

## 基于改进 I-Attention U-Net 的锌浮选泡沫图像分割算法

唐朝晖, 郭俊岑, 张虎<sup>†</sup>, 谢永芳, 钟宇泽

(中南大学自动化学院, 湖南长沙 410083)

**摘要:**针对泡沫图像的高度复杂性导致其难以被准确分割的难题,本文提出了一种新的 I-Attention U-Net 网络用于泡沫图像分割.该算法以 U-Net 网络作为主干网络,使用 Inception 模块替换第一卷积池化层来提取泡沫图像的多尺度、多层次浅层特征信息;引入金字塔池化模块,通过对不同尺度的特征图求和来提升分割效果;并对自注意力门控单元进行改进,使注意力单元更适合于浮选泡沫图像的分割,强化深层特征的重要性并对不同尺寸的泡沫边界进行强化学习.研究表明:本文所提出算法的 Jaccard 系数为 91.73%,Dice 系数为 95.66%.与同类其他分割算法结果相比,Jaccard 系数及 Dice 系数分别提高了 1.59%、0.88%.该模型能够较好地解决欠分割与过分割的问题,为后续的泡沫特征提取奠定基础.此外,该方法检测时间和模型参数少,具备可以部署在工业现场计算机的能力,有一定的实际应用价值.

**关键词:**泡沫浮选;泡沫图像分割;U-Net;Inception 模块;增强注意力机制

**中图分类号:**TP391.4;TD952 **文献标志码:**A

## Froth Image Segmentation Algorithm Based on Improved I-Attention U-Net for Zinc Flotation

TANG Zhaohui, GUO Juncen, ZHANG Hu<sup>†</sup>, XIE Yongfang, ZHONG Yuze

(School of Automation, Central South University, Changsha 410083, China)

**Abstract:** To solve the problem that froth image is difficult to be accurately segmented due to its high complexity, this paper proposes a new I-Attention U-Net network for froth image segmentation. The algorithm uses the U-Net network as the backbone network and uses the Inception module to replace the first convolutional pooling layer so as to extract the multi-scale and multi-level shallow feature information of the froth image. A Pyramid pooling module is introduced to improve the segmentation effect by summing the feature maps of different scales. And the self-attention gating unit is improved to make it more suitable for the segmentation of flotation froth images, which strengthens the importance of deep features and performs reinforcement learning on froth edges of different sizes. The research results show that the Jaccard coefficient of the algorithm proposed in this paper is 91.73% and the Dice coefficient is 95.66%. Compared with the results of other similar segmentation algorithms, the Jaccard coefficient and Dice coefficient are

\* 收稿日期:2022-03-15

基金项目:国家自然科学基金资助项目(62171476), National Natural Science Foundation of China (62171476)

作者简介:唐朝晖(1965—),男,湖南长沙人,中南大学教授,博士生导师

<sup>†</sup> 通信联系人, E-mail: zhanghu@csu.edu.cn

increased by 1.59% and 0.88%, respectively. The model can better segment the zinc flotation froth image, and solve the problems of under-segmentation and over-segmentation, which is a good way for the follow-up. In addition, the method has less detection time and fewer model parameters and also has the ability to be deployed in industrial field computers, which has certain practical application value.

**Key words:** froth flotation; froth image segmentation; U-Net; Inception module; enhanced attention mechanism

选矿是矿产资源加工中必不可少的一个重要环节,泡沫浮选是应用最为广泛的一种选矿方法,当今世界上90%的铅、锌、锑等金属都通过此方法被分离出来<sup>[1]</sup>.泡沫浮选是一种以表面化学为基础,利用矿物颗粒表面亲疏水性的差异来有效分离不同矿物的选矿方法<sup>[2]</sup>,浮选泡沫的表面视觉特征可以作为浮选工况和相关工艺指标的直接指示器<sup>[3]</sup>.目前,操作人员主要通过浮选现场观察浮选槽表面泡沫状态来判断有色金属浮选过程中泡沫矿物含量以及浮选生产运行状态<sup>[4]</sup>.但由于工业现场矿源复杂多变,这种人工操作方式存在很大的主观性和不确定性,无法保证浮选过程的长期稳定运行,造成矿物的浪费<sup>[5]</sup>.很多文章都指出可以通过观察浮选槽表面视觉特征,调整浮选槽液位、药剂量、鼓风量等操作参数来控制浮选过程<sup>[6-7]</sup>.因此在矿物浮选过程中引入机器视觉技术,准确客观测量泡沫参数以及量化描述生产状态,优化浮选过程操作,对工厂效率以及矿物回收率的提高具有重要意义<sup>[8]</sup>.

研究表明,泡沫尺寸大小分布、泡沫形态、颜色等静态纹理特征与动态纹理特征在工业过程判断泡沫浮选状态中发挥着重要作用<sup>[9-10]</sup>.通过分割泡沫图像,获得准确的泡沫尺寸分布、形态等特征参数,能更好地表征泡沫表面,进而指导浮选过程.但浮选泡沫图像中存在泡沫结构复杂、轮廓不清晰、泡沫之间粘连严重等问题,给实现泡沫图像分割增加了一定难度<sup>[11]</sup>.在过去的研究里,研究人员提出了多种泡沫图像分割算法,这些算法可以大致分为边缘检测法、分水岭算法<sup>[12-14]</sup>和阈值分割法<sup>[15]</sup>等.廖一鹏等人<sup>[16]</sup>提出了一种将多尺度边缘增强及自适应谷底边界检测相结合的气泡分割方法,有效增强边缘和抑制噪声.Zhang等人<sup>[13]</sup>利用每个泡沫上存在的光照亮点,提出基于光照模型的标记分水岭方法,从而有效识

别锌浮选泡沫图像中单个气泡的边界.Zhang等人<sup>[14]</sup>在此基础上提出了一种具有最优标记的分水岭分割算法来解决欠分割问题.肖玲玲<sup>[17]</sup>等人借助机器视觉和DSP技术,设计了一种改进的全局阈值分割的图像处理算法.然而,这些方法对先验知识过多依赖,使得泡沫图像的分割具有一定的局限性.

近年来,基于深度学习的方法在图像分割领域取得了较大进展.Shelhamer等人<sup>[18]</sup>突破了传统图像分割算法,使用全卷积网络(Fully Convolution Networks, FCN)对图像进行像素级分类,实现图像分割.Ronneberger等人<sup>[19]</sup>提出的对称U形结构网络(U-Net)以及Oktay<sup>[20]</sup>等人提出的Attention U-Net网络,通过跳跃连接将网络抽象的深层特征和蕴含上下文信息的浅层特征进行融合,强化网络对不同尺度的特征关注,减少浅层图像特征丢失,进而提高了分割的准确率.这些算法应用在医学图像分割上都取得了很好的效果,是目前基于深度学习图像分割算法的基础.在泡沫浮选方面,Liu等人<sup>[21]</sup>也提出了一种多尺度跳跃特征融合全连接卷积网络算法(multi-scale jump feature fusion fully connected convolutional network, MsJ),通过加入跳跃连接方式和残差块加强图像细节,对铜浮选泡沫图像进行精确分割.

