

基于关键点检测的南美白对虾体尺估测方法

伍学惠¹ 丁琪¹ 游冠祺¹ 徐焕良¹ 余洪锋² 翟肇裕¹

(1. 南京农业大学智慧农业学院(人工智能学院), 南京 211800; 2. 南京农业大学工学院, 南京 211800)

摘要: 南美白对虾体尺的准确测量在工厂化养殖中具有重要意义,然而在实际养殖环境中,观测台上常存在残余饲料干扰、虾只密集聚集、相互遮挡与粘连等问题,导致现有计算机视觉算法面临关键点定位不准、饲料误识别、重复检测以及遮挡下虾只无法完整识别等挑战。为解决上述问题,提出了一种对虾关键点检测模型 YOLO 11 - Shrimp。首先采用 Diverse branch block (DBB) 模块优化主干网络中的 Conv 模块,以显著增强特征表达能力;其次,融入坐标注意力机制,进一步提升关键点定位精度;最后,在检测头部分引入 C3k2_OREPA 模块,实现高效特征融合与表达。实验结果表明,与基准模型 YOLO 11 - Pose 相比,YOLO 11 - Shrimp 在 $PCK_{0.1}$ 指标上提升了 10.35 个百分点,在 $PCK_{0.2}$ 指标上提升了 7.82 个百分点;同时,饲料误检现象显著减少,密集分布场景下的重复检测问题得到有效缓解,虾体关键点偏移幅度明显降低,边界框置信度得分更加可靠。此外,设计了一种对虾体尺自动化估测系统。在虾只因遮挡无法完整检测时,能够自动根据可见的局部部位估测体尺。研究结果可为南美白对虾智能化养殖提供方法依据和参考。

关键词: 南美白对虾; 体尺测量; YOLO 11 - Pose; 关键点检测; 特征增强

中图分类号: TP391

文献标识码: A

文章编号: 1000-1298(2026)15-0157-11

OSID:



Whiteleg Shrimp Body Length Estimation Approach Based on Keypoint Detection

Wu Xuehui¹ Ding Qi¹ You Guanqi¹ Xu Huanliang¹ Yu Hongfeng² Zhai Zhaoyu¹

(1. College of Smart Agriculture (College of Artificial Intelligence), Nanjing Agricultural University, Nanjing 211800, China

2. College of Engineering, Nanjing Agricultural University, Nanjing 211800, China)

Abstract: Precise measurement of body length and morphological dimensions in whiteleg shrimp is critical for intelligent industrial aquaculture. However, practical farming environments present significant challenges, including interference from residual feed pellets, high stocking densities, mutual occlusion, and individual adhesion. These factors often lead to inaccurate keypoint localization, false positives from feed pellets, duplicate detection, and incomplete recognition of occluded individuals. To overcome these limitations, YOLO 11 - Shrimp, an enhanced model for shrimp keypoint detection was proposed. Specifically, YOLO 11 - Shrimp incorporated three key architectural enhancements. Firstly, standard convolutional modules within the backbone were replaced by diverse branch block (DBB) modules to enhance multi-scale feature representation. Secondly, the coordinate attention (CA) mechanism was integrated to capture long-range spatial dependencies, thereby refining keypoint localization precision. Finally, the C3k2_OREPA module was introduced into the detection head to substitute the original C3k2 structure, facilitating more robust feature fusion and representational efficiency. Experimental results demonstrated that, compared with the baseline YOLO 11 - Pose model, YOLO 11 - Shrimp improved $PCK_{0.1}$ by 10.35 percentage points and $PCK_{0.2}$ by 7.82 percentage points. Meanwhile, false detection caused by residual feed pellets were significantly reduced, and duplicate detection under dense scenes were suppressed. Also, the shrimp keypoint shift was markedly decreased, and bounding box confidence scores became more reliable. Furthermore, an automated shrimp body length estimation system was designed. When a shrimp cannot be fully detected due to occlusion, the system can automatically estimate the body length based on visible parts. The research results can provide a methodological

收稿日期: 2026-03-17 修回日期: 2026-04-01

基金项目: 中央高校基本科研业务费专项资金项目(106-YDZX2025022)

作者简介: 伍学惠(1989—),女,讲师,博士,主要从事计算机视觉与智慧水产养殖研究,E-mail: xhwu@njau.edu.cn

通信作者: 翟肇裕(1992—),男,副教授,博士,主要从事智慧农业、复杂场景感知与理解研究,E-mail: zhaoyu.zhai@njau.edu.cn

framework for precision monitoring in smart aquaculture for whiteleg shrimp.

Key words: whiteleg shrimp; body length estimation; YOLO 11 – Pose; keypoint detection; feature enhancement

0 引言

南美白对虾是全球最具经济价值的水产虾种之一,我国是养殖南美白对虾的主要国家^[1],产量占全国虾类养殖总量的 80% 以上^[2]。体尺作为对虾的关键生长指标,准确监测是优化投喂、调控密度及实施病害预警的重要依据^[3]。传统体尺测量依赖人工、效率低,且抓捕接触易导致对虾应激与损伤,影响养殖效益^[4]。因此,研发非接触的体尺估测方法已成为产业升级的关键需求。

现有研究多基于实例分割与目标检测等计算机视觉方法实现对虾体尺估测,虽在标准场景下取得一定效果,但在虾体半透明、姿态多变及高密度遮挡等复杂养殖环境中,仍存在边界难以精确提取与估测误差较大的问题^[5-11]。

关键点检测技术旨在定位图像中物体的语义关键点,广泛应用于人体姿态估计等任务。现有经典模型如 YOLO – Pose、HRNet 等近年来在农业中的应用研究日益广泛与深入,已成为一个重要研究方向^[12-20]。尽管关键点检测技术已在农业领域取得一定成果,但在南美白对虾体尺估测场景中,受饲料残渣干扰、个体密集及遮挡粘连等因素影响,关键点易出现定位不准或缺失问题,因此,提升检测精度并缓解遮挡与粘连带来的影响成为亟需解决的关键问题。

为应对上述挑战,本文提出改进的 YOLO 11 – Shrimp 模型。通过引入 Diverse branch block 模块、坐标注意力机制(Coordinate attention,CA)与 C3k2_OREPA 模块,实现从特征提取到特征融合的多层次优化,以提升关键点检测精度。在此基础上,构建对虾体尺自动化估测系统,并集成线性回归模型以应对遮挡导致的关键点缺失问题,实现全自动、非接触式精准测量。

