

基于改进 HED 网络模型的破碎矿石 图像分割方法

顾清华^{1,2*}, 危发文^{1,2}, 郭梦利^{1,2}, 江松^{1,2}, 阮顺领^{1,2}

¹西安建筑科技大学资源工程学院, 陕西 西安 710055;

²西安市智慧工业感知计算与决策重点实验室, 陕西 西安 710055

摘要 矿石的粒度大小是评判破碎机破碎效果的重要参考,而图像分割是矿石粒度检测的关键步骤。针对破碎矿石形状复杂、粘连和堆叠以及图像噪声严重而导致图像分割不准确的问题,提出一种基于改进 HED(Holistically-Nested Edge Detection)网络模型的破碎矿石图像分割方法。首先,对采集的矿石图像进行双边滤波预处理操作,减少噪声对分割的影响;其次,使用残差可变形卷积块替代普通卷积块以增强模型对不同大小形状矿石的特征提取能力,并利用空洞卷积替代原有的池化层以扩大感受野,保留矿石的全局信息;最后,使用具有底部短连接结构的 HED 网络框架对矿石进行特征提取,并将提取的特征与低级的细节信息相融合,减少对粘连和堆叠矿石颗粒的欠分割问题。

关键词 图像处理; 图像分割; 矿石粒度; HED 网络模型; 可变形卷积; 空洞卷积

中图分类号 TD672

文献标志码 A

doi: 10.3788/LOP202259.0210020

Segmentation Method of Broken Ore Image Based on Improved HED Network Model

Gu Qinghua^{1,2*}, Wei Fawen^{1,2}, Guo Mengli^{1,2}, Jiang Song^{1,2}, Ruan Shunling^{1,2}

¹School of Resource Engineering, Xi'an University of Architecture and Technology, Xi'an, Shaanxi 710055, China;

²Xi'an Key Laboratory of Smart Industry Perception Computing and Decision Making, Xi'an, Shaanxi 710055, China

Abstract The particle size of ore is an important reference to judge the crushing effect of crusher, and image segmentation is the key step of ore particle size detection. To solve the problems of image segmentation inaccuracies caused by complex shape, adhesion and stacking of broken ore, and serious image noise, a broken ore image segmentation method based on improved HED (Holistically-Nested Edge Detection) network model is proposed. First, the bilateral filtering pre-processing operation is carried out on the collected ore image to reduce the influence of noise on segmentation. Second, the residual deformable convolution block is used to replace the ordinary convolution block to enhance the feature extraction ability of the model for ores of different sizes and shapes, and the void convolution is used to replace the original pooling layer to expand the receptive field and retain the global information of ores. Finally, the HED network framework with a bottom-short connection structure is used for feature extraction of ore, and the extracted features are combined with low-level detail information to reduce the problem of undersegmentation of cohesive and stacked ore particles.

Key words image processing; image segmentation; ore size; HED network model; deformable convolution; atrous convolution

收稿日期: 2021-03-04; 修回日期: 2021-03-28; 录用日期: 2021-04-14

基金项目: 国家自然科学基金面上项目(51774228, 52074205)、陕西省自然科学基金杰青项目(2020JC-44)

通信作者: *qinghuagu@126.com

1 引言

破碎矿石的粒度大小是评判破碎效果的重要指标之一^[1],也是调节破碎参数的重要参考之一。破碎机依据矿石的粒度大小来调节破碎参数和进料的速度,从而使矿山企业达到高效率生产的目的。目前,国内的大多数选矿企业采用人工取样的方式对破碎矿石进行粒度检测,这不仅会导致准确率低下,还会无法满足实时性的要求。随着矿产资源的过度开采^[2],充分利用矿产资源、实现矿区绿色开采以及降低矿山生产能耗是现代化矿产企业所面临的新挑战。如何准确且实时地检测破碎矿石的粒度,仍是矿山行业的一个技术难题。

近几年,计算机有了飞跃的发展,其中图像处理技术被广泛应用于许多领域,如人脸识别、目标检测、语义分割和文字识别等^[3-9]。基于此,一些专家应用图像处理技术对矿石粒度进行自动检测,而关键环节就是图像分割。许多学者提出了基于矿石图像的分割方法,如柳小波等^[10]提出一种基于 U-Net 和 ResUNet 模型的传送带矿石图像分割方法,用于分割传送带上的矿石,从而测定矿石的粒度。董珂等^[11]提出一种基于改进分水岭变换的矿石图像分割方法,该方法基于积分图像的自适应阈值化算法来提取矿石区域,并利用分水岭算法对矿石区域进行分割。卢才武等^[12]提出了基于深度图像分析的细粒度矿石分级测定方法。周静等^[13]提出了一种基于协同表征的二部图矿石图像分割方法。Yuan 等^[14]提出一种基于深度学习的方法,采用该方法可以对矿石图像进行分割。Zhang 等^[15]提出一种基于邻域和 Otsu 的阈值分割方

