

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.  
DOI: 10.13300/j.cnki.hnlkxb.2025.02.009

## 基于双通道分层协同的 CEH-YOLOv8 鱼体病害检测方法

荣弘扬<sup>1</sup>, 汤永华<sup>1</sup>, 林森<sup>2</sup>, 张志鹏<sup>1</sup>, 王腾川<sup>1</sup>, 刘兴通<sup>1</sup>

1. 沈阳工业大学信息科学与工程学院/沈阳工业大学辽宁省机器视觉重点实验室, 沈阳 110870;  
2. 沈阳理工大学自动化与电气工程学院, 沈阳 110159

**摘要** 针对在鱼体病害检测中病害形状不规则、纹理不清晰以及病斑分散导致难以定位真实病害区域的问题, 提出一种基于双通道分层协同的 CEH-YOLOv8 鱼体病害检测方法。首先, 提出一种双通道特征提取网络, 增强模型对不规则以及不清晰纹理病斑的提取能力。然后, 提出一种高效通道空间注意力机制(ECSA), 提升模型对分布式目标的识别能力。同时为强化改进后的主干网络, 提出一种分层协同的特征金字塔网络(HBF-PN), 对主干网络提取出的信息进行分层次特征融合, 增强模型的特征表达能力。试验结果显示, CEH-YOLOv8 网络对鱼体病害的识别精确率、召回率和 mAP 分别达到 83.2%、72.5% 和 76.2%, 相比于 SOTA 方法 YOLOv10 提升了 6.9、11.6 和 11.9 个百分点, 相比原模型提高 4.3、6.9 和 6 个百分点, 单帧图像推理时间为 9.1 ms。以上结果表明, 改进后的 YOLOv8 网络可以精准筛选出带病鱼体, 可用于及时发现渔业病害以减少经济损失。

**关键词** 鱼体病害检测; YOLOv8; 特征提取网络; 注意力机制; 特征金字塔

**中图分类号** TP391.4 **文献标识码** A **文章编号** 1000-2421(2025)02-0083-11

随着人民生活水平的提高, 海洋食品的需求日益增加<sup>[1]</sup>, 因此海洋鱼类养殖业在短时间内得到了快速发展。在鱼类养殖过程中, 鱼体病害是影响鱼类产量的关键因素之一, 对养殖效益产生了巨大的影响。例如, 在挪威的一个海洋鲑鱼养殖场, 疾病导致的死亡占总损失的 70%, 另外据越南方面的报告, 每年因疾病导致的平均损失高达 10 亿美元<sup>[2]</sup>。因此, 研究一种高效且准确的鱼体病害检测方法以及及时防控鱼病是减少养殖损失的重要措施。

鱼体病害检测方法多种多样, 其中目视检查法是常用的方法之一<sup>[3]</sup>。然而这种方法不仅耗费大量的人力资源<sup>[4]</sup>, 而且其可靠性也有待考察。近年来, 随着人工智能的发展, 国内外学者开始尝试利用深度学习的方法来识别鱼体病害。Noman 等<sup>[5]</sup>对采集的病鱼图像使用光照调整等预处理程序并使用 HY-BRID-CNN 为基础结构对孟加拉国鲈鱼的伤口病等 4 种疾病进行检测, 最终在其自制的数据集上, 总体识别准确率为 99.28%, 但该方法未明确提及模型的

检测速度和实时性方面的表现且在实际复杂环境下的鲁棒性仍需进一步验证。Khabusi 等<sup>[6]</sup>针对目前缺乏公开的鱼病数据集和复杂的水下环境限制了鱼病自动检测和分类的问题, 提出利用背景消除的方法来减少背景的干扰, 并将 CBAM 注意力与 ResNet50 网络融合进行鱼病分类, 其准确率、精确率、召回率和  $F_1$ -score 分别达到 89.9%、89.9%、89.3% 和 89.7%。该方法在一定程度上解决了背景干扰的问题, 但该方法的实时性仍未得到验证。陈科等<sup>[7]</sup>以 YOLOv5s 模型为基础对鲫病害检测进行研究, 采用 ShuffleNetV2 改进主干网络, 对模型进行轻量化改进, 引入 CBAM 提高模型精准度, 并使用 ASPP 模块提升模型的鲁棒性, 最终实现 92.0% 的检测精度与 14 400 kb 的模型体积, 但其未考虑不规则病灶的检测并且试验条件局限于实验室规模。Yu 等<sup>[8]</sup>以 MobileNet3-GELU-YOLOv4 结构为基础对出血性败血症等 4 种鱼体病害进行检测与识别, 在轻量化模型的基础上进一步将 mAP 和帧率分别提高了 12.39% 和

收稿日期: 2024-07-01

基金项目: 辽宁省机器人联合基金项目(20180520022); 辽宁省应用基础研究计划项目(2023JH2/101300237)

荣弘扬, E-mail: ronghy0716@outlook.com

通信作者: 汤永华, E-mail: tangyonghua@sut.edu.cn

19.31 帧/s, 实现了检测速度与识别精度的双重提升, 但其未考虑到形态各异的病斑是否会被检测到的问题。魏立明等<sup>[9]</sup>利用 CNN 擅长提取鱼类图像细粒度特征的优点与 Transformer 善于获取全局图像信息的优势构建了 CViT-FDRM 鱼类疾病识别模型, 最终在自制 404 张测试集上达到了 97.02% 的识别准确率, 该方法成功提取了鱼病的细粒度特征, 但未充分考虑对分布式目标特征的信息捕捉能力。

以上研究者针对鱼体病害检测中的相关问题提出了多种解决方案。但这些检测研究仍处于早期阶段<sup>[10-12]</sup>, 均未考虑病害的形状和分布范围是否会对检测结果产生影响。因此, 本研究提出一种基于双通道分层协同的 CEH-YOLOv8 鱼体病害检测方法。首先, 提出一种双通道主干网络, 旨在增强网络对形状不规则、纹理不清晰病斑的检测能力。然后, 提出一种 ECSA 注意力机制, 增强模型对长程依赖关系的学习, 进而提升模型对分布式病害的特征提取能力。最后, 提出一种新型颈部网络 HBFPN, 充分融合不同通道的特征信息。旨在解决病害形状不规则、纹理不清晰以及病斑分散导致难以定位真实病

害区域的问题。

## 1 材料与方法

### 1.1 数据集采集与处理

本研究采用海康威视 DS-E12 高清摄像头。在鲤鱼养殖场中首先挑选出带有体表病灶的鱼并放至容器中, 随后采集图像信息, 最后删除误拍等无效图像后得到 550 张原始数据集。在真实养殖场景下, 鱼体表面图像的采集受到摄像头角度变化、病斑尺寸多样性、水体中水草遮挡及光照条件波动等多重因素的干扰。为应对这些挑战, 本研究采用了图像翻转、裁剪及添加噪声等数据增强算法。这些技术分别用于模拟摄像头的不同观测角度和捕捉鱼体病灶在不同位置和尺度下的特征; 同时, 通过添加噪声来模拟真实养殖环境中可能出现的图像质量问题。经过上述处理, 最终构建了 1 个包含 5 512 张样本的高质量鱼体病害图像数据集, 如图 1 所示。建立数据集后, 使用 LabelImg 软件进行病害标注, 并按照 8:1:1 的比例分为训练集、验证集和测试集。



