

基于 FML-Centernet 算法的鱼类识别检测

刘雨青^{1,2}, 王亚茹^{1,2*}, 黄璐瑶^{1,2}

¹上海海洋大学工程学院, 上海 201306;

²上海海洋可再生能源工程技术研究中心, 上海 201306

摘要 在鱼类识别检测技术中,采用 anchor-free 算法中的 Centernet 算法对鱼类进行识别检测时,低层特征信息容易丢失,导致识别精度和识别效率降低。为此,提出了一种基于 Feature fusion Module and Loss function optimization of Centernet (FML-Centernet) 算法的鱼类识别检测算法。在 Centernet 算法网络结构中引入特征融合模块将低层特征信息和高层特征信息融合,输出更加完整的特征图,提高识别检测精度;设置参数调节正负样本的损失比例,使得网络模型的损失函数得到优化,提高整个模型的识别检测效率。在 PASCALVOC 数据集中对所提算法进行有效性的验证,并对网络结构的性能进行分析。收集大量的目标数据集以及标注数据集信息,训练优化的网络结构并与不同的模型进行对比分析。实验结果表明,FML-Centernet 算法对鱼类进行识别检测时,识别平均精度(AP50)可以达到 85% 以上,平均检测时间低于 100 ms。所提算法不仅识别检测精度较高,而且识别检测效率也得到了提升。

关键词 机器视觉; 鱼类识别检测; Centernet 算法; 特征提取; 特征融合; 优化损失函数

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP202259.1615002

Fish Recognition and Detection Based on FML-Centernet Algorithm

Liu Yuqing^{1,2}, Wang Yaru^{1,2*}, Huang Luyao^{1,2}

¹College of Engineering Science and Technology, Shanghai Ocean University, Shanghai 201306, China;

²Shanghai Engineering Research Center of Marine Renewable Energy, Shanghai 201306, China

Abstract When the Centernet algorithm in an anchor-free algorithm is used to identify and detect fish, the low-level feature information is easily lost, resulting in a decrease in recognition accuracy and efficiency. Therefore, a fish recognition and detection algorithm based on the Feature fusion Module and Loss function optimization of Centernet (FML-Centernet) algorithm is proposed herein. The feature fusion module is incorporated into the Centernet algorithm's network structure to fuse the low- and high-level feature information, generate a more complete feature map, and improve the recognition and detection accuracy. By adjusting the loss ratio of positive and negative samples, the loss function of the network model is optimized and the recognition and detection efficiency of the overall model is improved. The effectiveness of the proposed algorithm is verified using the Pascalvoc dataset, and the performance of the network structure is analyzed. The optimized network structure is then compared with different models using a large number of target datasets and labeling dataset information. The experimental results show that the average recognition accuracy (AP50) of the FML-Centernet algorithm can exceed 85% and the average detection time is less than 100 ms. The proposed algorithm not only has high recognition and detection accuracy but also improves the recognition and detection efficiency.

Key words machine vision; fish recognition and detection; Centernet algorithm; feature extraction; feature fusion; loss function optimization

1 引言

近年来,鱼类识别技术结合机器视觉和深度学习算法成为渔业资源开发的关键技术之一。由于鱼的种

类复杂繁多,形态大小不一,识别有一定的难度。20世纪90年代,研究人员展开了基于机器视觉的鱼类识别方法的研究,这时的研究主要通过人工设计特征实现鱼类识别,但是这些方法耗费资源、效率低下。随

收稿日期: 2021-04-30; 修回日期: 2021-05-28; 录用日期: 2021-07-01

基金项目: 上海市科学技术委员会资助项目(19DZ2254800)

通信作者: *2432526810@qq.com

随着深度学习的发展^[1-3],基于卷积神经网络的鱼类识别技术被广泛应用。Li等^[4]于2017年基于regions with convolutional neural network features (R-CNN)算法提出了一种轻型的适合水下鱼类目标识别的算法,即Faster R-CNN。顾郑平等^[5]于2018年结合卷积神经网络(CNN)和迁移学习算法提出了一种基于预训练Inception V3网络特征和向量机(SVM)算法的混合分类算法对鱼类进行分类识别。2019年,Deep等^[6]提出了一种混合CNN算法,该算法使用CNN框架提取目标特征信息,使用SVM和k近邻(k-NN)的方法对鱼类进行识别分类。

