

基于 Deepcrack 网络的混凝土裂缝检测方法

武斌, 马玉静, 刘宇航, 赵洁*

(天津城建大学 计算机与信息工程学院, 天津 300384)

摘要:混凝土结构裂缝对建筑安全构成了极大的潜在威胁,裂缝检测对建筑结构的维护具有重要意义,当前基于深度学习的裂缝检测针对提取裂缝细节的能力仍有待提高。因此,该文对 Deepcrack 网络进行优化,提出了基于金字塔分割注意力和全局上下文的混凝土裂缝检测算法 PG-Deepcrack。首先,在编码器中提出双卷积-注意力并行模块,增加金字塔分割注意力分支为卷积层提供更丰富的多尺度裂缝信息;其次,为了捕获长距离依赖关系,并行模块操作后引入全局上下文模块,进一步提升网络对裂缝细节的表达能力;最后,在特征融合阶段利用全维动态卷积和 GELU 激活函数,对编解码器特征层联级融合,使网络更全面地保留不同尺寸的裂缝信息并提高模型的泛化性能。为验证网络模型的有效性,在 Deepcrack 数据集上与 7 个网络模型进行对比试验,所提出的网络表现了最佳性能, IoU 达到了 72.78%。

关键词:图像分割;裂缝检测;金字塔分割注意力;全局上下文;全维动态卷积

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2024)04-0198-07

doi:10.20165/j.cnki.ISSN1673-629X.2024.0030

Concrete Crack Detection Method Based on Deepcrack Network

WU Bin, MA Yu-jing, LIU Yu-hang, ZHAO Jie*

(School of Computer and Information Engineering, Tianjin Chengjian University, Tianjin 300384, China)

Abstract: Concrete structural cracks pose a great potential threat to building safety, and crack detection is of great significance to the maintenance of building structures. The current deep learning-based crack detection for extracting crack details still needs to be improved. Therefore, we optimize the Deepcrack network and propose a concrete crack detection algorithm PG-Deepcrack based on pyramid split attention and global context. Firstly, a dual-convolution-attention parallel block is proposed in the encoder to add a pyramid-split attention branch to provide richer multi-scale crack information for the convolutional layer. Secondly, in order to capture long-distance dependencies, a global context block is introduced after the operation of the parallel block, which further improves the ability of network to express the crack details. Finally, the omni-dimensional dynamic convolution and the GELU activation function are utilized in the feature fusion stage to cascade-level fusion of codec features, so that the network retains the information of different sizes of cracks in a more comprehensive way and improves the generalization performance of the model. To validate the effectiveness of the network model, a comparative test is conducted with seven network models on the DeepCrack dataset, and the proposed network exhibits the best performance with an IoU of 72.78%.

Key words: image segmentation; crack detection; pyramid split attention; global context; omni-dimensional dynamic convolution

0 引言

受多种因素影响,混凝土建筑结构表面极易产生裂缝,导致建筑结构加速恶化,缩短了使用寿命,严重时会造成重大的人民财产损失和恶劣的社会影响。因此,混凝土建筑的安全性和稳定性成为人们关注的首要问题,及早发现裂缝并采取合理的维护措施对于避免灾难性事故的发生具有重要意义^[1]。

在人工智能发展早期,基于图像处理技术的裂纹检测方法得到了广泛研究与应用,其中主要包括基于阈值分割^[2-3]、小波变换^[4-5]、边缘检测^[6-7]和形态学操作^[8-9]等不同算法。这些算法在一定程度上解决了人工目视存在的缺陷,大大提高了检测效率,检测结果具有客观性。然而在实际应用中,这些算法仅能有效地检测出某一种特定环境下的裂缝图像,需要根据开发

收稿日期:2023-07-03

修回日期:2023-11-03

基金项目:天津市科技计划项目重大科技专项(14ZCZDZX00868);天津市重点研发计划科技支撑重点项目(19YFZCGX00130);天津市企业科技特派员项目(19JCTPJC47200)

