

一种高精度路面裂缝检测网络结构:Crack U-Net

祝一帆 王海涛 李可 吴贺俊

中山大学计算机学院 广州 510006

(zhuyf6@mail2.sysu.edu.cn)

摘要 路面裂缝对行车安全有很大的潜在威胁,以往的人工检测方法效率不高。现有裂缝检测方法模型泛化能力低,在复杂背景下的裂缝分割能力差且效率不高。为了解决这些问题,文中提出了一种基于编码器-解码器结构的新改进型网络结构 Crack U-Net,目的是提高路面裂缝检测的模型泛化性以及检测精度。首先, Crack U-Net 用密集连接结构增强了基于编码器-解码器的网络 U-Net 模型,在以往结构的基础上提高了网络各层特征信息利用率,增强了模型的鲁棒性;其次, Crack U-Net 使用由残差块和 mini-U 组成的 Crack U-block 作为网络的基础卷积模块,相比传统双层卷积层, Crack U-block 可以提取出更丰富的裂缝特征;最后,在 Crack U-Net 的下采样节点中使用了空洞卷积替代传统卷积核,以充分捕获图像边缘的裂缝特征。为验证 Crack U-Net 模型的有效性,在公开裂缝数据集上进行了一系列测试。实验结果显示, Crack U-Net 在数据集上的 AIU 值比以往方法提升了 2.2%,在裂缝分割精度、泛化性上都优于现有方法。另外,参数轻量化部分的实验证明, Crack U-Net 可以进行很大程度的模型剪枝,无人机等移动设备将可满足剪枝后的 Crack U-Net 模型所需的计算资源。

关键词: 道路路面;裂缝检测;深度学习;图像分割

中图分类号 TP391

Crack U-Net: Towards High Quality Pavement Crack Detection

ZHU Yi-fan, WANG Hai-tao, LI Ke and WU He-jun

School of Computer Science and Engineering, Sun Yet-San University, Guangzhou 510006, China

Abstract Pavement cracks constitute a major potential threat to driving safety. Previous manual detection methods are highly subjective and inefficient. Current computer vision methods have limited applications in crack detection. Existing models have poor generalization capabilities and limited detection effects. To address this problem, a dense network structure of pavement crack detection, called Crack U-Net, is proposed to improve the model generalization capabilities and detection accuracy. Firstly, the dense connection structure of Crack U-Net adopts the network design from the encoder-decoder backbone network U-Net. Similar to the encoder-decoder backbone network, this structure of Crack U-Net is able to improve the utilization of feature information and to enhance the robustness of the model, as well. Secondly, the Crack U-block composed of residual blocks and mini-U is proposed as the basic convolution module of the network, which can extract more abundant crack features compared with the traditional double-layer convolution layer. Finally, dilated convolution is used in the middle layer of up sampling and down sampling in the network to fully capture the crack features, which is at the edge of the image. Crack U-Net runs on public fracture dataset and produces a series of experimental results. The experimental results show that the AIU value of this method on the dataset is 2.2% higher than the previous method, and it is better than the existing fracture segmentation accuracy and generalization. The experimental results also show that Crack U-Net model can be pruned, and the pruned model is suitable for loading to mobile devices for road crack detection.

Keywords Road pavement, Crack detection, Deep learning, Image segmentation

1 引言

裂缝是一种常见的路面缺陷种类,对道路行车安全有很大的潜在威胁。因此,及时发现并修复路面裂缝,保持路面的良好状态对车辆安全行驶有重要意义。传统的裂缝检测采用

人工视觉检测,效率不高。自动化检测裂缝可大幅度节省人力物力,准确的自动化检测可提高检测效率、降低漏报率。因此,自动化路面裂缝检测是近年来学者研究的一个热点问题。

早期的自动化裂缝检测方法,如阈值法^[1]、边缘检测方法^[2]和基于机器学习的方法^[3]被首先运用到裂缝检测中,但

到稿日期:2021-01-18 返修日期:2021-05-10

基金项目:国家自然科学基金(61672552);广州市科技计划项目(202002020045)

This work was supported by the National Natural Science Foundation of China(61672552) and Science and Technology Program of Guangzhou, China(202002020045).

