

基于 DeepLabV3 + 的污泥显微图像分块分割方法

赵立杰 王良娟 路星奎 邹世达 王国刚 黄明忠*

(沈阳化工大学信息工程学院 辽宁 沈阳 110142)

摘要 针对传统图像方法处理活性污泥相差显微图像存在过分割、欠分割,甚至分割失败问题,基于改进的 DeepLabV3 + 网络进行分块分割以提高丝状菌分割效果。该方法以一定重叠率将高分辨相差显微图像切分成多块区域并进行分割,再将分割图像拼接恢复到原始分辨率。所提方法在某城市污水处理厂活性污泥显微图像数据上进行验证。实验结果表明,轻量化分块分割方法相对于未分块的 DeepLabV3 +、U-Net、SegNet 模型在精确率、召回率、像素准确率和 IoU 性能指标上有一定程度的提升,模型大小显著降低。

关键词 活性污泥 相差显微镜 图像分割 轻量级 注意力机制

中图分类号 TP391

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2025.02.035

SLUDGE MICROSCOPIC IMAGE CHUNKING BASED ON DEEPLABV3 + METHOD

Zhao Lijie Wang Liangjuan Lu Xingkui Zou Shida Wang Guogang Huang Mingzhong*

(College of Information Engineering, Shenyang University of Chemical Technology, Shenyang 110142, Liaoning, China)

Abstract Activated sludge phase contrast microscopic image segmentation based on traditional image methods often suffers from over-segmentation, under-segmentation, and even segmentation failure. An improved DeepLabV3 + network is used for block segmentation to improve the segmentation effect of filamentous bacteria. This method divided a high-resolution phase-contrast microscopy image into multiple small areas with a certain overlap rate. The segmented images were stitched back to the original resolution. The proposed method was verified on the microscopic image data of activated sludge from a municipal sewage treatment plant. The experimental results show that the lightweight segmentation strategy model has a certain degree of improvement in segmentation accuracy, recall, pixel accuracy and IoU performance indicators compared with the undivided DeepLabV3 +, U-Net, and SegNet models, and the model size is significantly reduced.

Keywords Activated sludge Phase contrast microscope Image segmentation Lightweight Attention mechanism

0 引言

活性污泥法广泛应用于污水的生化处理厂。在生物降解过程中,污泥的沉降和压缩性能是生化处理的关键。污泥膨胀的发生常常导致污泥流失和出水水质恶化,严重危害污水处理厂运行^[1-2]。为了监测和控制活性污泥过程,常常借助显微镜观察污泥微观结构,分析活性污泥的稳定性、絮凝性和指示性微生物种群变化^[3]。

目前,显微图像定量分析法在监测活性污泥过程中的应用已得到关注和认可^[4]。絮体和丝状菌图像分割是污泥图像处理和 analysis 的基础和关键,直接影响后续污泥形态定量信息提取的准确性和污泥膨胀预报的可靠性。活性污泥图像的一些基本分割技术包括基于直方图的均值间阈值^[5]、图像增强之前的边缘检测^[6]、Canny 算法^[7]。文献^[8]提出了一种自动阈值算法,该算法在图像中选择两个阈值,其中一个部分比背景暗,另一部分比背景亮。一旦物体与背景分离,则通过减小的回转半径将它们分类为絮状物或细丝。由于

收稿日期:2021-10-07。国家重点研发计划项目(2018YFB1700200);辽宁省自然科学基金项目(201602599);辽宁省教育厅科研项目(LQ2017006)。赵立杰,教授,主研领域:智能信息处理。王良娟,硕士生。路星奎,硕士生。邹世达,硕士生。王国刚,教授。黄明忠,副教授。

双阈值方法并不完全令人满意,文献[9]开发了一个单一的阈值处理程序。在这种方法中,对原始图像进行处理,使得絮状物和细丝在相同的强度区域中变得可见,并且只需要一个阈值来将它们从背景中分离出来。文献[10]提出了一种由背景校正、直方图均衡化、中值滤波和形态学运算组成的连续分割算法。

