

改进的全局卷积网络在路面裂缝检测中的应用

李刚^{1*}, 高振阳¹, 张新春¹, 赵怀鑫², 刘卓³

¹长安大学电子与控制工程学院, 陕西 西安 710064;

²陕西省铁路集团有限公司科技质量部, 陕西 西安 710199;

³西安市西蓝天然气集团公司纪检监察委员会, 陕西 西安 710075

摘要 针对传统裂缝图像分割方法不能准确提取混凝土表面裂缝的难题,提出了一种改进的轻量级全局卷积网络的路面裂缝图像分割模型。根据深度卷积网络原理,使用大卷积核对裂缝图像进行分类和定位,针对裂缝特征构建轻量级的语义分割 MobileNetv2-GCN 模型。实验对比结果表明,该模型在三个公开裂缝数据集上都表现出优越的性能。采用中轴骨架算法提取语义分割后的裂缝骨架,计算裂缝平均宽度的物理值,其实验结果具有较高的准确性,可为公路健康检测提供可靠的数据支持。

关键词 图像处理; 语义分割; 大卷积核; 全局卷积网络; 平均交并比; 骨架提取

中图分类号 TP391.9

文献标志码 A

doi: 10.3788/LOP57.081011

Improved Global Convolutional Network for Pavement Crack Detection

Li Gang^{1*}, Gao Zhenyang¹, Zhang Xinchun¹, Zhao Huaixin², Liu Zhuo³

¹School of Electronic and Control Engineering, Chang'an University, Xi'an, Shaanxi 710064, China;

²Technology Quality Department, Shaanxi Province Railway Group Co., Ltd., Xi'an, Shaanxi 710199, China;

³Commission for Discipline Inspection and Supervision, Xi'an Xilan Natural Gas Group Co., Ltd., Xi'an, Shaanxi 710075, China

Abstract To address the inability of traditional crack image segmentation methods to inaccurately extract the crack on the concrete surface, an improved lightweight global convolutional network crack image segmentation model is proposed in this study. Based on the principle of deep convolution network, the large convolution kernel is used to classify and locate crack images. For the characteristics of cracks, a lightweight semantic segmentation model MobileNetv2-GCN is constructed. Experimental results show that the MobileNetv2-GCN model delivers superior performance in three open crack datasets. The central axis skeleton algorithm is used to extract the crack skeleton subsequent to semantic segmentation, and the physical value of the average width of the crack is calculated. The proposed model has high accuracy and can provide reliable data support for road quality detection.

Key words image processing; semantic segmentation; large convolution kernel; global convolution network; mean intersection over union; skeleton extraction

OCIS codes 100.2000; 100.4996; 100.1830; 150.1135

1 引言

裂缝是一种对公路安全构成潜在威胁的常见路面病害之一^[1]。为了保持道路良好的使用状态,对裂缝进行定位和修复是交通养护部门的一项重要工

作。裂缝测量的第一步是检测裂缝,然而手工检测裂缝相当繁琐,需要相关专业人员操作,劳动密度大,效率低。为了降低工作成本,方便道路检查,有必要实现路面裂缝的自动检测^[2-3]。

随着计算机视觉技术的发展,路面裂缝的自

收稿日期: 2019-08-05; 修回日期: 2019-09-08; 录用日期: 2019-09-12

基金项目: 国家自然科学基金(51408045)、西安市科学技术局科技创新引导项目[201805045YD23CG29(5)]、长安大学中央高校基本科研业务费专项资金(300102329203)

* E-mail: 15229296166@chd.edu.cn

动检测已成为人们研究的热点。早期, Liu 等^[4]和 Kaseko 等^[5]提出基于阈值的方法寻找裂缝区域, 假设真实的裂缝像素始终比周围背景的颜色深, 但最后裂缝分割的效果严重受阈值影响。Dollár 等^[6]将经典的结构森林边缘检测方法应用于裂缝检测, 然而该方法使用的裂缝数据是基于手工制作的, 缺乏代表性。Shi 等^[7]提出一种随机化结构森林裂缝检测算法, 结合多个层次的互补特征表示裂缝, 该方法优于现有的最小生成树路面裂缝检测^[8]、系统无监督训练的裂缝检测^[9]、自由路径计算特征的裂缝检测^[10]及最小路径选择裂缝检测^[11]等方法。然而, 随机化结构森林算法仍是利用手工制作的特征进行裂缝检测, 识别能力不足, 无法识别复杂背景中的裂缝。Li 等^[12]提出基于贪婪搜索的线性支持向量机算法, 该算法是基于 Canny 算子的图像分割方法, 受阈值影响较大, 不能分割复杂场景中的裂缝。

近年来, 深度学习以其良好的表现在计算机视觉领域得到了广泛的应用。Zhang 等^[13]采用深度学习方法进行基于裂缝块的裂缝分类检测, 该方法检测不方便, 对裂缝块大小比较敏感。Schmugge 等^[14]将裂缝检测作为一种分割任务, 利用深度学习将每个像素划分为裂缝或背景, 但裂缝分割的准确率较低。李良福等^[15]提出了复杂背景下的桥梁裂缝检测算法, 使用深度卷积生成式对抗网络增加裂缝数据集, 有效缓解了由于数据不充足引起的欠拟合现象, 其对密集连接的全卷积(FC-DenseNet103)模型进行了改进, 提出了适用于复杂背景的桥梁裂缝图像生成模型, 模型的参数量较少, 但模型的准确率还有待提高。

