

基于特征增强整体嵌套网络裂缝检测方法

徐胜军^{1,2}, 郝明^{1*}, 孟月波^{1,2}, 刘光辉¹, 韩九强^{1,2}

¹西安建筑科技大学信息与控制工程学院, 陕西 西安 710055;

²人工智能与数字经济广东省实验室(广州), 广东 广州 510320

摘要 针对自然场景下混凝土裂缝背景复杂、纹理多变所造成的裂缝分割不准确问题,提出了一种基于特征增强整体嵌套网络裂缝检测算法。首先,在整体嵌套网络,一种深度学习边缘检测网络的基础上,采用多尺度监督机制融合不同尺度混凝土裂缝的预测结果,增强网络对混凝土裂缝线性拓扑结构的表达能力;然后,采用一种卷积-反卷积特征融合模块将混凝土裂缝的反卷积深层语义特征和卷积浅层细节特征有效融合,深层语义特征可以减少复杂背景干扰并提高模糊裂缝区域特征响应,浅层特征可以提高裂缝细节表达能力,进而提高裂缝特征质量;最后,提出了混合空洞卷积边界细化模块,该模块利用残差网络和空洞卷积组细化裂缝边界,从而提高裂缝分割准确性。在数据集 Bridge_Crack_Image_Data 和 Crack Forest Dataset 上进行了测试,所提算法的准确率分别达到了 92.1% 和 91.6%, F_1 分数分别达到了 80.2% 和 91.1%。实验结果表明,所提算法在复杂自然环境下可获得稳定而准确的分割结果,具有较强的泛化性。

关键词 图像处理; 裂缝检测; VGG16; 整体嵌套网络; 混合空洞卷积; 语义分割

中图分类号 TP391.41

文献标志码 A

DOI: 10.3788/LOP202259.1010003

Crack Detection Method of Holistically-Nested Network Based on Feature Enhancement

Xu Shengjun^{1,2}, Hao Ming^{1*}, Meng Yuebo^{1,2}, Liu Guanghui¹, Han Jiuqiang^{1,2}

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

²Guangdong Artificial Intelligence and Digital Economy Laboratory (Guangzhou), Guangzhou 510320, Guangdong, China

Abstract In this paper, we propose a novel crack detection algorithm based on feature enhanced whole nested network to resolve the issue of inaccurate crack segmentation caused by complex background and changeable texture of concrete cracks in natural scenes. First, based on the holistically-nested network (a deep learning edge detection network), the multi-scale supervision mechanism was adopted to integrate the prediction results of concrete cracks of different scales to enhance the expression ability of the network to the linear topology of concrete cracks. Then, we used a convolution-deconvolution feature fusion module to effectively integrate the deconvolution deep semantic features and convolution shallow detail features of concrete cracks. The deep semantic features can reduce the interference of complex backgrounds and improve the feature response of the fuzzy crack area. The shallow features can improve the expression ability of crack details and the quality of crack features. Finally, we proposed a hybrid

收稿日期: 2021-04-01; 修回日期: 2021-05-23; 录用日期: 2021-05-31

基金项目: 国家自然科学基金(61803293, 51678470)、陕西省自然科学基金基础研究计划(2020JM472, 2020JM473, 2019JQ760)、陕西省重点研发计划(2021SF-429)

通信作者: *765377071@qq.com

void convolution boundary thinning module that used residual network and void convolution group to refine the fracture boundary and improve the accuracy of fracture segmentation. Using the Bridge_Crack_Image_Data dataset and Crack Forest Dataset, the accuracy of the proposed algorithm was 92.1% and 91.6% and the F_1 -score was 80.2% and 91.1%, respectively. The experimental results show that the proposed algorithm obtains stable and accurate segmentation results in complex natural environments and attains strong generalizations.

Key words image processing; crack detection; VGG16; holistically-nested network; mixed atrous convolution; semantic segmentation

1 引言

裂缝作为混凝土结构表面主要常见病害,准确、及时检测和修补裂缝对于混凝土结构良好状态的保持具有重大意义。早期主要通过人工巡检的方式来完成裂缝的检测,但是人工检测不仅耗时,而且费力。随着计算机视觉的发展,研究人员基于人工设计的视觉特征提出了基于图像处理的方法来实现裂缝的检测。传统的基于图像处理的方法主要有梯度方向直方图^[1]、局部二值模式^[2]、多特征滤波器组^[3]、边缘检测^[4]、多尺度特征^[5]等。然而人工设计的裂缝特征具有很强的主观性,同时特征设计复杂,鲁棒性不高,在自然场景下检测效果不是很理想。

深度学习网络具有很强的特征学习能力,以数据为驱动使得网络自己学习到特征。研究人员在基于深度学习的图像裂缝检测进行了大量深入的研究。在早期的基于深度学习的裂缝检测^[6-8]研究中,研究人员将裂缝图片划分为子块,并将子块送入二分类的检测网络中,最后将包含裂缝的子块框出来,然而这种基于子块检测的方法无法对裂缝宽度进行评估且会发生漏检和误检现象。近年来多采用全卷积网络(FCN)实现像素级的裂缝分割^[9];王森等^[10]使用FCN对结构体表面的裂纹进行检测,并针对FCN模型存在的不足,通过加深网络深度、拼接低层和高层特征来提高网络的检测效果。FCN在整体语义分割方面具有良好的性能,但是网络缺乏对细长线性结构进行捕捉的能力,因此在裂缝分割中容易出现错检、漏检现象。图像多尺度特征可以提高网络对线性结构的捕捉能力。杨文杰等^[11]提出了一种基于卷积神经网络结合聚类分割的识别方法,实现了对较复杂背景下混凝土表面裂缝图像的准确识别。Ren等^[12]在编解码结构下,设计了多重空洞卷积来获取更大感受野特征,并挤压激励上采样(SE-Upsampling)来放大有效特征的响应。Liu等^[13]设计了一种基于空洞卷积的空间金字塔池化(ASPP)模块以增大感受野并获取目标多尺

