



Open Access

引用格式: 卢国兴, 王惠儒, 周佳龙, 等. 基于计算机视觉的鱼、虾生物量统计与健康状态评估研究进展 [J]. 海南大学学报(自然科学版中英文), DOI: 10.65658/j.hndk.2025091502.

Citation: LU Guoxing, WANG Huiru, ZHOU Jialong, et al. Computer Vision-Based Research Progress on Biomass Statistics and Health Status Assessment of Fish and Shrimp[J]. Natural Science of Hainan University, DOI: 10.65658/j.hndk.2025091502.

基于计算机视觉的鱼、虾生物量统计与健康状态评估研究进展

卢国兴^{1,2,3}, 王惠儒³, 周佳龙¹, 梁霖², 钟国定³, 叶章颖¹,
赵建¹, 朋泽群¹✉

(1. 浙江大学生物系统工程与食品科学学院, 农业农村部设施农业装备与信息化重点实验室, 浙江 杭州 310058; 2. 杭州游韧智能科技有限公司, 浙江 杭州 311200; 3. 海南快渔生物科技有限公司, 海南 海口 570100)

摘要: 计算机视觉技术因其非侵入、高精度和自动化等特点, 已成为推动水产养殖智能化管理发展的关键技术手段。然而, 面对规模化、集约化养殖模式下对生物量高效精准统计与健康状况实时准确评估的迫切需求, 如何克服复杂水下环境干扰、个体间遮挡与形态多变等实际困难, 实现稳定可靠的视觉感知与分析, 仍是当前亟待解决的科学问题。为此, 本文围绕计算机视觉在水产动物生物量统计(包括群体计数、体长与体重估计)和健康状态评估(涵盖病害识别、畸形检测与行为监测)两大方面的应用进行系统综述。在生物量统计方面, 重点分析了基于检测、回归与跟踪的计数方法, 以及基于关键点、轮廓和立体视觉的体长体重估计技术; 在健康状态评估方面, 深入探讨了体色、纹理、体型特征在病害与畸形识别中的应用, 以及行为监测在生理活动、异常行为与群体动态中的量化方法。本文还指出当前技术面临的数据获取难、模型泛化能力弱、环境干扰强、多模态融合不足等挑战, 并对未来研究方向如跨域数据集构建、自适应模型开发和多技术融合等提出展望, 以促进水产养殖的智能化和精准化发展。

关键词: 计算机视觉; 鱼; 虾; 生物量统计; 健康状态评估

中图分类号: S969 **文献标志码:** A

DOI: 10.65658/j.hndk.2025091502 **CSTR:** 32403.14.hndk.2025091502

Computer Vision-Based Research Progress on Biomass Statistics and Health Status Assessment of Fish and Shrimp

LU Guoxing^{1,2,3}, WANG Huiru³, ZHOU Jialong¹, LIANG Lin², ZHONG Guoding³,
YE Zhangying¹, ZHAO Jian¹, PENG Zequn¹✉

(1. College of Biosystems Engineering and Food Science, Zhejiang University; Key Laboratory of Equipment and Informatization in Environment Controlled Agriculture, Ministry of Agriculture and Rural Affairs, Hangzhou 310058, China; 2. Hangzhou Agile Robotics Technology Co., Ltd., Hangzhou 311200, China; 3. Hainan Kuaifisher Biotechnology Co., Ltd., Haikou, Hainan 570100, China)

Abstract: Computer vision technology has emerged as a key technical means for the intelligent management of aquatic animal farming, thanks to its non-invasive, high-precision, and automated characteristics. This paper

Received: 2025-09-15; **Revised:** 2025-10-13; **Accepted:** 2025-10-16;

✉ **Corresponding author(s):** PENG Zequn, E-mail: pzqal1989@126.com

systematically reviews the applications of computer vision in two major aspects of aquatic animal farming: biomass statistics (including population counting, body length and weight estimation) and health status assessment (covering disease identification, deformity detection, and behavior monitoring). In terms of biomass statistics, the paper focuses on analyzing counting methods based on detection, regression, and tracking, as well as technologies for body length and weight estimation that rely on key points, contours, and stereo vision. For health status assessment, it delves into the application of body color, texture, and body shape features in disease and deformity identification, along with quantitative methods for behavior monitoring in the context of physiological activities, abnormal behaviors, and group dynamics. Furthermore, the paper points out the current challenges faced by the technology, such as difficulties in data acquisition, weak model generalization ability, strong environmental interference, and insufficient multi-modal fusion. It also puts forward prospects for future research directions, including the construction of cross-domain datasets, the development of adaptive models, and the integration of multiple technologies, aiming to promote the intelligent and precise development of aquaculture.

Keywords: computer vision; fish; shrimp; biomass statistics; health status assessment

0 引言

水产品养殖在全球粮食供应和经济发展中极为关键,其生产效率与动物健康状况直接影响产业的可持续性,因此,对水产动物实时统计和健康状态评估极为重要。然而,在传统养殖管理中,生物量统计大多依赖人工计数、现场称重和肉眼观察,健康状态评估则需借助实验室检测,存在效率低下、主观性强、易导致生物应激及物理损伤等局限性,更因预警滞后,容易错失疾病防控的最佳时机。随着人工智能和图像处理技术的不断突破,计算机视觉逐步实现了对水产动物外部形态和行为模式的自动化采集与智能解析,构建了一套以“非接触检测-实时数据处理-精准决策”为核心的技术体系^[1]。

近三十年来,计算机视觉在水产动物研究中的应用已逐步发展出多个方向:在生物量统计领域,从早期依赖传统图像处理的体长测量,逐渐发展出融合深度学习的群体计数与三维体重估算;在健康监测方面,则从最初的体色识别,扩展至融合体色、纹理与体型的多特征病害诊断,并结合运动轨迹实现行为异常的早期预警^[1]。现有研究覆盖了鱼类^[1,2]、虾类^[3,4]等多种主要水产品养殖对象^[5,6],应用场景也从实验室可控环境延伸至工业化循环水、深海网箱等复杂的实际应用场景。然而,水下光照条件不稳定、水体浑浊与颗粒散射、生物间遮挡频繁等现实因素,仍持续制约着技术的大规模推广。此外,模型在不同物种之间的泛化能力较弱,多源数据融合机制的缺乏,也是目前亟待突破的瓶颈。

综上所述,本文整合了近年来国内外相关研究成果,系统地阐述了计算机视觉在水产动物群体计数、体长测量、体重估计中的技术原理与应用案例,再深入分析其在病害检测、畸形识别、行为监测中的实践进展,通过对比不同技术路径的性能参数,明确各方法适用边界,最后剖析当前技术瓶颈并提出未来研究方向,为推动计算机视觉技术在智慧渔业中的产业化应用提供全面参考。

1 计算机视觉在水产动物生物量统计中的应用

水产动物生物量统计是养殖生产管理、产量预估与资源评估的核心环节。而传统人工统计方法存在效率低、主观性强、易对生物造成应激损伤等局限性。计算机视觉技术凭借非接触、自动化、高精度的优势,已形成涵盖群体计数、体长测量与体重估算的完整技术体系,有效解决了传统方法的痛点,推动水产养殖向智能化方向发展。

1.1 群体计数技术 群体计数是生物量统计的基础,计算机视觉通过对水产动物图像或视频数据的分析,实现个体数量的自动化统计,根据技术原理可分为基于检测、基于回归与基于跟踪三类核心方法,各类方法在适用场景与性能上呈现显著差异(如表1所示)。

表 1 不同群体计数方法对比

计数方法	原理	适用场景	优点	缺点	代表研究
基于检测的计数方法	利用YOLO、Faster R-CNN等算法检测个体并生成边界框,统计边界框数量实现计数	中低密度养殖(如成鱼网箱、虾类养殖)、目标轮廓清晰、光照条件稳定	计数逻辑直观,可同步获取个体位置与形态参数,易部署与调试	高密度重叠场景漏检率高,受光照、背景干扰影响大,小目标(如鱼苗)检测精度不足	Zhang等 ^[9]
基于回归的计数方法	通过MCNN、CSRNet等模型生成密度图,对密度图积分得到个体总数	高密度养殖(如虾苗、鱼苗培育)、个体尺寸差异小、密集分布无明显运动	高密度场景适应性强,计数效率高,轻量化模型可适配便携式设备	无法获取个体信息,密度图解释性弱,需大量标注数据适配不同物种	Li等 ^[12]
基于跟踪的计数方法	结合检测与跟踪算法(如DeepSORT、ByteTrack),建立帧间目标轨迹实现计数	动态场景(如鱼类游动、仔鱼转移)、中低密度、存在轻微遮挡	避免动态场景重复计数,可获取个体运动轨迹,适配养殖过程监测	依赖检测精度,严重遮挡或高速运动易导致轨迹断裂,计算复杂度高	Zhao等 ^[18]

