

朱明,汪荣,万鹏,等.基于YOLOv8-DBCS的循环水养殖环境下大口黑鲈异常体表特征检测[J].华中农业大学学报,2026,45(2):269-279.
DOI:10.13300/j.cnki.hnlkxb.2026.02.028

基于YOLOv8-DBCS的循环水养殖环境下 大口黑鲈异常体表特征检测

朱明^{1,2},汪荣¹,万鹏^{1,2},雷翔¹,范豪¹

1. 华中农业大学工学院/农业农村部水产养殖设施工程重点实验室,武汉 430070;
2. 农业农村部长江中下游农业装备重点实验室,武汉 430070

摘要 大口黑鲈(*Micropterus salmoides*)在循环水养殖过程中容易感染细菌和病毒,得病早期体表会出现充血和白斑等异常特征。为避免大口黑鲈大规模养殖死亡,提出一种基于YOLOv8的大口黑鲈异常体表特征检测模型YOLOv8-DBCS。首先,基于StarNet网络提出一种动态深度卷积(DIConv)主干网络DIStarNet,DIConv通过设计动态卷积核权重机制自适应调整卷积操作,进而有效捕捉多尺度的特征信息;其次,在颈部网络引入加权双向特征金字塔网络(bi-directional feature pyramid network, BiFPN)增强对来自主干网络多尺度信息的特征融合能力;此外,在检测头前加入CBAM(convolutional block attention module)注意力机制,提升对鱼体异常体表特征图像的学习与预测;最后将目标识别损失函数替换为SIoU(SCYLLA-intersection over union),以改善模型预测框与真实框的重合度,进一步提高模型对鱼体异常体表特征识别准确率。结果显示:YOLOv8-DBCS在检测性能上表现优异,YOLOv8-DBCS评价指标准确率(precision)、召回率(recall)、mAP₅₀和mAP₅₀₋₉₅分别为95.8%、92.4%、97.5%和66.2%;与基线模型相比分别提高3.6、4.9、7.0和3.4个百分点。在模型大小上,YOLOv8-DBCS的参数量(parameters)为 1.85×10^6 ,与基线模型相比降低了38.5%。

关键词 异常体表特征检测;特征提取网络;特征金字塔网络;注意力机制;损失函数;大口黑鲈;循环水养殖

中图分类号 S965.211 文献标识码 A 文章编号 1000-2421(2026)02-0269-11

大口黑鲈(*Micropterus salmoides*)因其优良的肉质、较快的生长速度及较高的经济价值,在我国水产养殖中占据了重要地位。近年来,我国大口黑鲈集约化养殖规模不断扩大,随着养殖密度增加和种质退化,由细菌和病毒引发的病害问题越来越突出,现已成为制约大口黑鲈养殖业健康发展的瓶颈^[1]。

循环水养殖大口黑鲈,由于养殖水体封闭,鱼类疾病的暴发通常会导致较大经济损失,在养殖过程中需要尽早发现和及时处理这些得病鱼体。研究表明,当环境发生改变或受到鱼类溃烂综合征、尾鳍腐烂、细菌性鳃病和寄生虫病等疾病的影响时,通常身体表面纹理、颜色等特征会发生改变,尤其在鱼身和鱼尾区域。严重时可能会导致鱼翻身或死亡。因此,对患病鱼体出现的上述异常体表特征进行检测十分必要^[2-3]。

传统的鱼类异常体表特征检测方法是通过养殖人员肉眼观测,该方法耗时耗力,这给大规模循环水养殖带来了挑战。随着图像处理技术的兴起,通过对鱼类异常体表特征图像的大量分析,患病鱼类体表的颜色、纹理等特征会发生改变^[4]。通过相机拍摄鱼类体表图像的变化可作为快速检测的依据^[5]。Sikder等^[6]提出了一种基于聚类分析与模糊逻辑对滤波图像进行分割的鱼病检测方法,该方法使用K-means的准确率为96.48%,使用C-means的准确率达到97.90%。但该方法存在数据集有限和需要人工提取特征的问题,并不适用于大规模的鱼病数据检测。Khabusi等^[7]针对水下鱼体体表病害特征不明显的问题,提出了基于卷积块注意力模块的具有背景去除的鱼病分类网络,引入CBAM注意力机制的ResNet50模型,实现了89.9%的准确率。Kumar

收稿日期:2025-07-19

基金项目:国家重点研发计划项目(2022YFD2001705);湖北省科学技术厅重大科技专项(2023BBA001)

朱明, E-mail: 13801392760@163.com

通信作者:万鹏, E-mail: wanpeng09@mail.hzau.edu.cn

等^[8]提出了一种基于伪哈密顿神经网络的方法 FDD-PHNN-PEOA, 实现了 99.2% 的感染鲑鱼检测准确率。Waleed 等^[9]借助卷积神经网络 AlexNet CNN 实现了对 3 种鱼类流行病的自动检测。Ahmed 等^[10]集成水质检测和深度学习技术提出了一种自动检测鱼类疾病的方法, 能够向养殖人员发送实时环境和病害警报。陈科等^[11]基于机器视觉对 YOLOv5s 模型进行轻量化改进, 构建了适合鲫的异常体表特征检测模型, 检测效率较高, 但其检测准确性仍需提升。荣弘扬等^[12]针对鱼体病害形状和纹理复杂难以定位的问题, 提出了一种基于双通道分层协同的 CEH-YOLOv8 鱼体病害检测方法, 实现了 83.2% 鱼体病害的识别准确率。