图1 数据集处理

Fig. 1 Datasets processing

### 1.2 YOLOv8 网络模型

YOLO (you only look once) 系列<sup>[13-14]</sup>算法自 2015 年推出以来, 因其准确的目标检测能力而广受欢迎。YOLOv8 是 Ultralytics 公司在 2023 年 1 月推出的开源模型, 它共有 n、s、m、l、x 5 种不同大小的模型规模以灵活应对多样化的应用场景和性能需求。在实际鱼类养殖场景下, 因鱼病检测的实时性要求较高<sup>[15]</sup>, 笔者采用推理速度最快且模型复杂度最低的 YOLOv8n 模型作为 Baseline 进行研究。

YOLOv8n 由主干网络、颈部网络、预测网络<sup>[16]</sup>

三大部分组成。主干网络采用了 CSPDarkNet 结构, 并提出一种新型空间金字塔池化方法-SPPF (serial parallel pooling fusion), SPPF 模块将 YOLOv5 网络中的 SPP 并行池化结构革新为串行结构, 通过连续应用多个  $5 \times 5$  最大池化层, 降低了计算量, 从而提升了处理速度, 实现了效率与性能的双重优化。颈部网络采用了 PANet (path aggregation network) 结构, 通过优化特征融合策略, 提高了多尺度目标检测的效率与准确性。预测网络使用了 Decoupled-Head 结构, 使模型更具灵活性和适应性。在损失函数方面,

YOLOv8 将 YOLOv7 分类损失 BCE-Loss 改进为 VFL-Loss,提高了分类的准确性,在回归损失 CIoU-Loss 基础上增加了 DFL-Loss,优化了边界框回归,提高了检测精度与稳定性。此外,主干网络和颈部网络都采用了 CBS 模块和 C2f 模块,其中 CBS 模块进行卷积操作、批量归一化和激活函数处理。C2f 模块取消了 YOLOv5 中 C3 模块分支内的卷积操作,并额外增加了 Split 操作,在实现轻量化的同时获取了更为丰富的梯度流信息。

### 1.3 改进的 YOLOv8 网络模型

本研究提出的改进 YOLOv8 网络模型如图 2 所示,绿色部分构成双通道特征提取网络,承担着从输入图像中精准提取各种类型病害特征的任务。橙色部分为 HBFPN 特征金字塔网络,负责对不同层级的特征进行融合,以获取更为丰富和准确的特征表示。蓝色部分为预测网络,负责对目标进行精准定位和分类,生成最终的检测结果。灰色部分说明了整个网络中每个模块的具体结构。

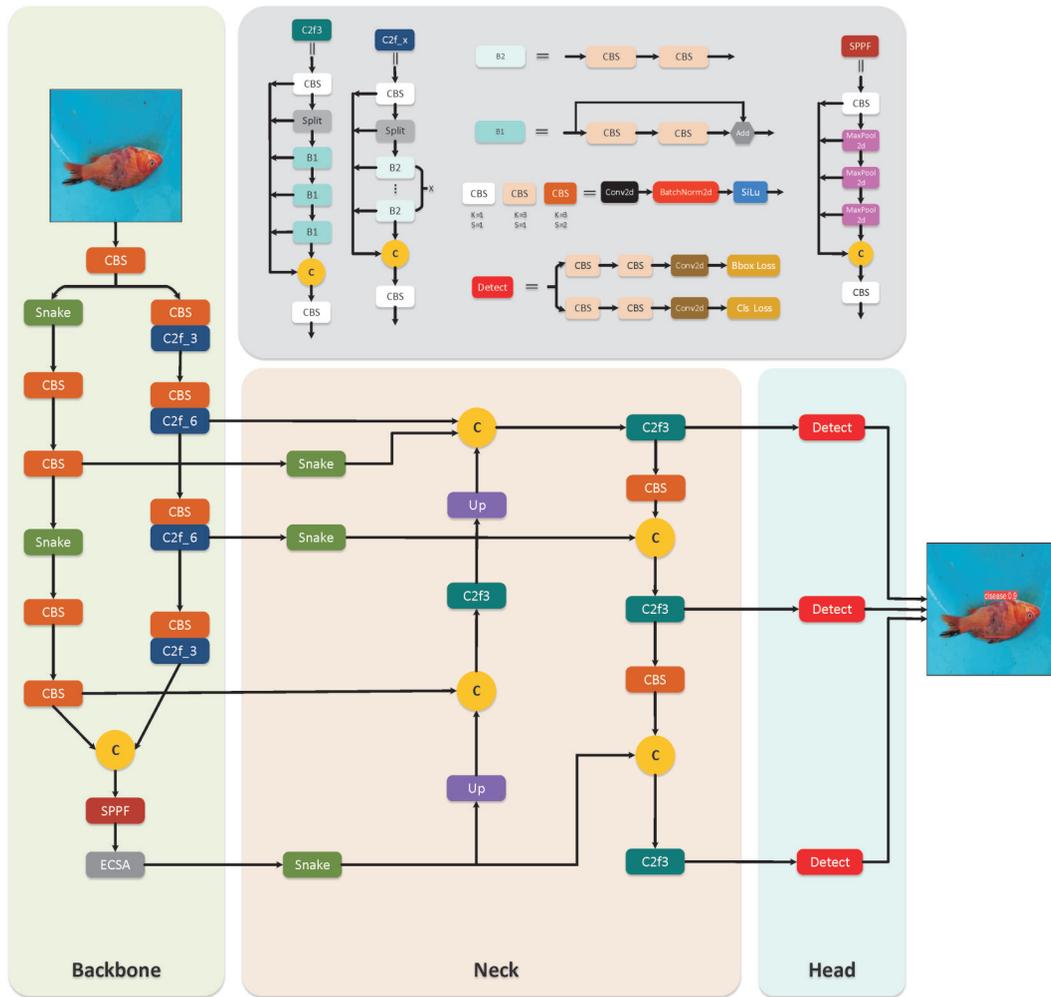


图 2 CEH-YOLOv8 网络结构  
Fig. 2 CEH-YOLOv8 network structure

### 1.4 Backbone 改进

标准卷积在提取鱼体病害这种具有随机发病形状的特征时,固定的 kernel size 和 stride 难以捕捉不规则和复杂的纹理特征,从而导致关键信息的丢失。相比之下,DSConv<sup>[17]</sup>具有更灵活的卷积路径,能够自适应地调整卷积方向,因此可以更好地提取不规则形状的特征信息。为保持对规则形状病斑的识别精度并增强对不规则病斑的识别能力,本

