李志鑫, 李桢桢, 南楚晗, 等. 基于改进 YOLOv8n 的轻量化水稻病害检测方法研究[J]. 智能计算机与应用,2026,16(6):67-74. DOI:10.20169/j.issn.2095-2163.24102701

基于改进 YOLOv8n 的轻量化水稻病害检测方法研究

李志鑫, 李桢桢, 南楚晗, 蔡金瀚, 李龙一
(南昌工程学院 信息工程学院, 南昌 330099)

摘 要: 针对目前水稻病害检测算法参数量大、计算复杂度高、在移动设备上部署困难等问题,提出一种基于 YOLOv8n 的轻量化水稻病害目标检测算法。首先,采用 Adown 卷积模块获得更有效的目标任务特征。其次,引入 DySample 超轻量动态上采样器提升模型泛化能力。最后,使用自研任务对齐动态检测头 TADDH,通过特征提取器从多个卷积层中学习任务交互特征,得到联合特征,使各个检测层能够捕获更全面的目标特征。实验结果表明,相较 YOLOv8n 原模型,ADT-YOLOv8n 轻量化模型在水稻病害检测识别任务中的 MAP 提高 2.5%,模型参数复杂度降低 40%,证明了改进后模型在模型轻量化及检测精度方面都具有一定优越性。

关键词: 病害检测; 轻量化; 目标检测; 卷积模块; 动态上采样器; 联合特征
中图分类号: TP391 **文献标志码**: A **文章编号**: 2095-2163(2026)06-0067-08

Research on lightweight disease detection method based on improved YOLOv8n for rice

LI Zhixin, LI Zhenzhen, NAN Chuhan, CAI Jinhan, LI Longyi
(School of Information Engineering, Nanchang Institute of Technology, Nanchang 330099, China)

Abstract: Aiming at the problems of large number of parameters, high computational complexity and difficult deployment on mobile devices, a lightweight rice disease target detection algorithm based on YOLOv8n is proposed. Firstly, Adown convolutional module is used to obtain more effective target task features. Secondly, the DySample ultra-lightweight dynamic up-sampler is introduced to improve the model generalization ability. Finally, the self-developed task-aligned dynamic detection head TADDH is used to learn task interaction features from multiple convolution layers through feature extractor to obtain joint features, so that each detection layer can capture more comprehensive target features. The experimental results show that compared with the original YOLOv8n model, the MAP of the ADT-YOLOv8n lightweight model in rice disease detection and recognition task is increased by 2.5%, and the parameter complexity of the model is reduced by 40%, which prove that the improved model had certain advantages in model lightweight and detection accuracy.

Key words: disease detection; lightweight; object detection; convolutional module; TADDH; joint characteristic

0 引 言

近年来,国内水稻种植业取得长足发展。然而,水稻病害依然是制约水稻种植进一步发展的重要障碍。常见的水稻病害包括白叶枯病、稻瘟病、褐斑病、东格鲁病毒病等。这些病害不仅直接关系到水稻的产量,还对其品质造成严重影响。如稻瘟病在水稻各个生长阶段都有可能发生,并且危害极大,严重时甚至可能导致绝产。如何快速有效地检测出水稻病害,对于防治及治疗水稻感染,保证水稻生产质量具有重要意义[1]。

随着科技发展,深度学习目标检测算法被越来越广泛地应用到了农业生产的各个环节中。目前,通用的目标检测算法可分为 2 类:单阶段目标检测方法(One-Stage Detectors)[2]和双阶段目标检测方法(Two-Stage Detectors)[3]。单阶段目标检测算法直接从输入图像中预测目标的类别和边界框位置,无需生成候选区域,具有更高的检测速度。单阶段

基金项目: 江西省水利厅科技项目(KT201639)。
作者简介: 李志鑫(1997—),男,硕士研究生。主要研究方向:深度学习,计算机视觉。
通信作者: 李桢桢(1981—),女,博士,讲师。主要研究方向:水信息采集与处理,信息系统开发。Email:2021994799@nit.edu.cn。
收稿日期: 2024-10-27

目标检测算法的代表有 YOLO (You Only Look Once)[4],SSD (Single Shot multibox Detector)[5] 等。两阶段检测算法首先生成一系列候选区域(region proposals),然后对这些候选区域进行分类和边界框回归,以确定最终检测结果。两阶段检测算法的代表有 R - CNN (Region - based Convolutional Neural Networks)[6]、Fast R - CNN (Fast Region - based Convolutional Neural Network)[7] 等。

