

GAN 数据增强下路面裂缝语义分割算法

阙云¹, 季雪¹, 蒋子平¹, 戴伊¹, 王叶飞¹, 陈嘉²

(1. 福州大学土木工程学院, 福州 350108; 2. 福州大学计算机与大数据学院, 福州 350108)

摘要:为解决现实情况下路面裂缝图像采集数量无法满足深度学习样本数量要求的问题,基于生成式对抗网络的数据扩增方法,提出一种以改进型 U-Net 网络模型为基础的路面裂缝语义分割算法。首先,基于传统图像处理方法将采集到的样本数据进行初次扩充,根据生成式对抗网络原理,实现样本数据再次扩充;其次,通过增加网络层数、添加归一化层、添加 Dropout 层提出一种基于改进型 U-Net 网络模型的路面裂缝语义分割算法;最后,利用基于改进型 U-Net 网络的路面裂缝语义分割模型提取扩增数据图像中的裂缝,在同等条件下与传统 U-Net 网络模型检测算法、现有主流分割算法 FCN 作实验对比研究。结果表明:该改进型算法的分割精度均优于其他两种算法,能较为准确地分割出路面裂缝,在背景像素较为复杂的情况下能较好地避免误检的情况,其平均像素精度、平均交并比分别达到了 92.43%、83.43%,在实际场景中具有较好的检测效果及较强的泛化性能。

关键词:道路工程;沥青路面裂缝;语义分割;数据增强;U-Net 网络;生成式对抗网络

中图分类号:U416.2 **文献标志码:**A **文章编号:**1671-5497(2023)11-3166-10

DOI:10.13229/j.cnki.jdxbgxb.20220003

Semantic segmentation algorithm of pavement cracks based on GAN data augmentation

QUE Yun¹, JI Xue¹, JIANG Zi-ping¹, DAI Yi¹, WANG Ye-fei¹, CHEN Jia²

(1. School of Civil Engineering, Fuzhou University, Fuzhou 350108, China; 2. College of Computer and Data Science, Fuzhou University, Fuzhou 350108, China)

Abstract: In view of the problem that the number of pavement crack images cannot meet basic needs for deep learning, according to using generative adversary network to expand the data-set, a pavement segmentation algorithm based on the U-Net network is proposed. Firstly, the data-set was initially expanded by traditional image generation, according to the principle of generative adversary network, an algorithm of pavement crack segmentation based on semantic segmentation was proposed, which was used to expand the data-set again. Secondly, based on the U-Net, an algorithm of pavement crack segmentation based on semantic segmentation was proposed, which increased the number of network layers and added Batch Normalization and dropout layer. Finally, the semantic segmentation model of pavement cracks was used to extract cracks in the expanded data image, and compared with the traditional detection algorithm

收稿日期:2022-01-04.

基金项目:国家自然科学基金项目(41772297).

作者简介:阙云(1980-),男,教授,博士.研究方向:路面结构与材料.E-mail:queyun_2001@fzu.edu.cn

通信作者:蒋子平(1975-),男,副教授,博士.研究方向:智能道路.E-mail:ziping@fzu.edu.cn

and the existing mainstream segmentation algorithm FCN. The results show that the segmentation accuracy of the algorithm is better than other two algorithms, which more precisely segments pavement crack images and avoids error detection when background pixel is complicated. The mean pixel accuracy and mean intersection over union of the algorithm are 92.43% and 83.43%, respectively. In the practical scene application, it has better detection effect and stronger generalization performance.

Key words: road engineering; pavement crack detection; semantic segmentation; data augmentation; U-Net network; generative adversary network

0 引言

裂缝是路面常见的破损类别^[1],其分割主要通过分析纹理、对比度等特征实现^[2,3],现有分割算法,如基于边缘检测的 Sobel 算子^[4,5]分割方法、基于直方图的路面裂缝阈值分割方法^[6-9]以及利用形态学与最大熵图像分割的检测算法^[10]等,在噪音明显或实际背景信息复杂时存在容易误判、检测效率低、稳定性差等问题。

近年来,深度学习在语义分割领域表现出优势可进一步提高裂缝分割的效率与稳定性,实现对像素点的分类^[11]。研究者基于全卷积神经网络(简称 FCN)构造出不同的改进型模型用于裂缝图像检测,均能得到较好的检测结果^[12-16]。Ronneberger 等^[17]在 FCN 基础上提出的 U 型对称网络 U-Net 起初应用于医学领域,如虹膜分割^[18],近年来才被应用于裂缝检测领域^[19],其与 FCN 设置的对比实验表明,虽存在缺失图像信息细节、误检等问题,但 U-Net 具有良好的鲁棒性,准确性更好^[20,21]。此外,基于 FCN 方法上改进得到的编码器-解码器网络 SegNet^[22]改进后用于复杂场景的隧道裂缝提取^[23],可有效实现端到端的裂缝分割,但对比实验得出其计算效率也低于 U-Net。

