第45卷 第3期 华 中 农 业 大 学 学 报 Vol.45 No.3
2026年 5月 Journal of Huazhong Agricultural University May 2026,148~160

戴志文,陈康飞,常安代,等.基于端到端点云分割的鮡科鱼类三维形态表型提取[J].华中农业大学学报,2026,45(3):148-160.
DOI:10.13300/j.cnki.hnlkxb.2026.03.013

基于端到端点云分割的鮡科鱼类三维形态表型提取

戴志文[1],陈康飞[1],常安代[2],苏晓静[3],谢磊[2],
杨庆勇[1],杨瑞斌[3],熊皓[2],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 62715;
3.华中农业大学水产学院,武汉430070

摘要 为实现鮡科鱼表型的高精度、自动化测量,解决二维图像处理的表型数据不够丰富立体及现有三维点云分割模型对复杂生物结构识别能力不足的问题,本研究以前臀鮡(*Pareuchiloglanis anteanalis*)为具体研究对象,提出一种适用于鮡科鱼类的端到端三维形态表型提取方法。该方法利用RGB相机采集的多视角图像序列,通过运动恢复结构(SfM)与多视图立体视觉(MVS)算法重建高保真三维点云模型。为有效分离目标与背景,设计了一种融合随机采样一致性(RANSAC)算法与HSV空间颜色特征的复合去噪方法,在保留鱼体细节的同时精确去除背景噪声。针对原始PointNet++网络特征提取不充分的问题,提出改进的PointNet++点云部件分割网络,通过引入基于密集连接的多层感知机DenseNet-MLP、点云三重注意力机制PTA和多尺度学习模块MSB,显著提升了模型对鱼体精细结构的分割性能。试验结果显示,MSE低于$10e^{-5}$,PSNR均值为60.8,召回率平均值为93.33%。改进后的网络模型的平均交并比(mIoU)、总体精度(OA)和平均精确度(mAcc)评估指标分别达到了88.9%、95.5%、93.8%,相对原模型分别提升了3.5、1.4、1.6百分点。能够精确分割鱼头、鱼身及鱼鳍等关键部件。综上,本研究提出的方法可用于水产动物表型高通量、无接触式的精准测量。

关键词 三维重建; 表型提取; 点云分割; 点云处理; PointNet++

中图分类号 TP391.4 **文献标识码** A **文章编号** 1000-2421(2026)03-0148-13

前臀鮡(*Pareuchiloglanis anteanalis*)是我国特有的冷水性小型经济鱼类,具有体形扁平、头大尾小等典型形态特征[1],主要分布于金沙江、青衣江、大渡河等水域[2]。近年来,受水电站建设等因素影响,鮡科鱼类栖息环境遭到破坏,资源量明显下降,人工驯养与种质资源保护需求日益迫切。在养殖管理中,体长、体高、鱼鳍形态等表型数据是评估鱼体生长和健康状况的重要指标。目前,前臀鮡表型测量多依赖人工完成,姚景龙等[3]曾通过测量多个形态度量性状分析其物种多样性,但该方法费时费力,易受主观因素影响,且测量过程可能对鱼体造成损伤。因此,发展无接触式表型测量技术对水产养殖和种质保护具有重要意义。

基于计算机视觉的鱼类表型测量已有较多研究。早期方法主要依赖二维图像分析,例如Yu等[4]利用改进YOLOv5模型结合图像增强技术,实现鱼类侧线鳞片的自动检测与计数;房舒[5]提出了基于深度学习的斑点叉尾鮰表型快速测量方法;Freitas等[6]利用计算机视觉系统对细鳞肥脂鲤(*Piaractus mesopotamicus*)体型进行分析。上述二维方法提升了测量效率,但由于缺乏深度信息,难以真实反映鱼体三维结构,且易受姿态、角度和光照条件影响,限制了表型测量的准确性和信息维度。

三维点云能够以高精度坐标记录物体三维几何形态,具有较强的视角和姿态适应性[7],已成为表型分析的重要技术方向,并在家畜体尺自动化测量等动物表型研究中展现出应用潜力[8-9]。在水产动物测量方面,He等[10]结合改进YOLOv8实例分割模型、三维点云和深度相机实现尺寸测量;Barrelet等[11]基于双GoPro相机立体视觉系统,通过相机标定、鱼体检测、立体匹配、分割、三维定位等步骤完成鱼类三维尺寸测量与行为分析。然而,三维点云通

收稿日期: 2025-09-29
基金项目: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
戴志文,E-mail:zw_dai@qq.com
通信作者: 郑芳,E-mail:zhengfang@mail.hzau.edu.cn;熊皓,E-mail:397149876@qq.com

常数据量大、背景复杂且易受噪声干扰，仍会影响分割和关键点识别精度。

从点云数据中自动、准确提取表型参数，关键在于实现高精度语义部件分割。早期点云处理方法主要包括多视图法和体素法。多视图法将三维点云投影为多个二维视角，并借助二维CNN提取特征[12]，但易造成空间信息损失，且性能依赖视角选择[13]。体素法将点云转化为规则三维网格后使用三维CNN处理[14]，虽便于卷积运算，但存在量化误差、内存占用大和高分辨率计算成本高等问题。随后，PointNet[15]被提出，可直接处理原始点云，并通过共享MLP和对称函数解决点云无序性问题，但其对局部几何结构建模不足。PointNet++[16]进一步采用层次化特征提取方式，增强了局部结构感知能力，成为点云分割领域的重要基线模型。在此基础上，PointCNN[17]通过X-Conv算子实现点云加权与排序，DGCNN[18]通过动态构图捕捉局部拓扑关系，Point Transformer[19]则引入自注意力机制建模点间长距离依赖。然而，现有点云分割方法多面向通用物体或规则结构场景，在鱼类表型提取中仍面临细小部件比例不平衡、鱼鳍边界模糊、体表纹理复杂以及点云噪声干扰等问题。尤其对于体型较小、鳍部薄且与躯干连接不清晰的鱼类，仍需进一步增强模型对局部几何结构、颜色纹理信息和细粒度部件边界的识别能力。

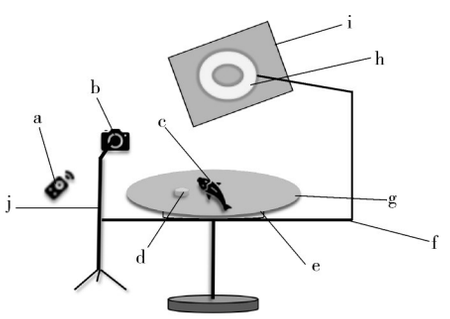
鮣科鱼具有特殊的生存适应机制，其三维形态表现为高度流线化的连续曲面结构，鳍部与躯干连接边界不明显；同时，鳍条薄且透明，在图像采集过程中易与背景混淆或产生伪影。加之体表斑纹和色彩变化复杂，进一步增加了自动分割中部件边界、细微结构及颜色纹理的识别难度，导致鱼头、鱼身、鱼鳍等关键表型部件在高通量测量中易出现错分、漏分和边界模糊等问题。本研究旨在为鮣科鱼类表型智能测量提供低成本、高精度、高通量、无接触的三维分割技术路径，弥补其三维形态自动解析研究不足，并为濒危鱼类保护、遗传育种、水产养殖智能装备开发、鱼道生态评估及种质资源数字化管理提供技术与数据支撑。

1　材料与方法

本研究以极具经济与生态价值的鮣科鱼类中的前臀鮣为研究对象，提出一种基于端到端点云分割的三维形态表型提取方法。该方法利用低成本RGB相机结合SfM[20]（structure from motion）与MVS[21]（multi-view stereo）算法重建高保真点云，并融合RANSAC与HSV颜色特征进行复合去噪；在此基础上改进PointNet++网络，对前臀鮣系统开展了图像采集、三维重建、分割模型构建与表型参数提取等方面的研究，形成一套适用于鮣科鱼类的完整的三维形态表型解析技术流程，实现鱼头、鱼身、鱼鳍等关键部件的精确分割。

1.1　图像采集

为获取三维重建所需的多视角图像，本研究搭建了自动化数据采集装置，如图1所示。装置主要由RGB相机、电动旋转台、LED光源和柔光板组成。试验对象为317尾外观完整的前臀鮣标本。采集前，擦拭鱼体表面以减少反光，并测量鱼体质量。采集时，将鱼体置于旋转台中央，相机固定于支架上，拍摄距离为20～25 cm；通过旋转台匀速旋转360°，约100 s完成1圈拍摄，获得鱼体全周向多视角图像序列。



a. 遥控器；b. 摄像器；c. 鱼；d. 参照物；e. 旋转台；f. 桌面；g. 轻薄底板；h. 光源；i. 透光纸板；j. 伸缩支架。a.Remote control；b. Camera；c. Fish；d. Reference object；e. Rotating stage；f.Desktop；g.Lightweight base plate；h.Light source；i.Translucent paper board；j.Telescopic stand.