通信作者:吴贺俊(wuhejun@mail.sysu.edu.cn)

这些方法易受光照、阴影和路面障碍等环境因素影响,并且这些方法都是基于手工设计的特征算子,检测效率和准确率不高。近年来,随着计算机视觉领域的发展,深度卷积神经网络(Deep Convolution Neural Network,DCNN)被广泛应用至裂缝检测,并取得了良好表现。相比传统方法,神经网络可以自动学习图像中的深层语义特征,达到更高的检测准确率。目前基于深度神经网络的裂缝检测方法主要分为基于图像分类的方法、基于目标检测的方法和基于图像分割的方法。基于图像分割的方法颗粒度小,检测精度高,是目前的研究热点方向,其中,将U-Net^[4]应用于裂缝分割的方法取得了良好的检测效果。然而,以往研究的模型中还存在样本外泛化性较差、复杂背景下裂缝分割能力较差的缺点。

为实现高效、鲁棒的路面裂缝检测,本文提出一种基于编码器-解码器(Encoder-Decoder)结构U-Net的裂缝检测网络Crack U-Net。首先将网络改进为密集连接结构,从以往经验来看^[4-5],这种结构能够高效利用多尺度卷积特征;其次,本文设计了一种基于残差的裂缝检测模块Crack U-block,依据残差块的特性^[6],这种结构可以加强特征提取能力并防止深度网络退化,提升网络的泛化能力;最后,Crack U-Net的下采样节点使用了空洞卷积^[7]来增加关键卷积层的感受野以捕获图像边缘的裂缝信息。实验结果表明,本文提出的Crack U-Net在检测准确率上优于以往的方法。Crack U-Net的剪枝轻量模型版本还可应用于移动设备上对裂缝检测。

2 相关工作

2.1 基于图像分类的裂缝检测方法

基于图像分类的方法一般使用轻量级的神经网络对目标图像进行分类。为了使检测的颗粒度更小,这类方法常常使用小型的窗口进行滑动检测遍历整张图像,过程中对每个窗口进行二分类。Cha等^[8]使用深度神经网络对裂缝图片进行二分类,其方法模型相对轻量,准确率较高。Luo等^[9]使用自行设计的CNN分类模型研究了网络深度与网络精度之间的关系。基于图像分类的方法虽然能得到裂缝的定位信息,但滑动窗口的检测方式导致结果较粗糙且呈块状、颗粒度过大,不能较好地体现裂缝的特征。降低窗口尺寸可以在一定程度上缓解颗粒度过大的问题,但这会大幅度牺牲模型的效率。

2.2 基于目标检测的裂缝检测方法

目标检测任务的目的是在图像中定位带有边框的对象,并确定对象的类别。Mao等^[10]提出一种基于Faster R-CNN的多任务增强裂缝检测方法,其方法效率高,对数据量的要求也较小。Suh等^[11]使用Faster R-CNN来检测民用基础设施表面的裂缝。Cha等^[12]提出ZF-net对Faster R-CNN进行了改进,以加快模型特征提取的速度。其中ZF-net^[13]是在AlexNet^[14]基础上的改进。对于形状紧凑的裂缝,基于目标检测的方法效果较好,然而,对于狭长和细小的裂缝,基于目标检测的方法中区域候选网络(Region Proposal Network,RPN)算法得出的矩形框面积过大,不利于具体形状的检出。

2.3 基于图像分割的裂缝检测方法

基于图像分割的方法较普遍的实现是使用全卷积网络结构,包括FCN^[15],U-Net^[4],SegNet^[16]等。Yang等^[17]提出在

HED^[18]方法的基础上加入特征金字塔模块的FPHBN网络进行路面裂缝检测,相比HED等边缘检测方法,其在裂缝上的检测结果的轮廓更清晰。Ren等^[19]提出了基于SegNet的裂缝检测网络CrackSegNet,使用编码器-解码器的结构进行裂缝检测。另有一些研究者使用基于编码器-解码器的U型全卷积网络结构对裂缝进行检测,利用多尺度的裂缝特征,一定程度上提升了裂缝检测的精度^[20-21]。基于图像分割的方法以像素为检测单位,颗粒度小,在模型预测过程中能完整地保留裂缝特征,成为近年来裂缝检测领域的技术趋势。

总体来看:1)基于图像分类的方法的模型效率和检测颗粒度是互相制约的,这使其检测颗粒度过大,难以体现微小裂缝的特征;2)基于目标检测的方法则需要使用矩形的检测框,但是矩形框显然难以精确表述形状复杂的裂缝,检测精度有提升空间;3)基于图像分割的方法颗粒度小,便于检测出图像中细微的特征,然而这类方法中由边缘检测方法改进而来的方法易受背景中的噪声影响,模型泛化性有限。

3 Crack U-Net 路面裂缝检测网络的框架

本文针对裂缝检测的具体应用情境,使用基于编码器-解码器的U-Net^[4]作为骨干网络,提出了Crack U-Net路面裂缝检测网络框架,其总体结构如图1所示。Crack U-Net使用Crack U-block作为网络中的特征提取单元模块(如图中的蓝色和绿色节点所示),在U-Net的基础上对网络中的卷积模块进行密集连接(如图中的虚线连接所示),并在网络中加入深监督,使网络的分支部分也可以输出结果。