1 材料与方法

1.1 南美白对虾图像数据采集

本研究以南美白对虾为研究对象,实验数据于 2024 年 11 月 20—21 日在实验室环境中采集,首先将对虾置于养殖池中暂养,并在养殖池旁部署自动化观察平台。采用俯拍视角,将高清摄像头固定于观察平台正上方中心位置,确保能够完整、清晰地捕获对虾的形态特征。数据集中包含了对虾养殖中常

见的复杂场景,例如饲料残留造成干扰、虾体间的粘连与重叠造成的遮挡,以及高密度下的虾群密集状态,如图 1 所示。




图 1 图像数据集样本

Fig. 1 Image samples in dataset

1.2 数据标注

采用 Labelme 标注工具对数据集进行标注:对于采集的每一幅图像,首先使用矩形框工具标注出包含整只虾体的外接矩形区域,随后利用点标注工具(point)精确定位每只虾的关键部位,包括头部(head)、头胸甲(carapace)、躯干(body)、尾节(telson)和尾部(tail)5 个特征点,并为每只虾分配唯一的身份 ID(Group ID),确保同一虾体对应的矩形框与关键点具有相同的编号,如图 2 所示。




图 2 数据标注示例

Fig. 2 Data annotation examples

数据集总共包含 964 幅图像,按照 7:2:1 的比例划分为训练集、验证集和测试集。训练集包含 674 幅图像,共计 5 881 只对虾、27 905 个关键点;验证集包含 192 幅图像,1 650 只对虾、8 250 个关键点;测试集包含 98 幅图像,822 只对虾、4 110 个关键点。训练集用于模型的训练,验证集用于在训练过程中评估模型性能,最终在从未见过的测试集图像上对模型检测效果进行评估。

2 模型构建与体尺拟合

2.1 YOLO 11 – Shrimp 网络结构

YOLO 11 – Pose 是在 YOLO 11 框架基础上提出的单阶段目标检测与姿态估计联合模型,由

Backbone、Neck 和解耦式检测头组成,可实现目标定位与关键点预测的端到端学习。其 Backbone 以 C3k2 模块为核心,并结合 SPPF 后引入 C2PSA 模块,在降低计算复杂度的同时增强多尺度特征表达与关键区域建模能力;Neck 采用 PAN-FPN 结构进行多尺度特征融合;Head 则通过解耦设计分别完成目标检测与关键点回归,从而提升复杂场景下的姿态估计精度。

在对虾养殖环境中,受个体粘连、密集堆叠、相互遮挡及饲料残渣干扰等因素影响,图像特征复杂,限制关键点识别精度。为此,提出改进模型 YOLO 11-Shrimp,通过结构优化与特征增强提升复杂场景下的检测与关键点定位性能。

以 YOLO 11-Pose 模型为基础框架,针对对虾检测任务中存在的复杂场景适应性与计算效率等问题,进行了结构改进,以增强模型的特征提取能力、注意力机制与运行效能。首先,将 Backbone 中第 1、3、5 层的标准卷积模块替换为 Diverse branch block (DBB) 模块。该模块通过引入多分支结构,融合不同尺度和结构的特征表示,增强了特征提取的多样性与鲁棒性,从而提升模型在复杂养殖环境中的场景适应能力。其次,在第 6 层与第 7 层之间嵌入坐标注意力机制 (CoordAtt)。该机制能够沿空间坐标方向建模通道间关系,显式捕捉位置敏感的特征信息,加强对虾目标的空间定位能力,提高检测精度与模型泛化性能。此外,在 Head 部分将第 14、17、20、23 层的 C3k2 模块替换为 C3k2_OREPA 模块。该模块采用在线重参数化技术,在训练阶段通过结构化的多分支设计优化参数分布,在推理阶段则合并为单一分支,从而在保持模型表达能力的同时,显著降低计算开销,提升整体运行效率。YOLO 11-Shrimp 网络结构如图 3 所示。

2.1.1 DBB 模块

为增强模型的特征表达能力并进一步提升检测精度,引入了多样化分支卷积结构 Diverse branch block (DBB) [21]。DBB 由 4 条并行特征提取路径构成,不同路径分别提取不同尺度特征,然后通过逐元素求和完成融合。其中, 1×1 卷积用于执行特征映射与降低维度;由 1×1 卷积与 3×3 卷积串联形成的结构,可模拟降维后再卷积的高效计算过程,强化模型的语义建模能力;由 1×1 卷积与平均池化组成的路径,用于融合局部纹理与全局统计信息;此外还包含独立的 3×3 卷积路径,提供基础且稳定的空间结构提取能力。

多路径信息的最终汇聚使模型能够同时捕获跨尺度纹理特征、空间结构特征以及全局分布趋势,形




图 3 YOLO 11-Shrimp 模型网络结构图

Fig. 3 YOLO 11-Shrimp network structure diagram

成更加充分且鲁棒的特征表达。在训练过程中,各分支路径均引入批归一化操作,以减小内部协变量偏移、稳定梯度分布,并产生类似模型集成与随机抑制的隐式正则化效果,从而提高训练稳定性并降低过拟合风险。

在虾体关键点检测中,目标细长且姿态变化大、尺度差异显著,单一卷积路径难以兼顾姿态变化与细节特征。DBB 通过多分支建模不同感受野与特征层级,增强对局部关节、整体结构及全局形态的综合感知,从而提升复杂场景下的适应性与鲁棒性。

DBB 模块的计算流程为

$$B_1 = \text{BN}_1(I F_{1 \times 1}^{(1)}) \quad (1)$$

$$B_2 = \text{BN}_{2b}(\text{BN}_{2a}(I F_{1 \times 1}^{(2)}) F_{3 \times 3}^{(2)}) \quad (2)$$

$$B_3 = \text{BN}_{3b}(\text{AVG}(\text{BN}_{3a}(I F_{1 \times 1}^{(3)}))) \quad (3)$$

$$B_4 = \text{BN}_4(I F_{1 \times 1}^{(4)}) \quad (4)$$

$$O_{\text{DBB}} = B_1 + B_2 + B_3 + B_4 \quad (5)$$

式中 I ——DBB 的输入特征图

B_i ——第 i ($i = 1, 2, 3, 4$) 个分支的输出特征图

图

BN_i ——第 i ($i = 1, 2, 3, 4$) 个分支对应的批量归一化运算符

AVG ——平均池化运算符

$F_{1 \times 1}^{(i)}$ ——第 i 个分支中 1×1 卷积运算符

$F_{3 \times 3}^{(i)}$ ——第 i 个分支中 3×3 卷积运算符

O_{DBB} ——DBB 模块的输出特征图

a 表示第 1 次 BN 操作, b 表示第 2 次 BN 操作。

2.1.2 CoordAtt 模块

通道注意力机制 (Coordinate attention, CA) [22]

