doi:10.6041/j.issn.1000-1298.2026.02.011

面向圈养模式的智能精准投喂系统研究

黄　凰[1,2]　成佳卿[1]　简凡皓[1]　陈焯然[1]　黄　磊[1]　李　潇[1]　刘子乾[1]
(1.华中农业大学工学院,武汉 430070;2.农业农村部水产养殖设施工程重点实验室,武汉 430070)

摘要:随着水产养殖业的快速发展,过度投喂导致饵料浪费与水质污染及投喂不足所引发的鱼群生长营养不良等问题愈发凸显,针对圈养模式,提出了一种基于视觉与多种传感器的圈养模式智能精准投喂系统,对 RGB 图像、深度图像、压强传感器和加速度传感器等多源数据融合实时量化成年糙鱼摄食强度并实现精准投喂控制。以改进的 YOLO v8n-seg 模型为核心进行 RGB 图像分割,将水面波动状态分为强、弱和无 3 种状态;在水面状态分割区域内采用 HSV 颜色检测方法对水面鱼饵进行面积检测;通过帧差法分析深度图像连续两帧的深度差异,将水面波动量化为强、弱、无 3 个等级;利用压强传感器和加速度传感器采集的数据提取关键特征,通过随机森林模型对鱼群摄食状态进行分类弥补单一视觉特征的局限性。通过加权融合策略将 5 类数据决策模块的结果进行融合并建立实时投喂决策模型。多次实地试验结果表明,投饵系统摄食强度评估精度达到 95.45%,投喂误差率仅为 1.72%,能够准确识别鱼群摄食强度,有效减少饵料浪费和水体污染,在实际圈养模式环境中具有较好的实用性和实时性。

关键词:智能精准投喂;摄食强度;多源数据融合;YOLO v8n-seg;帧差法;随机森林
中图分类号:S969.31;S951.2　**文献标识码**:A　**文章编号**:1000-1298(2026)02-0109-12　**OSID**:

Research of Intelligent Precision Feeding System for Captive Breeding

HUANG Huang[1,2]　CHENG Jiaqing[1]　JIAN Fanhao[1]　CHEN Zhuoran[1]　HUANG Lei[1]　LI Xiao[1]　LIU Ziqian[1]
(1. *College of Engineering*, *Huazhong Agricultural University*, *Wuhan* 430070, *China*
2. *Key Laboratory of Aquaculture Facility Engineering*, *Ministry of Agriculture and Rural Affairs*, *Wuhan* 430070, *China*)

Abstract: With the rapid development of aquaculture, problems such as excessive feeding leading to feed waste and water pollution, as well as insufficient feeding causing malnutrition in fish populations, have become increasingly prominent. An intelligent and precise feeding system for cage culture was proposed based on vision and multiple sensors. By integrating multi-source data such as RGB images, depth images, pressure sensors, and acceleration sensors, the system quantified the feeding intensity of adult fish in real time and achieved precise feeding. The system used an improved YOLO v8n-seg model for RGB image segmentation, dividing the water surface fluctuation state into three categories: strong, weak, and none. Within the segmented water surface state region, the HSV color detection method was employed to detect the area of fish feed on the water surface. The system analyzed the difference in depth values between two consecutive frames in the depth image by using the frame difference method, quantifying water surface fluctuations into three levels: strong, weak, and none. Key features were extracted from the data collected by pressure sensors and acceleration sensors, and a random forest model was used to classify the feeding state of the fish population to compensate for the limitations of single visual features. Ultimately, the results of the five data decision modules were fused through a weighted fusion strategy to establish a real-time feeding decision model. Through multiple field tests, the accuracy of feeding intensity assessment of this feeding system based on feeding behavior reached 95.45%, with a feeding error rate of 1.72%. It can accurately identify the feeding intensity of fish populations, effectively reduced feed waste and water pollution, and had good practicality and real-time performance in actual cage culture environments.

Key words: intelligent precision feeding; feeding intensity; multi-source data fusion; YOLO v8n-seg; frame difference method; random forest

收稿日期:2025-06-20　修回日期:2025-08-05
基金项目:中央高校基本科研业务费项目(2662024GXPY005)、湖北省农机装备补短板核心技术应用攻关项目(HBSNYT202217)和湖北省大学生创新创业训练项目(S202310504168)
作者简介:黄凰(1985—),女,副教授,博士,主要从事农业机械化和智能化生产与管理研究,E-mail:huanghuang@mail.hzau.edu.cn

0 引言

随着全球人口不断增长与水产品消费需求的日益增长,水产养殖逐渐成为弥补捕捞渔业缺口与保障水产品供给的重要支柱[1]。然而在水产养殖产业高速发展的背后,仍然存在饲料转化效率低、养殖运营成本较高及水体环境污染加剧三大突出矛盾。这些问题不仅制约着养殖产业生态链的良性循环,更限制着水产养殖技术革新与发展[2]。

饲料成本在整个养殖总成本中占有较大的比重,其中传统人工投喂或者机械投喂的方式存在诸多弊端[3-4]。养殖者常常会依赖日常经验判断进行饲料投喂,这种方式不仅容易受到主观因素干扰,还会出现投饵分布不均匀、饵料过多浪费等问题[5]。过量投喂不仅会明显提高养殖成本,还会严重加速水质恶化和危害鱼类健康,但投喂量不足则直接影响鱼群生长速度,甚至导致抢食等行为,一个合适的饲料投喂量能有效增加鱼类产量和提高养殖效益[6-7]。

基于机器视觉的智能投喂系统方法大多依赖图像的单一特征,而水产动物的生物多样性摄食强度具有复杂性和多变性。同一水产动物在不同时间、地点和环境下所表现出来的基本信息也并不相同[8]。由于单一特征信息判断具有一定的局限性,采用多源数据融合技术能够弥补单一特征在复杂环境的表征能力。例如,陈明等[9]通过提取摄食图像的颜色、形状和纹理等 11 类特征并从中筛选出贡献率最高的 3 个摄食评价因子,该方法采用加权融合方法确定最佳权重并实现了 98.89% 的准确率。国内学者通过结合近红外图像和神经模糊推理系统,实现了对鱼类摄食强度的自动化判断和投饵量的动态调整[10]。赵思琪等[11]提出了一种基于模糊逻辑控制的精准投喂系统,在不影响鱼类生长的前提下将饵料系数降低至 9.23%,有效提升了饵料利用率。此外,俞国燕等[12]提出了一种基于双目相机和深度学习的鱼类摄食强度分析方法,通过改进 YOLO v8n - seg 模型对水花进行语义分割和面积计算,在提高模型精确率 3.2 个百分点的同时,参数量和浮点运算量分别减少 71% 和 36%。因此,在摄食强度评估过程中通过结合计算机视觉等技术,有利于进一步提高鱼群摄食强度分析的精确率和鲁棒性。

本研究将对鱼类摄食过程中的摄食图像、水面压强和加速度信息进行多源数据融合,从而进行鱼群摄食强度等级量化。拟采用改进 YOLO v8n - seg 模型对 RGB 图像进行分割,根据水面状态量化鱼类摄食强度划分强、弱和无 3 类。在分割得到的水面区域掩码内,利用 HSV 颜色检测对剩余鱼饵进行检测及计算鱼饵像素总面积。利用帧差法处理深度图像间接量化水面波动特征。最后结合压强和加速度传感器实时采集水面表层的压强和六轴加速度从中提取特征,采用随机森林模型对水面状态进行分类。通过融合上述 5 类数据源信息并根据投喂过程中摄食强度特征,建立实时投喂决策模型提升圈养模式投喂系统的抗干扰性与智能化水平。

