

DOI:10.19479/j.2095-719x.2404290

双层卷积和多特征融合的路面裂缝分割方法

杨振舰, 邵娴晴, 王 娇

(天津城建大学 计算机与信息工程学院, 天津 300384)

摘要:针对复杂背景下道路裂缝分割方法存在的边缘细节易缺失、目标误判问题,提出双层卷积和多特征融合的路面裂缝分割网络。首先,采用U-Net网络为基础架构,设计双层卷积网络改进编码部分,增大感受野,提取丰富的上下文信息。其次,引入坐标注意力模块优化解码部分,进一步加强网络对裂缝边缘细节的学习。最后,将产生的多级特征反馈至特征融合模块,堆叠通道有效融合深层和浅层特征。此外,损失函数采用二值交叉熵损失和Dice损失函数相结合的方式,有效解决了背景大于裂缝像素点导致的样本不均衡问题。通过在CRACK500、CFD、Cracktree200公开数据集上的实验结果表明:该方法实现MIoU分别为76.8%、65.3%、53.0%,比现有方法MIoU平均提高3.5%,可以实现优异的道路裂缝自动分割效果。

关键词:缺陷检测;裂缝分割;双层卷积;多特征融合;图像处理;深度学习

中图分类号:TP391.41;TP183 **文献标志码:**A **文章编号:**2095-719X(2024)04-0290-07

Pavement Crack Segmentation Method Based on Bilevel Convolution and Multi-feature Fusion

YANG Zhenjian, SHAO Xianqing, WANG Jiao

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

Abstract: Aiming at the problems of missing edge details and misjudgment of target in road crack segmentation method under complex background, this article proposed a pavement crack segmentation network based on bilevel convolution and multi-feature fusion. Firstly, the U-Net network was used as the infrastructure to design a bilevel convolutional network to improve the coding part, increase the receptive field, and extract rich context information. Secondly, the coordinate attention module was introduced to optimize the decoding part to further enhance the network's learning of crack edge details. Finally, the generated multilevel features were fed back to the feature fusion module, and the deep and shallow features were effectively fused by stacking channels. In addition, the loss function combined binary cross-entropy loss and Dice loss function, which effectively solved the sample imbalance problem caused by a background larger than crack pixels. The experimental results on CRACK500, CFD, and Cracktree200 show that the MIoU achieved by this method is 76.8%, 65.3%, and 53%, respectively, which is 3.5% higher than the result by the existing methods, and it can achieve excellent automatic segmentation effect on road cracks.

Key words: defect detection; crack segmentation; bilevel convolution; multi-feature fusion; image processing; deep learning

裂缝是反映道路安全的重要指标,尤其是对于桥梁、隧道等重大公路工程。裂缝的形成会加速道路的老化,影响路基的强度和稳定性。如果裂缝不能及时修补,继续扩展蔓延,就会导致更严重的路面缺陷,造成重大交通事故,甚至人员伤亡。因此,定期进行裂缝检测对保证道路安全具有极其重要的作用。传统的人工检测方法不仅检测精度低,而且费时费力、影响正

常交通。基于此,研究裂缝自动检测的方法对道路安全具有十分重要的意义。

随着传统图像处理技术的发展,相关研究人员提出利用聚类算法^[1-2]、阈值分割^[3-4]、边缘检测^[5-7]等传统算法对裂缝进行自动检测,在节省人力的同时,取得了比人工检测更好的效果。但由于路面裂缝常会受到光照、阴影、遮挡物(如落叶、油污)等外部因素的干

收稿日期:2022-10-12;修订日期:2023-03-10

基金项目:天津市科技计划项目(20YDTPJC01310)

作者简介:杨振舰(1986—),男,山东茌平人,教授,博士

通信作者:邵娴晴(1997—),女,天津城建大学硕士生。研究方向:图像处理、裂缝检测。E-mail:ycygz@163.com.