通过引入位置信息对通道特征进行重标定。不同于传统全局池化方法会丢失空间信息,CA 沿水平与垂直方向进行编码,在建模全局依赖的同时保留位置信息,并生成两个方向的注意力权重对特征进行自适应加权,从而提升特征表达能力。

在南美白对虾关键点检测任务中,目标关键点通常沿虾体纵轴呈线性或准线性分布,并与头胸甲、腹部节段及尾节等解剖结构高度相关。CA 能够在保持轻量化设计的同时显式建模虾体在水平与垂直方向上的结构分布特征,更符合虾体形态特征与关键点分布规律。将 CA 模块引入 YOLO 11-Shrimp,能够更加精准地关注具有生物学结构意义的区域,在面对姿态弯曲、局部遮挡、旋转变换等捕捞场景时,仍能保持较强的方向感知能力与关键点定位稳定性。相关计算公式为

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i \leq W} x_c(h,i) \tag{6}$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j \leq H} x_c(j,w) \tag{7}$$

$$y_c(i,j) = x_c(i,j) g_c^h(i) g_c^w(j) \tag{8}$$

式中 W ——特征图宽度

H ——特征图高度

$z_c^h(h)$ ——第 c 个通道、第 h 行对应的水平池化输出结果

$z_c^w(w)$ ——第 c 个通道、第 w 列对应的垂直池化输出结果

$x_c(h,i)$ ——水平池化输入特征图中第 c 个通道、第 h 行、第 i 列的像素值

$x_c(j,w)$ ——垂直池化输入特征图中第 c 个通道、第 j 行、第 w 列的像素值

$y_c(i,j)$ ——输出特征图中第 c 个通道、第 i 行、第 j 列的像素值

$x_c(i,j)$ ——加权的输入特征图中第 c 个通道、第 i 行、第 j 列的像素值

$g_c^h(i)$ ——水平注意力中第 c 个通道、第 i 行对应的注意力权重

$g_c^w(j)$ ——垂直注意力中第 c 个通道、第 j 列对应的注意力权重

依靠这一方向感知的权重分配方式,CA 能够在保持较低计算量的同时,提高网络对细粒度局部与结构化目标信息的敏感性,从而有效增强特征表达能力并提升检测或识别性能。

2.1.3 C3k2_OREPA 模块

为进一步增强模型的特征提取能力,引入基于重参数化思想的 OREPA^[23] 模块来增强 YOLO 11-Shrimp 特征提取能力。OREPA 在训练阶段采用多

分支结构,其中包括标准卷积、深度可分离卷积、平均池化映射和频域先验等不同类型的结构,各并行分支共同参与特征表达,使网络在训练过程中能够同时学习局部纹理特征、通道语义关联与频率结构信息,形成类似模型集成的效果,并显著增强特征表示。

OREPA 通过多路径监督缓解梯度消失与信息退化问题,在不显著增加网络深度的情况下提升特征建模能力,适用于关键点检测中的细粒度特征学习。其训练阶段融合标准卷积、深度可分离卷积、池化及频域先验等多分支特征,实现空间、通道与频率信息的联合建模;推理阶段通过重参数化将多分支等效为单一卷积,在保证表达能力的同时兼顾计算效率。

基于上述特性,将 OREPA 结构引入 YOLO 11-Shrimp 的检测头中,通过替换原始 C3k2 模块内部的卷积算子构建改进的 C3k2_OREPA 结构。在保持原有局部残差连接形式不变的前提下,OREPA 通过训练阶段的多路径卷积表达与推理阶段的等效简化,使网络对局部区域形态变化及几何结构特征具备更强的建模能力,从而有效提升虾体关键点检测的整体性能。相关计算流程为

$$B_i(X) = \gamma_i \text{Conv}_i(X) \tag{9}$$

$$Y = \text{BN} \left(\sum_{i=1}^N B_i(X) \right) \tag{10}$$

式中 B_i ——第 i 个分支的输出结果

γ_i ——第 i 个分支的通道级线性缩放因子

X ——输入特征图

Y ——输出特征图

2.2 对虾体尺拟合

2.2.1 关键点的体尺长度计算

通过对虾体尺分段计算来应对其常见弯曲形态:将体尺划分为头部-背甲、背甲-躯干-尾节及尾节-尾部 3 部分,求和后作为体尺总长。头部-背甲段与尾节-尾部段分别对应不易变形的头胸甲和尾节,直接采用关键点间的欧氏距离计算。

背甲-躯干-尾节涵盖腹部 6 个体节,其弯曲程度影响实际长度。为准确反映形态,采用过三关键点的圆弧长度进行估算。首先基于三点坐标,通过最小二乘法拟合最优圆,获取圆心位置并计算平均半径 R 。随后,以头胸甲端与尾节端为圆弧起止点,根据两点相对于圆心的向量计算夹角弧度,最终通过公式求得该段弧长。针对特殊情况如三点共线或腹部平直,系统自动切换为欧氏距离计算,确保在不同姿态下均能可靠估计对虾的真实体尺。测量方法如图 4 所示。




图 4 体尺测量方法示意图

Fig. 4 Diagram of length estimation approach

在获取对虾真实体尺的过程中,准确测定每幅图像中观测台的直径像素长度是关键步骤。由于图像常受光照、饲料等环境因素干扰,且观测台的圆形边缘往往因遮挡或拍摄角度而呈现不连续或不完整的状态,直接进行边缘检测效果不佳。为此,采用一套结合颜色筛选、形态学修复与统计验证的检测流程。

