doi:10.6041/j.issn.1000-1298.2025.10.010

融合多特征与分层超图网络的鱼类异常行为检测与分类方法

龙　伟[1,2]　孙翠锁[1]　张　辰[1]　蒋林华[1,2]　胡灵犀[1,3]　徐立鸿[4]

(1.湖州师范学院信息工程学院,湖州 313000;2.浙江-法国水域资源与环境数字化监控联合实验室,湖州 313000;
3.湖州师范学院湖州市水域机器人技术重点实验室,湖州 313000;4.同济大学电子与信息工程学院,上海 201804)

摘要:在现代智慧水产养殖过程中,鱼类异常行为的实时监测对于提升养殖管理水平、降低群体疾病风险和优化饲料投放具有重要意义。针对鱼类异常行为检测中常见的图像模糊、环境背景复杂、行为类型多样以及算法精度与效率难以兼顾等问题,提出了一种基于改进 YOLO 11 架构的高鲁棒性检测模型 YOLO 11 - AB。该模型在主干网络中引入多尺度卷积模块 C3k2_PKI Module,增强了对不同尺度行为特征的感知能力;在特征提取阶段集成了轻量级混合局部通道注意力机制(MLCA),有效融合通道与空间信息,提升了网络特征表达效果;在模型颈部结构中,采用基于超图的跨层级表征网络(HyperC2Net)与混合聚合网络(MANet),进一步强化了对复杂水下场景中异常行为特征的捕捉和判别能力。试验结果显示,该模型在检测精确率、计算效率和分类性能方面均较传统方法有显著提升,精确率提高 3.3 个百分点,召回率提高 5.9 个百分点,平均精确度提升 4.4 个百分点。该方法可为高密度工厂化养殖中鱼类疾病的早期预警与管理决策提供技术支持。

关键词:智慧水产养殖;异常行为检测;多尺度特征融合;注意力机制;YOLO 11 - AB 模型

中图分类号:TP391.4;S24　　**文献标识码**:A　　**文章编号**:1000-1298(2025)10-0102-08　　**OSID**:

Fish Abnormal Behavior Detection and Classification via Multi-feature Fusion and Multi-tiered Hypergraph Network

LONG Wei[1,2]　SUN Cuisuo[1]　ZHANG Chen[1]　JIANG Linhua[1,2]　HU Lingxi[1,3]　XU Lihong[4]

(1. *School of Information Engineering*, *Huzhou University*, *Huzhou* 313000, *China*
2. *Zhejiang - French Digital Monitoring Laboratory for Aquatic Resources and Environment*, *Huzhou* 313000, *China*
3. *Huzhou Key Laboratory of Waters Robotics Technology*, *Huzhou University*, *Huzhou* 313000, *China*
4. *College of Electronics and Information Engineeriing*, *Tongji University*, *Shanghai* 201804, *China*)

Abstract: Real-time monitoring of abnormal fish behaviors plays a crucial role in enhancing management efficiency, reducing disease risk, and optimizing feed strategies in modern intelligent aquaculture. To address challenges such as image blurring, complex backgrounds, behavioral diversity, and the trade-off between detection accuracy and computational efficiency, a robust detection model, YOLO 11 - AB, was presented based on an improved YOLO 11 architecture. The model incorporated a multi-scale convolution module (C3k2_PKI Module) in the backbone network to enhance perception of behavioral features at various scales. A lightweight mixed local channel attention (MLCA) mechanism was integrated into the feature extraction stage to effectively fuse channel and spatial information, thereby improving feature representation. Additionally, the neck of the model adopted a hypergraph-based cross-level representation network (HyperC2Net) and a mixed aggregation network (MANet), further strengthening the detection and discrimination of abnormal behaviors in complex underwater environments. Experimental results demonstrated that the proposed model achieved significant improvements in detection accuracy, computational efficiency, and classification performance, with a 3.3 percentage points increase in

收稿日期:2025-08-01　修回日期:2025-08-20

基金项目:国家自然科学基金项目(62175037)和湖州市重点研发计划农业“双强”专项(2022ZD2060)

作者简介:龙伟(1978—),男,讲师,博士,主要从事图像处理、人工智能、水产养殖中的视觉技术研究,E-mail:lw@zjhu.edu.cn

通信作者:徐立鸿(1960—),男,教授,博士生导师,主要从事水产养殖机器视觉技术研究,E-mail:xulihong@tongji.edu.cn

precision, a 5.9 percentage points increase in recall, and a 4.4 percentage points increase in mean average precision compared with traditional methods. This approach provided technical support for early warning and management of fish diseases in high-density factory aquaculture, offering practical value for enhancing efficiency and promoting the sustainable development of the aquaculture industry.

Key words: smart aquaculture; abnormal behavior detection; multi-scale feature fusion; attention mechanism; YOLO 11 – AB model

0　引言

近年来,全球水产养殖业向智能化、规模化方向快速发展,也为鱼类健康管理带来新的方法[1-3]。鱼类异常行为经常受外部水质环境[4]影响,传统人工监测方式依赖经验判断,存在效率低、实时性差、主观偏差大等问题,难以满足现代高密度养殖场景的需求。因此,智能化鱼类异常行为检测与分类技术成为水产养殖数字化[5]升级的核心研究方向,其目标在于通过计算机视觉与深度学习融合,实现精准、实时、自动化的鱼类健康监测[6-7],为预防鱼类疾病、水质调控、活跃度分析和精准饲喂提供技术支撑[8-10],对优化养殖管理具有重要实践价值。