基于上述研究, 本文提出了一种改进的全局卷积网络(GCN)算法。为了实现全局卷积, 本文采用对称的、可分离的大卷积核来减少模型参数和计算成本, 进一步引入边界细化块提高裂缝边界附近的定位能力, 并将该模型建模为残差网络(ResNet152)和 GCN 的融合结构进行端对端的训练, 实验验证了大卷积核对裂缝分割的重要性。为了提高模型的泛化能力和准确性, 将多种预训练模型与全局卷积网络结合, 提出了一种融合可在移动端运行的 MobileNetv2 和全局卷积网络的 MobileNetv2-GCN 模型, 在不同公开裂缝数据集上验证了该模型的优越性。本文进一步采用中轴骨架算法提取裂缝骨架, 计算裂缝平均宽度, 通过实验验证该方法能够准确测量裂缝宽度。

2 全局卷积网络的裂缝图像分割方法

通过分析裂缝图像分类和语义分割模型的特点, 提出一种全局卷积网络, 解决裂缝图像分割中的分类和定位问题。

2.1 裂缝图像分类和分割模型

裂缝图像分割需要从带有语义标签的输入图像中输出每个像素的分数映射。该步骤面临分类和定位两个挑战, 然而研究发现对于分类和定位的要求是互相矛盾的。对于分类任务, 要求模型对同一个经过平移、旋转或重新标定的输入对象具有相同的分类结果。对于定位任务, 由于定位结果依赖于输入图像裂缝的位置, 需要模型对裂缝图像的改变具有很强的敏感性。

深度学习中, 分类和定位的差异导致模型结构不同。对于分类, 目前大多数框架, 如 AlexNet、VGGNet、GoogleNet 或 ResNet 都采用如图 1(a)所示的锥形网络。该网络结构从相对较小的隐藏层中提取特征, 该隐藏层在空间维度上比较粗糙, 分类器通过全连接层密集地连接整个特征图, 这使得模型对局部干扰具有鲁棒性并允许分类器处理不同类型的输入。相比之下, 对于定位, 需要相对较大的特征映射来编码更多的空间信息, 比如 FCN、SegNet 和 U-Net 分割框架采用图 1(b)所示“桶状”的网络结构, 并采用反卷积、反池化和扩张卷积等技术生成高分辨率特征图, 再用分类器局部连接特征图上的每个空间位置, 生成裂缝像素级语义标签。

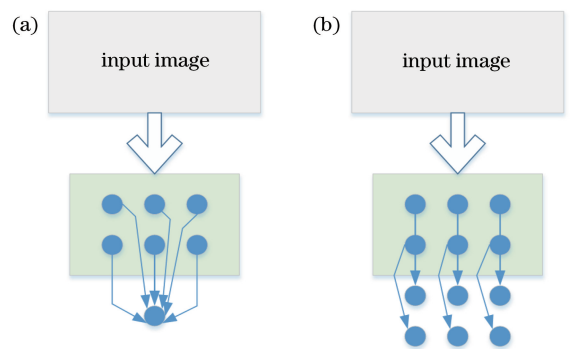


图 1 不同网络模型。(a)分类模型;(b)分割模型

Fig. 1 Different network models. (a) Classification model; (b) segmentation model

2.2 构建全局卷积网络

基于 2.1 节的分析, 全局池化会丢弃位置信息, 所以对裂缝实现定位的模型结构必须为全卷积网络, 没有任何全连接层或全局池化层。其次, 从分类的角度分析, 由于分类模型的密集连接结构, 卷积结

构的内核尺寸应该尽可能大,特别是当卷积核增加到特征图的空间大小时,该网络将与纯分类模型具有相同的优点。基于这两个原则,提出一个新的全局卷积网络,如图 2(b)所示,GCN 模块没有直接使用更大的卷积核,而是采用 GoogleNet 的思想,将大卷积核拆分为卷积组合,卷积核的大小由参数 k 控制,使用 $1 \times k + k \times 1$ 和 $k \times 1 + 1 \times k$ 的卷积组合,使得在特征图中的一个较大 $k \times k$ 区域紧密连接成为可能。与普通的 $k \times k$ 卷积相比,GCN 结构有较少的参数个数,这对于较大的卷积核尺寸更实用。

裂缝图像整体分割模型如图 2(a)所示,使用预训练的 ResNet152^[16]作为特征网络,全卷积改进网络(FCN4)^[17]作为分割框架,两者融合形成 ResNet-GCN 模型,从特征网络的不同阶段提取多尺度特征图。全局卷积网络结构为每类图像生成多尺度语义评分图,低分辨率的分数图将被反卷积层上采样,再与高分辨率的分数图叠加生成新的分数图,经过最后一次上采样后生成最终的语义评分图,输出预测

