

DOI:10.19651/j.cnki.emt.2208771

并行提取与特征融合注意力网络下的裂缝检测*

张华卫 贾文娟 张金龙 廉敬 李攀峰

(兰州交通大学电子与信息工程学院 兰州 730070)

摘要: 针对裂缝检测现有方法精度低、噪声多和细节丢失等问题,设计了一种基于并行提取和注意力融合网络的裂缝检测算法。首先,利用不同深度的多尺度卷积神经网络提取裂缝场景的高、低级特征;然后,为了提高检测精度,针对裂缝场景的特征,结合像素注意力机制对裂缝场景的高、低级特征进行有效融合,得到用于裂缝检测的有效融合特征;最后,利用非线性映射进行裂缝检测结果输出。实验结果表明,所提算法能够获得高精度检测结果的有效特征,裂缝检测结果细节更加清晰,且有监督学习方式在很大程度上消除了检测结果的噪声干扰,得到了视觉效果更佳的结果;所提算法在精确率和召回率等定量指标评价中同样具有良好的表现,裂缝检测精确率达到85%。

关键词: 裂缝检测;并行提取;注意力机制;特征融合

中图分类号: TN391.9 **文献标识码:** A **国家标准学科分类代码:** 510.40

Crack detection under parallel extraction and feature fusion
attention network

Zhang Huawei Jia Wenjuan Zhang Jinlong Lian Jing Li Panfeng

(School of Electronics and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: A crack detection algorithm based on parallel extraction and attention fusion network is designed to address the problems of low accuracy, much noise and detail loss of existing methods for crack detection. First, the high and low-level features of the crack scene are extracted using multi-scale convolutional parallel neural networks with different depths; then, to improve the detection accuracy, the high and low-level features of the crack scene are effectively fused with the pixel attention mechanism for the features of the crack scene to obtain effective fusion features for crack detection; finally, the crack detection results are output using nonlinear mapping. The experimental results show that the proposed algorithm can obtain effective features for high-precision detection results, the details of crack detection results are clearer, and the supervised learning approach largely eliminates the noise interference of detection results and obtains detection results with better visual effects; the proposed algorithm also has good performance in the evaluation of quantitative indexes such as accuracy rate and recall rate, and the accuracy rate of crack detection reaches 85%.

Keywords: crack detection; parallel extraction; attention mechanism; feature fusion

0 引言

近年来,随着轻重工业和交通运输的快速发展,安全隐患问题也日益突出,而裂缝问题严重影响着路基、路面、桥梁等建筑的安全,因此能够快速且准确的获取裂缝缺陷的位置等信息具有十分重要的研究意义^[1-2]。

目前,裂缝检测方法^[3]主要分为两大类,1)基于图像处理的传统方法,2)基于深度学习和神经网络模型的方法。

大多裂缝图像是户外环境下采集得到,噪声的影响进一步影响了裂缝检测的准确性和全面性,因此基于图像处理的裂缝检测算法需要降噪^[4]等预处理操作,不仅提高了算法复杂度且降噪过程会造成裂缝细节信息的丢失,因此传统裂缝检测方法存在较多的局限性。传统路面裂缝图像处理算法多从灰度变换、中值滤波、图像增强角度进行改进,能够有效去除孤立噪声点,平滑边缘,提高分割精度,但并不适用于多场景下^[5]。基于空间聚集特征的路面裂缝检测

收稿日期:2022-01-05

* 基金项目:国家自然科学基金地区科学基金(62061023)、国家自然科学基金(61941109)、国家自然科学基金地区科学基金(61861024)、甘肃省高原交通信息工程及控制重点实验室开放课题(20181102)项目资助

方法,以子块图像为处理单元,可以检测出较完整的裂缝区域,但算法过程较为复杂^[6]。尽管基于图像处理的裂缝检测方法^[7-9]不断改善,但依然存在检测精度不高和算法复杂等问题。