随着深度学习技术和人工智能技术的发展,深度学习技术在鱼类异常行为检测与分类领域也被广泛应用[11-12]。汤永华等[13]采用一种多标签边界框损失函数来减少小目标病害检测的漏检率,但无法满足不同行为对空间定位精度的差异化需求。LI 等[14]使用马赛克图像融合增强鱼体图像的位置信息,提高了位置信息的提取能力。郑荣才等[15]采用改进的 YOLO v7 技术对鲑鱼进行检测,在精度上有一定提高,但在面对目标多样性方面还有改进空间;LI 等[16]通过集成一个新的语义分割分支来分割病鱼的感染区域,虽然可以提高病鱼的检测率,但是误检率也会随之上升;类似地,HUANG 等[17]使用 CBAM 注意力模块强化受感染鱼区来提炼鱼病的特征信息,但是忽略了其行为中包含的与鱼类健康状态相关的信息。王怡飞等[18]提出一种淡水鱼鱼病检测方法,但是对于要融合多层次上下文信息场景下的检测,表现效果欠佳。曹宇等[19]提出基于改进 YOLO v8n 的水下鱼类目标识别轻量化模型,在检测精度上有一定的提升,但是对于鱼体异常行为的多变性,容易忽略一些重要信息。LI 等[20]提出用于检测和计数复杂水下环境鱼类异常行为的网络,克服了真实水下环境中存在的一些遮挡严重、目标模糊的问题。CAI 等[21]使用改进的 YOLO v7 模型实现了鲤鱼春季病毒血症感染鱼群的检测,但是这种应用只适用于检测单一感染,并且模型的泛化性较差。这些基于深度学习的鱼类和鱼病目标检测方法为实现智能化水产养殖提供了新思路和新方法,但目前多数鱼类异常行为检测和分类方法存在鱼体目标模糊、遮挡导致漏检和误检,对鱼类异常行为的分析有限而无法具体确定鱼类异常的种类,以及无法平衡计算复杂度、检测速度和检测精度等问题。

针对上述问题,本研究提出基于改进 YOLO 11 的鱼类异常行为检测与分类方法,通过在骨干网络采用多尺度卷积模块 C3k2_PKI Module,可以针对不同尺度的行为特征进行感知;在主干特征提取层引入轻量级的混合局部通道注意力机制(Mixed local channel attention, MLCA),同时考虑通道信息和空间信息,并结合局部信息和全局信息以提高网络的表达效果;在模型颈部特征提取网络中引入基于超图的跨层级和跨位置表示网络 HyperC2Net 和混合聚合网络 MANet 以增强特征提取。该方法突破传统检测框架对静态图像处理的局限,解决传统鱼类异常检测模型在复杂水下环境中准确率低、泛化性差等缺陷,为构建智能化水产养殖监测系统提供新的技术路径,为预防鱼类疾病、优化水产养殖提供技术支撑。

1　数据集选择与扩充

水下养殖水体的环境波动会直接引发鱼类的应激反应和生理机能紊乱,其行为形态可以敏锐反映水体环境中的细微变化,并且处于繁殖初期的幼鱼因生理耐受性较低,易受养殖水体特性变化影响。故本研究中采用“东方鲀异常行为数据集”,该数据集搜集了真实养殖环境下 4 种典型的鱼类异常行为的 400 幅图像。对原始“东方鲀异常行为数据集”进行数据增强,最终扩充成 4 000 幅图像。这些行为表征为鱼类异常行为检测和分类提供了可靠的生物标志物。数据集中鱼体异常行为图像如图 1 所示。

2　检测与分类模型构建

2.1　改进 YOLO 11 – AB 网络结构

YOLO 11 是 Ultralytics 官方公司开发的最新一代目标检测模型[22]。YOLO 11 通过在特征提取中引入 C3k2、C2PSA 注意力机制,大幅提升了检测精

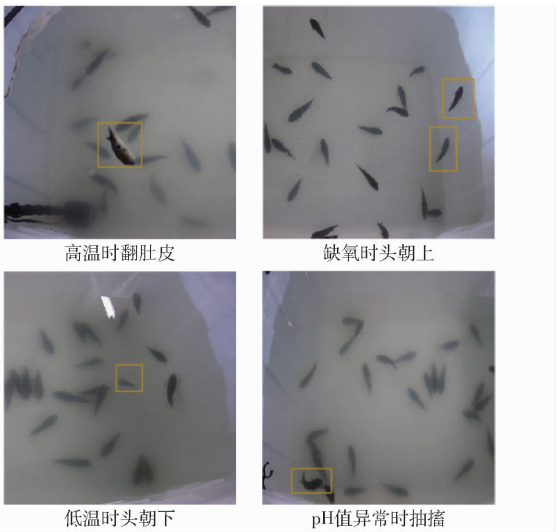


图 1 鱼体异常行为图像示例

Fig. 1 Images of fish abnormal behaviors

度与效率并保持轻量化的优势，显著强化了小目标检测与遮挡处理能力，成为兼顾精度、速度与跨场景适应性的目标检测算法。因此选用 YOLO 11 作为基础模型进行改进：设计替换原主干中的 C3k2 模块为 C3k2_PKI Module 来提供局部多尺度特征与全局上下文相结合的能力，更加丰富地提取鱼体形态、运动轨迹；引入轻量级的 MLCA 注意力机制模块，提高网络的表达效果；颈部采用 Hyper - YOLO 的 HyperC2Net 和 MANet 模块，丰富信息流并增强模型特征提取能力。改进后 YOLO 11 - AB 整体网络架构如图 2 所示。

2.2 C3k2_PKI Module 模块

鱼类的异常行为可能表现为不同尺度和频率的动作变化，C3k2_PKI Module 的多尺度卷积模块可以针对不同尺度的行为特征进行感知，如小卷积核分支能够捕捉细微局部动作[23]。这种多尺度特征提取使模型对不同幅度和频率的行为变化都更敏感。相比传统单一尺度的特征提取，C3k2_PKI Module 模块可以降低对异常行为的漏检率。其次 C3k2_PKI Module 提供局部多尺度特征与全局上下文相结合的能力，可以更加丰富地提取鱼体形态、运动轨迹。并且 C3k2_PKI Module 中的 CAA 上下文注意力机制[24]可以整合鱼体周围环境和鱼群行为的全局信息。因此，C3k2_PKI Module 模块可以提取到更具判别性的特征向量，在后续分类阶段提供更加可靠的依据。C3k2_PKI Module 模块用数学公式表示为

$$\begin{cases} L_{l-1,n} = \mathrm{conv}_{k_s \times k_s}(X^{(2)}_{l-1,n}) & (n = 0,1,\cdots,N_l - 1) \\ Z^{(m)}_{l-1,n} = \mathrm{DWConv}_{k^{(m)} \times k^{(m)}}(L_{l-1,n}) & (m = 1,2,3,4) \end{cases} \tag{1}$$