结果。

边界的准确识别与分割是图像分割的重要步骤,常见的边界预测方式是条件随机场(CRF),以及后来衍生出来的全连接 CRF(DenseCRF)^[18]和 CRFAsRNN^[19]。DenseCRF 是建立在完全连通图上的 CRF 变体,作为深度卷积后的处理方法,CRFAsRNN 将 DenseCRF 建模为 RNN 样式的运算符并提出端到端处理过程,但其涉及过多 CPU 计算。为了提高裂缝边界识别的准确率,添加边界细化(BR)模块,与 CRF 类处理方法不同,实验将 BR 模块集成到网络中,并进行端到端的训练,如图 2(c)所示。不同于 GCN 模块的大卷积核获得区域的整体语义连接特征,实验将边界对齐建模为残差结构,BR 模块使用小卷积核,提取更丰富的细节语义信息,获得更多的裂缝空间结构细节,重复使用 BR 模块,以提高裂缝特征图的分辨率,达到细化裂缝边界预测的目的。细化的分数图 S^* 的表达式为

$$S^* = S + R(S), \quad (1)$$

式中: S 为粗分数图; R 为残差分支。

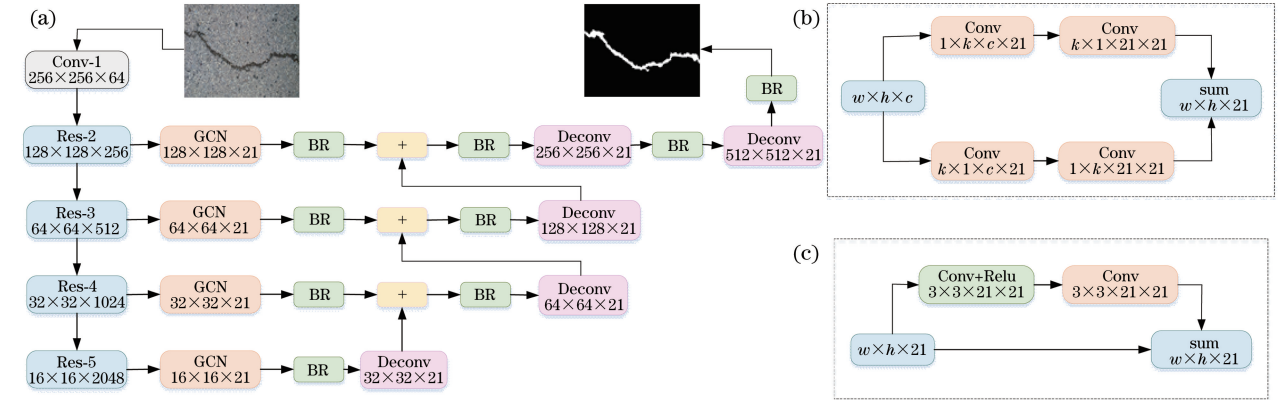


图 2 ResNet-GCN 模型的整体结构图。(a) 整个框架的结构;(b) GCN 结构;(c) 边界细化模块

Fig. 2 Overall structure of the ResNet-GCN model. (a) Structure of the entire framework;

(b) GCN structure; (c) boundary refinement module

3 实验

本节主要介绍裂缝数据集的采集和标签的制作,以及三个公开裂缝数据集的详细情况。通过分析裂缝图像分割模型,验证大卷积核的作用,并进一步提出新的模型进行实验对比。

3.1 获取裂缝数据集

实验对陕西区域的三条公路部分路段进行历时一个月的调研。在一天不同时段,使用尼康 D300 相机拍摄路面不同位置的裂缝,可确保拍摄的图像含有丰富形态的裂缝,并包含不同噪声,如光照、污

渍、杂物和伪裂缝。将这些复杂环境下的裂缝图像作为裂缝图像分割模型的样本,提高裂缝检测的泛化能力和鲁棒性。最终构建裂缝数据集并将裂缝分为六类,如图 3 所示。

实验采用的 ResNet-GCN 裂缝图像分割模型,将图像的分类预测转换为图像像素的分类预测,所以需要制作裂缝图像分割标签。采用图像标注软件 LableMe 制作裂缝图像标签,将裂缝像素标记为 255,背景像素标记为 0,实验标注的部分裂缝标签如图 4 所示,图 4(a)~4(c)为原裂缝图像,图 4(d)~4(f)为标注的裂缝图像。




图3 包含不同裂缝类型的数据集。(a)裂缝;(b)含水渍的裂缝;(c)含修补密封的裂缝;
(d)含车道线的裂缝;(e)拼接缝;(f)含杂物的裂缝

Fig. 3 Dataset containing different crack types. (a) Crack; (b) watery crack; (c) crack with repair seal;
(d) crack with lane line; (e) stitching seam; (f) crack containing debris




图4 实验裂缝数据的标注。(a) (b) (c)原始裂缝图像;(d) (e) (f)手工标记的裂缝

Fig. 4 Labeling of experimental crack data. (a) (b) (c) Original crack images; (d) (e) (f) manually marked cracks

