 模型，YOLO v10 在速度上和精度上优势明显。YOLO v10s 则是 YOLO v10 中的小型版本，兼顾速度和精度，但其在精度上依然有较大的提升空间。

### 1.2　YOLO v10s 模型改进

针对 YOLO v10s 模型准确率较低的问题，本文在 YOLO v10s 模型的基础上引入 3 个模块对该模型进行改进。在主干网络引入 ResNet50 网络；在颈部将 C2f 模块替换为 CSPPC 网络结构；引入归一化注意力模块 NAM，最终形成文本的 RCN 模型，其具体结构如图 1 所示。

#### 1.2.1　ResNet50 网络

为了提高 YOLO v10s 模型对于黄瓜病害的识别精度，在主干网络中引入了 ResNet50(Residual network with 50 layers)网络。该网络是深度残差网络(ResNet)的核心变体之一，其核心创新在于通过残差学习(Residual learning)和瓶颈(Bottleneck)

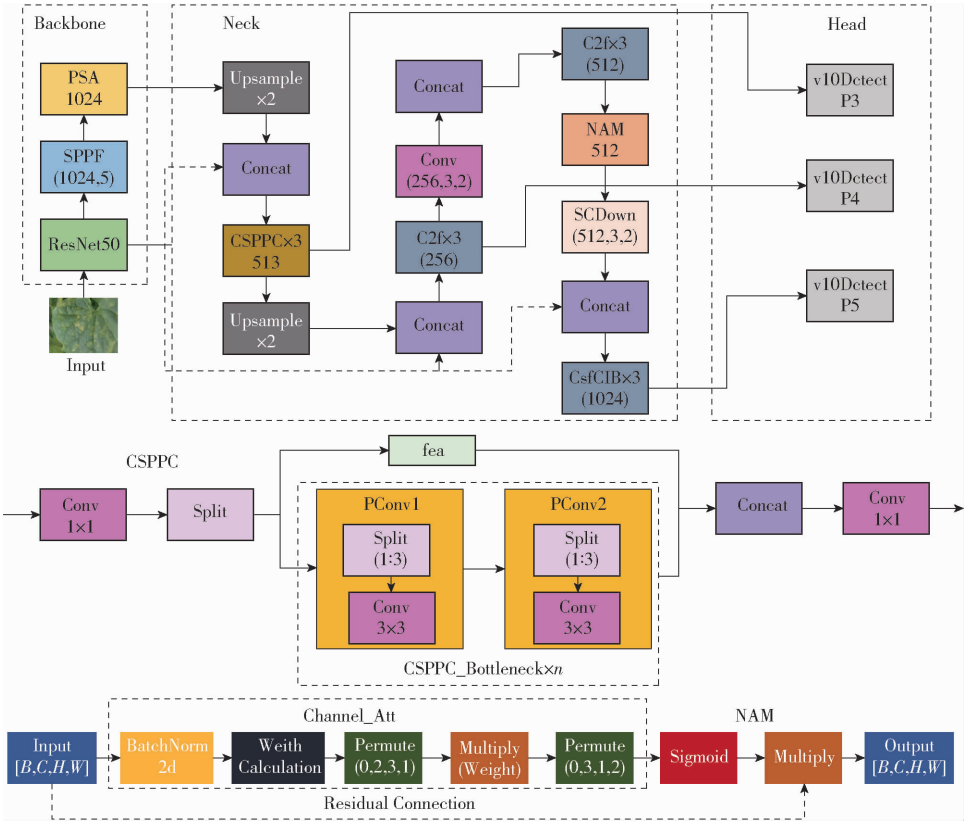


图 1 RCN 模型结构图

Fig. 1 RCN model structure diagram

结构解决了深度神经网络训练中的梯度消失、网络退化等问题，并显著提升了模型的性能与效率。

在传统深度神经网络中，随着网络层数的增加，模型容易出现梯度消失或爆炸问题，导致训练难以收敛；同时，网络深度增加时，准确率可能不升反降（即“退化问题”）。ResNet50 通过引入跳跃连接（Skip connection），允许网络直接学习输入与输出之间的残差，而非直接拟合复杂的原始映射。此外，ResNet50 采用了 Bottleneck 结构优化计算效率：每个残差块由 3 层卷积组成，即 1×1 卷积（压缩通道数，降维）、3×3 卷积（提取空间特征）和 1×1 卷积（恢复通道数，升维）。ResNet50 的网络架构分为 5 个阶段：初始阶段通过 7×7 大卷积核和最大池化快速降低特征图分辨率，随后 4 个阶段通过堆叠 Bottleneck 残差块逐步提升通道数（64→256→512→1 024→2 048），同时逐步降低特征图尺寸（224×224→7×7），最终通过全局平均池化替代全连接层输出分类结果。这种分阶段设计平衡了计算效率与特征抽象能力，使模型能够从低级纹理到高级语义逐层提取特征。与普通卷积堆叠相比，ResNet50 训练稳定、参数效率高，其更深层次的网络结构也为黄瓜病害中小型病斑的识别提供了支撑，实现黄瓜病害识别精度的提升。