法,首先利用 Otsu 方法对像素的邻域阈值进行优化,然后通过最小阈值对每个像素进行二值化,有效提高了阈值分割的有效性,该方法适用于非均匀光照的图像。张建立等^[16]提出一种基于形态学处理的矿石粒度检测方法。Malladi 等^[17]提出一种基于特定理论的分割方法。通过上述研究可以看出,目前的主要研究方向还是应用传统方法对矿石图像进行分割,应用深度学习技术来分割矿石图像的研究很少,而且破碎矿石的颗粒形状复杂,不同大小的矿石粘连、堆叠严重,使得分割结果不准确,这也间接导致该技术在矿山实际应用中的效果不理想。

目前,深度学习技术取得了巨大的发展,已经广泛应用于计算机视觉领域,如焦安波等^[18]利用 HED (Holistically-Nested Edge Detection) 网络模型对红外图像进行边缘检测,牟海维等^[19]利用改进的 DeepLabv3+ 网络模型可以对图像进行准确分割。基于此,本文利用 HED 网络模型对破碎矿石图像进行分割,并在已有的基础上对 HED 网络加以改进,以解决矿石粘连、堆叠所导致的欠分割问题,通过分割图来确定矿石的粒度大小以适时调节破碎机的参数,从而降低矿山企业的生产能耗,进而提高生产效率。

2 HED 网络模型的介绍

HED 网络是基于 VGG (Visual Geometry Group) 网络^[20]设计的,其是一个端到端的网络,具有 VGG 网络的特征提取能力。在 HED 网络的骨干部分采用 VGG 网络可以将全连接层结构全部移除,只保留卷积层,这种结构能够在图像中提取多层次、多尺度的特征信息。VGG 网络的结构如图 1 所示。




图1 VGG网络的结构

Fig. 1 Structure of VGG network

相比于限定输入图片尺寸的 VGG 网络, HED 网络由于去掉了全连接层, 所以可以对任意尺寸的图片进行训练和后期预测。参数的数目也随着全连接层的去除有了大幅度的降低, 从而大大提升了网络的运行效率。利用多尺度、多层级的 HED 网络可以在主干网络中插入多个侧边输出层, 并在侧边输出层上对特征信息进行深度监督, 将最后得到的结果与不同层得到的结果连接起来以达到优化边缘的目的。

然而, 图片的分辨率会随着网络层的加深越来越低, 这会导致部分图像边缘不清晰, 而且矿石堆叠、粘连严重, 进而导致矿石图像分割不准确。基于此, 对 HED 网络进行一部分改进。

3 基于改进 HED 网络模型的破碎矿石图像分割网络模型的设计

在破碎矿石图像的分割过程中, 破碎机破碎后的矿石形状不一, 当矿石输送至传送带上时, 不同大小的矿石堆叠、粘连在一起, 矿区的恶劣环境会导致采集的矿石图像中存在严重的噪声, 这些客观原因均会导致一般的分割方法分割不准确。使用传统的 HED 网络模型对矿石图像进行分割, 该分割过程会存在网络模型参数过多、分割用时过长、检测出的矿石边缘不完整以及得到的矿石边缘效果不显著等问题。为了解决上述问题, 本文设计一种改进的 HED 网络模型, 该模型利用残差可变形模块来替代传统卷积模块, 用来学习局部细节特征和自适应调整感受野。考虑到感受野的增大会导致空间敏锐度的降低而存在欠分割的问题, 使用空洞卷积层来替代常规的池化层, 能够在增大感受野的同时不会降低矿石图像的分辨率。

3.1 残差可变形卷积模块

为了更好地提取不同形状、不同大小的破碎矿石特征, 引入一种残差可变形卷积模块。可变形卷积模块是 Dai 等^[21]于 2017 年提出的, 其在每个卷积核元素上均额外增加一个方向参数, 使得卷积核能够在训练过程中扩展到很大范围。可变形卷积模块主要由可变形卷积层、标准卷积层、批归一化(BN)层和 ReLU 层构成, 模块结构如图 2 所示, 其中可变形卷积层和标准卷积层用于提取不同形状、不同大小的矿石图像特征, 批归一化层用于保证网络的输入具有相同的分布, ReLU 层用于减少参数的相互依存关系, 缓解过拟合问题的发生, \oplus 表示相加融合操作。