随着 You Only Look Once (YOLO)算法的发展^[3],研究者将YOLO算法应用在鱼类识别上。李庆忠等^[7]结合YOLO算法和迁移学习的方法训练出了Underwater-YOLO网络,实现了对小目标鱼类和重叠目标鱼类的检测。李均鹏^[8]结合MobileNet对YOLO-V3-Tiny存在的特征提取网络层数较浅及特征提取能力不足的问题进行了改进,提出了YOLO-V3-Tiny-MobileNet,该模型对鱼类的识别精度得到有效提高,而且其鲁棒性也比较强。但是,YOLO算法是一种基于先验框的检测算法,先验框会影响检测的准确率。为了提高检测的准确率,本文将无先验框^[9-12]的目标检

测算法——Centernet算法^[13-15]应用到鱼类识别检测技术上,但是Centernet算法中特征提取部分最终只输出一个高层的有效特征图,很容易丢失底层特征信息,且训练过程中正负样本的损失比例不平衡,影响检测的精度。为了解决这些问题,本文在Centernet算法中引入特征融合模块^[16-17]并调节正负样本损失比例的参数,从而提高检测的精度与效率。

2 网络模型设计

2.1 网络结构

Centernet主要由主干网络和检测网络组成。主干网络主要对图片进行特征提取,输出一个有效的特征图,Cenetnet的常用主干网络有Hourglass Network、DLANet和Resnet三种,Hourglass Network结构参数量比较大,DLANet没有完整的资源。故本实验组使用Resnet50作为Centernet的特征提取网络,但其最终输出的是一个高层特征,可能会导致低层特征的信息丢失。为了解决这一问题,本实验组引入特征融合模块将高层特征和低层特征进行融合,即把特征提取网络中的特征图C3、C4、C5进行特征融合,最终输出一个更有效的特征图,并利用此特征图预测热力图、中心坐标和宽高度。所提算法网络结构如图1所示。

