

DOI: 10.13382/j.jemi.B2104647

焦炭显微光学组织自动检测与提取方法研究*

王夏霖¹ 阚 秀¹ 孙维周² 曹 乐¹ 范艺璇¹
(1. 上海工程技术大学电子电气工程学院 上海 201620; 2. 安徽工业大学冶金工程学院 马鞍山 243002)

摘 要:焦炭显微光学组织结构测定是一种重要的焦炭质量评价方式,针对焦炭显微图像边缘模糊对比度低且存在光晕伪影等问题,设计一种基于语义分割和全连接条件随机场的焦炭显微光学组织自动检测与提取方法。首先,利用偏光显微镜、工业相机和上位机等搭建焦炭显微光学组织测定平台;其次,利用残差模块和注意力模块改进 Unet 网络模型,加强显微光学组织区域的输出权重,实现对焦炭光学组织的自动检测与分割;最后,使用全连接条件随机场对显微光学组织的空间特性进行建模,细化分割边缘,精确提取焦炭显微光学组织。实验结果表明,所提方法的精确度、召回率、F1 分数和准确率分别达到了 0.967、0.959、0.963、0.965,优于其他对比语义分割网络,证明该方法具有较高的分割性能,能够实现对焦炭显微光学组织的自动检测与提取。

关键词: 焦炭显微图像;焦炭显微光学组织;图像分割;全连接条件随机场

中图分类号: TP391.4;TN98 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Research on automatic detection and extraction of coke optical texture

Wang Xialin¹ Kan Xiu¹ Sun Weizhou² Cao Le¹ Fan Yixuan¹
(1. School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China;
2. School of Metallurgical Engineering, Anhui University of Technology, Maanshan 243002, China)

Abstract: Coke optical texture analysis is an important way to evaluate the quality of coke, aiming at the problems of fuzzy edge, low contrast and halo artifacts in coke photomicrographs, an automatic detection and extraction method for coke optical texture based on semantic segmentation and fully connected conditional random field is designed. Firstly, a coke optical texture measurement platform is built by using microscope, industrial camera and computer; secondly, the Unet is improved using residual module and attention module and the output weight of the coke optical texture is enhanced to realize automatic detection and segmentation of coke optical texture; finally, the spatial characteristics of coke optical texture are modeled using the fully connected conditional random field to refine the segmentation edges and achieve the accurate extraction of coke optical texture. The experimental results show that the precision, recall, F1-score and accuracy of the proposed method reach 0.967, 0.959, 0.963 and 0.965, respectively, which are better than other comparative semantic segmentation networks, proving that the method has high segmentation performance and can realize automatic detection and extraction of coke optical texture.

Keywords: coke photomicrograph; coke optical texture; image segmentation; fully connected conditional random field

0 引 言

焦炭是炼焦煤在高温干馏下形成的一种固体燃料,是高炉炼铁中的主要原料^[1]。焦炭的微观结构与其质量密切相关,其中,焦炭显微光学组织是指焦炭样品在偏光显微镜下放大 200~500 倍下呈现的焦炭气孔壁结构。焦炭的显微光学组织结构决定了焦炭的热强度和反应性,间接影响了焦炭在高炉炼铁中的劣化性能^[2-3]。因此,解析焦炭显微结构是焦化科研的研究热点,对焦炭显

微光学组织进行研究,不仅可以加深对炼焦煤和焦炭性质的认识,还对快速评价焦炭质量和指导配煤炼焦有着十分重要的意义^[4]。然而,由于焦炭显微光学组织的形成受到炼焦煤种类、炼焦煤变质程度和高温干馏条件等诸多因素的影响,焦炭在显微镜下会呈现出不同的光学性质,并且结构复杂,成分丰富。自动检测焦炭显微图像中的显微光学组织并实现准确提取,是实现焦炭质量自动测定的关键和难点。