1 材料与方法

1.1 试验装置与决策流程

试验装置如图 1 所示,在华中农业大学“零排放模式”圈养基地进行圈养桶环境下的粉鱼养殖投喂试验。

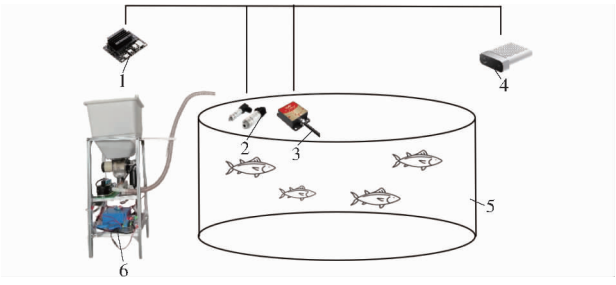


图 1 试验装置

Fig. 1 Test device

1. Jetson Nano 芯片 2. HM29 型压强传感器 3. HWT605 型加速度传感器 4. Azure Kinect 型深度相机 5. 圈养桶 6. 风送式投饵机

决策流程图如图 2 所示,采用 Jetson 嵌入式芯片为数据处理中心,实时处理和分析 YOLO 水面状态、HSV 鱼饵面积、深度图帧差法、压强传感器和加速度传感器 5 类检测数据,得到鱼群摄食强度等级,控制风送式投饵机工作。由 Jetson 嵌入式芯片实时数据融合分析,在 5 类多源数据融合的后端通过加权分配各模块置信度权重 W_i,得到最终的鱼群摄食强度等级。STM32 处理器根据 Jetson 芯片给出的指令控制投饵机调整饵料策略,实现圈养模式智能化投饵。

1.2 数据采集

1.2.1 RGB 摄食图像采集

基于微软 Azure Kinect 型深度相机搭建多模态数据采集系统,同步获取 RGB 和深度摄食图像,如图 3 所示,共获取图像 1 443 幅,并利用数据增强技术扩增数据集至 7 257 幅,用于模型训练和优化。

1.2.2 摄食过程水面压强与加速度数据采集

为了弥补单一视觉特征导致的不确定性,系统采用 HM29 型压强传感器实时监测鱼群摄食过程水面波动引起的压强变化。将压强传感器检测头部浸没在水面下 2 ~ 3 cm 处,观察投饵机投出的饵料在

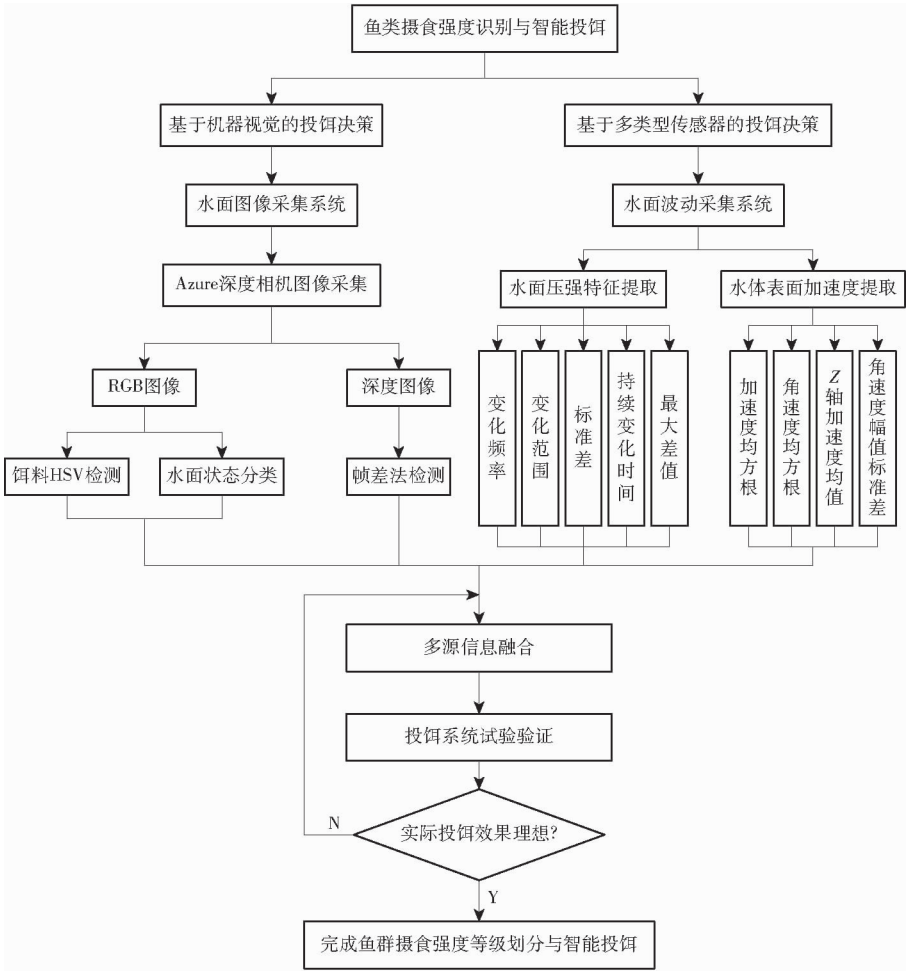


图 2　系统流程图

Fig. 2　System flowchart



图 3　RGB 和深度摄食图像

Fig. 3　RGB and depth feeding images

水面分布较集中的部位，将传感器固定在饵料集中区域，采集鲫鱼摄食过程水面表层压强的变化。试验共采集 149 组成年鲫鱼摄食过程水面压强数据，其中“强”类别有 40 组、“弱”类别有 71 组，“无”类别有 38 组。

将 HWT605 型加速度传感器安装在同一饵料集中区域的泡沫浮板上，在投喂过程中传感器将随着圈养桶内的水面上下起伏，从而得到水面的动态变化数据和水体状态等信息，获得 206 组不同摄食强度的数据样本，其中“强”类别有 70 组，“弱”类别有 68 组，“无”类别有 68 组。圈养桶内水体相对有限，鱼群摄食产生的整体水面波动特征会传播至整个水体，因此单个传感器在饵料集中区域附近能够有效捕捉到能反映鱼群整体摄食强度的代表性信号。

2　基于多源数据融合的鱼类摄食强度量化模型构建

2.1　基于改进 YOLO v8n－seg 分割算法的水面波动状态量化

2.1.1　网络总体结构

YOLO 系列算法是一种端到端的检测模型，核心思想是基于图像全局信息将图像划分为多个网格并在每个网格当中判断物体边界框和类别[13－14]。本文采用 YOLO v8n－seg 算法的网络结构与目标检测网络结构是一致的，在掩码生成方式上借鉴了 BOLYA 等[15]网络原理实现实例分割。本文基于 YOLO v8n－seg 框架并针对水面波动状态进行改进，在主干网络部分采用 Haar 小波下采样（Haar Wavelet DownSample，HWD）替代传统下采样层，通过空间频域分解机制保留图像低频纹理特征，在缓解边界模糊效应的同时降低计算复杂度。基于点采样机制重构上采样过程，其动态权重分配机制强化