扰,传统算法通常需要提前对图像进行大量的预处理,耗费时间,而且算法泛化性不好,检测精度较低,非常容易出现漏检误检等情况。

近年来,由于卷积神经网络(convolutional neural networks, CNN)具有较强的特征学习能力,可以避免光照、遮挡物等不可控因素的干扰,且大都不需要对图像进行预处理,可以满足精度和时间上的双重要求。因此基于卷积神经网络的深度学习技术已广泛应用于裂缝检测领域,成为目前的研究热点。Dung^[8]提出了一种全卷积网络(fully convolutional networks, FCN)^[9]来进行混凝土裂缝检测方法,该方法可以实现像素级裂缝分割,但是该模型在上采样中对特征的还原效果不够精细,对图像中细节不够敏感。在对各个像素进行分类时,没有考虑像素与像素之间的关系。Bang等^[10]提出了一种利用深度卷积编码-解码网络来识别图像中道路裂缝的分割方法,利用残差网络作为编码器进行特征提取,反卷积模块作为解码器定位输入图像中的裂缝。Yang等^[11]提出了一种基于 HED^[12]模型的特征金字塔和分层增压网络,通过金字塔模块整合多尺度语义信息,提出分层增强模块自上而下逐层加权来处理识别难度较大的样本。但是当背景环境出现大量噪声干扰时,分层加权会导致模型将低层特征的背景识别为目标,造成背景误判现象,大大降低了准确率。刘凡等^[13]通过将并行注意力模块嵌入 U-Net^[14]网络中的解码部分,增大上采样网络中的特征权重,很大程度抑制了背景图像中各种干扰问题。但是图像细节恢复效果模糊,与背景区分度不高。

事实上,图像细节的恢复依赖于上下文信息,因此在初步提取特征时应更加关注深层次上下文信息。此外,将提取到的多层次特征进行充分融合,可以有效解决目标误判问题。综上所述,提出双层卷积和多

特征融合的路面裂缝分割网络 BMFNet(bilevel convolution and multi-feature fusion network)。本文的研究意图主要包括:

(1)针对编码网络池化过程中的上下文信息丢失问题,设计双层卷积网络深层次提取上下文信息,自适应地在每个空间位置周围建立远程空间和通道间依赖关系,扩大感受野,从而丰富输出特征,有效区分背景和目标的差异。

(2)针对复杂背景下的细节易缺失、噪声干扰问题,引入坐标注意力机制进一步优化解码网络,将通道注意转化为2个一维特征编码过程,分别沿着2个空间方向聚集特征,更准确地定位目标的位置,帮助网络更好地专注于识别裂缝边缘。在此基础上,设计多尺度特征融合模块将低层和高层特征进行线性连接,互相补充得到全面的特征表达,以减少噪声干扰的误检问题。

(3)针对背景像素点过多导致的样本不平衡问题,设计二值交叉熵损失和 Dice 损失函数相结合的新损失函数。

1 网络模型

U-Net 网络由一个获取上下文信息的编码器和一个实现精确定位的解码器组成,是一种端到端的 U 型结构,该结构使它在使用更少的训练图片的同时,分割的准确度也较高。但是该网络对于细节特征处理得不够好,提取到的多层次特征没有得到充分融合,误检率也大大提高。因此本文以 U-Net 为基础网络模型,提出 BMFNet 整体结构,如图 1 所示,实现了端到端的裂缝分割效果。

