

DOI:10.19651/j.cnki.emt.2519199

相差显微图像的活性污泥微生物伪装目标检测*

赵立杰 金明溪 方一凡 黄明忠
(沈阳化工大学信息工程学院 沈阳 110021)

摘要: 准确监测活性污泥微生物对于保持污水处理系统的稳定运行至关重要。然而,微生物因其半透明形态和与周围环境的高度相似性而具有伪装特性,使得传统的检测方法表现不佳。针对活性污泥微生物伪装性、目标尺度多样性和复杂背景下边界模糊的问题,提出了一种基于多尺度感知和边缘增强的伪装目标检测方法。该方法通过多尺度特征感知模块的并行处理和逐步扩大感受野来提取丰富的上下文信息,以增强多尺度特征表示;利用边缘感知增强模块融合低层边缘细节与高层语义信息,获取边缘特征;再通过注意力引导模块融合边缘特征与多尺度特征,引导网络关注边缘的位置信息;使用上下文聚合模块自顶向下逐级聚合多层次特征,以进一步细化预测结果并生成预测图像。在伪装目标检测公共数据集和自建活性污泥微生物伪装数据集上,本方法在评价指标 S 值、加权 F 值和 E 值上分别提升了 2.2%、4.1%、2.1% 和 1.2%、2.2%、0.6%。实验结果表明,本方法在各数据集上均取得了优于其他模型的性能。

关键词: 伪装目标检测;活性污泥微生物;多尺度感知;边缘增强

中图分类号: TP391;TN0 文献标识码: A 国家标准学科分类代码: 520

Camouflaged object detection for activated sludge microorganisms in phase contrast microscopic images

Zhao Lijie Jin Mingxi Fang Yifan Huang Mingzhong

(College of Information Engineering, Shenyang University of Chemical Technology, Shenyang 110021, China)

Abstract: Accurate monitoring of activated sludge microorganisms is critical for maintaining the stable operation of wastewater treatment systems. However, due to their semi-transparent morphology and high similarity to the surrounding environment, these microorganisms exhibit camouflaged characteristics, rendering traditional detection methods ineffective. To address the camouflage characteristics of activated sludge microorganisms, the diversity of object scales, and the ambiguity of boundaries in complex contexts, this paper proposes a camouflaged object detection method based on multi-scale awareness and edge enhancement. The proposed method employs a multi-scale feature aware module to extract rich contextual information through parallel processing and progressive expansion of the receptive field, thereby enhancing multi-scale feature representation. An edge-aware enhancement module is introduced to fuse low-level edge details with high-level semantic information for more accurate edge feature extraction. These edge features are then integrated with the multi-scale features through an attention-guided feature module, enabling the network to focus on the positional information of edges. Finally, a context aggregation module is used to progressively aggregate multi-level features in a top-down manner, further refining the prediction and generating the final output. On the benchmark camouflaged object detection dataset and the self-constructed activated sludge microorganism camouflage dataset, the proposed method achieves improvements of 2.2%, 4.1%, and 2.1%, and 1.2%, 2.2%, and 0.6% in terms of the evaluation metrics S-measure, weighted F-measure, and E-measure, respectively. Experimental results demonstrate that the proposed method achieves superior performance over other models across all datasets.

Keywords: camouflaged object detection; activated sludge microorganisms; multi-scale awareness; edge enhancement

0 引言

活性污泥法是污水处理领域中应用最广泛的技术之

一,其核心是利用微生物的代谢活动,将污水中大部分有机物和部分无机污染物分解转化为无害且稳定的物质。在污水处理过程中,微生物的数量、生存状态和种类可以为工艺

收稿日期:2025-06-26

* 基金项目:2024 年辽宁省教育厅高等学校基本科研项目(LJ212410149042)、2023 年度辽宁省研究生教育教学改革研究项目(2023-132)资助

参数的调整提供依据^[1]。因此,实时、准确地监测活性污泥微生物对高效的污水处理运行至关重要。活性污泥系统中存在多种原生和后生动物,许多微生物由于表面半透明、颜色与背景相似,或附着于絮体表面,导致其轮廓模糊,与背景难以区分。因此,活性污泥微生物具有天然的伪装性。相较于显著目标检测^[2-3],伪装目标检测(camouflaged object detection, COD)旨在识别那些与背景具有高度视觉相似性的目标。因此,将伪装目标检测方法引入到活性污泥微生物的识别中,有望显著提升检测的准确性与鲁棒性。

活性污泥微生物检测主要分为传统检测方法和基于深度学习的方法。传统检测方法通过机器学习从图像中提取特征以实现自动检测和分类。Ginoris 等^[4]开发了一种基于图像处理和分类器的自动识别系统,能够有效识别活性污泥系统中的原生动物与后生动物。Boztoprak 等^[5]提出了一种使用边缘提取器和人工神经网络检测原生动物位置的方法。近年来,深度学习在微生物检测任务中得到了广泛的研究和发展。Zheng 等^[6]提出基于深度学习的智能分析方法,包含 3 个阶段:微生物图像预处理、特征提取及微生物信息分析以确定种类和位置,构建了包含 4 类微生物的 2 000 张图像数据集;Liu 等^[7]提出了 Biota Former 框架,利用不同尺度的注意力机制,同时捕获全局特征和局部细节来识别微生物,同时提出了 Biota-12 活性污泥微生物检测数据集,包含 12 类微生物,共 215 张图像。