1.1.1 基于检测的计数方法 在群体计数技术中,基于检测的方法以目标检测算法为核心支撑,其核心逻辑是先在图像中精准定位单个水产动物并生成对应的边界框,再通过统计边界框的数量来实现个体计数,这种“先检测个体,后统计数量”的思路,让计数过程具备了清晰的可追溯性。该类方法中,YOLO系列算法因兼顾精度与速度,成为水产场景的主流选择:崔榛^[7]针对红鳍东方鲀(*Takifugu rubripes*)改进YOLOv3模型,通过K-means聚类优化锚框、删除大尺度检测层并引入Soft-NMS算法,使计数准确率超90%、召回率超93%,同时检测速度提升3 ms,适配养殖场景的实时性需求;Bukas等^[8]在凡纳滨对虾(*Penaeus vannamei*)计数中采用YOLOv5m6模型,通过按光照-距离类别优化NMS与置信度阈值,在测试集上实现平均绝对百分比误差5.97%,此外在较远拍摄距离下仍保持较高识别精度;Zhang等^[9]提出YOLOv8n-MEMAGD算法,通过融入GELU激活函数、MPDIoU定位损失及多尺度特征融合模块,在斑石鲷(*Oplegnathus punctatus*)计数中平均绝对误差和均方根误差较低,且平均精度提升显著,帧率可达61 fps,满足动态养殖环境下的计数需求。此外,Faster R-CNN为代表的两阶段检测算法,凭借在目标定位精细度和多物种场景适配性上的独特优势,也在水产群体计数的特定场景中得到应用,如Li等^[10]以ZFNet为骨干网络的Faster R-CNN模型,在ImageCLEF鱼类数据集上实现mAP@82.7%,为多物种鱼类计数提供了可靠的目标定位基础。基于检测的计数方法的优势在于计数逻辑直观、个体定位精准,可同步获取个体形态信息,但其性能易受目标重叠与密度影响,在高密度养殖场景(如虾苗、鱼苗密集分布)中易出现漏检或重复计数,需结合图像预处理或后处理优化。

1.1.2 基于回归的计数方法 针对高密度水产动物场景下目标易重叠的问题,基于回归的计数方法应运而生,其核心原理是通过深度学习模型将图像直接映射为密度图,再对密度图进行积分运算得到个体总数,从根本上避免了高密度下目标检测的重叠干扰问题。该类方法的关键在于通过多尺度特征提取与密度分布建模,提升密集场景下的计数精度。Zhang等^[11]提出的多列卷积神经网络(MCNN),通过多尺度卷积列捕获不同尺寸虾苗的特征,首次将人群计数思路迁移至水产领域,为后续虾苗、鱼苗等小型水生生物的密度估计提供了框架;Li等^[12]开发的空洞卷积神经网络(CSRNet),利用空洞卷积扩大感受野,在高密度虾苗场景中有效减少空间信息损失,提升特征提取精度,为密集生物的计数提供了算法优化方向;Dang等^[13]针对虾苗尺寸变化问题,提出多尺度特征融合网络(MFFN),通过双向多尺度特征金字塔(BMFPN)提取多尺度特征,并动态调整高斯核大小适配虾苗尺寸差异,显著提升了高密度虾苗计数的稳定性;Liu等^[14]在“深蓝1号”深海网箱的大西洋鲑(*Salmo salar*)计数中,提出密集多尺度特征聚合网络,通过密集连接的空洞卷积聚合多尺度特征,生成高质量密度图,较MAN、HDNN等模型精度提升44%以上,适配深海网箱高密度鱼类计数需求。此外,轻量化模型的开发进一步拓展了该类方法的应用场景,如Li等^[15]针对鲫鱼(*Carassius auratus*)鱼苗提出的MSENet网络,集成Squeeze-and-Excitation注意力模块与密度图回归,可嵌入便携式设备,满足现场快速计数需求。基于回归的计数方法的核心优势在于高密度场景适应性强、计数效率高,但其局限性在于无法获取单个个体的位置与形态信息,且密度图的物理意义解释性较弱,需通过大量标注数据训练以适配不同物种与环境。

1.1.3 基于跟踪的计数方法 当水产动物处于游动、转移等动态场景时,个体易出现跨帧运动,从而导致重复计数。基于跟踪的计数方法致力于解决此类问题,其核心思路是通过在连续视频帧中追踪个体运动轨迹,实现目标跨帧关联与准确计数。该类方法通常结合目标检测与跟踪算法,通过提取目标的外观特

征与运动特征,建立帧间目标对应关系,避免因个体运动导致的计数偏差。洪宇^[16]针对水下鱼类动态计数,提出改进 DeepSORT 跟踪算法,以 YOLOv4 替换原检测器、CIOU 替换 IOU 进行目标匹配,有效解决了水下光照不均与鱼体遮挡导致的跟踪失效问题;Huang 等^[17]采用 YOLOv8 结合 ByteTrack 多目标跟踪算法,对大口黑鲈(*Micropterus salmoides*)进行轨迹分析,通过优化目标关联策略减少鱼体遮挡导致的体长测量目标丢失,为动态计数与体长测量的联动提供了技术支撑;Zhao 等^[18]提出 FA-ByteTrack 改进算法,结合时空图卷积网络,在 1.5 m×1.5 m×1 m 循环水箱中对 120 尾大口黑鲈(400~500 g)进行跟踪,提升了高遮挡场景下的目标关联精度,使体长测量相关的头尾关键点匹配准确率显著提高;Abe 等^[19]针对黑青鳉(*Oryzias latipes*)和孵化场仔鱼,设计基于帧间欧氏距离匹配质心的跟踪系统,结合遮挡检测,在 120 fps 下实现计数平均精度 91.67%,30 fps 下仍保持 87% 以上精度,满足大规模仔鱼转移过程中的动态计数需求。此外,传统跟踪算法如 Kalman 滤波、匈牙利算法也被广泛应用,如 Albuquerque 等^[20]结合 Blob 检测、混合高斯模型(MoG)与 Kalman 滤波,在 20 段红鳍鲃(*Pintado real*)鱼苗视频(约 1 000 尾)上实现计数平均精度 97.47%,解决了鱼苗游动导致的帧间位移问题。该类方法的优势在于可获取个体运动轨迹与动态行为信息,避免动态场景下的重复计数,但其性能依赖于目标检测精度与跟踪算法的鲁棒性,在高速运动、严重遮挡或物种外观相似场景中,易出现轨迹断裂或身份混淆,需通过多特征融合(如外观特征+运动特征)进一步优化。

1.2 体长与体重估计技术 体长与体重是水产动物生物量统计的关键参数,计算机视觉通过图像特征提取与建模,实现非接触式体长测量与体重估算,根据技术路径可分为基于关键点检测、基于轮廓提取与拟合、基于立体视觉三类方法,各类方法在精度与场景适配性上形成互补(如表 2 所示)。

表 2 不同体长/体重估计方法对比

估计方法	适用场景	优点	缺点	代表研究
基于关键点检测的体长测量	动态场景(如游动鱼类)、中低密度、个体姿态轻微弯曲	适应姿态变化,实时性强,可同步获取个体局部特征	依赖关键点标注数据,严重遮挡易漏检,小目标(如鱼苗)关键点定位难	He 等 ^[22]
基于轮廓提取与拟合的体长测量	静态场景(如脱水鱼、固定姿势养殖鱼)、光照稳定、无遮挡	计算成本低,易部署,静态个体精度高,无需复杂模型训练	依赖轮廓完整性,动态与弯曲个体误差大,无法获取深度信息	李振波等 ^[27]
基于立体视觉的三维尺寸与体重估计	水下动态场景、复杂环境(浑浊、低光)、高精度需求(如育种、产量预估)	三维信息全面,精度高,抗干扰强,适配动态与弯曲个体,体重估算参数多	设备成本高,需标定与校正,计算复杂,高密度重叠场景点云匹配难	Zhou 等 ^[30]

1.2.1 基于关键点检测的体长测量 基于关键点检测的体长测量是通过捕捉鱼头、鱼尾、背鳍、胸鳍等特征点,再利用特征点间的欧氏距离、弧长等几何关系计算体长,这种方式的核心优势在于能适应个体姿态变化,尤其适用于动态场景下的体长测量。该类方法通常以深度学习模型为基础,通过标注关键点点位训练检测模型,实现特征点的自动定位与匹配。温海磊^[21]以工厂化循环水养殖的大口黑鲈为研究对象,采用 YOLOv8 网络训练轻量化关键点检测模型,标注鱼头、鱼尾关键点并通过数据增强扩充数据集,结合张正友标定法与单目深度估计算法(depth anything)获取关键点三维坐标,计算欧氏距离作为体长,10 尾样本平均相对误差 6.4%,实时视频流帧数达 25 帧,满足循环水养殖实时监测需求;He 等^[22]将单阶段检测算法与深度相机结合,改进 YOLOv8 模型引入 C2F_ADCN 模块、BIFPN 特征融合与 Wise-IoU 损失函数,在自制 AASM 数据集(含鱼、蛤、蛭等)上实现实例分割 mAP@0.599.2%,并通过深度相机提取鱼体头尾关键点,较传统双目视觉方法精度提升显著;Suo 等^[23]采用双目相机结合两阶段检测算法,检测鱼体 4 个关键点(头、背鳍、胸鳍、尾)并设定背鳍-胸鳍中点为辅助点,使体长测量平均相对误差达 5.6%,为后续多关键点体长建模提供了参考;Yu 等^[24]构建 fish-keypoints 数据集,设计 CenterFishNet 鱼类专用特征提取主干网络,检测鱼类及其关键点并结合双目立体视觉进行三维重建,体长检测精准度达 85.1%,相对误差约 7%,解决了通用网络对鱼类特征提取不足的问题。该类方法的核心优势在于对个体姿态变化的适应性强,可处理轻微弯曲或倾斜的个体,且关键点定位精度高,为体长计算提供可靠依据;但其局限性在于依赖大量标注的关键点数据,对标注质量要求高,且在严重遮挡(如多鱼重叠)场景下,关键点易漏检或误检,需结合目标分割或跟踪算法优化。

