doi:10.6041/j.issn.1000-1298.2025.09.056

基于改进 YOLO v10n 的苹果叶片病害检测方法

赵　晓　杨梦婷　张懿丹
(陕西科技大学电子信息与人工智能学院, 西安 710021)

摘要: 苹果叶片病害的早期检测对于保障苹果产量和质量至关重要。然而,由于苹果叶片病害形态各异、病斑区域较小等特征,导致病害检测精度不高,难以满足现代农业精准防控的需求。针对这一问题,提出了一种基于改进 YOLO v10n 的苹果叶片病害检测方法。利用感受野注意力卷积(Receptive field attention convolution,RFAConv)替换主干网络中的标准 Conv,以增强网络对病害叶片重要特征的捕捉能力。在 Neck 网络使用重参数化泛化特征金字塔网络(Reparameterized generalized feature pyramid network,RepGFPN)实现低层特征与高层语义信息的融合,以提高模型对苹果叶片上不同尺度病害的特征提取能力。构建空间金字塔快速池化注意力(Spatial pyramid pooling-fast_attention,SPPF_attention)模块,使得模型能更有效地聚焦于重要的注意力信息。设计空间通道优化检测头(Spatial and channel reconstruction convolution_v10Detect,SC_C_v10Detect),提高模型对不同大小病斑的检测能力。结果表明,所提模型的精确率为 86.3%,召回率为 86.8%,mAP@0.5 为 90.8%,mAP@0.5:0.95 为 62.9%,与原始 YOLO v10n 模型相比,分别提高 1.2、4.2、2.1、2.8 个百分点。所提模型与 Faster R-CNN、SSD、YOLO v8n、YOLO v9s、YOLO v10n、YOLO 11n 模型相比,mAP@0.5 分别提升 25.9、12.2、2.8、1.6、2.1、1.4 个百分点。本研究提出的改进方法显著提升了苹果叶片病害的检测精度,为果园病害的早期预警和精准防治提供了可靠的技术支持,对推动农业智慧发展具有重要意义。

关键词: 苹果; 叶片病害; 目标检测; YOLO v10; 多尺度融合; 注意力机制
中图分类号: TP391.41　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)09-0657-10　　**OSID**:

Apple Leaf Disease Detection Method Based on Improved YOLO v10n

ZHAO Xiao　YANG Mengting　ZHANG Yidan
(*School of Electronic Information and Artificial Intelligence*, *Shaanxi University of Science and Technology*, *Xi'an* 710021, *China*)

Abstract: Early detection of apple leaf diseases is very important to ensure apple yield and quality. However, due to the characteristics of different disease forms and small lesion areas on apple leaves, the disease detection accuracy is not high, which is difficult to meet the needs of accurate prevention and control in modern agriculture. To address this issue, an improved YOLO v10n-based method for apple leaf disease detection was proposed. The standard convolution (Conv) in the backbone network was replaced with receptive field attention convolution (RFAConv) to enhance the network's ability to capture important features of diseased leaves. The reparameterized generalized feature pyramid network (RepGFPN) was introduced in the Neck network to fuse low-level features with high-level semantic information, thereby improving the model's ability to extract features of diseases at different scales on apple leaves. A spatial pyramid pooling-fast_attention (SPPF_attention) module was constructed to enable the model to focus more effectively on critical attention information. A spatial and channel reconstruction convolution_v10Detect (SC_C_v10Detect) head was designed to enhance the model's detection capability for lesions of varying sizes. Results showed that the proposed model achieved a precision of 86.3%, a recall of 86.8%, an mAP@0.5 of 90.8%, and an mAP@0.5:0.95 of 62.9%. Compared with the original YOLO v10n model, the performance metrics were improved by 1.2, 4.2, 2.1, and 2.8 percentage points, respectively. Furthermore, the proposed model outperformed Faster R-CNN, SSD, YOLO v8n, YOLO v9s, YOLO v10n, and YOLO 11n in terms of mAP@0.5, with improvements of 25.9, 12.2, 2.8, 1.6, 2.1, and 1.4 percentage points, respectively. The improved

收稿日期: 2025-03-12　修回日期: 2025-04-16
基金项目: 国家自然科学基金项目(61971272、61601271)
作者简介: 赵晓(1978—),女,副教授,博士,主要从事数字图像处理研究,E-mail: 1727877137@qq.com

method proposed significantly improved the detection accuracy of apple leaf diseases, and provided reliable technical support for early warning and precise prevention of orchard diseases, which was of great significance for promoting the intelligent development of agriculture.

Key words: apple; leaf disease; target detection; YOLO v10; multiscale fusion; attention mechanism

0 引言

在全球农业领域,苹果作为广泛种植且经济价值颇高的水果作物,其产业健康发展对于果农生计以及水果市场供应稳定意义重大。然而,苹果生长过程中病害种类繁多,时刻威胁着苹果植株的茁壮成长,其中叶片病害尤为突出,成为苹果种植过程中亟待攻克的难题。因此,准确且即时检测出叶片病害,对于苹果种植业的发展具有重要意义。

传统农作物病害检测主要依赖人工观察和实验室检测。人工观察依靠果农或农技人员肉眼判断叶片症状[1],实验室检测则采用显微镜观察、培养基分离、生化检测等方法[2],两种方式效率低、耗时长且易受主观因素影响,难以满足现代农业对高效、精准、实时检测的需求。近年来,在计算机视觉技术的飞速发展下,特别是随着深度学习方法的快速应用,利用卷积神经网络进行农作物病害检测[3-4]与识别成为近年来研究的热点,对苹果叶片病害的检测有了新的突破,提出了一系列高效、高精度的新方法。苹果叶片病害检测研究中,BANSAL 等[5]融合预训练模型构建混合网络,验证精度达 96.25%;DING 等[6]通过 CBAM 改进 ResNet18,分类准确率达 95.2%;王权顺等[7]优化 YOLO v4,采用二分 K 均值聚类调整锚框,替换主干网络为 Dense-Net121,平均精度提升至 97.52%。由此可见,在模型精度提升方面已取得显著成果,然而这些方法多在背景单一、光照均匀和病害种类有限的理想化数据集进行训练和测试,导致模型在实际应用中的泛化能力不足,且现有高精度模型在处理复杂数据时,易受背景干扰和光照变化影响,导致性能下降。JIANG 等[8]采用 SSD 算法在自建数据集 ALDD 上检测苹果叶病害,平均精度为 78.80%。李鑫然等[9]改进 Faster R-CNN 模型,通过优化感兴趣区域池化将精度提升至 82.48%。然而,这些模型的检测精度与当前先进的深度学习病害检测模型[10-11]相比仍存在较大差距。真实复杂场景下的叶片病害检测面临诸多挑战,如病害形态各异、病斑区域小等因素,这些问题限制了模型的泛化能力,导致检测性能难以满足实际需求。因此,设计一种高精度、满足实际应用需求的苹果叶片病害检测模型至关重要。