综上, 现有研究普遍存在对鱼病这类不规则小目标特征提取能力不足, 且在复杂养殖背景下的模型鲁棒性较弱的问题。本研究以循环水养殖环境下的大口黑鲈为目标, 采集并构建大口黑鲈异常体表特征检测数据集。以 YOLOv8 为基线模型, 首先, 提出一种动态深度卷积, 通过设计动态卷积核权重机制自适应调整卷积操作, 进而有效捕捉多尺度的特征信息; 其次, 在颈部网络引入加权双向特征金字塔网络增强, 对来自主干网络多尺度信息的特征融合能力; 然后, 在检测头前增加注意力机制, 提升对鱼体异常体表特征图像的学习与预测; 最后替换目标损失函数以改善模型预测框与真实框的重合度, 提出一种大口黑鲈异常体表特征检测模型 YOLOv8-DBCS, 旨在提升复杂背景下的大口黑鲈异常体表小目标特征的精准检测能力, 为循环水养殖大口黑鲈异常体表特征的检测及病害早期预警提供参考。

1 材料与方法

1.1 图像采集与处理


所有数据均采集自华中农业大学机电工程训练中心循环水养殖试验平台, 平台结构如图 1 所示。



图1 循环水养殖试验平台

Fig.1 Recirculating aquaculture test platform

试验平台主要由圆形养殖桶(直径和高度均为 1 m, 养殖水体容积 500 L)、微滤机、生物池、蓄水池组成。试验对象为大口黑鲈, 采购自湖北中鲈科技有限公司。本试验全部图像数据均由养殖人员在日常巡检过程中使用 Intel Realsense D435i 相机进行采集。拍摄时, 使用三脚架将相机固定在养殖桶水面上方的位置进行取景, 从而确保能够获取完整的图像, 图像分辨率为 1 920 像素 × 1 080 像素。鱼体异常体表特征现象主要发生在鳃部、鱼鳍、鱼身和鱼尾处, 如图 2 所示。数据采集不影响养殖对象正常生长, 不涉及动物伦理问题。



图中异常体表特征目标用红色方框表示。The missed targets in the image are indicated with red square boxes.

图2 大口黑鲈异常体表特征样本采集装置及数据示例
Fig.2 Sample data of *Micropterus salmoides* surface injury

模型在训练过程中的数据越丰富, 模型训练效果越好。为更好地训练模型, 对采集的图像进行预处理。采用数据增广的方法提升数据的多样性, 共采集了 1 000 张鱼体异常体表特征图像, 按照 8:1:1 的比例将采集图像划分为训练集、验证集和测试集。采用亮度调整、随机翻转、Mosaic 增强和 Mixup 增强等 4 种方式将训练集扩充至 4 000 张图像。使用 Labelme 软件标注时, 标注框要完全覆盖图像中所有鱼体异常体表特征区域(鱼患病时发生的如鱼身溃烂、鱼鳍腐烂和烂鳃等鱼体表面纹理和颜色特征改变的现象)。

1.2 YOLOv8 目标检测模型

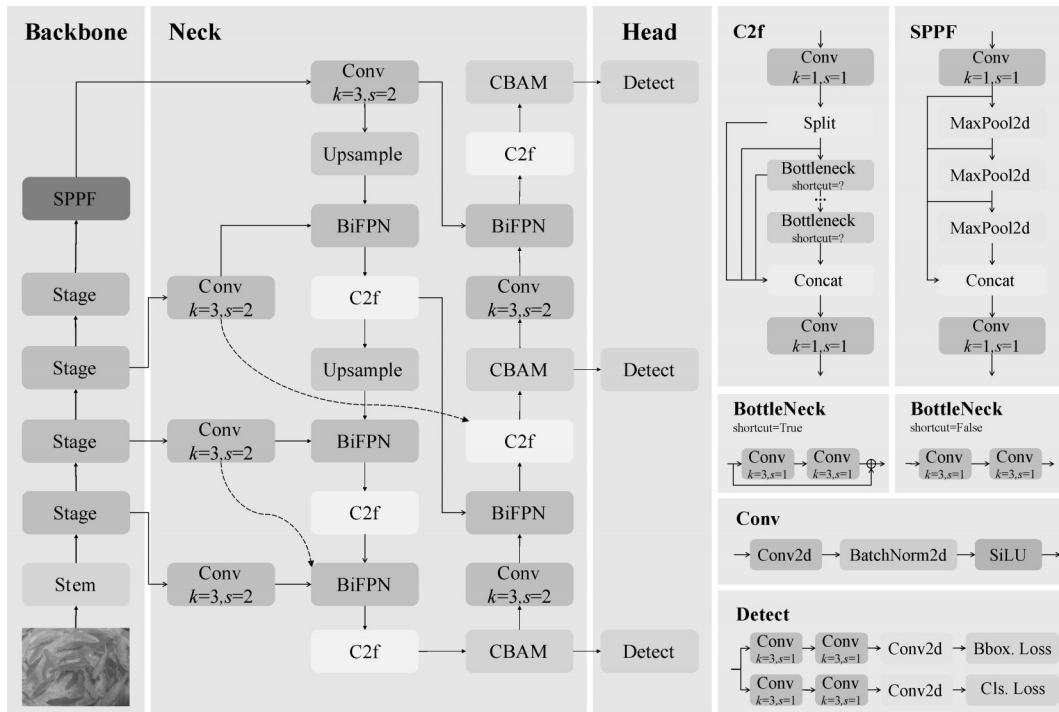
YOLOv8 是一款单阶段实时目标检测模型^[13], YOLOv8 项目根据不同规模的模型进行设计, 提供 YOLOv8n、s、m、l、x 共 5 个版本。其中, YOLOv8n 模型复杂程度最小, 架构最为轻量化, 检测精度相比其他 4 个版本稍低, 但检测速度最快。本研究采用 YOLOv8n 模型作为基线模型进行研究。

YOLOv8 模型由主干网络(Backbone)、颈部网

络(Neck)、头部网络(Head)3部分组成^[14]。YOLOv8使用了基于CSP(cross stage partial)Darknet变体的主干网络,该设计缓解了模型反向传播中的梯度消失问题,从而提高了训练的稳定性 and 模型性能。颈部网络负责聚合来自主干网络不同阶段的特征,使模型能够处理各种尺度的目标。YOLOv8的头部网络负责生成最终的检测结果,包括预测目标的边界框、目标性得分以及类别概率。

1.3 改进YOLOv8网络模型

本研究提出的YOLOv8-DBCS网络模型如图3所示,Backbone部分构成主干网络,需要从输入图像中提取出异常体表特征的目标区域。Neck部分为特征金字塔网络,负责对来自主干网络的多尺度信息进行特征融合。Head部分为检测网络,完成对目标特征进行精准定位并生成检测框。右边部分介绍整体网络模型中每个具体模块的结构。



k 表示卷积核大小, s 表示网络中某一层的步幅。 k represents the size of the convolution kernel, s represents the stride of a layer in the network.

