doi:10.6041/j.issn.1000-1298.2025.06.052

基于轻量级 CDW - YOLO v7 的鱼类排便行为自动检测方法

徐龙琴[1,2]　郑钦月[1,3]　高学凯[1,2]　崔　猛[4]　刘双印[1,3]　谢彩健[1,2]

(1. 仲恺农业工程学院信息科学与技术学院, 广州 510225; 2. 仲恺农业工程学院智慧农业创新研究院, 广州 510225;
3. 天津农学院计算机与信息工程学院, 天津 300384; 4. 萨里大学视觉、语音和信号处理中心, 吉尔福德 GU2 7XH)

摘要: 粪便是集约化水产养殖系统中有机废物的主要来源,排便数量的增加和时间的延长都会加快养殖水质中氨氮、亚硝酸盐等污染物的积累浓度和速度,因此,排便行为模式对于维持最佳水环境和确保可持续的鱼类生产至关重要。为解决传统排便行为分析费时费力的问题,本研究提出一种基于改进 YOLO v7 - tiny 的高性能、轻量级的鱼类排便行为识别模型 CDW - YOLO v7。该模型采用基于 C2f 结构的双向特征金字塔网络(C2f - bidirectional feature pyramid network,C2f - BiFPN)优化识别排便行为的多尺度和非线性特征融合能力,同时引入具有注意力机制的动态检测头(Dynamic head,DyHead)以增强模型在复杂环境中对鱼类排便行为关键特征的提取能力,并结合 WIoU 损失函数,减少因鱼类遮挡、重叠等造成的漏检现象,提高模型的准确性。实验结果表明,与基线模型 YOLO v7 - tiny 相比,CDW - YOLO v7 模型具有更好的性能,参数量减少 2.56×10^6,浮点运算量降低 5.90×10^9,同时平均精度均值(mean Average Precision,mAP)提高 2.04 个百分点。此外,该模型在模型大小、精度和检测速度等方面,均优于 3 种经典目标检测算法(YOLO v3 - tiny、YOLO v4 - tiny 和 YOLO v5s)。本研究为鱼类排便行为的精准检测和智能化水产养殖系统的发展提供了理论基础。

关键词: 鱼类排便行为; 水产养殖; YOLO v7 - tiny; 目标检测

中图分类号: S951.2; TP391.4　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)06-0554-11　　**OSID**:

Automatic Detection of Fish Defecation Behavior Based on Lightweight CDW - YOLO v7

XU Longqin[1,2]　ZHENG Qinyue[1,3]　GAO Xuekai[1,2]　CUI Meng[4]　LIU Shuangyin[1,3]　XIE Caijian[1,2]

(1. *College of Information Science and Technology*, *Zhongkai University of Agriculture and Engineering*, *Guangzhou* 510225, *China*
2. *Academy of Intelligent Agricultural Engineering Innovations*,
Zhongkai University of Agriculture and Engineering, *Guangzhou* 510225, *China*
3. *College of Computer and Information Engineering*, *Tianjin Agricultural University*, *Tianjin* 300384, *China*
4. *Centre for Vision*, *Speech and Signal Processing* (*CVSSP*), *University of Surrey*, *Guildford GU*2 7*XH*, *UK*)

Abstract: Fecal defecation is a primary source of organic waste in intensive aquaculture systems. The increase in the amount of defecation and the extension of time will accelerate the accumulation of pollutants such as ammonia nitrogen and nitrite in the aquaculture water. Therefore, monitoring fish defecation behavior is essential for maintaining optimal water conditions and ensuring sustainable fish production. In order to solve the problem that traditional defecation behavior analysis is time-consuming and labor-intensive, a high-performance, lightweight fish defecation behavior recognition model CDW - YOLO v7 was proposed based on the innovative enhancement of the YOLO v7 - tiny. In the proposed model, a bidirectional feature pyramid network (C2f - BiFPN) was applied to optimize feature extraction within the neck network, a DyHead target detection head with an attention mechanism was utilized to accurately detect fish defecation behavior and strengthen relevant features, and the WIoU loss function

收稿日期: 2025 - 01 - 23　修回日期: 2025 - 02 - 14

基金项目: 国家自然科学基金项目(62373390)、广东省基础与应用基础研究项目(2023A1515011230)和广州市科技计划项目(2023E04J1238、2023E04J1239)

作者简介: 徐龙琴(1977—),女,教授,主要从事智慧农业和智能信息处理等研究,E-mail: longqinxu@zhku.edu.cn

通信作者: 谢彩健(1985—),女,讲师,博士,主要从事智慧农业和农业大数据等研究,E-mail: xiecaijian@zhuku.edu.cn

was incorporated to improve the accuracy of the model's outputs. Experimental results indicated that the performance of the CDW－YOLO v7 model was much better than that of the baseline YOLO v7－tiny model because reducing the number of parameters loading models by 2.56×10^6 and giga floating-point operations per second (GFLOPs) by 5.90×10^9, while increasing mean average precision (mAP) by 2.04 percentage points. Additionally, the proposed model surpassed three classic object detection algorithms (YOLO v3－tiny, YOLO v4－tiny, and YOLO v5s) when evaluating criteria such as model size, accuracy, and detection speed. The research result can provide a theoretical foundation for subsequent detection of fish health and establishing a quantitative relationship between fish behavior and water quality.

Key words: fish defecation behavior; aquaculture; YOLO v7－tiny; object detection

0　引言

作为水产养殖业的主要组成部分,鱼类的生产不仅为人类提供了丰富的优质蛋白质[1],同时促进了经济发展和社会稳定。罗非鱼因其生长迅速、抗逆性强和养殖技术成熟等特点,成为典型的高密度养殖品种。在高密度养殖过程中,鱼类粪便成为养殖水体主要的有机废物来源[2],排便物的数量与水质变化密切相关,水质参数(如氨氮、亚硝酸盐、溶解氧含量及 pH 值等)的波动,通常会随着排便物数量的变化而发生显著变化,这些水质参数的升高往往导致水质恶化[3]。因此,将排泄物数量与水质变化进行关联分析,已成为水质调控的重要研究方向。此外,排便时间长短直接影响水中污染物的积累速度和浓度,尤其是在水交换不足的情况下,长时间的排便积累会导致水质急剧恶化[4]。因此,排便行为的时间模式和规律性对于水质的长期稳定性至关重要,检测和控制鱼类排便行为成为维持水质稳定和保障鱼类可持续生产的关键措施。

传统的鱼类排便行为分析方法包括人工观察和水质检测等手段[5]。人工观察依赖于经验丰富的人员通过目视观察记录鱼类排便行为,耗费大量时间人力,且易受主观因素影响[6]。水质检测是通过定期采集养殖水体样本来检测其中的氨氮、磷等含量,从而间接评估鱼类的排便行为[7-9],这种方法虽能够提供排便产物的信息,但无法直接观察和量化鱼类排便行为,且其过程需要专门设备和复杂技术的支持[10]。这些传统方法存在明显的局限性,主要表现在耗费资源和无法准确实时检测鱼类排便行为[11]。因此,迫切需要开发更有效、更自动化的方法来检测鱼类排便行为。

