

doi:10.6041/j.issn.1000-1298.2025.02.047

赤点石斑鱼氨氮应激行为嵌入式表征研究

聂鹏程¹ 钱程¹ 汪清平¹ 曾国权² 马建忠² 刘世晶³

(1. 浙江大学生物系统工程与食品科学学院, 杭州 310058; 2. 浙江省海洋水产养殖研究所, 温州 325000;
3. 中国水产科学研究院渔业机械仪器研究所, 上海 200092)

摘要: 基于应激行为学的赤点石斑鱼应激行为表征是实现赤点石斑鱼氨氮胁迫识别的前提与基础,但现有方法大多依赖于高性能硬件,不利于行为表征方法在养殖现场嵌入式系统上部署和应用。针对这一问题,结合赤点石斑鱼氨氮胁迫环境下活动量减少、躯体痉挛失衡等症状,提出了一种基于轻量化检测跟踪算法的赤点石斑鱼氨氮应激行为表征方法。首先使用 GhostV2 卷积对 YOLO v5s 进行轻量化改进,采用 AFPN 来支持不同维度特征直接融合,消融对比实验结果表明,改进后轻量化模型准确率和召回率分别为 94.3% 和 89.5%,平均精度均值为 96.2%,较改进前提高 1.6 个百分点,模型内存占用量约为轻量化前模型的 60%。为了减少在复杂环境中跟踪时赤点石斑鱼 ID 频繁跳变的问题,本文在 Ocsort 中嵌入了一个轻量级的外观特征提取网络并在目标关联时将目标的外观相似度矩阵引入总匹配代价矩阵;对比实验结果表明,改进后跟踪算法 MOTA 和 IDF1 分别为 94.7% 和 69.3%,比 YOLO v5s 与 OC-SORT 的检测跟踪算法分别提高 3.2、6.7 个百分点。最终结合石斑鱼氨氮应激行为学研究结果,选用赤点石斑鱼平均运动速度、躯体失衡石斑鱼数量来表征赤点石斑鱼氨氮应激行为,行为识别准确率为 92.2%,可准确检测出赤点石斑鱼是否处于氨氮胁迫环境中。本文的轻量化表征方法可部署到 Jetson Orin Nano 嵌入式系统上,平均运行速度为 6 f/s,可为工厂化赤点石斑鱼养殖氨氮胁迫的高效实时识别提供技术支撑。

关键词: 赤点石斑鱼; 氨氮应激行为表征; YOLO v5; Ocsort; 嵌入式系统部署

中图分类号: S951.2 文献标识码: A 文章编号: 1000-1298(2025)02-0503-08 **OSID:** 

Behavioral Representation for Ammonia-nitrogen Stress of *Epinephelus akaara* for Embedded System

NIE Pengcheng¹ QIAN Cheng¹ WANG Qingping¹ ZENG Guoquan² MA Jianzhong² LIU Shijing³

(1. College of Biosystems Engineering and Food Science, Zhejiang University, Hangzhou 310058, China

2. Zhejiang Mariculture Research Institute, Wenzhou 325000, China

3. Fishery Machinery and Instrument Research Institute, Chinese Academy of Fishery Sciences, Shanghai 200092, China)

Abstract: The stress behavior representation based on research on ammonia nitrogen stress behavior is the premise and basis for realizing the recognition of ammonia nitrogen stress of *Epinephelus akaara*. However, most of the existing methods rely on high-performance hardware, which is not conducive to the embedded deployment and application of behavior representation methods in aquaculture. Taking symptoms such as reduced activity and imbalanced body of *Epinephelus akaara* under stress environment into account, a behavior representation method was proposed to represent the ammonia nitrogen stress behavior of *Epinephelus akaara* based on lightweight detection and tracking algorithm. In the detection algorithm, GhostV2 convolution was firstly used to lighten the feature extraction network of YOLO v5s. Then asymptotic feature pyramid network was integrated into the neck of YOLO v5s to support direct interactive fusion of different dimensional features. The results of ablation and comparison experiments showed that the accuracy and recall rate achieved 94.3% and 89.5% and mAP@0.5 of the lightweight model was 96.2%, which was 1.6 percentage points higher than that of the original model while the model volume was about 60% of that of the original model. In the tracking algorithm, a lightweight ReID

收稿日期: 2024-02-01 修回日期: 2024-04-21

基金项目: 浙江省重点研发计划项目(2021C02025)、浙江省三农九方项目(2023SNJF077)和温州市农业高新园区开放性项目(KN20210009)

作者简介: 聂鹏程(1982—),男,研究员,博士生导师,主要从事数字农业与智能农业技术研究,E-mail: pcn@zju.edu.cn

network was embeded into Ocsort and the appearance similarity matrix was introduced into the matching cost matrix in target association period. Comparison experiments showed that MOTA and IDF1 of improved tracking algorithm achieved 94.7% and 69.3%, which were 3.2 percentage points and 6.7 percentage points higher than that of the original Ocsort with YOLO v5s. Combined with the research on ammonia nitrogen stress behavior, average velocity and number of imbalanced *Epinephelus akaara* were selected to characterize the ammonia nitrogen stress behavior of *Epinephelus akaara*. The accuracy of identifying the behavior of *Epinephelus akaara* based on the characterization proposed method was 92.2%, which can accurately classify whether the *Epinephelus akaara* was under ammonia nitrogen stress environment. The lightweight characterization method can be deployed on Jetson Orin Nano embedded system, with an average speed of 6 f/s, providing technical support for efficient and real-time identification of ammonia nitrogen stress in aquaculture.

