

DOI:10.3969/j.issn.2096-8248.2024.01.008

## 基于残差连接的水下小目标检测结构模型\*

杨森<sup>a</sup>, 董金耐<sup>a</sup>, 谢卓冉<sup>a</sup>, 蔡立鹏<sup>b</sup>, 钟锦扬<sup>a</sup>

(江苏海洋大学 a. 电子工程学院; b. 海洋工程学院, 江苏 连云港 222005)

**摘要:** 由于水下成像距离较远, 现有的水下图像目标检测数据集中存在大量小目标, 水下小目标特征信息和语义信息少, 目前常用的目标检测算法直接应用于水下检测时小目标漏检错检率较高。水下目标检测预处理阶段通常采用图像增强算法来提升图像观感质量, 并以此提升小目标检测精度, 但图像增强的数据预处理操作容易导致小目标特征丢失, 小目标检测性能下降。提出了一种基于残差连接的水下小目标检测结构模型, 讨论了图像增强提升目标检测性能的应用方式, 通过残差连接将增强算法与目标检测算法联合优化, 避免了过度增强导致的特征丢失问题, 提升了水下小目标检测精度。所提出的算法在 DUO 数据集上进行了实验, 实验结果表明, 相较于 YOLOv7, 该算法对小目标检测精度提升了 7.2%。在两个水下数据集上进行消融实验, 验证了所提出的残差连接的方式对于提升小目标检测性能具有促进作用。

**关键词:** 小目标检测; 图像增强; 残差连接; 联合训练

中图分类号: TP391

文献标志码: A

文章编号: 2096-8248(2024)01-0058-08

**引用格式:** 杨森, 董金耐, 谢卓冉, 等. 基于残差连接的水下小目标检测结构模型[J]. 江苏海洋大学学报(自然科学版), 2024, 33(1): 58-65.

## Underwater Small Object Detection Model Based on Residual Connections

YANG Miao<sup>a</sup>, DONG Jinnai<sup>a</sup>, XIE Zhuoran<sup>a</sup>, CAI Lipeng<sup>b</sup>, ZHONG Jinyang<sup>a</sup>

(a. School of Electronic Engineering; b. School of Ocean Engineering,

Jiangsu Ocean University, Lianyungang 222005, China)

**Abstract:** Due to the long distance of underwater imaging, there are a large number of small objects in the existing underwater image object detection datasets, and there is little feature and semantic information of underwater small objects. When the existing object detection algorithms are directly applied to underwater detection, the missed detection and false detection rate of small objects is relatively high. In the preprocessing stage of underwater object detection, image enhancement algorithms are usually used to improve the visual quality of images and improve the accuracy of small object detection. However, the data preprocessing operation of image enhancement can easily lead to the loss of small object features and a decrease in the performance of small object detection. Therefore, a structural model for underwater small object detection based on residual connections is proposed, and the application methods of image enhancement to improve ob-

\* 收稿日期: 2023-03-24; 修订日期: 2023-11-12

**基金项目:** 国家自然科学基金资助项目(62271236, 12171205); 江苏省自然资源发展专项资金(海洋科技创新)项目(JSZRHYKJ202116); 江苏省研究生科研与实践创新计划项目(KYCX2021\_053, KYCX22\_3395)

**作者简介:** 杨森(1978—), 女, 黑龙江五常人, 教授, 博士, 研究方向为海洋信息处理、人工智能及其应用、计算机应用技术和智能信息处理等, (E-mail) lemonmiao@gmail.com.

**通信作者:** 董金耐(1998—), 男, 河北邢台人, 硕士研究生, 研究方向为水下目标检测, (E-mail) jinnaidong@outlook.com.

ject detection performance are discussed. The enhancement algorithm and object detection algorithm are jointly optimized through residual connections, avoiding the problem of feature loss caused by excessive enhancement and improving the accuracy of underwater small object detection. The proposed algorithm was tested on the DUO dataset, and the experimental results showed that compared to YOLOv7, the algorithm improved the accuracy of small object detection by 7.2%. Ablation experiments were conducted on two underwater datasets, verifying that the proposed residual connection method has a promoting effect on improving the performance of small object detection.