其中 $L_{l-1,n} \in \mathbf{R}^{\frac{C_l}{2} \times H_l \times W_l}$，是卷积提取的局部特征，$Z^{(m)}_{l-1,n} \in \mathbf{R}^{\frac{1}{2}C_l \times H_l \times W_l}$，是第 m 次深度卷积 DWConv[27] 提取的上下文特征。设置 $k_s = 3$，$k^{(m)} = 2(m+1) + 1$，PKI 模块不使用扩展卷积，是为了防止提取过于稀疏的特征表示，C3k2_PKI Module 结构图如图 3 所示。

2.3 MLCA 轻量化注意力模块

在鱼类异常行为检测中，鱼类的异常行为通常只体现在某一帧的某一小区域，MLCA 是一种通过融合局部通道交互与空间特征增强的注意力机制[28]，可以较低计算代价同时提升通道间依赖性与空间细节的捕捉能力。MLCA 注意力机制可以提高对局部关键异常区域的关注能力，有助于识别“异常游动”或“部分僵直”等微小的行为特征。

MLCA 在通道维度上，通过局部分组通道注意力对相邻通道进行动态权重分配，避免全局通道压缩造成的信息损失；在空间维度上，采用轻量级深度

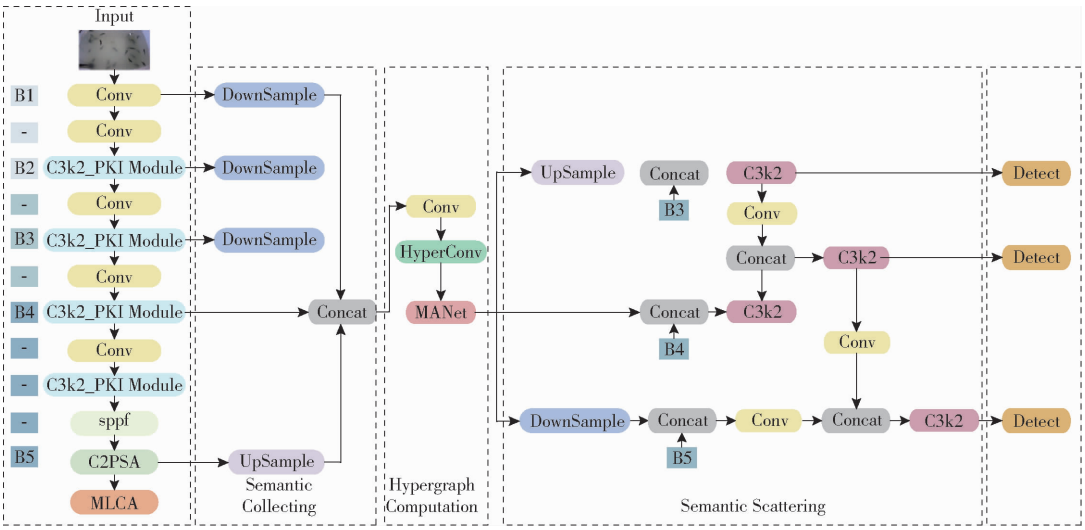


图 2 改进后的 YOLO 11 - AB 网络架构图

Fig. 2 Architecture diagram of improved YOLO 11 - AB network

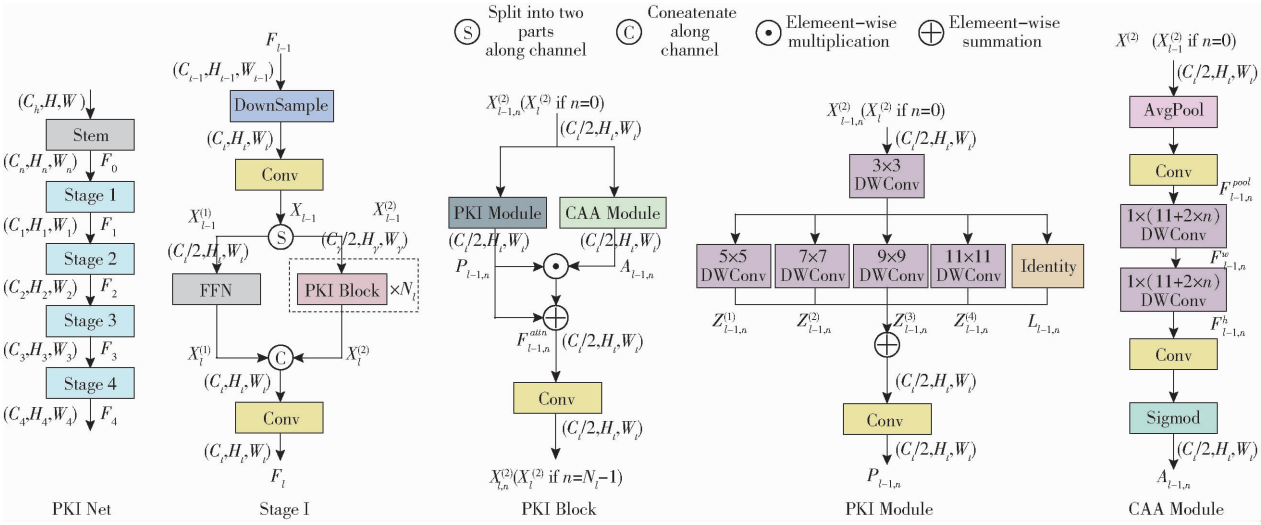


图 3　C3k2_PKI Module 结构图

Fig. 3　Structural diagram of C3k2_PKI Module

可分离卷积构建局部空间注意力，捕捉像素级空间上下文关系，强化目标边缘、纹理等细节特征的表达。2 种注意力模块的输出通过自适应加权融合，形成混合特征响应图，在减少参数量的前提下协同优化通道与空间信息的表征。MLCA 整体结构如图 4 所示。