研究将 DSConv 与标准卷积并行加入 YOLOv8 主干网络中。DSConv 用于捕捉图像中不规则形状病斑的特征信息,标准卷积对 DSConv 提取的特征进行有效整合与精细化处理,进一步增强了模型识别的准确性。然后在主干网络尾部与原主干网络进行特征融合,使得网络能够综合不同层级的特征信息,提高整个模型的识别精准度。其结构如图 3 所示。

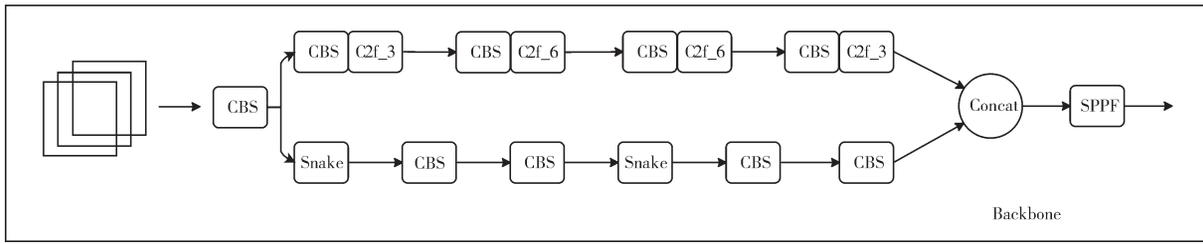


图3 双通道主干网络

Fig. 3 Dual-channel backbone network

DSCConv作为即插即用的模块在二维 $3 \times 3$ 卷积核的基础上扩展为 $9 \times 9$ 的卷积核,旨在扩大感受野,获取到更为广泛的图像信息。引入偏移量 $\Delta$ ,提高卷积核的灵活性,从而更为有效地捕捉到不规则病灶形状的信息,如公式(1)。

$$\Delta = \{\delta | \delta \in [-1, 1]\} \quad (1)$$

每个网格 $K_{i \pm c} = (x_{i \pm c}, y_{i \pm c})$ 的位置由与中心的水平距离 $c$ 决定, $c = \{0, 1, 2, 3, 4\}$ , $K$ 的数值如公式(2)所示:

$$K = \{(x-1, y-1), (x-1, y), \dots, (x+1, y+1)\} \quad (2)$$

在卷积核 $K$ 中,每个网格位置 $K_{i \pm c}$ 的选取遵循

累积的过程,这一过程起始于中心位置 $K_i$ ,随后依据前一个网格的位置来确定后续网格的位置,因此 $K_{i+1}$ 与 $K_i$ 之间的位置差异表现为一个偏移量 $\Delta$ 。因此,累加偏移量可以确保卷积核保持线性形态结构的一致性。如图4A、图4B所示,在 $x$ 轴方向上为公式(3),在 $y$ 轴方向上为公式(4)。

$$K_{i \pm c} = \begin{cases} (x_{i+c}, y_{i+c}) = (x_i + c, y_i + \sum_{l=1}^c \Delta y_l) \\ (x_{i-c}, y_{i-c}) = (x_i - c, y_i - \sum_{l=1}^c \Delta y_l) \end{cases} \quad (3)$$

$$K_{j \pm c} = \begin{cases} (x_{j+c}, y_{j+c}) = (x_j + \sum_{l=1}^c \Delta x_l, y_j + c) \\ (x_{j-c}, y_{j-c}) = (x_j - \sum_{l=1}^c \Delta x_l, y_j - c) \end{cases} \quad (4)$$

因此,相比于DCN(deformable convolution),如图4C所示,过于自由的偏置学习方式,DSCConv可以更好地提取微小细长的病害特征。

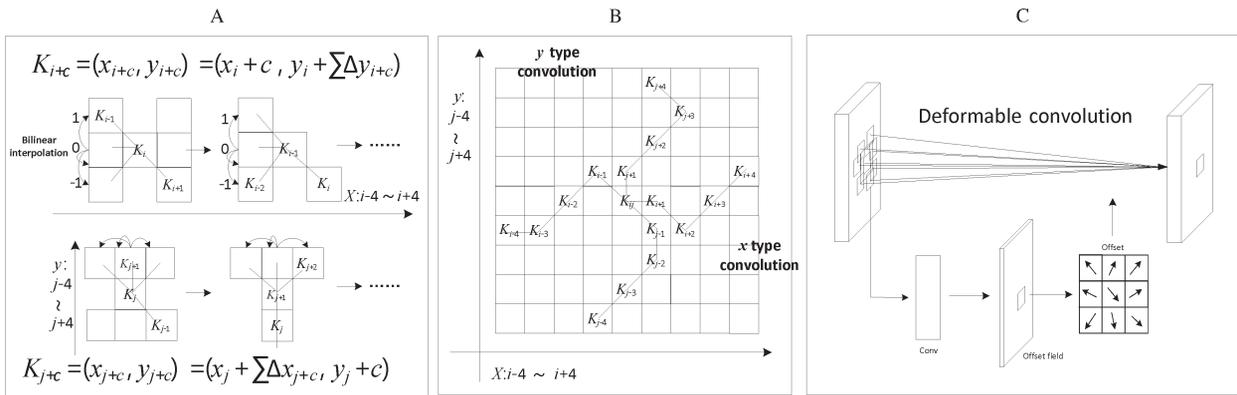


图4 DSCConv原理图

Fig. 4 Dynamic snake convolution schematic diagram

## 1.5 ECSA注意力机制

ECSA(efficient channel spatial attention)是一种融合了改进的ECA<sup>[18]</sup>(efficient channel attention)模块和ESA(efficient spatial attention)模块的注意力机制。首先对输入的图像通过改进的ECA模块将特征图在空间维度上压缩成一维矢量,以实现特征映射的空间信息进行有效聚合。然后通过ESA模块对图像的不同通道进行特征信息的提取与整合,进一步增强模型对真实目标区域的关注,如图5所示。

