



基于改进 YOLOv7-tiny 的凡纳滨对虾游动活跃性定量检测方法

李志坚^{1,2}, 张永琪^{1,2}, 吴迪^{1,2}, 孟雄栋^{1,2}, 李延天^{1,2}, 张丽珍^{1,2*}

(1. 上海海洋大学工程学院, 上海 201306;

2. 上海海洋大学, 上海海洋可再生能源工程技术研究中心, 上海 201306)

摘要: 在凡纳滨对虾养殖过程中, 养殖人员需通过人为提拉饲料盘来观测对虾的游动活跃状态, 以此了解其生长状况并制定投喂策略。为了解决人工观察凡纳滨对虾游动活跃状态时存在实时性不佳、主观因素影响大等问题, 提出一种基于改进 YOLOv7-tiny (improved YOLOv7-tiny) 检测模型和基于欧式距离多目标关联视觉检测方法, 用以定量分析饲料盘上对虾游动活跃状态。在 YOLOv7-tiny 模型基础上, 将标准卷积替换为 GSConv 卷积, 搭建 VoVGSCSPC 模块替换原先轻量化聚合 (ELAN-L) 模块并使用损失函数 MPDIoU 替代原损失函数 CIoU, 减少了模型容量并提升模型检测精度。通过改进 YOLOv7-tiny 模型的检测结果和基于欧式距离的多目标关联方法确定图像中对虾的位置, 据此计算对虾的游动位移、速度与转角, 量化出对虾游动活跃状态。在凡纳滨对虾数据集上验证后, 结果显示, 与 YOLOv7-tiny 模型相比, 改进 YOLOv7-tiny 模型错检率和漏检率分别降低 0.62% 与 1.05%, 推理速度提升 17.07%, 验证了改进后的模型有效性。通过对虾游动活跃性进行定量分析发现, 越活跃的对虾活跃性指标数值越大, 与实际情况相符。研究表明, 所提出的对虾游动活跃性定量检测方法可准确快速获得游动活跃性指标, 能高效地量化凡纳滨对虾在饲料盘上的活跃状态, 对掌握养殖过程中凡纳滨对虾健康状况具有重要意义。

关键词: 凡纳滨对虾; 游动活跃性; 机器视觉检测; YOLOv7-tiny; 池塘养殖

中图分类号: S 968.22; TP 391

文献标志码: A

为了获取凡纳滨对虾 (*Litopenaeus vannamei*) 的生长状况, 养殖人员需要进行定时巡塘, 通过提拉饲料盘至水面观察虾只游动行为并判断其活跃状态, 以此评判整个虾塘中的虾的生长状态, 进而调整喂养措施和养殖方案^[1-2]。游泳、跳跃和爬行是凡纳滨对虾的主要运动形式^[3], 目前观察虾类游动行为主要采用人工观察法^[4-7], 通过提起饲料盘后目视盘中虾的运动状态^[8], 这种方法需要丰富的专业知识和经验储备^[9]。由于养殖人

员经验不同, 会产生判断失误, 同时, 定时巡塘导致工作效率低下。机器视觉技术作为一种高效的目标行为监测手段, 可以减少人工观测误差, 做到在养殖过程中自动分析凡纳滨对虾的游动活跃情况。

国内外已有学者利用机器视觉的方法对水产动物的活跃状态进行研究, 袁永明等^[10]提出一种基于改进 Canny 边缘检测技术的罗非鱼游动情况观测方法, 实验结果表明, 该方法可用来监测和

收稿日期: 2024-04-02 修回日期: 2024-05-24

资助项目: 国家重点研发计划 (2019YFD0900401); 上海市水产动物良种创制与绿色养殖协同创新中心项目 (2021 科技 02-12)

第一作者: 李志坚 (照片), 从事机器视觉与图像处理技术研究, E-mail: zj-li@shou.edu.cn

通信作者: 张丽珍, 从事现代渔业和海洋装备研究, E-mail: lzzhang@shou.edu.cn



评估罗非鱼的游动情况。Morimoto 等^[11] 基于图像处理技术研究异常对虾游动轨迹, 根据游动情况判别虾的活跃情况, 以此判断是否已被感染, 可有效减少虾类感染所致的经济损失。但上述方法皆基于传统图像处理技术, 对于处理复杂背景下的图像存在一定局限。神经网络具有自主学习的特性和提炼复杂图像特征的能力, 且无须手工设计特征提取算法, 已被应用于鱼虾的活跃状态研究。de Oliveira Barreiros 等^[12] 针对斑马鱼 (*Danio rerio*) 游动行为模式, 提出一种基于 YOLOv2 (You Only Look Once version 2) 神经网络和卡尔曼滤波器的跟踪方法, 通过识别斑马鱼的游动轨迹研究其活跃行为。Wageeh 等^[13] 结合 MSR-YOLO 增强算法和光流算法来跟踪视频中每一帧的鱼的位置, 从而得到鱼体游动轨迹并分析活跃情况。Sun 等^[14] 通过搭建 G-RepVGG 模型来分析鱼类游动行为, 进而获取水质参数。Chahid 等^[15] 使用基于机器学习算法的控制策略, 跟踪生长轨迹和分析鱼类行为。Wang 等^[16] 和 Li 等^[17] 运用 YOLOv5 检测算法与 SiamRPN++ 跟踪算法等, 可以准确检测存在异常行为的鱼体, 从而达到及时预警的目的。上述研究都是针对鱼类的行为检测, 凡纳滨对虾是底栖生物, 虾塘池底环境能见度差, 成像困难, 背景复杂, 这些研究方法并不适用于对虾活跃状态的研究。因此, Yamaguchi 等^[18] 和 Nontarit 等^[8] 基于残差网络的 Mask R-CNN 网络算法, 通过分析饲料盘中的对虾图像研究虾的行为与活跃状态, 但 Mask R-CNN 检测算法有着检测速率慢和计算

量大等不足, 该算法不适用于现场应用场景。上述研究虽然实现了鱼虾活跃行为与状态的监测, 但都只是定性分析, 没有对活跃情况量化。

为定量研究凡纳滨对虾游动活跃状态, 提出基于改进 YOLOv7-tiny (improved YOLOv7-tiny) 的目标检测模型和基于欧式距离的多目标关联方法的对虾游动活跃性检测方法。通过改进 YOLOv7-tiny 模型获取对虾位置, 得到对虾质心与头部坐标信息, 利用基于欧式距离的多目标关联方法, 匹配前后两帧间的对虾, 利用卡尔曼滤波算法跟踪游动轨迹, 计算对虾游动活跃性指标, 量化出游动活跃状态。