**Key words:** small object detection; image enhancement; residual connection; joint training

水下目标检测是水下机器人自主作业视觉任务的重要组成部分。基于光学图像的检测方式分辨率较高,灵活性好,在近距离的水下目标检测任务中具有显著优势<sup>[1]</sup>。小目标检测长期以来作为目标检测中的重点和难点之一,为国内外研究人员广泛关注<sup>[2]</sup>。对小目标的定义一般分两种<sup>[3]</sup>,一种是计算目标面积像素占比,目标像素面积小于  $32^2$  时定义为小目标,另一种为计算目标像素点数在原图总像素的占比,占比小于 0.12% 的目标定义为小目标。目前常用的水下目标检测数据集,包括大型鱼类数据集 Fish4Knowledge<sup>[4]</sup>, Fishclef<sup>[5-7]</sup>, 野生鱼类数据集 Wild Fish Marker<sup>[8]</sup>, 丹麦北部的海峡 Brackish<sup>[9]</sup> 数据集,大连 URPC 挑战赛数据集和 DUO<sup>[10]</sup> 数据集等,由于水下成像距离较远,均含有一定比例的小目标,例如 URPC2021 数据集中存在 7.9% 的小目标,DUO 数据集中存在 4.2% 的小目标,Brackish 和 2015Fishclef 数据集中全部为小目标。小目标的检测精度往往低于其他尺寸目标检测精度,导致整体检测精度下降。

小目标存在覆盖面积较低、分辨率不足、特征表达不充分的问题,且由于模糊退化及色彩投射,分割小目标与背景非常困难,导致小目标检测漏检错检率较高。在水下特殊的成像环境中,图像可见度较低,水下小目标检测较为困难。Zhou 等<sup>[11]</sup> 和 Ye 等<sup>[12]</sup> 采用基于深度学习的水下图像增强(UIE)技术作为目标检测预处理操作,通过提高水下图像的视觉质量来提高小目标的特征表达能力,进而提升水下小目标的检测精度。然而有研究人员<sup>[13-14]</sup> 指出,直接将增强图像用于水下目标检测,由于增强方法侧重于提高能见度和对比度,并不能有效提高目标检测的精度,相反还会降低目标检测的表现。图像增强与目标检测联合训练的方式,使得增强算法按照目标检测性能为标准提升小目标的检测精度,

但是该方式加深了网络层数<sup>[15]</sup>,在训练中容易出现“退化现象”,导致检测效果下降。

本文对增强方法应用于目标检测性能提升的方式进行了探讨,提出基于图像增强与目标检测联合训练的检测结构模型,采用残差连接方式,通过将提升质量后的水下图像与原图特征融合来增强小目标所在区域质量,提升小目标的信息特征表达能力,进而解决目标检测联合训练方法由于网络加深导致的退化问题,提升小目标的检测精度。

## 1 相关工作

小目标检测一直以来都是目标检测任务的难点。目前常用的水下数据集中均存在大量的小目标(示例见图 1)。小目标特征信息和语义信息少,目标尺寸与背景尺寸不均衡,且在水下环境中图像退化严重,相较于自然环境下更容易与背景中噪声混淆,检测难度更大。




图 1 水下目标检测数据集示例

Fig. 1 Examples of underwater object detection dataset

针对小目标覆盖面积小、特征信息表达不充分的问题,研究人员采用引入上下文信息、数据增强、多尺度特征融合、注意力机制等方式提升小目标的检测性能。Zhang 等<sup>[16]</sup>在 SSD 基础上引入注意模块和多尺度特征融合,对通过卷积获得的输入图像的特征在通道和空间两方面进行加权,以突出显示克服水下图像中常见物体小而模糊等问题的有用信息,在 URPC 数据集上训练和测试,对小目标的检测性能显著提升。Pan 等<sup>[17]</sup>提出了多尺度的目标检测算法 M-ResNet,在预处理阶段采用 GAN 网络对水下图像进行增强,对检测网络选择三个尺度特征图,并在每个尺度的每个网格设置三种比例的锚框,提升了小目标检测的效果。Chen 等<sup>[18]</sup>提出 SWIPENet 神经网络,利用多个超分辨率的特征图且在多种尺寸的特征图上预测来改善小物体检测。