### 1.2.2 CSPPC 网络

在主干网络中引入 ResNet50 残差网络后，继续引入 CSPPC 网络结构对模型进行改进，CSPPC 结构是在借鉴了 PConv 结构的基础上，提出的一种新型的轻量化结构，将其替换掉颈部网络中的 C2f 模块，在减少参数量的同时还能提高黄瓜病害的识别精度，具体结构如图 2 所示。

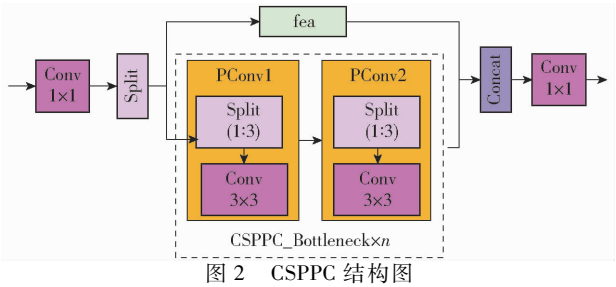


图 2 CSPPC 结构图

Fig. 2 CSPPC structure diagram

PConv（部分卷积）是一种轻量化的网络结构，其基本原理是利用特征图冗余，从而减少计算和内存访问。PConv 的特点是只在输入通道的一部分应用常规卷进行空间特征提取，而保留剩余通道不变。它拥有以下 3 个优势：PConv 只在较少的通道上做常规卷积，降低了计算量；因为只处理部分通道，需要搬运的数据量比传统卷积少很多，特别适合手机等内存带宽小的设备；PConv 只对输入通道的一部分进行计算，但保留的通道在后续的逐点卷积层中

仍然有用，允许特征信息在所有的通道中流动。特征图冗余是指在卷积神经网络的特征图中，不同的通道中存在大量的重复信息，这就导致网络在进行传播时增加了计算量，而 PConv（部分卷积）则解决了这个问题，通过只在部分通道上进行卷积，在减少计算量的同时还能够有效提取空间特征。总体而言，在引入了 CSPPC 网络结构后，能够让模型更加轻量化，降低模型运算时的参数量，提升模型对于黄瓜病害的识别速度，对于温室黄瓜病害识别的精度也有一定的提升。

### 1.2.3　NAM 注意力机制

对于深度卷积神经网络而言，注意力机制可以依据输入特征不同部分的重要性，赋予其不同的权重，进而保障了对图像信息里重要特征的提取。本文在颈部引入 NAM 注意力机制[20]，通过挖掘归一化操作中隐含的特征重要性信息，替代传统注意力机制中复杂的权重生成模块，从而实现高效的特征增强。应用于黄瓜病害识别方面，帮助模型更好地集中于黄瓜的病斑部位，减少无关信息干扰，提高模型对于黄瓜病斑部位的识别准确率，其具体结构如图 3 所示。

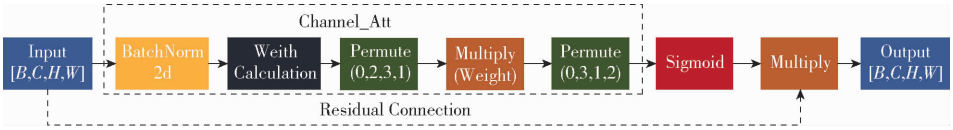


图 3　NAM 结构图

Fig. 3　NAM structure diagram

NAM 是一种轻量级的高效注意力机制，其采用 CBAM 的模块集成方式，重新设计了通道注意力和空间注意力子模块，这样使得 NAM 可以嵌入到每个网络 block 的最后，对于通道注意力子模块，使用 Batch normalization 中的缩放因子来反映各个通道变化大小。通道注意力子模块和空间注意力子模块如图 4、5 所示。