针对水稻病害检测问题。众多国内外研究者使用深度学习框架,提出了各种各样的新思路。Yin 等学者[8] 在 YOLOv8 网络中构建多分支卷积块注意模块(M-CBAM)以及引入最小点距交会(MPDIoU)作为边界盒损失度量,从而加快模型收敛速度及保持最佳检测性能,在私有数据集上的检测精度达到了 95.8%。Pavithra 等学者[9] 根据师生知识蒸馏机制,提出了一种名为 Oryza Sativa Pathosis Spotter (OSPS)-MicroNet 的轻量级 CNN 模型。实验结果表明,该轻量级 CNN 模型仅为重量级模型 RESNET152 的网络规模的 0.7%,但检测准确率达到了 92.02%。Yang 等学者[10] 基于 YOLOv5 算法,引入 RepVGG 网络结构,采用多分支拓扑的训练时间模型,通过层合并减少推理时间。实验结果,改进算法的准确率提高了约 2.7 个百分点。Ali 等学者[11] 提出了一种新的多尺度上下文特征提取网络,以能够在不同尺度和通道上捕获疾病特征的上下文局部和全局表示。在公共水稻病害数据集上,该方案的平均准确率达到 98.74%。王圆圆等学者[12] 针对水稻病害检测精度低、速度慢、模型复杂度高、部署困难等问题,提出一种基于改进的 YOLOv4-GhostNet 水稻病害识别方法。改进后的模型相比原模型,精度有略微的下降,但所占空间大大减小,更易于在移动设备上面部署。丁士宁[13] 将残差网络 ResNet50 用于自行构建的 8 类水稻病虫害数据集,在原模型基础上引入了迁移学习和 NonLocal 注意力机制。实验结果表明,改进模型的准确率达到 99.12%,相比于原模型提升了 2.92%。

1 改进 YOLOv8n 算法

虽然这些改进都提升了模型的检测能力或者减少了占用空间,但在轻量化方面还是有一定不足。因此本文基于 YOLOv8n[14] 模型提出一种改进的轻量化水稻叶病害检测识别模型(见图 1),以便更好地部署到农业生产设备上进行病害检测。主要改进如下:

(1)将主干及颈部网络中原有的 Conv 卷积模块替换为 ADown[15] 下采样卷积块,对输入特征图进行空间维度的压缩,同时增大特征图的感受野,使得网络能够从更大范围内提取特征,从而不仅实现轻量化,而且能更好地捕捉全局语义信息。

(2)使用动态上采样器 DySample[16] 替换原有的上采样结构。DySample 主要采用点重采样的方法,而非传统的基于内核的方法,这不仅提高了资源效率,而且简化了在 Pytorch[17] 中的实现。

(3)使用自研检测头 TADDH 替换原有的检测头,特征提取器从多个卷积层中学习任务交互特征,得到联合特征。这种联合特征能够更好地捕捉分类和定位任务的相关性,有助于提高整体检测性能。

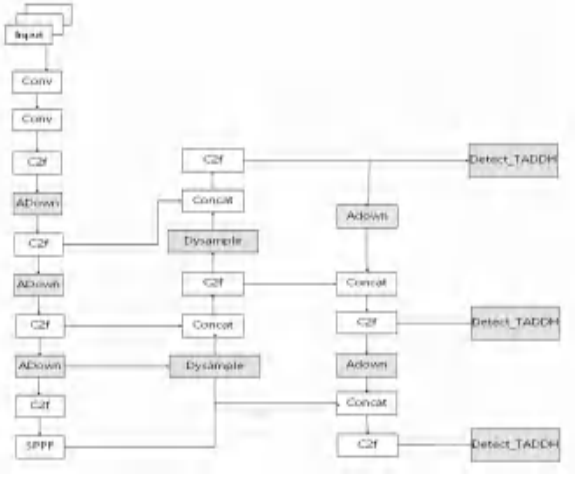


图 1 改进后 YOLOv8 结构图

Fig. 1 Structure diagram of improved YOLOv8

1.1 ADown 下采样卷积块

在深度学习模型中,下采样(downsampling)技术[18] 通过减少特征图的空间维度,帮助模型在更高层次上捕捉图像的特征,同时减少计算量。但往往会带来信息瓶颈[19] 问题。数据 X 在进行转换时可能会导致信息丢失,数学公式如下:

$$I(X,X) \geqslant I(X,\ f_\theta(X)) \geqslant I(X,g_\varphi(f_\theta(X))) \quad (1)$$