将采集的裂缝图像和标签滑动裁剪为 $512 \text{ pixel} \times 512 \text{ pixel}$ 大小的图像,最终选取 3600 张含丰富信息的裂缝图像。为了评估模型的泛化能力,根据交叉验证原则,将裂缝数据集分为 3 个部分:60%数据用于模型训练,20%数据用于模型验证,20%数据用于模型测试,如表 1 所示。

表 1 裂缝数据集详情

Table 1 Crack dataset details

Data	Training	Verification	Test
Image size / (pixel×pixel)	512×512	512×512	512×512
Number of images	2160	720	720

为了进一步验证算法的性能,在 Crack500^[20]、GAPs384^[21] 和 Cracktree200^[8] 三个公开数据集上进行实验。

Crack500:使用手机在天普大学主校区拍摄 500 张大小为 $2000 \text{ pixel} \times 1500 \text{ pixel}$ 的图像,每个裂缝图像都有一个对应的像素级标注的二进制标签图像。由于图像数量和计算资源有限,且每张图像尺寸较大,实验前将每张图像裁剪成 16 个部分重叠的图像区域,采用这种方式最终得到 1896 张不同的裂缝图像。

GAPs384:引入德国沥青路面病害图像,通过提供标准化的高质量大规模路面病害数据集,验证算法的实际应用能力。该裂缝数据集从德国沥青路

面病害数据集选取只包含裂缝类别的图像,并进行像素级标注。实验使用该数据集测试所提网络模型的泛化能力。

Cracktree200:包括 206 张尺寸为 $800 \text{ pixel} \times 600 \text{ pixel}$ 的路面图像,该数据集具有阴影、遮挡、低对比度、噪声等各种类型的裂缝。数据集的标注为像素级二值图像标签,可直接用于评价模型性能。

3.2 卷积核大小对裂缝图像分割的影响

采用 GCN 来实现分类器和特征之间的紧密连接。GCN 的关键思想是使用大卷积核,卷积核大小用参数 k 表示。为了验证其有效性,实验采用图 2 所示整体架构并分别测试不同 k 值情况下的模型性能。为了更好地比较实验结果,使用一个简单的 1×1 卷积替换 GCN 作为基准,使用平均交并比 (m_{IoU}) 作为评价标准。平均交并比的计算公式为

$$m_{IoU} = \left(\frac{\sum_{i=0}^n \frac{p_{ii}}{\sum_{j=0}^n p_{ij} + \sum_{j=0}^n p_{ji} - p_{ii}}}{n+1} \right) \quad (2)$$

式中: $n+1$ 为类别数,包含裂缝和背景两类,此时 n 取 1; p_{ij} 为本属于类 i 但被预测为类 j 的像素数量; p_{ii} 为正确预测类 i 的数量; p_{ji} 为本属于类 j 但被预测为类 i 的像素数量。不同卷积核大小的 GCN 实验结果如表 2 所示。

表 2 不同卷积核大小的 GCN 实验结果对比

Table 2 Comparison of GCN results with different convolution kernel sizes

k	Base	3	5	7	9	11	13	15
$m_{IoU} / \%$	70.5	71.1	71.9	72.6	73.3	74.1	75.2	76.6

实验使用从 3 到 15 不同大小的奇数核,只使用奇数核是为了避免出现对齐错误。 $k=15$ 的情况下,特征图大小等于 16×16 ,网络结构变成“真正的全局卷积”。从结果可以看到,裂缝图像分割的准确率随着 k 值的增加而不断提高,特别是 $k=15$ 的“全局卷积”以 7.2% 的显著优势超过最小核卷积结果。实验结果表明,大卷积核为 GCN 结构提供良好的性能,这与第 2 节的分析一致。

在上述实验中,基准网络结构和不同核大小的 GCN 模型之间存在差异,所以不能确定模型的改进是归因于大卷积核还是 GCN。一种可能认为是 k 值越大带来的额外参数导致性能提高,另一种则考虑使用简单结构代替 GCN 实现更大卷积核的实验效果。因此,将进一步验证 GCN 模型的性能。

1) GCN 结构中,参数的数量随着 k 值的增加而线性增加,因此假设表 2 中的性能改进主要源自参数数量的增加。为了解决这个问题,将 GCN 与普通 $k \times k$ 卷积进行比较,结果如图 5 所示。从结果可以看到,对于任意给定的卷积核大小,普通卷积网络结构包含的参数比 GCN 多,但后者性能始终优于前者。同样明显的是,对于普通卷积,当 $k \leq 5$ 时,卷积核越大性能越好,但是 $k \geq 7$ 时,卷积核越大性能越差,可能是太多的参数使训练发生过拟合,

表 3 GCN 和等效的小内核堆叠卷积对比

Table 3 Comparison of GCN and equivalent small kernel stack convolution

k		3	5	7	9	11
$m_{10U}/\%$	GCN	71.1	71.9	72.6	73.3	74.1
	Stack	69.8	70.9	69.5	68.2	67.5

对于较大的卷积核尺寸,卷积核的堆叠会带来比 GCN 更多的参数,这可能会影响实验结果,减缓模型的预测速度。因此,减少堆叠卷积的中间特征图数量,并进行更进一步的比较,实验结果如表 4 所示。结果表明,GCN 模型的性能受较少参数的影响,与普通堆叠卷积相比,GCN 是一种更好的结构。