度上的卷积特征,提升了分割性能。曹锦纲等^[14]在卷积结构上加入了通道注意力机制和位置注意力机制来获取更加有效的特征。因为裂缝具有线性细长的特征,所以多尺度监督学习可以增强网络捕捉线性结构的能力。Zou等^[15]提出了DeepCrack模型,该模型采用SegNet将裂缝的编码解码特征融合,得到了更丰富的裂缝特征,同时借鉴了深度学习边缘检测整体嵌套(HED)网络,采用深度监督网络进行多尺度监督学习以增强模型捕捉裂缝线性结构的能力。Yang等^[16]采用UNet融合卷积和反卷积特征,构建不同卷积层的特征金字塔,并采用多尺度监督学习提升网络捕捉裂缝线性拓扑结构的能力。

上述方法对裂缝检测中存在的问题进行了探究,然而自然环境下背景纹理多变和裂缝模糊等因素为裂缝检测带来了大量的错检、漏检问题。为了提高裂缝检测算法的精确性和鲁棒性,本文提出了一种基于特征增强整体嵌套网络裂缝检测(CFEHNet)方法。所提方法首先基于HED网络通过多尺度监督学习融合不同卷积阶段的混凝土裂缝预测结果,提高网络对混凝土裂缝线性拓扑结构的捕捉能力。然后针对HED的特征提取网络VGG16^[17]不能在复杂背景下很好提取裂缝特征的问题,提出了一种卷积-反卷积特征融合模块来增强特征,将每个阶段的裂缝卷积特征和反卷积特征融合,对裂缝的细节特征和语义特征进行融合。语义特征可以有效过滤背景噪声并提高模糊裂缝检测率,浅层特征可以提高裂缝细节的表达力,增强裂缝特征质量。最后针对反卷积跨度大导致细节特征丢失的问题,提出了边界细化模块(BR),通过残差网络和空洞卷积组进一步学习裂缝边界细节信息特征,提高了裂缝分割精准度。在数据集Bridge_Crack_Image_Data和Crack Forest Dataset(CFD)上进行实验验证,实验结果表明,所提方法解决了深度学习模型受到自然环境下背景纹理多变和裂缝模糊等因素影响所导致的错检、漏检等问题,提高了分割精度。

2 基本原理

2.1 网络结构

HEDNet 主要由基于 VGG16 的特征提取网络、深度监督模块 (DS) 和特征融合模块 (FUSE) 3 部分组成^[18], 其结构如 [图 1(a)] 所示。VGG16 用于提取不同尺度的裂缝特征, 深度监督模块对 VGG16 提取的不同阶段的裂缝特征进行有监督的学习来压缩裂缝特征, 输出通道数为 1 的裂缝特征, 并通过反卷积恢复到原图尺度。深度监督模块主要由 1×1 卷积核、反卷积和 Sigmoid 激活函数组成, 其具体结构如 [图 1(b)] 所示。特征融合模块将 5 个阶段反卷积结果通过 1×1 卷积进行多尺度特征融合作为最终结果。HEDNet 通过多尺度融合提高了网络对线性结构特征的捕捉能力, 但是所提取特征简单, 缺乏语义特征, 同时反卷积跨度大, 导致分割不精细。为解决此问题, 本实验组提出了 CFEHNet 模型, 其

结构如图 2 所示。所提 CFEHNet 使用卷积-反卷积融合模块来增强各阶段裂缝特征, 在各阶段融合了含有语义特征的反卷积特征, 同时在深度监督模块后增加了细化模块来改善反卷积跨度过大导致分割不精细的问题。VGG16 网络包括 5 阶段卷积结构和 3 层全连接层, 每阶段卷积层数分别为 2、2、3、3、3, 每阶段卷积末尾连接最大池化层, 主要作用是提取裂缝特征。裂缝在不同尺度上有着相似的规则性, 同时在整体上具有线性拓扑结构的特征。因此, 可以利用网络不同尺度特征进行判别, 如果多个尺度推测像素点为“裂缝”, 那么该点是“裂缝”的可能性较大; 反之, 如果多个尺度推测像素点不是“裂缝”, 那么该点是背景的可能性较大。基于此, HEDNet 使用深度监督网络对所有阶段的卷积特征分别进行学习, 与经典的深度学习网络只产生单侧预测结果不同, HEDNet 通过深度监督模块产生了 5 个侧边网络, 得到了不同尺度裂缝分割结果, 其