作者简介:武斌(1966-),男,教授,硕士,研究方向为机器视觉与模式识别;通信作者:赵洁(1984-),男,副教授,博士,研究方向为图像处理、计算机视觉。

者经验选择最适合的算法并调参以获得准确的检测结果,即存在泛化能力弱、鲁棒性差的问题。

随着深度学习的迅速发展,越来越多的研究人员将卷积神经网络应用于土木工程领域,进一步提高了对裂缝的检测效率和精度。Ren 等人^[10]提出了基于 SegNet 的 CrackSegNet 裂纹检测网络,该网络更有效地提取了多尺度特征,取得了更高的检测精度,但 IoU 值仅达到了 59.06%,检测效果仍有待提升。Zaid 等人^[11]基于多尺度目标定位和增量标注细化提出了具有弱监督框架的路面裂缝分割网络,但该网络没有关注细小裂缝的分割问题。Li 等人^[12]提出了基于 VGG16 网络结构的跳过连接裂纹检测网络 SCCDNet,利用深度可分离卷积法提高了裂纹分割的精度,同时降低了模型的复杂性,但其精度只能达到 0.729 4,远低于 0.829 6 的召回率,表明抗错误检测的能力弱于抗遗漏检测的能力。Wang 等人^[13]提出了一种结合注意力机制和空间金字塔的裂纹分割网络,该模型关注到了对裂缝细节信息的提取精度但忽略了背景噪声对裂缝的干扰,检测效果不理想。刘凡等人^[14]基于 U-Net 网络提出了并行注意力机制,分别从通道和空间两个维度关注裂缝信息并抑制背景噪声,但检测结果中存在裂缝间断、不连续的问题。综上所述,由于裂缝在背景、形状、大小等方面具有多样复杂性,基于卷积神经网络的混凝土裂缝分割仍然是一项具有挑战性的

检测任务。

为进一步加强神经网络对裂缝背景噪声的抗干扰性,同时提升对裂缝细节的检测效果,该文以 Zou 等人^[15]提出的 Deepcrack 网络为基础,提出了一种结合金字塔分割注意力(pyramid split attention)和全局上下文信息(global context)的混凝土裂缝检测网络模型 PG-Deepcrack。主要贡献如下:

- (1) 提出了双卷积-注意力并行模块,在基础的卷积分支上,再增加一个金字塔分割注意力分支,为原卷积层补充多尺度、更丰富的裂缝信息,提高网络对细小裂缝表达的准确性。
- (2) 在编码器中引入全局上下文模块,自适应地调整图像不同区域的权值,捕获像素级长距离依赖关系,进行全局上下文建模,加强网络对裂缝区域的关注度,并能进一步消除背景噪声的干扰。
- (3) 在特征融合部分使用全维动态卷积和 GELU 激活函数,实现对多尺度特征的自适应融合,增强融合效果。