1.2.2 基于轮廓提取与拟合的体长测量 基于轮廓提取与拟合的体长测量方法,更侧重于通过图像处理

技术获取水产动物的二维轮廓,再借助几何模型对轮廓进行优化拟合,最终计算体长,核心是通过轮廓优化消除噪声与背景干扰,提升体长计算的准确性,这种方法适用于静态或姿态较稳定的个体测量。Balaban 等^[25]采用最小外接矩形法,在光箱环境中测量粉红鲑、红鲑等 4 种阿拉斯加鲑鱼体长,通过不断旋转矩形并计算最小面积确定鱼体长度,结合面积与体宽信息估算体重,为鲑鱼体长-体重关联模型提供了精准数据;魏明鑫^[26]以鲫鱼为研究对象,提出改进的形态学骨架提取方法获取鱼体体长中心线:对二值图像进行连续开运算和腐蚀操作去除噪声,添加头部、尾鳍顶点并通过最小二乘法拟合中心线,再分别采用单目与双目视觉测量体长-单目视觉通过对比标定板特征线像素值宽度与水层标定比例系数计算体长(平均误差 2.76%),双目视觉通过轴线汇聚结构完成像素坐标系到世界坐标系转换,相邻点欧氏距离求和得到体长,骨架拟合有效解决了鱼体轻微弯曲导致的体长误算;李振波等^[27]通过图像细化操作,利用鱼苗图像中的像素点个数计算鱼苗体长,实现鱼苗体长的快速估算,适用于早期鱼类生长监测,避免了人工测量对鱼苗的损伤;Lee 等^[28]采用 10 个关键点构建测量线,通过相邻点欧氏距离求和计算海参(*Stichopus japonicus*)体长,对 300 个样本测量误差小于 0.17%;Misimi 等^[29]使用最小外接矩形法对大西洋鲑鱼(*Gadus morhua*)和大西洋鳕鱼进行体长与体宽测量,为分析鱼类在死后僵硬和冰藏期间的尺寸体型变化提供了数据支撑。该类方法的优势在于无需复杂的深度学习模型,计算成本低,易在嵌入式设备部署,且对静态个体测量精度高;但其局限性在于对轮廓完整性要求高,受光照不均、水体浑浊或个体遮挡影响大,难以处理动态或严重弯曲的个体,且二维轮廓无法反映深度信息,易因拍摄角度导致体长低估或高估。

1.2.3 基于立体视觉的三维尺寸与体重估计 为应对水下动态、复杂环境下的高精度测量需求,基于立体视觉的三维尺寸与体重估计方法逐渐成为研究热点,它通过多相机或深度相机获取水产动物的三维坐标信息,结合水折射校正模型消除环境干扰,不仅能计算体长,还能获取体宽、体高的三维尺寸,再通过体长-体重回归模型或三维体积估算体重。该类方法的核心是通过三维信息获取解决二维视觉的深度歧义问题,提升尺寸测量的准确性与鲁棒性。Zhou 等^[30]以体长 250~320 mm 的鲈鱼(*Lateolabrax japonicus*)为研究对象,采用 Real Sense D435 双目相机采集 RGB 和深度图像,通过对比度自适应 Grab Cut 算法分割鱼体,利用轮廓检测与最小外接矩形判断鱼体姿态,直体鱼选取矩形与轮廓交点为测量点,弯曲体采用改进 Zhang-Suen 算法提取骨架并“拉直”处理,同时基于折射定律建立校正模型,为鲈鱼体重估算提供了高精度体长数据;Risholm 等^[31]使用水下 3D 距离门控相机替代传统双目相机,在浑浊水体中测量自由游动鱼类体长,通过深度信息优化个体轮廓提取,解决了传统双目视觉在浑浊环境下精度不足的问题;Zhang 等^[32]基于 RGB-D 图像结合深度学习,构建全自动鱼类生物量估计系统,通过深度神经网络实现水下活鱼体长测量,并结合体长-体重幂函数模型,实现体重全自动估算,为养殖产量预估提供了一体化方案;Shi 等^[33]基于 LabVIEW 开发立体视觉系统,自动提取斑石鲷吻端和尾鳍关键测量点,体长平均相对误差<2.55%,同时通过体表面积-体重模型估算体重,提升了测量系统的易用性与功能性;Deng 等^[34]用深度相机结合关键点检测,从水面上方实现加州鲈体长无损测量,避免了水下设备部署的复杂性,为池塘养殖体长测量提供了新方案。该类方法的优势在于可获取三维尺寸信息,测量精度高,抗环境干扰能力强,可处理动态与弯曲个体,且三维数据为体重估算提供了多参数支撑(如体宽、体高);但其局限性在于设备成本较高,需进行相机标定与水折射校正,计算复杂度高,且在高密度重叠场景下,三维点云匹配难度大,需结合实例分割算法进一步优化。

2 计算机视觉在水产动物病害和畸形中的应用

2.1 水产动物病害检测中的图像特征提取与应用 在水产养殖中,疾病是制约产业可持续发展的核心问题^[35]。传统病害诊断方法(如临床观察、病原学检测)依赖专业设备与人员,存在检测周期长、侵入性强、预警滞后等局限,易导致疾病扩散^[36]。计算机视觉技术通过提取养殖对象体色、纹理、体型等特征,构建“图像预处理-特征提取-病害识别”的自动化诊断体系(如图 1 所示),可实现体表病害的快速、无损、精准检测,为养殖病害防控提供关键技术支撑。




图1 技术路线图

2.1.1 体色特征在病害检测中的应用 体色是水产动物体表最直观的生理特征,正常状态下具有物种特异性与稳定性。然而,当水产动物患病时,其体色往往会发生显著变化,这些变化能够为疾病诊断提供关键线索。当受到鱼溃疡综合征、尾鳍腐烂、细菌性鳃病和寄生虫病等疾病的影响时^[37],鱼的皮肤可能会出现斑点或体色变化,严重时可能会导致鱼翻身或死亡。当虾类感染弧菌病、肝胰腺细小病毒病、黑鳃病等疾病时,虾体颜色与健康状态下的体色差异显著。因此,对体色特征的提取和分析对于疾病检测具有重要意义。

在常见的 RGB 颜色空间中,每个像素点对应红(R)、绿(G)、蓝(B)三个颜色通道,通过精确计算不同颜色通道的像素值变化,能够精准捕捉体色的细微改变,病斑颜色特征的提取效果如图2所示。为了识别不同鱼类中受红斑病(RSD)影响的区域, Malik 等^[38]提出了一个基于模糊规则的方法(FRBAM)、三角隶属函数(TMFN)、Canny 边缘检测器和标准 RGB 颜色模型的系统。使用 FRBAM 和 TMFN 方法跟踪鱼的 RSD 区域使用通常的 RGB 模型, RSDF 的受损区域呈红色(颜色形成和伪彩色图像)^[33]。通过采集从 Haor 地区的 RSD、红病虫害治疗、有鳍鱼类疾病和流行性溃疡综合征(EU 影响的鱼类样本,获取了各种大小的 RSDF 照片。通过用红色像素标记鱼的 RSD 影响区域,更好地从 RSDF 照片中识别它们^[40]。Nayan 等^[41]通过使用标准 RGB 模型用红色(红色像素)标记受影响区域来准确检测鱼类中受 RSD 影响的区域。HSV 颜色空间在体色分析中也具有独特优势,它将颜色分为色调(H)、饱和度(S)和明度(V)三个分量。Rachman 等^[42]使用基于 HSV 阈值的方法来确定鱼的哪些部分受到了疾病感染,采用了 MobileNetV2 作为模型系统架构,并结合图像处理技术,通过设置 HSV 阈值来分割出患病区域。这种方法能够更直观地描述体色的属性,对于一些体色变化较为复杂的疾病检测场景具有更好的适应性。




图2 病斑颜色特征提取效果

注: A: 待处理患病鱼图像; B: 病斑提取效果

2.1.2 纹理特征在病害检测中的应用 纹理反映体表组织的微观结构(如粗糙度、平滑度、方向性),病变区域(如细菌性鳃病的鳃丝增生、虾类黑鳃病的鳃部黑化)的纹理特征与正常区域存在显著差异,可通过纹理分析实现早期、细微病害的识别。Li 等^[43]在对计算机视觉技术应用于鱼类疾病诊断的综述里,着重总结了图像处理、多模态成像及传感器检测等方法,并明确指出多信息融合和深度学习是未来的发展趋势,这为利用纹理特征等图像信息进行水产养殖智能化疾病诊断提供了坚实的理论基础。Reddy 等^[44]通过图像处理结合 SVM 分类检测鱼类疾病,在整个检测过程中,通过有效提取纹理特征和分析,实现了 94.12% 的准确率,为鱼病早期诊断提供了切实有效的方法。Ahmed 等^[45]采用图像增强结合 SVM

分类检测鱼类疾病,准确率达 94.12%,为水产养殖病害诊断提供了可靠方案。许瑞峰等^[46]通过改进 YOLOv8 网络(结合 FasterNet 轻量化主干和 EMA 注意力机制)提取对虾图像前景,结合 Farneback 光流法和 GLCM 提取运动与纹理特征,训练 SVM 分类器实现对虾发病视频片段的检测,在 300 个测试样本上准确率达 83%,体型特征与其他特征协同作用,有效降低了工厂化养殖中对虾病害检测的成本与复杂度。