过去几十年中,不断有学者使用图像处理方法对焦炭显微结构进行分析研究,并且取得了一系列研究结果。梁磊等^[5]等用传统的 OTSU 分割算法对焦炭显微光学组织的灰度图像中最亮区域进行分割,并以此来测定焦炭的热膨胀系数。闫国晨等^[6]等将焦炭显微图像划分为小块,并统计每小块中的灰度差,利用灰度差来分割焦炭显微光学组织和背景区域。Zhou 等^[7]提出了一种改进的均值漂移聚类算法,较好的解决了焦炭显微光学组织边界模糊的问题。近年来,以数据驱动、能够自动学习特征的卷积神经网络在自然图像分割如眼底视盘分割^[8]、肿瘤分割^[9]、车道线检测^[10]和遥感图像识别^[11-12]等上取得了很好的分割效果。2014 年,Long 等^[13]提出全卷积神经网络 FCN,开启了将深度学习应用于语义分割的序幕。2015 年,Ronneberger 等^[14]提出了 Unet 网络,Unet 借鉴了 FCN 网络的设计思路并在网络中加入了反卷积操作和跳跃连接,增强了提取局部特征的能力。Abraham 等^[15]将注意力机制引入到 Unet 网络中,使得网络能够自动聚焦于不同形状的目标结构,进一步提高了医学图像中病理分割的精度和效率。

当前焦炭显微图像处理方法仍然以传统图像处理方法为主,在实际使用中需要大量的人工干预以提高算法对焦炭显微图像的处理结果,且焦炭显微光学组织的分割精度也未达到实用化程度。受到深度学习语义分割网络在医疗图像分割、遥感影像分类等应用领域的启发,本文将改进深度学习语义分割网络并用于分析焦炭显微图像。本文设计了改进的 Unet 网络,通过融合残差机制和注意力机制进一步强化网络的特征提取能力并提高网络的重建能力,实现了焦炭显微光学组织的自动检测与分割;将全连接条件随机场作为网络的后处理对显微光学组织的空间特性进行建模,细化网络的分割结果,使显微光学组织的边界更加清晰,实现对焦炭显微光学组织的精确提取。

1 焦炭显微光学组织测定系统搭建

本文使用的焦炭显微图像采集自专业人员制作的焦炭样品,焦炭显微光学组织测定系统主要由 ZESIS AXIO Imager M2m 偏光显微镜、Axiocam 工业相机、光源、电源

等组成的硬件设备采集平台,以及实现自动测定和控制的上位机软件设备组成,硬件设备采集平台如图 1 所示。




图 1 焦炭显微光学图像采集系统

Fig. 1 Image acquisition system of coke photomicrographs

焦炭显微光学组织测定系统主要流程如图 2 所示,主要有参数设置模块、图像采集模块、图像载入模块、显微光学组织检测分割模块、精确提取模块和输出模块组成。上位机首先设定调整硬件采集系统的参数,控制偏光显微镜对焦炭样品进行精准对焦和曝光,然后驱动物镜按照设定路径及步距在 X-Y 轴水平方向移动,并调用工业相机拍摄 3 mm×3 mm 的焦炭表面区域,最终合成存储分辨率为 2 752×2 208 pixel 的 RGB 焦炭显微图像。在采集焦炭显微图像的同时,上位机中图像处理软件自动读取已采集的显微图像,并自动实现对焦炭显微光学组织的检测提取,最后将提取结果输出。




图 2 焦炭显微光学组织测定系统流程

Fig. 2 Process flow of coke optical texture measuring system

如图 3 所示,焦炭显微光学组织成分复杂、边界模糊,显微图像中存在着过曝噪点,给测定工作增加很多困难。

2 焦炭显微光学组织自动检测与提取方法

为了准确提取焦炭显微图像中的显微光学组织,本文基于机器视觉语义分割技术设计了焦炭显微光学组织




图 3 焦炭显微图像中复杂场景
Fig.3 Complex scenes in coke photomicrograph

自动检测和提取方法。本文方法由两部分组成,分别为基于改进 Unet 网络的显微光学组织自动检测与分割部分和基于全连接条件随机场的显微光学组织精确提取部分。焦炭显微光学组织的自动检测与分割是精确提取的前提和基础,首先,对焦炭显微图像进行分块采样后,使用改进的 Unet 网络 RAUnet 自动检测分割每张焦炭小图中的显微光学组织,分割完成后重新合成原分辨率大小的二值焦炭显微光学组织图像。然后,使用全连接条件随机场基于 RAUnet 网络输出的二值图像对焦炭显微图像建模,充分考虑图像像素间关系,最后重新输出具有空间一致性的提取结果,进一步细化上一步的分割结果,完成焦炭显微光学组织的精确提取,方法流程如图 4 所示。