2.4　HyperC2Net 网络

水下环境的复杂性导致捕获的鱼体图像常模糊不清，削弱了鱼体轮廓和运动轨迹的识别能力。这些问题降低了检测算法的整体性能，增加了误判和漏判的风险。HyperC2Net 是基于超图计算的语义收集与分散框架 HGC－SCS（Hypergraph computation empowered semantic collecting and scattering）的一种实现，能够捕捉语义空间中的潜在高阶相关性[29]。HyperC2Net 通过超网络驱动的动态卷积参数与多尺度时空特征融合机制，有效解决了传统鱼类异常检测模型在复杂水下环境中的准确率低、泛化性差等缺陷。因此通过将 HyperC2Net 网络引入到特征提取网络中捕捉局部动作细节与整体动作趋势，全面融合来自骨干网络的跨层级与跨位置信息，HyperC2Net 网络结构图如图 5 所示。

2.5　MANet 混合聚合网络网络

MANet 是一种面向复杂视觉任务设计的深度神经网络架构，其核心思想是通过多模态特征融合与动态权重分配机制，实现对不同层次、尺度特征的协同优化与高效利用。针对水下光照变化等干扰，MANet 在特征聚合阶段引入跨尺度交互模块，利用空洞卷积与可变形卷积增强空间感知范围，同时结合通道注意力机制优化特征通道的贡献权重，有效缓解水下图像模糊、目标变形带来的识别偏差。MANet 网络结构图如图 6 所示。

MANet 协同融合 3 种典型卷积变体：用于通道特征重新校准的 1×1 旁路卷积，用于有效空间特征处理的深度可分离卷积（DSConv），以及用于增强特征层次整合的模块。这种融合在训练阶段产生了更加多样化和丰富的梯度流，这放大了 5 个关键阶段中每个基本特征中封装的语义深度。MANet 可以表述为