因 U-Net 具有较好的裂缝分割效果,许多裂缝分割任务均以该网络为基础,该网络适合小数据集情况,但存在误检、漏检现象。生成式对抗网络(简称 GAN)^[24]是一种最为典型的基于深度学习的数据增强算法,它通过生成器、判别器两部分网络的“博弈”过程,通过学习图像特征,可生成较为逼真的与输入数据分布一致的图片。基于 GAN 提出的 CrackGAN 增强方法^[25],解决了路面裂缝识别任务中样本分布不均衡问题。李良福等^[26]基于 GAN,扩充了桥梁裂缝图像数据集,通过丰富样本,缓解模型过拟合问题。但因 GAN 训练过程复杂,计算机计算成本较大^[27],在道路领域采用的研究较少。

鉴于此,本文针对 U-Net 本身存在的问题及沥青路面裂缝特点,对网络作进一步改进,将基于 GAN 扩增的图像样本作为改进型 U-Net 网络模型的输入数据,并进行分割实验。同时,将其检测效果与传统方法及深度学习方法作比较。

1 数据增强实验

1.1 数据采集

为确保样本多样性,将实验人员分成 3 组,分别在福州市建平路、妙峰路、福湾路 3 条干路上采集数据。采用 ORDRO AC7 相机,最大像素可达 800 万,满足数据获取精度要求。

设备设置不同拍摄离地距离,分辨率统一设置为 2048×2048 像素。由于图像在不同天气、时刻、路段拍摄,因此样本具有多光照、背景复杂等特点。

1.2 数据扩增

现实条件下难以获取大量有标签的样本,拟采用数据增强方法扩增样本,以解决实际模型训练中样本数量不足等问题。首先采用传统图像处理方法进行初次扩增;其次在初次扩增样本基础上,基于 GAN 再次扩增。

采用几何变换方法中的翻转、旋转、裁剪;基于光度变换中的色彩抖动以及添加高斯噪声实现初次扩充,部分扩充操作如表 1 所示。扩充后的样本记为 traditional-set,并作为 GAN 样本扩充实验的训练样本。

1.3 路面裂缝图像生成模型

传统图像处理方法虽可以在一定程度上增加带标注样本的数量,却不能较好的增加样本多样性,对模型精度的提高成效甚微。GAN 作为一种深度学习的方法,通过学习图像特征,可生成较为逼真的与输入数据分布一致的图片,不失为一种优异的数据增强方法。

(1) 生成式对抗网络原理

GAN 由 Goodfellow 等提出。该模型由生成

表 1 基于图像处理的数据增强
Table 1 Data augmentation based on image manipulation

处理方法	原始图像	处理图像		
		a	b	c
翻转与旋转				
裁剪				
高斯噪声				
色彩抖动				

器(G)和判别器(D)两个基本结构组成。生成器任务为:任意采样一个噪音 z ,将该噪音输入生成器 G 中,经过非线性映射运算,输出 $G(z)$,记为生成数据(或伪数据)。判别器任务为:将获得的 $G(z)$ 与真实数据 x 作概率计算,输出判别结果。整个模型训练过程中,判别器用来学习分辨真假数据(真,得分为1;假,得分为0)以防止生成器生成的假样本瞒天过海,整个训练相当于一个动态的“博弈”过程。

(2)基础模型选择

GAN在实际应用中,若样本复杂,GAN可能存在生成效果差、模式崩溃、梯度消失^[28]等问题。对此,研究者在其基础上提出一系列改进模型。

深层卷积生成式对抗网络(简称DCGAN)^[29],成功将卷积神经网络与GAN相结合,它可以直接对采集到的自然图像进行训练,对计算机性能要求不高,实验成本较低 q ,以下采用DCGAN为样本扩增实现模型。

(3)图像生成模型结构

DCGAN网络适用于 64×64 分辨率等小尺寸数据。本次研究对象为自然条件下收集的实时图片样本,分辨率过低会影响后续图像分类的结果,故实验期望生成 256×256 分辨率大小路面裂缝图像,据此,提出了一种APCDGAN(Asphalt pavement crack deep convolutional generative adversarial networks)的网络模型,以DCGAN为基础网络模型,对生成网络及判别网络作了一定调整与改进,以适应 256×256 分辨率要求。具体模型结构如图1所示。

