

基于多分辨率网络的桥梁裂缝检测方法研究

李良福, 武彪*, 王楠

陕西师范大学计算机科学学院, 陕西 西安 710119

摘要 针对传统的桥梁裂缝检测算法具有抗噪能力差和难以处理复杂背景的裂缝图像,以及常规深度学习图像分割算法存在空间精确度低的问题,提出一种基于多分辨率且具有较高空间精确度的桥梁裂缝检测方法。首先使用无人机采集桥梁图像,通过图像增强处理得到桥梁裂缝数据集。接着利用并行连接多分辨率子网和重复的多尺度融合,使检测模型在整个过程中保持高分辨率表示,同时在相同深度和相似水平的低分辨率表示的帮助下执行重复的多尺度融合以提升高分辨率表示,使得高分辨率表示中具有很强的语义特征。最后在数据集上对所提算法进行训练及验证。结果表明,所提算法的各项分割指标都有较为显著的提升,裂缝检测准确率高达 93.8%,平均交互比达到 85.48%。

关键词 图像处理; 桥梁裂缝检测; 语义分割; 无人机数据采集; 高分辨率网络

中图分类号 TP391.9

文献标志码 A

doi: 10.3788/LOP202158.1210004

Method for Bridge Crack Detection Based on Multiresolution Network

Li Liangfu, Wu Biao*, Wang Nan

School of Computer Science, Shaanxi Normal University, Xi'an, Shaanxi 710119, China

Abstract Aiming at the problem that traditional bridge crack detection algorithms have poor antinoise ability and difficulty processing crack images with complex backgrounds, and the conventional deep learning image segmentation algorithm has low spatial accuracy, a bridge crack detection method based on multi-resolution and high spatial accuracy is proposed. First, the unmanned aerial vehicle is used to collect bridge images. The bridge crack dataset is obtained through image enhancement processing. Then, the parallel connection is used to connect multi-resolution subnets and repeated multi-scale fusions, so that the detection model maintains high-resolution representations throughout the process, while performing repeated multiscale fusion using low-resolution representations of the same depth and similar level. This is to improve the high-resolution representation so that high-resolution representation also exhibits strong high-level semantic features. Finally, the proposed algorithm is trained and verified on the dataset. The results show that all the segmentation indexes of the proposed algorithm are significantly improved, the accuracy of crack detection is as high as 93.8%, and the average interaction ratio reaches 85.48%.

Key words image processing; bridge crack detection; semantic segmentation; unmanned aerial vehicle data collection; high resolution network

OCIS codes 100.2000; 100.4996; 100.1830; 150.1135

1 引言

截至 2019 年 12 月,世界上已建成的大跨度斜拉桥前 10 座有 7 座在中国,世界上已建成的铁路/

公铁两用斜拉桥排名前 8 位均在中国,世界上已建成的大跨度悬索桥前 10 座有 6 座在中国^[1],其中港珠澳大桥因难度高超而被称作桥梁界的“珠穆朗玛峰”,其是世界最长的跨海大桥。我国无论从大桥数

收稿日期: 2020-09-17; 修回日期: 2020-09-30; 录用日期: 2020-10-14

基金项目: 国家自然科学基金(61573232, 61401263)

* E-mail: 984789463@qq.com

量还是质量方面,均已处于世界领先水平。然而,由于桥梁结构的原因,在长期使用中难免会遇到各类损坏,从而造成安全隐患。对于我国这样一个桥梁大国来说,桥梁维护成为了交通建设中尤为重要的部分,而裂缝又是最主要的桥梁病害之一,所以桥梁裂缝的检测是桥梁维护工作中的重中之重。