首先将图像转换至 HSV 色彩空间进行阈值分割,提取墨绿色观测台区域并生成二值掩模,通过形态学操作净化区域并利用 Canny 边缘^[24]检测获取轮廓。针对轮廓断裂问题,采用形态学闭合连接边缘,进而提取轮廓并利用 PCA 主成分分析^[25]确定各段主方向,按角度分组筛选平行轮廓组。通过对平行轮廓采样点计算距离得到候选直径,再使用 KDE 核密度估计^[26]分析其分布,选取主峰值区间内的中位数作为直径像素长度。结合观测台实际直径(60 cm),计算像素与实际长度比例系数,从而将对虾像素体尺转换为真实物理长度。

2.2.2 对虾体尺估测

虾体因遮挡或其他原因导致局部长度信息缺失时,无法直接通过累加各关键点间距离获得总体尺。考虑到对虾各分段长度与总体尺之间存在显著的比例关系,将虾体划分为头部-背甲、背甲-躯干-尾节、尾节-尾部 3 个部分,对应图 4 中的①、②、③段,并以这 3 部分的长度作为自变量,分别为 X_1 、 X_2 、 X_3 ,总体尺作为因变量 Y ,建立线性回归方程。在虾体检测不完整的情况下,可通过该拟合方程估算其体尺。建立的预测模型为

$$Y = b_0 + b_1X_1 + b_2X_2 + b_3X_3 + \varepsilon \quad (11)$$

式中 b_0 ——截距项

b_1 、 b_2 、 b_3 ——偏回归系数

ε ——误差项

模型训练采用最小二乘法,通过最小化预测值与真实值之间的残差平方和来确定最优参数组合公式为

$$\hat{\beta} = \arg \min_{\beta} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

其中

$$\beta = (b_0, b_1, b_2, b_3)^T$$

式中 y_i ——第 i 个样本的真实体尺

$\hat{y}_i$ ——模型预测的第 i 个样本的体尺

该方法在几何上表示为寻找一个超平面,使所有样本点到该平面的垂直距离之和最小,从而在欧氏空间中实现最佳线性拟合。

为保证回归模型的可靠性,首先从数据集中筛选出身体结构完整、关键点清晰的对虾个体,用于后续的建模分析。通过对这些完整样本进行测量与统计分析,发现虾体 3 个区段的长度与全长之间存在明确的比例关系:头部-背甲段平均约占全长的 33%,背甲-躯干-尾节段约占 49.5%,尾节-尾部段约占 17.5%。这些比例在不同个体间呈现相对稳定的分布规律,波动范围较小。

上述结果说明,对虾体尺在形态学上具有较高的结构稳定性,各组成部分的长度占比呈现固有规律。这一特性为建立线性回归模型提供了重要的生物学基础,也满足了回归分析中对自变量相对稳定、相互间具有明确协变关系的基本假设,有助于提升模型拟合的可靠性与预测的准确性。

为系统比较不同自变量组合对虾体全长估测的效果,分别构建了单变量与双变量线性回归模型。当系统检测到虾体存在残缺或关键点不全时,会基于完整性判断自动选择适用的预测模型进行体尺估计。

为探究虾体各局部长度的关联强度,分别以头部-背甲长度、背甲-躯干-尾节长度、尾节-尾部长度作为单一自变量,构建了 3 个独立的单变量线性回归方程,分别为

$$Y = 100.57 + 2.62X_1 \quad (13)$$

$$Y = 22.07 + 2.02X_2 \quad (14)$$

$$Y = 152.59 + 4.50X_3 \quad (15)$$

这 3 个方程符合线性回归在虾体长范围有限下的统计规律。小占比体节的自变量 X 值较小且远离原点,为了使回归线能较好拟合较高的总长 Y 值,模型倾向于降低斜率并抬高截距。相反,占比最大的中间段 X 值较大,最接近主导变量,其回归线更接近通过原点,截距最小。当检测到虾体不完整且仅能识别出 3 段中的某一段时,根据所识别段落类别自动匹配并调用相应的分段线性回归模型,以完成该虾体的体尺估计。

同时构建双变量回归方程,将虾体 3 个区段长度进行两两组合,分别建立以不同区段组合为自变量的回归方程。具体模型如下:

以头部-背甲长度 X_1 与背甲-躯干-尾节长度 X_2 作为自变量,得到回归方程

$$Y = 6.77 + 1.22X_1 + 1.21X_2 \quad (16)$$

以头部-背甲长度 X_1 与尾节-尾部长度 X_3 作为自变量,得到回归方程

$$Y = 58.19 + 1.76X_1 + 1.85X_3 \quad (17)$$

以背甲-躯干-尾节长度 X_2 与尾节-尾部长度 X_3 作为自变量,得到回归方程

$$Y = 7.14 + 1.47X_2 + 1.56X_3 \quad (18)$$

当缺少了占比最大的中间段时,剩余的两段会通过更大的截距来匹配实际总长。当检测到虾体不完整且仅能识别出 3 个形态学段落中的某两段时,将根据已识别段落的具体类别,自动匹配并调用相应的分段线性回归模型,完成该虾体的体尺估计。该流程与单变量检测场景下的处理逻辑一致,均通过局部特征推断整体尺寸。

2.3 实验平台与参数设置

实验在 Linux 操作系统下完成,CPU 型号为 AMD EPYC 9754 128-Core Processor,GPU 型号为 NVIDIA RTX 4090D。编程语言为 Python 3.8.10,深度学习框架为 Pytorch 2.0.0,CUDA 版本为 11.8。优化器为 AdamW,训练迭代轮数为 80,初始学习率为 0.002,批量大小为 8。

2.4 评价指标

2.4.1 模型评价指标

采用精确率、召回率、平均精度均值(mAP)、正确关键点百分比(PCK)对关键点检测性能进行评估。PCK 相关公式为

$$PCK_{\alpha} = \frac{1}{N} \sum_{k=1}^N I\left(\frac{\|P_k^{pred} - P_k^{gt}\|_2}{s} \leq \alpha\right) \times 100\% \quad (19)$$

其中 $s = \sqrt{w^2 + h^2}$
式中 P_k^{pred} ——第 k 个关键点的预测坐标
 P_k^{gt} ——第 k 个关键点的真实坐标
 N ——所有有效关键点对的总数
 s ——归一化因子
 w ——每只虾真实关键点外接矩形宽度
 h ——每只虾真实关键点外接矩形高度
 α ——归一化误差阈值,分别设置为 0.1 和 0.2,分别表示误差不超过 10% ($PCK_{0.1}$) 和误差不超过 20% ($PCK_{0.2}$) 的关键点比例

