

胡健健, 何小海, 龚剑, 等. 基于改进 DeeplabV3+的岩心图像裂缝提取算法[J]. 智能计算机与应用, 2025, 15(1): 1-9. DOI: 10.20169/j.issn.2095-2163.24110508

基于改进 DeeplabV3+的岩心图像裂缝提取算法

胡健健¹, 何小海¹, 龚剑², 卿粼波¹, 滕奇志¹

(1 四川大学 电子信息学院, 成都 610041; 2 成都西图科技有限公司, 成都 610065)

摘要: 岩心裂缝对于油气勘探有着重要意义,是宝贵的地质研究资料,对岩心裂缝图像进行裂缝提取有助于地质专家进行后续的研究工作。岩心裂缝图像存在着裂缝细小、裂缝和背景区域像素值接近等问题,已有的图像分割算法对裂缝提取效果不佳。为了改善岩心裂缝的提取效果,本文提出基于改进 DeeplabV3+的岩心图像裂缝提取算法。本文算法设计了新的解码器,对图像进行充分多尺度特征融合,增强了模型对裂缝边缘细节的表征能力;同时,引入条形池化模块(SPM),作为空洞空间金字塔池化模块(ASPP)中的池化层,从而有效减少了背景区域对裂缝目标提取的干扰。实验结果表明,提出的基于改进 DeeplabV3+的岩心图像裂缝提取算法,相比于原始 DeeplabV3+网络,改进算法在 $mIoU$ 、 mPA 、 $F1$ - Score 上分别提升了 1.88%、4.49%、3.02%。

关键词: 岩心裂缝图像; DeeplabV3+; 多尺度特征融合; 条形池化

中图分类号: TP183

文献标志码: A

文章编号: 2095-2163(2025)01-0001-09

Improved DeeplabV3+ algorithm for fracture extraction in core images

HU Jianjian¹, HE Xiaohai¹, GONG Jian², QING Linbo¹, TENG Qizhi¹

(1 College of Electronics and Information Engineering, Sichuan University, Chengdu 610041, China;

2 Chengdu Xitu Technology Co. Ltd., Chengdu 610065, China)

Abstract: Core fractures are of great significance for oil and gas exploration and serve as valuable geological research data. Extracting fractures from core fracture images helps geological experts in subsequent research work. However, core fracture images face challenges such as tiny fractures and pixels in the fracture and background areas being close in value, leading to unsatisfactory results from existing image segmentation algorithms. To improve the extraction of core fractures, this paper proposes an algorithm based on an improved DeeplabV3+ for fracture extraction from core images. The proposed algorithm designs a new decoder that fully performs multi-scale feature fusion on the image, enhancing the model's ability to capture detailed fracture edges. Additionally, a Strip Pooling Module (SPM) is introduced as the pooling layer in the Atrous Spatial Pyramid Pooling (ASPP), effectively reducing interference from the background areas during fracture target extraction. Experimental results demonstrate that the proposed Improved DeeplabV3+ Algorithm for Fracture Extraction in Core Images shows good performance in extracting fractures from core fracture images, with enhancements of 1.88%, 4.49%, and 3.02% in $mIoU$, mPA , and $F1$ Score, respectively, compared to the original DeeplabV3+ network.

Key words: core fracture images; DeeplabV3+; multi-scale feature fusion; strip pooling

0 引言

由地质应力、岩石变形或流体运动等地质作用引起的岩石表面形成的破裂,称之为岩心裂缝。岩

心裂缝是重要的油气储藏渗透空间,对油气运移起着关键作用,是重要的地质研究资料。岩心图像中裂缝的提取,对于地质专家研究地质构造、资源勘探有着重要意义。传统的岩心图像裂缝提取主要依靠

基金项目: 国家自然科学基金(62071315)。

作者简介: 胡健健(2001—),男,硕士研究生,主要研究方向:图像处理与识别,计算机视觉;龚剑(1975—),男,学士,软件工程师,主要研究方向:图像通信,计算机科学与工程;卿粼波(1982—),男,博士,教授,博士生导师,主要研究方向:多媒体通信与信息系统,人工智能与计算机视觉,嵌入式系统;滕奇志(1961—),女,博士,教授,博士生导师,主要研究方向:数字图像处理,模式识别,三维图像重建及分析等。

通信作者: 何小海(1964—),男,博士,教授,博士生导师,主要研究方向:图像处理与网络通信,人工智能与大数据分析,图像通信。Email: hxxh@scu.edu.cn。

收稿日期: 2024-11-05

专业人员手动提取来完成,需要投入大量的人力资源,消耗较多时间,且容易受主观影响,造成裂缝提取不准确。

随着图像处理技术的快速发展,人们开始将图像分割算法运用到岩心图像的裂缝提取中。高超^[1]提出了基于 Beamlet 的岩心裂缝提取算法,先利用大津阈值分割算法将岩心灰度图像转化成二值图,再利用 Beamlet 变换,从二值图中提取出裂缝,能一定程度消除强噪声的影响,但是阈值需要人工设置,且提取速度较慢。韦宇飞^[2]提出基于渗流模型的裂缝提取算法,可以进一步抑制噪声、减小孔洞等非裂缝部分的影响,但是提取的准确度和效率还需要提高。李朝辉^[3]提出改进的相位一致算法对岩心裂缝进行提取,对于改善所提取裂缝的连通性有一定效果,但是泛化性能不足。这些传统的图像分割算法,相较于最初的人工提取的方法,在裂缝提取的效率方面有了很大提升,但依然存在提取准确度不足、泛化程度不高等不足之处,对于目标和背景差异较小的岩心裂缝图像,无法取得良好的提取效果。