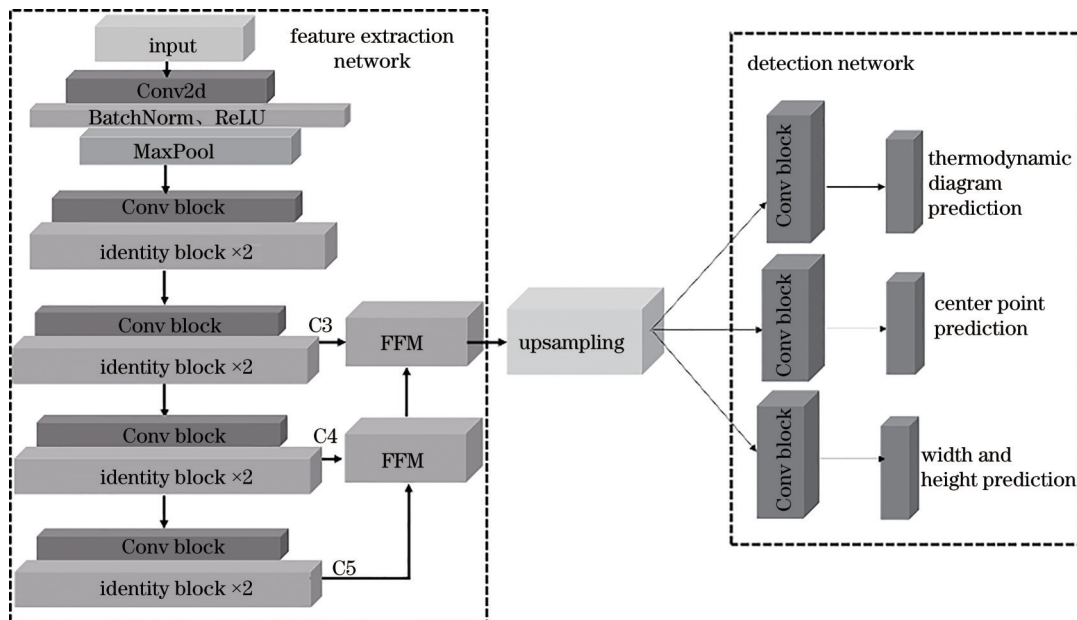


图1 所提算法网络模型结构

Fig. 1 Network model structure of proposed algorithm

2.2 特征融合

特征提取网络可以输出不同尺度的特征层,低层特征具有较高的分辨率、更多的位置信息及其他细节信息,但是经过的卷积层比较少,从而导致其语义性比较低并且有更多的噪声。高层特征经过的卷积层较多,语义性比较强,噪声也比较少,但是分辨率过低,感知细节的能力较差。将底层特征和高层特征融合在一

起,不仅能够提高分辨率和语义性,还能够减低噪声,可以提高目标检测能力。本实验组采用Feature Fusion Module (FFM)算法进行特征融合,如图2所示。

FFM算法通过反卷积上采样使高层特征的尺度与低层特征尺度相同,再通过连接层和卷积层将高层特征和低层特征融合在一起输出一个初步的融合特征图,然后通过引进的通道注意力机制(结构类似于

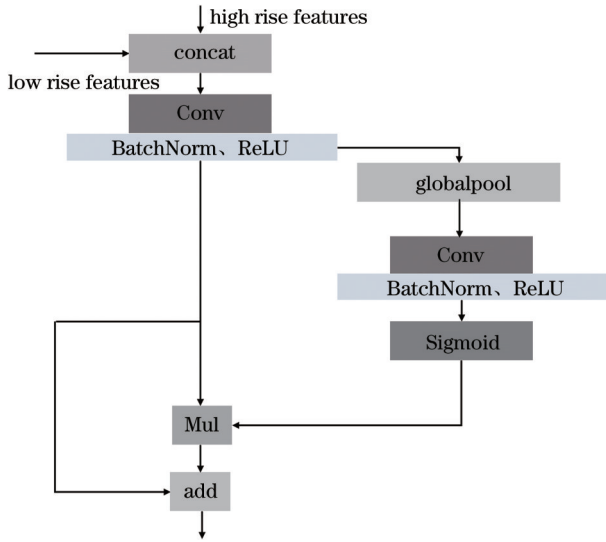


图 2 FFM 网络结构

Fig. 2 Network structure of FFM

SENet^[18]对初步融合特征图中相连接的特征进行全局平均池化,生成一个特征向量,同时学习出一个权重向量,最后将其与初步融合特征图进行加权,输出一个更有效的融合特征图。之所以引进这样的注意力机制,原因在于其可以使得融合特征图的表达能力增强,并且减低特征融合后产生的噪音。FFM可以描述为

$$y(x) = \omega_0 + \sum_{i=1}^n \omega_i x_i + \sum_{i=1}^{n-1} \sum_{j=i+1}^n \langle \mathbf{v}_{i,f_j}, \mathbf{v}_{j,f_i} \rangle x_i x_j, \quad (1)$$

式中: $\omega_0 + \sum_{i=1}^n \omega_i x_i$ 是线性部分, ω_0 是权重;

$\sum_{i=1}^{n-1} \sum_{j=i+1}^n \langle \mathbf{v}_{i,f_j}, \mathbf{v}_{j,f_i} \rangle x_i x_j$ 是非线性部分,这部分是 FFM 算法的核心,其中 x 是样本, n 是样本 x 的维度, x_i 是第 i 个维度上的值, x_j 是第 j 个特征的值; \mathbf{v}_i 和 \mathbf{v}_j 是对应 x 的隐向量。

2.3 损失函数设计

在 Centernet 算法中,负责预测的是物体中心左上角的特征点,在训练时需要找到真实框,通过真实框和对应图片的预测结果计算模型的损失函数。损失函数主要由热力图的损失(目标分类置信度的损失)、中心点位置的损失、宽高损失 3 部分组成。