与传统的分割方法相比,一系列基于深度学习的图像语义分割方法被提出,实现了更加精准且高效的分割,使图像分割的应用范围得到了进一步的推广。文献[11]提出了用于像素级分类的全卷积神经网络(Fully Convolutional Networks, FCN),解决了语义级别的图像分割问题,并提出对输出激活图进行上采样,从中可以计算像素级输出。文献[12]在基于 FCN 的像素预测框架中,提出了一种金字塔场景解析网络,该网络能够编码多尺度上下文信息,通过逐渐恢复空间信息来捕捉更清晰的对象边界。DeepLab 系列模型^[13-16]是 Chen 等提出的深度卷积神经网络(Deep Convolutional Neural Network, DCNN)模型,其核心是使用空洞卷积,不仅能在计算特征响应时明确地控制响应的分辨率,而且还能扩大卷积核的感受野,在不增加参数量和计算量的同时,能够整合更多的特征信息。文献[17]提出了一种自适应多尺度模块和自适应引信模块来解决单个特征图很难获得足够强的表征特征及浅层特征通过的网络层数较少,特征表示能力较弱的问题。该模块可以根据图像的大小特征自适应融合不同分支的多尺度特征,在目标复杂多变的数据集中具有较好的分割效果。文献[18]提出了一种有效的特征学习模块以提高特征质量和降低层间依赖性,能够在不同层之间恢复和共享上下文信息。实验结果证明了该网络在准确性和鲁棒性方面的优越性。文献[19]提出了一种改进的损失函数构建 Dual U-Net 深度学习模型的方法,实现污泥相差显微图像丝状菌和絮体的自动分割。然而深度学习模型往往模型规模较大,很难满足资源受限场景下高精度、低能耗实时运行要求,因此基于深度学习的图像分割模型轻量化引起学术界和工业界高度关注^[20]。

针对现有的深度学习图像分割模型轻量化需求,本文基于 DeepLabV3 + 框架,使用双注意力机制改进的 MobileNetV2 网络替换 DeepLabV3 + 主干网络 Xception^[21],以减少模型参数量。针对所采集的污泥相差显微图像中含目标较小的丝状菌和目标较大的絮体,存在类别不均衡问题。将污泥相差显微图像分成多个含重叠区域的等面积的子图像,子图像作为数据集输入分割网络进行图像分割,再将分割好的子图像恢复成完整的原始图像获得所需的分割结果。

1 污泥相差显微图像分块分割

1.1 污泥相差显微图像分割问题描述

在数据采集过程中,污泥图像是通过相差显微镜获得的。与普通显微镜相比,相差显微镜获取的活性污泥图像在较低放大倍率下对丝状菌表现出更好的辨别能力,能够更有效地检测丝状菌,同时样品无须染色。但是,相差显微图像固有的光晕和阴影效应导致絮状物和丝状菌边界周围存在明亮的光晕、絮体区域与背景之间的对比度较低,如图 1 所示。由于活性污泥中丝状菌形态细长纵横比大、絮体结构复杂具有高度形变特性,相差显微图像固有的微观伪影严重阻碍了絮体和丝状菌的可靠分割。




图 1 污泥相差显微图像

1.2 污泥图像分块分割策略

如表 1 所示统计出了 316 幅污泥图像数据集各类别的分布情况,可以看出背景占据图像的大部分区域,絮体与丝状菌存在严重的类别不均衡现象。细小丝状菌分割难度大且在污泥图像中十分常见,在不同图像中的分布是不可预测的。在整个数据集中,几乎每幅图像都包含细小丝状菌这类小目标。这种数据分布的严重不均衡妨碍了训练进程。小目标数量少且尺寸相对较小,因此在训练中对于网络的优化作用较小,这种不均衡的网络参数优化导致分割性能不佳。针对这个问题,本文使用分块分割策略提升污泥相差显微图像的分割效果。该策略是将数据集图像分成多幅等面积的子图像再进行分割,可根据数据集的不同调整分块数量。

表 1 污泥图像数据集各类像素个数及占比

目标	像素个数	占比
背景	834 741 808	0.840
絮体	144 384 982	0.145
丝状菌	14 923 258	0.015

若将原始图像分成 2×2 的 4 块子图,如图 2(a)、图 2(b)所示分别为分成不重叠的 $1\ 024 \times 768$ 子图和重叠像素点为 200 的 $1\ 124 \times 868$ 的子图。分别将这两类分块后子图作为数据集输入到分割网络中进行分割再拼接成原始图片大小。图 2(c)、图 2(d)所示为还原成原图的局部区域,从图 2(c)可以观察到,图像边缘的信息没有分割出来,导致无重叠子图拼接时容易出现明显的拼接缝隙,而含重叠区域子图拼接后无任何拼接缝隙如图 2(d)所示。于是在分块策略中,切分原始图像时,相邻子图之间需留有一部分的重叠区域,便于后期消除拼接缝隙。