针对水下图像对比度低,水下小目标特征弱、易与背景噪音混淆的问题,一些学者基于图像增强技术来提高图像对比度,利用增强小目标特征信息的方式对小目标检测性能进行了改进。Yang 等<sup>[19]</sup>在 2021 年提出了一种轻量级的自适应特征融合网络 LAFFNet,通过多个不同尺寸的分支生成多尺度特征图,然后利用通道注意自适应地拼接这些特征映射,对水下图像进行增强,最终增强后的图像能更好地适应各种高级视觉任务。Liu 等<sup>[13]</sup>提出一种基于

对象引导的双对抗对比学习的水下增强方法,将增强后的图像对目标检测模型进行预训练,之后将水下增强算法直接与目标检测模型进行结合训练,增强了水下目标检测算法的性能。Zhang 等<sup>[15]</sup>提出一种图像增强和目标检测联合训练的方法,针对水下环境在增强模块中引入去噪、色彩校正和去模糊三个子模块,缓解同时导致水下成像质量显著下降的三个主要因素的影响,用于提升水下目标检测算法的性能。图像增强与目标检测独立优化时,图像增强以人眼感官为标准,丢失了小目标的特征信息,导致检测精度下降。图像增强和目标检测联合训练的方式,大大增加了网络深度,在训练过程中容易出现网络退化现象,导致目标检测精度下降。

## 2 基于残差连接的水下小目标检测结构模型

水下图像质量严重退化导致小目标检测漏检错检率较高。水下图像增强是改善水下图像质量,提高目标特征信息利用率的有效手段。目前常见的增强方法侧重于提高能见度和对比度,忽略了相关的内在特征检测,因此不能有效提高目标检测的精度。对此,本文提出了残差连接的小目标检测模型,其整体网络结构如图 2 所示。

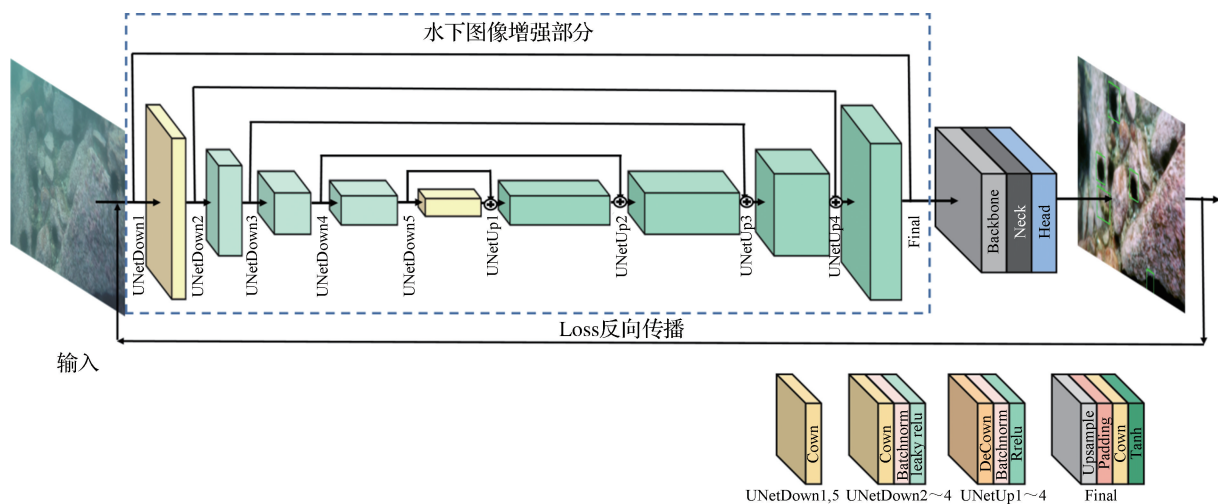


图 2 基于残差连接的水下小目标检测网络框架

Fig. 2 Framework of underwater small object detection network based on residual connections

该模型采用图像增强网络生成图像与原图的残差连接方式来丰富图像小目标的表征性,通过图像增强丰富水下图像的色彩和对比度信息,利用残差连接将增强后的图像与原图进行融合来补充水下小

目标的特征信息,将增强处理后的图像输入目标检测网络框架,计算类别和位置的 Loss,反向更新图像增强和目标检测的权重,使得图像增强网络以目标检测性能为标准对图像进行增强,达到小目标检