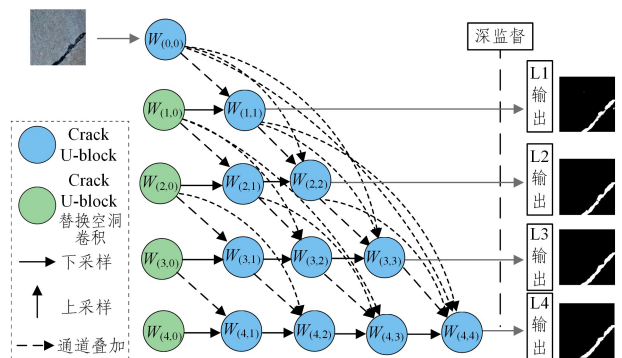


图1 Crack U-Net(电子版为彩色)

Fig. 1 Crack U-Net

3.1 U-Net 结构

Crack U-Net的网络架构以U-Net为基础。U-Net^[4]是一种带有跳跃连接的基于编码器-解码器结构的全卷积网络,其结构如图2所示,其中蓝色虚线框是网络的编码器部分,绿色虚线框是解码器部分。在U-Net中,输入图像经过多层的卷积下采样过程被编码为具有高度抽象特征信息的底层特征图像,该特征图像经过同样层数的卷积上采样解码,可被还原至与输入图像相同的尺寸并作为网络的输出。U-Net的结构中,编码器和解码器的水平对应层采用跳跃连接结构,编码器中图像经过裁剪后被叠加在解码器中的图像通道上。从结构上来看,编码器-解码器的结构有助于网络压缩提取出图像中最具代表性的特征,同时跳跃连接也使得每一层提取出的特征都能得到利用,避免了下采样过程中图像小尺寸特征的丢失。




图 2 U-Net(电子版为彩色)

Fig. 2 U-Net

U-Net 结构在医学图像分割中取得了良好的效果。裂缝图像检测也可以定义为一个二值分割任务,因此 Crack U-Net 采用 U-Net 作为模型的基础骨干网络。但是,U-Net 在裂缝检测上的应用还十分有限,具体包括如下限制因素:1)编码器层和解码器层之间的信息传递比较有限,简单的跳跃连接难以充分弥补上采样过程中造成的特征信息丢失;2)卷积模块中的双层传统卷积层结构提取出的特征代表性有限;3)网络中参数量较大,单位图像预测时间较长,难以应用至移动端的裂缝检测中;4)传统卷积核的感受野较小。

3.2 Crack U-Net 结构

为实现高精度的裂缝检测,本文提出一种基于编码器-解码器结构 U-Net 的 Crack U-Net 网络结构。Crack U-Net 针对 U-Net 存在的不足提出了如下的新设计:1)针对层间特征信息交流有限和模型参数量较大的问题,Crack U-Net 中的编码器和解码器之间采用密集连接;2)针对卷积模块特征提取能力有限的问题,设计了基于残差模块的 Crack U-block 结构替换 U-Net 中的双层卷积;3)针对卷积核感受野有限的问题,在网络的下采样节点中使用空洞卷积核替代传统的卷积核。下面对这些模块分别进行介绍。

3.2.1 Crack U-block

为使网络中的各个节点能够提取出更具代表性、更鲁棒的裂缝特征,加强网络的泛化性能,本文设计了一种适用于裂缝检测的卷积模块 Crack U-block 以替换 U-Net 中的双层卷积,如图 3 所示。Crack U-block 的内部结构称为 mini-U 结构,这种结构是一种由残差块^[6](见图 3(a))和上下采样层构

成的小型编码器-解码器结构(见图 3(b))。

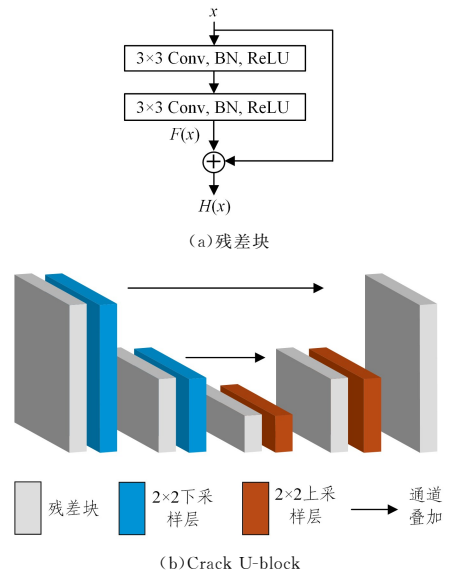


图 3 Crack U-block 的内部结构

Fig. 3 Construction of Crack U-block

残差块的输入输出关系如下:

$$H(x) = F(x) + x \tag{1}$$

其中, x 为输入, $F(x)$ 为卷积层输出, $H(x)$ 为残差模块输出。mini-U 结构由残差块和上下采样层交替组成。设输入的特征图尺寸为 $h \times w \times c$, 其中 h 和 w 为图像的宽和高, c 为图像的通道数。图像输入 Crack U-block 后经过 3 次通道数分别为 64, 128 和 256 的 3×3 卷积残差块间隔两次下采样的组