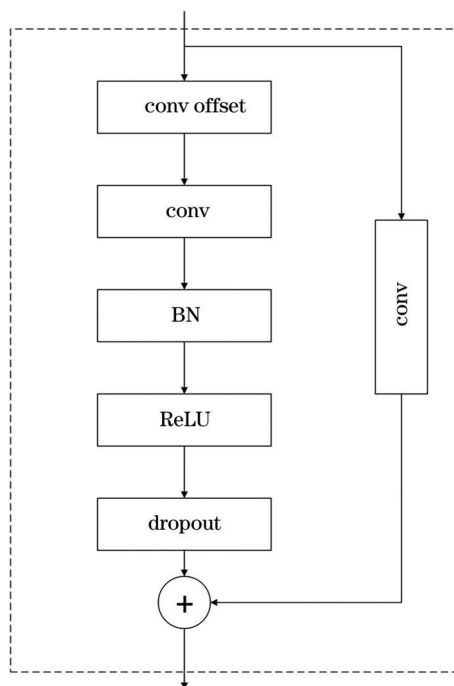


图 2 可变形卷积模块的结构

Fig. 2 Structure of deformable convolution module

传统的卷积核大都是标准大小, 如 3×3 和 5×5 等, 这种标准卷积核的适应能力差, 泛化能力较弱。由于破碎矿石的形状复杂, 大小不一, 标准卷积核难以提取破碎矿石的全部特征。可变形卷积是标准卷积的一种改进, 其在卷积单元中增加的偏移量可以通过梯度反向传播进行端到端的学习。加上偏移量的学习之后, 可变形卷积核的大小和位置可以根据当前需要识别的图像内容进行动态调整, 卷积核的采样点能够根据学习的进行而自适应变化, 从而学习到不同大小、不同形状的图像特征。

以 5×5 大小的卷积核为例, 标准的卷积核如图 3(a) 所示。从图 3(a) 可以看到, 标准的卷积核规则地落在破碎矿石图像中的一个矩形区域内, 这可以提取该区域中的矿石图像特征, 矩形区域 S 可表




图 3 卷积采样点的示意图。(a) 标准卷积; (b) 可变形卷积
Fig. 3 Schematic of convolution sampling points.

(a) Standard convolution; (b) deformable convolution

示为

$$S = \{(x, y)\} = \{(2, 2), (1, 2), \dots, (-2, 1), (-2, 2)\}, \quad (1)$$

式中: (x, y) 表示区域 S 中的一个点。对应的输出结果 Y 在不规则区域 S_0 处的结果可表示为

$$Y(S_0) = \sum_{S_n \in S} w(S_n) x(S_0 + S_n), \quad (2)$$

式中: x 表示输入图像的特征关系; S_n 表示在矩形区域 S 中的第 n 个位置; w 表示采样点的权重。可变形卷积在卷积核的采样点处增加了一个可学习的偏移变量 ΔS_n , 为此没有标准卷积的限制, 可根据不同矿石的形状特征进行自适应调整, 可变形卷积的结果如图 3(b) 所示。可变形卷积通过不断学习可以更好地获取矿石的结构和位置信息, 从而得到更为准确的分割结果。可变形卷积后的输出结果可表示为

$$Y(S_0) = \sum_{S_n \in S} w(S_n) x(S_0 + S_n + \Delta S_n). \quad (3)$$

3.2 空洞卷积

本研究另一项改进之处就是使用空洞卷积

层来替代常规的池化层。在卷积神经网络中, 池化层的作用是对特征进行下采样处理以减小输出空间的大小, 从而增大感受野以及减少网络参数的数量, 进而降低计算的复杂度。但池化层有一个缺陷, 即在分割过程中不仅会使空间的敏锐度降低, 还可能会丢失一些重要的边缘信息, 这将直接导致矿石图像的欠分割。