1 材料与方法

1.1 实验材料

材料采集 实验样本捕捞于上海市奉贤区凡纳滨对虾淡水养殖场, 于上海海洋大学工程学院科研实验室养殖缸内进行培养, 缸体尺寸为 120 cm×50 cm×50 cm, 养殖水体环境 24 h 持续充氧, 温度 29 °C, 盐度 20, 采录数据时对虾平均体长 6~9 cm, 平均体重 2.5~3.5 g, 所有实验动物均按照上海海洋大学动物实验伦理审查委员会制定的实验动物福利伦理原则进行养殖管理及实验操作。采集平台示意图如图 1 所示, 将饲料盘放置于养殖缸中, 平时饲料盘距水面 40 cm, 在需要观察时, 将饲料盘提拉至距水面 5 cm 处, 保持其略低于水面, 摄像设备为 Mi 10 Ultra, 其分辨率




图 1 采集平台

(a) 采集平台简图, 1. 拍摄支架, 2. 摄像设备, 3. 增氧设备, 4. 饲料盘, 5. 养殖缸, 6. 加热棒; (b) 采集平台实物图。

Fig. 1 Sampling platform

(a) sampling platform diagram, 1. shooting bracket, 2. camera equipment, 3. oxygenation equipment, 4. feed tray, 5. aquarium, 6. heating rod; (b) physical images of the sampling platform.

2340×1080, 架设于饲料盘上方固定高度 65 cm 处俯视拍摄, 确保镜头视野覆盖饲料盘, 所拍图像格式为 JPG、视频格式为 MP4, 帧率为 30 帧/s。对所收集视频与图像进行预处理, 以减少由于拍摄环境对图像质量所产生的影响。

数据扩充 为增强算法的泛化性和准确度, 采用数据扩充方法去增加数据集的样本量, 以减少训练中出现过拟合的可能性^[19-20]。通过模糊、翻转、旋转等方式扩大数据集的样本数量, 同时调整图片亮度 and 对比度来模拟不同光照环境下捕获的对虾图像。此外, 还增加了 106 张秀丽白虾 (*Chinese white prawn*) 和克氏原螯虾 (*Procambarus clarkii*) 的图像以提高模型的泛化能力。经数据扩充后, 共获得 3 020 张对虾数据集图像, 并按 7 : 1 : 2 的比例划分训练集、验证集和测试集。

1.2 目标检测模型

通过检测模型精确检测图像中的对虾目标并获取其位置坐标, 是量化研究凡纳滨对虾游动活跃状态的首要任务。较小的模型可以降低部署时的硬件成本, 加快模型检测速度。选择检测速率

快、检测精度高、架构轻、参数少的 YOLOv7-tiny 作为检测器主体架构。但 YOLOv7-tiny 模型为了轻量化的目的, 减少了网络层数, 弱化了模型提取与融合图像特征的能力, 为了增强模型性能, 在 YOLOv7-tiny 模型原有网络架构的基础上进行改进, 引入损失函数 MPDIoU, 提出改进模型 improved YOLOv7-tiny。

网络架构 improved YOLOv7-tiny 网络架构如图 2 所示, 其架构分为输入部分 (input)、骨干网络 (backbone) 和头部模块 (head) 3 个部分。改进之处在于在 head 模块中将轻型卷积模块 (GSConv) 代替原有的标准卷积 (Conv), 将 VoVGSCSPC 模块替换原先的轻量化聚合 (ELAN-L) 模块, 在加快模型运行速率的同时提高模型检测能力。

图 3-a 为 GSConv 卷积的结构示意, 在标准卷积 (Conv) 与深度可分离卷积 (DSConv) 拼接的基础上, 通过通道重排操作 (Shuffle) 将标准卷积生成的特征信息渗透至深度可分离卷积中, 经此操作可缓解由模型轻量化所带来的特征提取与融合能力下降的影响。

VoVGSCSPC 是一种聚合轻量级特征融合模

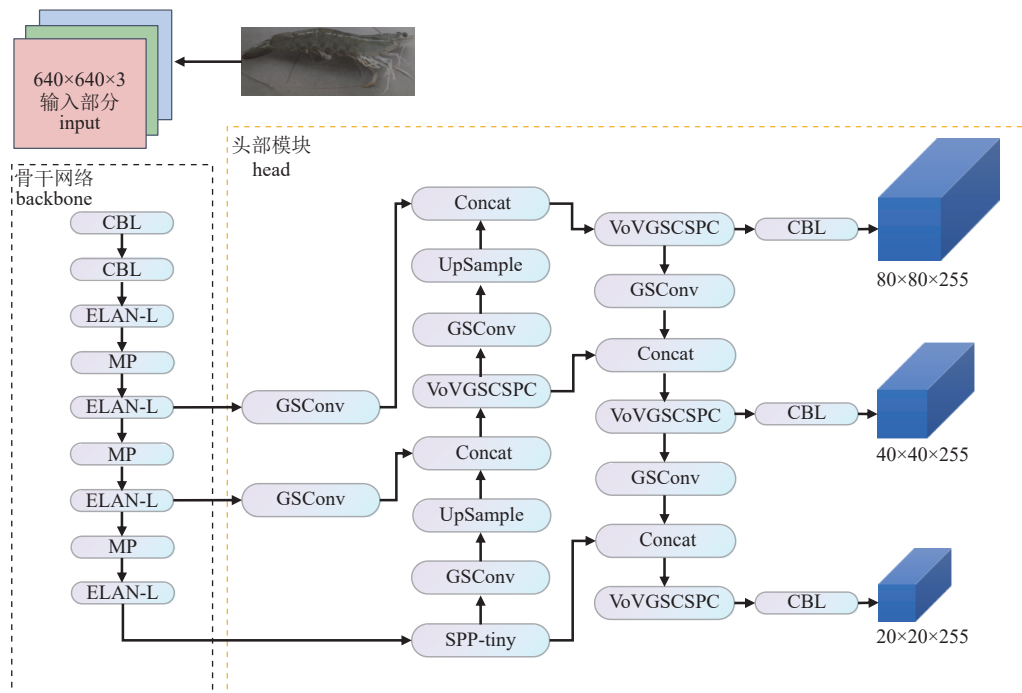


图 2 improved YOLOv7-tiny 网络架构示意图

CBL 表示标准卷积 (Conv)、批量归一化 (Batch Normalization) 和 LeakyReLU 激活函数的组合; ELAN-L 表示轻量化聚合模块; MP 表示最大池化; UpSample 表示上采样; Concat 表示特征图拼接; SPP-tiny 表示轻量级可变大池化。

Fig. 2 Architecture of improved YOLOv7-tiny

CBL represents the combination of Conv, Batch Normalisation and LeakyReLU function; ELAN-L represents lightweight aggregation module; MP represents Max Pooling; UpSample represents upsampling; Concat represents feature map stitching; SPP-tiny represents lightweight spatial pyramid pooling.

