

DOI:10.13409/j.cnki.jdpme.20231108005

改进U-Net模型的隧道掌子面图像语义分割研究*

陈登峰, 程静, 赵蕾, 何拓航

(西安建筑科技大学 建筑设备科学与工程学院, 陕西 西安 710000)

摘要: 隧道掌子面岩体结构是判断岩土工程地质条件、制定施工和支护方案、预防塌方及涌水等事故的直观依据。将U-Net模型应用于掌子面岩体结构图像分割与识别时,下采样过程中缩小图像尺寸会导致岩体部分细节信息丢失,上采样过程中将低层特征传递到高层的跳跃连接导致特征映射过大。因此,提出加入空洞空间卷积池化金字塔模块ASPP和卷积注意力模块CBAM的改进U-Net模型。在U-Net模型的跳跃连接过程中加ASPP,利用不同膨胀率的空洞卷积捕获不同尺度的上下文信息,融合不同感受野的信息,从而更全面的理解图像内容;U-Net模型的下采样过程中加入CBAM,使网络模型更加关注有用的特征,从而增强特征的表达能力。实验结果表明,改进的网络模型相较于原始U-Net模型分割和识别性能有显著提升,在某隧道工程掌子面岩体图像数据集上Precision达到93.04%,mIoU达到74.98%,mPA达到78.89%。

关键词: 隧道掌子面; 图像语义分割; 卷积注意力模块; 空洞空间卷积池化金字塔模块

中图分类号: U45 **文献标识码:** A **文章编号:** 1672-2132(2025)04-0776-08

Semantic Segmentation of Tunnel Handheld Noodle Rock Mass Structure Images with Improved U-Net Model

CHEN Dengfeng, CHENG Jing, ZHAO Lei, HE Tuohang

(School of Building Services Science and Engineering, Xi'an University of Architecture and Technology, Xi'an 710000, China)

Abstract: The structural characteristics of the rock mass exposed at the tunnel face provide a direct basis for assessing geotechnical conditions, formulating construction and support strategies, and mitigating risks of accidents such as collapses and water inrush. When applying the U-Net model to the segmentation and recognition of tunnel face rock mass structure images, the downsampling process can lead to the loss of fine details in the rock mass, while the skip connections used during upsampling to transfer low-level features to higher levels may cause excessively large feature maps. To address these issues, an improved U-Net model is proposed by incorporating the Atrous Spatial Pyramid Pooling (ASPP) module and the Convolutional Block Attention Module (CBAM). Specifically, the ASPP is integrated into the skip connections of the U-Net model to capture multi-scale contextual information through atrous convolutions with varying dilation rates, enabling the fusion of features from diverse receptive fields for a more comprehensive understanding of image content. Concurrently, the CBAM is

* 收稿日期:2023-11-08;修回日期:2024-04-01

基金项目:陕西省自然科学基金面上项目(2024JC-YBMS-286)、西安市科技计划项目(2023JH-GXRC-0216, 2024JH-KGDW-0112)、前沿交叉领域培育专项项目(X20230072)资助

作者简介:陈登峰(1976—),男,副教授,硕导,博士。主要从事智慧岩土工程研究。E-mail:chdengf@xauat.edu.cn

embedded into the downsampling process of the U-Net model to enhancing the network focus more on useful features, thereby enhancing the representation capability of the extracted features. Experimental results demonstrate that the improved network model significantly outperforms the original U-Net in both segmentation and recognition performance. Evaluated on a tunnel face rock mass image dataset from a specific engineering project, the improved model achieves a Precision of 93.04%, mean Intersection over Union (mIoU) of 74.98%, and a mean Pixel Accuracy (mPA) of 78.89%.