1 文中方法

1.1 网络结构

该文提出的混凝土裂缝检测的网络模型 PG-Deepcrack 主要分为三部分:编码器、解码器和特征融合,整体结构如图 1 所示。

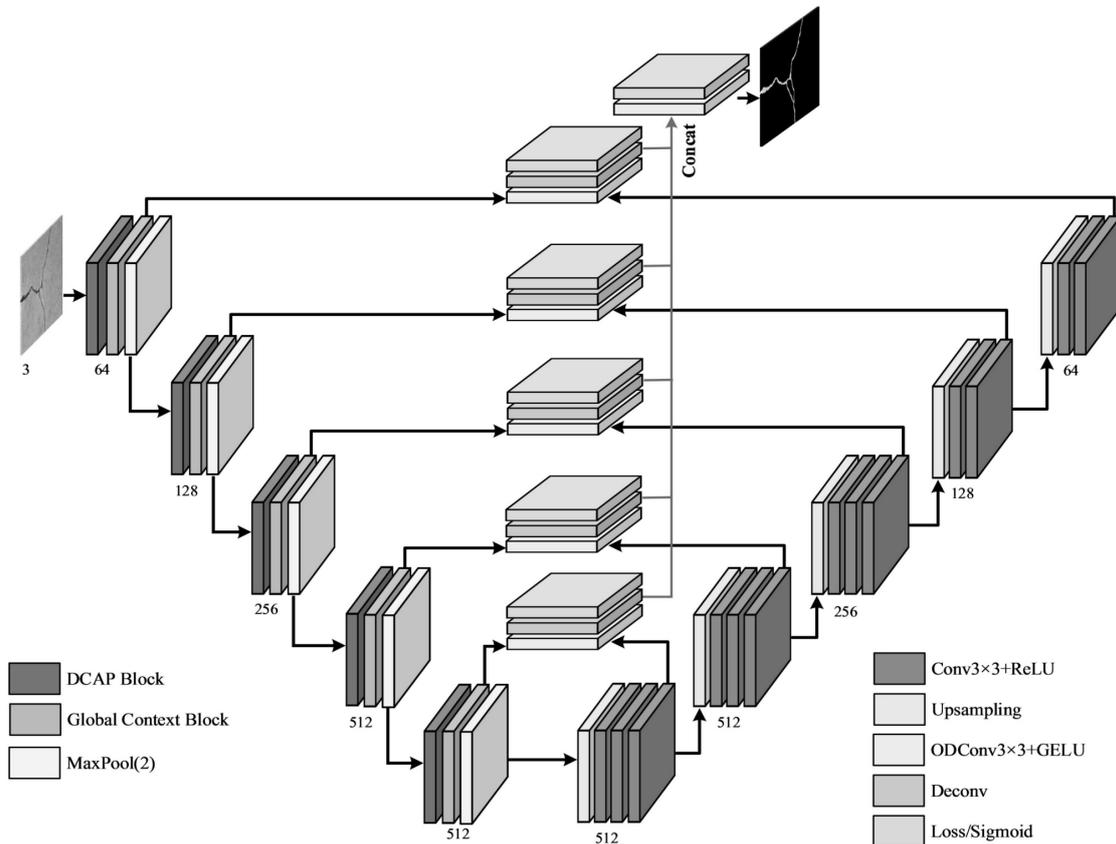


图 1 PG-Deepcrack 网络结构

其中,图中的数字表示通道数。模型的编码器与解码器各有五个卷积模块,在编码器中使用双卷积-注意力并行模块(DCAP)代替原 Deepcrack 网络中的五层普通卷积模块,减少了裂缝细节信息在卷积和池化过程中的丢失,保留更丰富的裂缝细节像素;在每个双卷积-注意力并行模块之后引入全局上下文模块(GC),通过对特征图建模,建立长距离依赖关系,使网络增强对裂缝的关注,抑制背景噪声的影响。在特征融合部分,使用一个卷积核大小为 3×3 的全维动态卷积层和 GELU 激活函数,融合编解码器对应层的特征图,捕捉到两个特征层之间的相互作用关系,解决尺度变化带来的问题,使得模型具有更好的鲁棒性。为减少计算开销,解码器部分仍然保留原网络中的卷积模块。

1.2 双卷积-注意力并行模块

在裂缝分割任务中,裂缝边缘像素容易被误判注为背景噪声,进而造成边缘细节丢失。为了保留丰富的裂缝边缘细节,该文提出了双卷积-注意力并行模块(Dual-Convolution-Attention Parallel Block, DCAP),结构如图 2 所示。该模块由两个分支结构组成,其中一个分支由两个 3×3 大小的卷积层组成,有

效地对输入图像中的裂缝信息进行特征提取;另一个分支由一个 1×1 大小的卷积层和金字塔分割注意力模块(PSA)构成,能够使网络在特征提取阶段增强对裂缝的关注度,有效减少裂缝信息的丢失,增强裂缝的特征表达力。最后将两个分支结构拼接融合,第二分支为第一分支补充更丰富的细节特征,提高裂缝检测的准确率和鲁棒性。