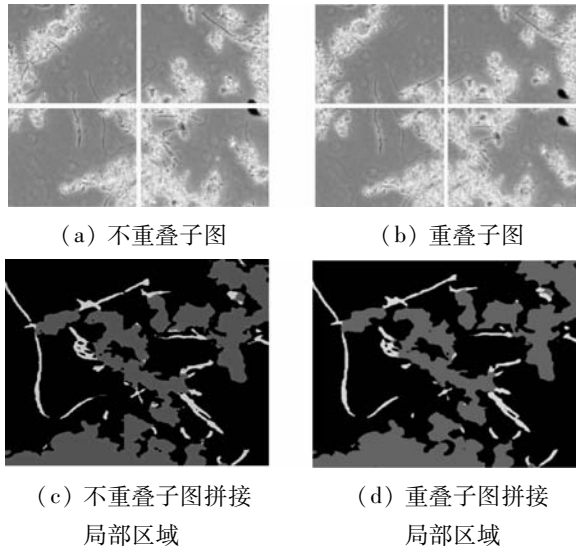


图 2 分块子图与拼接局部区域图

如图 3 所示为分块分割流程,包括图像采集、分块策略、模型训练、图像拼接。图像采集为从沈阳某城市污水处理厂中取样通过图像采集系统获取活性污泥图像,将图像进行标注构建的数据集分为训练、验证和测试数据。通过将完整的活性污泥图像分成较小的子图像输入分割网络对单独进行分割,图像中的阴影、光照和复杂背景对图像分割造成的影响会显著减少。

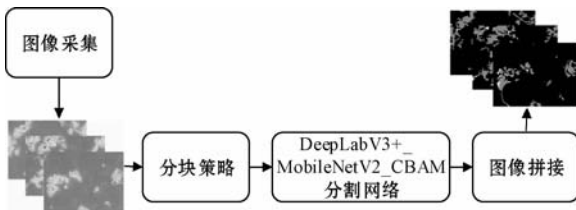


图 3 分块分割策略

为了提高模型的泛化能力,对训练集进行随机翻转、水平位移、颜色抖动等操作实现数据增强,添加灰边防止图像失真。采用 Dice Loss 损失函数来衡量网络的分割误差,使用预训练模型加快网络的收敛速度,Adam 优化器进行参数优化。将测试集输入到训练好的 DeepLabV3 + _MobileNetV2_CBAM 网络中分割,输

出的子图像按顺序粘贴到对应位置上恢复成原始图像大小,实现更高精度的分割。

1.3 DeepLabV3 + _MobileNetV2_CBAM 图像分割模型

1.3.1 MobileNetV2_CBAM 主干网络

污泥相差显微图像的前景特征与背景干扰都较为复杂,为使模型能够更好地将注意力聚焦在前景特征上,在 MobileNetV2 中引入 Convolutional Block Attention Module (CBAM) 注意力机制^[22]帮助倒残差模块细化中间特征图。

如图 4 所示 CBAM 分为两个独立的部分,空间注意力模块(Channel Attention Module, CAM)和通道注意力模块(Spatial Attention Module, SAM)。CAM 分别使用平均池化和最大池化操作聚合特征映射的空间信息,生成两个不同的空间上下文特征图,分别表示平均池特征和最大池特征。再将两个特征图转发到一个共享网络,以生成空间注意力图。SAM 并行进行最大池化和平均池化操作,将池化特征进行全连接,增加通道关联并通过缩放参数降维后使用 sigmoid 函数将通道权值映射到 0 到 1 之间。CBAM 沿着通道和空间两个独立的维度依次推断出注意力图,再将注意力图乘以输入特征图进行自适应特征优化。该注意力模块设计为轻量级,参数和计算的成本在大多数情况下可以忽略不计。