针对上述问题,本文基于 YOLO v10n 模型[12]提出一种改进的苹果叶片病害检测方法。通过构建真实复杂场景的数据集和优化网络结构,提升模型对小病斑检测精度和多尺度特征提取能力,为复杂农业场景下的病害识别提供更有效的解决方案。

1 YOLO v10 模型

YOLO v10 是 YOLO[13](You only look once)系列较新的目标检测模型。YOLO v10 模型主要由主干网络(Backbone)、颈部网络(Neck)、头部网络(Head)3 部分组成。YOLO v10 继承并优化了前代模型的优势,具有更高的检测精度与更快的推理速度,这对于农业病害检测具有重要意义。因此,选用 YOLO v10 作为基准模型是实现高效、准确的苹果叶片病害检测的理想选择。

YOLO v10 是一种单阶段目标检测模型,其模型根据尺寸不同分为 5 种类型:YOLO v10n、YOLO v10s、YOLO v10m、YOLO v10l、YOLO v10x。随着模型深度和宽度依次增加,检测精度也逐步提升,但训练花费时间也相应提升。针对农业生产的实际需求,本研究选择 YOLO v10n 作为基准模型,在保证检测精度的同时,兼顾识别速度,以期满足苹果叶片病害实时检测的要求。

2 改进 YOLO v10n 模型

针对苹果叶片病害形态各异、病斑区域小特征导致检测精度不高的问题,本文对 YOLO v10n 模型进行改进,改进模型结构如图 1 所示,其中 c 表示通道数,h、w 表示特征图高度、宽度。利用感受野注意力卷积(Receptive field attention convolution,RFAConv)替换主干网络中的标准 Conv,增强网络对病害叶片重要特征的捕捉能力,从而更有效地提取病害区域的特征;在 Neck 网络使用重参数化泛化特征金字塔网络(Reparameterized generalized feature pyramid network,RepGFPN)实现低层特征与高层语义信息的融合,以提高模型对苹果叶片上不同尺度病害的特征提取能力;重新设计 SPPF 模块,在此基础上加入注意力机制,即空间金字塔快速池化注意力(Spatial pyramid pooling-fast_attention,SPPF_attention)模块,这一改进使得模型在处理病害叶片特征时,能更有效地聚焦于重要的注意力信

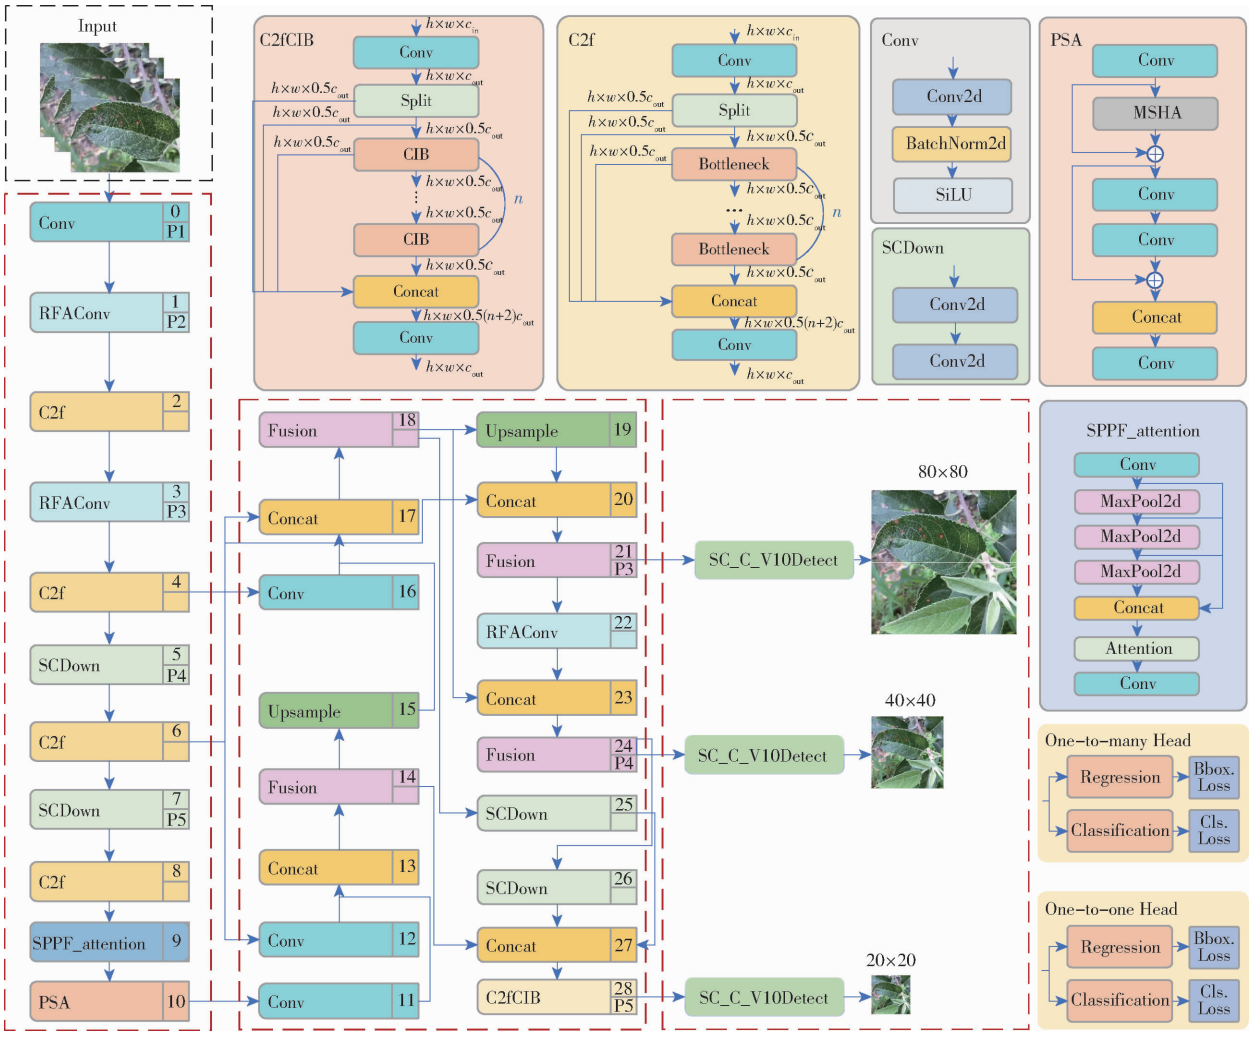

图 1　改进 YOLO v10n 模型结构图

Fig. 1　Improvement of YOLO v10n model structure diagram

息；设计空间通道优化检测头（Spatial and channel reconstruction convolution _ v10Detect，SC _ C _ v10Detect），有效提高模型对不同大小病斑的检测能力，提升模型的检测精度和召回率。

