

尹利华,崔艳荣,曾龙军. 基于改进 YOLO v8 轻量化小麦病害检测方法研究[J]. 江苏农业科学,2025,53(20):279-287.

doi:10.15889/j.issn.1002-1302.2025.20.031

# 基于改进 YOLO v8 轻量化小麦病害检测方法研究

尹利华,崔艳荣,曾龙军

(长江大学计算机科学学院,湖北荆州 434000)

**摘要:**随着全球气候的不断变化和农业生产模式的持续调整,小麦病害的危害程度变得越来越复杂且多变。尽管深度学习技术在小麦病害检测领域已经展现出了良好的性能,但在面对复杂多变的实际种植环境时,其识别效果仍然存在一定的局限性。为了应对这一挑战,提出一种基于改进 YOLO v8n 的轻量化小麦病害检测方法,旨在提高在真实环境中对小麦病害的检测能力。该方法通过在 YOLO v8n 主干网络中引入 ODConv,增强模型对小麦病害特征的提取能力,以提高模型性能和精确度。此外,在颈部网络中引入 BiFPN 特征融合网络,减少复杂背景的影响,BiFPN 采用加权的特征融合机制,在训练过程中自动调节权重,以优化特征融合的效果获取更有价值的信息。最后,在颈部网络引入带 GSConv 的 Slim-Neck,以减少模型的参数量和计算量,使网络模型达到轻量化的效果,同时能保持模型的精度。结果表明,改进后的 OBS-YOLO v8 网络模型精确率为 91.3%,召回率为 71.3%, $mAP@0.5$  为 77.3%,相对于原模型分别提高 5.2、1.3、2.2 个百分点;其中参数量仅为 2.8 M,同比下降 10%,计算量仅为 6.6 G,同比下降 26%,不仅在可部署的移动设备上使用小麦病害检测系统奠定了坚实的基础,还为在实际农业生产环境中高效、准确地检测小麦病害提供了一种切实可行的解决方案。期待这一研究成果能够推动农业智能化、信息化的发展进程,为构建现代农业产业体系、实现乡村振兴贡献力量。

**关键词:**小麦病害检测;YOLO v8n;深度学习;轻量化;ODConv;BiFPN;Slim-Neck

**中图分类号:**S126;TP391.41 **文献标志码:**A **文章编号:**1002-1302(2025)20-0279-09

在农业生产的广阔天地中,小麦作为世界上最重要的粮食作物之一,其产量与品质直接关系到全球粮食安全和亿万人民的生计<sup>[1]</sup>。然而,小麦种植过程中面临着诸多挑战,其中病害问题尤为突出。小麦病害不仅会导致作物生长受阻、产量下降,严重时甚至可能引发绝收,给农业生产带来巨大损

失。因此,如何高效、准确地识别并防控小麦病害,成为农业科学研究与实践中的亟待解决的关键问题。

随着计算机视觉与深度学习技术的飞速发展,目标检测技术在作物检测领域展现出了巨大的应用潜力。胡国玉等提出一种基于 Swin Transformer 的葡萄病害检测模型 Swin-TDL,平均精度为 92.7%<sup>[2]</sup>。刘笑意等提出基于改进 YOLO v5 的苹果叶病害识别算法,可部署于移动端,为苹果病害早期诊断提供指导<sup>[3]</sup>。Kasana 等提出一种用于马铃薯病害早期检测的基于注意力的轻量级深度学习模型,利用迁移学习结合注意力模块和空间注意力模块,通过关注图像特定的部分,实现对马铃薯

收稿日期:2024-11-02

基金项目:国家自然科学基金面上项目(编号:62077018)。

作者简介:尹利华(2000—),男,湖南永州人,硕士研究生,研究方向

为深度学习与目标检测。E-mail:2023720829@yangtzeu.edu.cn。

通信作者:崔艳荣,博士,教授,主要从事网络安全、信息处理研究。

E-mail:cyanr@yangtzeu.edu.cn。

and Pattern Recognition (CVPR). Honolulu:IEEE,2017:936-944.

[18] Liu S, Qi L, Qin H F, et al. Path aggregation network for instance segmentation [C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City:IEEE,2018:8759-8768.

[19] Jiang Y Q, Tan Z Y, Wang J Y, et al. Giraffedet: a heavy-neck paradigm for object detection [J]. arXiv preprint, arXiv:2202.04256. <https://arxiv.org/abs/2202.04256>.

[20] Xu X Z, Jiang Y Q, Chen W H, et al. Damo-yolo: a report on real-time object detection design [EB/OL]. arXiv preprint, arXiv:2211.15444,2022. [2024-10-12]. <https://arxiv.org/abs/2211.15444>.

[21] Zhang K, Wu Y L, Wang J Y, et al. Semantic context-aware network for multiscale object detection in remote sensing images [J]. IEEE Geoscience and Remote Sensing Letters,2021,19:8009705.

[22] Zheng Z H, Wang P, Ren D W, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation [J]. IEEE Transactions on Cybernetics,2022,52(8):8574-8586.

[23] Zhang H, Zhang S J. Shape-IoU: more accurate metric considering bounding box shape and scale [EB/OL]. arXiv preprint, arXiv:2312.17663,2023. [2024-10-12]. <https://arxiv.org/abs/2312.17663>.