最近,基于神经网络的裂缝缺陷检测方法相继被提出,其中作为第三代人工智能的产物,耦合神经网络(PCNN)也被广泛用于裂缝检测问题。小波变换消除光照影响和马尔可夫随机场优化 PCNN 的裂缝检测算法针对裂缝图像在光照不均匀下难以检测问题进行了改进,但算法需要多次迭代,具有较高的复杂度^[10]。头脑风暴优化 PCNN 算法,获得了 PCNN 模型的最优参数,提高了检测精度,但局部还存在少量噪声^[11]。Zhang 等^[12]提出将深度卷积神经网络用于裂缝检测任务,并获得了准确率较高的检测结果。Xie 等^[13]通过完全卷积神经网络和深度监督网络的深度学习模型(HED)来进行边缘检测,效果明显高于传统边缘算子,但其模型过于庞大。深度全卷积神经网络架构(Scg-Net),减少了大量参数,但得到的结果不够精细^[14]。多尺度特征进行语义分割任务(U-Net),提高了模型的普适性,但检测速度过慢^[15]。特征金字塔和层次增强网络(FPHBN)模型,通过以金字塔方式集成来自高层的语义信息来丰富低层特征,在不同数据集上都取得了较好的检测效果^[16]。

裂缝缺陷多出现于混凝土建筑、路面等环境下,在路面养护和混凝土建筑的安全问题中,裂缝是最常见,也是最严重的缺陷之一。对于同样场景下的裂缝,破坏程度决定了裂缝的可见度,同时,决定着检测结果的准确性。传统的裂缝检测大多从数字图像处理的角度出发,多采用阈值分割

的方法获得检测结果,而不同的裂缝需要非常准确的动态阈值才能获得精度较高的检测结果,且大多裂缝场景带有严重的噪声干扰,传统检测需要对其进行降噪与增强等一系列预处理,增加算法复杂度的同时丢失了部分裂缝信息。相较于传统的裂缝检测算法,深度学习类的方法^[17-19]能够获得更加丰富的裂缝信息和图像特征。

综上所述,本文提出了一种结合并行提取与注意力融合网络的裂缝检测算法,该方法不需要进行降噪等预处理,而是直接将裂缝场景输入网络模型,进而输出检测结果。为了获得裂缝场景的有效特征,设计了不同深度的并行提取模块,进而获得输入场景的高、低级特征,并通过注意力融合的方式获得裂缝特征,然后在检测模块得到裂缝检测结果。实验表明,所提方法能够获得细节更加清晰的裂缝检测结果,在定量指标上也表现出了优势。

1 本文算法

目前,裂缝检测的难点在于两个方面:1)不同的环境引起的非典型裂缝结构复杂,表现为向各个方向扩散及分叉,导致既有算法无法高效处理;2)采集过程中由于路面、桥梁等结构固有的噪声点及环境光导致的清晰度下降,如图 1 所示,传统的数字图像处理方法无法兼顾上述问题,导致其检测结果精度较低。数据驱动模型在全监督学习下,可以将上述问题归结为一个问题,即将消噪、清晰度恢复和裂缝识别整合为单纯的裂缝检测问题,只需在损失函数最小化的约束下关注精度更高的输出即可。因此,本文选择目前较为流行的数据驱动方法,利用全监督学习的思想完成模型训练,并获得检测结果。




图 1 一组裂缝场景示意图

为了提高检测精度且减小算法复杂度,本文设计了一种注意力融合卷积神经网络,主要包含多尺度特征提取模块、注意力融合和裂缝检测模块。其中,特征提取包含高级特征提取和低级特征提取,利用不同深度的提取模块得到相应的特征;为了消除冗余特征对检测精度的影响,利用注意力机制对高、低级特征进行有效融合,并将融合特征以非线性映射的方式输出为裂缝检测结果,网络结构如图 2 所示。

1.1 特征提取

卷积神经网络凭借其优势在图像处理和计算机视觉

任务中发挥了充分的作用。通常,裂缝场景具有以下特征:1)裂缝场景颜色单一;2)裂缝场景噪声明显;3)不同的裂缝场景具有不同的裂缝结构和可视化度。相较于传统的图像处理方法,有监督的训练学习可以同时兼顾以上特征。既有特征提取方法所得特征太过单一,很难满足复杂场景下的裂缝检测要求,为了能够获得用于裂缝输出的有效特征,设计了一种多尺度不同深度的并行特征提取网络,特征提取模型如图 3 所示。