测性能提升的效果。这种方法避免了过度增强导致的特征丢失问题,提升了水下小目标检测精度。所提出的结构模型在 DUO 数据集上进行了实验,实验结果表明该结构模型相较于 YOLOv7 对小目标检测精度提升了 7.2%,其他尺寸目标均有提升。在两个水下数据集上进行了消融实验,验证了本文所提出的残差连接的方式对于提升小目标检测性能具有重要作用。

基于残差连接的水下小目标检测模型的图像增强部分采用 U-Net 型编解码器结构,生成器网络部分采用 U-Net 型编解码器结构。输入图像分辨率为  $640 \times 640 \times 3$ ,其中编码器第一层和第五层采用步长为 2 的  $3 \times 3$  卷积操作,第 2,3,4 层采用卷积、批归一化以及 leaky relu 非线性激活函数叠加,编码器最终学习到  $640$  个大小为  $8 \times 8$  的特征映射。解码器使用这些特征映射来学习生成增强的  $640 \times 640 \times 3$  图像,并按照图像中的连接方式将相应层进行通道叠加。解码器 1~4 层采用反卷积、批归一化以及 relu 非线性激活函数叠加。最终经过上采样、padding、卷积以及 Tanh 激活函数。鉴别器采用马尔可夫 PatchGAN 架构。该架构基于 patch 级别的信息进行区分,这种方式对于有效捕捉局部纹理和风格等高频特征非常重要且参数量更少。4 个卷积层用于将  $640 \times 640 \times 6$  输入(真实图像和生成图像)转换为  $40 \times 40 \times 1$  输出,代表鉴别器的平均有效性响应。在每一层,使用步长为 2 的  $3 \times 3$  卷积滤波器,然后以与生成器相同的方式应用非线性和 BN。

本文利用在 EUVP 数据集上预先训练好的 Funiegan 模型来初始化模型,之后仅利用生成器部分将水下图像输入到生成器中进行增强,经过生成器中的编码器和解码器后得到初始的增强图像。将原图与增强后的图像利用残差连接进行 concat 取均值,经过残差连接后的增强图像丰富了图像信息量,增加图像的整体和局部对比度,并且融合浅层特征图的纹理信息和高层特征图的语义信息来增强预测的特征表示。

为满足水下检测实时性、精度高的要求,目标检测网络采用最新的目标检测器 YOLOv7<sup>[20]</sup>。增强后  $640 \times 640 \times 3$  大小的图像输入到 Backbone 网络中(Backbone 网络结构如图 3 所示),首先经过 4 层 CBS,CBS 主要由 Conv+BN+SiLU 构成,之后特征图变为  $160 \times 160 \times 256$  大小。随后经过由多个 CBS 构成的 ELAN 模块,后面的输入通道与上层输出通道保持一致,经过最后一个 CBS 输出为需要的通道。然后为 3 个 MP+ELAN 的输出,对应 C3/C4/C5 的输出,大小分别为  $80 \times 80 \times 512$ ,  $40 \times 40 \times 1024$ ,  $20 \times 20 \times 1024$ 。其中 MP 层将特征图按通道数进行拆分,一部分经过 Maxpool 和 CBS 操作,另一部分经过两次 CBS 操作,之后将两部分按照通道数进行叠加,恢复为输入的通道数。Head 部分对于 Backbone 最后输出的 32 倍降采样特征图 C5,然后经过 SPPCSPC,通道数从 1024 变为 512。先按照 topdown 和 C4,C3 融合,得到 P3,P4 和 P5,再按 bottom-up 和 P4,P5 作融合。