为克服ECA平均池化操作会将噪声也纳入计算

的缺点,本研究在ECA平均池化的基础上引入最大池化。首先对输入的特征图进行全局平均池化与最大池化的操作,将特征图从大小为 $(N, C, H, W)$ 转换为 $(N, C, 1, 1)$ ,并将经过池化后的特征输入到卷积核大小为 $k$ 的一维卷积中,其中 $C$ 为通道数, $|x|_{\text{odd}}$ 为距离 $x$ 最近的奇数, $\gamma$ 和 $b$ 分别取2和1。

$$C = 2^{(\gamma * k - b)} \quad (5)$$

$$k = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} \quad (6)$$

然后经过sigmoid激活函数将权重映射在 $0 \sim 1$ 。

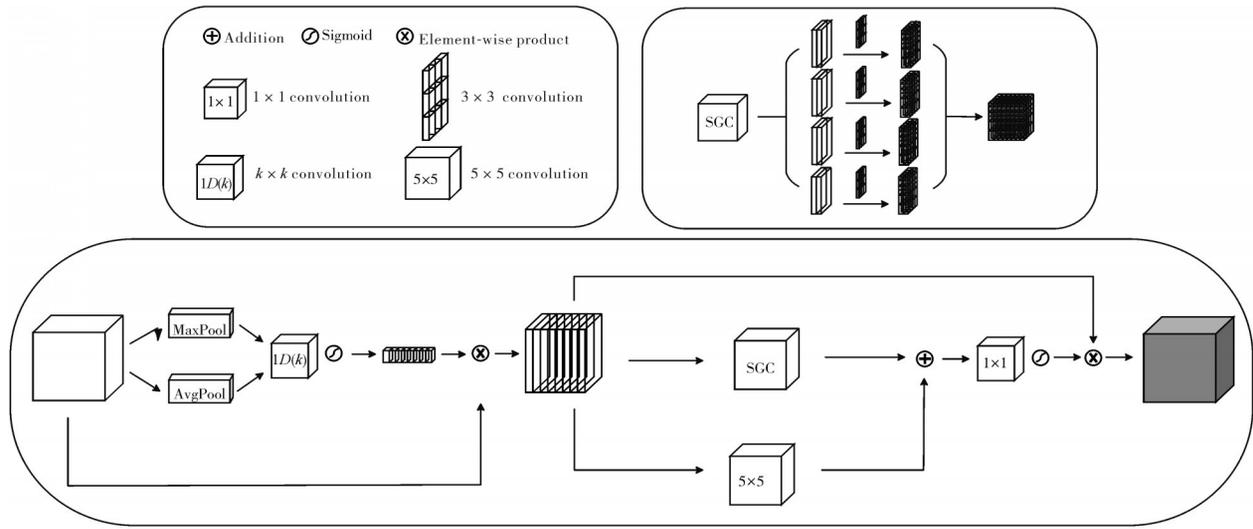


图5 ECSA 模型具体结构

Fig. 5 Specific structure of the ECSA module

将得到的权重与原始特征图进行 element-wise (公式中用  $\otimes$  表示) 操作生成 ESA 模块所需的输入特征。改进的 ECA 注意力机制公式如下：

$$F_c = M_c(F) \otimes F \quad (7)$$

$$M_c(F) = \sigma \left( f_{\text{conv}}^{k \times k} (F_{\text{avg}}^c(F)) + f_{\text{conv}}^{k \times k} (F_{\text{max}}^c(F)) \right) \quad (8)$$

SAM (spatial attention module) 在通道压缩时采用最大池化和平均池化, 但此过程会导致学习长程依赖关系的能力降低, 进而损失对分布式目标的特征提取能力。为弥补这一不足, 在原始 SA (spatial attention) 的基础上引入 SGC (spatial group convolution) 模块, 如图 5 所示。SGC 为 4 组  $3 \times 3$  卷积, 通过引入分组卷积使模型能够更加专注于病害特征的提取, 然后增加 1 层  $5 \times 5$  卷积层以增强模型的可表达性。随后通过  $1 \times 1$  卷积实现多通道的特征融合, 在保留各通道特征学习的基础上利用通道混合重新整合多通道信息。最后所得结果经 sigmoid 操作生成空间注意力特征图, 再与模块输入特征相乘, 得到优化后的特征表示。ECSA 注意力的公式如下：

$$M_{CS} = M_s(F_c) \otimes F_c \quad (9)$$

$$M_s(F_c) = \sigma \left( f_{\text{conv}}^{1 \times 1} \times \left( \sum_{i=0}^3 f_{\text{conv}}^{3 \times 3} (F_c) + f_{\text{conv}}^{5 \times 5} \right) \right) \quad (10)$$

其中,  $F$  表示输入特征,  $F_c$  表示通道注意力的输出特征,  $F_{\text{avg}}^c$  和  $F_{\text{max}}^c$  表示平均池化特征和最大池化特征,  $M_c$  表示通道注意力,  $M_s$  表示空间注意力,  $M_{CS}$  表示 ECSA 注意力,  $f_{\text{conv}}^{1 \times 1}$ ,  $f_{\text{conv}}^{3 \times 3}$ ,  $f_{\text{conv}}^{5 \times 5}$  和  $f_{\text{conv}}^{k \times k}$  表示  $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$  和  $k \times k$  大小卷积核的卷积运算,  $\sigma$  为 sigmoid 函数。

## 1.6 特征金字塔改进

在 FPN<sup>[19]</sup> (feature pyramid networks) 的演化过程中, PANet<sup>[20]</sup> (path aggregation network) (图 6A) 与 BiFPN<sup>[21]</sup> (bidirectional feature pyramid network) (图 6B) 等结构成为其代表性成果。然而在鱼体病害检测的实际应用中, 虽然 BiFPN 结合双通道主干网络能够提取到丰富的特征信息, 但其单一的特征融合方式限制了其融合复杂特征信息的能力。为弥补这一不足, 本研究提出一种分层协同的特征金字塔网络 (hierarchy bidirectional feature pyramid network, HBFPN), 如图 6C 所示。HBFPN 将 R1 (Right 1) 与 L1 (Left 1) 经过 DSConv 提取出的特征进行融合, 同时将 L2 与 P7 经过 DSConv 提取出的特征进行融合, 全面捕捉不同尺度下的鱼体病害特征信息。最后将 R2 经过 DSConv 提取出的特征进行跨层融合, 形成更为全面和精细的特征表达。因此将双通道的主干网络与 HBFPN 特征金字塔相结合能够充分利用主干网络在特征提取方面的优势, 并通过 HBFPN 的特征融合策略进一步提升整个模型的病害检测能力。

## 1.7 试验条件

为确保试验环境的统一性, 在模型训练和测试时采用相同的实验平台配置。该平台基于 Ubuntu 18.04 操作系统, CPU 主频为 2.50 GHz、核心数为 24, 运行内存为 32 GB。此外 GPU 型号为 NVIDIA RTX 3060, 显存大小为 12 GB。在软件方面, 采用 Pytorch 深度学习框架, 并使用 Python 3.7 进行编程。