Key words: *Epinephelus akaara*; ammonia-nitrogen stress behavior representation; YOLO v5; Ocsort; embedded deployment

0 引言

我国已成为世界上最大的石斑鱼养殖国家,并且工厂化养殖已经成为一种重要的养殖方式^[1]。但在工厂化养殖高密度条件下,石斑鱼极易暴露在氨氮胁迫的环境中。根据应激行为学的研究,处于氨氮胁迫下的石斑鱼短时间内会出现呼吸机能下降等异常行为,而且会增加患病风险,甚至导致石斑鱼大规模死亡^[2-5]。

传统的水产养殖主要有两种方式来表征石斑鱼行为,并判断其是否受到氨氮胁迫:一种是依靠养殖人员的经验和肉眼观察石斑鱼的行为特征,但这种方式实时性差、劳动力需求大;另外一种方式是依靠氨氮传感器实时监测水质中氨氮浓度,但这种方式对传感器的精度要求高,长时间浸泡在海水中的传感器极易腐蚀。目前绝大多数高精度氨氮传感器依赖进口且在海水中的使用寿命短,因此基于氨氮传感器的表征方式整体实施成本高、难以大规模推广。

计算机视觉作为一种非侵入式、成本相对可控且易于推广的新方法,给渔业养殖的智能化转型带来了新思路。针对鱼类异常行为识别,一些学者研究基于图像分类的方法对鱼类行为进行直接识别^[6-7]。这些方法都在不使用时空信息的情况下直接对图像进行分类,但鱼群行为通常由长序列时空信息表示,仅从单幅图像识别鱼群行为有可能丢失关键信息造成误判。

基于多目标跟踪的鱼类异常行为检测与表征近年来受到了极大的关注。通过对鱼类的行为进行智能检测和跟踪,根据跟踪结果再提取鱼类行为就可以反演鱼类养殖的环境状况和健康状况^[8-10]。

上述基于多目标跟踪的鱼类异常行为表征方法虽然取得了较好的结果,但这些表征方法大都比较复杂、部署困难,难以应用在实际的工厂化养殖环境中。因此,本文提出一种基于 YOLO v5_GA 和 LD_

Ocsort 轻量化检测跟踪算法的氨氮应激行为表征方法,针对赤点石斑鱼氨氮胁迫下的行为进行特征提取与表征并部署到嵌入式系统上,以期对赤点石斑鱼工厂化养殖氨氮胁迫识别与管控提供思路。

1 数据采集与处理方法

1.1 数据采集

赤点石斑鱼氨氮胁迫实验在浙江省温州市浙江省海洋水产养殖研究所洞头基地进行。实验中将 200 尾体长为(10±1) cm 的赤点石斑鱼分为 10 组,每组都准备质量浓度为 0 mg/L 和 10 mg/L 两种氨氮环境。其中,10 mg/L 质量浓度环境是用 NH₄Cl 配置出的氨氮胁迫环境;0 mg/L 质量浓度环境为满足赤点石斑鱼养殖要求的正常养殖环境。

实验系统主要由养殖水箱、视频采集系统和计算机组成。养殖水箱为圆柱形,直径约为 0.6 m,所有环境水深约为 0.5 m。视频采集系统主要由帧率为 30 f/s 的摄像头和安装摄像头的桁架组成。在此期间,保证溶解氧质量浓度 5.8~7.0 mg/L、水温 21~27℃、pH 值 7.7~8.0,避免其他水质因子对氨氮胁迫实验的影响,两种环境中的赤点石斑鱼视频截图如图 1 所示。

1.2 数据集构建

从采集的 30 个视频中构建赤点石斑鱼氨氮胁迫检测跟踪数据集,每个视频时长为 10 min。首先,从获取的 30 个视频中尽可能多地选择 8 000 幅图像,通过 Labelimg 标注这些图像,按照比例 7:2:1 随机划分 8 000 幅图像作为训练集、验证集、测试集,构建赤点石斑鱼检测数据集。然后选取 10 个视频,使用 Darklabel 对这些视频进行标注,用于评估本文提出的赤点石斑鱼跟踪算法。