2.4.2 体尺拟合评价指标

为客观评估各回归方程的拟合优度与预测准确性,采用决定系数 R^2 、均方根误差(RMSE)、平均绝对百分比误差(MAPE)作为评价指标。

3 结果与分析

3.1 基线模型对比

选取 YOLO v8-Pose、YOLO 11-Pose、YOLO 12-Pose 以及 HRNet-w32 这 4 种代表性关键点检测模型进行对比实验。其中,YOLO v8-Pose、YOLO 11-Pose、YOLO 12-Pose 属于 YOLO 系列的单阶段姿态估计模型,以其实时性强、推理速度快著称,近年来在工业级部署场景中表现出色;HRNet-w32 则代表了经典的双阶段高分辨率网络,通过多尺度并行分支结构维持高分辨率特征表示,在关键点检测的精度上长期处于领先地位。在模型规模选择方面,本文采用的 YOLO 模型均为 n 规模,其主要原因在于:首先,研究任务聚焦于养殖场景下的虾体关键点检测,该类目标通常具有尺度较小、结构相对稳定、背景变化有限等特点,对超大规模模型的特征表征能力依赖程度较低;其次,在数据规模相对有限的情况下,进一步增大模型深度与宽度虽可提升网络容量,但往往伴随着参数冗余与过拟合风险的增加,对关键点定位精度的提升并不显著。从计算开销来看,n 规模的模型参数量更小,计算复杂度更低,在保证多尺度特征融合与关键点回归能力的同时,更有利于在资源受限的实际养殖环境中实现高效、稳定的推理与部署。综上,选择 YOLO 11n-Pose 作为基础模型不仅在精度与效率之间取得了良好平衡,也更能客观体现本文方法的性能优势,具有更高的工程实用价值和推广意义。在本研究中,各个模型的训练迭代轮数均为 80 轮,初始学习率均为 0.002,优化器为 AdamW。采用相同的数据增强策略,经过在同一数据集上的训练与评估,从检测精度、PCK、参数量等多个维度进行了综合分析。实验结果如表 1 所示。表中 mAP50 表示关键点相似度阈值(OKS)大于 0.5 时所有虾体关键点类别平均精度均值,mAP50-95 表示在关键点相似度阈值从 0.5 到 0.95 以 0.05 为步长变化时,对各阈值下的 mAP 取平均值。

表 1 基线模型对比

Tab.1 Baseline model comparison

模型	精确率/%	召回率/%	mAP50/%	mAP50-95/%	PCK/%	参数量
YOLO v8-Pose	99.2	98.7	99.5	98.3	$PCK_{0.1}$:83.24/ $PCK_{0.2}$:86.26	3.08×10^6
YOLO 11-Pose	99.5	98.8	99.5	98.1	$PCK_{0.1}$:82.95/ $PCK_{0.2}$:87.04	2.66×10^6
YOLO 12-Pose	99.0	98.7	99.4	96.6	$PCK_{0.1}$:80.66/ $PCK_{0.2}$:87.35	2.64×10^6
HRNet-w32	99.0	99.3	99.0	93.5		2.85×10^7

实验结果表明, YOLO v8 - Pose 仅在 $PCK_{0.1}$ 指标上略高于 YOLO 11 - Pose, 在 mAP50 - 95 指标上也仅领先 0.2 个百分点。然而, YOLO 11 - Pose 在其它各项指标上均表现更优, 关键点检测精确率较 YOLO v8 - Pose 高出 0.3 个百分点, 召回率高出 0.1 个百分点, $PCK_{0.2}$ 提升 0.78 个百分点, 同时具有更少的参数量。此外, YOLO 12 - Pose 仅在 $PCK_{0.2}$ 指标上比 YOLO 11 - Pose 高出 0.31 个百分点, 其余指标均不及后者。而 HRNet - w32 在所有对比指标中均落后于 YOLO 11 - Pose。由此可知, YOLO 11 - Pose 在整体性能上表现最为均衡, 在保持较高关键点定位精度的同时, 参数量较少, 综合评估效果优于其他对比模型。因此, 最终选定 YOLO 11 - Pose 作为后续关键点检测任务的基础模型。

3.2 不同实验方案对比

为了提升 YOLO 11 - Pose 模型在对虾关键点检测任务中的性能, 引入了卷积模块优化与注意力机制嵌入进行模型增强。对比分析不同模块组合在检测精度、PCK 值等方面的表现, 结果如表 2、3 所示。

表 2 不同卷积模块优化对比

Tab.2 Comparison of different convolutional modules					%
模块	精确度	召回率	mAP50	mAP50 - 95	PCK
standard	99.5	98.8	99.5	97.8	82.95 ($PCK_{0.1}$) 87.04 ($PCK_{0.2}$)
LDconv ^[27]	99.3	98.4	99.5	98.1	82.44 ($PCK_{0.1}$) 86.33 ($PCK_{0.2}$)
DCnv ^[28]	99.2	99.0	99.5	98.0	80.90 ($PCK_{0.1}$) 85.20 ($PCK_{0.2}$)
ODConv ^[29]	98.0	96.8	99.2	94.8	67.01 ($PCK_{0.1}$) 74.45 ($PCK_{0.2}$)
DBB	99.8	98.9	99.5	98.1	88.16 ($PCK_{0.1}$) 91.55 ($PCK_{0.2}$)

表 3 注意力机制嵌入对比

Tab.3 Comparison of different attention mechanisms					%
模块	精确率	召回率	mAP50	mAP50 - 95	PCK
standard	99.5	98.8	99.5	97.8	82.95 ($PCK_{0.1}$) 87.04 ($PCK_{0.2}$)
+ EMA ^[30]	99.2	98.7	99.5	98.4	85.09 ($PCK_{0.1}$) 89.00 ($PCK_{0.2}$)
+ CA	99.8	99.5	99.5	99.0	90.48 ($PCK_{0.1}$) 92.28 ($PCK_{0.2}$)