表 4 减少堆叠卷积层数的实验结果对比

Table 4 Comparison of experimental results to reduce the number of stacked convolution layers

Number of layers	Stack			GCN
	2048	1024	210	2048
$m_{10U}/\%$	71.1	70.5	68.6	72.8
Parameter amount / k	75885	28505	4307	608

3) 所提的 GCN 通过向特征图引入密集连接的方法来提高裂缝图像分割能力。基于此原因可推断,由于 GCN 非常接近纯分类问题,位于裂缝

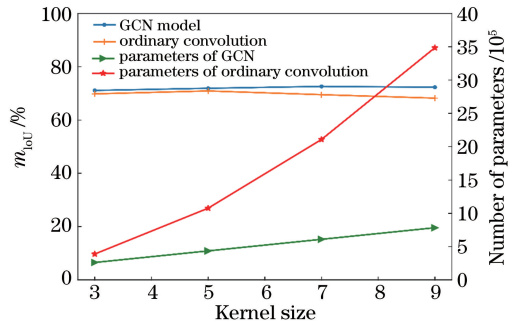


图 5 GCN 与普通卷积核的比较

Fig. 5 Comparison of GCN and ordinary convolution kernel

这减少了卷积核增大带来的好处。然而,在训练中发现大卷积核实际上使网络难以收敛,而 GCN 结构不会受其影响。

2) 将 GCN 与堆叠的小卷积进行比较。形成一个大卷积核的另一种简单方法不是使用 GCN,而是使用堆叠的小内核卷积,这在 CNN 架构中非常常见,比如 VGGNet。实验使用两个 3×3 卷积核来近似一个 5×5 卷积核,将 GCN 与等效的不同内核大小的堆叠卷积进行比较,结果如表 3 所示。为了与 GCN 结构保持一致,实验没有在堆叠的卷积中应用非线性。结果表明,对于任何较大的内核尺寸,GCN 的性能仍优于普通堆叠卷积。

图像中心的像素可能会从 GCN 中获得更多信息,而对于裂缝的边界像素,其性能主要受定位能力的影响。

为了验证上述推断,将裂缝分割图像分为两部分:1)边界区域,其像素到裂缝边界小于等于 3 pixel 的部分;2)内部区域作为其他像素。实验评估 GCN 裂缝图像分割模型在两个区域的分割结果,如表 5 所示。实验发现 GCN 模型主要提高内部区域的精度,对边界区域的影响很小,这有力地支持所提算法。此外,在表 5 中,对 BR 模块进行评估,与 GCN 结构相反,BR 模块主要提高计算边界区域的精度,证实 BR 模块的有效性。

3.3 本文裂缝分割模型及实验结果分析

在 2.2 节中,裂缝图像分割模型是优化的 ResNet152。由于 ResNet152 结构相对较复杂,网络参数较多,训练成本较高,因此将 GCN 模

表5 添加边界细化块的实验结果对比

Table 5 Comparison of experimental results after adding boundary refinement blocks

Model	Boundary accuracy / %	Center accuracy / %	Overall accuracy / %
Baseline	71.3	90.1	70.3
GCN	71.5	91.1	85.6
GCN+BR	72.6	92.3	86.7

型与 ResNet50、ResNet101 和 MobileNetv2 预训练模型结合, 提出新的 ResNet50-GCN、ResNet101-GCN 和 MobileNetv2-GCN 结构。实验过程中, 同样采用图 2 所示网络结构和大卷积内核, 删除 ResNet 和 MobileNetv2 对应的原始瓶颈结构中的前两层, 用 GCN 模型替换并添加边界细化模块。

为了充分比较各模型的裂缝图像分割性能, 将提出的 ResNet50-GCN、ResNet101-GCN 和 MobileNetv2-GCN 模型与 ResNet-GCN 模型进行比较。该对比实验在裂缝数据集上对三个新模型进行预训练, 并在 Cracktree200 裂缝数据集上进行微调。

对比实验均采用 Python3 编程语言和 TensorFlow 框架, 在配置为 i7 处理器, 1080ti GPU 的高性能计算机上完成。对训练的样本进行图像平均减法和水平翻转处理以增强数据, 提高模型的泛化能力。训练过程中, 通过经验和实验验证, 最终将参数设置如下: 迭代次数为 600 次, 训练批次大小为 8, 动量为 0.99, 权重衰减为 0.0005, 此训练参数的设置能够保证网络模型准确高效运行。

经过一系列对比实验, 提出的新融合预训练模型与原 ResNet-GCN 模型实验对比结果如表 6 所示, 新融合预训练模型的准确率比 ResNet-GCN 模型更高, 原因在于原模型参数过多, 产生了过拟合现象。该对比实验结果还表明基于 MobileNetv2-GCN 模型的实验结果均略优于其他预训练模型, 而且该模型较小, 在模型加载和预测过程中有很大优势。

表6 不同预训练融合模型的实验结果对比

Table 6 Comparison of experimental results of different pre-training fusion models