COD 方法包括传统方法和基于深度学习的方法。传统方法主要依赖人工设计特征,如颜色、纹理、几何梯度等特征。但在复杂的场景中,这些特征效果一般会减弱。随着深度学习技术的进步,许多基于深度学习的伪装目标检测方法被提出。Fan 等^[8]提出了搜索识别网络,将任务分为搜索和识别两个阶段来定位和细化伪装目标,但该方法在复杂背景下易出现定位偏差。Sun 等^[9]提出了上下文感知跨层融合网络,通过融合上下文感知的交叉层次特征提升检测精度,但对小尺度目标特征保留不足,易在融合过程中被大尺度特征掩盖。Sun 等^[10]提出了边界引导的伪装目标检测网络,挖掘并集成边界相关的边缘语义以提升检测性能,但其对局部相似特征的区分能力较弱,在复杂场景下容易受到干扰而导致边界预测偏差。复杂场景中易受局部相似特征误导而导致边界偏差。He 等^[11]提出了特征分解和边缘重建模型,通过特征频段分解和频率注意力挖掘前景微差异,并结合边缘重建辅助任务生成精确边界,但在复杂背景或噪声干扰下泛化性不足,边缘重建易出现错误。Sun 等^[12]提出了全局-局部协同优化策略,同时建模局部细节与全局依赖关系以提升精度,但计算量大、推理速度慢,且在强伪装场景下精度下降。同时涉及各种相关线索作为辅助任务添加到 COD 中,如频率^[13]、梯度^[14]。以及采用一系列有效的策略,如缩放,不确定性和迭代细化^[15]。

针对 BGNet^[10]在全局上下文建模、边缘预测精度和小目标特征保留不足的问题,已有研究通过优化骨干网络、改

进模块设计以及引入注意力机制等策略,实现了更丰富的特征表示并提升了模型泛化能力^[16-17]。针对活性污泥微生物的伪装特性、目标尺度多样性和复杂背景下目标边界模糊的问题,提出了基于 BGNet 改进的多尺度感知与边缘增强伪装目标检测网络。

本研究的方法采用 PVT v2 (pyramid vision transformer v2, PVT v2)^[18]作为骨干网络。首先,提出多尺度特征感知模块对提取的多尺度特征进行上下文信息的捕获;然后,提出边缘感知增强模块对低层特征和高层特征进行特征提取获取边缘特征;提出注意力引导模块融合边缘特征和多尺度特征来学习边缘的位置信息;最后,使用上下文聚合模块自顶向下逐级聚合多层次特征以预测伪装目标。本研究在自建活性污泥微生物伪装数据集和 CAMO、COD10K 和 NC4K 3 个 COD 公共数据集上进行了大量的实验,验证了方法的先进性和有效性。

1 方 法

1.1 整体框架

本研究提出的基于多尺度特征感知和边缘增强伪装目标检测网络的整体框架如图 1 所示。采用 PVT-v2 作为网络的骨干网络,提取输入图像的特征 $f_i (i=1,2,3,4)$ 。将 $f_i (i=1,2,3,4)$ 输入到多尺度特征感知模块(multi-scale feature aware module, MFAM)捕获丰富的上下文信息,以获取更丰富的多尺度特征 $f_{R_i} (i=1,2,3,4)$;将包含局部边缘信息的低级特征(f_1, f_2)和包含全局位置信息的高级特征(f_4)输入到边缘感知增强模块中(edge-aware enhancement module, EEM)中捕获相关的边缘语义。利用多个注意力引导模块(attention-guided feature module, AFM)将获得的边缘信息与经过 MFAM 的多尺度特征整合在一起,以引导网络关注边缘信息,从而增强伪装目标和边界特征的表达能力。最后,采用多个上下文聚合模块(context aggregation module, CAM)以自上而下的方式聚合多级特征,逐步细化检测结果。在推理过程中,选择最后一个 CAM 的预测作为最终检测结果。

1.2 骨干网络

BGNet 采用 Res2Net50 作为骨干网络,虽然具备一定的局部多尺度特征提取能力,但在全局上下文信息建模方面仍存在不足。相比之下,PVT-v2 将 CNN 中常用的金字塔结构与 Transformer 的全局建模能力相结合,通过渐进式收缩金字塔生成多尺度特征,实现全局信息建模与多尺度特征提取的兼顾,并在降低计算复杂度的前提下提升小目标和复杂背景下的检测精度。

PVT-v2 的整体由 4 个阶段组成,特征图分辨率在每个阶段逐步减半、通道数逐步增加,形成多尺度特征金字塔。网络首先通过卷积式 Patch Embedding 将输入图像划分为不重叠的图像块并投影为特征嵌入,随后在各阶段的 Transformer 块中引入空间降采样注意力,在计算自注意

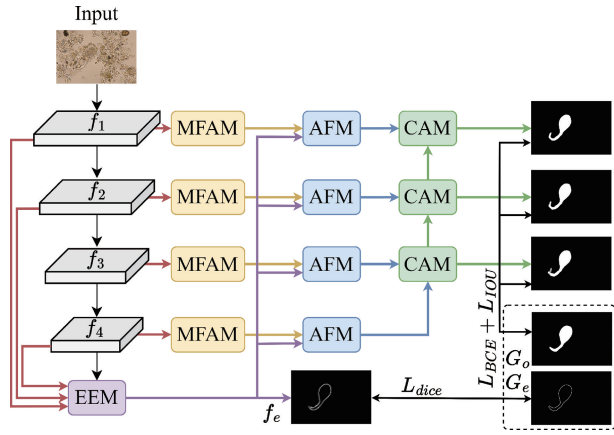


图1 网络整体架构图

Fig.1 Overall network architecture

力时对 Key 和 Value 进行降采样以降低计算量和显存占用。各阶段的自注意力机制能够捕获全局上下文关系,而金字塔结构则保留了不同尺度的特征表示,既有利于细节保留,又能提供高层语义信息,最终输出的多尺度特征可直接用于后续的特征融合与解码过程。

