

丁士宁,姜明富. 基于改进 FCOS 的水稻叶片病害检测模型[J]. 江苏农业科学,2024,52(12):232–238.

doi:10.15889/j.issn.1002–1302.2024.12.031

# 基于改进 FCOS 的水稻叶片病害检测模型

丁士宁<sup>1</sup>,姜明富<sup>1,2</sup>

(1. 信阳农林学院信息工程学院,河南信阳 464000; 2. 澳门理工大学应用科学学院,澳门 999078)

**摘要:**针对传统水稻病害识别方法主要依赖人工,效率低下且存在人工主观误差的问题,提出一种基于改进 FCOS 模型的水稻叶片病害检测模型。首先收集 950 张 3 种不同病害的水稻叶片图像,构建 Pascal Voc 格式的水稻叶片病害数据集。为增强模型的泛化能力,对划分为训练集的图像进行数据增强,训练集图像由 760 张扩增至 6 080 张。然后构建检测模型,改进 FCOS 模型在原模型的基础上,在特征融合网络引入 CBAM 注意力模块;损失函数中,回归损失函数采用 CIOU 损失函数,分类损失函数和中心度损失函数与原 FCOS 模型保持一致。改进的 FCOS 模型在水稻叶片病害数据上的平均精度均值达 77.7%,相比原 FCOS 模型提升了 2.3 百分点,改进的模型在不明显提升检测时间的情况下,提升了模型的精度。通过试验与模型 YOLOF、Faster R – CNN、VarifocalNet、NAS – FCOS、TOOD 进行对比,结果表明本研究模型取得了最高的检测精度,且在检测精度和检测速度上取得了最高的权衡。结果表明,本研究提出的模型能够比较精准地识别水稻白叶枯病、胡麻叶斑病和叶瘟病,可以为水稻叶片病害的检测提供参考。

**关键词:**改进 FCOS 模型;水稻叶片病害图像;Pascal Voc 格式;CBAM 注意力模块;CIOU 损失函数

**中图分类号:**S126;TP391.41 **文献标志码:**A **文章编号:**1002–1302(2024)12–0232–07

水稻作为我国重要的粮食作物之一,有着悠久的种植历史。我国水稻的种植面积和产量均居世界前列<sup>[1]</sup>。然而水稻在各个生长周期易受到各种病虫害侵害,从而严重损害水稻的产量和品质。因此,及时准确识别水稻病虫害并根据识别结果采取对应的防治措施,对于保证水稻的健康生长是十分重要且必要的。

传统的植物病害识别方法主要依赖于人工进行,该方法效率低且依赖于人的主观意识<sup>[2]</sup>。伴随着深度学习技术的发展,以 Faster R – CNN 为代表的双阶段检测模型、以 YOLO 系列为代表的一阶段检测模型已应用到植物图像检测领域<sup>[3–5]</sup>。朱红春等使用 Faster R – CNN 对茶叶嫩芽进行检测,与传统的茶叶嫩芽识别算法的对比试验表明,该模型在检测精度和速度上具备优势<sup>[6]</sup>。王云露等对 Faster R – CNN 进行改进,其使用 ResNest 网络作为骨干特征提取网络,特征融合网络使用特征金字塔网络(FPN),并采用级联机制优化样本选择机制,改进后

模型的平均精度均值(mean average precision,简称 mAP)达到 86.2%,比改进前提升了 8.7%,验证了模型在苹果叶片小目标病斑和复杂背景下病斑的检测有效性<sup>[7]</sup>。涂淑琴等将 Faster R – CNN 应用于百香果检测,并实现了无遮挡、遮挡、重叠和背景 4 种情形下的自动检测<sup>[8]</sup>。董浪等使用 Faster R – CNN 识别梨树花芽,其采用 ResNet 101 作为骨干特征提取网络,并在模型中融入了特征金字塔网络,模型的平均精度均值达到 91.27%,每幅图像的检测时间为 0.395 s,说明模型在自然光照环境下梨树花芽检测具有有效性和实时性<sup>[9]</sup>。魏冉等将特征金字塔网络和注意力机制 SKNet 引入 Faster R – CNN,改进后的模型对樱桃的平均精度均值达 98.24%<sup>[10]</sup>。徐会杰等在 YOLO v3 模型的基础上提出了 YOLO v3 – Corn 模型,新模型在玉米叶片病虫害数据上的平均精度均值达到了 93.31%,比 YOLO v3 模型提高了 4.03%<sup>[11]</sup>。王根等从损失函数、骨干特征提取网络、anchor 生成等多个方面对 YOLO v3 模型提出了改进,并将改进后的模型应用于茶草位置检测,对茶树和杂草的检测精确率分别达到 82.56%、85.34%<sup>[12]</sup>。沈志豪等在 YOLOX – s 模型的基础上,重新设计了特征提取网络的深度,引入了注意力机制和 SPPF 模块,改进后的模型用于田间麦穗检测及计数,在实拍的麦田图像中,改进模