目标检测模型是一种人工智能技术,旨在识别图像或视频中的特定对象并确定其位置和类别[12-13],在能够有效提高检测效率和数据准确性的同时,为深入研究鱼类排便的行为模式提供了可能。这些技术的不断发展为目标检测领域注入了新的活力[14-18]。在目标检测技术的众多创新中,YOLO(You only look once)系列模型的出现彻底改变了目标检测的局面,提供了快速、紧凑且准确的解决方案[19-20]。特别是 YOLO v5 和 YOLO v7 进一步提高了检测速度和准确性,实现了实时性和准确性之间更好的平衡[21]。这些特性使得基于 YOLO 的模型成为水产养殖领域的首选,尤其是针对小目标的检测和轻量化应用方面,最近的研究已经证明基于 YOLO 的模型在水产养殖中的有效性[22-26]。尽管取得了一定进展,但在实际养殖环境中检测鱼类的排便行为仍然存在挑战,背景复杂、鱼类遮挡、像素模糊和设备受限等因素降低了检测系统的准确性和可靠性,影响其实际应用。因此,提高基于 YOLO 的水产养殖检测模型的有效性至关重要。

针对水产养殖中排便行为的检测需求,本文采集一个综合性的鱼类排便行为数据集,并基于 YOLO v7－tiny 提出轻量级模型 CDW－YOLO v7。该模型在特征融合层中采用 C2f－BiFPN 结构,进一步优化多尺度和非线性特征的融合能力;将检测头替换为基于注意力机制的 DyHead 检测头,增强模型在复杂环境中对排便行为关键特征的提取能力;并采用 WIoU 损失函数,优化检测框与真实框之间的重叠不足,构建复杂环境下高识别率和轻量化的鱼类排便行为检测模型。

1　材料与方法

1.1　实验地点和环境

实验数据采集自广东省渔业技术推广站的循环水罗非鱼养殖车间,重点观察养殖期间罗非鱼的排便行为。其排便特征表现为腹部出现一段较长的排泄物,使用水下摄像机可以有效捕捉这一行为。

数据采集示意图如图 1 所示,主要由聚丙烯板构成的圆形鱼池、水下摄像机和计算机设备组成。循环养殖池直径为 2.7 m、高为 1 m、水深为 0.8 m,池内通过支架安装了一台 DS－2XC6244F－L 型海康威视摄像机,分辨率为 1 920 像素 ×1 080 像素,

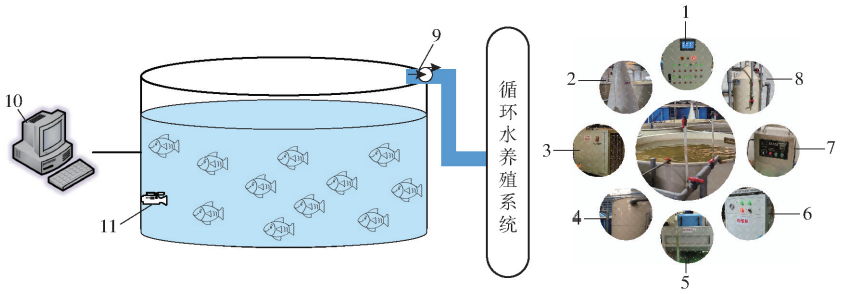

图 1 罗非鱼排便行为数据采集系统示意图

Fig. 1 Schematic representation of tilapia defecation behavior data acquisition system

1. 控制柜 2. 氧锥 3. 空气能恒温机 4. 生物塔 5. 微滤机 6. 制氧机 7. 臭氧发生器 8. 蛋白分离器 9. 水泵 10. 计算机 11. 摄像机

帧率设置为 25 f/s。养殖池内共饲养 50 条罗非鱼,平均每条约为 0.5 kg。为保持最佳的营养条件,每天 09:00 和 17:00 使用嘉盛饲料喂养罗非鱼两次,确保满足罗非鱼各阶段的营养需求。此外,传感器持续监测水产养殖系统中的水质指标,包括溶解氧含量、氨氮含量及 pH 值等,并保持在最佳范围内。

1.2 数据处理

收集了 35 个排便行为视频,平均时长为 70 min,帧率为 25 f/s。将获得的视频每 60 s 取一帧,共选取包含排便行为的图像 1 081 幅,其中最多可观察到 8 条罗非鱼的排便行为,部分情况下无此活动。使用图像注释软件 DarkLabel 注释数据,将视频分割成帧后标记存为排便行为的样本,生成包含排便信息和坐标数据的 txt 文件。

为方便训练和评估过程,将数据按比例 6∶2∶2 分为训练集、验证集和测试集,如表 1 所示。随机选择 691 幅图像作为训练集,173 幅图像作为验证集,217 幅图像作为测试集。

表 1 罗非鱼排便行为数据集

Tab. 1 Details of tilapia defecation behavior dataset

数据集	图像数量	标签数量
训练集	691	2 179
验证集	173	565
测试集	217	665

2 算法模型建立

图 2 为本文所提方法流程。首先,通过抽帧和裁剪采集的视频数据,构建罗非鱼排便行为数据集;然后,基于此数据集选择恰当的基准模型;针对实际水产养殖环境中复杂背景、鱼类遮挡和像素模糊等问题,改进基准模型,提高模型的识别效率;最后,将收集到的罗非鱼排便图像输入到改进 CDW-YOLO v7 模型中。

2.1 基于 YOLO v7-tiny 的改进模型

YOLO v7-tiny 是 YOLO v7 系列中规模最小的模型版本[27],其将模型重新参数化整合到网络架构,采用 YOLOX 的匹配策略[28],并集成 YOLO v5

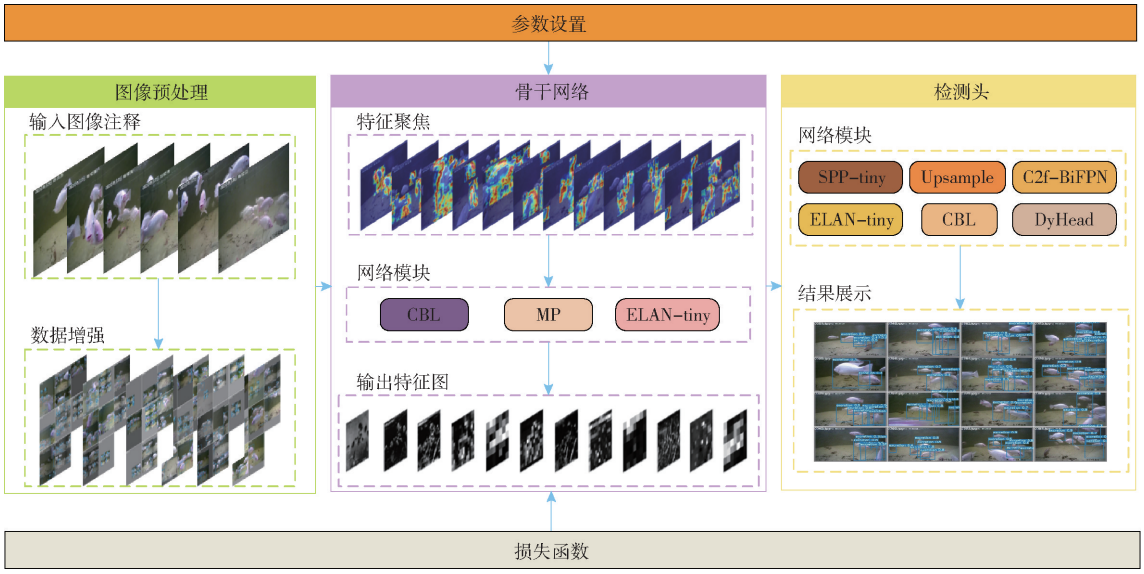

图 2 改进模型的训练流程图

Fig. 2 Pipeline of proposed model

的跨网格搜索标签分发策略，实现了 ELAN 高效的网络架构和辅助头训练。在本研究中，作为基准架构的 YOLO v7－tiny，由骨干网络、特征融合层和检测头 3 个核心组件组成。骨干网络作为特征提取的核心框架，负责从输入图像中提取特征并生成一系列特征图，这些特征图提供了有效代表鱼类排便行为的语义信息特征集。特征融合层是 YOLO v7－tiny 的特征融合网络，负责整合与鱼类排便行为相关的 3 种不同尺度的特征。检测头的作用是评估其预测的边界框是否与基于这些融合特征点的图像中描述的排便行为相一致。