1.3 多尺度特征感知模块

为了提取丰富的上下文信息,并避免小目标特征在多尺度融合中被掩盖,受到残差多尺度特征提取器设计思路的启发^[19],提出了多尺度特征感知模块,如图2所示。该模块通过多分支卷积与残差连接,在保证计算效率的同时有效扩大感受野。该模块采用3×3卷积进行并行处理,并结合残差块逐步扩大感受野,以增强特征表达能力。首先,对于输入特征 $f_i, i \in \{1, 2, 3, 4\}$ 利用4个分支来捕获不同的特征,每个分支使用非对称卷积1×3和3×1结合3×3卷积,在扩大感受野的同时降低计算复杂度。将每个分支的输出被添加到下一个分支的输入中,之后将4个分支的输出进行级联,并通过1×1卷积调整通道数量。最后,将其添加到输入特征 f_i 中,得到最终输出特征 f_{Ri} 。

$$out_k^i = \begin{cases} Conv(f_i), k = 1 \\ Conv(f_i \oplus out_{k-1}^i), k = 2, 3, 4 \end{cases} \quad (1)$$

$$f_{Ri} = f_i \oplus F_{conv1}(Cat_{k=1}^4(out_k^i)) \quad (2)$$

式中: f_i 表示骨干网络产生的第 i 个特征, k 为分支数, $Conv(\cdot)$ 表示上述堆叠的卷积层, $out_k^i(\cdot)$ 表示第 k 个分支的输出, \oplus 表示逐元素加法, F_{conv1} 表示1×1卷积, $Cat_{k=1}^4(\cdot)$ 表示4个分支的级联。

1.4 边缘感知增强模块

在 COD 任务中边缘先验信息有助于更好的分割和定位目标,因此边缘检测可以作为一种有效的辅助任务添加到 COD 任务中。低层特征虽包含丰富的边缘信息,但同时存在大量冗余,为了强化边缘细节,受到 BGNet 中边缘感知模块的启发^[10],提出了边缘感知增强模块,如图3所示。该模块通过边缘增强器(edge enhancer, EE)强化低级特征的边缘细节,并结合高级特征的全局语义信息,实现边缘信息




图2 多尺度特征感知模块


Fig.2 Illustration of MFAM

的提取。低级特征包含丰富的边缘细节信息,使用边缘增强器来强化低级特征的细节信息。低级特征包含丰富的边缘细节信息,但同时也存在大量的冗余信息,高级特征具有高层语义信息或全局位置信息,助于定位伪装目标的整体区域。首先,使用1×1卷积对 f_i 进行通道降维,使用EE加强 f_1, f_2 的细节信息,然后通过级联操作将特征 f'_1 和上采样后的 f'_2, f'_4 的进行整合。最后,整合后的特征经过一个3×3卷积、深度可分离卷积和1×1卷积,并通过 Sigmoid 激活函数获得最终的边缘特征 f_e 。

$$f'_i = \begin{cases} F_{conv1}(f_i \ominus AP(f_i)) \oplus f_i, i = 1 \\ Up(F_{conv1}(f_i \ominus AP(f_i)) \oplus f_i), i = 2 \\ Up(F_{conv1}(f_i)), i = 4 \end{cases} \quad (3)$$

$$f_e = Sig \left(F_{conv1} \left(F_{DWConv} \left(F_{conv} (Cat(f'_1, f'_2, f'_4)) \right) \right) \right) \quad (4)$$

式中: $AP(\cdot)$ 表示平均池化, \ominus 表示逐元素减法, $Up(\cdot)$ 表示双线性插值上采样操作, $Ca(\cdot)$ 表示特征通道的级联操作, F_{conv} 表示3×3卷积, F_{DWConv} 表示3×3深度可分离卷积, $Sig(\cdot)$ 表示 Sigmoid 激活函数。



⊕Upsample ⊙Concat ⊕Addition ⊖Subtraction

图3 边缘感知增强模块

Fig.3 Illustration of EEM

1.5 注意力引导模块

为了更有效地检测目标,受到 BGNet 中边缘引导特征模块的启发^[10],提出了注意力引导模块,如图4所示。该模块通过引导门控注意力并结合局部通道注意力增强关键特征,实现目标的精确定位。使用引导门控注意力来学习边缘的位置信息,以增强具有对象结构语义的特征表示。同时,为了实现良好的整合并获得强大的表征,引入了局部通道注意力机制来探索跨通道交互,挖掘通道间的关键线索。首先,将给定的输入特征 $f_i, i \in \{1, 2, 3, 4\}$ 和边缘特

征 f_e 连接起来,然后经过引导门控注意力(GA)后再与输入特征相加得到精确定位边缘的位置信息。为了增强特征表示,引入局部注意力来探索关键的特征通道^[20]。具体来说,使用全局平均池化(GAP)来聚合卷积特征。然后通过 1D 卷积和 Sigmoid 函数得到相应的权重。不同于全连接操作,它捕获了所有通道之间的依赖关系,但具有较高的复杂度,探索了局部跨通道交互,并以局部的方式学习每个注意力。之后,将通道注意力与输入特征 f_{ie} 相乘,通过 1×1 卷积对通道进行降维,得到最终输出 f_{Ri}^a 。

$$f_{ie} = F_{conv} \left(\sigma \left(GA \left(Cat \left(f_{Ri}, D(f_e) \right) \right) \right) \otimes f_{Ri} \right) \quad (5)$$

$$f_{Ri}^a = F_{conv1} \left(\sigma \left(F_{1D}^k \left(GAP \left(f_{ie} \right) \right) \right) \otimes f_{ie} \right) \quad (6)$$

式中: D 表示下采样, \otimes 表示逐像素乘法, $GA(\cdot)$ 表示“BN-Conv-Relu-Conv-BN”串联操作, F_{1D}^k 表示核大小为 k 的 1D 卷积, σ 表示 Sigmoid 激活函数。核大小 k 可以自适应的设置为 $k = \lfloor (1 + \log_2 C/2) \rfloor_{odd}$, $\lfloor * \rfloor_{odd}$ 表示最接近的奇数, C 为 f_e^i 的通道数,通道尺寸受内核大小的影响,适合的内核大小可以通过特征引导模块将关键信息的通道突出出来,排除相关度低的通道和噪声的影响,进而增强语义特征的表示。