2.1 焦炭显微光学组织检测与分割模型

本文改进的 RAUnet 语义分割网络结构如图 5 所示。RAUnet 网络参考 Unet 网络的端到端结构,输入为




图 4 本文方法流程
Fig.4 Flow chart of this paper




图 5 RAUnet 网络结构
Fig.5 Structure of RAUnet

768×768 pixel 大小的 RGB 焦炭显微图像,输出为黑白焦炭显微光学组织图像。在输出图像中,焦炭显微光学组织为白色,其他成分为黑色。
RAUnet 网络由非对称的编码器和解码器构成。网络的编码器由 4 个下采样模块组成,每个下采样模块包

括两个残差模块和一个最大池化层,负责提取并输出图像的低分辨率特征矩阵。网络中间的连接模块由两个残差模块和一个注意力模块组成。网络的编码器由 4 个上采样模块组成,每个上采样模块包括两个残差模块和反卷积层。对应的,它逐级将低分辨率特征矩阵还原为原

始分辨率大小。由于编码器中的最大池化层容易丢失位置、形状等关键低级语义信息,因此在编码器和对应解码器之间设置带有注意力模块的跳跃连接,将浅层网络中保留较好的位置信息直接传递给解码器,使得网络能够更好的恢复图像信息。焦炭显微光学组织分割本质上是一个逐像素点的二分类问题,网络最终通过 sigmoid 层输出一个概率图,概率图上每个像素位置都对应着该点属于焦炭显微光学组织的概率值,通过对概率图进行阈值处理,得到最终焦炭显微光学组织的分割结果。

1) 残差模块

在深度学习中,随着神经网络深度的增加,网络的性能会得到提升,但一味地增加网络深度会出现梯度消失或爆炸现象。本文借鉴 Resnet 网络^[16]的设计思路,通过添加残差模块来解决这一问题,残差模块结构如图 6 所示。




图 6 残差模块结构图

Fig. 6 Structure of residual module

本文所使用的残差模块可以表示为:

$$H(X) = F(X) + X \quad (1)$$

由式(1)可知,通过残差模块中首尾的恒等连接,将模块输入特征 X 与模块提取特征 $F(X)$ 相加得到模块输出 $H(X)$,因此网络在前向传播中,网络深层流入更多信息,从而避免梯度消失问题。而模块特征提取 $F(X)$ 包括如下操作:BN layer + Mish layer + 3×3 conv layer + BN layer + Mish layer + 3×3 conv layer。其中,BN layer 的加入能够有效降低网络在训练过程中的复杂性和不确定性,同时,也可以有效降低网络在训练时出现过拟合的概率。而 Mish 激活函数^[17]能够使更多的信息流入网络的深处,当其输入 x 为负时,Mish 函数仍能保证一个较小的输出,Mish 函数表示为:

$$Mish(x) = x \times \tanh(\ln(1 + \exp(x))) \quad (2)$$

相较于常见的 ReLU 激活函数,Mish 激活函数的输出没有被完全截断。因此,Mish 激活函数可以进一步避免梯度消失问题,提高模型的泛化能力。

2) 注意力模块

焦炭显微光学组织中的惰性显微组分特征与图像背景特征非常相似,一般分割方法很难正确辨别这两类区域。因此,本文引入了注意力模块^[18],并将其置于下采样模块与对应上采样模块的跳跃连接之间。注意力模块能对网络底层提取的低分辨率全局特征进行有效修正,并结合网络深层提取的高分辨率局部特征,加强焦炭显