图1　多视角鮣科鱼的视频采集装置示意图

Fig.1　Schematic diagram of a video acquisition device for multi-angle Sisoridae

1.2　鮣科鱼的三维重建

获得视频后，利用FFmpeg以每秒1帧（1 fps）的速率抽帧，为每尾鱼生成约100～120张不同视角的静态图像，作为三维重建输入数据。抽取图像按时间顺序编号，图2展示了1尾鱼的不同视角帧图像。

采用基于运动恢复结构SfM与多视图立体视觉MVS相结合的三维重建流程，将二维多视角图像序列转化为三维点云模型。该流程主要包括稀疏重建与相机位姿估计、稠密重建2个阶段。

1）稀疏重建与相机位姿估计。在SfM三维重建

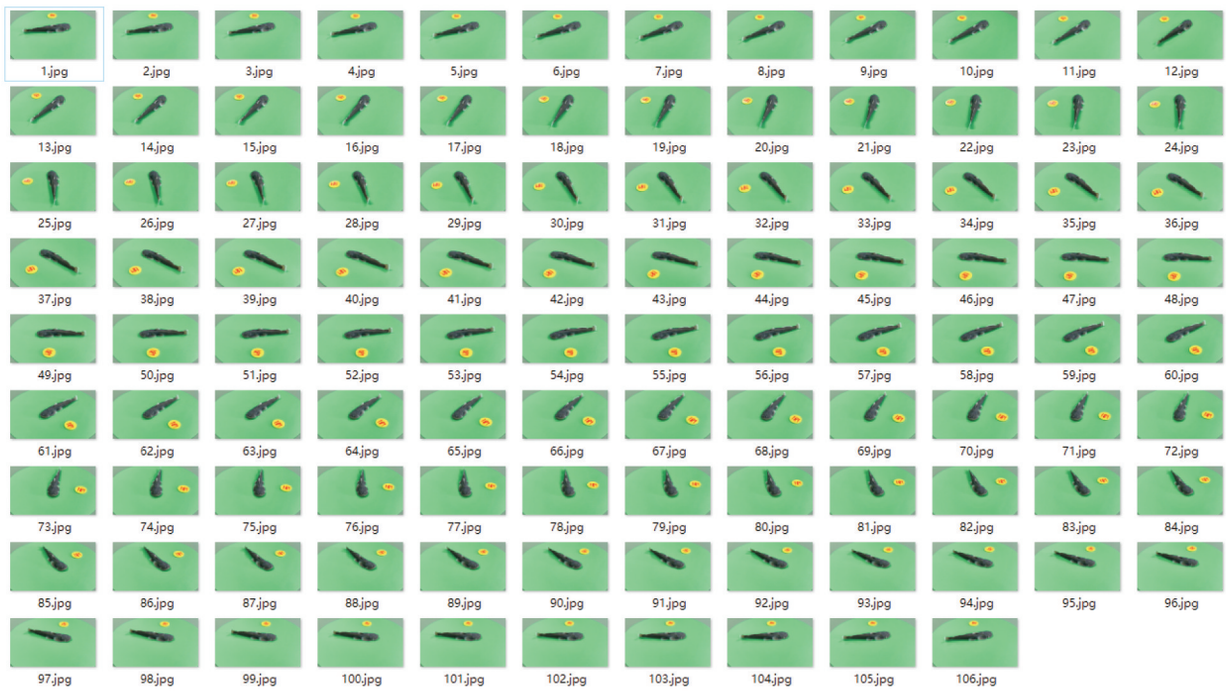


图2 视频流抽取不同角度的帧数据

Fig.2 Extracting frame data from different angles in the video stream

中采用ORB[22](oriented FAST and rotated BRIEF)算法进行图像特征点检测与匹配。ORB结合FAST角点检测和BRIEF描述子的优势,具有计算效率高和旋转鲁棒性强的特点。特征点提取后,通过描述子间的汉明距离完成快速匹配。为提高匹配精度,采用RANSAC算法剔除由视角变化、遮挡等引起的误匹配点,并估计最优几何模型。随后,基于筛选后的匹配结果,采用增量式SfM逐步加入图像,并通过三角测量和捆绑调整优化相机位姿与三维点坐标,最终获得相机内外参数和稀疏点云。图3展示了SfM生成的稀疏点云结果。

2)稠密重建。在相机位姿和稀疏点云基础上,采用MVS算法进行稠密重建,得到高密度鱼体三维点云。图4展示了6尾鱼经MVS重建和纹理映射后的网格模型,该流程将二维图像转化为后续分割与测量所需的精确三维点云数据。

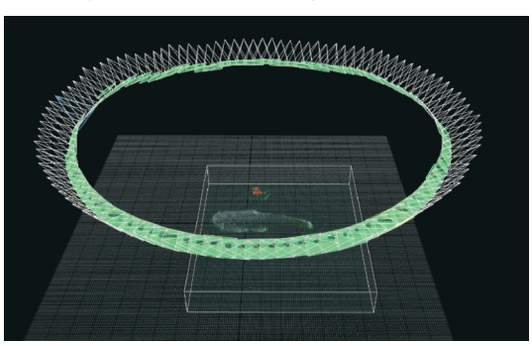


图3 获取位姿信息和稀疏点云

Fig.3 Acquiring pose information and sparse point clouds

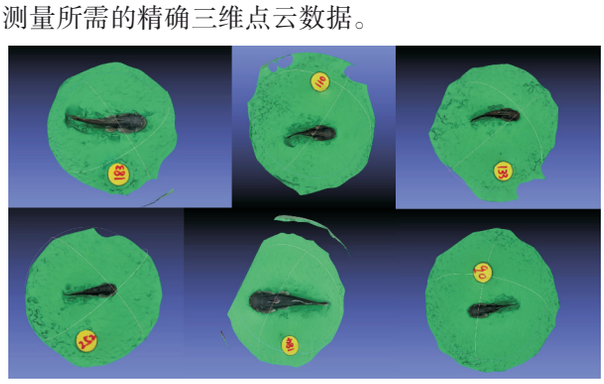


图4 鮸科鱼的密集重建结果

Fig.4 Dense reconstruction results of Sisoridae

1.3 点云预处理

三维重建获得的原始点云包含鱼体、旋转台、支撑物及由光照和重建误差产生的离群点与噪声,易影响后续分割与表型测量。单独使用RANSAC虽可去除背景平面,但可能误删贴近平面的腹部或鳍部边缘点;仅依赖颜色阈值则易受背景颜色相近和光照不均影响,导致分割不足或过度分割。因此,本研究采用结合RANSAC平面检测与HSV颜色特征的复合点云预处理方法,其流程如图5所示。预处理后,对点云数据进行标注,用于后续点云分割任务。

1) RANSAC平面分割与初步分离。对原始点

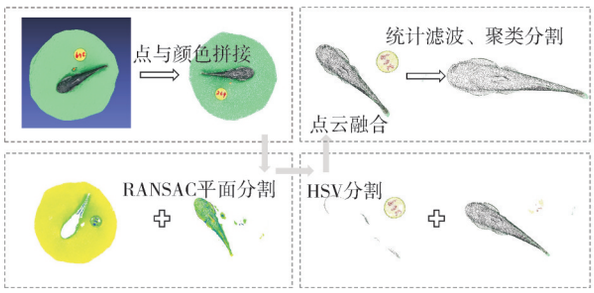


图5　噪声处理总体路线

Fig.5　Overall workflow of noise process

云应用RANSAC算法检测背景平面，通过迭代随机采样拟合最优平面模型，将点云分为背景平面内点集和包含鱼体及少量噪声的外点集。

2）基于HSV颜色空间的精细化处理。为减少RANSAC分割造成的鱼体信息损失，进一步利用点云RGB颜色信息进行精细化处理。首先将RGB颜色值转换为HSV颜色空间，以更好地区分颜色与光照信息，HSV分布如图6所示。其中H为色相，S为饱和度，V为颜色空间，R、G、B为归一化后的颜色通道值。