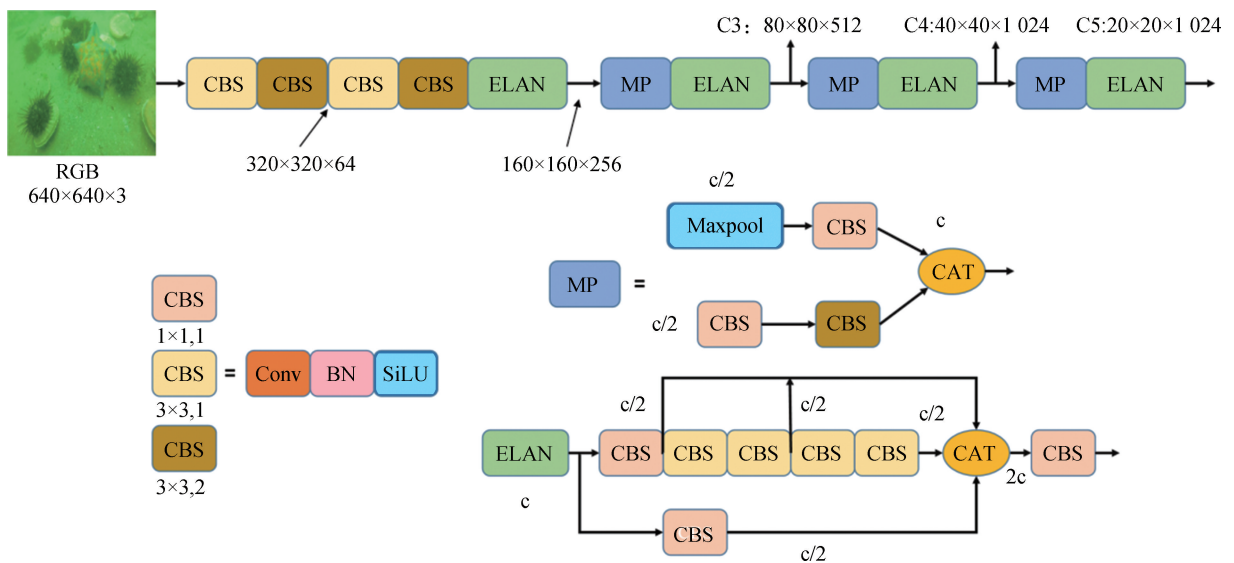


图 3 YOLOv7 Backbone 结构  
Fig. 3 Backbone structure of YOLOv7

基于残差连接的目标检测算法 Loss 设计如式(1)所示,置信度损失和分类损失均采用 BCEWithLogitsLoss<sup>[20]</sup> 函数进行计算,坐标损失采用 CIoU 计算,计算公式如式(2)所示。

$$\text{Loss}_{\text{object}} = \text{Loss}_{\text{loc}} + \text{Loss}_{\text{conf}} + \text{Loss}_{\text{class}}, \quad (1)$$

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \alpha v, \quad (2)$$

$$v = \frac{4^2}{\pi} \left( \arctan\left(\frac{w}{h^{\text{gt}}}\right) - \arctan\left(\frac{w}{h}\right) \right)^2, \quad (3)$$

$$\alpha = \frac{v}{(1 - \text{IoU}) + v}. \quad (4)$$

其中,  $\frac{\rho^2(b, b^{\text{gt}})}{c^2}$  是一个正则项,用于防止过拟合,  $\alpha$  用于平衡参数,  $v$  用来衡量长宽比是否一致。将目标检测 Loss 进行反向传播到整个网络中,更新优化参数,增强了算法对于水下小目标的检测能力。

### 3 实验结果与分析

实验对比了本文算法及 Faster RCNN, YOLOv7 和 Cascade RCNN<sup>[21]</sup> 在 DUO 数据集上的表现,同时在 DUO 和 Brackish 数据集上设计了消融实验,对比基础模型,增强和检测单独训练、联合

训练不增强残差连接,联合训练增加残差连接的整体检测精度和小目标检测精度。DUO 数据集整合了多年的 URPC 数据集,删除了重复数据集,并对数据集进行了重新标注,标注信息较为精确。Brackish 数据集包含 97.5% 的小目标,且包含不同水体浑浊度。实验平台的操作系统为 Ubuntu18.04, CUDA 11.0, CUDNN 8.0.3, 硬件为 Intel Core i7-11700 CPU (2.5 GHz), 显卡为 Nvidia GeForce RTX 3080ti (12 GiB 显存), 32 GiB 内存。

#### 3.1 评价指标

采用平均精确度 (MAP)、平均召回率 (AR) 来评估目标检测。在大型自然环境 MS COCO 数据集集中的 MAP 考虑了目标分类的精度和定位的精度。具体来说, AP, AP50 和 AP75 分别描述了检测模型在不同 IOU (交并比) 阈值 {0.5; 0.05; 0.95}, 0.5, 0.75 下的整体精度性能。AP<sub>s</sub>, AP<sub>m</sub> 和 AP<sub>l</sub> 评价探测器对不同尺度物体的检测效果。