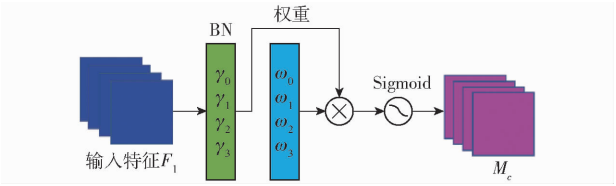


图 4　通道注意力子模块

Fig. 4　Channel attention submodule

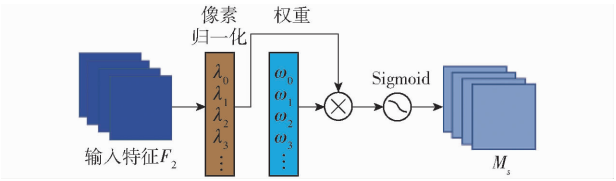


图 5　空间注意力子模块

Fig. 5　Spatial attention submodule

通道注意力子模块如图 4 所示，输入特征图通过批归一化（Batch normalization，BN）层，利用 BN 中的可训练仿射参数计算通道重要性。其中 $\gamma$（比例因子）的绝对值被归一化为权重，用于衡量每个通道的显著性。特征图经过维度置换后，与权重逐通道相乘，再通过 Sigmoid 函数生成注意力掩膜，最终输出为原始特征图与注意力掩膜的逐元素乘积，抑制非显著通道的特征响应。

空间注意力子模块如图 5 所示，输入特征图类似通道注意力机制，但将 BN 的比例因子应用于空间维度即“像素归一化”，通过统计每个空间位置的均值和标准差，衡量像素级的重要性。其中 $\lambda$ 为空间维度的比例因子，特征图与空间权重逐位置相乘，再通过 Sigmoid 函数生成空间注意力掩膜，输出为原始特征图与空间掩膜的逐元素乘积，增强显著区域的特征表达。

综上，NAM 注意力机制拥有轻量化的结构，其应用性较强，可以轻松融入其他模型，同时凭借其归一化的操作提高了对黄瓜病害识别的效率，有利于模型更多地聚焦于黄瓜病害的病斑处，减少信息干扰，增强识别的准确率，能够更好地部署到应用端。

## 2　实验与结果分析

### 2.1　实验数据

#### 2.1.1　数据获取

黄瓜常见的病害有炭疽病、霜霉病、白粉病、灰霉病、疫病、枯萎病等。本文选取在温室内发病率较高的炭疽病和霜霉病 2 种病害[21]作为实验研究对象。

本文数据集皆为自采，采集地点为陕西省咸阳市杨陵区和河南省周口市川汇区的日光温室和连栋温室，采集时间为 2024 年 11 月 3 日—2025 年 1 月 26 日 8:00—18:00，拍摄设备为华为 nova 8 型 5G 手机，采用原生相机拍摄，共获得 2 种病害的高清图像 277 幅，病害图像实例见图 6。

#### 2.1.2　数据集构建

首先，针对数据中的高质量图像，采取旋转、镜像、平移、随机设亮度、添加高斯噪声等操作对数据集进行扩充，将图像数量由 277 幅扩充至 1 990 幅，增强数据的鲁棒性，提高模型对于病害识别的泛化能力。然后使用 LabelImg 对黄瓜病斑进行标记，使用 VOC 格式，标签类别分别为 Anthracnose 和 Downy



(a) 霜霉病 (b) 炭疽病

图 6 黄瓜病害样本数据示例

Fig. 6 Sample data of cucumber diseases

mildew,标记后将生成对应名称的 xml 文件,文件中将存储病斑的类别及其位置信息。最后,将实验数据按照比例约 8∶1∶1随机划分为训练集、验证集和测试集,表 1 为 2 种病害的具体数量。