2 基于轻量级检测跟踪算法的行为表征

本文研究对象为氨氮胁迫环境下的赤点石斑




图 1 两种环境中赤点石斑鱼视频截图

Fig. 1 *Epinephelus akaara* in two environments

鱼,在氨氮胁迫实验中出现了活动量减少、躯体痉挛失衡等症状。针对这些特征,结合石斑鱼氨氮应激行为学成果,本文提出了一种基于 YOLO v5_GA 和 LD_Ocsort 轻量化检测跟踪算法的赤点石斑鱼氨氮应激行为表征方法,具体如图 2 所示。先由 YOLO v5_GA 检测出赤点石斑鱼并检测出痉挛失衡的赤点石斑鱼,再由 LD_Ocsort 对前后帧检测出的赤点石斑鱼目标进行跟踪匹配。在跟踪结果的基础上提取平均速度和躯体痉挛失衡赤点石斑鱼数量就可以表征赤点石斑鱼应激行为,进而反演养殖环境状况。




图 2 赤点石斑鱼氨氮应激行为表征方法

Fig. 2 Behavioral representation for ammonia-nitrogen stress of *Epinephelus akaara*

此外,本文应用场景为赤点石斑鱼工厂化养殖场,这种场景下所使用的处理器大多为算力有限的嵌入式平台,因此有必要对检测跟踪算法进行轻量化处理后再进行应激行为表征。

2.1 轻量化 YOLO v5_GA 检测模型

YOLO 系列是一种精度高、检测速度快的检测器,已被广泛应用于鱼类智能检测中^[11-14]。本文使用的检测模型是 YOLO v5,在保持较高准确率和速度的同时,也有更好的鲁棒性。YOLO v5 主要包括 Input、Backbone、Neck 和 Detection Head 4 部分。尽管 YOLO v5 有较高的检测精度,但实际养殖环境中的低算力处理器难以满足 YOLO v5 高计算复杂度需求。为了解决上述问题,本文提出了一种更轻量级的检测模型 YOLO v5_GA,其结构如图 3 所示。在改进的模型中引入了 GhostV2 卷积来减少检测模型中的参数量;利用 AFPN 特征融合方式替换 Neck 中原有的融合方式,从而增强特征融合效果并简化网络结构。

2.1.1 检测模型轻量化

传统卷积网络为了得到比较全面的信息会产生大量相似冗余的特征信息,导致卷积网络参数量大、计算时间长。本文在 Backbone 和 Neck 中引入 GhostV2 卷积^[15]替换其中的传统卷积。GhostV2 卷积由两个模块组成:Ghost 模块和长距离注意力机制模块;将输入特征经过两个模块处理后的特征逐元素相乘就可以得到最后的输出特征。与传统卷积相比,GhostV2 卷积既能有效减少冗余特征信息,又能充分利用解耦全连接注意力机制,从而在空间上实现信息交互、长距离信息捕捉。

此外,本文用步长为 1 的 GhostV2bottleneck 结构替换 C3 模块中原有 bottleneck 结构形成了 C3GhostV2 模块。在 Backbone 特征提取网络中,使用 C3GhostV2 模块以进一步降低骨干特征提取网络的参数量和计算复杂度。在后续新构建的特征融合网络中,也使用 C3GhostV2 模块在第 2 次特征融合前对第 1 次特征融合的结果进行特征再提取。




图3 改进的轻量化YOLO v5_GA网络结构图

Fig.3 Improved lightweight YOLO v5_GA network structure diagram

2.1.2 渐进特征金字塔网络

作为一种渐进特征融合网络,AFPN(Asymptotic feature pyramid network)支持非相邻层级的直接交互,渐进融合了低、中、高层特征^[16]。与FPN+PAN的特征融合方式相比,AFPN避免了不相邻特征间较大的语义差异,因此取得了比FPN+PAN更好的效果。受AFPN的启发,YOLO v5_GA在Neck中采用AFPN特征融合方式,其中低层特征C1、中层特征C2和高层特征C3分别由Backbone中第2个C3GhostV2模块、第3个C3GhostV2模块和SPPF模块产生,分别表示8、16、32倍下采样特征。整个特征融合方式如下:首先,经过GhostV2卷积的中低层特征C1和C2进行自适应特征融合ASFF_2^[17]。在首次自适应特征融合完成后,中低层特征经过C3GhostV2模块进一步提取特征后与高层特征进行第2次自适应特征融合。在所有特征融合完成后,生成的多尺度特征P1、P2、P3供后续的Detection Head处理产生检测结果。整个多尺度特征渐近融合过程如图4所示。




图4 AFPN特征融合方法

Fig.4 Way of feature fusion by AFPN

在特征自适应融合之前需进行上采样和下采样

以对齐自适应融合时的输入特征维度。在第1次自适应融合ASFF_2中,采用尺度因子为2的1×1卷积和双线性插值对C2的2倍上采样特征进行处理,并采用步长为2的2×2卷积对C1的2倍下采样特征进行处理,目的是在C1和C2自适应融合前对齐输入特征维度。类似地,在第2次自适应融合ASFF_3中,同样采用尺度因子为2、4的1×1卷积和双线性插值分别进行2、4倍上采样,采用步长为2、4的2×2、4×4卷积分别进行2、4倍下采样。ASFF_2和ASFF_3的特征融合公式分别为

$$\mathbf{y}_{ij}^l = \alpha_{ij}^l \mathbf{x}_{ij}^{1 \rightarrow l} + \beta_{ij}^l \mathbf{x}_{ij}^{2 \rightarrow l} \tag{1}$$