图3 YOLOv8-DBCS网络结构

Fig.3 YOLOv8-DBCS network architecture

1.4 Backbone改进

传统卷积在特征提取过程中存在感受野固定、适应性不足和计算效率低的问题,难以充分捕捉尺度变化大、形状不规则的鱼体异常体表目标特征,容易造成关键特征区域信息的遗漏。为提升模型对这类非结构化目标的识别能力,本研究将YOLOv8原CSP主干结构替换为更具轻量性与多尺度建模能力的StarNet^[15]主干网络,并在此基础上提出一种动态深度卷积模块(dynamic inception depthwise convolution block,DI-Conv)用于替换StarNet Block模块中的逐点卷积。改进主干网络DIStarNet有效解决传统卷积神经网络在多尺度特征提取、信息融合及计算效率方面的不足。该设计不仅提升网络的适应性与灵活性,也在整体上增强模型对异常体表特征目

标的识别精度与鲁棒性。其主干结构如图4所示。

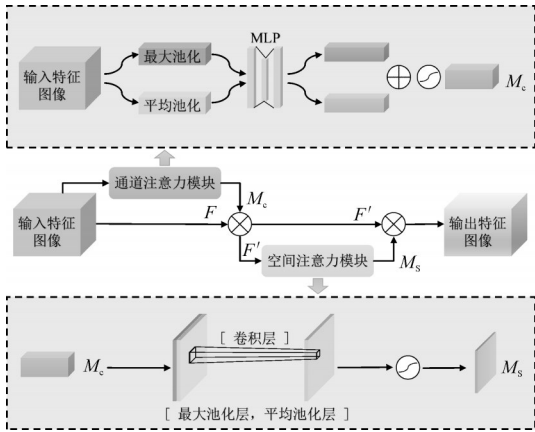
DICov卷积采用1个 3×3 卷积和2个条形卷积提取输入特征信息,通过设计动态卷积核权重机制,给每个输入特征通道生成对应的权重,让模型在每次前向传播时根据不同的权重自适应调整卷积操作,进而有效捕捉多尺度的特征信息。相比传统 7×7 卷积或MLP模块,DICov卷积在进一步压缩参数的同时仍保留了网络对复杂纹理和细粒度异常区域的处理效果。其具体步骤如下。

输入特征图为 $X \in R^{C \times H \times W}$,通过自适应池化提取全局上下文信息,并用 1×1 卷积输出每个卷积分支的权重:

$$W_{dkw} = \text{Conv}_{1 \times 1}(\text{AvgPool}(X)) \quad X \in R^{3 \times 1 \times 1} \quad (1)$$

$$W_i = \text{Softmax}(\text{reshape}(W_{dkw})), \quad i = 1, 2, 3 \quad (2)$$

小目标预测带来了挑战。CBAM (convolutional block attention module)^[18]模块通过加权突出特征图中的通道和空间位置,增强模型对目标特征的响应,同时抑制无关背景特征,在检测头前加上CBAM模块,能有效增强模型在处理目标密集或复杂场景对关键特征的敏感性,以改善原模型对小目标的检测能力。



MLP表示多层感知机, M_c 表示通道注意力权重, F 表示输入特征图, F' 表示处理后特征图, M_s 表示空间注意力权重。MLP represents multi-layer perceptron, M_c representing channel attention weights, F represents the input feature map, F' represents the processed feature map, and M_s represents spatial attention weight.

图6 CBAM 注意力机制结构

Fig.6 CBAM attention mechanism architecture

由图6可知,CBAM模块结合了空间注意力(spatial attention)和通道注意力(channel attention)2个模块。首先,输入特征图像经过通道注意力机制进行池化和全连接层运算生成通道权重结果,将通道权重结果和输入特征图像相加后得到通道提取特征图,将通道提取特征图输入到空间注意力机制进行卷积和池化操作获取空间权重结果,最后将归一化后的空间权重结果和通道提取特征图相乘,得到最终加权后的特征图。

1.7 SIoU 损失函数

YOLOv8模型采用CIoU (complete intersection over union)损失函数,其由位置损失、置信度损失和分类损失3部分组成^[19]。在检测大口黑鲈异常体表特征这种小目标多、形状不规则的任务中,CIoU损失函数对小目标的优化能力存在不足。因此,本研究引入SIoU损失函数^[20],其在CIoU损失函数的基础上进一步加入真实框和预测框之间的向量角度,通过重新定义角度约束机制,更精确地优化边界框位置和形状。从而提高大口黑鲈异常体表特征这类小目标检测的准确率和鲁棒性。SIoU损失函数包

含:角度损失、距离损失、形状损失、IoU损失,如图7所示。




图7 SIoU参数示意图

Fig.7 SIoU parameters schematic diagram

角度损失是通过角度约束机制,减少预测框向目标框对齐时的旋转自由度,使得预测框可以沿最优路径移动到真实框。计算公式为:

$$\Delta = 1 - 2 \sin^2 \left(\arcsin \left(\frac{C_h}{\sigma} \right) - \frac{\pi}{4} \right) \quad (8)$$

$$\sigma = \sqrt{(b_{cx}^{gt} - b_{cx})^2 + (b_{cy}^{gt} - b_{cy})^2} \quad (9)$$

$$C_h = \max(b_{cy}^{gt}, b_{cy}) - \min(b_{cy}^{gt}, b_{cy}) \quad (10)$$

式(8)~(10)中: Δ 表示角度损失, $(b_{cx} - b_{cy})$, $(b_{cx}^{gt} - b_{cy}^{gt})$ 表示预测框与真实框的中心坐标。

