

周逸驰,陈彦祥,刘季松,等.基于关键点检测的前臀鲢表型测量与体质量预测[J].华中农业大学学报,2026,45(2):45-57.
DOI:10.13300/j.cnki.hnlkxb.2026.02.006

基于关键点检测的前臀鲢表型测量与体质量预测

周逸驰¹,陈彦祥¹,刘季松²,熊皓²,苏晓静³,杨庆勇¹,杨瑞斌³,郑芳¹

1. 华中农业大学信息学院,武汉 430070; 2. 华电金沙江上游水电开发有限公司叶巴滩分公司,甘孜 627153;
3. 华中农业大学水产学院,武汉 430070

摘要 为提高前臀鲢(*Pareuchiloglanis anteanalis*)表型数据获取效率并降低人工测量误差,构建基于关键点检测的表型自动测量与体质量预测方法。采集前臀鲢腹部视角、侧面视角与背部视角图像共951张,采用COCO格式完成关键点标注,并基于关键点坐标计算体长、体高、眼间距等传统体尺及框架距离指标;在相同训练配置下对RTMPOSE、LiteHRNet、YOLOv12n-pose与YOLOv8n-pose进行对比评估。结果显示,YOLOv8n-pose在测试集上的精确率为94.70%,表型测量平均相对误差(mean relative error, MRE)为5.45%,多数表型相对误差控制在10%以内;进一步结合相关性与共线性分析筛选胸鳍基部起点间距离(X_5)、胸鳍基部起点到腹鳍基部右端起点距离(X_7)、体高(X_{10})、头长(X_{12})和眼间距(X_{14})等表型指标建立体质量多元回归模型,测试集决定系数 R^2 为0.97。结果表明,该方法可实现前臀鲢表型的自动化测量与体质量的定量估算。

关键词 前臀鲢;表型测量;计算机视觉;YOLOv8n-pose;关键点检测;体质量预测

中图分类号 TP391.4 **文献标识码** A **文章编号** 1000-2421(2026)02-0045-13

前臀鲢(*Pareuchiloglanis anteanalis*)身体扁平,头大尾小^[1],主要分布在金沙江、青衣江、大渡河等江河及其支流的水域^[2],属我国本土冷水性小型经济鱼类。然而,近年来水电站的建设与运营对包括前臀鲢在内的鲢科鱼类的生存环境造成了严重破坏,其资源量严重下降,因此人工驯养的开发与推广显得尤为重要。在现代渔业管理与养殖工作中,鱼体表型信息的精准获取为渔业人员提供了关键的参考依据。目前对前臀鲢的表型数据收集仍以人工测量为主,例如姚景龙等^[3]通过人工测量多个形态度量性状分析前臀鲢的物种多样性。但人工测量存在效率低、成本高、误差较大、数据质量受人工主观因素影响等问题,且人工测量难以满足大规模监测和长期研究的需求,因此,结合深度学习的自动测量系统研究十分必要。

近年来,随着深度学习技术在计算机视觉领域中的发展,其高精度自动提取特征数据的能力正被广泛应用于水产养殖业,特别是鱼只表型(phenotype, 又称性状,指生物体可观察的形态、功能等特

征,是基因型与环境相互作用的产物,涵盖个体体型结构、生理指标及行为特征等)数据等外部特征的测量。在表型分割与检测方面,郭奕等^[4]提出了一种SA-MaskR-CNN模型结合二次迁移学习方法,在真实环境下鱼体语义分割综合评价指标达到96.04%。Yu等^[5]使用U-Net网络进行鱼体分割,实现了鱼体尺寸的精确测量。Freitas等^[6]使用Mask R-CNN网络将细鳞肥脂鲤(*Piaractus mesopotamicus*)的头部、身体、鱼鳍等区域进行分割,进而测量鱼体的全长、体长、体高等体尺数据,并应用于大规模表型分析。Suo等^[7]利用水下双目相机采集立体图像,通过Faster R-CNN检测图像中的鱼类目标,并构建了堆叠沙漏网络来检测每条鱼的特定关键点,再利用检测到的关键点来估计鱼的体长,该方法避开了全局立体匹配算法中像素方向匹配困难的问题。同时,YOLO系列算法的关键点检测功能在农业数据测量领域也有广泛的应用,作为单阶段目标检测算法,YOLO算法相比于目前用于测量水产动物表型的Faster R-CNN、Mask R-CNN等两阶段目标检测算法具

收稿日期:2025-07-14

基金项目:湖北省支持种业高质量发展资金项目(HBZY2023B009);国家自然科学基金项目(31971421);华电集团金沙江上游远期放流鱼种人工繁育技术研究项目(T-2022-04)

周逸驰, E-mail: zhoyichi28@163.com

通信作者:郑芳, E-mail: zhengfang@mail.hzau.edu.cn

有显著优势,该算法能够同时支持物体检测、图像分割、关键点检测等任务,检测速度更快,能够满足多元化的水产动物不同表型测量需求^[8-10]。程思奇^[11]针对R-YOLO5F模型在鱼体倾斜等情况下容易出现关键点偏移的问题,对模型进行了改进,提出了DR-YOLO5F模型以实现水下鱼体长度测量,模型精度达到了91.62%;Zhou等^[12]利用YOLOv7网络模型在复杂水环境下识别红鳍东方鲀(*Takifugu rubripes*),识别精确率达到90.2%;何志鹏等^[13]通过YOLOv8模型计算黄颡鱼的胸鳍、腹鳍、头部等面积参数来进行体质量预测,其表型识别系统的误差均在1%左右。

在体质量预测建模领域,近年来鱼类体质量估计技术也取得了显著进展:Kolarevic等^[14]通过多模态传感器融合方法,实现了大西洋鲑体质量实时动态监测;Murugaiyan等^[15]基于预训练的Google Inception-v3模型开展水下鱼类图像分类研究,在小样本条件下取得95.37%的分类准确率,为后续基于图像表型特征进行体质量估计提供参考;此外,田洁等^[16]提取深度信息与生长数据进行映射建模,拟合出目标特征并结合网格搜索优化支持向量回归算法实现大菱鲆体质量估测,验证了深度学习驱动表型-体质量关联分析的可行性。

尽管上述研究已推动鱼类智能测量技术发展,针对前臀鲃等鲃科小型淡水鱼类仍存在三大关键技术挑战:一是物种针对性不足,现有研究多聚焦于红鳍东方鲀、黄颡鱼、大西洋鲑等经济性海水或大宗淡水鱼类,目前尚未有研究针对前臀鲃这一“身体扁平、头大尾小”特殊形态鱼类的表型进行自动测量,通用模型难以适配其独特解剖结构的关键点定位需求;二是传统方法局限未突破,传统形态学方法仍依赖人工操作,存在效率低、可扩展性差等问题,且部分自动测量方法采用“包围框回归”提取表型,易受鱼体姿态变化影响,无法像关键点检测那样精准定位鱼体解剖学标志,导致体尺数据误差较大;三是“表型-体质量”关联的物种适配性缺失,现有体质量预测模型多基于特定物种(如黄颡鱼、大菱鲆)的形态特征构建,未形成针对鲃科鱼类的通用框架,无法直接迁移至前臀鲃体质量估计任务。

基于上述研究现状与应用需求,本研究以前臀鲃为对象,融合数字图像处理与深度学习方法,构建了基于YOLOv8n-pose的关键点驱动表型自动测量

框架。结合其体型特征,对关键点标注体系与约束策略进行优化(如补充眼间距测量所需的头部标志点等),实现体长、体高、眼间距等可量可数表型性状的自动化、高效率获取。在此基础上,构建包含侧视与背视等视角的前臀鲃表型数据集,并进一步建立“表型参数-体质量”的非线性映射模型;依托关键点对应的解剖学标志,降低姿态变化对测量与预测结果的影响,以期鲃科小型淡水鱼类的表型测量与体质量估计提供可迁移的方法框架。