图 4 CBAM

给定一个中间特征图 $F \in \mathbf{R}^{C \times H \times W}$ 作为输入时, CBAM 依次推断出一个通道注意图 $M_c \in \mathbf{R}^{C \times 1 \times 1}$ 和空间注意图 $M_s \in \mathbf{R}^{1 \times H \times W}$ 。整体注意力机制过程可表示为:

$$\begin{aligned} F' &= M_c(F) \otimes F \\ F'' &= M_s(F') \otimes F' \end{aligned} \quad (1)$$

式中: \otimes 表示特征图之间相乘, F'' 为最终的细化输出。

改进的 MobileNetV2_CBAM 主干网络由多个含有双注意力机制的倒残差单元组成。具有 CBAM 的倒残差模块如图 5 所示,将低维压缩表示作为输入,通过 1×1 卷积将低维空间映射到高维空间。使用 ReLU6 非线性激活函数,通过限制输出值最大值为 6,增强模型在低精度硬件设备上计算时的鲁棒性,避免计算精度损失。再采用深度可分离卷积进行滤波提取特征,

特征图通过双注意力机制自适应地细化特征后使用线性卷积被映射回低维空间, CBAM 的特征细化过程最终会使网络很好地利用给定的特征从而得到更好的分割结果。线性卷积后不使用 ReLU6 非线性激活函数, 以减少可能造成的信息丢失或破坏。每次卷积后添加批量标准化层, 调节各层输入的分布, 增加深度网络学习过程的稳定性, 优化曲面更平滑^[23]。

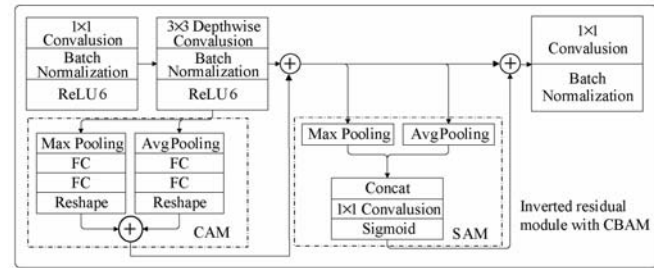
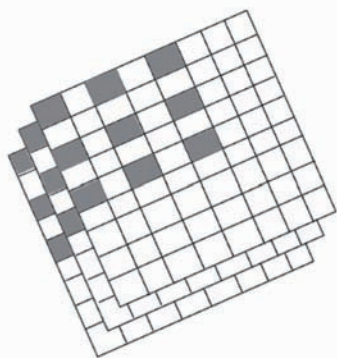



图 5 具有 CBAM 的倒残差模块

MobileNetV2_CBAM 中的深度可分离卷积使用膨胀率为 2 的空洞卷积扩大感受野, 获取更多的上下文信息。图 6 所示为深度可分离卷积, 首先采用 depthwise convolution 将标准卷积分解为每个输入通道独立执行膨胀率为 2 的空洞卷积进行特征提取操作, 再通过 pointwise convolution 卷积计算输入通道的线性组合来构建新的特征图。



(a) 使用膨胀率为 2 的 depthwise convolution



(b) pointwise convolution

图 6 使用膨胀率的深度可分离卷积

1.3.2 图像分割模型

污泥相差显微图像分块分割模型如图 7 所示。该体系基于 DeepLabV3 + 架构采用 MobileNetV2_CBAM

为主干网络, 保持尽可能少的层数, 以将参数数量减少到约 280 万, 从而降低计算复杂度和内存成本。该网络采用语义分割常用的 encoder-decoder 结构, 可以通过逐渐恢复空间信息来捕获更清晰的目标边界。使用 Atrous Spatial Pyramid Pooling (ASPP) 模块来挖掘不同尺度的卷积特征以及编码全局内容信息的图像层特征, 提升分割效果。本文网络的主要优点是内存需求小, 适合在移动应用中实现, 而不用担心内存存储容量。