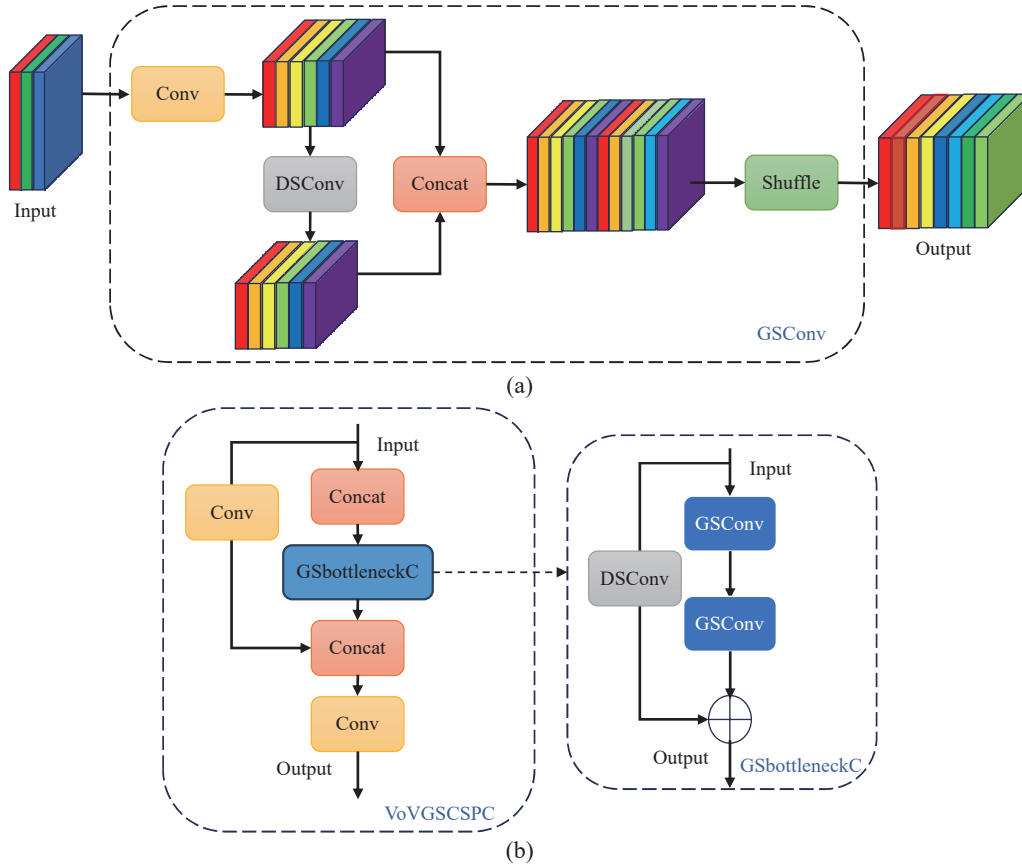


图 3 GSConv 模块 (a) 和 VoVGSCSPC 模块 (b)
 Fig. 3 Architecture of GSConv (a) and VoVGSCSPC (b)

块, 通过减少特征通道的数量, 降低模型复杂程度, 加快模型计算速率 (图 3-b)^[21]。融入轻型卷积模块 (GSConv) 来代替原先的标准卷积, 使卷积计算的输出尽可能接近标准卷积, 在加快运算时间的同时保证精度。在 GSConv 的基础上设计了 GSbottleneckC 结构, 该结构类似于残差网络中的残差模块, 由 2 个互相堆叠的 GSConv 模块和 1 个 DSConv 组成。将上层输出结果与 GSbottleneckC 进行拼接聚合, 执行前向传播计算进而得到特征图。

损失函数 在 YOLOv7-tiny 算法中, 运用损失函数 CIoU 计算模型输出与真实值之间的距离, 值越小表示模型输出与真实值之间的误差越小。虽然 CIoU 考虑了边界框纵横比之间的关系, 但由于需要通过特定参数 ν 反映纵横比之间的差异, 而并非通过边界框置信度反映真实差异度, 会导致模型训练时产生模糊效应, 影响计算精度。此外由于训练数据会涵盖质量较低的特征图像, 目标框几何属性会加剧低质量特征对收敛精度的影响, 致使训练曲线产生震荡。针对此情况, 将损

失函数 CIoU 变更为损失函数 MPDIoU^[22], 计算公式:

$$\begin{cases} \text{IoU} = \frac{B_{\text{gt}} \cap B_{\text{prd}}}{B_{\text{gt}} \cup B_{\text{prd}}} \\ d_1^2 = (x_1^{\text{prd}} - x_1^{\text{gt}})^2 + (y_1^{\text{prd}} - y_1^{\text{gt}})^2 \\ d_2^2 = (x_2^{\text{prd}} - x_2^{\text{gt}})^2 + (y_2^{\text{prd}} - y_2^{\text{gt}})^2 \\ \text{MPDIoU} = \text{IoU} - \frac{d_1^2 + d_2^2}{w^2 + h^2} \end{cases} \quad (1)$$

式中, B_{gt} 表示真实边界框, B_{prd} 表示预测边界框; IoU 表示预测框与真实框的交集面积与并集面积的比值; $(x_1^{\text{prd}}, y_1^{\text{prd}})$ 、 $(x_2^{\text{prd}}, y_2^{\text{prd}})$ 与 $(x_1^{\text{gt}}, y_1^{\text{gt}})$ 、 $(x_2^{\text{gt}}, y_2^{\text{gt}})$ 分别表示预测框与真实框的左上角坐标和右下角坐标; d_1 表示预测框左上角与真实框左上角之间的距离; d_2 为预测框右下角与真实框右下角之间的距离; w 与 h 分别为输入图像宽度与高度。

模型训练损失定义:

$$\text{Loss value} = 1 - \text{MPDIoU} \quad (2)$$

1.3 基于欧式距离的多目标关联

检测模型检测到图像中的凡纳滨对虾后, 可输出每只虾的质心坐标 (基于边界框返回值所得到的中心坐标) 与头部坐标位置, 由于每张图像上会有多只凡纳滨对虾, 并且模型是连续检测多张图像, 每张图像返回多个坐标参数。质心坐标是按目标置信度进行排列的, 因此无法准确区分连续帧中每只虾的坐标。为了匹配前后两帧中的对虾, 提出一种基于欧式距离的多目标关联方法。

图 4 是基于欧式距离的多目标关联方法的工作流程, 首先通过检测模型获取图像中对虾位置坐标信息, 计算相邻两帧欧式距离代价矩阵, 找到差值最小两组坐标进行匹配关联, 得到对虾连续帧间的坐标集。