针对分类置信度的损失函数 L_k ,由于模型的最终输出为一个低分辨率的特征图,并且一个特征点只能对一个目标进行预测,会产生极度不平衡的正负样本。为了使得模型能够产生较为平衡的正负样本,本实验组通过目标分类置信度的损失函数来实现这一目标。

$$L_k = \alpha_1 L_n + \alpha_2 L_p, \quad (2)$$

$$L_n = -(1 - \hat{Y}_{xyc})^{\beta_1} \log(\hat{Y}_{xyc} + \delta), \quad (3)$$

$$L_p = -(1 - \hat{Y}_{xyc})^{\beta_2} \log \hat{Y}_{xyc}, \quad (4)$$

式中:图像的正负样本为 x_{yc} ; \hat{Y}_{xyc} 是图像的预测值; α, β, δ 为相应参数。在目标分类置信度的损失函数中,为了解决正负样本不平衡的问题,需要让正样本的损失得到提高,负样本的损失降低。因此设置了

α, β, δ 3 个参数,参数值是通过多次搜索验证得到的最优数据。通过设置 β_1 和 δ 两个参数实现降低负样本的损失,损失函数为 L_n ;调节 β_2 实现提升正样本的损失比例,损失函数 L_p 。正负样本的损失比例使用 α 参数进行控制,从而得到类别置信度函数 L_k 。

在主干网络图片经过下采样后,特征图被重新映射到原图时会发生像素偏移从而产生精度误差。中心点位置的损失 L_o 的表达式为

$$L_o = \frac{1}{N} \sum_p \hat{O}_p - \left(\frac{p}{R} - \hat{p} \right), \quad (5)$$

式中: N 是图像中关键点的总数;原图的真实值的坐标为 p ;预测的物体中心点坐标为 \hat{p} ; R 为主干网络下采样的倍数; \hat{O}_p 表示预测的偏移量,每个目标中心点都通过偏移量补偿偏差。网络对每个目标尺度进行预测时,宽高会产生一定的误差,宽高的损失 L_s 的表达式为

$$L_s = \frac{1}{N} \sum_{k=1}^N \left| \hat{S}_{pk} - S_k \right|, \quad (6)$$

式中: S_k 代表真实图像的尺度; \hat{S}_{pk} 代表预测图像的尺度。则总的损失函数为

$$L_D = L_k + \varphi_o L_o + \varphi_s L_s \quad (7)$$

式中: φ_o 和 φ_s 分别是中心点损失和宽高损失所占的比例。

3 样本数据集

3.1 样本数据集增强

采用水下摄像头和网络爬虫的方式获取鱼类图片,但是在保证图片质量的情况下,图片数量有限。因此,要对已有的小样本数据集进行数据扩增处理,从而得到大样本数据集。大样本数据集有利于网络模型的训练与验证,使得网络模型的泛化能力更强。

数据扩增手段主要包含随机旋转图像、调整曝光度和饱和度、调整亮度分量、调节直方图均衡化的阈值等。图 3 为图像进行空间变换的结果。

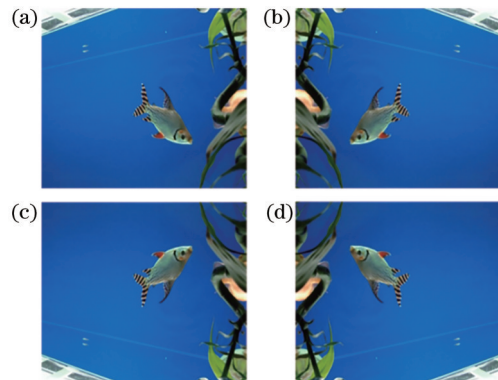


图 3 图像空间几何变换。(a)原始图像;(b)镜像;(c)翻转;(d)旋转

Fig. 3 Image space geometric transformation. (a) Original image; (b) mirror image; (c) flip; (d) spin

3.2 数据集标注

数据集标注就是人工划分出图像中相关目标所在区域的位置信息、分类信息和语义信息等,使得模型训练时更好获取目标的特征。不同领域的需求不同,对于标注的要求也是不同的。在目标检测与识别和图像分类的数据集中,只需要标注图片中所含目标类别。