特征提取模块主要由两部分组成:低级特征和高级特征提取模块。通常,在卷积网络模型的浅层输出的大多是

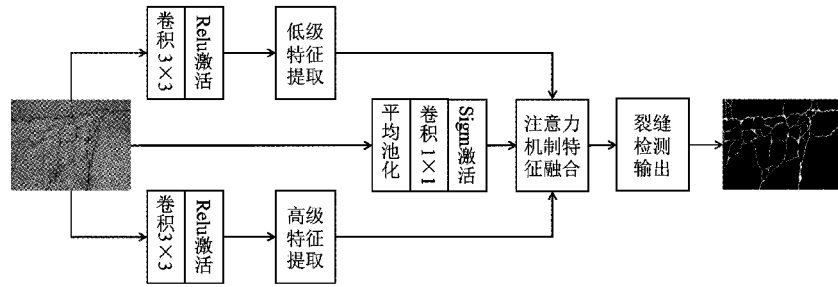


图 2 本文整体网络模型

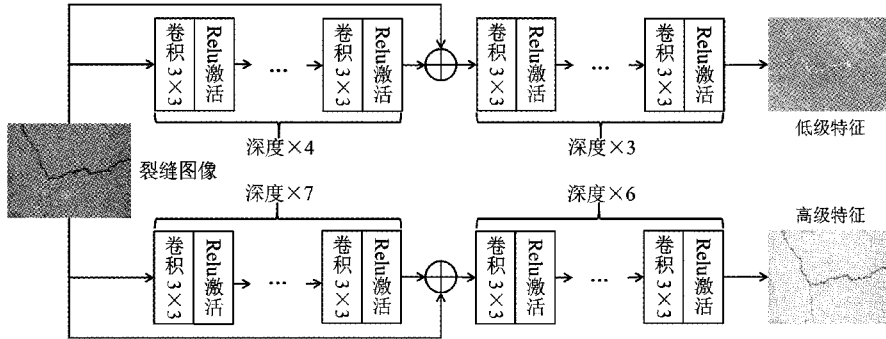


图 3 特征提取模型

局部特征,而局部特征一般包括输入图像的轮廓、边缘和线条等低级信息,因此,以浅层结构获取裂缝场景的低级特征,裂缝场景的低级特征仅展示了裂缝的大致轮廓和边缘;随着网络层数的加深,局部信息不断迭代后,便可获得更加复杂的高级特征,高级特征展示了输入的全局信息,包括细节等,因此,以深层结构提取裂缝场景的高级特征。为了防止网络出现的信息丢失问题,在进行特征提取时引入残差补偿策略^[20],以避免信息丢失问题。

在裂缝场景中,裂缝特征是裂缝检测任务关注的主要特征。由于深层网络提取的特征包含了较多的全局信息,因此本文以深层提取进行裂缝场景高级特征的提取,以较浅的网络进行裂缝低级特征提取。高级特征提取模块的深度为 12 层卷积和 1 个残差块,低级特征模块深度为 7 层卷积和 1 个残差块。为了保证输入和输出具有相同的尺寸,本文卷积步长为 1,边缘填充参数为 1,卷积核均为 3×3,3×3 的卷积相较于大的卷积核,不仅可以有效提取图像特征,而且能够降低模型参数和计算复杂度。为了实现卷积处理后的非线性映射,采用 ReLU 函数作为整体网络的激活函数。

1.2 注意力融合

裂缝检测精度取决于有效的裂缝特征信息,本文利用注意力机制的自适应像素融合方式进行裂缝场景的高、低级特征融合。注意力融合结构如图 4 所示。融合结构主要包括注意力权重计算和特征融合,将低级特征记为 F_L ,高级特征记为 F_H ,注意力权重计算表达式为:

$$\beta = \text{Sig}(\text{Conv}_L(\text{AP}(X))) \quad (1)$$

$$\alpha = \text{Sig}(\text{Conv}_H(\text{AP}(X))) \quad (2)$$

其中, α, β 分别是高、低级特征的融合权重; Sig 表示 Sigmoid 激活函数, Conv_L 是低级特征权重卷积, Conv_H 是高级特征权重卷积, AP 是平均池化操作, X 是输入的裂缝场景。高、低级特征注意力权重获取时,其方式是一致的,但是其输出并不相同,主要是为了适应裂缝检测的需要,实际上,在每次训练过程中,注意力权重值也在不断的被优化,直到损失值收敛,检测结果达到更佳。则经过注意力像素融合的特征可表示为:

$$F = \beta F_L + \alpha F_H \quad (3)$$

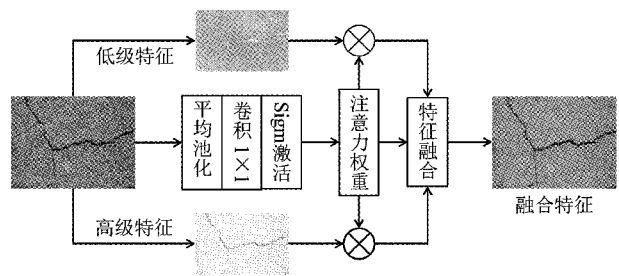


图 4 特征融合示意图

裂缝场景的高级特征通常包含了更多的细节信息,而低级特征表现了大致轮廓信息。本文模型下一组裂缝场景的高、低级特征如图 5 所示,可以看出,高级特征显示了较为全面的裂缝特征,而低级特征仅体现了大致的裂缝轮廓,但低级特征同时保留了裂缝场景的噪声信息,黑框标记区域更加清晰地展示了高、低级特征的差异;为了消除噪声影响,获得效果更好的检测结果,在特征融合模块,使用了注意力机制,对噪声等冗余特征进行了抑制,同时对

裂缝特征权重进行提高,采用注意力机制的自适应融合后,融合特征将裂缝的轮廓、细节和纹理等信息都表现了

出来,将融合特征作为裂缝检测即非线性映射的输入则可以得到全监督学习下的裂缝检测结果。




图 5 裂缝场景及其特征可视化

1.3 裂缝检测

本文设计了一种结合并行卷积提取与注意力像素融合的裂缝检测网络模型,相较于传统的数字图像处理检测方法,所提方法能够直接有效地获得裂缝检测结果。在裂缝检测模块,将注意力融合模块的输出特征作为该模块的输入,并通过非线性映射得到裂缝检测结果。裂缝检测模块结构如图 6 所示,检测模块主要包含 1 层 3×3 的卷积和 1 个激活层,激活函数采用 Relu 函数。在测试集中随机选择一组裂缝场景,本文模型的检测结果如图 7 所示。不同

于常规检测,基于全监督训练的方法无需考虑光照不均匀、裂缝结构复杂等问题,只关注网络模型提取的有效特征,并以训练的方法尽可能的实现损失最小,进而得到逼近真实结果的裂缝输出。可以看出,本文模型对于复杂裂缝结构同样具有较为理想的检测性能。




图 6 裂缝检测结构

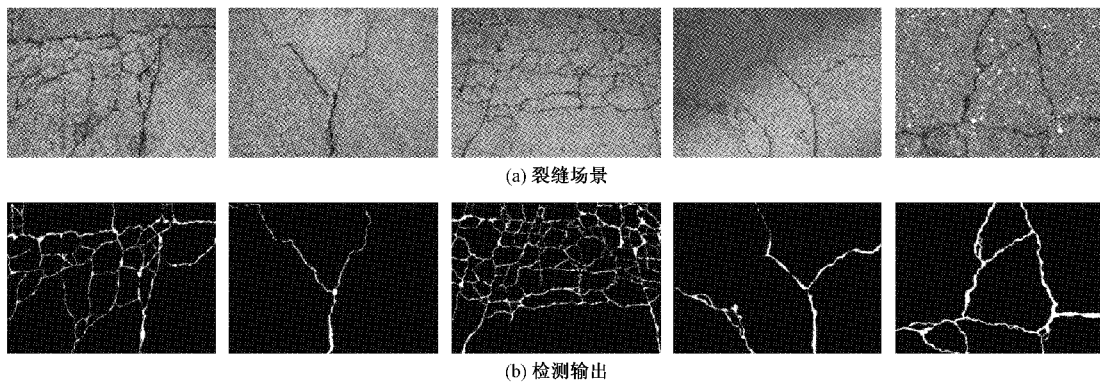


图 7 一组裂缝场景检测输出

1.4 训练细节

本文采用 Python 实现模型编写,并在 Pytorch 框架下进行模型部署,硬件环境为 Windows10 系统,处理器为 Intel(R) Core(TM) i5-9400 CPU@2.90 GHz。本文进行全监督训练采用的数据集为 CRACK500^[16],训练周期为

100 时,损失值达到收敛,整个训练过程的学习率为 0.001。训练过程的损失曲线如图 8 所示。

训练参数优化采用改进的随机梯度下降方式,为了得到更加精确的裂缝检测结果,本文采用均方误差损失和感知损失的结合作为整个训练过程的损失函数。均方误差




图 8 损失曲线

损失和感知损失^[21]表达式如下:

$$L_2 = \frac{1}{NHW} \sum_{i=1}^N \|f'_i - f_i\|^2 \quad (4)$$

$$L_p = \sum_{j=1}^3 \frac{1}{C_j H_j W_j} \|\varphi_j(f') - \varphi_j(f)\|^2 \quad (5)$$