多层级特征耦合,提升小尺寸目标识别准确率。改进 YOLO v8n－seg 网络框架如图 4 所示。

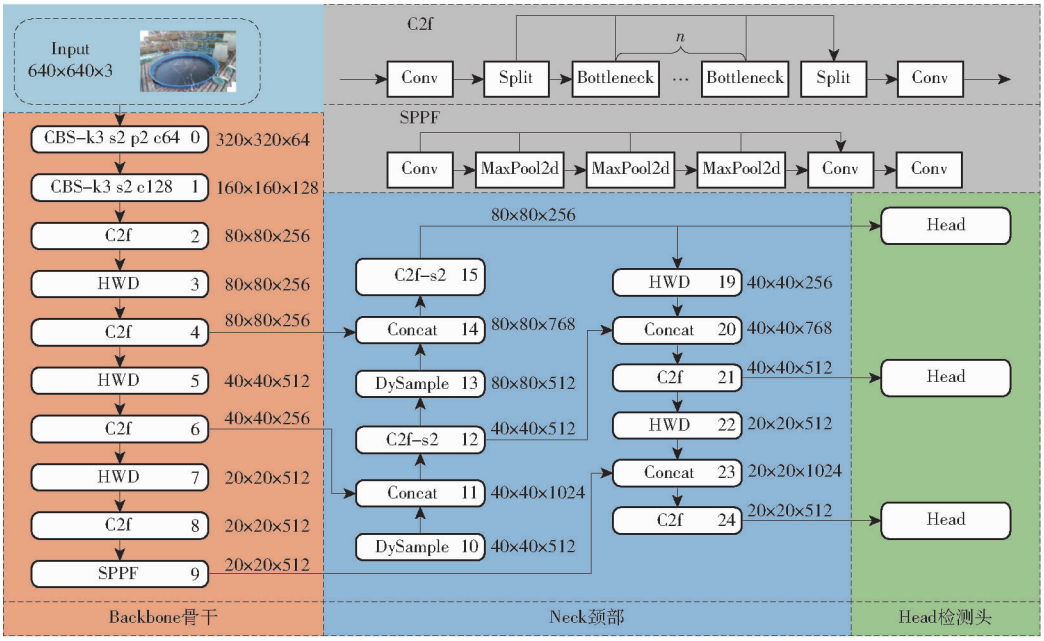


图 4 改进 YOLO v8n－seg 网络模型

Fig. 4 Improved YOLO v8n－seg network model

2.1.2 融合 HWD 模块的频域特征下采样优化

在 YOLO v8n－seg 架构中融合 HWD[16－18]模块,通过频域特征保持机制重构下采样策略改善水面目标的边缘分割精度,如图 5 所示。Haar 小波变换能够将图像信号分解为低频与高频分量,低频分量保留图像的主要结构信息,高频分量捕捉图像的边缘及纹理细节。HWD 模块将图像分解为 4 个子带,为确保整体图像结构信息不丢失,主要保留 LL 子带以压缩空间分辨率和减少特征图尺寸,减少计算量和压缩特征图尺寸,提升模型在 Jetson 等边缘设备上的推理速度;同时结合部分高频分量,捕捉图像在水平、垂直和对角线 3 个方向的细节。

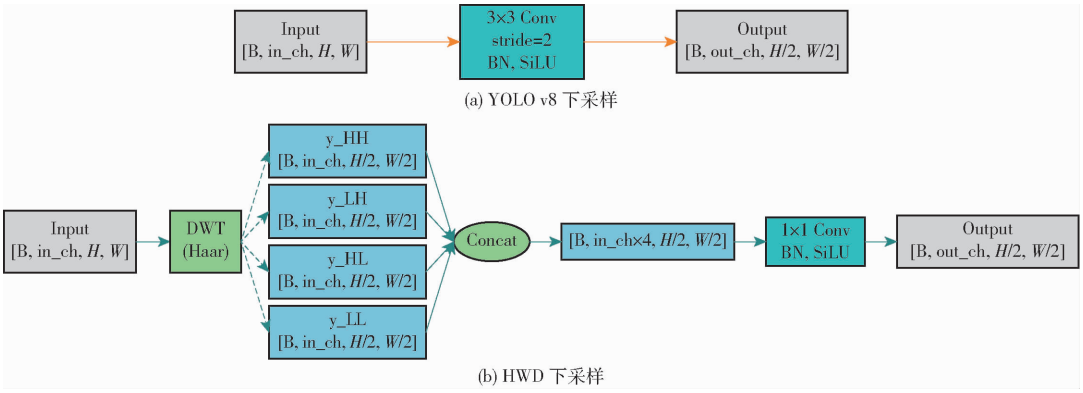


图 5 Haar Wavelet DownSample 模块

Fig. 5 Haar Wavelet DownSample module

在 YOLO v8n－seg 的 Backbone 部分,将原有的部分 Conv 直接替换为 HWD 下采样操作,使得网络能够在减少计算量,压缩特征图尺寸的同时保留更完整的空间信息。在 P3、P4、P5 层特征下采样阶段,引入 HWD 模块进行特征降维,减少下采样带来的信息损失,结合 C2f 结构的轻量级多分支连接方式,提升不同尺度特征的交互能力。

2.1.3 基于 DySample 的动态上采样边缘增强

由于实际场景中水面状态受光照、波纹等多种因素影响,水面与圈养桶的水体边界(水-桶交界区域)的分界常常显得模糊,导致使用 YOLO v8n－seg 进行实例分割时,水面状态分割的边缘精度较低。对此,在 YOLO v8n－seg 的 Neck 部分引入动态上采样模块(Dynamic sampling, DySample)[19－20]。DySample 模块通过 1×1 卷积学习动态偏移量,生成自适应的采样网格,同时该模块支持偏移量预测分组,每一组生成一组独立的偏移量,允许模块针对不同特征通道或区域应用多样化的采样策略。将预测的偏移量与初始采样网格结合,生成采样坐标,如图 6 所示。

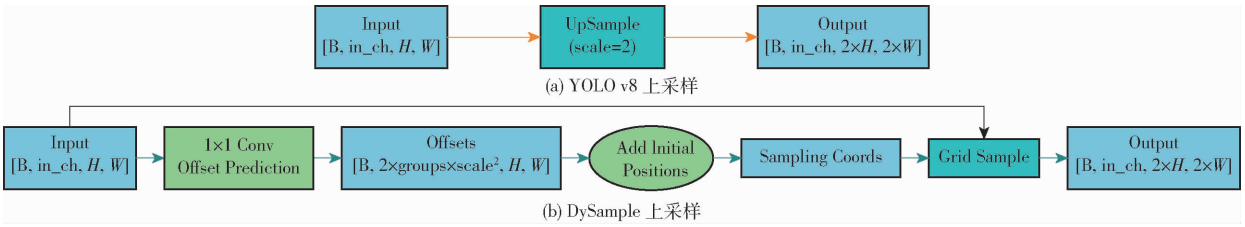


图 6　DySample 模块

Fig. 6　DySample module

与传统的固定上采样相比，在处理水面目标的分割任务时，DySample 模块能够减少水面边缘识别模糊的现象，在特征重建过程中可以保留更多的纹理细节信息。在模型改进过程中，DySample 模块根据摄食图像局部上下文信息动态生成各个非均匀采样点，能够提升水面状态分割和边缘精度。

2.2　基于 YOLO v8n－seg 水面分割区域的 HSV 鱼饵检测

色调饱和度明度（Hue saturation value，HSV）颜色检测主要基于色调（H）、饱和度（S）和明度（V）这 3 个关键参数，通过分析图像中每个像素点的色彩特征、颜色深浅与明暗变化识别和理解图像中的颜色信息[21]。采用 YOLO 模型对水产养殖投喂场景的 RGB 图像进行实例分割，在获得投喂过程圈养桶水体表面的分割掩码后利用 HSV 颜色检测方法识别水面淡黄色饵料区域面积。在特征提取阶段，将原始图像转换至 HSV 颜色空间，设置 HSV 最佳参数阈值组合 $H_{min}=115$、$H_{max}=176$、$S_{min}=0$、$S_{max}=52$、$V_{min}=120$、$V_{max}=241$，如图 7（每一组第 1 幅图为原始拍摄图，第 2 幅图为基于水面状态分割掩码（黄色填充）进行水面鱼饵（红色填充）HSV 检测效果图，第 3 幅图为单独水面鱼饵（红色填充）HSV 检测效果图）所示。模型将 HSV 颜色掩码与分割区域掩码融合，提取水面区域内淡黄色鱼饵特征，对符合条件区域进行鱼饵轮廓提取并采用红色区域填充。

2.3　基于深度图像的鱼类摄食强度量化方法

采用 Azure Kinect 型深度相机采集摄食过程中的深度图像，成年鲹鱼在投喂过程浮出水面进行摄食，甚至会产生激烈的抢食行为，这些都会引起剧烈水面波动，通过捕捉这些水面变化特征，从而准确量化水面的波动强度。