病害的早期检测<sup>[4]</sup>。王浩宇等提出一种苹果叶片病害识别模型 EGV2 - CA, 采用 Ghost Module 的 original 分支作为首层卷积层, 引入 CA 注意力机制实现对苹果叶片的病害识别, 准确率达 87.06%<sup>[5]</sup>。以上研究都展现了深度学习技术在农业上的应用。

深度学习技术在小麦病害检测上也有应用, 小麦病害目标检测技术利用深度学习算法, 特别是卷积神经网络等模型, 对小麦叶片、茎秆等部位的图像进行分析与处理, 自动提取病害特征, 并与预设的病害数据库进行比对, 从而实现对小麦条锈病、赤霉病、白粉病等常见及新发病害的精准识别<sup>[6]</sup>。李震等提出一种基于 YOLO v7 - tiny 的轻量化模型, 在主干网络中采用 ELAN 替代 E - ELAN, 颈部网络中采用 PANet 进行特征聚合, 在检测头部分采用普通卷积替换原模型的 REPCov, 实现对小麦不同生长部位的白粉病害检测, 精确率达 83.8%<sup>[7]</sup>。沈广辉等利用高光谱成像结合特征波长实现对小麦赤霉病瘿粒识别, 虽然有着较高的正确率, 但是高光谱仪器昂贵沉重难以在实际生产环境中使用<sup>[8]</sup>。Mao 等提出了一种基于多样化增强特征和边缘特征的小麦病害检测模型, 提高了模型特征提取的能力, 实现田间小麦病害的实时检测<sup>[9]</sup>。时雷等提出一种基于改进 YOLO v8s 的小麦赤霉病识别方法, 改进后模型比原模型提高 2 个百分点, 能有效实现小麦赤霉病精准检测, 但模型所能检测的小麦病害种类不多<sup>[10]</sup>。Jouini 等提出一种基于浅层 CNN 特征细化的轻量级小麦叶片病害检测方法, 采用冻结预训练模型以进行特征提取, 并添加自定义的 CNN 层, 集成了可训练的 CNN 实现对小麦病害的检测<sup>[11]</sup>。

然而, 现如今的深度学习模型仍面临一些挑战, 复杂背景的干扰以及叶片遮挡等, 模型的检测速度以及模型大小对于实际的场景构成了限制, 在真实的大田环境下还是难以实现一定精度的检测。鉴于此, 本研究聚焦小麦病害目标检测技术的探索与应用, 旨在通过构建高效、鲁棒的深度学习模型, 提出一种基于改进 YOLO v8 轻量化小麦病害检测算法, 实现在复杂环境下对小麦常见病害(如锈病、叶枯病、白粉病等)的精准识别与定位。在提高模型检测精度的同时将模型达到轻量化的效果。本研究主要包括以下方面:(1)引入 ODConv 卷积在主干网络中使用, 增强模型对小麦病害的特征提取能力和捕获上下文信息能力。(2)引入 BiFPN 特征融合网络, 该模块能有效融合不同尺度的特征信息,

获取更多有价值的信息, 提高模型对小麦病害的检测精度。(3)引入带 GSConv 的 Slim - Neck, 有效降低了模型的参数量和网络复杂性。改进后模型不仅有着较小的模型内存, 还有着较高的精确率, 方便部署于移动端检测小麦病害。

## 1 材料与方法

### 1.1 数据集来源

本试验所使用的小麦病害数据集来自于 Roboflow 平台的 classification of disease computer vision project 公开数据集, 数据集中包含 4 种常见小麦病害: 小麦叶枯病、小麦黄锈病、小麦白粉病、小麦茎锈病。一共包含 2 687 张真实环境下的小麦病害图片, 部分数据样例如图 1 所示。为了让模型接触足够的样本数据, 保留数据集中的验证集和测试集。将数据集按 6 : 3 : 1 的比例分配为训练集、验证集和测试集。为了确保数据集的充足性和多样性, 本研究采用 Mosaic 在线数据增强技术。这种技术能够在训练过程中实时地对图像数据进行增强处理, 通过组合多张图像来生成新的训练样本, 从而有效地增加训练数据的数量和丰富性, 有助于提高模型的泛化能力和性能。

### 1.2 OBS - YOLO v8 网络模型构建

1.2.1 YOLO v8 网络模型 YOLO v8 是 Ultralytics 公司于 2023 年推出的 YOLO 产品<sup>[12]</sup>。YOLO v8 在之前成功的 YOLO 系列版本基础上, 引入了新的骨干网络架构、无锚框检测头、解耦头等先进技术, 以进一步提高模型性能和灵活性<sup>[13-17]</sup>。YOLO v8 包含 n、s、m、l 和 x 等 5 个模型类别, 模型尺寸和参数量依次提升; 其中 YOLO v8n 最快、最小, YOLO v8x 最准确、最慢。综合性能以及模型体积大小考虑, 本研究采用 YOLO v8n 作为基础网络模型, YOLO v8n 包含 3 个部分: 主干网络、颈部网络和检测头。