## 1.8 超参数设置

本研究选取 YOLOv8n 作为基础模型, 输入图

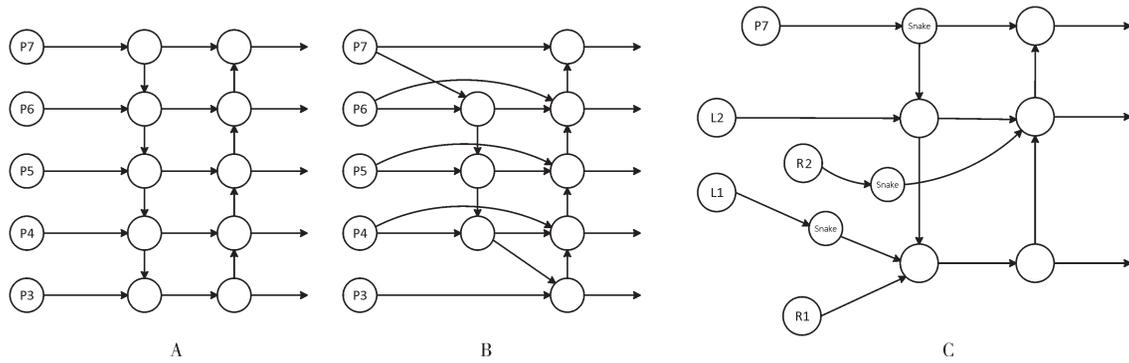


图6 PANet(A)、BiFPN(B)与HBFPN(C)网络结构图

Fig. 6 Network structure diagram of PANet(A), BiFPN(B) and HBFPN(C)

像尺寸为640像素×640像素×3像素。为优化训练效率,设定训练迭代次数为300次,当模型在连续100次迭代中未能提升性能指标时,训练过程将终止。此外设定批处理大小(batch\_size)为8,初始学习率设置为0.01,使用Adam优化器,试验中未采用Mosaic训练策略。

### 1.9 评价指标

本研究采用精确率(precision,  $P$ )、召回率(recall,  $R$ )和平均精度均值(mAP,公式中用 $P_{mA}$ 表示)作为评价指标,以全面评估模型的性能。同时还考虑了计算量(GFLOPs)和模型大小,以衡量模型的复杂度和实际应用效率。相关指标计算公式如下,其中 $T_p$ 表示真阳性, $F_p$ 表示假阳性, $F_N$ 表示漏报的真阳性数量, $P_A$ 表示平均精度。

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (11)$$

$$R = \frac{T_p}{T_p + F_N} \times 100\% \quad (12)$$

$$P_A = \int_0^1 P(R) dR \times 100\% \quad (13)$$

$$P_{mA} = \frac{1}{n} \sum_{i=0}^n P_A \times 100\% \quad (14)$$

## 2 结果与分析

### 2.1 消融实验

为体现本研究中改进的有效性,对模型进行6组消融实验。将双通道主干网络、ECSA注意力机制、HBFPN金字塔网络分别添加到YOLOv8模型中,并进行多个改进模块的组合试验。具体试验结果如表1所示。将主干网络替换成双通道主干网络后,由于DSConv对不规则形状病斑的特征提取能力的增强,模型的精确率、召回率和mAP分别提升了2.1、3.3和1.8百分点。在主干网络的尾部融入ECSA注意力机制后,模型能够综合提取通道和空间信息,进而更好

地捕捉分布式目标的特征。在增加少量参数的情况下,精确率、召回率和mAP分别提升了1.6、1.9和1.4百分点。在探究多个模块组合使用的效应时,将双通道主干网络与HBFPN的组合使用,能够使模型在保持高效特征提取的同时,更精准地利用不规则特征的信息,提高对复杂病斑的识别能力。精确率、召回率、mAP实现了3.6、5.1和4.1百分点的提升。同时双通道主干网络与ECSA注意力机制的组合,既增强了模型对不规则特征的关注度,又加强了对分布式特征的信息提取能力,精确率、召回率、mAP分别提升了3、3.9和2.9百分点。最后将双通道主干网络、ECSA注意力机制与HBFPN同时加入进模型中,精确率、召回率、mAP上分别得到了4.3、6.9和6百分点的提升。综上,经过一系列实验验证,通过综合运用双通道主干网络、ECSA注意力机制和HBFPN特征金字塔网络与YOLOv8网络进行结合,为鱼体病害检测领域带来了新的方法。

### 2.2 YOLOv8使用不同Backbone与FPN的试验结果

为验证双通道主干网络与HBFPN结合的检测效果,本研究对比了YOLOv8结合PANet与YOLOv8结合BiFPN 2种模型,试验结果如表2所示。与YOLOv8+PANet相比,本研究提出的方法在精确率、召回率、mAP方面实现了3.6、5.1和4.1百分点的提升。同时与YOLOv8+BiFPN相比较,也提升了3.4、4.9和3.3百分点。

### 2.3 不同Backbone与FPN结合的效果对比

为进一步验证双通道主干网络与HBFPN相结合的有效性,本研究挑选5组具有不同形状且纹理不清晰的病斑图像进行检测效果的对比,如图7所示。黄色框是未能检测出病害的区域。传统的检

表 1 消融实验结果对比

Table 1 Comparison results of ablation test results

模型 Model	双通道 Backbone	ECSA	HBFPN	精确率/% Precision	召回率/% Recall	平均精度均值/% mAP	计算量/( $\times 10^9$ ) FLOPs	单帧推理时间/ms Single frame image inference time
YOLOv8n	×	×	×	78.9	65.6	70.2	8.9	6.9
改进 1 Improved 1	✓	×	×	81.0	68.9	72.0	9.2	8.5
改进 2 Improved 2	×	✓	×	80.5	67.5	71.6	9.0	7.5
改进 3 Improved 3	✓	✓	×	81.9	69.5	73.1	10.5	9.0
改进 4 Improved 4	✓	×	✓	82.5	70.7	74.3	10.1	8.9
本研究 This study	✓	✓	✓	83.2	72.5	76.2	10.6	9.1

注：模型中改进 1 为 YOLOv8 结合双通道 Backbone，改进 2 为 YOLOv8 结合 ECSA 注意力机制，改进 3 为 YOLOv8 结合双通道 Backbone 与 ECSA 注意力机制，改进 4 为 YOLOv8 结合双通道 Backbone 与 HBFPN 特征金字塔。Note: In the model, improved 1 is YOLOv8 combined with dual-channel Backbone, improved 2 is YOLOv8 combined with ECSA attention mechanism, improved 3 is YOLOv8 combined with dual-channel Backbone and ECSA attention mechanism, and improved 4 is YOLOv8 combined with dual-channel Backbone and HBFPN feature pyramid.