对深度相机采集到的连续 2 帧深度图像深度值差异进行分析，从中提取鱼群摄食过程水面波动的空间分布和时间变化特征，深度差值计算式为

$$D(i,j)=|F_t(i,j)-F_{t-1}(i,j)| \tag{1}$$

式中　$D(i,j)$——像素点(i,j)深度帧间差值

$F_t(i,j)$、$F_{t-1}(i,j)$——当前帧和上一帧的深度

对深度差值图像进行阈值化处理生成二值图后，通过轮廓检测算法提取变化区域轮廓，过滤微小轮廓干扰，统计剩余的有效轮廓数量后，进行阈值分类等级。当轮廓数量小于 3 时，系统判定水面状态为无波动；当轮廓数量在 3～5 之间时，系统判定水面状态为弱波动；当轮廓数量超过 5 时，系统判定水面状态为强波动，同时水面波动强度能够间接反映鱼群摄食强度。基于可见光图像的波动检测方法容易受环境光照波动及天气变化干扰，导致其在圈养场景中检测结果稳定性较低。而深度传感技术通过

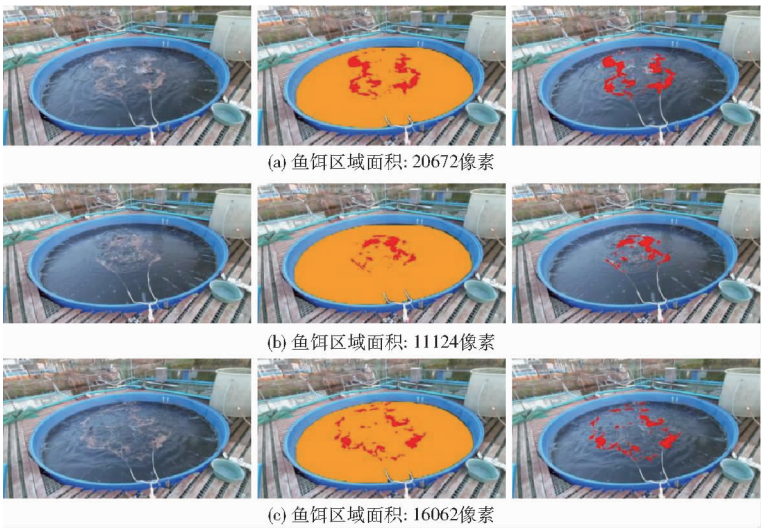
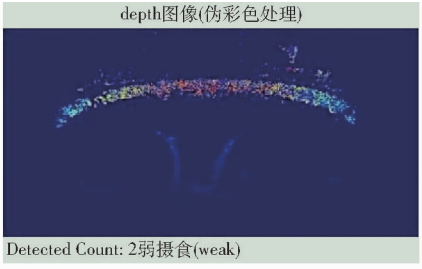


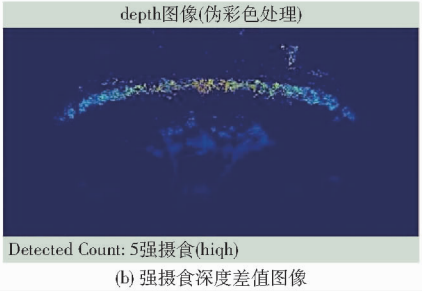
图 7　HSV 鱼饵检测效果

Fig. 7　Detection effect of HSV bait

物理距离测量直接获取水面三维形变数据,规避了光学成像的亮度敏感性缺陷,深度图像帧差法检测如图 8(图中展示深度图像帧差法检测结果,分别对应弱摄食、强摄食 2 种状态,其中水面中心蓝色轮廓表示波动区域)所示。



(a) 弱摄食深度差值图像



(b) 强摄食深度差值图像

图 8 深度图像帧差法

Fig. 8 Frame difference method on depth images

2.4 基于压强传感器和加速度传感器的鱼类摄食强度量化随机森林模型

2.4.1 随机森林算法

随机森林是一种传统机器学习算法,通过创建大量的决策树完成分类或回归任务,以提升整体模型的精确率和稳定性[22-23]。在训练每棵树时,都会从原始数据集中随机挑出一部分数据点,在每棵树的每个分裂节点处随机选取一部分特征寻找最佳分裂点。

2.4.2 HM29 型压强传感器特征提取

对采集到的压强数据进行特征提取,包含变化幅度、波动频率、标准差、持续变化时间和压强最大差值 5 种特征值,用于随机森林模型训练。

(1)变化幅度

变化幅度反映水面波动的最大压强变化量,是波动强度的重要标志。

(2)波动频率

波动频率为单位时间内压强变化的次数,通过计算相邻波峰或波谷之间的时间间隔估算波动频率。

(3)标准差

水面压强标准差表示压强变化范围,标准差越大,水面变化幅度越大,表明鱼群摄食活动较为激烈。

(4)持续变化时间

持续变化时间是指在摄食过程水面表层压强处于非稳定波动状态的持续时间,该参数间接反映了水面波动的稳定性和周期规律。

(5)压强最大差值

水面表层压强最大差值,是指鱼类摄食时水面所承受的最大压强与最小压强之间的数值差。

将提取的 5 种特征与已分类的摄食强度标签一同组成数据集,例如,在强摄食状态下,波动频率和压强最大差值(136 Hz 和 0.303 kPa)远高于无摄食状态(41 Hz 和 0.074 kPa),表明鱼群摄食强度越大,水面变化幅度越大。

2.4.3 HWT605 型加速度传感器特征提取

从 HWT605 型传感器获取的加速度数据中提取加速度均方根、角速度均方根、Z 轴加速度均值及角速度幅值标准差 4 类特征。

(1)加速度均方根A_{rms}

加速度均方根反映三轴加速度总体强度,能够表征鱼群活动剧烈程度,计算式为

$$A_{rms}=\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(A_{x,i}^2+A_{y,i}^2+A_{z,i}^2\right)} \tag{2}$$

式中 N——时间窗口内数据点数量

$A_{x,i}$、$A_{y,i}$、$A_{z,i}$——第 i 个数据点三轴加速度值

(2)角速度均方根ω_{rms}

角速度均方根反映三轴角速度总体强度,能够表征鱼群运动的方向变化,计算式为

$$\omega_{rms}=\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(\omega_{x,i}^2+\omega_{y,i}^2+\omega_{z,i}^2\right)} \tag{3}$$

式中 $\omega_{x,i}$、$\omega_{y,i}$、$\omega_{z,i}$——第 i 个数据点三轴角速度

(3)Z 轴加速度均值$A_{z,\mathrm{mean}}$

Z 轴加速度均值表示鱼群摄食过程中水面在 Z 轴方向平均加速度,能够反映摄食过程水面波动强度和波动趋势。

(4)角速度幅值标准差$\sigma_{\omega,mag}$

角速度幅值标准差反映角速度幅值波动程度,能够表征鱼群转向行为稳定性,计算式为

$$\sigma_{\omega,mag}=\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(\omega_{mag,i}-\overline{\omega}_{mag}\right)^2} \tag{4}$$

式中 $\omega_{mag,i}$——第 i 个数据点角速度幅值

$\overline{\omega}_{mag,i}$——时间窗口内角速度幅值均值

提取的这些特征对区分鱼群的不同摄食强度具有重要意义,例如,在强摄食状态下,Z 轴加速度均值和加速度均方根(1.038 4、1.046 8 m/s^2)明显高于无摄食状态(0.991 4、0.991 9 m/s^2),反映鱼群摄食强度对水面波动加速度的直接影响。

2.4.4 多源数据融合与投饵策略

通过多源数据融合,有利于进一步挖掘数据的

价值，提升信息分析的作用[24]。在系统前期分别得到 5 种决策模块的判断结果之后，根据每个数据源的可靠性和置信度，确定每个模块置信度权重，采用加权融合的方法得到最终鱼类摄食强度等级。后端加权融合公式为

$$P_{\text{intensity}} = P_{\text{yolo}}W_1 + P_{\text{depth}}W_2 + P_{\text{pressure}}W_3 + P_{\text{acceleration}}W_4 + P_{\text{bait}}W_5 \quad (5)$$