3.3 消融实验

为评估不同改进方案对模型性能的影响, 设计了 8 种模型配置进行对比训练与验证, 包括: 原始

YOLO 11 - Pose 模型, 分别单独嵌入模块 DBB、模块 CA 和 C3k2_OREPA 的模型, 两两组合嵌入的 3 种配置 DBB + CA、DBB + C3k2_OREPA、C3k2_OREPA + CA, 以及同时集成模块这 3 个模块的完整改进模型。PCK 指标的变化趋势相较于其他指标更为显著, 因此消融实验选取其作为评价指标进行对比分析。相关实验结果见表 4。

表 4 消融实验
Tab.4 Ablation experiment

C3k2_OREPA	DBB	CA	PCK/%
√	√	√	82.95 ($PCK_{0.1}$)/87.04 ($PCK_{0.2}$)
			88.29 ($PCK_{0.1}$)/91.46 ($PCK_{0.2}$)
			88.16 ($PCK_{0.1}$)/91.55 ($PCK_{0.2}$)
√	√	√	90.48 ($PCK_{0.1}$)/92.28 ($PCK_{0.2}$)
			91.56 ($PCK_{0.1}$)/93.29 ($PCK_{0.2}$)
√	√		91.64 ($PCK_{0.1}$)/93.67 ($PCK_{0.2}$)
√		√	92.40 ($PCK_{0.1}$)/93.89 ($PCK_{0.2}$)
√	√	√	93.30 ($PCK_{0.1}$)/94.86 ($PCK_{0.2}$)

注: √表示采用此模块。

结果表明, 集成全部 3 个改进模块的 YOLO 11 - Shrimp 模型在关键点定位精度上提升最为显著, 其 $PCK_{0.1}$ 指标较基线模型提高了 10.35 个百分点, $PCK_{0.2}$ 指标也提升了 7.82 个百分点, 表明所采用的模块在关键点检测任务中具有良好的协同增强作用。

3.4 检测结果对比

相较于 YOLO 11 - Pose 基线模型, 优化后的 YOLO 11 - Shrimp 模型在密集、复杂场景下表现出更优的检测性能, 其边界框预测的整体置信度有显著提升, 如图 5 所示。

在面对饲料干扰的复杂场景时, YOLO 11 - Pose 基线模型易将饲料误识别为虾体, 而 YOLO 11 - Shrimp 模型通过结构优化, 显著抑制了此类误检现象, 如图 6 所示。

在虾只密集聚集的场景下, YOLO 11 - Pose 易产生冗余检测框, 而改进后的 YOLO 11 - Shrimp 模型有效改善了此类重复检测问题, 如图 7 所示。

YOLO 11 - Pose 模型在关键点检测任务中存在一定的局限性: 其关键点定位精度尚不足够理想, 对部分身体部位的关键点预测存在明显偏差; 尤其在虾体密集、相互粘连的复杂场景中, 模型容易发生特征混淆, 导致将一只虾的关键点错误地标注到相邻虾体上。相比之下, YOLO 11 - Shrimp 模型则在这些方面取得了显著改善。检测结果如图 8 所示。

3.5 体尺拟合方法评估

对于构建的 3 个独立的单变量线性回归方程, 通过计算各方程的决定系数 R^2 和均方根误差




图 5 密集场景下边界框置信度

Fig.5 Overall improvement in confidence of bounding boxes in dense scenes




图 6 饲料误检

Fig.6 Feed pellet false detection

(RMSE)以及平均绝对百分比误差(MAPE)来评估其拟合优度与预测准确性,具体结果如表 5 所示。同时评价双变量回归方程的准确性,如表 6 所示。

实验结果表明,在单变量回归模型中,“背甲-躯干-尾节”长度对应的 R^2 最高,为 0.945, RMSE 为 27.62 像素, MAPE 为 2.53%,说明该段长度与对虾全长的线性关系最强,预测最为可靠。“头部-背甲”长度的 R^2 也较高,为 0.914, RMSE 为 34.48 像素, MAPE 为 3.15%,表明其与全长也具有很强的相关性,但略低于前者。相比之下,“尾节-尾部”长度的 R^2 明显偏低为 0.830, RMSE 为 48.44 像素, MAPE 为 4.37%,说明仅依靠该段长度预测全长时




图 7 重复检测

Fig.7 Duplicate detection




图 8 关键点偏移及重复检测

Fig.8 Keypoint offset and duplicate detection

误差较大,其单独预测能力有限。

由表 5、6 可知,无论是哪一种双变量组合,其决定系数 R^2 均高于单变量中最高的决定系数 R^2 (0.945), RMSE 均低于单变量中最低的 RMSE 值

表 5 单变量回归方程评估

Tab. 5 Univariate regression equation evaluation			
变量	决定系数	RMSE/ 像素	MAPE/ %
	R^2		
头部-背甲长度	0. 914	34. 48	3. 15
背甲-躯干-尾节长度	0. 945	27. 62	2. 53
尾节-尾部长度	0. 830	48. 44	4. 37

表 6 双变量回归方程评估

Tab. 6 Bivariate regression equation evaluation				
变量 1	变量 2	决定系 数 R^2	RMSE/ 像素	MAPE/ %
头部-背甲长度	背甲-躯干-尾节 长度	0. 990	11. 97	1. 04
头部-背甲长度	尾节-尾部长度	0. 957	24. 31	2. 26
背甲-躯干-尾节 长度	尾节-尾部长度	0. 974	19. 05	1. 74

(27.62 像素), MAPE 均低于单变量中最低的值 (2.53%),说明同时使用两个变量能更全面地预测整体度,显著提高模型的整体预测能力。而不同变量组合的预测效果存在差异。“头部-背甲”和“背甲-躯干-尾节”的决定系数 R^2 为 0.990,为最高, RMSE 为 11.97 像素, MAPE 为 1.04%,均为最低,最接近完美拟合,说明这两个区段共同覆盖对虾全长的绝大部分形态信息,二者联合时表现出很好的解释力;“背甲-躯干-尾节”和“尾节-尾部”的决定系数 R^2 为 0.974, RMSE 为 19.05 像素, MAPE 为 1.74%,也有很好的表现,说明这两部分的组合对整体尺度的预测同样有效;“头部-背甲”和“尾节-尾部”的决定系数 R^2 为 0.957, RMSE 为 24.31 像素, MAPE 为 1.74%,相较于前两组略低。