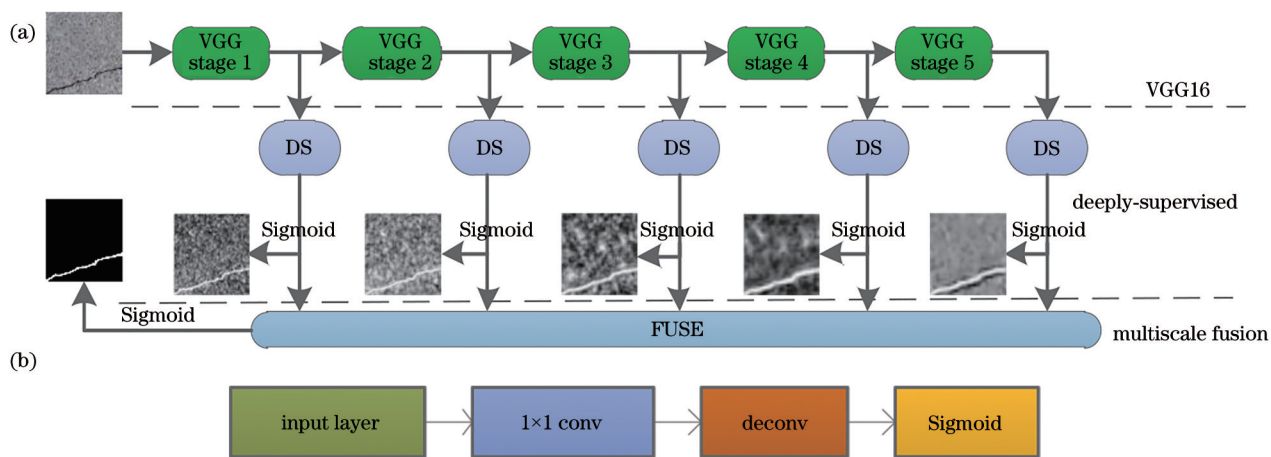


图 1 HEDNet。(a)HEDNet 结构;(b)深度监督模块结构

Fig. 1 HEDNet. (a) Structure of HEDNet; (b) structure of deep supervision module

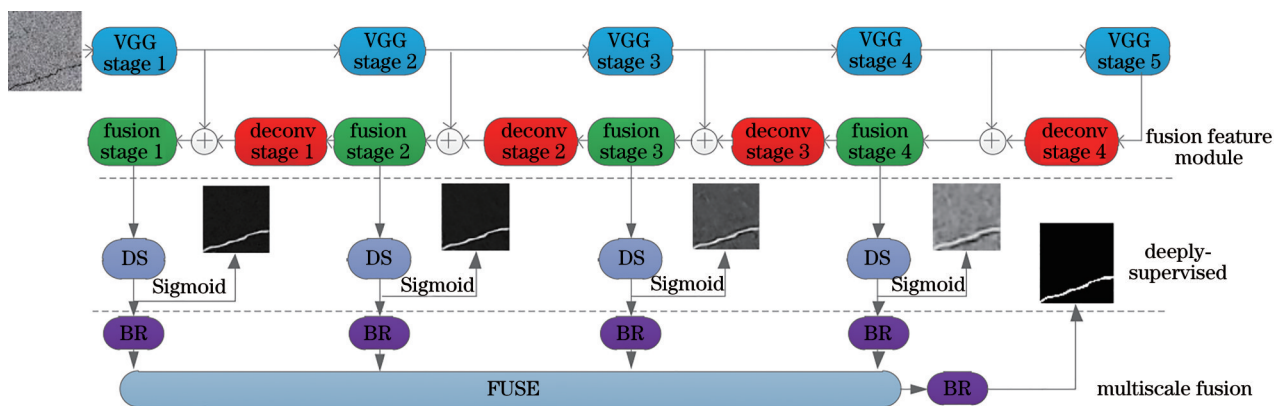


图 2 CFEHNet 模型结构

Fig. 2 Structure of CFEHNet model

HEDNet在得到不同尺度特征激活图后,通过多尺度特征融合模块,将不同尺度特征响应激活图拼接融合,得到融合分割特征激活图。多尺度特征融合可以有效增强裂缝区域的特征响应,减弱非裂缝区域的特征响应,从而有效提高网络对裂缝的线性拓扑结构特征的捕捉能力。

HEDNet使用VGG16网络提取裂缝特征,在VGG16的第1阶段、第2阶段主要提取裂缝细节特征,但是背景纹理特征也会被提取到,不利于裂缝分割,且缺少语义信息,容易发生断裂现象。VGG16第4、5阶段特征包含了中级、高级特征,主要为全局的语义特征,但是丢失了裂缝细节特征。HED只是简单对5个阶段卷积特征进行监督学习,缺少各阶段特征融合。因此,为了解决复杂背景纹理、噪声等强干扰所带来的误分割问题,本实验组提出了一种基于卷积-反卷积特征融合方法,利用反卷积学习裂缝图像stage 5的语义特征,并重建从stage 1到stage 4各阶段的反卷积特征,重建的各阶段反卷积特征不仅具有更为鲁棒的裂缝高级语义特征信息,而且能有效消除复杂背景纹理、噪声等强干扰特征。HEDNet使用深度监督网络对不同阶段的特征图进行反卷积学习,但是采样跨度过大,丢失了裂缝边界细节特征,导致裂缝边界分割不准确,针对这个问题,本实验组基于空洞卷积方法提出了一种边界细化模块,通过残差网络和空洞卷积组融合上下文信息来学习裂缝边界细节信息特征,提高了裂缝的分割精度。

2.2 卷积-反卷积特征融合模块

细节特征和语义特征对于自然场景下裂缝的准确分割具有十分重要的意义。HED采用VGG16网络提取裂缝特征时,可以获得5个阶段的多尺度裂缝特征图,VGG16网络的较低层可以捕获更多的细节信息,即stage 1、stage 2阶段包含了更多的裂缝细节特征信息,给裂缝位置的准确检测提供了有效信息的同时,也包含了大量的背景噪声信息,这些噪声特征会对裂缝分割造成影响。VGG16网络的较高层具有更丰富的图像语义信息,即stage 3、stage 4、stage 5阶段主要包含了更多的裂缝语义特征,这些特征消除了背景噪声的干扰,但同时也丢失了更多的裂缝细节特征信息,导致分割不精细。所提方法首先针对VGG16网络stage 5包含丰富语义特征的特点,利用反卷积学习自动提取裂缝图像高层语义特征,重建stage 1到stage 4各阶段的反卷

积特征,但是不重建stage 5特征,因为对stage 5过多下采样会造成分割不精细的问题。重建后各阶段反卷积特征不仅具有更为鲁棒的裂缝高级语义特征信息,而且能有效消除复杂背景纹理、噪声等强干扰特征。然后把重建的stage 1到stage 4各阶段的反卷积特征和对应层级VGG16网络提取的各阶段特征进行拼接融合。卷积-反卷积特征融合方法采用 1×1 卷积学习对卷积-反卷积特征进行融合,增强裂缝图像高级语义特征,消除复杂背景纹理、噪声特征干扰的同时,保留裂缝图像的细节特征。卷积-反卷积特征融合模块如图3所示,左边为VGG16提取的特征,右边为重建的反卷积特征,将二者按照1:1的比例进行拼接融合,并通过 1×1 的卷积学习融合特征图,从而得到卷积-反卷积融合特征(图3中间部分),其过程可描述为