**表 1 数据集图像数量**

**Tab. 1 Number of images in dataset** 幅

| 类别 | 训练集 | 验证集 | 测试集 | 合计 |
|---|---|---|---|---|
| 炭疽病 | 810 | 90 | 90 | 990 |
| 霜霉病 | 770 | 115 | 115 | 1 000 |
| 合计 | 1 580 | 205 | 205 | 1 990 |

## 2.2 实验平台

本文的实验皆采用同一服务器进行训练和验证,服务器的具体参数如下:CPU 为 14 核 Intel Core i5 - 13600K @ 5.1 GHz;GPU 为 NVIDIA GeForce RTX 4070 Ti SUPER;操作系统为 64 位 Windows 11;软件环境为 Python 3.11、Cuda 12.4、PyTorch 2.5.1。

## 2.3 实验参数设置

图像输入分辨率为 640 像素 ×640 像素,初始学习率为 0.01,训练周期为 200,批次大小为 16。在该周期下,通过多次实验发现模型能实现收敛,满足实验所需要求。

## 2.4 评价指标

采用精确率(Precision, P)、召回率(Recall,R)、平均精度均值(Mean average precision,mAP)作为衡量目标检测精度的指标。预测框与真实框的重叠程度用交并比(IoU)来表示,通常会设定一个阈值(如 0.5),IoU 高于该阈值则认为预测正确,否则为错误。AP@0.5 是阈值为 0.5 时,目标检测模型得到的 AP,mAP@0.5 则是其所有类别的均值;AP@0.5∶0.95 则是模型在阈值为 0.5 ~0.95 时(步长 0.05)得到的 AP 平均值,mAP@0.5∶0.95 则是其所有类别的平均值,是更为严格且精确的检测指标[22]。

## 2.5 实验结果

### 2.5.1 RCN 模型实验结果

通过对 RCN 模型进行训练,得到最佳权重 best.pt 文件,然后通过测试集对 RCN 模型的性能进行测试,具体性能指标如表 2 所示。

**表 2 RCN 实验结果**

**Tab. 2 RCN experimental result** %

| 类别 | P | R | mAP@0.5 | mAP@0.5∶0.95 |
|---|---|---|---|---|
| 炭疽病 | 93.4 | 98.7 | 98.9 | 67.9 |
| 霜霉病 | 96.6 | 97.5 | 97.6 | 72.9 |
| 平均值 | 95.0 | 98.1 | 98.3 | 70.4 |

由表 2 可知,RCN 模型在 IoU 阈值为 0.5 的情况下,平均精度均值可以达到 98.3%,能够实现温室黄瓜病害的精准识别,符合对于 YOLO v10s 模型的改进预期,霜霉病在精确率和 mAP@0.5∶0.95 表现优异,分别为 96.6% 和 72.9%,而炭疽病则在召回率和 mAP@0.5 更为优秀,分别为 98.7% 和 98.9%,总体而言,RCN 模型对于炭疽病和霜霉病都有着较高的识别精度,能够满足实际应用的需求。

### 2.5.2 不同注意力机制模型对比

在相同的位置引入不同的注意力机制,与本文的注意力机制进行对比,分别引入 CBAM[23]、CA[24]、SE[25]、GAM[26]、ECA[27]注意力机制,性能对比如表 3 所示。

**表 3 不同注意力机制模型性能对比**

**Tab. 3 Performance comparison of different attention mechanism models**

| 模型 | mAP@0.5/% | 计算量 |
|---|---|---|
| YOLO v10s | 95.4 | $2.45\times10^{10}$ |
| YOLO v10s_SE | 95.9 | $2.52\times10^{10}$ |
| YOLO v10s_CBAM | 96.4 | $2.64\times10^{10}$ |
| YOLO v10s_CA | 96.2 | $2.62\times10^{10}$ |
| YOLO v10s_GAM | 96.5 | $2.82\times10^{10}$ |
| YOLO v10s_ECA | 96.0 | $2.47\times10^{10}$ |
| YOLO v10s_NAM | 96.1 | $2.45\times10^{10}$ |