1 材料与方法

1.1 图像采集及测量

挑选出317条外表无损伤的前臀鲃标本作为研究对象。如图1所示,标本被放置在专门设计的图像采集装置上进行拍摄。为了确保鱼体姿态的标准化,鱼体被水平放置于一个纯色背景板上,头部朝右,尾部朝左,以保证拍摄时的姿态一致性。图像采集装置包括一个可调节高度的支架,用于固定工业相机,相机与鱼体之间的距离设为50 cm,以确保图像清晰度和比例尺的准确性。鱼体与相机之间的角度通过水平仪校准,以确保拍摄视角的垂直性。

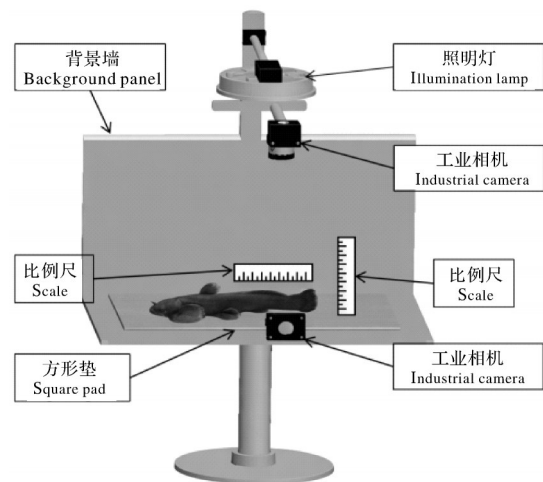


图1 图像采集装置

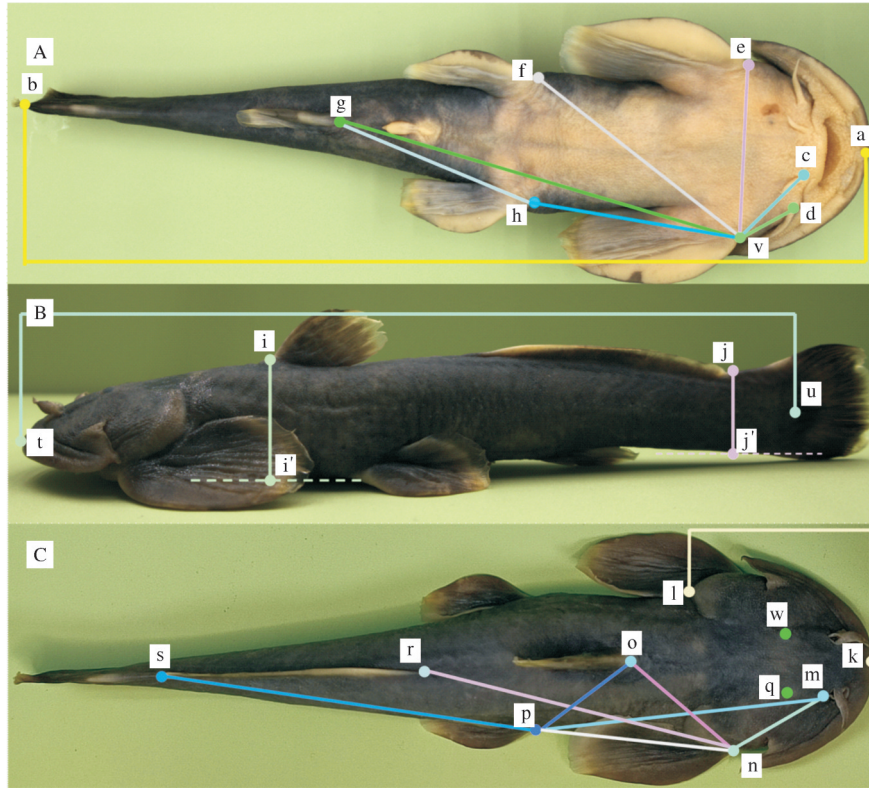
Fig.1 The image acquisition device

为实现图像采集自动化,本研究采用工业相机获取鱼体图像;为获取更清晰的鱼体尺寸特征,选用海康MVL-KFO814M-12MPE相机,该相机镜头分辨率为1200万像素,通光口径为F2.8~F22,镜头接口为C口,帧率为19.2帧/s,分别选择焦距为8、12 mm的镜头拍摄不同视角的前臀鲃图像。在图像画面中放置10 cm比例尺,采用定焦拍摄,拍摄得到包含比例尺的侧面、背部和腹部图像信息,确保数据的

一致性和可重复性。

图像采集装置从侧视、俯视2个视角拍摄317条前臀鲃标本的图像,共获得951张图片,可分为3组,分别为腹部(图2A)、侧面(图2B)、背部(图2C)视角

图片,用于完成不同视角的表型检测任务。为了验证模型的泛化性,使用普通手机摄像头额外拍摄81组图片,构成验证数据集。鱼体表型数据通过图像中的像素长度以及图像比例参数计算得到。



A:腹部 Ventral; B:侧面 Lateral; C:背部 Dorsal. 不同小写字母代表不同关键点标注 Different lowercase letters represent different keypoint annotations.

图2 前臀鲃不同视角关键点标注图像

Fig.2 Keypoint-annotated images of *Pareuchiloglanis anteanalis* from different perspectives

本研究测量的传统鱼体特征指标^[13]包括全长、体长、头长、体高、眼间距、尾柄长和脂鳍长度。同时,为更好地提供体质量预测参数,本研究在泄殖孔、背鳍、腹鳍、胸鳍、内颌须、外颌须和鼻须等部位增加特征点标注,用于测量框架指标(基于关键点标注得到的解剖学标志点坐标,在二维图像平面内计算指定两标志点之间的欧氏直线距离,并结合图像标尺完成像素-实际长度换算所得的距离型表型指标),并由关键点点对距离计算得到25种表型值,如表1所示。所有图像使用COCO Annotator软件对前臀鲃特征点进行标注,标注文件以JSON格式存储,构建关键点检测模型开发所需的数据集。

1.2 数据预处理

为了提高模型的泛化能力和鲁棒性,对标注完成的数据图像使用增强算法进行扩充(亮度调整、翻转、旋转、缩放、平移)。通过增加数据多样性,生成

更为丰富的数据集,帮助模型更好地学习目标特征,从而提高检测精度和稳定性。

为了有效地训练和评估模型,将鱼体图片数据集按照体质量分段划分为训练集、验证集和测试集。为了对鱼体质量进行分类,将其划分为3个区间: $<5\text{ g}$ 、 $5\sim 10\text{ g}$ 、 $>10\text{ g}$ 。体质量 $<5\text{ g}$ 的样本在317个总样本中共计174条,体质量在 $5\sim 10\text{ g}$ 区间的样本数量为106条,体质量 $>10\text{ g}$ 的样本数目为37条。利用数据处理工具确保每个体质量区间的样本在3类数据集(训练集、验证集、测试集)中均衡分布,且每个区间内数据按80%、10%、10%的比例随机划分。

1.3 图像关键点检测模型

本研究选取的研究对象前臀鲃的尺寸、特征都有明显差异,为实现前臀鲃关键点位置的精确定位,在对几种常用模型的特点进行分析与对比后,发现YOLOv8模型作为一种较新的目标检测模型,具有

快速检测、精准度高、多尺度检测等显著特性^[17],能够满足本研究的主要需求,其网络结构如图3所示。YOLO算法是一种单阶段目标检测算法,其网络结构分为特征提取网络(Backbone)、特征融合网络(Neck)、输出检测头(Head)3个部分^[18]。

YOLOv8模型的Head部分采用目前主流的解耦合头(decoupled-head),将分类和检测头分离,同时Loss部分引入了分布式焦点损失(distribution focal loss,DFL,公式中记作 L_{DF})的思想^[19],如式(1)所示:

$$L_{DF} = - \sum_{i=1}^N \alpha_i \cdot (1 - p_i) \gamma \cdot \log(p_i) \quad (1)$$