表 2 不同 Backbone 与 FPN 的组合效果分析

Table 2 Analysis of combination effect of different Backbone and FPN

模型 Model	精确率/% Precision	召回率/% Recall	平均精度均值/% mAP	计算量/( $\times 10^9$ ) FLOPs	单帧推理时间/ms Single frame image inference time
YOLOv8+PANet	78.9	65.6	70.2	8.9	6.9
YOLOv8+BiFPN	79.1	65.8	71.0	8.9	7.1
双通道 Backbone+HBFPN Dual-channel Backbone+HBFPN	82.5	70.7	74.3	10.1	8.9

测网络结构，如 YOLOv8 和 YOLOv8+BiFPN 在应对不规则形状病害以及复杂纹理病害的检测任务时，通常会出现漏检的情况。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。

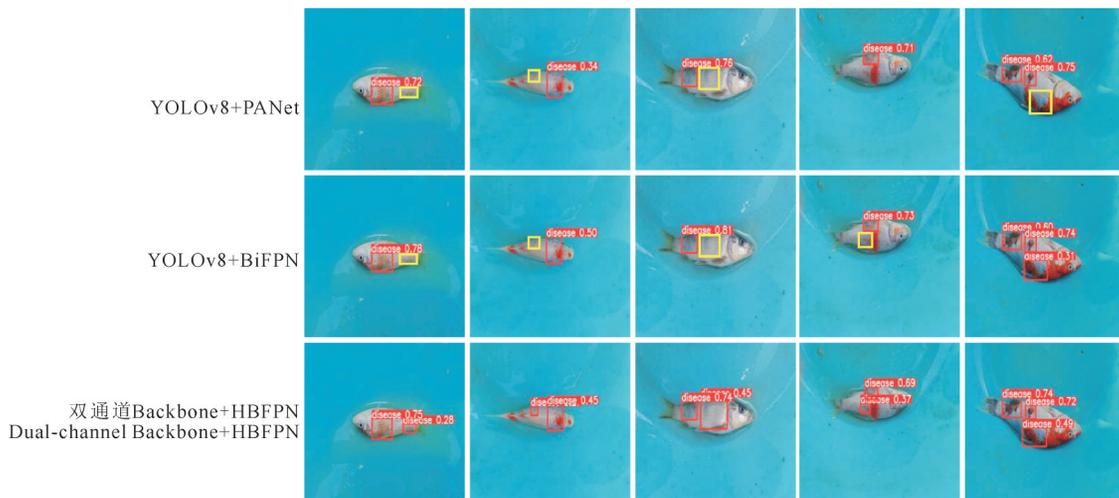


图 7 对比不同 Backbone 与 FPN 组合的可视化检测效果

Fig. 7 Compare the visual detection effect of different Backbone and FPN combinations

## 2.4 不同模型的对比试验

为进一步验证本研究中模型的综合性能,将本研究网络与 M-G-YOLOv4、改进的 YOLOv5n、YOLOv7-tiny、YOLOv9<sup>[22]</sup>、Faster-RCNN、目前的 SOTA 方法 YOLOv10<sup>[23]</sup>以及 CEH-YOLOv10n 进行对比试验,具体如表 3 所示。首先,尽管 YOLOv10 与 CEH-YOLOv10n 在推理速度方面具有优势,但其 NMS-free 的思想在小目标检测上具有局限性,进而降低了对细小病斑的识别精准度。因此在涉及随机病斑大小的鱼体病害检测领域,其应用潜力受到一定限制。大规模参数网络如 YOLOv9 和 Faster-RCNN 在鱼体病害检测中,预测率和召回率差异较大,主要因网络参数过多导致过拟合的出现。鱼体病害检测任务需要提取病害的细粒度与分散目标的特征,而过大的参数量使得模型难以部

署且仅对个别简单样本预测有效。此外,本研究提出的方法仅需 6.7 MB 存储空间且浮点运算量为  $10.6 \times 10^9$ 。在推理速度方面,尽管本研究提出的方法落后于 M-G-YOLOv4、改进的 YOLOv5n 和 YOLOv7-tiny 网络,但整体速度仍保持在单帧推理时间 10 ms 以下。在通用精确度指标方面,本研究方法的 mAP 值相比于 M-G-YOLOv4、改进的 YOLOv5n、YOLOv7-tiny、YOLOv9、YOLOv10、CEH-YOLOv10n 和 Faster-RCNN 分别提升了 11.1、5.1、10.9、14.1、11.9、9.8 和 13.4 百分点,证明本研究方法在鱼体病害检测任务中的有效性和实用性。综上,本研究避免了大规模参数网络在鱼体病害检测任务中的过拟合问题,同时保持了较高的预测精度和实时性能,为鱼体病害检测领域提供了一种高效、准确的方法。

表 3 不同网络模型比较结果

Table 3 Comparison results of different network models

模型 Model	精确率/% Precision	召回率/% Recall	平均精度均值/% mAP	计算量/( $\times 10^9$ ) FLOPs	单帧推理时间/ms Single frame image inference time	权重大小/MB Model size
M-G-YOLOv4 <sup>[8]</sup>	73.1	60.7	65.1	14.2	19.6	35.2
Improved-YOLOv5n <sup>[7]</sup>	76.5	62.8	71.1	3.8	11.1	6.6
YOLOv7-tiny <sup>[14]</sup>	73.6	60.7	65.3	3.4	6.8	3.3
YOLOv9 <sup>[22]</sup>	74.4	50.8	62.1	238.9	50.4	102.8
YOLOv10 <sup>[23]</sup>	76.3	60.9	64.3	8.4	4.5	5.8
CEH-YOLOv10n	78.2	63.2	66.4	9.1	6.7	6.0
Faster-RCNN	75.8	52.0	62.8	138	45	112.8
本研究 This study	83.2	72.5	76.2	10.6	9.1	6.7

## 2.5 鲁棒性实验

为进一步验证本研究中方法的鲁棒性,从互联网上选取 4 组鱼体病害图像作为测试样本,如图 8 所示,黄色框是未能检测出病害的区域。这些图像不仅涵盖了多样化的病害类型及多种患病鱼种,而且还包含了不同程度的背景干扰,从而对模型的鲁棒性进行测试。

图 8 中的第 1 列图像展示了病害分布广泛且特征复杂的场景。在此情况下,YOLOv8n 模型出现了漏检现象,而本研究所提模型则能够准确识别并检测出患病部位。第 2 列图像的背景干扰较为严重,导致基线模型错误地将背景干扰识别为病害。相比之下,本研究的模型能够精准聚焦于真实病害的具体位置,有效避免了误检情况的发生。第 3 列图像中的病害形状不规则且纹理不清晰。基线模型虽然能够检测出病害的位置,但置信度较低,可靠性较差。而本研究模型则能够准确定位发病区域,且置信度也有大幅提升。第 4 列图像中的病害不仅分布广泛,而

且部分病害的纹理不清晰、形状不规则。YOLOv8n 模型未能检测到全部病害,漏检了 1 个纹理不清晰、形状不规则的病害,同时检测到的病害置信度也明显不如本研究模型。综上,本研究所提出的模型在鱼体病害检测领域展现出了一定的优势,不仅能够有效应对多样化病害类型的挑战,还能够提高检测的准确性和可靠性。

## 2.6 热力图可视化分析

为直观展示 CEH-YOLOv8 模型的有效性,将本研究改进的方法与原始模型进行热力图可视化对比,如图 9 所示。在热力图中,颜色越红表示该区域对于预测结果的贡献越大,即模型对于该区域的关注程度越高。在原始模型 YOLOv8n 的热力图中,如图 9 第 2 行所示,红色区域较少且未覆盖全部病害区域,这反映出未改进的模型在病害区域的关注度不够集中。相比之下,如图 9 第 3 行所示,展示了本研究方法的热力图,其中所有病害区域均被深红色区域准确覆盖,