1.4 轨迹跟踪

轨迹跟踪用于将关联后的对虾坐标进行连接, 绘制游动轨迹。使用卡尔曼滤波算法可减少跟踪过程受到的系统噪声与观测噪声的扰动, 提高对虾目标跟踪精度与稳定性。在跟踪算法中把虾的游动近似为从一个坐标系到另一坐标系的匀速线性运动。轨迹跟踪算法中虾的状态变量 $X_k = \{c_{xk}, c_{yk}, \gamma_k, \phi_k, \dot{c}_{xk}, \dot{c}_{yk}, \dot{\gamma}_k, \dot{\phi}_k\}$, 其中 (c_{xk}, c_{yk}) 表示图像中每一帧虾的质心位置, γ_k, ϕ_k 表示边界框的宽度与高度, $\dot{c}_{xk}, \dot{c}_{yk}, \dot{\gamma}_k, \dot{\phi}_k$ 是 $c_{xk}, c_{yk}, \gamma_k, \phi_k$ 的导数并蕴含速度信息, 且初始状态值为 0。

卡尔曼滤波器中的状态转移方程和目标观测方程:

$$\begin{cases} X_k = AX_{k-1} + w_k \\ Z_k = HX_k + v_k \end{cases} \quad (3)$$

$$A = \begin{bmatrix} 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (4)$$

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (5)$$

式中, X_{k-1} 为状态变量; Z_k 为观测变量; w_k 与 v_k 分别为系统过程噪声与系统观测噪声, 且均为满足高斯分布的独立随机变量; A 为状态转移矩阵; H 为观测矩阵。

滤波跟踪开始阶段对卡尔曼滤波器的状态向量、协方差矩阵和模型参数赋初值。预估修正阶段卡尔曼滤波器利用 k 时刻最优粒子的观测信息来预测 $k+1$ 时刻的粒子信息, 利用观测值校正当前值, 以得到最优解。其中状态预估方程:

$$X(k|k-1) = AX(k-1|k-1) \quad (6)$$

式中, $X(k|k-1)$ 为当前时刻状态变量, $X(k-1|k-1)$ 为上一时刻的最优状态变量。

误差协方差变量预估方程:

$$P(k|k-1) = AP(k-1|k-1)A^T + Q_{k-1} \quad (7)$$

式中, $P(k|k-1)$ 为 $X(k|k-1)$ 对应的误差协方差, $P(k-1|k-1)$ 为 $X(k-1|k-1)$ 对应的误差协方差, A^T 为 A 的转置矩阵, Q_{k-1} 为上一时刻的过程噪声。

迭代更新阶段, 使用卡尔曼增益 (Kalman Gain) 来权衡和调整预估状态和观测信息之间的关系, 通过不断迭代更新, 最终获得最优估计值。

卡尔曼增益计算公式:

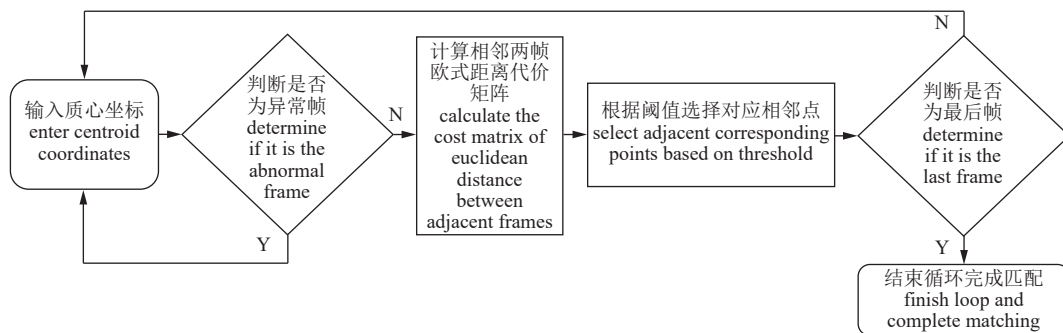


图 4 多目标关联方法

Fig. 4 Multi-target association method

$$K_{gk} = P(k|k-1)H^T [H \times P(k|k-1) \times H^T + R_k]^{-1} \quad (8)$$

式中, K_{gk} 为卡尔曼增益, H^T 为 H 的转置矩阵, R_k 为观察噪声。

修正更新状态变量:

$$X(k|k) = X(k|k-1) + K_{gk} [Z_k - H \times X(k|k-1)] \quad (9)$$

式中 $X(k|k)$ 为更新后的状态变量。

更新误差协方差:

$$P(k|k) = (I - K_{gk}H)P(k|k-1) \quad (10)$$

式中, $P(k|k)$ 为 $X(k|k)$ 对应的误差协方差, I 为单位矩阵。

1.5 游动活跃性指标

游动距离 游动活跃性指标的设立可定量研究虾只活跃性。游动位移是指虾在观测时间内所移动的距离, 游动速度是指虾在单位时间内所移动的距离, 游动转角是指虾在游动过程中方向改变的角度^[23], 游动角速度是指虾在单位时间内所转动的角度, 通过监测游动位移、速度、转角与角速度可以定量研究虾只游动活跃状态。

根据质心坐标的欧式距离进行计算, 并将所得像素位移乘以转换系数得到位移结果。其计算式:

$$\begin{cases} \alpha = \frac{L}{r} \\ d_k = \sqrt{[\alpha(c_{xk} - c_{xk-1})]^2 + [\alpha(c_{yk} - c_{yk-1})]^2} \\ D = \sum_{k=1}^n d_k \end{cases} \quad (11)$$

式中, α 为转换系数, L 是代表实际拍摄区域的长度 (cm), r 代表图像长度中的像素数; d_k 为从第 k 帧到第 $k+1$ 帧的游动距离 (cm); D 为累加的游动距离 (cm); n 为所截取帧的总数; 当前视频帧率为 30 帧/s。

游动速度 游动速度计算公式:

$$v = \frac{D}{\Delta t} \quad (12)$$

式中, Δt 为游动时间, 即观测时间 (s)。

游动转角 凡纳滨对虾每一帧中的游动偏转方向通过对虾质心坐标与头部进行判别, 游动转角 θ_k 范围为 $[0, 2\pi]$, 计算公式:

$$\theta_k = \begin{cases} \arctan \frac{h_{yk} - c_{yk}}{h_{xk} - c_{xk}}, h_{xk} - c_{xk} > 0, h_{yk} - c_{xk} \geq 0 \\ 2\pi + \arctan \frac{h_{yk} - c_{yk}}{h_{xk} - c_{xk}}, h_{xk} - c_{xk} > 0, h_{yk} - c_{xk} \leq 0 \\ \pi - \arctan \frac{c_{yk} - h_{yk}}{h_{xk} - c_{xk}}, h_{xk} - c_{xk} < 0, h_{yk} - c_{xk} < 0 \\ \pi + \arctan \frac{h_{yk} - c_{yk}}{h_{xk} - c_{xk}}, h_{xk} - c_{xk} < 0, h_{yk} - c_{xk} > 0 \end{cases} \quad (13)$$