图 4 注意力引导模块
Fig. 4 Illustration of AFM

1.6 上下文聚合模块

为了整合多级特征进一步细化检测结果,沿用 BGNet 中的上下文聚合模块来挖掘上下文语义以增强目标检测^[10],CAM 如图 5 所示。CAM 考虑了跨尺度交互来提升特征表示,首先,对 f_{Ri}^a 进行上采样并与 f_{Ri+1}^a/f_{Ri+1}^c 连接起来,然后经过 1×1 的卷积得到初始聚合特征 f_m 。接下来,将 f_m 沿通道维度平均分成 4 个特征图 ($f_m^1, f_m^2, f_m^3, f_m^4$), 然后进行跨尺度交互融合,通过一系列空洞卷积来整合相邻分支的特征以提取多尺度上下文特征。最后,将所有聚合分支的结果再用一个 1×1 卷积,一个残差连接和一个 3×3 卷积串联起来得到最终结果。

$$f_m^j = F_{conv}^{n_j} (f_m^{j-1} \oplus f_m^j \oplus f_m^{j+1}), j = 1, 2, 3, 4 \quad (7)$$

$$f_{Ri}^c = F_{conv} (F_{conv1} ([*] f_m^j)) \oplus f_m \quad (8)$$

式中: $F_{conv}^{n_j}$ 表示一个膨胀率为 n_j 的 3×3 空洞卷积, F_{conv} 表示 3×3 卷积, F_{conv1} 表示 1×1 卷积, $[*]$ 是拼接运算。对于 $i = \{1, 2\}$, CAM (f_{Ri+1}^c) 的输出将与 f_{Ri}^a 一起作为下一个 CAM 的输入以获得 f_{Ri}^c , 最终得到伪装物体的预测 $C_i (i \in \{1, 2, 3\})$ 。




图 5 上下文聚合模块
Fig. 5 Illustration of CAM

1.7 损失函数

使用加权二元交叉熵损失 L_{BCE}^w 和加权交并比损失 L_{IOU}^w 对伪装对象进行监督^[21],这种方式为不同显著性的像素会分配不同的权重。使用 Dice 损失 L_{dice} 对伪装对象边缘进行监督^[22],可以解决正负样本间的强不平衡问题。因此,总损失定义为:

$$L_{total} = \sum_{i=1}^3 (L_{BCE}^w(C_i, G_o) + L_{IOU}^w(C_i, G_o)) + 3L_{dice}(C_e, G_e) \quad (9)$$

式中: C_i 表示伪装目标的预测图像, G_o 表示伪装目标的真值图, C_e 表示伪装目标边缘的预测图像, G_e 表示伪装目标边缘的真值图。

2 实 验

2.1 数据集

1) COD 数据集

使用 3 种最常见的基准数据集进行训练和测试,分别是 CAMO^[23], COD10K^[8] 和 NC4K^[24]。CAMO 一共包含 1 250 张伪装图像,其中 1 000 张用于训练,剩余的 250 张用于测试。COD10K 是 COD 领域包含图像最多、图像种类最丰富的伪装图像数据集,共有 5 056 张图像,其中 3 040 张用于训练,剩余的 2 026 张图像用于测试。NC4K 数据集一般被用来评估 COD 算法的泛化能力,它的 4 121 张图像全部被用来参与测试。

2) 活性污泥微生物数据集

活性污泥微生物由于其在颜色和形态与周围环境高度相似,因此具有天然的伪装特征。为了更好的检测微生物,本研究构建了一个用于活性污泥微生物伪装目标检测的相差显微图像数据集,即伪装活性污泥微生物数据集 (camouflaged activated sludge microorganisms, CASM)。污泥样本采集自中国某污水处理厂,成像前通过吸管搅拌以确保样本均匀性。采用相差显微镜进行图像采集,因其能增强未染色活体样本中细微结构的可见性,特别适合观察活性污泥中的原生动物和后生动物。图像采集设备如图 6 所示。在显微镜定位目标后,根据其大小与结构复杂性选择适宜放大倍数,以清晰捕捉整体形状、纤毛及内部结构等关键形态特征。除使用显微镜上安装的数字相机外,

部分图像还通过移动设备直接通过目镜拍摄。所得图像构成一个多样且具有代表性的数据集,捕捉了活性污泥中微生物群落的复杂性。CASM 数据集中伪装微生物的示例如图 7 所示。




图 6 图像采集设备

Fig. 6 Image acquisition equipment




图 7 伪装微生物的示例

Fig. 7 Examples of camouflaged microorganisms

CASM 数据集共包含 1 888 张图像,其中包含 208 张亮场图像、1 234 张相差图像和 44 张镜检图像。数据集涵盖了 25 种不同类别的原生生物和后生物,以确保数据具有代表性。数据集中微生物类别的分布如图 8 所示。CASM 数据集分为 CASM-train 和 CASM-test 两个子集,CASM-train 包含 1 321 张用于训练的图像,CASM-test 包含 567 张用于测试的图像。值得注意的是每种微生物的亮场图像、相差图像和镜检图像按一定比例分配到了训练集和测试集,这有助于模型对不同图像学习能力的提升。




图 8 CASM 中微生物类别的直方图分布

Fig. 8 Histogram distribution of microbial categories

2.2 实验细节

本研究提出的模型在 Pytorch 中实现,使用 NVIDIA A10 GPU 加速训练。模型使用预训练的 PVTv2 作为主干网络,将输入图像的尺寸调整为 416×416 并采用水平翻转、随机裁剪等方法进行数据增强以缓解网络训练过程中

的过拟合问题。在训练阶段,使用 AdamW 作为模型的优化器,初始学习率设为 1×10^{-4} ,训练轮数为 50,批处理大小为 16,训练过程中采用“Poly”学习率衰减策略。