随着计算机视觉技术的发展,基于深度学习的图像分割算法也在持续取得成果。Evan Shelhamer 等^[4]提出了 FCN(Fully Convolutional Network)网络,将 CNN(Convolutional Neural Network)网络中的全连接层换成卷积层,并将不同深度的特征图通过跳跃连接而融合,开启了深度学习在语义分割方面的应用;Badrinarayanan 等^[5]提出了 SegNet 网络,通过对图像进行编码和解码提取目标特征,进一步推动了图像分割的发展;Ronneberger 等^[6]提出 UNet 网络,也是将图像先后通过编码器和解码器,网络结构呈 U 字型,引入了跳跃连接,有效提高了分割结果的准确性;Chen 等^[7-10]先后提出了 DeeplabV1、DeeplabV2、DeeplabV3、DeeplabV3 + 网络。DeeplabV1 网络使用空洞卷积来扩大感受野,并且运用了条件随机场(Conditional Random Field, CRF)来对深度卷积神经网络的分割结果进行改善;DeeplabV2 在 DeeplabV1 的基础上引入了空洞空间金字塔池化模块(Atrous Spatial Pyramid Pooling, ASPP),能够进行多尺度特征提取;DeeplabV3 在 DeeplabV2 的基础上改进了 ASPP 模块,使得模型可以更好地捕捉上下文信息,提高分割精度;DeeplabV3+在 DeeplabV3 的基础上加入解码器模块,将低层特征和高层特征融合,能更好地提高分割性能。

本文将 DeeplabV3+网络用于岩心图像的裂缝提取,针对岩心裂缝图像存在裂缝细小、裂缝与背景部分像素值差异较小的问题,设计了一种改进的 DeeplabV3+图像分割网络,用于提取岩心图像中的裂缝。

1 DeeplabV3+网络

很多用语义分割网络都有一个共同特点,就是侧重于利用已有的骨干网络来进行深层特征的提取,如 MobileNet、ResNet、Xception 等^[11-13]。研究者设计这些网络的初衷是解决图像分类问题,提取出的深层特征包含了丰富的语义信息,且可以带来更大的感受野,但是缺少了空间位置信息和局部细节信息。DeeplabV3+就很好的解决了这个问题,其将骨干网络提取到的深层特征和浅层特征融合,保留了丰富的语义信息同时又不丢失图像的局部细节信息,有效地提高了图像分割的效率和准确性。

DeeplabV3+的整体架构是编码器-解码器结构,网络结构图如图 1 所示。编码器的骨干网络是包含空洞卷积的深度卷积神经网络,通常是一些图像分类网络,如 ResNet、Xception 等。骨干网络用于提取图像的深层特征,可以提高感受野,丰富语义信息深层特征再送入 ASPP 模块,用于引入图像的多尺度信息。解码器部分先用 1×1 的卷积对骨干网络输出的 Layer1 低级特征进行降维,再与 ASPP 模块输出的深层特征拼接后用 3×3 的卷积融合,最后再利用双线性插值输出与原图像尺寸相同的预测图。

DeeplabV3+相较于其他的图像分割网络有许多新颖之处。首先,DeeplabV3+中使用了空洞卷积,如在骨干网络中用空洞卷积提取不同尺度的特征,在 ASPP 中使用了多个并行的空洞卷积更好地捕获图像的多尺度信息。空洞卷积的卷积核按设定间隔插入空洞,使得在进行卷积操作时跨越了更大的空间范围,相比于普通卷积,空洞卷积在扩大感受野的同时不增加参数总量,降低了网络复杂度。其次,DeeplabV3+引入了 ASPP 模块,ASPP 模块由一个全局平均池化层和多个并行的采样率不同的空洞卷积层组成,将不同尺度的特征图进行融合,提高网络的多尺度信息提取能力。最后,DeeplabV3+采用解码器将深层特征和浅层特征融合,再进行上采样操作,逐渐恢复图像的分辨率,细化分割结果。由于 DeeplabV3+只将 Layer1 浅层特征和 ASPP 输出的深层特征融合,而没有利用其他浅层特征的边缘信息,