式中, θ_k 为凡纳滨对虾第 k 帧的游动转角, 其示意图如图 5 所示; (h_{xk}, h_{yk}) 是凡纳滨对虾头部位置坐标。

游动角速度 游动角速度 ω 计算公式:

$$\omega = \frac{\sum_{k=1}^n |\theta_{k+1} - \theta_k|}{\Delta t} \quad (14)$$

2 结果

2.1 训练环境与参数

网络学习、训练、验证与推理实验基于 Windows 10 系统; CPU 与 GPU 分别为 Intel(R) Xeon(R) Gold 5218 处理器和 Nvidia GeForce RTX 3070 显卡; 软件环境为 Python 3.9、Pytorch 1.13、Torchvision 0.14; 加速环境为 Cuda11.7 和 Cudnn8.6。

图像大小为 $640 \times 640 \times 3$; 批量尺寸 (batch-size) 和迭代周期 (epoch) 为 8 与 101 轮; 学习率初值 0.001、动量 0.937; 采用 Adam 模型优化器; 权重衰退指数 0.000 5。

2.2 检测模型评估指标

选择准确率 (P)、召回率 (R)、平均精度 (average precision, AP)、平均精度均值 (mean average precision, mAP) 作为检测模型的评估指标^[24]。上




图 5 游动转角

Fig. 5 Swimming angle

述相关指标计算公式:

$$P = \frac{TP}{TP + FP} \quad (15)$$

$$R = \frac{TP}{TP + FN} \quad (16)$$

$$mAP = \frac{\sum_j \int_0^1 P(R) dR}{j} \quad (17)$$

$$mAP_{0.5-0.95} = \frac{1}{10} (mAP_{0.5} + mAP_{0.55} + mAP_{0.6} + \dots + mAP_{0.9} + mAP_{0.95}) \times 100\% \quad (18)$$

式中, TP 为被模型正确判断为正的样本数量; FP 为被模型错误判断为正的样本数量; FN 为被模型错误判断为负的样本数量; P 为查准率; R 为查全率; mAP 表示模型中所有类别的检测准确性, j 表示模型中所含类别的个数; $mAP_{0.5-0.95}$ 表示置信度 $IoU \in [0.5 : 0.05 : 0.95]$ 中 mAP 的平均值。

2.3 损失函数有效性验证

为了验证损失函数 MPDIoU 的有效性, 将 improved YOLOv7-tiny 网络架构分别与损失函数 CIoU 和 MPDIoU 组合进行对虾检测模型的训练, 2 种损失函数的性能指标和训练曲线分别见表 1 和图 6。

从表 1 和图 6 可看出, 与 CIoU 相比, 使用 MPDIoU 的准确率、召回率与 $mAP_{0.5-0.95}$ 分别提升了 0.24%、0.20% 和 3.60%。由于检测模型是基于 improved YOLOv7-tiny 的网络架构, 使用损失函数 MPDIoU 的训练时长比使用 CIoU 短。故将 MPDIoU 作为损失函数用于模型训练, 可得到最为理想的检测效果。

2.4 improved YOLOv7-tiny 模型有效性验证

为验证 YOLOv7-tiny 作为初始网络架构的可行性和评估 improved YOLOv7-tiny 模型的有效性, 将 YOLOv7 系列模型与 improved YOLOv7-tiny 模型进行测试对比, 结果如表 2 所示。

表 1 2 种损失函数的性能指标

损失函数 loss function	准确率/% P	召回率/% R	平均准度均值/% $mAP_{0.5-0.95}$	训练时间/h training time
CIoU	99.60	99.60	69.50	5.66
MPDIoU	99.84	99.80	73.10	5.40

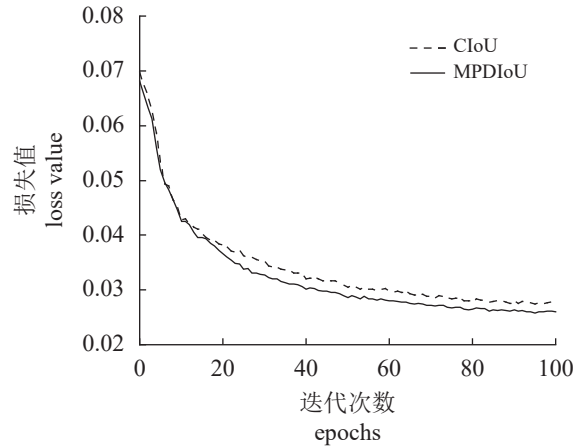


图 6 2 种损失函数训练曲线

Fig. 6 Loss curves of two loss functions

由表 2 可知, YOLOv7-tiny 比 YOLOv7 和 YOLOv7x 的准确率分别高 0.66% 和 0.16%, 召回率分别比 YOLOv7 和 YOLOv7x 高 1.10% 和低 0.20%, $mAP_{0.5-0.95}$ 分别比 YOLOv7 和 YOLOv7x 高 5.70% 和低 0.30%。此外, YOLOv7-tiny 的模型大小、参数数量和复杂度 3 个指标都是最小的。为提升游动活跃性检测的实时性, 拥有较小模型内存和较低复杂度的 YOLOv7-tiny 是一个理想的网络初始架构, 而 improved YOLOv7-tiny 模型相较 YOLOv7-tiny 有更高的准确率和召回率, 与此同时 improved YOLOv7-tiny 的 $mAP_{0.5-0.95}$ 比 YOLOv7-tiny 提高了 4%, 此外模型内存降低 0.90 MB, 参数量下降 8.30%, 复杂度减少 1.30 GB。可以看出 improved YOLOv7-tiny 模型整体检测性能得到提升, 可实现凡纳滨对虾的迅速准确检测。


表 2 不同检测模型性能指标

模型 model	准确率/% P	召回率/% R	平均准度均值/% $mAP_{0.5-0.95}$	模型大小/MB model size	参数量 parameters	复杂度/GB FLOPs
YOLOv7	99.10	98.5	64.9	74.8	3 6481 772	103.2
YOLOv7x	99.60	99.7	70.5	142.1	70 782 444	188.0
YOLOv7-tiny	99.76	99.5	69.1	12.3	6 007 596	13.0
improved YOLOv7-tiny	99.85	99.8	73.1	11.4	5 529 236	11.7

2.5 虾只检测结果对比

分别用 YOLOv7-tiny 和 improved YOLOv7-tiny 检测模型检测饲料盘中的凡纳滨对虾, 检测结果显示 improved YOLOv7-tiny 的检测精度高于 YOLOv7-tiny, YOLOv7-tiny 存在较多的漏检和错检现象, 图版中所示为其中产生错误检测结果的

部分示例, 在第 383 帧中 YOLOv7-tiny 模型漏检 1 只虾, 在第 411 帧与第 425 帧中位于饲料盘上方两只虾重合时 YOLOv7-tiny 模型不能区分重合目标, 而改进后的 YOLOv7-tiny 模型能检测到重合目标。



图版 部分帧数下对虾图像对比结果

1-3、4-6 及 7-9 分别为原图、YOLOv7-tiny 及 improved YOLOv7-tiny 的检测结果。1、4 和 7 代表第 383 帧, 2、5 和 8 代表第 411 帧, 3、6 和 9 代表第 425 帧。

Plate Comparative results of shrimp at partial frame rates

1-3, 4-6, and 7-9 respectively represent the original image, YOLOv7 tiny and improved YOLOv7 tiny. 1, 4 and 7 represent the frame 383; 2, 5 and 8 represent the frame 411; 3, 6 and 9 represent the frame 425.