2.3 评价指标

为了评估模型的性能,采用的评价指标如下: S-measure (S_o)^[25]、加权 F-measure (F_β^w)^[26]、E-measure (E_ϕ)^[27]、自适应 E-measure (E_ϕ^{ad})、最大 E-measure (E_ϕ^{max})、自适应 F-measure (F_β^{ad})^[28]、平均 F-measure (F_β^m)、最大 F-measure (F_β^{max}) 和平均绝对误差 (M)。评估时, M 越小越好,其他指标越大越好。主要公式定义为:

$$S_o = \alpha S_o + (1 - \alpha) S_r \quad (10)$$

$$F\text{-measure} = \frac{(1 + \beta^2) P \times R}{\beta^2 \times P + R} \quad (11)$$

$$E\text{-measure} = \frac{1}{W \times H} \sum_{x=1}^W \sum_{y=1}^H \phi | P(x, y) - G(x, y) | \quad (12)$$

$$M = \frac{1}{W \times H} \sum_{x=1}^W \sum_{y=1}^H | P(x, y) - G(x, y) | \quad (13)$$

式中: S_o 和 S_r 分别为面向目标和面向区域的结构相似性度量, α 参数为 0.5。 β 是精确率与召回率之间的权重, β^2 设置为 0.3。 $\phi(\cdot)$ 为增强矩阵, W 和 H 表示真值图的宽度和高度, P 和 G 分别代表预测图和其对应的真实标签。

2.4 实验结果

为了验证本研究方法的有效性,本研究将其与 12 个 COD 方法进行比较: SINet^[8], LSRNet^[22], C²Fnet^[9], SINet-V2^[29], BGNet^[10], BSA^[19], SegMaR^[15], FEDER^[11], DGNet^[14], TJNet^[30], FSEL^[13], GLCONet^[12]。这些方法代表了 COD 领域的最新的研究发展,覆盖了边缘辅助、多尺度融合、特征分解、频域建模以及全局-局部优化等多种策略。通过与这些方法的比较,可以全面评估方法在伪装目标检测任务中的有效性。

1) COD 公共数据集定量比较

本研究方法在 3 个 COD 公共数据集上与 11 种先进方法之间的性能对比结果如表 1 所示。结果表明,本研究方法在 3 个 COD 公共数据集上的评估指标都明显优于其他先进模型。例如,与最优的竞争指标相比,在 CAMO 数据集上本研究的方法将 S_o 、 F_β^w 和 E_ϕ 分别提高了 1.9%、2.2% 和 1.3%;在 COD10K 数据集上本研究的方法将 S_o 、 F_β^w 和 E_ϕ 分别提高了 2.2%、4.1% 和 2.1%;在 NC4K 数据集上, S_o 、 F_β^w 和 E_ϕ 分别提高了 1.7%、2.5% 和 1.2%。与目前的 COD 模型相比,本研究的方法在 S_o 、 F_β^w 、 E_ϕ 和 M 评价指标上均有较好的检测结果,证明了本研究方法相比于其他方法的有效性与先进性。

2) CASM 数据集的定量比较

本研究方法在 CASM 数据集上与 11 种先进方法之间的性能对比结果如表 2 所示。结果表明,本研究方法在 CASM 数据集上的评估指标都明显优于其他先进模型。

例如,与最优的竞争方法 GLCONet 相比,本研究的方法在 CASM 数据集将 S_a 、 F_β^w 分别提高了 1.1%、2.2%,同时其

他 7 个评价指标均有所提升,证明了本研究方法在 CASM 数据集上相比于其他方法的有效性先进性。

表 1 CAMO、COD10K 和 NC4K 数据集的定量结果

Table 1 Quantitative results on three datasets: CAMO, COD10K, and NC4K

模型	CAMO-Test				COD10K-Test				NC4K			
	$S_a \uparrow$	$F_\beta^w \uparrow$	$M \downarrow$	$E_\phi \uparrow$	$S_a \uparrow$	$F_\beta^w \uparrow$	$M \downarrow$	$E_\phi \uparrow$	$S_a \uparrow$	$F_\beta^w \uparrow$	$M \downarrow$	$E_\phi \uparrow$
SINet	0.745	0.644	0.092	0.829	0.776	0.631	0.043	0.864	0.808	0.723	0.058	0.871
LSRNet	0.787	0.696	0.080	0.854	0.804	0.673	0.037	0.880	0.840	0.766	0.048	0.895
C2FNet	0.719	0.796	0.080	0.864	0.813	0.686	0.036	0.890	0.838	0.762	0.049	0.897
SINet-V2	0.820	0.743	0.070	0.882	0.815	0.680	0.037	0.887	0.847	0.784	0.048	0.903
BGNet	0.812	0.749	0.073	0.870	0.831	0.722	0.033	0.901	0.851	0.788	0.044	0.907
BSANet	0.796	0.717	0.079	0.859	0.818	0.699	0.034	0.894	0.841	0.771	0.048	0.903
SegMaR	0.815	0.742	0.071	0.872	0.833	0.724	0.033	0.895	0.841	0.781	0.046	0.905
FEDER	0.807	0.782	0.069	0.873	0.823	0.740	0.032	0.900	0.846	0.817	0.045	0.905
DGNet	0.839	0.769	0.057	0.901	0.822	0.693	0.033	0.896	0.857	0.784	0.042	0.911
TJNet	0.842	0.778	0.064	0.890	0.844	0.738	0.030	0.907	0.864	0.799	0.042	0.912
FSEL	0.821	0.758	0.067	0.893	0.830	0.728	0.031	0.898	0.854	0.792	0.042	0.914
GLCONet	0.816	0.748	0.069	0.882	0.822	0.714	0.033	0.891	0.852	0.791	0.043	0.914
本文	0.861	0.818	0.052	0.914	0.866	0.781	0.024	0.928	0.881	0.832	0.035	0.926