式中　W_1、W_2、W_3、W_4、W_5——YOLO v8 水面状态检测、深度图像帧差法检测、压强传感器检测、加速度传感器检测和 HSV 鱼饵检测的权重

P_{yolo}、P_{depth}、P_{pressure}、$P_{\text{acceleration}}$、P_{bait}——各模块判断结果

权重的分配是基于各类数据源在当前环境和鱼群摄食状态下的可靠性，经过多次试验调整，最终设置权重参数为 $W_1 = 0.20$；$W_2 = 0.15$；$W_3 = 0.20$；$W_4 = 0.15$；$W_5 = 0.30$。当鱼类摄食强度等级 $P_{\text{intensity}} < 0.8$，则判定鱼群处于强摄食状态；当 $0.8 \leqslant P_{\text{intensity}} < 1.5$，鱼群处于弱摄食状态；当 $P_{\text{intensity}} \geqslant 1.5$ 时，说明鱼群已经处于无摄食状态，无需投喂饵料。

在实际水产养殖中，投喂量通常按鱼类总体重的 2% 进行基准调控。基于养殖行为学观察，适度调控摄食强度可有效降低群体应激反应，据此设计了分级投喂策略：系统启动后首先执行 7 kg 基础饵料投喂，随后进入动态监测模式，当累计捕获 3 次弱摄食活跃度生物信号时，即触发投喂终止机制，在保障鱼类正常代谢需求的前提下实现精准营养管理。

2.5　风送式投饵机结构设计与可行性验证

投饵机硬件设计与通信部分是整个精准投喂系统核心，直接关系到设备在水产养殖中精准投喂的实现。本研究设计一套风送式投饵机，如图 9 所示。

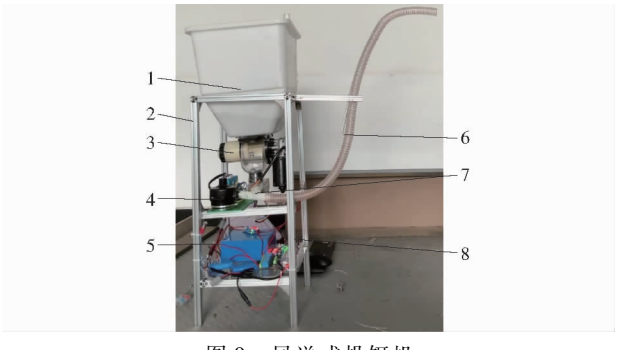


图 9　风送式投饵机

Fig. 9　Air-assisted bait spreader

1. 饵料仓　2. 铝条支架　3. 电动下料器　4. 直流风机　5. 电源模块　6. PU 风管　7. 三分管　8. STM32 微处理器

饵料仓位于投饵机的上部，下方连接下料器的大槽可调料盒，鱼饲料经过电动下料器旋转槽输送到三分管内，利用三分管右侧的直流风机吹动饲料通过 PU 风管顺利抛洒出去，风送式投饵机有以下特点。

（1）能针对圈养桶养殖方式进行投饵，直流风机额定功率为 204 W，最大风压可达 9.5 kPa，经过多次试验，在直径为 25 mm 的 PU 钢丝软管内能够轻松吹动鱼饵，最高投喂高度可达 1.5 m 左右，投喂直径可达 4 m，配合 45°俯仰角机构可以进一步优化投喂范围。因实际养殖户的圈养方式有陆基圈养和池塘圈养 2 种，可根据圈养桶实际情况，选配合适风机和投料管，达到预期投喂高度和范围。

（2）投喂的鱼饵饲料能够通过电机驱动下料器均匀投放，并通过树脂 3D 打印的三分管吹到圈养桶中心。三分管右侧连接直流风机及风管，最上面连接下料器出料口，能够确保饲料均匀散布，避免饵料堆积或浪费。

（3）控制系统采用 STM32 与 Jetson Nano 的协同工作模式，通过 UART 串口实时传输鱼群摄食强度等级数据。投饵机配备 20 000 mA·h 锂电池，单次充电可支持投饵机完成约 25 次投喂任务。

3　结果与分析

3.1　改进 YOLO v8n－seg 模型性能

3.1.1　试验环境

构建的模型在 Ubuntu18.04 操作系统下进行训练，主机为 IntelXeonPlatinum8474C，GPU 为 RTX4090，显卡内存为 24 GB。输入图像尺寸为 640 像素×640 像素，学习率初始值为 0.001，动量为 0.937，优化器设置为随机梯度下降，批次大小为 16，训练轮次为 300。

3.1.2　评价指标

采用精确率（Precision，P）、召回率（Recall，R）、平均精度均值（mean Average Precision，mAP）、模型参数量、浮点运算量（Floating point operations per second，FLOPS）、模型内存占用量和单帧耗时对模型的性能进行综合评价。

3.1.3　不同模型性能试验结果

对 YOLO v8n－seg、YOLO v8n－seg－HWD、YOLO v8n－seg－DySample、YOLO v8n－seg－HWD－DySample 4 种不同版本的轻量化模型进行性能对比试验，试验结果如表 1 所示。

从表 1 可知，改进 YOLO v8n－seg－HWD－DySample 模型具有较高的平均精度均值和召回率，分别达到 98.2% 和 98.0%。与基线模型相比，

表 1 不同模型性能试验结果

Tab. 1 Experimental results of different model performances

模型	精确率/%			召回率/%	平均精度均值/%	模型参数量	浮点运算量	模型内存占用量/MB	单帧耗时/ms
	强波动	弱波动	无波动						
Model1	98.3	94.5	97.9	96.6	96.9	3.26×10^6	1.20×10^{10}	6.47	7.5
Model2	98.3	97.2	98.0	97.8	97.8	2.94×10^6	1.15×10^{10}	5.88	6.7
Model3	98.3	96.5	98.0	97.7	97.6	3.27×10^6	1.20×10^{10}	6.50	7.9
Model4	98.3	98.4	98.0	98.0	98.2	2.95×10^6	1.15×10^{10}	5.90	7.0

注:Model1 为 YOLO v8n - seg,Model2 为 YOLO v8n - seg - HWD,Model3 为 YOLO v8n - seg - DySample,Model4 为改进 YOLO v8n - seg - HWD - DySample 模型。

mAP 提升 1.3 个百分点,召回率提升 1.4 个百分点,参数量、浮点运算量、模型内存占用量方面分别减少 9.5%、4.2% 和 8.8%,单帧耗时提升 6.7%。改进模型在投饵过程中针对水面状态分割的精确率有所提升,能够更好地保留水面边缘细节信息。YOLO v8n - seg - HWD - DySample 模型更加适应圈养桶养殖环境,其较快的检测速度也适合实际部署的条件,不同模型检测结果如图 10(每组第 1 幅图表示鱼群摄食强度为无,第 2 幅图表示鱼群摄食强度为弱,第 3 幅图表示鱼群摄食强度为强。各子图左上角的数字均表示模型对当前图像水面状态分类的置信度分数)所示。