主干网络是由 CBS 模块、C2f 模块、SPPF 模块构成, CBS 模块用于对输入图像或特征图进行卷积操作, 通过卷积降低分辨率并增加通道数, 同时利用批归一化和 SILU 激活函数增强模型的稳定性和非线性特性。C2f 是 YOLO v8 中用于深度特征提取的模块, 通过 2 个不同大小的卷积核(1 × 1 和 3 × 3)来替代传统的单一卷积核, 从而增加感受野并减少计算量, C2f 模块的设计有助于增强梯度流动, 提高模型性能。SPPF 模块用于进行空间金字塔池化操作, 可以将不同尺度的特征图拼接起来, 从而提

高模型对不同尺寸目标的检测能力。

颈部网络由特征金字塔 FPN 和路径聚合网络

PAN 设计为 PANet 结构,采用上下文特征信息多尺度的融合,提升网络对目标的感受能力。



图1 部分小麦病害图像示例

检测头采用了解耦设计,将分类和边界框回归 2 个任务分别处理,有助于提升模型在复杂场景下

的检测性能;同时还采用了新的无锚点检测方式。YOLO v8n 网络模型如图 2 所示。

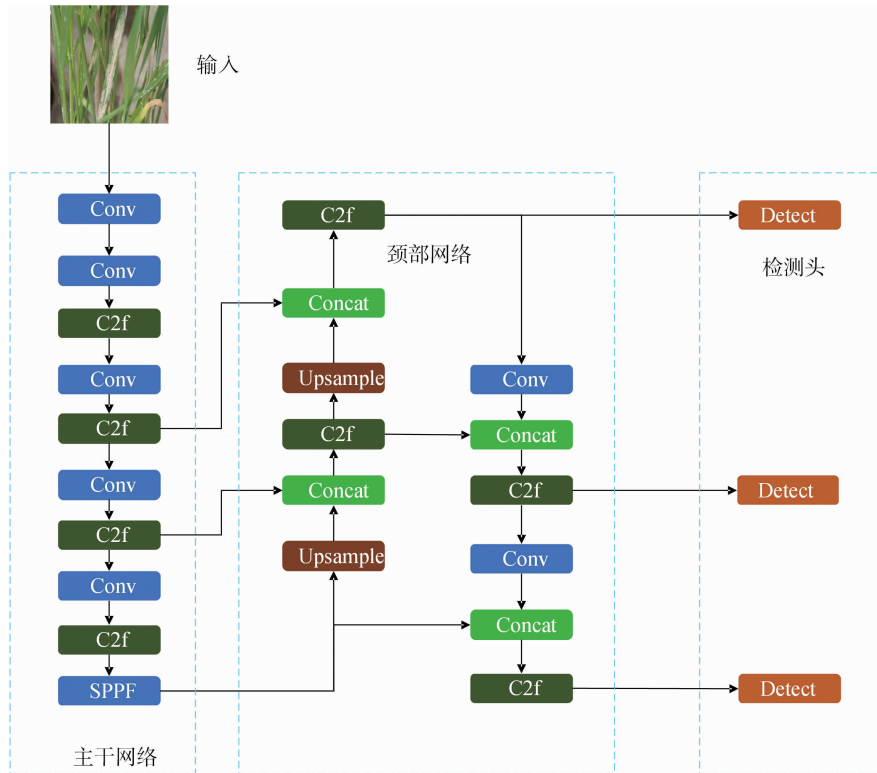


图2 YOLO v8n 网络模型

1.2.2 OBS - YOLO v8 网络模型构建 为有效提高小麦病害检测的精度以及方便部署移动端使用,本研究对 YOLO v8n 的网络结构进行创新改进,构建了 OBS - YOLO v8 网络模型。OBS - YOLO v8 网

络模型结构图如图 3 所示。本研究在 YOLO v8n 模型的基础上进行了多项关键性改进以提升其性能并实现轻量化。具体而言,本研究采取了以下措施: 为了显著增强模型对小麦病害的特征提取能