其中,I 表示互信息;f 和 g 表示变换函数;θ 和 φ 分别表示 f 和 g 的参数;在深度神经网络中,$f_\theta(\cdot)$ 和 $g_\varphi(\cdot)$ 分别表示深度神经网络中 2 个连续层的运算。从式(1)中可以预测,随着网络层数的增加,原始数据将更容易丢失。然而,深度神经网络的参数是基于网络的输出以及给定的目标,然后在生成新的梯度后通过计算损失函数来更新网络。可以想象,更深的神经网络的输出并不能够保留有关预测目标的完整信息。这就使得在网络训练期间利用不完整的信息成为可能,从而导致梯度不可靠和收敛性差。

当函数 r 具有逆变换函数 v 时，称该函数为可逆函数，定义公式如下：

$$X = v_\zeta(r_\varphi(X)) \tag{2}$$

其中，φ 和 ζ 分别表示 r 和 v 的参数。数据 X 由可逆函数转换而不会丢失信息，定义公式为：

$$I(X,X) = I(X,r_\varphi(X)) = I(X,v_\zeta(r_\varphi(X))) \tag{3}$$

当网络的变换函数由可逆函数组成时，可以获得更可靠的梯度来更新模型。虽然这样的设计可以使一千多层的深度神经网络收敛得非常好，但却破坏了研究选用深度神经网络的初衷之一。也就是说，对于难题，很难直接找到简单的 mapping 函数来将数据映射到目标。对于这个问题，使用信息瓶颈的概念来展开探讨。信息瓶颈的公式具体如下：

$$I(X,X) \geqslant I(Y,X) \geqslant I(Y,f_\theta(X)) \geqslant \cdots \geqslant I(Y,\hat{Y}) \tag{4}$$

一般来说，$I(Y,X)$ 信息只会占据 $I(X,X)$ 信息的极小部分。但是，却对目标任务至关重要。因此，即使前馈阶段丢失的信息量不显著，只要覆盖了 $I(Y,X)$ 信息，训练效果也会受到很大影响。为了解决上述问题，提出了一种新的辅助监督框架，称为可编程梯度信息（PGI），如图 2(d)所示。PGI 主要包括 3 个组成部分，即主支、辅助可逆支和多级辅助信息。从图 2(d) 中，PGI 的推理过程仅使用 main 分支，因此不需要任何额外的推理成本。至于其他 2 个组件，具体用于解决或减缓深度学习方法中的几个重要问题。其中，辅助可逆分支旨在应对由于网络加深造成信息瓶颈、使损失函数无法生成可靠梯度的问题。而多级辅助信息旨在处理多预测分支的架构和轻量级模型时深度监管带来的误差积累问题。

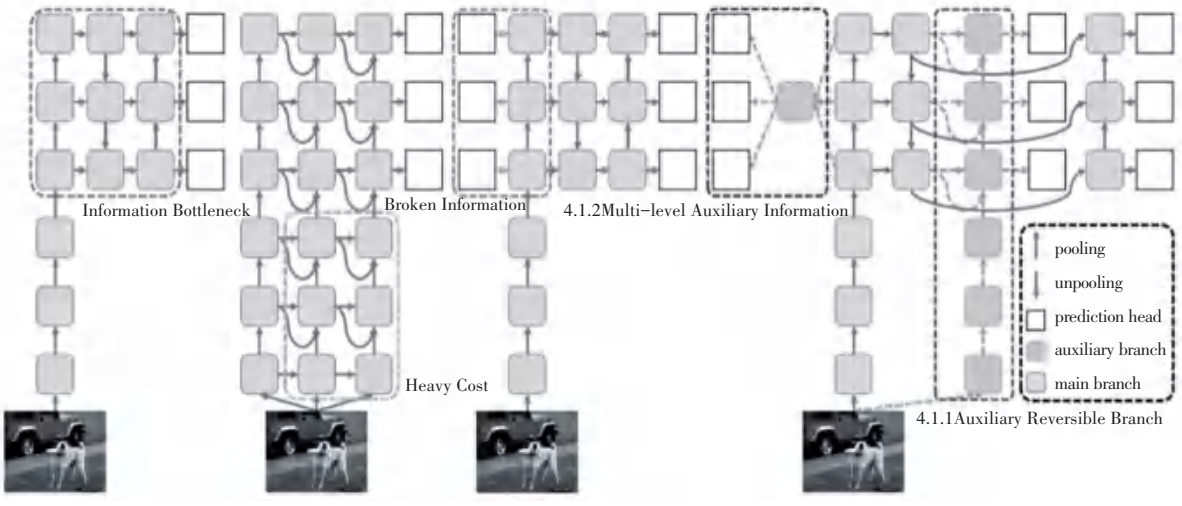


图 2　PGI 以及相关的网络架构和方法

Fig. 2　PGI and related network architectures and methods

通过这种设计，即使是轻量级和浅层的神经网络也可以实现有效的信息保留和准确的梯度更新。如图 2 中的深色方框展示的主分支，通过辅助可逆分支提供的可靠梯度信息，可以获得更有效的目标任务特征，而不会因为信息瓶颈而损失重要信息。ADown 下采样卷积块的结构如图 3 所示。