随着计算机图像技术的飞速发展,其为实现桥面裂缝的智能检测提供了巨大的帮助。传统的检测算法一般采用图像处理法。早期效果较好的方法是由 Abdel-Qader 等^[2]于 2006 年提出的基于 Sobel 算子和傅里叶变换的算法。2015 年, Bu 等^[3]提出了一种基于小波的图像特征以及支持向量机来自动检测桥梁图像中裂缝的方法,该方法在第一阶段中决定是否应对图像进行预处理(取决于图像特性),在第二阶段是从图像中提取小波特征。2019 年,李灏天等^[4]提出了一种基于 Bilateral-Frangi 滤波的裂缝检测算法,该算法可以更好地抑制噪声干扰。2020 年,贺福强等^[5]提出了基于海森矩阵旋转矢量不变性的滤波去噪声和局部区域裂缝走势生长方向连接的联合提取裂缝算法。各种运用于图像处理的中值滤波方法^[6-9]层出不穷,但是由于传统的图像处理方法往往仅能处理简单的裂缝类型,对于复杂背景或特征不明显的细小裂缝,均不能有效检测,所以研究者又提出了将深度学习算法应用在桥梁裂缝检测领域。2016 年, Zhang 等^[10]在裂缝检测的过程中运用了深度卷积神经网络,通过计算图像的块中心点为裂缝像素的概率,从而得到整幅图像中各像素为裂缝像素的概率。2018 年, Chen 等^[11]提出了定位细小裂缝的方法,通过卷积神经网络(CNN)和朴素贝叶斯(NB)数据相融合的 NB-CNN 对裂缝进行检测,但是并未对裂缝实现有效提取。2019 年,朱苏雅等^[12]提出了一种基于 U-Net 卷积网络的像素级语义分割算法并对桥梁裂缝进行检测,然而该算法仅对较为明显且单根粗大型裂缝的检测效果较好,并不能有效检测细小裂缝以及复杂的网状裂缝。

近年来,深度学习方法在其他领域也表现出了优异的性能,但是经典的深度学习模型直接应用在桥梁裂缝的检测^[13-15]却存在着诸多问题。对于桥梁裂缝的检测工作来说,经典的分割模型所得到的特征图分辨率较低,这会丢失空间结构信息,导致最终的空间精度偏低。本文针对上述问题,提出一种多分辨率的桥梁裂缝语义分割模型,简称 HRBCS。模型运行的整个过程中,在保存高分辨率表征的同时通过步长为 2 的卷积操作来生成多个中低分辨率的分支,并通过重复的多尺度融合,最终可以得到具有较高空间精度的高分辨率特征图,这对复杂情况下的桥梁裂缝检测效果有了极大的提升。

2 准备工作

2.1 图像的采集与分类

初始数据集通过型号为 Phantom 4 Pro 的无人机自带的 CMOS (Complementary Metal-Oxide-Semiconductor) 面阵相机来采集得到。通过对桥梁裂缝数据集的分析,发现不同类别的裂缝所产生的危害也大不一样。实验根据基本形态和危害程度将裂缝分为如下几个类别。1) 单根细小裂缝^[16]: 一般宽度在 10 mm 以下,这种裂缝不同于一般的小目标,由于裂缝本身具有细长不规则的特性,且当背景较为昏暗时,模型很难提取到明显的裂缝特征,而细小桥梁裂缝作为几种裂缝中特征最不明显的一类,检测与分割工作更是难上加难。2) 单根粗壮裂缝: 这种裂缝类似于单根细小裂缝,但是宽度一般极大,同时也是一种较为严重的病害。3) 交叉裂缝: 交叉裂缝一般为几条单根裂缝的随机组合。4) 网状裂缝: 网状裂缝一般来说形状极其不规则,裂缝之间相连,长边长度一般小于 3 m,而短边长度大于 40 cm。几类裂缝的部分图像,如图 1 所示。

由于所提算法旨在针对背景复杂多样、噪声种类繁多和分布及形态毫无规律的桥梁裂缝图像进




图 1 不同类型的桥梁裂缝。(a)单根细小裂缝;(b)单根粗壮裂缝;(c)交叉裂缝;(d)网状裂缝

Fig. 1 Different types of bridge cracks. (a) Single small crack; (b) single thick crack; (c) cross crack; (d) reticulated crack

行考虑,在图像采集的过程中,选择不同材质背景的数座桥梁并分别在不同天气的情况下进行采集,共采集 20300 张高分辨率的图片,其中包含图 1 的各类桥梁裂缝图像以及桥梁无裂缝图像。

2.2 图像的预处理

在原始采集的图像中,无裂缝的桥梁图像较多,




图 2 桥梁裂缝图像数据集扩充后的部分图像。(a)原图;(b)90°旋转;(c)180°旋转;(d)水平翻转;(e)竖直翻转

Fig. 2 Partial images of expanded bridge crack image dataset. (a) Original images; (b) 90° rotation; (c) 180° rotation; (d) horizontal flip; (e) vertical flip