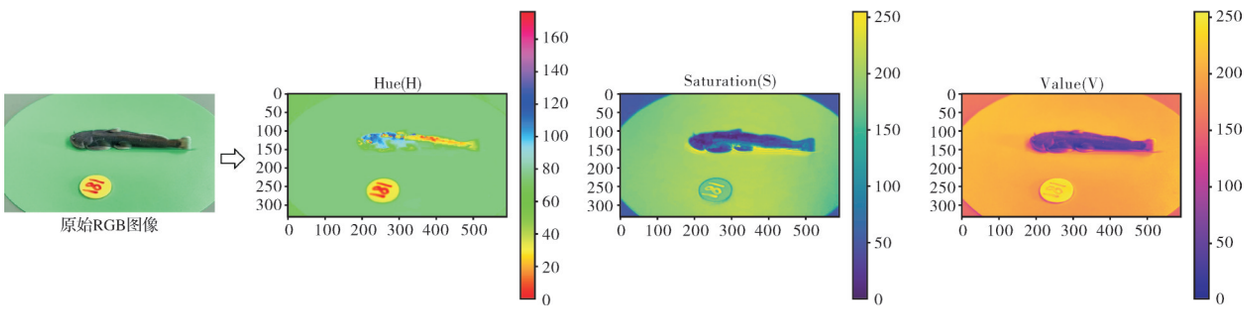


图6　RGB图像在HSV上的分布图

Fig.6　Distribution of RGB images in HSV color space

3）点云融合与去噪。为剔除剩余的孤立噪声点，采用统计离群点移除（statistical outlier removal，SOR）滤波器对融合后的点云进行处理。随后利用欧氏聚类算法分离目标点云，设置领域半径r=0.01 m，最小聚类点数N_min=200，最终提取仅含鱼的点云数据，提高点云纯净度和后续分割精度。

4）部件分割数据集制作。本研究对202尾前臀鳅样本进行三维重建，并通过自动滤波与人工修正获得高质量点云数据，构建部件分割数据集。每尾鱼点云被标注为7类部件：头部、躯干、尾鳍、胸鳍、腹鳍、背鳍和脂鳍，对应数字标签为0～6，标注结果如图7所示。由于原始数据规模有限，采用随机旋转、平移和下采样等数据增强方法，将训练样本扩展至402个，以提升模型鲁棒性和泛化能力。最终，数据集按7∶2∶1划分为训练集、验证集和测试集。

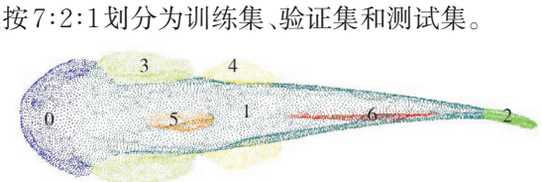


图7　数据标注示例

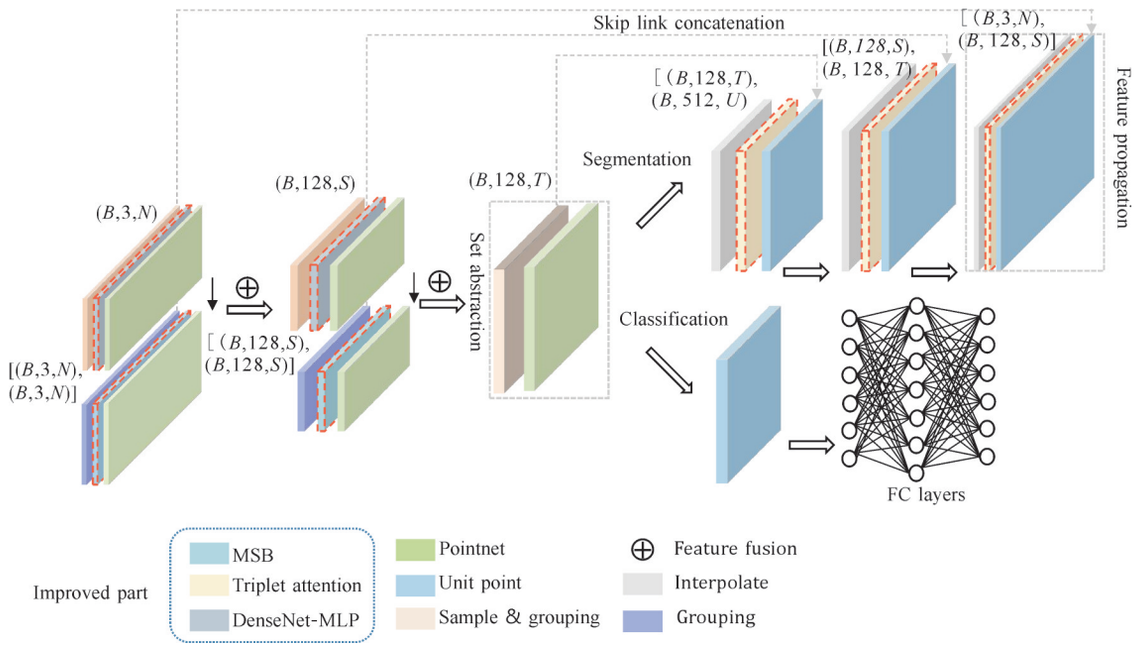
Fig.7　Example of data annotation

1.4　改进的PointNet++分割模型

PointNet++通过分层抽象结构提取点云局部特征，是点云分割领域的经典基线模型。但在处理鳅科鱼形态复杂、部件边界模糊的点云时，原始PointNet++仍存在特征表达不足的问题。为此，本研究从特征复用、空间结构建模和颜色信息融合3个方面对其进行改进：引入密集连接MLP增强特征复用能力，设计三分支注意力机制强化鱼体空间结构学习，并提升RGB附加信息的特征提取能力，从而提高点云部件分割精度。改进后的网络结构如图8所示，红色虚线框为3项核心改进模块。

1）基于密集连接的多层感知机（DenseNet-MLP）。在PointNet++的抽象SA（Set Abstraction）模块中，本研究借鉴DenseNet思想[23]，以DenseNet-MLP替代原始MLP结构，如图9所示。输入为$[B,C_{in},K,S]$，B为批次大小，C_{in}为输入的通道数，K表示每个点的邻域大小，S为采样点数。该结构使每一层同时接收前序所有层的特征输出，增强了多层次几何特征表达能力，并缓解深层网络训练中的梯度消失问题。

2）点云三重注意力机制。本研究在特征传播模块中引入基于三重注意力机制（triplet attention）[24]改进的点云三重注意力机制网络结构（PTA），以增强模型对点云空间分布和局部结构的感知能力。PTA通过建模通道维度和空间维度间的依赖关系，提高局部特征聚合效果和部件分类精度，其结构如



图中红色虚线框内为改进模块 The improved module is in the red dotted box in the figure.