Keywords: tunnel palm-leaf noodles; image semantic segmentation; convolutional attention module; dilated spatial pyramid pooling module

0 引言

地质灾害会对隧道工程带来严重经济损失并威胁到施工人员的生命安全^[1-2]。隧道地质结构类型复杂,岩体结构对于理解地质历史、预测岩石性质、分析岩石稳定性以及进行地质工程和勘探具有重要意义。隧道掌子面岩体结构图像是判断岩土工程地质条件直观和准确的依据,能够对其进行准确分割与识别,获取岩体结构类型、岩体结构完整程度和地下水的情况等,有利于围岩分级和风险预估,预防掌子面塌方、涌水等事故。

图像分割技术广泛应用于农业、工业、医学等领域和自动驾驶^[3]、机器人、无人机的避障、跟踪和路径规划^[4]、医学图像影像处理^[5]等场景。基于数字图像处理、拓扑学和数学模型,主要采用基于阈值^[6-7]、基于区域图像^[8]、基于边缘检测^[9]和基于超像素^[10]的分割方法等。Zhu等^[11]基于相邻像素点,提出了一种区域生长算法,并采用各向异性扩散滤波对图像进行了滤波去噪,从而实现了图像的精确分割。Lu等^[12]在Prewitt算子的基础之上,提出一种对纤维边缘分割的方法,验证数字分析对纺织物测量的可行性。

由于隧道掌子面图像特征比较复杂,这些传统的方法普遍提取图像的上下文信息和空间信息不充分,分割效率和分割精度比较低。基于深度学习的图像分割如U-Net网络、全卷积网络FCN、Debseg-Net网络^[13]、多尺度特征融合^[14]和注意力机制^[15]的采用有效提高了图像分割精度。2015年,Ronneberger^[16]等提出编码器和解码器完全对称的U-Net网络用于图像语义分割,该模型通过将低层与高层图像特征进行融合拼接,达到提升分割精度的目的。He^[17]等基于U-Net模型提出ST-UNet模

型,采用一个增强模块将Swin Transformer和CNN两个编码器进行融合,有效提高了图像分割的性能。

U-Net网络在下采样进行特征提取时,会丢失一部分细节信息,导致分割精度不高;在跳跃连接过程中,直接利用通道拼接引入浅层空间信息则融合了大量冗余信息。针对以上问题,本文运用卷积注意力模块(Convolutional Block Attention Module, CBAM)和空洞空间卷积池化金字塔模块(Atrous Spatial Pyramid Pooling, ASPP),对U-Net模型进行改进,以提高掌子面岩体图像分割的准确性。

1 网络模型

1.1 U-Net模型

U-Net模型主要由编码器(Encoder)和解码器(Decoder)两部分组成,如图1所示。在编码阶段,输入图像通过一系列卷积、池化操作逐步进行下采样;在解码阶段,逐步进行上采样并通过反卷积操作增加空间分辨率。在各个步骤中,编码器将低级特征与对应的解码器特征进行合并,通过跳跃连接与更高级别的特征进行融合。

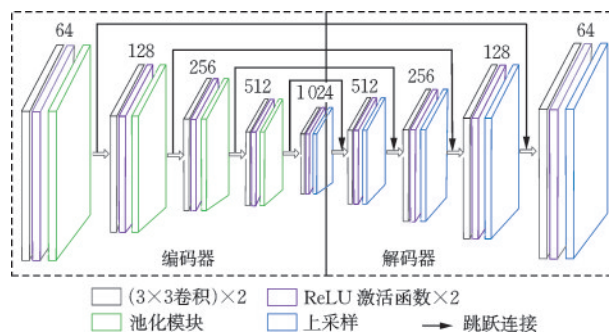


图1 U-Net模型

Fig.1 U-Net Model

U-Net在许多图像分割任务中表现出色,但U-Net在下采样过程中涉及到缩小图像尺寸会导致部分细节信息的丢失,跳跃连接直接将低层特征传递到高层,会导致上采样过程中特征映射的过大,生成的特征图具有较高的空间分辨率,甚至会造成过拟合和反向传播过程中的梯度消失或爆炸。在隧道掌子面岩体结构图像中,有些岩体目标特征比较复杂,岩体之间边缘区分不明显以及边缘比较粗糙等问题,对U-Net图像语义分割模型用于隧道掌子面岩体结构图像的分割提出了更高的要求。