微光学组织区域的输出权重。本文使用的注意力模块分别由一个通道注意力模块和一个空间注意力模块组成,通道注意力模块结构如图 7 所示。




图 7 通道注意力模块结构

Fig. 7 Structure of channel attention module

通道注意力模块的输入为大小 $H \times W \times C$ 的特征 F ,对 F 分别进行平均池化和最大池化操作,将输入特征分别融合成两个大小为 $1 \times 1 \times C$ 的通道注意描述矩阵,将两个通道注意描述矩阵并联经感知机作用后结果直接相加,使用 sigmoid 激活函数将通道权重归一化到 $[0, 1]$,得到如式(3)所示的通道注意力系数 A_c ,将该注意力系数与模块输入特征图 I 相乘得到通道加权后的特征图 F' 。

$$A_c(F) = \text{sigmoid}(\text{MLP}(\text{Avgpool}(F) + \text{MLP}(\text{MaxPool}(F)))) \quad (3)$$

空间注意力模块结构如图 8 所示。




图 8 空间注意力模块结构

Fig. 8 Structure of spatial attention module

空间注意力模块将新特征分别通过一个最大池化层和一个平均池化层,得到两个 $H \times W \times 1$ 的通道描述矩阵,将这两个矩阵维度拼接在一起,经一个 7×7 的卷积层进行降维处理,同样使用 sigmoid 激活函数将空间权重归一化到 $[0, 1]$,得到如式(4)所示的空间注意力系数 A_s 。最后,将空间注意力系数 A_s 与特征 F' 相乘后得到新特征 F'' 。

$$A_s(F') = \text{sigmoid}(f^{7 \times 7}([\text{AvgPool}(F'), \text{MaxPool}(F')])) \quad (4)$$

2.2 全连接条件随机场后处理

由于语义分割网络的重复下采样操作丢失了大量的图像边缘信息,网络输出图像边缘的像素点较为平滑。为了进一步提高局部精确度,本文使用全连接条件随机场^[19-20]作为图像后处理阶段,处理过程如图 9 所示,在后处理结果中,白色区域为焦炭显微光学组织,灰色区域为图像背景。

全连接条件随机场作用于整张焦炭显微图像,使每个像素都与图像中任意独立像素建立联系,将局部空间




图 9 全连接条件随机场后处理流程

Fig. 9 Process flow of fully connected conditional random field

信息拓展到整张图像,从而获得更加精确的像素分类结果。对于给定的焦炭显微图像 I ,全连接条件随机场的能量函数为:

$$E(x | I) = \sum_i \psi_u(x_i) + \sum_{i < j} \psi_p(x_i, x_j) \quad (5)$$

式中: x_i 表示图中第 i 个像素点的类别,其取值范围为 $[0, 1]$, 0 表示为背景, 1 表示为焦炭显微光学组织。一元势函数 $\psi_u(x_i)$ 描述当前像素点 x_i 的相关信息,其直接取自语义分割网络的后端输出,即:

$$\psi_u(x_i) = -\lg P(x_i) \quad (6)$$

式中: $P(x_i)$ 代表语义分割网络推理出的像素点 x_i 为显微光学组织或者是背景的概率。二元势函数 $\psi_p(x_i, x_j)$ 对图像中像素点 i, j 之间的空间相关性进行建模。

$$\psi_p(x_i, x_j) = \mu(x_i, x_j) [\omega_1 k_1 + \omega_2 k_2] \quad (7)$$

$$k_1 = \exp\left(-\frac{|p_i - p_j|^2}{2\sigma_\alpha^2} - \frac{|I_i - I_j|^2}{2\sigma_\beta^2}\right) \quad (8)$$