式(1)中, α_i 为平衡因子, p_i 为预测概率, γ 为调整因子, N 为类别数。同时,Loss部分还使用了task-aligned assigner正负样本匹配方式^[20],通过构建联合任务目标函数来同时考虑分类任务和回归任务。该目标函数结合了分类置信度和定位精度(通常使用交并比(intersection over union, IoU,公式中记作

J_{IoU})来衡量,并基于该联合目标来动态调整正负样本的分配^[21]。

$$J_{IoU} = \frac{|A \cap B|}{|A \cup B|} \quad (2)$$

$$T = S^\alpha \cdot J_{IoU}^\beta \quad (3)$$

式(2)~(3)中, A 为候选框, B 为真实框, S 为分类分数, α, β 分别是控制分类任务和回归任务相对重要性的权重系数, S^α 强调了分类任务的贡献, J_{IoU}^β 强调了定位任务的贡献。

为检验模型效果,本研究选择精确率(precision, P)、召回率(recall, R)作为模型评估指标。精确率和召回率的计算公式分别如式(4)、(5)所示。

$$P = \frac{T_p}{T_p + F_p} \quad (4)$$

$$R = \frac{T_p}{T_p + F_N} \quad (5)$$

式(4)~(5)中, T_p 表示预测为正类且实际为正类的样本数, F_p 表示被错误预测为正类的样本数, F_N 表示被错误预测为负类的样本数。

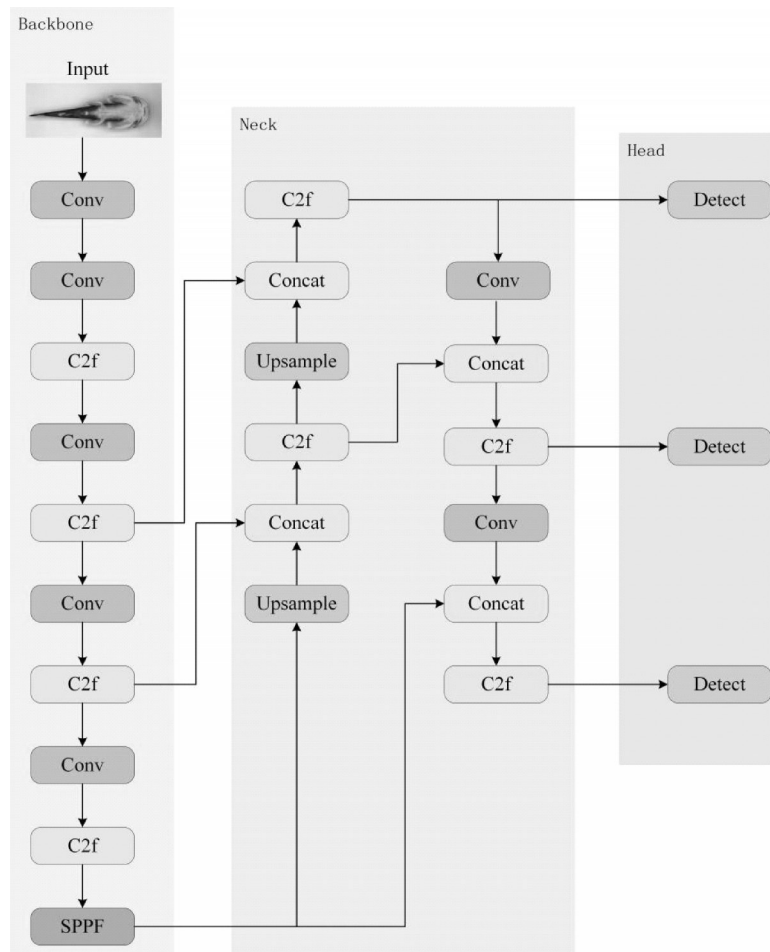


图3 YOLOv8网络结构图

Fig.3 YOLOv8 network architecture diagram

表1 关键点与表型指标对应关系
Table 1 Correspondence between keypoint pairs and phenotype traits

编号 No.	关键点 Keypoint	表型指标 Phenotype traits
X ₁	a, b	全长 Total length
X ₂	t, u	身长 Body length
X ₃	c, v	内颌须基部到胸鳍基部起点距离 Distance from the inner mandibular barbel base to the pectoral-fin base point
X ₄	d, v	外颌须基部到胸鳍基部起点距离 Distance from the outer mandibular barbel base to the pectoral-fin base point
X ₅	v, e	胸鳍基部起点间距离 Distance between pectoral-fin base points
X ₆	v, f	胸鳍基部起点到腹鳍基部左端起点距离 Distance from pectoral-fin base point to left pelvic-fin base point
X ₇	v, h	胸鳍基部起点到腹鳍基部右端起点距离 Distance from pectoral-fin base point to right pelvic-fin base point
X ₈	v, g	胸鳍基部起点到泄殖孔距离 Distance from pectoral-fin base point to vent
X ₉	h, g	腹鳍基部起点到泄殖孔距离 Distance from pelvic-fin base point to vent
X ₁₀	i, i'	体高 Body depth
X ₁₁	j, j'	尾柄高 Caudal peduncle depth
X ₁₂	k, l	头长 Head length
X ₁₃	r, s	脂鳍长度 Adipose-fin length
X ₁₄	w, q	眼间距 Interorbital distance
X ₁₅	m, n	鼻须基部到胸鳍基部起点距离 Distance from nasal barbel base to pectoral-fin base point
X ₁₆	n, o	胸鳍基部起点到背鳍基部起点距离 Distance from pectoral-fin base point to dorsal-fin base point
X ₁₇	n, r	胸鳍基部起点到脂鳍基部起点距离 Distance from pectoral-fin base point to adipose-fin base point
X ₁₈	n, p	胸鳍基部起点到腹鳍基部起点距离 Distance from pectoral-fin base point to pelvic-fin base point
X ₁₉	n, s	胸鳍基部起点到脂鳍基部末端距离 Distance from pectoral-fin base point to posterior end of adipose-fin base
X ₂₀	p, s	腹鳍基部起点到脂鳍基部末端距离 Distance from pelvic-fin base point to posterior end of adipose-fin base
X ₂₁	o, p	背鳍基部起点到腹鳍基部起点距离 Distance from dorsal-fin base point to pelvic-fin base point
X ₂₂	m, p	鼻须基部到腹鳍基部起点距离 Distance from nasal barbel base to pelvic-fin base point
X ₂₃	m, r	鼻须基部到脂鳍基部起点距离 Distance from nasal barbel base to adipose-fin base point
X ₂₄	m, o	鼻须基部到背鳍基部起点距离 Distance from nasal barbel base to dorsal-fin base point
X ₂₅	r, o	背鳍基部起点到脂鳍基部起点距离 Distance from dorsal-fin base point to adipose-fin base point

不同小写字母代表不同关键点标注(具体位置见图2)。Different lowercase letters represent different keypoint annotations (the specific location is shown in Fig.2).