1.2　DySample 超轻量动态上采样器

动态采样（DySample）是一种高效的上采样[20]方法，广泛应用于密集预测任务如语义分割、目标检测、实例分割、全景分割和单目深度估计等。其设计目标是通过动态调整采样位置，提高上采样过程的灵活性和准确性，同时保持低计算成本和内存占用。DySample 通过学习输入特征图的动态偏移量，生成自适应的采样网格。这些偏移量决定了在上采样过程中每个输出像素的位置，从而实现对输入特征的精确对齐和重建。使用卷积层从输入特征图中提取高层次的语义信息，为生成动态采样网格提供必要的上下文信息。结合动态采样网格，DySample 通常采用双线性插值或其他高效的插值方法来计算输出特征。这确保了上采样后的特征图在空间上与输入特征图保持一致，同时保留更多的细节信息。图 4 展示了 Dysample 中基于采样的动态上采样和模块设计。图 4 涵盖了 2 个主要部分：

(1)基于采样的动态上采样（见图 4）。这部分展示了如何从输入特征(X) 通过采样点生成器创建采样集(S)，然后利用 grid sample 函数对输入特征进行重新采样，得到上采样特征(X')。

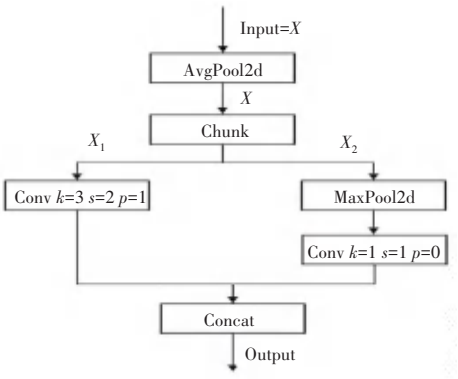


图 3 ADown 下采样卷积块结构图

Fig. 3 ADown subsampling convolution block structure diagram

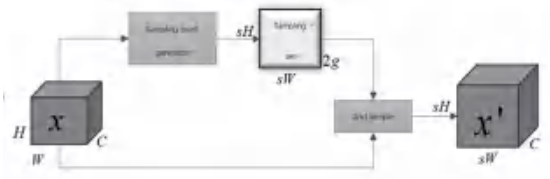


图 4 基于采样的动态上采样结构图

Fig. 4 Dynamic up-sampling structure diagram based on sampling

(2)Dysample 中的采样点生成器(见图 5)。详细描绘了生成采样点的 2 种方法:静态范围因子和动态范围因子。

其中,静态范围因子通过线性层和像素洗牌技术(pixel shufie)结合固定的范围因子来生成偏移量(0),然后与原始网格位置(G)相加得到采样集(S)。而动态范围因子除了线性层和像素洗牌,还引入了动态范围因子,首先生成一个范围因子,然后用其来调节偏移量(0)。这里的 σ 表示 Sigmoid 函数,用于生成范围因子。通过以上设计,DySample 不仅保留了最佳性能,而且摆脱了定制的 CUDA 包,并消耗最少的计算资源,在延迟、训练内存、训练时间、GFLOPs 和参数数量方面均表现出优越性。

1.3 动态检测头 TADDH

Detect_TADDH 是一种基于任务动态对齐思想的检测头(Task Dynamic Align Detection Head)。检测头结构如图 6 所示,研究中改进了传统目标检测器分类和定位分支相互独立的设计,通过引入任务交互特征学习,实现更紧密的任务协作。具体而言,Detect _ TADDH 通过共享卷积、动态卷积(DyDCNv2)和任务分解模块,提升检测器的性能,特别是在资源受限的场景中保持较低的计算开销。其中,共享卷积层(Shared Convolution Layers)由 2 层 Conv_GN 组构成,共享卷积的设计旨在减少模型的参数量和计算成本,并通过特征共享,确保特征提取过程中目标尺度之间的特征可以互相借鉴。通过减少参数量,模型更加轻量化,适合部署在资源受限的环境中。不仅大幅减少了参数量,并且通过保持不同检测层之间的特征共享,确保了各个检测层能够捕获到更全面的目标特征。任务分解模块中,2 个任务分解模块均由 Task Decomposition 组成,用于将共享的特征分解为各自任务特定的特征。然后又在分类分支和定位分支上,对共享特征进行任务分解,分别生成适用于分类任务和目标定位任务的特征。