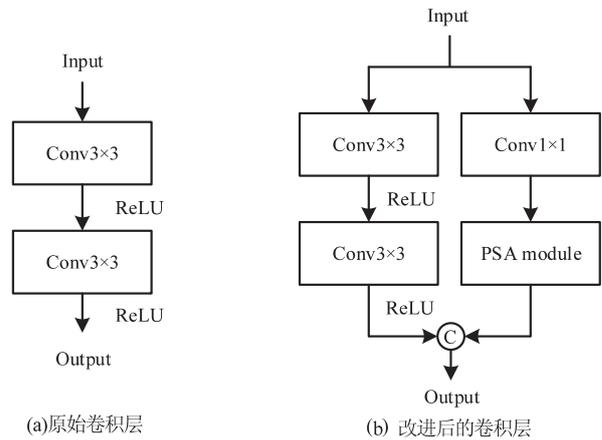


图 2 双卷积-注意力并行模块结构

金字塔分割注意力(Pyramid Split Attention, PSA)^[16]结构如图 3 所示。

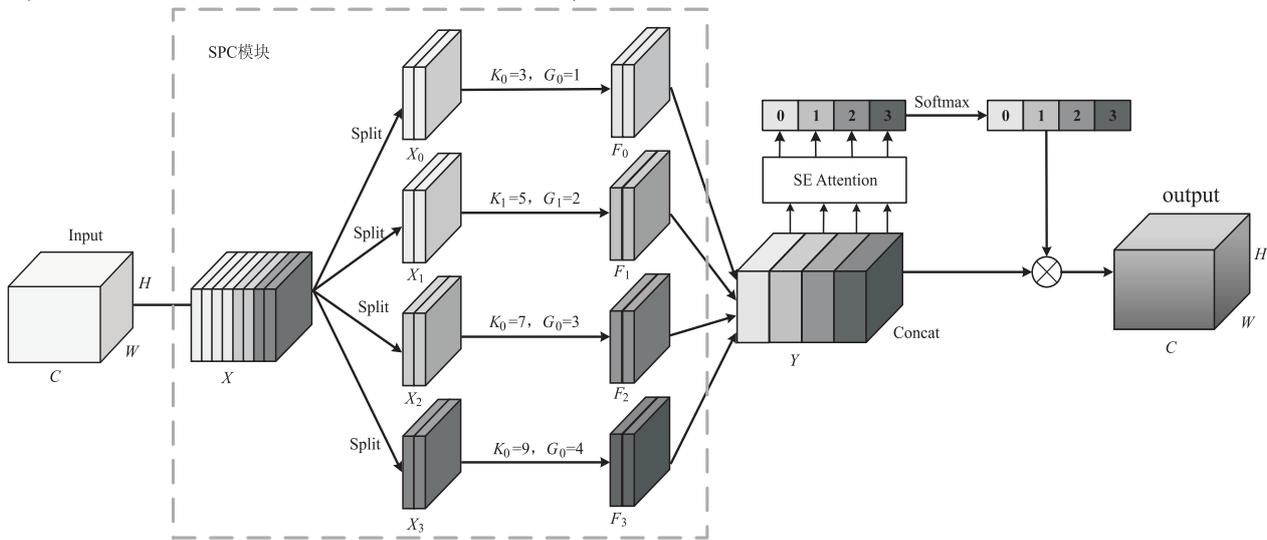


图 3 金字塔分割注意力模块

第一步,通过分割和融合模块(Split and Concat, SPC)将输入特征 X 的通道划分为 4 组生成 $X_i (i = 0, 1, 2, 3)$,每组分别对应 3, 5, 7, 9 大小的卷积核提取信息,产生 4 组多尺度信息的特征图 $F_i (i = 0, 1, 2, 3)$,最后由 Concat 拼接操作得到多尺度特征图 F 。其中特征图 F_i 与 F 分别用公式 1、公式 2 表示:

$$F_i = \text{Conv}(K_i \times K_i)(X_i), i = 0, 1, 2, 3 \quad (1)$$

$$F = \text{Cat}([F_0, F_1, \dots, F_3]) \quad (2)$$

第二步,利用压缩和激励模块(Squeeze-and-Excitation, SE)^[17]将多尺度特征图进行全局平均池化编码全局信息,获得不同尺度特征图的注意力权重

Z_i ;为实现注意力信息交互并融合跨维度信息,将 Z_i 进行 Concat 拼接生成向量 Z ,利用 Softmax 再分配特征图权重向量,此过程分别用公式 3~5 表示:

$$Z_i = \text{SEWeight}(F_i), i = 0, 1, 2, 3 \quad (3)$$

$$Z = Z_0 \oplus Z_1 \oplus Z_2 \oplus Z_3 \quad (4)$$

$$\text{att} = \text{Softmax}(Z) \quad (5)$$

最后,将归一化的权重向量 att 与特征图 F 进行点乘操作,生成的特征用公式 6 表示。此操作实现了注意力权重和通道之间的交互,使在特征图中对裂缝识别更重要的通道被赋予更高的权重。

$$X' = F \odot \text{attention} \quad (6)$$

1.3 全局上下文模块

为避免通过堆叠卷积层的方式获取全局上下文信息,该文在编码器中引入全局上下文模块(Global Context, GC)^[18],用于提取全局上下文信息,从而获得更丰富的浅层和深层特征,消除无关背景噪声的干扰,其结构如图 4 所示。

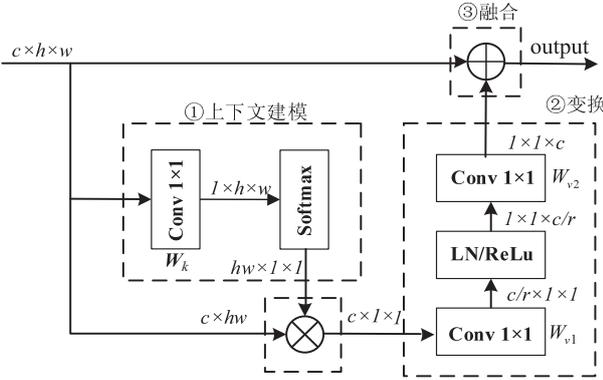


图 4 全局上下文模块

由图 4 可以看出,全局上下文模块可以划分为三个阶段:第一阶段是上下文建模操作,采用 1×1 卷积 W_k 和 Softmax 函数生成关注权重,通过归一化所有输出来保证它们的总和等于 1,避免预测结果偏离实际情况。它将所有位置的特征聚合在一起,形成一个全局上下文特征。第二阶段是特征变换操作, W_{v1} 和 W_{v2} 是两个 1×1 的卷积层,其通道数分别为 C/r 和 C, C

表示输入特征映射的通道数, r 表示维度的缩减比,其中 r 等于 16。由于两层瓶颈变换使优化更加困难,因此在瓶颈变换中(在 ReLU 前面)加入了层归一化(Layer Normalization, LN),降低优化难度,提高泛化性。通过 1×1 卷积 W_p 进行特征变换,捕获通道维度之间的相互依赖性。第三阶段是相加操作,将原始的特征图与变换后的特征图进行融合。GC 模块的整体表达式如公式 7 所示:

$$z_i = x_i + W_{v2} \text{ReLU}(\text{LN}(W_{v1} \sum_{j=1}^{N_p} \frac{e^{W_{x_j}}}{\sum_{m=1}^{N_p} e^{W_{x_m}}} x_j)) \quad (7)$$