距离损失是预测框与真实框中心点之间的欧氏距离,SIoU损失函数会根据角度损失进一步增强对位置关系的度量,计算公式为:

$$\Delta = \sum_{t=x,y} (1 - e^{-\gamma \rho_t}) \quad (11)$$

$$\rho_x = \left(\frac{b_{cx}^{gt} - b_{cx}}{C_w} \right), \rho_y = \left(\frac{b_{cy}^{gt} - b_{cy}}{C_h} \right), \gamma = 2 - \Delta \quad (12)$$

式(11)~(12)中: Δ 表示距离损失。

形状损失通过度量预测框和真实框之间的宽高比差异,进一步优化2个边界框的形状匹配度。计算公式为:

$$\Omega = \sum_{t=w,h} (1 - e^{-\omega_t \theta}) \quad (13)$$

$$\omega_w = \frac{|\tau_w - \tau_w^{gt}|}{\max(\tau_w, \tau_w^{gt})}, \omega_h = \frac{|h - h^{gt}|}{\max(h, h^{gt})} \quad (14)$$

式(13)~(14)中: Ω 表示形状损失, τ_w^{gt} , h^{gt} 为真实框长、宽, τ_w , h 为预测框长、宽, $\theta \in [2, 6]$,其能够有效调节预测框与真实框的比例差异,平衡计算中边界框形状与位置优化的优先级^[21]。

SIoU损失函数为:

$$L_{SIoU} = 1 - \text{IoU} + \frac{\Delta + \Omega}{2} \quad (15)$$

式(15)中,IoU损失是预测框与真实框的交并比。

1.8 试验环境

1) 试验平台。处理器: Intel(R) Core(TM) i7-12700KF (3.6 GHz); 显卡: NVIDIA GeForce RTX3090(24 GB 显存), 内存大小 32 GB; 操作系统: Windows 11; CUDA 版本: 11.7; Pytorch 版本: 1.13.0; Python 版本: 3.9.19。

2) 参数设置。迭代批次为 4; 优化器: 随机梯度下降法 (stochastic gradient descent, SGD); 初始学习率为 0.01, 动量参数为 0.937, 权重衰减为 0.000 5, 共训练 500 轮。

1.9 评价指标

本研究选用准确率 (precision, P)、召回率 (recall, R)、平均精度均值 (mean average precision, mAP; 公式中用 $P_{m\Delta}$ 表示)、参数量 (parameters) 和检测速度作为模型的评价指标。准确率和召回率可通过计算预测结果与真实标注框在 IoU 阈值大于 0.5 时的匹配情况得到。平均精确度 (average precision, AP; 公式中用 P_{Δ}) 通过对 P - R 曲线面积积分获得, $P_{m\Delta}$ 是对所有类别 P_{Δ} 进行平均得到。参数量作为指标用于评价改进模型的轻量化效果。其计算公式

如下:

$$P = \frac{T_P}{T_P + F_P} \quad (16)$$

$$R = \frac{T_P}{T_P + F_N} \quad (17)$$

$$P_{\Delta} = \int_0^1 P(R) dR \quad (18)$$

$$P_{m\Delta} = \frac{1}{c} \sum_{i=1}^c P_{\Delta i} \quad (19)$$

式(16)~(17)中: T_P (true positive) 表示预测出正确类别的正样本数, F_P (true negative) 表示预测出正确类别的负样本数, F_N (false negative) 表示预测出错误类别的正样本数。

2 结果与分析

2.1 不同主干网络对比试验

为提升模型对不同尺度目标的特征提取能力, 尝试替换 YOLOv8 的原始主干网络, 与 4 种经典的主干结构进行对比 (表 1)。通过替换主干评估不同特征提取策略对检测精度与模型复杂度的影响, 为优化检测性能提供理论依据。不同主干网络对比试验结果如表 1 所示。

表 1 不同主干网络试验结果

Table 1 Test results of different backbone network

模型 Model	准确率/% Precision	召回率/% Recall	平均精度均值/% mAP ₅₀	平均精度均值/% mAP ₅₀₋₉₅	参数量/($\times 10^6$) Parameters
YOLOv8	92.2	87.5	90.5	62.8	3.01
ConvNeXtV2 ^[22]	87.5	84.3	80.1	45.6	7.10
MobileNetV4 ^[23]	88.6	86.4	85.5	55.2	5.16
EfficientViT ^[24]	88.7	85.8	80.5	50.6	3.67
DIStarNet	93.8	87.4	93.5	63.0	1.55