#### 3.2 结果与分析

3.2.1 残差连接的小目标检测算法检测精确率对比 本文所提小目标检测算法与 Faster RCNN, YOLOv7 和 Cascade RCNN 在 DUO 数据集上的检测效果如图 4 所示。




图 4 检测效果对比

Fig. 4 Comparison of detection results

从图 4 可以看出,Faster RCNN,Cascade RCNN 和 YOLOv7 对背景中小目标的分辨能力较差,将背景误检测为目标。检测细节部分如图 5 所示,其中红色圆圈所示 Cascade RCNN 和 YOLOv7 错将背景误检测为海胆,而本文提出的算法由于提升了小目标的信息表征,提高了目标的对比度信息,降低了模型的误检率。四种算法的检测精度如表 1 所示,Faster RCNN,Cascade RCNN 和 YOLOv7 直接应用于水下时,Faster RCNN 对小目标的检测精度  $AP_s$  为 0.481,Cascade RCNN 为 0.436,YOLOv7 为 0.452;本文算法的小目标检测性能  $AP_s$  为 0.524,相较于 Faster RCNN,Cascade RCNN 和 YOLOv7,本文算法的检测性能分别提升了 0.043,0.088 和 0.072,同时也提升了其他尺寸目标的检测精度,缩短了小目标与其他尺寸目标检测精度的差距。本文算法在小目标检测平均召回率 AR 方面相较 Faster RCNN,Cascade RCNN 和 YOLOv7 分别提升了 0.168,0.163 和 0.084。可见,采用残差连接的小目标检测算法,增强了背景中的小目标的细节信息,使得背景中的小目标更多地被检测出来,提升了小目标的检测精度以及召回率。本文所提模型对每张图片的推理时间相较于 YOLOv7 仅增加了 0.003 s。

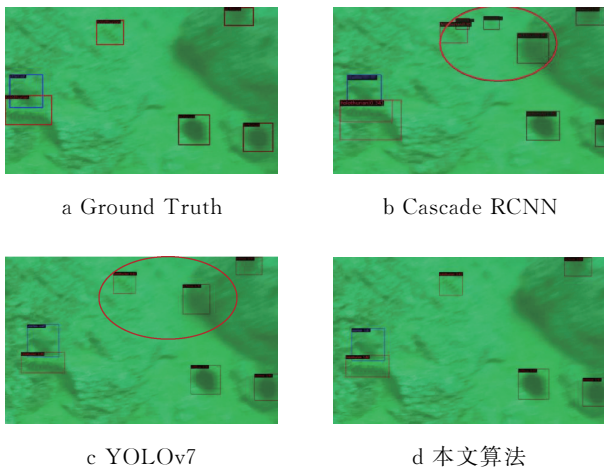


图 5 检测效果细节对比

Fig. 5 Comparison of detection effect details

表 1 在 DUO 数据集上的实验结果

Table 1 Experiments results on DUO dataset

模型	MAP	$AP_s$	$AP_m$	$AP_l$	AR	时间/s
Faster RCNN	0.612	0.481	0.629	0.599	0.559	0.028
Cascade RCNN	0.614	0.436	0.632	0.597	0.564	0.031
YOLOv7	0.678	0.452	0.693	0.669	0.643	0.048
本文算法	0.688	0.524	0.696	0.685	0.727	0.051

3.2.2 消融实验 为了验证所提出残差连接联合优化算法的有效性,在 DUO 数据集和 Brackish 数据集上进行了消融实验。实验对比了图像增强与目标检测作为单独步骤(enh)、图像增强与目标检测直接联合训练(enhonline)、图像增强网络与目标检测通过残差网络联合训练(res)三种实验,结果见表 2,表中“√”表示采用了该训练方式。实验数据显示,在 DUO 数据集上图像增强和目标检测算法作为单独步骤时,Cascade RCNN 算法相较于基础模型小目标检测精度提升了 0.045,但是对于整体目标检测精度 MAP 下降 0.007。YOLOv7 采用增强图像进行训练时,小目标检测精度相较于基本模型下降了 0.355,MAP 下降 0.008。在 Brackish 数据集上采用增强图像进行训练时,Cascade RCNN 算法相较于基础模型对于小目标检测精度不变,目标检测精度 MAP 上升 0.009,YOLOv7 采用增强图像进行训练时,小目标检测精度下降了 0.03,检测精度 MAP 下降 0.013,原因是图像增强单独训练时图像感官较好,但是丢失了小目标的细节信息。