合,尺寸变为 $\frac{h}{4} \times \frac{w}{4} \times 256$,该尺寸下的特征图拥有高度抽象的特征;之后,特征图经过两次上采样和残差块的组合还原为原本尺寸,特征图的通道数为即将融合的节点需求的大小。由于 Crack U-block 中 mini-U 的结构增加了网络的层数,导致网络出现了一定的退化风险,残差块有助于缓解深度神经网络的退化现象^[6],防止改进后的网络检测效果回退。

3.2.2 密集连接

为了提高浅层卷积模块的特征信息利用率,Crack U-Net 通过密集连接分别将不同深度下相同尺度的特征进行融合。密集连接和残差块中跳跃连接的思想类似,都是在网络卷积层前后使用短路的方式将其直接连接起来,两者的不同之处是密集连接把所有的卷积层互相结合,每一层都会接收其前面所有层的输出作为额外的输入。这样的连接可以有效利用每层提取的特征信息,有助于让模型获得更鲁棒的特征^[22]。

与 U-Net 仅仅将相对应的编码器和解码器进行跳跃连接的类残差结构不同,Crack U-Net 受密集连接思想的启发,在对应的编码器和解码器中加入额外的 Crack U-block,如图 1 所示。如此,通过将解码器中的每个 Crack U-block 从垂直和水平角度与其前面 Crack U-block 的输出相结合,融合了不同分辨率下的多尺度特征;从倾斜角度与其前面所有 Crack U-block 的输出相结合,融合了在相同分辨率下的浅层和深层的特征。这样的密集连接带来的多尺度特征聚合能使网络中的特征信息流通效率得到大幅度提升^[5]。

3.2.3 模型剪枝

裂缝检测程序常需要搭载在裂缝检测的移动设备上,如无人机设备。为便于模型在移动设备上的部署,本文在 Crack U-Net 中加入深监督,如图 1 所示。深监督^[23]是指除了训练网络的输出层,也对网络中的中间层进行监督训练,是一种防止网络中间层得不到训练而无法进行反向传播的机制。在 Crack U-Net 中使用深监督训练每一垂直层的输出,即图 1 中编号为 $W_{(1,1)}$, $W_{(2,2)}$, $W_{(3,3)}$, $W_{(4,4)}$ 的节点。这些节点经过深监督训练后在实际检测时可以单独进行输出,其输出分别为 L1-L4 输出。

在 Crack U-Net 中加入深监督进行训练后,得到的模型可以进行剪枝。预测时将下标首位为 1 的节点 ($W_{(1,0)}$ 和 $W_{(1,1)}$) 水平以下,即网络第二行以下的节点全部删去,可得到以 L1 输出为输出结果的新分支模型。同理可得 L2-L4 输出的分支模型。分支模型较原模型参数量大幅度减少,而准确率仍优于其他方法(详见第 5 节实验数据)。因此,分支模型可应用至移动设备的裂缝检测中。

3.2.4 适应裂缝检测的设计

为了更好地使模型适应裂缝检测的应用,本文在 Crack U-Net 中加入一些特定设计。首先,为了提高卷积操作的感受野,在降低计算成本的同时充分捕获出现在图像边缘和角落的裂缝信息,将网络编码器和解码器过渡层,即编号为 $W_{(1,0)}$, $W_{(2,0)}$, $W_{(3,0)}$, $W_{(4,0)}$ 的节点中的卷积核改为空洞卷积核^[7]。如图 4 所示,在尺寸不变的前提下,空洞卷积核的感受野随膨胀率(Dilated rate)的上升而提高,本文将膨胀率设为 2,使 3×3 的卷积核拥有 5×5 的感受野。