对于锌浮选过程,一张泡沫图像中气泡大小差异较大,容易造成分割不准确的问题;泡沫表面受自然光照、图像采集系统照明、现场光照等多种光照的影响,存在色偏以及大量的阴影等问题.虽然上述深度学习算法可以应用于锌浮选泡沫图像分割,但仍然无法准确清晰地将泡沫边界识别出来,使得泡沫图像分割存在过分割或者欠分割的问题.一张泡沫图像由大量大小不一的气泡构成,即便是少量的误分割问题也将导致泡沫图像尺寸大小分布产生很大

的变化,对后续特征提取、工况识别等产生较大影响.

本文针对锌浮选泡沫图像的特点和分割的难点,对深度学习网络的性能进行分析,利用深度学习的优势,基于U-Net网络架构设计出一种新的算法用于泡沫图像分割,减少泡沫边界信息丢失,提高泡沫分割算法准确率.本文的主要贡献如下:

浅层特征包含更多细节、纹理、位置等信息,对浅层特征的提取有利于处理图像中的单个泡沫,因此,本文将Inception<sup>[22]</sup>模块与批量归一化(Batch Normalization, BN)相结合用于第一层特征提取.同时Inception层增加网络的宽度,不同尺寸的卷积核使得特征图获得不同大小的感受野,加强了网络对泡沫图像中不同大小泡沫边界的提取能力.

改进注意力门控机制,加强对浅层特征的关注与提取,强化模型对不同尺寸气泡的学习能力.将该机制加在每一个上采样部分,增强网络的上采样能力.

通过对构建的泡沫图像数据集的评估,证明了本文所提出的改进I-Attention U-Net算法与当前常用分割算法(FCN-8s、U-Net、Attention U-Net和MsJ)

相比具有更好的表现,得到了更好的分割效果.模型在Jaccard系数、Dice系数和像素准确率上均有提高.

## 1 网络结构与算法原理

### 1.1 网络结构

图1为网络整体框架图.改进的I-Attention U-Net网络采用编码-解码的U形对称结构,网络包括依次连接的输入层、编码器模块、金字塔池化模块、解码器模块和输出层.输入泡沫图像,编码器部分采用4层卷积池化模块,逐步提取泡沫图像特征信息,每次下采样特征通道的数量加倍,特征图尺寸减半,第一层卷积池化模块改用Inception+BN层,扩展网络的宽度与深度,使用 $1\times 1$ ,  $3\times 3$ ,  $5\times 5$ 不同尺寸的卷积核,获取不同的感受野,丰富该层提取的特征信息.再经过3层普通卷积池化下采样后,通过在U-Net网络的编码块末端设置的金字塔池化模块,结合上下文信息,完成对泡沫图像的下采样.上采样部分经过反卷积池化操作结合下采样各层信息和上采样的输入信息还原细节信息以及图像精度,但在最后一层解码块使用Inception+BN层,多尺度还原

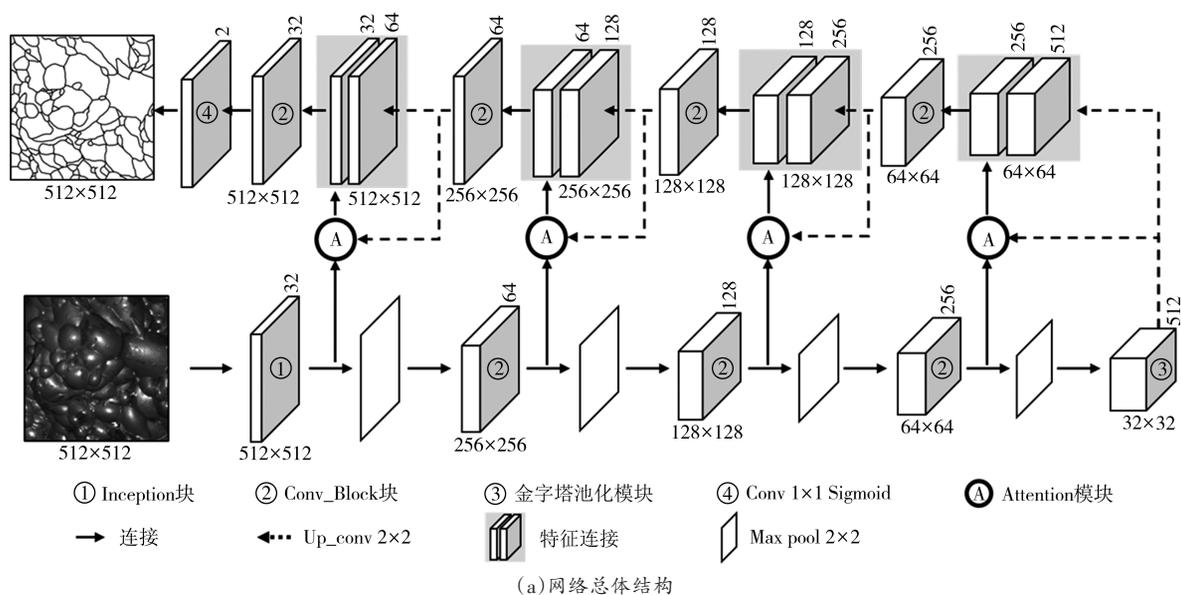


图1 本文提出的I-Attention U-Net网络结构

Fig. 1 The proposed I-Attention U-Net network structure

细节信息.同时在 U-Net 编解码层之间的跳跃连接处引入改进的增强注意力门控机制,帮助解码器更好地修复目标的细节.最后通过  $1 \times 1$  的卷积和 Sigmoid 激活函数,得到与输入泡沫图像相同分辨率的泡沫分割图片.其中编解码器各有 3 层普通卷积池化,称为 Conv\_Block 子模块,每个子模块包含 2 个  $3 \times 3$  卷积层、BN 层和非线性激活函数 ReLU 层.经过两次  $3 \times 3$  的卷积操作,增加网络中每一个像素的感受野,使得特征图中每一个像素可以代表原图中的一块区域.BN 的目的是加速网络收敛.