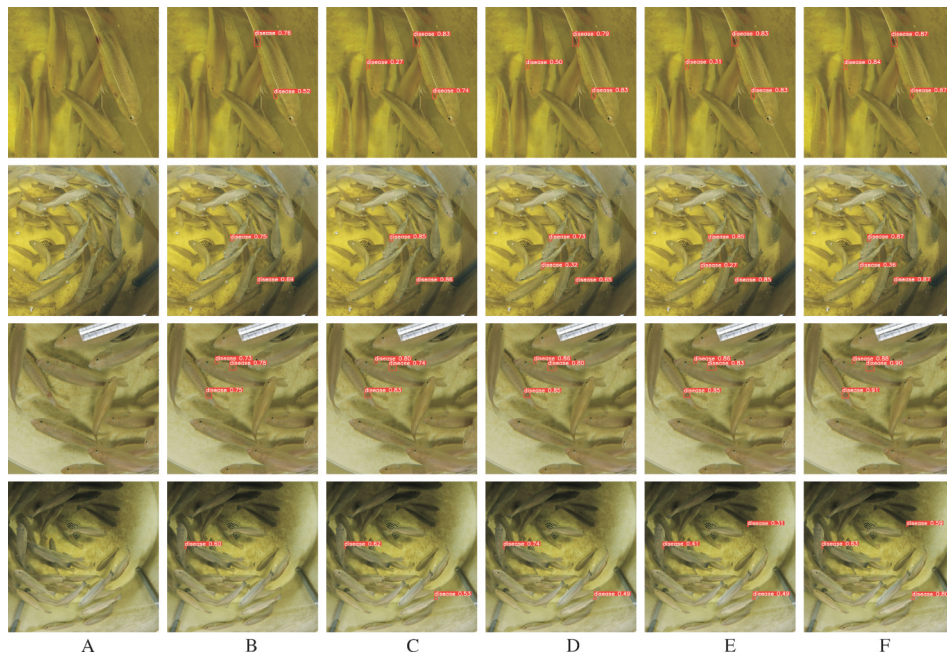
由表 1 可知, DIStarNet 主干网络在大口黑鲈异常体表特征目标检测任务中优势显著。与经典模型 YOLOv8 主干网络相比, 准确率高 1.6 百分点、召回率微降 0.1 百分点、mAP₅₀ 提升 3 百分点、mAP₅₀₋₉₅ 提升 0.2 百分点、参数量少 1.46×10^6 , 以更精简参数实现检测性能提升。相较于 ConvNeXtV2, 本模型准确率提升 6.3 百分点、召回率提升 3.1 百分点、mAP 指标提升的同时参数量减少了 5.55×10^6 。对比轻量模型 MobileNetV4, 准确率和召回率分别提高 5.2 和 1.0 百分点。相比 EfficientViT, 本研究准确率和召回率分别提升 5.1、1.6 百分点, 参数量减少 2.12×10^6 。DIStarNet 在保证轻量化的同时显著提升检测精度。

本研究还选取 4 组不同形状和纹理的鱼体异常体表特征图像进行检测效果对比, 如图 8 所示。主干

网络 ConvNeXtV2、MobileNetV4 和 EfficientViT 在实际养殖环境复杂情况下应对检测目标小、形状不规则的鱼体异常体表特征容易发生漏检问题。这是由于病害发病形状不规则且有时会与鱼体本身的纹理相重合, 从而导致病害纹理不清晰, 使得网络难以准确区分和定位真实的患病区域。而本研究提出的检测模型可以解决这类问题, 拥有精准识别不规则形状病害的能力。

2.2 消融实验

为了验证本研究提出的改进模块的有效性, 以 YOLOv8 为基准模型, 通过分别引入主干网络 DIStarNet、特征金字塔网络 BiFPN、注意力机制 CBAM 以及损失函数 SIOU, 分析各模块对整体检测性能的贡献。消融实验结果如表 2 所示。



A: Origin image; B: ConvNeXtV2; C: MobileNetV4; D: EfficientViT; E: YOLOv8; F: DIStarNet.

图 8 不同主干网络检测效果对比

Fig.8 Comparison of detection effects of different backbone networks

表 2 消融实验结果

Table 2 Results of ablation experiments

模型 Model	准确率/% Precision	召回率/% Recall	平均精度均值/% mAP ₅₀	平均精度均值/% mAP ₅₀₋₉₅	参数量/($\times 10^6$) Parameters
YOLOv8	92.2	87.5	90.5	62.8	3.01
YOLOv8+DIStarNet	93.8	87.4	93.5	63.0	1.55
YOLOv8+BiFPN	94.7	91.0	97.2	62.4	2.23
YOLOv8+CBAM	94.8	88.8	95.7	63.2	3.11
YOLOv8+SIoU	94.5	87.8	95.4	64.2	3.01
YOLOv8+DIStarNet+BiFPN	94.8	91.4	96.6	64.1	2.05
YOLOv8+DIStarNet+BiFPN+CBAM	95.6	92.2	97.1	65.1	1.85
YOLOv8-DBCS	95.8	92.4	97.5	66.2	1.85

结果表明,当仅增加 BiFPN 时,准确率提升 2.5 百分点,召回率提升 3.5 百分点, mAP_{50} 从 90.5% 大幅提升至 97.2%。BiFPN 作为高效特征金字塔网络,其多尺度特征融合能力能让模型更好整合不同层级特征,虽 mAP_{50-95} 微降 0.4 百分点,但整体强化了小目标检测性能。当仅添加 CBAM 时, mAP_{50} 提升 5.2 百分点, mAP_{50-95} 提升 0.4 百分点,准确率和召回率分别提升 2.6、1.3 百分点,表明在检测头前添加 CBAM 注意力机制可动态抑制背景噪声干扰,使模型在预测时更多地聚焦关键特征。当使用 SIoU 损失函数替换原模型损失函数后,准确率提升 2.3 百分点, mAP_{50-95} 提升 1.4 百分点,召回率提升 0.3 百分点, mAP_{50} 从 90.5% 提升至 95.4%,表明引入 SIoU 有助于优化预测框与真实框的定位关系,提升定位精度。

同时引入 DIStarNet 与 BiFPN 时,准确率相比基线模型提升 2.6 百分点、召回率提升 3.9 百分点, mAP_{50} 达到 96.6%, mAP_{50-95} 为 64.1%。DIStarNet 优化特征提取, BiFPN 强化特征融合,二者组合模型在特征处理全流程更高效。组合 DIStarNet、BiFPN 和 CBAM 时,参数量压缩至 1.85×10^6 ,且所有指标提升均超过 2 百分点,全方位提升对鱼体异常体表特征目标的检测能力。试验结果表明, YOLOv8-DBCS 的各改进模块均提升了模型的整体性能,且在组合使用时产生了更好的检测精度与鲁棒性。

2.3 不同目标检测模型对比试验

针对高密度循环水养殖场场景下大口黑鲈体表异常特征存在目标较小、不易检测的情况,本研究设计了 YOLOv8-DBCS 结构网络。为了检验模型的性

能,将本研究模型YOLOv8-DBCS与YOLO系列模型和具有代表性的RetinaNet、SSD以及Faster-R-CNN目标检测网络进行试验对比(统一的配置以及相同的数据集),检测结果如表3所示。