随着人工智能的发展,深度学习的数据标注工具也有许多。本实验组用 labelImg 对目标样本进行矩形框标注,标注信息采用 PascalVOC 数据集的格式进行保存,标注的类别信息级边界框坐标信息以 xml 格式存在,如图 4 所示。标注的数据包含文件名、图片来源及拥有者、图片大小、图片类别、检测难易程度、目标坐标值等。

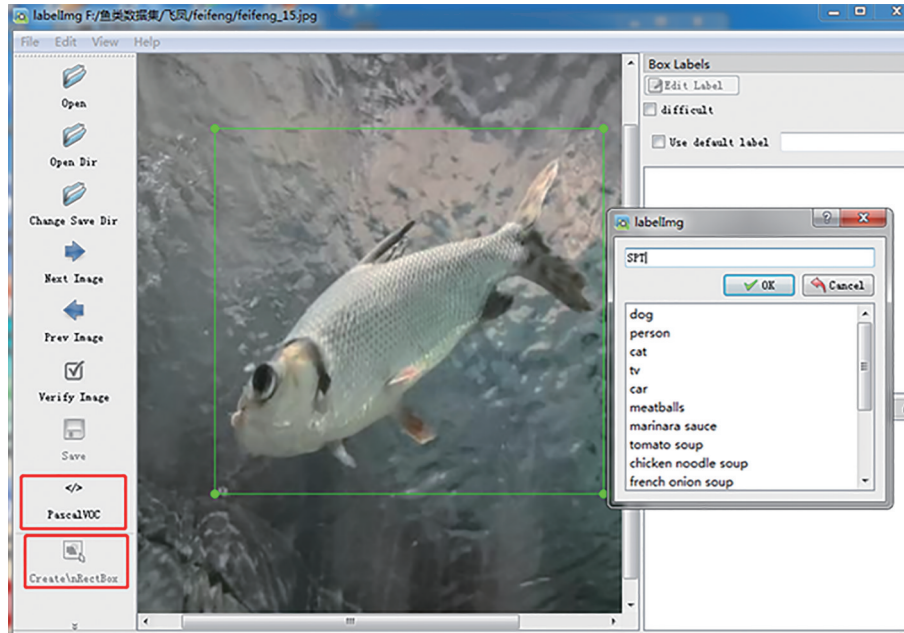


图 4 标注数据
Fig. 4 Label data

3.3 目标数据集

目标数据集共包含 5 种鱼类,分别为飞凤鱼 (SPT)、银鲳鱼 (Pomfret)、大甲鲈 (Linnaeus)、蓝黄梅

鲷 (CT) 和观赏鱼类 (DF), 每种各有 200 张图片, 共标记了 1523 个样本。鱼类数据集的部分图片如图 5 所示, 此数据集用于接下来的模型训练与模型验证。




图 5 目标数据集
Fig. 5 Target dataset

4 网络结构的训练与验证

4.1 实验环境配置

实验在 Inter(R) i5 CPU、32 GB RAM 和 Nvidia GTX 1060Ti 的硬件设备上进行,采用 VS code 编辑器,深度学习的框架是 Tensorflow-gpu 1.13.1 和 Keras 2.1.5,模型训练步数 step 设置为 1000,学习率为 0.001,训练整个样本的 epoch 设置为 100。

4.2 算法有效性验证

首先在 PASCALVOC 数据集上验证所提算法的有效性。训练集为 VOC07+12,测试集为 07test-dev,共训练 2000 轮。然后对不同算法进行对比实验:实验 1 是原始的 Centernet 算法,用 Centernet 表示;实验 2 是引入特征模块的算法,用 FMCCenternet 表示;实验 3 是在实验 2 的基础上改进损失函数的算法,用 FML-Centernet 表示。评价指标选用平均精度 (AP),AP 是通过预测值与真实值的平均交并比 (IoU) 的阈值计算出来的,AP 越高,网络模型的有效性越高,识别准确率就越高。设置的阈值不同,得到的 AP 也不相同。本