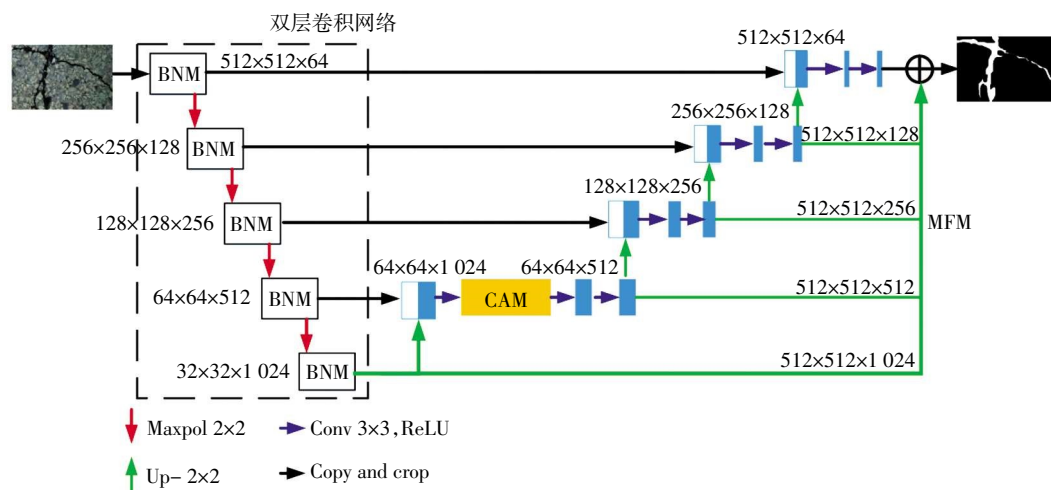


图 1 BMFNet 网络结构示意图

1.1 双层卷积网络

为了有效收集全局上下文信息,减少网络在下采样的最大池化操作中会因特征图分辨率减小而产生信息丢失问题,本文设计双层卷积提取网络作为编码部分.网络主要由双层卷积模块(bilevel convolution network module, BNM)组成,该模块包含一个3×3卷积和自校准空洞卷积,结构如图2所示.




图2 双层卷积模块

自校准空洞卷积是基于自校准卷积^[15]改进的双层卷积块,包含2层结构:一层是自校准层;另一层是空洞卷积层.通过添加不同膨胀率的空洞卷积串联组合层,不但可以保持原始特征大小以获得局部上下文信息,还可以增强原始感受野,以减少池化带来的信息丢失.该双层卷积将自校准层提取的区别性特征和空洞卷积层的丰富原始信息沿通道维度合并,有效加强了特征表达.双层卷积结构如图3所示.

具体来说,双层卷积提取网络由5个自校准空洞卷积模块和4个下采样层组成,在每层下采样中,通

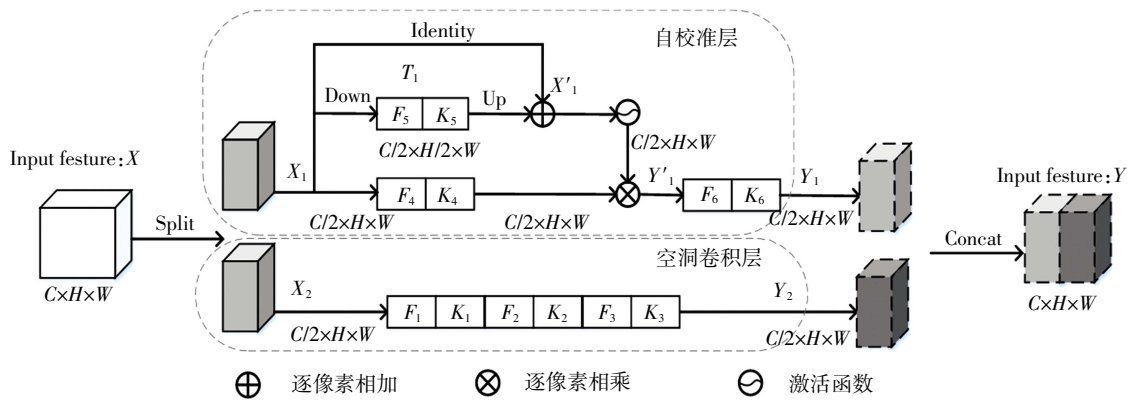


图3 双层卷积结构图

道数会增加1倍,依次为64,128,256,512,1024.自校准空洞卷积的输入特征为 $X \in R^{C \times H \times W}$,输出特征为 $Y \in R^{C \times H \times W}$. $\{F_n, n = 1, 2, \dots, 6\}$ 表示不同卷积核大小的卷积层, $\{K_i, i = 1, 2, \dots, 6\}$ 表示对应的滤波器.首先,将输入特征 X 分隔成 $\{X_1, X_2\}$ 2部分,分别用于收集自校准层和空洞卷积层的上下文信息.