YOLOv7-tiny 模型与 improved YOLOv7-tiny 模型的检测结果对比如表 3 所示。improved YOLOv7-tiny 模型推理的错检率与漏检率比 YOLOv7-tiny 模型分别降低了 0.62% 和 1.05%, 且 improved YOLOv7-tiny 检测模型单张图片的推理时间加快了 7.58 ms。因此, 改进后的模型有更好的检测能力, 且速率更快。

2.6 游动活跃性指标计算

经人工观察后选取较活跃的虾与不活跃的虾各 5 组, 计算上述 10 组对虾样本的游动活跃性指

表 3 模型检测结果

Tab. 3 Model detection results

模型 models	错检率/% error detection	漏检率/% misdetection	推理时间/s inference time
YOLOv7-tiny	1.04	3.95	21.38
improved YOLOv7-tiny	0.42	2.90	17.73

标, 位于虚线左下方的为不活跃的虾, 虚线右上方的为较活跃的虾, 总体而言较活跃对虾的游动速度比不活跃对虾快, 较活跃对虾的游动角速度的数值比不活跃对虾的大 (图 7)。但是通过分析样本 3 与样本 5 的结果可以发现, 样本 3 中的对虾游动速度小于样本 5 中的虾, 但其游动角速度对虾大于样本 5 中的虾, 与实际观察结果相对后, 发现样本 3 中的对虾游动活跃性更好, 故不能仅通过游动速度来判断对虾的游动活跃状态, 需要将游动速度与游动角速度综合考虑进行分析。此外, 经观察样本 10 中的对虾游动速度快且转动幅度大, 是所选取的 10 组样本中最为活跃的一组, 从游动活跃性指标分析, 样本 10 中的对虾游动速度和游动角速度数值分别为 6.3 cm/s 和 4.8 rad/s, 高于平均值, 表明该对虾的游动较活跃, 与实际情况相符, 验证了本研究所提出的游动活跃性检测方法的有效性。

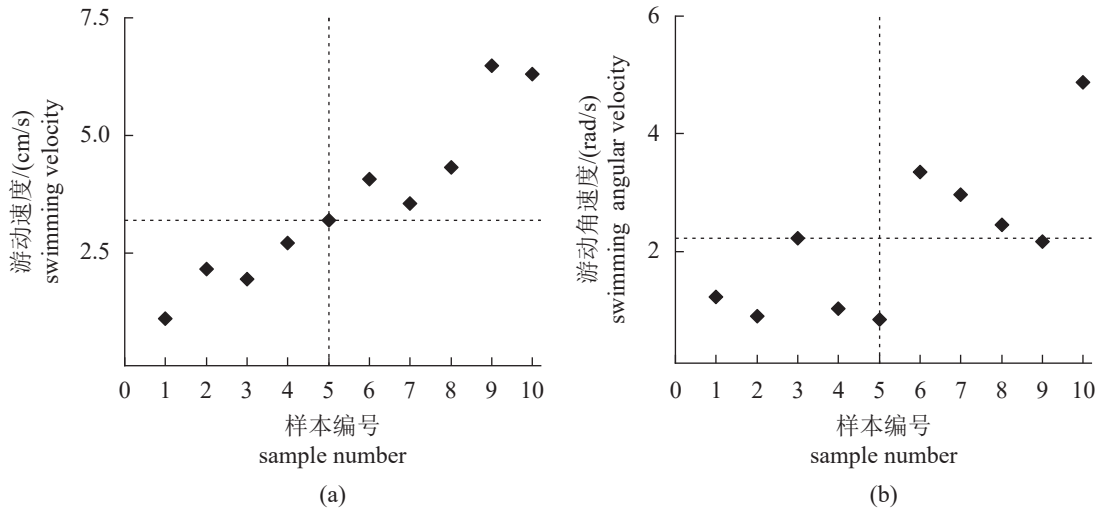


图 7 游动活性指标

Fig. 7 Swimming activity indicator

3 讨论

3.1 活跃性与游动轨迹

提取上述样本 1、样本 3、样本 4、样本 5、样本 8 与样本 10 的对虾游动轨迹, 如图 8 所示。从游动轨迹图中可直观看出较活跃的虾与不活跃的虾游动活跃情况, 较活跃的虾游动距离更远, 转向幅度更明显。样本 1、样本 3、样本 4、样本 5、样本 8 与样本 10 的对虾游动速度分别为 1.1、1.9、2.7、3.1、4.3 与 6.3 cm/s, 样本 1、样本 3、样本 4、样本 5、样本 8 与样本 10 的对虾游动角速度分别为 0.9、2.4、1.1、0.7、2.5 与 4.8 rad/s。从所提取的游动活性指标上可以看出, 样本 10 的对虾游动速度最快、游动距离最远、游动状态最活跃, 与游动轨迹情况相符, 从游动轨迹上可

看出样本 3 的对虾转动幅度比样本 5 的大, 与其更大的游动角速度数值相呼应。因此, 游动轨迹稳定性地展现了对虾所处的游动活跃状态, 印证了所提出的量化指标可用于对饲料盘定期观察, 以此判断对虾的活跃性。

3.2 游动活性指标分析

观测对虾游动活跃性是养殖户判断当前养殖状况是否符合预期的重要参照^[25], 但人工观测标准不一, 存在较多不确定性, 此外, 针对虾类活跃性的研究大多停留在定性层面, 很难做到定量评价^[26]。研究表明, 虾类的游动速度和轨迹是虾类游动活跃行为中的重要指标。李娜^[27]基于机器视觉实现单只虾体游动位移和速度的参数化。汪峰^[28]基于机器视觉提取对虾游动速度用以表征活力强度。由于对虾游动时主要依靠游泳足的频繁摆动^[29], 不能只考虑直线游动情况, 还需考虑其转向时的游动情况, 故不能仅通过游动位移与速度来判断对虾的游动活跃状态。本研究综合考虑了对虾游动时的位移情况和转向角度, 用游动速度与游动角速度分析对虾游动情况, 游动轨迹结果表明, 所提出的游动活性指标可与游动轨迹相互印证, 验证了所提出的活性指标的合理性。