图 4 空洞卷积

Fig. 4 Dilated convolution


为缓解裂缝图像数据集中存在的样本不平衡^[24]问题,Crack U-Net 模型的训练中选择 Focal Loss 作为损失函数。样本不平衡问题指数数据集中正负样本的比例过大,不利于模型将注意力集中在需要识别的正样本上。对于裂缝图像数据集,图像中需要重点识别的裂缝像素数量仅占整张图片像素数量的较小部分,易分类的背景像素反而占大多数,显然存在样本不平衡问题。Focal Loss 损失函数在交叉熵损失函数的基础上加入了权重参数,通过调整权重参数能够增大模型对正样本的注意力,强调裂缝像素的识别,同时削弱背景像素中噪声对模型的影响。Focal Loss 的计算公式如下:

$$Loss = \begin{cases} -\alpha \cdot \hat{y}^\gamma \cdot \log(1 - \hat{y}), & \text{if } y = 0 \\ -\alpha \cdot (1 - \hat{y})^\gamma \cdot \log \hat{y}, & \text{if } y = 1 \end{cases} \quad (2)$$

其中, α 为样本的不平衡系数, γ 为降低易分类样本权重的参数。在 Crack U-Net 的深监督中也同样使用 Focal Loss 作为损失函数。

4 数据集

本文使用的数据集为公开裂缝数据集 CRACK500^[17] 和 CFD^[25],数据集示例图片如图 5 所示。数据集中包含了多种光照、阴影和路面障碍等环境因素影响下的裂缝图像,有助于充分训练出较高泛化性的模型。其中 CRACK500 训练集包括 400 张 2560×1440 尺寸的 RGB 图像,测试集包括 300 张 2560×1440 尺寸的 RGB 图像。为了扩大数据集图像数量,对图像进行裁剪,将每张图像裁剪为 16 张大小相同的图像,并去除裁剪后裂缝像素个数不足 1000 的图像,最终获得 1896 张 640×360 尺寸的训练集图像和 1124 张 640×360 尺寸的测试集图像;CFD 数据集包括 118 张 480×320 尺寸的 RGB 图像,数据集的整体信息如表 1 所列。其中 CRACK500 数据集中的裂缝特征较明显,且数据量较大,而 CFD 数据集中的裂缝较细小、密集,且数据量较小,因此实验使用 CRACK500 数据集对模型进行训练和测试,使用 CFD 数据集对模型进行样本外数据泛化性实验。



(a)CRACK500 数据集

(b)CFD 数据集

图 5 数据集裂缝图像

Fig. 5 Crack datasets images

表1 数据集统计信息
Table1 Datasets statistics

	CRACK500 训练集		CRACK500 测试集		CFD
	裁剪前	裁剪后	裁剪前	裁剪后	
图片数量	400	1 896	300	1 124	118
图片尺寸	2 560×1 440	640×360	2 560×1 440	640×360	480×320

5 实验及结果

5.1 实验设备

本文实验的硬件环境为 Intel Core i5-7500 CPU, NVIDIA GeForce GTX 1080Ti GPU; 软件环境为 Windows 10 操作系统, Python3. 6, Pytorch1. 4 以及相关的神经网络 Python 库。

5.2 实验细节

为验证本文方法的有效性, 实验分为以下 4 个部分。1) 方法对比实验: 先在 CRACK500 训练集上对各方法的模型进行训练, 然后在 CRACK500 测试集上进行测试, 对比各模型的准确率等指标; 2) 样本外泛化性实验: 使用 CRACK500 数据集训练的模型直接在 CFD 数据集上进行测试, 对比各模型的样本外泛化性; 3) 消融实验: 使用去除各模块的模型在 CRACK500 数据集上进行训练和测试, 根据实验数据判定各模块对模型的影响; 4) 剪枝实验: 使用剪枝后得到的分支模型 L1 在无人机拍摄的路面裂缝图片集上进行测试, 检验分支模型是否适合应用至移动设备的路面裂缝检测。

此外, 训练中将卷积时的填充参数 (Padding) 设置为 1, 目的是保证卷积前后图像的尺寸不变, 因而通道叠加时不需要进行裁剪, 保留了完整的图像特征信息; 模型使用 Adam 优化器进行优化, 学习率设置为 0.0001, 训练批 (batch) 大小为 4, 训练迭代次数为 95。