对于背景复杂、目标与背景相差不大的岩心裂缝图像, 分割结果仍较为粗糙, 且 DeeplabV3+的 ASPP 模块中用到的池化操作是全局平均池化, 对于狭长的

裂缝目标, 这种池化操作容易引入背景污染信息, 因此需要从充分利用浅层特征的边缘信息和提高对狭长目标边界的提取能力方面改进网络。

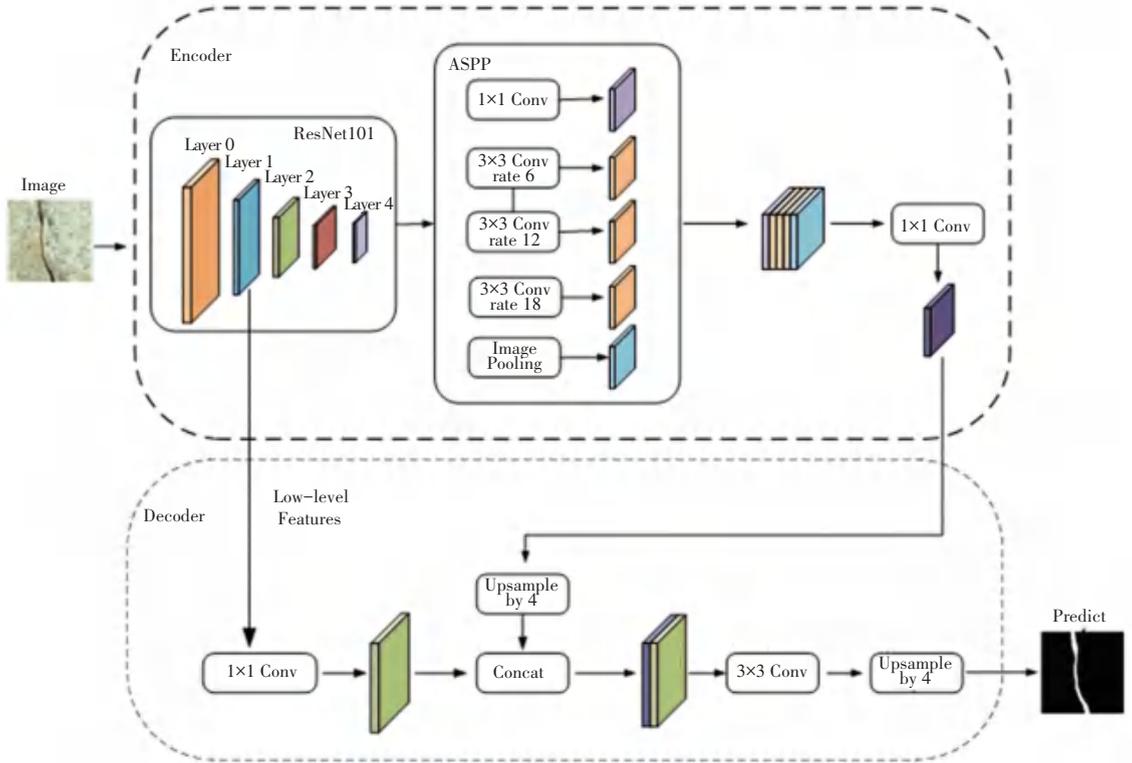


图 1 DeeplabV3+网络结构
Fig. 1 Structure of the DeeplabV3+ model

2 改进的 DeeplabV3+网络

2.1 整体网络结构

由于岩心裂缝图像目标和背景像素值相似, 边界存在模糊不清的情况, 且裂缝目标通常呈狭长状, 直接使用 DeeplabV3+对裂缝进行提取容易造成欠分割、过分割等分割不精的情况。针对上述问题, 本文在 DeeplabV3+的基础上改进出一种新的图像分割网络。针对 DeeplabV3+未充分利用浅层特征的有效信息, 本文提出新的解码器, 将深层特征和各浅层特征充分融合, 加强网络对边缘信息的提取能力; 针对全局平均池化对狭长型裂缝分割不精的情况, 本文引入条形池化模块 (Strip Pooling Module, SPM), 进行 ASPP 模块中的池化操作, 提高对细长目标的分割准确性。改进的 DeeplabV3+网络结构如图 2 所示。

2.2 改进解码器 (Improved-Decoder)

DeeplabV3+基于编码器-解码器的基本架构, 编码器可以降低图像的空间维度, 将输入图像转换成紧凑抽象的深层特征, 扩大感受野; 解码器通过上

采样操作, 将抽象的特征信息转换为图像级别的输出, 使网络实现在像素级别对图像进行预测。在解码过程中, 引入跳跃连接可以将浅层特征的细节信息融入到深层特征中, 提高分割精度。DeeplabV3+将 ASPP 模块输出的深层特征和骨干网络的其中一个浅层分支融合后再输出, 提升了网络对边缘信息的提取能力^[14]。但对于边缘模糊不清的细小裂缝, 仅利用一个分支的浅层特征细节信息, 并且仅通过两次上采样操作就将深层特征图恢复成原尺寸的预测图, 仍会导致分割粗糙的情况。因此, 本文解码过程借鉴 FPN (Feature Pyramid Network) 网络的解码思想, 引入更多的横向连接, 将深层特征逐级上采样并与对应的浅层特征融合, 形成“自上而下”的信息传输路径, 与编码器“自下而上”的路径相对应。改进后的解码器结构如图 3 所示, 整个过程经过 4 次上采样和 3 次特征融合得到预测结果, 即深层特征 High-Features 上采样 2 倍, 与经过 1x1 卷积的浅层特征 Low-Features3 拼接后, 再经过 3x3 的卷积进行融合得到 y3。继续进行上述过程, 直至融合完浅层特征 Low-Features2 和 Low-Features1, 得到融合