在自校准层中,对输入 X_1 进行 $r \times r$ 的平均池化操作获得特征 T_1 .接着,对特征 T_1 进行基于 K_5 的卷积变换和上采样操作,得到自校准残差项权重 X'_1

$$X'_1 = \text{Up}(F_5(T_1)) = \text{Up}(T_1 \times K_5) \quad (1)$$

式中: $\text{Up}(\ast)$ 表示双线性插值操作,实现中间参考量从小尺度空间到原始特征空间的映射.

然后,为建立远程关系,将残差项权重 X'_1 和 X_1 输入特征逐像素相加,经过激活函数处理后,和基于 K_4 卷积变换后的特征进行逐像素相乘得到 Y'_1

$$Y'_1 = F_4(X_1) \cdot \sigma(X_1 + X'_1) = X_1 \times K_4 \quad (2)$$

式中: σ 表示sigmoid函数.接着经过基于 K_6 卷积变换后得到自校准层输出 Y_1 .

在空洞卷积层中,为提高输入特征 X_2 的有效感受野,设计使用膨胀率为2,4,8的空洞卷积串联模块组合,得到全局上下文特征 Y_2

$$Y_2 = F_3(F_2(F_1(X_2))) = ((X_2 \times K_1) \times K_2) \times K_3 \quad (3)$$

最后,将特征 Y_1 和 Y_2 沿通道维度合并,生成具有丰富语义信息的特征 Y .

双层卷积网络通过自校准空洞卷积模块提取来自校准层和空洞卷积层2个不同尺度空间的信息,可以互补对输入图像的特征处理,大大增加感受野,提取到更为完整、准确的裂缝区域.

1.2 解码网络

为进一步将多尺度特征映射到更精细尺度,更有效地恢复图像细节,对解码网络部分的不同层次特征进行有效融合.首先引入坐标注意力^[16]模块(coordinate attention, CAM)进行优化,再将优化的分级特征分别反馈至多特征融合模块(multi-feature fusion module, MFM),以解决复杂背景下噪声干扰问题.

1.2.1 坐标注意力模块

通道注意力可以显著提升模型的性能,但是通常忽略了位置信息,而位置信息对于生成空间选择性注意力图非常重要.因此,本文在解码网络中嵌入坐标注意力机制进行优化,通过将位置信息嵌入到通道注意力中,充分利用双层卷积提取阶段裂缝特征的有效位置信息,弥补卷积运算在提取细节特征时的缺失问题.坐标注意力模块结构如图4所示.

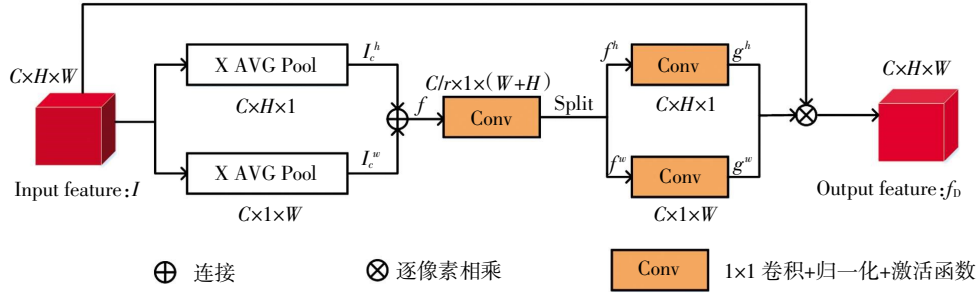


图4 坐标注意力模块结构图

在坐标注意力模块中,首先输入特征向量 I ,使用尺寸 $(H, 1)$ 和 $(1, W)$ 的池化卷积核沿着垂直坐标方向和水平坐标方向对每个通道进行编码,生成一对具有方向感知能力的特征映射 I_c^w 和 I_c^h

$$I_c^h = \frac{1}{W} \sum_{0 \leq i \leq W} I_c(h, i) \quad (4)$$

$$I_c^w = \frac{1}{H} \sum_{0 \leq j \leq H} I_c(j, w) \quad (5)$$

式中: I_c^h 表示高度为 h 的第 c 个通道输出特征; I_c^w 表示宽度为 w 的第 c 个通道输出特征. W 和 H 表示特征图的宽度和高度.