综上, 使用空洞卷积层来替代常规卷积层, 即在卷积核中间填充“0”, 通过这种方式能够扩大卷积核以增大感受野。该操作的优点在于即使不进行池化操作, 也可以增大感受野, 而且能够更好地获取图像的全局信息。在空洞卷积中, 空洞率 l 为指定内核元素中“0”的数量, 若定义空洞卷积的内核大小为 t , 则扩张后卷积核的大小 y 为

$$y = t + (t - 1)(l - 1). \quad (4)$$

通过设置空洞率可以有效扩大卷积核的大小, 3×3 大小的卷积核在不同空洞率下的扩张结果如图 4 所示。

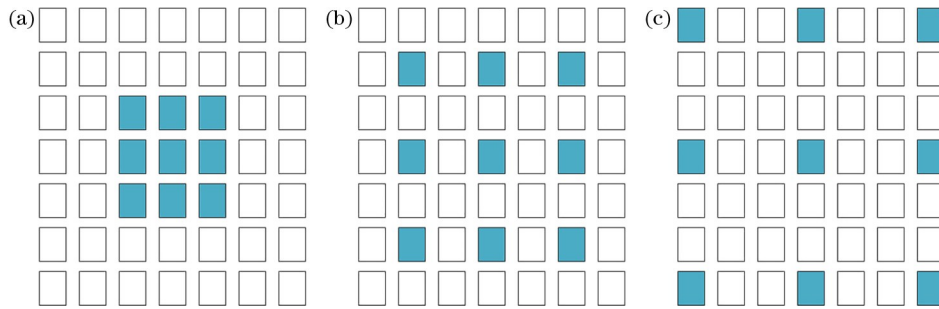


图 4 3×3 大小的卷积核在不同空洞率下的扩张结果。(a) $l=1$; (b) $l=2$; (c) $l=3$

Fig. 4 Expansion results of convolution kernel of 3×3 size under different cavity rates. (a) $l=1$; (b) $l=2$; (c) $l=3$

3.3 破碎矿石图像分割网络的框架

本文提出的网络结构是基于改进的 HED 网络进行设计的, 该网络结构可用于分割矿山破碎矿石, 可以将不同阶段所提取的特征进行融合, 能够充分利用不同的感受野来提取多尺度特征。网络的大体框架如图 5 所示, 主要包括三个部分。

第一部分为网络的预训练部分(图 5 的虚线框), 其是整个模型的主干。其中包括 4 个小阶段, 每个小阶段先通过可变形卷积对矿石图像的特征进行学习, 然后依次经过扩张率分别为 2、4、8 和 4 的空洞卷积对特征进行连接, 并将得到的特征进行融合, 使得模型能够获取更为精确的矿石边缘特征, 这部分的主要作用是在不同尺度下获取矿石边缘的细节特征, 以便能够较好地分割粘连颗粒。需要注意的是, 分割过程中需保证特征图的尺寸与输

入图像一致, 以便后续的融合操作能够顺利进行。

第二部分主要由侧输出部分构成。当卷积深度较大时, 网络所提取的特征不够具体, 而且无法体现实际的矿石边缘信息, 因此网络框架的前 4 个阶段用于提取矿石特征。首先使用 16 个 1×1 大小的滤波器对各阶段所提取的矿石特征进行卷积运算, 并将各阶段得到的 16 张特征图使用 1×1 大小的滤波器进行融合, 从而得到一张特征图; 然后使用由高到低的短连接将深层信息传递到浅层语义信息中, 利用此方法可以得到更为准确的矿石边缘线; 最后与人工标注的结果进行对比, 从而获得输出层的损失并用于后续的训练。