### 1.2 Inception 模块

2015 年, Szegedy 等人<sup>[22]</sup>在 GoogLeNet 模型中第一次提出 Inception 结构. Inception 块采用不同大小的卷积核,横向增加网络结构,使得特征图中的每一个像素可以获得不同大小的感受野,最后将其拼接在一起对不同尺度特征进行有效融合,实现多尺度读取输入图像特征向量<sup>[23]</sup>.经典的 U-Net 网络编解码部分仅包括  $3 \times 3$  的卷积层和  $2 \times 2$  的池化层,卷积操作单一,往往对图像不同尺度特征信息的学习不全面,同时限制网络的深度和宽度.

由于浅层特征图分辨率更高,每个像素对应原图的感受野小,包含更多位置、细节、纹理信息,对浅层特征的关注将更加有利于对浮选泡沫图像中的单个泡沫的分割,本文采用 Inception 架构取代经典的 U-Net 网络编解码部分第一卷积池化层中的单一的卷积操作,同时对 Inception-V1 块进行改进,即在  $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$  卷积层后接入 BN 层.采用的 Inception 模块含有三条卷积支路,网络中每一层都能学习到“稀疏”( $3 \times 3$ ,  $5 \times 5$ )或“不稀疏”( $1 \times 1$ )的特征,因此该

Inception 模块具有三个不同尺度的特征提取能力和融合能力,可以弥补 U-Net 模型单一尺度卷积操作的局限性,从而提高模型对泡沫边界的分割能力.编解码部分均采用 Inception 模块,保证图像分割的准确性. Inception 模块如图 2 所示.

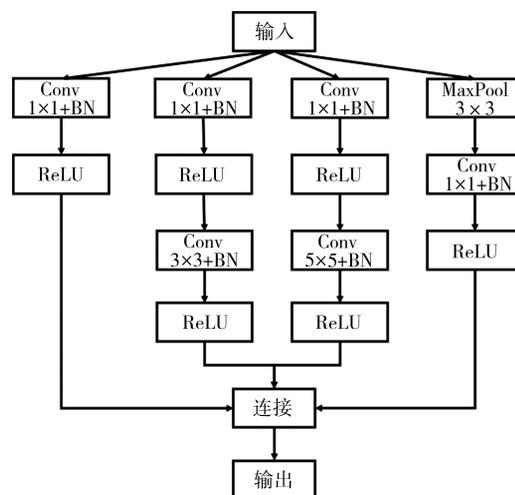


图 2 Inception 网络结构

Fig. 2 Inception network structure

### 1.3 注意力门控单元

注意力机制 (Attention Mechanism) 为了加强重要特征信息,会选择对不同的像素分配不同的权重.将注意力机制应用于 U-Net 分割网络中,可以更好地提升对目标区域的关注度,更好地抑制背景<sup>[24]</sup>.本文在 U-Net 网络编解码层间的跳跃连接处加入改进的增强注意力门控机制,以深层特征作为门控信号,对浅层特征进行再一次加强后与深层特征结合,增强用于精确分割的浅层信息.改进的增强注意力模块如图 3 所示.

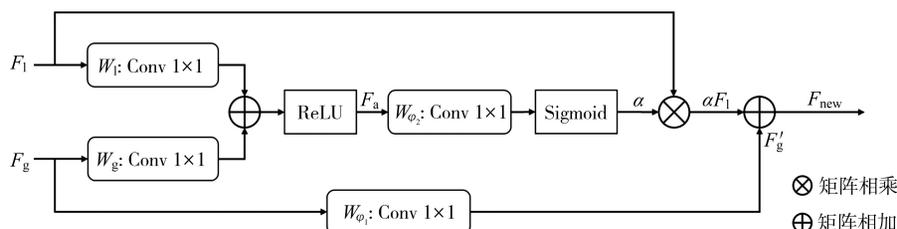


图 3 改进的注意力模块

Fig. 3 The improved attention module

浅层特征  $F_1$  作为特征输入,深度特征  $F_g$  作为门控信号,分别经过核为 1 的  $W_1$  和  $W_g$  卷积,使两个特征的通道数相同,并逐元素相加.经过 ReLU 激活函数增加非线性能力,通过  $1 \times 1$  卷积层  $W_{\varphi_2}$  和 Sigmoid 激活函数,得到与输入特征图尺寸相同、通道数为 1

的注意力权重图  $\alpha$ ,使其与特征图  $F_1$  相乘,实现自注意力机制.深层特征  $F_g$  通过  $1 \times 1$  卷积层  $W_{\varphi_1}$  后得到与  $F_1$  相同通道的新特征图  $F'_g$ ,最终将深度特征图  $F'_g$  经过与  $\alpha F_1$  逐点相加得到新的特征图  $F_{new}$ ,强化深度特征,进而实现多层次特征的融合.计算方法如下:

$$F_a = \sigma_1(W_1 \cdot F_1 + W_g \cdot F_g + b_g) \quad (1)$$

$$F_g' = W_{\varphi 1} \cdot F_g + b_{\varphi 1} \quad (2)$$

$$\alpha = \sigma_2(W_{\varphi 2} \cdot F_a + b_{\varphi 2}) \quad (3)$$

$$F_{\text{new}} = (\alpha \otimes F_1) \oplus F_g' \quad (4)$$

式中： $\alpha$ 为注意力权重； $\sigma_1$ 是ReLU函数； $\sigma_2$ 是Sigmoid函数； $W_1$ 、 $W_g$ 、 $W_{\varphi 1}$ 、 $W_{\varphi 2}$ 为线性变换参数； $b_g$ 、 $b_{\varphi 1}$ 、 $b_{\varphi 2}$ 都是对应卷积的偏置项。

#### 1.4 金字塔池化模块

PSPNet(Pyramid Scene Parseing Network)对场景解析是基于语义分割的,赋予图像中每个像素一个类别标签<sup>[25]</sup>。其中的金字塔池化模块(Pyramid Pooling Module, PPM)使用不同尺度的池化核对特征图进行池化,可以更好地融合局部和全局信息<sup>[26]</sup>。为了更好感知锌矿浮选泡沫图像中包含的丰富细节信息,模型使用多尺度金字塔池化模块获取泡沫边界信息。池化参数分别为(1,1)、(2,2)、(4,4)和(8,8),金字塔池化模块对这4种尺度的特征图进行融合,获得最终的金字塔池化全局特性。

## 2 泡沫图像分割算法设计

本文泡沫图像分割模型训练与测试流程如图4所示。首先,通过工业相机自主采集泡沫图像,得到原始泡沫图像集,同时对原始泡沫图像中的泡沫边界分别进行像素级标注,得到人工泡沫分割图像,共同建立泡沫图像数据集。其次,对工业相机所获得的泡沫图像样本和对应的人工手动做出的分割图像一起进行旋转、翻转,数据增强处理得到样本图像,将所有样本图像按比例划分为训练集、验证集、测试