将公式(4)和公式(5)产生的特征沿通道维度连接,然后使用 1×1 卷积压缩特征图通道数量,生成中间特征 f

$$f = \delta(\text{conv})\text{concat}(I_c^w, I_c^h) \quad (6)$$

式中: δ 表示 ReLU 激活函数.

再将特征切分为 2 个单独的特征 f^h 和 f^w ,再利用 2 个 1×1 卷积将它们分别变换到和输入特征 I 同样的通道数,记为 g^h 和 g^w

$$g^h = \sigma(\text{conv}(f^h)) \quad (7)$$

$$g^w = \sigma(\text{conv}(f^w)) \quad (8)$$

式中: σ 表示 sigmoid 激活函数.

最后,将输出特征 g^h 和 g^w 分别用作水平和垂直坐标的注意力权重,与原始特征图 I 逐像素相乘,得到最终注意力模块输出 f_D

$$f_D = I \times g^h \times g^w \quad (9)$$

1.2.2 多特征融合模块

对于输入图像,其在浅层特征提取阶段能保持裂缝区域的边界,但对局部噪声处理不好,如黑点和污垢.相反,随着网络层次的加深,特征的提取逐渐具有更好的抗噪声能力,但未必能保持对边界分割的完整性.因此,线性融合不同特征提取阶段的特征可以很好地权衡两者,使特征信息表达更加全面.基于此,本文设计特征融合模块作为网络的输出模块,融合解码器和最后一层编码器的多尺度裂缝特征,互相补充深

浅层次特征信息表达,减少背景干扰造成的目标误检等问题.

具体来说,通过双线性插值的方式将解码模块每次上采样之前产生的 4 个侧边特征图映射为输入图像尺寸.再将它们与网络最后一级特征图通道连接,并送入 1×1 的卷积层来降低输出特征通道数,生成最终的二值预测图.

1.3 损失函数

裂缝检测作为二值图像分割问题,本文采用语义分割任务常用的二值交叉熵损失函数(binary cross entropy loss, BCE)和 Dice 损失函数结合的方式,可以很好地解决背景像素点大于裂缝像素点导致的样本不均衡问题.改进后的损失函数 Loss 为

$$\text{Loss} = \text{Loss}_{\text{BCE}} + \alpha \text{Loss}_{\text{Dice}} =$$

$$-\frac{1}{S} \sum_n [G_n \log(P_n) + (1 - G_n) \log(1 - P_n)] +$$

$$\alpha \left[1 - \frac{\sum_n G_n P_n + \mu}{\sum_n P_n + G_n + \mu} + \frac{\sum_n (1 - G_n)(1 - P_n) + \mu}{\sum_n 2 - P_n - G_n + \mu} \right] \quad (10)$$

式中: Loss_{BCE} 、 $\text{Loss}_{\text{Dice}}$ 分别表示二值交叉熵损失函数和 Dice 损失函数; α 为比例系数,设置为 1; S 表示图像像素点个数; G_n 表示像素点 n 的标签值; P_n 表示像素点 n 的预测值.

2 模型的训练与评价

2.1 数据集

为验证所提方法的有效性和泛化性,本文在 CRACK500^[12]公开裂缝数据集上训练与测试,并在 CFD^[17]、Cracktree200^[18]数据集上进行验证.

CRACK500 数据集于 2019 年被提出,是目前最大的具有像素级注释的公开路面裂缝数据集,它面临着裂缝宽度的不同、裂缝与周围环境之间的低对比度

等挑战. 该数据集被分为 1 896 张训练图像、348 张验证图像和 1 124 张测试图像. 图像的大小是 640×360, 每个路面裂缝图片都有一个像素级的注释二进制图片.