为定量评估各模型的性能, 本文采用以下指标进行分割准确率评估: 平均交并比 (AIU)、准确率 (Precision, P)、召回率 (Recall, R) 和 F1 得分 (F1-score, F)。其中, Yang 等^[17]提出的平均交并比 (AIU) 是各分割结果图像交并比 (IoU) 的平均值, 相比 IoU, AIU 更关注分割结果中对裂缝定位中点的准确度, 更适合作为裂缝分割效果的评价指标。各评价指标的计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (3)$$

$$R = \frac{TP}{TP + FN} \quad (4)$$

$$F = \frac{(\alpha^2 + 1) \times P \times R}{\alpha^2 \times (P + R)} \quad (5)$$

$$AIU = \frac{1}{N_t} \sum \frac{N'_{pg}}{N'_p + N'_g - N'_{pg}} \quad (6)$$

其中, TP 为正确识别的裂缝像素数; FP 为误检为裂缝的像素数; TN 为正确识别的背景像素数; FN 为未检出的裂缝像素数; t 为阈值; N_t 为 $t \in [0.01, 0.99]$ 下每隔 0.01 间隔的阈值总数; 对于给定的 t , N'_{pg} 为预测像素和基准 (Ground Truth) 像素的交集, $N'_p + N'_g$ 为预测像素和基准像素的并集。实验中的 AIU 指数数据集中所有图像 AIU 的均值。AIU 的取值为 0 到 1, 其值越高, 表示预测效果越好。

本文提出的方法为基于编码器-解码器的全卷积网络的方法, 为使对比实验更具有说服力, 选取近年来表现优异、同样基于全卷积网络或是编码器-解码器结构的模型作为对比方法。实验中作为对比的方法包括两种边缘检测方法 RCF^[26] 和 FPHBN^[17], 以及两种基于编码器解码器的全卷积网络方法 U-Net^[4] 和 SegNet^[16]。这些方法具体的特征如下。

(1)RCF:RCF 是一种在经典边缘检测方法 HED^[18] 的基础上改进的方法。其使用全卷积网络和多尺寸特征融合的结构, 与本文网络相似, 适合作为对比方法。

(2)FPHBN:FPHBN 同样为基于全卷积网络的方法, 其在 HED 的基础上加入了特征金字塔和分层推进结构, 其在裂缝检测上的表现超过了同期未针对裂缝进行改进的图像分割方法, 适合作为对比方法。

(3)U-Net:U-Net 为经典的编码器-解码器全卷积网络, 同时也是本文的骨架网络, 选择 U-Net 作为对比方法可以直观地体现本文方法的改进效果。

(4)SegNet:SegNet 是一种用于图像分割的编码器-解码器全卷积网络, 其与 U-Net 的不同是在下采样中保存了特征图的 pooling indices, 并将其传递至上采样层中, 以此保留了图像的更多细节。因此, 选择 SegNet 作为对比方法, 可以比较本文方法在 U-Net 上的改进是否比其他类似方法有更好的效果。

5.3 实验结果

(1)在 CRACK500 数据集上的实验: 首先, 选取各方法在 CRACK500 上训练时在验证集中取得最好效果的模型, 作为对比模型。其次, 将各模型在 CRACK500 测试集上进行测试, 图 6 为各方法的效果对比。




图6 对比实验图

Fig. 6 Comparison experiment results

相比基于边缘检测的方法 RCF 和 FPHBN, 本文方法的分割结果更清晰; 相比未针对裂缝检测进行改进的编码器-解码器方法 SegNet 和 U-Net, 本文方法的分割结果裂缝特征更突出, 在细节特征上检测更准确。各模型的效果与模型参数量数据如表 2 所列。数据表示, 本文模型在各项指标上均优于对比方法, 在关键指标 AIU 上比其他方法中最好的 SegNet 提高了 2.2%。图 7 为所有方法的准确率-召回率 (Precision-Recall) 曲线。可以看出, 在准确率相同的情况下, 本文方法的

召回率更高;同样,在召回率相同的情况下,本文方法的准确率更高,证明了本文方法的裂缝分割结果优于所有对比方法。

表2 CRACK500 数据集上的对比实验结果

Table 2 Comparison experiment results on CRACK500

方法	Precision	Recall	F1-score	AIU
RCF	0.539	0.733	0.569	0.424
FPHBN	0.608	0.752	0.673	0.489
SegNet	0.674	0.711	0.671	0.523
U-Net	0.699	0.663	0.660	0.514
Ours	0.650	0.772	0.684	0.545




图7 PR 曲线图

Fig. 7 PR curve

(2)在 CFD 数据集上的实验:为检验与对比各方法模型的样本外泛化性,实验中选取各方法在 CRACK500 上训练时在验证集中取得最好效果的模型在 CFD 数据集上直接进行测试。测试结果如表 3 所列。数据显示,Crack U-Net 在未训练过的数据集上的表现仍优于其他方法,证明了该模型的泛化性较高。

表3 CFD 数据集上的对比实验结果

Table 3 Comparison experiment results on CFD

方法	Precision	Recall	F1-score	AIU
RCF	0.219	0.469	0.247	0.151
FPHBN	0.224	0.620	0.329	0.171
SegNet	0.509	0.755	0.591	0.430
U-Net	0.594	0.664	0.612	0.451
Ours	0.617	0.725	0.654	0.497