$$O_s = \text{concatenate}(I_c^s, I_r^s) * K_s, \quad (1)$$

式中: O_s 表示第s阶段拼接融合输出的特征; I_c^s 表示

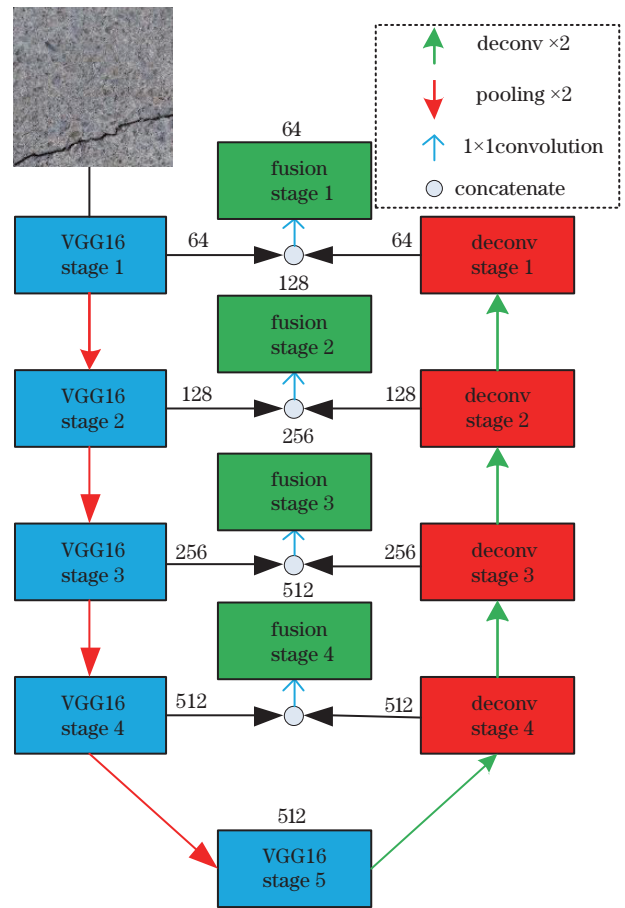


图3 卷积-反卷积特征融合模块

Fig. 3 Convolution-deconvolution feature fusion module

VGG16网络提取的第s阶段的特征; I_r^s 表示基于反卷积网络重建的第s阶段的特征; $\text{concatenate}(I_c^s, I_r^s)$

表示对提取的 I_c, I_r 特征图进行通道拼接融合操作; K_s 为一个 1×1 卷积核; * 表示卷积操作, c 表示卷积, t 表示反卷积。

反卷积层的参数及特征融合参数如表 1 所示, 表中 M 代表 VGG stage 5 的输出图像大小。和 VGG16 网络提取的特征相比, 所提基于卷积-反卷积网络特征的融合网络利用反卷积学习捕获裂缝图像语义特征, 并将高阶语义特征逐层向下与低

阶段特征进行融合, 进而对 VGG16 网络提取的 5 个阶段的裂缝特征进行了语义重建, 实现了 VGG16 网络多阶段、跨通道的特征信息交互与融合, 尤其是对于包含语义信息较少的 stage 1、stage 2、stage 3 等低阶段特征, 所提特征融合网络使得低阶段特征不仅保留了丰富的裂缝细节特征, 而且融合了更多的裂缝中级、高级语义特征, 有效消除了复杂背景纹理、噪声等特征的干扰。

表 1 反卷积网络结构及特征融合参数

Table 1 Deconvolution network structure and feature fusion parameters

Deconvolution stage	Convolution	Channel	Pool	Output
conv_5_3		512	Max, 2×2	2M×2M
Fuse with conv_4_3	1×1	512		2M×2M
D4(4_1,4_2,4_3)	3×3	256	Max, 2×2	4M×4M
Fuse with conv_3_3	1×1	256		4M×4M
D3(3_1,3_2,3_3)	3×3	128	Max, 2×2	8M×8M
Fuse with conv_2_2	1×1	128		8M×8M
D2(2_1,2_2)	3×3	64	Max, 2×2	16M×16M
Fuse with conv_1_2	1×1	64		16M×16M
D1(1_1,1_2)	3×3	64		16M×16M

2.3 边界细化模块

基于深度学习的分割方法有效提升了裂缝分割效果, 但是由于自然环境下混凝土背景纹理多变、裂缝模糊等因素常导致裂缝边界分割不精细。边界分割不精细的问题主要在于上采样跨度过大

导致边界信息丢失, 因此可以通过卷积融合上下文信息来学习边界特征, 从而提高边界分割的精度。为了获得更加准确的边界特征, 受文献[17-18]启发, 本实验组设计了一种边界细化模块对裂缝边界特征进行学习。所提边界细化模块如图 4 所示。

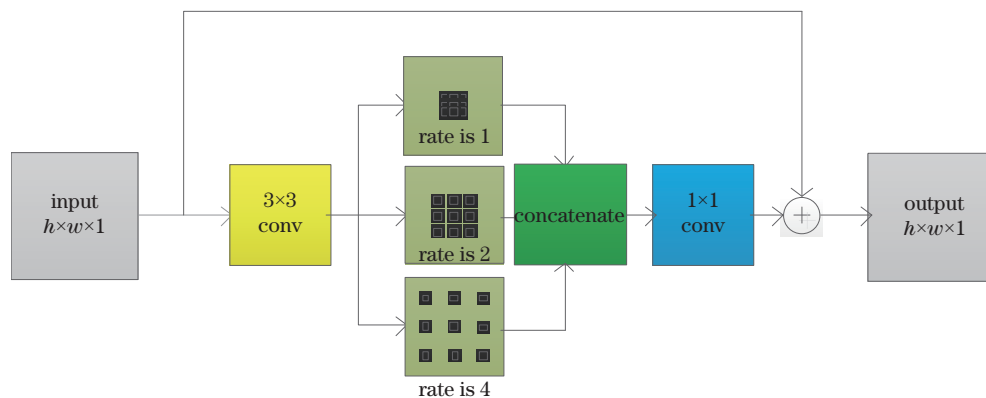


图 4 边界细化模块结构

Fig. 4 Structure of boundary refinement module

边界细化模块位于侧边网络输出和融合层后面, 边界细化模块主要由残差网络和空洞卷积组成。对于 $h \times w \times 1$ 的输入, 首先通过一个 3×3 卷积核进行初步特征提取, 裂缝边界情况复杂, 单一卷积核的感受野过于固定, 不能很好地对裂缝边界进行细化, 因此可以通过融合上下文信息