表 2 CASM 数据集的定量结果

Table 2 Quantitative results on CASM dataset

模型	$S_a \uparrow$	$F_\beta^w \uparrow$	$M \downarrow$	$E_\phi \uparrow$	$E_\phi^{ad} \uparrow$	$E_\phi^{\max} \uparrow$	$F_\beta^{ad} \uparrow$	$F_\beta^m \uparrow$	$F_\beta^{\max} \uparrow$
SINet	0.708	0.324	0.050	0.873	0.802	0.961	0.625	0.745	0.825
LSRNet	0.920	0.867	0.008	0.969	0.958	0.977	0.842	0.882	0.899
C2FNet	0.875	0.674	0.017	0.948	0.905	0.977	0.753	0.840	0.896
SINet-V2	0.917	0.860	0.007	0.972	0.952	0.979	0.829	0.870	0.899
BGNet	0.872	0.649	0.017	0.959	0.939	0.981	0.812	0.870	0.920
BSANet	0.923	0.872	0.007	0.966	0.971	0.972	0.869	0.887	0.899
SegMaR	0.927	0.871	0.008	0.971	0.959	0.977	0.838	0.882	0.906
FEDER	0.902	0.829	0.009	0.959	0.945	0.965	0.810	0.847	0.871
DGNet	0.926	0.864	0.007	0.972	0.959	0.981	0.836	0.872	0.901
TJNet	0.808	0.500	0.027	0.944	0.934	0.979	0.815	0.856	0.915
FSEL	0.898	0.812	0.010	0.947	0.924	0.955	0.774	0.831	0.862
GLCONet	0.933	0.886	0.006	0.976	0.966	0.984	0.861	0.886	0.921
本文	0.945	0.908	0.005	0.982	0.976	0.988	0.880	0.911	0.935

3)CASM 数据集的定性比较

本研究方法与一些具有代表性的 COD 模型的可视化结果如图 9 所示。对于具有长柄、鞭毛和吸管的微生物,本研究方法能够更准确识别微生物位置以及长柄和鞭毛细节。对于复杂背景下的微生物和较小微生物,本研究方法能够在呈现较好的识别效果的同时保留一定的细节信

息。可视化结果表明,本研究方法对比其他方法在边界模糊、背景高度相似的情况下依然可以准确地预测不同尺度的对象,准确定位出伪装活性污泥微生物的位置且预测结果具有更清晰的边界和区域形状,检测结果具有更低的误检率和漏检率。

本研究方法与其他模型在边缘提取方面的可视化比

较如图 10 所示。可以看出, BGNet 的边缘预测结果相较于本研究方法仍显粗糙, 缺乏对目标结构的精确定位。MGL 虽然引入了基于复杂图模型的辅助边缘检测网络, 但其预测结果仍然丢失了许多局部结构细节, 导致边界模

糊。相比之下, 本研究方法通过 EEM 与 AFM, 有效融合了低层细节与高层语义信息, 显著提升了边缘结构感知能力。实验结果验证了本方法在与目标相关边缘信息挖掘以及伪装目标精确定位方面的有效性与优越性。