2.1　感受野注意力卷积（RFAConv）

在苹果叶片病害检测中，背景干扰和局部特征提取不足是两个主要挑战。背景干扰可能导致模型误将健康叶片的部分区域识别为病害，而局部特征提取不足则会影响模型对病害区域的精准定位和分类。为解决这些问题，RFAConv[14] 通过在卷积操作中引入注意力机制，增强模型对病害相关特征的聚焦能力。具体而言，RFAConv 通过对输入特征进行变换，计算感受野内每个位置的注意力权重，并将这些权重与标准卷积核融合，从而在卷积运算中对病害区域进行有偏重的处理。这种方法不仅能够有效抑制背景干扰，还能提升对苹果叶片局部病害特征的提取能力，最终提高病害检测的精度。

RFAConv 结构如图 2 所示。首先使用展开操作（Unfold）方法或分组卷积（Group Conv）操作来提取感受野空间特征，这些操作有助于捕捉图像中的局部细节和空间信息；其次，对每个感受野特征使用平均池化（Average pooling）进行全局信息聚合。平均池化操作通过对特征图进行下采样，保留重要的全局信息，从而生成注意力图；然后利用生成的注意力图对特征进行加权。通过将注意力图与原始特征图相乘，增强重要区域的特征，抑制不重要区域，有助于网络更有效地提取苹果叶片病害区域的特征；最后，通过卷积操作提取加权后的特征，生成最终的特征图，用于后续的检测任务。

本研究利用 RFAConv 替换 YOLO v10n 主干网络中的标准 Conv，使得模型能够更精确地捕捉病害区域的特征，增强对复杂背景和小目标的鲁棒性，提高检测精度。

2.2　重参数化泛化特征金字塔网络（RepGFPN）

在苹果叶片病害检测任务中，传统特征融合方法存在计算成本高、特征交互效率低等问题。以特征金字塔网络（Feature pyramid network，FPN）[15] 为例，其采用自顶向下的方式对多尺度特征进行融合，

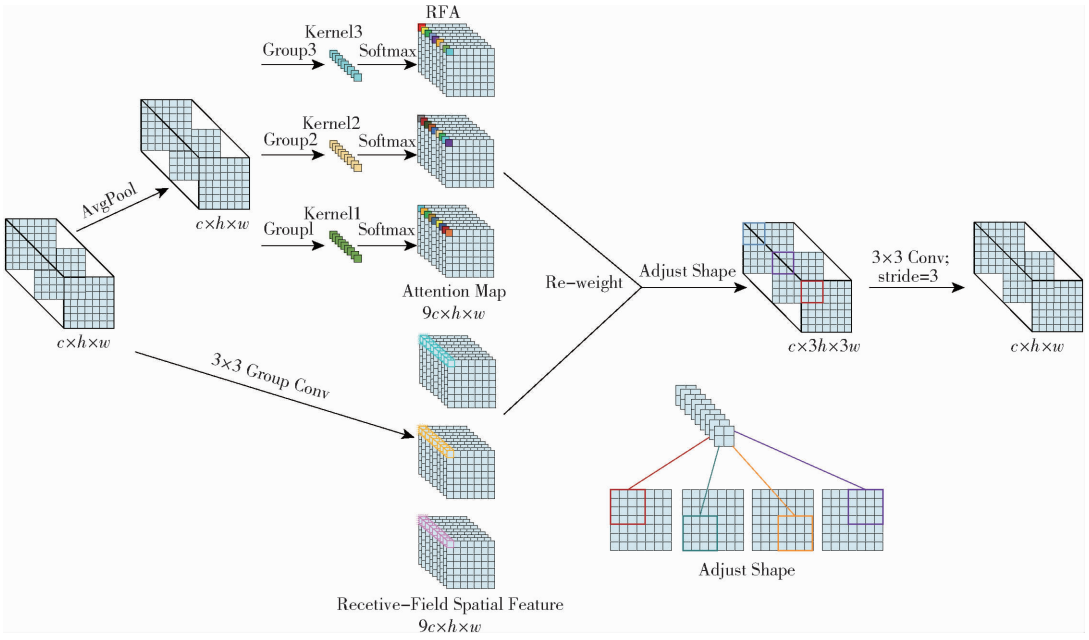

图 2 感受野注意力卷积结构图

Fig. 2 Receptive field attention convolution structure diagram

虽能够捕捉不同尺度信息,但会显著增加计算成本。双向特征金字塔网络(Bidirectional feature pyramid network,BiFPN)[16]通过优化节点连接结构提升了特征融合性能,但仍未能完全解决计算复杂性和特征交互效率的问题。泛化特征金字塔网络(Generalized feature pyramid network,GFPN)[17]虽能够有效融合多层次特征,但仍存在显著缺陷:其 Queen Fusion 操作引入了大量冗余的上采样与下采样运算,进一步增加了计算复杂性和资源消耗。针对上述问题,RepGFPN[18]有效解决了传统特征融合方法的困境。

RepGFPN 网络结构如图 3 所示。RepGFPN 通过优化特征融合策略,采用不同尺度特征图匹配不同通道维度的设计,在有效控制计算成本的同时,增强了多尺度特征的提取能力,从而更好地捕捉苹果叶片病害的细微特征。此外,该方法改进了 GFPN 的 Queen Fusion 模块,移除冗余上采样操作以提高计算效率。为进一步提升特征融合效果,RepGFPN 引入 CSPNet 替代传统的 3×3 卷积模块,强化了高级语义信息与低级空间信息的交互

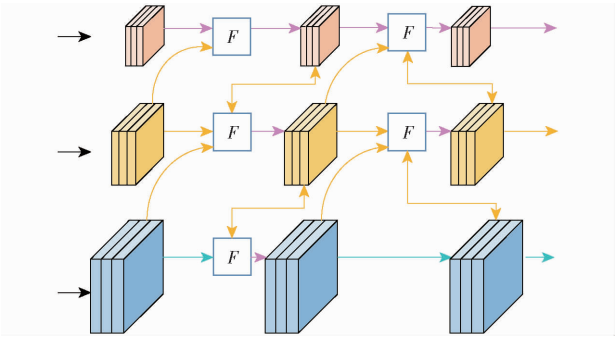

图 3 重参数化泛化特征金字塔网络结构图

Fig. 3 RepGFPN network structure diagram

能力。最后,结合重参数化机制和 ELAN 网络对 CSPNet 进行增强,进一步优化了模型性能,使其在保持实时检测速度的同时,显著提升了苹果叶片病害的识别精度。

在 RepGFPN 网络中,Fusion Block 作为关键模块,承担着主要的特征融合任务。Fusion Block 模块结构如图 4 所示。首先对输入的特征图进行 Concat 操作,以此整合多方面的特征信息。接着,借助 1×1 卷积对整合后的特征图进行通道降维处理,以降低计算复杂度并提取关键特征维度。而后,运用多个