1.4 动态融合模块

为了保留最丰富的裂缝信息,该文在特征融合模块中使用了全维动态卷积和 GELU 激活函数实现编解码器对应特征层之间的动态融合。通过将不同尺度的特征图进行组合,可以帮助模型更全面地识别和定位裂缝,提高裂缝分割的精度,增强网络的鲁棒性。

1.4.1 全维动态卷积

全维动态卷积(Omni-Dimensional Dynamic Convolution, ODConv)^[19],其结构如图 5 所示。首先,通过逐通道全局平均池化(Global Average Pooling, GPA)运算将输入特征 x 压缩到具有 c_{in} 长度的特征向量中。经 FC 层将压缩特征向量映射到具有压缩比 $r = 1/16$ 的低维空间,降低模型复杂度。

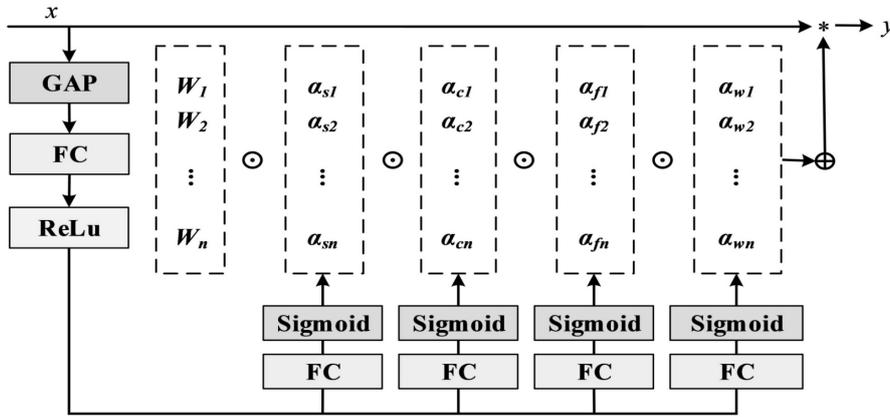


图 5 全维动态卷积

对于 4 个头部分支,每个分支由 FC 层和 Sigmoid 函数组成,分别生成归一化的 $\alpha_{wi}, \alpha_{fi}, \alpha_{ci}$ 和 α_{si} 。ODConv 利用多维注意力机制并以并行方式沿核空间的卷积核数量、输出通道数、输入通道数和空间维度(4 个维度)学习 4 种类型的注意,显著增强了基本卷积运算的特征提取能力。其计算公式表示为:

$$y = (\alpha_{w1} \odot \alpha_{f1} \odot \alpha_{c1} \odot \alpha_{s1} \odot W_1 + \dots + \alpha_{wn} \odot \alpha_{fn} \odot \alpha_{cn} \odot \alpha_{sn} \odot W_n) * x \quad (8)$$

其中, $\alpha_{wi} \in R$ 表示将注意力标量分配给整个卷积核, $\alpha_{fi} \in R^{c_{in}}$ 表示为每个滤波器 W_n 输出通道 c_{out} 分配不同

的标量, $\alpha_{ci} \in R^{c_{in}}$ 表示为每个滤波器 W_n 的输入通道 c_{in} 分配不同的标量, $\alpha_{si} \in R^{k \times k}$ 表示为每个滤波器 W_n 在空间位置处分配不同的标量, \odot 表示沿着核空间的不同维度的乘法运算, $*$ 表示卷积运算。

1.4.2 GELU 激活函数

高斯误差线性单元(GELU)^[20]是一种高性能的非线性激活函数,因为其非线性变化是一种符合预期的随机正则变换方式,其本质是 Dropout、Zoneout 和 ReLU 的合成。与 ReLU 激活函数相比,它在零点附近比 ReLU 更加平滑,这可以使模型有更好的泛化性能。

因此,该文在每个动态卷积后配合使用 GELU 激活函数,不仅提高了模型的训练速度和精度,而且减少了模型参数数量。

2 实验结果与分析

2.1 实验配置

为了保证实验的真实性和统一性,实验在基于 Ubuntu 和 Cuda11.4 建立的深度学习环境下进行,所提出的网络模型及消融实验、对比实验采用相同的系统、平台以及编译环境。计算机硬件和环境配置参数详如表 1 所示。

表 1 实验环境及配参数

硬件/软件	参数/版本
操作系统	Ubuntu18.04.6
CPU	Inter(R) Core(TM) i9-10900X CPU @ 3.70GHz×20
GPU	NVIDIA GeForce RTX 3080 Lite Hash Rate
内存	32 GB
Anaconda	4.10.1
PyTorch	1.11.0
Python	3.9