图8 改进PointNet++的网络结构

Fig.8 Network architecture of improved pointNet++

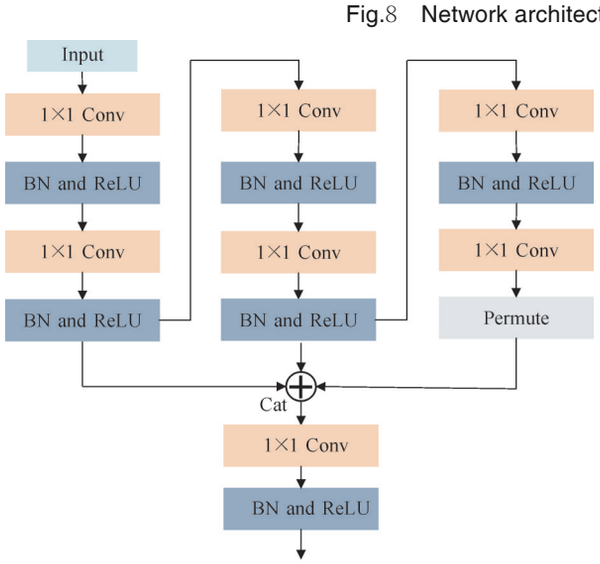


图9 基于DenseNet的MLP网络结构

Fig.9 The MLP network structure based on DenseNet

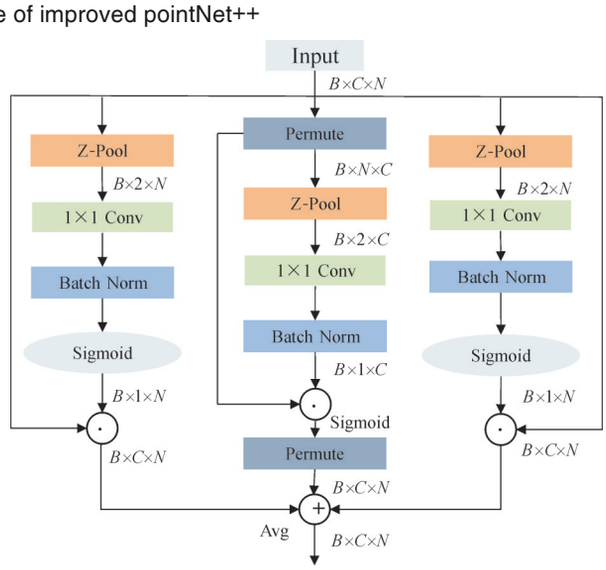


图10 点云三重注意力机制网络结构

Fig.10 Network architecture of point triplet attention mechanism

图10所示。其中B为批次大小，C为通道数，N为点的数量。模块包含3个分支：通道注意力(channel attention)和2个空间注意力分支，分别在不同维度上进行特征建模。

通道注意力分支：该分支用于建模通道间依赖关系。首先采用Z-Pool对输入特征进行最大池化和平均池化，并拼接得到$[B,2,N]$的通道描述特征；随后经1×1卷积、BN和Sigmoid生成注意力权重，最后与原始特征逐点相乘，增强关键通道响应。Z-Pool计算见公式(1)。

$$P_z(x)=[M(x),A(x)] \tag{1}$$

空间注意力分支1：该分支侧重局部空间结构建模。通过维度置换将输入特征由$[B,C,N]$转换为$[B,N,C]$，再经Z-Pool、一维卷积、BN和Sigmoid生成空间注意力权重，并与输入特征相乘后恢复原始维度，从而突出局部邻域中的关键点特征。

空间注意力分支2：该分支主要捕获全局空间依赖关系。其直接在空间维度上进行注意力建模，通过Z-Pool、一维卷积、BN和Sigmoid生成权重，并与

输入特征逐点融合。该分支与空间注意力分支1互补，可同时增强局部与全局空间特征表达。在特征传播过程中，PTA能够在上采样恢复点特征的同时突出关键局部结构，使特征表达更加丰富，便于后续MLP进一步提取局部和全局信息，从而提升点云分割精度。

3）多尺度学习模块MSB。本方法改进了PointNet++的SA（set abstraction）模块，引入MSB结构（multi-scale bottleneck多尺度学习模块），其网络结构如图11所示。原始PointNet++通常将RGB颜色与XYZ坐标直接拼接输入，难以充分挖掘几何信息与颜色纹理信息的差异。MSB模块通过多个并行分支扩大感受野，每个分支由3层1×1卷积组成，用于提取不同层次的语义特征；随后将各分支输出进行通道拼接，并通过1×1卷积融合，生成增强后的多尺度特征。通过MSB模块和自适应池化分别建模局部与全局颜色信息，最终融合生成增强特征。该结构既提升了几何特征表达能力，又增强了RGB信息利用效果，为后续点云部件分割提供更充分的特征表示。

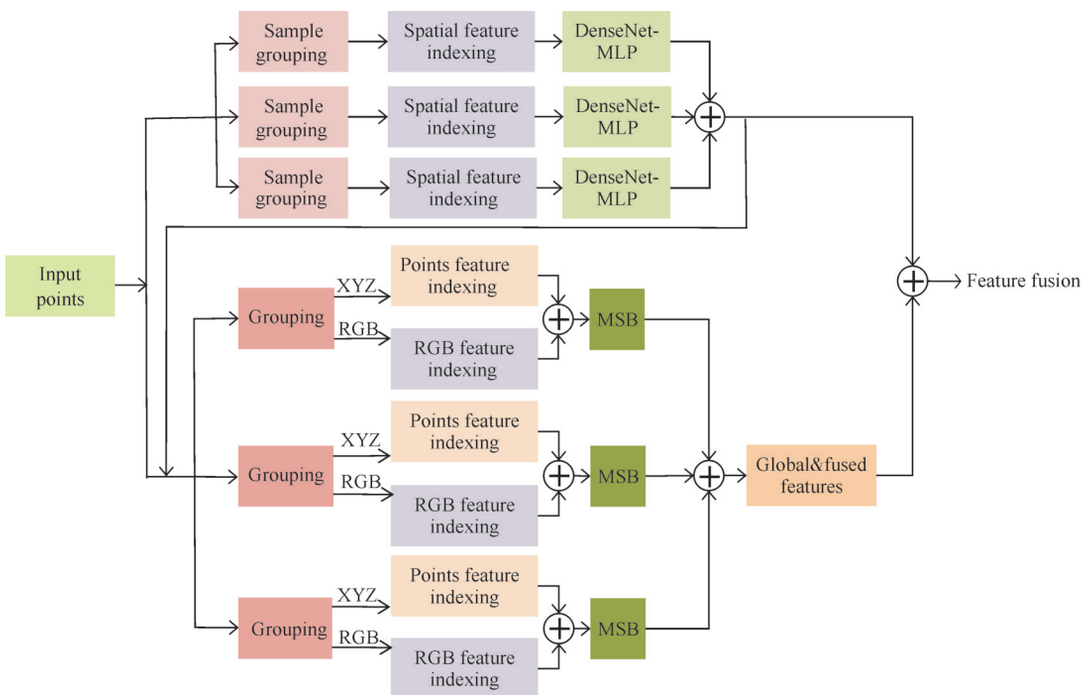


图 11　改进后的SA模块网络结构

Fig.11　Network architecture of improved SA module

1.5　表型提取算法

基于改进PointNet++模型对鱼体进行分割后，采用主成分分析（PCA）方法对鱼头、鱼身、鱼鳍等部件进行量化测量，自动提取长度、宽度等表型参数，如图12所示。

1）基于PCA的表型测量。首先采用RANSAC算法获取三维重建场景中的底部平面，并根据平面参数对去噪后的鲚科鱼点云进行姿态校正，使其统一投影到XOY平面。随后利用主成分分析（PCA）提取点云的主要空间方向，通过数据中心化、协方差矩阵计算、特征分解和主成分选择，确定鱼体或各分割部件的最大延展方向。最后，结合PCA投影结果与最小外接矩形，自动计算分割后点云的长度、宽度等表型参数。

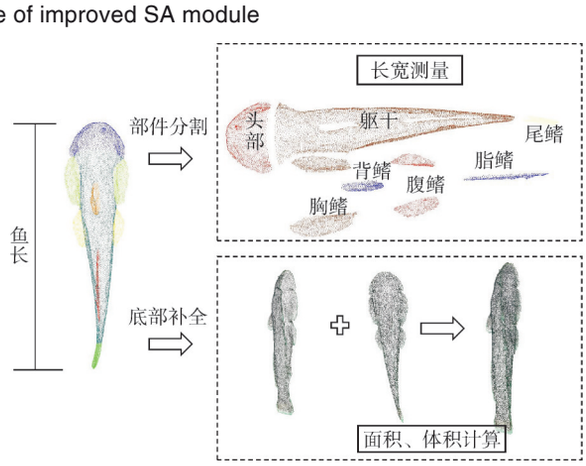


图 12　鲚科鱼的表型提取

Fig.12　Extraction of phenotypic traits in Sisoridae

2）鲚科鱼点云底部补全。由于三维重建过程中鱼体底部点云容易缺失，基于RANSAC获得的底面

信息，通过坐标旋转和平面投影生成底部点云，并采用密度自适应配准算法完成点云拼接，以提高模型完整性。融合后产生的边界冗余点主要分布于鱼鳍、腹部和尾部区域，因此，进一步在CloudCompare软件中构建形态学滤波流程去除冗余点，以降低表面积和体积计算误差。对于腹部较平整的样本可整体补全；若尾部与躯干存在明显高度差，则分别进行融合拼接，图13展示了6尾鲥科鱼点云的补全效果。