实验中设置 3 种阈值,当 IoU 阈值为 0.5 到 0.95,对应的平均精度为 AP;当 IoU 阈值为 0.5 时,对应的平均精度为 AP50;当 IoU 阈值是 0.75 时,对应的平均精度 AP75。具体结果如表 1 所示。

表 1 不同算法的对比分析实验

Table 1 Comparative analysis experiments of different

Algorithm	algorithms			unit: %
	AP75	AP50	AP	
Centernet	28.65	79.21	38.03	
FMCCenternet	31.51	81.36	37.98	
FML-Centernet	42.51	85.99	43.91	

从表 1 可以看出:3 种情况下,FML-Centernet 的 AP 都比原始 Centernet 算法高;且 FMCCenternet 的 AP50 达到了 81.36%。但所提 FML-Centernet 的 AP 是最高的,AP50 达到了 85.99%。

4.3 目标数据集的训练

将目标数据集在 3 种不同的网络模型中进行训练,观察训练时损失函数的变化。图 6~8 分别为




图 6 Centernet 的损失函数曲线

Fig. 6 Loss function curve of Centernet




图 7 FMCCenternet 的损失函数曲线

Fig. 7 Loss function curve of FMCCenternet




图 8 FML-CenterNet 的损失函数曲线

Fig. 8 Loss function curve of FML-CenterNet

CenterNet、FMCenterNet、FML-CenterNet 的损失函数曲线。从图 6 可以看出,原始 CenterNet 网络模型训练 85 轮时,损失函数值最小,为 0.2565。从图 7 可以看出,当模型训练达到 40 轮时,损失函数值为 0.2,训练 80 轮时,损失函数值最小,为 0.0058。由此可知,引入特征融合模块可以使损失函数值下降得更快,且变得更小,说明预测值与真实值之间的误差更小,识别的精度就更高,模型的拟合效果更好。

在引入特征融合模块的网络模型中修改损失函数。通过设置损失函数中的参数值,调节正负样本损失的比例,优化整个模型中损失函数。通过不断地设置参数值获取最优的数据,设置 $\beta_1 = 3$ 和 $\delta = 0.2$ 两个参数实现降低负样本的损失,正样本的损失则利用

$\beta_2 = 1.5$ 来提升。正负样本的损失比例使用 α 参数进行控制,设置 $\alpha_1 = 0.25, \alpha_2 = 1$, 得到类别置信度函数 L_k 。从图 8 可以看出,模型训练迭代到 95 轮时,损失函数值最小,为 0.0024,仅是 FMCenterNet 的最小值的 0.41,说明通过设置参数来平衡正负样本的损失比例,对模型的损失函数进行优化是有效的。

5 不同网络模型的验证分析

5.1 不同网络模型的对比分析

使用训练集和验证集验证网络模型的有效性,将 Faster-RCNN、YOLOV4、CenterNet、FMCenterNet 和 FML-CenterNet 进行对比。此时网络模型有效性的评估标准是 AP50 及平均检测时间。具体的实验结果如表 2 所示。

表 2 不同网络模型的对比分析实验结果

Table 2 Comparative analysis of experimental results of different network models

Network model	Network structure	AP50 / %	Average detection time /ms
Faster-RCNN	VGG	74.32	221.35
YOLOV4	CSPDarknet53	76.95	185.46
CenterNet	ResNet50	79.21	178.69
FMCenterNet	ResNet50+FFM	81.36	140.23
FML-CenterNet	ResNet50+FFM+LOSS	85.99	99.85

从表 3 可以看出,3 种 CenterNet 网络模型的 AP50 均高于 Faster-RCNN 和 YOLOV4,说明无先验框的识别检测算法比有先验框识别检测算法具有优越性。引入特征融合模块的 FMCenterNet 的 AP50 高于 CenterNet,说明特征融合模块能够很好地融合高层特征信息和低层特征信息,使得整个网络模型的识别精度提高。在引入特征融合模块的基础上,调节训练过程中正负样本的损失比例优化整个网络模型的损失函数,结果显示 FML-CenterNet 网络模型的 AP50 是最高的。FML-CenterNet 的 AP50 比 CenterNet 高 6.78 个百