2.1.3 体型特征在病害检测中的应用 体型特征通过量化病变区域的大小、周长、轮廓复杂度等参数,反映病害的严重程度与发展趋势,尤其适用于体表出现凸起、溃烂、残缺等形态改变的病害(如虾类白斑病、鱼类皮肤肿瘤)。以对虾体疾病检测为例,通过提取虾体病变区域的体型特征,可有效判断病变的程度和发展趋势。Ramachandran 等^[47]通过改进的 DICNN 模型检测虾白斑病,该模型准确率高达 97.22%,为虾病早期检测提供了高效方法。Varma 等^[48]通过集成 K-means 聚类 and DLCNN 的 SDNet 模型,检测虾类疾病,准确率达 98.51%,为虾病分类提供高效方法。Shang 等^[49]通过图像特征提取结合改进的 WOA-CNN-BiGRU 模型,评估无水运输中石斑鱼(*Epinephelus*)的健康状态,分类准确率达 97.43%,为鱼类运输健康监测提供了高效方法。Shanvi 等^[50]通过卷积神经网络分类新鲜和感染鱼,准确率达 94%,为水产养殖质量控制提供自动化解决方案。胡静^[51]通过多类支持向量机和改进模糊 C-means 聚类,实现鲤科病鱼种类识别(准确率 95%)和病斑分割(准确率 92%),在病鱼种类识别和病斑分割过程中,体型特征与其他特征相互配合,为病鱼图像处理提供了高效方法。林晓敏^[52]通过计算机视觉技术构建鱼群健康状态评估系统,结合行为分析与生理指标监测实现鱼类健康状态实时评估,体型特征等视觉信息的运用为智能养殖提供了技术支持。陈科等^[53]通过改进 YOLO 模型结合计算机视觉构建轻量级鱼病无损检测模型,在提升检测速度与准确率的过程中,体型特征的提取与运用使得该模型适用于复杂养殖环境下的病害识别。丁国超等^[54]设计的基于机器视觉的鱼病识别处理装置,通过图像采集与处理模块结合分类算法实现病鱼自动识别与处理,在整个识别处理过程中,体型特征等图像信息的利用提高了养殖效率与病害防控能力。

综上,体色、纹理、体型三类特征在水产动物病害检测中展现出不同的技术优势与局限性。为系统对比各类方法的检测性能,本文对基于计算机视觉的疾病检测技术进行了综合分析,结果如下表 3 所示。三类特征在病害检测中呈现出互补性技术特征:体色特征凭借直观的视觉差异适用于快速初筛,但对早期隐性病变敏感度不足;纹理特征通过微观结构分析提升诊断精度,却受限于复杂计算与噪声干扰;体型特征则以量化形态异常为优势,却在动态或细微病变中存在检测盲区。这种技术分野提示,未来研究可通过多特征融合策略(如体色-纹理联合分割、体型-行为动态关联)突破单一模态局限,同时需针对水体环境干扰(如光照波动、悬浮颗粒)开发自适应预处理算法,以提升检测模型的鲁棒性。此外,表格数据反映出当前研究在跨物种普适性方面的不足,这为构建多物种联合训练数据集提供了研究方向。

表 3 基于计算机视觉的疾病检测方法对比分析

检测方法	检测效果	优点	缺点	代表研究
体色特征	病斑分割准确率: 92%	直观捕捉体色异常,易识别物种特异性变化	依赖颜色通道差异,早期病变检测受限;易受水体光照、浑浊度影响	胡静 ^[45]
纹理特征	鱼类病害分类准确率: 86%	反映病变细微差异,多模态融合下鲁棒性强	计算复杂度较高;对图像噪声和质量敏感;依赖有效的预处理	Malik等 ^[32]
体型特征	虾白斑综合征检测准确率: 97.22%	客观量化形态异常;可自动提取高层抽象特征	对细微畸形或动态变化检测不足;复杂遮挡情况下轮廓提取精度易降低	Ramachandran等 ^[41]

2.2 水产动物畸形检测中的计算机视觉技术 畸形检测的核心是通过计算机视觉量化水产动物形态的异常偏差,主要通过对水产动物的形态特征进行精确分析来实现。在特征提取过程中,常用的技术包括边缘检测、轮廓提取和几何特征计算等。边缘检测算法如 Canny 算法,能够准确地检测出鱼类身体的边缘,勾勒出其轮廓。轮廓提取则是通过特定的算法和技术,能够将边缘连接成连续的轮廓线,准确地呈现出水产动物的体型特征。这不仅有助于识别正常形态的水产动物,更能敏锐地发现因畸形导致的体型异常变化。几何特征计算则是从量化的角度对轮廓进行分析,包括计算水产动物的长度、宽度、面积、周长等几何参数,以及一些体型描述子,如圆形度、矩形度等。这些几何特征能够为畸形的判断提供客观的量

化指标,使得畸形检测更加科学、准确。例如,当鱼类的身体长度与宽度比例超出正常范围,或者某些体型描述子偏离了正常的数值区间时,就可能暗示存在畸形情况。

基于这些关键技术,众多学者展开了深入研究,并取得了一系列具有实际应用价值的成果。Lee 等^[55]通过体色分割、轮廓提取及 Turn Angle Cross-correlation(TAC)方法,深入实现了虾体体型完整性分析,分类准确率达 93.7%-94.2%,高度适用于虾类质量实时检测,能在养殖、捕捞、加工等环节及时察觉虾体质量问题。Zhang 等^[56]提出基于进化构造特征(ECO)结合 AdaBoost 模型的创新方法,自动构建特征进行虾体体型分级,在 879 个样本中准确率达 95.1%,精度 0.948,召回率 0.920,验证了方法的高效性,有力支持虾类品质评估与分类。Costa 等^[57]通过对欧洲鲈鱼(*Dicentrarchus labrax*)进行采样,基于图像分析,并利用轮廓形态测量法(椭圆傅里叶分析, EFA)与多元建模技术(偏最小二乘建模, PLS)相结合,畸形个体分类准确率 88.21%。在鱼类搏斗过程中,鱼鳃经常发生变化, Sweidan 等^[58]利用边缘检测和小波变换方法提取鱼鳃的体型特征,并通过主成分分析和支持向量机方法实现了异常鱼鳃体型的分类。Sture 等^[59]通过构建由三个彩色成像 CMOS 相机和三个激光器组成的 3D 计算机视觉系统采集大西洋鲑的图像,利用计算彩色点云、图像预处理、提取几何与体色特征,并采用 SVM 进行分类的方法,该系统判别畸形效率为 86%。张伟等设计平铺单粒化装置结合模板匹配法,通过类重心矩特征与 SVM 分类,实现生鲜/熟对虾完整性检测(识别率 99.6%/99.4%),并搭建在线剔除系统,能按检测结果实时自动剔除体型不完整对虾,处理速度远超人工分选,极大提升对虾加工生产效率与质量。

综上,计算机视觉技术在水产动物畸形检测中,通过边缘检测、轮廓提取与几何特征计算等方法,实现了虾类、鱼类等物种的畸形形态量化分析。然而,水产动物健康状态评估体系不仅需关注个体形态异常,更需结合行为特征构建全方位监测网络,例如游动模式、应激反应及活动量变化等动态指标。因此,从个体形态检测延伸至群体行为监测,成为计算机视觉技术在健康状态评估中深化应用的必然趋势。

3 计算机视觉在水产动物行为监测中的应用

3.1 生理活动监测 当环境中溶氧^[60]、温度^[61]、盐度^[62]、氨氮^[63]和病原感染等超出正常范围时,鱼类通常会表现出异常的生理活动,例如拍尾频率的变化、跳跃、咬合和翻转等,虾类常表现出异常游动(如打转、跳跃)、附肢抽搐、摄食减少或停滞不动等行为。这些特异性行为反应为评估环境胁迫程度提供了重要窗口,并推动了基于计算机视觉的自动化监测技术发展。

南美白对虾(*Litopenaeus vannamei*)通常在没有足够氧气的情况下浮出水面呼吸,针对此现象, Ran 等^[64]利用基于幽灵卷积改进的轻量级 YOLOv5 模型,可实现缺氧浮头行为的精准检测。Xu 等^[65]利用基于投影面积变化计算机视觉算法,结合图像增强与帧差分析技术,从而建立了罗非鱼(*Oreochromis mossambicus*)群体基于行为特征的缺氧程度分级监测方法。Bao 等^[66]利用自主设计的 3D 计算机视觉采集装,结合 Otsu 阈值分割与 Watershed 算法,从而建立了基于 3D 行为参数的溶氧胁迫分级监测模型。此外,呼吸节律本身是反映鱼类氧气代谢状况的直接指标, Høgstædt 等^[67]使用支持向量机、自适应提升和数学形态学等图像处理方法的计算机视觉算法设计了一个远程实验平台,实现了鱼类呼吸节律的实时检测。此外,贾贝贝等^[68]采用支持向量机(SVM)精确提取鱼鳃形态变化,结合形态学细化算法量化尾鳍摆动频率,为生理特征与水质胁迫关联性研究提供了范例。徐榛等^[69]通过图像处理、差分运算及鱼眼定位方法,实时监测点带石斑鱼口部张合状态。鉴于石斑鱼口部张合频率和幅度与鱼的呼吸状况及健康状态密切相关,通过对这些关键指标的精准监测,成功实现异常行为识别与报警功能,极大地提升了养殖效率,为石斑鱼养殖的精细化管理提供了有力支持。