1.2 改进的U-Net模型

针对隧道掌子面岩体结构图像的特点,在U-Net模型中加入卷积注意力模块CBAM和空洞空间卷积池化金字塔模块ASPP模块,以提升分割网络的性能,如图2所示。

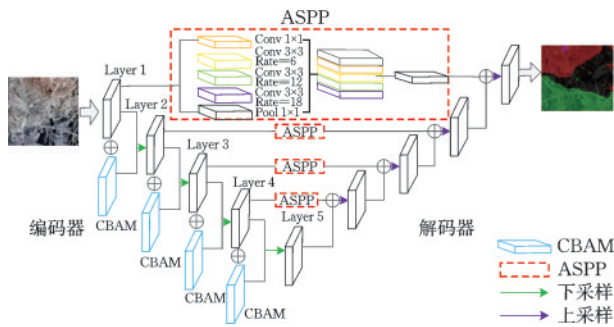


图2 改进的网络模型

Fig.2 The improved network model

在下采样阶段加入CBAM模块,使网络更好的学习权值信息,并对不同的特征通道赋予不同的权值,提高有用信息的利用率,进而获得更多的有用信息,从而增强全局上下文感知能力,使网络更好地理解整体图像的语义结构。在跳跃连接过程中加入ASPP模块,扩张卷积采用不同扩张率提取多尺度特征,以更好地捕获目标物体的边界特征,还能减少信息损失,保留更多的原始图像信息,提升分割边界的精度和性能。

1.2.1 CBAM 模块

CBAM^[18]包含通道注意力模块(CAM')和空间注意力模块(SAM)两个独立子模块,如图3和图4所示。




图3 CAM'模块

Fig.3 Channel Attention Module'




图4 SAM 模块

Fig.4 Spatial Attention Module

SAM模块通过最大池化和平均池化操作对特征图进行处理,再通过 7×7 卷积运算将结果拼接,最后通过sigmoid函数得到 $C \times H \times W$ 空间注意力特征图。如式(1)所示:

$$SAM = \delta(f^{7 \times 7}([\text{Avgpool}(A); \text{MaxPool}(A)])) \quad (1)$$

CAM'模块通过最大池化和平均池化操作得到一个特征图,再经过共享的MLP模块和ReLU激活函数处理,最后通过sigmoid函数得到 $C \times 1 \times 1$ 通道注意力特征图。如式(2)所示:

$$CAM' = \delta([\text{MLP}(\text{AvgPool}(A)); \text{MLP}(\text{MaxPool}(A)); A]) \quad (2)$$

CBAM首先将输入特征图A通过CAM'生成通道注意力权重,然后乘以原始输入特征图得到特征图M;将特征图M传递到SAM生成空间注意力权重,并与特征图M逐元素相乘,得到输出特征图B。如式(3)所示:

$$B = SAM \times CAM' \times A \quad (3)$$

式中, δ 表示sigmoid激活函数;A和B表示图3和图5特征图,C表示通道数,H和W表示特征图的高和宽, $SAM \in 1 \times H \times W$, $CAM' \in C \times 1 \times 1$, $A \in C \times H \times W$, $f^{7 \times 7}$ 表示一个具有 7×7 大小的卷积运算。




图5 CBAM 模块

Fig.5 Convolutional Block Attention Module

1.2.2 ASPP 模块

ASPP^[19]模块用于实现不同感受野尺度下的信息提取。ASPP使用多个不同扩张率的空洞卷积,在卷积核中引入扩张率来调整有效感受野,从而捕获多个尺度下的上下文信息。在每个扩张率下,ASPP对输入特征图进行最大池化或平均池化等操作,再将不同尺度下的池化结果融合成一个综合特征,并输出融合后的特征图,如图6所示。