图13 点云补全结果

Fig.13 Point cloud completion results

1.6 评估指标

在实例分割实验中，本文采用平均精度（mAcc）、总体精度（OA）和平均交并比（mIoU）作为评价指标，通过逐点比较预测类别与真实标签，评估点云分割性能。

$$I_{\mathrm{mAcc}}=\frac{1}{N}\sum_{j=1}^{N}\frac{T_{Pj}}{T_{Pj}+F_{Nj}+F_{Pj}} \tag{2}$$

公式（2）用于计算mAcc，其中N表示部件总数，T_{Pj}是第j个部件的真阳性点数，F_{Pj}是第j个部件的假阳性点数，F_{Nj}是第j个部件的假阴性点数。

$$I_{\mathrm{OA}}=\frac{\sum_{i=1}^{M}T_{Pi}}{\sum_{i=1}^{M}(T_{Pi}+F_{Pi}+F_{Ni})} \tag{3}$$

公式（3）用于计算OA，其中M是点云中的总点数，T_{Pi}是第i个点被正确分类为其对应部件的数量，F_{Pi}是第i个点被错误分类为另一个部件的数量，F_{Ni}是第i个点未被分类为任何部件的数量。

$$I_{\mathrm{mIoU}}=\frac{1}{n}\sum_{i=1}^{n}I_{\mathrm{IoU}j},I_{\mathrm{IoU}j}=\frac{N_{\mathrm{Intersection}j}}{N_{\mathrm{Union}j}} \tag{4}$$

公式（4）用于计算mIoU，其中n是部件的总数，$N_{\mathrm{Intersection}j}$是预测和真实标签中属于第$j$个部件的点的交集，$N_{\mathrm{Union}j}$是预测和真实标签中属于第$j$个部件的点的并集，$I_{\mathrm{IoU}j}$是第$j$个部件的交并比。

在表型测量实验中利用参照物在重建后得到的三维模型上的测量值与真实值之间的比值，来计算鲥科鱼性状的真实值，计算方法如公式（5）所示，其中，L_{C}为模型中的计算值，L_{S}为参照物的真实测量值，L_{T}为建模后鲥科鱼的某一部件的计算值，L_{P}为鲥科鱼的真值。本研究中采用圆形塑料片作为参照物，其测量的厚度为1.8 mm，直径为30.0 mm。

$$L_{\mathrm{P}}=\frac{L_{\mathrm{T}}\times L_{\mathrm{C}}}{L_{\mathrm{S}}} \tag{5}$$

为评估其计算精度误差，研究采用公式（6）作为误差率，其中M_{a}为人工测量值，M_{r}为自动测量值，即实验预测值。均方根误差（relative root mean square error，RMSE）用于衡量实验方法预测结果的方差程度，其计算如公式（7）所示，其中$\widehat{Y}_i$为第i个样本的自动预测值，Y_i为第i个样本的人工测量值。

$$d=\frac{M_{\mathrm{a}}-M_{\mathrm{r}}}{M_{\mathrm{r}}}\times 100\% \tag{6}$$

$$X_{\mathrm{RMSE}}=\sqrt{\frac{1}{n}\sum_{i}^{n}\left(\widehat{Y}_i-Y_i\right)^2} \tag{7}$$

1.7 实验环境与参数配置

表1展示了实验环境配置与数据集划分方案。实验采用NVIDIA RTX3090 GPU作为主要计算设备，运行环境为Python 3.8，并通过Anaconda进行虚拟环境管理。为保证实验的科学性和可重复性，PointNet++、DGCNN等基线模型及各阶段改进模型均在相同操作系统和实验环境下运行，训练批次大小（batch size）统一设置为16。

表1 实验配置

Table 1 Experimental configuration

配置名称 Configuration name	配置参数 Configuration parameter
显卡 Graphics card	NVIDIA RTX3090
显存大小 Memory size	24GB
处理器 Processor	14 vCPU Intel(R) Xeon(R) Platinum 8362 CPU @ 2.80 GHz
操作系统 Operating system	Ubuntu18.04
开发环境 Development environment	Python3.8
算法框架 Algorithm framework	Pytorch1.6.0，CUDA10.1

2 结果与分析

2.1 改进模型评估分析

改进后的模型经过255轮次训练，其他公开模型在自建的数据集上的训练轮次保持不变。如图14所示，每隔10个epoch绘制1次最佳的mIoU和OA值，其中Baseline为PointNet++网络模型，Final为本研究改进后的PointNet++网络结构。

通过图14可以看出，模型训练在第220轮后精度的提升趋于稳定。随着训练轮次的增加，改进后

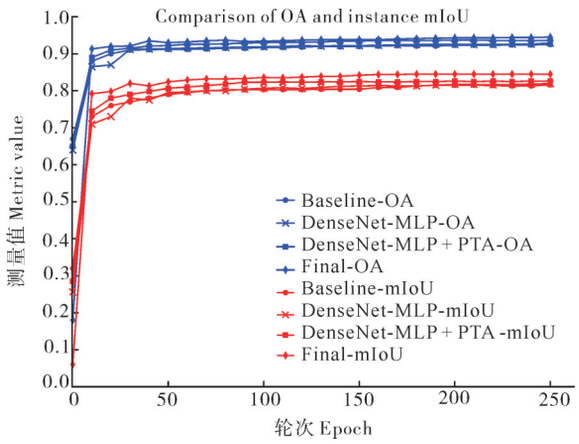


图 14　模型迭代改进训练时的评估表现

Fig.14　Evaluation performance during iterative model improvement training

的网络模型在测试集上的评估指标值显著提升，其中 OA 超过了 95%，mIoU 达到了 88.3%；而 Baseline 模型的 OA 为 94%，mIoU 为 85.5%。

表 2 展示了不同迭代改进模型在点云分割任务中的性能对比，并通过 OA、mIoU 和 mAcc 评价各改进模块的有效性。基线 PointNet++模型的 OA、mIoU 和 mAcc 分别为 94.1%、85.4% 和 92.2%。在 SA 模块中引入 DenseNet-MLP 后，OA 提升 0.4 百分点，mIoU 提升 0.9 百分点，说明 DenseNet-MLP 有助于增强特征表达能力。进一步加入 PTA 后，mIoU 和 mAcc 均提升 1.1 百分点，表明该模块能够提升复杂部件的分割能力。在此基础上，引入 MSB 模块后，模型 OA、mIoU 和 mAcc 分别提升 0.7、1.5 和 0.4 百分点。最终模型相较于基线模型，OA、mIoU 和 mAcc 分别提升 1.4、3.5 和 1.6 百分点，表明本研究所提出方法能够有效提高点云分割精度、模型泛化能力和细粒度部件识别效果。

2.2　点云分割消融实验

表 3 展示了 10 种公开点云分割模型与基于 PointNet++改进的分割模型在本研究自建数据集上的总体精度（OA）和平均交并比（mIoU）的性能对比。在 10 种公开模型对比试验中，Point-BERT[25] 和 PointMLP 在自建的数据集上的表现较为突出，尤其在 mIoU 上超越了其余 8 种点云分割模型，表明这 2 种模型在点云分割任务中对于细节的处理和精度的提升方面具有较好的优势。在 PointNeXt[26] 网络模型中，它的分割任务表现结果显示评估指标相对较低，OA 和 mIoU 值分别为 87.0% 和 76.3%，显示出 PointNeXt 模型在对自建的数据集训练与测试时的局限性，从而说明少量的数据集对于 PointNeXt 网络模型在分割任务上的能力不佳。

表 2　基于 PointNet++的点云分割模型在各阶段优化后的性能比较

Table 2　Performance comparison of the PointNet++ based point cloud segmentation model after optimization at various stages　%

模型 Model	OA	mIoU	mAcc
PointNet++	94.1	85.4	92.2
DenseNet-MLP+PointNet++	94.5	86.3	92.3
DenseNet-MLP+ PTA+PointNet++	94.8	87.4	93.4
Final model	95.5	88.9	93.8