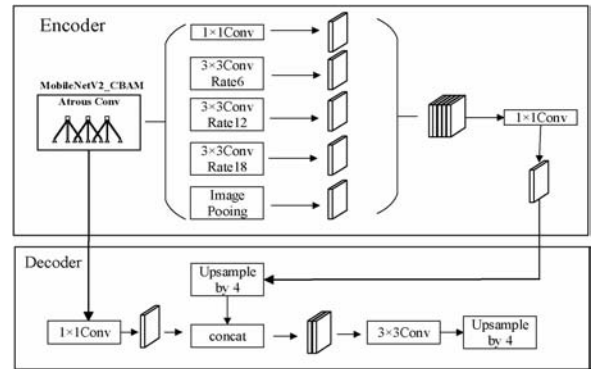


图 7 DeepLabV3 +_MobileNetV2_CBAM 网络结构

Encoder 的结构具有两个特点: (1) 在 MobileNetV2_CBAM 里使用了空洞卷积。(2) 在图像经过 MobileNetV2_CBAM 之后的结果分为两部分, 一部分直接传入 Decoder, 另一部分通过 ASPP 模块对进入的特征图进行多速率、多有效视场的卷积或池化操作, 从而捕获多个比例尺的目标。ASPP 模块有 5 个分支分别是 1×1 的卷积层, 膨胀率为 6、12、18 的 3×3 的卷积层和一个池化层, 得到 5 个特征图, 将特征图拼接后再使用 1×1 卷积压缩特征。

Decoder 中输入有两部分, 一部分是 MobileNetV2_CBAM 经过两次下采样输出的含较低语义信息的特征图, 一部分是 MobileNetV2_CBAM 经过四次下采样后得到的含较高语义信息的特征图进行并行空洞卷积后链接起来输出的特征图。该特征图通过 4 倍的双线性上采样操作, 与具有相同空间分辨率的含较低语义信息的特征图连接。连接之后, 使用多个 3×3 卷积来细化特征, 再使用一个 4 倍的双线性上采样获得最终预测结果。

1.3.3 损失函数

复杂场景中适当的损失函数对于保证深度学习模型的性能至关重要。污泥图像中常出现类别不均衡的问题, 使用交叉熵的损失函数可能导致训练会被像素较多的类主导, 对于较小的物体很难学习到其特征, 从而降低网络的有效性。为了使模型能获得较好的表征学习能力, 本文采用 Dice Loss 损失函数进行模型训练。公式如下:


$$D_{\text{iceLoss}} = 1 - \frac{2T_P}{2T_P + F_N + F_P} \quad (2)$$

式中: T_P (True Positive) 为将正类预测为正类数; T_N (True Negative) 为将负类预测为负类数; F_P (False Positive) 为将负类预测为正类数; F_N (False Negative) 为将正类预测为负类数。

2 实验

2.1 活性污泥显微图像数据

活性污泥样品采自沈阳某 A^2O 污水厂的曝气池出口离液面 50 cm 处, 每个样品使用带有截面尖端枪头的校准移液枪取 10 μL 于载玻片上, 并用 24 mm \times 24 mm 的正方形盖玻片覆盖, 放置在倒置光学显微镜 (Nikon Eclipse TS100) 上, 使用工业数码相机 (ToupTek ToupCamuoms03100kPa) 和图像采集软件 (ToupView) 从左上到右下呈“Z”形拍摄 36 (6 \times 6) 幅像素为 2 048 \times 1 536 的 RGB 彩色图像。显微镜相差放大倍数为 100 倍, 以清晰地观察到絮体和丝状菌的形状和结构。如图 8 (a) 所示为污泥相差显微图像, 图 8 (b) 为使用 labelme 软件进行标注的图像, 其中: 标注图中的灰色为絮体, 白色为丝状菌, 分割目标为絮体和丝状菌。