来提高边界预测准确率。为了获得不同大小感受野的边界特征信息, 本实验组使用了一组空洞卷积(空洞率分别为 1, 2, 4)来提取不同大小感受野边界特征, 将混合空洞卷积组提取的特征拼接融合再与原始特征响应相加, 最终边界细化模块的输出为

$$f_{BR} = \text{conv} \left\{ \text{cat} \left[\text{Aconv}(r_1, 1), \text{Aconv}(r_2, 2), \text{Aconv}(r_3, 4) \right] \right\} + f_{DS}, \quad (2)$$

式中: $\text{conv}(\cdot)$ 表示 1×1 卷积; $\text{Aconv}(r, n)$ 表示空洞率为 n 的空洞卷积; $\text{cat}(\cdot)$ 表示特征通道拼接; f_{DS} 表示深度监督模块输出特征图; f_{BR} 表示边界细化模块特征图。边界细化模块可以利用图像边界的上下文信息, 进一步提高裂缝边界分割的准确度。

3 分析与讨论

3.1 实验平台配置及数据集构建

实验平台硬件配置为 Inter Xeon E5 2650 处理器、32 GB 内存、2 个 NVIDIA TitanV Volta 12 GB 显卡 (GPU 处理单元)。开发环境为 Spyder 集成开发环境和 Python 3.6 语言, 操作系统为 Windows 10。深度学习框架采用 Pytorch 1.1、Nvidia 公司 CUDA 8.0 的 GPU 运算平台及 cuDNN 6.0 深度学习 GPU 加速库。实验数据集采用公共数据集 Bridge_Crack_Image_Data^[6] 和 Crack Forest Dataset

(CFD)^[19]。Bridge_Crack_Image_Data 共有 2000 张 1024×1024 大小的桥梁裂缝图像, 涵盖 5 种不同背景的桥面裂缝, 场景复杂, 识别难度较大, 实验以其中 1700 张作为训练集、100 张作为验证集、其余 200 张作为测试集。因为背景区域占比过大, 为了加强模型对裂缝区域的特征学习, 对训练集数据进行了数据增强, 手工选取图像中裂缝区域进行裁剪, 对图像进行多次旋转、翻转生成了 28818 张 256×256 大小的裂缝图像。CFD 包括 118 张路面裂缝图像, 均为路面裂缝, 背景单一, 多为细小裂纹, 图像大小均为 480×360 , 实验以其中 90 张作为训练集、10 张作为验证集、其余 18 张作为测试集。同样对训练集数据进行增强, 加强裂缝区域的特征学习, 裁剪裂缝区域, 旋转、翻转生成 2000 张 360×360 大小的裂缝图像。数据增强后的部分数据集如图 5 所示。




图 5 数据增强后的部分数据集

Fig. 5 Partial dataset after data enhancement

实验中训练过程中, batch-size 设为 16, epoch 为 60, 初始学习率为 0.01, 使用随机梯度下降进行优化, 动量为 0.9, 实验采用指数衰减学习率, 每 5 个 epoch 衰减 1 次, 衰减系数为 0.7。采用交叉熵损失

函数来训练模型, 交叉熵损失函数的表达式为

$$L = \begin{cases} -(1 - y') \log y' & , y = 1 \\ -y' \log(1 - y') & , y = 0 \end{cases}, \quad (3)$$

式中: L 代表交叉熵损失之和; y 代表标签类型, 1 为

裂缝,0为背景;输出概率 $y' \in [0, 1]$ 。同时裂缝分割正负样本极不均衡,背景占比过大,文献^[20]在交叉熵损失函数中添加Dice系数来减少正负样本不均衡带来的影响,本实验组为了使网络更好地学习前景裂缝特征,在交叉熵损失的基础上提出了Focal损失来提高裂缝像素学习的权重,其表达式为

$$L_{FL} = \begin{cases} -\alpha(1-y')^\gamma \log y', & y=1 \\ -(1-\alpha)y'^\gamma \log(1-y'), & y=0 \end{cases}, \quad (4)$$

式中: L_{FL} 代表Focal损失之和; α 为权重比,实验中采用背景像素点和裂缝像素点之比作为权重; γ 为难易样本指数系数,取为2。图6为所提模型训练集损失曲线和验证集精确度曲线。

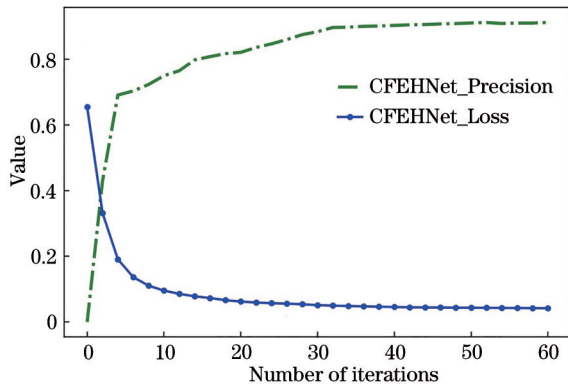


图6 训练损失值和验证精确率变化情况

Fig. 6 Change of training loss value and verification accuracy rate

为了验证CFEHNNet对于裂缝分割的有效性,与HED^[21]、UNet^[23]、SegNet^[24]等网络分别进行了定性、定量对比实验。所有网络均采用VGG16^[22]作为特征提取网络,其中UNet和SegNet使用了反卷积重建各阶段特征,HED使用了整体嵌套网络。对比实验分为5部分,第1部分为特征激活图可视化实验,包含两组,第1组用来验证卷积-反卷积特征融合模块对于激活图的影响,第2组用来验证深度监督模块对于激活图的影响;第2部分为各阶段侧边网络对于结果的贡献实验;第3部分为边界细化模块有效性验证实验;第4部分针对Bridge_Crack_Image_Data数据集验证了所提模型的有效性;第5部分针对CFD验证了所提模型的有效性。