表 3　不同点云分割模型在鱿科鱼的数据集上的性能评估值

Table 3　Performance evaluation of different point cloud segmentation models on the fish dataset　%

模型 Model	OA	mIoU
PointNet	93.6	85.1
PVCNN	94.5	86.8
CurveNet	93.5	85.2
DGCNN	89.2	77.2
PAConv	92.8	84.1
Point Transformer	93.2	83.4
PointNeXt-s_c64	85.8	74.4
PointNeXt-s	87.0	76.3
Point-BERT	94.8	87.4
PointMLP	94.5	87.8
PointNet++	94.1	85.4
本研究 This study	95.5↑	88.9↑

改进后的 PointNet++模型在 OA 和 mIoU 两个主要指标上均优于表 3 中公开模型，表现出更好的点云部件分割能力。与 PointMLP 相比，其 OA 和 mIoU 分别提升 1.0 和 1.1 百分点；与 Point-BERT 相比，mIoU 提升 1.5 百分点，说明改进网络在特征提取和细节分割方面具有优势。综上，改进后的 PointNet++通过多模块优化和特征增强，提升了复杂点云场景下的分割精度与鲁棒性，并能在样本量相对有限的条件下获得更适用于鱿科鱼实例分割的模型权重。

2.3　预测评估结果

为验证模型泛化能力，本研究在验证集上选取 9 尾不同姿态的鱼标本进行实例分割预测，评估结果如表 4 所示。结果表明，改进模型整体分割性能优于原始 PointNet++，说明其在实际预测中具有更好的泛化能力和分割效果。DenseNet-MLP 单独改进后

的模型与原始PointNet++差异较小，因此不作重点分析；在DenseNet-MLP基础上加入PTA机制后，mIoU和mAcc分别提升2.5和0.9百分点。最终改进模型进一步提升了分割性能，9尾鱼标本中单尾IoU最大提升7.4百分点，整体mIoU提升4.6百分点，mAcc提升1.7百分点。

表4 迭代改进的网络模型实际预测的评估结果

Table 4 Evaluation results of actual predictions from the iteratively improved network model %

模型 Model	mIoU	mAcc	IoU								
			fish1	fish2	fish3	fish4	fish5	fish6	fish7	fish8	fish9
PointNet++	83.1	92.5	81.3	83.1	88.2	81.3	85.6	82.5	84.6	83.8	81.4
+DenseNet-MLP+PTA	85.6	93.4	82.0	86.9	88.3	82.7	86.5	86.0	87.1	85.6	85.5
Final model	87.7	94.2	86.6	88.1	88.4	88.7	88.8	88.0	88.3	86.4	86.3

图15展示了15尾前臀鮈（体质量3.5～6.5 g）在三维点云部件分割中，模型改进前后的平均分类准确率（mAcc）对比。结果表明，不同部件的分割精度存在差异，主要与小体型样本重建后的点云密度分布不均有关，尤其在曲率变化较大的区域，点云密度明显低于主体部位。改进模型在多个部件上的分割精度均有提升，其中头部因几何结构稳定，mAcc基本保持在87.0%左右，提升较小；背鳍和脂鳍提升较明显，mAcc分别提高3.3和4.7百分点。图16对比了原始模型与改进模型的预测分割效果。原始模型主要存在部件边界模糊和过分割问题，不利于鮈科鱼形态表型分析；改进模型则有效缓解了上述问题，提高了细粒度部件分割效果。

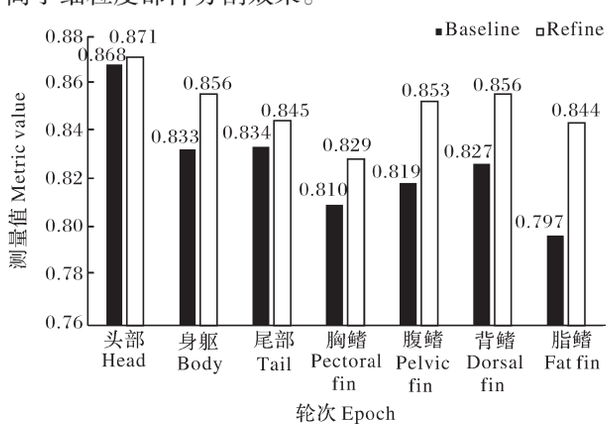


图15 鮈科鱼的不同部位分割精度对比

Fig.15 Comparison of segmentation accuracy of different parts of Sisoridae

在图16(a1)中，头部区域的边界分割模糊不清，且分割边界呈现凌乱不整齐的情况；在图16(a1,c1,e1,f1,i1)中，出现了胸鳍或腹鳍的过分割问题；而在图16(d1,g1,h1)中，背鳍和脂鳍存在漏分割的情况。与此相比，图16(a2～e2)，显示了改进后的模型在不同形态表型分割边界上划分能力的显著提升。改进后的模型在边界区分上更加清晰、整齐，且减少了过分割和漏分割的问题，能够相对完整地分割出每一个表型特征。

2.4 表型测量实验与结果分析

本研究选取20尾前臀鮈进行表型测量实验。由于胸鳍和背鳍常与身体侧边紧密贴合，且鱼体大小会影响测量误差，人工参考值本身存在较大不确定性，因此本研究暂不将胸鳍和背鳍纳入评估，转而选择其他性状进行测量对比。表5展示了其中1尾鱼的自动与手动测量结果，以及20尾鱼各性状测量的均方误差。

从表5中可以看出，在体质量为3.38 g的鱼样本中以手动测量值为基准，自动测量与手动测量的最大绝对误差为1.77 mm，最小绝对误差为0.31 mm。与手动测量相比，多个表型参数的自动测量准确度达到92.6%以上。全样本的测量对比显示，最大均方误差值为4.51 mm，表明自动测量系统精度总体可在±1～7 mm误差范围内获取鱼类表型数据。需要说明手动测量本身存在操作者的偏差，点云分割模型的预测存在算法泛化误差，且在使用RGB相机获得三维模型与真实的鱼存在微小误差。

如图17所示，通过4组小提琴图对比了鱼类全长、头长、体宽和体高的自动测量与手动测量分布，各子图均标注了中位数、25%～75%四分位距。如图17A所示，2种测量方式的全长分布高度重合，绝对误差范围为2～7 mm（中位数误差为2 mm）。图17B显示体宽测量的中位数误差为0.8 mm，表明该参数的自动测量结果能够作为实际的参考价值。从图17C～D中头长和体高测量的中位数误差都保持在1 mm以下。

相关系数（R）的计算如公式(8)所示。

$$R=\frac{\mathrm{Cov}(M_a,M_r)}{\sqrt{\mathrm{Var}[M_a]\mathrm{Var}[M_r]}} \tag{8}$$