结果 y_1 。最后, y_1 上采样 2 倍, 输出与原图尺寸相同的预测图。改进后的解码器将深层特征与各级浅层特征进行了充分融合, 增强了网络对细节特征的

提取能力同时, 多次的特征融合, 进一步加强了网络对多尺度特征的代表能力。

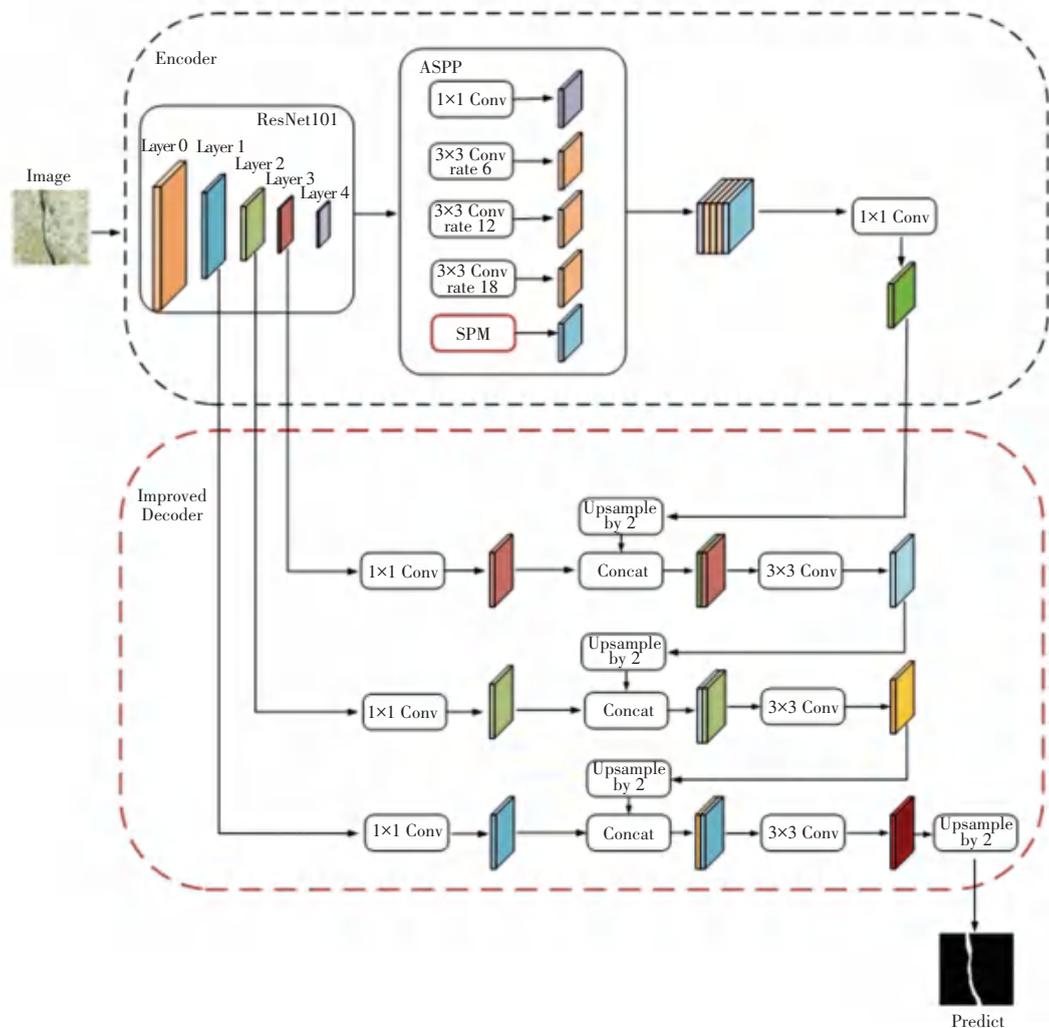


图2 改进的 DeeplabV3+网络结构

Fig. 2 Structure of the improved DeeplabV3+ model

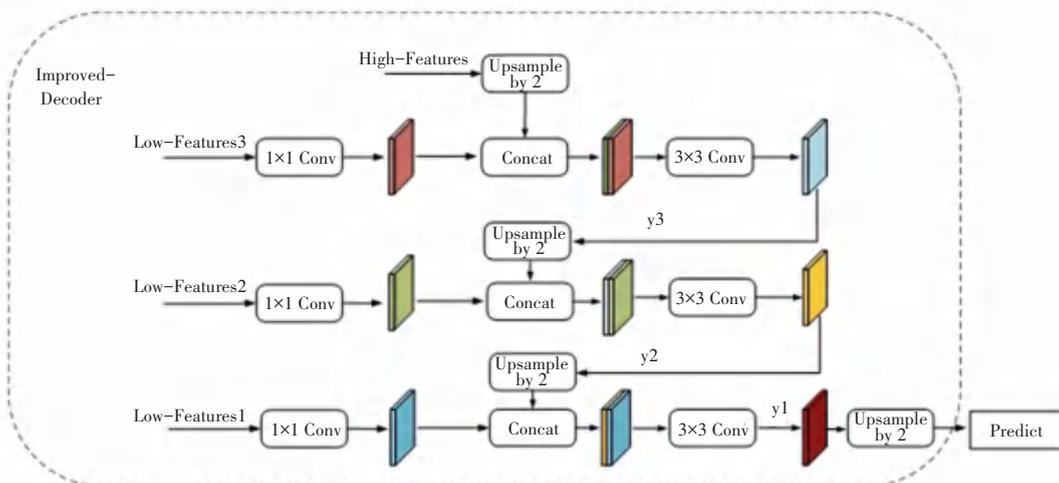


图3 改进解码器结构

Fig. 3 Structure of improved-decoder

2.3 SPM 条形池化模块

池化是提取深层特征的重要步骤,有利于减少特征图的尺寸,降低参数量,提高捕获远程上下文信息的能力。传统的池化操作有最大池化、平均池化等,其基于 $N \times N$ 的正方形池化核对特征图进行池化操作,如图 4(a)所示。对于长条形离散分布的裂缝目标,使用正方形池化核会不可避免地混入无关背景特征的污染信息,限制了模型捕获上下文的灵活性。与传统池化不同,条形池化可以沿着特征图的特定维度使用长条形池化核进行池化操作,因此可以有效捕获离散区域的远距离依赖关系,如图 4(b)所示。同时在特征图的其余空间维度上保持狭窄的内核形状,防止不同标签区域之间的信息干扰。因此,本文在 ASPP 中将全局平均池化替换成条形池化,减少了背景区域对岩心裂缝区域的信息污染,提高了岩心裂缝目标的分割精度。

传统的平均池化是将特征图分为若干个矩形区域,对每一个矩形区域内的像素值求平均值,用该平均值替代对应矩形区域的像素值,输出到下一层。平均池化的计算如下式所示:

$$y_{uwv} = \frac{1}{|R_{uw}|} \sum_{(i,j) \in R_{uw}} x_{wij} \quad (1)$$

其中, y_{uwv} 表示特征图 w 在矩形区域 R_{uw} 内进行平均池化的结果; x_{wij} 表示特征图 w 的矩形区域 R_{uw} 中位于 (i, j) 处的像素值; $|R_{uw}|$ 表示矩形区域 R_{uw} 内的元素个数。

从式(1)可以看出,平均池化使用的矩形窗口会不可避免的将背景信息混入到目标区域中,而使用条形池化则可以使这个问题在一定程度上得到解决。