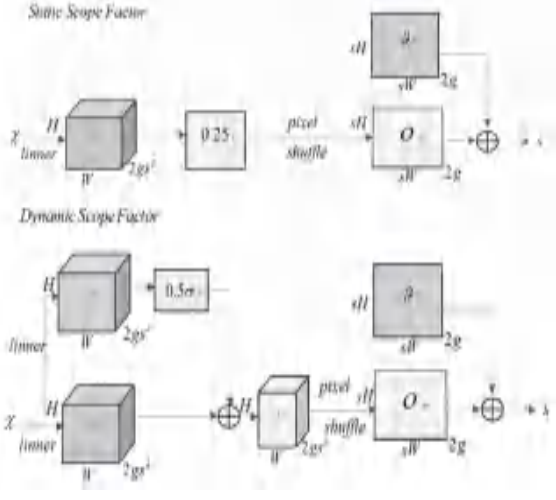


图 5 采样点生成器结构图

Fig. 5 Sample point generator structure diagram

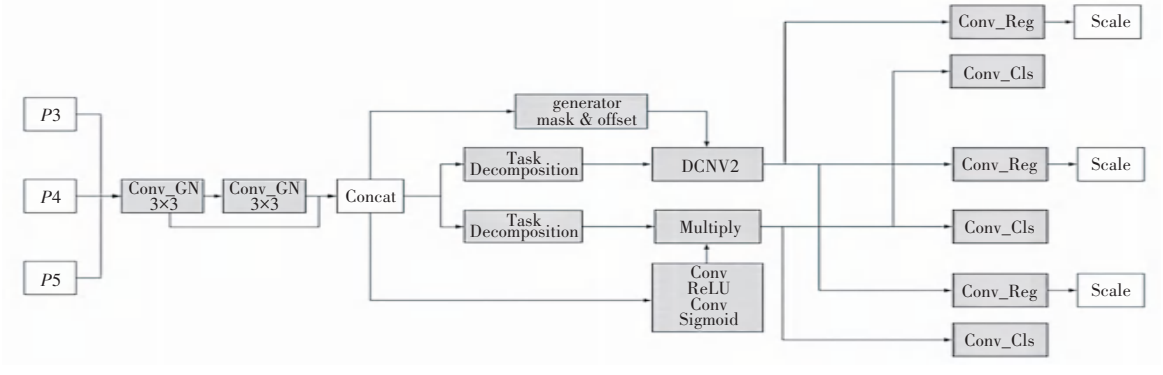


图 6 Detect_TADDH 检测头结构图

Fig. 6 Detect_TADDH detect header structure diagram

2　数据集处理

实验所使用的数据集来自于 Kaggle 网站，共包含 6 000 多张图像，这些图像被平均分为 4 个类别：白叶枯病（Bacterial blight）、稻瘟病（Rice Blast）、褐斑病（Brown Spot）、东格鲁病毒病（Rice tungro spherical virus），相关病害如图 7 所示。