Model	m_{IoU} / %	Accuracy / %	Model size / MB
ResNet-GCN	76.6	86.7	671.0
ResNet50-GCN	82.6	90.2	274.0
ResNet101-GCN	83.6	93.4	492.0
MobileNetv2-GCN	84.6	98.5	15.5

上述实验结果表明 MobileNetv2-GCN 非常适用于裂缝图像分割而且性能最优。后续将详细介绍

MobileNetv2-GCN 模型在采集裂缝数据集上的实验结果及模型评估。实验采用的参数比较合理, 所以模型的损失下降较快, 收敛到最小值。从图 6 和图 7 可以看到, 模型验证准确率达到 98.2%, m_{IoU} 达到 84.6%, 都达到较高的稳定水平, 可准确分割裂缝图像。

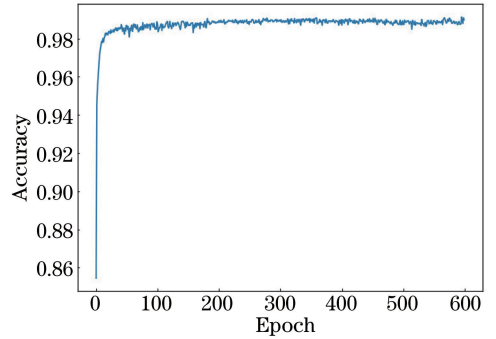



图6 MobileNetv2-GCN 模型的测试准确率

Fig. 6 Test accuracy of MobileNetv2-GCN model

图7 MobileNetv2-GCN 模型测试的 m_{IoU} Fig. 7 Test m_{IoU} of MobileNetv2-GCN model

从图 8 可直观地看到模型分割结果, MobileNetv2-GCN 模型分割的裂缝图像与对应的标签图像基本一致, 从图中标记区域可看到只有在某些细小的裂缝分叉和某些裂缝纹理复杂处出现偏差, 由此可推断所提的 MobileNetv2-GCN 模型有很好的裂缝分割性能。

为了进一步验证算法的性能, 将所提模型在 Crack500、GAPs384 和 Cracktree200 三个裂缝数据集上进行对比实验, 结果如表 7 所示。从表 7 可以看到 MobileNetv2-GCN 在裂缝数据集上的 m_{IoU} 达到 80% 以上, 测试准确率达到 90% 以上, 实验结果表明该模型具有很好的泛化能力, 可准确实现裂缝图像分割, 为进一步计算裂缝宽度提供保证。

为了验证 MobileNetv2-GCN 模型的裂缝分割性能, 不仅将 MobileNetv2-GCN 与经典的 SegNet^[22] 和 DeepLab^[23] 语义分割方法进行裂缝图

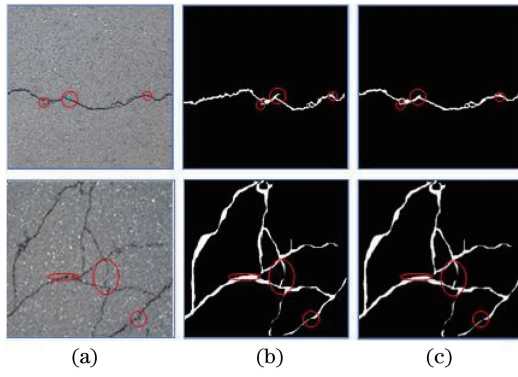


图 8 MobileNetv2-GCN 模型裂缝分割效果。(a)原图;(b)标签;(c)预测结果

Fig. 8 Crack segmentation effect of MobileNetv2-GCN model. (a) Original images; (b) label images; (c) prediction results

表 7 不同数据集上 MobileNetv2-GCN 的实验结果

Table 7 Experimental results of MobileNetv2-GCN on different datasets

Dataset	Crack500	GAPs384	Cracktree200	Proposed
$m_{IoU} / \%$	85.8	82.3	80.5	85.3
Accuracy / %	95.5	92.4	89.6	98.5

像分割对比,还与现有的裂缝图像分割模型 CNN^[24]和 FCN^[25]在采集的数据集上进行对比,实验结果如表 8 所示。从表 8 可以看到,SegNet 和 DeepLab 在一定程度上可提取图像中的裂缝,但准确率较低,实验中还发现分割后的裂缝图像含有大

量噪声,不适用于复杂场景下的裂缝图像分割。CNN 和 FCN 表现出相当好的裂缝图像分割性能,但与所提的 MobileNetv2-GCN 模型相比还具有一定差距,从对比结果可以看到,MobileNetv2-GCN 模型是一种高性能的裂缝分割模型。

表 8 MobileNetv2-GCN 与其他裂缝分割模型实验对比结果

Table 8 Comparison of MobileNetv2-GCN and other crack segmentation models

Model	SegNet	DeepLab	CNN	FCN	MobileNetv2-GCN
$m_{IoU} / \%$	67.8	69.2	72.3	80.5	85.3
Accuracy / %	74.5	80.3	81.9	89.6	98.5