式(8)中，$\mathrm{Cov}(M_a,M_r)$用于计算自动测量值与手动测量值之间的协方差，$\mathrm{Var}[M_a]$表示为自动测

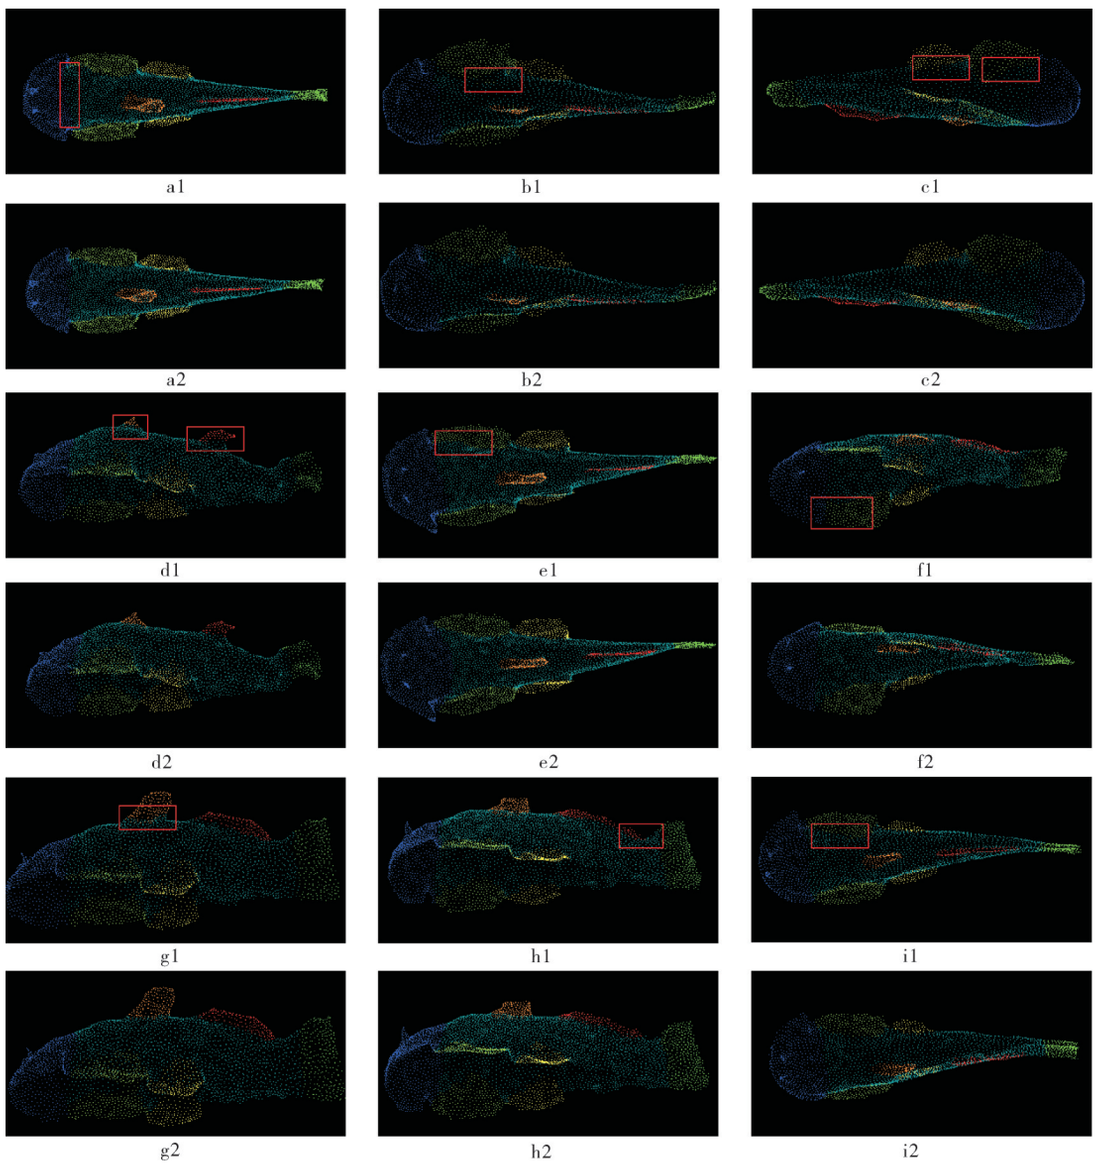


图 16　原有模型与改进模型的分割结果对比

Fig.16　Comparison of segmentation results between the original model and the improved model

量的方差值，Var$[M_r]$表示为手动测量的方差值。从表 6 可以看出相关系数最低为 0.913，相关系数较大的有体长、体高、体宽，这 3 个值并未涉及到点云的分割测量，故而准确率更高。以上数据表明，本研究在通过获得三维点云之后，进行点云的部件分割并做测量得到不同的性状参数与手动测量的结果之间具有较强的相关性，证明了研究方法的有效性。

3　讨　论

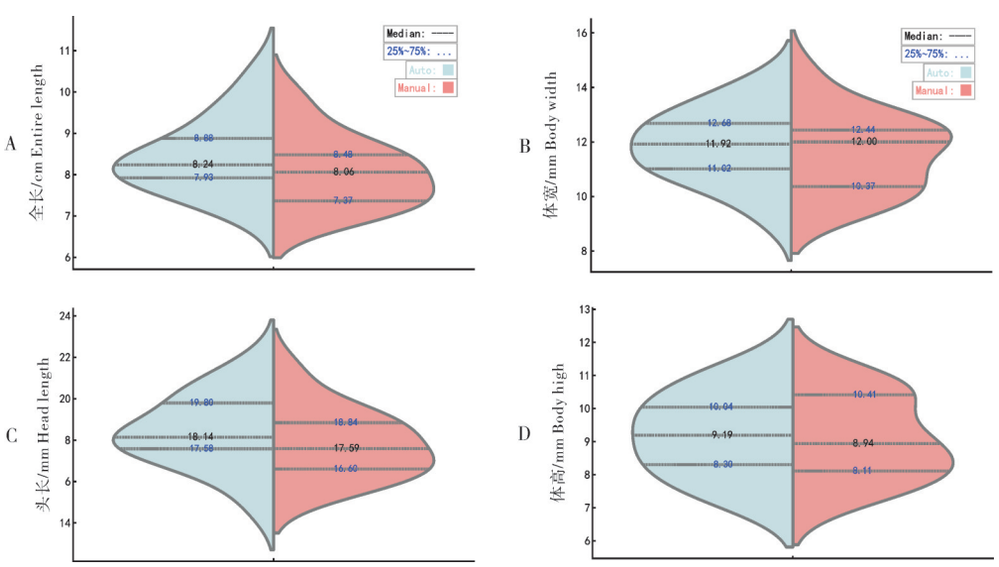
本研究构建了鳙科鱼从多视角图像采集、三维重建、点云预处理、部件分割到表型测量的完整流程，实现了 317 尾前臀鳙标本的稳定图像采集，并结合 SfM、MVS、RANSAC 与 HSV 颜色分割方法获得较高质量的鱼体点云。与家畜等体型较大、部件边界清晰的动物表型测量研究相比[8-9]，前臀鳙体型小、鱼鳍薄且透明，鳍部与躯干边界模糊，部件比例极不平衡，分割难度更高。针对鳙科鱼点云分割难题，本研究在 PointNet++基础上引入 DenseNet-MLP、PTA 点云三重注意力机制和 MSB 多尺度学习模块，增强了模型对局部结构、边界细节和颜色纹理信息的表达能力。实验结果表明，改进模型 mIoU 达到 88.9%，较原始 PointNet++提升 3.5 百分点，尤其在背鳍、脂鳍等小尺度、边界模糊部件上的识别效果提升明显。这表明该方法不仅能有效分割鱼体主体结构，也能较好识别鱼鳍等难分割部位，适用于鳙科鱼类端到端的三维形态表型提取，弥补了现有水产

表5 鮸科鱼的表型测量数据

Table 5 Phenotypic measurement data of Sisoridae

表型名称 Phenotype name	自动测量值 Automatic measurement	手动测量值 Manual measurement	相对误差 Relative error	误差率/% Error rate	均方误差 Root mean square error
全长/mm Total length	70.75	69.82	0.93	1.32	4.51
体长/mm Body length	49.02	50.79	1.77	2.11	1.47
头长/mm Head length	14.61	15.76	1.15	6.34	1.13
体宽/mm Body width	9.22	9.56	0.34	3.69	0.57
体高/mm Body height	8.91	8.51	0.40	4.48	0.37
尾柄高/mm Caudal peduncle height	5.13	4.82	0.31	6.04	0.43
脂鳍长/mm Adipose fin length	22.16	23.80	1.64	7.40	1.75
表面积/cm^2 Surface area	54.85	—	—	—	—
体积/cm^3 Volume	13.47	—	—	—	—
体质量/g Body weight	—	3.38	—	—	—

注：—表示没有数据。Note: — indicates no data.