式中, α_{ij}^l 和 β_{ij}^l 表示输入特征向量 $\mathbf{x}_{ij}^{1 \rightarrow l}$ 和 $\mathbf{x}_{ij}^{2 \rightarrow l}$ 在位置 (i,j) 的空间融合权重。

$$\mathbf{y}_{ij}^l = \alpha_{ij}^l \mathbf{x}_{ij}^{1 \rightarrow l} + \beta_{ij}^l \mathbf{x}_{ij}^{2 \rightarrow l} + \gamma_{ij}^l \mathbf{x}_{ij}^{3 \rightarrow l} \tag{2}$$

式中, γ_{ij}^l 表示输入特征向量 $\mathbf{x}_{ij}^{3 \rightarrow l}$ 在位置 (i,j) 的空间融合权重。

2.2 轻量级LD-Ocsort跟踪算法

OC-SORT算法是一种继承于SORT算法的两阶段跟踪算法,其核心是通过检测器将前帧中的目标检测出来,再通过卡尔曼滤波算法进行后帧预测,然后使用匈牙利算法匹配对预测值和实际观察值进行匹配与跟踪。

与SORT算法相比,OC-SORT提出了3种优化策略:观测中心动量(Observation-centric momentum, OCM)、观测中心恢复(Observation centered recovery, OCR)和观测中心更新(Observation reupdate, ORU)^[18]。

然而,OC-SORT算法单纯依靠运动特征进行跟踪,难以适应本文目标遮挡频繁的跟踪任务。因此,本文提出了一个嵌入轻量级外观特征提取网络的跟踪算法LD_Ocsort,该外观特征提取网络基于

GhostNet0.5x^[15]构建,在提取完外观特征向量后将前后帧目标外观特征相似度矩阵融入匹配代价矩阵中进行匹配,进而有效减少ID切换次数。




图5 LD_Ocsort 算法跟踪流程

Fig. 5 Tracking process of LD_Ocsort

然后,OCM 将前帧目标预测框和本帧检测框关联起来,将预测框与检测框的动量特征信息、外观特征向量以及交并比信息融入到匹配代价矩阵中,然后利用匈牙利算法分配 ID 并跟踪。此阶段的匹配代价矩阵计算公式为

$$C_{OCM} = C_{appr}(X_{t-1}, D_t) + C_{IOU}(X'_t, D_t) + C_V(X'_t, D_t) \tag{3}$$

式中, X'_t 表示 t 帧卡尔曼滤波预测的轨迹预测框, D_t 表示 t 帧检测框, X_{t-1} 表示 $t-1$ 帧的轨迹框。 C_V 、 C_{appr} 、 C_{IOU} 分别为动量特征、外观相似度、交并比特征矩阵。

最后,将未匹配的预测框和未匹配检测框输入 OCR,OCR 在得到未匹配轨迹框和未匹配检测框的外观相似度代价矩阵后用匈牙利算法进行匹配。此阶段的匹配代价矩阵计算公式为

$$C_{OCR} = C_{appr}(X_{t-1}^{unmatched}, D_t^{unmatched}) \tag{4}$$

式中 $X_{t-1}^{unmatched}$ —— $t-1$ 帧未匹配的轨迹框
 $D_t^{unmatched}$ —— t 帧未匹配的检测框

3 实验结果与分析

本文在 PC 端数据处理配置如下:CPU 为 Intel i5-12400,内存 32 GB,GPU 为 GTX3080ti。操作系统为 Windows 10,64 位,深度学习框架为 Pytorch 1.8.0,CUDNN 11.1。

本文使用的嵌入式端计算平台为:Jeston Orin Nano,GPU 为 32-Tensor core Ampere,内存为 4 GB。相应环境配置为:Ubuntu 20.04,CUDA 11.4.315、cuDNN 8.6.0.166,JetPack 5.1.1、Python 3.8、Pytorch 1.11。

3.1 YOLO v5_GA 检测模型结果分析

在目标检测模型评价中,使用精确率(Precision)、召回率(Recall)、平均精度均值(mAP)、模型内存占用量 4 个指标进行检测模型评价。

LD_Ocsort 算法跟踪流程分为 3 步,如图 5 所示。首先,由检测器对本帧目标进行检测,同时利用 Kalman 滤波器对前帧轨迹进行预测。

3.1.1 YOLO v5_GA 训练结果分析

在 YOLO v5_GA 训练时,使用 SGD 优化器进行训练,训练阶段目标检测模型的 momentum 设置为 0.937。训练时初始学习率设置为 0.01,训练批次设置为 16,输入图像尺寸设置为 640 像素×640 像素,并在训练前使用 Mosaic 数据增强。

