



基于计算机视觉的大黄鱼体尺、体重性状表型 测量装置开发和应用

王禹莎¹, 王家迎¹, 辛瑞², 柯巧珍¹,
江鹏鑫¹, 周涛¹, 徐鹏^{1,3*}

(1. 厦门大学海洋与地球学院, 福建省海洋生物遗传育种重点实验室, 福建 厦门 361102;

2. 厦门大学航空航天学院, 福建 厦门 361005;

3. 大黄鱼育种国家重点实验室, 福建 宁德 352103)

摘要: 鱼类的体重、体长等表型性状是水产养殖和遗传育种中非常重要的经济性状, 为了避免人工测量的不确定性、误差随机性和效率低下的问题, 本研究开发出一种基于 Mask Region Convolutional Neural Network (Mask R-CNN) 的自动化、无侵入式鱼类图像分割和表型性状测量的装置。该装置包括图像采集装置和控制软件两部分, 其中图像采集装置可以测量不同规格鱼类(体长 1~40 cm)。基于 Mask R-CNN 的控制软件, 可以对图片进行目标性状的训练和预测, 实现目标数据的测量、存储和管理。本研究利用该装置对 477 尾 3 月龄大黄鱼进行了图像采集和基于大黄鱼图像的体长、体高、体重性状预测。研究表明, 利用该装置测量的大黄鱼体长和体高的平均相对误差均小于 4%。基于体长、体高、体表面积的多元回归模型对体重进行拟合, 测量值与真实体重的相关系数为 0.99, 平均相对误差为 4%, 对每张图片的平均处理时间为 3 s, 测量速率是人工的 8 倍。该系统可以实现自动化、高效、准确地获取大黄鱼体型与体重性状, 为大黄鱼种质资源评价、良种选育和种质创新提供更加便捷高效的表型测评工具。

关键词: 大黄鱼; 图像分析; 体尺性状; 体重估测

中图分类号: S 951.2

文献标志码: A

大黄鱼 (*Larimichthys crocea*) 是中国海水养殖产量最大的鱼类, 2021 年产量达到 25 万 t^[1]。体型作为一个重要的经济性状, 修长、偏瘦的大黄鱼往往更受到消费者的青睐。但复杂的水环境导致获取鱼体型信息只能在陆地上进行测量, 且大黄鱼体型与体长、体高、头长等多个体尺性状相关, 利用游标卡尺进行人工测量存在误差大、耗时长的缺点, 难以进行大规模测量, 限制了大黄鱼体型性状的遗传改良^[2-4]。因此, 开发一种低成本

本、方便快捷的测量装置和方法对大黄鱼体型性状的遗传选育具有重要意义。

基于计算机的图片识别已在人类和部分动植物研究中广泛应用, 如图像分类(猫狗分类等)^[5-7]、个体识别(人脸识别等)^[8-9]和表型识别(水稻株高、玉米棒数量识别等)^[10-11], 而在鱼类研究应用中较少。Strachan^[12]最早将计算机视觉技术应用于鱼类体尺性状测量的研究, 通过控制拍摄时的照明条件, 采用简单的光照阈值来检测鱼类体长。

收稿日期: 2022-08-23 修回日期: 2022-10-18

资助项目: 国家重点研发计划(2022YFD2401001); 福建省科技重大专项(2020NZ08003); 福建省种业创新与产业化项目(2021FJSCZY01); 国家杰出青年科学基金(32225049)

第一作者: 王禹莎(照片), 从事智能仪器与装备研究, E-mail: Sia_YS_Wang@163.com

通信作者: 徐鹏, 从事鱼类基因组与遗传育种研究, E-mail: xupeng@xmu.edu.cn



Abdullah 等^[13]通过边缘和角检测法对短体羽鳃鲐 (*Rastrelliger brachysoma*)、脂眼凹肩鲈 (*Selar crumenophthalmus*) 进行头部和尾部的位置估计, 再用这些信息估算鱼体长度。2018年, 杨杰超等^[14]利用鱼体轮廓点和包络线的距离关系, 计算轮廓上重要分界点间的距离关系, 得到了大黄鱼的体长、体宽、尾鳍长的测量值。这些方法的共同特点都要求拍摄环境归一化, 通过阈值分割或边缘/角检测等传统技术提取相关鱼体特征, 但在面对较为复杂的真实生产环境以及多样化的形态学特征提取中, 泛化能力具有一定的局限性。计算机的不断发展带来图像识别技术的提升, 通过机器学习可以更高效、精准地获取图像信息。例如, LeNet、AlexNet、GoofLeNet 和 YOLO 等技术已被用于鱼类分类^[15-17]。龚瑞^[18]提出了基于 Faster R-CNN 模型训练得到对虾头部、胸甲部以及尾部的关键点, 进而获得体长、头胸甲长和头胸甲宽 3 个参数的测量值。鱼体重与体尺性状存在显著相关。已有研究表明, 鱼类体尺性状和体重之间具有 $W=qL^n$ 的关系^[19], 其中 q 是与鱼体体积占比相关的常数。Balaban 等^[20]使用图像处理技术预测不同鲑类的体质量, 测定系数为 0.93~0.99, 这表明可以用体尺性状预测鲑的体重, 但每个物种由于其体貌的独特性, 体尺与体重模型存在差异。

本研究拟建立大黄鱼标准化体尺与体重测量平台, 基于计算机视觉和深度学习技术对大黄鱼图片进行体尺性状预测, 实现基于大黄鱼图像进行体长、体高和其他关键体尺性状预测和准确性评估, 并通过体表面积建立评估大黄鱼体重预测的最佳模型, 为大黄鱼精准高效体尺性状的测量提供参考。