表 2 消融实验检测精度对比

Table 2 Comparison of ablation test accuracy

数据集	模型	enh	enhonline	res	MAP	$AP_s$
Brackish	Cascade RCNN				0.947	0.970
		√			0.956	0.970
			√		0.957	0.970
	YOLOv7			√	0.958	0.970
		√			0.801	0.700
			√	√	0.788	0.670
DUO	Cascade RCNN				0.614	0.436
		√			0.607	0.481
			√		0.604	0.471
	YOLOv7			√	0.629	0.498
		√			0.678	0.452
			√	√	0.670	0.097
		√		0.682	0.561	
		√	√	0.688	0.514	

注:“√”表示采用了相应的训练方式。

在 DUO 数据集上,直接采用图像增强和目标检测联合训练的算法,Cascade RCNN 与 YOLOv7 算法相较于基础模型的小目标检测精度分别上升了 0.035 和 0.199,整体检测精度 Cascade RCNN 下降 0.010,YOLOv7 平均检测精度 MAP 上升 0.004。在 Brackish 数据集中直接采用图像增强和目标检测联合训练的算法 Cascade RCNN 相较于基础模型

小目标检测不变,而YOLOv7算法相较于基础模型小目标检测上升了0.015,但是整体检测精度下降。这是由于图像增强与目标检测联合训练的方式有效提升了小目标所在区域质量,提升了小目标的特征表达能力,但由于增加了网络深度,在训练中容易造成网络退化的现象,导致其检测精度低于基础模型。

本文所提出的基于残差连接小目标检测结构模型,在DUO数据集上Cascade RCNN相较于基础模型小目标的检测精度 $AP_s$ 提升了0.062,YOLOv7算法与基础模型相比小目标的检测精度 $AP_s$ 提升了0.062,两种算法整体检测精度MAP均有提升。在Brackish数据集上Cascade RCNN相较于基础模型小目标的检测精度 $AP_s$ 不变,YOLOv7算法与基础模型相比小目标的检测精度 $AP_s$ 提升了0.004,Cascade RCNN和YOLOv7算法整体检测精度MAP相较于各自基础模型分别提升了0.011和0.002。可以看出,本文所提出的基于残差连接小目标检测算法丰富了图像小目标的特征性,提升了小目标的检测效果,且解决了联合训练网络加深导致的网络退化问题,提升了整体目标检测效果。

本文在两个数据集上对所提出的算法进行了验证,实验结果表明增强算法和检测算法分开训练时,整体检测精度有所下降,直接将增强算法和目标检测算法联合训练的方式在训练中容易出现网络退化的现象,而本文所提出的残差连接方式,可以有效补充小目标的特征细节信息,增强小目标的对比度信息,提升小目标检测精度。

## 4 结论

本文首先讨论了增强算法对于目标检测性能的影响,分析了增强后的水下图像目标检测准确率下降的原因,以及增强算法在目标检测任务中的应用方式,并提出了一种基于残差连接的水下小目标检测算法。算法将增强后的图像与原图残差连接方式进行融合,增强的图像提升了对比度色彩信息,残差连接方式对网络卷积过程中丢失的信息进行了补充,解决了由于网络加深带来的网络退化现象,将增强的算法与目标检测算法联合优化,使得增强的图像更有利于目标检测。所提出的算法在DUO上对所提出的算法进行了验证,实验结果表明所提出的算法能有效提升小目标的检测性能,且不影响模型的推理时间。为了验证残差连接的有效性,在DUO

和Brackish数据集上进行了消融实验。实验结果表明本文所提出的残差连接的方式可以有效补充小目标的特征细节信息,增强目标的对比度信息,进而解决了网络加深带来的网络退化问题,提升了小目标检测精度。