从测试集中随机选取 10 个图像样本,基于样本图像中虾只的实际体长(gt_length)与系统测量(pred_length)的体长,计算得到平均绝对误差(MAE)和平均相对误差(MRE),结果如表 7 所示。实验结果表明,所有样本的平均绝对误差均控制在 1 cm 以内,平均相对误差均不超过 10%。这表明该系统在对虾体尺的自动测量任务中具有较高的精度和良好的稳定性。

3.6 检测系统界面

设计并实现了一套对虾体尺自动测量系统。该系统采用模块化的图形用户界面,主要划分为 3 个功能区:左侧面板垂直分为上下两部分,上半部分持续显示用户选取的原始图像,下半部分在检测流程结束后,可视化呈现带有虾体关键点(如头部、腹节、尾部标注)及个体编号的检测结果图;右侧面板为实时文本日志输出区,用于记录系统运行的各阶

表 7 实际体长和测量体长的误差

Tab. 7 Error between actual and measured body length				
样本 编号	实际体长/ cm	测量体长/ cm	MAE/ cm	MRE/%
1	13. 31	13. 32	0. 01	0. 08
2	12. 12	11. 58	0. 54	4. 46
3	11. 98	11. 47	0. 51	4. 26
4	12. 76	11. 94	0. 82	6. 43
5	12. 36	11. 97	0. 39	3. 16
6	13. 17	12. 66	0. 51	3. 87
7	12. 81	12. 45	0. 36	2. 81
8	13. 15	12. 80	0. 35	2. 66
9	13. 11	12. 80	0. 31	2. 36
10	12. 93	12. 83	0. 10	0. 77

段状态与最终统计结果;界面底部设有操作控件,包括“选择图片”与“开始检测”按钮。如图 9 所示。




图 9 体尺估测系统界面

Fig. 9 Body length estimation system interface

系统启动时,将自动加载预训练的 YOLO 11-Shrimp 目标检测模型。用户通过“选择图片”按钮选择图像后,点击“开始检测”即可启动分析流程。系统首先利用 YOLO 11-Shrimp 模型识别图像中每一只虾个体,标注其关键解剖点并分配唯一编号,同时检测图像中的标定圆盘,通过计算其像素直径与实际物理尺寸的比例,确定空间尺度换算关系。基于此比例尺及检测到的关键点位置,系统可逐只计算虾体的实际体尺。若部分虾体因遮挡或重叠导致关键点缺失,系统将调用预设的拟合算法对其体尺进行估计。

检测完成后,系统整合所有精确测量与拟合估测的体尺数据,生成结构化表格,包含每只虾的编号、像素长度与实际物理长度,并自动计算样本的平均体尺。所有中间文件与结果均按检测会话自动存储于以序列编号命名的独立文件夹内,确保历史记录互不干扰。右侧日志区将输出摘要信息,包括检测到的虾体数量、标定成功状态、平均体尺等关键指标,最终通过弹窗提示检测完成。

该系统实现了从图像输入到体尺数据提取与统计的全流程自动化,用户仅需两次交互操作即可获得完整的测量结果,显著提升了群体对虾体尺检测

的效率。

4 结 束 语

以 YOLO 11 - Pose 作为基线模型,提出了一种专用于对虾关键点检测的高精度模型 YOLO 11 - Shrimp。通过 DBB 卷积核优化、CA 注意力机制嵌入、检测头优化等方法,增强了多尺度特征的表达与融合能力,提升了对虾关键点定位精度。实验结果表明,改进后的 YOLO 11 - Shrimp 模型在对虾关键点检测任务中取得了显著性能提升,关键点定位准确性明显提高。与基线模型 YOLO 11 - Pose 相比, $PCK_{0.1}$ 指标提升了 10.35 个百分点, $PCK_{0.2}$ 指标提升了 7.82 个百分点。此外,在实际复杂场景下的检测表现也得到明显优化:饲料误检现象显著减少、密集

分布场景下的重复检测问题得到有效抑制、虾体关键点偏移幅度明显降低,边界框置信度得分更为可靠。最后,提出一套自动化的对虾体尺估测系统。采用线性回归模型对虾体长度进行拟合。当观测台直径出现检测异常时,系统将仅输出可靠的像素长度,避免因尺度参考错误而引入更大偏差。本研究提出的关键点检测与体尺估测系统具备良好的系统集成能力与工程扩展潜力,可作为养殖物联网平台中的视觉感知子模块进行部署。通过标准化数据接口,将对虾体尺估测结果上传至养殖管理系统,并与投喂记录、养殖密度及历史生长数据等多源信息进行融合分析,从而为精准投喂策略制定、养殖密度动态调控以及病害风险预警等养殖决策提供数据支撑。

参 考 文 献

[1] 国家虾蟹产业技术体系. 南美白对虾产业发展报告[J]. 中国水产, 2021(5):27 - 36.

[2] Zhang Q, Liu Q, Han Y. Assessing the fishery resource status of China's coastal waters using surplus production models[J]. Journal of Ocean University of China, 2021, 20(5): 1236 - 1244.

[3] 朱从容. 计算机视觉技术在水产养殖中的应用[J]. 浙江海洋学院学报(自然科学版), 2008, 27(4): 439 - 443. Zhu Congrong. The application of computer vision technology in aquaculture[J]. Journal of Zhejiang Ocean University (Natural Science Edition), 2008, 27(4):439 - 443. (in Chinese)

[4] Hong H, Yang X, You Z, et al. Visual quality detection of aquatic products using machine vision[J]. Aquacultural Engineering, 2014, 63: 62 - 71.

[5] Ran X, Liu Y, Pan H, et al. Shrimp phenotypic data extraction and growth abnormality identification method based on instance segmentation[J]. Computers and Electronics in Agriculture, 2025, 229: 109701.

[6] Lai P C, Lin H Y, Lin J Y, et al. Automatic measuring shrimp body length using CNN and an underwater imaging system[J]. Biosystems Engineering, 2022, 221: 224 - 235.

[7] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580 - 587.

[8] Ren S, He K, Girshick R, et al. Faster R - CNN: towards eal-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137 - 1149.

[9] Carion N, Massa F, Synnaeve G, et al. End-to-end object detection with transformers[C] //European Conference on Computer Vision. Cham: Springer International Publishing, 2020: 213 - 229.