在 YOLO v7－tiny 模型的基础上，本文所提出的算法引入了以下改进措施。首先，基于 C2f 引入了双向特征金字塔模块 C2f－BiFPN，同时将模型宽度减小到 0.5。然后，用 DyHead 检测头替换原来的检测头。最后，引入 WIoU 损失函数替换基线 YOLO v7－tiny 模型的 CIoU 损失函数。YOLO v7－tiny 架构的具体改进如图 3 所示。

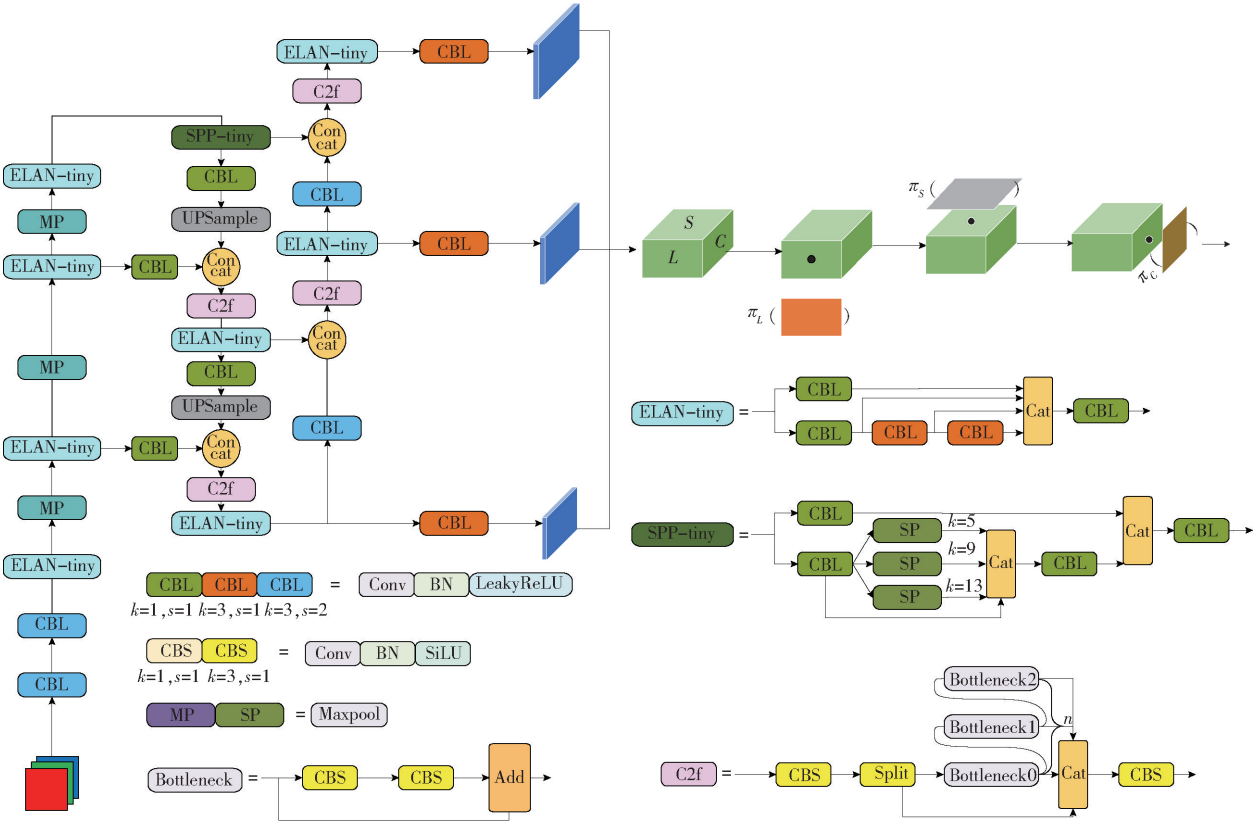

图 3　CDW－YOLO v7 网络结构图

Fig. 3　Structure of CDW－YOLO v7 network

2.1.1　C2f－BiFPN

浅层图像提供了更多的位置信息、目标的轮廓和边缘信息，从而提高了提取更精细目标特征的有效性。然而，在复杂背景罗非鱼排便识别场景中，图像数据存在气泡和光反射等现象，降低了行为特征的可见性，再经过多次卷积处理后，特征变得更加模糊。此外，罗非鱼间的相互遮挡也会对定位精度产生负面影响。为了解决这些问题，引入了 BiFPN 网络优化 YOLO v7－tiny 的颈部结构以增强网络合并更多特征信息的能力。

该结构由 3 个双向层组成，连接来自骨干网络不同层次的特征，每个双向层都有两条路径，并在原 PAFPN 结构的基础上增加了一条侧向路径，以增强特征图的表达能力。具体来说，将 C4 模块的输出特征图（对应于 16 倍下采样的特征图）与 P2 检测层所在的同尺度特征图融合，通过加权特征融合和快速归一化技术，实现了效率和准确性的平衡。

此外，C2f 结构将输入特征图通过第 1 个卷积层进行变换，输出两部分特征图，这些特征图经过不同的卷积层处理后合并，合并后的特征图再经过第 2 个卷积层处理，最终输出。这一设计提高了模型的非线性表示能力，能够更好地处理复杂的图像特征，从而在目标检测任务中取得更好的效果。在改进颈部连接后插入 C2f，增强了网络融合显著特征的能力，降低了上采样和下采样操作中关键特征信息的损失。改进网络结构如图 4 所示。

2.1.2　Dynamic Head

动态头[29]是一种将尺度感知、空间感知和任务感知统一在一起的新型动态检测头，其具体配置如图 5 所示。该设计将检测头的输入视为具有维度 ×

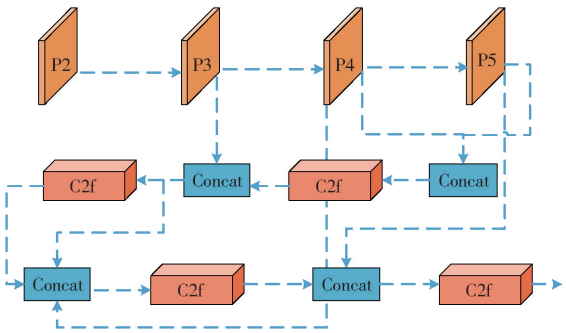

图 4 C2f - BiFPN 结构图

Fig. 4 Structure of C2f - BiFPN

空间 × 通道 3 维张量,在特征的每个特定维度上分别部署注意力机制。尺度感知注意力模块部署在水平维度上,学习各种语义级别的相对重要性,根据单个对象的规模将特征增强到适当级别。空间感知注意力模块部署在空间维度上,处理特征的高度和宽度,学习空间位置中连贯的判别表示。任务感知注意力模块部署在通道上,引导不同的特征通道根据对象的不同卷积核响应,更好地支持不同的任务。