Zheng 等^[70]使用计算机视觉捕捉日本青鳉的鳃活动和呼吸节律,可用于评估水中铜离子的污染水平。Kane 等^[71]利用基于视频的运动分析系统,结合自定义软件开发的坐标追踪与行为算法,并通过量化鱼类的速度、总移动距离、分形维数等行为指标,精准捕捉 MS222 暴露下的应激反应,为环境毒理学中鱼类亚致死行为评估提供了标准化量化工具。Liao 等^[72]通过计算机视觉提取斑马鱼(*Danio rerio*)群的平均游泳速度,以间接揭示暴露于 Cu^{2+} 的鱼的应激反应污染。值得注意的是,行为学研究已明确揭示化学污

染物对鱼类运动模式的影响,例如鲫鱼的拍尾频率被用作水质评估中化学污染物的指标^[73]。实验表明,暴露于 NaOH 和草甘膦 60 分钟后,尾部跳动频率从约 120 次/分钟的正常范围增加到 240~500 次/分钟。尽管针对拍尾这一特定行为的自动化视觉检测研究相对较少,但利用计算机视觉捕捉污染物引发的多种、广义的异常行为模式已成为重要方向。基于此,Ran 等^[74]以 YOLOv8 为基线,采用内容感知特征重组并利用动态卷积开发了一种有效的模型来检测卷曲、漂浮、跳跃、同类相食和死亡等异常虾的行为。

当虾被感染时,它们会出现不吃东西、出现在浅水中、突然移动等异常行为。Morimoto 等^[75]利用基于图像处理的三步检测法,发现感染白斑病的虾在喂食阶段移动距离较健康虾减少 44% 且无饵料响应,建立了可用于早期识别感染虾的自动化检测模型。Li 等^[76]利用基于图像融合的 BCS-YOLOv5 模型(集成双向特征金字塔网络、坐标注意力模块与空间金字塔池化),结合混合高斯运动特征提取技术,揭示了它在真实水产养殖环境中检测异常鱼类行为的潜力,可用于评估与鱼病预警、水质变化、缺氧等相关的鱼类状况。

3.2 异常行为监测 随着计算机技术的发展,计算机视觉方法已被普遍应用于监测水产动物的异常行为,这为监测运动模式提供了一种无损伤且有效的方法。计算机视觉已被广泛应用于从视频图像中提取运动信息,例如平均游泳速度、转弯角度和离水面的高度,从而有效地确定它们的健康状况和活动水平,从而为异常情况提供及时警报。

针对鱼类行为的智能化监测与分析,研究者们从提升目标检测与跟踪精度、捕捉运动特征、到实现高维高精度解析等方面展开了深入探索。Wang 等提出了一种基于改进的 YOLOv5 和 SiamRPN++ 的鱼类异常行为跟踪算法^[77]。Arvind 等^[78]提出了一种基于 Mask R-CNN 的分段神经网络用于鱼类检测,并利用 GOTURN 算法来跟踪检测结果。在提升基础检测模型性能以适应水下复杂环境方面,李道亮等通过对 YOLOv5 网络的改进,融合运动轮廓信息与时空特征,显著提升了异常行为检测的准确性(基于图像融合技术的鱼类异常行为实时检测方法)。而 Long 等^[79]在 YOLOv5s 中嵌入三重注意力机制(协同注意力+卷积块注意力),使模型对水下模糊图像的识别准确率提升至 95.88%。

除了依赖深度学习方法,传统计算机视觉技术在运动特征捕捉也具有独特优势。Kato 等^[80]基于图像采用光流法对金鱼进行行为监测与识别,通过计算图像中像素点的运动矢量,能够精准捕捉金鱼的运动轨迹和速度变化,为金鱼活力评估提供了有效的技术路径。为了检测环境刺激引起的鱼类爆发性游泳行为,Abe 等^[81]使用图像的差分法来表示养殖蓝鳍金枪鱼(*Thunnus thynnus*)鱼苗突然加速的特征值,并使用获得的特征值来区分正常和异常行为,这使得可以使用视频场景检测单个鱼苗。此类方法因规避了复杂检测步骤,在实时性要求高的场景(如突发应激行为预警)中更具实用性。Sun 等^[82]提出自适应聚类算法,结合低氧鱼图像特征将分割速度提升 56%。徐建瑜等^[83]从水槽侧面透明壁拍摄,巧妙利用鱼与背景之间的良好对比度,以体长倍数游速这一独特指标有效反映鱼的活跃程度。通过对不同体长鱼的游速进行测量和分析,发现体长倍数游速能够较好地反映鱼在不同生理状态下的活力差异,为鱼类活力评估提供了一种简单而有效的方法。多传感器与新型感知技术正拓展行为监测的维度,Papadakis 等^[84]开发的多相机同步系统可实现九个养殖池的次秒级行为记录(如逃逸与撕咬动作),为统计建模提供高精度时序数据。在三维行为分析领域,Xia 等^[85]通过量化鱼类在二维及三维空间中的行为变化(如运动轨迹、姿态参数)实现水生毒性的精准分析与预测。

3.3 群体行为监测 群体行为模式作为关键的监测维度,在水产动物活力评估体系中占据着不可或缺的地位。对于群居性水产动物,如鱼群,鱼群的聚集程度、个体间的间距以及群体游动方向的一致性等特点,在正常情形下,鱼群会保持相对稳定且有序的聚集模式,个体间间距适宜,群体游动方向呈现出较高的一致性。然而,当遭受疾病侵袭、水质污染、温度异常等不良环境因素影响,鱼群的聚集模式可能发生显著异常变化。个体间间距可能突然增大,导致鱼群呈现松散状态;或者间距急剧缩小,出现过度聚集现象;甚至群体游动方向陷入混乱,丧失原本的有序性。针对上述行为响应机制,Liu 等^[86]创新性地提出基于多目标跟踪的鱼群活动量估计框架(IFFT)。该方法通过改进 FasterNet 网络架构,引入跨帧特征学习分支和深度聚合模块,实现高精度实时跟踪且可通过椭圆拟合可视化群体空间分布特性。Israeli 等^[87]通过

计算机视觉系统量化低溶氧胁迫下鱼群动态,创新性地采用群体运动模式图(PMP)表征活跃性变化。该方法虽未提供绝对量化值,但通过可视化动态图谱揭示了溶氧梯度与行为响应的关联规律,为环境应激机制研究提供了关键依据。Sadoul 等^[87]的补充研究发现,活跃状态下鱼群呈现扩散特征(个体间距增大),而应激状态下则出现紧缩现象,间距缩减约 40%,该结论从群体动力学角度拓展了评估维度(需注意其样本量局限对普适性的影响)。

在量化分析技术方面,冯国富等^[88]集成 YOLOv4 目标检测与 DeepSort 跟踪算法,精准捕获虾苗应激前后的表型特征变化。基于体色与纹理特征的分类模型分别达到 91.98% 和 96.56% 的准确率,实现了应激响应的客观量化。而汪峰^[89]利用进一步构建多维度评估模型,通过游动速度、方向突变频率及聚集系数等动态参数,建立了虾苗活力分级标准,为种苗筛选提供可量化的决策支持。

在运动参数分析技术方面,Yu 等^[90]使用 Harris 角检测方法对特殊行为的特征点进行提取,并通过 Lucas Kanade 光流法获得子图像中体长为 6~7 cm 的鲤鱼(*Cyprinus carpio*)的速度,平均精度为 96.02%,可用于判断鱼群的速度是否异常。范伟康^[91]运用计算机视觉技术提取鱼群游动高度及离散度等运动参数,并结合水质检测系统,发现鱼群的行为变化与水质状况之间存在紧密联系,即可通过对鱼群运动参数的监测和分析,间接判断水质的优劣,为水质监测提供了一种新颖且有效的生物监测方法。

为提升高密度群体监测精度,Liu 等^[92]设计了一种基于 Transformer 模型的监测方法,该模型具有目标检测、航迹预测和重识别 3 个分支,同时建立鱼的运动模型和外观模型,用于在水箱环境中跟踪多条鱼。Terayama 等^[93]进一步将该技术扩展至高密度鱼群平均速度分布测量,结合外观模型提升了重叠目标的跟踪精度。

综上,计算机视觉技术通过捕捉个体运动轨迹、群体空间分布及行为响应模式,实现了水产动物生理活动、异常行为与群体行为监测的动态量化。然而,不同监测场景对技术方法的实时性、精度及环境适应性要求各异。为系统评估主流技术的性能边界,本文对关键行为监测方法进行多维对比(表 4),涵盖检测精度、创新点及场景适用性等指标,旨在为养殖实践中的技术选型与优化提供实证参考。

表 4 水产动物行为监测技术性能对比

监测场景	技术方法	核心指标	准确率(%)	创新点	文献
缺氧预警	轻量化YOLOv5	浮头行为识别	95.6	幽灵卷积压缩模型	Ran等 ^[58]
	3D视觉+Otsu分割	鱼群三维运动参数	90.2	溶氧胁迫分级模型	Bao等 ^[54]
呼吸监测	SVM+形态学细化	尾鳍摆动频率	准确性高	生理-水质关联量化	贾贝贝等 ^[62]
	鱼眼定位算法	口部张合幅度	84.0	异常行为实时报警	徐榛等 ^[63]
群体行为	IFFT多目标跟踪	群体聚集度	实时分析	椭圆拟合空间分布	Liu等 ^[80]
	YOLOv4+DeepSort	运动轨迹变化	96.6	应激响应量化模型	冯国富等 ^[82]
水质关联	鱼群离散度分析	游动高度/分散度	显著相关	生物式水质预警($r=0.89$)	范伟康 ^[85]