[10] 翟肇裕, 张梓涵, 徐焕良, 等. YOLO 算法在动植物表型研究中应用综述[J]. 农业机械学报, 2024, 55(11): 1 - 20. Zhai Zhaoyu, Zhang Zihan, Xu Huanliang, et al. Review of applying YOLO family algorithms to analyze animal and plant phenotype[J]. Transactions of the Chinese Society for Agriculture Machinery, 2024, 55(11):1 - 20. (in Chinese)

[11] Lee Y K, Lin B Y, Weng T H, et al. Counting and measuring the size and stomach fullness levels for an intelligent shrimp farming system[J]. Connection Science, 2023, 35(1): 2268878.

[12] He K, Gkioxari G, Dollár P, et al. Mask R - CNN[C] //Proceedings of the IEEE International Conference on Computer Vision, 2017: 2961 - 2969.

[13] Xu Y, Zhang J, Zhang Q, et al. Vitpose: simple vision transformer baselines for human pose estimation[J]. Advances in Neural Information Processing Systems, 2022, 35: 38571 - 38584.

[14] Geng Z, Sun K, Xiao B, et al. Bottom-up human pose estimation via disentangled keypoint regression[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 14676 - 14686.

[15] Wang J, Sun K, Cheng T, et al. Deep high-resolution representation learning for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 43(10): 3349 - 3364.

[16] Maji D, Nagori S, Mathew M, et al. YOLO-Pose: enhancing yolo for multi person pose estimation using object keypoint similarity loss[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 2637 - 2646.

[17] 刘刚, 曾雪婷, 刘晓文, 等. 基于改进 YOLO v5 - pose 的群养生猪体尺自动测量方法[J]. 农业机械学报, 2025, 56(5): 455 - 465.

Liu Gang, Zeng Xueting, Liu Xiaowen, et al. An automatic measurement method for the body dimensions of group-reared pigs based on the improved YOLO v5 – pose[J]. Transactions of the Chinese Society for Agriculture Machinery, 2025, 56(5): 455 – 465. (in Chinese)

[18] Qu H, Leng A, Deng Y, et al. A keypoint detection-based approach for real-time aggressive behavior identification in goats [J]. Applied Animal Behaviour Science, 2025, 292: 106745.

[19] 黄小平, 侯现坤, 郭阳阳, 等. 基于改进 YOLO v7 – Pose 的牛脸关键点检测与姿态识别方法[J]. 农业机械学报, 2024, 55(11): 84 – 92, 102.

Huang Xiaoping, HOU Xiankun, Guo Yangyang, et al. A method for cattle face key point detection and pose recognition based on improved YOLO v7 – Pose[J]. Transactions of the Chinese Society for Agriculture Machinery, 2024, 55(11): 84 – 92, 102. (in Chinese)

[20] 刘莫尘, 褚镇源, 崔明诗, 等. 基于改进 YOLO v8 – Pose 的红熟期草莓识别和果柄检测[J]. 农业机械学报, 2023, 54 (增刊 2): 244 – 251.

Liu Mochen, Chu Zhenyuan, Cui Mingshi, et al. Red-ripe strawberry recognition and pedicel detection based on improved YOLO v8 – Pose[J]. Transactions of the Chinese Society for Agriculture Machinery, 2023, 54(S2): 244 – 251. (in Chinese)

[21] Ding X, Zhang X, Han J, et al. Diverse branch block: building a convolution as an inception-like unit[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 10886 – 10895.

[22] Hou Q, Zhou D, Feng J. Coordinate attention for efficient mobile network design [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713 – 13722.

[23] Hu M, Feng J, Hua J, et al. Online convolutional re-parameterization [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 568 – 577.

[24] Canny J. A computational approach to edge detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009 (6): 679 – 698.

[25] Hotelling H. Analysis of a complex of statistical variables into principal components[J]. Journal of Educational Psychology, 1933, 24(6): 417.

[26] Parzen E. On estimation of a probability density function and mode[J]. The Annals of Mathematical Statistics, 1962, 33(3): 1065 – 1076.

[27] Zhang X, Song Y, Song T, et al. LDConv: linear deformable convolution for improving convolutional neural networks[J]. Image and Vision Computing, 2024, 149: 105190.

[28] Dai J, Qi H, Xiong Y, et al. Deformable convolutional networks [C] // Proceedings of the IEEE International Conference on Computer Vision, 2017: 764 – 773.

[29] Li C, Zhou A, Yao A. Omni-dimensional dynamic convolution [PP/OL]. V1. arXiv(2022 – 11 – 16) [2026 – 04 – 01]. <https://doi.org/10.48550/arXiv.2209.07947>.

[30] Ouyang D, He S, Zhang G, et al. Efficient multi-scale attention module with cross-spatial learning [C] // ICASSP 2023—2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Rhodes: IEEE, 2023: 1 – 5.

(上接第 147 页)

[25] 魏天娇, 胡祝华, 范习禹. 水产养殖中水质与鱼类行为双向映射模型研究[J]. 农业机械学报, 2024, 55(3): 290 – 299.

Wei Tianjiao, Hu Zhuhua, Fan Xiyu. Construction of a bidirectional mapping model between water quality and fish behavior in aquaculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(3): 290 – 299. (in Chinese)

[26] 赵思琪. 池塘水产养殖精准投喂系统研究与试验[D]. 南京: 南京农业大学, 2019.

Zhao Siqi. Design and experiment of precise feeding system for pond aquaculture [D]. Nanjing: Nanjing Agricultural University, 2019. (in Chinese)

[27] 赵思琪, 赵三琴, 顾家冰, 等. 池塘水产养殖投饲区溶解氧稳定性分析研究[J]. 中国农机化学报, 2023, 44(6): 75 – 82.

Zhao Siqi, Zhao Sanqin, Gu Jiabing, et al. Analysis and research on dissolved oxygen stability in the feeding area of pond aquaculture[J]. Journal of Chinese Agricultural Mechanization, 2023, 44(6): 75 – 82. (in Chinese)

[28] 赵思琪, 丁为民, 赵三琴, 等. 基于 EDEM – Fluent 的气动式鱼塘投饲机性能优化[J]. 农业机械学报, 2019, 50(9): 130 – 138.

Zhao Siqi, Ding Weimin, Zhao Sanqin, et al. Performance analysis and optimization of pneumatic fishpond feeder based on EDEM – Fluent coupling[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(9): 130 – 138. (in Chinese)