A. 全长；B. 体宽；C. 头长；D. 体高。A. Entire length; B. Body width; C. Head length; D. Body high.

图17 手动测量与分割自动测量对比

Fig.17 Comparison between manual measurement and automatic segmentation measurement

表6 鮸科鱼自动与手动测量的相关系数

Table 6 Correlation coefficient between automatic and manual measurement of Sisoridae

表型名称 Phenotypic name	相关系数(R) Correlation coefficient
全长 Total length	0.962
体长 Body length	0.943
头长 Head length	0.931
体宽 Body width	0.972
体高 Body height	0.967
尾柄高 Caudal peduncle height	0.947
脂鳍长 Adipose fin length	0.913

动物表型获取技术的不足[10-11]。

从效率来看，单尾鱼完成完整处理流程平均耗时约579.24 s，其中三维重建约458.0 s，是主要时间开销；而分割推理耗时较短，说明系统具备进一步工程化优化的基础。当前方法仍存在两方面不足：一是图像采集在离水条件下完成，与实际水下活鱼检测场景存在差异；二是三维重建尚未启用GPU加速，限制了高通量应用效率。未来可重点优化水下成像系统，引入防水补光、色彩校正和图像去散射算法，同时采用GPU加速三维重建，并扩充不同体

型和姿态样本，以进一步提升系统的实用性和泛化能力。

参考文献 References

[1] 中国科学院动物研究所 . 前臀鳈(*Pareuchiloglanis anteanalis* Fang，Xu et Cui，1984)[EB/OL]. 北京：中国科学院动物研究所，2018(2018-01-17)[2025-09-29]. http://museum.ioz.ac.cn/topic_detail.aspx? id=69081. Institute of Zoology，Chinese Academy of Sciences. *Pareuchiloglanis anteanalis* Fang，Xu et Cui，1984[EB/OL]. Beijing：National Zoological Museum of China，Institute of Zoology，Chinese Academy of Sciences，2018(2018-01-17)[2025-09-29]. http://museum.ioz.ac.cn/topic_detail.aspx? id=69081(in Chinese).

[2] 冯云鹏，杨胜保，方善臣，等 . 野生前臀(鳈)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 parent fishes[J]. Scientific fish farming，2024(5)：75-77 (in Chinese).

[3] 姚景龙，陈毅峰，李堃，等 . 中华鳈与前臀鳈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] YU H H，WANG Z M，QIN H X，et al. An automatic detection and counting method for fish lateral line scales of underwater fish based on improved YOLOv5[J]. IEEE access，2023，11：143616-143627.

[5] 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 with English abstract).

[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/OL]. Aquaculture，2023，562：738847[2025-09-29]. https://doi.org/10.1016/j.aquaculture.2022.738847.

[7] GUO Y L，WANG H Y，HU Q Y，et al. Deep learning for 3D point clouds：a survey[J]. IEEE transactions on pattern analysis and machine intelligence，2021，43(12)：4338-4364.

[8] GUO H，LI Z B，MA Q，et al. A bilateral symmetry based pose normalization framework applied to livestock body measurement in point clouds[J]. Computers and electronics in agriculture，2019，160：59-70.

[9] HU H，YU J C，YIN L，et al. An improved PointNet++ point cloud segmentation model applied to automatic measurement method of pig body size[J/OL]. Computers and electronics in agriculture，2023，205：107560[2025-09-29]. https://doi.org/10.1016/j.compag.2022.107560.

[10] 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.

[11] BARRELET C，CHAUMONT M，SUBSOL G. Automatic coral reef fish identification and 3D measurement in the wild [PP/OL]. arXiv，2023：2312.07357 [2025-09-29]. https://arxiv.org/abs/2312.07357.

[12] SU H，MAJI S，KALOGERAKIS E，et al. Multi-view convolutional neural networks for 3D shape recognition[C]//2015 IEEE International Conference on Computer Vision (ICCV). Santiago：IEEE，2016：945-953.

[13] HAMDI A，ALZAHRANI F，GIANCOLA S，et al. MVTN：learning multi-view transformations for 3D understanding[J]. International journal of computer vision，2025，133(4)：2197-2226.

[14] MENG H Y，GAO L，LAI Y K，et al. VV-net：voxel VAE net with group convolutions for point cloud segmentation[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul：IEEE，2019：8499-8507.

[15] CHARLES R Q，HAO S，MO K C，et al. PointNet：deep learning on point sets for 3D classification and segmentation [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu：IEEE，2017：77-85.

[16] QI C R，YI L，SU H，et al. PointNet++：deep hierarchical feature learning on point sets in a metric space[PP/OL]. arXiv，2017：1706.02413 [2025-09-29]. https://arxiv.org/abs/1706.02413.

[17] LI Y Y，BU R，SUN M C，et al. PointCNN：convolution on X-transformed points[J]. Neural information processing systems，2018，31：820-830.

[18] PHAN A V，LE NGUYEN M，NGUYEN Y L H，et al. DGCNN：a convolutional neural network over large-scale labeled graphs[J]. Neural networks，2018，108：533-543.

[19] GUO M H，CAI J X，LIU Z N，et al. PCT：point cloud transformer[J]. Computational visual media，2021，7(2)：187-199.

[20] SNAVELY N，SEITZ S M，SZELISKI R. Photo tourism：exploring photo collections in 3D[J]. ACM transactions on graphics，2006，25(3)：835-846.

[21] SEITZ S M，CURLESS B，DIEBEL J，et al. A comparison and evaluation of multi-view stereo reconstruction algorithms [C]//Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington，DC：IEEE Computer Society，2006：519-528.

[22] RUBLEE E，RABAUD V，KONOLIGE K，et al. ORB：an efficient alternative to SIFT or SURF[C]//2011 International Conference on Computer Vision. Piscataway：IEEE，2011：2564-2571.

[23] HUANG G，LIU Z，VAN DER MAATEN L，et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).

Honolulu:IEEE,2017:2261-2269.
[24] MISRA D,NALAMADA T,ARASANIPALAI A U,et al. Rotate to attend:convolutional triplet attention module[C]// 2021 IEEE Winter Conference on Applications of Computer Vision (WACV).Waikoloa:IEEE,2021:3138-3147.
[25] YU X M,TANG L L,RAO Y M,et al.Point-BERT:pre-training 3D point cloud transformers with masked point modeling[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).Piscataway: IEEE, 2022: 19291-19300.
[26] QIAN G C,LI Y C,PENG H W,et al.PointNeXt:revisiting PointNet++ with improved training and scaling strategies [PP/OL]. arXiv, 2022: 2206.04670 [2025-09-29]. https://arxiv.org/abs/2206.04670 .

Three-dimensional morphological phenotypic extraction of carnichodidae based on end-to-end point cloud segmentation

DAI Zhiwen[1],CHEN Kangfei[1],CHANG Andai[2],SU Xiaojing[3],XIE Lei[2],
YANG Qingyong[1],YANG Ruibin[3],XIONG Hao[2],ZHENG Fang[1]

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

Abstract To achieve high-precision and automatic phenotypic measurement of carpenters, and address the limitations of insufficient phenotypic informations in two-dimensional image processing, as well as the inadequate recognition capability of existing three-dimensional point cloud segmentation models for complex biological structures. This study focuses on *Pareuchiloglanis anteanalis* and proposes an end-to-end point cloud segmentation-based method for extracting three-dimensional morphological phenotypes of sisorid fish. The proposed method reconstructed a high-fidelity 3D point cloud model from multi-view image sequences captured by an RGB camera using the structure from motion (SfM) and multi-view stereo (MVS) algorithms. To effectively separate the target from the background and retain detailed morphological features of the fish body, a hybrid denoising strategy is designed by integrating the random sample consensus (RANSAC) algorithm with HSV spatial color features, which enables accurate background noise removal while preserving fine fish body details. To overcome the insufficient feature extraction capability of the original PointNet++ network, an improved PointNet++ network for point cloud part segmentation is proposed. By incorporating densely connected multi-layer perceptron (DenseNet-MLP), a point triple attention mechanism(PTA), and a multi-scale learning module (MSB), the model's segmentation performance for fine fish body structures was significantly enhanced. Experimental results demonstrated that the mean squared error (MSE) was below 10e-5, the average peak signal-to-noise ratio (PSNR) was 60.8, and the average recall rate was 93.33%. The improved network model achieved a mean intersection over union (mIoU) of 88.9%, an overall accuracy (OA) of 95.5%, and a mean accuracy (mAcc) of 93.8%, representing respective improvements of 3.5, 1.4, and 1.6 percentage point compared with the original model. It can accurately segment key anatomical components such as the fish head, body, and fins. To sum up, the method proposed in this study can be used to accurately measure the phenotypic qualcomm of aquatic animals without contact.

Keywords three-dimensional reconstruction; phenotypic extraction; point cloud segmentation; point cloud processing; PointNet++

(责任编辑:边书京)