为了评估 YOLO v5_GA 的性能,在每个训练轮次结束后在验证数据集上进行测试。从图 6 可以看出,在前 50 个训练轮次的训练损失值迅速减小,随着迭代次数的增加,模型损失逐渐趋于稳定。最终经过 260 个训练轮次后损失函数收敛,训练结束,模型精确率和召回率分别稳定在 94.3% 和 89.5% 左右。




图6 YOLO v5_GA 训练结果分析

Fig. 6 Training results of YOLO v5_GA

3.1.2 消融实验结果分析

为了能在嵌入式平台上部署轻量级检测模型,本文基于轻量化目标首先在 Backbone 和 Neck 中采用 GhostV2 卷积和 GhostV2bottleneck 使模型内存占用量变小,从结果可看出 GhostV2 中长距离解耦全连接注意力机制对空间上特征提取和聚合能力的增强,使得 YOLO v5s-GhostV2 的检测效果相较于 YOLO v5s 有所提升。此外,从表 1 也可以看出 AFPN 使用更低的内存占用量达到与 YOLO v5s 相近的检测效果。

表 1 消融实验结果

Tab.1 Results of ablation test

检测模型	精确率/	召回率/	mAP@	内存占用
	%	%	0.5/%	量/MB
YOLO v5s	91.6	92.1	94.6	13.70
YOLO v5s - GhostV2	93.8	88.3	95.8	7.72
YOLO v5s - AFPN	90.2	88.2	94.5	11.70
YOLO v5s - GhostV2 + AFPN	94.3	89.5	96.2	8.09

当同时使用 GhostV2 和 AFPN 的特征融合方式时,精确率提 2.7 个百分点,mAP@0.5 提高 1.6 个百分点,YOLO v5_GA 的精确率和平均精度均值均有所上升,而模型内存占用量减少了约 40%,有利于检测模型在嵌入式系统上部署。

3.1.3 对比实验结果分析

为了选择最佳的检测模型,本文将 YOLO v5_GA 与 Faster R - CNN^[19]、SSD^[20]、YOLO v8s^[21] 几种常见的检测模型进行比较,实验结果如表 2 所示。与两阶段检测器 Faster R - CNN 相比,YOLO v5_GA 在 mAP@0.5 上提高 0.4 个百分点,同时模型内存占用量仅为 Faster R - CNN 的 1/40。与单阶段检测器 SSD 相比,YOLO v5_GA 的 mAP@0.5 提高 4.6 个百分点,而模型内存占用量仅为 SSD 的 1/23。

表 2 不同模型综合对比结果

Tab.2 Comprehensive comparison results of different models

检测模型	mAP@0.5/	mAP@0.5:0.95/	内存占用
	%	%	量/MB
YOLO v5_GA	96.2	65.9	8.04
YOLO v8s	96.5	71.4	21.40
Faster R - CNN	95.8	70.9	321.00
SSD	91.6	51.3	188.00

与 YOLO v8s 相比,YOLO v5_GA 的 mAP@0.5 几乎保持不变但模型内存占用量仅为 YOLO v8s 的 40%。综合考虑,本文提出的 YOLO v5_GA 在模型内存占用量上具有明显的优势,同时在面对频繁遮挡和尺度变化的复杂环境时也能保持较好的检测效果,是最适合本文检测赤点石斑鱼的轻量级模型。

3.2 LD - Ocsort 跟踪算法结果分析

在跟踪算法评价中,使用 IDF1、MOTA 和模型内存占用量 3 个常用的跟踪算法评价指标进行评价。

为了验证 LD_Ocsort 与 YOLO v5_GA 组合检测跟踪算法的性能,分析对比了 YOLO v5_GA、YOLO v5s 检测算法与 LD_Ocsort、OC - SORT、DeepSort^[22] 跟踪算法几种组合算法在跟踪测试视频上的跟踪效

果,对比实验结果见表 3。当使用 YOLO v5_GA 作为检测器时,本文改进的 LD_Ocsort 取得了最高的 MOTA (94.7%) 和 IDF1 (69.3%),比原始 OC - SORT 分别提高 1.6、2.2 个百分点。与主流的跟踪算法 DeepSort 相比,本文改进的 LD_Ocsort 在 MOTA 和 IDF1 上也有更好的表现,模型内存占用量更小,对嵌入式平台的部署更加友好。当使用 YOLO v5s 作为检测器时,改进的 LD_Ocsort 在所有跟踪算法中也取得了突出的表现,改进的 YOLO v5_GA 与 LD_Ocsort 检测跟踪算法对比原始 YOLO v5s 与 OC - SORT 的检测跟踪算法在 MOTA 和 IDF1 上分别提高 3.2、6.7 个百分点。