本研究选取了代表不同架构范式与计算开销的RTMPOSE^[22]、LiteHRNet^[23]、YOLOv12n-pose和YOLOv8n-pose 4种关键点检测模型进行对比实验。RTMPOSE是一款针对实时多人姿态估计任务设计的轻量级网络;LiteHRNet则通过保持高分辨率特征图、减少通道数与参数量来兼顾性能与效率;YOLOv12n-pose在YOLOv12目标检测框架基础上集成了姿态检测头^[24],以统一的目标检测-关键点回归流程实现一体化推理;YOLOv8n-pose则以YOLOv8为骨干,增设关键点检测分支,融合自上而下与自下而上的方法优势,以进一步提升定位精度。

为保障评估过程的公平性与结果有效性,所有模型均基于完全相同的数据集、标注规范及训练超参数完成训练,关键训练超参数明确设定为batch size=16、训练轮次epochs=100。该设置通过固定核心训练条件,最大限度消除数据分布不均与超参数差异对模型性能测评的潜在影响,确保RTMPOSE、LiteHRNet等不同架构模型的对比建立在统一基准之上,提升结果的参考价值。在上述标准化的训练与测试框架下,对4种模型的P、R、F₁-score及mAP@0.5进行全面衡量,同时补充模型参数量及实时性指标(FPS),以多维度衡量模型性能。模型训练与推理测试均在云端GPU服务器上完成,硬件配置为: Intel Xeon Gold 6430(16核)CPU, 120 GB内存, NVIDIA RTX 4090(单卡)GPU。

1.4 误差测量

为更好地评估本研究提出的、基于YOLOv8n-pose模型的关键点检测方法计算鱼体表型特征的误差,本研究分别使用平均绝对误差(mean absolute error, MAE, 公式中记作 ϵ_a)、平均相对误差(mean relative error, MRE, 公式中记作 ϵ_r)、均方误差(mean squared error, MSE, 公式中记作 ϵ_s)、均方根误差(root mean squared error, RMSE, 公式中记作 ϵ_q),用于评估检测模型的效果,其计算公式分别如式(6)~(9)所示。

$$\epsilon_a = \frac{1}{n} \sum_{i=0}^n |y_i - \hat{y}_i| \quad (6)$$

$$\epsilon_r = \frac{1}{n} \sum_{i=0}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \quad (7)$$

$$\epsilon_s = \frac{1}{n} \sum_{i=0}^n (y_i - \hat{y}_i)^2 \quad (8)$$

$$\epsilon_q = \sqrt{\epsilon_s} \quad (9)$$

式(6)~(9)中, y_i 是第*i*个样本的实际值, \hat{y}_i 是第*i*个样本的预测值, n 是样本总数。样本的真实值是

通过计算标注后生成的数据集中对应JSON文件中关键点坐标间的距离。将这些坐标距离计算值作为基准值,用于评估模型识别结果的准确性。本研究通过选取编号140~200的61条前臀鲢的数据作为估计样本,通过对比计算3种视角的模型识别表型值与手测表型值,若各表型值平均相对误差小于10%则可视为模型训练达到预期效果。

1.5 体质量预测模型的建立与验证

为选择预测体质量的参数,首先,加载体质量数据和表型数据,并将它们合并到1个数据框中。使用线性回归(linear regression)模型拟合表型参数和体质量之间的线性关系。使用 R^2 系数来评估各表型值与体质量的相关性, R^2 系数反映了自变量对因变量的解释程度,取值范围为0~1。 R^2 值越接近1,说明自变量对因变量的解释力越强。计算公式如式(10)所示。

$$R^2 = 1 - \frac{\sum_{i=1}^n \sum (y_i - \hat{y}_i)^2}{\sum_{i=1}^n ((y_i - \bar{y}_i)^2)} \quad (10)$$

使用经相关性分析筛选后的显著表型数据构建多元线性回归模型。使用线性回归类初始化回归模型,并在训练集上拟合该模型。回归模型通过最小化预测值与实际值之间的均方误差来找到最佳的回归系数。再使用 R^2 、MSE、RMSE、MRE来评估模型性能,通过训练得到的回归模型,其回归方程用式(11)表示:

$$W = \beta_0 + \beta_1 \times X_1 + \beta_2 \times X_2 + \dots + \beta_i \times X_i \quad (11)$$

式(11)中, β_0 为截距, β_i 为每个表型 X_i 的回归系数。对回归模型做方差分析,得到回归方差(regression sum of squares,公式中记作 S_{SR})、残差方差(error sum of squares,公式中记作 S_{SE})和总方差(total sum of squares)。回归方差反映了所有预测值与实际值均值之间的偏差,表示模型可解释的方差;而残差方差反映了所有实际值与预测值之间的偏差,表示模型无法解释的方差;总方差等于回归方差和残差方差之和。

F 统计量用于检验回归模型的总体显著性,即检

验模型中的自变量是否能够显著解释因变量的变化,计算公式如下式(12)。通过将计算出的 F 统计量与对应的 F 分布临界值进行比较,判断回归模型的显著性。

$$F = \frac{\frac{S_{SR}}{k}}{\frac{S_{SE}}{n-k-1}} \quad (12)$$

式(12)中, k 是自变量的个数, n 是样本总数。

2 结果与分析

2.1 模型选择

为了对目标检测模型进行精准选型,本研究在相同数据划分与训练配置下,对RTMPOSE、LiteHRNet、YOLOv12n-pose及YOLOv8n-pose 4种网络展开系统评估。由表2可知,就检测性能而言,RTMPOSE和LiteHRNet虽召回率表现较好(分别为91.04%和92.64%),但其精确率(分别为85.95%和89.11%)、 F_1 值(分别为88.43%和90.82%)及mAP@0.5(分别为89.02%和89.23%)均逊色于YOLOv12n-pose和YOLOv8n-pose;YOLOv12n-pose在精确率、召回率、 F_1 值和mAP@0.5上分别达93.40%、93.50%、93.45%和92.35%,性能表现均衡;而YOLOv8n-pose以94.70%的精确率、95.00%的召回率、94.80%的 F_1 值和93.97%的mAP@0.5全面领先,其中精确率较YOLOv12n-pose、LiteHRNet和RTMPOSE分别提升1.30、5.59和8.75百分点,mAP@0.5较LiteHRNet与RTMPOSE分别提升4.74和4.95百分点。从参数规模与实时性角度分析,YOLOv8n-pose参数量为 3.2×10^6 ,处于合理区间,且FPS达148帧/s,能够满足实时检测的需求。综上,YOLOv8n-pose在检测准确性、召回率、参数效率与实时性之间达成最佳平衡。

为进一步比较不同模型在训练过程中的优化表现与稳定性,本研究绘制了各模型的训练损失变化曲线。如图4所示,YOLOv8n-pose的收敛速度最快,初始阶段下降迅速,后期趋于平稳,最终损失最低,表明其在训练阶段具备更强的稳定性与拟合能

表2 不同模型性能表

Table 2 Experiment results of different models

模型 Model	参数量 Parameter	精确率/% Precision	召回率/% Recall	F_1 -score/%	mAP@0.5/%	推理速度/(帧/s) FPS
RTMPOSE	3.3×10^6	85.95	91.04	88.43	89.02	132
LiteHRNet	1.1×10^6	89.11	92.64	90.82	89.23	112
YOLOv12n-pose	2.9×10^6	93.40	93.50	93.45	92.35	192
YOLOv8n-pose	3.2×10^6	94.70	95.00	94.80	93.97	148

力。YOLOv12n-pose整体表现次之,损失下降平稳,最终损失略高于YOLOv8n-pose;LiteHRNet和RTMPOSE的损失曲线波动较大,尤其在训练前期震荡明显,表明其训练过程更易受到噪声干扰,优化能力相对较弱。