集。接下来,构建深度I-Attention U-Net卷积神经网络分割模型,调整泡沫图像分割网络的参数,并将网络中的超参数进行优化,将训练集图片送入构建的分割模型进行训练。最后,利用所述改进的U-Net神经网络模型对测试集中的泡沫图像进行识别分割,得到网络最后的分割结果,验证泡沫图像分割在本文网络中的有效性。

#### 2.1 建立泡沫图像数据集

本文所用的数据均来自中国广东某铅锌矿选矿厂工业现场,图像均采集视频中截取。每隔3h选取1段视频,选择8段视频(总计24h)。为保证每一张图片都没有重叠部分、相互独立,从捕获的视频中每一秒采集一张泡沫图像,每段视频(44s)可以采集到44张图片,一共352张分辨率为692×518的泡沫图像。将每张泡沫图像裁剪为512×512大小的图像,每一张泡沫图像的人工标签(Ground Truth, GT)全部由经验丰富的专家手动标记。对获得的图像以及相应的标签图像用于训练,再对原始数据采用水平翻转、垂直翻转以及90°、180°、270°旋转的方法进行数据增强,使得模型拥有更好的泛化能力。

#### 2.2 构建加权损失函数

本文构建了以Dice损失函数和二分类交叉熵值(Binary Cross Entropy, BCE)损失函数为基础的加权损失函数,表达式如下:

$$\text{DiceLoss} = 1 - \frac{2|X \cap Y|}{|X| + |Y|} \quad (5)$$

$$\text{BCELoss} = \sum_m [Y \log X + (1 - Y) \log(1 - X)] \quad (6)$$

$$\text{Loss} = 1/3 \times \text{BCELoss} + 2/3 \times \text{DiceLoss} \quad (7)$$

式中： $X$ 代表预测分割结果； $Y$ 代表实际的标签值。

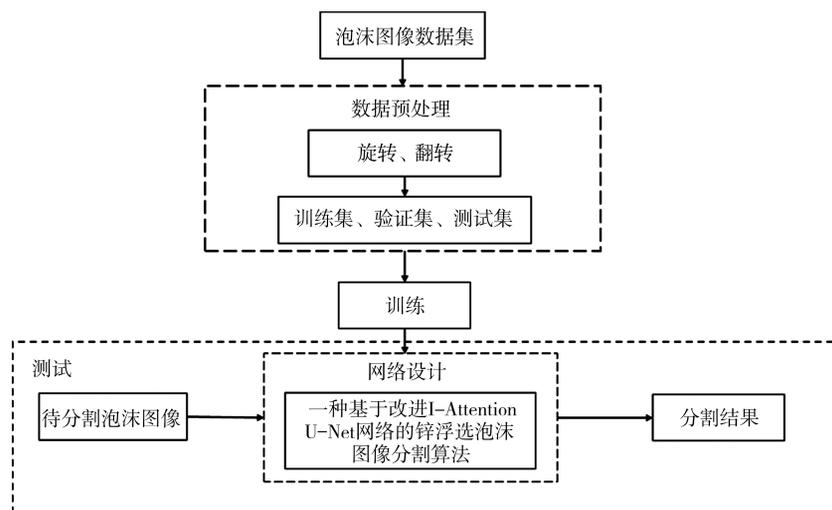


图4 锌浮选泡沫图像分割模型训练与测试流程框图

Fig. 4 The training and testing flow chart of the image segmentation model of zinc flotation froth

$Y \log X$  部分对应泡沫边界区域,  $(1 - Y) \log(1 - X)$  部分对应泡沫表面区域. 将这两种方法结合在一起可以在一定程度上减少损失, 同时受益于 BCE 的稳定性, 能够解决分割精度低、网络不易收敛的问题, 使得网络具有分割精度高、收敛快的优点.

### 2.3 训练过程

实验计算机为 Windows 10 系统, CPU 为 Inter i7-11700K, 以 Python 作为开发语言, 使用 PyCharm 2020 x64 进行模型网络训练和测试, 并利用 NVIDIA RTX3080 显卡加速模型网络的运算. 在以上的实验环境下对样本进行训练, 随机将 2 112 对带有 GT 的泡沫图像按照 7:2:1 的比例分为训练集、验证集和测试集, 其中训练集为 1 478 对样本, 验证集为 422 对样本, 测试集为 212 对样本.

网络训练过程中, 通过 Adam 优化器来自动更新迭代网络内部参数, 网络训练 epochs 次数为 400 次, 学习率为 0.000 1, batch size 为 16, 损失函数为构建的加权损失函数, 利用 Early Stopping 技术抑制训练过程中过拟合问题.

训练集与验证集损失函数值与准确率变化曲线如图 5 所示, 横坐标表示迭代次数, 纵坐标表示损失值. 由图 5 可知, 在迭代次数达到 300 次时, 损失函数值已接近稳定, 且基本达到最低值, 网络收敛且验证准确度高.

## 3 实验结果与分析

本节将所提算法在实际工业现场采集到的数据上进行实验验证, 并且将算法中不同的模块性能进行验证以及不同网络模型之间进行对比实验, 从而更好体现所提算法的性能.

### 3.1 算法评价指标

为对图像分割性能进行评估, 将分割结果与人工标注结果对比, 基于像素测度计算评估系数, 以综合评判性能优劣. 本文采用 Jaccard 系数、区域相似度系数 (Dice coefficient) 和像素准确率 (Pixel Accuracy, PA) 3 个指标对泡沫分割结果进行定量分析, Jaccard、Dice 和 PA 计算公式如下:

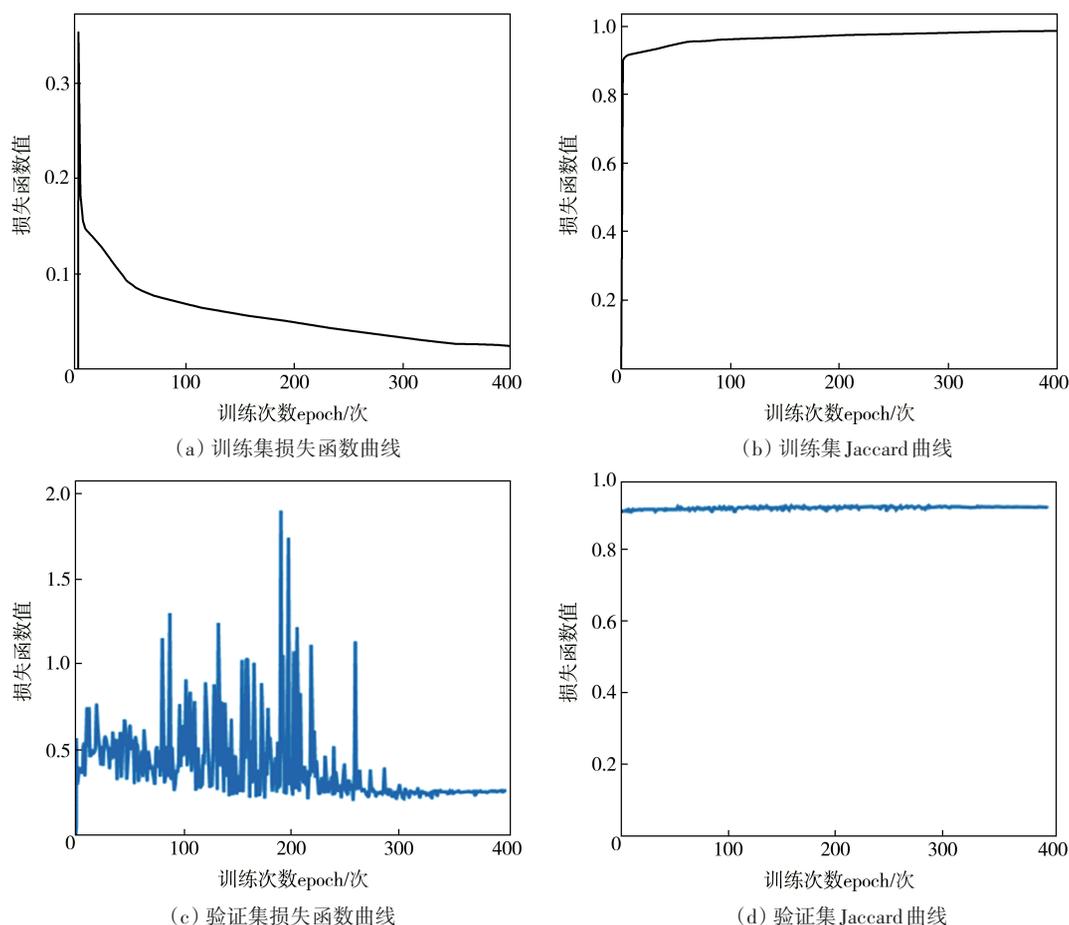


图 5 训练集和验证集的损失值曲线(左)与 Jaccard 系数曲线(右)

Fig. 5 Curves of loss value(left) and Jaccard coefficient (right) in training datasets and validation datasets

$$\text{Jaccard} = \frac{|V_{\text{seg}} \cap V_{\text{gt}}|}{|V_{\text{seg}} \cup V_{\text{gt}}|} = \frac{\text{TP}}{\text{FP} + \text{TP} + \text{FN}} \quad (8)$$

$$\text{Dice} = 2 \frac{|V_{\text{seg}} \cap V_{\text{gt}}|}{|V_{\text{seg}}| + |V_{\text{gt}}|} = \frac{2\text{TP}}{\text{FP} + 2\text{TP} + \text{FN}} \quad (9)$$

$$\text{PA} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (10)$$

式中:  $V_{\text{seg}}$  代表预测分割结果;  $V_{\text{gt}}$  代表实际的标签值; TP 表示泡沫边界像素类被正确分类样本面积; TN 表示背景像素类被正确分类样本面积; FP 表示背景像素类被错分为泡沫边界像素类样本面积; FN 表示泡沫边界像素类被错分为背景像素类样本面积. Jaccard 系数常用于比较有限样本集之间的相似性与差异性, Jaccard 系数越大, 样本相似度越高. Dice 系数同样用于评估两者的相似性, Dice 系数越大, 相似性就越高. PA 系数对应于准确率, PA 系数越大, 准确率就越高.

### 3.2 不同网络模块性能对比

#### 3.2.1 改进的增强注意力机制模块有效性验证

为了验证注意力机制在泡沫图像分割上的效果, 以及对比改进注意力机制的作用, 本文基于 U-Net 网络设计了两个对比实验, 关键评价指标结果如表 1 所示.

表 1 评价指标结果

Tab.1 The results of evaluation indicators

算法	Jaccard/%
U-Net	90.29
Attention U-Net	90.63
改进的 Attention U-Net	90.82

从表 1 可知, 没有加入任何注意力机制的 U-Net 网络其 Jaccard 系数为 90.29%, 加入了注意力机制的模型其 Jaccard 系数为 90.63%, 验证了注意力机制的效果. 而加入本文提出的改进注意力机制的模型其 Jaccard 系数为 90.82%, 因此, 本文提出的改进注意力机制模块可有效提高 Attention U-Net 模型的性能.

#### 3.2.2 Inception 模块不同位置性能对比

以 Attention U-Net 网络为基础, 引入不同的 Inception 模块. 本文采用了 Inception v1+BN 层模块, 与 Inception v1 和 Inception v2 模块进行对比实验, 结果如表 2 所示. 实验结果证明: 在 Inception 模块中引入 BN 层不仅可以加速模型训练, 还可以使网络学习更加稳定, 可提升模型精度.

为证明在本文构建的网络中, Inception 模块代

表 2 Inception 模块对比实验结果

Tab.2 Comparative experimental results under different inception modules

模块	Jaccard/%
Inception v1	90.66
Inception v2	90.02
本文的 Inception 模块	90.88

替第一个卷积池化模块的有效性, 本文进行多组 Inception 模块位置实验. 以本文网络架构为基础, 尝试用 Inception 模块替换不同位置的卷积池化模块, 得到了 5 个不同的网络. 以下实验均采用相同数据集, 使用相同的损失函数和训练策略, 并保证相关参数一致. 其结果如表 3 所示.

表 3 Inception 模块不同位置测试结果

Tab.3 Inception module test results at different locations

位置	Jaccard/%
第二卷积池化模块	91.63
第三卷积池化模块	90.51
第四卷积池化模块	90.16
第一和第二卷积池化模块	91.58
本文替换的位置 (第一卷积池化模块)	91.73

由表 3 可知, 使用 Inception 模块代替本文所构建网络的第一卷积池化模块, 使得测试集上的 Jaccard 指标达到最大, 为 91.73%, 其他位置以及多个位置包含 Inception 模块网络的 Jaccard 系数均低于该数值, 由此证明本文所构建的网络中 Inception 模块代替第一卷积池化模块的有效性.