为了进一步地检测水稻病害，使用 LabelImg 软件对相关病虫害图像进行手工标注，添加相应的检测框。相关标注示意图如图 8 所示。



（a）白叶枯病　（b）稻瘟病　（c）褐斑病　（d）东格鲁病毒病

图 7　水稻病害图

Fig. 7　Rice diseases map

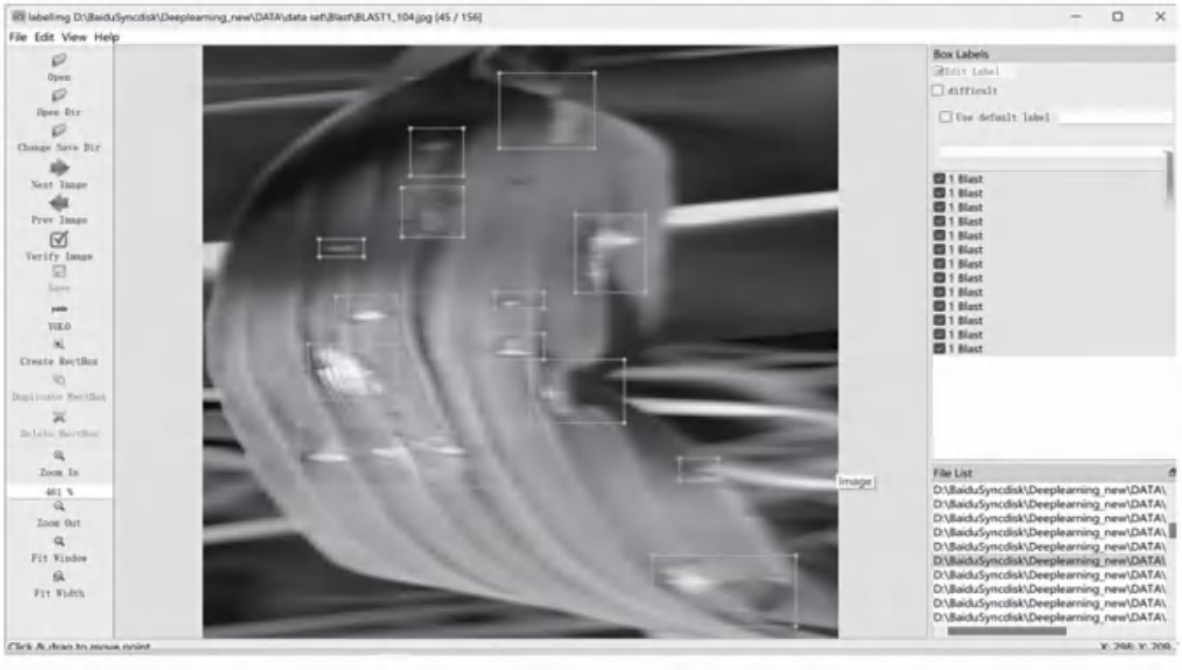


图 8　标注过程图

Fig. 8　Annotation process diagram

标注完成以后，根据 8∶1∶1 的比例将数据集分为训练集、验证集和测试集，为后续实验做好数据准备。

3　实验结果与分析

3.1　实验环境及参数设置

此次实验在 Windows 10 操作系统下进行，使用了基于 PyTorch 1.12.0 框架的深度学习环境，搭建了 YOLOv8 的模型架构。实验环境配置了 CUDA 11.3 和 Python 3.9。在硬件方面，选择了配备 8 GB 显存的 RTX 4060 显卡，以及主频为 3.80 GHz 的 AMD Ryzen 7 8845H 处理器。模型配置 2 个并行工作进程，以加速训练过程。整个训练过程进行 300 个周期，每个周期处理的数据批次大小为 16 张图像。输入到模型中的图像分辨率统一设定为 640×640。

3.2　评价指标

为了客观评价改进后的算法在水稻病害检测中的检测能力，选取平均准确率[21]（Average Precision，AP）和类别均值平均准确率[22]（mean Average Precision，mAP）作为检测精度评价指标。评价指标的计算公式如下：

$$P = \frac{TP}{TP + FP} \tag{5}$$

$$R = \frac{TP}{TP + FN} \tag{6}$$

$$AP = \int_0^1 P(r)\,dr \tag{7}$$

$$mAP = \frac{1}{N}\sum_{i=0}^{n} AP_i \tag{8}$$

其中,TP 表示被正确地识别出病害为正例的样本数量;FN 表示被错误地分类为负例的样本数量;FP 表示被错误地分类为正例的样本数量;AP 表示对单个类别标签的平均精确率的度量;mAP 表示 AP 的平均值。选取参数量(Params)、计算量(FLOPs)作为轻量化评价指标。定义公式分别如下:

$$Params = \sum_{l=1}^{L} Num(l) \tag{9}$$

$$FLOPs = 2 \times \sum Mul(l) \tag{10}$$

其中,L 表示模型的层数;Num 表示参数量;Mul 表示乘加操作。参数量衡量的是模型中所有可训练参数的总数。模型的参数量越少,表明模型越轻量化,计算资源消耗越少。计算量是衡量模型复杂度的另一个重要指标,表示模型执行的浮点运算次数。可以表示为每层网络的乘加运算(Multiply-Accumulate Operations,MACs)总和。FLOPs 越少,模型的计算量越小,推理速度通常也越快。研究中 AP、mAP 作为检测精度的指标,Parmars 和 FLOPs 作为轻量化的指标,就可以全面评价改进后算法的性能。

3.3 消融实验

为了验证各个改进结构的有效性,进行了一系列消融实验,并采用相同的训练环境和参数,实验结果见表 1。

表 1 的消融实验表明,在实验条件不变的情况下,通过对 YOLOv8n 模型逐渐引入 ADown、DySample、TADDH 等改进机制,可以有效提升模型检测精度,并降低一定参数和计算量。其中,应用了所有改进方案的模型 8 相比基线模型 YOLOv8n,mAP@0.5 提升了 2.5%,参数量减少了 40%,计算量减少了 5%,在所有的改进方案中表现最为突出,表明改进后的算法不仅实现了轻量化,性能也得到了显著提升。