1 材料与方法

1.1 实验对象

大黄鱼样本来源于福建省宁德市富发水产有限公司。本实验随机从 4 个海上网箱采集 477 尾 3 月龄的大黄鱼作为研究对象。

1.2 图片采集

为了快速获取高质量大黄鱼图片, 设计开发了一种大黄鱼图像分割和表型性状测量装置, 该装置分为图像采集装置和控制软件。其中图像采集装置作为硬件部分, 其核心组成部件包括摄影

箱、图像捕获装置和散热装置。

图像采集装置采用 MV-CA050-20UC 工业相机搭配 ZX-SF1614S 镜头, 可通过无线与有线两种方式与上位机进行数据传输, 并由控制软件进行大黄鱼图像数据的人机交互管理。在拍摄前, 先用 MS 222 麻醉剂将鱼麻醉, 然后利用图像获取装置连续快速捕捉大黄鱼图像, 同时, 利用游标卡尺和高精度电子天平对每条大黄鱼样本进行体长、体高、体重的性状测量和记录, 用于后续算法和模型准确性的评估。

1.3 构建图像训练集

为了构建图像识别的训练集, 本研究利用图像标注工具 Labelme 对 477 尾大黄鱼图像进行两类性状的人工标注, 一是生长相关性状, 包括体长 (BL)、体高 (BH); 二是体型相关的体尺性状, 包括如图 1 所示 P_1 ~ P_{12} 共 12 个形态学特征点。其中, 特征点以 2 个点为 1 组进行多目标类别标注。

对每尾鱼的图像按高斯模糊、椒盐噪声和 γ 变换随机参数各生成 3 张图像, 最后获得 4293 张鱼体图像数据。从中随机选取 3843 张作为训练集, 450 张作为测试集, 用于后续训练和预测。增强后的鱼体图像见图 2。

1.4 构建图像模型

本研究选择 Mask R-CNN 网络进行实例分割 (图 2)。首先, 将训练集中的图片传入预训练的神经网络中 (ResNet101), 获得相应的特征图。然后, 通过特征图中的每一点设定感兴趣区域 (ROI), 获得多个 ROI 候选框, 在 Region Proposal Network (RPN) 中对候选框进行二值分类和 Bounding-box regression。最后, 对剩余的 ROI 进行 ROI Align, 对这些 ROI 进行类别分类、目标区域分割和相关参数输出, 用于后续测试集大黄鱼形态学参数检测和体质量性状的拟合。

在训练阶段, 根据 Mask R-CNN 的分类、定位以及掩膜分割三个输出, 对训练集中图像的兴趣区域进行多任务损失函数 (multi-task loss function) 定义:

$$L = L_{\text{cla}} + L_{\text{box}} + L_{\text{mask}}$$

式中, L_{cla} 为分类损失, L_{box} 为定位损失, 使用 softmax 进行分多类。在 mask 分支中, 对每个兴趣区域的输出为 $K \times m^2$, 表示 K 个尺寸为 $m \times m$ 的二值掩膜, K 为物体类别个数。掩膜的损失函

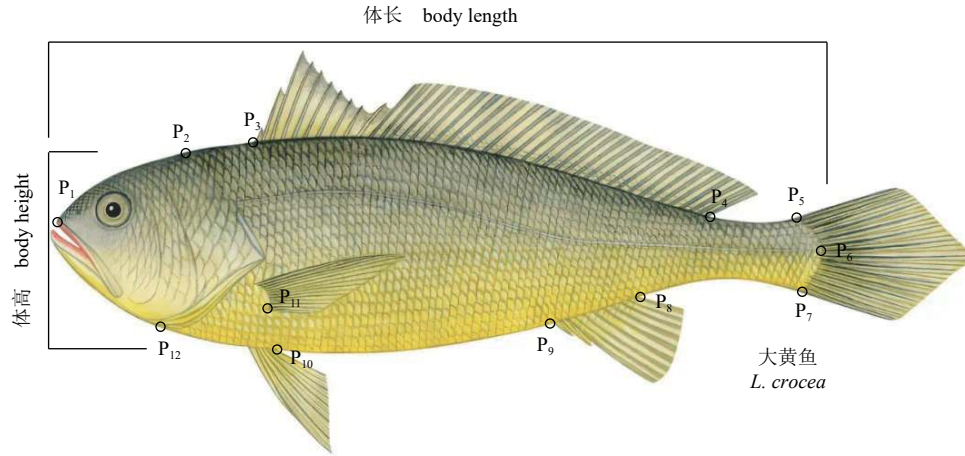


图 1 大黄鱼体型性状测量形态学

P₁. 吻端, P₂. 鳃盖上线, P₃. 背鳍基部前端, P₄. 背鳍基部后端, P₅. 尾鳍基部上端, P₆. 尾鳍基部与侧线交点, P₇. 尾鳍基部下端, P₈. 臀鳍基部后端, P₉. 臀鳍基部前端, P₁₀. 左腹鳍基部, P₁₁. 左胸鳍基部, P₁₂. 鳃盖下线

Fig. 1 Morphological traits measurement of *L. crocea*

P₁. caudal end, P₂. upper edge of gill cover, P₃. anterior end of dorsal fin base, P₄. posterior end of dorsal fin base, P₅. superior end of caudal fin base, P₆. intersection of caudal fin base and measuring line, P₇. inferior end of caudal fin base, P₈. posterior end of anal fin base, P₉. anterior end of anal fin base, P₁₀. base of left ventral fin, P₁₁. base of left pectoral fin, P₁₂. inferior edge of gill cover