4 存在的问题与挑战

深度学习算法的快速改进促进了计算机视觉技术的发展,为水产养殖中许多以前无法解决的问题提供了新的策略。然而,随着研究的不断深入,通过计算机视觉技术检测水产动物异常过程中暴露出了许多挑战。

(1)数据获取与标注的瓶颈。现有研究依赖的数据集普遍存在样本量不足、异常类别覆盖不全的问题。水产养殖环境的特殊性(如浑浊水体、低光照)导致异常鱼类图像采集难度大,且标注过程需要专业知识与大量时间成本。例如,跨物种(鱼/虾)关键点(如鱼背鳍、虾头胸甲)标注数据匮乏;某些疾病(如早期肝胰腺细小病毒感染)的体表特征不明显,人工标注易产生主观误差。此外,跨地域、跨季节的养殖环境差异进一步加剧了数据分布不均,使得模型难以学习到具有普适性的特征。

(2)模型泛化能力受限。深度卷积网络在复杂养殖场景中易出现过拟合现象,表现为训练集准确率与实际部署效果存在显著差距。检测类模型从低密场景迁移至高密场景时易出现漏检;体长模型跨物种

应用时,关键点匹配准确率下降。此外,模型对未见过的异常类型(如新发病原引发的体表症状)缺乏鲁棒性,需重新标注数据并微调模型,限制了其动态适应性。

(3)算法设计的复杂性与主观性。深度学习架构的选择(如 ResNet、YOLO 系列)及参数调优(如学习率、批量大小)依赖研究人员的经验,缺乏系统性指导。例如,静态轮廓拟合与动态关键点检测这两种体长估计方法的参数体系相互独立,调优过程耗时,同一物种的体长测量结果易出现偏差;在鱼类畸形检测中,不同网络层数对小样本特征的提取效果差异显著,而超参数组合的爆炸式增长使得调优过程耗时且低效。这种主观性导致研究结果难以复现,阻碍了技术的标准化推广。

(4)水下环境干扰与动态场景挑战。水下成像的物理特性(如光线衰减、悬浮颗粒散射)导致图像对比度低、噪声高,传统边缘检测与分割算法失效。例如,基于 2D 视觉的鱼群密度估计在鱼体相互遮挡时误差率高达 30%,需结合 3D 点云或多视角融合技术才能提升精度。

(5)多模态数据融合与解释性不足。现有方法多依赖单一视觉模态,未充分利用水质传感器、生物电信号等多源数据。例如,群体计数未结合水流速度等环境数据,易将临时密集的鱼群误判为养殖密度超标。此外,深度学习模型的“黑箱”特性使得诊断结果缺乏可解释性,难以获得养殖户信任,需发展基于注意力机制的可视化技术,明确模型决策依据。

5 总 结

本文系统综述了计算机视觉技术在水产动物生物量统计(群体计数、体长体重估计)和健康状态评估(病害检测、畸形识别、行为监测)中的应用。研究表明,该技术能够有效克服传统方法的局限性,实现非接触、自动化、高精度的监测,极大地提升了水产养殖的管理效率和智能化水平。基于检测、回归和跟踪的计数方法各有其适用场景;基于关键点、轮廓和立体视觉的体长体重估计技术精度不断提高;结合体色、纹理、体型特征及行为分析的健康状态评估体系日益完善。然而,该技术仍面临水下环境复杂、数据获取难、模型泛化弱等挑战。未来研究需通过构建跨域数据集、开发自适应模型、深化多模态融合等手段,突破现有瓶颈,推动计算机视觉技术从实验室研究走向大规模产业化应用,最终为实现智慧渔业的精准化、自动化与可持续发展提供核心驱动力。

作者贡献声明

XXX: 负责论文初稿撰写、初稿修订、经费支持。XXX: 参与修订稿件。XXX: 编校规范制定。XXX: 参与编校规范制定。XXX: 参与编校规范制定,参与编写英文模板。全体作者均参与结果讨论。

利益冲突声明

作者声明,其不存在已知的可能影响本论文所报告工作的竞争性经济利益或个人关系。

AI 使用声明

本文的英文题名、摘要和关键词采用腾讯元宝翻译生成,并进行了部分修改。如果论文中使用了 AI 工具生成部分论文内容,请在文章末尾明确声明使用 AI 工具的名称版本,生成内容采用情况,未声明即视为未使用。本刊采用 AIGC 工具进行检测。本刊不接受 AI 生成全文和 AI 生成数据、研究方法、研究内容、结论等关键部分的稿件,欢迎作者使用 AI 生成视频摘要、图片摘要等增强发表附件材料,辅助说明论文内容,加强论文的传播。

伦理声明

本研究中涉及人类或动物的任何实验,均须提供伦理声明,例如:“动物实验遵循北京中医药大学实验动物管理与使用伦理委员会的指导原则,并经北京中医药大学动物伦理使用委员会批准(伦理代码:此处提供)。”对于不涉及人类或动物的生物学研究,可提供“不适用”声明。

电子补充材料(如需要)

补充材料可在本文的在线版本中获取 <https://doi.org/DOI>(访问地址由出版者自动插入)

数据可用性

请直接声明所需数据的可用性信息,例如:“支持论文结论所需的所有数据均已包含在稿件和/或电子补充材料中。如需获取与本文相关的其他数据,可向通信作者提出申请。”(多数作者选此项)或“不适用。”

致谢(Acknowledgements)

本文得到海南省期刊出版研究基金项目(HNPA-2024-B02)支持。

This work was supported by the Hainan Provincial Journal Publishing Research Fund (HNPA-2024-B02).

参考文献:

- [1] SABERIOON M, GHOLIZADEH A, CISAR P, et al. Application of machine vision systems in aquaculture with emphasis on fish: state - of - the - art and key issues[J]. *Reviews in Aquaculture*, 2017, 9(4): 369–387.
- [2] AL-ABRI S, KESHVARI S, AL-RASHDI K, et al. Computer vision based approaches for fish monitoring systems: a comprehensive study[J]. *Artificial Intelligence Review*, 2025, 58(6): 185.
- [3] YEH C T, LING M S. Portable device for ornamental shrimp counting using unsupervised machine learning[J]. *Sensors and Materials*, 2021, 33(9): 3027–3036.
- [4] GÜMÜŞ B, BALABAN M Ö, ÜNLÜSAYIN M. Machine vision applications to aquatic foods: a review[J]. *Turkish Journal of Fisheries and Aquatic Sciences*, 2011, 11(1): 171–180.
- [5] KAKEHI S, SEKIUCHI T, ITO H, et al. Identification and counting of Pacific oyster *Crassostrea gigas* larvae by object detection using deep learning[J]. *Aquacultural Engineering*, 2021, 95: 102197.
- [6] 赵澜锴, 高国栋, 孙子皓, 等. 基于机器视觉的牡蛎分级设备设计 [J]. *食品与机械*, 2024, 40(4): 78–83.
ZHAO L K, GAO G D, SUN Z H, et al. Research on oyster grading equipment based on machine vision[J]. *Food & Machinery*, 2024, 40(4): 78–83.
- [7] 崔榛. 基于计算机视觉的红鳍东方鲀计数系统 [D]. 大连: 大连海洋大学, 2020.
CUI Z. Based on computer vision the counting system of puffer fish[D]. Dalian: Dalian Ocean University, 2020.
- [8] BUKAS C, ALBRECHT F, UR-REHMAN M S, et al. Robust deep learning based shrimp counting in an industrial farm setting[J]. *Journal of Cleaner Production*, 2024, 468: 143024.
- [9] ZHANG Z Z, LI J W, SU C W, et al. A method for counting fish based on improved YOLOv8[J]. *Aquacultural Engineering*, 2024, 107: 102450.
- [10] LI X, SHANG M, QIN H W, et al. Fast accurate fish detection and recognition of underwater images with Fast R-CNN[C]//Proceedings of OCEANS 2015-MTS/IEEE Washington. Washington: IEEE, 2015: 1–5.
- [11] ZHANG Y Y, ZHOU D S, CHEN S Q, et al. Single-image crowd counting via multi-column convolutional neural network[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 589–597.
- [12] LI Y H, ZHANG X F, CHEN D M. CSRNet: dilated convolutional neural networks for understanding the highly congested scenes[C]//Proceedings of 2018 IEEE/CVF Conference on COMPUTER VISION and Pattern Recognition. Salt Lake City: IEEE, 2018: 1091–1100.
- [13] DANG T H, DANG N H, TRAN V T. Shrimp larvae detection and counting in aquaculture using multiscale feature fusion networks[J]. *Computers and Electronics in Agriculture*, 2025, 233: 109850.