CFD(crackforest dataset)数据集于 2016 年被提出, 该数据集由 118 张北京城市道路路面裂缝的图像组成, 图像的大小是 480×320, 这些图像包含了阴影和交通车道, 裂缝的宽度为 1~3 mm.

Cracktree200 数据集于 2012 年被提出, 包含 206 张大小为 800×600 的路面裂缝图像, 这些图像包含有阴影和遮挡的场景. 每个图像都有一个用于直接评估的像素级注释.

为保证模型的训练效果, 采用对原始输入图片进行等比例缩放、灰度条填充的预处理策略, 将图片大小调整为统一的 512×512×3. 将 CRACK500 数据用于训练集、验证集和测试集, Cracktree200 和 CFD 数据集全部用于测试集. 因此, 共有训练样本 1 896 张, 验证样本 348 张, 测试样本 1 448 张. 其中, Crack500、CFD、Cracktree200 数据集部分样本图像和标签如图 5 所示.




图 5 裂缝数据集样本

2.2 模型训练参数

实验环境为 Ubuntu 系统, 编程语言为 Python, 基于 PyTorch1.10.0 深度学习框架搭建模型, GPU 为 NVIDIA GeForce GTX 1080, CUDA 版本为 10.2. 在训练过程中, 本文将初始学习速率设置为 0.000 1, 选用 Adam 优化器, 批处理大小设置为 2, 训练 epoch 为 200 个, shuffle 设置为 True.

模型训练-验证 Loss 曲线如图 6 所示. 当 Epoch 达到 100 时, 损失曲线波动达到平稳.




图 6 训练-验证损失函数

2.3 评价指标

裂缝检测作为一项像素级别的语义分割任务, 其最常用的评价指标是平均交并比 (mean intersection over union, MIoU) 和平均像素准确率 (mean pixel accuracy, MPA). MPA 计算的是正确分类的像素数量与所有像素数量的平均比值. 在本文中, 其计算的是实际裂纹像素数量与所有像素的平均比值. MIoU 计算的是真实标签和预测值 2 个集合的交集和并集的平均比值, 在本文中, 其计算的是分割真实裂纹与预测裂纹之间的平均交并比. 假设共有类 (包括背景), 平均像素准确率和平均交并比的计算方法如式 (11)-(12) 所示

$$MPA = \frac{1}{k + 1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij}} \tag{11}$$

$$MIoU = \frac{1}{k + 1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \tag{12}$$

式中: p_{ij} 代表实际为第 i 类预测为 j 类的像素数量; p_{ii} 代表实际为第 i 类预测为 i 类的像素数量; p_{ji} 代表实际为 j 类预测为 i 类的像素数量.

2.4 实验结果分析

为验证各模块的有效性, 本文在 CRACK500 数据集上进行消融实验. 基准模型采用 U-Net, 模型 1 是在原编码网络中采用双层卷积提取网络, 模型 2 是在模型 1 基础上添加坐标注意力模块 (CAM), 模型 3 是在模型 2 上添加多特征融合模块 (MFM), 模型 4 是在模型 3 的基础上采用改进后的损失函数. 通过计算客观指标来比较不同模块在裂缝图像上的分割效果. 实验结果如表 1 所示.

由表 1 可以看出, 模型 1 相比基准模型, MIoU 和 MPA 分别提高了 6.3 和 0.4 个百分点, 说明双层卷积

表 1 BMFNet 的消融实验结果

模型	双层卷积网络	CAM	MFM	损失函数	MIoU/%	MPA/%
Baseline					67.1	84.7
模型 1	✓				73.4	85.1
模型 2	✓	✓			74.6	85.7
模型 3	✓	✓	✓		75.9	86.4
模型 4	✓	✓	✓	✓	76.8	87.2

网络提取全局上下文信息的准确率有所提升; 模型 2 相比模型 1, MIoU 和 MPA 分别提高了 1.2 和 0.6 个百分点, 说明引入坐标注意力机制后对裂缝的定位和识别细化能力明显提高; 模型 3 相比模型 2, MIoU 和 MPA 分别高出了 1.3 和 0.7 个百分点, 说明添加融合模块后分割误检率有所下降; 模型 4 比模型 3, MIoU 和 MPA 分别高出了 0.9 和 0.8 个百分点, 说明使用改进的损失函数更加贴合模型训练, 效果有显著提升. 实验效果图如图 7 所示.