第三部分为权值融合部分, 主要作用是将不同阶段所获取的特征图进行融合, 就是进行一个类似于“与”的算法, 融合后可以得到最终的破碎矿石分

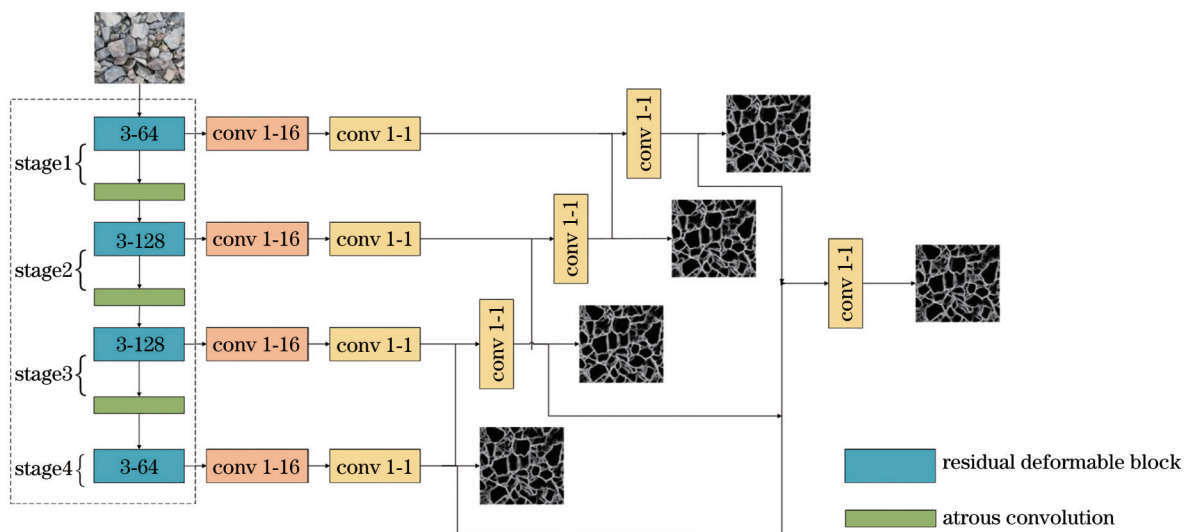


图 5 所提网络的框架结构

Fig. 5 Framework structure of proposed network

割图。

3.4 损失函数

损失函数作为衡量模型预测好坏的标准之一，其对模型有着重要的影响。本研究定义的损失函数即为所有像素点的二分类损失函数的和，表达式为

$$L_{\text{side}}(W, \tau) = \sum_{m=1}^M \alpha_m l_{\text{side},m}(W, \tau_m), \quad (5)$$

式中： l_{side} 表示边缘的输出代价； W 表示所有参数的集合； α_m 为 m 层加权融合之后的权重； M 为侧输出层的数量。

3.5 破碎矿石图像的分割流程

首先对在矿区采集的矿石图片进行预处理并制作训练集，使用训练好的改进 HED 网络模型对预处理后的图片进行训练，从而提取出矿石颗粒的轮廓。其次使用 OpenCV 软件对矿石的粒度进行统计计算，从而得到矿石粒度的具体分布情况和分割结果。在对矿石粒度大小的测定过程中主要利用 OpenCV 软件中的 findContours 算法、boundingRect 算法和 contourArea 算法，其中 findContours 算法是用来查找所有矿石颗粒的轮廓，boundingRect 算法是用来得到每个轮廓的最小外接矩形，contourArea 算法是用来计算外接矩形的面积。最后根据矩形面积的大小来得出矿石粒度的大小分布情况。

4 矿石图像分割实验

4.1 训练集与模型训练

由于矿山地理环境复杂，矿石破碎的过程中会产生大量的粉尘且弥漫在整个空间中，而且矿石颗粒表面凹凸不平，这会导致其对光线有不同的反射

情况，使得采集到的图像无法获得理想的效果。为了降低上述不利因素对图像分割结果的影响，需要对采集的矿石图像进行去噪的预处理。为了保证去噪的同时不损失矿石图像的边缘部分，将在传送带上采集的图像进行双边滤波的预处理，处理结果如图 6(a) 和图 6(b) 所示。




图 6 双边滤波处理前后的图像。(a) 矿石原图像；(b) 3×3 滤波窗口滤波后的图像

Fig. 6 Images before and after bilateral filtering. (a) Original image of ore; (b) image filtered by 3×3 filtering window

工业相机所采集的原始图像尺寸为 $3456 \text{ pixel} \times 4608 \text{ pixel}$ 。为了扩大训练集以及提高训练速度，从采集的图像中选取 800 张图像，并从中随机挑选一部分作为训练集，剩下的图像作为测试集，对训练集进行预处理后作为实验的样本集，最后利用 labelme 软件对训练集进行标注以制作标签集，样本集与对应的标签集构成了训练集。

利用预处理后的矿石图片来训练改进的 HED 网络，训练完成后提取矿石轮廓以选出最适宜的权

重模型,使用该模型对测试图像进行测试。模型的训练参数如表 1 所示。优化函数采用 Adam 函数,该函数具有计算高效和内存占用少的优点。实验硬件为具备 4 张 RTX2080 显卡的计算机,使用的编程语言为 Python,OpenCV 是在 Python3.5 环境下建立的,深度学习框架为 TensorFlow 和 Keras。

将本文设计的改进 HED 网络模型在 Adam 算法下进行训练,则模型的损失和准确率与迭代次数




图 7 改进 HED 网络模型的损失和准确率与迭代次数的关系。(a)损失;(b)准确率

Fig. 7 Relationship among loss, accuracy, and iterations of improved HED network model. (a) Loss; (b) accuracy