通过骨干网络和特征金字塔网络的卷积处理

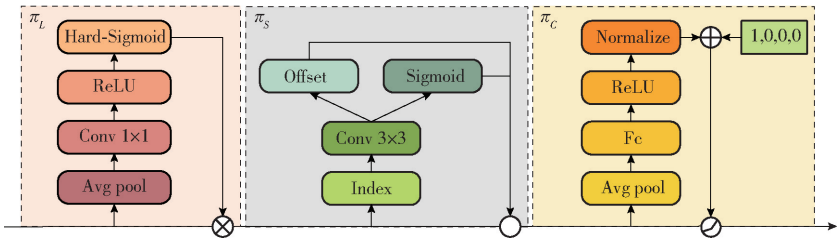

图 5 Dynamic Head 结构图

Fig. 5 Structure of Dynamic Head

后,图像调整为统一尺寸的三维特征向量 $\boldsymbol{F}\in\mathbf{R}^{L\times S\times C}$($L$ 表示金字塔层数,S 表示特征图宽度和高度的乘积,C 表示特征通道数),Dynamic Head 将基于全连接层实现的自注意力机制转换为 3 个连续的注意力,每个注意力仅关注一个视角,其计算公式为

$$W(\boldsymbol{F})=\pi_C(\pi_S(\pi_L(\boldsymbol{F})\boldsymbol{F})\boldsymbol{F})\boldsymbol{F} \tag{1}$$

式中 π_L——尺度感知注意力

π_S——空间感知注意力

π_C——任务感知注意力

根据不同尺度的语义重要性动态融合在输入的 L 维度上的特征操作,尺度感知注意力计算公式为

$$\pi_L(\boldsymbol{F})\boldsymbol{F}=\sigma\left(f\left(\frac{1}{SC}\sum_{S,C}\boldsymbol{F}\right)\right)\boldsymbol{F} \tag{2}$$

式中 $\sigma(\cdot)$——Hard-Sigmod 激活函数

$f(\cdot)$——1 × 1 卷积的线性函数

利用可变形卷积增强注意稀疏性,在同一空间位置进行跨层次特征聚合,空间感知注意力为

$$\pi_S(\boldsymbol{F})\boldsymbol{F}=\frac{1}{L}\sum_{l=1}^{L}\sum_{k=1}^{K}w_{l,k}\boldsymbol{F}(l;p_k+\Delta p_k;c)\Delta m_k \tag{3}$$

式中 K——稀疏采样位置数量

$w_{l,k}$——特定层 l 和特定采样位置 k 下权重

p_k——自学习空间采样位置

Δp_k——第 k 个采样位置的可学习空间偏移量

c——特征通道的索引,即第 c 个通道

Δm_k——位置处 p_k 自学习的重要性

通过开关控制超参数是否学习激活的阈值动态选择打开或关闭功能通道以支持不同的任务,任务感知注意力为

$$\pi_C(\boldsymbol{F})\boldsymbol{F}=\max(\alpha^1(\boldsymbol{F})\boldsymbol{F}_C+\beta^1(\boldsymbol{F}),\alpha^2(\boldsymbol{F})\boldsymbol{F}_C+\beta^2(\boldsymbol{F})) \tag{4}$$

式中 $\max(\cdot)$——超参数函数学习激活通道的阈值

α^1、α^2、β^1、β^2——学习控制激活阈值超函数

$\boldsymbol{F}_C$——第 c 通道分割的特征

该模块首先通过池化技术降低数据维度,再经过两个全连接层进一步处理,为确保数据适当,缩放和调整归一化步骤,生成最终的输出结果。

2.1.3 WIoU

当边界框之间无重叠区域时,CIoU 损失函数在反向传播过程中不产生有效梯度,导致重叠区域的宽度无法更新。为克服这一局限性,本研究提出一种边界框损失函数的优化方案,采用 WIoU 替代 CIoU,以提高检测框的收敛速度和准确性。

WIoU 损失函数的改进体现在 3 个版本中,各自针对不同的问题进行了优化。在 WIoU v1 中,采用了两层距离注意力机制,当锚框与目标框重合度较高时,会削弱几何因素的惩罚,从而更精准地回归排便区域的边界框。WIoU v2 在此基础上,借鉴了 Focal Loss 的单调聚焦机制,降低了简单示例对总损失值的影响,使得模型在处理较为复杂的鱼类排便样本时仍能保持较高的检测精度。进一步地,WIoU v3 引入了非单调聚焦系数,以应对低质量样本可能带来的有害梯度,从而保证模型在不同质量的锚框情况下能稳定训练,并适应复杂水下环境中的排便检测任务。

通过将 WIoU 损失函数应用于 CDW－YOLO v7 模型，有效地优化了目标框回归，提高鱼类排便区域的检测精度，并减少边界框收敛过程中的不稳定性，从而显著提高了模型在复杂水产环境下的性能。

2.2　模型评价指标

为了评估 CDW－YOLO v7 模型在罗非鱼排便行为识别方面的性能，使用行为识别任务领域中的标准评价指标，包括参数量、浮点运算量（Giga floating-point operations per second，GFLOPs）、精确率（Precision）、召回率（Recall）、F1 分数（F1 score）、平均精度均值（mean Average Precision，mAP）和帧率（FPS）。mAP@0.5 用来衡量模型在所有类别上的检测性能，mAP@0.5:0.95 是通过选取 10 个离散的 IoU 阈值对其对应的 mAP 结果进行均值计算所得。

3　结果与讨论

3.1　实验设置

模型训练过程中，使用 Adam 优化器，初始学习率设定为 0.01；训练轮次设置为 200，每批次包含 16 个样本；图像尺寸调整为标准的 640 像素×640 像素，IoU 阈值设置为 0.20。使用的实验硬件环境包括：CPU 为 Intel（R）Xeon（R）Gold 6146 CPU@3.20 GHz，GPU 为 24 GB 内存的 GeForce RTX 3090。实验软件环境基于 Ubuntu 16.04.7 操作系统，深度学习环境为 CUDA Toolkit 11.3.1 + CUDA 11.1 + PyTorch 1.10.0，编程语言为 Python 3.8。

3.2　排便行为识别结果

本文使用 YOLO v7－tiny 算法构建了鱼类排便行为识别模型 CDW－YOLO v7，研究绘制了 CDW－YOLO v7 在训练过程中的相关曲线，主要包括损失值（Loss）、mAP、Recall 和 Precison 曲线。如图 6a 和图 6b 所示，CDW－YOLO v7 的 Loss 曲线在训练和验证过程中均表现出稳定的下降趋势，证实了模型的可靠性。同时，如图 6c～6f 所示，mAP、Recall 和 Precision 在前 100 个训练轮次内快速增加，然后趋于稳定达到最优收敛。