图 7 BMFNet 不同模块的消融实验效果

从图 7b 中可以看出, 原模型对裂缝的分割效果并不好, 受噪声干扰较大, 并且存在大量漏检情况; 从




图 8 BMFNet 与不同算法对比的可视化效果图

图 7c 中看出, 在编码部分采用双层卷积提取网络后, 裂缝的大致形态完整度提升. 这是由于添加空洞卷积层后感受野更大, 提取的信息也更加丰富了, 但是仍有裂缝细节丢失; 从图 7d 中看出, 图像细节边缘有更多的保留, 说明引入坐标注意力模块优化后, 网络对细节的处理能力有所加强; 从图 7e 中看出, 与真实标签对比后的漏检现象明显减少, 说明加入融合模块后有效减少了漏检率. 综上所述, 验证了本文提出网络模型的有效性.

为验证本文方法与其他方法比较的优越性, 本文将模型与 CrackForest^[17]、FBHBN^[11]、SegNet^[19]、TransUnet^[20] 算法进行对比评估. 实验在 CRACK500 数据集上训练验证, 并分别在 3 个不同数据集上进行测试, 对比指标结果如表 2 所示.

表 2 BMFNet 与不同算法性能对比指标结果 %

模型	Crack500 测试集		CFD 测试集		Cracktree200 测试集	
	MIoU	MPA	MIoU	MPA	MIoU	MPA
CrackForest	56.3	68.3	50.6	52.7	50.1	51.4
FBHBN	60.0	61.5	40.5	40.6	42.0	42.7
SegNet	70.6	78.5	55.7	59.9	50.7	59.7
TransUnet	74.2	78.4	59.7	62.7	50.6	53.1
BMFNet	76.8	87.2	65.3	71.3	53.0	66.5

由表 2 可见, CrackForest 与 BMFNet 的指标相差较多, 说明本文提出的 BMFNet 与传统模型相比具有更大的优势; FBHBN 和 SegNet 的指标也明显低于 BMFNet, 原因是没有很好地融合多层次特征, 忽略了对裂缝深层细节的处理, 导致准确率下降; 而本文提出的 BMFNet 利用多特征融合模块对深浅层特征进行融合, 超过了目前流行的语义分割算法 TransUnet, MIoU 和 MPA 分别达到 76.8% 和 87.2%, 说明 BMFNet 针对复杂背景下的裂缝分割任务失误率更小、准确度更高. BMFNet 可视化对比效果如图 8 所示.

由图 8 所示, 图中的 3 行图片分别展示了 BMF-

Net 在 CRACK500、CFD 和 Cracktree200 数据集的可视化效果图。从第三行(b)列检测结果可以看出,传统算法的 CrackForest 并不适合裂缝结构较复杂时的裂缝提取,在裂缝较细和背景噪声较多时无法检测出裂缝轮廓。从第 2 行(c),(d),2 列效果可以看出,FBHBN 和 SegNet 算法容易受到光照阴影干扰,不能很好地分割出真实效果;从第 1 行(e)列效果看出,TransUnet 算法在进行裂缝提取任务时,细节处不够准确,会受到噪声干扰,存在大量目标误检的情况;BMFNet 在不同场景下的裂缝检测中表现良好,因为双层卷积网络能够提取丰富的上下文信息,融合模块能够让多层次特征充分互补,减少噪声干扰的误检现象。综上所述,本文方法在 3 个公开数据集上的表现效果良好,验证了方法的泛化性和有效性,因此 BMFNet 更适合于复杂背景下的路面裂缝分割任务。