定量分析分别选取精确率(precision)、召回率(recall)以及 F_1 分数作为模型评价指标。对于裂缝像素分类问题来说,只有裂缝和非裂缝两类,假设裂缝像素为正样本,非裂缝像素为负样本。上述评价指标可通过混淆矩阵计算,混淆矩阵如表2所示。

表2 混淆矩阵

Table 2 Confusion matrix

Sample	Predicted positive sample (positive)	Prediction negative sample (negative)
Actually positive sample (positive)	TP	FN
Actually negative sample (negative)	FP	TN

3个指标的表达式分别为

$$P_{\text{precision}} = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (5)$$

$$R_{\text{recall}} = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (6)$$

$$S_{F_1} = \frac{2 \times P_{\text{precision}} \times R_{\text{recall}}}{P_{\text{precision}} + R_{\text{recall}}}, \quad (7)$$

式中: N_m 分别表示该类型的数量, $m=TP, FN, FP, TN$ 。

3.2 特征激活图可视化实验

3.2.1 卷积-反卷积特征融合模块有效性可视化实验

为了验证特征融合模块提取的各阶段裂缝特征性能,对VGG16各阶段激活图和基于特征融合模块的VGG16的各阶段激活图进行可视化,结果如图7所示,其中第1行为使用特征融合模块的可视化激活图,第2行为VGG16各阶段可视化激活图。从图7可以看出,VGG16各阶段虽然可以捕捉到裂缝特征,但是各阶段都存在背景特征的较强干扰,特别是stage 1、stage 2两个阶段,背景纹理特征干扰尤其严重,而基于特征融合模块的激活图不仅保留了裂缝信息而且过滤了背景噪声。原因主要在于对VGG16第5阶段特征进行了反卷积学习,第5阶段特征包含了大量图像的高级语义信息,噪声和背景干扰特征较少,因此重建各阶段反卷积会有效消除噪声和背景纹理特征的干扰,并和VGG16同阶段卷积融合,这样就大大消除了噪声和背景纹理特征的干扰,同时细节特征也被保留下来。

3.2.2 深度监督模块有效性可视化实验

为验证深度监督模块的有效性,对CFEHNNet、SegNet、Unet的预测结果激活图进行可视化,结果如图8所示。所提模型、UNet、SegNet均使用VGG16作为特征提取网络,并使用反卷积重构了各阶段特征。UNet和SegNet没有使用深度监督模块,均只在最顶层输出预测结果,没有融合其他阶




图7 VGG16和特征融合模块可视化对比

Fig. 7 Visual comparison between VGG16 and feature fusion module




图8 深度监督模块有效性可视化对比

Fig. 8 Visual comparison of effectiveness of deep supervision module

段的输出。从可视化结果来看,UNet、SegNet的非裂缝区域仍然存在噪声,尤其是SegNet的预测结果受噪声干扰较大,而CFEHNNet通过各阶段特征融合有效地增强裂缝区域的特征响应,减弱非裂缝区域的特征响应,从而提高了网络对于裂缝线性结构特征的响应,激活图结果背景清晰,裂缝区域分割效果好。

3.3 各阶段侧边网络输出对于结果的贡献

为验证各阶段侧边网络输出对于实验结果的

贡献,分别单独去除 stage 1、stage 2、stage 3、stage 4 和全部保留进行了对比测试,实验结果如表 3 所示,去除 stage 1 对于结果贡献最大,在 Bridge_Crack_Image_Data 数据集上精确率下降了 6.22 个百分点,召回率下降了 1.56 个百分点, F_1 分数下降了 3.4 个百分点;在 CFD 数据集上精确率下降了 4.92 个百分点,召回率下降了 3.74 个百分点, F_1 分数下降 4.33 个百分点。去除 stage 4 对于结果贡献最小,在 Bridge_Crack_Image_Data 数据集上精确率下降了

表3 各阶段侧边网络输出对于结果的贡献

Table 3 Contribution of side network output to result in each stage

Condition	Bridge_Crack_Image_Data			Crack Forest Dataset		
	Precision	Recall	F_1	Precision	Recall	F_1
CFEHNNet without stage 1	0.8534	0.6907	0.7634	0.8615	0.8648	0.8631
CFEHNNet without stage 2	0.8756	0.6913	0.7726	0.8805	0.8845	0.8825
CFEHNNet without stage 3	0.8942	0.6945	0.7817	0.9058	0.9056	0.9057
CFEHNNet without stage 4	0.9134	0.7011	0.7932	0.9104	0.9013	0.9060
CFEHNNet	0.9156	0.7063	0.7974	0.9107	0.9022	0.9064

0.22个百分点,召回率下降了0.52个百分点, F_1 分数下降了0.42个百分点;在CFD数据集上精确率下降了0.03个百分点,召回率下降了0.09个百分点, F_1 分数下降了0.04个百分点。从表3可以发现,所有阶段特征均对结果有贡献,表明对不同阶段的卷积特征进行融合可以有效提高网络检测裂缝的性能。

3.4 边界细化模块有效性分析

为了验证边界细化模块的有效性,将裂缝图像分为两部分:边界区域,其像素到裂缝边界小于等于3个像素的部分;内部区域,其他裂缝像素。对使用边界细化模块和不使用边界细化模块的模型进行了对比实验,实验结果如表4所示。从表4可以看出,边界细化模块对裂缝边界区域分割准确度有一定提高,相比于不使用边界细化模块的模型,在边界区域准确率提高了1.93个百分点,内部区域无明显改变,整体提升了0.47个百分点,这说明了所提边界细化模块可以进一步提高裂缝边界分割精度。

表4 边界细化模块对比实验

Table 4 Comparison experiment of boundary thinning module

Model	Boundary accuracy	Center accuracy	Overall accuracy
CFEHNet without BR	0.7138	0.9412	0.9167
CFEHNet	0.7331	0.9414	0.9214

3.5 模型对比实验结果分析

3.5.1 Bridge_Crack_Image_Data数据集对比实验

为了验证所提网络对于裂缝分割的有效性,分别采用CFEHNet与HEDNet^[17]、UNet^[20]、SegNet^[21]等网络在Bridge_Crack_Image_Data数据集上进行了裂缝分割对比实验,部分检测结果如图9所示,其中第1列为原图,第2列为ground truth,第3~5列分别为UNet、SegNet、HEDNet检测结果,最后1列为所提网络检测结果。