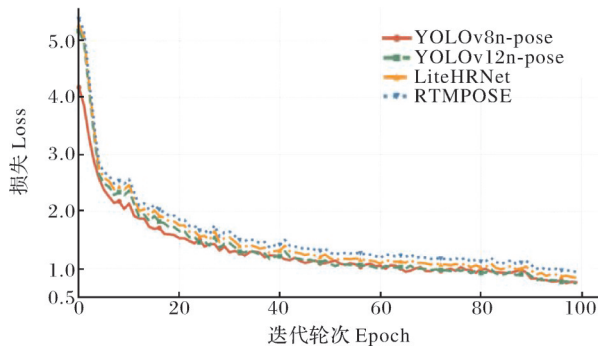
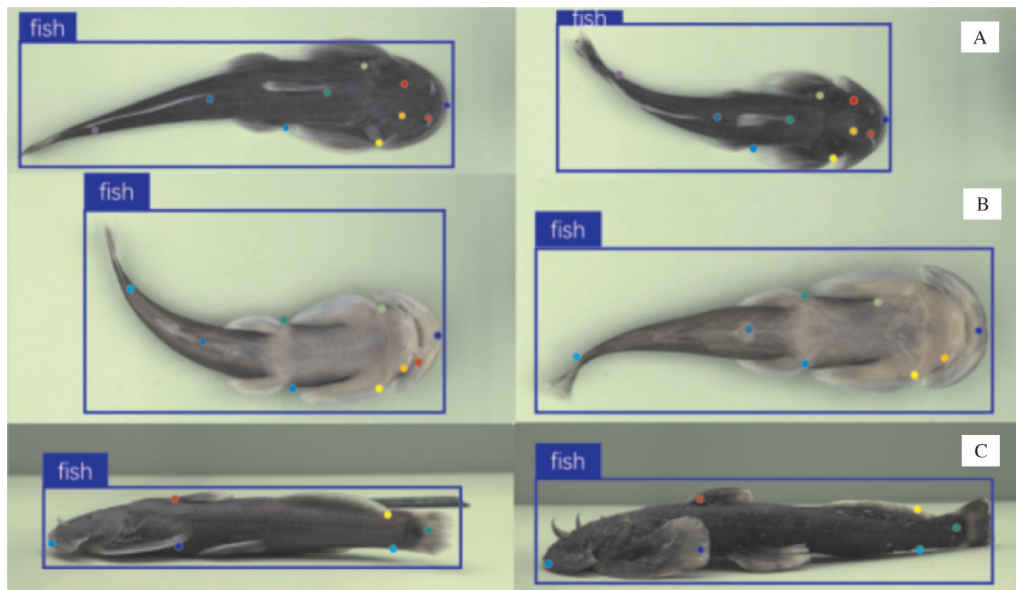


图4 不同模型训练损失曲线对比

Fig.4 Training loss curve comparison of different models

2.2 表型测量

从模型检测结果来看,对于不同体态、光线、大小的前臀鲃标本图像,YOLOv8n-pose关键点模型均检测出精确的关键点位置,部分结果如图5所示。



A:背部 Dorsal;B:腹部 Ventral;C:侧面 Lateral.

图5 各视角下YOLOv8n-pose模型检测结果

Fig.5 Detection results of the YOLOv8n-pose model from different perspectives

为了进一步比较不同模型在表型测量任务中的性能差异,分析了YOLOv8n-pose、YOLOv12n-pose、LiteHRNet与RTMPOSE 4种模型在25个表型预测中的平均误差表现。由表4可知,YOLOv8n-pose在MAE(0.138 8%)、MRE(5.446 1%)与RMSE(0.228 5%)等核心指标上均优于其他模型,体现出

为评估关键点检测模型在前臀鲃表型测量任务中的误差表现,本研究引入MAE、MRE、RMSE和标准差等指标,对YOLOv8n-pose模型预测误差进行系统性分析。由表3可知,在25个表型维度中,YOLOv8n-pose在多数表型上取得了较低的平均MRE,整体平均值为5.45%,除因特征点难以准确定位的体高相对误差为10.636%外,其余表型相对误差均在0~10%区间内,胸鳍基部起点到脂鳍基部末端(X_{19})相对误差最小,为1.679%,表明最终选择的YOLOv8n-pose模型在测试集上的关键点预测效果比较理想。体高定义为背鳍纵切面上的背腹轴距离,由于对应关键点在图像中纹理特征不明显,且背腹轴下端易受胸鳍遮挡,导致该指标误差相对较大。另一方面,腹鳍基部起点到泄殖孔的距离对鱼尾摆放较为敏感,数据集中存在部分摆放姿态异常的样本,因此该指标误差偏高(8.036%)。约60%的表型指标预测平均相对误差(MRE)集中在3%~5%,表明YOLOv8n-pose模型在前臀鲃图像上的关键点识别与表型测量具有较高稳定性。

更高的测量精度与鲁棒性。尽管该模型的标准差为0.797 9,略高于其余模型,但结合其整体误差水平显著更低的特点,说明其预测结果在低误差区间内的波动仍可控,整体稳定性更优。综上,YOLOv8n-pose在本任务中综合表现最佳,最终被选为后续关键点提取与表型计算的基础检测框架。

表3 YOLOv8n-pose模型表型测量结果

Table 3 YOLOv8n-pose phenotypic measurement results

表型值 Phenotypic value	平均值/cm Mean	标准差 SD	平均绝对误差 MAE	平均相对误差/% MRE	均方根误差 RMSE	均方误差 MSE
X ₁	9.610 6	2.744 3	0.689 3	7.585	1.620 4	2.625 7
X ₂	8.616 3	2.475 2	0.330 6	4.518	0.836 8	0.700 3
X ₃	1.103 6	0.224 0	0.081 1	7.587	0.099 3	0.009 9
X ₄	0.864 4	0.187 6	0.044 5	5.477	0.064 0	0.004 1
X ₅	2.239 0	0.642 5	0.188 1	9.026	0.276 2	0.076 3
X ₆	3.141 0	0.866 3	0.087 1	2.949	0.116 5	0.013 6
X ₇	2.518 4	0.706 0	0.100 5	4.156	0.141 2	0.020 0
X ₈	4.023 9	1.117 9	0.122 3	3.306	0.159 8	0.025 5
X ₉	1.640 3	0.501 0	0.142 8	8.036	0.324 5	0.105 2
X ₁₀	1.022 7	0.169 3	0.109 0	10.636	0.120 2	0.014 5
X ₁₁	0.684 2	0.092 2	0.049 9	7.477	0.068 2	0.004 6
X ₁₂	0.943 7	0.208 7	0.035 2	4.249	0.044 2	0.001 9
X ₁₃	2.897 6	0.732 9	0.160 2	4.893	0.204 9	0.042 0
X ₁₄	0.673 2	0.140 7	0.036 0	5.818	0.042 9	0.001 9
X ₁₅	1.246 7	0.310 5	0.061 9	5.469	0.076 3	0.005 8
X ₁₆	1.681 9	0.387 2	0.064 0	4.116	0.083 4	0.006 9
X ₁₇	3.962 3	1.053 2	0.177 6	4.805	0.214 7	0.046 1
X ₁₈	2.457 6	0.588 7	0.102 9	4.496	0.127 1	0.016 1
X ₁₉	6.789 1	1.778 6	0.107 4	1.679	0.138 9	0.019 3
X ₂₀	4.342 8	1.200 2	0.136 1	3.424	0.164 8	0.027 1
X ₂₁	1.374 9	0.354 7	0.093 2	7.317	0.119 1	0.014 1
X ₂₂	3.495 5	0.862 9	0.118 3	3.694	0.139 1	0.193 6
X ₂₃	4.849 6	1.297 4	0.171 3	3.712	0.213 7	0.045 7
X ₂₄	2.363 2	0.575 6	0.088 8	4.082	0.113 2	0.012 8
X ₂₅	2.498 3	0.729 1	0.172 9	7.647	0.203 7	0.041 4

表4 不同模型表型测量性能对比

Table 4 Phenotypic measurement performance of different models

模型 Model	标准差 SD	平均绝对误差 MAE	平均相对误差/% MRE	均方根误差 RMSE
RTMPOSE	0.286 6	0.244 7	9.049 7	0.297 8
LiteHRNet	0.246 3	0.245 5	8.677 6	0.246 4
YOLOv12n-pose	0.237 2	0.206 2	7.284 0	0.239 0
YOLOv8n-pose	0.797 9	0.138 8	5.446 1	0.228 5

2.3 表型数据分析

通过夏皮罗-威尔克(S-W)检验法^[25]对前臀鳍体质量数据进行正态性检验。结果表明,体质量数据近似服从正态分布($P>0.05$)。基于此,采用皮尔逊相关系数(r)评估各表型参数与体质量之间的线性相关关系, $|r|$ 越接近1表明线性相关性越强,为后续表型筛选与多元回归建模提供依据。

在25项表型指标中,有22项与体质量呈较强线性相关($|r|>0.80$),其中14项的相关系数达到0.90以上,表明这些表型指标的测量值与体质量关系紧密,可用于后续分析与建模。其中,胸鳍基部起点到腹鳍基部右端起点距离(X_7)与体质量的相关性最高($r=0.981$)。相对而言,外颌须基部到胸鳍基部起点