条形池化使用了水平、垂直两个池化核,在两个空间维度上分别对特征图进行池化操作,再将结果进行融合^[15], SPM 结构如图 5 所示。若特征图的大小为 $H \times W$,则对应的水平、垂直两个维度上的池化核大小分别为 $1 \times W$ 和 $H \times 1$,其在水平和垂直方向上的池化计算过程如下式所示:

$$y_i^h = \frac{1}{W} \sum_{0 \leq j < W} x_{i,j} \quad (2)$$

$$y_j^v = \frac{1}{H} \sum_{0 \leq i < H} x_{i,j} \quad (3)$$

其中, y_i^h 表示特征图第 i 行元素的平均值; y_j^v 表示特征图第 j 列元素的平均值; $x_{i,j}$ 表示特征图在 (i, j) 处的元素值。

再使用一个 3×3 的一维卷积核,将池化结果 $y^h \in \mathbb{R}^{H \times 1}$ 和 $y^v \in \mathbb{R}^{1 \times W}$ 扩展到与输入特征图相同的尺寸 $H \times W$,扩展后的结果为 $y^h \in \mathbb{R}^{H \times W}$ 和 $y^v \in \mathbb{R}^{H \times W}$ 。之后对扩展后的两个维度的特征图对应位置求和,其计算过程如下式所示:

$$y_{i,j} = y_{i,j}^h + y_{i,j}^v \quad (4)$$

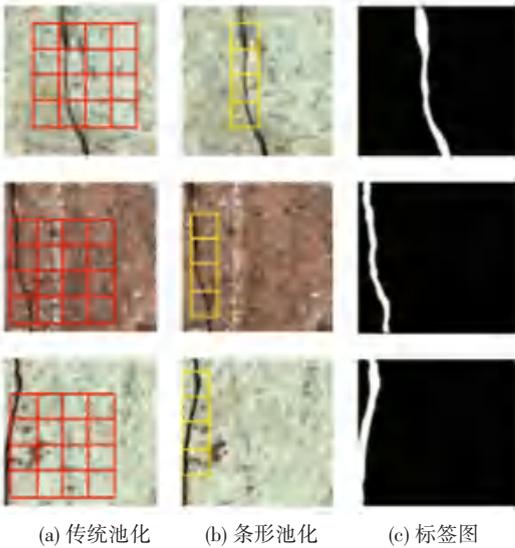


图 4 传统池化和条形池化对比

Fig. 4 Comparison between traditional pooling and strip pooling

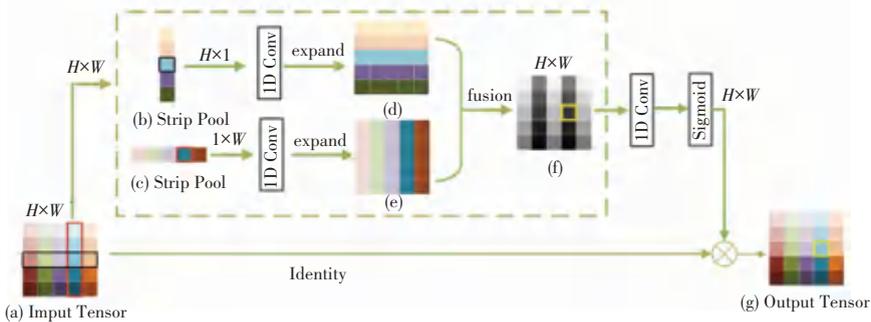


图 5 SPM 结构图

Fig. 5 Structure of SPM

最后,用一个 1×1 的卷积核进行卷积操作,再通过 Sigmoid 函数进行激活,与输入特征图进行同位置元素相乘,输出最终结果 z , 计算过程如下式所示:

$$z = \text{scala}(x, \sigma(f(y))) \quad (5)$$

其中, x 表示输入特征图; y 表示两个维度融合后的特征图; f 表示 1×1 的卷积操作; σ 表示 Sigmoid 激活函数; scala 表示数值乘法运算。