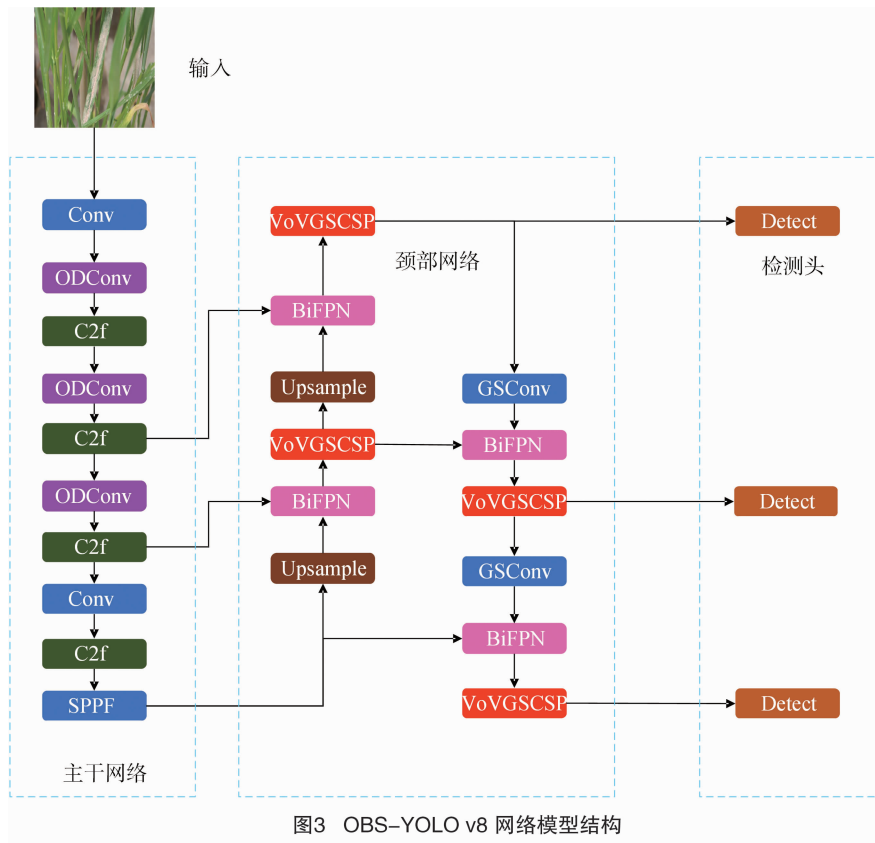


图3 OBS-YOLO v8 网络模型结构

力和上下文信息捕获能力,本研究对 YOLO v8n 的主干网络进行了部分优化,将标准卷积创新为 ODConv 卷积。这一改进不仅带来了模型对小麦病害检测精准率的显著提升,还进一步优化了卷积运算的效果。

在颈部网络部分中,本研究引入了 BiFPN 加权双特征金字塔网络。该网络通过独特的加权特征融合机制,对特征融合效果进行了显著优化。它利用学习到的特征不断更新权重,从而能够更有效地提取和融合有价值的信息,进一步提高模型的性能。

为了实现模型的轻量化,本研究引入了带有 GSConv 的 Slim-Neck 结构。这一结构在降低模型计算量和简化网络结构复杂性的同时,保持了模型的一定精度。通过这一改进,本研究成功地在保持模型性能的同时,实现了轻量化的目标。

以下将分为几个小节,逐步且详细地讲解本研究针对 YOLO v8n 模型所采用的改进方法。

1.2.3 引入 ODConv 卷积 在传统的卷积神经网络中,卷积层的卷积核的大小以及个数是固定的。全维度动态卷积方法在多维上实现了卷积核的动态性,从而使卷积神经网络的性能得到了提高。ODConv 是一种关注了空域、输入通道和输出通道

等维度上的动态性的卷积方法<sup>[18]</sup>。ODConv 引入了采用并行策略的多注意机制,可以沿核空间的 4 个维度学习卷积核的不同注意,通过对卷积核进行线性加权,并根据输入数据的不同动态调整卷积核的权重,能够增强模型对小麦病害特征的提取能力,以提升模型的性能以及精确率。ODConv 卷积公式如下:

$$y = (\delta_{a1} \odot \delta_{b1} \odot \delta_{c1} \odot \delta_{d1} \odot w_1 + \dots + \delta_{an} \odot \delta_{bn} \odot \delta_{cn} \odot \delta_{dn} \odot w_n) * x \quad (1)$$

式中:  $x \in \mathbf{R}^{h \times w \times c_{in}}$  和  $y \in \mathbf{R}^{h \times w \times c_{out}}$  分别代表输入特征和输出特征(具有高度  $h$  和宽度  $w$  的  $c_{in}, c_{out}$  通道);  $w_i$  表示由  $c_{out}$  个滤波器组成的第  $i$  个卷积核;  $\delta_{ai} \in \mathbf{R}^{k \times k}$  表示沿着卷积核  $w_i$  核空间注意标量,  $\delta_{bi} \in \mathbf{R}^{c_{in}}$  表示沿着卷积核  $w_i$  输入通道维数注意标量,  $\delta_{ci} \in \mathbf{R}^{c_{out}}$  表示沿着卷积核  $w_i$  输出通道维数注意标量,  $\delta_{di} \in \mathbf{R}$  表示沿着卷积核的注意标量,  $\odot$  表示沿着卷积核空间的不同维度的乘法运算;  $*$  是卷积运算。ODConv 卷积结构图如图 4 所示。

图 5 展示了这 4 类注意标量作用于卷积核上的过程,以位置、通道、滤波器和卷积核权重依次乘以卷积核  $w_i$ ,通过这种方式将 4 种类型的注意标量考虑进来。ODConv 模块能够显著增强 CNN 卷积运算