4 测量裂缝宽度

使用 MobileNetv2-GCN 模型可准确分割裂缝图像,实验将利用中轴骨架算法提取裂缝分割图像后的单像素骨架,进而计算裂缝平均宽度的物理值。

4.1 提取裂缝骨架

提取裂缝骨架的目的是将裂缝在像素级上进行转换,将单像素裂缝及其拓扑结构进行可视化,为计算裂缝宽度提供基础条件。

先对输出的预测像素图像进行标记,将检测得到的裂缝分为多个裂缝段,其次将这些裂缝段细化为宽度仅为一个像素的裂缝骨架,以定量描述图像中的裂缝,最后根据生成的骨架,确定裂缝的宽度形态特征。裂缝图像的骨架化方法有中轴法^[26]、Hilditch 算法^[27]和 Zhang 快速并行算法^[28]等。Hilditch 算法的缺点是判断某一像素是否为边缘像素时,判断条件太多,条件之间存在重复,而且对宽度较大的裂缝不能准确进行骨架化,生成的裂缝骨

架化图像模糊。Zhang 快速并行算法是利用相互并列的结构元素,基于形态学方法对二值化图像进行裂缝细化,更易于实现且计算简单,但 Zhang 快速算法不能保证细化的裂缝宽度为单像素,而且细化的裂缝图像含有很多毛刺,这对后面计算裂缝宽度带来很大影响。综上所述,实验采用中轴法精准地去除各裂缝毛刺,快速准确地提取裂缝骨架,得到的裂缝骨架如图 9 所示。图 9(a)~9(c)表示分割后的裂缝图像,图 9(d)~9(f)表示在分割的裂缝图像上提取的裂缝骨架,从图中可以看到提取的裂缝骨架准确率很高,细小的裂缝分支也能很好地提取骨架。

4.2 计算裂缝平均宽度的物理值

根据 3.1 节提出的中轴算法提取裂缝骨架,可计算得到裂缝平均宽度的形态特征,当裂缝以单像素宽度表示骨架时,裂缝平均宽度的评估方法为

$$D = \frac{\int_S f^2(x, y) ds}{L} \cong \frac{\sum f^2(x, y) ds}{\sum f(x, y) dl}, \quad (3)$$




图9 裂缝骨架提取。(a)(b)(c)分割后的二值图像;(d)(e)(f)提取的裂缝骨架图像

Fig. 9 Crack skeleton extraction. (a)(b)(c) Binary images after segmentation; (d)(e)(f) extracted crack skeleton images

式中: L 为裂缝长度; d_s 为裂缝单元的有限面积; D 为裂缝的平均宽度,通过对校准图像的像素位移积分除以裂缝的骨架长度即可得到。如图10所示,实验从测量的裂缝图像中选取24绘制裂缝平均宽度真实像素与预测像素作对比。从图10可以看到,预测的裂缝平均宽度像素与真实平均宽度像素相差很小,最大相差为8 pixel,证明该方法可准确测量裂缝的平均宽度。

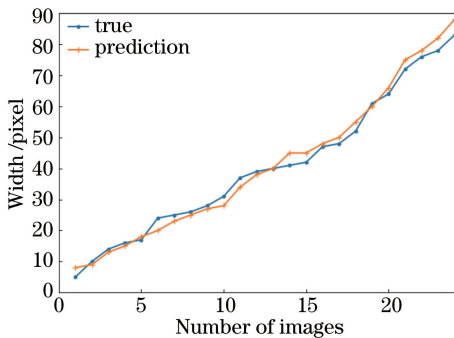


图10 真实与预测的裂缝平均宽度像素对比

Fig. 10 Comparison of real and predicted average crack width pixel

基于上述实验,可在给定拍照距离的情况下,将裂缝的像素宽度转换为物理宽度。此外通过计算整幅图像中裂缝像素占总像素数的比例,可定量评估图像中裂缝的覆盖率,这些指标可为公路健康检测提供重要参考数据。

5 结 论

通过对裂缝图像分类和分割的分析,发现大卷积核对于缓解分类和定位之间的矛盾至关重要,根据大卷积核原理,提出了全局卷积网络。对比实验结果表明,使用较大的卷积内核在裂缝图像分割中取得了较好的性能。为了进一步细化裂缝边界,又提出了一种新的边界细化块方法。实验结果证明,全局卷积网络主要对裂缝像素内部区域进行改进,而边界细化块则提高了裂缝边缘的分割性能。为了继续深化模型,采用大卷积核和边界细化块,将MobileNetv2预训练模型与GCN结合,构造了一个训练成本低、网络结构简单、参数少的高性能优化

MobileNetv2-GCN裂缝图像分割模型。得到准确分割的裂缝图像后,进一步进行骨架提取测量裂缝的平均宽度,取得了良好效果。与现有路面裂缝分割方法相比,提出了比较完整的路面裂缝自动检测算法。