为了使桥梁裂缝数据集中的特征更明显,选择了具有色彩恢复的多尺度图像增强(MSRCR)算法,该算法利用彩色恢复因子 C 来调节原始图像中三个颜色通道之间的比例关系,从而将相对较暗区域的信息突显出来,进而消除图像色彩失真的缺陷。经过 MSRCR 算法处理后的图像,其局部对比度增大,亮度与真实场景相似,在人们视觉感知下,图像显示更加逼真。

最后将扩充后的 1×10^4 张桥梁裂缝图像进行标定以及分类,其中共有 5 个类别,包括 4 类裂缝以及背景。以 PASCAL VOC 2012 语义分割数据集格式进行存储,所有标注结果均存储在对应图片名的 XML 文件中。

而提出的语义分割算法需要较多的裂缝图像来帮助网络模型学到桥梁裂缝的特征,所以从 20300 张原始图像中选取 2000 张较为明显的裂缝图像,通过几何变换和线性变换等数字图像处理方法将裂缝数据集扩充到 1×10^4 张。部分经过图像处理方法扩充后的图像如图 2 所示。

3 基于多分辨率网络的桥梁裂缝语义分割模型

3.1 HRBCS 出现的原因分析

从图 1 可以看到,桥梁裂缝图像具有背景复杂、纹理多样、噪声繁多且分布无规律等特点。传统的检测算法难以处理种类复杂的噪声,所以检测效果不佳。深度学习领域中的语义分割算法^[17]具有非常优秀的特征提取能力,因此提出一种基于多分辨率网络的改进 HRBCS 模型,用于检测并分割桥梁裂缝。目前,主流的趋势是由较高的分辨率特征图开始,通过步长为 2 的卷积块甚至是池化操作来逐渐缩小特征图的尺寸,从而丰富各个通道的信息,最

后通过一个全局池化处理来输出通道信息。例如,经典的 FCN(Fully Convolutional Networks)^[18]是先对图像进行下采样处理再使用转置卷积进行上采样处理,不使用跳层连接;U-Net 系列的模型^[19]采用对称结构先对图像进行下采样处理再进行上采样处理,同时使用跳层连接来恢复下采样处理过程所丢失的信息;DeepLab 系列的模型^[20]应用编码-解码模式将空洞卷积替换分类网络中的常规卷积,用来计算中等分辨率表示。上述模型在公共数据集和某些领域中均产生了较好的效果,但对于高分辨率图像也会丢失很多细节。

3.2 多分辨率网络的特点

多分辨率网络^[21]简称 HRNet,其是一种能够在整个过程中保持高分辨率表示的网络模型,创新之处在于使用并行连接多分辨率子网以及重复的多尺度融合。下面介绍该模型采用的两种方法。

1) 并行连接多分辨率子网:HRNet 的模型结构如图 3 所示,保持模型的最上面一层特征图为高分辨率表示。与大多数现有方法中采用先下采样再恢复的串联方式不同,其可以使低级的空间信息在该网络上得以充分保留。




图 3 多分辨率网络模型的结构

Fig. 3 Structure of multi-resolution network model

2) 重复的多尺度融合:本模型中多尺度融合需要用到情形共有以下三种。第一种为将中低分辨率表示的分支进行融合,使其为形成下一层的高分辨率特征图提供帮助,如图 4(a)所示。具体操作流程:首先将两个中低分辨率表示的分支通过 1×1 的卷积变换到高分辨率同样的通道数;然后对两个中低分辨率表示进行上采样处理,使得两个低分辨率表示的尺寸与高分辨率表示一致($H/4, W/4$),其中 H 为图像高度, W 为图像宽度;最后将三个不同分辨率表示进行求和,得到最后融合的高分辨率表示。

第二种为将高低分辨率表示的分支进行融合,使其为形成下一层的中分辨率特征图提供帮助,如图 4(b)所示。具体操作流程:首先将高分辨率表示的分支通过步长为 2 的 3×3 的卷积变换到与中间分辨率表示相同的尺寸($H/8, W/8$)与通道数;然后将先后通过 1×1 卷积与上采样操作的最低分辨率表示同样调整到与中间分辨率表示相同的尺寸与通道数;最后将三个不同分辨率表示进行求和,得到最后融合的中分辨率表示。第三种为将中高分辨率表示的分支进行融合,使其为形成下一层的低分辨率