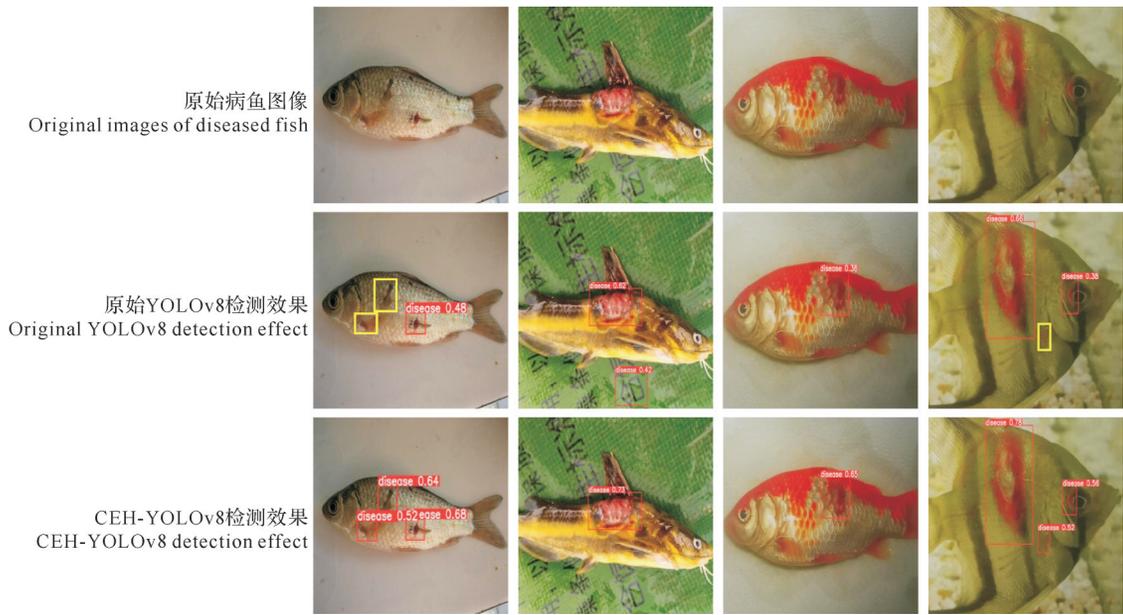


图 8 基线模型与本研究模型的检测效果对比

Fig. 8 Comparison of baseline model and the detection effect of the study model

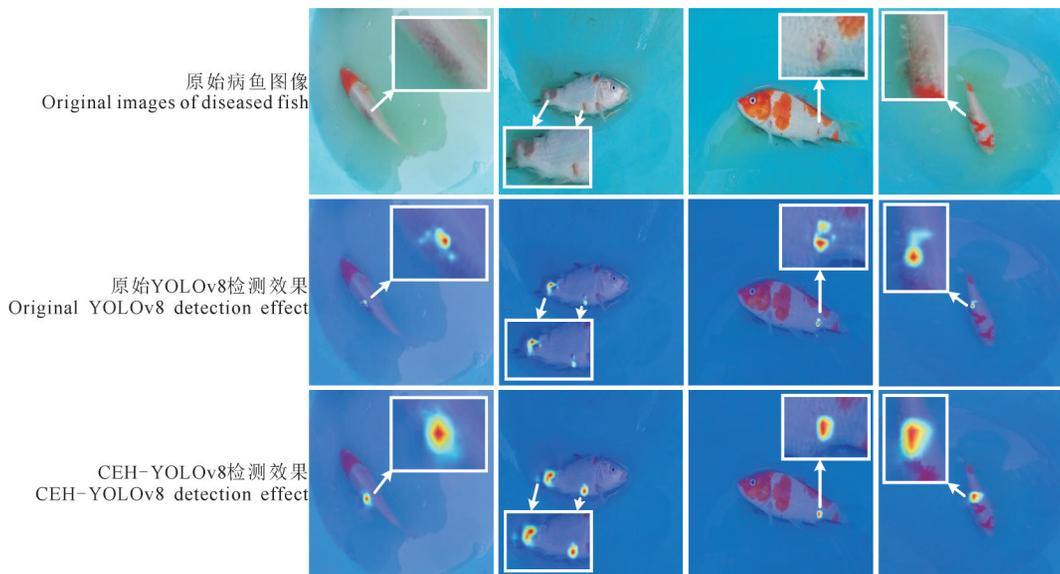


图 9 YOLOv8改进前后热力图对比

Fig. 9 Comparison of thermal map before and after YOLOv8 improvement

这表明了本研究的方法能够有效聚焦在病害区域的目标信息上,从而验证了该改进方法的有效性。

### 3 讨论

针对目前使用深度学习技术进行鱼体病害识别时因鱼体病斑形状不规则、纹理不清晰以及病斑分散导致难以定位真实病害区域的难题,本研究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。该方法通过将 DSConv 与标准卷积并行加入 YOLOv8 主干网络、增强了模型对不规则

病斑形状及复杂病害纹理的特征提取能力。设计的 ECSA 注意力机制进一步增强模型对目标区域的关注度,有效提升模型对杂散布病斑的识别精度。引入了 HBFPN 特征金字塔,进一步强化了整个模型的特征融合能力。通过消融实验证明本研究提出的改进点可以有效提升病害检测的准确率。在对比试验中,本研究提出的方法在精确率、召回率和 mAP 上较原始 YOLOv8 网络分别提升 4.3、6.9 和 6 个百分点。与 YOLOv10 网络相比,提升幅度达到了 6.9、11.6 和 11.9 百分点。这说明本研究设计的双通道主

干网络以及ECSA注意力机制检测出了原始网络无法发现的病害。同时,本研究方法的模型大小为6.7 MB,单帧推理时间为9.1 ms,有效地平衡了模型的大小和推理速度。在鲁棒性实验中,本研究的方法在面对复杂的背景干扰和病斑形状时,也未出现漏检误检的情况,且置信度高于基线模型,进一步验证了本研究改进的有效性。

鉴于目前鱼病数据集的稀缺现状,本研究所使用的数据集无法涵盖到足够的鱼病种类和鱼的品种,因此本研究模型在水下鱼体病害检测的深层次性能验证仍受到一定限制。在未来的工作中,我们将进一步优化本文方法的网络结构,以提升模型的性能和泛化能力。同时,我们也将继续丰富鱼体病害数据集,涵盖更多种类的鱼体和病害,以确保模型能够应对各种实际场景的挑战,为水产养殖业的病害防控提供更加准确和高效的技术支持,推动该领域的持续发展。