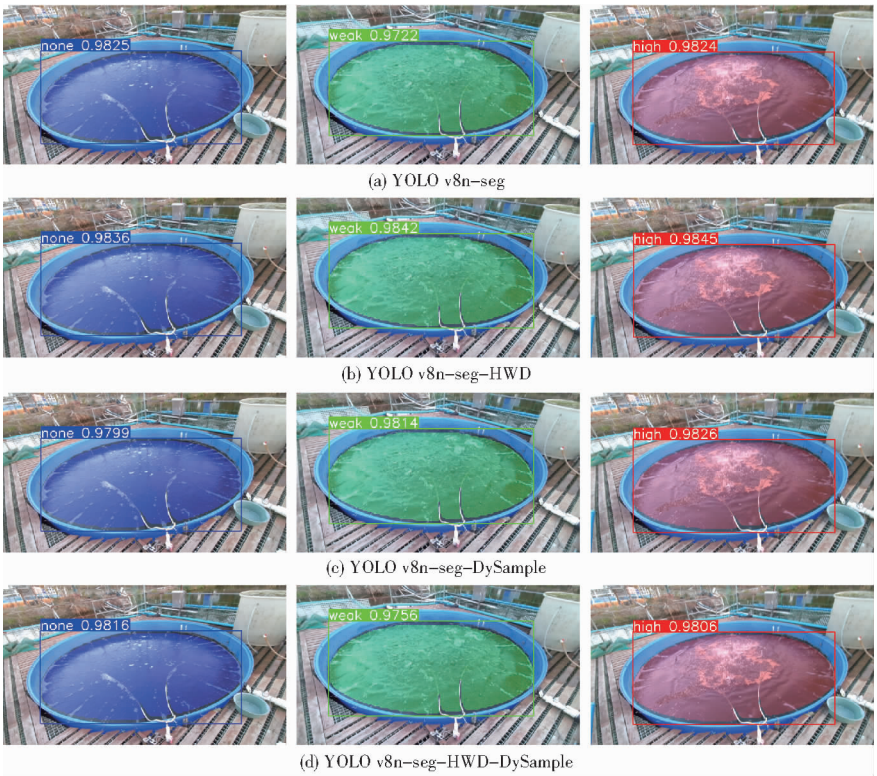


图 10 YOLO 不同改进模型检测结果

Fig. 10 Results of different improved YOLO models

3.1.4 不同模型分割结果对比

为了进一步验证改进模型对水面状态分割的检测性能,将比较典型的实例分割模型 MASK - RCNN[25]、RTMDET[26]、YOLACT 与 YOLO v8n - seg - HWD -DySample 模型进行对比试验,试验结果如表 2 所示,不同模型实际检测效果如图 11 所示。虽然 MASK - RCNN 和 YOLACT 模型召回率较高,但平均精度均值偏低,仅为 96.10% 和 96.90%。RTMDET 平均单帧耗时需要 228.54 ms,具有较大的模型内存占用量,严重占有了边缘设备的计算资源,不符合实际部署条件。从模型分割精确率、浮点运算量、模型内存占用量和单帧耗时综合考虑,YOLO v8n - seg - HWD - DySample 模型具有较高的检测精确率和召回率,最适合部署在 Jetson Nano 设备上,在饵料投喂时实时检测图像信息及饵料分布情况。

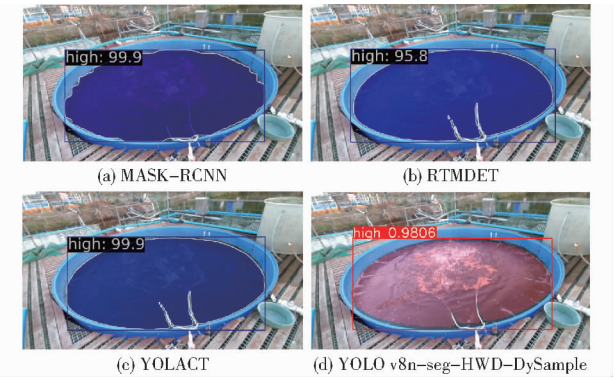
3.1.5 模型实际部署性能

为评估模型在边缘设备上的实际部署性能,将

表 2　不同实例分割算法对比

Tab. 2　Comparison of different instance segmentation algorithms

模型	平均精度均值/%	召回率/%	模型内存占用量/MB	单帧耗时/ms
MASK－RCNN	96.10	98.70	336.15	155.4
RTMDET	96.70	97.70	168.67	228.54
YOLACT	96.90	98.10	134.64	92.2
YOLO v8n－seg－HWD－DySample	98.20	98.00	5.90	7.0



(a) MASK-RCNN　(b) RTMDET　(c) YOLACT　(d) YOLO v8n-seg-HWD-DySample

图 11　不同实例分割模型检测结果

Fig. 11　Results of different instance segmentation models

YOLO v8n－seg 模型与改进 YOLO v8n－seg－HWD－DySample模型部署在 Jetson Nano 设备上进行对比，输入图像尺寸为 1 280 像素×720 像素。由表 3 可知，原模型平均精度均值为 96.9%，召回率为 96.6%，单帧耗时为 221.4 ms。而改进 YOLO v8n－seg－HWD－DySample 模型在相同条件下，mAP 达到 98.2%，召回率为 98.0%，单帧耗时为 203.5 ms。由于边缘设备的算力有限，改进模型单帧耗时比原 YOLO v8n－seg 模型提升 8.08%，证明其在 Jetson 设备上具有更优的实时性，为圈养模式智能投喂提供了更可靠的支持。

表 3　模型在 Jetson Nano 设备上的检测结果

Tab. 3　Detection result of the model on the Jetson Nano device

模型	mAP50/%	召回率/%	单帧耗时/ms
YOLO v8n－seg	96.9	96.6	221.4
YOLO v8n－seg－HWD－DySample	98.2	98.0	203.5

3.2　基于压强传感器和加速度传感器的鱼类摄食强度量化

3.2.1　水面表层压强-随机森林模型性能

基于每个特征在决策树分类过程中被使用的频率计算出各个特征的重要性和贡献度占比。由此可知，在随机森林模型当中，“压强变化频率”和“最大差值”2 个特征值对模型预测贡献程度最大，分别为 25.10% 和 25.03%，说明它们能够有效区分不同水面波动状态。此外，“变化范围”的重要性为 20.55%，“持续变化时间”为 19.95%，“标准差”为 9.36%。通过对训练参数的调整，随机森林模型分类准确率可达 95.56%，精确率为 95.24%、召回率为 97.53%、F1 值为 96.15%。

3.2.2　水面波动加速度-随机森林模型性能

在得到训练完的模型后，根据模型预测分类过程中每个特征使用的频率计算出 4 个特征重要性和贡献度占比。加速度均方根和 Z 轴加速度均值在模型分类中具有较高的贡献度，分别占 29.34% 和 31.29%。这表明 Z 轴方向加速度波动对于量化水面波动和鱼群摄食强度有较大的影响。角速度均方根贡献度为 17.93%，角速度幅值标准差贡献度为 21.44%。加速度随机森林模型分类准确率可达 98.44%、精确率为 96.97%、召回率为 99.35%，F1 值为 98.08%。对压强与加速度传感器分别从不同的物理意义上进行分析，有利于提高对摄食强度检测的准确性。

3.3　多源智能精准投喂系统性能

3.3.1　评价指标

本文提出 2 种重要的指标评价整套精准投喂系统，即投喂误差率(Feeding error rate, FER)和摄食强度评估精度(Accuracy of feeding intensity assessment, AFIA)。

(1) 投喂误差率 FER

投喂误差率用于衡量实际投饵量偏离预测合理投喂范围的程度，反映投喂策略精确性，计算式为

$$FER=\begin{cases}\dfrac{W_{\text{predmin}}-W_{\text{actual}}}{W_{\text{predmin}}}\times 100\% & (W_{\text{actual}}<W_{\text{predmin}})\\ \dfrac{W_{\text{actual}}-W_{\text{predmax}}}{W_{\text{predmax}}}\times 100\% & (W_{\text{actual}}>W_{\text{predmax}})\\ 0 & (W_{\text{predmin}}\leqslant W_{\text{actual}}\leqslant W_{\text{predmax}})\end{cases} \tag{6}$$