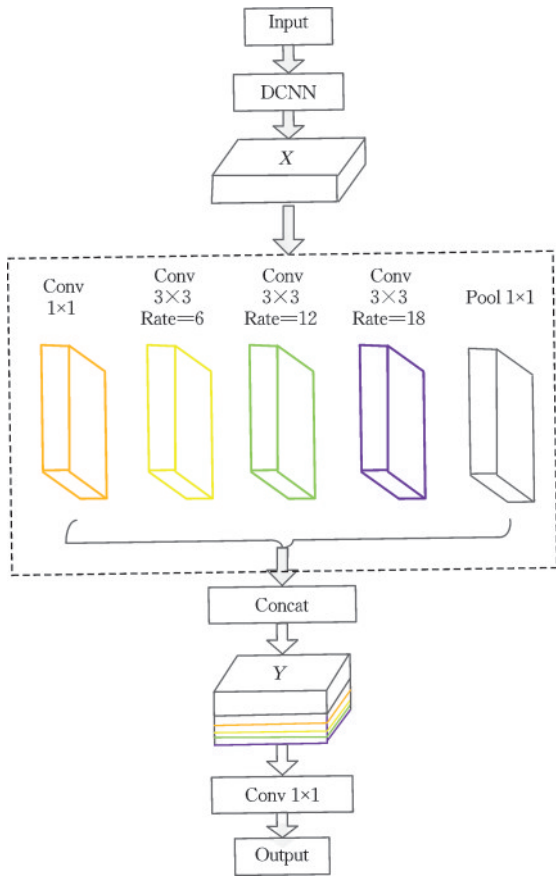


图6 ASPP模块

Fig.6 Atrous Spatial Pyramid Pooling

1.3 激活函数

通过激活函数引入非线性变换,使得神经网络能够学习和表示复杂的非线性关系。在神经网络的每个神经元上应用激活函数,将输入信号转换为输出信号并传递到下一层,每层网络所接收的特征图输入为上一层网络的输出特征图。

在卷积层使用ReLU激活函数学习图像的抽象特征,反卷积层采用ReLU激活函数帮助还原图像的一些细节特征。激活函数ReLU为:

$$F_i = \begin{cases} 0, & Q_i < 0 \\ Q_i, & Q_i \geq 0 \end{cases} \quad (i=1, \dots, N) \quad (4)$$

其中, N 为输入特征图的大小; Q_i 为输入特征图的第 i 个值, F_i 为对应的输出。

采用Softmax函数用于模型的输出层,以进行像素级的分类,激活函数Softmax为:

$$F_i = e^{x_i} / \sum_{j=1}^N e^{Q_j} \quad (5)$$

其中, F_i 表示Softmax函数的输出值,表示在给定输入向量 x 的情况下,第 i 个元素的概率。 e^{x_i} 表示输入向量 Q 的元素经过指数运算并求和, N 是输入向量的长度。

2 案例研究

2.1 数据预处理

本文在某隧道工程中所获得的隧道掌子面图像岩体结构种类有斑岩、花岗岩、风化、破碎带和松散土和背景6种类型(表1中类别数)。由于获得的图像像素不同,将获得的原始图像统一裁剪为 448×448 像素的图像,进行图像数据扩增后得到实验数据集5700张。常见岩体结构如图7所示。




图7 岩体结构类型

Fig.7 Rock Mass Structure Types

2.2 实验环境

实验平台环境:Windows 10操作系统,Python 3.9编程语言,显卡:GeForce RTX 3090,显存为24 G,CUDA版本11.1,CUDNN版本8,Intel(R) Xeon(R) CPU E5-2678 v3 @ 2.50 GHz。

经过多次实验,优化参数设置如表1。

表1 改进的U-Net模型参数

num_classes(岩体结构类别数)	6
input_shape(输入张量形状)	448×448
batch size(批量大小)	2
Optimizer(算法优化器)	Adam
Training: Test(训练集:验证集)	9:1
Learning Rate(学习率)	0.000 1
Activation(激活函数)	ReLU
Epochs(迭代次数)	100

2.3 评价指标

采用图像分割中常用的像素准确率(pixel accuracy, PA)、交并比(intersection over union, IoU)、精确度(Precision)和召回率(Recall)这些评价指标对分割效果进行准确性评价。