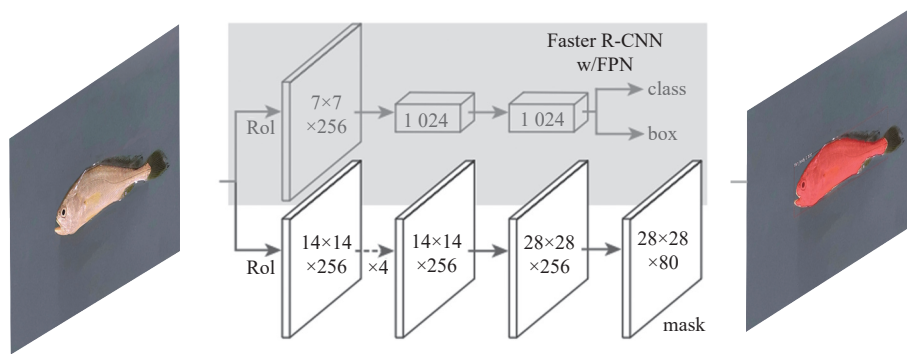


图 2 Mask R-CNN 网络结构^[21]

Fig. 2 Mask R-CNN network architecture

数定义为平均二值交叉熵损失 L_{mask} 。 L_{mask} 只定义对应类别的掩膜损失, 其他类别的掩膜输出不会影响该类别的损失值, 防止在兴趣区域上类之间的竞争。

将测试集输入到经过训练集训练的模型中, 得到分割后的图像和目标帧相关参数。然后, 通过计算检测帧中的像素数, 映射到实际鱼体形态学参数, 得到相应的体尺性状测量结果。最后, 基于分割后的图像进行鱼体侧表面积的计算, 通过统计学方法拟合得到估测体重。整体算法工作流程如图 3 所示。

1.5 基于图像的体尺性状测量

体尺性状特征参数测量如图 4 所示, 图中的两个区域分别表示检测框和分割对象总区域。

$P_0(x_0, y_0)$ 和 $P_2(x_2, y_2)$ 分别表示检测框左上角和右下角的点坐标。 $\overline{P_0P_1}$ 和 $\overline{P_1P_2}$ 分别代表检测框长、宽像素数。

为实现体尺性状关键点位置的确定, 实验中使用式 (1) 来计算实际拍摄区域长度 (600 mm) 与照片对应像素数之间的换算比例 θ 。通过训练后的深度学习模型, 可以得到每张测试图片目标分割特征区域的准确检测框。通过得到左上点和右下点的坐标, 利用式 (2) 和式 (3) 计算出目标区域像素的长和宽。最后, 利用式 (4) 和式 (5) 得到的像素点数相乘, 得到目标性状的实际长度。

$$\theta = \frac{L}{n} \tag{1}$$

$$\overline{P_0P_1} = x_0 - x_2 \tag{2}$$

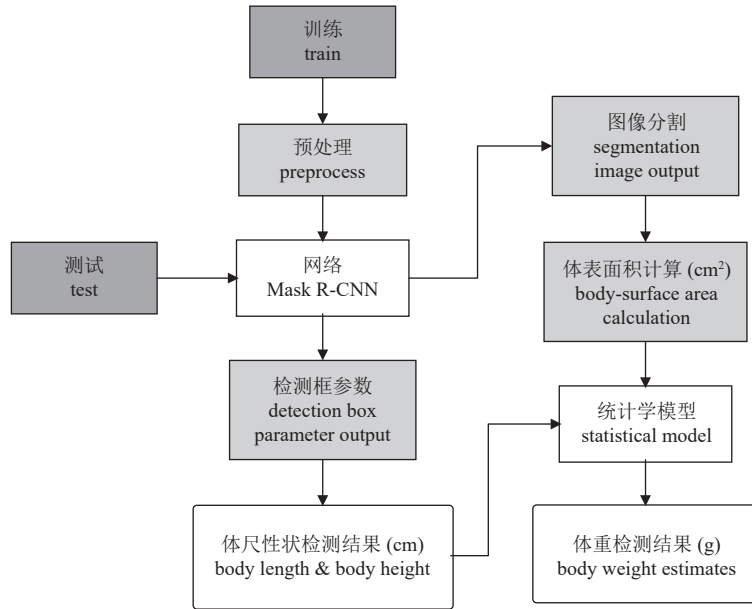


图 3 整体算法工作流程
Fig. 3 Overall flowchart

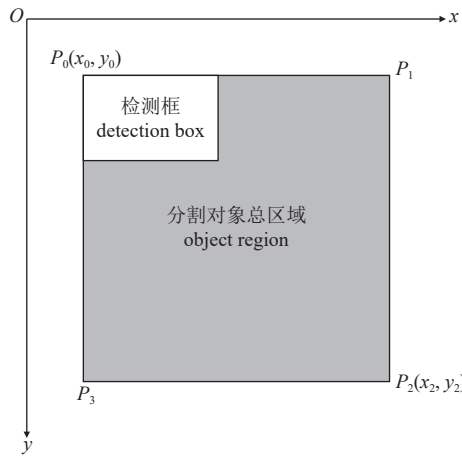


图 4 特征参数检测示意图

Fig. 4 Schematic diagram of feature parameter detection

$$\overline{P_1P_2} = y_0 - y_2 \quad (3)$$

$$L_{\text{real}} = \overline{P_0P_1} \times \theta \quad (4)$$

$$W_{\text{real}} = \overline{P_1P_2} \times \theta \quad (5)$$

式中, L 代表实际拍摄区域的长度, n 代表图像长度中的像素数, L_{real} 代表映射到实际长度后的计算长度, W_{real} 代表映射到实际宽度后的计算宽度。