### 3.3 消融实验

为验证本文所构建的网络中各个模块的有效性, 进行消融实验, 训练了 5 个不同的网络用于对比分析. 第 1 个模型为 Attention U-Net 模型; 模型 2 在模型 1 的基础上, 引入 Inception 块替换 Attention U-Net 网络编解码第一层的卷积块, 实现多尺度特征提取; 第 3 个模型为改进的 Attention U-Net 模型, 使用改进注意力门控单元替换第 1 个模型的注意力机制; 第 4 个模型将 Inception 块与改进注意力门控单元一同加入 U-Net 网络; 第 5 个模型在第 4 个模型的基础上引入金字塔池化层, 即本文所提出的模型. 分别训练以上模型, 其结果如表 4 所示.

由表 4 可知, 当引入不同模块时, 模型在 Jaccard 系数、Dice 系数和 PA 系数上均得到了不同程度的提升. Attention U-Net 网络分割交并比系数为 90.63%,

表 4 消融实验测试结果

Tab.4 Test results of ablation experiment

编号	Jaccard/%	Dice/%	PA/%
1	90.63	95.16	91.70
2	90.88	95.30	91.94
3	90.82	95.23	91.83
4	91.44	95.50	92.15
5	91.73	95.66	92.39

将 Attention U-Net 网络编解码器中的第一层传统卷积替换为 Inception, 网络的分割交并比系数较 Attention U-Net 网络提升了 0.25%, 说明 Inception 块能够扩大感受野, 提取更多泡沫边界细节特征信息. 使用改进的增强注意力机制后网络的分割交并比系数较 Attention U-Net 网络提高了 0.19%, 说明改进增强注意力机制的使用使得网络在训练时偏向于学习泡沫边界特征, 从而增强了网络对泡沫边界特征的表达能力. 通过在编码器最后一层加入金字塔池化模块, 提取具有上下文关联的泡沫特征, 有助于解码器上采样时多尺度恢复泡沫边界信息, 网络的分割交并

比系数提高了 1.10%.

### 3.4 不同分割算法结果分析

为综合评价不同分割算法性能, 引入图像质量评估指标均方误差 (Mean squared error, MSE)、峰值信噪比 (Peak signal-to-noise ratio, PSNR), 计算公式如下:

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} \|X(i, j) - Y(i, j)\|^2 \quad (11)$$

$$PSNR = 10 \lg \frac{\text{Max}_Y^2}{MSE} \quad (12)$$

式中:  $X$ 、 $Y$  分别表示模型输出的预测图与手工标记的分割图像;  $m$ 、 $n$  分别表示图像的宽和高;  $\text{Max}_Y$  表示分割图像像素点最大像素值 (即 255). 在进行图像质量评估时, MSE 越小, 则模型输出的分割图像与手工标记的分割图像越接近; PSNR 数值越大, 表明模型输出的图像质量越高.

本文分别对 FCN-8s、U-Net、Attention U-Net、MsJ 和改进 I-Attention U-Net 算法五种网络模型的分割性能进行实验对比, 评估指标对比如表 5 所示, 不同模型的输出结果如图 6 所示.

表 5 不同模型测试结果及其性能指标

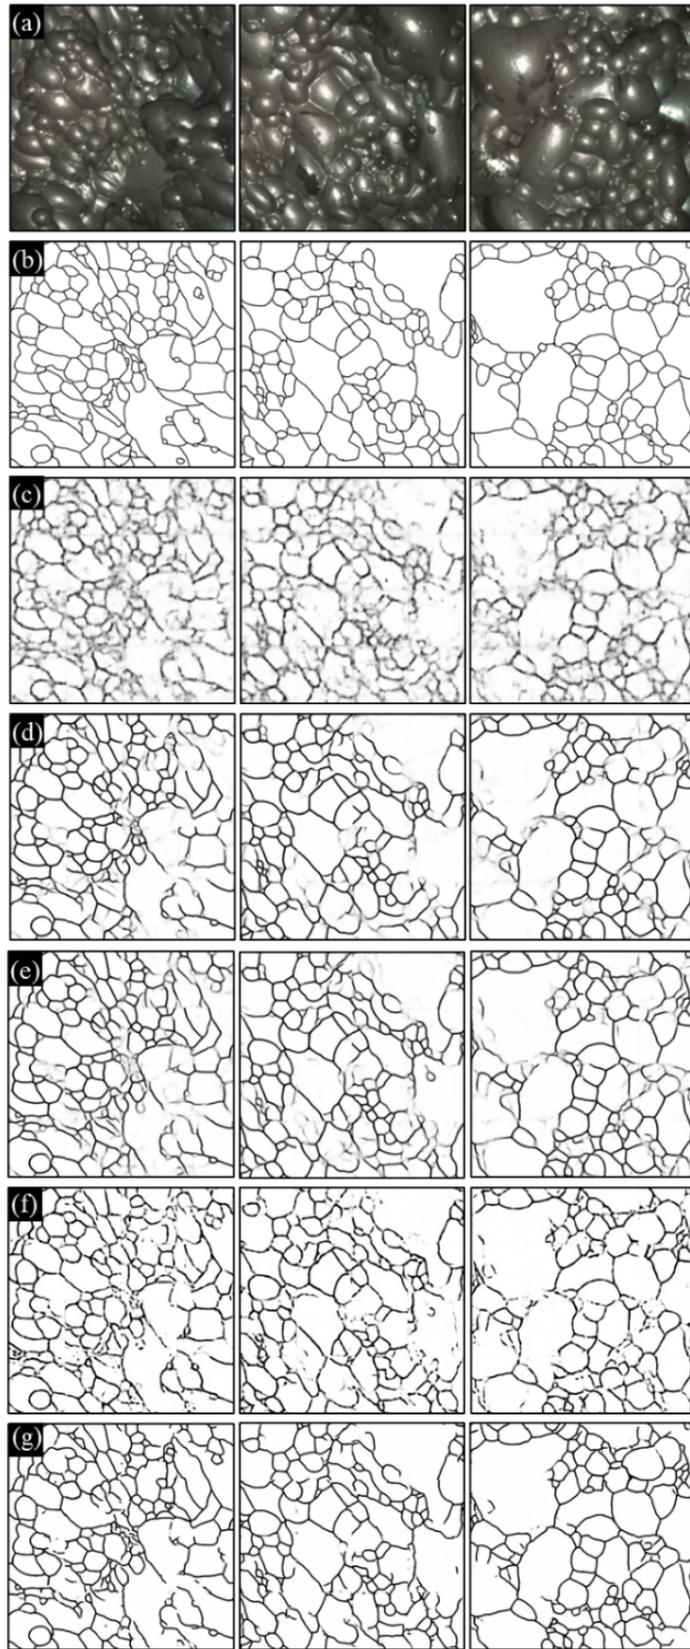
Tab.5 Test results of different segmentation algorithms