表3 不同检测模型对比结果

Table 3 Comparison results of detection performance of different models

模型 Model	准确率/% Precision	召回率/% Recall	平均精度均值/% mAP ₅₀	平均精度均值/% mAP ₅₀₋₉₅	参数量/($\times 10^6$) Parameters	检测速度/(帧/s) FPS
Faster-R-CNN ^[25]	78.7	50.6	48.7	41.8	41.25	18.5
SSD ^[26]	85.8	81.7	87.6	43.5	24.58	22.1
RetinaNet ^[27]	88.3	80.1	86.8	42.4	36.2	46.4
YOLOv5s	91.1	90.4	89.8	62.1	1.76	74.9
YOLOv7-tiny	83.0	82.1	80.2	52.4	6.01	58.6
YOLOv8n	92.2	87.5	90.5	62.8	3.01	72.3
YOLOv10n	89.8	83.7	87.6	57.5	3.10	60.5
YOLOv11n	89.2	85.3	90.1	58.7	2.62	66.8
GhostNetV3	87.5	82.6	88.3	55.2	2.72	70.7
YOLOv8-DBCS	95.8	92.4	97.5	66.2	1.85	75.2

传统两阶段模型Faster-R-CNN在大口黑鲈体表特征检测中因网络结构复杂、参数量大而表现欠佳,准确率和召回率分别为78.7%和50.6%,mAP₅₀、mAP₅₀₋₉₅只有48.7%和41.8%。单阶段模型SSD、RetinaNet相比Faster-R-CNN检测性能有所提升。但SSD在处理小目标时表现欠佳,因为其特征图分辨率随着网络层级加深而降低,小目标特征提取不充分^[28]。RetinaNet虽然引入Focal Loss改善了类别不平衡问题,但模型参数量相对较大,计算成本较高^[29]。因此,对大口黑鲈复杂体表特征的细粒度识别能力有限。YOLOv5s模型展现了小幅轻量化和检测速度优势,模型参数量仅有 1.76×10^6 ,检测速度也达到了74.9帧/s。YOLOv8n准确率达到92.2%,仅次于本研究模型,YOLOv10n因训练策略局限导致对小目标异常特征识别精度不足^[30]。对比采用重参数化方法的轻量化模型GhostNetV3,本模型在准确率、召回率及不同IoU阈值下的mAP等关键指标上均有显著提升。改进的YOLOv8-DBCS模型在轻量化基础上,模型的准确率和召回率分别达到95.8%和92.4%,mAP₅₀和mAP₅₀₋₉₅分别为97.5%和66.2%,在检测速度方面优于其他模型,实现了75.2帧/s的检测能力。对比YOLO系列及传统模型,本模型在大口黑鲈异常体表特征检测任务中,突破小目标识别瓶颈,精准提取大口黑鲈体表细粒度特征,有效平衡模型复杂度与识别性能。

2.4 模型鲁棒性试验


本研究挑选4组大口黑鲈异常体表特征图像进行测试,包含了鱼群密集、暗光环境、灯光干扰和小目标特征4个场景,进而对模型的鲁棒性进行检测效

果对比,结果如图9所示。

在小目标特征场景下,YOLOv10和YOLOv8表现出1处漏检情况,且暗光环境场景下,YOLOv10模型的部分预测结果的可靠性不足,容易导致误判。YOLOv5模型检测效果均低于本研究模型。而本研究模型YOLOv8-DBCS对于4种场景下的大口黑鲈异常体表特征目标均能准确检出,且有8处异常体表特征目标检测置信度达到了80%以上,说明改进后模型在小目标特征、暗光环境及多鱼群密集干扰的情况下具有良好的检测能力和鲁棒性。在灯光干扰场景中改进模型依然存在2处漏检现象,说明在极端光照干扰及目标边缘模糊条件下模型的鲁棒性仍有一定不足。未来可进一步引入多模态信息以适应不同环境下的异常体表特征目标检测。

3 讨论

大口黑鲈循环水养殖过程中感染细菌和病毒时,体表会出现充血和白斑等异常特征。为防止出现大规模养殖死亡情况,本研究提出了一种基于YOLOv8的大口黑鲈异常体表特征检测方法YOLOv8-DBCS,提出的动态深度卷积DICov通过设计动态卷积核权重机制自适应调整卷积操作,进而有效捕捉多尺度的特征信息。在颈部网络引入BiF-PN模块增强对来自主干网络多尺度信息的特征融合能力。在检测头前加入CBAM注意力机制,提升模型对关键特征的学习与预测;最后将目标识别损失函数替换为SIoU,以改善模型预测框与真实框的重合度,进一步提高模型对鱼体异常体表特征识别精准率。消融实验结果表明:YOLOv8-DBCS的准



A: YOLOv10; B: YOLOv5; C: YOLOv8; D: YOLOv8-DBCS. 图中漏检目标用蓝色圆框表示。The missed targets in the image are indicated with blue circular boxes.