以 0.02 mm 精度游标卡尺的人工测量结果作为大黄鱼体长、体高的真实值, 对测试集中的 50 张图片进行检测。将检测结果与真实值对比, 得到检测误差。分别计算最大绝对误差 (MaAE)、最大相对误差 (MaRE)、最小绝对误差 (MiAE)、最小相对误差 (MiRE)、平均绝对误差 (MAE) 和平均

相对误差 (MRE), 用于体尺性状检测结果评估。

1.6 基于图像的体重估测

利用神经网络输出的检测框进行鱼体分割, 使用最大类间方差法选取默认阈值进行二值化处理, 选择最大联通域为鱼体用于后续分析。为进一步提高目标区域提取的准确性, 针对分割后的图像采用先开运算式 (6)、后闭运算式 (7) 的形态学处理。

$$\text{dist} = \text{open}(\text{src}, \text{element}) = \text{dilate}[\text{erode}(\text{src}, \text{element})] \quad (6)$$

$$\text{dist} = \text{close}(\text{src}, \text{element}) = \text{erode}[\text{dilate}(\text{src}, \text{element})] \quad (7)$$

基于分割后的鱼体, 按照如下流程对鱼体侧面积进行计算, 并预测鱼体重量性状: 首先, 对根据预测框分割后的二值化黑白图像进行遍历。其次, 对图像中白色像素部分精确计数, 得到白色像素点个数 a 。再次, 计算白色像素个数占图像总像素 I 的比例 p 。

然后, 根据图像像素与现实中的长度的对应规律计算出整张图像对应的实际面积 S_{all} , 其中鱼体占比 p 所对应的面积即为大黄鱼鱼体侧表面积, 具体公式见式 (8) 和式 (9)。

$$p = \frac{a}{I} \quad (8)$$

$$S = S_{\text{all}} \times p \quad (9)$$

根据鱼体表面积 S 、体长 L 、体高 H 和体重 M

之间的常用数学模型 [式 (10)~式 (12)], 基于训练集计算出各参数, 利用各参数计算出测试集鱼体重性状。

$$\text{多项式: } M = a + bS + cL + dH \quad (10)$$

$$\text{线性: } M = a + bS \quad (11)$$

$$\text{幂函数: } M = aS^b \quad (12)$$

最后, 为了确定拟合效果最佳的数学模型, 以 0.02 g 高精度电子天平人工测量结果为真实值, 使用有体重记录的 277 个个体数据作为样本进行拟合。计算 R^2 、 P -value 统计量、均方根误差 (MSE)、MAE、MRE、MaAE、MaRE 这 7 个指标 (13~17), 用于评估不同模型的拟合效果。

$$\text{MSE} = \sqrt{\frac{\sum_{i=1}^N [W_{\text{estimated},i} - W_{\text{measured},i}]^2}{N}} \quad (13)$$

$$\text{MAE} = \frac{\sum_{i=1}^N |W_{\text{estimated},i} - W_{\text{measured},i}|}{N} \quad (14)$$

$$\text{MRE} = \frac{\sum_{i=1}^N |W_{\text{estimated},i} - W_{\text{measured},i}| / W_{\text{measured},i}}{N} \times 100 \quad (15)$$

$$\text{MaAE} = \max_{i=1}^N (|W_{\text{estimated},i} - W_{\text{measured},i}|) \quad (16)$$

$$\text{MaRE} = \max_{i=1}^N \left(\frac{|W_{\text{estimated},i} - W_{\text{measured},i}|}{W_{\text{measured},i}} \right) \quad (17)$$

2 结果

2.1 体尺检测结果

本研究共得到 477 尾大黄鱼体型数据, P_4P_8 的检出率最高, 为 99.3%; P_7P_{12} 的检出率最低, 为 90.2%, 其他形态学参数检出结果如表 1 所示。

表 1 体尺性状检出率

Tab. 1 Detection rate of morphological traits

体尺性状 morphological traits	BL	BH	P_2P_{12}	P_3P_{10}	P_4P_8	P_5P_7	P_1P_6	P_1P_2	P_9P_{10}	P_7P_{12}	P_2P_5
漏检数 number of misses	0	0	20	20	2	9	11	5	20	27	13
检出率/% detection rate	100.00	100.00	92.80	92.80	99.30	96.80	96.00	98.20	92.80	90.20	95.30

注: BH. 体高, BL. 体长, 下同
Notes: BH. body height, BL. body length, the same below

体长、体高检测的相对误差如图 5 所示。体长相对误差整体低于体高相对误差, 大部分个体的体长相对误差在 6% 以内, 体高相对误差在 9% 以内, 两性状平均相对误差均约为 3%, 没有出现剧烈波动的异常数据, 说明系统没有出现误检情况, 系统检测精度能够达到设计需求。

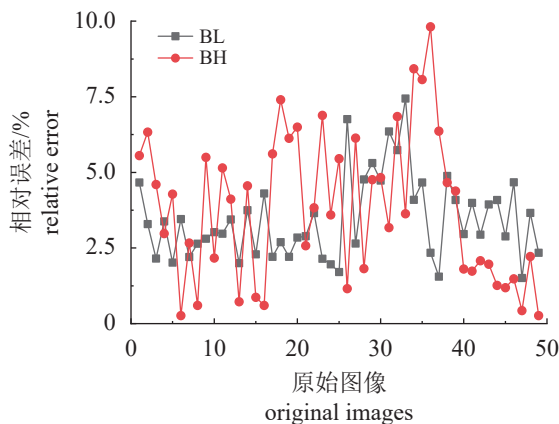


图 5 体长和体高检测的相对误差

Fig. 5 Relative error in body length and body height detection

体长、体高性状的检测误差结果如表 2 所示, 可以看出, 体长检测最大相对误差为 7.44%, 最小相对误差为 1.51%, 平均相对误差为 3.45%。体高检测最大相对误差为 9.81%, 最小相对误差为 0.27%, 平均相对误差为 3.82%。