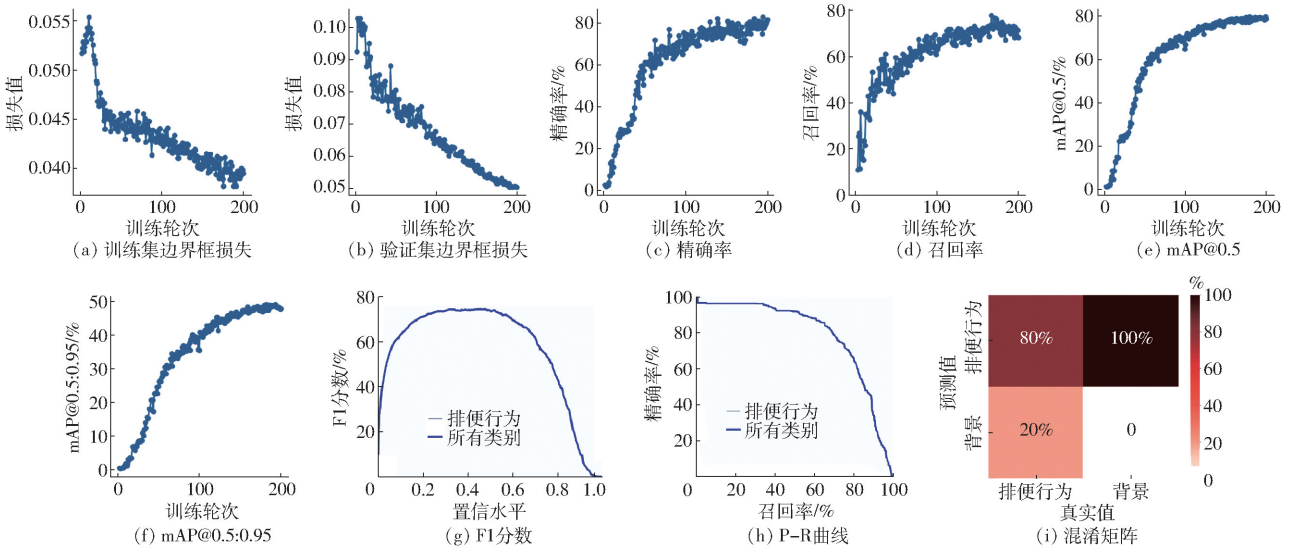

图 6　CDW－YOLO v7 模型的训练结果

Fig. 6　Training results of CDW－YOLO v7 model

为进一步验证模型，本研究在测试数据集上使用 CDW－YOLO v7 模型，生成与置信度得分相关的 F1 分数和 P－R 曲线。由图 6g 可知，置信度得分为 0.3～0.5，F1 分数较高；在置信水平为 0.456 时，平均 F1 分数达到峰值 74.0%。图 6h 展示了以 Recall 为横轴，Precision 为纵轴的 P－R 曲线，其覆盖面积即为 mAP 的值，达到 78.8%，优于在验证集上的表现。表明改进模型具有良好的鲁棒性，在未训练过数据上表现出色。

为对模型进行更详细评估，使用混淆矩阵作为评价指标，如图 6i 所示。可以看出，本文模型正确识别鱼类排便行为的准确率达到 80.0%，证实了其在检测和分类鱼类排便行为方面的有效性和可靠性。

3.3　模型性能分析

为了评估 CDW－YOLO v7 模型在鱼类排便行为识别方面的性能，使用相同的数据集对 5 个模型（YOLO v3－tiny[30]，YOLO v4－tiny[31]，YOLO v5s[32]，YOLO v7－tiny[33] 以及本文 CDW－YOLO v7）进行比较分析，结果见表 2。

由表 2 可知，CDW－YOLO v7 模型的 mAP 达到 79.99%，明显高于其他 4 种模型（YOLO v3－tiny 为 77.97%、YOLO v4－tiny 为 77.39%、YOLO v5s 为 78.45%、YOLO v7－tiny 为 77.95%）。这是因为该模型采用的 C2f－BiFPN 结构增加了额外的特征提取层，使其能够更有效地捕捉图像中的细节和特征。

表 2 不同算法结果对比

Tab. 2 Comparisons of different algorithms

模型	参数量	浮点运算量	精确率/%	召回率/%	mAP/%	帧率/(f·s^{-1})
YOLO v3 - tiny	8.67×10^{6}	1.30×10^{10}	79.41	70.99	77.97	259.1
YOLO v4 - tiny	5.87×10^{6}	1.62×10^{10}	54.91	84.25	77.39	371.0
YOLO v5s	7.02×10^{6}	1.59×10^{10}	74.45	75.75	78.45	134.0
YOLO v7 - tiny	6.01×10^{6}	1.32×10^{10}	73.66	73.66	77.95	59.0
CDW - YOLO v7	3.45×10^{6}	7.30×10^{9}	80.37	71.33	79.99	38.4

同时,模型精确率为 80.37%,明显优于 YOLO v3 - tiny(79.41%)、YOLO v4 - tiny(54.91%)、YOLO v5s(74.45%)、YOLO v7 - tiny(73.66%)。这表明该模型在区分鱼类是否表现出排便行为方面表现突出,有效减少了将非排便事件误报为排便事件的情况。然而,尽管 CDW - YOLO v7 模型在精确率上取得了较好的表现,但召回率仅为 71.33%,与 YOLO v3 - tiny(70.99%)相当,略低于 YOLO v5s(75.75%)和 YOLO v7 - tiny(73.66%),显著低于 YOLO v4 - tiny(84.25%)。这种差异归因于精确率与召回率之间的权衡,在优化模型精度的过程中,较高的置信阈值设置导致低置信目标被忽略,从而影响召回率。

为了实现轻量化设计,将 YOLO v7 - tiny 模型的宽度减半,相应地减少了每层的卷积核数量。在模型参数量与卷积核数量成正比的情况下,CDW - YOLO v7 的参数量仅为 3.45×10^{6},约为其他模型(YOLO v3 - tiny(8.67×10^{6})、YOLO v4 - tiny(5.87×10^{6})、YOLO v5s(7.02×10^{6})和 YOLO v7 - tiny(6.01×10^{6}))的一半左右。此外,C2f - BiFPN 模块引入的 Bottleneck 层采用 1×1 卷积和 3×3 卷积的组合,显著减少了模型的参数量。在计算复杂度方面,CDW - YOLO v7 的浮点运算量仅为 7.30×10^{9},比 YOLO v7 - tiny 的 1.32×10^{10}减少了 5.90×10^{9}。与 YOLO v3 - tiny(1.30×10^{10})、YOLO v4 - tiny(1.62×10^{10})和 YOLO v5s(1.59×10^{10})相比,CDW - YOLO v7 的性能优化更为显著,特别适合低功耗设备上的实时处理需求。值得注意的是,尽管 CDW - YOLO v7 的帧率为 38.4 f/s,低于 YOLO v3 - tiny(259.1 f/s)、YOLO v4 - tiny(371.0 f/s)、YOLO v5s(134.0 f/s)和 YOLO v7 - tiny(59.0 f/s),但在鱼类排便行为识别这样的低帧率应用场景中,这一帧率已经足够。因为排便行为通常持续一段时间,每秒处理几帧数据即可有效捕捉其特征。综上所述,CDW - YOLO v7 模型在轻量化设计、计算效率优化以及实时性能方面表现突出,非常适合于鱼类排便行为的识别应用。

3.4 不同场景下排便行为对比

为了全面评估 CDW - YOLO v7 模型的有效性,对其在鱼类遮挡和像素模糊等复杂场景中的检测结果进行了详细分析和比较。图 7 为在这些条件下鱼类排泄行为的检测结果,其中未检测到的排便行为以黄色三角形表示,错误检测用绿色圆圈表示。