$$k_2 = \exp\left(-\frac{|p_i - p_j|^2}{2\sigma_\gamma^2}\right) \quad (9)$$

式中: $\mu(x_i, x_j)$ 为标签兼容项,若 $x_i \neq x_j$ 则 $\mu(x_i, x_j) = 1$, 否则为 0, 这意味着该式只作用于类别不同的像素点。式(7)中 $[\omega_1 k_1 + \omega_2 k_2]$ 是两个在不同特征空间中的高斯核 k_1, k_2 ; p_i 和 p_j 代表像素点 i, j 的坐标; I_i 和 I_j 代表不同像素点的 RGB 颜色;超参数 ω_1 和 ω_2 控制高斯核的权重; $\sigma_\alpha, \sigma_\beta$ 和 σ_γ 控制高斯核的尺度。因此,第 1 个高斯核 k_1 可以将距离相近且颜色相似的像素判断为同属于一个物体,而第 2 个高斯核 k_2 可以用来剔除语义分割网络结果中的独立噪点。

全连接条件随机场的概率函数可以表示为:

$$P(X = x | I) = \frac{1}{Z} \exp(-E(x | I)) = \frac{1}{Z} \exp\left(\sum_i \psi_u(x_i) + \sum_{i < j} \psi_p(x_i, x_j)\right) \quad (10)$$

由于直接计算 $P(X)$ 较为复杂,一般采用近似推断的方法使用函数 $Q(X)$ 来代替 $P(X)$,并通过迭代最小化两者的 KL 散度对 $Q(X)$ 进行更新,具体更新策略如算

法 1 所示。

算法 1: 全连接条件随机场概率函数更新步骤

输入: $\psi_u(x_i)$; 高斯核 k_1, k_2 ; 高斯核权重 ω_1, ω_2 ; 不同类别之间的兼容性矩阵 μ

输出: 更新后的概率分布 Q_i

- 1) 信息传递: 使用 k_1, k_2 对所有类为显微光学组织的特征图 Q_i 做滤波计算;
- 2) 滤波结果累积和: 对 k_1, k_2 的滤波结果,按照权重 ω_1, ω_2 做累和相加;
- 3) 兼容变换: 对所有类为显微光学组织的特征图 Q_i , 凭借其兼容性矩阵进行更新计算;
- 4) 将数据项 $\psi_u(x_i)$ 做累和计算;
- 5) 数据归一化

本文在使用全连接条件随机场进行图像后处理时,每张焦炭显微图像通过 5 次迭代推理以最小化能量函数,判断图像中每个像素点的最可能类别并输出最终预测结果,从而使得显微光学组织的边界更加清晰明确。

3 焦炭显微光学组织测定实验

3.1 实验数据采集与处理

利用第 1 节中所搭建的硬件设备采集平台,本文共采集来自 15 个焦炭样品的 118 张焦炭显微图像,每张焦炭显微图像分块裁剪为 12 张 768×768 pixel 的显微小图,最终形成包含 1 416 张图像的实验数据集。随机抽取数据集中的 350 张图像,按 6 : 3 : 1 的比例划分为模型训练集、测试集和验证集,并对数据图像进行焦炭显微光学组织标注,其中,焦炭显微光学组织标注为 1,其他部分标注为 0。数据集标注结果示例如图 10 所示。




图 10 焦炭显微图像及其标注结果

Fig. 10 Images and label results of coke photomicrograph

由于焦炭显微图像数据集较小,为了提高 RAUnet 网络模型的泛化性能,防止网络训练时出现过拟合现象,本文在模型训练阶段使用图像增强策略,将图像对比度、亮度进行随机调整,随机水平翻转和随机角度旋转随机组合,扩充训练数据集,本文数据集制作流程如图 11 所示。




图 11 数据集制作流程
Fig. 11 Production process of dataset

3.2 自动检测与提取模型训练与评价

本文选择 precision、recall、F1-score 和 accuracy 作为焦炭显微光学组织提取结果的评价指标：

$$precision = \frac{TP}{TP + FP}$$

(11)

$$recall = \frac{TP}{TP + FN}$$

(12)

$$F1-score = \frac{2precision \times recall}{precision + recall}$$

(13)

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

(14)