(a) 污泥相差显微图像 (b) 标注图像

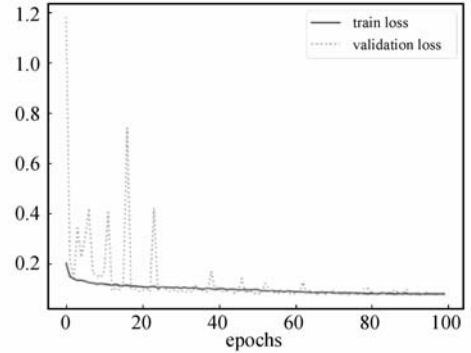
图 8 污泥相差显微图像分析

2.2 模型训练

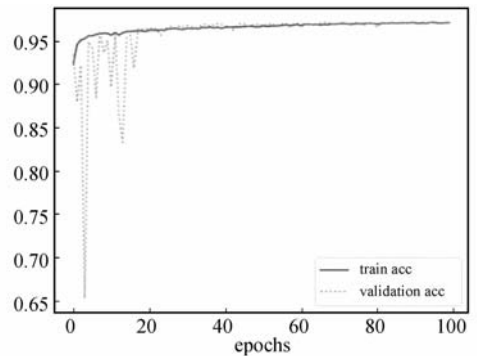
为了验证分块策略和改进网络的有效性, 使用 316 幅典型图像及标注图像构建成数据集, 将一幅高分辨率原始图像切分为多幅子图。经验证将污泥显微图像数据集分成 3 \times 4 幅子图效果最佳, 重叠像素区域无须过大, 占子图的 20% ~ 30% 即可。本文重叠像素区域设置为 200, 分块后子图像素为 662 \times 645。分别用 316 幅原图和切分后的 3 792 幅子图作为本次实验数据集, 按照 6: 2: 2 划分为互不交叉的训练集、验证集和测试集。在本次实验中, 采用基于 TensorFlow 后端的 Keras 库来搭建深度学习模型, 在一台 3.60 GHz 8 核 Intel Core i9-9900K CPU 的服务器上完成代码测试, 服务器具有 11 GB 显存的 GeForce RTX 2080 Ti 显卡和 27 GB 内存。

将像素为 2 048 \times 1 536 的未分块图像与像素为

662 \times 645 的分块图像设置为 512 \times 512 分别输入分割网络进行训练。初始学习率为 0.001, 验证集损失函数 2 次不发生变化就下降学习率为原来的 0.9 倍继续训练。batch 设置为 4, epochs 设置为 100, 保存网络训练的最优模型。如图 9 所示为 DeepLabV3 + _MobileNetV2_CBAM 活性污泥絮体和丝状菌分块分割模型训练和校验迭代 100 轮的损失值和准确率曲线。



(a) 训练和测试损失值



(b) 训练和测试准确率

图 9 模型损失值和准确率

2.3 评价指标

使用召回率 (Recall)、精确率 (Precision)、像素准确率 (Pixel Accuracy, PA)、交并比 (Intersection over Union, IoU) 作为评价图像分割网络性能指标来判断模型的好坏。式子如下:

$$R_{\text{recall}} = \frac{T_P}{T_P + F_N} \quad (3)$$

$$P_{\text{recision}} = \frac{T_P}{T_P + F_P} \quad (4)$$

$$P_A = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (5)$$

$$I_{\text{oU}} = \frac{T_P}{T_P + F_P + F_N} \quad (6)$$

式中: R_{recall} 反映了被正确判定的正例占总的正例的比值; P_{recision} 表示被正确判定的正例占实际为正例的比值; P_A 是分割对的像素总数占像素总数的比值; I_{oU} 是真实标签和预测分割图片的交集与并集的比值, IoU 值越高, 表明其推断出的分割结果越接近人工标注结果。

2.4 结果与分析

在测试集上评估分块分割网络性能,分别用 U-Net、SegNet、DeepLabV3 + _Xception 和 DeepLabV3 + _MobileNetV2_CBAM 进行图像未分块分割和分块分割,

分割结果如图 10 和图 11 所示。其中:(a)是原始图像,(b)是标注图像,(c)、(d)、(e)、(f)分别是 U-Net、SegNet、DeepLabV3 + _Xception 和 DeepLabV3 + _MobileNetV2_CBAM 的分割图像。




图 10 污泥显微图像未分块分割结果




图 11 污泥显微图像分块分割结果

图 10 是污泥显微图像未分块分割结果。观察可以发现,各网络能够较好地分割出污泥显微图像中的大部分区域,但细小的丝状菌没有被分割出来,有些丝状菌虽然能分割出来但存在分割不连续和误分割的问题。图 11 是通过分块策略将完整的图像分成 12 个子图像,单独进行分割再还原恢复成原始分辨率的分割结果。分块后子图像中小目标所占的面积与子图面积比例变大,充分利用高分辨率图像的像素信息,更有利于细小丝状菌的分割。输出的丝状菌连续且一些细小丝状菌也能够更加完整地分割出来,改善图像的分割效果,体现了分块策略对小目标分割的有效性。