图9 不同模型检测效果对比

Fig.9 Comparison of detection effects of different models

准确率、召回率、 mAP_{50} 和 mAP_{50-95} 分别为 95.8%、92.4%、97.5% 和 66.2%，与基线模型相比分别提高了 3.6、4.9、7.0 和 3.4 个百分点。在模型大小上，YOLOv8-DBCS 的参数量仅为 1.85×10^6 ，与基线模型相比降低了 38.5%。在模型鲁棒性试验结果显示本研究模型在 4 种场景下均未出现漏检和误检的情况，且置信度高于基线模型。

YOLOv8-DBCS 模型在多组试验中表现出较高的检测精度和良好的鲁棒性，但在复杂环境下仍存在一定不足。SIoU 损失函数在大多数情况下能够提升预测框与真实框的重合度，但当异常体表特征呈现出不规则形变（如白斑边界模糊、充血区域呈弥散分布）时，预测框会出现轻微的外扩或偏移，表明 SIoU 在处理复杂边界形态时的适应性仍有限，未能检测出部分测试样本中鱼鳍和鱼尾边缘的呈不规则形变的异常体表特征区域。此外，本研究仅基于大口黑鲈数据集开展训练和验证，缺乏对其他经济鱼类的泛化能力评估。不同鱼种在形态特征上存在较大差异，未来可通过引入更多鱼类数据集，提升模型的通用性，以确保其在更广泛的水产养殖场景中应用。其次，本模型在检测精度方面仍有优化空间。在复杂环境（如光照变化、背景干扰）下，模型仍可能

出现漏检。未来可探索自监督学习、跨模态数据融合等方法，提高模型的鲁棒性。还可探索基于边缘部署的方式，使得模型能够在水产养殖生产实际环境中运行。

参考文献 References

- [1] 雷燕, 戚瑞荣, 崔龙波, 等. 大口黑鲈鱼种弹状病毒病的诊断 [J]. 大连海洋大学学报, 2015, 30(3): 305-308. LEI Y, QI R R, CUI L B, et al. Diagnosis of rhabdovirus disease in juvenile largemouth bass *Micropterus salmonides* [J]. Journal of Dalian Fisheries University, 2015, 30(3): 305-308 (in Chinese with English abstract).
- [2] 董寒旭, 曾伟伟. 大口黑鲈蛙虹彩病毒病研究进展 [J]. 病毒学报, 2022, 38(3): 746-756. DONG H X, ZENG W W. Research progress on largemouth bass ranavirus disease [J]. Chinese journal of virology, 2022, 38(3): 746-756 (in Chinese with English abstract).
- [3] PEYGHAN R, REZAIIE A, HASSANI F, et al. Histopathological study of gill and fish treatment in ichthyophthiriasis of white skirt tetra (*Gymnocorymbus ternetzi*) [J]. Iranian veterinary journal, 2021, 17(1): 106-110.
- [4] GORGOGNONE B, BAILEY C, FAST M D, et al. Co-infections and multiple stressors in fish [J]. Bulletin of the European Association of Fish Pathologists, 2020, 40(1): 4-19.
- [5] PARK J S, OH M J, HAN S. Fish disease diagnosis system

- based on image processing of pathogens' microscopic images [C]//2007 Frontiers in the Convergence of Bioscience and Information Technologies, October 11-13, 2007, Jeju, Korea. Jeju: IEEE, 2008: 878-883.
- [6] SIKDER J, SAREK K I, DAS U K. Fish disease detection system; a case study of freshwater fishes of Bangladesh [J]. International journal of advanced computer science and applications, 2021, 12(6): 867-871.
- [7] KHABUSI S P, HUANG Y P, LEE M F. Attention-based mechanism for fish disease classification in aquaculture [C]//2023 International Conference on System Science and Engineering (ICSSE), July 27-28, 2023, Ho Chi Minh, Vietnam. Ho Chi Minh: IEEE, 2023: 95-100.
- [8] KUMAR S, KARTHIKEYAN P, SURESHKUMAR C. Fish disease detection in aquaculture using pseudo hamiltonian neural network optimized with Philippine eagle optimization algorithm [J/OL]. Knowledge-based systems, 2025, 317: 113374 [2025-07-19]. <https://doi.org/10.1016/j.knsys.2025.113374>.
- [9] WALEED A, MEDHAT H, ESMAIL M, et al. Automatic recognition of fish diseases in fish farms [C]//2019 14th International Conference on Computer Engineering and Systems (ICCES), December 17-17, 2019, Cairo, Egypt. Cairo: IEEE, 2020: 201-206.
- [10] AHMED M S, AURPA T T, AZAD M A K. Fish disease detection using image based machine learning technique in aquaculture [J]. Journal of King Saud University (computer and information sciences), 2022, 34(8): 5170-5182.
- [11] 陈科, 周勇, 薛明洋, 等. 基于机器视觉和改进YOLOv5s的鲫病害轻量级无损检测模型 [J]. 水生生物学报, 2024, 48(7): 1141-1148. CHEN K, ZHOU Y, XUE M Y, et al. Lightweight nondestructive detection model of crucian carp disease based on machine vision and improved YOLOv5s [J]. Acta hydrobiologica sinica, 2024, 48(7): 1141-1148 (in Chinese with English abstract).
- [12] 荣弘扬, 汤永华, 林森, 等. 基于双通道分层协同的CEH-YOLOv8鱼体病害检测方法 [J]. 华中农业大学学报, 2025, 44(2): 83-93. RONG H Y, TANG Y H, LIN S, et al. A method of detecting fish diseases with CEH-YOLOv8 based on dual-channel and hierarchical synergism [J]. Journal of Huazhong Agricultural University, 2025, 44(2): 83-93 (in Chinese with English abstract).
- [13] LOU H T, DUAN X H, GUO J M, et al. DC-YOLOv8: small-size object detection algorithm based on camera sensor [J/OL]. Electronics, 2023, 12(10): 2323 [2025-07-19]. <https://doi.org/10.3390/electronics12102323>.
- [14] 杨大勇, 黄正栋, 郑昌贤, 等. 基于改进YOLOv8n的茶叶嫩梢检测方法 [J]. 农业工程学报, 2024, 40(12): 165-173. YANG D Y, HUANG Z Y, ZHENG C X, et al. Detecting tea shoots using improved YOLOv8n [J]. Transactions of the CSAE, 2024, 40(12): 165-173 (in Chinese with English abstract).
- [15] MA X, DAI X Y, BAI Y, et al. Rewrite the stars [C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 16-22, 2024, Seattle, WA, USA. Seattle: IEEE, 2024: 5694-5703.
- [16] 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), June 13-19, 2020, Seattle, WA, USA. Seattle: IEEE, 2020: 10778-10787.
- [17] 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, June 18-23, 2018, Salt Lake City, UT, USA. Salt Lake City IEEE, 2018: 8759-8768.
- [18] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]//Computer Vision - ECCV 2018: 15th European Conference, September 8 - 14, 2018, Munich, Germany. Cham: Springer, 2018: 3-19.
- [19] 袁杰, 谢霖伟, 郭旭, 等. 基于改进YOLOv7的苹果叶片病害检测方法 [J]. 农业机械学报, 2024, 55(11): 68-74. YUAN J, XIE L W, GUO X, et al. Apple leaf disease detection method based on improved YOLOv7 [J]. Transactions of the CSAM, 2024, 55(11): 68-74 (in Chinese with English abstract).
- [20] 田有文, 覃上声, 闫玉博, 等. 基于改进YOLOv8的田间复杂环境下蓝莓成熟度检测 [J]. 农业工程学报, 2024, 40(16): 153-162. TIAN Y W, QIN S S, YAN Y B, et al. Detecting blueberry maturity under complex field conditions using improved YOLOv8 [J]. Transactions of the CSAE, 2024, 40(16): 153-162 (in Chinese with English abstract).
- [21] GEVORGYAN Z. Siou loss: more powerful learning for bounding box regression [DB/OL]. arXiv, 2022: 2205.12740 [2025-07-19]. <https://arxiv.org/abs/2205.12740>.
- [22] WOO S, DEBNATH S, HU R H, et al. ConvNeXt V2: co-designing and scaling ConvNets with masked autoencoders [C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 17-24, 2023, Vancouver, BC, Canada. Vancouver: IEEE, 2023: 16133-16142.
- [23] QIN D F, LEICHNER C, DELAKIS M, et al. MobileNetV4: universal models for the mobile ecosystem [C]//Computer Vision - ECCV 2024: 18th European Conference, September 29 - October 4, 2024, Milan, Italy. Cham: Springer, 2025: 78-96.
- [24] CAI H, LI J Y, HU M Y, et al. EfficientViT: lightweight multi-scale attention for high-resolution dense prediction [C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV), October 1-6, 2023, Paris, France. Paris: IEEE, 2024: 17256-17267.
- [25] 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.
- [26] LIU W, ANGUOLOV D, ERHAN D, et al. SSD: single shot MultiBox detector [C]//Computer Vision - ECCV 2016.