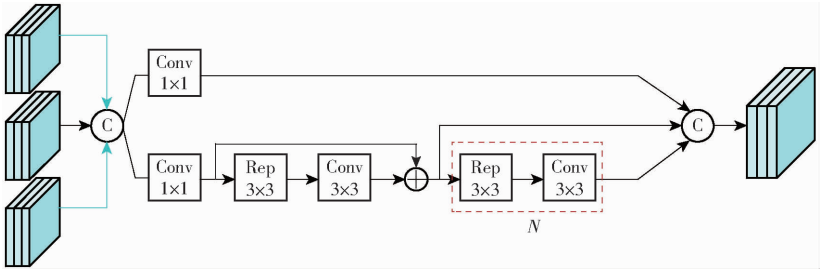

图 4 Fusion Block 网络结构图

Fig. 4 Fusion Block network structure diagram

Rep 3×3 卷积与 3×3 卷积对特征展开深度变换操作，在此过程中，多个层级均会产生相应的输出，这些输出承载着不同层次的特征信息。最终，通过再次执行 Concat 操作，将各层级输出的特征信息进行融合，从而获得最终的输出结果。

因此本研究采用 RepGFPN 替代原特征融合方法能够增强特征融合效果，实现低层特征与高层语义信息的融合，从而提高模型对苹果叶片上不同尺度病害的特征提取能力。

2.3　空间金字塔快速池化注意力（SPPF_attention）

针对苹果叶片病害检测中关键区域聚焦能力弱的问题，本研究对 SPPF[19] 模块进行了改进。SPPF 模块是一种用于特征提取和融合的空间金字塔池化结构。然而，其在处理病害叶片特征时，难以有效聚焦于关键的注意力信息，导致对病害区域的判别能力有限。为此，本研究在 SPPF 模块的基础上引入注意力机制，提出了 SPPF_attention 模块。

SPPF_attention 结构如图 5 所示。在最后一层 1×1 卷积前嵌入注意力机制，具体采用空间注意力机制，通过对特征图的空间维度进行操作，生成 1 个空间注意力图，以此来突出特征图中重要的空间区域。首先，对特征图在通道维度上进行全局平均池化和全局最大池化操作，分别得到 2 个不同的 $h \times w \times 1$ 特征描述；将这 2 个特征描述在通道维度上进行拼接，然后通过 1 个 7×7 卷积层进行特征融合与降维，得到 1 个新的特征图；再经过 1 个 Sigmoid 激活函数，将特征图的值映射到 0～1 之间，生成空间注意力权重图；最后，将这个空间注意力权重图与原始特征图逐元素相乘，以此来增强重要空间区域的特征响应，抑制不重要区域的特征响应。该模块借助上述注意力机制，可使网络自动聚焦于苹果叶片病害的关键区域，区分出更具代表性和区分度的特征，显著提升对病害特征的识别能力。

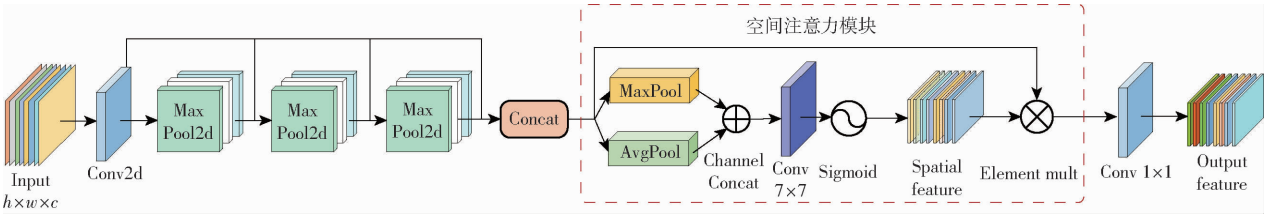

图 5　空间金字塔快速池化注意力模块结构图

Fig. 5　SPPF_attention structure diagram

2.4　空间通道优化检测头（SC_C_v10Detect）

针对苹果叶片病害检测中特征冗余导致的计算成本高和病害叶片漏检误检的问题，本研究引入了空间和通道重建卷积[20]（Spatial and channel reconstruction convolution，SCConv）模块，并将其与 YOLO v10 检测头结合。SCConv 独特的架构能够有效增强特征表示能力。SCConv 模块结构如图 6 所示。SCConv 模块由 2 个核心单元组成：空间重建单元（Spatial reconstruction unit，SRU）和通道重建单元（Channel reconstruction unit，CRU）。其中，SRU 通过分离重建方法抑制空间冗余，增强特征表示能力；CRU 则采用分割-变换-融合策略减少通道冗余。将 SCConv 与 YOLO v10 检测头结合后，模型能够更好地捕捉苹果叶片病斑的形状、颜色、纹理、边缘等细微特征，从而更准确地区分健康叶片与患病叶片以及不同类型的病害。

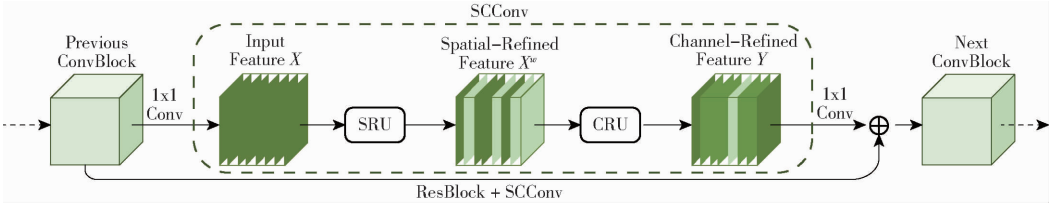

图 6　空间和通道重建卷积模块结构图

Fig. 6　SCConv module structure diagram

SC_C_v10Detect 检测头结构如图 7 所示。首先将经过多尺度融合操作后的特征图送入 SCConv 模块，SCConv 模块对融合后的特征图进行进一步特征提取和优化；经过 SCConv 处理后的特征将作为输入传递给 YOLO v10 的检测头，检测头再将这些特征映射为最终的预测结果，包括目标的位置和类别

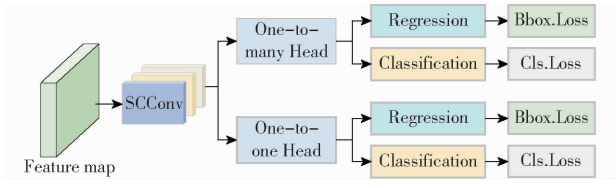

图 7　空间通道优化检测头结构图

Fig. 7　SC_C_v10Detect structure diagram

信息。在传递过程中,特征图的尺寸、通道数等会根据检测头的要求进行相应调整。SC_C_v10Detect 检测头能够有效提高模型对不同大小病斑的检测能力,精准识别不同类型病害,减少误检漏检,提升模型的检测精度和召回率。

3 结果与分析

3.1 实验平台和参数设置

为确保实验条件的一致性,本文在相同实验环境下对所提模型及对比模型进行了训练与验证。在远程服务器 Autodl 上搭建了实验环境,CPU 为 15vCPU Intel(R) Xeon(R) Platinum 8474C,内存为 80 GB,GPU 为 NVIDIA RTX 4090D,显存为 24 GB,CUDA 11.8 版本,深度学习框架为 PyTorch 2.0.1 版本,编程语言为 Python 3.10。输入图像分辨率为 640 像素×640 像素。设置模型参数如下:训练周期为 200,批量大小为 16;使用 Adam 优化器,初始学习率设置为 0.01。