从图 10、图 11 中可以看出,在絮体和丝状菌上 DeepLabV3 + _MobileNetV2_CBAM 比 DeepLabV3 + _Xception、U-Net 和 SegNet 具有更好的分割效果。当图像出现复杂的前景与背景时,U-Net 方法经常忽略丝状菌的边界,SegNet 方法不能为丝状菌分割生成平滑的边缘。DeepLabV3 + 模型能较好地应对不同环境,具有较强的泛化能力。实验结果表明在 DeepLabV3 + 框架中编码器模块能够通过多个尺度上应用空洞卷积来获得多尺度上下文信息,使用简单而有效的解码器模块可以沿着对象边界细化分割结果。改进的主干网络 MobileNetV2_CBAM 能够更好地提取特征,提高了分割网络的性能。

表 2 记录了未分块分割模型 U-Net、SegNet、DeepLabV3 + _Xception、DeepLabV3 + _MobileNetV2_CBAM 和分块分割模型 T-U-Net、T-SegNet、T-DeepLabV3 + _

Xception、T-DeepLabV3 + _MobileNetV2_CBAM 在测试集上分割结果的评价指标及模型大小。可以看出,模型使用分块策略处理后絮体(Floc)和丝状菌(Fila)在 Precision、Recall 和 IoU 分割指标上均有显著提高,各网络的 IoU 在丝状菌上分别提高了 17.1%、15.7%、10.9%、10.3%,产生一个更好的污泥图像分割结果,大大减少了丝状菌误分类的现象。可见分块分割模型可以很好地识别出污泥显微图像中小目标的轮廓区域,使模型更好地提取关键区域的特征信息。分块分割模型在最后的分割结果表现上高于未分块分割模型,验证了分块策略在分割网络中能提高性能且具有泛化性。

表 2 显示,DeepLabV3 + _Xception 模型体积最大,DeepLabV3 + _MobileNetV2_CBAM 模型体积最小只有 DeepLabV3 + _Xception 的 7%。但在 IoU 分割指标上絮体和丝状菌比 DeepLabV3 + _Xception 分别提高了 1.9%、1.8%。结果证明具有 CBAM 的倒残差模块能够很好地强调或抑制中间特性,更好地学习到目标前景特征,在保持较小开销的同时取得了一定的性能提升,倒残差模块中跳跃连接可以更好地恢复扩展路径的图像细节。通过在 DeepLabV3 + _MobileNetV2_CBAM 模型中添加 CBAM,放在每个分类器的前面,在预测之前对最终的由上采样的全局特征和相应的局部特征组成的特征进行细化,使模型自适应地只选择有意义的特征,有助于进一步改善分割效果。本文网络能够在提高性能的同时显著降低模型的计算复杂度,有效减少网络参数和所占内存。

表 2 模型性能对比及模型大小

模型	Precision			Recall			IoU			PA	Size
	Floc	Fila	Mean	Floc	Fila	Mean	Floc	Fila	Mean		
U-Net	0.728	0.506	0.617	0.875	0.228	0.552	0.660	0.187	0.424	0.94	62.8M
T-U-Net	0.890	0.589	0.740	0.888	0.477	0.683	0.718	0.358	0.538	0.96	
SegNet ^[24]	0.710	0.353	0.532	0.848	0.182	0.515	0.630	0.136	0.383	0.93	44.1M
T-SegNet	0.789	0.518	0.654	0.830	0.402	0.616	0.679	0.293	0.486	0.95	
DeepLabV3 + _Xception	0.798	0.548	0.673	0.880	0.430	0.655	0.720	0.317	0.519	0.95	158.0M
T-DeepLabV3 + _Xception	0.853	0.605	0.729	0.870	0.590	0.655	0.753	0.426	0.590	0.96	
DeepLabV3 + _MobileNetV2_CBAM	0.833	0.615	0.724	0.856	0.429	0.643	0.731	0.341	0.536	0.95	11.3M
T-DeepLabV3 + _MobileNetV2_CBAM	0.857	0.592	0.725	0.886	0.636	0.761	0.772	0.444	0.608	0.96	

3 结 语

针对活性污泥相差显微图像丝状菌和絮体分割过

程中由于丝状菌目标小分割精度低问题,本文基于 MobileNetV2_CBAM 主干网络的 DeepLabV3 + 分割模型,采用分块分割方法,建立轻量化丝状菌和絮体显微图像分割模型,一定程度上克服了微小目标在深度学

习过程中由于下采样导致信息丢失造成的分割精度降低的问题,同时减小了模型的大小和参数量。在某城市污水处理厂采集的活性污泥相差显微图像数据集实验验证结果表明,本文所提的分块分割策略在分割性能和模型大小上具有相对优势,满足了分割精度和轻量化的需求,便于边缘端部署。