式中：TP 代表网络将人工标注的焦炭显微光学组织区域正确分类；TN 代表网络将图像背景区域正确分类为背景区域；FP 代表网络将背景区域错误分类为焦炭显微光学组织区域；FN 代表网络将焦炭显微光学组织区域错误分类为图像背景。

本文网络使用的深度学习框架为 PyTorch12.0,同时使用 GPU 来加速网络模型的训练和测试。在实验参数优化阶段,鉴于 Adam 算法可在模型训练时自适应地调整学习率提高网络收敛速度,本文选用 Adam 算法作为优化器,设置初始学习率为 0.000 1,网络训练阶段的 batch size 为 2,训练迭代 200 轮。RAUnet 网络训练过程的准确率和损失率变化曲线如图 12 所示,随着迭代次数的增加,网络的准确率不断增加,并在 100 轮左右达到最佳,因此将此时的网络参数保存为最佳模型。




图 12 RAUnet 网络训练过程准确率和损失率变化曲线
Fig. 12 Accuracy and loss curve of RAUnet during the training process

3.3 实验结果与分析

1) 消融实验

为了验证本文所提模型方法的有效性,本文设计网络消融实验以证明残差模块、注意力模块和全连接条件随机场能够有效提高算法的分割性能。实验以 Unet 为骨干网络,分别选择了 5 种网络模型:(1) Unet;(2) Unet +Residual block;(3) Unet + Attention block;(4) RAUnet;(5)RAUnet-CRF 进行对比实验,实验结果如表 1 所示。

由表 1 可以看出,残差模块和注意力模块的加入都能在一定程度上改善网络的分割效果。其中,Unet +残差模块的 F1-score 和 accuracy 比 Unet 提升了 0.015 和 0.021,Unet+注意力模块的 F1-score 和 accuracy 比 Unet 提升了 0.019 和 0.023。全连接条件随机场在 RAUnet

表 1 消融实验结果

Table 1 Results of ablation experiments

Network	precision	recall	F1-score	accuracy
(1) Unet	0.921	0.937	0.935	0.928
(2) Unet + Residual block	0.944	0.952	0.950	0.949
(3) Unet + Attention block	0.951	0.949	0.954	0.953
(4) RAUnet	0.963	0.957	0.961	0.962
(5) RAUnet-CRF	0.967	0.959	0.963	0.965

的基础上进一步提高了评价结果,RAUnet-CRF 算法的 F1-score 和 accuracy 在上述算法中达到最高,分别为 0.963 和 0.965。消融实验结果证明:残差模块能够提高网络的特征提取能力,强化了分割效果;注意力模块加强了目标区域的输出效果,提高了网络分割性能;全连接条件随机场的加入,能够进一步精确网络的分割结果。

2) 对比实验

为了进一步验证本文所提模型方法的实用性, 本文将所设计网络模型 RAUnet-CRF 与 Unet++^[21]、ResUnet^[22] 进行对比实验, 实验结果如表 2 所示。

表 2 不同语义分割网络的评价结果

Table 2 Evaluation results of different semantic segmentation networks				
Network	precision	recall	F1-score	accuracy
(1) Unet++	0.951	0.947	0.944	0.945
(2) ResUnet	0.955	0.954	0.950	0.956
(3) RAUnet-CRF	0.967	0.959	0.963	0.965

从表 2 可以看出, 本文所设计算法 RAUnet-CRF 的 f1-score 和 accuracy 对比 Unet++ 和 ResUnet 分别提高了 0.019、0.02 和 0.013、0.009。同时, 本文从测试集中随机选取 4 张焦炭显微图像, 分别利用 3 种网络算法进行焦炭光学组织提取实验, 实验结果如图 13 所示。