其中,式(4)是均方误差损失表达式,式(5)是感知损失表达式。 f' 是本文模型的裂缝检测输出; f 是数据集标签; N 是检测个数; H 和 W 是图像尺寸; $\varphi(f')$ 和 $\varphi(f)$ 分别是本文检测结果和标签的在感知计算中的语义特征图; C_j 、 H_j 和 W_j 分别是特征图的通道数、高度和宽度。其中,感知损失可以计算检测结果和数据集标签的语义特征差异,本文感知损失采用 VGG-16 网络输出的特征图进行

计算。则整个训练过程的损失函数可表示为:

$$L = L_2 + \delta L_p \quad (6)$$

其中, δ 是感知损失权重,其取值为 0.02。

2 实验分析

为了进一步验证所提模型的有效性,本文分别从主观视觉和定量指标两个角度进行实验验证分析,主观评价可以直观的观察出各方法的优势与缺陷,定量指标从客观角度加以验证个方法的不足与优势。由于本文裂缝检测算法是以卷积神经网络为框架设计,为了更加充分的体现所设计模型的先进性,本文选取了 3 种卷积神经网络类裂缝检测算法进行实验对比,分别为 HED^[13]、Seg-Net^[14]、U-Net^[15];PCNN^[11]作为裂缝检测的经典算法,本文同样选为对比算法。为了进一步体现出所提方法的优势,对不同结构的裂缝场景检测进行对比,包括单一结构裂缝场景、复杂结构裂缝场景和带有噪声的裂缝场景。

2.1 主观评价

图 9 是一组单一结构裂缝场景检测的对比,其中,PCNN 方法由于其阈值设定不准确导致检测结果出现了




图 9 单一结构裂缝场景检测对比

断痕,且检测结果因区域连通表现出了明显的噪声。HED方法消除了部分噪声,但仍存在裂缝检测不彻底和局部噪声。Seg-Net 实现了较为彻底的检测,对于单一结构的裂缝场景,该方法能够实现效果较好的裂缝检测,但存在局部裂缝的断痕现象。U-Net 同样消除了部分噪声,但裂缝检测结果的断痕现象仍然较为明显。本文方法对单一结构的裂缝场景能够实现彻底且全面的检测,并消除了噪声的干扰。

图 10 是一组带噪声和深色结构的裂缝场景检测对比,可以看出,各方法具有不同的表现。PCNN 的检测结果不仅丢失了部分裂缝,且含有大量的噪声。HED 消除了些许噪声,但少许噪声仍然存在,且裂缝丢失严重。Seg-Net 和 U-Net 方法克服了噪声的干扰,获得了较为理想的检测输出,但局部区域的裂缝丢失明显,检测结果出现了断痕。本文方法不仅消除了噪声的干扰,同样获得了裂缝信息保留更加丰富的结果。




图 10 噪声与深色结构裂缝场景检测对比

图 11 和 12 分别是带有噪声的单一结构裂缝场景和复杂结构的裂缝场景检测对比。可以看出,对噪声严重和结构复杂的裂缝场景,PCNN 的输出具有明显的毛刺,而且丢失了较多的裂缝信息。HED 的输出没有噪声的影响,但是裂缝检测较为粗糙。U-Net 和 Seg-Net 的输出消除了噪声的影响,获得了较为清晰的裂缝检测结果,但局部区域的断痕仍然存在,尤其是 U-Net 方法在复杂结构裂缝场

景检测中的表现较差。

综上所述,各算法在不同特征场景的裂缝检测中均表现出了优势与不足;整体而言,PCNN 无法处理特征复杂的裂缝场景,HED 算法、Seg-Net 和 U-Net 算法的检测效果优于 PCNN 算法,主要得益于卷积模型在图像任务中的优势,但由于模型设计欠佳,导致其检测结果在噪声和断痕等方面仍有不足。本文方法针对不同特征场景,通过所