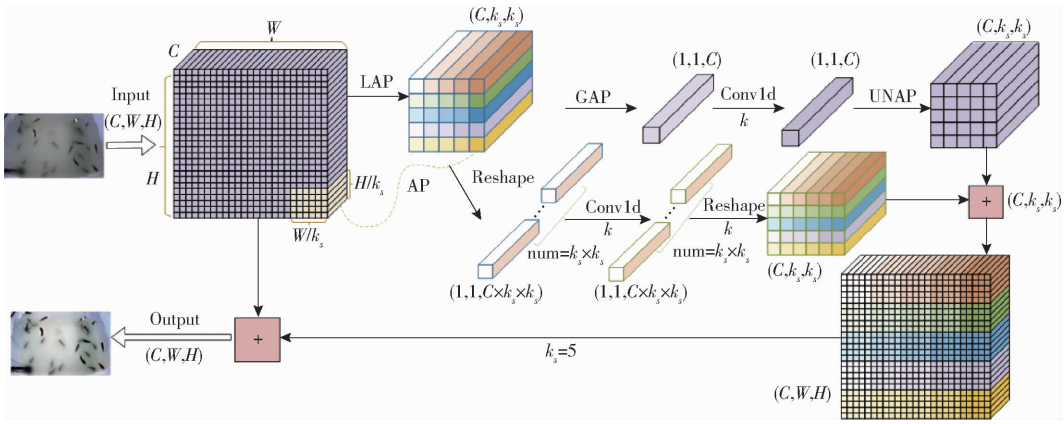


图 4　MLCA 算法原理图

Fig. 4　Schematic of MLCA

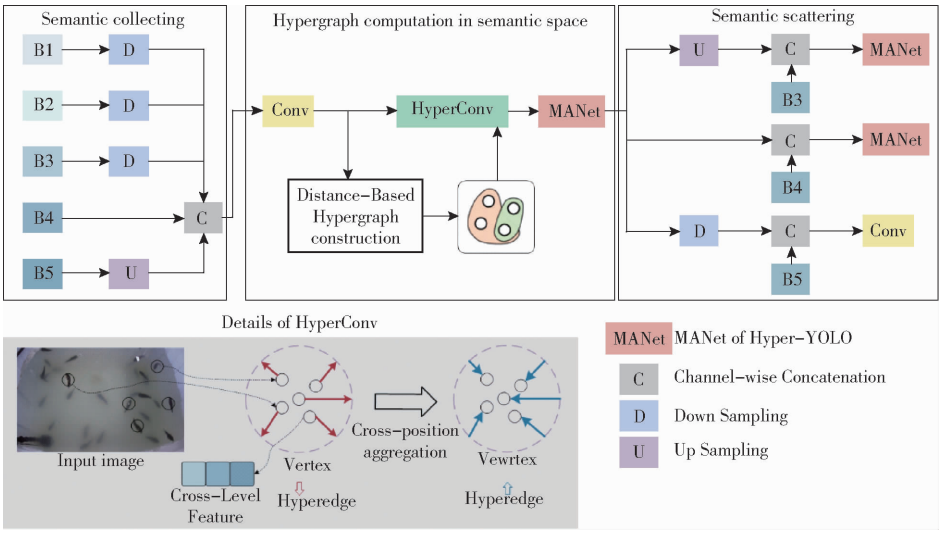


图 5 HyperC2Net 网络结构图

Fig. 5 Structural diagram of HyperC2Net net

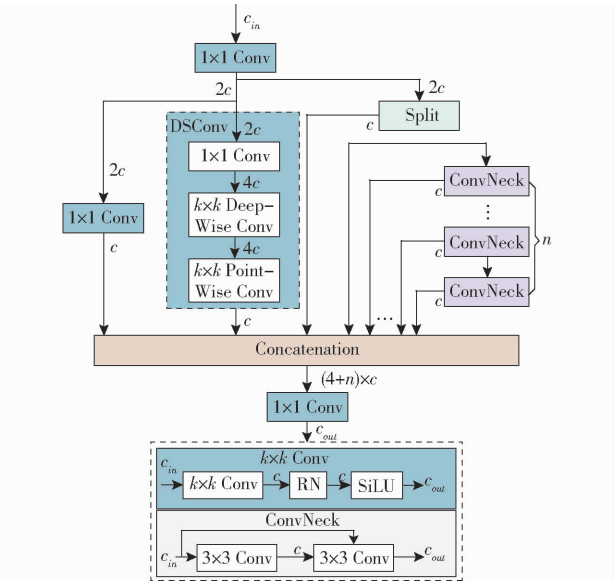


图 6 MANet 网络结构图

Fig. 6 Structure of MANet

$$\begin{cases} X_{mid} = \mathrm{Conv}_1(X_{mid}) \\ X_1 = \mathrm{Conv}_2(X_{mid}) \\ X_2 = \mathrm{DSConv}(\mathrm{Conv}_3(X_{mid})) \\ X_3 = X_4 = \mathrm{Split}(X_{mid}) \\ X_5 = \mathrm{ConvNeck}_1(X_4) + X_4 \\ X_6 = \mathrm{ConvNeck}_2(X_5) + X_5 \\ \vdots \\ X_{4+n} = \mathrm{ConvNeck}_n(X_{3+n}) + X_{3+n} \end{cases} \tag{2}$$

其中 X_{mid} 的通道号为 $2c$。而 $X_1, X_2, \cdots, X_{4+n}$ 的特征通道计数为 c。最后，通过一个串联操作来融合和压缩这 3 种类型特征的语义信息。

3 试验

3.1 试验环境及评价指标

本研究模型构建在 PyTorch 深度学习框架之上，并在 Ubuntu 22.4 操作系统环境下进行试验。PyTorch 版本为 2.3.1，搭配的 Python 版本为 3.10.14。模型训练任务在配备 NVIDIA A100 - PCIE - 40GB * 3 的 GPU 上执行。为了确保模型训练的一致性和可重复性，输入图像被标准化为 640 像素 ×640 像素。在训练过程中，Batch - Size 设置为 32，共进行 200 个周期轮次训练。学习率设定为 0.01，动量参数设置为 0.937，选用随机梯度下降（SGD）作为优化器。以精确率（Precision，P）、召回率（Recall，R）、平均精确度（mAP50）、参数量（Params）、浮点运算量（FLOPs）、帧率（FPS）为主要评价指标进行试验比较。

3.2 模型对比试验

为了进一步验证所提模型 YOLO 11 - AB 的检测性能和先进性，将其与 Faster R - CNN、SSD、YOLO 系列其他算法以及基准模型 YOLO 11 几种主流水下目标检测算法进行对比试验，统一在“东方鲀异常行为数据集”上，以及在同一训练环境和超参数下训练网络模型。对比试验结果如表 1 所示。

Faster R - CNN 是两阶段目标检测算法[30]，计算复杂度和时间开销较大，识别速度慢，模型复杂度高，故无法用来检测和分类水下复杂环境的鱼类异常行为。SSD 算法[31]和 YOLO 系列算法一样都是单阶段目标检测算法，在识别速度和小目标检测场景下较 Faster R - CNN 有一定程度的提升。然而 SSD 需要在多个尺度的特征图上进行检测，增加了模型复杂度。由表 1 可以看出，与 Faster R - CNN、SSD、YOLO v7[32]、YOLO v8[33]、YOLO v10[34]几种模型对比，本试验提出的 YOLO 11 - AB 网络模型平均精确度最高，为 83.2%，同时帧率也是最高，为

128.5 f/s。此外 YOLO 11－AB 模型轻量化程度也比其他模型高，其参数量、浮点运算量分别为 2.5×10^6、6.3×10^9。通过以上对比试验结果表明，YOLO 11－AB 模型在面对水下复杂场景的鱼类异常行为检测和分类精度表现最佳的同时，模型复杂度最低，识别速度也满足实时识别，适用于水下复杂场景下的鱼类异常行为检测和分类任务。不同模型检测的性能对比如图 7 所示。

表 1　对比试验结果

Tab.1　Comparative experiment results

模型	精确率/%	召回率/%	平均精确度/%	参数量	浮点运算量	帧率/(f·s^{-1})
Faster R－CNN	54.8	45.6	57.4	3.96×10^7	2.0×10^{11}	17.4
SSD	62.5	55.6	63.8	3.58×10^7	8.96×10^{10}	5.2
YOLO v7	70.2	78.5	75.3	2.96×10^7	5.0×10^9	94.8
YOLO v8	84.5	77.6	77.6	3.1×10^6	7.4×10^9	101.2
YOLO v10	71.3	72.4	77.5	2.9×10^6	7.6×10^9	51.8
YOLO 11	82.2	71.7	78.8	2.6×10^6	6.5×10^9	94.6
YOLO 11－AB	85.5	77.6	83.2	2.5×10^6	6.3×10^9	128.5