收稿日期:2023–07–24

基金项目:河南省科技攻关项目(编号:222102210300);河南省高等学校青年骨干教师培养计划(编号:2021GGJS176);信阳农林学院青年教师科研基金项目(编号:QN2021057)。

作者简介:丁士宁(1993–),男,河南信阳人,硕士,助教,研究方向为模式识别与人工智能。E – mail:1728252083@qq.com。

型的计数准确率达到 97.93%<sup>[13]</sup>。杨堃等提出基于视觉加强注意力改进的 YOLO v5 - VE 模型,在制作的植物病虫害数据集上的检测平均准确率达到 73.49%<sup>[14]</sup>。骆润玫等提出 YOLO v5 - C,并将该模型应用到复杂背景下的广佛手病虫害识别上,平均精度均值达到了 93.06%,比基础网络 YOLO v5s 提高 2.45%<sup>[15]</sup>。

FCOS(fully convolutional one-stage object detection)模型作为经典的 Anchor-free 模型,在植物图像识别检测、行人检测等各个领域均有所应用<sup>[16]</sup>。龙燕等在原 FCOS 基础上,从骨干网络、损失函数等方面进行改进,改进模型应用于自然环境下苹果果实检测,其平均精度均值达到 96.3%<sup>[17]</sup>。黄河清等提出了基于模型剪枝的多维度特征 Slim-FOCS 算法,对柑橘检测平均精度均值达到 96.01%<sup>[18]</sup>。刘丹等使用 FCOS 算法进行行人检测,其使用轻量化网络 MobileNet v2 替换 ResNet 50 网络,并增加 C2 层进行特征融合,提高了检测精度和速度<sup>[19]</sup>。刘竞升等在 FCOS 模型的基础上,通过增加特征增强网络构建了二阶段无锚框检测算法,通过在舰船数据集与其他主流舰船检测算法对比,验证了所提模型的有效性<sup>[20]</sup>。

本研究首先收集白叶枯病(rice bacterial leaf blight)、胡麻叶斑病(rice brown spot)、叶瘟病(rice leaf blast)等水稻叶片病害图像构建数据集,然后在 FCOS 模型的基础上,为了更充分地提取特征,在特征融合网络中引入 CBAM(convolutional block attention module)注意力机制<sup>[21]</sup>。而对于模型损失函数,分类损失函数与原 FCOS 网络一致,采用 Focal Loss 损失函数,而回归损失函数则采用 CIOU(Complete-IoU)损失函数,从而实现水稻叶片病害的精准检测<sup>[22-23]</sup>。

## 1 构建水稻叶片病害检测模型

### 1.1 构建 FCOS 检测模型

Faster R-CNN、RetinaNet 等属于基于锚框(anchor-based)检测模型,其需要单独为每个数据集设置 Anchor,而且通常 Anchor 的设置会极大地影响模型的结果,这明显限制了 Anchor-based 模型的应用。本研究使用的 FCOS 模型作为无锚框(Anchor-free)检测模型,不需要为每个数据集单独适配 Anchor。