- [14] LIU H C, YU Y N, WANG L, et al. Automatic fish counting in aquaculture with dense multi-scale feature aggregation network[C]//Proceedings of 2023 42nd Chinese Control Conference (CCC). Tianjin: IEEE, 2023: 8246–8251.
- [15] LI W R, ZHU Q, ZHANG H Y, et al. A lightweight network for portable fry counting devices[J]. *Applied Soft Computing*, 2023, 136: 110140.
- [16] 洪宇. 基于改进 DeepSORT 的水下鱼类计数方法研究 [D]. 上海: 上海海洋大学, 2022.
HONG Y. Research on underwater fish counting method based on improved DeepSORT[D]. Shanghai: Shanghai Ocean University, 2022.
- [17] HUANG Z M, ZHAO H X, CUI Z G, et al. Early warning system for nocardiosis in largemouth bass (*Micropterus salmoides*) based on multimodal information fusion[J]. *Computers and Electronics in Agriculture*, 2024, 226: 109393.
- [18] ZHAO H X, CUI H W, QU K M, et al. A fish appetite assessment method based on improved ByteTrack and spatiotemporal graph convolutional network[J]. *Biosystems Engineering*, 2024, 240: 46–55.
- [19] ABE K, KITANISHI R, HABE H, et al. A fish counting system with video camera for hatchery-produced juvenile fish[J]. *IEICE Transactions on Information and Systems*, 2025, E108-D(11): 1335–1347.
- [20] FRANÇA ALBUQUERQUE P L, GARCIA V, DA SILVA OLIVEIRA JUNIOR A, et al. Automatic live fingerlings counting using computer vision[J]. *Computers and Electronics in Agriculture*, 2019, 167: 105015.
- [21] 温海磊. 基于 YOLOv8 和单目深度估计的水下大口黑鲈实时检测与体长质量估计方法研究 [D]. 武汉: 华中农业大学, 2024.
WEN H L. Real-time detection and body length mass estimation method of underwater largemouth bass based on YOLOv8 and monocular depth estimation[D]. Wuhan: Huazhong Agricultural University, 2024.
- [22] HE Z Q, XU X Q, LUO J L, et al. A measurement model for aquatic animals based on instance segmentation and 3D point cloud[J]. *IEEE Access*, 2024, 12: 156208–156223.
- [23] SUO F Y, HUANG K W, LING G, et al. Fish keypoints detection for ecology monitoring based on underwater visual intelligence[C]//Proceedings of 2020 16th International Conference on Control, Automation, Robotics and Vision (ICARCV). Shenzhen: IEEE, 2020: 542–547.
- [24] YU Y Z, ZHANG H, YUAN F. Key point detection method for fish size measurement based on deep learning[J]. *IET Image Processing*, 2023, 17(14): 4142–4158.
- [25] BALABAN M O, ÜNAL ŞENGÖR G F, SORIANO M G, et al. Using image analysis to predict the weight of Alaskan salmon of different species[J]. *Journal of Food Science*, 2010, 75(3): E157–E162.
- [26] 魏明鑫. 视觉图像分析在鱼体重量测量中的应用研究 [D]. 大连: 大连理工大学, 2023.
WEI M X. Application research of visual image analysis in fish weight measurement[D]. Dalian: Dalian University of Technology, 2023.
- [27] 李振波, 钮冰珊, 彭芳, 等. 基于可见光谱的鱼苗体长估测方法研究 [J]. *光谱学与光谱分析*, 2020, 40(4): 1243–1250.
LI Z B, NIU B S, PENG F, et al. Estimation method of fry body length based on visible spectrum[J]. *Spectroscopy and Spectral Analysis*, 2020, 40(4): 1243–1250.
- [28] LEE D, KIM S, PARK M, et al. Weight estimation of the sea cucumber (*Stichopus japonicas*) using vision-based volume measurement[J]. *Journal of Electrical Engineering & Technology*, 2014, 9(6): 2154–2161.
- [29] MISIMI E, ERIKSON U, DIGRE H, et al. Computer vision - based evaluation of pre - and postrigor changes in size and shape of Atlantic cod (*Gadus morhua*) and Atlantic salmon (*Salmo salar*) fillets during rigor mortis and ice storage: effects of perimortem handling stress[J]. *Journal of Food Science*, 2008, 73(2): E57–E68.
- [30] ZHOU M G, SHEN P F, ZHU H, et al. In-water fish body-length measurement system based on stereo vision[J]. *Sensors*, 2023, 23(14): 6325.
- [31] RISHOLM P, MOHAMMED A, KIRKHUS T, et al. Automatic length estimation of free-swimming fish using an underwater 3D range-gated camera[J]. *Aquacultural Engineering*, 2022, 97: 102227.

- [32] ZHANG T Y, YANG Y Q, LIU Y Y, et al. Fully automatic system for fish biomass estimation based on deep neural network[J]. *Ecological Informatics*, 2024, 79: 102399.
- [33] SHI C, WANG Q B, HE X L, et al. An automatic method of fish length estimation using underwater stereo system based on LabVIEW[J]. *Computers and Electronics in Agriculture*, 2020, 173: 105419.
- [34] DENG Y X, TAN H Q, ZHOU D Z, et al. An automatic body length estimating method for *Micropterus salmoides* using local water surface stereo vision[J]. *Biosystems Engineering*, 2023, 235: 166–179.
- [35] AMENYOGBE E. Application of probiotics for sustainable and environment-friendly aquaculture management-a review[J]. *Cogent Food & Agriculture*, 2023, 9(1): 2226425.
- [36] 吴淑勤, 王亚军. 我国水产养殖病害控制技术现状与发展趋势 [J]. 中国水产, 2010(8): 9–10.
- [37] SIKDER J, SAREK K I, DAS U K. Fish disease detection system: a case study of freshwater fishes of Bangladesh[J]. *International Journal of Advanced Computer Science and Applications*, 2021, 12(6): 861–865.
- [38] MALIK S, KUMAR T, SAHOO A K. Image processing techniques for identification of fish disease[C]//Proceedings of 2017 IEEE 2nd International Conference on Signal and Image Processing (ICSIP). Singapore: IEEE, 2017: 55–59.
- [39] AHN J Y, LEE K A, LEE M J, et al. Surface Plasmon resonance aptamer biosensor for discriminating pathogenic bacteria *Vibrio parahaemolyticus*[J]. *Journal of Nanoscience and Nanotechnology*, 2018, 18(3): 1599–1605.
- [40] SU X D, SUTARLIE L, LOH X J. Sensors, biosensors, and analytical technologies for aquaculture water quality[J]. *Research*, 2020, 2020: 8272705.
- [41] NAYAN A A, MOZUMDER A N, SAHA J, et al. Early detection of fish diseases by analyzing water quality using machine learning algorithm[J]. *Walailak Journal of Science and Technology*, 2020, 29(5): 14346–14358.
- [42] RACHMAN F, AKBAR M N S, PUTERA E. Fish disease detection of epizootic ulcerative syndrome using deep learning image processing technique[C]//Proceedings of the 9th International Conference on Fisheries and Aquaculture. Jakarta: TIHKM Publishing, 2022: 23–34.
- [43] LI D L, LI X, WANG Q, et al. Advanced techniques for the intelligent diagnosis of fish diseases: a review[J]. *Animals*, 2022, 12(21): 2938.
- [44] REDDY M K S, SWAPNA P. Detection of fish disease using machine learning techniques[J]. *International Journal of Engineering Science and Advanced Technology*, 2021, 21(3): 7–15.
- [45] AHMED M S, AURPA T T, AZAD M A K. Fish disease detection using image based machine learning technique in aquaculture[J]. *Journal of King Saud University-Computer and Information Sciences*, 2022, 34(8): 5170–5182.
- [46] 许瑞峰, 王瑶华, 丁文勇, 等. 基于改进 YOLOv8 和多元特征的对虾发病检测方法 [J]. 智慧农业(中英文), 2024, 6(2): 62–71.
- XU R F, WANG Y H, DING W Y, et al. Shrimp diseases detection method based on improved YOLOv8 and multiple features[J]. *Smart Agriculture*, 2024, 6(2): 62–71.
- [47] RAMACHANDRAN L, MOHAN V, SENTHILKUMAR S, et al. Early detection and identification of white spot syndrome in shrimp using an improved deep convolutional neural network[J]. *Journal of Intelligent & Fuzzy Systems*, 2023, 45(4): 6429–6440.
- [48] VARMA G T, KRISHNA A S. SDNet: integrated unsupervised learning with DLCNN for shrimp disease detection and classification[C]//Proceedings of 2022 IEEE International Conference on Data Science and Information System (ICDSIS). Hassan: IEEE, 2022: 1–6.
- [49] SHANG N, ZHANG C X, ZHANG W G, et al. Assessment of fish health status for waterless transportation based on image features and deep learning models[J]. *Aquaculture*, 2025, 595: 741697.
- [50] CHAUHAN S. Deep learning for aquaculture: classifying fresh and infected fish using convolutional neural networks[C]//Proceedings of 2024 9th International Conference on Communication and Electronics Systems (ICCES). Coimbatore: IEEE, 2024: 1455–1460.