的距离($r=0.690$)以及腹鳍基部起点到泄殖孔的距离($r=0.550$)与体质量的相关性较低。

通过计算表型与体质量的相关性系数,可以初步筛选出相关性大于0.8的表型。然而,观察发现许多体尺在鱼体上存在测量区域重合,尤其是从鱼头部末端到尾前的鱼身段,通过标注多个关键点计算得到16个近似身长的体尺,其中10个框架指标的相关系数超过0.9。为优化计算模型,利用皮尔逊相关系数计算表型特征之间的相关矩阵,结果显示相关系数超过0.9的表型参数间,相关系数处于较高水平,因此对这部分表型开展共线性分析,计算方差膨胀因子(variance inflation factor, VIF)。根据计算结果,腹鳍基部起点到脂鳍基部末端、胸鳍基部起点到

脂鳍基部末端、胸鳍基部起点到腹鳍基部起点距离等 5 个取点于胸鳍、腹鳍、脂鳍的框架指标,其 VIF 值处于极高水平(远超过 10),表明它们存在显著共线性,因此在这 5 个表型中选择与体质量相关性最高的指标—胸鳍基部起点到腹鳍基部右端起点(X_7),其相关系数为 0.981。随后,结合与已选表型(X_7)比例关系不趋同且相关系数超过 0.9 的其他表型,共同作为体质量预测模型的自变量。最终保留的表型指标为:胸鳍基部起点间距离(X_5)、胸鳍基部起点到腹鳍基部右端起点距离(X_7)、体高(X_{10})、头长(X_{12})、眼间距(X_{14}),即前臀鲢体质量的 5 个最主要影响表型指标。

根据相关性结果,对 5 个筛选出的表型做通径分

析,将表型性状对体质量的影响划分为直接影响和间接影响。由表 5 可知,胸鳍基部起点到腹鳍基部右端起点相关系数显著高于其他表型,说明该表型对体质量影响最大。根据间接分析结果,胸鳍基部起点到腹鳍基部右端起点(X_7)的直接系数和相关系数最大,分别为 0.820 和 0.981,即该框架指标对前臀鲢体质量的直接作用最明显,同时,表型 X_5 、 X_{10} 、 X_{12} 、 X_{14} 均通过 X_7 对体质量有一定的影响。眼间距(X_{14})的间接系数最大,达到了 1.059。除胸鳍基部起点到腹鳍基部右端起点(X_7)外的其他表型间接系数均大于直接系数。头长(X_{12})、眼间距(X_{14})的直接系数均为负值,表明这 2 种表型对体质量产生负向作用。

表 5 前臀鲢表型性状与体质量的通径分析

Table 5 Path analysis of phenotypic traits and body weight in *Pareuchiloglanis anteanalis*

表型 Phenotype	相关系数 Correlation coefficient	直接系数 Direct effect coefficient	间接系数 Indirect effect coefficient	间接作用拆解 Decomposition of indirect effects				
				X_5	X_7	X_{10}	X_{12}	X_{14}
X_5	0.920	0.670	0.753	—	0.752	0.203	-0.071	-0.130
X_7	0.981	0.820	0.161	0.153	—	0.221	-0.077	-0.137
X_{10}	0.949	0.233	0.761	0.145	0.778	—	-0.073	-0.134
X_{12}	0.901	-0.082	0.983	0.145	0.767	0.208	—	-0.136
X_{14}	0.914	-0.145	1.059	0.150	0.772	0.215	-0.077	—

2.4 体质量预测模型

通过绘制各表型特征与体质量的散点图(图 6),发现变量间呈现近似线性分布趋势,初步支持线性模型的适用性。进一步对残差进行检验,结果显示:正态性检验(Shapiro-Wilk, $P > 0.05$)与异方差性检验(Breusch-Pagan, $P > 0.1$)均通过,表明残差服从正态分布且方差齐性,满足线性回归核心假设。

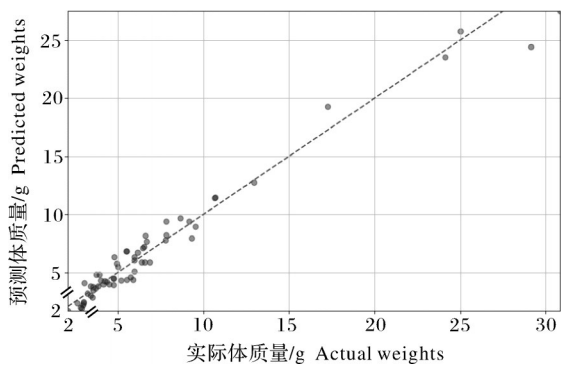


图 6 体质量预测模型散点图

Fig.6 Scatter plot of the body weight prediction model

由图 6 可知,预测体质量与实际体质量之间的相关性较高,大部分数据点聚集在完美拟合线(虚线)附近,但仍有一些点偏离较大,尤其是高体质量值部分。这可能是由于高体质量样本较少,模型在高体

质量范围内的泛化能力不足所致。

为验证线性模型的优越性,本研究额外尝试了二阶多项式回归、支持向量回归(support vector regression, SVR)和随机森林(random forest, RF)3 种非线性模型(表 6)。结果显示,二阶多项式回归虽预测精度略高($R^2=0.98$, $RMSE=1.32$),但其交叉验证误差较线性模型增加 15%,存在过拟合风险;SVR 和 RF 的 R^2 值(0.96 和 0.95)与线性模型($R^2=0.97$)接近,但模型复杂度显著提高且可解释性下降,因此线性模型仍为最优选择,根据多元回归分析结果,得到根据鱼体表型值的体质量预测模型为:

$$W = -12.46 + 1.89X_5 + 7.73X_7 + 0.33X_{10} - 2.45X_{12} - 3.42X_{14}$$

模型的 R^2 值为 0.97,表明该回归模型对实际体质量的解释力较强,约 97% 的实际体质量变异可以通过所选取的体型指标来解释。 $RMSE=1.47$, $MRE=0.14\%$,表示模型预测的体质量值与实际值之间的平均偏差较小,在预测体质量时具有较高的准确性。

由表 7 可知, R^2 随着变量的增加逐步提升,标准差(SE)从最初的 2.363 减少到最终模型的 0.989,说明随着相关变量的引入,模型的拟合度和预测精度

表6 不同预测模型的性能对比

Table 6 Performance comparison of different prediction models

模型 Model	R^2	均方根误差 RMSE	模型复杂度(参数数量) Model complexity (number of parameters)
线性回归 Linear regression	0.97	1.47	低(1截距+5表型系数,共6个) Low (1 intercept plus 5 phenotypic coefficients, six in total)
二阶多项式回归 Quadratic polynomial regression	0.98	1.32	中(1截距+5一次项+10二次项系数,共16个) Medium (1 intercept plus 5 linear-term coefficients plus 10 quadratic-term coefficients, 16 in total)
支持向量回归 Support vector regression	0.96	—	高($\approx 50\sim 63$ 个支持向量+2~3个超参数,共52~66个) High (about 50 to 63 support vectors plus 2 to 3 hyperparameters, 52 to 66 in total)
随机森林 Random forest	0.95	—	高(100棵树 \times 每棵约50个节点参数,约5000个) High (one 100 trees with about 50 decision nodes per tree, about 5 000)

提高。同时, P 值在所有模型中均为0.000,表示每个模型中的变量组合都具有显著的统计意义。

表7 逐步回归模型表现

Table 7 Performance of stepwise regression models

模型 Model	R^2	标准误差 SE	P
X_5	0.846	2.363	0.000
X_5, X_7	0.965	1.124	0.000
X_5, X_7, X_{10}	0.969	1.065	0.000
X_5, X_7, X_{10}, X_{12}	0.971	1.018	0.000
$X_5, X_7, X_{10}, X_{12}, X_{14}$	0.973	0.989	0.000