从图 7 可以看到,模型训练到第 44 次之后,损失值趋于平缓稳定的状态,说明模型基本收敛;模型的准确率在训练到 20 次后达到 0.929,并在其之后一直保持在一个高准确率的状态,其平均准确率为 0.92,由此可见改进的 HED 网络模型具有较高的精度。

4.2 实验结果与分析

为了更好地对实验结果进行有效性评估,利用人工绘制图像边缘并将绘制的图像作为标准图,将其与改进后的网络分割结果图进行对比,其中破碎矿石图像中每个轮廓的内部像素为 1,外部像素为 0。实验过程中,采用准确率(A)、召回率(R)和精确率(P)作为性能指标,表达式分别为

$$A = \frac{x_{TP} + x_{TN}}{x_{TP} + x_{FN} + x_{FP} + x_{TN}}, \quad (6)$$

$$R = \frac{x_{TP}}{x_{TP} + x_{FN}}, \quad (7)$$

$$P = \frac{x_{TP}}{x_{TP} + x_{FP}}, \quad (8)$$

式中: x_{TP} 表示算法图和标准图中像素值均为 1 的像素点数量; x_{FP} 表示测试结果图中像素值为 1 而标准图中像素值为 0 的像素点数量; x_{FN} 表示结果图中像素值为 0 而标准图中像素值为 1 的像素点数量; x_{TN} 表示结果图和标准图中像素值均为 0 的像素点

表 1 模型的训练参数

Table 1 Training parameters of model

Parameter	Value
Number of calculations	300
Iterations	100
Number of images per iteration	4
Number of training samples	1000

的关系如图 7 所示。

数量。

为了验证改进后网络的有效性,使用 Canny 算子、原始 HED 网络和改进 HED 网络对验证测试集中的 10 张图片进行对比实验,每张图片在不同网络模型下的准确率、召回率和精确率如表 2 所示。从表 2 可以看到,改进 HED 网络在准确率方面比 Canny 算子提升了 0.1569,引入可变形卷积和空洞卷积后的 HED 网络在召回率方面达到了 0.8144,而且在精确率方面达到了 0.9362,证实了改进网络的准确性。

为了测试改进的 HED 网络模型在破碎矿石图像分割中的应用效果,将其与 Canny 算子和原始 HED 网络的分割结果进行对比分析,三种模型对不同焦距下采集的破碎矿石照片的分割结果如图 8 所示。

从图 8 可以看到,Canny 算子无法对图像中较大块的矿石进行准确分割,尤其是矿石边缘部分,无法得到完整的矿石边缘线,小块矿石的分割效果也难以令人满意,存在严重的欠分割和过分割的现象,无法解决矿石粘连的问题;原始 HED 网络虽然可以分割出大块矿石和小块矿石,但也无法有效解决矿石粘连的问题,尤其是在粘连严重的位置几乎无法分割出边缘线;相比较而言,改进的 HED 网络模型的分割效果有了明显提升,能够将大块矿石和

表 2 不同网络的性能指标
Table 2 Performance indicators of different networks

Image	Accuracy			Recall			Precision		
	Canny	HED	Improved HED	Canny	HED	Improved HED	Canny	HED	Improved HED
1	0.7283	0.8172	0.9183	0.8162	0.8438	0.8275	0.8754	0.9219	0.9428
2	0.7882	0.8635	0.9117	0.8225	0.8035	0.8173	0.8829	0.9178	0.9537
3	0.7937	0.8879	0.9225	0.8156	0.8167	0.8158	0.8478	0.9378	0.9389
4	0.7014	0.8918	0.9308	0.8068	0.8124	0.8067	0.8513	0.9247	0.9409
5	0.7691	0.8815	0.9126	0.7995	0.8037	0.8117	0.8218	0.9345	0.9128
6	0.7437	0.8857	0.9215	0.8093	0.7969	0.8027	0.8145	0.9362	0.9390
7	0.7659	0.8972	0.9118	0.8109	0.8089	0.8164	0.8047	0.9419	0.9268
8	0.7573	0.8027	0.9169	0.8038	0.8129	0.8058	0.8439	0.9370	0.9503
9	0.7654	0.8896	0.9027	0.7995	0.8097	0.8187	0.8057	0.9105	0.9218
10	0.7715	0.8889	0.9047	0.8092	0.8126	0.8213	0.8120	0.9279	0.9348
Average	0.7585	0.8706	0.9154	0.8093	0.8121	0.8144	0.8360	0.9290	0.9362