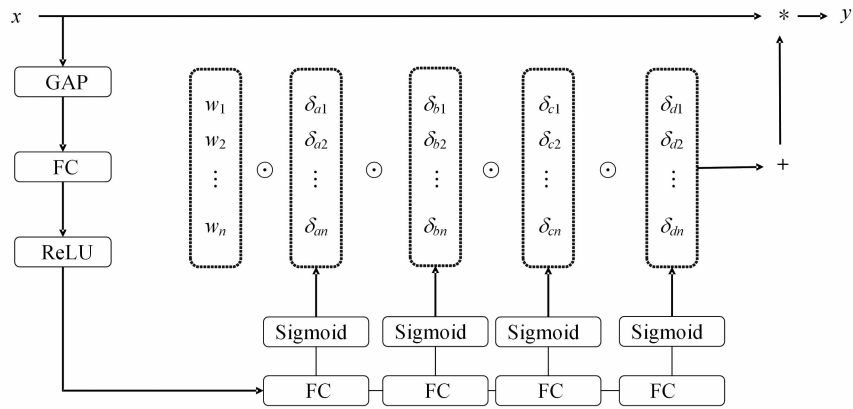


图4 ODCnv 卷积结构

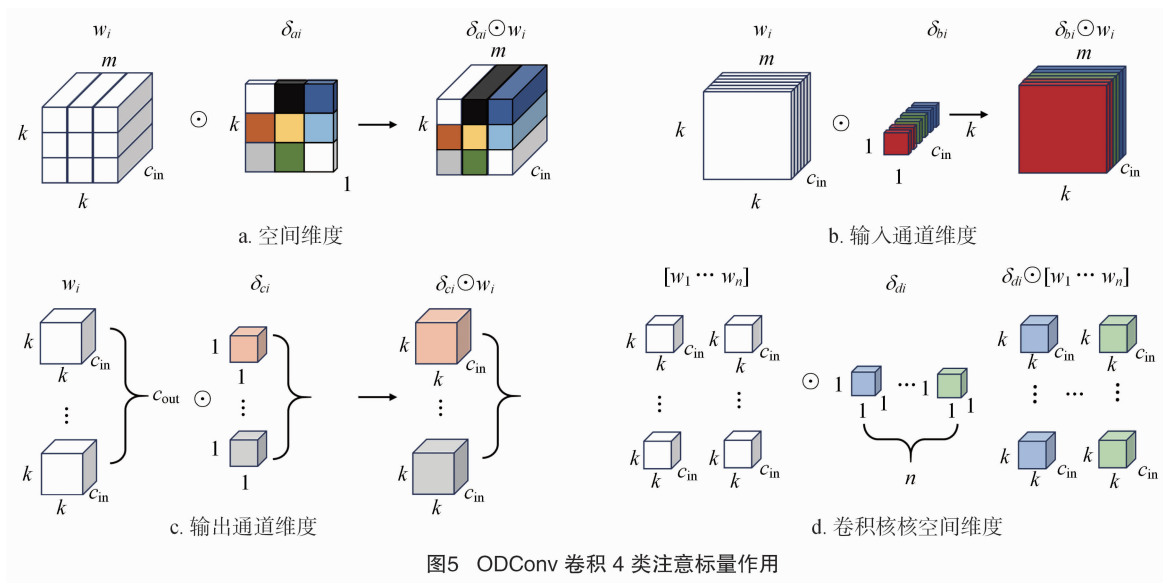


图5 ODCnv 卷积 4 类注意标量作用

的特征提取能力,捕获丰富的上下文信息。

1.2.4 引入 BiFPN 特征融合网络 在 YOLO v8 原网络模型中,颈部网络采用特征金字塔 FPN 和路径聚合网络 PAN 为 PANet 结构设计。PANet 结构设计独特,包含了自顶向下和自底向上 2 种信息流路径。这种设计巧妙地促进了底层细节特征与顶层全局特征之间的深度融合与交互,从而增强了模型对图像信息的全面理解和利用能力。虽然这种方法能提高模型的检测精准度,但部分小麦病害特征存在表现微小且不易发现的情况,很容易遗漏微小目标物体。为此,本研究将采用 BiFPN 特征融合网络进一步提高对小目标检测的准确性<sup>[19]</sup>。加权双向特征金字塔网络 BiFPN 是对 PANet 的一种优化和升级。它摒弃了 PANet 中可能导致重要信息丢失的单一输入节点设计,从而简化了网络结构并确保了信息的完整性。更为先进的是,当输入节点

与输出节点处于同一层级时,BiFPN 会巧妙地在这 2 个节点间增设额外的连接边。这样的设计能够在不大幅增加计算成本的前提下,实现更多特征的融合,进而提升模型的特征提取与表达能力。PANet 和 BiFPN 结构如图 6 所示。

网络模型在特征融合的过程中,由于输入特征有着不同的分辨率,导致网络模型对输出特征不统一,BiFPN 还采用加权的特征融合机制,在路径上分配合理的权重,训练过程中自动调整,以优化特征融合的效果,从而提高特征表示的准确性,以获得更有价值的信息。减少因小麦病害特征尺寸过大导致漏检错检。输入特征和输出特征的关系式(2)为:

$$o = \sum_i \frac{\omega_i}{\varepsilon + \sum_j \omega_j} \cdot I_i \quad (2)$$

式中:  $I_i$  为输入特征;  $o$  为输出特征;  $\omega_i$  为输入特征




图6 PANet 和 BiFPN 结构

对应的权重。设置  $\epsilon$  为 0.000 1,防止数值出现不稳定的情况。经式(2)使归一化权重的值放缩在 0 到 1 之间。

1.2.5 引入带 GSConv 的 Slim - Neck Li 等提出一种新的方法,使用 GSConv 卷积来减轻模型的复杂度并保持精度<sup>[20]</sup>。Slim - Neck 通过引入轻量级卷积技术 GSConv 来实现在维持精度的同时减轻模型的复杂度。在卷积神经网络进行图像特征融合的过程中,空间压缩和通道扩展的传统操作往往伴随着语义信息的损失。然而,GSConv 通过整合深度可分离卷积 DSC 的优势,并致力于使卷积的输出尽可能接近标准卷积 SC 的效果,成功地在减少语义信息丢失的同时,降低了计算成本并提升了处理速度。这种设计不仅优化了特征融合过程,还确保了网络性能的稳定性和高效性。在颈部网络部分,