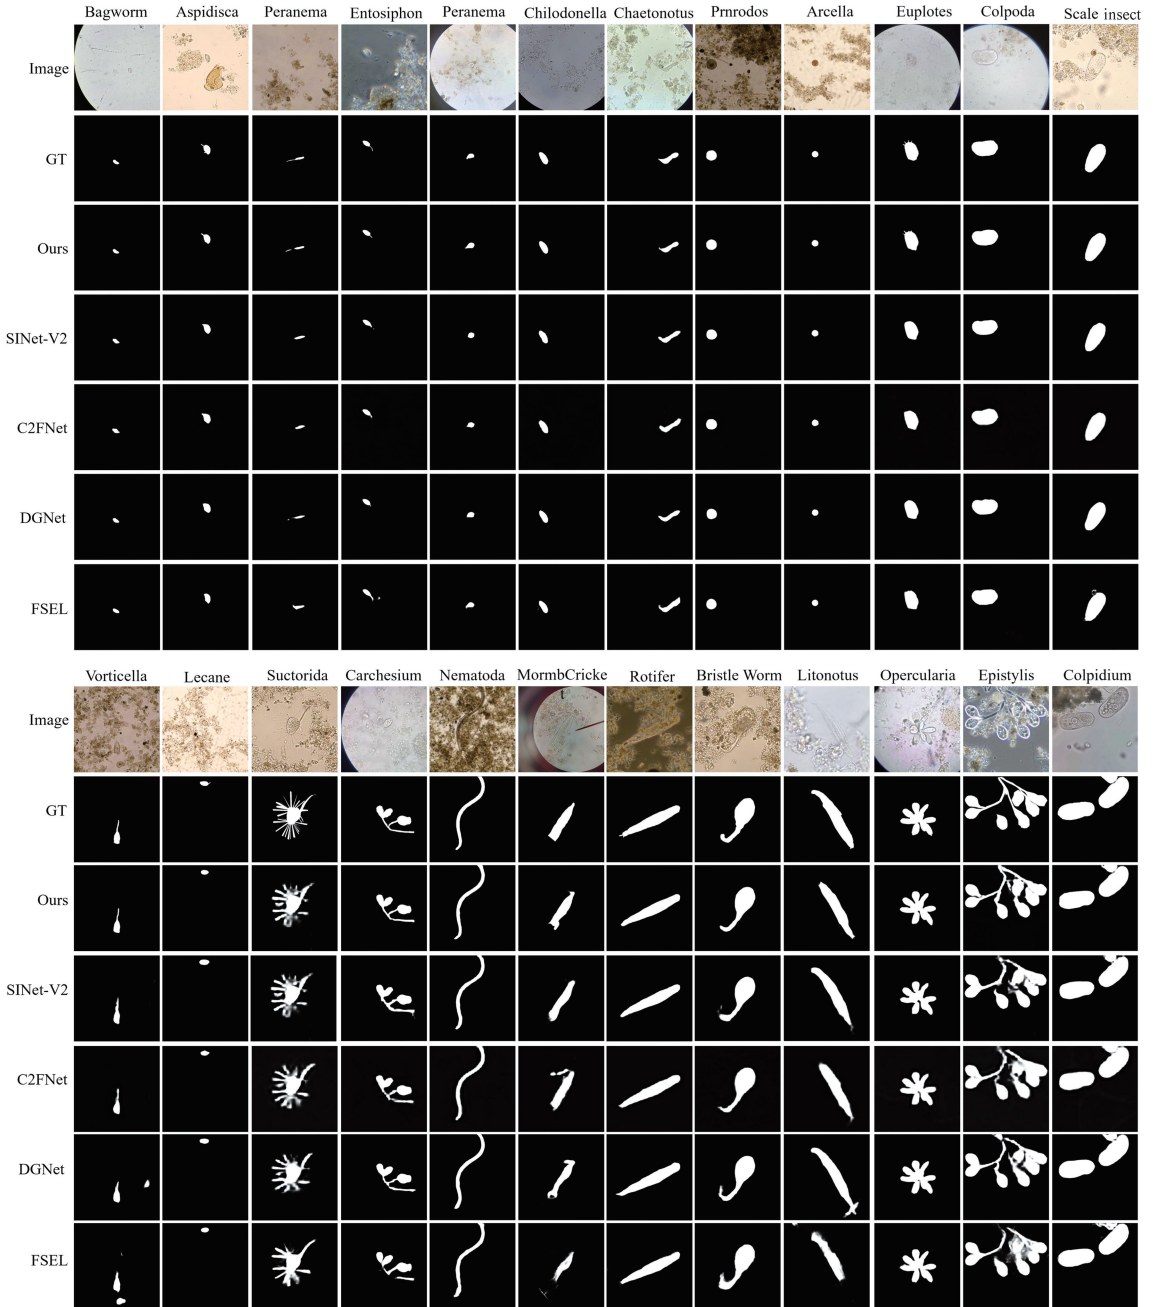


图 9 与一些具有代表性的 COD 模型在 CASM 数据集上的视觉比较

Fig. 9 Visual comparison with some representative COD models on the CASM dataset

2.5 消融实验

为了验证每个关键模块的有效性, 在 CASM 上进行消融实验, 结果如表 3 所示。基线模型为模型 a, 模型仅保留基础的骨干网络和 CAM 中的聚合操作。值得指出的是, 本研究方法采用了 PVTv2 作为骨干网络, 以替代原始

BGNet 中使用的 Res2Net50, 从而提升了多尺度特征提取能力和整体性能。

MFAM 的有效性: 从表 3 可知, 模型 b 的性能优于基线模型。在 S_o 、 F_β^o 和 E_ϕ 指标上均有提升, 特别是指标 F_β^o 提升了 1.1%, 指标 M 无显著差异, 证明了 MFAM 模块的




图 10 与其他边缘提取方法的可视化比较

Fig. 10 Visual comparison with other edge extraction methods

有效性。MFAM 模块可以有效捕获上下文信息增强模型

的特征提取能力。

EEM 的有效性:从表 3 可知,模型 c 在指标 S_a 、 F_β^w 和 E_ϕ 上表现均优于模型 b,指标 M 无显著差异,证明了 EEM 模块的有效性。EEM 模块的边缘信息可以增强了模型对边界的理解,说明添加辅助任务能够有效提高模型检测精度。

AFM 的有效性:从表 3 可知,与模型 c 相比模型 d 在指标 S_a 和 F_β^w 上均有所提升,指标 E_ϕ 和 M 无显著差异,证明了 AFM 模块的有效性。AFM 模块可以有效学习边缘语义信息,增强模型的特征表达能力。

CAM 的有效性:从表 3 可知,与模型 d 相比模型 e 在指标 S_a 、 F_β^w 、 E_ϕ 和 M 上均有所提升,证明了 CAM 模块的有效性。

表 3 CASM 数据集上的消融实验

Table 3 Ablation study results on CASM dataset

模型	MFAM	EEM	AFM	CAM	CASM			
					$S_a \uparrow$	$F_\beta^w \uparrow$	$M \downarrow$	$E_\phi \uparrow$
a					0.934	0.889	0.007	0.976
b	✓				0.939	0.900	0.007	0.978
c	✓	✓			0.942	0.902	0.006	0.979
d	✓	✓	✓		0.944	0.904	0.006	0.979
e	✓	✓	✓	✓	0.945	0.908	0.005	0.982

3 结 论

针对活性污泥微生物的伪装性、目标尺度多样性和复杂背景下目标边界模糊的问题,提出了一种基于多尺度感知和边缘增强的伪装目标检测方法。该方法使用多尺度特征感知模块获取上下文信息,使用边缘感知增强模块中捕获相关的边缘语义,使用注意力引导模块引导网络关注边缘信息,最后使用上下文聚合模块自上而下的逐步细化检测结果。同时,构建了一个用于活性污泥微生物伪装检测的数据集,该数据集中包含 25 种活性污泥微生物,共计包含 1 888 张图片。实验结果表明,所提出的方法在自建 CASM、CAMO、COD10K 和 NC4K 数据集上取得了较好的检测结果。未来的工作将扩展和丰富 CASM 数据集的类别和规模,并引入更多样化的工况条件,以进一步提升模型在实际应用中的泛化能力。

参考文献

[1] ARAÚJO DOS SANTOS L, FERREIRA V, PEREIRA M O, et al. Relationship between protozoan and metazoan communities and operation and performance parameters in a textile sewage activated sludge system [J]. European Journal of Protistology, 2014, 50(4): 319-328.

[2] 魏明军,杨轩,葛一琿,等. 基于深度网络特征交互的 RGB-T 显著目标检测 [J]. 电子测量技术, 2025,

48(13): 174-182.

WEI M J, YANG X, GE Y H, et al. RGB-T salient object detection based on deep network feature interaction [J]. Electronic Measurement Technology, 2025, 48(13): 174-182.

[3] 卢笑,曹意宏,周炫余,等. 基于深度强化学习的两阶段显著性目标检测 [J]. 电子测量与仪器学报, 2021, 35(6): 34-42.