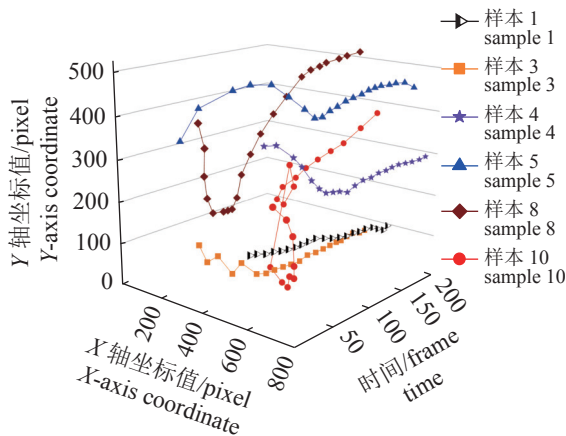


图 8 游动轨迹

Fig. 8 Trajectory of swimming

4 结论

本研究旨在开发一种凡纳滨对虾游动活跃性的定量检测方法, 用以对游动活跃进行量化。通过在初始 YOLOv7-tiny 模型中引入 GSConv 卷积和 VoVGSCSPC 模块, 在减小模型参数和复杂度

的同时加强了模型性能, 将原损失函数 CIoU 替换为损失函数 MPDIoU, 提升模型训练精度。与 YOLOv7-tiny 模型相比, 改进后的 YOLOv7-tiny 模型的错检率和漏检率分别减少 0.62% 和 1.05%, 且推理时间和模型参数量分别加快 3.65 s 和下降 8.3%, 说明该模型具有较好的鲁棒性。提取对虾的游动轨迹并计算游动活跃性指标, 定量分析对虾游动活跃性, 越活跃的虾对应活跃性指标数值越大, 与实际相同, 即越活跃的对虾游动轨迹距离越远、转幅越大。因此, 所提出的对虾游动活跃性检测方法能有效地反映游动活跃状态。

本论文主要研究凡纳滨对虾游动活跃性的定量检测方法, 实验时采集平台采用人工升降料盘的方式, 后续为了更好地提高游动活跃性的检测效率, 将开发使用自动升降料盘进行定时、定高采集与检测。此外, 采集多种规格下凡纳滨对虾的游动与爬行情况, 可以进一步提升虾只活跃性判断的精确性与实时性, 为数值量化凡纳滨对虾活跃状态提供支持。本研究提出的方法为基于对饲料盘观察来判断虾的活跃性, 具有可拓展性, 通过扩充训练数据集、调整模型参数, 可推广应用对于水产动物计数测量、病害诊断等方面。

(作者声明本文无实际或潜在的利益冲突)

参考文献 (References):

- [1] Li J, Xu W K, Deng L M, *et al.* Deep learning for visual recognition and detection of aquatic animals: a review[J]. *Reviews in Aquaculture*, 2023, 15(2): 409-433.
- [2] Bardera G, Owen M A G, Pountney D, *et al.* The effect of short-term feed-deprivation and moult status on feeding behaviour of the Pacific white shrimp (*Litopenaeus vannamei*)[J]. *Aquaculture*, 2019, 511: 734222.
- [3] 王克行. 虾蟹类增殖学 [M]. 北京: 中国农业出版社, 1997.
Wang K X. Shrimp and crab enrichment[M]. Beijing: China Agriculture Press, 1997. (in Chinese).
- [4] Álvarez-Ellacuría E A, Palmer M, Catalán I A, *et al.* Image-based, unsupervised estimation of fish size from commercial landings using deep learning[J]. *ICES Journal of Marine Science*, 2020, 77(4): 1330-1339.
- [5] 曾庆婷, 于赫男, 林小涛, 等. 氮氨胁迫下凡纳滨对虾运动行为与能量分配模式变化 [J]. 中国水产科学, 2016, 23(1): 198-206.
- [6] Zeng Q T, Yu H N, Lin X T, *et al.* Effects of ammonia-nitrogen on locomotor performance and the energy budget of *Litopenaeus vannamei*[J]. *Journal of Fishery Sciences of China*, 2016, 23(1): 198-206 (in Chinese).
- [7] Xi M Z, Rahman A, Nguyen C, *et al.* Smart headset, computer vision and machine learning for efficient prawn farm management[J]. *Aquacultural Engineering*, 2023, 102: 102339.
- [8] 李钊丞, 项盛羽, 沈梦庭, 等. 南美白对虾快速游动发声特征及其信息利用研究 [J]. *水生生物学报*, 2023, 47(6): 997-1006.
- [9] Li Z C, Xiang S Y, Shen M T, *et al.* Acoustic characteristics of fast swimming and its information utilization for *Litopenaeus vannamei*[J]. *Acta Hydrobiologica Sinica*, 2023, 47(6): 997-1006 (in Chinese).
- [10] Nontarit C, Kondo T, Khamkaew W, *et al.* Shrimp-growth estimation based on ResNeXt for an automatic feeding-tray lifting system used in shrimp farming[C]//IEEE. Proceedings of the 2022 17th International Joint Symposium on Artificial Intelligence and Natural Language Processing (iSAI-NLP). Chiang Mai: IEEE, 2022: 1-6.
- [11] 裴凯洋, 张胜茂, 樊伟, 等. 基于计算机视觉的鱼类视频跟踪技术应用研究进展 [J]. *海洋渔业*, 2022, 44(5): 640-647.
- [12] Pei K Y, Zhang S M, Fan W, *et al.* Research progress of fish video tracking application based on computer vision[J]. *Marine Fisheries*, 2022, 44(5): 640-647 (in Chinese).
- [13] 袁永明, 施珮. 基于图像处理的鱼群运动监测方法研究 [J]. *南方水产科学*, 2018, 14(5): 109-114.
- [14] Yuan Y M, Shi P. Study on fish movement monitoring method based on image processing[J]. *South China Fisheries science*, 2018, 14(5): 109-114 (in Chinese).
- [15] Morimoto T, Zin T T, Itami T. A study on abnormal behavior detection of infected shrimp[C]//IEEE. Proceedings of the 2018 IEEE 7th Global Conference on Consumer Electronics (GCCE). Nara: IEEE, 2018: 291-292.
- [16] de Oliveira Barreiros M, de Oliveira Dantas D, de Oliveira Silva L C, *et al.* Zebrafish tracking using YOLOv2 and Kalman filter[J]. *Scientific Reports*, 2021, 11(1): 3219.