3 结 语

本文提出了一种双层卷积和多特征融合的路面裂缝分割网络 BMFNet,有效地解决了裂缝边缘细节易缺失和目标误检问题。首先通过双层卷积提取网络来增强网络对裂缝区域的提取能力;然后通过坐标注意力机制捕获方向和位置感知信息来更准确地识别裂缝边缘;最后通过特征融合模块对多尺度特征信息线性融合输出,有效解决模型在复杂背景下的误检现象;另外,改进单一损失函数解决背景占比较大的问题,提高了分割的准确性。总体上,在 3 个具有代表性的公开数据集上测试,MPA 分别达到了 87.2%、71.3%、66.5%,MIoU 分别达到了 76.8%、65.3%、53.0%,能够满足自然条件下的裂缝检测需求。在后续工作中,将研究如何计算裂缝具体的长度和宽度,并将成果在道路巡检机器上进行应用,为道路安全任务提供帮助。

参考文献:

- [1] 李 鹏,李 强,马味敏,等.基于 K-means 聚类的路面裂缝分割算法[J].计算机工程与设计,2020,41(11):3143-3147.
- [2] 王德方,曾卫明,王倪传.基于改进 K-means 算法的不均匀光照下道路裂缝检测[J].计算机应用与软件,2015,32(7):244-247.
- [3] 张振海,贾争满,季 坤.基于改进的 Otsu 法的地铁隧道裂缝识别方法研究 [J].重庆交通大学学报(自然科学版),2022,41(1):84-90.
- [4] 韦春桃,余俊辰,赵 平,等.基于自适应阈值的细小裂缝与微灰度差异裂缝自动检测方法[J].中外公路,2019,39(1):58-63.
- [5] 赵 芳,周旺辉,陈岳涛,等.改进的 Canny 算子在裂缝检测中的应用[J].电子测量技术,2018,41(20):107-111.
- [6] 申有义,田忠斌,王建青,等.基于多尺度边缘检测技术的煤系灰岩裂缝分布预测[J].物探与化探,2018,42(4):725-730.
- [7] 徐 欢,李振璧,姜媛媛,等.基于 OpenCV 和改进 Canny 算子的路面裂缝检测[J].计算机工程与设计,2014,35(12):4254-4258.
- [8] DUNG C V. Autonomous concrete crack detection using deep fully convolutional neural network [J]. Automation in Construction, 2019, 99: 52-58.
- [9] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston: IEEE, 2015: 3431-3440.
- [10] BANG S, PARK S, KIM H, et al. Encoder-decoder network for pixel-level road crack detection in black-box images[J]. Computer-Aided Civil and Infrastructure Engineering, 2019, 34(8): 713-727.
- [11] 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.
- [12] XIE S, TU Z. Holistically-nested edge detection[C]// 2015 IEEE International Conference on Computer Vision (ICCV). Santiago: IEEE, 2015: 1395-1403.
- [13] 刘 凡,王君锋,陈峙宇,等.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.
- [14] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]// Medical Image Computing and Computer-Assisted Intervention (MICCAI). Munich: Springer, 2015: 234-241.
- [15] LIU J J, HOU Q, CHENG M M, et al. Improving convolutional networks with self-calibrated convolutions[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE/CVF, 2020: 10096-10105.
- [16] HOU Q, ZHOU D, FENG J. Coordinate Attention for Efficient Mobile Network Design[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville: IEEE/CVF, 2021: 13713-13722.
- [17] SHI Y, CUI L, QI Z, et al. Automatic road crack detection using random structured forests[J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(12): 3434-3445.
- [18] ZOU Q, CAO Y, LI Q, et al. CrackTree: automatic crack detection from pavement images[J]. Pattern Recognition Letters, 2012, 33(3): 227-238.
- [19] SCHMUGGE S J, RICE L, LINDBERG J, et al. Crack segmentation by leveraging multiple frames of varying illumination [C]// 2017 IEEE Winter Conference on Applications of Computer Vision (WACV). Santa Rosa: IEEE, 2017: 1045-1053.
- [20] CHEN J, LU Y, YU Q, et al. Transunet: transformers make strong encoders for medical image segmentation[J]. ArXiv Preprint ArXiv, 2021, 2102: 04306.