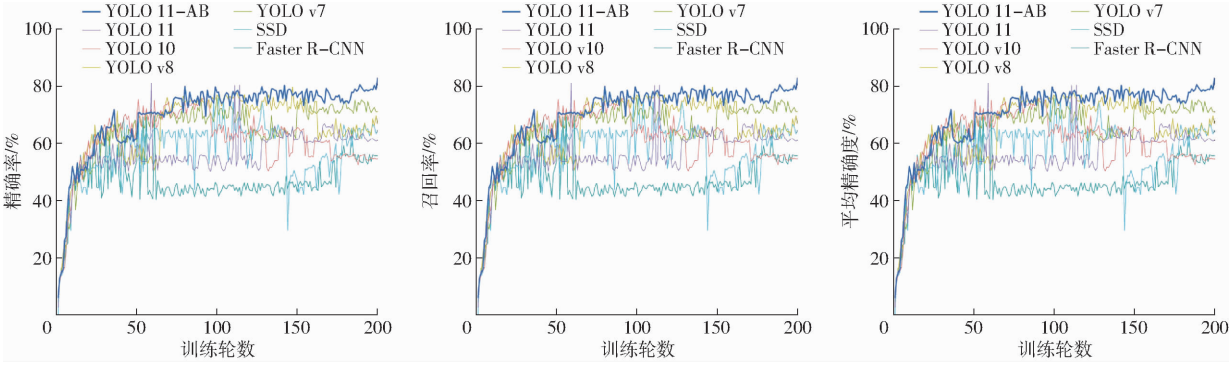


图 7　模型性能曲线

Fig.7　Performance comparison chart of models

3.3　模型消融试验

在同一数据集、训练环境和超参数下共进行 7 组消融试验，不同改进模型消融试验结果如表 2 所示。

表 2　消融试验结果

Tab.2　Ablation experiment results

模型	C3k2_PKI	MLCA	HyperC2Net	精确率/%	召回率/%	平均精确度/%	帧率/(f·s^{-1})
YOLO 11	×	×	×	82.2	71.7	78.8	94.6
Model 1	√	×	×	83.4	72.5	79.2	70.2
Model 2	×	√	×	82.7	70.6	79.7	95.8
Model 3	×	×	√	84.3	73.7	80.1	78.6
Model 4	√	√	×	85.8	75.1	78.9	56.7
Model 5	√	×	√	86.2	75.9	79.0	56.3
Model 6	×	√	√	86.9	77.4	79.0	59.8
YOLO 11－AB	√	√	√	85.5	77.6	83.2	128.5

注：√表示采用此模块，×表示未采用此模块。

由表 2 可知，原始 YOLO 11 模型的平均精确度为 78.8%，精确率为 82.2%，召回率为 71.7%，帧率为 94.6 f/s。在仅分别引入和改进 C3k2_PKI 模块、MLCA 模块、HyperC2Net 模块时，精确率和召回率也有相应的提升，证明了试验的有效性。在 Backbone 层特征提取替换为 C3k2_PKI 模块的同时，引入 MLCA 注意力机制模块和 Neck 层采用 Hyper－YOLO 中的 HyperC2Net 网络，相比于原模型平均精确度提高 4.4 个百分点，精确率提高 3.3 个百分点，召回率提高 5.9 个百分点，且帧率也提高 33.9 f/s，实时性得到一定提高。

总体来说，在 Backbone 网络将特征提取层替换为 C3k2_PKI 模块的同时引入 MLCA 注意力机制模块，Neck 层采用 Hyper－YOLO 中的 HyperC2Net 网络的模型效果相比于其他几种模型检测精度更佳，有较好的集成度。

3.4 对比结果可视化分析

如图 8、9 所示，分别从温度、pH 值和水体溶解氧浓度等实际养殖场景最容易遇到的异常情况以及不同光照、不同密度、水体模糊几种复杂环境进行了对比分析，YOLO 11 - AB 相比 YOLO 11 在多鱼体图像检测和分类中检测精度更高，同时没有出现漏检和低质量锚框。综上所述，改进模型在检测和分类任务中表现最优，适应性良好，鲁棒性强，对鱼体特征的分析能力更强，充分验证所提改进模型的可行性。

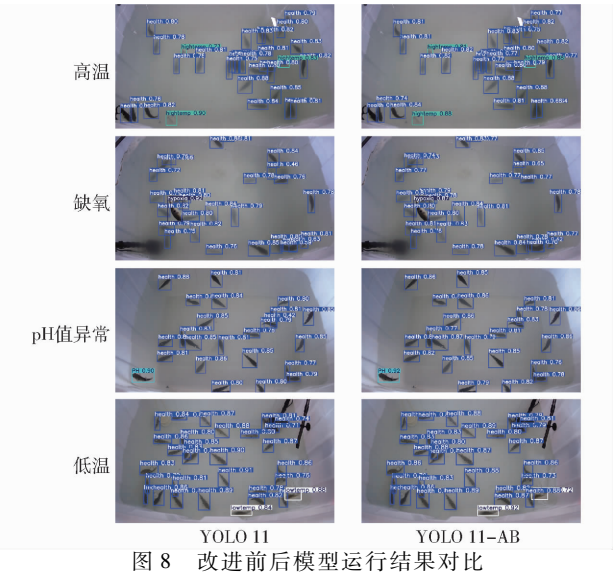


图 8 改进前后模型运行结果对比

Fig. 8 Comparison of original and improved model performance

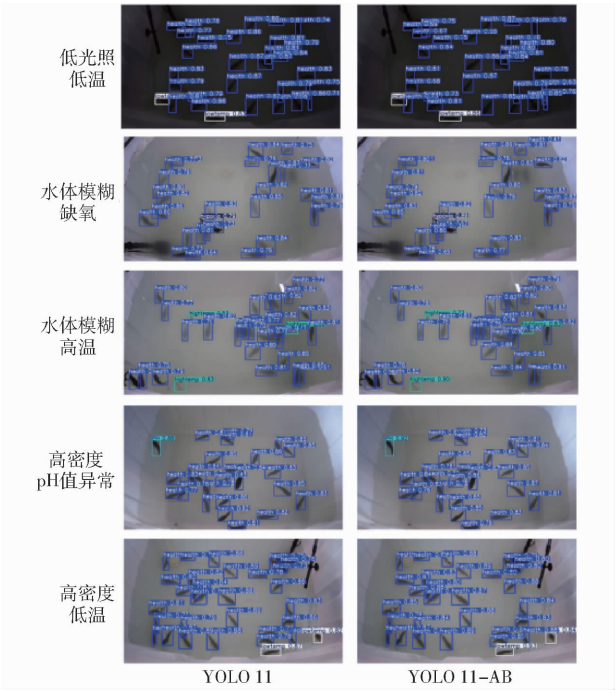


图 9 不同环境下运行结果对比

Fig. 9 Comparison of operation results in different environments

4 结束语

针对水下复杂环境中鱼类异常行为检测与分类的难题，提出了一种基于 YOLO 11 架构的高精度检测与分类算法 YOLO 11 - AB。通过引入多尺度卷积模块 C3k2_PKI Module，模型能够更充分地感知鱼体在不同尺度下的形态特征和运动轨迹，增强了对局部细节与全局信息的提取能力。轻量级混合局部通道注意力机制（MLCA）的集成，显著增强了对关键异常区域的关注。针对水下环境中复杂干扰因素，模型颈部采用 HyperC2Net 网络，通过动态卷积参数与多尺度时空特征融合，显著提高了模型在复杂场景下的检测准确率和泛化能力。试验结果表明，YOLO 11 - AB 模型在检测精度、计算效率及异常行为分类性能等方面均优于传统方法。YOLO 11 - AB 模型很好地展现出在水产养殖领域的应用前景，不仅能够降低养殖过程中的人工和管理成本，还能在水下复杂环境的条件下，及时识别出鱼类的异常行为，从而实现疾病早期预警，可以大大提升水产养殖的质量和降低养殖户经济损失，对水产养殖行业具有积极意义。