由表 3 中数据可知,在加入 GAM 注意力机制后 mAP@0.5 提升最大,相较于原 YOLO v10s 模型提升 1.1 个百分点,但其计算量也大幅增长,较原模型增长了 $3.7\times10^{9}$。其中,相比于本文中所引入的 NAM 注意力机制,引入 CBAM 和 GAM 在 mAP@0.5 上分别提升 0.3、0.4 个百分点,但其计算量分别提升 $1.9\times10^{9}$和 $3.7\times10^{9}$,引入其它注意力机制在mAP@0.5 上均低于 NAM,其中,加入 SE 注意力机制相较于原 YOLO v10s 模型提升最小,仅 0.4 个百分点。而本文中所使用的 NAM 注意力机制在 mAP@0.5 提升 0.7 个百分点的基础上,实现了计算量近乎零增长,保证了模型精度的同时又实现了轻量化,在面临实时任务目标检测和低资源环境下能够更好地部署在移动端,满足实际应用的需求。

### 2.5.3　消融实验

为了验证 YOLO v10s 模型改进的有效性，对改进后的 YOLO v10s 模型进行消融实验，消融实验的具体结果见表 4。

**表 4　消融实验结果**

**Tab. 4　Ablation test results**　　%

| 模型 | P | R | mAP@0.5 | mAP@0.5:0.95 |
|---|---|---|---|---|
| YOLO v10s | 90.7 | 90.7 | 95.4 | 65.1 |
| YOLO v10s_N | 91.0 | 93.2 | 96.1 | 65.7 |
| YOLO v10s_C | 94.8 | 93.5 | 96.2 | 66.6 |
| YOLO v10s_R | 98.4 | 96.9 | 97.2 | 67.1 |
| YOLO v10s_NC | 92.0 | 88.9 | 96.8 | 67.0 |
| YOLO v10s_NR | 96.3 | 93.5 | 96.8 | 68.0 |
| YOLO v10s_CR | 97.6 | 94.3 | 96.9 | 68.3 |
| YOLO v10s_RCN | 95.0 | 98.1 | 98.3 | 70.4 |

注：YOLO v10s 模型后的字母代表对该模型进行的改进，其中 N 表示加入 NAM 注意力机制，C 表示加入 CSPPC 网络，R 表示加入 ResNet50 残差网络。

由表 4 可知，在经过优化后的数据集上 YOLO v10s 精确率和召回率均为 90.7%，mAP@0.5 达到了 95.4%。在只加入一项改进时，加入 ResNet50 残差网络提升最大，相较于 YOLO v10s，精确率、召回率、mAP@0.5、mAP@0.5:0.95 分别提升 7.7、6.2、1.8、2.0 个百分点，其中精确率达到了 98.4%，为所有模型中最优。在加入 2 项改进后，相比于未加入 ResNet50 残差网络的模型，加入 ResNet50 残差网络的模型提升显著，因此 ResNet50 残差网络对于模型性能的提升所占比重较大，其中 YOLO v10s_CR 模型表现优异，相比于 YOLO v10s，精确率、召回率、mAP@0.5、mAP@0.5:0.95 分别提升 6.9、3.6、1.5、3.2 个百分点。YOLO v10s_RCN 则为本文所使用的模型，除精确率外其余性能指标在所有模型中均为最优，精确率、召回率、mAP@0.5、mAP@0.5:0.95 分别达到了 95.0%、98.1%、98.3% 和 70.4%，相较于 YOLO v10s 分别提升 4.3、7.4、2.9、5.3 个百分点；相较于只加入一项改进的 YOLO v10s_R，召回率提升 1.2 个百分点，mAP@0.5 提升 1.1 个百分点，mAP@0.5:0.95 提升 3.3 个百分点；相较于加入 2 项改进的 YOLO v10s_CR，召回率、mAP@0.5、mAP@0.5:0.95 分别提升 3.8、1.4、2.1 个百分点。

本文模型与 YOLO v10s 模型在 200 轮的训练周期下，其精确率、召回率、mAP@0.5 及损失值变化曲线如图 7 所示，由图 7 可知，RCN 模型的精确率、召回率和 mAP@0.5 及损失值表现优异，能够满足温室黄瓜病害的检测需求。

### 2.5.4　与不同模型的对比

选取主流模型 Faster R-CNN、SSD、YOLO v5、YOLO v6[28]、YOLO v7[29]、YOLO v8、AlexNet 与 RCN 模型进行对比，具体结果见表 5。