表 3 不同跟踪检测模型对比结果

Tab.3 Comparison results of different detection and tracking models

检测模型	跟踪模型	MOTA/ %	IDF1/ %	内存占用量/ MB
YOLO v5_GA	DeepSort	89.2	46.5	8.04 + 43.20
	OC - SORT	93.1	67.1	8.04
	LD_Ocsort	94.7	69.3	8.04 + 5.27
YOLO v5s	DeepSort	90.2	49.9	13.70 + 43.20
	OC - SORT	91.5	62.6	13.70
	LD_Ocsort	91.6	69.0	13.70 + 5.27

本文选择 Jetson Orin Nano 作为 YOLO v5_GA 与 LD_Ocsort 算法嵌入式端部署平台,Jetson Orin Nano 是 NVIDIA 新一代适用于机器人等移动设备的嵌入式端计算平台,算力较 PC 端有较大差距,这也是本文对检测跟踪算法进行精简轻量化改进的原因之一。在 Orin Nano 平台上使用相同的跟踪测试视频对 YOLO v5_GA 与 LD_Ocsort 检测跟踪算法测试,计算出嵌入式端上检测跟踪算法的 MOTA 和 IDF1 分别为 94.6% 和 69.3%,与 PC 端的测试结果几乎一致,实验结果表明跨端部署不会影响 YOLO v5_GA 与 LD_Ocsort 的跟踪性能。总之,改进后的 YOLO v5_GA 和 LD_Ocsort 的组合检测跟踪算法既有优秀的检测跟踪性能也有优秀低成本部署性能,有助于在嵌入式平台进行赤点石斑鱼的应激行为表征。

3.3 氨氮应激行为分析及表征

在本文赤点石斑鱼氨氮胁迫实验中,处于正常水质环境中的大部分赤点石斑鱼会在空间中不规则游动,运动幅度较大。而一旦处于氨氮胁迫的异常环境中,部分赤点石斑鱼躯体失去平衡且多数石斑鱼会趋于静止,平均运动幅度也明显减小。从图 7 中可以看到,在氨氮胁迫环境下,赤点石斑鱼位移明显低于正常环境下运动距离;另外,在氨氮胁迫环境




图7 两种环境下赤点石斑鱼检测和跟踪结果

Fig.7 Detection and tracking results of *Epinephelus akaara* in two environments

下躯体失衡赤点石斑鱼数量也明显多于正常环境中躯体失衡赤点石斑鱼数量。两种环境中赤点石斑鱼位移、失衡数量变化见图8。




图8 两种环境中赤点石斑鱼位移、失衡数量变化曲线

Fig.8 Changes of movement and number of imbalanced *Epinephelus akaara*

为了明确行为参数能够表征赤点石斑鱼状态，进而反演养殖环境状况，本文结合石斑鱼氨氮胁迫实验以及相关氨氮应激行为学研究成果，选择赤点石斑鱼平均运动速度和累计躯体失衡数量两种参数来表征赤点石斑鱼应激行为。

为验证本文提出的表征方法，现将采集的30个视频分割成300个子视频进行测试，每个视频时长为1 min，其中含有正常水质环境视频200个，氨氮胁迫环境视频100个，将这300个视频按照比例7:3随机划分成训练集和验证集。用本文提出的氨氮应激行为表征方法提取赤点石斑鱼速度和躯体失衡数量两种特征，再输入SVM分类模型训练，在训练集上分类效果如图9所示，在验证集上分类准确率为92.2%，可以较为准确地检测出赤点石斑鱼群体是否处于氨氮胁迫环境中。

3.4 嵌入式平台部署

在完成氨氮应激行为表征后，为更方便地将本文方法部署到赤点石斑鱼工厂化养殖现场，本文设

计了一种工厂化养殖移动巡检设备，如图10所示。




图9 SVM分类模型在训练集上的分类效果

Fig.9 Classification performance of SVM model on training set



图10 赤点石斑鱼工厂化养殖移动巡检装备

Fig.10 Mobile inspection equipment for *Epinephelus akaara* industrial farming

移动巡检设备以Jetson Orin Nano为主控，可以移动采集并实时处理不同养殖高位池的赤点石斑鱼图像及视频数据。鉴于实验环境和真实养殖环境光照、背景差异较大，导致实验环境中训练的检测跟踪算法无法直接应用到真实养殖环境中，故使用巡检过程中采集到的养殖环境图像对实验环境下的YOLO v5_GA和LD_ocsort算法重新训练，最后将迁移训练后的检测跟踪算法部署至Jetson Orin Nano嵌入式端平台，通过循环推理实验，计算出单幅图像检测平均耗时为75 ms，跟踪平均耗时为85 ms，整体表征速度约为6 f/s。

在巡检过程中使用行为表征方法处理采集到的赤点石斑鱼视频数据，先对视频检测跟踪进而表征出赤点石斑鱼群体行为参数并识别赤点石斑鱼行为，图11展示了真实养殖环境下的检测跟踪结果。嵌入式平台的低成本、结构紧凑优势，使得原本停留在PC端的应激行为表征方法可以实际部署到赤点石斑鱼工厂化养殖现场，为赤点石斑鱼工厂化养殖氨氮胁迫识别与管控提供技术支撑。