3.2 评价指标

采用精确率、召回率、平均精度均值(mean Average Precision,mAP)、参数量和帧率作为评价指标对模型进行评估。mAP@0.5 指 IoU 为 0.5 时的平均精度均值;mAP@0.5:0.95 指 IoU 从 0.5 到 0.95,步长 0.05 时的平均精度均值。

3.3 数据集构建

3.3.1 数据集采集

目前,苹果叶片病害检测研究主要依赖于 PlantVillage 数据集。然而,该数据集图像主要在实验室受控条件下拍摄,与实际田间场景存在显著差异,为提升研究的实用价值,并弥合实验室与现实环境的差距,本研究采集了自然条件下复杂背景的苹果叶片病害图像来构建数据,以确保模型在实际场景下推理识别的可行性和有效性。数据来源于网络搜集和实地拍摄。

本文通过搜索引擎和专业网站收集苹果病害叶片图像,并以陕西省白水县苹果园的叶片作为研究对象。在 2024 年 7—9 月使用小米手机采集 5 种果园常见的叶片病害,大部分图像在晴朗天气光照良好条件下获取,少部分图像在阴雨天气采集。该数据集包含苹果树生长期间常见的 5 种叶片病害(斑点落叶病、褐斑病、灰斑病、锈病和黑星病)。采集 5 种病害图像共 2 800 幅,分别为斑点落叶病 520 幅、褐斑病 620 幅、灰斑病 510 幅、锈病 595 幅、黑星病 555 幅。然后通过 LabelImg 对数据集手动标注。图 8a~8e 分别展示了采集数据中斑点落叶病、褐斑病、灰斑病等苹果叶片病害样例,图 8f 为健康叶片图像,用作对比。



图 8 苹果叶片病害示例

Fig. 8 Example of apple leaf disease

3.3.2 数据集扩充

为了提升模型的泛化能力及鲁棒性,使用了 Python 的 Pillow(PIL)库,对标注好的数据集图像进行左右翻转、上下翻转、亮度增强等操作,将数据集数量从原始的 2 800 幅扩充至 5 423 幅,并通过 Python 再将对应的 XML 标签文件进行扩增。以锈病为例,图 9a 为原始图像,图 9b~9d 分别为上下翻转、左右翻转、亮度增强操作所进行的数据集扩增样本示例。

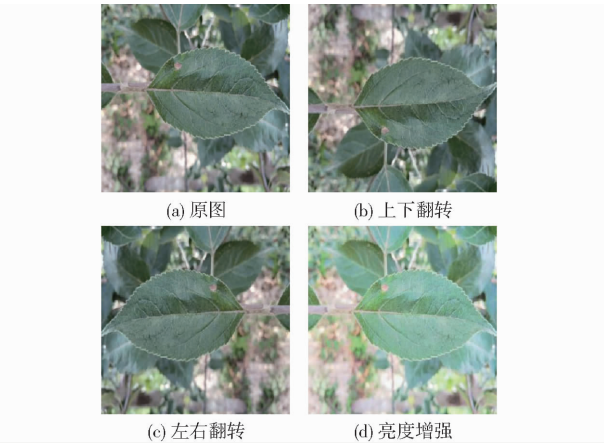

图 9 苹果叶片病害图像扩充示例

Fig. 9 Examples of apple leaf disease image augmentation

3.4 实验结果

3.4.1 骨干网络中不同卷积模型性能对比

为验证本文改进主干卷积的有效性,将 ODConv[21]、DynamicConv[22]、AKConv[23] 与 RFAConv 进行对比,结果如表 1 所示。

由表 1 可知,RFAConv 与其他卷积相比,召回率、平均精度均值最高。RFAConv 与 ODConv 相比,召回率、mAP@0.5 和 mAP@0.5:0.95 分别提高

表 1　骨干网络中不同卷积模型性能对比

Tab. 1　Performance comparison of different convolution models in backbone network　%

卷积类型	精确率	召回率	mAP@0.5	mAP@0.5:0.95
ODConv	84.2	83.0	87.9	58.2
DynamicConv	85.4	82.8	87.2	58.9
AKConv	84.5	84.4	88.1	59.5
RFAConv(本文)	84.0	86.0	89.1	61.0

3.0、1.2、2.8 个百分点；与 DynamicConv 相比，召回率、mAP@0.5 和 mAP@0.5:0.95 分别提高 3.2、1.9、2.1 个百分点；与 AKConv 相比，召回率、mAP@0.5 和 mAP@0.5:0.95 分别提高 1.6、1.0、1.5 个百分点。因此，将原模型 YOLO v10n 中主干网络的标准卷积替换为 RFAConv，在 YOLO v10n 模型中具有更好的性能，能够有效提高检测精度。

为进一步从视觉角度验证不同卷积算子的特征提取能力差异，图 10 为 ODConv、DynamicConv、AKConv 与 RFAConv 在相同测试样本上的感受野热力图对比。由图 10 可知，RFAConv 生成的热力图在病害区域呈现出更集中、更准确的高激活响应(红色区域)，其激活范围与真实病斑的吻合度最高。这一可视化结果与表 1 中的量化指标相互印证，直观地解释了 RFAConv 在召回率和 mAP 上的优势源于其更精准的感受野自适应能力，能够有效区分病害特征与背景干扰，从而为本文提出的卷积改进提供了有力的可视化证据。

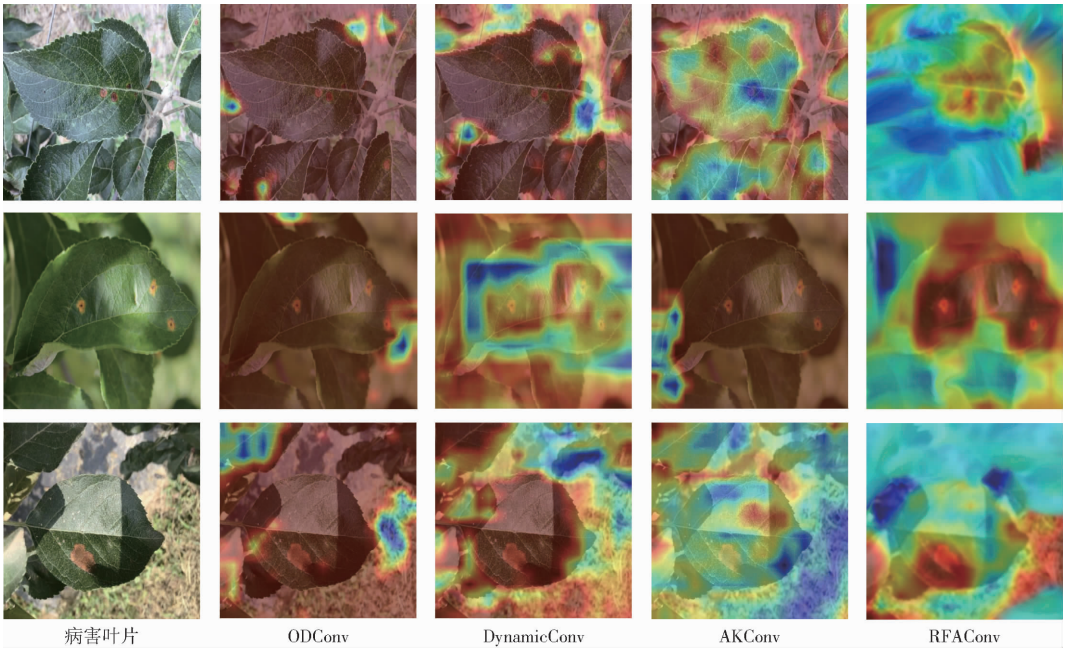

图 10　不同卷积的感受野热力图

Fig. 10　Receptive field heat maps of different convolutions

3.4.2　不同注意力机制模型性能对比

为验证本文提出的注意力机制 SA 模块的有效性，设计对比实验。在完全相同的网络架构和训练条件下分别添加 CA[24]、CBAM[25] 注意力机制，与本文注意力机制进行对比，结果如表 2 所示。