算法	Jaccard/%	Dice/%	PA/%	MSE	PSNR	参数量/million	训练时间/ min	检测时间/s
FCN-8s <sup>[18]</sup>	83.28	90.80	84.78	1 818.20	15.715 0	18.64	63±3	3.25±0.25
U-Net <sup>[19]</sup>	90.29	94.86	91.23	1 017.93	18.287 0	7.85	245±5	1.2±0.25
Attention U-Net <sup>[20]</sup>	90.63	95.16	91.70	906.59	18.810 0	8.12	310±2	1.5±0.25
MsJ <sup>[21]</sup>	90.14	94.78	90.95	562.16	20.906 6	11.91	600±5	2.78±0.25
改进 I-Attention U-Net	91.73	95.66	92.39	423.41	22.701 7	5.07	410±4	0.73±0.25

从表 5 可知, 相比于其他算法, 本文提出的改进 I-Attention U-Net 算法模型在锌浮选泡沫数据集中的表现最好, 其 Jaccard 系数和 PA 分别为 91.73% 和 92.39%. 相比于 FCN-8s、U-Net、Attention U-Net 以及 MsJ 算法, 本文提出的算法模型在准确率和图像质量方面都得到了提升. 此外, 模型的参数量和计算速度也是衡量模型性能的重要指标, 参数量越小越容易部署在微型计算机上, 而较短的检测时间将大大提高系统的实时性. 对比不同模型的参数量、训练时间以及检测时间, 如表 5 所示. 其中训练时间是指当验证集损失函数达到稳定时, 训练模型所用的时间; 检测时间是指模型处理一张泡沫图像所需时间. 训练时间和检测时间与实验计算机硬件有直接关系, 本文实验所用计算机已在 2.3 节详细说明. 将上述 5 种模型经过多轮训练后, 取其均值得到训练时间以及

检测时间. 从表 5 可知, FCN-8s 模型训练时间最短, 是因为当该模型训练迭代至第 40 次时产生过拟合, 但是单次迭代时间最长. U-Net 以及 Attention U-Net 模型在第 230 次迭代左右时达到最优, 但从图 6 可知分割效果远不如本文所提出的算法. MsJ 参数量大, 训练时间长, 在第 350 次迭代时达到最优. 本文所提出的模型相较于其他模型, 训练时间略长, 但是检测时间短, 参数量小, 具备部署工业现场计算机的能力.

本文提出的算法与其他算法的泡沫图像分割结果如图 6 所示. 为了有效对比不同算法在泡沫图像上的表现, 我们选用了 3 张泡沫大小分布差别较大的泡沫图像作为结果展示. (a) 为从现场采集到的泡沫图像, (b) 为人工标记的分割结果, (c) 到 (g) 分别为 FCN-8s、U-Net、Attention U-Net、MsJ 和本文提出



(a) 原始泡沫图像; (b) 人工GT分割结果; (c) FCN-8s网络的分割结果; (d) U-Net网络的分割结果;  
(e) Attention U-Net网络的分割结果; (f) MsJ网络的分割结果; (g) 本文网络的分割结果

图6 不同分割算法的分割结果

Fig.6 Segmentation results of different segmentation algorithms

算法的分割结果.FCN-8s网络对于明显的泡沫边界可以做到有效分割,但是线条粗糙;对于小泡沫和不明显的泡沫边界无法有效分割.FCN-8s难以准确地分割出泡沫的边界,泡沫边界模糊且不连续,整体欠分割严重.U-Net网络使得分割结果的泡沫边界较FCN-8s更清晰,分割结果的图像更符合泡沫图像分割的结果,线条之间的连贯性更好,清晰度更高.但是对于一些强粘连泡沫之间的边界还是无法有效识别,图6(d)中还是存在很多不清晰的线条.Attention U-Net网络加入了注意力机制,会强化学习每一层特征,也就使得分割结果中的小泡沫和强链接泡沫之间的边界更加清晰.MsJ网络没有使用注意力机制,而是通过卷积块和金字塔采样保留图像不同层次特征,使得分割结果虽然识别了不同尺寸的泡沫边界,但是卷积块的存在弱化了强链接泡沫之间的边界,分割结果就会忽略这些较弱的边界.本文算法通过引入Inception+批量归一化层和金字塔池化层,并增强注意力模块后,有效减少了泡沫边界细节特征信息丢失的现象,泡沫界限清晰,在粘连泡沫处的边界也能识别并画出来,泡沫分割的准确率较高,且分割边界更加精细.综上,本文算法对结构纹理复杂的泡沫图像分割效果较好,这充分证明了本文算法的有效性.

#### 4 结论

1) 在网络中通过Inception块中多卷积核组合的方法来扩大感受野,在保持空间信息的情况下,获取多尺度浅层特征信息.引入改进的增强注意力门控机制,强化学习气泡边界特征.通过Inception块、改进增强注意力机制以及金字塔池化模块的组合,泡沫边界分割得更加清晰、连贯,提高了分割的准确性.Dice系数和像素准确率分别达到了95.66%、92.39%.从分割图像的效果来看,有效弥补了传统的泡沫图像分割算法对单个泡沫分割不彻底、不精细的缺陷.

2) 在采集到的工业泡沫图像数据集上进行实验验证,本文提出的算法对于泡沫图像中泡沫的边界的自动分割取得了较好的效果.相比于其他分割算法,本文提出的算法参数量小,检测时间短,更加具备可以部署在工业现场中小型计算机的能力,具备一定的实际意义和实用价值.

3) 精确的泡沫测量对于泡沫浮选工况感知与优化控制都具有十分重要的意义.泡沫图像分割是

后续泡沫特征提取等操作的基础,在未来,将进一步探索泡沫图像特征与锌矿泡沫浮选品位之间的模型关系.