分点,比 FMCenterNet 高 4.63 个百分点。FML-CenterNet 的平均检测时间在 100 ms 以内,识别检测效率高于其他模型。实验结果表明,优化损失函数可以提高网络模型的识别精度和识别检测速率,从而提高网络模型的性能。

5.2 目标测试集的结果验证

使用目标测试集对不同网络模型进行验证,使用 Faster-RCNN、YOLOV4 和 FML-CenterNet 网络训练好的权重文件识别目标数据集中的 5 类鱼。以 AP50 和平均检测时间为参考指标,AP50 的值越大,说明模

型的识别率就越大,平均检测时间越短,模型的拟合效果就越好。详细结果如表 3 所示。部分识别结果如图 9 所示。

表 3 不同网络模型对目标测试集的验证结果

Table 3 Verification results of different network models on target test set

Network model	Fish	AP50 %	Average detection time /ms
Faster-RCNN	SPT	73.82	220.36
	Pomfret	74.21	218.23
	Linnaeus	73.34	219.34
	CT	74.53	215.26
	DF	74.15	217.35
YOLOV4	SPT	76.96	180.52
	Pomfret	76.52	181026
	Linnaeus	76.03	184.37
	CT	77.01	183.45
	DF	76.86	187.25
FML-Centernet	SPT	85.45	100.21
	Pomfret	86.13	98.36
	Linnaeus	86.02	98.45
	CT	85.86	96.15
	DF	86.24	97.69




图 9 部分识别结果。(a)(b) Faster-RCNN; (c)(d) YOLOV4; (e)(f) FML-Centernet

Fig. 9 Partial recognition results. (a) (b) Faster-RCNN; (c) (d) YOLOV4; (e) (f) FML-Centernet

从表 3 可以看出, FML-Centernet 对每类鱼的识别准确率都高于其他的网络模型, 对于 Linnaeus 的识别率可以达到 86.02%, 对于 DF 的识别可以达到 86.24%。平均检测时间在 100 ms 内。实验结果表明, 在 Centernet 算法中引入特征融合模块和调节正负样本损失比例的参数是可以有效地提高识别率和工作

效率的。因此, 所提算法可以广泛应用于鱼类识别技术上。

6 结 论

随着目标检测算法不断被推出, 鱼类识别技术有所提高, 基于先验框的目标检测算法被广泛应用于鱼类识别技术上, 但是先验会降低识别检测的正确率。本实验组使用改进的 Centernet 算法对鱼类进行识别, 在原始的特征提取模块中加入特征融合模块, 将低层特征信息和高层特征信息融合到一起, 生成一个更有效的特征图, 提高识别检测精度。此外, 训练过程中正负样本的损失比例不平衡, 通过调节 β_1 和 δ 两个参数实现负样本损失的降低, 实现正样本损失的提升由 β_2 来调节, 正负样本的损失比例由 α 参数进行控制, 最终网络模型的损失函数得到优化, 降低了损失函数值, 提高了识别检测效率。实验结果表明, 引入特征融合模块和设置调节正负样本损失的比例参数能够提高识别检测效率, 所提 FML-Centernet 算法可以广泛应用到鱼类识别技术中。