定性分析。从对比结果图可以看出:对于背景干扰较少且裂缝清晰的裂缝来说,如[图9(1)],实验中所有模型都可以清晰地检测出裂缝;但是对于背景较为复杂,且干扰信息较多的测试图来说,如[图9(2)],其背景为石子路,纹理非常复杂且存在污渍,裂缝总体较为清晰。从测试对比结果中可以发现:SegNet和UNet使用了反卷积重建了各阶段特征图,利用了深层语义信息和浅层细节信息的结合,可以较好地检测出裂缝区域,但是对于一些大的污渍存在误判;HEDNet对于污渍只有少量误判,说明HEDNet可以更好地捕捉线性拓扑特征,但是检测的裂缝区域出现了断裂现象,这是因为HED各阶段特征直接来自VGG16,没有使用反卷积重建各阶段特征,缺乏语义信息,在裂缝对比度不高的区域容易发生断裂。CFEHNet在HEDNet的基础上使用了卷积-反卷积特征融合模块增强各阶段裂缝特




图9 Bridge_Crack_Image_Data部分测试结果对比

Fig. 9 Comparison of partial test results of Bridge_Crack_Image_Data

征,多尺度特征融合模块抑制非裂缝区域的特征响应,优化了裂缝特征激活图响应,不仅完整地提取了裂缝,并且可以对块状污渍区域进行正确分割。对于背景干扰较少,但是裂缝区域与背景差异很小且裂缝较为细小的场景来说,如[图 9(3)、图 9(4)],HED 由于缺少语义特征,分割结果中裂缝出现断裂现象,UNet 和 SegNet 将浅层信息和深层信息融合,对于这类裂缝的检测有所改善。所提网络融合了上下文信息,不仅可以准确提取细小的裂缝,而且得到了连续的裂缝结构,表明所提网络具有较强捕获线性拓扑结构的能力。

定量分析。不同模型在 Bridge_Crack_Image_Data 数据集中检测结果的定量分析如表 5 所示。从表 5 可以看出:UNet 和 SegNet 的 F_1 分数指标要优于 HED 网络,说明反卷积重构各阶段特征对于裂缝提取具有更重要的作用;所提网络在精确率、召回率、 F_1 分数等指标上均取得了优于所有对比模型的结果。与不使用边界细化模块的 CFEHNet 相比,所提网络进一步提高了裂缝边界分割的精准度,其精确率、召回率、 F_1 分数分别提升了 0.58 个百分点、

0.38 个百分点、0.47 个百分点;相比于 HED、UNet、SegNet,其 F_1 分数指标分别提高了 4.13 个百分点、2.81 个百分点、3.16 个百分点。因此,从定性指标来看,所提网络具有更好的识别能力。

3.5.2 CFD 对比实验

为进一步验证所提网络的有效性,在 CFD 上进行裂缝检测对比实验。对比网络在 CFD 上的部分检测结果如图 10 所示,其中第 1 列为原图,第 2 列为 ground truth,第 3~5 列分别为 SegNet、UNet、HEDNet 的检测结果,最后 1 列为所提网络检测结果。

定性分析。CFD 为路面裂缝数据集,裂缝区域具有对比度低和细小的特点。从图 10 可以看出,对于不同结构的裂缝区域,和 UNet、SegNet、HEDNet 的检测结果相比,CFEHNet 的检测结果均是最优的。在[图 10(1)]中,在一些裂缝对比度低区域及裂缝细小区域,其他模型均出现了多处漏检和错检现象,所提模型在这些难度较大检测的位置仍然可以很好检测,并保留了裂缝细节。[图 10(2)]中存在干扰物油滴,所提模型可好过滤掉油滴的干扰,并提取了裂缝区域,而 UNet 和 SegNet 这些网络,将一些油滴检测为裂缝。在[图 10(3)]中一段裂缝明显,另一段裂缝模糊,所提模型对模糊的裂缝也具有较好的检测能力。[图 10(4)]为大规模龟裂裂缝,且部分裂缝区域对比度低,所提模型可以将大部分区域正确检测且保留裂缝细节,说明模型在复杂情况下也有很强的线性拓扑结构捕捉能力,但是在一些地方仍然会出现漏检现象,如图中矩形框部分,部分裂缝区域断裂。

表 5 Bridge_Crack_Image_Data 上的定量分析比较
Table 5 Comparison of quantitative analysis of Bridge_Crack_Image_Data

Algorithm	Precision	Recall	F_1
HED ^[21]	0.9167	0.6503	0.7608
UNet ^[23]	0.8945	0.6822	0.7740
SegNet ^[24]	0.8745	0.6887	0.7705
CFEHNet without BR	0.9156	0.7063	0.7974
CFEHNet	0.9214	0.7101	0.8021




图 10 CFD 上的部分测试结果对比

Fig. 10 Comparison of partial test results of CFD

定量分析。不同模型在 CFD 中检测结果的定量分析如表 6 所示。从表 6 可知,所提网络的精确率、召回率、 F_1 分数分别达到了 0.9164、0.9062 和 0.9113, 优于其他对比方法。和 HED、UNet、SegNet 等网络相比,CFEHNNet 的 F_1 分数分别提高了 4.36 个百分点,2.59 个百分点,3.11 个百分点。因此,从定性指标对比来说,所提网络具有更好的识别能力。

表 6 CFD 上的定量分析比较

Table 6 Comparison of quantitative analysis of CFD

Algorithm	Precision	Recall	F1-score
HED ^[21]	0.8656	0.8699	0.8677
UNet ^[23]	0.8811	0.8897	0.8854
SegNet ^[24]	0.8816	0.8789	0.8802
CFEHNNet without BR	0.9107	0.9022	0.9064
CFEHNNet	0.9164	0.9062	0.9113