由表 5 可知，RCN 模型的 mAP@0.5 比 Faster R-CNN、SSD、AlexNet、YOLO v5、YOLO v6、YOLO v7、YOLO v8 分别高出 28.0、21.8、16.0、8.1、12.2、8.6、4.8 个百分点，总体来说，RCN 模型性能优良，

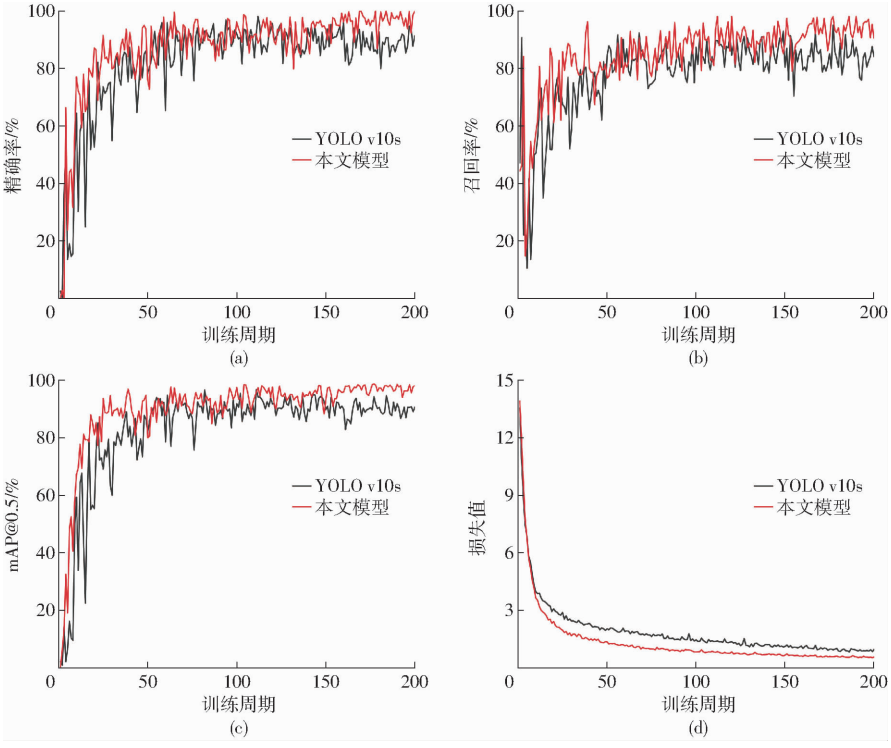


图 7　精确率、召回率、mAP@0.5、损失值变化曲线

Fig. 7　Precision, recall, mAP@0.5 and loss change curves

表 5 不同检测模型性能对比

Tab. 5 Performance comparison of different detection models %

| 模型 | mAP@0.5 |
|---|---|
| Faster R-CNN | 70.3 |
| SSD | 76.5 |
| AlexNet | 82.3 |
| YOLO v5 | 90.2 |
| YOLO v6 | 86.1 |
| YOLO v7 | 89.7 |
| YOLO v8 | 93.5 |
| RCN | 98.3 |

能够更好地应用于温室黄瓜病害检测中。

### 2.6 可视化结果分析

为了更加直观展现 YOLO v10s 和本文模型的结果差异,选取了部分预测结果如图 8 所示,可以看到,对于炭疽病,YOLO v10s 的检测准确率仅为 62%,霜霉病为 88%,但在对 YOLO v10s 进行改进后的 RCN 模型,在 2 种病害的检测任务中准确率均为 99%,满足实际应用的需求。