与平均池化相比,条形池化的操作区域长且窄,避免在间隔较远的孤立区域建立不必要的连接关系,且条形池化模块是轻量级的,容易根据需要嵌入到网络之中,从而提高捕获特定方向或形状信息的能力,提升网络的分割性能。

3 实验及结果

为验证本文所提基于改进 DeeplabV3+的岩心图像裂缝提取算法的有效性,在实验环境相同的情况下,在岩心裂缝数据集上用其他图像分割算法与本文进行对比实验。为了说明本文所提基于改进 DeeplabV3+的岩心图像裂缝提取算法的泛化能力,还在公开数据集 Crack500 上进行对比实验。上述两组实验所采用的对比算法有 DDRNet^[16], GCN^[17], ENet^[18], UNeXt^[19], DeeplabV3+。另外,本文还设计了消融实验,以验证所改进部分的有效性和合理性。

3.1 数据集介绍

使用高分辨率线阵相机对岩心裂缝进行扫描采集得到岩心裂缝图像,由于所采集到的裂缝图像分辨率过高、尺寸过大,直接输入网络进行训练会造成显存爆炸。因此,对这些裂缝图像进行裁剪,得到 425 张 500×500 的岩心裂缝图像,再用 Labelme 工具进行标注,得到岩心裂缝图像数据集。

Crack500 是网上主流的裂缝公开数据集,由 Yang 等^[20]拍摄的道路裂缝图像,共计 3 020 张道路裂缝图像及其对应的标注图。数据集中的裂缝形状大小差异较大,图像背景较为复杂,裂缝边缘不清晰,适合用于评估本文所提算法的泛化能力。

将这两个数据集的训练集和测试集之比均设为 8 : 2,为了减少过拟合、提升网络的鲁棒性,再分别对上述数据集随机采用水平翻转、垂直翻转、水平垂直翻转等方式进行数据增强,扩充数据集。

3.2 评价指标

本文采用平均交并比 ($mIoU$)、平均像素准确率 (mPA)、F1 分数 ($F1 - \text{Score}$) 来评估算法的性能,这 3 个指标是语义分割任务中常用的评估指标,

数值都在 0~1 之间,越接近 1 说明模型性能越好,可有效验证模型的性能。

$mIoU$ 是指模型对所有类别预测的结果和真实值的平均交并比。 mPA 是指每个类别中被正确分类的像素所占比例,再累加求平均的结果; $F1$ 分数是指精确率和召回率的调和平均值,用于综合评估模型的准确性和全面性,其中精确率指的是模型预测为正类中实际为正类的比例,召回率指的是实际为正类的样本中被模型准确无误地预测的比例:

$$mIoU = \frac{1}{2} \left(\frac{TP}{TP + FN + FP} + \frac{TN}{TN + FN + FP} \right) \times 100\% \quad (6)$$

$$mPA = \frac{1}{2} \left(\frac{TP}{TP + FP} + \frac{TN}{TN + FN} \right) \times 100\% \quad (7)$$

$$F1 = 2 \frac{\frac{TP}{TP + FP} \times \frac{TP}{TP + FN}}{\frac{TP}{TP + FP} + \frac{TP}{TP + FN}} \times 100\% \quad (8)$$

其中, TP 表示模型预测和实际均为正例; TN 表示模型预测和实际均为反例; FP 表示模型预测为正例、实际为反例; FN 表示模型预测为反例、实际为正例。

3.3 参数设置与训练

本文实验环境采用 Ubuntu18.04 LTS 系统,处理器为 Intel(R) Core(TM) i7-9700,显卡为 NVIDIA GeForce RTX2080Ti,软件环境为 CUDA12.4 + python 3.9.19 + pytorch1.12.1。

选用合理的训练参数是提高模型性能的重要步骤,本文选用 Adam 优化器来对模型参数进行优化,学习率设置为 0.001,每次迭代的样本数设置为 32,在岩心裂缝数据集上训练迭代次数设置为 100 次,在 Crack500 数据集上训练迭代次数设置为 45 次。

正确选用损失函数是模型性能最优化的关键,本文选用 DiceLoss 函数作为模型训练时的损失函数。DiceLoss 是图像分割任务中常用的损失函数,用于评估预测样本和真实样本之间的相似度,与交叉熵损失函数相比,在对样本类别不平衡情况时, DiceLoss 效果更加显著,适合处理本文中裂缝与背景大小比较小的情况。DiceLoss 的计算公式如下:

$$DiceLoss = 1 - \frac{2 \sum_{i=1}^N p_i g_i}{\sum_{i=1}^N p_i + \sum_{i=1}^N g_i} \quad (9)$$