PA表示类别预测正确的像素数目与总像素的比值,计算公式如下:

$$PA = \frac{\sum_{i=1}^n P_{ii}}{\sum_{i=1}^n \sum_{j=1}^n P_{ij}} = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

IoU表示类别预测结果和真实结果的交集与并集之比,计算公式如下:

$$IoU = \frac{P_{ii}}{\sum_{j=1}^n P_{ij} + \sum_{j=1}^n (P_{ij} - P_{ii})} = \frac{TP}{TP + FP + FN} \quad (7)$$

Precision表示预测结果为正例实际也为正例的像素占预测为正例的像素的比值,计算公式如下:

$$Precision = \frac{TP}{TP + FP} \quad (8)$$

Recall表示预测结果为正例实际也为正例的像素占实际为正例的像素的比值,计算公式如下:

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

其中, n 为类别总数(视分割类型调整); P_{ii} 指真实值为 i , 预测值为 i 的像素数; P_{ij} 指真实值为 i , 预测值为 j 的像素数; TP(true positives)为真正例, FP(false positives)为假正例, FN(false negatives)为假反例, TN(true negatives)为真反例。

PA、IoU、Precision 和 Recall 的取值范围均为 $(0, 1)$, 且越大越好。

3 结果与分析

3.1 对比实验

对相同的隧道掌子面岩体图像训练样本集和测试样本集,采用 PSPnet^[20]、U-Net、Deeplabv3^[21]、FCN^[22]与本文提出的改进 U-Net 模型进行图像语义分割对比实验。

由于各模型训练 100 轮时均已收敛至最佳性能,为了保证模型训练结果对比的有效性,因此各模型训练次数均设置为 100 轮。

PSPnet、Deeplabv3、FCN、U-Net 和本文模型对花岗岩、斑岩、风化、松散土和破碎带等五类常见岩体结构的整体对比结果见图 8, 分割结果见表 2。表 2 中粗体字表示每类模型的评价指标最高值。

从图 8 和表 2 可以看出,相较于其他模型,本文所提出的模型分割与识别性能和分割精度相较于其他模型整体较优。

由于隧道岩体结构图像包含复杂的纹理、结构和形状信息,捕捉这些信息需要强大的特征表示能力。PSPnet、Deeplabv3 和 FCN 等模型由于局部感受野较小,无法很好地捕捉全局信息,对包含复杂纹理和结构的隧道岩体结构图像分割效果不太理想;U-Net 模型分割能力相对较好,但由于一些岩体结构之间有一定的相似性,导致模型在训练的过程中很难分辨,因此分割效果有待提高;本文提出的改进 U-Net 模型加入了 CBAM 模块和 ASPP 模块,不仅使模型更好的关注重要信息并动态调整注意力,还以不同感受野捕捉图像信息,有效增强了模型的学习能力,对五类岩体类型的分割结果 IoU、Recall 和 Precision 三项指标总体效果较好。