LU X, CAO Y H, ZHOU X Y, et al. Two-stage salient object detection based on deep reinforcement learning [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(6): 34-42.

[4] GINORIS Y P, AMARAL A L, NICOLAU A, et al. Development of an image analysis procedure for identifying protozoa and metazoa typical of activated sludge system [J]. Water Research, 2007, 41(12): 2581-2589.

[5] BOZTOPRAK H, ÖZBAY Y. Detection of protozoa in wastewater using ANN and active contour in image processing [J]. IU-Journal of Electrical & Electronics Engineering, 2013, 13(2): 1661-1666.

[6] ZHENG X, TANG CH Y, LYU J R, et al. A novel method for microbial detection in wastewater treatment [J]. Journal of Engineering Science and Technology Review, 2024, 17(7): 153-162.

[7] LIU SH N, CHEN H ZH, LIU R K, et al. BiotaFormer: Detecting biota in microscopic activated

- sludge images for wastewater treatment [C]. 2024 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). IEEE, 2024: 1616-1619.
- [8] FAN D P, JI G P, SUN G L, et al. Camouflaged object detection [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020: 2774-2784.
- [9] SUN Y J, CHEN G, ZHOU T, et al. Context-aware cross-level fusion network for camouflaged object detection [C]. 30th International Joint Conference on Artificial Intelligence (IJCAD), 2021: 1025-1031.
- [10] SUN Y J, WANG SH, CHEN CH L Z, et al. Boundary-guided camouflaged object detection [C]. 31st International Joint Conference on Artificial Intelligence (IJCAD), 2022: 1335-1341.
- [11] HE CH M, LI K, ZHANG Y CH, et al. Camouflaged object detection with feature decomposition and edge reconstruction [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 22046-22055.
- [12] SUN Y G, XUAN H Y, YANG J, et al. GLCONet: Learning multisource perception representation for camouflaged object detection [J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36(7): 13262-13275.
- [13] SUN Y G, XU CH Y, YANG J, et al. Frequency-spatial entanglement learning for camouflaged object detection [C]. European Conference on Computer Vision (ECCV), 2024: 343-360.
- [14] JI G P, FAN D P, CHOU Y CH, et al. Deep gradient learning for efficient camouflaged object detection [J]. Machine Intelligence Research, 2023, 20(1): 92-108.
- [15] JIA Q, YAO SH L, LIU Y, et al. Segment, magnify and reiterate: Detecting camouflaged objects the hard way [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022: 4713-4722.
- [16] 池盼盼, 梅琛楠, 王焰, 等. 基于边缘填充的单兵迷彩伪装小目标检测 [J]. 纺织学报, 2024, 45(1): 112-119.
- CHI P P, MEI CH N, WANG Y, et al. Edge-filling based detection of small camouflaged targets for individual soldiers [J]. Journal of Textile Research, 2024, 45(1): 112-119.
- [17] 丁铨, 白雪琼, 吕勇, 等. 基于特征聚合与边缘检测的伪装目标检测 [J]. 光子学报, 2024, 53(8): 267-278.
- DING CH, BAI X Q, LYU Y, et al. Camouflaged object detection based on feature aggregation and edge detection [J]. Acta Photonica Sinica, 2024, 53(8): 267-278.
- [18] WANG W H, XIE E Z, LI X, et al. PVT v2: Improved baselines with pyramid vision transformer [J]. Computational Visual Media, 2022, 8(3): 415-424.
- [19] ZHU H, LI P, XIE H, et al. I can find you! Boundary-guided separated attention network for camouflaged object detection [C]. AAAI Conference on Artificial Intelligence, 2022, 36(3): 3608-3616.
- [20] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020: 11531-11539.
- [21] WEI J, WANG SH H, HUANG Q M. F³Net: Fusion, feedback and focus for salient object detection [C]. AAAI Conference on Artificial Intelligence, 2020, 34(7): 12321-12328.
- [22] XIE EN Z, WANG W J, WANG W H, et al. Segmenting transparent objects in the wild [C]. European Conference on Computer Vision (ECCV). Cham: Springer, 2020: 696-711.
- [23] LE T N, NGUYEN T V, NIE ZH L, et al. Anabranh network for camouflaged object segmentation [J]. Computer Vision and Image Understanding, 2019, 184: 45-56.
- [24] LYU Y Q, ZHANG J, DAI Y C, et al. Simultaneously localize, segment and rank the camouflaged objects [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 11591-11601.
- [25] FAN D P, CHENG M M, LIU Y, et al. Structure-measure: A new way to evaluate foreground maps [C]. 2017 IEEE International Conference on Computer Vision (ICCV). IEEE, 2017: 4558-4567.
- [26] MARGOLIN R, ZELNIK-MANOR L, TAL A. How to evaluate foreground maps [C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2014: 248-255.
- [27] FAN D P, JI G P, QIN X B, et al. Cognitive vision inspired object segmentation metric and loss function [J]. Scientia Sinica Informationis, 2021, 6(6): 5.
- [28] ACHANTA R, HEMAMI S, ESTRADA F, et al. Frequency-tuned salient region detection [C]. 2009 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2009: 1597-1604.
- [29] FAN D P, JI G P, CHENG M M, et al. Concealed object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(10): 6024-6042.
- [30] TANG ZH, TANG J, ZOU D P, et al. Two guidance joint network based on coarse map and edge map for camouflaged object detection [J]. Applied Intelligence, 2024, 54(15): 7531-7544.

作者简介

赵立杰, 博士, 教授, 主要研究方向为智能信息处理。

E-mail: zhaolijie@syuct.edu.cn

金明溪, 硕士, 主要研究方向为计算机视觉。

方一凡, 硕士, 主要研究方向为计算机视觉。

黄明忠 (通信作者), 硕士, 副教授, 主要研究方向为智能信息处理。

E-mail: syhmz75111@syuct.edu.cn