其中, N 表示像素的总个数; p_i 表示预测图中第

i 个像素的像素值; g_i 表示真实标签图中第 i 个像素的像素值。

3.4 实验结果分析

3.4.1 改进 DeeplabV3+的有效性验证

本文通过改进 DeeplabV3+的解码器结构和 ASPP 模块的池化层,提出了改进的 DeeplabV3+的图像分割算法,为了验证所提算法的有效性和合理性,将本文算法和主流深度学习图像分割算法 DDRNet、GCN、ENet、UNeXt、DeeplabV3+在岩心裂缝数据集上进行对比分析,各个算法的裂缝分割结果和指标如图 6 和表 1 所示。在该数据集上,GCN 网络提取结果连通性较差,存在断裂现象;UNeXt、DeeplabV3+ 网络提取结果存在一部分噪点;DDRNet、ENet 提取结果虽然与真实标签较为接近,但是存在欠分割现象。本文算法减少了背景对裂缝目标的信息污染,提高了网络对裂缝目标的提取能

力;同时增强了网络对裂缝边缘细节的提取能力。与其他对比算法相比,本文算法在 $mIoU$ 、 mPA 、 $F1 - Score$ 指标上均优于其他算法,且对裂缝的分割结果更接近于真实标签,验证了本文算法的有效性。

表 1 岩心裂缝数据集的对比结果

Table 1 Comparison results of core fracture datasets

算法	$mIoU/ \%$	$mPA/ \%$	$F1 - Score/ \%$
DDRNet	75.96	80.75	69.91
GCN	73.06	77.58	65.01
ENet	77.17	81.72	71.84
UNeXt	77.53	84.81	72.52
DeeplabV3+	76.92	81.43	71.44
本文算法	78.80	85.92	74.46

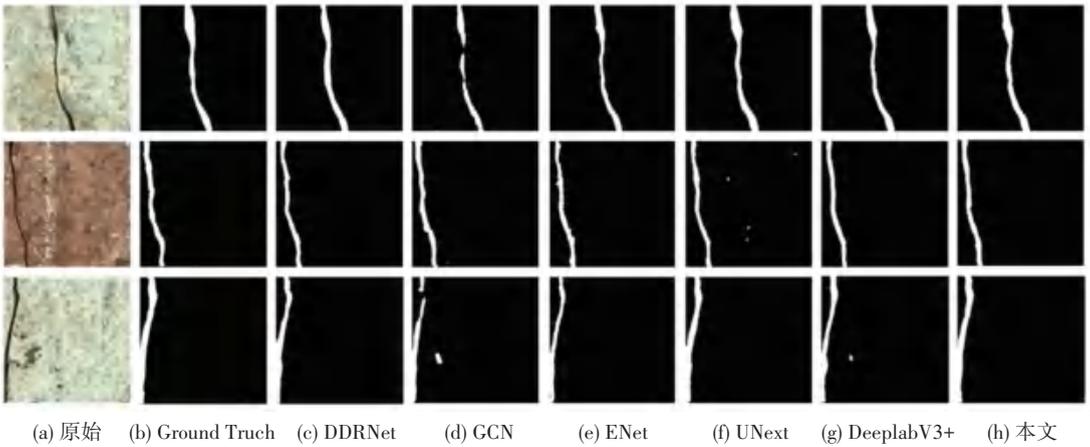


图 6 岩心裂缝图像对比结果可视化

Fig. 6 Visualization of core fracture image comparison results

3.4.2 改进 DeeplabV3+的泛化性能评估

为验证改进算法的泛化性能,本文在公共数据集 Crack500 上进行不同算法间的对比实验,不同分

割算法在 Crack500 数据集上的分割结果如图 7 和表 2 所示。可以看出,在 Crack500 数据集上,本文所提算法分割效果良好,优于其他对比算法。

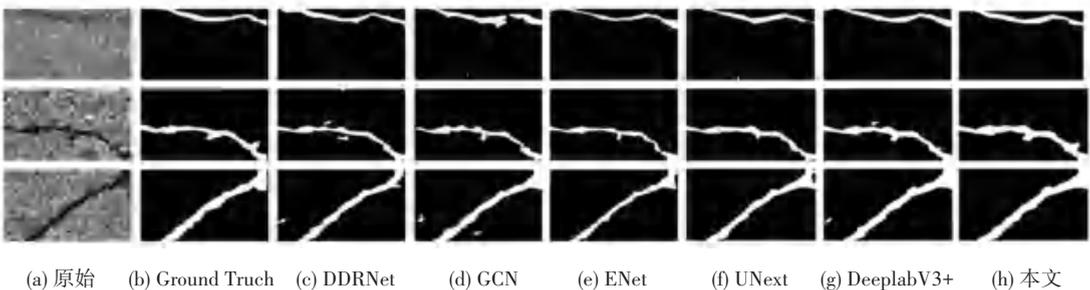


图 7 公共数据集 Crack500 对比结果可视化

Fig. 7 Comparison results of the Crack500 public dataset are visualized

相比于 DeeplabV3+, 本文算法在 $mIoU$ 、 mPA 、 $F1 - Score$ 3 个指标上分别提升了 1.14%、0.69%、1.26%。本文算法提取的裂缝边缘更加接近真实标签图像, 减少了背景区域对目标提取的干扰, 分割结果噪声明显减少。在 Crack500 数据集上, 本文算法指标结果和可视化结果均优于其他算法, 说明本文算法具有良好的泛化能力。