4 结论

(1)针对工厂化水产养殖中传统方式对赤点石斑鱼氨氮胁迫行为判断存在实时性差、可靠性差、成




图 11 工厂化养殖环境下巡检视频检测跟踪结果

Fig. 11 Detection and tracking results of videos captured by mobile inspection equipment in industrial farming environment

本高等问题,构建了一种基于 YOLO v5_GA 和 LD_Ocsort 轻量化检测跟踪算法的氨氮应激行为表征方法,表征方法可以部署到嵌入式系统上且运行速度为 6 f/s,可为赤点石斑鱼工厂化养殖氨氮胁迫识别

与管控提供技术支撑。

(2)在表征方法中检测模型部分,通过引入 GhostV2 卷积和 AFPN 特征融合方式对检测模型进行轻量化改进,消融对比实验结果表明,YOLO v5_GA 模型对赤点石斑鱼识别精确率为 94.3%,召回率为 89.5%,平均精度均值为 96.2%,与 YOLO v5s 相比平均精度均值提高 1.6 个百分点,但模型内存占用量降低 40%,且综合性能优于其他主流目标检测模型。

(3)在表征方法中跟踪算法部分,在 OC-SORT 的基础上嵌入轻量化赤点石斑鱼外观提取网络,并将外观特征向量加入到跟踪匹配过程中,结果显示基于 YOLO v5_GA 的 LD_Ocsort 的组合跟踪算法 MOTA 和 IDF1 为 94.7% 和 69.3%,比 YOLO v5s 与 OC-SORT 的组合算法分别提高 3.2、6.7 个百分点,且综合性能优于其他检测跟踪算法,是最适合本文的轻量化检测跟踪算法。

参 考 文 献

- [1] RIMMER M A, GLAMUZINA B. A review of grouper (Family Serranidae; Subfamily Epinephelinae) aquaculture from a sustainability science perspective[J]. Reviews in Aquaculture, 2019, 11(1): 58–87.
- [2] LI D, WANG G, DU L, et al. Recent advances in intelligent recognition methods for fish stress behavior[J]. Aquacultural Engineering, 2022, 96: 102222.
- [3] XU Z, CAO J, QIN X, et al. Toxic effects on bioaccumulation, hematological parameters, oxidative stress, immune responses and tissue structure in fish exposed to ammonia nitrogen: a review[J]. Animals, 2021, 11(11): 3304.
- [4] YAN X, CHEN Y, DONG X, et al. Ammonia toxicity induces oxidative stress, inflammatory response and apoptosis in hybrid grouper (♀ *Epinephelus fuscoguttatus* × ♂ *E. lanceolatus*) [J]. Frontiers in Marine Science, 2021, 8: 667432.
- [5] 郑乐云. 氨氮和亚硝酸盐对斜带石斑鱼苗的急性毒性效应[J]. 海洋科学, 2012, 36(5): 81–86.
- [6] 孙龙清, 王泊宁, 王嘉煜, 等. 基于 G-RepVGG 和鱼类运动行为的水质监测方法[J]. 农业机械学报, 2022, 53(增刊 2): 210–218.
- [7] SUN Longqing, WANG Boning, WANG Jiayu, et al. Water quality monitoring based on fish movement behavior and G-RepVGG[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(Sup. 2): 210–218. (in Chinese)
- [8] WANG G, MUHAMMAD A, LIU C, et al. Automatic recognition of fish behavior with a fusion of RGB and optical flow data based on deep learning[J]. Animals, 2021, 11(10): 2774.
- [9] 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.
- [10] LI Daoliang, JIANG Guoqi, YANG Jian'an, et al. Detection and tracking algorithm of fish hypoxia stress behavior based on computer vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 399–406. (in Chinese)
- [11] XU W, ZHU Z, GE F, et al. Analysis of behavior trajectory based on deep learning in ammonia environment for fish[J]. Sensors, 2020, 20(16): 4425.
- [12] LI J, CHEN W, ZHU Y, et al. Intelligent detection and behavior tracking under ammonia nitrogen stress [J]. Neurocomputing, 2023, 559: 126809.
- [13] 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.
- [14] 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)
- [15] 张璐, 黄琳, 李备备, 等. 基于多尺度融合与无锚点 YOLO v3 的鱼群计数方法[J]. 农业机械学报, 2021, 52(增刊): 237–244.
- [16] ZHANG Lu, HUANG Lin, LI Beibei, et al. Fish school counting method based on multi-scale fusion and no anchor YOLO v3 [J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Sup.): 237–244. (in Chinese)
- [17] WANG H, ZHANG S, ZHAO S, et al. Real-time detection and tracking of fish abnormal behavior based on improved YOLOV5 and SiamRPN++ [J]. Computers and Electronics in Agriculture, 2022, 192: 106512.