为了评估 Mask R-CNN 算法性能, 比较 Mask R-CNN 算法与传统算法、深度学习的鱼体分割算法在大黄鱼体型性状预测上的性能差异。Mask R-CNN 算法在体长与体高性状预测方面的准确性分别为 96.55% 和 96.71%, 高于 Canny 和 SLIC 预测准确性, 与 Fast-RCNN 算法预测准确性性能相似。Mask R-CNN 算法在大黄鱼体长、体高性状估算的误差远低于其他三种算法。这些结果表明与 Canny、SLIC 和 Fast-RCNN 算法相比, Mask R-CNN 算法更适用于大黄鱼体长、体高的估算 (表 3)。

2.2 体重估测结果

对公式 (8)~(10) 数学模型的相关系数进行拟合, 得到如下公式。

$$\text{Polynomial: } M = -6.68045 + 0.53827S + 0.55207L + 1.03386H \quad (18)$$

表 2 体长体高检测误差

Tab. 2 Detection error of body length and body height

性状 features	最大绝对误差/cm MaAE	最大相对误差/% MaRE	最小绝对误差/cm MiAE	最小相对误差/% MiRE	平均绝对误差/cm MAE	平均相对误差/% MRE
体长/cm BL	0.62	7.44	0.12	1.51	0.28	3.45
体高/cm BH	0.21	9.81	0.01	0.27	0.09	3.82

$$\text{Linear: } M = 0.72643 - 2.58021S \quad (19)$$

$$\text{Power curve: } M = 0.24556S^{1.29823} \quad (20)$$

表 4 为不同的体重预测模型公式 (18)~(20) 对应的结果误差。各模型预测结果均与人工测量

表 3 不同算法对体长体高的误差及准确性

Tab. 3 The error and precision of different algorithms for

算法 method	误差 MSE		准确性 precision		
	BL	BH	BL	BH	
					%
Canny	5.74	4.23	88.12	90.20	
SLIC	4.81	5.63	89.25	91.36	
Fast-RCNN	3.65	3.96	97.10	95.60	
Mask R-CNN	3.45	3.82	96.55	96.71	

表 4 不同数学模型对体重拟合的结果

Tab. 4 Results of mass fittings of different statistical models

模型 equation	均方根误差/g RMSE	平均绝对误差/g MAE	平均相对误差/% MRE	R^2	最大绝对误差/g MaAE	最大相对误差/% MaRE	P
多项式 polynomial	0.35	0.26	3.00	0.99	1.76	28.00	<0.001
线性 linear	0.54	0.34	4.00	0.97	3.28	35.00	<0.001
幂 power curve	0.54	0.34	4.00	0.97	2.28	35.00	<0.001

3 讨论

与传统的人工测量相比, 计算机视觉技术具有高通量、高效益、高精准确性的优势^[22]。在系统识别过程中, 特征测量的标准化在提升运算速率的同时提高了估计精度^[23]。对于大黄鱼的遗传改良而言, 形态学参数是重要的经济性状和繁殖目标, 因为它们不仅反映该鱼的健康情况, 同时强烈影响消费者的购买意愿, 因此在繁育过程中, 会人为地选择体型修长的鱼进行繁育^[24-25]。但在实际研究中, 获取鱼类体型信息是非常困难的, 依靠人工只能简单测量体长和体重性状, 不能获取其他体型信息, 且人工测量标准不一、误差较大, 大大降低了测量效率和商业应用价值。因此, 本研究开发大黄鱼图像数据采集装置, 并基于 Mask R-CNN 网络框架提出了一种大黄鱼体型检

测算法, 除了可以对体长、体高等 12 个形态学特征点位置进行检测以外, 还可以预测体重性状。在水产应用领域, 利用机器学习处理图像的技术有很多, 例如 SVM^[26-27]、KNN^[28]、AdaBoost^[29]、YOLOv3^[30] 和 Fast-RCNN^[31] 等。其中, CNN 作为机器学习中最流行的模型, 在体尺性状检测中应用最为广泛, 能够有效解决目标区域重叠的问题, 实现高精度预测^[3]。CNN 模型主要包括改进模型和混合模型, 基于检测精度、速度等各方面性能综合考虑, 实验选择 Mask R-CNN 深度学习框架作为图像处理算法, 该方法由 He 等^[21] 在 IEEE International Conference on Computer Vision (ICCV) 中提出。该框架在 Faster R-CNN^[32] 基础框架上, 用 RoIAlign 代替 RoIPooling, 使得特征图与原始图位置对应更加准确, 精确度提升; 同时, 模型

结果没有显著差异 ($P < 0.01$)。其中, 多项式模型拟合效果最好 ($R^2 = 0.99$, MaRE=3%, MxRE=28%), 优于线性模型和幂函数模型。后二者的 R^2 为 0.97, 平均相对误差为 4%, 均方差为 0.54。

图 6 为分别使用线性和非线性回归模型根据鱼体表面积对体重进行拟合的结果, 图中点的颜色表示预测情况, 黑色表示在正常范围内, 红色反之。从图中可以看出, 鱼体表面积与体重的相关性为 0.97。

为了进一步对比系统检测和人工检测的效率, 分别统计基于游标卡尺的人工检测方法和基于系统检测方法在一尾鱼的体长、体高测量中所需的时间。结果显示, 人工检测每条鱼平均耗时 38 s, 系统检测平均耗时 3 s, 检测速率相差悬殊, 系统检测效率约是人工检测的 8 倍。