图 4 融合操作示意图。(a)中低分辨率融入高分辨率;(b)高低分辨率融入中等分辨率;(c)中高分辨率融入低分辨率

Fig. 4 Schematic of fusion operation. (a) Low and medium resolution merged into high resolution; (b) high and low resolution merge into medium resolution; (c) medium and high resolution merge into low resolution

率特征图提供帮助,如图 4(c)所示,这种方法可以使高分率表示中具有很强的语义特征,分割结果在空间上的预测会更加准确。

3.3 构建 HRBCS 模型

根据多分辨率网络的思想,对于语义分割而言,由于其主干网络在空间上预测的精确度优于其他主干网络,则桥梁裂缝的检测工作对预测的空间精确度要求也较高。因此,提出 HRBCS 模型并用于桥梁裂缝的检测,HRBCS 模型如图 5 所示,其中 s 为步长,⊕为融合操作。

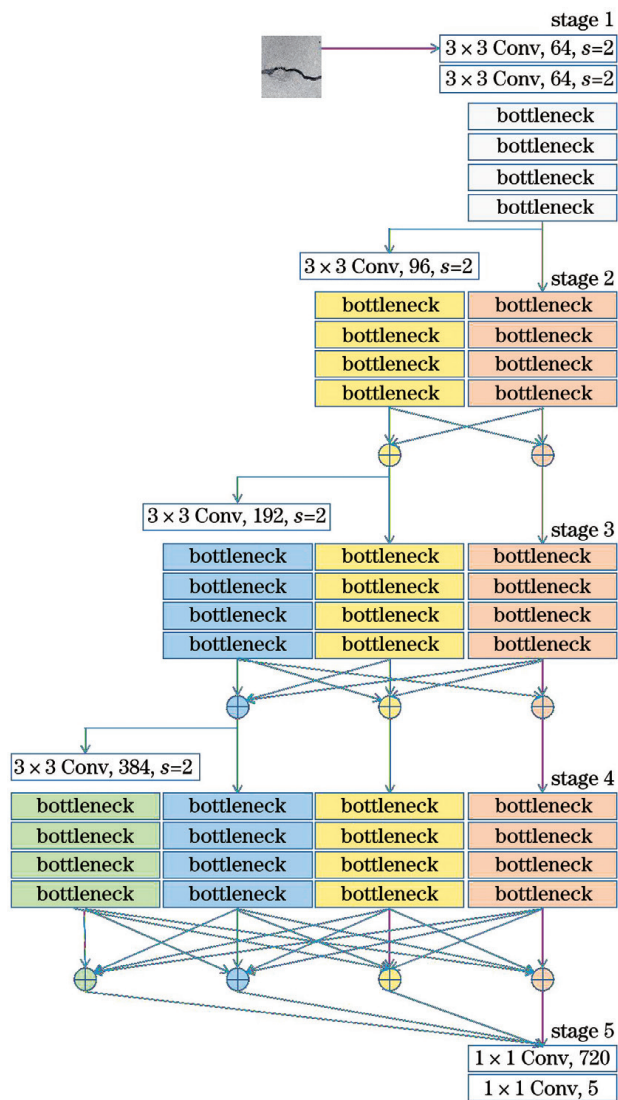


图 5 HRBCS 模型
Fig. 5 HRBCS model

首先输入桥梁裂缝图像(尺寸为 $[H, W, 3]$),通过 HRBCS 模型的 5 个阶段后得到最后的输出,下面详细介绍模型中的 5 个阶段。

第一个阶段:首先通过两次步长为 2 的 3×3 卷积操作,可以使图像的高(H)和宽(W)变为原来的

$1/4$;接着使用 4 个瓶颈块来初步提取图像特征并将通道数变为 256;最后将得到的输出(尺寸为 $[H/4, W/4, 256]$)输入第二阶段中。

第二个阶段:首先接收到第一个阶段输出的高分率分支(尺寸为 $[H/4, W/4, 256]$),并通过步长为 2 的 3×3 卷积层来产生一个较低分辨率分支(尺寸为 $[H/4, W/4, 256]$);接着对每一个分支分别使用瓶颈块进行特征提取;最后对特征进行重复的多尺度融合以得到最后的输出,并将得到的输出(尺寸分别为 $[H/4, W/4, 32]$ 和 $[H/8, W/8, 64]$)输入第三阶段中。