参 考 文 献

[1] 聂鹏程，钱程，汪清平，等. 赤点石斑鱼氨氮应激行为嵌入式表征研究[J]. 农业机械学报，2025，56(2)：503 - 510，522.
NIE Pengcheng，QIAN Cheng，WANG Qingping，et al. Embedded behavioral characterization of ammonia-nitrogen stress response in *Epinephelus akaara*[J]. Transactions of the Chinese Society for Agricultural Machinery，2025，56(2)：503 - 510，522. (in Chinese)

[2] 李道亮，姜国旗，杨建安，等. 基于计算机视觉的鱼类低氧胁迫行为检测与跟踪算法[J]. 农业机械学报，2023，54(10)：399 - 406.
LI Daoliang，JIANG Guoqi，YANG Jian'an，et al. Computer vision-based detection and tracking algorithm for hypoxic stress behavior in fish[J]. Transactions of the Chinese Society for Agricultural Machinery，2023，54(10)：399 - 406. (in Chinese)

[3] 存英. 智慧渔业赋能水产种业的研究应用与发展[J]. 高科技与产业化，2025，31(2)：11 - 13.
CUN Ying. Smart fisheries empowering aquaculture seed industry：research，applications and development[J]. High Technology and Industrialization，2025，31(2)：11 - 13. (in Chinese)

[4] MUSTAFA H，MUSTAPHA A，HAYDER G，et al. Applications of IoT and artificial intelligence in water quality monitoring and prediction：a review[C]//2021 6th International Conference on Inventive Computation Technologies (ICICT). IEEE，2021：

968 – 975.

[5] LIU Chunhong, WANG Zhiyong, LI Yachao, et al. Research progress of computer vision technology in abnormal fish detection [J]. Aquacultural Engineering, 2023, 103: 102350.

[6] CUI Meng, LIU Xubo, LIU Haohe, et al. Fish tracking, counting, and behaviour analysis in digital aquaculture: a comprehensive survey[J]. Reviews in Aquaculture, 2025, 17(1): e13001.

[7] MANDAL A, GHOSH A R. Role of artificial intelligence (AI) in fish growth and health status monitoring: a review on sustainable aquaculture[J]. Aquaculture International, 2024, 32(3): 2791 – 2820.

[8] 范世领. 淡水鱼类病害监测与防治技术[J]. 当代水产, 2024, 49(6): 70 – 72.
FAN Shiling. Monitoring and prevention technologies for freshwater fish diseases[J]. Contemporary Aquaculture, 2024, 49(6): 70 – 72. (in Chinese)

[9] ALY S M, FATHI M. Advancing aquaculture biosecurity: a scientometric analysis and future outlook for disease prevention and environmental sustainability[J]. Aquaculture International, 2024, 32(7): 8763 – 8789.

[10] 郑亚澎, 张璐, 刘尊续. 双目视觉下基于 NGBoost 的鱼体质量估算方法[J]. 农业机械学报, 2024, 55(增刊 2): 294 – 302.
ZHENG Yapeng, ZHANG Lu, LIU Zunxu. Fish mass estimation method based on NGBoost under binocular vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(Supp. 2): 294 – 302. (in Chinese)

[11] 徐立鸿, 崔钰惠, 刘世晶, 等. 基于帧间深度特征差分的大西洋鲑鱼群活跃度分类模型[J]. 农业机械学报, 2023, 54(11): 259 – 265.
XU Lihong, CUI Yuhui, LIU Shijing, et al. Spatiotemporal feature dynamics-driven activity assessment of salmon schools using deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 259 – 265. (in Chinese)

[12] UDDIN M G, RAHMAN A, TAGHIKHAH F R, et al. Data-driven evolution of water quality models: an in-depth investigation of innovative outlier detection approaches-A case study of irish water quality index (IEWQI) model[J]. Water Research, 2024, 255: 121499.

[13] 汤永华, 张志鹏, 林森, 等. 基于多标签补偿的改进 YOLOv8 鱼体病害检测方法[J]. 农业工程学报, 2024, 40(23): 227 – 234.
TANG Yonghua, ZHANG Zhipeng, LIN Sen, et al. An improved YOLOv8-based fish disease detection method with multi-label compensation[J]. Transactions of the CSAE, 2024, 40(23): 227 – 234. (in Chinese)

[14] LI Xin, HAO Yinfeng, ZHANG Pan, et al. A novel automatic detection method for abnormal behavior of single fish using image fusion[J]. Computers and Electronics in Agriculture, 2022, 203: 107435.

[15] 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)

[16] LI Xuefei, ZHAO Shili, CHEN Chunlin, et al. YOLO – FD: an accurate fish disease detection method based on multi-task learning[J]. Expert Systems with Applications, 2024, 258: 125085.

[17] HUANG Y P, KHABUSI S P. A CNN – OSELM multi-layer fusion network with attention mechanism for fish disease recognition in aquaculture[J]. IEEE Access, 2023, 11: 58729 – 58744.