表 1 消融实验

Table 1 Ablation experiment

Groups	YOLOv8n	YOLOv8n_ADown	YOLOv8n DySample	YOLOv8n TADDH	mAP/%	Params/M	FLOPs/G
1	√				0.881	3.01	8.2
2	√	√			0.892	2.60	7.4
3	√		√		0.887	3.00	8.1
4	√			√	0.893	2.20	8.6
5	√	√	√		0.896	2.60	7.4
6	√		√	√	0.903	2.20	8.6
7	√	√		√	0.901	1.80	7.8
8	√	√	√	√	0.906	1.80	7.8

3.4 对比实验

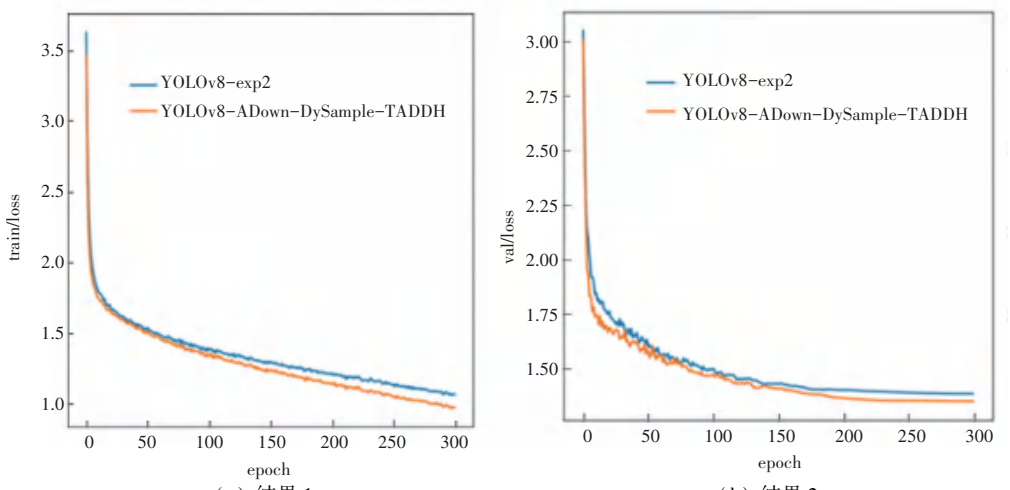
3.4.1 训练损失对比

为了验证改进后的 YOLOv8n 算法性能得到提升,使用改进后的 YOLOv8n 训练水稻病害数据集,得到训练与验证的损失图像,将相关损失图像与 YOLOv8n 模型的损失图像对比,得到对比结果如图 9 所示。图 9 表明,在相同训练周期下,改进后的模型表现出较低损失值,说明网络训练效率相比基线模型得到了提升,训练结果更好。

3.4.2 模型对比

为了验证改进后 YOLOv8n 的效果,选取 RT-DETR、YOLOv6、YOLOv7-tiny 等检测算法进行对比实验,对水稻病害数据集中的 4 类病害图像进行测试,结果见表 2。由表 2 可知,改进后的模型无论是在总体检测精度上、还是单独类别的检测精度上都优于 RT-DETR、YOLOv6、YOLOv7-tiny 等主流模型。进一步观察结果可以发现,无论是检测精度、还是召回率方面,改进后的模型相比 YOLOv8n 原模型都有提高。其中,Brown Spot 类别(一些较小的病害目标)的提升效果最为显著,Tungro 类别(一些较大的病害目标)的提升较不明显。之所以会出现这种情况,是因为实验所采用的改进方案对于小目标检

测更有优势，例如，Adown 模块的设计注重保留尽可能多的图像信息，这对于小目标检测尤为重要，因为小目标在图像中占据的空间较小，容易在下采样过程中丢失重要信息。因此，Adown 模块有助于改善小目标检测的性能。而且相比其他模型，改进后的模型在参数量及计算量上都更轻量，满足了在移动设备上部署检测的需要。



（a）结果 1　　（b）结果 2

图 9　损失对比图

Fig. 9　Loss comparison chart

表 2　对比实验

Table 2　Comparative experiments

Model	Bacterial blight	Blast	Brown Spot	Tungro	mAP/%	Params/M	Flops/G
YOLOv3-tiny	0.791	0.855	0.857	0.913	0.854	12.1	19.0
YOLOv8	0.889	0.860	0.860	0.915	0.881	3.0	8.2
YOLOv6	0.867	0.857	0.866	0.898	0.872	4.2	11.8
YOLOv7-tiny	0.835	0.866	0.847	0.888	0.859	6.0	13.2
RT-DETR	0.849	0.851	0.842	0.889	0.858	28.0	100.6
本文模型	0.915	0.887	0.897	0.924	0.906	1.8	7.8