第三个阶段和第四个阶段重复第二个阶段的工作,并将得到的输出(尺寸分别为 $[H/4, W/4, 32]$ 、 $[H/8, W/8, 64]$ 、 $[H/16, W/16, 128]$ 和 $[H/32, W/32, 256]$)输入第五个阶段中。

第五个阶段:首先将三个并行的低分辨率子网的输出通过双线性插值和 1×1 卷积上采样,可以到高分率子网的尺寸($[H/4, W/4]$);然后通过简单的连接操作来连接相同尺寸的 4 个分支(尺寸为 $[H/4, W/4, 480]$);最后将连接结果通过 1×1 的卷积后,通道数转为语义分割的类别数目,从而得到最后的结果(尺寸为 $[H/4, W/4, 5]$)。

在 HRBCS 模型中,第一阶段只是降低了图像的分辨率,并且通过 1×1 卷积后将通道数变为 256,中间阶段对产生的低分辨率分支进行重复的多尺度融合,从而进一步提取图像特征。这里将产生低分辨率分支的功能以及重复的多尺度融合功能进行分离,产生低分辨率分支的功能在二~四阶段的开头,重复的多尺度融合功能在二~四阶段的结尾。

模型中频繁用到的瓶颈块^[22]是 ResNet-50/101/152 网络中的经典残差模块。瓶颈块的结构如图 6 所示。首先使用 1×1 的卷积来降低通道数以减少计算开销,然后使用 3×3 的卷积对特征进行提




图 6 特征提取块示意图
Fig. 6 Schematic of feature extraction block

取,最后使用 1×1 的卷积来恢复通道数。需要注意的是,每个卷积块后面均连接批量归一化(BN)层可以对特征进行归一化处理,残差连接前、 1×1 卷积后只接入 BN 层,可以避免加权之后的特征皆为正,从而保持特征的多样性。跳层连接也有两种情况:当输入模块和残差支路的通道数一致时,直接进行相加;当两种通道数不一致时(一般发生在分辨率降低之后,与分辨率通道数一般相同),需要对输入特征使用 1×1 卷积,之后同样使用 BN 层,而不使用 ReLU 层。

4 结果分析

4.1 实验配置

4.1.1 数据集的设置

通过比较数据集的不同数量来划分比例并研究其对最终模型精度的影响,在多次实验后确定将数据集中的 1×10^4 张图像划分为三个部分:训练集 8000 张,占总数的 80%,验证集和测试集各占 1000 张,分别为总数的 10%。此外,为了避免偶然性,所有实验都是重复三次后取均值,以保证结果的准确性与客观性。

4.1.2 实验平台

使用的实验平台配置如下: Intel i7 处理器, NVIDIA GeForce GTX 1070 显卡。具体的运行软

件环境:操作系统为 Ubuntu 20.04,深度学习框架采用 PyTorch 1.5.0 和 Python 3.7,开发环境采用 cuda 11.0, TorchVision 0.6.0。

4.1.3 参数设置

在训练过程中,选择 Adam 优化器,批处理大小设为 64,初始的学习率被设为 0.01,动量设为 0.9,权重衰减系数设为 0.0005,最大迭代次数设为 1.6×10^4 。在训练阶段,学习率的变化方式采用学习率预热的方式,可以使网络有更好的表现。

4.2 对比实验

区别于传统的分割网络,实验使用的分割目标共有 5 种类别,分别为单根细小裂缝、单根粗壮裂缝、交叉裂缝、块状裂缝以及伪裂缝。为了验证所提算法对桥梁裂缝分割的准确性和有效性,共设置三大组对比实验。第一组是所提算法与传统分割算法的对比;第二组是所提算法模型在原始数据集与扩充数据集上训练效果的差异;第三组是使用不同的语义分割算法对 5 类裂缝进行检测。