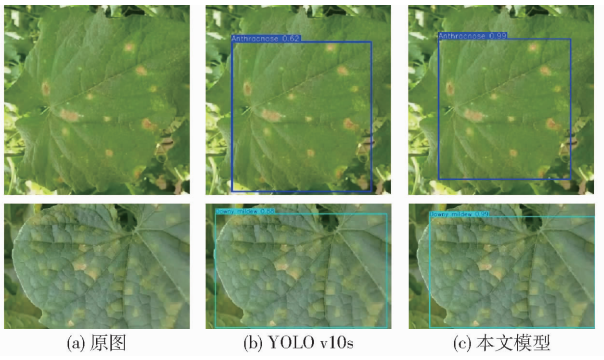

(a) 原图 (b) YOLO v10s (c) 本文模型

图 8 YOLO v10s 与 RCN 模型可视化结果

Fig. 8 Visualization results of YOLO v10s and RCN model

## 3 结论

(1)为了解决 YOLO 模型对于黄瓜病害识别准确率较低的问题,本文通过对 YOLO v10s 进行改进,提出一种新的 RCN 模型。首先在主干网络加入 ResNet50 残差网络,增强模型的网络深度;其次在颈部将 C2f 模块替换成 CSPPC 结构,减少模型的计算量,同时提高模型精度;最后引入 NAM 注意力机制,通过归一化操作使得模型更加轻量化,最终形成本文 RCN 模型。

(2)通过实验比较,本文 RCN 模型中的 ResNet50 残差网络对于模型精度的提升占据较大的比重,且相比于 YOLO v10s 模型,改进的 RCN 模型 mAP@0.5 可以达到 98.3%,mAP@0.5:0.95 可以达到 70.4%,分别提升 2.9、5.3 个百分点,改进效果明显。对比常见的主流模型 Faster R-CNN、SSD、AlexNet、YOLO v5、YOLO v6、YOLO v7、YOLO v8 也有着较大的优势,精度率曲线、损失值曲线等也表明了 RCN 模型的优越性,该模型能够精确识别温室黄瓜病害,可更好地部署在移动端。

## 参 考 文 献


[1] 朱国仁. 对我国设施蔬菜病虫害技术的评价和建议[M]. 北京: 中国科学出版社, 1999: 94-96.

[2] 陈芳,王福堂,贺超兴,等. 日光温室黄瓜白粉病发生规律及防治技术探讨[J]. 新疆农垦科技,2022,45(5): 28-31.
Chen Fang, Wang Futang, He Chaoxing, et al. Study on the occurrence law and control technology of cucumber powdery mildew in solar greenhouse[J]. Xinjiang Agricultural Reclamation Science and Technology, 2022,45(5): 28-31. (in Chinese)

[3] 王慧,李梅兰,许建平,等. 基于冠层温湿度模型的日光温室黄瓜霜霉病预警方法[J]. 应用生态学报,2015,26(10): 3027-3034.
Wang Hui, Li Meilan, Xu Jianping, et al. Early warning method for cucumber downy mildew in solar greenhouse based on canopy temperature and humidity model[J]. Chinese Journal of Applied Ecology, 2015,26(10): 3027-3034. (in Chinese)

[4] 纪思亮. 山东济宁温室黄瓜病虫害防治技术[J]. 农业工程技术,2023,43(36): 66-67.
Ji Siliang. Greenhouse cucumber pest and disease control techniques in Jining, Shandong[J]. Agricultural Engineering Technology, 2023,43(36): 66-67. (in Chinese)

[5] 郭文娟,冯全,李相周. 基于农作物病害检测与识别的卷积神经网络模型研究进展[J]. 中国农机化学报,2022,43(10): 157-166.
Guo Wenjuan, Feng Quan, Li Xiangzhou. Research progress on convolutional neural network models for crop disease detection and recognition[J]. Journal of Chinese Agricultural Mechanization, 2022, 43(10): 157-166. (in Chinese)

[6] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[J]. Advances in Neural Information Processing Systems, 2012,25: 1097-1105.

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

[8] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[PP/OL]. V3. arXiv(2014-05-07)[2025-05-12]. https://arxiv.org/abs/1311.2524v3.

[9] Girshick R. Fast R-CNN[PP/OL]. V2. arXiv(2015-09-27)[2025-05-12]. https://arxiv.org/abs/1504.08083v2.

[10] Ren S, He K, Girshick R, et al. Faster R-CNN: towards real time object detection with region proposal networks[J]. IEEE

Transactions on Pattern Analysis and Machine Intelligence,2016,39(6): 1138 - 1149.

[11] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, 2016: 779 - 788.

[12] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, 2017: 6517 - 6525.

[13] Liu W, Anguelov D, Erhan D, et al. SSD: single shot multiBox detector[PP/OL]. V5. arXiv(2016 - 12 - 29)[2025 - 05 - 12]. https://arxiv.org/abs/1512.02325v5.