图 11 带噪声的单一结构裂缝场景检测




图 12 复杂结构裂缝场景检测对比

设计模型捕获了裂缝场景的高、低级特征,并结合注意力机制和自适应融合的方式获得了用于裂缝检测的最终特征,消除了噪声的干扰,实现了较为彻底且准确的裂缝检测。

2.2 客观评价

主观评价往往具有一定的片面性,因此,本文同样对各方法以定量指标的形式进行客观评价。在裂缝检测问题中,精确率(Precision)、召回率(Recall)、F分数(F-Score)^[19]。上述各指标的数学表达式如下。

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

$$Recall = \frac{TP}{TP + FN} \quad (8)$$

$$F_{Score} = \frac{2Precision \times Recall}{Precision + Recall} \quad (9)$$

其中, TP 是真实的正例数量, FP 是负例数量, FN 是预测的正例数量。精确率表示正例的结果中真正例的

比例,主要强调裂缝检测的准确性;召回率表示真实的正例中有多少被预测为正例,主要强调裂缝检测中将多少裂缝信息检出,上述指标均是越大越好。为了说明所提方法的有效性,本文利用上述指标进行各算法的客观评价,所提算法与对比算法在整个测试集上的平均指标对比如表 1 所示。可以看出,无论是单一结构的裂缝场景,还是复杂结构或者带有噪声的裂缝场景,PCNN 的精确率、召回率和 F 分数指标较差,结合主观评价也可看出。相较于 PCNN 方法,HED 得到了较为理想的结果,其精确率和召回率均优于 PCNN 方法。Seg-Net 获得了更加理想的指标,尤其是召回率和 F 分数均高于所提方法。U-Net 作为视觉任务中较为成熟的一种网络结构,在裂缝检测中同样发挥出了优势,其指标均高于 PCNN 和 HED 方法。本文方法的客观指标均高于对比方法。结合主、客观评价,所提方法在混凝土面裂缝检测中具有良好的表现,不仅实现了裂缝信息比较全面的检测,同时在精确率、召回率和 F 分数指标上具有较大的优势。

表 1 整个测试集上的平均指标对比

参数	PCNN	HED	Seg-Net	U-Net	所提方法
Precision	0.726 5	0.793 0	0.852 1	0.835 6	0.852 3
Recall	0.784 4	0.821 1	0.886 9	0.868 3	0.893 6
F-Score	0.751 6	0.806 6	0.869 1	0.851 6	0.872 3

2.3 消融实验

为了说明所提网络结构相关模块及注意力融合的重要性,本文对整体结构进行消融分析,具体包括:1)采用低级特征检测(low-level feature detection, LFD);2)采用高级特征检测(high-level feature detection, HFD);3)使用

非注意力融合(non-attention fusion, NAF)。将上述 3 种实验的结果与本文基于高、低级特征和注意力融合(high and low-level features detection and attention fusion, H-LFD-AF)的方式进行对比。消融实验的主观对比如图 13 所示。




图 13 消融实验对比

在图 13 中,仅使用高级特征进行裂缝检测出现了较为明显的裂缝丢失和断痕现象,而仅使用低级特征进行裂缝检测的结果很差,不仅严重丢失了裂缝信息,同时检测结果的视觉效果较差。将高、低级特征同时用于裂缝检测,而不适用注意力融合的结果如图 13(d)所示,可以看出,该结果的检测效果和视觉效果均优于图 13(a)和(b),因此,将高、低级特征的融合用于裂缝检测是有效的,但该结果出现了噪声,主要原因是在融合特征时,将噪声等冗余特征也进行了融合。图 13(e)是本文将高、低级特征进行注意力融合检测的结果,可以看出,注意力融合方式消除了噪声等冗余特征的影响,获得了较为干净且裂缝检测彻底的结果。表 2 是消融实验的客观评价,从表 2 可以看出,本文最终模块均优于消融模块,结合消融实验的主、客观评价,本文网络模型提取裂缝场景的高、低级特征和注意力融合方式是有效的。

表 2 消融实验客观评价

参数	HFD	LFD	NAF	H-LFD-AF
<i>Precision</i>	0.768 4	0.711 6	0.810 6	0.867 9
<i>Recall</i>	0.797 7	0.737 4	0.843 3	0.912 4
<i>F-Score</i>	0.782 8	0.724 3	0.826 6	0.889 6