参 考 文 献

- [1] 王一同, 周宏强, 闫景道, 等. 基于深度学习算法的计算光学研究进展[J]. 中国激光, 2021, 48(19): 1918004. Wang Y T, Zhou H Q, Yan J X, et al. Advances in Computational Optics Based on Deep Learning[J]. Chinese Journal of Lasers, 2021, 48(19): 1918004.
- [2] 亢超, 李文祥, 黄岫, 等. 基于深度学习的主动光学校正算法研究[J]. 光学学报, 2021, 41(6): 0611004. Kang C, Li W X, Huang S, et al. Research on Active Optical Correction Algorithm Based on Deep Learning [J]. Acta Optica Sinica, 2021, 41(6): 0611004.
- [3] 刘中法, 杨艺哲, 方宇, 等. 基于深度学习的虚拟相衬成像方法[J]. 光学学报, 2021, 41(22): 2217001. Liu Z F, Yang Y Z, Fang Y, et al. Deep Learning-Based Virtual Phase Contrast Imaging Method[J]. Acta Optica Sinica, 2021, 41(22): 2217001.
- [4] Li X, Tang Y H, Gao T W. Deep but lightweight neural networks for fish detection[C]//OCEANS 2017-Aberdeen, June 19-22, 2017, Aberdeen, UK. New York: IEEE Press, 2017: 17290486.
- [5] 顾郑平, 朱敏. 基于深度学习的鱼类分类算法研究[J]. 计算机应用与软件, 2018, 35(1): 200-205. Gu Z P, Zhu M. Fish classification algorithm based on depth learning[J]. Computer Applications and Software, 2018, 35(1): 200-205.
- [6] Deep B V, Dash R. Underwater fish species recognition using deep learning techniques[C]//2019 6th International Conference on Signal Processing and Integrated Networks (SPIN), March 7-8, 2019, Noida, India. New York: IEEE Press, 2019: 665-669.
- [7] 李庆忠, 李宜兵, 牛炯. 基于改进 YOLO 和迁移学习的水下鱼类目标实时检测[J]. 模式识别与人工智能, 2019, 32(3): 193-203.

- Li Q Z, Li Y B, Niu J. Real-time detection of underwater fish based on improved YOLO and transfer learning[J]. *Pattern Recognition and Artificial Intelligence*, 2019, 32(3): 193-203.
- [8] 李均鹏. 基于迁移学习的复杂场景鱼类识别方法研究[D]. 大连: 大连海洋大学, 2020.
- Li J P. Research on methods for fish identification under the complex scene based on transfer learning[D]. Dalian: Dalian Ocean University, 2020.
- [9] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 779-788.
- [10] Law H, Deng J. CornerNet: detecting objects as paired keypoints[J]. *International Journal of Computer Vision*, 2020, 128(3): 642-656.
- [11] Tian Z, Shen C H, Chen H, et al. FCOS: fully convolutional one-stage object detection[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 9626-9635.
- [12] Zhou X Y, Wang D Q, Krähenbühl P. Objects as points [EB/OL]. (2019-04-16)[2021-03-04]. <https://arxiv.org/abs/1904.07850>.
- [13] Tang C W, Liu C L, Chiu P S. HRCenterNet: an anchorless approach to Chinese character segmentation in historical documents[C]//2020 IEEE International Conference on Big Data (Big Data), December 10-13, 2020, Atlanta, GA, USA. New York: IEEE Press, 2020: 1924-1930.
- [14] Fan S Q, Zhu F H, Chen S C, et al. FII-CenterNet: an anchor-free detector with foreground attention for traffic object detection[J]. *IEEE Transactions on Vehicular Technology*, 2021, 70(1): 121-132.
- [15] 姜建勇, 吴云, 龙慧云, 等. 基于 CenterNet 的实时行人检测模型[J]. *计算机工程*, 2021, 47(10): 276-282.
- Jiang J Y, Wu Y, Long H Y, et al. CenterNet-based real-time pedestrian detection model[J]. *Computer Engineering*, 2021, 47(10): 276-282.
- [16] 徐仲谋, 杨亦乐, 董飞, 等. 基于 CenterNet-GYolov3 的车辆检测方法[J]. *软件*, 2020, 41(5): 25-30.
- Xu Z M, Yang Y L, Dong F, et al. Vehicle detection method based on CenterNet-GYolov3[J]. *Computer Engineering & Software*, 2020, 41(5): 25-30.
- [17] 邢林春, 罗建华, 陈正捷, 等. 基于 Dempster-Shafer 证据理论的特征融合在军用电子设备模块化故障诊断过程中的应用[J]. *装甲兵工程学院学报*, 2005, 19(4): 35-38.
- Xing L C, Luo J H, Chen Z J, et al. Applied research on characteristics fusion based on Dempster-Shafer evidential theory on failure diagnosis for military electronic equipment module[J]. *Journal of Armored Force Engineering Institute*, 2005, 19(4): 35-38.
- [18] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.