参 考 文 献

- [1] Liu Y L. The maintenance technology of cracks in highway asphalt pavement[J]. China Highway, 2019 (7): 108-109.
刘永良. 公路沥青路面裂缝的养护技术[J]. 中国公路, 2019(7): 108-109.
- [2] Wang B, Wang X, Chen F, et al. Pavement crack recognition based on aerial image[J]. Acta Optica Sinica, 2017, 37(8): 0810004.
王博, 王霞, 陈飞, 等. 航拍图像的路面裂缝识别[J]. 光学学报, 2017, 37(8): 0810004.
- [3] Yue Y, Wang Y, Duan J L, et al. Experimental study on fiber Bragg grating monitoring the crack of CFRP concrete composite arch[J]. Chinese Journal of Lasers, 2015, 42(8): 0805004.
岳音, 王源, 段建立, 等. 光纤光栅CFRP混凝土复合拱裂缝监测实验研究[J]. 中国激光, 2015, 42(8): 0805004.
- [4] Liu F F, Xu G A, Yang Y X, et al. Novel approach to pavement cracking automatic detection based on segment extending [C] // 2008 International Symposium on Knowledge Acquisition and Modeling, December 21-22, 2008, Wuhan, China. New York: IEEE, 2008: 10453525.
- [5] Kaseko M S, Ritchie S G. A neural network-based methodology for pavement crack detection and classification[J]. Transportation Research Part C: Emerging Technologies, 1993, 1(4): 275-291.
- [6] Dollár P, Zitnick C L. Structured forests for fast edge detection [C] // 2013 IEEE International Conference on Computer Vision, December 1-8, 2013, Sydney, NSW, Australia. New York: IEEE, 2013: 14145062.
- [7] Shi Y, Cui L M, Qi Z Q, et al. Automatic road crack detection using random structured forests[J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(12): 3434-3445.
- [8] Zou Q, Cao Y, Li Q Q, et al. CrackTree: automatic

- crack detection from pavement images [J]. *Pattern Recognition Letters*, 2012, 33(3): 227-238.
- [9] Oliveira H, Correia P L. Automatic road crack detection and characterization[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2013, 14(1): 155-168.
- [10] Nguyen T S, Begot S, Duculty F, et al. Free-form anisotropy: a new method for crack detection on pavement surface images [C] // 2011 18th IEEE International Conference on Image Processing, September 11-14, 2011, Brussels, Belgium. New York: IEEE, 2011: 12504420.
- [11] Amhaz R, Chambon S, Idier J, et al. Automatic crack detection on two-dimensional pavement images: an algorithm based on minimal path selection [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(10): 2718-2729.
- [12] Li G, Zhao X X, Du K, et al. Recognition and evaluation of bridge cracks with modified active contour model and greedy search-based support vector machine[J]. *Automation in Construction*, 2017, 78: 51-61.
- [13] Zhang L, Yang F, Zhang Y M D, et al. Road crack detection using deep convolutional neural network[C]// 2016 IEEE International Conference on Image Processing (ICIP), September 25-28, 2016, Phoenix, AZ, USA. New York: IEEE, 2016: 16521492.
- [14] Schmutge 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), March 24-31, 2017, Santa Rosa, CA, USA. New York: IEEE, 2017: 16881695.
- [15] Li L F, Sun R Y. Bridge crack detection algorithm based on image processing under complex background [J]. *Laser & Optoelectronics Progress*, 2019, 56(6): 061002.
李良福, 孙瑞赟. 复杂背景下基于图像处理的桥梁裂缝检测算法 [J]. *激光与光电子学进展*, 2019, 56(6): 061002.
- [16] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE, 2016: 16541111.
- [17] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation [J]. *Computer Science*, 2015, 12(30): 3431-3440.
- [18] Krähenbühl P, Koltun V. Efficient inference in fully connected CRFs with gaussian edge potentials [C] // *Advances in Neural Information Processing Systems 24* (NIPS 2011), December 16-17, 2011, Granada, Spain. New York: Curran Associates., 2011: 109-117.
- [19] Zheng S, Jayasumana S, Romera-Paredes B, et al. Conditional random fields as recurrent neural networks [C] // 2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 15801852.
- [20] Yang F, Zhang L, Yu S J, et al. Feature pyramid and hierarchical boosting network for pavement crack detection [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019.
- [21] Eisenbach M, Stricker R, Seichter D, et al. How to get pavement distress detection ready for deep learning? A systematic approach [C] // 2017 International Joint Conference on Neural Networks (IJCNN), May 14-19, 2017, Anchorage, AK, USA. New York: IEEE, 2017: 17010772.
- [22] 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.
- [23] Chen L C, Papandreou G, Kokkinos I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834-848.
- [24] Fan Z, Wu Y, Lu J, et al. Automatic pavement crack detection based on structured prediction with the convolutional neural network [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2018, 561(254): 128-150.
- [25] Yang X C, Li H, Yu Y T, 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.
- [26] Hu Y, Wang P. Skeleton extracting algorithm via optimized discrete λ -medial axis [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2017, 29(8): 1505-1514.
胡炎, 王萍. 优化的离散 λ -中轴骨架提取算法 [J]. *计算机辅助设计与图形学学报*, 2017, 29(8): 1505-1514.
- [27] Hilditch C J. Comparison of thinning algorithms on a parallel processor [J]. *Image Vision Computing*, 1983, 1(3): 115-132.
- [28] Zhang T Y, Suen C Y. A fast parallel algorithm for thinning digital patterns [J]. *Communications of the ACM*, 1984, 27(3): 236-239.