- hillside orchard[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(5): 413 – 421, 448. (in Chinese)
- [18] 韩振浩, 朱立成, 苑严伟, 等. 基于重心自适应调控的山地果园运输车设计与试验[J]. 农业机械学报, 2022, 53(2): 430 – 442.
- HAN Zhenhao, ZHU Licheng, YUAN Yanwei, et al. Design and test of transport vehicle for hillside orchards based on center of gravity regulation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 430 – 442. (in Chinese)
- [19] 洛阳拖拉机研究所. 机械工程手册[M]. 北京: 机械工业出版社, 1978.
- [20] 张静, 刘昱, 郑德聪, 等. 丘陵山地拖拉机机身自平衡机构稳定性分析[J]. 中国农机化学报, 2022, 43(9): 102 – 108.
- ZHANG Jing, LIU Yu, ZHENG Decong, et al. Stability analysis of self-balancing mechanism for the body of hilly tractors[J]. Journal of Chinese Agricultural Mechanization, 2022, 43(9): 102 – 108. (in Chinese)
- [21] MOU X B, LUO Q, MA G J, et al. Simulation analysis and testing of tracked universal chassis passability in hilly mountainous orchards[J]. Agriculture, 2023, 13(7): 1458.
- [22] 吉旭, 唐勇, 林蜀云, 等. 山地履带自走式辣椒收获机底盘动力学仿真与试验[J]. 中国农机化学报, 2022, 43(7): 72 – 80.
- JI Xu, TANG Yong, LIN Shuyun, et al. Dynamic simulation and test of the tracked chassis of the mountainous self-propelled pepper harvester[J]. Journal of Chinese Agricultural Mechanization, 2022, 43(7): 72 – 80. (in Chinese)
- [23] 潘冠廷, 杨福增, 孙景彬, 等. 小型山地履带拖拉机爬坡越障性能分析与试验[J]. 农业机械学报, 2020, 51(9): 374 – 383.
- PAN Guanting, YANG Fuzeng, SUN Jingbin, et al. Analysis and test of obstacle negotiation performance of small hillside crawler tractor during climbing process[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(9): 374 – 383. (in Chinese)
- [24] YANG H T, XIA C G, HAN J Y, et al. Analysis of stability and dynamic model simulation of mountain tractor rollover[J]. IOP Conference Series: Earth and Environmental Science, 2020, 512(1): 012151.
-

(上接第 510 页)

- [14] 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.
- [15] TANG Y, HAN K, GUO J, et al. GhostNetV2: enhance cheap operation with long-range attention[J]. Advances in Neural Information Processing Systems, 2022, 35: 9969 – 9982.
- [16] YANG G, LEI J, ZHU Z, et al. AFPN: asymptotic feature pyramid network for object detection[C]//2023 IEEE International Conference on Systems, Man, and Cybernetics (SMC). IEEE, 2023: 2184 – 2189.
- [17] 郭建军, 何国煌, 徐龙琴, 等. 基于改进 YOLO v4 的肉鸽行为检测模型研究[J]. 农业机械学报, 2023, 54(4): 347 – 355.
- GUO Jianjun, HE Guohuang, XU Longqin, et al. Pigeon behavior detection model based on improved YOLO v4[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(4): 347 – 355. (in Chinese)
- [18] CAO J, PANG J, WENG X, et al. Observation-Centric SORT: rethinking SORT for robust multi-object tracking[C]//IEEE Conference on Computer Vision & Pattern Recognition. IEEE, 2023: 9686 – 9696.
- [19] 谭鹤群, 李玉祥, 朱明, 等. 通过图像增强与改进 Faster – RCNN 网络的重叠鱼群尾数检测[J]. 农业工程学报, 2022, 38(13): 167 – 176.
- TAN Hequn, LI Yuxiang, ZHU Ming, et al. Detecting overlapping fish population using image enhancement and improved Faster – RCNN networks[J]. Transactions of the CSAE, 2022, 38(13): 167 – 176. (in Chinese)
- [20] 张立杰, 周舒骅, 李娜, 等. 基于改进 SSD 卷积神经网络的苹果定位与分级方法[J]. 农业机械学报, 2023, 54(6): 223 – 232.
- ZHANG Lijie, ZHOU Shuhua, LI Na, et al. Apple location and classification based on improved SSD convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6): 223 – 232. (in Chinese)
- [21] 梁秀英, 贾学镇, 何磊, 等. 基于 YOLO v8n – seg 和改进 Strongsort 的多目标小鼠跟踪方法[J]. 农业机械学报, 2024, 55(2): 295 – 305, 345.
- LIANG Xiuying, JIA Xuezhen, HE Lei, et al. Multi-object mice tracking based on YOLO v8n – seg and improved Strongsort [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 295 – 305, 345. (in Chinese)
- [22] WOJKE N, BEWLEY A, PAULUS D. Simple online and realtime tracking with a deep association metric[C]//IEEE International Conference on Image Processing. IEEE, 2017: 3645 – 3649.