式中　W_{predmin}、W_{predmax}——系统计算的理论投喂量最小值和最大值

W_{actual}——投喂系统实际投喂饲料量

(2) 摄食强度评估精度 AFIA

摄食强度评估精度用于评估智能投喂系统对鱼群摄食强度程度分类的整体精确性，计算式为

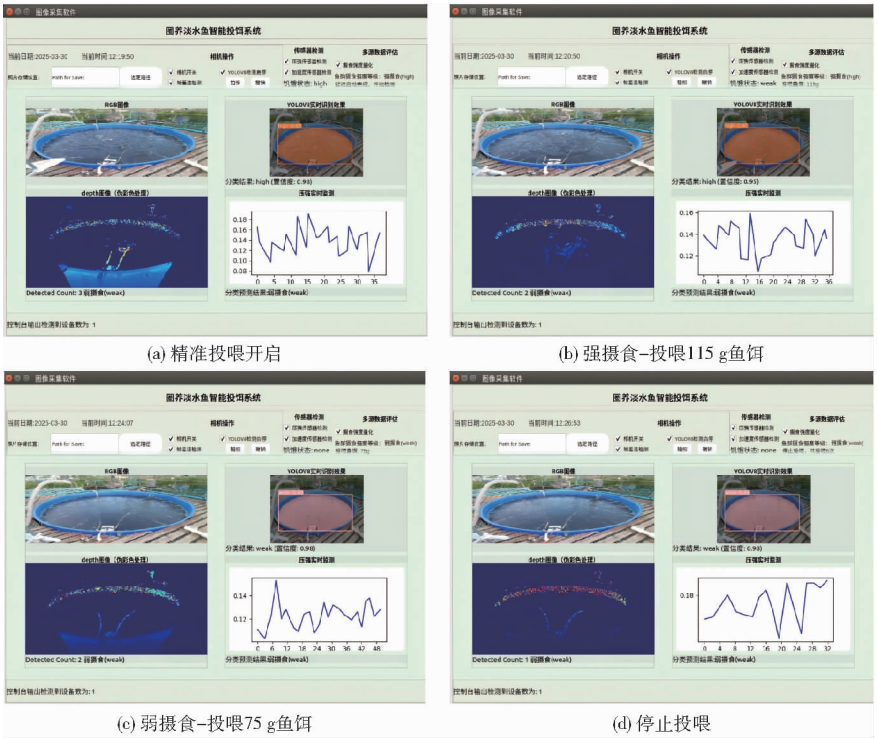
$$AFIA=\frac{\sum_{i=1}^{3}TP_i}{\sum_{i=1}^{3}(TP_i+FP_i)}\times 100\% \tag{7}$$

式中 TP_i、FP_i——第 i 类别真正例和假正例

在淡水鱼智能投喂系统效能评估中，投喂误差率作为衡量投喂精准性的核心评价指标。当 FER 指标为 0 时，表明系统预测与鱼群实际需求达到匹配。通过监测 FER 指标的变化趋势，可以精准识别投喂策略偏差程度。同时，引入摄食强度评估精度作为评估鱼群饥饿状态分类准确性的重要指标。

3.3.2 系统运行试验及结果

基于 Python 语言开发了一种多源精准智能投饵系统，利用 Qt 进行图形用户界面设计。为了保证数据采集、图像处理和智能投喂决策的实时性与流畅性，系统利用专门的线程负责处理 Azure Kinect 型深度相机和各类传感器的数据采集，确保检测过程数据流不间断；而多源数据融合分析和投喂指令发送则在独立的线程中进行，系统运行界面如图 12 所示。



(a) 精准投喂开启 (b) 强摄食–投喂115 g鱼饵

(c) 弱摄食–投喂75 g鱼饵 (d) 停止投喂

图 12 系统检测界面

Fig. 12 Software detection interface

在华中农业大学水产基地七号塘的 1 号圈养桶内，对其中圈养的鲫鱼鱼群进行了投饵验证试验。在每次投喂过程中，自动投饵机首先进行 7 kg 饲料的基础投喂，通过深度相机和传感器实时采集鱼群抢食行为数据，获得实时鱼群摄食强度等级；当系统累计检测到 3 次无摄食信号时，将结束本次投喂。试验结果如表 4 所示，共开展了 7 种不同投喂量试验，其中包含一开始 7 kg 鱼饵定量投喂、3 次强摄食

表 4 投喂试验过程

Tab. 4 Feeding experiment process

检测时间/s	视觉决策	压强决策	深度帧差决策	残余饵料决策	加速度决策	摄食强度	投饵机命令	结果
系统启动				定量投喂 7 000 g 鱼饵				
0 ~ 30	弱	弱	强	强	弱	强	强摄食投喂	正确
30 ~ 65				定量投喂 115 g 鱼饵				
65 ~ 95	强	弱	弱	强	无	强	强摄食投喂	正确
95 ~ 130				定量投喂 115 g 鱼饵				
130 ~ 160	弱	无	弱	弱	无	弱	弱摄食投喂	正确
160 ~ 181				定量投喂 75 g 鱼饵				
181 ~ 211	强	强	弱	强	无	强	强摄食投喂	正确
211 ~ 232				定量投喂 115 g 鱼饵				
232 ~ 262	弱	无	弱	强	无	弱	弱摄食投喂	正确
262 ~ 283				定量投喂 75 g 鱼饵				
283 ~ 313	弱	无	弱	弱	无	弱	弱摄食投喂	正确
313 ~ 334				定量投喂 75 g 鱼饵				
系统关闭				结束投喂				

投喂(115 g 鱼饵投喂)和 3 次弱摄食投喂(75 g 鱼饵投喂)。在多源智能精准投喂系统的实时检测过程中记录每次系统给出的鱼类摄食强度量化结果,并与人工根据圈养桶内水面波动程度和剩余饵料量判断得出的结果进行对比,如图 13(Pressure:压强检测;YOLO:YOLO v8n - seg 检测;Depth:深度图帧差法检测;Bait:鱼饵 HSV 检测;Acceleration:加速度检测;Intensity:摄食强度量化结果;Rating:鱼群摄食强度量化等级)所示,连续多天进行试验,得到鱼群摄食量化结果具有 95.45% 的准确率。

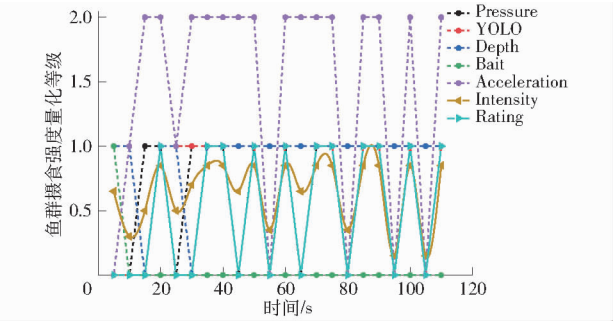


图 13　鱼群摄食强度量化曲线

Fig. 13　Quantification curves of fish school hunger levels

在 5 个批次的投饵试验过程中,通过分析预测投饵量和实际投饵量,根据人工投喂试验数据分析,将预测投喂量设定为 7 450 ~ 7 600 克,每天投喂 2 次,计算每次试验 FER,如表 5 所示。试验结果平均 FER 达到 1.72%,说明构建的投饵系统在实际圈养模式环境中能有效预测投饵量。

表 5　FER 指标

Tab. 5　FER indicators

试验批次	预测最小值/g	预测最大值/g	实际投喂量/g	投喂误差率/%
1 - 1	7 450	7 600	7 557.58	0
1 - 2	7 450	7 600	7 445.19	0
2 - 1	7 450	7 600	8 007.14	5.36
2 - 2	7 450	7 600	7 669.97	0.92
3 - 1	7 450	7 600	7 332.80	1.57
3 - 2	7 450	7 600	7 220.41	3.08
4 - 1	7 450	7 600	7 550.87	0
4 - 2	7 450	7 600	7 894.75	3.88
5 - 1	7 450	7 600	7 450.37	0
5 - 2	7 450	7 600	7 782.36	2.40

4　结论

(1)以 YOLO v8n - seg 模型为基线模型引入 HWD 模块替换 YOLO v8 原有传统的下采样层,运用二维离散小波变换将特征图分解为低频与高频分量。引入 DySample 上采样模块,动态调整采样点位置与整合多尺度特征。YOLO v8n - seg - HWD - DySample 模型平均精度均值达到 98.2%,召回率达到 98.0%,相较于基线模型在水面状态分割任务中分别提升 1.3、1.4 个百分点,并降低 8.8% 模型内存占用量与 9.5% 浮点运算量。

(2)通过深度图像量化鱼群活动引发的水面扰动特征,采用基于帧间差异计算帧差法捕捉摄食过程中的水面波动情况。通过帧差累积计算与动态阈值分类,将水面波动强度划分为强波动、弱波动、无波动 3 类指标,构建了鱼群摄食强度与水面波动物理状态之间的动态关联模型。

(3)通过 HM29 型压强传感器和 HWT605 型加速度传感器实时监测水面表层压强以及加速度特征。鱼群在投喂过程因摄食及抢食行为会产生较大的压强与加速度信号波动,从中提取 5 种压强特征与 4 种加速度特征,对水面波动进行等级划分。压强与加速度随机森林模型分类准确率分别达到 95.56% 和 98.44%,进一步增强了模型对鱼群摄食强度的量化能力。

(4)系统通过融合 RGB 图像 YOLO 水面状态分割与鱼饵检测、深度图像帧差法检测、HM29 型压强传感器及 HWT605 型加速度传感器等 5 种决策模块,按照各自的置信度权重构建加权融合决策模型。通过多次试验优化确定各决策模块的权重。该模型摄食强度评估准确率达到 95.45%,投喂误差率仅为 1.72%。

(5)风送式投饵机是智能投饵系统的核心投饵执行器,开发的投饵机以 STM32 微处理器为主控芯片,能够实时接收来自 Jetson Nano 数据处理中心的投饵指令。根据接收到的指令,控制直流风机与下料装置的启停,调整投饵作业的投饵量和投饵频率。

参　考　文　献

[1] ALIYU I, KOLO J G, AIBINU A M, et al. A proposed fish counting algorithm using digital image processing technique[J]. Nigerian Journal of Technology, 2017, 36(3): 113 - 120.