第一组实验选择阈值分割算法和 Canny 算法作为传统的裂缝检测算法。为了验证所提算法对背景的适应性,特别选择 4 类不同裂缝在不同的背景条件下进行实验。实验的可视化结果如图 7 所示。从图 7 可以看到,两种传统算法容易受到噪声的干




图 7 不同算法的裂缝检测结果。(a)原图;(b)标签;(c)阈值分割算法;(d)Canny 算法;(e)所提算法

Fig. 7 Crack detection results of different algorithms. (a) Original images; (b) labelling; (c) threshold segmentation algorithm; (d) Canny algorithm; (e) proposed algorithm

扰,并且对于细小裂缝以及由细小裂缝线性组成的网状裂缝这种特征不明显的图像,更是难以检测分割,而所提算法则能在不同的背景条件下,极为优异地检测与分割各类裂缝。

第二组实验是验证扩增数据集对所提算法的影响,分别在原始的数据集以及扩充的数据集上进行训练,并分别在测试集上进行测试。首先按照同样的比例将 2000 张未经过扩充以及增强处理的原始图像划分训练集、测试集和验证集,其中训练集中含

有 1600 张图像,测试集和验证集中各含有 200 张图像。接着进行两轮训练与测试,第一轮直接使用未经过扩充和增强的 1600 张桥梁裂缝图像进行训练,并在其划分出 200 张图像的测试集上进行测试;第二轮使用经过第 2 节提出的扩充及增强方法后的 8000 张图像进行训练,并在其 1000 张图片的测试集上进行测试。最后分别得到测试结果,这里选择从直观的可视化角度以及数据化角度进行评价。裂缝检测结果的直观可视化结果如图 8 所示。




图 8 有无数据集扩充的可视化结果。(a)原图;(b)标签;(c)无数据集扩充;(d)有数据集扩充

Fig. 8 Visualization results with or without dataset expansion. (a) Original images; (b) labelling; (c) without dataset expansion; (d) with dataset expansion

量化评价前先简单介绍语义分割中像素的分类,通常使用 x_{TP} 表示预测的类别与标签类别一致的像素, x_{FN} 表示未被正确预测出的像素,即标签属于目标类别而预测结果相反, x_{FP} 表示被错误预测为目标类别的像素。接着给出用于量化评价实验结果的指标:精确率(P)、召回率(R)以及平均交互比(mIOU)^[23-24],计算公式分别为

$$x_{mIOU} = x_{TP} / (x_{TP} + x_{FP} + x_{FN}), \quad (1)$$

$$P = x_{TP} / (x_{TP} + x_{FP}), \quad (2)$$

$$R = x_{TP} / (x_{TP} + x_{FN}). \quad (3)$$

F_1 分数可以看作模型精确率和召回率的一种加权平均值,其兼顾了精确率和召回率的查全和查

准的作用。 F_1 分数的具体计算公式为

$$F_1 = 2 \times \frac{P \times R}{P + R}. \quad (4)$$

接着使用 4 个量化指标来对比数据集对训练结果的影响,实验后得到的结果如表 1 所示。从图 8

表 1 有无数据集扩充对 HRBCS 模型的影响

Table 1 Effect of HRBCS model with or without dataset expansion

Number of training samples	With or without dataset expansion	P / %	R / %
1800	Without dataset expansion	48.7	34.1
8000	With dataset expansion	93.8	93.5

和表 1 可以看到,所提算法的裂缝检测准确率高达 93.8%,未扩充数据集的实验出现一定的欠拟合现象,而所提的数据集扩充及增强方法获得了很好的效果。

第三组实验是将一些在公共数据集上结果突出的分割算法与所提算法进行对比。首先依然从几类裂缝图像的可视化结果进行对比,结果如图 9 所示,其中 PSPNet 为 Pyramid Scene Parsing 网络。




图 9 所提算法与主流算法的分割结果。(a)原图;(b)标签;(c) U-Net++;(d) DeepLab-V3+;(e) PSPNet;(f)所提算法

Fig. 9 Segmentation results of proposed algorithm and mainstream algorithm. (a) Original images; (b) labelling; (c) U-Net++; (D) DeepLab-V3+; (e) PSPNet; (f) proposed algorithm