由表8可知,以体质量为因变量、以5个表型指标为自变量建立的多元线性回归模型整体达到极显著水平($F=412.3532, P<0.01$),表明所建回归模型在统计学上具有显著意义并能总体解释观测到的体质量变异。由图7可知,残差围绕零值呈随机分布,在较低至中等预测体质量范围(约5~10 g)内残差点密集且偏差较小,未见明显的系统性偏倚;同时在较高预测体质量处存在若干正向残差及个别离群点,提示模型在大体质量区间存在一定的低估倾向。

对不同体质量区间的估计误差进行分析(表9),

表8 多元回归方程的方差分析

Table 8 Analysis of variance (ANOVA) for the multiple regression equation

项目 Items	总平方和 Total sum of squares	自由度 Degrees of freedom	均方 Mean square	F	P
回归 Regression	8 096.685	5	1 619.337	412.352	$2.697\ 390 \times 10^{-62}$
残差 Residual	369.145	94	3.927 071	—	—
总计 Total	8 465.830	99	—	—	—

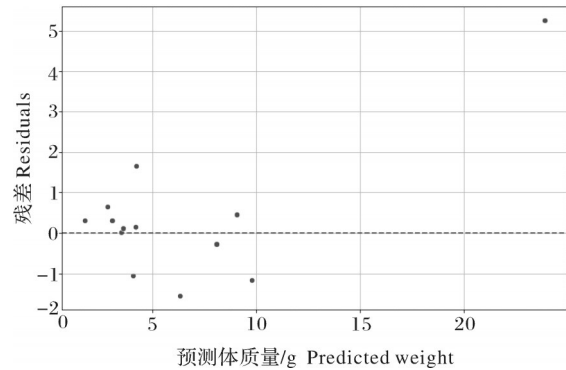


图7 体质量预测模型多元回归方程残差图

Fig.7 Residual plot of multiple regression equation for body weight prediction model

表9 不同体质量区间的预测结果分析

Table 9 Analysis of prediction results for different weight ranges

体质量/g Weight ranges	R^2	标准误差 SE	精确率 Accuracy
<5	0.965	0.489	0.931
>5, <10	0.912	0.839	0.927
>10	0.702	1.192	0.702

由于各体质量区间样本分布不一,模型性能差异明显。对于体质量小于5 g的样本,模型的决定系数(R^2)为0.965,表明模型能够很好地拟合数据,预测精度达到0.931,显示出极高的准确性。相较之下,对于体质量为5~10 g的样本, R^2 降至0.912,预测精度下降至0.927,仍表现良好。体质量超过10 g的样本的模型性能显著降低, R^2 仅为0.702,预测精度降至0.702。

3 讨论

鱼类养殖育种中,传统的人工测量表型方法普

遍面临效率低下、成本高昂、数据质量不稳定等问题。本研究中,研究对象前臀鲃属于小型鱼类,体尺数据本身较小,更容易受到人工主观判断的影响,导致测量误差增大。针对上述问题,本研究构建了基于关键点检测的自动化测量模型,实现对前臀鲃多个可量可数性状的自动获取,并提高测量效率与一致性。结果表明,该模型在前臀鲃特征点识别方面性能表现优异,精确率达到94.70%,可为前臀鲃等鲃科鱼类的自动识别与表型测量提供技术支持。

近年来,计算机视觉技术已在水产表型测量领域逐步应用,基于深度学习网络模型能够有效提取鱼类表型性状。Gümüs等^[26]使用LensEye-NET软件对欧洲鲃(*Silurus glanis*)和非洲鲃(*Clarias gariepinus*)图像进行分析,得到体长误差在1%以内。翁智等^[27]提出一种改进后的实例分割网络Mask2former,并利用该网络测得体高、十字部高、体斜长和管围4种体尺的平均相对误差分别为4.32%、3.71%、5.58%和6.25%。本研究的表型测量误差与已有研究结果总体一致。同时,在传统体尺指标之外引入基于关键点的框架距离指标,使表型表征更加丰富;全部表型的平均相对误差为5.45%。

在水产生物表型与体质量预测研究基础上,本研究采用相关性分析、通径分析与多元回归分析相结合的方法,针对前臀鲃开展了体质量预测多元回归模型研究。结果发现,胸鳍基部起点间距离、胸鳍基部起点到腹鳍基部右端起点、体高、头长和眼间距5个表型是影响前臀鲃体质量的主要因素,可作为今后选育过程中的主要考察表型性状。体质量预测模型的 R^2 值达到0.97,MRE达到0.14%,且经显著性检验表明模型拟合效果精准。

需要指出的是,本研究的数据采集与测量主要在相对可控条件下完成,复杂背景、姿态遮挡或光照变化可能对关键点定位与部分表型计算产生影响;同时,不同体质量区间样本数量差异可能影响模型在部分区间的泛化表现。后续研究可进一步扩充样本量与体质量区间覆盖范围,增加不同环境与拍摄条件下的数据验证,并在此基础上优化关键点检测的鲁棒性与体质量预测模型的适用性,以更好服务于增殖放流、选种育种及生态监测等应用场景。

参考文献 References

[1] 方树森,许涛清,崔桂华. 鲃属 *Pareuchiloglanis* 鱼类一新种[J]. 动物分类学报,1984, 9(2):209-211. FANG S M, XU T Q, CUI G H. A new species of the catfish genus *Pareuchiloglanis*

(Pisces: Sisoridae) from China[J]. Acta zootaxonomica sinica, 1984, 9(2):209-211 (in Chinese).

- [2] 冯云鹏,杨胜保,方善臣,等. 野生前臀亲鱼摄食驯化技术探究[J]. 科学养鱼,2024(5):75-77. FENG Y P, YANG S B, FANG S C, et al. Study on feeding and domestication technology of wild anterior hip parent fish[J]. Scientific fish farming, 2024(5):75-77 (in Chinese).
- [3] 姚景龙,陈毅峰,李堃,等. 中华鲃与前臀鲃的形态差异和物种有效性[J]. 动物分类学报,2006(1):11-17. YAO J L, CHEN Y F, LI K, et al. Morphological variations and species validity of *Pareuchiloglanis sinensis* and *P. anteanalis* in southwestern of China[J]. Acta zootaxonomica sinica, 2006(1):11-17 (in Chinese with English abstract).
- [4] 郭奕,黄佳芯,邓博奇,等. 改进Mask R-CNN的真实环境下鱼体语义分割[J]. 农业工程学报,2022, 38(23):162-169. GUO Y, HUANG J X, DENG B Q, et al. Semantic segmentation of the fish bodies in real environment using improved Mask-RCNN model[J]. Transactions of the CSAE, 2022, 38(23):162-169 (in Chinese with English abstract).
- [5] YU C, LIU Y P, HU Z H, et al. Precise segmentation and measurement of inclined fish's features based on U-Net and fish morphological characteristics[J]. Applied engineering in agriculture, 2022, 38(1):37-48.
- [6] FREITAS M V, LEMOS C G, ARIEDE R B, et al. High-throughput phenotyping by deep learning to include body shape in the breeding program of pacu (*Piaractus mesopotamicus*) [J]. Aquaculture, 2023, 562: 738847 [2025-07-14]. <https://doi.org/10.1016/j.aquaculture.2022.738847>.
- [7] SUO F Y, HUANG K W, LING G, et al. Fish keypoints detection for ecology monitoring based on underwater visual intelligence [C]//2020 16th International Conference on Control, Automation, Robotics and Vision (ICARCV). December 13-15, 2020. Shenzhen, China. Shenzhen: IEEE, 2020: 542-547.
- [8] KAMPFFMEYER M, SALBERG A B, JENSSEN R. Semantic segmentation of small objects and modeling of uncertainty in urban remote sensing images using deep convolutional neural networks[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). June 26-July 1, 2016, Las Vegas, NV, USA. Las Vegas: IEEE, 2016:680-688.
- [9] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(6):1137-1149.
- [10] 闫党康. 基于改进的Mask R-CNN的鱼类识别算法研究[J]. 计算机与数字工程, 2023, 51(6):1238-1243. YAN D K. Research on fish recognition algorithm based on improved mask R-CNN [J]. Computer & digital engineering, 2023, 51(6):1238-1243 (in Chinese with English abstract).