- [51] 胡静. 基于机器视觉的鲤科病鱼图像快速处理方法的研究 [D]. 长春: 吉林农业大学, 2012.
- HU J. Research on fast processing method for images of sick cyprinidae fishes based on machine vision[D]. Changchun: Jilin Agricultural University, 2012.
- [52] 林晓敏. 基于机器视觉的智能鱼群健康状态评估系统建构与研究 [J]. 产品可靠性报告, 2024(10): 85–87.
- [53] 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.
- [54] 丁国超, 孙殿棋, 徐汉林, 等. 一种基于机器视觉的鱼病识别处理装置: CN113598098A[P]. 2021–11–05.
- DING G C, SUN D Q, XU H L, et al. Fish disease recognition processing device based on machine vision: CN113598098A[P]. 2021–11–05.
- [55] LEE D J, XIONG G M, LANE R M, et al. An efficient shape analysis method for shrimp quality evaluation[C]//Proceedings of 2012 12th International Conference on Control Automation Robotics & Vision (ICARCV). Guangzhou: IEEE, 2012: 865–870.
- [56] ZHANG D, LILLYWHITE K D, LEE D J, et al. Automatic shrimp shape grading using evolution constructed features[J]. *Computers and Electronics in Agriculture*, 2014, 100: 116–122.
- [57] COSTA C, ANTONUCCI F, BOGLIONE C, et al. Automated sorting for size, sex and skeletal anomalies of cultured seabass using external shape analysis[J]. *Aquacultural Engineering*, 2013, 52: 58–64.
- [58] SWEIDAN A H, EL-BENDARY N, HEGAZY O M, et al. Water pollution detection system based on fish gills as a biomarker[J]. *Procedia Computer Science*, 2015, 65: 601–611.
- [59] STURE Ø, ØYE E R, SKAVHAUG A, et al. A 3D machine vision system for quality grading of Atlantic salmon[J]. *Computers and Electronics in Agriculture*, 2016, 123: 142–148.
- [60] BAO Y J, JI C Y, ZHANG B, et al. Representation of freshwater aquaculture fish behavior in low dissolved oxygen condition based on 3D computer vision[J]. *Modern Physics Letters B*, 2018, 32(34/35/36): 1840090.
- [61] BARTOLINI T, BUTAIL S, PORFIRI M. Temperature influences sociality and activity of freshwater fish[J]. *Environmental Biology of Fishes*, 2015, 98(3): 825–832.
- [62] LEHTONEN T K, WONG B B M, KVARNEMO C. Effects of salinity on nest-building behaviour in a marine fish[J]. *BMC Ecology*, 2016, 16(1): 7.
- [63] JIN J H, AMENYOGBE E, YANG Y, et al. Effects of ammonia nitrogen stress on the physiological, biochemical, and metabolic levels of the gill tissue of juvenile four-finger threadfin (*Eleutheronema tetradactylum*) [J]. *Aquatic Toxicology*, 2024, 274: 107049.
- [64] RAN X, LI B B, LI D L, et al. Detection of surfacing white shrimp under hypoxia based on improved lightweight YOLOv5 model[J]. *Aquaculture International*, 2023, 31(6): 3601–3618.
- [65] XU J Y, LIU Y, CUI S R, et al. Behavioral responses of tilapia (*Oreochromis niloticus*) to acute fluctuations in dissolved oxygen levels as monitored by computer vision[J]. *Aquacultural Engineering*, 2006, 35(3): 207–217.
- [66] BAO Y J, JI C Y, ZHANG B, et al. Representation of freshwater aquaculture fish behavior in low dissolved oxygen condition based on 3D computer vision[J]. *Modern Physics Letters B*, 2018, 32(34/35/36): 1840090. (查阅网上资料, 本条文献与第 60 条文献重复, 请确认)
- [67] HØGSTEDT E B. Developing a deep learning pipeline for automated salmon welfare analysis by respiration frequency[D]. Trondheim: Norges Teknisk-Naturvitenskapelige Universitet, 2023.
- [68] 贾贝贝, 邵振洲, 王瑞, 等. 基于机器视觉的鱼类行为特征提取与分析 [J]. 生态毒理学报, 2017, 12(5): 193–203.
- JIA B B, SHAO Z Z, WANG R, et al. Extraction and analysis of fish behavior based on machine vision[J]. *Asian Journal of Ecotoxicology*, 2017, 12(5): 193–203.

- [69] 徐榛,邢克智,田云臣,等. 基于机器视觉的点带石斑鱼异常行为识别方法研究[J]. 渔业现代化, 2016, 43(1): 18–23.
XU S, XING K Z, TIAN Y C, et al. Study on the identification of abnormal behavior of *Epinephelus malabaricus* based on machine vision[J]. Fishery Modernization, 2016, 43(1): 18–23.
- [70] ZHENG H Y, LIU R, ZHANG R, et al. A method for real-time measurement of respiratory rhythms in medaka (*Oryzias latipes*) using computer vision for water quality monitoring[J]. *Ecotoxicology and Environmental Safety*, 2014, 100: 76–86.
- [71] KANE A S, SALIERNO J D, GIPSON G T, et al. A video-based movement analysis system to quantify behavioral stress responses of fish[J]. *Water Research*, 2004, 38(18): 3993–4001.
- [72] LIAO Y, XU J Y, WANG W J. A method of water quality assessment based on biomonitoring and multiclass support vector machine[J]. *Procedia Environmental Sciences*, 2011, 10: 451–457.
- [73] XIAO G, FAN W K, MAO J F, et al. Semantic description of fish abnormal behavior based on the computer vision[C]//Proceedings of the 10th Chinese Conference on Image and Graphics Technologies. Beijing: Springer, 2015: 18–27.
- [74] RAN X, LI B B, ZHANG Y H, et al. Anomalous white shrimp detection in intensive farming based on improved YOLOv8[J]. *Aquacultural Engineering*, 2024, 107: 102473.
- [75] MORIMOTO T, ZIN T T, ITAMI T. A study on abnormal behavior detection of infected shrimp[C]//Proceedings of 2018 IEEE 7th Global Conference on Consumer Electronics (GCCE). Nara: IEEE, 2018: 291–292.
- [76] 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.
- [77] WANG H, ZHANG S, ZHAO S L, et al. Fast detection of cannibalism behavior of juvenile fish based on deep learning[J]. *Computers and Electronics in Agriculture*, 2022, 198: 107033.
- [78] ARVIND C S, PRAJWAL R, BHAT P N, et al. Fish detection and tracking in pisciculture environment using deep instance segmentation[C]//Proceedings of TENCON 2019–2019 IEEE Region 10 Conference (TENCON). Kochi: IEEE, 2019: 778–783.
- [79] LONG W, WANG Y W, HU L X, et al. Triple Attention Mechanism with YOLOv5s for Fish Detection[J]. *Fishes*, 2024, 9(5): 151.
- [80] KATO S, TAMADA K, SHIMADA Y, et al. A quantification of goldfish behavior by an image processing system[J]. *Behavioural Brain Research*, 1996, 80(1/2): 51–55.
- [81] ABE K, TANAKA M, HABE H, et al. Video scene detection of burst swimming by fry of farmed-raised bluefin tuna[C]//Proceedings of 2018 4th International Conference on Frontiers of Signal Processing (ICFSP). Poitiers: IEEE, 2018: 105–109.
- [82] SUN L Q, LUO B, LIU T, et al. Algorithm of adaptive fast clustering for fish swarm color image segmentation[J]. *IEEE Access*, 2019, 7: 178753–178762.
- [83] 徐建瑜,刘鹰. 基于计算机视觉的罗非鱼适应环境的体色变化研究[J]. 水生生物学报, 2009, 33(2): 164–169.
XU J Y, LIU Y. Study on colormodification of tilapia *Oreochromis niloticus* under environmental background and stress by computer vision[J]. *Acta Hydrobiologica Sinica*, 2009, 33(2): 164–169.
- [84] PAPADAKIS V M, GLAROPOULOS A, KENTOURI M. Sub-second analysis of fish behavior using a novel computer-vision system[J]. *Aquacultural Engineering*, 2014, 62: 36–41.
- [85] XIA C L, FU L W, LIU Z Y, et al. Aquatic toxic analysis by monitoring fish behavior using computer vision: a recent progress[J]. *Journal of Toxicology*, 2018, 2018(1): 2591924.
- [86] LIU Y R, LI B B, SI L G, et al. Group activity amount estimation for fish using multi-object tracking[J]. *Aquacultural Engineering*, 2025, 110: 102534.
- [87] ISRAELI D, KIMMEL E. Monitoring the behavior of hypoxia-stressed *Carassius auratus* using computer vision[J]. *Aquacultural Engineering*, 1996, 15(6): 423–440.
- [88] 冯国富,汪峰,陈明. 基于计算机视觉和 XGBoost 的虾体活力检测[J]. 湖南农业大学学报(自然科学版), 2023, 49(2):

218–222.

FENG G F, WANG F, CHEN M. Shrimp vitality detection based on computer vision and XGBoost[J]. *Journal of Hunan Agricultural University (Natural Sciences)*, 2023, 49(2): 218–222.

[89] 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.

[90] YU X N, WANG Y Q, AN D, et al. Identification methodology of special behaviors for fish school based on spatial behavior characteristics[J]. *Computers and Electronics in Agriculture*, 2021, 185: 106169.

[91] 范伟康. 基于鱼群行为分析的水质监测系统研究 [D]. 杭州: 浙江工业大学, 2015.

FAN W K. Research on water quality monitoring system based on the behavior of fish school[D]. Hangzhou: Zhejiang University of Technology, 2015.

[92] LIU Y R, LI B B, ZHOU X H, et al. FishTrack: multi-object tracking method for fish using spatiotemporal information fusion[J]. *Expert Systems with Applications*, 2024, 238: 122194.

[93] TERAYAMA K, HIOKI H, SAKAGAMI M A. A measurement method for speed distribution of collective motion with optical flow and its applications to school of fish[J]. *International Journal of Semantic Computing*, 2015, 9(2): 143–168.

作者简介

卢国兴(1989—), 男, 福建人, 浙江大学农业生物环境与能源工程 2023 级博士研究生, 研究方向: 设施水产养殖工程与智能装备。E-mail: lgx1517@163.com

朋泽群(1989—), 男, 安徽人, 工程师, 研究方向: 智能化养殖技术与装备研究。E-mail: pzqal1989@126.com

(责任编辑: 王玖琪)



This is an open access article under the terms of the Creative Commons Attribution 4.0 International License (CC BY 4.0, <https://creativecommons.org/licenses/by/4.0/>).

© The Author(s) 2025. Published by Editorial Department of Journal of Hainan University.