GSConv 利用通道混淆的方法对连接的特征图进行融合,以此生成足够修长的特征图。这种融合方式使特征图的通道维度显著增加至最大值,而宽度和高度维度则相应地缩减至最小值。这种设计优化了特征图的形态,使得后续的小麦病害特征转换更加适宜和高效。GSConv 通过减少冗余信息并适度压缩非关键的重要信息,来有效地降低计算复杂性。GSConv 卷积结构如图 7 所示。Slim - Neck 是一种用于目标检测器架构的设计范式,适用于网络模型的颈部网络部分减少了计算成本并提高了性能,其使用了一次性聚合方法来设计跨级部分网络 GSCSP 模块 VoV - GSCSP。VoV - GSCSP 模块降低了计算量和网络模型结构的复杂性,但还保持了足够的精度。VoV - GSCSP 模块结构图如图 8 所示。

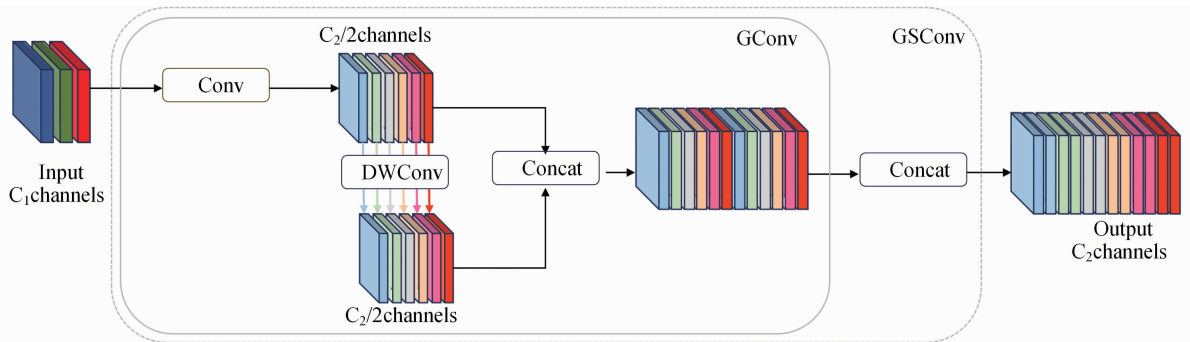


图7 GSConv 卷积结构

### 1.3 试验平台与评价指标

1.3.1 试验平台 本研究试验所用的操作系统是 Ubuntu 22.04 系统, GPU 为 24 G 显存 NVIDIA GeForce RTX 4090, CPU 型号为 Xeon® Platinum 8352V 16 核,使用 Python 3.10.13 和 PyTorch 2.1.2 深度学习框架,试验模型训练参数如表 1 所示。试验时间为 2024 年 6—10 月,试验地点为长江大学计

算机科学学院。

1.3.2 评价指标 为评估模型的有效性,本研究采用精确率、召回率、 $mAP@0.5$ 、模型的数量以及计算量作为模型性能的评价指标。精确率、召回率、 $mAP$  计算公式如下所示:

$$P = \frac{TP}{TP + FP}; \tag{3}$$

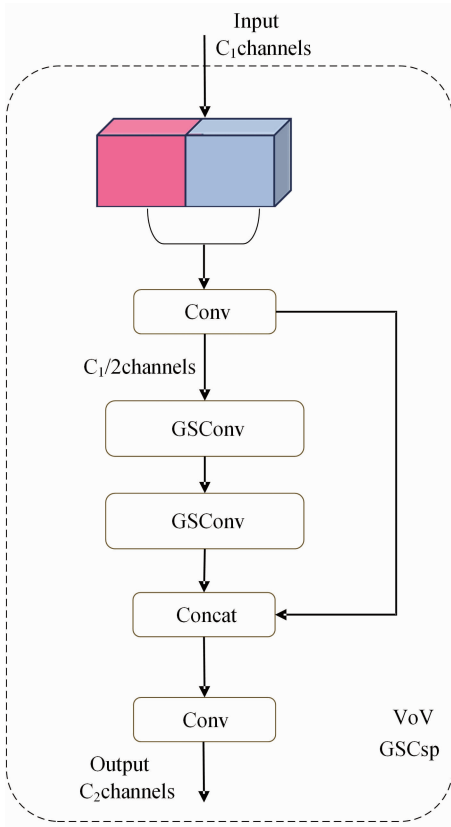


图8 VoV-GSCSP 模块结构

表 1 试验模型参数表

参数名称	设定值
输入图像大小(像素)	640 × 640
模型迭代次数(次)	500
批处理大小(张)	32
优化器	SGD
初始学习率	0.01
学习率衰减策略	余弦退火衰减
线程数	12

$$R = \frac{TP}{TP + FN}; \quad (4)$$

$$AP = \int_0^1 P(R) dR; \quad (5)$$

$$mAP = \frac{1}{n} \int_1^n AP_i。 \quad (6)$$

式中:  $TP$  表示模型预测正确的正样本数;  $FP$  表示模型预测错误的负样本数;  $FN$  表示模型预测错误的负样本数;  $P(R)$  是在召回率  $R$  处的精确率,  $AP_i$  是类别  $i$  的平均精确率 ( $AP$ );  $n$  是类别的数量。