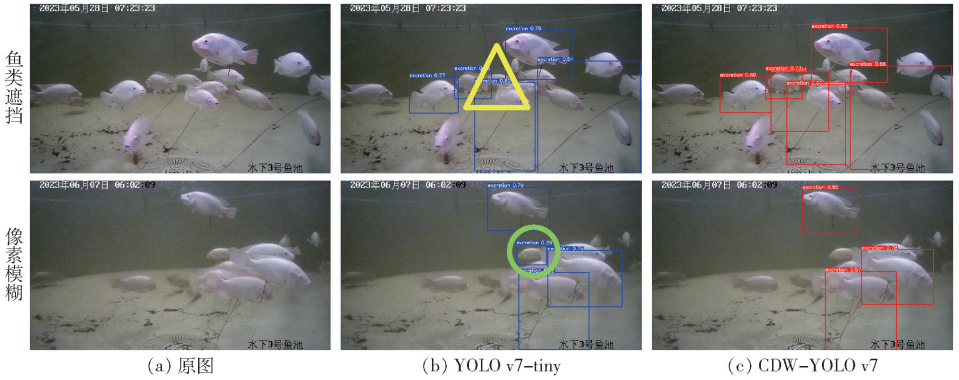

(a) 原图 (b) YOLO v7-tiny (c) CDW-YOLO v7

图 7 不同场景下排便行为对比结果

Fig. 7 Comparative results of defecation behavior under different scenarios

3.4.1 鱼类遮挡下排便行为对比

在循环水养殖池中,鱼类频繁地游动、聚集和觅食,导致它们在空间中频繁移动和重叠,从而增加了鱼类遮挡的可能性。在识别鱼类排便行为时,鱼类遮挡可能导致某些排便行为实例被部分或完全遮盖,增加了识别难度。特别是在严重遮挡情况下,模型可用信息减少,进而影响目标定位和边界框回归的准确性,表现为识别精度低、误检漏检现象严重。因此,本研究比较了不同模型在鱼类遮挡情况下的识别性能(图 7)。在鱼类遮挡情况下,YOLO v7 - tiny 模型未

能检测到黄色三角形标记的排便行为。相比之下，改进 CDW－YOLO v7 模型成功识别了这一行为，并且在其他排便行为的识别置信度得分上明显优于原始模型。这是因为改进 CDW－YOLO v7 模型有效地解决了部分遮挡问题。这是通过整合具备更强目标定位能力的 DyHead 检测头，并引入严格惩罚检测框与真实目标之间边界框重叠不足的 WIoU 损失函数，从而提高了部分遮挡下的目标识别能力。

3.4.2　像素模糊时排便行为对比

在养殖环境中，水中悬浮物和溶解物较多，如淤泥和有机物等，会导致水体浑浊，从而影响光的传播和反射。这些因素使得水下图像出现失真和像素模糊，严重影响了模型对目标行为的准确识别和分析能力。此外，水下环境中光线较弱，光的散射和吸收也会导致图像亮度不均和细节模糊，进一步降低图像清晰度。当图像像素模糊时，图像的清晰度和锐度会减弱，使得目标行为的特征不明显，难以准确提取和利用其关键信息。因此，模型表示特征能力受到影响，进而影响后续识别任务的准确性和稳定性。在像素模糊情况下不同模型的识别结果如图 7 所示。尽管 YOLO v7－tiny 和 CDW－YOLO v7 都能准确识别排便行为，但 YOLO v7－tiny 出现了误检现象（图 7 中的绿色圆圈）。这一现象的主要原因是 YOLO v7－tiny 的特征提取能力有限，无法有效处理模糊图像所带来的挑战。相反，CDW－YOLO v7 模型能够更高效地整合排便行为的多尺度非线性特征信息，从像素模糊图像中提取细节特征，从而减少误检现象的发生。

3.5　消融实验

为有效地展示本文所提改进模块对罗非鱼排便行为识别性能的影响，并验证 C2f－BiFPN 模块、DyHead 模块和 WIoU 损失函数 3 种改进策略所带来的性能提升，进行消融实验。表 3 为采用不同模块的检测模型性能差异。

表 3　消融实验结果

Tab.3　Results of ablation experiment

模型	宽度	C2f－BiFPN	DyHead	WIoU	参数量	浮点运算量	精确率/%	召回率/%	mAP/%	帧率/(f·s^{-1})
Model 1	1.0	×	×	×	6.01×10^{6}	1.32×10^{10}	73.66	73.26	77.95	59.0
Model 2	0.5	×	×	×	1.51×10^{6}	3.40×10^{9}	68.06	67.61	69.71	104.9
Model 3	0.5	√	×	×	2.59×10^{6}	6.00×10^{9}	71.22	70.95	73.83	106.6
Model 4	0.5	√	√	×	3.45×10^{6}	7.30×10^{9}	74.81	76.28	77.86	41.4
CDW－YOLO v7	0.5	√	√	√	3.45×10^{6}	7.30×10^{9}	80.37	71.33	79.99	38.4

注：√表示使用该模块，×表示不使用该模块。

由表 3 可知，使用宽度为 0.5 的 YOLO v7－tiny 模型，在引入 C2f－BiFPN 模块后，识别效果显著提升，模型的精确率和 mAP 分别提高 3.16、4.12 个百分点。在增强多层次特征融合的基础上，考虑鱼类排便行为特征的细节，引入自注意力机制，动态调整尺度、空间和任务 3 个维度的权重，自适应地聚合输入行为的特征。因此，与 YOLO v7－tiny－w ＋ C2f－BiFPN 相比，添加了 DyHead 检测头的模型精确率和 mAP 分别提高 3.59、4.03 个百分点。最后，引入了 WIoU 损失函数改善模型对目标边界框的拟合能力。在 YOLO v7－tiny－w＋C2f－BiFPN＋DyHead 模式下，精确率和 mAP 分别提高 5.56、2.13 个百分点。与 YOLO v7－tiny 基本模型相比，CDW－YOLO v7 模型的精确率和 mAP 分别提高 6.71、2.04 个百分点。同时，该优化策略使得参数量减少 2.56×10^{6}，浮点运算量减少 5.90×10^{9}。尽管召回率和帧率略有下降，但整体性能指标仍较好。综上所述，本研究通过多种优化改进提高了鱼类排便行为识别的准确性，每个模块均对性能提升做出了贡献，实现了性能和模型大小之间的最佳平衡。

为直观展示模型优化前后的变化，使用扩展梯度加权类激活映射（Extended gradient-weighted class activation mapping，XgradCAM）可视化模型的输出，结果如图 8～10 所示。在宽度为 0.5 的 YOLO v7－tiny 模型下，热力图的覆盖面积相对分散，仅覆盖了部分鱼体，甚至不能完全捕捉到排便行为，存在明显的不确定性和噪声。随着 C2f－BiFPN 模块、DyHead 检测头和 WIoU 损失函数的引入，热力图的覆盖区域逐渐变得更加集中和清晰。这些优化措施使模型能够捕获排便行为的关键细节，同时过滤掉无关的背景信息，提高了优化目标边界框预测的准确性和置信度。因此，CDW－YOLO v7 模型在复杂背景下具有强大的目标识别能力。

3.6　模型局限性

尽管改进 CDW－YOLO v7 模型在鱼类排便行为检测中展示了较高的准确性和实时性，但仍存在不足。首先，模型的泛化能力受到训练数据多样性的影响，由于实验数据主要来自特定环境，不同水