- [13] Wageeh Y, Mohamed H E D, Fadl A, *et al.* YOLO fish detection with Euclidean tracking in fish farms[J]. *Journal of Ambient Intelligence and Humanized Computing*, 2021, 12(1): 5-12.
- [14] Sun L Q, Wang B N, Yang P, *et al.* Water quality parameter analysis model based on fish behavior[J]. *Computers and Electronics in Agriculture*, 2022, 203: 107500.
- [15] Chahid A, N'Doye I, Majoris J E, *et al.* Fish growth trajectory tracking using Q-learning in precision aquaculture[J]. *Aquaculture*, 2022, 550: 737838.
- [16] Wang H, Zhang S, Zhao S L, *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.
- [17] Li X, Hao Y F, Zhang P, *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.
- [18] Yamaguchi M, Nontarit C, Kondo T, *et al.* Accuracy Improvement of the Shrimp-size Estimation Method for an Automatic Feeding-tray Lifting System Used in Shrimp Farming[C]//IEEE. Proceedings of the 2023 20th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON). Nakhon Phanom: IEEE, 2023: 1-5.
- [19] Suarez P L, Sappa A, Carpio D, *et al.* Deep learning based shrimp classification[C]//Proceedings of the International Symposium on Visual Computing. Cham: Springer International Publishing, 2022: 36-45
- [20] Fan K J, Su W H. Applications of fluorescence spectroscopy, RGB- and MultiSpectral imaging for quality determinations of white meat: a review[J]. *Biosensors*, 2022, 12(2): 76.
- [21] Li H, Li J, Wei H, *et al.* Slim-neck by GSConv: a better design paradigm of detector architectures for autonomous vehicles[J]. arXiv preprint arXiv: 2206.02424, 2022.
- [22] Ma S L, Xu Y. MPDIoU: a loss for efficient and accurate bounding box regression[J]. arXiv preprint arXiv: 2307.07662, 2023.
- [23] Zhao X Q, Yan S, Gao Q. An algorithm for tracking multiple fish based on biological water quality monitoring[J]. *IEEE Access*, 2019, 7: 15018-15026.
- [24] 王金鹏, 周佳良, 张跃跃, 等. 基于优选 YOLOv7 模型的采摘机器人多姿态火龙果检测系统 [J]. *农业工程学报*, 2023, 39(8): 276-283.
- Wang J P, Zhou J L, Zhang Y Y, *et al.* Multi-pose dragon fruit detection system for picking robots based on the optimal YOLOv7 model[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2023, 39(8): 276-283 (in Chinese).
- [25] Hu W C, Chen L B, Yu P J, *et al.* A deep learning-based white shrimp body length and bait detection methodology for turbid underwater aquaculture environment[C]//IEEE. Proceedings of the 2023 5th International Conference on Computer Communication and the Internet (ICCCI). Fujisawa: IEEE, 2023: 60-65.
- [26] 李为, 荣宽, 覃丽蓉, 等. 水产动物行为及其在渔业中的应用研究进展 [J]. *水生生物学报*, 2021, 45(5): 1171-1180.
- Li W, Rong K, Qin L R, *et al.* Research progress of aquatic animal behavior and its application in fisheries [J]. *Acta Hydrobiologica Sinica*, 2021, 45(5): 1171-1180 (in Chinese).
- [27] 李娜. 基于机器视觉的虾体活力状态检测方法研究 [D]. 唐山: 华北理工大学, 2021.
- Li N. Study on detection method of shrimp body vitality based on machine vision[D]. Tangshan: North China University of Science and Technology, 2021 (in Chinese).
- [28] 汪峰. 基于计算机视觉的虾苗活力分析研究 [D]. 上海: 上海海洋大学, 2022.
- Wang F. Research on the vitality analysis of shrimp fry based on computer vision[D]. Shanghai: Shanghai Ocean University, 2022 (in Chinese).
- [29] 张沛东, 张秀梅, 李健. 对虾的行为生态学研究进展 I. 对虾的行为习性 [J]. *应用生态学报*, 2006, 17(1): 127-130.
- Zhang P D, Zhang X M, Li J, *et al.* Research advances in behavioral ecology of penaeid shrimps I. Behavior of penaeid shrimps[J]. *Chinese Journal of Applied Ecology*, 2006, 17(1): 127-130 (in Chinese).

Quantitative detection method of swimming activity of *Litopenaeus vannamei* based on improved YOLOv7-tiny

LI Zhijian^{1,2}, ZHANG Yongqi^{1,2}, WU Di^{1,2}, MENG Xiongdong^{1,2}, LI Yantian^{1,2}, ZHANG Lizhen^{1,2*}

(1. College of Engineering Science and Technology, Shanghai Ocean University, Shanghai 201306, China;

2. Shanghai Engineering Research Center of Marine Renewable Energy, Shanghai Ocean University, Shanghai 201306, China)

Abstract: Shrimp is rich in a variety of trace elements and vitamins, and has a substantial nutritional value, it is also be widely recognized as an important ingredient in high-end, well-known cuisine. Among them, the cultural production of *Litopenaeus vannamei* accounts for about 85% of the total production of shrimp culture, which is an important economic aquaculture object. The active state of *L. vannamei* reacts its health condition and behavioral situation. Surveying and identifying the activity of *L. vannamei* is helpful in finding abnormal behavior in aquaculture, to give early warning and take remedial methods promptly, lessen economic losses in aquaculture, and improve the yield and efficiency of aquaculture. Nowadays in the *L. vannamei* pond aquaculture process, aquaculture personnel often need to monitor the active swimming state of the shrimp by manually pulling the feed tray, then analyzing the overall environment of the aquaculture pond and formulating effective aquaculture breeding strategies. However, due to the complexity of the pond underwater environment, artificial observation experience is limited, so the method of manually observing the active state of *L. vannamei* has a lot of problems, such as inefficiency limited scope of application, low accuracy, poor real-time performance, high labor intensity and other problems. In order to solve these problems, propose a visual detection method for the activity of *L. vannamei* based on an improved YOLOv7 tiny network detection model and multi-objective association based on Euclidean distance to quantitatively study the swimming activity status of shrimp. Based on the YOLOv7 tiny network model, the standard convolution was replaced by Conv convolution, and a VoVGSCSPC module was built to replace the original lightweight aggregation module (ELAN-L). The MPDIoU loss function was used instead of the CIoU loss function to reduce the model capacity and improve the model detection accuracy. The position of shrimp in the image was determined by the visual detection results of improved YOLOv7-tiny model and the multi-objective association method based on Euclidean distance, from which the shrimp's swimming displacement, speed and turn angle were calculated to quantify the shrimp's swimming activity status. After validation on the *L. vannamei* dataset, the results showed that the misdetection rate and omission rate of the improved YOLOv7-tiny model were reduced by 0.62% and 1.05%, respectively, compared with the YOLOv7-tiny model. The inference speed was improved by 17.07%, so the effectiveness of the improved model was verified. Quantitative analysis of the activity of shrimp showed that the more active shrimp corresponded to the higher the activity index value, which was consistent with the actual situation. The study showed that the proposed quantitative detection method could accurately and quickly obtain the swimming activity index, and could efficiently quantify the swimming activity state of *L. vannamei* on the feed tray, which was of great significance to grasp the health status of *L. vannamei* and improved the intelligent level of shrimp culture.

Key words: *Litopenaeus vannamei*; swimming activity; machine vision detection; YOLOv7-tiny; pond aquaculture

Corresponding author: ZHANG Lizhen. E-mail: lzzhang@shou.edu.cn

Funding projects: National Key R & D Program of China (2019YFD0900401); Project of Shanghai Collaborative Innovation Center for Aquatic Animal Breed Creation and Green Breeding (2021 Science and Technology 02-12)