FCOS 模型的整体结构框图如图 1 所示。模型

主要包括骨干特征提取网络 Backbone、特征融合网络 Neck、头部检测网络 Head 等 3 个部分。骨干特征提取网络特取水稻叶片图像的特征,这里采用的是 ResNet50 模型,ResNet 网络解决了卷积神经网络面临的网络退化问题,其主要结构是残差块<sup>[24]</sup>。Neck 连接特征提取网络和 Head,对从特征提取网络输入的单尺度或多尺度特征进行分治和融合,这里采用特征金字塔网络(feature pyramid networks,简称 FPN)<sup>[25]</sup>,并在其中引入了 CBAM 注意力机制。Head 包括分类分支、回归分支、中心度(Center-ness)分支,分类和回归在该部分网络进行。

具体工作过程:首先输入水稻叶片图像,经由骨干特征提取网络 ResNet50 提取特征,得到(C1, C2, C3, C4, C5)层特征图,其对应的步长为(2, 4, 8, 16, 32),层数越高,特征信息越丰富。将(C3, C4, C5)层特征输入到 FPN 网络中进行特征分治和特征融合,获得(P3, P4, P5)层特征图,对 P5 层特征进行卷积操作得到(P6, P7)层特征图。(P3, P4, P5, P6, P7)对应的步长为(8, 16, 32, 64, 128)。最后在 Head 层对特征金字塔(P3, P4, P5, P6, P7)的每一层特征图进行分类和回归,预测水稻叶片的种类和位置信息。在 Head 的 Center-ness 分支表征当前位置与所预测物体中心点之间的距离,该距离衡量该位置是否是物体中心的置信度,便于后续非极大值抑制(non-maximum suppression,简称 NMS)筛选保留高质量的候选框。

### 1.2 特征融合网络

本模型的特征融合网络以特征金字塔网络为主体,在其中加入 CBAM 模块。FPN 利用了 ConvNet 的金字塔特征层次结构,构建具有高层次语义的特征金字塔<sup>[25]</sup>。对于 ResNet50 网络,将 conv3、conv4、conv5 这些残差块的输出表示为(C3, C4, C5),其对应的步长为(8, 16, 32),对应的通道尺寸(channel dimensions)为(512, 1 024, 2 048)。(C3, C4, C5)均经过 11 卷积层以减少通道尺寸,经过 11 卷积层之后,通道尺寸均降为 256,为了便于描述,将经过 11 卷积层的(C3, C4, C5)记为(D3, D4, D5)。(D4, D5)上采样后与(D3, D4)进行逐元素相加,并在合并的特征图上经由 33 的卷积以生成特征图(P3, P4),特征 P5 直接由 D5 经由 3×3 的卷积得到,这样生成了特征图(P3, P4, P5)。特征图 P5 经过步长为 2 的 3×3 卷积获得特征图 P6,同理获得特征图 P7。这样就生成了一组特征图(P3, P4,