- Cham: Springer, 2016: 21-37.
- [27] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]//2017 IEEE International Conference on Computer Vision (ICCV). October 22-29, 2017, Venice, Italy. Venice: IEEE, 2017: 2999-3007.
- [28] FU C Y, LIU W, RANGA A, et al. DSSD: deconvolutional single shot detector [DB/OL]. arXiv, 2017: 1701.06659 [2025-07-19]. <https://arxiv.org/abs/1701.06659>.
- [29] YANG C, HUANG Z H, WANG N Y. QueryDet: cascaded sparse query for accelerating high-resolution small object detection [C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 18-24, 2022, New Orleans, LA, USA. New Orleans: IEEE, 2022: 13658-13667.
- [30] WANG A, CHEN H, LIU L H, et al. YOLOv10: real-time end-to-end object detection [DB/OL]. arXiv, 2024: 2405.14458 [2025-07-19]. <https://arxiv.org/abs/2405.14458>.

Detecting characteristics of abnormal body surface in *Micropterus salmoides* under recirculating aquaculture systems based on YOLOv8-DBCS

ZHU Ming^{1,2}, WANG Rong¹, WAN Peng^{1,2}, LEI Xiang¹, FAN Hao¹

1. College of Engineering, Huazhong Agricultural University/Ministry of Agriculture and Rural Affairs Key Laboratory of Aquaculture Facilities Engineering, Wuhan 430070, China;
2. Ministry of Agriculture and Rural Affairs Key Laboratory of Agricultural Equipment in Mid-Lower Yangtze River, Wuhan 430070, China

Abstract *Micropterus salmoides* is prone to bacterial and viral infections under recirculating aquaculture systems (RAS). Characteristics of abnormal body surface in *M. salmoides* including redness and white spots may appear at the early stages of its illness. A YOLOv8-BCS model for detecting the characteristics of abnormal body surface in *M. salmoides* based on YOLOv8 was proposed to prevent large-scale mortality in aquaculture. A dynamic depthwise convolution (DConv) feature extraction network, DIStarNet, was proposed based on the StarNet network. DConv adaptively adjusted the convolution operation by designing a dynamic convolution kernel weight mechanism, thereby effectively capturing multi-scale feature information. A weighted bidirectional feature pyramid network (bi-directional feature pyramid network, BiFPN) was introduced into the neck network to enhance the feature fusion capability of multi-scale information from the backbone network. A convolutional block attention module (CBAM) attention mechanism was added before detection to improve the learning and extracting images of the characteristics of abnormal body surface in fish. The target recognition loss function was replaced with SCYLLA-intersection over union (SIoU) to improve the overlap between the model's predicted bounding boxes and the ground truth bounding boxes, thereby further enhancing the accuracy of recognizing the characteristics of abnormal body surface in fish. The results showed that YOLOv8 DBCS exhibited excellent performance of detection, with evaluation metrics including Precision, Recall, mAP₅₀, and mAP₅₀₋₉₅ being 95.8%, 92.4%, 97.5%, and 66.2%, respectively. Compared with that of the baseline model, these metrics increased by 3.6, 4.9, 7.0, and 3.4 percentage point, respectively. The model size of YOLOv8-DBCS was 1.85 million parameters, with a reduction of 38.5% compared with that of the baseline model. It will provide valuable reference for detecting the characteristics of abnormal body surface and early warning of diseases under recirculating aquaculture systems for *M. salmoides*.

Keywords detecting the characteristics of abnormal body surface; feature extraction network; feature pyramid network; attention mechanism; loss function; *Micropterus salmoides*; recirculating aquaculture systems (RAS)

(责任编辑:陆文昌)