表 2　不同注意力机制模型性能对比

Tab. 2　Comparison of performance of different attention mechanism models　%

注意力类型	精确率	召回率	mAP@0.5	mAP@0.5:0.95
YOLO v10n	85.1	82.6	88.7	60.1
YOLO v10n_CA	84.5	82.8	88.4	59.1
YOLO v10n_CBAM	83.7	83.9	88.2	59.1
YOLO v10n_SA(本文)	83.4	85.1	88.6	59.5

由表 2 可知，使用 YOLO v10n_SA 注意力机制与其他注意力机制相比，召回率表现最优，达到 85.1%，相较于 YOLO v10n、YOLO v10n_CA、YOLO v10n_CBAM 分别提高 2.5、2.3、1.2 个百分点。4 种注意力类型的召回率对比如图 11 所示，由图 11

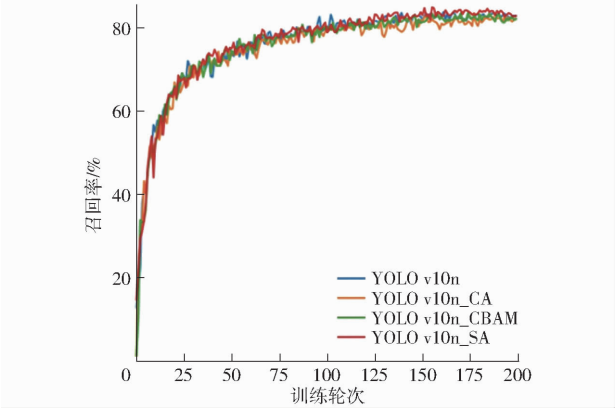

图 11　训练过程召回率变化曲线

Fig. 11　Change of recall rate during training

可以看出,引入 SA 注意力机制的模型召回率表现最优。因此,引入 SA 注意力机制能更有效地捕捉病害区域的全局特征,减少漏检情况,从而更适合应用于苹果叶片病害的精准识别任务。

3.4.3 消融实验对比

为验证本文提出的各改进模块方法的有效性,以 YOLO v10n 作为基线模型,在相同实验环境下依次添加 RepGFPN、SPPF_attention、RFAConv 以及 SC_C_v10Detect 进行消融实验,结果如表 3 所示。其中,"√"表示当前列的模块添加到了当前行的模型中。

表 3 消融实验结果

Tab. 3 Ablation experiment results %

模型	RepGFPN	SPPF_attention	RFAConv	SC_C_v10Detect	精确率	召回率	mAP@0.5	mAP@0.5:0.95
YOLO v10n					85.1	82.6	88.7	60.1
Model-1	√				84.9	85.8	88.9	60.9
Model-2		√			83.4	85.1	88.6	59.5
Model-3			√		84.0	86.0	89.1	61.0
Model-4				√	86.4	83.1	88.7	58.8
Model-5	√	√			84.2	85.5	89.5	60.9
Model-6	√	√	√		85.9	84.7	90.4	62.2
Model-7	√	√	√	√	86.3	86.8	90.8	62.9

由表 3 可知,使用 RepGFPN 替换原有的特征融合方式后,召回率、mAP@0.5 和 mAP@0.5:0.95 分别提高 3.2、0.2、0.8 个百分点,由此可以验证 RepGFPN 能够更全面地捕捉病害区域的特征,减少信息丢失、提升对复杂背景的鲁棒性以及改善对小目标病害的检测能力,显著提升了模型召回率。当把重新设计的 SPPF_attention 模块加入模型后,召回率提高 2.5 个百分点,可以验证其在检测病害区域时具有更全面的覆盖能力,能够有效减少漏检情况。使用 RFAConv 替换网络中部分标准 Conv 后,召回率、mAP@0.5 和 mAP@0.5:0.95 分别提高 3.4、0.4、0.9 个百分点,验证了该模块能够更全面地捕捉病害区域的特征且具有更高的边界定位精确性。将原 v10Detect 检测头改进为 SC_C_v10Detect 检测头后,精确率、召回率分别提高 1.3、0.5 个百分点,验证了该模块是有效的,增强了模型对病害区域的检测能力。当 4 个优化模块同时融入,相较于原 YOLO v10n 模型,精确率、召回率、mAP@0.5 和 mAP@0.5:0.95 分别提高 1.2、4.2、2.1、2.8 个百分点,因此,本文模型在苹果叶片病害检测中具有更好的检测效果。

为更直观地验证各改进模块对困难样本(如小目标或背景复杂的病害区域)的检测效果,图 12 为典型小目标苹果叶片病害样本的检测结果对比,其中分图题对应于表 3。由图 12 可以看到,基线模型在微小病斑和复杂背景区域存在明显漏检,而随着 RepGFPN、SPPF_attention、RFAConv 和 SC_C_v10Detect 模块的逐步引入,模型对小目标的捕捉能力、边缘病斑的识别精度以及复杂背景的鲁棒性均得到显著提升。最终融合全部改进模块的模型表现出最优的检测性能,这与表 3 中的定量分析结果相互印证。

3.4.4 不同检测模型性能对比

为进一步验证所提模型的有效性,将改进模型与目前主流的深度学习算法模型(Faster R-CNN[26]、SSD[27]、YOLO v8n、YOLO v9s[28]、YOLO