从图 9 可以看到,对于最容易检测到的单根粗大型裂缝,几种模型的检测结果均表现较好,可以完整检测分割出来;对于单根细小型裂缝,只有所提算法表现较好,其余三种主流算法均不能得到有效的分割结果;对于单根粗大型裂缝和单根细小型裂缝线性组合形成的块状裂缝与网状裂缝,由于其他三种主流分割算法在单根细小型裂缝检测上的表现,已经可以预见其在复杂的裂缝上也很难对细小裂缝部

分有好的表现,但所提算法在处理单根细小型裂缝以及复杂的网状裂缝的分割过程中,表现极为突出。从宏观的角度分析,所提算法始终保持高分辨率特征图,所以对于单根细小型裂缝以及近乎由单根细小型裂缝所组成的复杂网状裂缝而言,在空间上的精确度更为准确。

接着依然使用实验二中用到的几项评价指标对分割结果进行更为直观的评估,评估结果如表 2 所

表 2 所提算法与主流语义分割算法的对比

Table 2 Comparison between proposed algorithm and mainstream semantic segmentation algorithms

Algorithm	Precision /%	Recall /%	F_1 score /%	mIoU /%	Parameter / 10^6
U-Net++	71.0	70.3	70.7	75.30	59.5
DeepLab-V3+	82.6	80.9	81.7	78.60	43.5
PSPNet	95.1	56.9	71.2	76.00	65.9
Proposed algorithm	93.8	93.5	93.6	85.48	65.9

示。从表 2 可以看到,对于不同形态的细小桥梁裂缝,在精确率、召回率、 F_1 分数和平均交互比等几项指标中,所提算法明显优于其他三种主流的语义分割算法,进一步从数据角度论证了所提算法对桥梁裂缝检测的有效性;在与 PSPNet 相同的参数量之下,所提算法的平均交互比达到了 85.48%,比 PSPNet 算法高出近 10 个百分点。

5 结 论

本文提出并实现一种基于高分辨率卷积神经网络的桥梁裂缝检测方法,介绍所用数据集的采集以及预处理过程,并详细讲述所提算法的实现过程,最终完成对裂缝图像的精准检测。实验结果表明,数据集的扩充可以有效缓解由数据不充足引起的欠拟合现象;与现有桥梁裂缝检测算法相比,所提算法在复杂背景中有更理想的检测效果;与现有的语义分割模型相比,所提的桥梁裂缝图像分割模型在空间上的精确度更高;并且在相同的参数量下,所提算法的检测效果更好。