图 13 焦炭显微光学组织提取结果

Fig. 13 Extraction results of coke optical texture

由图 13 可知, 对于图 13A 和 D, 在焦炭惰性显微组分区, Unet++ 的分割效果最差, 出现了大面积的错分现象, ResUnet 也出现了小面积的过分割现象, 而本文所设计算法 RAUnet-CRF 与真实结果最为接近。对于图 13B, 3 种网络都能较为准确地提取显微光学组织, 但是 Unet++ 对图像左下方的噪点存在误分割, 且提取的显微光学组织中存在孔洞。对于图 13C, 在显微图像中的光晕噪声区域, Unet++ 和 ResUnet 都错误的将光晕中心分类为焦炭显微光学组织, 而本文所设计算法 RAUnet-CRF 由于加入的注意力机制模块, 有效抑制了无用特征的传播, 在光晕噪声处理上相较于 Unet++ 和 ResUnet 算法结果更接近人工标注结果。对比实验结果表明, 本文所设计网络模型 RAUnet-CRF 拥有良好的分割性能, 可以有效实现对焦炭显微光学组织的准确分割提取。

4 结 论

针对焦炭显微图像中由于焦炭显微光学组织成分多样、边界模糊、显微图像存在过曝噪声等因素导致的图像分割精度低的问题, 以及传统人工数点法精度低, 效率差的问题, 本文设计了一种基于语义分割和全连接条件随机场的焦炭显微光学组织自动检测和提取方法。该方法将显微图像采集平台和显微光学组织自动检测提取算法结合起来: 首先搭建了基于偏光显微镜、工业相机和上位机的焦炭显微光学组织测定平台, 实现焦炭显微图像的自动采集; 然后设计了焦炭显微光学组织自动检测与分割网络 RAUnet, 其在网络的编码和解码部分引入残差模块, 拓展了网络深度的同时提高了网络特征提取能力, 同时在编码器和解码器之间的跳跃连接中加入了注意力模块, 关注焦炭显微光学组织部分的特征信息, 强化网络的重建能力; 最后通过全连接条件随机场进一步细化分割结果, 实现焦炭显微光学组织的精确提取。实验结果表明, 残差模块、注意力模块和全连接条件随机场的加入能够有效提高网络的分割性能, 本文方法能够实现对显微图像中的焦炭显微光学组织的自动检测分割与精确提取。

参考文献

[1] UENO H, ENDO S, TONOMURA S, et al. Outline of CO₂ ultimate reduction in steelmaking process by innovative technology for cool earth 50[J]. Journal of the Japan Institute of Energy, 2015, 94: 122-129.

[2] SHEN F, GUPTA S, LIU Y, et al. Effect of reaction conditions on coke tumbling strength, carbon structure and mineralogy[J]. Fuel, 2013, 111: 223-228.

[3] PUSZ S, KRZESINKA M. Changes in a coke structure due to reaction with carbon dioxide[J]. International Journal of Coal Geology, 2010, 81(4): 287-292.

[4] 侯彩霞, 林加雄, 郭瑞, 等. 焦炭的显微结构对溶损劣化的影响[J]. 燃料与化工, 2019, 50(3): 6-10.

HOU C X, LIN J X, GUO R, et al. Effects of microscopic structure on coke solution loss and deterioration[J]. Fuel and Chemical Process, 2019, 50(3): 6-10.

[5] 梁磊, 孙章, 魏侦凯, 等. 冶金焦炭结构及其组成的研究进展[J]. 燃料与化工, 2019, 50(2): 18-22.

LIANG L, SUN ZH, WEI ZH K, et al. Progress in research of structure and composition of metallurgical coke[J]. Fuel and Chemical Process, 2019, 50(2): 18-22.

[6] 闫国晨, 郭瑞. 显微图像法测量焦炭孔结构的发展与现状[J]. 燃料与化工, 2021, 52(02): 22-25.