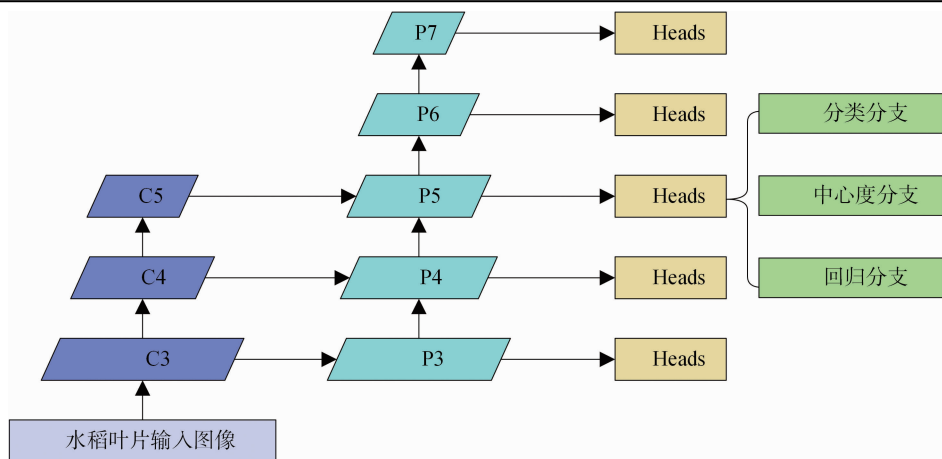


图1 FCOS 模型框架

P5, P6, P7), 其对应的步长为(8, 16, 32, 64, 128), 其输出通道数均为 256。

为更好地进行特征提取和特征分治, 在 FPN 上加入 CBAM 注意力模块。CBAM 模块处于  $1 \times 1$  卷

积块之后, 上采样之前, 加入了 CBAM 模块的特征融合网络模型如图 2 所示。在本模型中, 累计加入了 3 个 CBAM 模块。

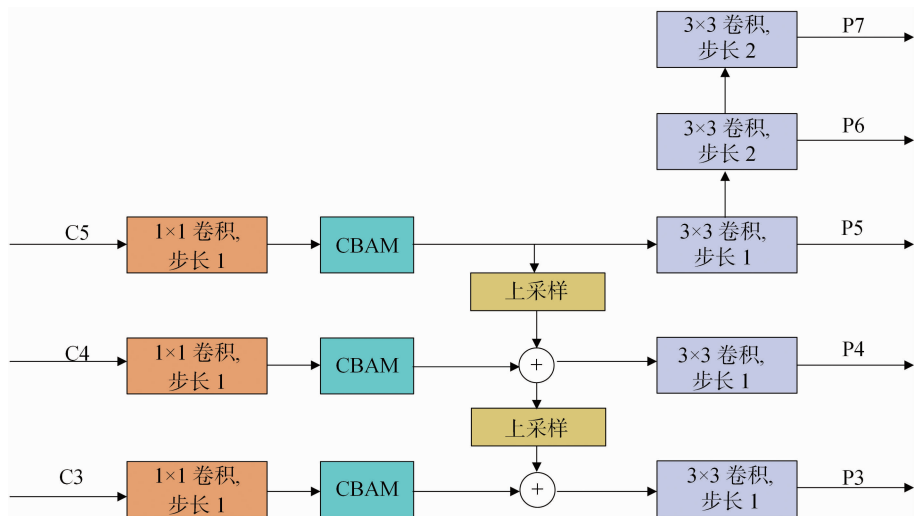


图2 特征融合网络模型

注意力机制类似人的注意力, 选择性地关注重要的或感兴趣的特征, 减少甚至忽视不相关或不感兴趣的特征。当模型的计算能力有限时, 注意力机制将算力分配到相关重要特征上, 从而更好地学习特征, 减少了资源浪费。通道注意力模块和空间注意力模块是 CBAM 模块的重要组成部分, 这 2 个模块让网络知道哪些信息需要强调, 哪些信息需要抑制。CBAM 论文通过试验验证, 先通过通道注意力模块再通过空间注意力模块可以取得最佳性能<sup>[21]</sup>。CBAM 结构如图 3 所示。

通道注意力模块的结构如图 4 所示。其输入特征图  $F$  的维度是  $H \times W \times C$ , 分别经过最大池化和平均池化操作得到相应的特征图  $F_{\max}^C$  和  $F_{\text{avg}}^C$ , 其维度

均为  $1 \times 1 \times C$ 。 $F_{\max}^C$  和  $F_{\text{avg}}^C$  经由包含一个隐层的多层感知器 MLP 里, 将经过 MLP 的注意力图进行像素级相加, 最后由 sigmoid 函数激活。通道注意力模块的计算过程见公式(1):

$$M_c(F) = \sigma \{ \text{MLP}[\text{AvgPool}(F)] + \text{MLP}[\text{MaxPool}(F)] \} \\ = \sigma \{ W_1 [W_0(F_{\text{avg}}^C)] + W_1 [W_0(F_{\max}^C)] \} \quad (1)$$

式中:  $W_1$  和  $W_0$  是多层感知器 MLP 的权重参数;  $\sigma$  是 sigmoid 激活函数;  $\text{MaxPool}$  是最大池化操作;  $\text{AvgPool}$  是平均池化操作。

空间注意力模块的结构如图 5 所示。将输入的特征图  $F'$  分别进行最大池化和平均池化操作, 得到  $H \times W \times 1$  的特征图  $F_{\max}^s$  和  $F_{\text{avg}}^s$ , 然后将 2 个特征图