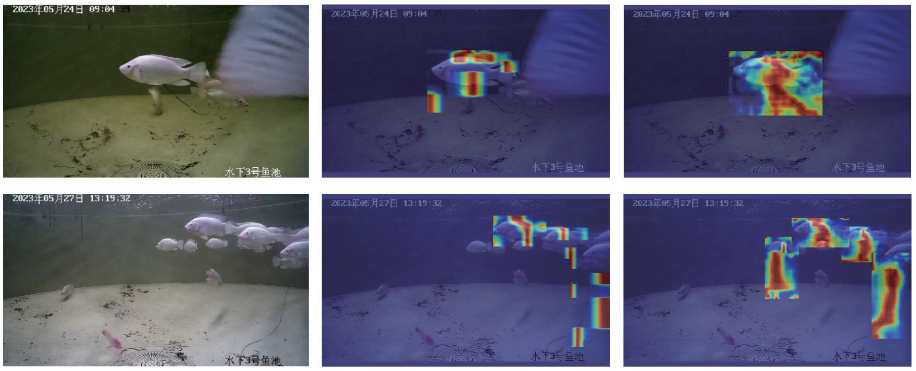

(a) 原图 (b) YOLO v7-tiny-w (c) YOLO v7-tiny-w+C2f-BiFPN

图 8 C2f - BiFPN 模块的可视化特征图

Fig. 8 Visualized feature maps of C2f - BiFPN module

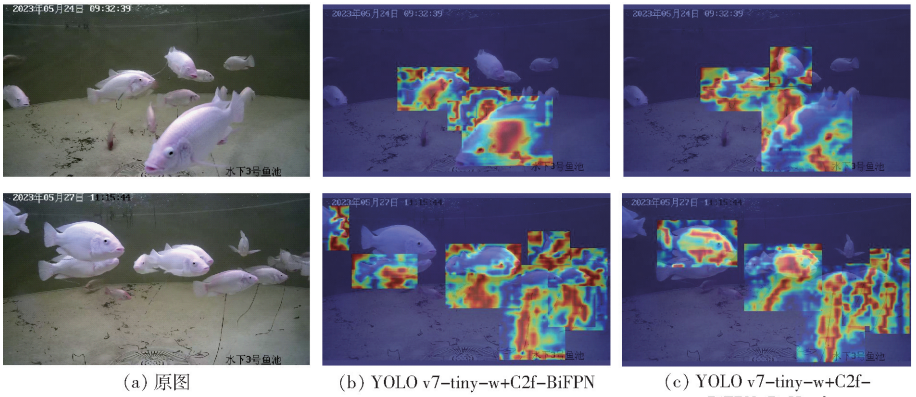

(a) 原图 (b) YOLO v7-tiny-w+C2f-BiFPN (c) YOLO v7-tiny-w+C2f-BiFPN+DyHead

图 9 DyHead 检测头的可视化特征图

Fig. 9 Visualized feature maps of DyHead detection head

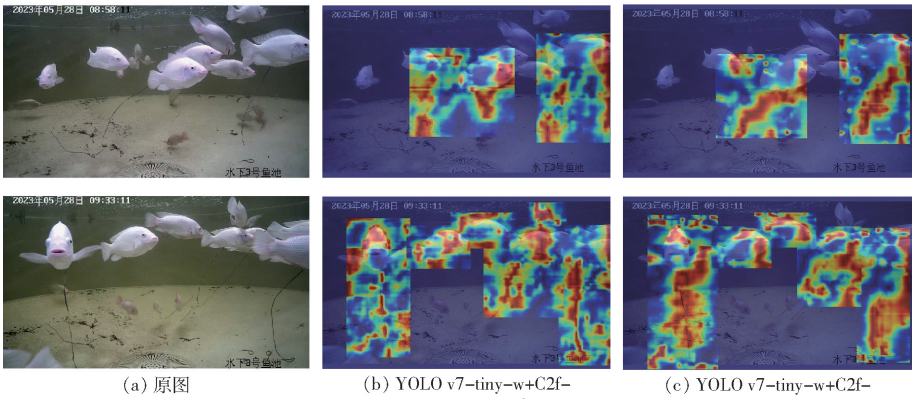

(a) 原图 (b) YOLO v7-tiny-w+C2f-BiFPN+DyHead (c) YOLO v7-tiny-w+C2f-BiFPN+DyHead+WIoU

图 10 WIoU 损失函数的可视化特征图

Fig. 10 Visualized feature maps of WIoU loss function

质、光照变化以及鱼类种类的差异可能会对检测效果产生影响,导致模型的适应性受到限制。其次,模型在处理小目标检测时存在一定困难,尤其在光照反射、水流扰动或鱼类快速游动的情况下,可能出现漏检或误检。特别是在复杂背景的环境中,检测效果仍有提升空间。此外,在高密度养殖环境中,模型可能难以有效区分重叠或遮挡的排便目标。目前的方法主要依赖于单帧图像进行检测,未充分利用时间序列信息,如果能够引入基于时序的特征融合或视频级别的分析,可能进一步提高检测的稳定性和鲁棒性。

4 结论

(1)提出了一种可用于罗非鱼排便行为自动检测的行为识别模型 CDW - YOLO v7。通过收集罗非鱼 35 个排便行为视频,共选取包含排便行为的图像 1 081 幅进行实验。结果表明,该模型将网络宽度缩小至 0.5,而且使用 C2f - BiFPN 结构替换 PAN 模块增强特征融合,实施具有自注意机制的 DyHead 检测头,并利用 WIoU 损失函数进行动态梯度调整,

由此模型的精确率提高 6.71 个百分点，达到 80.37%，同时减少模型参数。

（2）与 YOLO v3－tiny、YOLO v4－tiny、YOLO v5s、YOLO v7－tiny 等其他目标检测模型相比，改进 CDW－YOLO v7 模型对鱼类排便行为识别的综合效果最优。在模型参数量仅为 3.45×10^6 的前提下，其 mAP 最优（79.99%），显著优于其他模型，展示了轻量级高性能模型在水产养殖应用中的潜力。

参 考 文 献

[1] VERDEGEM M, BUSCHMANN A H, LATT U W, et al. The contribution of aquaculture systems to global aquaculture production[J]. Journal of the World Aquaculture Society, 2023, 54(2): 206－250.

[2] KOUL B, YAKOOB M, SHAH M P. Agricultural waste management strategies for environmental sustainability[J]. Environmental Research, 2022, 206: 112285.

[3] LAM S S, AMBAK M A, JUSOH A, et al. Waste excretion of marble goby (oxyeleotris marmorata bleeker) fed with different diets[J]. Aquaculture, 2008, 274(1): 49－56.

[4] LI H, CUI Z, CUI H, et al. Hazardous substances and their removal in recirculating aquaculture systems: a review[J]. Aquaculture, 2023, 569: 739399.

[5] SHREESHA S, PAI M M M, PAI R M, et al. Pattern detection and prediction using deep learning for intelligent decision support to identify fish behaviour in aquaculture[J]. Ecological Informatics, 2023, 78: 102287.

[6] ABANGAN A S, KOPP D, FAILETTAZ R. Artificial intelligence for fish behavior recognition may unlock fishing gear selectivity[J]. Frontiers in Marine Science, 2023, 10: 1010761.

[7] CHARY K, BRIGOLIN D, CALLIER M D. Farm-scale models in fish aquaculture-an overview of methods and applications[J]. Reviews in Aquaculture, 2022, 14(4): 2122－2157.

[8] LI H C, YU K W, LIEN C H, et al. Improving aquaculture water quality using dual-input fuzzy logic control for ammonia nitrogen management[J]. Journal of Marine Science and Engineering, 2023, 11(6): 1109.

[9] AREPALLI P G, NAIK K J. Water contamination analysis in IoT enabled aquaculture using deep learning based AODEGRU[J]. Ecological Informatics, 2024, 79: 102405.

[10] LI J, CHEN W, ZHU Y, et al. Intelligent detection and behavior tracking under ammonia nitrogen stress[J]. Neurocomputing, 2023, 559: 126809.

[11] SUN L, WANG B, YANG P, et al. Water quality parameter analysis model based on fish behavior[J]. Computers and Electronics in Agriculture, 2022, 203: 107500.

[12] XIN Z, CHEN S, WU T, et al. Few-shot object detection: research advances and challenges[J]. Information Fusion, 2024, 107: 102307.