图 8 不同网络模型的分割结果。(a)原图;(b) Canny算子;(c)原始HED网络;(d)改进的HED网络

Fig. 8 Segmentation results of different network models. (a) Original images; (b) Canny operator; (c) original HED network; (d) improved HED network

小块矿石在保证准确率的前提下分割出来,在粘连严重的位置也能得到大概的矿石边缘线(图 8 实线框),而且不需要复杂的参数调试就能较好地解决破碎矿石粘连而导致分割不准确的问题。

为了更好地描绘不同网络模型对分割破碎矿石的代价,则不同网络的耗时对比实验结果如表 3 所示。从表 3 可以看到,使用改进的 HED 网络模型对破碎矿石图像进行分割,分割一张图片的时间比原始

表 3 不同网络的耗时对比结果

Table 3 Time comparison results of different networks

Model	MIOU / %	Time / ms
Canny	72.62	128
HED	76.49	98
Improved HED	77.23	81

HED 网络模型快 17 ms,相较于 Canny 算子更是提升了 47 ms,而且平均交并比(MIOU)提高了 4.61 个百

分点,证明改进的HED网络模型在保证准确率的同时具有很好的实时性。

4.3 消融实验结果与分析

本文模型是在HED网络模型的基础上进行改进的,使用残差可变形卷积网络(DCN)来替代常规卷积网络,并在特征提取部分使用空洞卷积(DC)层来替代池化层。为了进一步分析改进的HED网络模型的性能,将本文网络模型拆分为三组实验,使用平均精确率(AP)作为评价指标,实验结果如表4所示。

表4 不同网络模型的消融实验结果

Table 4 Ablation experiment results of different network models

Experiment	DCN	DC	AP / %
1	×	×	85.47
2	✓	×	90.23
3	✓	✓	92.37

从表4可以看到,网络模型引入DCN后能够更好地提取不同大小矿石的特征信息,AP值提升了近5个百分点;继续引入DC后,网络模型增大了感受野,其能够更好地获取全局信息,AP值相对于第二组实验提升了2.14个百分点。综上,改进的HED网络模型能够有效提升分割效果。

5 结 论

针对破碎矿石粒度检测不准确以及矿石粘连而导致分割不准确的问题,提出一种基于改进HED网络模型的矿石图像分割以及粒度测定方法。使用Canny算子、原始HED网络模型以及改进HED网络模型来检测10张破碎矿石图像的分割情况,并将得到的结果进行比较。实验结果表明,改进的HED网络模型基本解决了矿石粘连所导致的分割不准确,双边滤波方法对图像清晰度的要求也有了明显的降低,适用于矿山的实际生产环境,而且矿石边缘的分割效果也大体符合要求,证明了改进的HED网络模型能够应用在矿山的实际生产作业中。

参 考 文 献

[1] Liu Y W, Liu M J. Influence of particle size on gas desorption and diffusion difference of soft and hard coal particles[J]. Journal of China Coal Society, 2015, 40(3): 579-587.
刘彦伟,刘明举.粒度对软硬煤粒瓦斯解吸扩散差异性的影响[J].煤炭学报,2015,40(3):579-587.

[2] Wang S M, Sun Q, Qiao J W, et al. Geological guarantee of coal green mining[J]. Journal of China Coal Society, 2020, 45(1): 8-15.
王双明,孙强,乔军伟,等.论煤炭绿色开采的地质保障[J].煤炭学报,2020,45(1):8-15.

[3] Zhang B B, Mahemuti P. Improved flame target detection algorithm based on YOLOv3[J]. Laser & Optoelectronics Progress, 2021, 58(24): 2411003.
张彬彬,帕孜来·马合木提.基于YOLOv3改进的火焰目标检测算法[J].激光与光电子学进展,2021,58(24):2411003.

[4] Zhang J Q, Li X Y, Li L Y, et al. Landsat 8 remote sensing image based on deep residual fully convolutional network[J]. Laser & Optoelectronics Progress, 2020, 57(10): 102801.
张家强,李潇雁,李丽圆,等.基于深度残差全卷积网络的Landsat 8遥感影像云检测方法[J].激光与光电子学进展,2020,57(10):102801.

[5] He C E, Xu H J, Wang Z, et al. Automatic segmentation algorithm for multimodal magnetic resonance-based brain tumor images[J]. Acta Optica Sinica, 2020, 40(6): 0610001.
何承恩,徐慧君,王忠,等.多模态磁共振脑肿瘤图像自动分割算法研究[J].光学学报,2020,40(6):0610001.