表 2 公共数据集 Crack500 的对比结果

Table 2 Comparison results of the public dataset Crack500

算法	$mIoU$ / %	mPA / %	$F1 - Score$ / %
DDNet	73.44	79.60	67.18
GCN	74.57	82.24	69.15
ENet	73.62	80.05	67.51
UNet	74.01	81.03	68.20
DeeplabV3+	74.87	87.28	70.07
本文算法	76.01	87.97	71.33

3.5 消融实验

为验证改进 DeeplabV3+ 所采用模块的有效性和合理性, 本文在实验环境相同的情况下, 设置了 4 组消融实验, 实验结果见表 3。由消融实验结果可知, 本文所采用的两个模块均能够有效提升模型对裂缝目标的提取能力。Improved-Decoder 将浅层特征图充分融入到深层特征图, 使模型更加关注裂缝的边缘细节, 提升模型对细小裂缝的提取能力; SPM 条形池化模块通过狭窄条形池化核, 有效捕获离散裂缝区域的远距离依赖关系, 减少背景区域对裂缝目标提取的干扰, 使得模型能更好地保留裂缝纤细部位的特征。因此, 本文同时采用 Improved-Decoder 和 SPM 条形池化模块来提升模型对裂缝的提取效果。

表 3 消融实验结果

Table 3 Results of ablation test

Improved-Decoder	SPM	$mIoU$ / %	mPA / %	$F1 - Score$ / %
N	N	76.92	81.43	71.44
N	Y	77.02	82.93	71.66
Y	N	77.99	84.64	73.20
Y	Y	78.80	85.92	74.46

4 结束语

本文旨在解决岩心裂缝提取过程中存在的裂缝边缘细节分割粗糙、分割结果易受到背景信息污染

的问题, 提出基于改进 DeeplabV3+ 的岩心图像裂缝提取算法。通过改进 DeeplabV3+ 的解码器网络结构, 将深层特征与各级浅层特征充分融合, 并逐级上采样, 提升了网络对裂缝边缘细节的提取能力; 引入条形池化模块, 作为 ASPP 模块中的池化层, 减少背景对裂缝目标的信息污染, 提高网络捕获狭长型裂缝的能力。在岩心裂缝数据集上进行的对比实验证明, 本文提出的基于改进 DeeplabV3+ 的岩心图像裂缝提取算法, 岩心裂缝的提取效果良好, 在公开数据集 Crack500 上进行的不同网络间的对比实验结果表明, 本文提出的改进算法具有良好的泛化性能, 同时消融实验验证了本文改进各模块的有效性。在此后的研究中, 将进一步在不降低模型的分割性能前提下对模型轻量化进行探究。

参考文献

- [1] 高超, 王正勇. 基于 Beamlet 的岩心裂缝提取算法[J]. 信息与电子工程, 2010, 8(2): 186-189.
- [2] 韦宇飞, 吴晓红, 袁传虎, 等. 基于渗流模型的成像测井裂缝提取算法[J]. 太赫兹科学与电子信息学报, 2014, 12(2): 272-275.
- [3] 李朝辉, 蒋宜勤, 卿粼波, 等. 改进相位一致的岩心图像裂缝提取方法[J]. 计算机与数字工程, 2015, 43(4): 695-699.
- [4] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2015: 3431-3440.
- [5] 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.
- [6] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]//Proceedings of the 18th International Conference on Medical Image Computing and Computer-assisted Intervention. Cham: Springer, 2015: 234-241.
- [7] CHEN L, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[J]. Computer Science, 2014, 1(4): 357-361.
- [8] 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.
- [9] CHEN L. Rethinking atrous convolution for semantic image segmentation[J]. arXiv preprint arXiv, 1706.05587, 2017.
- [10] CHEN L, 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 (ECCV). Piscataway, NJ: IEEE, 2018: 801-818.
- [11] HOWARD A G. Mobilenets: Efficient convolutional neural networks for mobile vision applications[J]. arXiv preprint arXiv, 1704.04861, 2017.

- [12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2016: 770-778.
- [13] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2017: 1251-1258.
- [14] LIN T, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2017: 2117-2125.
- [15] 杨萍, 张汐. 改进 DeepLabv3+ 的道路表面裂缝检测方法 [J/OL]. 计算机工程, 1-10 [2024-11-20]. <https://doi.org/10.19678/j.issn.1000-3428.0069114>.
- [16] HONG Y, PAN H, SUN W, et al. Deep dual-resolution networks for real-time and accurate semantic segmentation of road scenes [J]. arXiv preprint arXiv, 2101.06085, 2021.
- [17] CHEN M, WEI Z, HUANG Z, et al. Simple and deep graph convolutional networks [C]//Proceedings of the International Conference on Machine Learning. PMLR, 2020: 1725-1735.
- [18] PASZKE A, CHAURASIA A, KIM S, et al. ENet: A deep neural network architecture for real-time semantic segmentation [J]. arXiv preprint arXiv, 1606.02147, 2016.
- [19] VALANARASU J M J, PATEL V M. UNeXt: Mlp-based rapid medical image segmentation network [C]//Proceedings of the International Conference on Medical Image Computing and Computer-assisted Intervention. Cham: Springer, 2022: 23-33.
- [20] YANG F, ZHANG L, YU S, et al. Feature pyramid and hierarchical boosting network for pavement crack detection [J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 21 (4): 1525-1535.