[13] 袁红春,李春桥. 基于改进可变形卷积的 FDC－YOLO v8 水下生物目标检测方法研究[J]. 农业机械学报,2024,55(11):140－146.
YUAN Hongchun, LI Chunqiao. Research on FDC－YOLO v8 underwater biological object detection method improved by deformable convolution[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 140－146. (in Chinese)

[14] 张岚,邢博闻,李彩,等. 采用改进 SSD 网络的海参目标检测算法[J]. 农业工程学报,2022,38(8):297－303.
ZHANG Lan, XING Bowen, LI Cai, et al. Algorithm for detecting sea cucumbers based on improved SSD[J]. Transactions of the CSAE, 2022, 38(8): 297－303. (in Chinese)

[15] CAO S, ZHAO D, LIU X, et al. Real-time robust detector for underwater live crabs based on deep learning[J]. Computers and Electronics in Agriculture, 2020, 172: 105339.

[16] SUN H, YUE A, WU W, et al. Enhanced marine fish small sample image recognition with RVFL in Faster R－CNN model[J]. Aquaculture, 2025, 595: 741516.

[17] 孙龙清,孙希蓓,吴雨寒,等. 基于 DRN－Faster R－CNN 的复杂背景多目标鱼体检测模型[J]. 农业机械学报,2021,52(增刊):245－251,315.
SUN Longqing, SUN Xibei, WU Yuhan, et al. Multi-target fish detection model based on DRN－Faster R－CNN in complex background[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Supp.): 245－251, 315. (in Chinese)

[18] AKRAM W, HASSAN T, TOUBAR H, et al. Aquaculture defects recognition via multi-scale semantic segmentation[J]. Expert systems with applications, 2024, 237: 121197.

[19] 翟肇裕,张梓涵,徐焕良,等. YOLO 算法在动植物表型研究中应用综述[J]. 农业机械学报,2024,55(11):1－20.
ZHAI Zhaoyu, ZHANG Zihan, XU Huanliang, et al. Review of applying YOLO family algorithms to analyze animal and plant phenotype[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(11):1－20. (in Chinese)

[20] 郑荣才,谭鼎文,徐青,等. 基于改进 YOLO v7 的鲑鱼检测模型轻量化研究[J]. 农业机械学报,2024,55(11):132－139.
ZHENG Rongcai, TAN Dingwen, XU Qing, et al. Lightweight salmon detection model based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 132－139. (in Chinese)

[21] HUANG Y Z, HAN L, YANG X, et al. Enhanced batch sorting and rapid sensory analysis of mackerel products using YOLO

v5s algorithm and CBAM: validation through TPA, colorimeter, and PLSR analysis[J]. Food Chemistry: X, 2023, 19: 100733.
[22] ZHOU L, XIE X, JIANG L, et al. Diagnosis of cryptocaryoniasis in large yellow croaker (*Larimichthys crocea*) by real-time object detection based on YOLO v3[J]. Aquaculture, 2024, 581: 740418.
[23] PRASETYO E, SUCIATI N, FATICHAH C. YOLO v4 - tiny with wing convolution layer for detecting fish body part[J]. Computers and Electronics in Agriculture, 2022, 198: 107023.
[24] DU L, LU Z, LI D. A novel automatic detection method for breeding behavior of broodstock based on improved YOLO v5[J]. Computers and Electronics in Agriculture, 2023, 206: 107639.
[25] GAO X, YU A, TAN J, et al. GSD - YOLOX: lightweight and more accurate object detection models[J]. Journal of Visual Communication and Image Representation, 2024, 98: 104009.
[26] WANG H, ZHANG S, ZHAO S, et al. Fast detection of cannibalism behavior of juvenile fish based on deep learning[J]. Computers and Electronics in Agriculture, 2022, 198: 107033.
[27] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLO v7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464 - 7475.
[28] GE Z, LIU S, WANG F, et al. YOLOX: exceeding YOLO series in 2021[J]. arXiv Preprint, arXiv:2107.08430, 2021.
[29] DAI X, CHEN Y, XIAO B, et al. Dynamic head: unifying object detection heads with attentions[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 7373 - 7382.
[30] 李文涛,张岩,莫锦秋,等. 基于改进 YOLO v3 - tiny 的田间行人与农机障碍物检测[J]. 农业机械学报,2020,51(增刊1):1 - 8,33.
LI Wentao, ZHANG Yan, MO Jinqiu, et al. Detection of pedestrian and agricultural vehicles in field based on improved YOLO v3 - tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 1): 1 - 8, 33. (in Chinese)
[31] 刘莫尘,高甜甜,马宗旭,等. 基于 MSRCR - YOLO v4 - tiny 的田间玉米杂草检测模型[J]. 农业机械学报,2022,53(2): 246 - 255, 335.
LIU Mochen, GAO Tiantian, MA Zongxu, et al. Target detection model of corn weeds in filed environment based on MSRCR algorithm and YOLO v4 - tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 246 - 255, 335. (in Chinese)
[32] 李健源,柳春娜,卢晓春,等. 基于改进 YOLO v5s 和 TensorRT 部署的鱼道过鱼监测[J]. 农业机械学报,2022,53(12): 314 - 322.
LI Jianyuan, LIU Chunna, LU Xiaochun, et al. Fish passage monitoring based on improved YOLO v5s and TensorRT deployment[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(12): 314 - 322. (in Chinese)
[33] 王昱,姚兴智,李斌,等. 基于改进 YOLO v7 - tiny 的甜椒畸形果识别算法[J]. 农业机械学报,2023,54(11):236 - 246.
WANG Yu, YAO Xingzhi, LI Bin, et al. Malformed sweet pepper fruit identification algorithm based on improved YOLO v7 - tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 236 - 246. (in Chinese)

(上接第 526 页)

[18] AISHWARYA M P, REDDY A P. Dataset of groundnut plant leaf images for classification and detection[J]. Data in Brief, 2023, 48: 109185.
[19] SASMAL B, DAS A, DHAL K G, et al. A novel groundnut leaf dataset for detection and classification of groundnut leaf diseases[J]. Data in Brief, 2024, 55: 110763.
[20] JU R Y, CAI W. Fracture detection in pediatric wrist trauma X-rayimages using YOLO v8 algorithm[J]. Scientific Reports, 2023, 13(1): 20077.
[21] WANG C Y, YEH I H, LIAO H Y M. YOLO v9: learning what you want to learn using programmable gradient information [J]. arXiv Preprint, arXiv:2402.13616,2024.
[22] XIA Z, PAN X, SONG S, et al. Vision transformer with deformable attention[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 4794 - 4803.
[23] CAI X, LAI Q, WANG Y, et al. Poly kernel inception network for remote sensing detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 27706 - 27716.
[24] 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.
SHI Lei, YANG Chengkai, LEI jingkai, et al. Wheat spikelet detection of fusarium head blight based on improved YOLO v8s [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 280 - 289. (in Chinese)
[25] JIANG Y, TAN Z, WANG J, et al. GiraffeDet: a heavy-neck paradigm for object detection[J]. arXiv Preprint, arXiv:2202.04256, 2022.
[26] 李鑫,南新元. 基于改进 YOLO v7-tiny 算法的多种类不均衡样本水稻害虫检测[J]. 山东农业科学,2024,56(6):133 - 142.
LI Xin, NAN Xinyuan. Detection of rice pests in multi-species unbalanced samples based on improved YOLO v7-tiny algorithm [J]. Shandong Agricultural Sciences, 2024, 56(6): 133 - 142. (in Chinese)