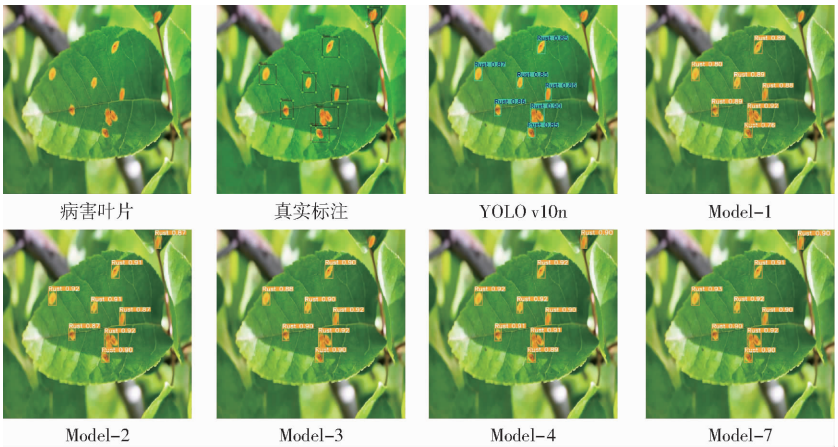

图 12 消融实验检测结果可视化

Fig. 12 Visualization of ablation test results

v10n、YOLO 11n)进行对比实验,结果如表 4 所示。

表 4　不同检测模型性能对比

Tab. 4　Performance comparison of different detection models

模型	精确率/%	召回率/%	mAP@0.5/%	帧率/(f·s^{-1})	参数量
Faster R-CNN	42.9	78.4	64.9	42.0	1.371×10^{8}
SSD	64.5	56.3	78.6	12.0	2.628×10^{7}
YOLO v8n	83.8	83.8	88.0	290.0	3.000×10^{6}
YOLO v9s	86.2	83.1	89.2	98.6	7.130×10^{6}
YOLO v10n	85.1	82.6	88.7	201.7	2.710×10^{6}
YOLO 11n	84.7	85.4	89.4	204.3	2.580×10^{6}
改进 YOLO v10n(本文)	86.3	86.8	90.8	218.6	2.970×10^{6}

由表 4 可知,本文模型的 mAP@0.5 比 Faster R-CNN、SSD、YOLO v8n、YOLO v9s、YOLO v10n、YOLO 11n 模型分别高 25.9、12.2、2.8、1.6、2.1、1.4 个百分点;精确率比 Faster R-CNN、SSD、YOLO v8n、YOLO v9s、YOLO v10n、YOLO 11n 模型分别高 43.4、21.8、2.5、0.1、1.2、1.6 个百分点;召回率比 Faster R-CNN、SSD、YOLO v8n、YOLO v9s、YOLO v10n、YOLO 11n 模型分别高 8.4、30.5、3.0、3.7、4.2、1.4 个百分点。在模型复杂度方面,与基准模型相比,本文模型在参数量仅增加 9.5% 的情况下,实现了 218.6 f/s 的推理速度。这一结果表明,所提改进方案在显著提升检测精度的同时,较好地保持了模型的轻量化特性,有效平衡了精度与计算效率的权衡关系。因此,本文提出的苹果叶片病害检测算法具有一定的优越性。

3.5　可视化对比验证

图 13 为模型检测的可视化结果。通过可视化可更直观地评估算法在检测苹果叶片病害方面的有效性,图中清晰地展示了检测到的苹果叶片病害的位置、大小和类别信息,这些信息有助于更全面地评估算法的准确性和效率。从图 13 可以看出,改进模型不仅检测框对应的概率值显著增大,而且能够检测到之前未发现的苹果叶片病害区域,降低了漏检率。由此可见,相较于原始 YOLO v10n 模型,所提模型检测效果更优。

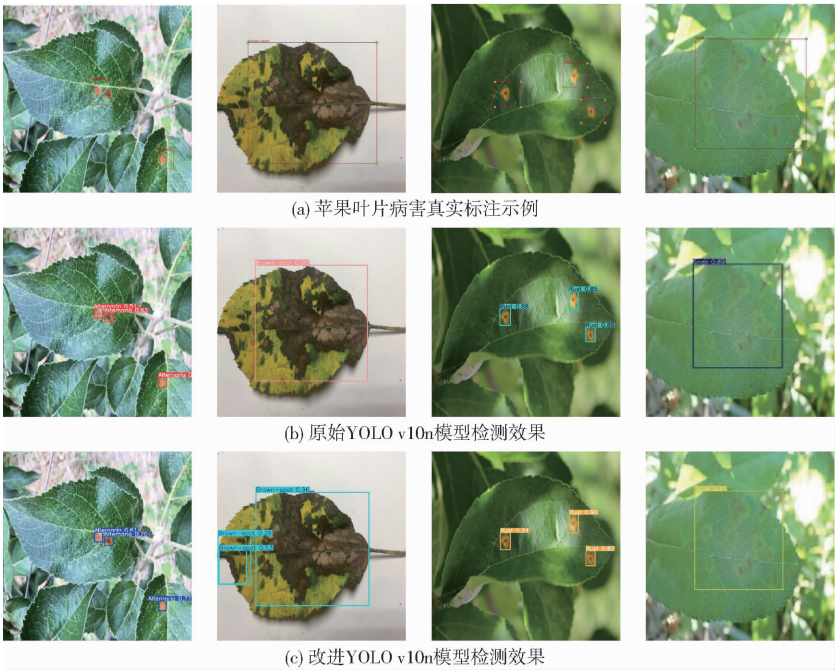

(a) 苹果叶片病害真实标注示例

(b) 原始YOLO v10n模型检测效果

(c) 改进YOLO v10n模型检测效果

图 13　改进前后检测效果对比图

Fig. 13　Comparison of detection results before and after improvement

4　结论

(1)针对苹果叶片病害的形态各异、病斑区域较小等特征导致检测精度不高问题,提出了一种基于改进 YOLO v10n 的苹果叶片病害检测方法,实现了苹果叶片病害快速且精准检测。构建了多样化真实场景的病害数据集提升数据质量。在模型改进方面,采用 RFAConv 替代主干网络中的标准卷积,增强病害关键特征提取能力;在 Neck 网络使用 RepGFPN 实现多尺度特征融合,以提高模型对不同尺度病害的特征提取能力;优化 Backbone 中的 SPPF 模块,引入注意力机制构建 SPPF_attention 模块,使模型能够更精准地聚焦于病害区域的关键信息;设计 SC_C_v10Detect 检测头,进一步提升模型对多尺度病斑的检测性能。

(2)所提模型与原始模型相比,精确率、召回

率、mAP@0.5 和 mAP@0.5:0.95 分别提高 1.2、4.2、2.1、2.8 个百分点;与主流检测模型(Faster R-CNN、SSD、YOLO v8n、YOLO v9s、YOLO v10n、YOLO 11n)相比,mAP@0.5 分别提升 25.9、12.2、2.8、1.6、2.1、1.4 个百分点。特别值得注意的是,在实现上述性能提升的同时,模型仍保持了 218.6 f/s 的推理速度。这一高效性能使得本文提出的检测方法可实现苹果叶片病害的实时精准检测,有助于及早防控病害、减少经济损失,推动苹果产业向智能化、精准化方向发展。

参 考 文 献

[1] 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 of convolutional neural network model based on crop disease detection and recognition[J]. Journal of Chinese Agricultural Mechanization, 2022, 43(10): 157-166. (in Chinese)

[2] ZHENG J Y, LI K Y, WU W B, et al. RepDI: a light-weight CPU network for apple leaf disease identification[J]. Computers and Electronics in Agriculture, 2023, 212: 108122.