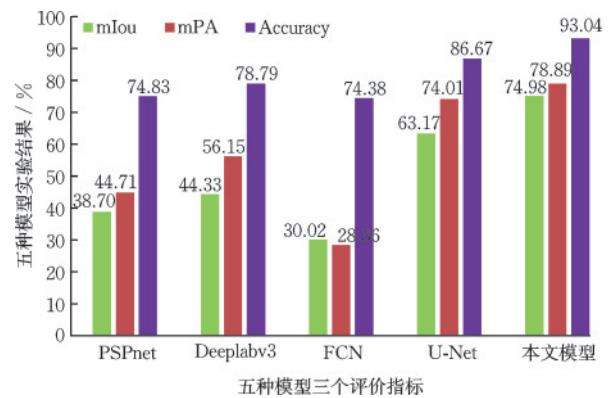


图8 不同模型100轮实验结果
Fig.8 Results of 100 rounds of experiments on different models

表 2 不同模型对五类岩体的分割结果

Table 2 Different Models' Segmentation Results for Five Rock Mass Types

岩体类型/ 评价指标	模型	PSPnet	Deeplabv3	FCN	U-Net	本文模型
斑岩	IoU	71.37	74.47	69.93	86.40	87.31
	Recall	78.85	77.89	61.79	90.38	94.82
	Precision	78.39	82.99	72.16	88.17	91.68
花岗岩	IoU	39.83	48.50	35.06	72.49	74.51
	Recall	42.83	54.39	28.72	81.37	81.22
	Precision	85.05	81.75	42.49	86.92	87.67
破碎带	IoU	28.75	42.62	36.35	52.71	72.39
	Recall	31.06	43.43	35.27	61.59	70.38
	Precision	38.65	86.75	41.45	63.24	65.65
风化	IoU	52.35	61.57	56.70	74.85	80.23
	Recall	71.68	84.56	63.82	86.16	89.36
	Precision	66.01	69.38	67.16	90.28	88.74
松散土	IoU	32.19	54.19	49.26	71.82	75.01
	Recall	64.47	81.72	58.48	80.56	81.29
	Precision	39.12	61.66	42.17	86.88	89.69

3.2 消融实验

在原始 U-Net 模型分别加入 CBAM 模块和 ASPP 模块,并与原始 U-Net 模型进行性能比较,探究 CBAM 模块和 ASPP 模块对改进 U-Net 模型的影响,结果如图 9 所示。

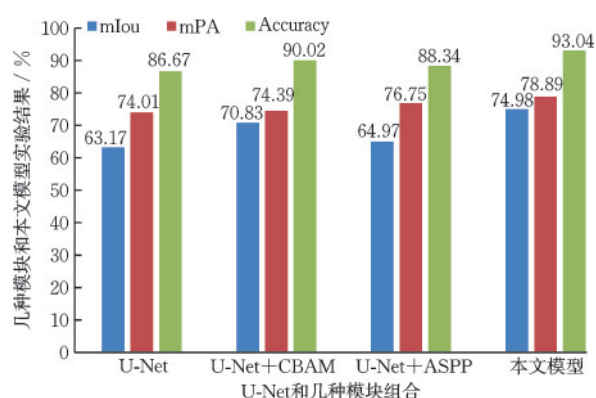


图 9 各模块对整体模型的性能影响

Fig.9 The Impact of Each Module on the Overall Model

由图 9 可知,相较于原始 U-Net 模型,加入 CBAM 和 ASPP 对模型的分割效果和分割准确性都起到了积极作用。

(1)在下采样部分加入注意力机制 CBAM 使网络能够在通道和空间维度上自适应地选择和强调

重要的特征信息, mIoU 提升 7.66%, mPA 提升 0.38%, Accuracy 提升 3.35%。

(2)在跳跃连接处引入 ASPP 后,不同扩张率的空洞卷积能更全面地融合多尺度信息,从而提升模型在像素级别的语义分割任务中的准确性, mIoU 提升 1.80%, mPA 提升 2.74%, Accuracy 提升 1.67%。

(3)本文改进 U-Net 模型在隧道掌子面岩体结构语义分割方面的性能优于原始 U-Net 模型, mIoU 提高 11.81%, mPA 提高 4.88%, Accuracy 提高 6.37%。

3.3 图像分割结果对比

将原图、标签图、Deeplabv3、PSPnet、FCN、U-Net 和本文模型的分割结果如图 10 所示。输入图像与输出分割效果图均为 448×448 的 RGB 图像。

由图 10 可见:FCN 对五类岩体分割结果与标签图相差较大,很多岩体结构都未能分割开; PSPnet 模型对风化分割效果较好,但是对破碎带几乎全部漏分、将花岗岩和斑岩错分,整体分割效果最差; Deeplabv3 模型对风化和松散图分割效果较好,但是对破碎带和斑岩存在大量漏分现象,整体分割效果较差; U-Net 分割结果与实际标签图较相