#### 参考文献

- [1] 刘尚争,谭帅.矿物浮选泡沫图像处理技术的发展:《矿物浮选泡沫图像处理与过程监测技术》[J].矿业研究与开发,2020,40(1):166.  
LIU S Z, TAN S. Development of mineral flotation foam image processing technology—"Mineral flotation foam image processing and process monitoring technology"[J]. Mining Research and Development, 2020, 40(1): 166. (in Chinese)
- [2] NAYAK A, JENA M S, MANDRE N R. Beneficiation of lead-zinc ores—A review[J]. Mineral Processing and Extractive Metallurgy Review, 2022, 43(5): 564–583.
- [3] 桂卫华,阳春华,徐德刚,等.基于机器视觉的矿物浮选过程监控技术研究进展[J].自动化学报,2013,39(11):1879–1888.  
GUI W H, YANG C H, XU D G, et al. Machine-vision-based online measuring and controlling technologies for mineral flotation—A review [J]. Acta Automatica Sinica, 2013, 39(11): 1879–1888. (in Chinese)
- [4] 梁秀满,田童,刘文涛,等.基于多颜色分量CLBP提取的浮选泡沫状态识别[J].中国矿业,2020,29(12):183–187.  
LIANG X M, TIAN T, LIU W T, et al. Flotation bubble state recognition based on multi-color component CLBP extraction [J]. China Mining Magazine, 2020, 29(12): 183–187. (in Chinese)
- [5] 郭建平.基于向量形态学重构的铜浮选泡沫图像分割方法研究及应用[D].长沙:中南大学,2012:8–9.  
GUO J P. Research and application of copper flotation foam image segmentation method based on vector morphology reconstruction [D]. Changsha: Central South University, 2012: 8–9. (in Chinese)
- [6] 谭佳珉,梁龙,彭耀丽,等.煤泥浮选过程中粒度对泡沫性质的影响[J].中国矿业大学学报,2019,48(1):195–203.  
TAN J K, LIANG L, PENG Y L, et al. Effect of particle size on the froth property in coal flotation[J]. Journal of China University of Mining & Technology, 2019, 48(1): 195–203. (in Chinese)
- [7] 谭利平,张泽琳,赵伟,等.基于机器视觉的矿物浮选泡沫监控研究进展[J].矿业研究与开发,2020,40(11):123–130.  
TAN L P, ZHANG Z L, ZHAO W, et al. Research status of mineral flotation foam monitoring based on machine vision [J]. Mining Research and Development, 2020, 40(11): 123–130. (in Chinese)
- [8] LIU J P, GUI W H, TANG Z H, et al. Machine vision based production condition classification and recognition for mineral flotation process monitoring [J]. International Journal of Computational Intelligence Systems, 2013, 6(5): 969–986.
- [9] 朱建勇,黄鑫,杨辉,等.基于稀疏化神经网络的浮选泡沫图像

- 特征选择[J]. 控制与决策, 2021, 36(7): 1627-1636.
- ZHU J Y, HUANG X, YANG H, et al. Selection method for froth image characters based on sparse neural network[J]. Control and Decision, 2021, 36(7): 1627-1636. (in Chinese)
- [10] AI M X, XIE Y F, XIE S W, et al. Shape-weighted bubble size distribution based reagent predictive control for the antimony flotation process[J]. Chemometrics and Intelligent Laboratory Systems, 2019, 192: 103821.
- [11] 田慕玲. 基于二维直方图加权的模糊C均值聚类的煤泥浮选泡沫图像的分割[J]. 电子技术与软件工程, 2015(9): 82-84.
- TIAN M L. Froth image segmentation of slime flotation based on fuzzy C-means clustering weighted by two-dimensional histogram[J]. Electronic Technology & Software Engineering, 2015(9): 82-84. (in Chinese)
- [12] 宁哲. 一种铜钼矿浮选泡沫图像分割算法[J]. 电脑知识与技术, 2014, 10(12): 2875-2877.
- NING Z. A segmentation algorithm of copper-molybdenum mine flotation froth image[J]. Computer Knowledge and Technology, 2014, 10(12): 2875-2877. (in Chinese)
- [13] ZHANG J, TANG Z H, AI M X, et al. Nonlinear modeling of the relationship between reagent dosage and flotation froth surface image by Hammerstein-Wiener model[J]. Minerals Engineering, 2018, 120: 19-28.
- [14] ZHANG H, TANG Z H, XIE Y F, et al. A watershed segmentation algorithm based on an optimal marker for bubble size measurement[J]. Measurement, 2019, 138: 182-193.
- [15] 陈良琴, 王卫星. 基于气泡跟踪与相位相关的浮选表面气泡平移运动估计[J]. 四川大学学报(工程科学版), 2016, 48(5): 143-152.
- CHEN L Q, WANG W X. Flotation surface bubble displacement motion estimation based on bubble tracking and phase correlation[J]. Journal of Sichuan University (Engineering Science Edition), 2016, 48(5): 143-152. (in Chinese)
- [16] 廖一鹏, 王卫星. 结合多尺度边缘增强及自适应谷底检测的浮选气泡图像分割[J]. 光学精密工程, 2016, 24(10): 2589-2600.
- LIAO Y P, WANG W X. Flotation froth image segmentation based on multiscale edge enhancement and adaptive valley detection[J]. Optics and Precision Engineering, 2016, 24(10): 2589-2600. (in Chinese)
- [17] 肖玲玲, 龙魁. 基于DSP技术的钨矿初选系统的研究[J]. 矿业研究与开发, 2013, 33(2): 88-92.
- XIAO L L, LONG K. Design of primary sorting system of tungsten ore based on the DSP[J]. Mining Research and Development, 2013, 33(2): 88-92. (in Chinese)
- [18] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [19] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. 2015: 234-241.
- [20] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention U-Net: Learning Where to Look for the Pancreas[EB/OL]. [2021-02-20]. <https://arxiv.org/abs/1804.03999>.
- [21] LIU J P, GAO Q Q, TANG Z H, et al. Online monitoring of flotation froth bubble-size distributions via multiscale deblurring and multistage jumping feature-fused full convolutional networks[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(12): 9618-9633.
- [22] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA: IEEE, 2015: 1-9.
- [23] 王俊杰, 张军航. 基于多尺度特征融合的小样本遥感图像分割[J]. 华中科技大学学报(自然科学版), 2022, 50(3): 62-67.
- WANG J J, ZHANG J H. Small sample remote sensing image segmentation based on multiscale feature fusion[J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2022, 50(3): 62-67. (in Chinese)
- [24] 蔡畅, 陈军波, 陈心浩. 基于改进U-Net方法的脑肿瘤磁共振图像分割[J]. 中南民族大学学报(自然科学版), 2021, 40(4): 417-423.
- CAI C, CHEN J B, CHEN X H. MRI image segmentation of brain tumor based on improved U-Net method[J]. Journal of South-Central University for Nationalities (Natural Science Edition), 2021, 40(4): 417-423. (in Chinese)
- [25] ZHAO H S, SHI J P, QI X J, et al. Pyramid scene parsing network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, HI, USA: IEEE, 2017: 6230-6239.
- [26] 邹北骥, 易博松, 刘晴. 一种基于改进U形网络的眼底图像视网膜新生血管检测方法[J]. 湖南大学学报(自然科学版), 2021, 48(4): 19-25.
- ZOU B J, YI B S, LIU Q. A method of retinal neovascularization detection on retinal image based on improved U-net[J]. Journal of Hunan University (Natural Sciences), 2021, 48(4): 19-25. (in Chinese)