[6] Zhang H L, Li Q, Guan X. An improved three-dimensional dual-path brain tumor image segmentation network[J]. Acta Optica Sinica, 2021, 41(3): 0310002.
张恒良,李镛,关欣.一种改进的三维双路径脑肿瘤图像分割网络[J].光学学报,2021,41(3):0310002.

[7] Xu C, Wang L. Image semantic segmentation method based on improved DeepLabv3+ network[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1610008.
徐聪,王丽.基于改进DeepLabv3+网络的图像语义分割方法[J].激光与光电子学进展,2021,58(16):1610008.

[8] Truong M T N, Kim S. Automatic image thresholding using Otsu's method and entropy weighting scheme for surface defect detection[J]. Soft Computing, 2018, 22(13): 4197-4203.

[9] Yang Y, Li L W, Jiang W C, et al. Multi target detection of high resolution remote sensing image based on optimized Yolo v3 network[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1601002.
杨耘,李龙威,江万成,等.基于优化Yolo v3网络的高分遥感影像多目标检测[J].激光与光电子学进展,2021,58(16):1601002.

- [10] Liu X B, Zhang Y W. Ore image segmentation method of conveyor belt based on U-net and Res_UNet models[J]. Journal of Northeastern University (Natural Science), 2019, 40(11): 1623-1629.
柳小波, 张育维. 基于 U-Net 和 Res_UNet 模型的传送带矿石图像分割方法[J]. 东北大学学报(自然科学版), 2019, 40(11): 1623-1629.
- [11] Dong K, Jiang D L. Ore image segmentation algorithm based on improved watershed transform[J]. Computer Engineering and Design, 2013, 34(3): 899-903.
董珂, 蒋大林. 基于改进分水岭变换的矿石图像分割算法[J]. 计算机工程与设计, 2013, 34(3): 899-903.
- [12] Lu C W, Qi F, Ruan S L. Grade determination of fine grain ore based on depth image analysis[J]. Journal of Applied Sciences, 2019, 37(4): 490-500.
卢才武, 齐凡, 阮顺领. 基于深度图像分析的细粒度矿石分级测定方法[J]. 应用科学学报, 2019, 37(4): 490-500.
- [13] Zhou J, Yang F, Shi L Y, et al. Ore image segmentation by bipartite graph based on collaborative representation[J]. Computer Engineering, 2016, 42(10): 236-241.
周静, 杨凡, 史凌祎, 等. 基于协同表征的二部图矿石图像分割[J]. 计算机工程, 2016, 42(10): 236-241.
- [14] Yuan L, Duan Y Y. A method of ore image segmentation based on deep learning[M]//Huang D S, Gromiha M M, Han K, et al. Intelligent computing methodologies. Lecture notes in computer science. Cham: Springer, 2018, 10956: 508-519.
- [15] Zhang G Y, Liu G Z, Zhu H, et al. Ore image thresholding using bi-neighbourhood Otsu's approach [J]. Electronics Letters, 2010, 46(25): 1666-1668.
- [16] Zhang J L, Ye P K, Sun S S. Detection of ore granularity based on morphological image processing [J]. Machinery Design & Manufacture, 2020(3): 68-71.
张建立, 叶平坤, 孙深深. 形态学图像处理下的矿石粒度的检测[J]. 机械设计与制造, 2020(3): 68-71.
- [17] Malladi S R S P, Ram S, Rodriguez J J. Superpixels using morphology for rock image segmentation[C]//2014 Southwest Symposium on Image Analysis and Interpretation, April 6-8, 2014, San Diego, CA, USA. New York: IEEE Press, 2014: 145-148.
- [18] Jiao A B, He M, Luo H B. Research on significant edge detection of infrared image based on deep learning[J]. Infrared Technology, 2019, 41(1): 72-77.
焦安波, 何淼, 罗海波. 一种改进的 HED 网络及其在边缘检测中的应用[J]. 红外技术, 2019, 41(1): 72-77.
- [19] Mu G W, Guo Y, Quan X H, et al. Magnetic resonance imaging brain tumor image segmentation based on improved U-Net[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0410022.
牟海维, 郭颖, 全星慧, 等. 基于改进 U-Net 的磁共振成像脑肿瘤图像分割[J]. 激光与光电子学进展, 2021, 58(4): 0410022.
- [20] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04) [2021-03-01]. <https://arxiv.org/abs/1409.1556>.
- [21] Dai J F, Qi H Z, Xiong Y W, et al. Deformable convolutional networks[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 764-773.