本研究将采用参数量和计算量来衡量模型的轻量化。参数量是衡量模型空间复杂度的一个重要指标,它反映了模型所需存储资源的多少。具体

而言,参数量越大,模型占用的显存也就越多,这对于在资源有限的环境中部署模型构成了挑战。而较低的参数量则意味着模型更为紧凑,有利于在资源受限的场景下实现有效部署。

另一方面,计算量则是评估模型时间复杂度的关键指标。它直接关联到模型的推理速度,即模型处理输入数据并产生输出的时间。计算量越大,模型的推理时间通常也就越长,这可能会影响到应用的实时性和用户体验。

鉴于参数量和计算量在衡量模型轻量化方面的重要作用,本研究将采用这 2 个指标来综合评估模型的轻量化效果。通过优化模型结构、减少冗余参数和降低计算复杂度等手段,旨在实现模型在保持较高性能的同时,显著减少参数量和计算量,从而达到轻量化的目的。

## 2 结果与分析

### 2.1 消融试验

为了严格评估本研究提出改进方法的效果,将在 YOLO v8n 的基础上逐步引入改进方法,以验证每个改进方法对模型的影响。由表 2 可知,第 2 组在引入 ODConv 后,模型的精确率、召回率以及平均精确率都有所提高,说明在引入 ODConv 卷积的模型通过动态调整卷积核的权重有效提高了模型对小麦病害的检测精准率。在引入 BiFPN 后,模型的精确率虽然没有提高,但召回率和平均精确率分别提升了 1.3、1.7 百分点,参数量和计算量变化不大,说明 BiFPN 加权的特征融合能有效提升模型对小麦病害图像不同尺度的特性信息融合能力。在引入带 GSCSP 的 Slim-Neck 后,模型的精确率、召回率和平均精确率分别提升 2.2、2.8、1.8 百分点,参数量下降 13%,计算量下降 18%,表明模型有效解决了在空间压缩和通道扩展时的语义丢失问题,在参数量和计算量下降的同时精确率得到提升。第 7 组试验集成所有改进点,改进后的模型相比于 YOLO v8n 基础模型精确率、召回率、平均精确率分别上升 5.2、1.3、2.2 百分点,参数量下降 10%,计算量下降 26%。本研究所提出的 3 个改进点不仅作用上互不冲突,而且展现出了良好的适配性。每个改进点都充分发挥了其独特的优势,共同促使模型达到了最优性能。在保持模型体积相对较小的情况下,这些改进点有效地提升了模型对小麦病害的检测准确率,实现了性能与效率的双重提升。

表 2 消融试验结果

序号	ODConv	BiFPN	Slim - Neck	精确率 (%)	召回率 (%)	<i>mAP@0.5</i> (%)	参数量 (M)	计算量 (G)
1	—	—	—	86.1	70	75.1	3.1	8.9
2	√	—	—	89.2	73.0	77.2	3.1	7.9
3	—	√	—	85.9	71.3	76.8	3.1	8.7
4	—	—	√	88.3	72.8	76.9	2.7	7.3
5	√	√	—	89.0	70.8	77.8	3.0	7.8
6	√	—	√	87.7	72.4	76.4	2.8	6.6
7	√	√	√	91.3	71.3	77.3	2.8	6.6

## 2.2 对比试验

为了进一步验证所提出的 OBS - YOLO v8 模型的性能,本研究选取多个广泛认可的原模型进行对比试验,包括 Faster R - CNN、YOLO v5s、YOLO v6n、YOLO v7 - tiny、YOLO v8s,在相同的数据集下进行试验对比分析 OBS - YOLO v8 模型的性能。结果如表 3 所示。不难看出,改进后的 OBS - YOLO v8 网络模型的精确率优于其他模型,与参数量庞大的 YOLO v8s 模型相比平均精确率仅相差 0.8 个百分点,但 OBS - YOLO v8 模型的参数量仅为 2.8 M,计算量仅为 6.6 G,都远小于其他模型,表明 OBS - YOLO v8 在小麦病害检测上有出色的准确性,其轻量化的特点使 OBS - YOLO v8 模型更易部署资源受限的应用环境中。

表 3 不同模型对比实验结果

模型	精确率 (%)	召回率 (%)	<i>mAP@0.5</i> (%)	参数量 (M)	计算量 (G)
Faster R - CNN	74.7	63.0	73.7	41.3	137.3
YOLO v5s	88.6	71.6	77.1	7.0	15.8
YOLO v6n	86.5	68.9	72.3	4.3	11.1
YOLO v7 - tiny	85.4	63.5	70.4	6.0	13.0
YOLO v8n	86.1	70.0	75.1	3.1	8.9
YOLO v8s	90.7	75.6	78.1	11.1	28.4
OBS - YOLO v8	91.3	71.3	77.3	2.8	6.6

为了进一步展示改进后 OBS - YOLO v8 网络模型与原 YOLO v8n 网络模型的对比效果,图 9 展示了改进前后模型在测试集上的检测效果。由图 9 可见,在原 YOLO v8n 网络模型中对各个病害检测出现漏检的情况,改进后的 OBS - YOLO v8 模型有效解决了这一问题,且 OBS - YOLO v8 网络模型对病害检测精确率高于原 YOLO v8 网络模型,证明了本研究所提出的改进算法的有效性。综合效果表明,本研究提出的 OBS - YOLO v8 网络模型在小麦病害