(3)消融实验:为验证本文各模块的有效性,对模型进行消融实验。检验的模块包括密集连接、残差模块、mini-U、空洞卷积 4 种。将包含以上不同模块的模型在相同实验环境(CRACK500 训练集)上训练相同的迭代次数(150 次),并在测试集上测试模型的 AIU 数据,实验结果如图 8 所示。图中共显示了 v1-v6 这 6 种模型的实验结果,对于每种模型,图中使用红线划去的模块代表在模型中删去的模块。对比 v1 和 v2 可以看出,v2 的模型中使用了密集连接,虽然增强了特征信息的利用率,但是增加了网络层数,导致网络难以训练,因此其 AIU 略低于 v1;对比 v1 和 v4 可以看出,v4 的模型中同时使用了密集连接和残差模块,在充分利用特征和增加流动性的同时解决了网络退化问题,因此其 AIU 相较 v1 有大幅提升;对比 v4 和 v5 可以看出,v5 使用了 mini-U 模块,能更好地学习裂缝图片的语义信息,因此其 AIU 进一步提升了;对比 v5 和 v6 可以看出,v6 的模型在 v5 的基础上在关键层中使用了空洞卷积,能更好地捕获图像边缘细小的裂缝信息,因此其 AIU 比 v5 更高。总的来说,本文方法针对裂缝数据所进行的各项改进均有效提升了裂缝检测的精度。




图8 消融实验结果(电子版为彩色)

Fig. 8 Ablation experiment results

(4)剪枝实验:为验证 3.2.3 节中叙述的模型剪枝的可行性,对模型进行了剪枝实验。实验中使用网络在 CRACK500 训练集上训练 95 个轮次后得到的模型,按照 3.2.3 节的方式剪枝获得模型 L1-L4,并分别在 CRACK500 的测试集和 CFD 数据集上进行测试,测试结果如表 4 所列。从表 4 可以看出,在 CRACK500 测试集上,虽然 L1 的分割效果不及 L4,但也与其他方法中最好的 SegNet 效果不相上下;在 CFD 数据集上,L1 的分割效果已超过其他方法中最好的 U-Net。各剪枝模型在 CRACK500 上的具体分割效果如图 9 所示。可以看出,由 L1 至 L4,分支模型检测的精确度逐渐升高,分割的细节表现也趋于完善。同时相比 L4,L1 的参数数量降低为原本的 17.8%,模型的轻量化使得其适合被搭载至移动检测平台。

表4 剪枝实验数据

Table 4 Pruning experiment results

剪枝模型	参数量/M	AIU	
		CRACK500	CFD
L1	6.0	0.507	0.478
L2	12.4	0.512	0.487
L3	21.4	0.524	0.494
L4	33.9	0.539	0.497




图9 CRACK500 数据集上的剪枝实验结果

Fig. 9 Pruning experiment results on CRACK500

为了进一步验证本文剪枝模型在移动设备图像上的泛化性,使用大疆精灵 RTK 型号无人机拍摄的裂缝图像作为测试集进行实验,测试集包括 121 张标注过的图像。测试结果

如图 10 所示,可以看出,即使 L1 剪枝模型并未在无人机数据集上进行训练,其表现依然优于其他对比方法。相较其他模

型,L1 模型分割的结果屏蔽了路面裂缝图像中常见的噪声影响,如路面白色标记线、沥青修补和光照阴影等。




图 10 无人机图像上的实验效果

Fig. 10 UAV images experiment results

实验的具体数据如表 5 所列。从分割效果来看,本文的剪枝模型在多项指标上均优于对比方法,在关键指标 AIU 上比其他方法中最好的 U-Net 提高了 5.1%,证明了本文模型的泛化性比其他方法强;从占用内存和运行时间来看,本文的剪枝模型在参数量最低的同时拥有最快的单张图片运行速度。

表 5 无人机图像上的实验结果

Table 5 UAV images experiment results


方法	Precision	Recall	F1-score	AIU	参数量/M	运行时间/(秒/张)
RCF	0.276	0.847	0.377	0.255	14.8	0.037
FPHBN	0.365	0.897	0.485	0.345	14.7	0.035
SegNet	0.424	0.940	0.559	0.410	29.4	0.032
U-Net	0.517	0.823	0.608	0.462	31.0	0.039
Ours	0.594	0.816	0.653	0.513	6.0	0.025