在 Bridge_Crack_Image_Data 和 CFD 的对比实验和定量分析表明,所提网络有效解决了裂缝的背景复杂、背景前景差别小、裂缝线性细长易断裂等问题对于裂缝检测结果的干扰,能准确分割出混凝土裂缝区域。因此,所提网络不仅能准确检测混凝土裂缝,具有更好的裂缝线性拓扑结构识别能力,而且对于复杂背景下各种强干扰具有鲁棒性。

4 结 论

提出了一种特征增强整体嵌套网络混凝土裂缝检测方法。所提方法对于具有背景复杂、细小特征的裂缝具有较好分割性能。该方法通过多尺度监督学习,融合不同卷积阶段的预测结果,提高了网络对线性拓扑结构的捕捉能力;提出了卷积-反卷积特征融合模块,将每个阶段的卷积特征和反卷积特征融合,利用卷积早期细节特征和反卷积语义特征增强了裂缝特征质量;通过边界细化模块进一步对裂缝边界进行细化分割,提高了裂缝边界分割精度。实验结果表明,所提网络具有较好的识别能力和鲁棒性。

参 考 文 献

[1] Tang J X, Gu Y L. Automatic Crack Detection and Segmentation Using a Hybrid Algorithm for Road Distress Analysis[C]. IEEE International Conference on Systems. 2013:3026-3030.
 [2] Kim H, Ahn E, Cho S, et al. Comparative analysis

of image binarization methods for crack identification in concrete structures[J]. Cement and Concrete Research, 2017, 99:53-61.

- [3] Hu Y, Zhao C X, Wang H N. Automatic Pavement Crack Detection Using Texture and Shape Descriptors [J]. IETE Technical Review, 2010, 27(5):398-405.
 [4] Huynh P, Ross R, Martchenko A, et al. Dou-edge evaluation algorithm for automatic thin crack detection in pipelines[C]//2015 IEEE International Conference on Signal and Image Processing Applications (ICSIPA). IEEE, 2015: 191-196.
 [5] Jiang X, Ma Z J, Ren W X. Crack Detection from the Slope of the Mode Shape Using Complex Continuous Wavelet Transform[J]. Computer-Aided Civil and Infrastructure Engineering, 2012, 27(3): 187-201.
 [6] 李良福,马卫飞,李丽,等.基于深度学习的桥梁裂缝检测算法研究[J].自动化学报,2019,45(09):1727-1742.
 Li L F, Ma W F, Li L, et al. Research on bridge crack detection algorithm based on deep learning [J]. Acta automatica Sinica, 2019, 45 (09): 1727-1742.
 [7] Cha Y J, Choi W, Choi Wooram, et al. Deep learning-based crack damage detection using convolutional neural networks[J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5): 361-378.
 [8] Yang Q, Shi W, Chen J, et al. Deep convolution neural network-based transfer learning method for civil infrastructure crack detection[J]. Automation in Construction, 2020, 116:103199.
 [9] Yang X C, Li H, Yu Y, et al. Automatic pixel-level crack detection and measurement using fully convolutional network[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(12): 1090-1109.
 [10] 王森,伍星,张印辉,等.基于深度学习的全卷积网络图像裂纹检测[J].计算机辅助设计与图形学学报, 2018, 30(05):859-867.
 Wang S, Wu X, Zhang Y H, et al. Full convolution network image crack detection based on deep learning [J]. Journal of computer aided design and graphics, 2018, 30 (05): 859-867.
 [11] 杨杰文,章光,陈西江,等.融合深度学习聚类分割和形态学的混凝土表面裂缝量化识别[J].激光与光电子学进展, 2020, 57(22): 221023.
 Yang J W, Zhang G, Chen X J, et al. Quantitative identification of concrete surface cracks based on deep learning clustering segmentation and morphology[J]. Laser & Optoelectronics Progress, 2020, 57(22): 221023.

- [12] Ren Y, Huang J, Hong Z, et al. Image-based concrete crack detection in tunnels using deep fully convolutional networks[J]. *Construction and Building Materials*, 2020, 234:117367.
- [13] Liu W, Huang Y, Li Y, et al. FPCNet: Fast pavement crack detection network based on encoder-decoder architecture[J]. *arXiv preprint arXiv:1907.02248*, 2019.
- [14] 曹锦纲, 杨国田, 杨锡运. 基于注意力机制的深度学习路面裂缝检测[J]. *计算机辅助设计与图形学学报*, 2020, 32(08):1324-1333.
Cao J G, Yang G T, Yang X Y. Deep learning pavement crack detection based on attention mechanism [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2020, 32 (08): 1324-1333.
- [15] Zou Q, Zhang Z, Li Q, et al. Deepcrack: Learning hierarchical convolutional features for crack detection [J]. *IEEE Transactions on Image Processing*, 2018, 28(3): 1498-1512.
- [16] 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.
- [17] 王爱丽, 张宇泉, 吴海滨, 等. 基于空洞卷积胶囊网络的激光雷达数据分类[J]. *中国激光*, 2021, 48(11): 1110003.
Wang A L, Zhang Y X, Wu H B, et al. Lidar data classification based on hole convolution capsule network[J]. *Chinese Journal of Lasers*, 2021, 48(11): 1110003.
- [18] Xie S, Tu Z. Holistically-nested edge detection[C]// *Proceedings of the IEEE international conference on computer vision*. 2015: 1395-1403.
- [19] Peng C, Zhang X, Yu G, et al. Large kernel matters: improve semantic segmentation by global convolutional network[C]// *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017: 4353-4361.
- [20] Shi Y, Cui L M, Qi Z Q, et al. Automatic road rack detection using random structured forests[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(12): 3434-3445.
- [21] 张世宽, 吴清潇, 林智远. 焊缝图像中结构光条纹的检测与分割[J]. *光学学报*, 2021, 41(05):88-96.
Zhang S K, Wu Q X, Lin Z Y. Detection and segmentation of structured light stripe in weld image [J]. *Acta optica Sinica*, 2021, 41 (05): 88-96.
- [22] 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*. Springer, Cham, 2015: 234-241.
- [23] 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.
- [24] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. *arXiv preprint arXiv:1409.1556*, 2014.