参 考 文 献

- [1] Mao W Q, Hu X W. Latest developments and prospects for long-span bridges in China[J]. *Bridge Construction*, 2020, 50(1): 13-19.
毛伟琦, 胡雄伟. 中国大跨度桥梁最新进展与展望[J]. *桥梁建设*, 2020, 50(1): 13-19.
- [2] Abdel-Qader I, Pashaie-Rad S, Abudayyeh O, et al. PCA-based algorithm for unsupervised bridge crack detection[J]. *Advances in Engineering Software*, 2006, 37(12): 771-778.
- [3] Bu G P, Chanda S, Guan H, et al. Crack detection using a texture analysis-based technique for visual bridge inspection[J]. *Electronic Journal of Structural Engineering*, 2015, 14(1): 41-48.
- [4] Li H T, Chen X D, Xu H Y, et al. Bridge crack detection algorithm based on Bilateral-Frangi filter[J]. *Laser & Optoelectronics Progress*, 2019, 56(18): 181401.
李灏天, 陈晓冬, 徐怀远, 等. 基于 Bilateral-Frangi 滤波的桥梁裂缝检测算法[J]. *激光与光电子学进展*, 2019, 56(18): 181401.
- [5] He F Q, Luo H, Ping A, et al. Bridge crack extraction algorithm based on Hessian matrix enhancement and local crack connection[J]. *Journal of Guizhou University (Natural Sciences)*, 2020, 37(3): 69-75.
贺福强, 罗红, 平安, 等. 基于海森矩阵增强与局部裂缝拼接相结合的桥梁裂缝提取算法[J]. *贵州大学学报(自然科学版)*, 2020, 37(3): 69-75.
- [6] Wang G Z. Pavement crack extraction based on path morphology[D]. Wuhan: Wuhan University, 2018: 20-28.
王国志. 基于路径形态学的道路裂缝提取[D]. 武汉: 武汉大学, 2018: 20-28.
- [7] Ma Y, Wang G J. Detection for bridge surface crack based on 2D complex discrete wavelet packet transform[J]. *Journal of Shenyang University of Technology*, 2018, 40(6): 659-663.
马芸, 王国军. 基于二维复数离散小波包变换的桥面裂缝检测[J]. *沈阳工业大学学报*, 2018, 40(6): 659-663.
- [8] Zhao F, Zhou W H, Chen Y T, et al. Application of improved Canny operator in crack detection[J]. *Electronic Measurement Technology*, 2018, 41(20): 107-111.
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.
- [9] Han K, Han H F. Pavement crack detection method based on region-level and pixel-level features[J]. *Journal of Railway Science and Engineering*, 2018, 15(5): 1178-1186.
韩锲, 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.
- [10] Zhang L, Yang F, Daniel Z Y, 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 Press, 2016: 3708-3712.
- [11] Chen F C, Jahanshahi M R. NB-CNN: deep learning-based crack detection using convolutional neural network and Naive Bayes data fusion[J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(5): 4392-4400.
- [12] Zhu S Y, Du J C, Li Y S, et al. Method for bridge crack detection based on the U-Net convolutional networks[J]. *Journal of Xidian University*, 2019(4): 35-42.
朱苏雅, 杜建超, 李云松, 等. 采用 U-Net 卷积网络的桥梁裂缝检测方法[J]. *西安电子科技大学学报*, 2019(4): 35-42.
- [13] Fan R, Bocus M J, Zhu Y L, et al. Road crack detection using deep convolutional neural network and adaptive thresholding [C] // 2019 IEEE Intelligent Vehicles Symposium (IV), June 9-12, 2019, Paris, France. New York: IEEE Press, 2019: 474-479.
- [14] Xu H Y, Su X, Xu H Y, et al. Autonomous bridge

- crack detection using deep convolutional neural networks [C] // Proceedings of the 3rd International Conference on Computer Engineering, Information Science & Application Technology (ICCIA 2019), May 30-31, 2019, Chongqing, China. Paris: Atlantis Press, 2019.
- [15] Liang X H, Cheng Y Z, Zhang R J, et al. Bridge crack classification and measurement method based on deep convolutional neural network [J]. Journal of Computer Applications, 2020, 40(4): 1056-1061.
梁雪慧, 程云泽, 张瑞杰, 等. 基于卷积神经网络的桥梁裂缝识别和测量方法 [J]. 计算机应用, 2020, 40(4): 1056-1061.
- [16] Wang J W, Yu P F, Luo H B. Classification method of railway bridge cracks based on improved Faster R-CNN + ZF model [J]. Journal of Beijing Jiaotong University, 2020, 44(1): 106-112.
王纪武, 鱼鹏飞, 罗海保. 基于改进 Faster R-CNN + ZF 模型的铁路桥梁裂缝分类方法 [J]. 北京交通大学学报, 2020, 44(1): 106-112.
- [17] Qing C, Yu J, Xiao C B, et al. Deep convolutional neural network for semantic image segmentation [J]. Journal of Image and Graphics, 2020, 25(6): 1069-1090.
青晨, 禹晶, 肖创柏, 等. 深度卷积神经网络图像语义分割研究进展 [J]. 中国图象图形学报, 2020, 25(6): 1069-1090.
- [18] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [19] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [M] // Navab N, Hornegger J, Wells W, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [20] 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.
- [21] Sun K, Xiao B, Liu D, et al. Deep high-resolution representation learning for human pose estimation [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 5686-5696.
- [22] Sze V, Chen Y H, Yang T J, et al. Efficient processing of deep neural networks: a tutorial and survey [J]. Proceedings of the IEEE, 2017, 105(12): 2295-2329.
- [23] Li L F, Hu M. Method for small-bridge-crack segmentation based on generative adversarial network [J]. Laser & Optoelectronics Progress, 2019, 56(10): 101004.
李良福, 胡敏. 基于生成式对抗网络的细小桥梁裂缝分割方法 [J]. 激光与光电子学进展, 2019, 56(10): 101004.
- [24] 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, 孙瑞赞. 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.