结束语 针对路面裂缝检测方法受背景噪声影响严重、模型泛化性不强的问题,本文提出了一种基于编码器-解码器结构 U-Net 的路面裂缝检测网络结构 Crack U-Net。首先将作为骨干网络的编码器-解码器结构 U-Net 改进为密集连接结构,并加入深监督机制,提高了网络中的特征信息利用率,同时支持模型剪枝;其次在网络中使用由残差块和 mini-U 组成的 Crack U-block 作为网络的基础卷积模块,使网络节点能够提取出更丰富、更具代表性的裂缝特征信息;最后在网络的下采样节点中采用空洞卷积,增大关键层卷积的感受野。本文将编码器-解码器网络结构运用到路面裂缝检测中,并结合裂缝图像的特点提出了新的网络结构和模块。实验结果表明,本文提出的改进模块提高了模型检测效果,与以往方法相比,Crack U-Net 在 CRACK500 数据集上的 AIU 值提升了 2.2%,在 CFD 数据集上的 AIU 值提升了 4.6%,提高了路面裂缝检测模型的泛化性与精度,同时为路面裂缝检测提供了新的解决方法。后续的研究将对模型的检测应用作进一步的优化,包括模型单位图像预测时间的计算,以进一步降低模型计算量,使其更适用于移动检测设备。

参考文献

- [1] LI H F, WU Z L, NIE J J, et al. Automatic crack detection algorithm for airport pavement based on depth image[J]. Journal of Traffic and Transportation Engineering, 2021, 20(6): 1-12.
- [2] TIAN W, SHEN H, LI X, et al. Research on corridor surface crack detection technology based on image processing[J]. Electronic Design Engineering, 2020, 28(5): 148-151, 156.
- [3] MARQUES A, CORREIA P L. Automatic road pavement crack detection using SVM[J]. Lisbon, Portugal; Dissertation for the Master of Science Degree in Electrical and Computer Engineering at Instituto Superior Técnico, 2012, 31(4): 157-170.
- [4] 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. Cham: Springer, 2015: 234-241.
- [5] ZHOU Z, SIDDIQUEEMMR, TAJBAKSHSHN, et al. Unet++: Redesigning skip connections to exploit multiscale features in image segmentation[J]. IEEE Transactions on Medical Imaging, 2019, 39(6): 1856-1867.
- [6] 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.
- [7] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[J]. arXiv: 1511. 07122.
- [8] CHA Y J, CHOI W, BÜYÜKÖZTÜRK O. Deep learning-based crack damage detection using convolutional neural networks[J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5): 361-378.
- [9] PAULY L, PEEL H, LUO S, et al. Deeper Networks for Pavement Crack Detection[C]// 34th International Symposium in Automation and Robotics in Construction. 2017: 479-485.
- [10] TANG J, MAO Y, WANG J, et al. Multi-task enhanced dam crack image detection based on faster R-CNN[C]// 2019 IEEE 4th International Conference on Image, Vision and Computing (ICIVC). IEEE, 2019: 336-340.

- [11] SUH G, CHA Y J. Deep faster R-CNN-based automated detection and localization of multiple types of damage[C]// Sensors and Smart Structures Technologies for Civil, Mechanical and Aerospace Systems 2018. International Society for Optics and Photonics, 2018, 10598:105980T.
- [12] CHA Y J, CHOI W, SUH G, et al. Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(9): 731-747.
- [13] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks[C]// European Conference on Computer Vision. Cham: Springer, 2014: 818-833.
- [14] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [15] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 3431-3440.
- [16] 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.
- [17] 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.
- [18] XIE S, TU Z. Holistically-nested edge detection [C]// Proceedings of the IEEE International Conference on Computer Vision, 2015: 1395-1403.
- [19] 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.
- [20] LIU Z, CAO Y, WANG Y, et al. Computer vision-based concrete crack detection using U-net fully convolutional networks[J]. Automation in Construction, 2019, 104: 129-139.
- [21] QU Z, XIE Y. Concrete Pavement Crack Detection Algorithm Based on Full U-net[J]. Computer Science, 2021, 48(4): 187-191.
- [22] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700-4708.
- [23] LEE C Y, XIE S, GALLAGHER P, et al. Deeply-supervised nets [C]// Artificial Intelligence and Statistics, 2015: 562-570.
- [24] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]// Proceedings of the IEEE International Conference on Computer Vision, 2017: 2980-2988.
- [25] 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.
- [26] LIU Y, CHENG M M, HU X, et al. Richer convolutional features for edge detection [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 3000-3009.



ZHU Yi-fan, born in 1997, postgraduate. Her main research interests include computer vision and crack detection.



WU He-jun, born in 1974, Ph.D, associate professor. His main research interests include intelligent perception computing, new mobile Internet of things, autonomous robot clusters.

(责任编辑:柯颖)