参 考 文 献

- [1] Guo J, Peng Y, Wang S, et al. Filamentous and non-filamentous bulking of activated sludge encountered under nutrients limitation or deficiency conditions[J]. *Chemical Engineering Journal*, 2014, 255: 453–461.
- [2] Valverde-Pérez B, Wágner D S, Lóránt B, et al. Short-sludge age EBPR process—Microbial and biochemical process characterisation during reactor start-up and operation[J]. *Water Research*, 2016, 104: 320–329.
- [3] Mesquita D, Amaral A, Ferreira E. Activated sludge characterization through microscopy: A review on quantitative image analysis and chemometric techniques[J]. *Analytica Chimica Acta*, 2013, 802: 14–28.
- [4] Costa J, Mesquita D, Amaral A, et al. Quantitative image analysis for the characterization of microbial aggregates in biological wastewater treatment: A review[J]. *Environmental Science and Pollution Research*, 2013, 20: 5887–5912.
- [5] Jenné R, Cenens C, Geeraerd A, et al. Towards on-line quantification of flocs and filaments by image analysis[J]. *Biotechnology Letters*, 2002, 24: 931–935.
- [6] Heine W, Sekoulov I, Burkhardt H, et al. Early warning-system for operation-failures in biological stages of WWTPs by on-line image analysis[J]. *Water Science and Technology*, 2002, 46(4–5): 117–124.
- [7] Sikora M, Smolka B. Feature analysis of activated sludge based on microscopic images[C]//Canadian Conference on Electrical and Computer Engineering 2001: 1309–1314.
- [8] Worman A, Packman A I, Johansson H, et al. Effect of flow-induced exchange in hyporheic zones on longitudinal transport of solutes in streams and rivers[J]. *Water Resources Research*, 2002, 38(1): 2–15.
- [9] Jenné R, Banadda E, Smets I, et al. Detection of filamentous bulking problems: Developing an image analysis system for sludge composition monitoring[J]. *Microscopy and Microanalysis*, 2007, 13(1): 36–41.
- [10] Perez Y, Leite S, Coelho M. Activated sludge morphology characterization through an image analysis procedure[J]. *Brazilian Journal of Chemical Engineering*, 2006, 23(3): 319–330.
- [11] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 39(4): 640–651.
- [12] Zhao H, Shi J, Qi X, et al. Pyramid scene parsing network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6230–6239.
- [13] Chen L, Papandreou G, Kokkinos I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[EB]. arXiv:1412.7062, 2014.
- [14] Chen L, Papandreou G, Kokkinos I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 40(4): 834–848.
- [15] Chen L C, Papandreou G, Schroff F, et al. Rethinking Atrous convolution for semantic image segmentation[EB]. arXiv:1706.05587, 2017.
- [16] Chen L, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//European Conference on Computer Vision, 2018: 801–818.
- [17] Liu Y, Zhu Q, Cao F, et al. High-resolution remote sensing image segmentation framework based on attention mechanism and adaptive weighting[J]. *International Journal of Geo-Information*, 2021, 10(4): 241.
- [18] Shu Y, Zhang J, Xiao B, et al. Medical image segmentation based on active fusion-transduction of multi-stream features[J]. *Knowledge-Based Systems*, 2021, 220: 106950.
- [19] Zhao L, Zou S, Zhang Y, et al. Segmentation of activated sludge phase contrast microscopy images using u-net deep learning model[J]. *Sensors and Materials*, 2019, 31(6): 2013–2028.
- [20] 史宝岱,张秦,李瑶,等. 面向图像目标识别的轻量化卷积神经网络[J]. *计算机工程*, 2022, 48(6): 257–262.
- [21] Chollet F. Xception: Deep learning with depthwise separable convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 1800–1807.
- [22] Woo S, Park J, Lee J, et al. CBAM: Convolutional block attention module[C]//European Conference on Computer Vision, 2018: 3–19.
- [23] Santurkar S, Tsipras D, Ilyas A, et al. How does batch normalization help optimization? [C]//32nd International Conference on Neural Information Processing Systems, 2018: 2488–2498.
- [24] Badrinarayanan V, Kendall A, Cipolla R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481–2495.