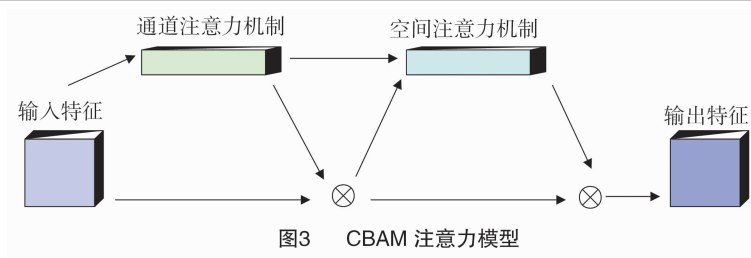


图3 CBAM 注意力模型




图4 CBAM 的通道注意力模块




图5 CBAM 的空间注意力模块

拼接,得到  $H \times W \times 2$  的特征图,再经由卷积操作将通道维度降到1,最后经由 sigmoid 函数激活。空间注意力机制的计算过程可以由如下公式表达为:

$$M_s(F') = \sigma \{ \text{Conv}[\text{AvgPool}(F'); \text{MaxPool}(F')] \} \\ = \sigma [\text{Conv}(F_{\text{avg}}^s; F_{\text{max}}^s)]。 \quad (2)$$

式中:Conv 代表卷积操作,这里使用  $7 \times 7$  卷积。

CBAM 模块的整体计算过程可以描述为:

$$F' = M_c(F) \otimes F; \quad (3)$$

$$F_{SCA} = M_s(F') \otimes F'。 \quad (4)$$

式中: $F_{SCA}$  是 CBAM 输出的注意力加强后的特征图; $M_c(F)$  是通道注意力模块输出; $M_s(F')$  是空间注意力模块输出; $\otimes$  是逐像素相乘操作。

CBAM 是轻量化通用模块,在特征融合网络中引入 CBAM 模块,在不显著增大计算时间的情况下,提高模型识别水稻病虫害的精度。

### 1.3 损失函数

损失函数用来判断模型预测的精度高不高,损失函数值越小,模型的精度越高。FOCS 模型的损失函数由分类损失  $L_{cls}$ 、回归损失  $L_{reg}$ 、目标中心度损失  $L_{center-ness}$  3 个部分构成,即

$$L = L_{cls} + L_{reg} + L_{center-ness} \quad (5)$$

分类损失采用 Focal Loss 损失函数,该函数使模型在训练时更关注难以训练的样本,提升模型训练效果。其公式如下

$$FL(p_i) = -\alpha_i(1-p_i)^\gamma \ln(p_i)。 \quad (6)$$

式中: $p_i$  表示水稻病害类别的概率; $\alpha_i$  和  $\gamma$  是调制系数,这里取  $\alpha_i = 2, \gamma = 0.25$ 。

目标中心度损失采用交叉熵损失函数,抑制低质量样本,提升模型训练效果。具体公式为:

$$L_{center-ness} = \sqrt{\frac{\min(l^*, r^*)}{\max(l^*, r^*)} \times \frac{\min(t^*, b^*)}{\max(t^*, b^*)}}。 \quad (7)$$

式中: $l^*, r^*, t^*, b^*$  分别是当前像素点与目标框的左、右、上、下边界的距离。

框回归分支的损失函数使用 CIoU 损失函数,CIoU 考虑了重叠面积、中心点距离、宽高比等元素,计算公式如下:

$$L_{CIoU} = 1 - IoU + \frac{d^2}{c^2} + \alpha v; \quad (8)$$

$$v = \frac{4}{\pi^2} \left( \arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2; \quad (9)$$

$$\alpha = \begin{cases} 0, & IoU < 0.5 \\ \frac{v}{(1 - IoU) + v}, & IoU \geq 0.5 \end{cases} \quad (10)$$

式中: $IoU$  是真实检测框与预测检测框面积的交并比; $d$  是真实检测框的中心点与预测检测框的中心点之间的距离; $c$  是覆盖 2 个检测框的最小封闭长方形框的对角线长度; $w^{\text{gt}}$ 、 $h^{\text{gt}}$  是真实检测框的宽和高; $w$ 、 $h$  是预测检测框的宽和高。