[2] 于泽,姜忠爱,张靖铎,等. 水产养殖自动投饵机发展现状[J]. 河北渔业, 2020(1): 57 - 60.
YU Ze, JIANG Zhongai, ZHANG Jingduo, et al. Development status of automatic bait feeders in aquaculture[J]. Hebei Fisheries, 2020(1): 57 - 60. (in Chinese)

[3] 刘朝阳,王永强,周聪玲,等. 室外池塘养殖投饵系统智能控制方法研究[J]. 中国农业科技导报, 2023, 25(5): 123 - 130.
LIU Chaoyang, WANG Yongqiang, ZHOU Congling, et al. Research on intelligent control method of feeding system in outdoor breeding pond[J]. Journal of Agricultural Science and Technology, 2023, 25(5): 123 - 130. (in Chinese)

[4] 赵建,朱松明,叶章颖,等. 循环水养殖游泳型鱼类摄食活动强度评估方法研究[J]. 农业机械学报, 2016, 47(8): 288 - 293.
ZHAO Jian, ZHU Songming, YE Zhangying, et al. Assessing method for feeding activity of swimming fishes in RAS[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(8): 288 - 293. (in Chinese)
[5] 朱明, 张镇府, 黄凰,等. 鱼类养殖智能投喂方法研究进展[J]. 农业工程学报, 2022, 38(7): 38 - 47.
ZHU Ming, ZHANG Zhenfu, HUANG Huang, et al. Research progress on intelligent feeding methods in fish farming[J]. Transactions of the CSAE, 2022, 38(7): 38 - 47. (in Chinese)
[6] SKØIEN K R, ALFREDSEN J A. Feeding of large-scale fish farms: motion characterization of a pneumatic rotor feed spreader [C]//2014 Oceans-St. John's. IEEE, 2014: 1 - 7.
[7] 贾成功,张学良,陈俊华,等. 基于鱼群摄食规律的投饵系统研究[J]. 机械工程师, 2017(8): 22 - 25,28.
JIA Chenggong, ZHANG Xueliang, CHEN Junhua, et al. Research on bait casting system based on feeding rule of fish[J]. Mechanical Engineer, 2017(8): 22 - 25,28. (in Chinese)
[8] 郑金存,叶章颖,赵建,等. 融合摄食过程声像特征的鱼类摄食强度量化方法研究[J]. 海洋与湖沼, 2024, 55(3): 577 - 588.
ZHENG Jincun, YE Zhangying, ZHAO Jian, et al. Sensitive detection of fish feeding intensity by using sound and image features of feeding process[J]. Oceanologia et Limnologia Sinica, 2024, 55(3): 577 - 588. (in Chinese)
[9] 陈明,张重阳,冯国富,等. 基于特征加权融合的鱼类摄食活动强度评估方法[J]. 农业机械学报, 2020, 51(2): 245 - 253.
CHEN Ming, ZHANG Chongyang, FENG Guofu, et al. Intensity assessment method of fish feeding activities based on feature weighted fusion[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 245 - 253. (in Chinese)
[10] ZHOU C, LIN K, XU D, et al. Near infrared computer vision and neuro-fuzzy model-based feeding decision system for fish in aquaculture[J]. Computers and Electronics in Agriculture, 2018, 146: 114 - 124.
[11] 赵思琪,丁为民,张建凯. 基于模糊逻辑控制的鱼塘养殖精准投饲系统设计与试验[J]. 农业现代化研究, 2019, 40(3): 527 - 536.
ZHAO Siqi, DING Weimin, ZHANG Jiankai. Design and experiment of precision feeding system of pond culturing based on fuzzy-logic control[J]. Research of Agricultural Modernization, 2019, 40(3): 527 - 536. (in Chinese)
[12] 俞国燕,钱利文,刘皞春,等. 基于双目相机和深度学习的鱼类摄食强度分析方法[J]. 农业机械学报, 2025, 56(3): 403 - 413,424.
YU Guoyan, QIAN Liwen, LIU Haochun, et al. Design and experimentation of fish feeding intensity system based on binocular cameras and deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 403 - 413, 424. (in Chinese)
[13] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 779 - 788.
[14] REDMON J, FARHADI A. YOLO 9000: better, faster, stronger[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017: 7263 - 7271.
[15] BOLYA D, ZHOU C, XIAO F, et al. Yolact: real-time instance segmentation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. IEEE, 2019: 9157 - 9166.
[16] XU G, LI W, ZHANG X, et al. Haar wavelet downsampling: a simple but effective downsampling module for semantic segmentation[J]. Pattern Recognition, 2023, 143: 109773.
[17] SONG Z, YANG J, ZHANG D, et al. Semi-supervised dim and small infrared ship detection network based on Haar wavelet [J]. IEEE Access, 2021, 9: 29686 - 29695.
[18] PAN P, YUAN F, CHENG E. Underwater image de-scattering and enhancing using dehazenet and HWD[J]. Journal of Marine Science and Technology, 2018, 26(4): 1 - 13.
[19] LIN Z, YUN B, ZHENG Y. Ld-YOLO: a lightweight dynamic forest fire and smoke detection model with dysample and spatial context awareness module[J]. Forests, 2024, 15(9): 1630.
[20] LIU W, LU H, FU H, et al. Learning to upsample by learning to sample[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. IEEE, 2023: 6027 - 6037.
[21] SURAL S, QIAN G, PRAMANIK S. Segmentation and histogram generation using the HSV color space for image retrieval[C]//Proceedings of International Conference on Image Processing. IEEE, 2002: 589 - 592.
[22] 方匡南,吴见彬,朱建平,等. 随机森林方法研究综述[J]. 统计与信息论坛, 2011, 26(3): 32 - 38.
FANG Kuangnan, WU Jianbin, ZHU Jianping, et al. A review of random forests algorithm[J]. Statistics & Information Forum, 2011, 26(3): 32 - 38. (in Chinese)
[23] 马玥,姜琦刚,孟治国,等. 基于随机森林算法的农耕区土地利用分类研究[J]. 农业机械学报, 2016, 47(1): 297 - 303.
MA Yue, JIANG Qigang, MENG Zhiguo, et al. Classification of land use in farming area based on random forest algorithm [J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(1): 297 - 303. (in Chinese)
[24] 化柏林,李广建. 大数据环境下多源信息融合的理论与应用探讨[J]. 图书情报工作, 2015, 59(16): 5 - 10.
HUA Bolin, LI Guangjian. Discussion on theory and application of multi-source information fusion in big data environment[J]. Library and Information Service, 2015, 59(16): 5 - 10. (in Chinese)
[25] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R - CNN[C]//Proceedings of the IEEE International Conference on Computer Vision. IEEE, 2017: 2961 - 2969.
[26] LY C, ZHANG W, HUANG H, et al. Rtmdet: an empirical study of designing real-time object detectors[J]. arXiv preprint arXiv, 2022: 2212.07784.