YAN G CH, GUO R. Development and present situation of

- micrographic method for measuring coke pore structure[J]. Fuel and Chemical Process, 2021, 52(02): 22-25.
- [7] ZHOU F, GUANG X. A novel intelligent technique for recognition of coke optical texture [J]. Journal of Software, 2011, 6(8): 1476-1483.
- [8] 侯向丹, 赵一浩, 刘洪普, 等. 融合残差注意力机制的UNet视盘分割[J]. 中国图象图形学报, 2020, 25(9): 1915-1929.
- HOU X D, ZHAO Y H, LIU H P, et al. Optic disk segmentation by combining Unet and residual attention mechanism[J]. Journal of Image and Graphics, 2020, 25(9): 1915-1929.
- [9] LIANG S, ZHANG R G, LIANG D Y, et al. Multimodal 3D DenseNet for IDH genotype prediction in gliomas[J]. Genes (Basel), 2018, 9(8): 382.
- [10] KIM J, LEE M. Robust lane detection based on convolutional neural network and random sample consensus [C]. International Conference on Neural Information Processing, 2014.
- [11] 王敏, 陈金勇, 王港, 等. 面向深度学习的遥感图像目标样本生成方法[J]. 国外电子测量技术, 2019, 38(4): 60-65.
- WANG M, CHEN J Y, WANG G, et al. Remote sensing image object sample generation method for deep learning[J]. Foreign Electronic Measurement Technology, 2019, 38(4): 60-65.
- [12] CHU Z, TIAN T, R FENG, et al. Sea-land segmentation with Res-UNet and fully connected CRF [C]. IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium, 2019.
- [13] LONG J, SHELHEMAR E, DARREL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4): 640-651.
- [14] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015.
- [15] ABRAHAM N, KHAN N M. A novel focal loss function with improved attention U-Net for lesion segmentation[C]. 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI), 2019.
- [16] 王飞, 张莹, 邵豪, 等. 多尺度残差网络模型的研究及其应用[J]. 电子测量与仪器学报, 2019, 33(4): 19-28.
- WANG F, ZHANG Y, SHAO H, et al. Research and application of the multi-scale residual networks model[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(4): 19-28.
- [17] ZHENG X, CHEN J, WANG H, et al. A deep learning-based approach for the automated surface inspection of copper clad laminate images [J]. Applied Intelligence, 2020, 51: 1262-1279.
- [18] CHEN Y, ZHANG X, CHEN W, et al. Research on recognition of fly species based on improved RetinaNet and CBAM [J]. IEEE Access, 2020 (8): 102907-102919.
- [19] 陈彦彤, 李雨阳, 陈伟楠, 等. 基于深度语义分割的遥感图像海面舰船检测研究[J]. 仪器仪表学报, 2020, 41(1): 233-240.
- CHEN Y T, LI Y Y, CHEN W N, et al. Sea surface ship detection based on deep semantic segmentation using remote sensing image [J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 233-240.
- [20] 杨超, 周大可, 杨欣. 基于篡改区域轮廓的图像拼接篡改盲取证算法[J]. 电子测量技术, 2020, 43(4): 132-138.
- YANG CH, ZHOU D K, YANG X. Blind forensics for image tampering based on tampered contour[J]. Electronic Measurement Technology, 2020, 43(4): 132-138.
- [21] ALEXAKIS E, ARMENAKIS C. Evaluation of Unet and Unet++ architectures in high resolutions image change detection applications[C]. ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2020: 1507-1514.
- [22] FID A, FW B, PC A, et al. ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data-ScienceDirect [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 162: 94-114.

作者简介



王夏霖, 2019 年于南京工程学院获得学士学位, 现为上海工程技术大学硕士研究生, 主要研究方向为图像处理。

E-mail: xialin_wang@163.com

Wang Xialin received his B. Sc. degree from Nanjing Institute of Technology in 2019.

Now he is a M. Sc. candidate in Shanghai University of Engineering Science. His main research interest includes image processing.



阚秀, 2013 年于东华大学获得博士学位, 现为上海工程技术大学电子电气工程学院副教授, 主要研究方向为智能控制、数据分析、复杂网络及其应用。

E-mail: 02130002@sues.edu.cn

Kan Xiu received the Ph. D. degree in Control Engineering in 2013 from Donghua University. She is currently an associate professor with the School of Electronic and Electrical Engineering, Shanghai University of Engineering Science. Her main research interests include intelligent control, data engineering and analytics, as well as complex networks and their applications.