2 结果与讨论

为验证模型在水稻叶片病害图像数据上的有效性,在服务器平台上进行试验验证。服务器的配置如下: Ubuntu 20. 04 操作系统, PyThon 3. 7, PyTorch 1. 10, CUDA 11. 3, CUDNN 8. 2, 所用显卡为 RTX 3090 (显存 25. 4 GB)。所有模型均在

mmdetection 3. 0 框架下进行训练和测试。本试验模型的结果均在 Featurize 平台( [https://featurize. cn/](https://featurize.cn/) )上运行得出,运行时间为 2023 年 5 月至 7 月上旬。

2.1 数据收集和数据集制作

数据来源于 Kaggle 网站。从 Kaggle 网站收集水稻白叶枯病、胡麻叶斑病、叶瘟病图像数据,并人工筛除模糊不清的图像,最终得到图像 950 张,部分图像如图 6 所示。使用 Labelme 软件对水稻叶片病害位置进行标注,最终得到 Pascal Voc 格式的数据集。按照约 8 : 2 的比例划分训练集和测试集,并对训练集数据进行数据增强,使用的数据增强方式包括图像翻转(水平、垂直)、图像旋转(90°、180°、270°)、图像明暗度调节,从而将训练集图像数量增强至原先的 8 倍,扩增后的训练集包含 6 080 张图像。数据集划分结果如表 1 所示。

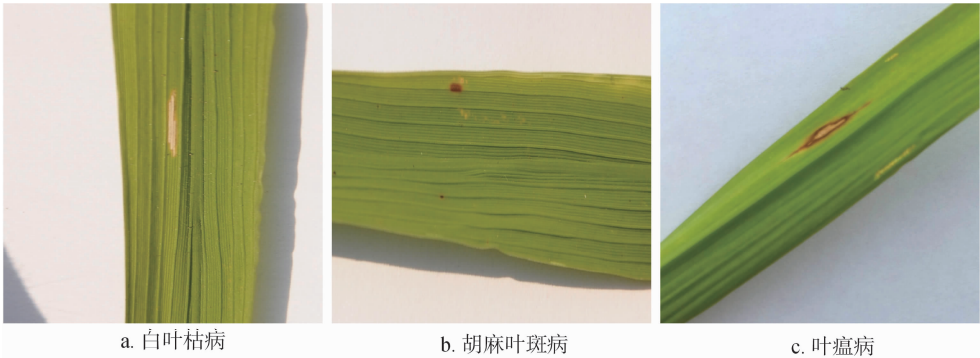


图6 水稻叶片病害图像示例

表 1 水稻叶片病害数据划分

病害类别	训练集	增强后的训练集	测试集
白叶枯病	277	2 216	69
胡麻叶斑病	221	1 768	55
叶瘟病	262	2 096	66
总数	760	6 080	190

2.2 参数设置和评价指标

使用随机梯度下降算法( stochastic gradient descent, 简称 SGD) 更新模型参数, 学习率设为 0. 01, 动量设为 0. 9, epoch 设置为 12, batch size 设为 16, 学习率采用 Warm up 策略, 在第 8 个和第 11 个 epoch 之后, 学习率降为原先的 0. 1 倍。模型的训练损失随迭代次数的变化曲线如图 7 所示, 横坐标为迭代次数, 纵坐标为损失。随着迭代次数的增加, 模型的损失函数整体趋势是随之降低, 在 4 000 次迭代后, 损失函数基本无变化, 说明了模型训练的有效性。









图7 损失函数变化曲线

本研究使用平均精度均值( mAP) 和平均帧率( frame per second, 简称 FPS) 分别衡量模型的精度和速度。平均精度均值是各水稻叶片病害检测精度的均值, 其值越高, 说明模型训练的结果越精确。平均帧率是指在当前软硬件条件下, 模型每秒可以处理的图像数量, 单位是图像数量/ s, 简记做 img/ s。平均帧率值越高, 说明模型在单位时间内处理的图

像数量越多,模型的速度越快。平均帧率的测量需要在相同软硬件条件和相同维度的输入图像下进行。在本研究中,在全数据集上测试平均帧率,全数据集是指由增强后的训练集和测试集构成的数据集,包含了 6 270 张图像。