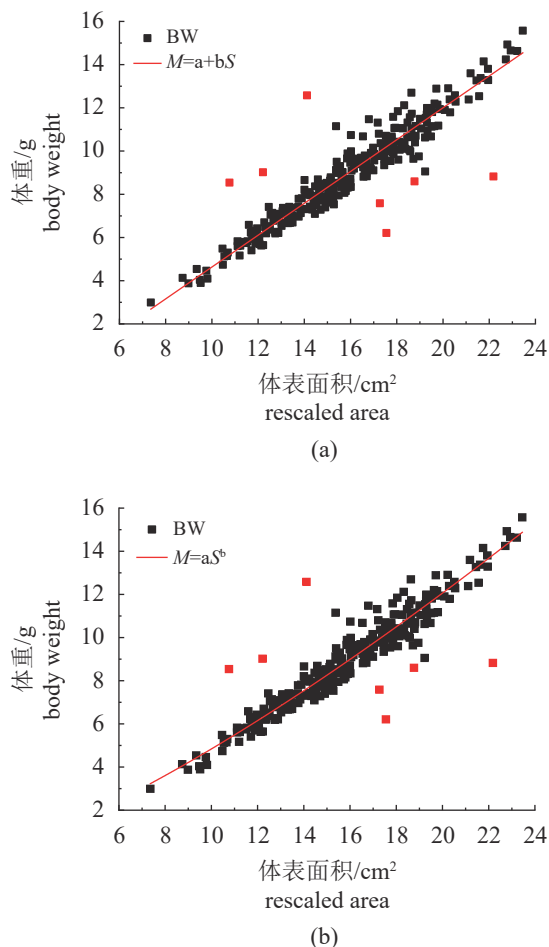


图6 鱼体表面积与体重之间的回归关系

(a) 线性回归, (b) 非线性回归

Fig. 6 Regression relationships between body weight and fish body surface area

(a) linear regression, (b) nonlinear regression

中添加了全卷积神经网络 (fully convolutional network, FCN), 可同时完成目标检测、目标分类、像素级目标分割三任务。检测精度对于体尺性状检测算法而言非常重要。原始数据的采集是决定算法精度最关键的步骤之一。其中, 标准化光照尤为重要^[14]。Hsieh 等^[33]利用霍夫变换计算金枪鱼的长度, 提出的算法对 600 幅金枪鱼图像的检测平均误差为 $4.5\% \pm 4.4\%$ 。Monkman 等^[34]使用不同框架下的 R-CNN 模型对舌齿鲈 (*Dicentrarchus labrax*) 的体长进行检测, 并结合 OpenCV 提高图像计算精度, 平均误差为 2.2%, 但该模型仅适用于鲈。Munoz-Benavent 等^[35]使用立体视觉系统对大西洋蓝鳍金枪鱼 (*Thunnus thynnus*) 的体长进行测量, 平均误差为 3%。房舒^[36]基于深度学习方法, 对鱼类体长和全长测量的平均相对误差的精度在

4% 以内。黄康为^[37]基于机器视觉对水下鱼类进行体长和体宽的预测, 相对误差分别为 4.7% 和 9.2%。本研究体长、体高预测的精度与以往研究基本一致。

体重是衡量鱼类生长速率和经济价值最直观的性状, 鱼体表面积与体重存在显著相关, 有研究对 4 种纳氏白鲢 (*Coregonus nelsonii*) 的体重进行预测, 发现体重与体表面积的相关系数为 0.93~0.99^[20]。杨杰超等^[14]发现基于体长来预测大黄鱼体重比全长预测体重更准确, 其体长与体重的相关性达到 0.9992。本研究评估线性、幂函数、多项式这三个模型对大黄鱼的体重预测效果, 发现基于体表面积、体长和体高三个指标的多项式拟合效果最好, 相关系数达到 0.99, 平均相对误差为 3%, 而基于体表面积的线性模型和幂函数模型计算的相关系数分别为 0.97 和 0.97, 说明用于体重预测的体型信息越多, 体重预测越准确。鱼类体重不仅取决于形状和体积, 也取决于内脏百分比、内脏脂肪的占比等^[38-40], 而这些信息无法从图像中获取, 需要采取其他方法, 如超声波测量等来解决^[38]。在大黄鱼养殖中, 繁殖期的雌雄亲鱼之间体型差异很大, 内脏和脂肪占比也不同, 受样本组成和样本量的影响, 本研究仅使用 3 月龄 (体重 2~16 g) 的大黄鱼进行体重预测, 其拟合模型只能用于相同月龄或相同规格鱼类。因此, 有必要测量不同月龄的大黄鱼, 丰富扩大训练集样本量, 使得测量装置可以用于不同月龄大黄鱼体重性状预测。

高效便捷一直是研究者所关注的重要评价指标, 本实验结果表明, 使用本研究算法进行检测, 检测速率为 3.0 s/条, 而手持游标卡尺进行检测, 检测速率为 38.0 s/条。系统检测的效率是人工检测的 8 倍以上, 且人工检测难以做到速度和准确性的同时提高。

本研究提出的算法具有可扩展性, 在将来的研究中, 拟在系统内纳入更丰富的大黄鱼表型性状检测功能, 如体色评价分级等; 并进一步优化拍摄装置, 以提升原始数据集质量, 提高检测精度。

(作者声明本文无实际或潜在的利益冲突)

参考文献 (References):