## 参考文献:

- [1] 董金耐,杨森,谢卓冉,等.水下图像目标检测数据集及检测算法综述[J].海洋技术学报,2022,41(5):60-72.
- [2] 刘勇,黄佳炜,孙帅成,等.基于多线性Fukunaga-Koontz变换的海天背景中红外小目标检测[J].淮海工学院学报(自然科学版),2019,28(2):13-19.
- [3] 张艳,张明路,吕晓玲,等.深度学习小目标检测算法研究综述[J].计算机工程与应用,2022,58(15):1-17.
- [4] HSIAO Y H, CHEN C C, LIN S I, et al. Real-world underwater fish recognition and identification, using sparse representation [J]. Ecological Informatics, 2014, 23: 13-21.
- [5] KALPATHY-CRAMER J, DE HERRERA A G S, DEMNER-FUSHMAN D, et al. Evaluating performance of biomedical image retrieval systems—an overview of the medical image retrieval task at ImageCLEF 2004—2013 [J]. Computerized Medical Imaging and Graphics, 2015, 39: 55-61.
- [6] SALMAN A, JALAL A, SHAFAIT F, et al. Fish species classification in unconstrained underwater environments based on deep learning [J]. Limnology and Oceanography: Methods, 2016, 14(9): 570-585.
- [7] JÄGER J, RODNER E, DENZLER J, et al. Sea-CLEF 2016: object proposal classification for fish detection in underwater videos [C]//CLEF (working notes), 2016: 481-489.
- [8] CUTTER G, STIERHOFF K, ZENG Jiaming. Automated detection of rockfish in unconstrained underwater videos using Haar cascades and a new image dataset: labeled fishes in the wild [C]//2015 IEEE Winter Applications and Computer Vision Workshops. Waikoloa, HI, USA, 2015: 57-62.
- [9] LEVY D, BELFER Y, OSHEROV E, et al. Automated analysis of marine video with limited data [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. Salt Lake City, UT, USA, 2018: 1385-1393.
- [10] LIU Chongwei, LI Haojie, WANG Shuchang, et al. A dataset and benchmark of underwater object detection for robot picking [C]//2021 IEEE International Conference on Multimedia and Expo Workshops (ICMEW). Shenzhen, China, 2021: 1-6.

- [11] ZHOU Yuan, WU Qiang, YAN Kangming, et al. Underwater image restoration using color-line model [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2018, 29(3): 907-911.
- [12] YE Xinchun, LI Zheng, SUN Baoli, et al. Deep joint depth estimation and color correction from monocular underwater images based on unsupervised adaptation networks [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2020, 30(11): 3995-4008.
- [13] LIU Risheng, JIANG Zhiying, YANG Shuzhou, et al. Twin adversarial contrastive learning for underwater image enhancement and beyond [J]. *IEEE Transactions on Image Processing*, 2022, 31: 4922-4936.
- [14] CHEN Long, JIANG Zheheng, TONG Lei, et al. Perceptual underwater image enhancement with deep learning and physical priors [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021, 31(8): 3078-3092.
- [15] ZHANG Xueting, FANG Xiaohai, PAN Mian, et al. A marine organism detection framework based on the joint optimization of image enhancement and object detection [J]. *Sensors*, 2021, 21(21): 7205.
- [16] ZHANG Jiashuo, ZHU Linlin, XU Liheng, et al. MFFSSD: an enhanced SSD for underwater object detection [C]//2020 Chinese Automation Congress (CAC). Shanghai, China: IEEE, 2020: 5938-5943.
- [17] PAN T S, HUANG H C, LEE J C, et al. Multi-scale ResNet for real-time underwater object detection [J]. *Signal, Image and Video Processing*, 2021, 15(5): 941-949.
- [18] CHEN Long, LIU Zhihua, TONG Lei, et al. Underwater object detection using Invert Multi-Class Adaboost with deep learning [C]//2020 International Joint Conference on Neural Networks (IJCNN). Glasgow, United Kingdom, 2020: 1-8.
- [19] YANG H H, HUANG K C, CHEN W T. LAFF-Net: a lightweight adaptive feature fusion network for underwater image enhancement [C]//2021 IEEE International Conference on Robotics and Automation (ICRA), 2021: 685-692.
- [20] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [J]. *arXiv, arXiv*: 2207.02696, 2022.
- [21] CAI Zhaowei, VASCONCELOS N. Cascade R-CNN: high quality object detection and instance segmentation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(5): 1483-1498.

(责任编辑:秦海明 实习编辑:张昌保)