2.3 试验结果

为验证模型的有效性,本研究将所提模型与 YOLOF、Faster R – CNN、VarifocalNet、NAS – FCOS、TOOD、FCOS 等模型进行对比<sup>[3,16,26–29]</sup>,结果见表 2。YOLOF 的平均帧率指标最高,达到 61.8,说明该模型在当前软硬件条件下每秒可以处理 61.8 张图像,模型推理速度远高于其他模型,但其平均精度均值指标最低,分别低于 Faster R – CNN、VarifocalNet、NAS – FCOS、TOOD、FCOS、改进 FCOS 模型 4.5、5.5、6.7、8.5、6.7、9.0 百分点。Faster R – CNN 模型的平均精度均值达到 73.2%,低于改进 FCOS 模型 4.5 百分点,其平均帧率达到 31.9,低于改进 FCOS 模型 5.0。VarifocalNet 模型的平均精度均值和平均帧率分别达到了 74.2% 和 32.7,均低于改进 FCOS 模型。NAS – FCOS 模型的平均精度均值达到 75.4%,低于改进 FCOS 模型 2.3 百分点,其平均帧率仅为 26.7。TOOD 模型的平均精度均值达到 77.2%,仅比改进 FCOS 模型低 0.5 百分点,但其平均帧率明显低于改进 FCOS 模型,每秒比改进 FCOS 模型少处理 8.6 张图片。原 FCOS 模型的平

均精度均值达到 75.4%,低于改进 FCOS 模型 2.3 百分点。经分析认为,改进 FOCS 模型在精度和速度上取得了最高的权衡,且其在不明显降低速度的前提下,提升了模型的识别效果。

表 2 多模型检测性能对比

模型	平均精度均值 (%)	平均帧率 (img/s)
YOLOF	68.7	61.8
Faster R – CNN	73.2	31.9
VarifocalNet	74.2	32.7
NAS – FCOS	75.4	26.7
TOOD	77.2	28.3
FOCS	75.4	39.1
改进 FOCS	77.7	36.9

为进一步验证 CBAM 模块和 CIOU 模块对 FOCS 模型的作用,将 CBAM 模块和 CIOU 模块分别组合进行对比试验,试验结果如表 3 所示。不添加 CBAM 和 CIOU 模块的模型是原 FCOS 模型,同时添加 CBAM 模块和 CIOU 模块的模型是改进 FCOS 模型。CBAM 模块的加入增加了 1.7 百分点的检测精度,CIOU 模块的加入增加了 1.2 百分点的检测精度,同时加入 CBAM 和 CIOU 模块增加了 2.3 百分点的检测精度,相对于单独增加 CBAM 模块和 CIOU 模块分别提升了 0.6 百分点和 1.1 百分点的检测精度,说明了所提模型的有效性。

表 3 不同模块对模型的影响

CBAM	CIOU	平均精度均值 (%)	各病害类型的精度		
			白叶枯病	胡麻叶斑病	叶瘟病
√	√	75.4	0.698	0.691	0.874
		77.1	0.702	0.741	0.869
√	√	76.6	0.706	0.718	0.875
		77.7	0.733	0.741	0.857

3 讨论与结论

首先收集水稻白叶枯病、胡麻叶斑病、叶瘟病这 3 种水稻叶片病害图像从而构建相应的数据集,数据集为 Pascal voc 格式;然后搭建 FCOS 模型进行水稻叶片病害检测。在 FCOS 模型的特征提取模块引入 CBAM 模块以增强特征提取能力;损失函数中回归损失函数采用 CIOU 损失函数,分类损失和目标中心度损失与原 FCOS 模型保持一致。试验结果表明,所提模型的平均精度达到 77.7%,在不明显

提高计算时间的前提下,提升了模型精度。但在实际应用中,仅对 3 种水稻病害进行检测远远不足,将进一步收集更多种类的水稻病害图像数据,扩大模型检测病害种类范围。

参考文献:

[1]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.  
[2]张永玲. 基于 Android 的水稻病虫害图像识别与诊断系统的研究[D]. 杭州:浙江理工大学,2018.  
[3]Ren S Q,He K M,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, 2017, 39 (6): 1137–1149.
- [4] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA. IEEE, 2016: 779–788.
- [5] Redmon J, Farhadi A. YOLO9000: better, faster, stronger [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA. IEEE, 2017: 6517–6525.
- [6] 朱红春, 李旭, 孟炆, 等. 基于 Faster R-CNN 网络的茶叶嫩芽检测[J]. 农业机械学报, 2022, 53(5): 217–224.
- [7] 王云露, 吴杰芳, 兰鹏, 等. 基于改进 Faster R-CNN 的苹果叶部病害识别方法[J]. 林业工程学报, 2022, 7(1): 153–159.
- [8] 涂淑琴, 黄健, 林跃庭, 等. 基于改进 Faster R-CNN 的百香果自动检测[J]. 实验室研究与探索, 2021, 40(11): 32–37.
- [9] 董浪, 许建峰, 靳江周, 等. 基于改进 Faster R-CNN 的梨树花芽识别方法[J]. 河北农业大学学报, 2021, 44(6): 116–121.
- [10] 魏冉, 裴悦琨, 姜艳超, 等. 基于改进 Faster R-CNN 模型的樱桃缺陷检测[J]. 食品与机械, 2021, 37(10): 98–105, 201.
- [11] 徐会杰, 黄仪龙, 刘曼. 基于改进 YOLO v3 模型的玉米叶片病虫害检测与识别研究[J]. 南京农业大学学报, 2022, 45(6): 1276–1285.
- [12] 王根, 江晓明, 黄峰, 等. 基于改进 YOLO v3 网络模型的茶草位置检测算法[J]. 中国农机化学报, 2023, 44(3): 199–207.
- [13] 沈志豪, 刘金江, 张建洋. 基于改进 YOLOX-s 的田间麦穗检测及计数[J]. 江苏农业科学, 2023, 51(12): 164–171.
- [14] 杨堃, 范习健, 薄维昊, 等. 基于视觉加强注意力模型的植物病虫害检测[J]. 南京林业大学学报(自然科学版), 2023, 47(3): 11–18.
- [15] 骆润玫, 殷惠莉, 刘伟康, 等. 基于 YOLO v5-C 的广佛手病虫害识别[J]. 华南农业大学学报, 2023, 44(1): 151–160.
- [16] Tian Z, Shen C H, Chen H, et al. FCOS: fully convolutional one-stage object detection [C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea (South). IEEE, 2019: 9626–9635.
- [17] 龙燕, 李南南, 高研, 等. 基于改进 FCOS 网络的苹果环境下苹果检测[J]. 农业工程学报, 2021, 37(12): 307–313.
- [18] 黄河清, 胡嘉沛, 李震, 等. 基于模型剪枝改进 FCOS 的实时柑橘检测研究[J]. 河南农业大学学报, 2021, 55(3): 453–459.
- [19] 刘丹, 汪慧兰, 曾浩文, 等. 改进 FCOS 的行人检测算法[J]. 计算机工程与设计, 2022, 43(11): 3264–3270.
- [20] 刘竞升, 伍星, 王洪刚, 等. 改进 FCOS 的二阶段 SAR 舰船检测算法[J]. 计算机工程与应用, 2021, 57(24): 144–151.
- [21] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module [C]//European Conference on Computer Vision. Cham: Springer, 2018: 3–19.
- [22] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318–327.
- [23] Zheng Z H, Wang P, Liu W, et al. Distance-IoU loss: faster and better learning for bounding box regression[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993–13000.
- [24] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA. IEEE, 2016: 770–778.
- [25] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA. IEEE, 2017: 936–944.
- [26] Chen Q, Wang Y M, Yang T, et al. You only look one-level feature [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA. IEEE, 2021: 13034–13043.
- [27] Zhang H Y, Wang Y, Dayoub F, et al. VarifocalNet: an IoU-aware dense object detector [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA. IEEE, 2021: 8510–8519.
- [28] Wang N, Gao Y, Chen H, et al. NAS-FCOS: fast neural architecture search for object detection [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA. IEEE, 2020: 11940–11948.
- [29] Feng C J, Zhong Y J, Gao Y, et al. TOOD: task-aligned one-stage object detection [C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, QC, Canada. IEEE, 2021: 3490–3499.