[14] 袁杰,谢霖伟,郭旭,等. 基于改进 YOLO v7 的苹果叶片病害检测方法[J]. 农业机械学报,2024,55(11): 68 - 74.
Yuan Jie, Xie Linwei, Guo Xu, et al. Apple leaf disease detection method based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 68 - 74. (in Chinese)

[15] 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.
Zhang Liqiang, Wu Lingmei, Jiang Linli, et al. Grape leaf disease detection based on improved YOLO v8s[J]. Jiangsu Agricultural Sciences,2024,52(21): 221 - 228. (in Chinese)

[16] 张惠莉,代晨龙,任景龙,等. 基于 YOLO v8 - GSGF 模型的葡萄病害识别方法研究[J]. 农业机械学报,2024,55(11): 75 - 83.
Zhang Huili, Dai Chenlong, Ren Jinglong, et al. Grape disease identification method based on YOLO v8 - GSGF model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(11):75 - 83. (in Chinese)

[17] Son Changhwan. Leaf spot attention networks based on spot feature encoding for leaf disease identification and detection[J]. Applied Sciences,2021,11(17): 7960.

[18] Mathew P, Mahesh M. Leaf-based disease detection in bell pepper plant using YOLO v5[J]. Signal, Image and Video Processing,2021,16(3): 1 - 7.

[19] Zhang Y, Wa S Y, Liu Y S, et al. High-accuracy detection of maize leaf diseases CNN based on multi-pathway activation function module[J]. Remote Sensing,2021,13(21): 4218 - 4237.

[20] LIU Y C, Shao Z R, Teng Y Y, et al. NAM: normalization-based attention module[PP/OL]. V1. arXiv(2021 - 11 - 24)[2025 - 05 - 12]. https://arxiv.org/abs/2111.12419v1.

[21] 陈志勇,岳清华,李佳乐,等. 日光温室黄瓜主要病虫害绿色防控技术规程[J]. 现代农村科技,2025,(1): 41 - 42.
Chen Zhiyong, Yue Qinghua, Li Jiale, et al. Technical regulations for green prevention and control of major cucumber diseases and pests in solar greenhouses[J]. Modern Rural Science and Technology,2025,(1): 41 - 42. (in Chinese)

[22] 叶琪,王丽芬,马明涛,等. 基于改进 YOLO v8 的草莓病害检测方法[J]. 江苏农业科学,2024,52(20): 250 - 259.
Ye Qi, Wang Lifen, Ma Mingtao, et al. Strawberry disease detection method based on improved YOLO v8[J]. Jiangsu Agricultural Sciences,2024, 52(20): 250 - 259. (in Chinese)

[23] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[PP/OL]. V2. arXiv(2018 - 07 - 18)[2025 - 05 - 12]. https://arxiv.org/abs/1807.06521v2.

[24] Hou Q B, ZHOU D Q, Feng J S. Coordinate attention for efficient mobile network design[PP/OL]. V1. arXiv(2021 - 03 - 04)[2025 - 05 - 12]. https://arxiv.org/abs/2103.02907v1.

[25] Hu J, Shen L, Albanie S, et al. Squeeze-and-excitation networks[PP/OL]. V2. arXiv(2018 - 01 - 16)[2026 - 05 - 28]. https://arxiv.org/abs/1709.01507v2.

[26] Liu Y, Shao Z, Hoffmann N. Global attention mechanism: retain information to enhance channel-spatial interactions[PP/OL]. V1. arXiv(2021 - 12 - 10)[2025 - 05 - 12]. https://arxiv.org/abs/2112.05561v1.

[27] Wang Q, Wu B, Zhu P, et al. ECA - Net: efficient channel attention for deep convolutional neural networks[PP/OL]. V4. arXiv(2020 - 03 - 19)[2025 - 05 - 12]. https://arxiv.org/abs/1910.03151v4.

[28] Li C, Li L, Jiang H, et al. YOLOv6: a single-stage object detection framework for industrial applications[PP/OL]. V1. arXiv(2022 - 09 - 07)[2025 - 05 - 12]. https://arxiv.org/abs/2209.02976v1.

[29] Wang C, Alexey B, Hong Y. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[PP/OL]. V3. arXiv(2022 - 07 - 15)[2025 - 05 - 12]. https://arxiv.org/abs/2207.02696v3.