[3] 盛帅,段先华,胡维康,等. Dynamic-YOLOX:复杂背景下的苹果叶片病害检测模型[J]. 计算机科学与探索, 2024, 18(8): 2118-2129.
SHENG Shuai, DUAN Xianhua, HU Weikang, et al. Dynamic-YOLOX: an apple leaf disease detection model in complex background[J]. Journal of Computer Science and Exploration, 2024, 18(8): 2118-2129. (in Chinese)

[4] 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. Research on grapevine 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)

[5] BANSAL P, KUMAR R, KUMAR S. Disease detection in apple leaves using deep convolutional neural network[J]. Agriculture, 2021, 11(7): 617.

[6] DING R R, QIAO Y L, YANG X H, et al. Improved ResNet based apple leaf diseases identification[J]. IFAC-PapersOnLine, 2022, 55(32): 78-82.

[7] 王权顺,吕蕾,黄德丰,等. 基于改进 YOLOv4 算法的苹果叶部病害缺陷检测研究[J]. 中国农机化学报, 2022, 43(11): 182-187.
WANG Quanshun, LÜ Lei, HUANG Defeng, et al. Research of apple leaf disease defect detection based on improved YOLOv4 algorithm[J]. Journal of Chinese Agricultural Mechanization, 2022, 43(11): 182-187. (in Chinese)

[8] JIANG P, CHEN Y H, LIU B, et al. Real-time detection of apple leaf diseases using deep learning approach based on improved convolutional neural networks[J]. IEEE Access, 2019, 7: 59069-59080.

[9] 李鑫然,李书琴,刘斌. 基于改进 Faster R_CNN 的苹果叶片病害检测模型[J]. 计算机工程, 2021, 47(11): 298-304.
LI Xinran, LI Shuqin, LIU Bin. Apple leaf diseases detection model based on improved Faster R_CNN[J]. Computer Engineering, 2021, 47(11): 298-304. (in Chinese)

[10] 张立杰,周舒骅,李娜,等. 基于改进 SSD 卷积神经网络的苹果定位与分级方法[J]. 农业机械学报, 2023, 54(6): 223-232.
ZHANG Lijie, ZHOU Shuhua, LI Na, et al. Apple location and classification based on improved SSD convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 223-232. (in Chinese)

[11] 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)

[12] WANG A, CHEN H, LIU L, et al. Yolov10: real-time end-to-end object detection[J]. arXiv Preprint, arXiv:2405.14458, 2024.

[13] CHITHAMBARATHANU M, JEYAKUMAR M K. Survey on crop pest detection using deep learning and machine learning approaches[J]. Multimedia Tools and Applications, 2023, 82(27): 42277-42310.

[14] ZHANG X, LIU C, YANG D, et al. RFAConv: innovating spatial attention and standard convolutional operation[J]. arXiv Preprint, arXiv:2304.03198, 2023.

[15] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117-2125.

[16] TAN M, PANG R, LE Q V. Efficientdet: scalable and efficient object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.

[17] JIANG Y, TAN Z, WANG J, et al. GiraffeDet: a heavy-neck paradigm for object detection[J]. arXiv Preprint, arXiv:2202.04256, 2022.

(下转第 728 页)

[16] JIANG Y, XU X, HUANG Q, et al. Optimizing regional irrigation water use by integrating a two-level optimization model and an agro-hydrological model[J]. Agricultural Water Management, 2016, 178: 76 – 88.
[17] LI J, JIAO X, JIANG H, et al. Optimization of irrigation scheduling for maize in an arid oasis based on simulation-optimization model[J]. Agronomy, 2020, 10(7): 935.
[18] LI X, ZHANG C, HUO Z. Optimizing irrigation and drainage by considering agricultural hydrological process in arid farmland with shallow groundwater[J]. Journal of Hydrology, 2020, 585: 124785.
[19] JIANG Y, XIONG L, XU Z, et al. A simulation-based optimization model for watershed multi-scale irrigation water use with considering impacts of climate changes[J]. Journal of Hydrology, 2021, 598: 126395.
[20] XU X, HUANG G, SUN C, et al. Assessing the effects of water table depth on water use, soil salinity and wheat yield: searching for a target depth for irrigated areas in the upper Yellow River basin[J]. Agricultural Water Management, 2013, 125: 46 – 60.
[21] KROES J G, VAN DAM J C. Reference manual SWAP: version 3.0.3 (Alterra-Report 773)[M]// Green world research. Wageningen: Alterra, 2003: 211.
[22] WILLIAMS J R, JONES C A, KINIRY J R, et al. The EPIC crop growth model[J]. Trans. ASAE, 1989, 32: 497 – 511.
[23] 徐旭, 黄冠华, 黄权中. 农田水盐运移与作物生长模型耦合及验证[J]. 农业工程学报, 2013, 29(4): 110 – 117.
XU Xu, HUANG Guanghua, HUANG Quanzhong. Coupled simulation of soil water flow, solute transport and crop growth processes at field scale and its validation[J]. Transactions of the CSAE, 2013,29(4):110 – 117. (in Chinese)
[24] JIANG Y, XU X, HUANG Q, et al. Assessment of irrigation performance and water productivity in irrigated areas of the middle Heihe River basin using a distributed agro-hydrological model[J]. Agricultural Water Management, 2015, 147: 67 – 81.
[25] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multi-objective genetic algorithm: NSGA – Ⅱ[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182 – 197.
[26] 姜瑶. 黑河中游绿洲多尺度农业水文过程及用水效率的模拟分析与优化调控研究[D]. 北京: 中国农业大学, 2017.
JIANG Yao. Simulation analysis and optimal regulation for agro-hydrological processes and water use efficiency on multiple scales of the middle Heihe River basin[D]. Beijing: China Agricultural University, 2017. (in Chinese)
[27] GARCIA-VILA M, FERERES E. Combining the simulation crop model AquaCrop with an economic model for the optimization of irrigation management at farm level[J]. European Journal of Agronomy, 2012, 36(1): 21 – 31.

(上接第 666 页)

[18] XU X, JIANG Y, CHEN W, et al. Damo-yolo: a report on real-time object detection design[J]. arXiv Preprint, arXiv:2211.15444, 2022.
[19] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904 – 1916.
[20] LI J, WEN Y, HE L. Scconv: spatial and channel reconstruction convolution for feature redundancy[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 6153 – 6162.
[21] LI C, ZHOU A, YAO A. Omni-dimensional dynamic convolution[J]. arXiv Preprint, arXiv:2209.07947, 2022.
[22] HAN K, WANG Y, GUO J, et al. ParameterNet: parameters are all you need for large-scale visual pretraining of mobile networks[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 15751 – 15761.
[23] ZHANG X, SONG Y, SONG T, et al. AKConv: convolutional kernel with arbitrary sampled shapes and arbitrary number of parameters[J]. arXiv Preprint, arXiv:2311.11587, 2023.
[24] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[J]. arXiv Preprint, arXiv:2103.02907, 2021.
[25] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[J]. arXiv Preprint, arXiv:1807.06521, 2018.
[26] 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): 1137 – 1149.
[27] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[J]. arXiv Preprint, arXiv: 1512.02325, 2015.
[28] WANG C Y, YEH I H, MARK L H Y. Yolov9: learning what you want to learn using programmable gradient information[C]// European Conference on Computer Vision, 2024: 1 – 21.