- [11] 程思奇. 基于关键点检测的水下鱼体长度测量技术研究与应用[D]. 大连: 大连海洋大学, 2023. CHENG S Q. Research and implementation of fish body length measurement technology based on keypoint detection[D]. Dalian: Dalian Ocean University, 2023 (in Chinese with English abstract).
- [12] ZHOU S Y, CAI K W, FENG Y H, et al. An accurate detection model of *Takifugu rubripes* using an improved YOLO-V7 network [J/OL]. Journal of marine science and engineering, 2023, 11 (5) : 1051 [2025-07-14]. <https://doi.org/10.3390/jmse11051051>.
- [13] 何志鹏, 巩高瑞, 熊阳, 等. 基于计算机视觉的黄颡鱼表型特征测量和体重预测模型研究[J]. 水生生物学报, 2024, 48 (7): 1149-1158. HE Z P, GONG G R, XIONG Y, et al. A phenotypic measurement and weight prediction model of *Pelteobagrus fulvidraco* based on computer vision[J]. Acta hydrobiologica sinica, 2024, 48 (7) : 1149-1158 (in Chinese with English abstract).
- [14] KOLAREVIC J, CALDUCH-GINER J, ESPMARK Å M, et al. A novel miniaturized biosensor for monitoring Atlantic salmon swimming activity and respiratory frequency [J/OL]. Animals, 2021, 11 (8) : 2403 [2025-07-14]. <https://doi.org/10.3390/ani11082403>.
- [15] MURUGAIYAN J S, PALANIAPPAN M, DURAIRAJ T, et al. Fish species recognition using transfer learning techniques [J]. International journal of advances in intelligent informatics, 2021, 7 (2) : 188 [2025-07-14]. <https://doi.org/10.26555/ijain.v7i2.610>.
- [16] 田洁, 杨信廷, 徐大明, 等. 基于深度图像的大菱鲆体重估测模型研究[J]. 中国农业科技导报, 2019, 21(9): 90-96. TIAN J, YANG X T, XU D M, et al. Research on the estimation model of *Scophthalmus maximus*' weight based on depth image [J]. Journal of agricultural science and technology, 2019, 21 (9): 90-96 (in Chinese with English abstract).
- [17] 周晖. 基于深度学习的鱼类体尺测量研究[D]. 上海: 上海海洋大学, 2022. ZHOU H. Research of fish size measurement based on deep learning[D]. Shanghai: Shanghai Ocean University, 2022 (in Chinese with English abstract).
- [18] HUSSAIN M. YOLOv1 to v8: unveiling each variant, a comprehensive review of YOLO [J]. IEEE access, 2024, 12: 42816-42833.
- [19] LI X, WANG W, WU L, et al. Generalized focal loss: learning qualified and distributed bounding boxes for dense object detection [DB/OL]. arXiv, 2006: 2006.04388 [2025-07-14]. <https://doi.org/10.48550/arXiv.2006.04388>.
- [20] 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 [2025-07-14]. <https://doi.org/10.1016/j.compag.2021.106512>.
- [21] ZHOU Y J, ZHU W G, HE Y H, et al. YOLOv8-based spatial target part recognition [C]//2023 IEEE 3rd International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA). May 26-28, 2023, Chongqing, China. Chongqing: IEEE, 2023: 1684-1687.
- [22] JIANG T, LU P, ZHANG L, et al. RtmPose: Real-time multi-person pose estimation based on mmpose [DB/OL]. arXiv, 2023: 2303.07399 [2025-07-14]. <https://doi.org/10.48550/arXiv.2303.07399>.
- [23] YU C Q, XIAO B, GAO C X, et al. Lite-HRNet: a light-weight high-resolution network [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 20-25, 2021. Nashville, TN, USA. Nashville: IEEE, 2021: 10435-10445.
- [24] MAJI D, NAGORI S, MATHEW M, et al. YOLO-pose: enhancing YOLO for multi person pose estimation using object keypoint similarity loss [C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). June 19-20, 2022. New Orleans, LA, USA. New Orleans: IEEE, 2022: 2636-2645.
- [25] SHAPIRO S S, WILK M B. An analysis of variance test for normality (complete samples) [J]. Biometrika, 1965, 52(3/4): 591-611.
- [26] GÜMÜŞ E, YILAYAZ A, KANYILMAZ M, et al. Evaluation of body weight and color of cultured European catfish (*Silurus glanis*) and African catfish (*Clarias gariepinus*) using image analysis [J/OL]. Aquacultural engineering, 2021, 93: 102147 [2025-07-14]. <https://doi.org/10.1016/j.aquaeng.2021.102147>.
- [27] 翁智, 范琦, 郑志强. 基于二维与三维的无接触式肉牛体尺自动测量方法 [J/OL]. 智慧农业, 2024, 1-12 (2024-08-06) [2025-07-14]. <http://kns.cnki.net/kcms/detail/10.1681.S.20240517.1017.002.html>. WENG Z, FAN Q, ZHENG Z Q. Automatic body size measurement method for beef cattle based on 2D and 3D contactless sensing [J/OL]. Smart agriculture, 2024, 1-12 (2024-08-06) [2025-07-14]. <http://kns.cnki.net/kcms/detail/10.1681.S.20240517.1017.002.html> (in Chinese with English abstract).

Measuring phenotype and predicting body weight of *Pareuchiloglanis anteanalis* based on keypoint detection

ZHOU Yichi¹, CHEN Yanxiang¹, LIU Jisong², XIONG Hao²,
SU Xiaojing³, YANG Qingyong¹, YANG Ruibin³, ZHENG Fang¹

1. College of Informatics, Huazhong Agricultural University, Wuhan 430070, China;
2. Yebatan Branch of Huadian Jinshajiang Upstream Hydropower Development Co., Ltd., Ganzi 627153, China;
3. College of Fisheries, Huazhong Agricultural University, Wuhan 430070, China

Abstract A method of automatically measuring the phenotype and predicting the body weight of *Pareuchiloglanis anteanalis* based on the keypoint detection was developed to improve the efficiency of obtaining the phenotypic data of *P. anteanalis* and reduce errors caused by manual measurements. 951 images were collected from the ventral, lateral, and dorsal views of *P. anteanalis*. Keypoints were annotated in the COCO format. Traditional body size including body length, body height, and interorbital distance and indexes of frame distance were calculated based on the coordinates of keypoints. RTMPOSE, LiteHRNet, YOLOv12n-pose, and YOLOv8n-pose were comparatively evaluated under the same configuration of training, and YOLOv8n-pose was determined to be used for the automatic measurement of phenotypic parameters. Results showed that YOLOv8n-pose had a precision of 94.70% on the test set, with mean relative error (MRE) of 5.45% for phenotypic measurements, and the relative error of most phenotypes was controlled within 10%. Key indexes of phenotype including the distance between pectoral-fin origins (X_5), the distance from the pectoral-fin base to the right pelvic-fin base (X_7), body height (X_{10}), head length (X_{12}), and interorbital distance (X_{14}), were further selected by combining correlation and collinearity analysis to establish a multiple regression model for predicting body-weight, yielding an R^2 of 0.97 on the test set. It is indicated that the proposed method can achieve automated measurement of phenotype and quantitative estimation of body weight of *P. anteanalis*. It will provide data support for monitoring growth and evaluating selective breeding of small sisorid freshwater fishes.

Keywords *Pareuchiloglanis anteanalis*; measuring the phenotype; computer vision; YOLOv8n-pose; keypoint detection; prediction of body weight

(责任编辑:葛晓霞)