## 参考文献 References

- [1] ALI TOUFIQUE K, FAROOK S N, BELTON B. Managing fisheries for food security: implications from demand analysis [J]. *Marine resource economics*, 2018, 33(1): 61-85.
- [2] 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.
- [3] AZHAR A S B M, HARUN N H B, YUSOFF N B, et al. Image enhancement on underwater images for protozoan white spot fish disease detection [C]//2022 international conference on intelligent systems and computer vision (ISCV). Fez, Morocco: IEEE, 2022: 1-4.
- [4] 汤永华, 石非凡, 林森, 等. 基于融合非局部操作的YOLOv5s高密度锦鲤鱼苗检测方法[J]. *浙江农业学报*, 2024, 36(4): 952-967. TANG Y H, SHI F F, LIN S, et al. YOLOv5s high-density koi fry detection method based on fusion non-local operation [J]. *Acta agriculturae zhejiangensis*, 2024, 36(4): 952-967 (in Chinese with English abstract).
- [5] NOMAN M A, HOSSEN M S, ISLAM M, et al. HYBRID-CNN: for identification of rohu fish disease [C]//2022 13th international conference on computing communication and networking technologies (ICCCNT). Kharagpur, India: IEEE, 2022: 1-6.
- [6] 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). Ho Chi Minh, Vietnam: IEEE, 2023: 95-100.
- [7] 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).
- [8] YU G, ZHANG J, CHEN A, et al. Detection and identification of fish skin health status referring to four common diseases based on improved YOLOv4 model [J/OL]. *Fishes*, 2023, 8(4): 186 [2024-07-01]. <https://doi.org/10.3390/fishes8040186>.
- [9] 魏立明, 赵奎, 王宁, 等. 细粒度鱼类疫病图像识别算法模型[J]. *激光与光电子学进展*, 2023, 60(16): 119-128. WEI L M, ZHAO K, WANG N, et al. Fine-Grained fish disease image recognition algorithm model [J]. *Laser & optoelectronics progress*, 2023, 60(16): 119-128 (in Chinese with English abstract).
- [10] LI D L, LI X, WANG Q, et al. Advanced techniques for the intelligent diagnosis of fish diseases: a review [J/OL]. *Animals*, 2022, 12(21): 2938 [2024-07-01]. <https://doi.org/10.3390/ani12212938>.
- [11] HATZILYGEROUDIS I, DIMITROPOULOS K, KOVAS K, et al. Expert systems for farmed fish disease diagnosis: an overview and a proposal [J/OL]. *Journal of marine science and engineering*, 2023, 11(5): 1084 [2024-07-01]. <https://doi.org/10.3390/jmse11051084>.
- [12] MIA M J, BIN MAHMUD R, SADAD M S, et al. An in-depth automated approach for fish disease recognition [J]. *Journal of King Saud University (computer and information sciences)*, 2022, 34(9): 7174-7183.
- [13] LI R, WU Y P. Improved YOLO v5 wheat ear detection algorithm based on attention mechanism [J/OL]. *Electronics*, 2022, 11(11): 1673 [2024-07-01]. <https://doi.org/10.3390/electronics11111673>.
- [14] 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]//2023 IEEE/CVF international conference on computer vision (ICCV). Vancouver, Canada: IEEE, 2023: 7464-7475.
- [15] 陈科. 基于机器视觉和改进YOLOv5s的鲫鱼病害轻量级无损检测模型研究 [D]. 杭州: 浙江科技大学, 2024. CHEN K. Lightweight nondestructive detection model of *Crucian* disease based on machine vision and improved YOLOv5s [D]. Hangzhou: Zhejiang University of Science and Technology, 2024 (in Chinese with English abstract).
- [16] 周涛, 王骥, 麦仁贵. 基于改进YOLOv8的实时菠萝成熟度目标检测方法[J]. *华中农业大学学报*, 2024, 43(5): 10-20. ZHOU T, WANG J, MAI R G. Real-time object detection method of pineapple ripeness based on improved YOLOv8 [J]. *Journal of Huazhong Agricultural University*, 2024, 43(5): 10-

20. (in Chinese with English abstract).
- [17] QI Y L, HE Y T, QI X M, et al. Dynamic snake convolution based on topological geometric constraints for tubular structure segmentation[C]//2023 IEEE/CVF international conference on computer vision (ICCV). Paris, France: IEEE, 2023: 6047-6056.
- [18] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF conference on computer vision and pattern recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 11531-11539.
- [19] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//2017 IEEE conference on computer vision and pattern recognition (CVPR). Honolulu, HI, USA: IEEE, 2017: 936-944.
- [20] 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, UT, USA: IEEE, 2018: 8759-8768.
- [21] 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.
- [22] WANG C Y, YE H I, MARK LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information[C]// Computer vision - ECCV 2024. Cham: Springer Nature Switzerland, 2025: 1-21.
- [23] WANG A, CHEN H, LIU L H, et al. YOLOv10: Real-Time end-to-end object detection[DB/OL]. Arxiv, 2024: 2405.14458 [2024-07-01]. <https://arxiv.org/abs/2405.14458v2>.

## A method of detecting fish diseases with CEH-YOLOv8 based on dual-channel and hierarchical synergism

RONG Hongyang<sup>1</sup>, TANG Yonghua<sup>1</sup>, LIN Sen<sup>2</sup>, ZHANG Zhipeng<sup>1</sup>, WANG Tengchuan<sup>1</sup>, LIU Xingtong<sup>1</sup>

1. College of Information Science and Engineering/Liaoning Province Key Laboratory of Machine Vision, Shenyang Polytechnic University, Shenyang 110870, China;

2. College of Automation and Electrical Engineering, Shenyang University of Technology, Shenyang 110159, China

**Abstract** A method of detecting fish diseases with CEH-YOLOv8 based on dual-channel and hierarchical synergism was developed to solve the problems of the irregular shapes, unclear textures, and scattered disease spots making it difficult to localize the true lesion areas in the detection of fish diseases. A dual-channel feature extraction network was introduced to enhance the ability of model to extract irregular lesion areas with unclear textures. Then, an efficient channel spatial attention (ECSA) mechanism was proposed to improve the capability of model to recognize distributed targets. A hierarchical and balanced feature pyramid network (HBFPN) for was presented to reinforce the improved backbone network and perform hierarchical feature fusion on the information extracted from the backbone network at different levels to enhance the ability of model to express feature. The results showed that the CEH-YOLOv8 network had an accuracy rate of 83.2%, a recall rate of 72.5%, and a mean average precision (mAP) of 76.2% in detecting fish diseases, respectively. Compared with the state-of-the-art (SOAT) YOLOv10 method and the original model, it increased the accuracy rate, recall rate, and mAP by 6.9, 11.6, and 11.9 percent points, and 4.3, 6.9, and 6 percent points, respectively. The inference time for a single frame was 9.1 ms. It is indicated that the improved YOLOv8 network can accurately screen fish with diseases and be used for early detection of fishery diseases to reduce economic losses.

**Keywords** detection of fish diseases; YOLOv8; feature extraction network; attention mechanism; feature pyramid

(责任编辑:边书京)