4　结束语

为了对水稻病害进行准确的检测识别，本文提出了一种基于轻量化 YOLOv8n 的水稻病害检测模型。采用 Adown 卷积模块替换原来的 CBS 模块，通过减少特征图的空间维度（即下采样），降低计算复杂度并增强网络的感知野。颈部网络上采样层面，使用 DySample 结构，提高特征提取的灵活性和精度。最后，引入 Detect_TADDH 动态检测头，通过使用共享卷积，大幅减少参数数量，使得模型更轻便。经过这些改进，模型在水稻病害数据集上的检测精度提高到 90.6%，参数量降低了 40%，更好地满足了农业检测的需要。后续将进一步研究如何将模型应用到移动设备和嵌入式设备上，以进一步助力农业生产。

参考文献

[1] 汪俊. 水稻主要病虫害及其防治措施[J]. 耕作与栽培，2024，44(5)：131-133.

[2] ZHANG Kefei，WANG Teng，YANG Xiaolin，et al. STATNet：One-stage coal-gangue detector based on deep learning algorithm for real industrial application[J]. Energy and AI，2024，17：100388.

[3] JADYN A，MAKAR D，W C F，et al. Two-stage cryogenic HEMT-based amplifier for low-temperature detectors[J]. Journal of Low Temperature Physics，2024，214(3-4)：256-262.

[4] YANG W，JIANG M，FANG X，et al. A high-precision and efficient method for badminton action detection in sports using you only look once with hourglass network[J]. Engineering Applications of Artificial Intelligence，2024，137：109177.

[5] QIAN W，ZHU Z，ZHU C，et al. Efficient deployment of Single Shot Multibox Detector network on FPGAs[J]. Integration，2024，99：102255.

[6] 何兆蓉，郭健，徐琦，等. 基于改进 Mask R-CNN 的非结构环境小目标语义分割算法[J]. 电子技术应用，2024，50(10)：76-81.

[7] 朱克佳. 基于深度学习的目标检测研究[J]. 现代信息科技, 2024,8(13):76-83.
[8] YIN Jie, HUANG Peng, XIAO Dong, et al. A lightweight rice pest detection algorithm using improved attention mechanism and YOLOv8[J]. Agriculture,2024,14(7):1052.
[9] PAVITHRA T P, BARANIDHARAN B. OSPS-MICRONET: A distilled knowledge micro-CNN network for detecting rice diseases [J]. Frontiers in Computer Science,2024,6:1279810.
[10] YANG Hui, LIN Dan, ZHANG Guo, et al. Research on detection of rice pests and diseases based on improved Yolov5 algorithm[J]. Applied Sciences, 2023,13(18):10188.
[11] ALI S A, AJABNOOR N, KHALID W E, et al. Lesion-aware visual transformer network for paddy diseases detection in precision agriculture[J]. IEEE Access, 2023,11:79707-79720.
[12] 王圆圆, 林建, 王姗. 基于 YOLOv4-tiny 模型的水稻早期病害识别方法[J]. 江苏农业科学,2023,51(16):147-154.
[13] 丁士宁. 基于 ResNet50 的水稻病虫害识别[J]. 现代信息科技,2024,8(16):127-130.
[14] VARGHESE R S M. YOLOv8: A novel object detection algorithm with enhanced performance and robustness [C]// Proceedings of 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). Piscataway,NJ:IEEE, 2024:1-6.
[15] 戴林华, 黎远松, 石睿. 基于改进 YOLOv8n 算法的水稻叶片病害检测[J]. 湖北民族大学学报(自然科学版),2024,42(3):382-388.
[16] XIE Danyan, YAO Wenyi, SUN Wenbo, et al. Real-time identification of strawberry pests and diseases using an improved YOLOv8 algorithm[J]. Symmetry,2024,16(10):1280.
[17] 张进军. PyTorch 框架下的复杂场景目标识别方法研究[J]. 现代计算机,2024,30(8):66-71.
[18] 王明, 邓志良, 严飞, 等. 基于下采样优化的点云配准方法[J]. 应用激光,2024,44(5):201-207.
[19] 孙一文. 基于信息瓶颈的强化学习泛化性问题研究[D]. 天津:天津大学,2022.
[20] 刘依林. 基于深度学习的点云上采样算法研究[D]. 北京:北京邮电大学,2023.
[21] 郑果. 基于机器视觉的水稻病虫害监测预警技术研究[D]. 重庆:重庆三峡学院,2023.
[22] 刘涛, 仲晓春, 孙成明, 等. 基于计算机视觉的水稻叶部病害识别研究[J]. 中国农业科学,2014,47(4):664-674.