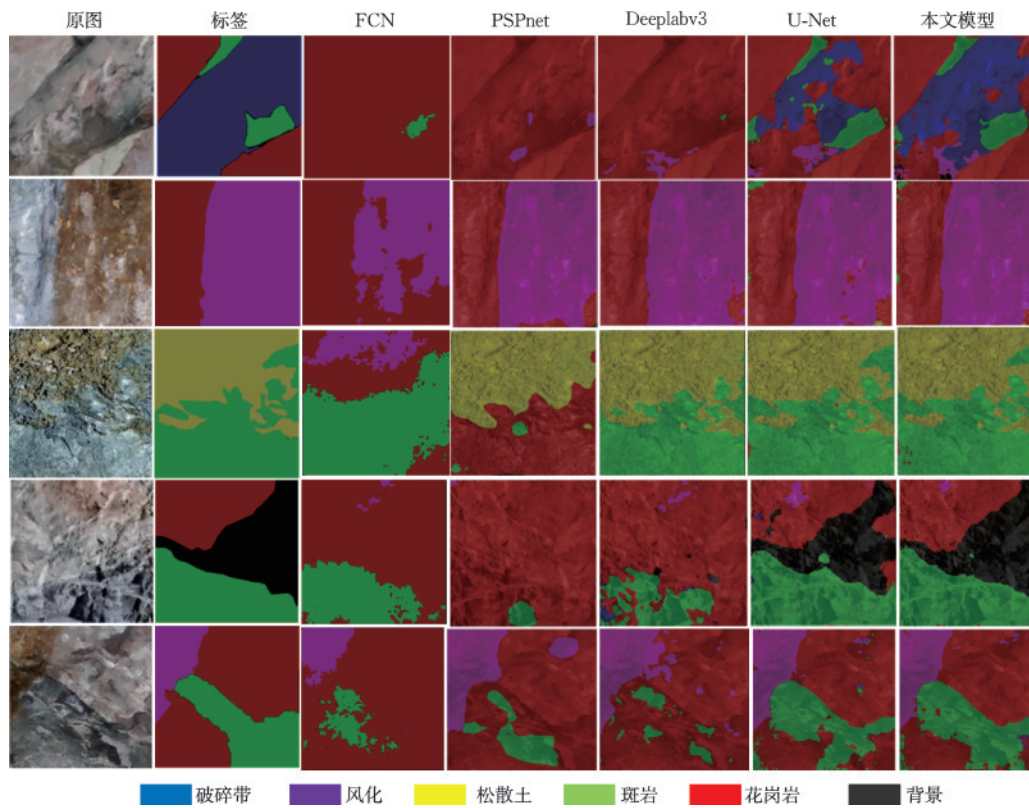


图 10 岩体结构图像显示结果对比

Fig.10 Comparison of Rock Mass Structure Image Display Results

似,对五类岩体错分和漏分较低,整体分割效果较好;本文所提改进 U-Net 模型分割效果较原始 U-Net 模型与实际标签图更为接近,细节信息更为清晰,分割效果和分割准确性有所提升。

4 结 论

针对隧道掌子面岩体结构图像分割需求,在原始 U-Net 模型基础上,融合卷积注意力模块 CBAM 和空洞空间金字塔池化模块 ASPP,提出改进的 U-Net 语义分割模型。通过实验,得出如下结论:

(1)本文改进的 U-Net 模型相较于原始 U-Net 模型分割算法精度较优,mIoU 提高 11.81%,mPA 提高 4.88%,Accuracy 提高 6.37%。

(2)本文改进的 U-Net 模型可以很好实现对隧道掌子面岩体结构的语义分割,在某隧道工程掌子面岩体图像数据集上 Precision 达到 93.04%。

(3)本文所提的图像语义分割方法对样本依赖性较强,对于有遮挡或模糊的图像的数据集的分割效果需要进一步研究。

参 考 文 献:

- [1] Pieter E S, Petr T, Petra T, et al. Characterizing the uppermost 100m structure of the San Jacinto fault zone southeast of Anza, California, through joint analysis of geological, topographic, seismic and resistivity data[J]. *Geophysical Journal International*, 2020, 222(1): 781-794.
- [2] Jean-Claude B, Rigobert T, Joachim E, et al. Geological context mapping of Batouri Gold District (East Cameroon) from Remote sensing imaging, GIS processing and field works[J]. *Journal of Geographic Information System*, 2019, 11(6): 766-783.
- [3] Geiger A, Lenz P, Urtasun R. Are we ready for autonomous driving? The KITTI vision benchmark suite [C]//*Proceedings of IEEE Conference on Computer Vision & Pattern Recognition*, New York: IEEE, 2012, 3354-3361.
- [4] Ohgushi T, Horiguchi K, Yamanaka M. Road Obstacle Detection Method Based on an Autoencoder With Semantic Segmentation [C]//*Proceedings of the Asian Conference on Computer Vision*. Springer, Cham, 2020: 223-238.

- [5] 段杰,崔志明,沈艺,等.一种改进FCN的肝脏肿瘤CT图像分割方法[J].图学学报,2020,41(1):100-107.
Duan J, Cui Z M, Shen Y, et al. A CT image segmentation method for liver tumor by an improved FCN[J]. Journal of Graphics, 2020, 41(1): 100-107. (in Chinese)
- [6] Otsu N. A threshold selection method from gray-level histograms[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9(1): 62-66.
- [7] Yen J C, Chang F J, Chang S. A new criterion for automatic multilevel thresholding[J]. IEEE Transactions on Image Processing, 1995, 4(3): 370-378.
- [8] Khani H, Hamdi H, Nghiem L, et al. An Improved Regional Segmentation for Probability Perturbation Method[C]//Proceedings of the 79th Eage Conference and Exhibition. Paris, France: [s.n.], 2017.
- [9] Wang H, Oliensis J. Generalizing edge detection to contour detection for image segmentation[J]. Computer Vision & Image Understanding, 2010, 114(7): 731-744.
- [10] Achanta R, Shaji A, Smith K, et al. SLIC superpixels compared to state-of-the-art superpixel methods [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274-2282.
- [11] Zhu W, Shen Y. A region growing segmentation approach for MRI brain image processing[C]//Proceedings of IEEE 13th International Conference on Anti-counterfeiting, Security, and Identification. Xiamen: [s.n.], 2019: 188-191.
- [12] Lu S, Xin B, Deng N, et al. Investigation of cross-sectional image analysis method to determine the blending ratio of polyester/cotton yarn[J]. Journal of Microscopy, 2020, 279(1): 16-25.
- [13] 覃本学,沈疆海,马丙鹏,等.基于Debseg-Net的岩屑图像语义分割[J].科学技术与工程,2022,22(29):12927-12935..
Qin B, Shen J, Ma B, et al. Semantic segmentation of rock debris image based on Debseg-Net [J]. Science Technology and Engineering, 2022, 22(29), 12927-12935. (in Chinese).
- [14] Wang X, Li Z, Huang Y, et al. Multimodal medical image segmentation using multi-scale context-aware network [J]. Neurocomputing, 2022, 486: 135-146.
- [15] Zou L, Zhang Z, Du H, et al. DA-IMRN: Dual-attention-guided interactive multi-scale residual network for hyperspectral image classification[J]. Remote Sensing, 2022, 14(3): 530.
- [16] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [C]//Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015, 9351: 234-241.
- [17] He X, Zhou Y, Zhao J, et al. Swin transformer embedding U-Net for remote sensing image semantic segmentation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-15.
- [18] Woo S, Park J, Lee J Y. et al. CBAM: Convolutional block attention module[C]//Proceedings of the European conference on computer vision. Cham: Springer, 2018, 11211: 3-19.
- [19] Chen L-C, 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.
- [20] Zhao H, Shi J, Qi X, et al. Pyramid Scene Parsing Network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, New York: IEEE Press, 2017: 6230-6239.
- [21] Chen L C, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C] //Proceedings of the European conference on computer vision. Cham: Springer, 2018: 801-818.
- [22] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE Press, 2015: 3431-3440.

(本文编辑:周小潭)