在网络训练中优化器选择 Adam,学习率设置为 $1e-4$,使用交叉熵损失函数,由于内存的限制,多线程的数量和批处理的大小设置为 1 个,并使用 200 个 epoch 进行训练。

2.2 实验数据集

所有实验均在公开数据集 Deepcrack (Liu)^[21] 上进行训练,并在 Deepcrack 测试集上进行测试。Deepcrack 是一个包含 537 幅大小为 544×384 像素的混凝土裂缝数据集,其中 300 张为训练集,237 张为测试集。它具有多场景多尺度的混凝土裂缝,包括遮挡、阴影、水坑、污渍等多种噪声。

2.3 评价指标

混凝土裂缝分割的实质是对图像上每个像素点进行二分类。因此,每个像素的检测结果可分 4 类,得到的混淆矩阵可由表 2 所示。

表 2 混淆矩阵

混淆矩阵		真实值	
		Positive	Negative
预测值	Positive	TP	FP
	Negative	FN	TN

为全面衡量网络模型的性能,该文使用了 5 个评价指标:准确率 (Accuracy)、精确度 (Precision)、召回率 (Recall)、F 值 (F1-score)、交并比 (IoU)。将使用 IoU 值作为性能评估的总体指标。

准确率表示模型预测正确的结果(包括正样本和负样本)所占总体的比例:

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FN} + \text{FP} + \text{FN}} \quad (9)$$

精确度表示被正确预测的正样本与所有被预测为正样本之比,其值越大则表示裂缝的分割越准确:

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (10)$$

召回率表示被正确预测的正样本与实际正样本之比,其值越大则表示裂缝的分割越完全:

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (11)$$

F 值被定义为召回率和精确度的调和平均值,其值越大则表示裂缝的分割越有效:

$$\text{F1-score} = \frac{2 * \text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (12)$$

IoU 是模型预测图与真值图的交集和并集的面积之比,其值越大则表示预测图与真值图的重叠程度越高:

$$\text{IoU} = \frac{\text{TP}}{\text{TP} + \text{FP} + \text{FN}} \quad (13)$$

2.4 实验结果

2.4.1 对比实验

将文中网络模型与四个经典的分割网络模型 (DeconvNet^[22]、FCN^[23]、U-Net^[24]、SegNet^[25]) 和三个先进的裂缝检测网络模型 (Deepcrack^[15]、LinkCrack^[26]、AR-Unet^[27]) 进行了比较,验证所提网络的有效性。

以上网络模型在 Deepcrack 数据集上的可视化结果如图 6 所示。从第一、二行结果中可以看出,文中方法对细小裂缝表达能力更强,检测结果更完整;从第五行可以看出,文中方法不易受裂缝边缘噪声的干扰,检测结果更准确。总体而言,提出的 PG-Deepcrack 网络在 Deepcrack 测试集上对细小裂缝检测效果最佳,对形状复杂的裂缝检测结果最完整;且受噪声的影响最小,出现错检、漏检的情况更少,但对于成像不清晰、低对比度的裂缝区域,该模型分割的效果仍有待提高。表 3 记录了各个网络模型在 Deepcrack 测试集中的性能表现,与以上 7 个网络相比,PG-Deepcrack 获得了最佳的 A、P、R、F1 和 IoU 值,分别达到了 98.71%、83.25%、86.28%、83.33% 和 72.78%。因此,从实验数据中可以看出,改进后的 PG-Deepcrack 网络对裂缝细节的表达能力更强,对背景噪声的抗干扰性更强,在裂缝的分割性能上有大幅提升。