[1] 农业农村部渔业渔政管理局, 全国水产技术推广总站,

- 中国水产学会. 2021 中国渔业统计年鉴 [M]. 北京: 中国农业出版社, 2021: 21-26.
- Bureau of Fishery Administration of the Ministry of Agriculture and Rural Affairs, National Fisheries Technology Extension Center, China Society of Fisheries. China fishery statistical yearbook 2021[M]. Beijing: China Agriculture Press, 2021: 21-26 (in Chinese).
- [2] Palaiokostas C. Predicting for disease resistance in aquaculture species using machine learning models[J]. *Aquaculture Reports*, 2021, 20: 100660.
- [3] Zhao S L, Zhang S, Liu J C, *et al.* Application of machine learning in intelligent fish aquaculture: a review[J]. *Aquaculture*, 2021, 540: 736724.
- [4] Zhou C, Xu D M, Chen L, *et al.* Evaluation of fish feeding intensity in aquaculture using a convolutional neural network and machine vision[J]. *Aquaculture*, 2019, 507: 457-465.
- [5] Beucher A, Møller A B, Greve M H. Artificial neural networks and decision tree classification for predicting soil drainage classes in Denmark[J]. *Geoderma*, 2019, 352: 351-359.
- [6] Schauland S, Kummert A, Park S B, *et al.* Vision-based pedestrian detection - improvement and verification of feature extraction methods and SVM-based classification[C]//Proceedings of the IEEE Intelligent Transportation Systems Conference. Toronto, Canada: IEEE, 2006: 97-102.
- [7] 谢素仪. 宠物猫脸检测的方法研究 [D]. 上海: 上海交通大学, 2010.
- Xie S Y. Research on pet-cat face detection algorithm[D]. Shanghai: Shanghai Jiao Tong University, 2010 (in Chinese).
- [8] Déniz O, Bueno G, Salido J, *et al.* Face recognition using Histograms of Oriented Gradients[J]. *Pattern Recognition Letters*, 2011, 32(12): 1598-1603.
- [9] Srikantaswamy R, Samuel R D S. A novel face segmentation algorithm from a video sequence for real-time face recognition[J]. *EURASIP Journal on Advances in Signal Processing*, 2007: 051648.
- [10] Giménez-gallego J, González-teruel J D, Jiménez-buendía M, *et al.* Segmentation of multiple tree leaves pictures with natural backgrounds using deep learning for image-based agriculture applications[J]. *Applied Sciences*, 2019, 10(1): 202.
- [11] Xiong J B, Yu D Z, Liu S Y, *et al.* A review of plant phenotypic image recognition technology based on deep learning[J]. *Electronics*, 2021, 10(1): 81.
- [12] Strachan N J C. Length measurement of fish by computer vision[J]. *Computers and Electronics in Agriculture*, 1993, 8(2): 93-104.
- [13] Abdullah N, Shafry M, Rahim M S M, *et al.* Measuring fish length from digital images (FiLeDI)[C]//Proceedings of the 2nd International Conference on Interaction Sciences: Information Technology, Culture and Human. Seoul, Korea: ACM, 2009: 38-43.
- [14] 杨杰超, 许江淳, 陆万荣, 等. 基于计算机视觉的大黄鱼体尺测算与体质量估测[J]. *中国农机化学报*, 2018, 39(6): 66-70.
- Yang J C, Xu J C, Lu W R, *et al.* Computer vision-based body size measurement and weight estimation of large yellow croaker[J]. *Journal of Chinese Agricultural Mechanization*, 2018, 39(6): 66-70 (in Chinese).
- [15] Chen G, Sun P, Shang Y. Automatic fish classification system using deep learning[C]//Proceedings of the 2017 IEEE 29th International Conference on Tools with Artificial Intelligence (ICTAI). Boston, USA: IEEE, 2017: 24-29.
- [16] Meng L, Hirayama T, Oyanagi S. Underwater-drone with panoramic camera for automatic fish recognition based on deep learning[J]. *IEEE Access*, 2018, 6: 17880-17886.
- [17] Villon S, Mouillot D, Chaumont M, *et al.* A Deep learning method for accurate and fast identification of coral reef fishes in underwater images[J]. *Ecological Informatics*, 2018, 48: 238-244.
- [18] 龚瑞. 基于计算机视觉的鱼虾识别和形态参数测量 [D]. 厦门: 厦门大学, 2018.
- Gong R. Fish recognition and morphological parameters measurement of prawn based on computer vision[D]. Xiamen: Xiamen University, 2018 (in Chinese).
- [19] Bidder G P. Constant differential growth-ratios and their significance[J]. *Nature*, 1925, 115(2883): 155-156.
- [20] 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.
- [21] He K M, Gkioxari G, Dollár P, *et al.* Mask R-CNN[C]//Proceedings of IEEE International Conference
- 中国水产学会主办 sponsored by China Society of Fisheries