3 结 论

裂缝检测在混凝土建筑、公路等安全检测中具有重要意义,而卷积神经网络凭借其优势在图像处理中发挥了充分的作用,本文针对此类问题,设计了一种并联卷积网络提取与自适应注意力融合的端到端裂缝检测方法。通过不同深度的网络分别获取用于裂缝检测的高、低级特征。将高、低级特征通过像素注意力机制实现自适应融合。将融合特征作为裂缝检测即非线性映射的输入,进而得到裂缝检测结果。主观视觉实验和客观评价充分表明了本文方法的可用性和有效性,另外,本文对并联结构和注意力融合模块进行消融实验以表明模型设计的合理性和每个模块的必要性。全监督学习对数据集具有较大的依赖,目前用于裂缝检的数据集有限,这将导致在有限的数据集上训练的模型对真实场景下的裂缝检测精度不高,因此,裂缝检测数据集扩充与增强也是下一步需要研究与实现的。

参考文献

- [1] 苑玮琦,薛丹. 基于机器视觉的隧道衬砌裂缝检测算法综述[J]. 仪器仪表学报, 2017, 38(12): 3100-3111.
- [2] 陶志勇,于子佳,林森. PSO_SVM 算法在太阳能电池板裂缝缺陷检测研究[J]. 电子测量与仪器学报, 2021, 35(1): 18-25.
- [3] 韩钰,韩洪飞. 基于区域级和像素级特征的路面裂缝检测方法[J]. 铁道科学与工程学报, 2018, 15(5): 1178-1186.
- [4] 范新南,严炜,史朋飞,等. PCNN 简化模型结合快速自适应双边滤波的裂缝图像去噪算法[J]. 国外电子测量技术, 2021, 40(5): 8-13.
- [5] QINGBO Z. Pavement crack detection algorithm based on image processing analysis [C]. 2016 8th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC), IEEE, 2016, 1: 15-18.
- [6] 张德津,李清泉,陈颖,等. 基于空间聚集特征的沥青路面裂缝检测方法[J]. 自动化学报, 2016, 42(3): 443-454.
- [7] OLIVEIRA H, CORREIA P L. CrackIT An image processing toolbox for crack detection and characterization [C]. 2014 IEEE International Conference on Image Processing (ICIP). IEEE, 2014: 798-802.
- [8] 唐伟,余波,赵嘉彬,等. 改进 MASK 匀光与 K-means 聚类结合的桥梁裂缝提取[J]. 电子测量术, 2021, 44(22): 128-133.
- [9] XIAO Y, LI J. Crack detection algorithm based on the fusion of percolation theory and adaptive canny operator [C]. 2018 37th Chinese Control Conference (CCC), IEEE, 2018: 4295-4299.
- [10] SU S L, GONG T. Bridge pavement crack detection under uneven illumination using improved penn algorithm [J]. The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2020, 42: 1033-1040.
- [11] 范新南,汪杰,史朋飞,等. 基于头脑风暴优化的 PCNN 路面裂缝分割算法[J]. 西南交通大学学报, 2021, 56(3): 572-578.
- [12] ZHANG L, YANG F, ZHANG Y D, et al. Road crack detection using deep convolutional neural network [C]. 2016 IEEE International Conference on Image Processing (ICIP), IEEE, 2016: 3708-3712.
- [13] XIE S, TU Z. Holistically-nested edge detection [C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1395-1403.
- [14] BADRINARAVANAN V, KENDALL A, CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(12): 2481-2495.
- [15] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]. International Conference on Medical Image Computing and Computerassisted Intervention,

- Springer, Cham, 2015: 234-241.
- [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] OZGENEL C F, SORGUC A G. Performance comparison of pretrained convolutional neural networks on crack detection in buildings[C]. ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction, IAARC Publications, 2018, 35: 1-8.
- [18] 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.
- [19] ZOU Q, ZHANG Z, LI Q, et al. Deeprack: Learning hierarchical convolutional features for crack detection [J]. IEEE Transactions on Image Processing, 2018, 28(3): 1498-1512.
- [20] 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, 2016: 770-778.
- [21] SIMONVAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. ArXiv Preprint, 2014, ArXiv:1409.1556.

作者简介

张华卫, 高级工程师, 主要研究方向为计算机视觉、图像处理、电子与通信系统等。

E-mail: zhanghuawei@mail.lzjtu.cn

贾文娟(通信作者), 硕士研究生, 主要研究方向为计算机视觉、图像处理等。

E-mail: 13789068795@qq.com

张金龙, 硕士研究生, 主要研究方向为计算机视觉、图像处理等。

E-mail: 1473513328@qq.com