2.4.2 消融实验

为验证提出的不同改进方法的有效性,进行了模块消融实验。以 Deepcrack 网络为基准,在 Deepcrack

测试集上讨论了 DCAP 模块、GC 模块、动态融合模块以及三个模块之间的组合作对裂缝提取精度的效

果。各模块在网络中的性能表现如表 4 所示,其中“√”表示使用的模块,“—”表示未使用的模块。

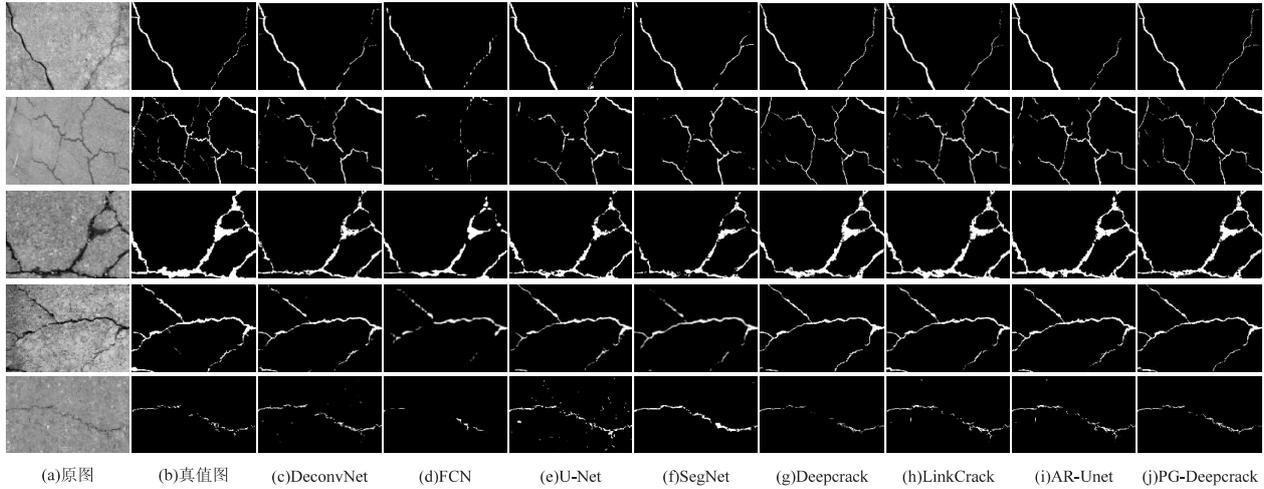


图 6 在 Deepcrack 数据集上的可视化结果

表 3 不同方法在 Deepcrack 数据集上的性能比较 %

网络模型	<i>A</i>	<i>P</i>	<i>R</i>	F1	IoU
DeconvNet ^[22]	98.34	83.28	79.40	79.35	67.14
FCN ^[26]	98.37	76.10	75.74	73.99	60.31
U-net ^[25]	98.39	81.97	80.33	79.46	67.23
SegNet ^[25]	98.16	76.05	78.30	77.41	64.58
Deepcrack ^[15]	98.56	79.22	86.09	81.16	69.61
LinkCrack ^[26]	98.47	80.94	84.25	80.53	68.82
AR-Unet ^[27]	98.40	80.17	83.18	79.71	67.97
Ours	98.71	83.25	86.28	83.33	72.78

表 4 不同模块消融实验性能比较

Deepcrack	DCAP	GC	ODFuse	<i>A</i> / %	<i>P</i> / %	<i>R</i> / %	F1 / %	IoU / %
√	—	—	—	98.56	79.22	86.09	81.16	69.60
√	√	—	—	98.63 ↑	81.71 ↑	85.16 ↓	82.04 ↑	70.91 ↑
√	—	√	—	98.67 ↑	81.99 ↑	85.67 ↓	82.38 ↑	71.32 ↑
√	—	—	√	98.60 ↑	81.29 ↑	84.67 ↓	81.64 ↑	70.31 ↑
√	√	√	—	98.68 ↑	82.36 ↑	85.89 ↓	82.76 ↑	71.84 ↑
√	√	—	√	98.63 ↑	81.40 ↑	84.96 ↓	81.81 ↑	70.72 ↑
√	—	√	√	98.68 ↑	81.32 ↑	88.01 ↑	83.15 ↑	72.50 ↑
√	√	√	√	98.71 ↑	83.25 ↑	86.28 ↑	83.33 ↑	72.78 ↑

由表 4 可以看出,将 Deepcrack 网络中的卷积层替换为提出的 DCAP 模块, *P* 值提高了 2.49 百分点, IoU 值提高了 1.31 百分点;在编码器中引入 GC 模块后, *A*, *P*, *R*, F1, IoU 值均有所提高,其中 *P* 值提高了 2.77 百分点, IoU 值提高了 1.72 百分点;在特征融合模块将 Deepcrack 中使用的普通卷积替换为全维动态卷积后, *P* 值提高了 2.07 百分点, IoU 提高了 0.71 百分点, 各模块均进一步改善了裂缝检测的性能,提升了分割精度,充分证明了文中方法的有效性。

3 结束语

针对混凝土裂缝分割任务中语义信息丢失、忽略裂缝细节的问题,设计了像素级分割网络模型 PG-Deepcrack。首先,在编码器中提出了双卷积-注意力并行模块增强网络对裂缝细节特征的表达力;其次,在编码器中引入全局上下文模块使网络更加关注裂缝特征同时抑制背景噪声;最后,在特征融合模块使用全维动态卷积和 GELU 激活函数,提高多尺度特征融合效

果。经对比验证,该方法在五项评价指标上均取得了最佳效果。因此,改进后的算法具有更强的裂缝检测能力,进一步推动了实现混凝土裂缝的智能化检测工作。

但该模型为确保分割精度,牺牲了内存资源消耗和计算成本。因此,接下来将借鉴轻量化网络的设计思想,减小模型大小和内存占用,使其在实际工程中能够部署在移动设备上。

参考文献:

- [1] 邓 露,褚鸿鹄,龙砺芝,等. 基于深度学习的土木基础设施裂缝检测综述[J]. 中国公路学报,2023,36(2):1-21.
- [2] LI Peng, WANG Chao, LI Shuangmiao, et al. Research on crack detection method of airport runway based on twice-threshold segmentation[C]//2015 fifth international conference on instrumentation and measurement, computer, communication and control (IMCCC). Qinhuangdao: IMCCC, 2015:1716-1720.
- [3] 杨才千,李 帅,王博昆,等. 基于动态阈值的混凝土裂缝高抗噪提取及识别方法[J]. 东南大学学报:自然科学版, 2021,51(6):967-972.
- [4] ZHOU J, HUANG P S, CHIANG F P. Wavelet-based pavement distress detection and evaluation[J]. Optical Engineering, 2006, 45(2):027007.
- [5] WU S, LIU Y. A segment algorithm for crack detection[C]//2012 IEEE symposium on electrical & electronics engineering (EESYM). Kuala Lumpur: IEEE, 2012:674-677.
- [6] SANTHI B, KRISHNAMURTHY G, SIDDHARTH S, et al. Automatic detection of cracks in pavements using edge detection operator[J]. Journal of Theoretical and Applied Information Technology, 2012, 36(2):199-205.
- [7] YEUM C M, DYKE S J. Vision-based automated crack detection for bridge inspection[J]. Computer-Aided Civil and Infrastructure Engineering, 2015, 30(10):759-770.
- [8] 晏班夫,徐观亚,栾 健,等. 基于 Faster R-CNN 与形态法的路面病害识别[J]. 中国公路学报, 2021, 34(9):181-193.
- [9] YUN H B, MOKHTARI S, WU L. Crack recognition and segmentation using morphological image-processing techniques for flexible pavements[J]. Transportation Research Record, 2015, 2523(1):115-124.
- [10] 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.
- [11] AL-HUDA Z, PENG B, ALGBURI R N A, et al. Weakly supervised pavement crack semantic segmentation based on multi-scale object localization and incremental annotation refinement[J]. Applied Intelligence, 2013, 53:14527-14546.
- [12] LI H, YUE Z, LIU J, et al. Scddnet: apixel-level crack segmentation network[J]. Applied Sciences, 2021, 11(11):5074.
- [13] WANG W, SU C. Convolutional neural network-based pavement crack segmentation using pyramid attention network[J]. IEEE Access, 2020, 8:206548-206558.
- [14] 刘 凡,王君锋. 基于并行注意力 UNet 的裂缝检测方法[J]. 计算机研究与发展, 2021, 58(8):1718-1726.
- [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] ZHANG H, ZU K, LU J, et al. EPSANet: an efficient pyramid squeeze attention block on convolutional neural network[C]//Proceedings of the Asian conference on computer vision. Macau: [s. n.], 2022:1161-1177.
- [17] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF conference on computer vision and pattern recognition. Salt Lake City: IEEE, 2018:7132-7141.
- [18] CAO Y, XU J, LIN S, et al. Gcnnet: non-local networks meet squeeze-excitation networks and beyond[C]//2019 IEEE/CVF international conference on computer vision workshop (ICCVW). Seoul: IEEE, 2019:1971-1980.
- [19] LI C, ZHOU A, YAO A. Omni-dimensional dynamic convolution[J]. arXiv:2209.07947, 2022.
- [20] HENDRYCKS D, GIMPEL K. Gaussian error linear units (gelus)[J]. arXiv:1606.08415, 2016.
- [21] LIU Y, YAO J, LU X, et al. DeepCrack: a deep hierarchical feature learning architecture for crack segmentation[J]. Neurocomputing, 2019, 338:139-153.
- [22] NOH H, HONG S, HAN B. Learning deconvolution network for semantic segmentation[C]//2015 IEEE international conference on computer vision (ICCV). Santiago: IEEE, 2015:1520-1528.
- [23] SHELHAMER E, LONG J, DARRELL D. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6):640-651.
- [24] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//Proceedings of international conference on medical image computing and computer-assisted intervention. [s. l.]: Springer, 2015:234-241.
- [25] BADRINARAYANAN V, HANDA A, CIPOLLA R. Segnet: a deep convolutional encoder-decoder architecture for robust semantic pixel-wise labelling[J]. arXiv:1505.07293, 2015.
- [26] LIAO J, YUE Y, ZHANG D, et al. Automatic tunnel crack inspection using an efficient mobile imaging module and a lightweight CNN[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9):15190-15203.
- [27] JING P, YU H, HUA Z, et al. Road crack detection using deep neural network based on attention mechanism and residual structure[J]. IEEE Access, 2023(11):919-929.