- on Computer Vision. Venice, Italy: IEEE, 2017: 2980-2988.
- [22] Brosnan T, Sun D W. Improving quality inspection of food products by computer vision—a review[J]. *Journal of Food Engineering*, 2004, 61(1): 3-16.
- [23] Blonk R J W, Komen J, Tenghe A, *et al.* Heritability of shape in common sole, *Solea solea*, estimated from image analysis data[J]. *Aquaculture*, 2010, 307(1-2): 6-11.
- [24] Gjedrem T. Flesh quality improvement in fish through breeding[J]. *Aquaculture International*, 1997, 5(3): 197-206.
- [25] Navarro A, Zamorano M J, Hildebrandt S, *et al.* Estimates of heritabilities and genetic correlations for body composition traits and G × E interactions, in gilthead seabream (*Sparus auratus* L.) [J]. *Aquaculture*, 2009, 295(3-4): 183-187.
- [26] Tang Q, Qiu W, Zhou Y C. Classification of complex power quality disturbances using optimized S-transform and kernel SVM[J]. *IEEE Transactions on Industrial Electronics*, 2020, 67(11): 9715-9723.
- [27] Zhou C, Zhang B H, Lin K, *et al.* Near-infrared imaging to quantify the feeding behavior of fish in aquaculture[J]. *Computers and Electronics in Agriculture*, 2017, 135: 233-241.
- [28] Jia B B, Zhang M L. Multi-dimensional classification via *k*NN feature augmentation[J]. *Pattern Recognition*, 2020, 106: 107423.
- [29] Tharwat A, Hemedan A A, Hassanien A E, *et al.* A biometric-based model for fish species classification[J]. *Fisheries Research*, 2018, 204: 324-336.
- [30] Cai K W, Miao X Y, Wang W, *et al.* A modified YOLOv3 model for fish detection based on MobileNetv1 as backbone[J]. *Aquacultural Engineering*, 2020, 91: 102117.
- [31] Prasetyo E, Suciati N, Faticah C. A comparison of YOLO and mask R-CNN for segmenting head and tail of fish[C]//Proceedings of the 2020 4th International Conference on Informatics and Computational Sciences (ICI-CoS). Semarang, Indonesia: IEEE, 2020: 1-6.
- [32] Ren S, He K, Girshick R B, *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.
- [33] Hsieh C L, Chang H Y, Chen F H, *et al.* A simple and effective digital imaging approach for tuna fish length measurement compatible with fishing operations[J]. *Computers and Electronics in Agriculture*, 2011, 75(1): 44-51.
- [34] Monkman G G, Hyder K, Kaiser M J, *et al.* Using machine vision to estimate fish length from images using regional convolutional neural networks[J]. *Methods in Ecology and Evolution*, 2019, 10(12): 2045-2056.
- [35] Muñoz-Benavent P, Andreu-García G, Valiente-González J M, *et al.* Enhanced fish bending model for automatic tuna sizing using computer vision[J]. *Computers and Electronics in Agriculture*, 2018, 150: 52-61.
- [36] 房舒. 基于深度学习的鱼类表型数据测量方法研究[D]. 杭州: 浙江大学, 2021.
- Fang S. Research on fish phenotypic data measurement method based on deep learning[D]. Hangzhou: Zhejiang University, 2021 (in Chinese).
- [37] 黄康为. 基于机器视觉的水下动态鱼体尺寸测量方法研究与实现 [D]. 杭州: 浙江大学, 2021.
- Huang K W. Research and implement of machine vision based underwater dynamic fish size measurement method[D]. Hangzhou: Zhejiang University, 2021 (in Chinese).
- [38] Haffray P, Bugeon J, Rivard Q, *et al.* Genetic parameters of in-vivo prediction of carcass, head and fillet yields by internal ultrasound and 2D external imagery in large rainbow trout (*Oncorhynchus mykiss*) [J]. *Aquaculture*, 2013, 410-411: 236-244.
- [39] Kause A, Paananen T, Ritola O, *et al.* Direct and indirect selection of visceral lipid weight, fillet weight, and fillet percentage in a rainbow trout breeding program[J]. *Journal of Animal Science*, 2007, 85(12): 3218-3227.
- [40] Navarro A, Zamorano M J, Hildebrandt S, *et al.* Estimates of heritabilities and genetic correlations for growth and carcass traits in gilthead seabream (*Sparus auratus* L.), under industrial conditions[J]. *Aquaculture*, 2009, 289(3-4): 225-230.

Application of computer vision in morphological and body weight measurements of large yellow croaker (*Larimichthys crocea*)

WANG Yusha¹, WANG Jiaying¹, XIN Rui², KE Qiaozhen¹,
JIANG Pengxin¹, ZHOU Tao¹, XU Peng^{1,3*}

(1. Fujian Province Key Laboratory of Marine Biological Genetic Breeding,
College of Oceanic and Earth, Xiamen University, Xiamen 361102, China;

2. School of Aerospace Engineering, Xiamen University, Xiamen 361005, China;

3. State Key Laboratory of *Larimichthys crocea* Breeding, Ningde 352103, China)

Abstract: Phenotypic traits such as body weight and body length of fish are very important economic traits in aquaculture and genetic breeding. In order to avoid the uncertainty, error randomness and low efficiency of manual measurement, this paper develops an automated, non-invasive device based on Mask Region Convolutional Neural Network (Mask R-CNN) for fish image segmentation and phenotypic traits measurement. The device consists of two parts: an image acquisition device able to measure fish of different sizes (body length 1-40 cm) and control software. The control software based on Mask R-CNN can train and predict the target traits of images, and realize the measurement, storage and management of target data. The experimental results show that the average relative error in body length and body height of *Larimichthys crocea* measured by the device is less than 4%. The body weight was fitted with multiple regression models based on body length, body height and body surface area. The correlation coefficient between measured values and the real body weight was 0.99, the average relative error was 4%, and the average processing time for each image was 3 seconds, which was 8 times as fast as manual measurement. The data measurement device based on machine vision and image capture developed in this study can automatically, efficiently and accurately obtain morphological and weight data of *L. crocea*, which provides a more convenient and efficient phenotype evaluation tool for the evaluation of *L. crocea* germplasm resources, breeding of improved varieties and germplasm innovation.

Key words: *Larimichthys crocea*; image analysis; morphological traits; mass estimation

Corresponding author: XU Peng. E-mail: xupeng77@xmu.edu.cn

Funding projects: National Key Research and Development Program (2022YFD2401001); Special Foundation for Major Research Program of Fujian Province (2020NZ08003); Seed Industry Innovation and Industrialization Project of Fujian Province (2021FJSCZY01); National Science Fund for Distinguished Young Scholars (32225049)