[18] 王怡飞, 袁红春. 基于注意力机制及 GSConv – YOLOv8 的淡水鱼鱼病检测方法[J]. 渔业现代化, 2025, 52(2): 118 – 125.
WANG Yifei, YUAN Hongchun. Freshwater fish disease detection method based on attention mechanism and GSConv – YOLOv8[J]. Fishery Modernization, 2025, 52(2): 118 – 125. (in Chinese)

[19] 曹宇, 李佳阳, 王芳. 基于改进 YOLOv8n 的水下鱼类目标识别轻量化模型[J]. 上海海洋大学学报, 2025, 34(1): 188 – 200.
CAO Yu, LI Jiayang, WANG Fang. Lightweight model for underwater fish object detection based on enhanced YOLOv8n[J]. Journal of Shanghai Ocean University, 2025, 34(1): 188 – 200. (in Chinese)

[20] LI Yinjia, HU Zeyuan, ZHANG Yixi, et al. DDEYOLOv9: network for detecting and counting abnormal fish behaviors in complex water environments[J]. Fishes, 2024, 9(6): 242.

[21] CAI Yaoyi, YAO Zekai, JIANG Haibo, et al. Rapid detection of fish with SVC symptoms based on machine vision combined with a NAM – YOLO v7 hybrid model[J]. Aquaculture, 2024, 582: 740558.

[22] KHANAM R, HUSSAIN M. YOLOv11: an overview of the key architectural enhancements[J]. arXiv Preprint, arXiv: 2410.17725, 2024.

[23] CAI Xinhao, LAI Qiuxia, WANG Yuwei, 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] CHEN Chongqing, HAN Dezhi, CHANG Chinchen. CAAN: context-aware attention network for visual question answering[J]. Pattern Recognition, 2022, 132: 108980.

[25] HAN Qi, FAN Zejia, DAI Qi, et al. On the connection between local attention and dynamic depth-wise convolution[J]. arXiv Preprint, arXiv: 2106.04263, 2021.

[26] WAN Dahang, LU Rongsheng, SHEN Siyuan, et al. Mixed local channel attention for object detection[J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106442.

(下转第 118 页)

apple leaf disease detection[J]. Frontiers in Plant Science, 2024, 14: 1323301.

[19] WANG Xiaojuan. AgeDETR: attention-guided efficient DETR for space target detection[J]. Remote Sensing, 2024, 16(18): 3452.

[20] FU Z. DLSW - YOLO v8n: a novel small maritime search and rescue object detection framework for UAV images with deformable large kernel net[J]. Drones, 2024, 8(7): 310.

[21] YU Zhongwen. LSM - YOLO: compact and effective ROI detector for medical detection[J]. arXiv Preprint, arXiv: 2408.14087, 2024.

[22] 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)

[23] 罗斌,李家超,周亚男,等. 基于改进 YOLO v8 的轻量化稻瘟病孢子检测方法[J]. 农业机械学报, 2024, 55(11): 32 - 38.
LUO Bin, LI Jiachao, ZHOU Ya'nan, et al. Lightweight rice blast spores detection method based on improved YOLO v8[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 32 - 38. (in Chinese)

[24] 杨断利,齐俊林,陈辉,等. 基于改进 YOLO v8n 模型的散养蛋鸡个体行为识别方法与差异分析[J]. 农业机械学报, 2024, 55(11): 112 - 123.
YANG Duanli, QI Junlin, CHEN Hui, et al. Individual behavioral identification and differential analysis of free-range laying hens based on improved YOLO v8n model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 112 - 123. (in Chinese)

[25] 徐浩哲,王元兴. 改进 YOLO v10n 的无人机航拍图像检测算法[J]. 计算机科学与应用, 2025, 15(1): 230 - 238.
XU Haozhe, WANG Yuanxing. Algorithm for aerial image detection of unmanned aerial vehicles based on improved YOLO v10n[J]. Computer Science and Application, 2025, 15(1): 230 - 238. (in Chinese)

[26] CHEN R. YOLO - CE: an underwater low-visibility environment target detection algorithm based on YOLO 11[J]. The Journal of Supercomputing, 2025, 81(5): 1 - 24.

[27] 李宗刚,宋秋凡,杜亚江,等. 基于改进 DETR 的机器人铆接缺陷检测方法研究[J]. 铁道科学与工程学报, 2024, 21(4): 1690 - 1700.
LI Zonggang, SONG Qiufan, DU Yajiang, et al. Research on robot riveting defect detection method based on improved DETR[J]. Journal of Railway Science and Engineering, 2024, 21(4): 1690 - 1700. (in Chinese)

[28] 胡焱,原子昊,涂晓光,等. 基于对比学习的改进 SSD 目标检测算法[J]. 红外技术, 2024, 46(5): 548 - 555.
HU Yan, YUAN Zihao, TU Xiaoguang, et al. Improved SSD object detection algorithm based on contrastive learning[J]. Infrared Technology, 2024, 46(5): 548 - 555. (in Chinese)

[29] 张秀再,邱野,沈涛. 基于改进 SSD 算法的地铁场景小行人目标检测[J]. 计算机研究与发展, 2025, 62(2): 397 - 407.
ZHANG Xiuzai, QIU Ye, SHEN Tao. Small pedestrian target detection in subway scene based on improved SSD algorithm[J]. Journal of Computer Research and Development, 2025, 62(2): 397 - 407. (in Chinese)

(上接第 109 页)

[27] FENG Yifan, HUANG Jiangang, DU Shaoyi, et al. Hyper-yolo: when visual object detection meets hypergraph computation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 47(4): 2388 - 2401.

[28] REN Shaoqing, HE Kaiming, 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, 2016, 39(6): 1137 - 1149.

[29] LIU W, ANGUVLOV D, ERHAN D, et al. SSD: single shot multibox detector[C]// European Conference on Computer Vision, Springer, Cham, 2016: 21 - 37.

[30] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: 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.

[31] SOHAN M, SAI RAM T, RAMI REDDY C V. A review on YOLO v8 and its advancements[C]// International Conference on Data Intelligence and Cognitive Informatics, Springer, Singapore, 2024: 529 - 545.

[32] WANG Ao, CHEN Hui, LIU Lihao, et al. YOLO v10: real-time end-to-end object detection[J]. Advances in Neural Information Processing Systems, 2024, 37: 107984 - 108011.