检测上不仅有着较高的检测精度,还能有较小的体积便于部署资源受限的移动端。

## 3 讨论与结论

针对真实环境下小麦病害检测效果不佳,本研究提出了一种基于 YOLO v8n 的优化模型 OBS - YOLO v8 方法。将其应用于小麦病害检测中取得不错的效果,试验结果表明,精确率、召回率、*mAP@0.5* 分别为 91.3%、71.3%、77.3%,相对于原 YOLO v8n 网络模型分别提高了 5.2、1.3、2.2 个百分点;参数量和计算量分别下降 10% 和 26%。表明本研究提出的 OBS - YOLO v8 网络模型在提升模型性能的同时还降低了模型的复杂度,为后续的移动端部署奠定了基础。

小麦病害种类复杂繁多,本研究数据集中只用了 4 种小麦病害,一定程度上限制了模型的应用,在后续的工作中将收集更多真实环境下的小麦病害种类以丰富数据集,引入新的改进点进一步提升模型。此外,在未来计划将模型部署移动端上运用于实际中,以进一步推动农业智能化。

### 参考文献:

- [1] Callaway E. Wheat disease's global spread concerns researchers[J/OL]. Nature, 2023 [2023 - 05 - 11]. <http://www.nature.com/articles/d41586-023-01043-8?>
- [2] 胡国玉,刘广,周星光,等. 基于 Swin - TDL 算法的果园环境下葡萄病害检测方法[J]. 中国农机化学报, 2024, 45(8): 234 - 239.
- [3] 刘笑意,段纳,徐止政,等. 基于改进 YOLO v5 的苹果叶病害识别算法[J]. 计算机应用与软件, 2025, 42(8): 283 - 290.
- [4] Kasana S S, Rathore A S. Attention - based light weight deep learning models for early potato disease detection [J]. Applied Sciences, 2024, 14(17): 8038.
- [5] 王浩宇,崔艳荣,胡玉荣,等. 基于改进 EfficientNet v2 的苹果叶片病害识别模型[J]. 山东农业科学, 2024, 56(9): 124 - 132.



图9 检测结果对比

- [6] Kumar D, Kukreja V. Image segmentation, classification, and recognition methods for wheat diseases: two Decades' systematic literature review [J]. Computers and Electronics in Agriculture, 2024, 221: 109005.
- [7] 李震, 李佳盟, 王楠, 等. 基于轻量化改进模型的小麦白粉病检测装置研发[J]. 农业机械学报, 2023, 54(增刊2): 314-322.
- [8] 沈广辉, 曹瑶瑶, 刘馨, 等. 近红外高光谱成像结合特征波长筛选识别小麦赤霉病瘿粒[J]. 江苏农业学报, 2021, 37(2): 509-516.
- [9] Mao R, Zhang Y C, Wang Z X, et al. DAE - Mask: a novel deep - learning - based automatic detection model for in - field wheat diseases[J]. Precision Agriculture, 2024, 25(2): 785-810.
- [10] 时雷, 杨程凯, 雷镜楷, 等. 基于改进 YOLO v8s 的小麦小穗赤霉病检测研究[J]. 农业机械学报, 2024, 55(7): 280-289.
- [11] Jouini O, Aoueleiyine M O, Sethom K, et al. Wheat leaf disease detection: a lightweight approach with shallow CNN based feature refinement[J]. AgriEngineering, 2024, 6(3): 2001-2022.
- [12] Sunkara R, Luo T. No more strided convolutions or pooling: a new CNN building block for low - resolution images and small objects [M]//Machine Learning and Knowledge Discovery in Databases. Cham: Springer Nature Switzerland, 2023: 443-459.
- [13] Zhao K Y. Enhancing the performance and accuracy in real - time football and player detection using upgraded YOLO v5 architecture [J]. International Journal of Computational Intelligence Systems, 2024, 17(1): 163.
- [14] Norkobil Saydirasulovich S, Abdusalomov A, Jamil M K, et al. A YOLO v6 - based improved fire detection approach for smart city environments[J]. Sensors, 2023, 23(6): 3161.
- [15] Li C, Lin J Q, Li Z, et al. An efficient detection method for Litchi fruits in a natural environment based on improved YOLO v7 - Litchi [J]. Computers and Electronics in Agriculture, 2024, 217: 108605.
- [16] Li Q X, Ma W J, Li H, et al. Cotton - YOLO: improved YOLO v7 for rapid detection of foreign fibers in seed cotton [J]. Computers and Electronics in Agriculture, 2024, 219: 108752.
- [17] Zhou T, Wang H W, Du Y H, et al. M3YOLO v5: feature enhanced YOLO v5 model for mandibular fracture detection [J]. Computers in Biology and Medicine, 2024, 173: 108291.
- [18] Li C, Zhou A, Yao A. Omni - dimensional dynamic convolution [EB/OL]. 2022, arXiv preprint, arXiv: 2209. 07947 (2022 - 09 - 16) [2024 - 10 - 02]. <https://arxiv.org/abs/2209.07947>.
- [19] Tan M X, Pang R M, Le Q V. EfficientDet: scalable and efficient object detection [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 10778-10787.
- [20] Li H L, Li J, Wei H B, et al. Slim - neck by GSConv: a lightweight - design for real - time detector architectures [J]. Journal of Real - Time Image Processing, 2024, 21(3): 62.