整个网络结构由生成网络和判别网络两部分组成。如图1所示,将原始图像输入判别网络输入端,经过卷积核大小为 3×3 ,个数为64的卷积

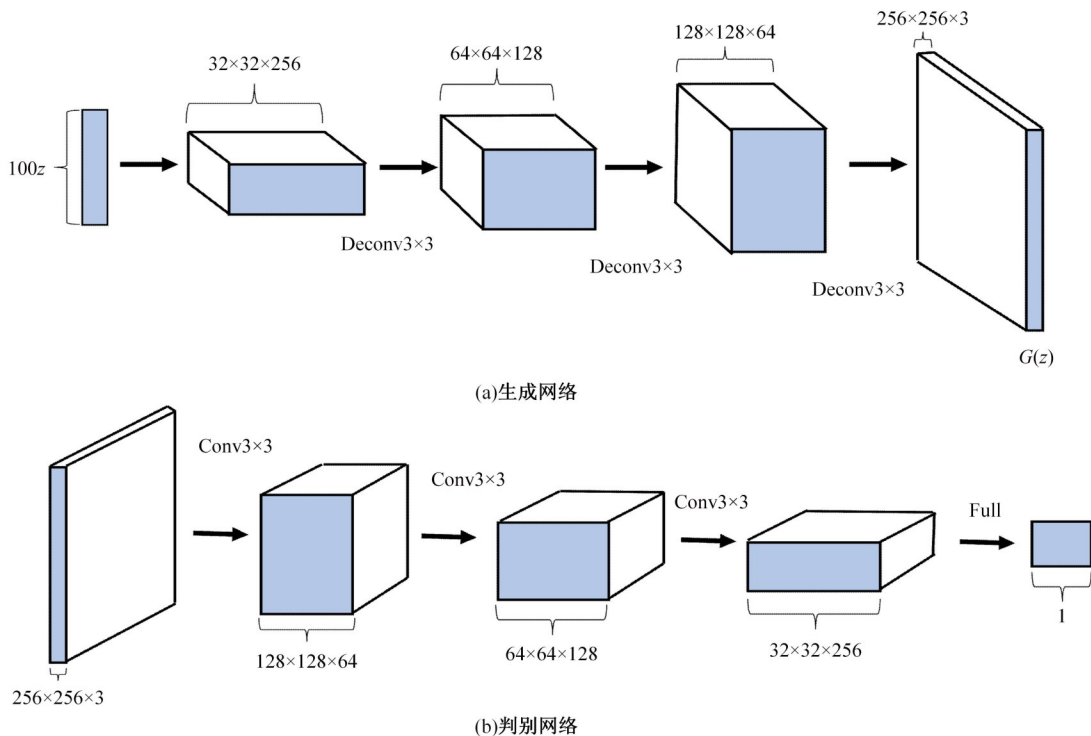


图 1 APCDCGAN 网络结构示意图

Fig. 1 Structure of asphalt pavement crack deep convolutional generative adversarial networks

层进行卷积操作,采用 LeakyReLU 作为激活函数,取 α 为 0.3。此后,再经过两层卷积核大小(Conv)为 3×3 ,个数分别为 128、256 的卷积层进行卷积操作,并采用 Batch Normalization 算法优化。最后,将特征图输入最后一层全连接层(Full)中,该层使用 sigmoid 激活函数。各层中均加入 Dropout 技术以防止过拟合现象的出现,取其值为 0.25。

判别网络通过对真实图像的学习后,具备判断能力,对生成网络中生成的“假”样本进行判断。将判别网络固定住,开始训练生成网络。将生成网络中输入 100 维度的随机噪音向量, $32 \times 32 \times 256$ 为长、宽均为 32,通道数为 256 的特征映射图,经过通道数为 128,卷积核大小为 3×3 的反卷积层(Deconv),得到 $64 \times 64 \times 128$ 的特征图,以此类推,最终得到 $256 \times 256 \times 3$ 的“虚假”路面裂缝图像。

(4)数据扩增结果

处理量大小设置为 128,迭代次数取 200,每次迭代绘制出 25 个 256×256 大小的路面裂缝图片。将 traditional-set 数据集输入 APCDCGAN 网络,经过充分训练后,最终生成裂缝图片,将样本集记为 GAN-set。图 2 为部分经一定迭代后生




图 2 基于 APCDCGAN 网络生成的路面裂缝图像
Fig. 2 Pavement crack images generated by APCDCGAN

成的图片。由图中的迭代效果可看出,随着训练时间的增加,模型生成的图像越来越清晰。当判别网络的输出值无限接近于 1 时,判别网络便将输入的图像判定为真实裂缝图像,当其输出数值接近 0 时,判别网络将输入图像鉴定为生成网络生成的图像。

1.4 建立图像数据库

(1)图像标注

U-Net 为监督学习模型,因此需要人工对实验中每张原始图像做像素标记,将图像中的裂缝区域标记出来,与背景分离。模型通过对已标记的裂缝图像训练学习,最终完成对路面裂缝的识别。

人工对 1800 张实验数据做裂缝标注,有裂缝的记为正样本,无裂缝的记为负样本,得到一个与原始数据集相对应的标签数据集。选用 LableMed 的 python 版本做裂缝的标签图像。在标注过程中,将裂缝的颜色标记为红色(255, 0, 0),对应特征值为 1,背景标记为黑色(0, 0, 0),特征值为 0。

(2)分割数据集

图 3 为部分训练集样本示例。实验以 1800 张原始图像与对应的 1800 张标签图像作为裂缝分割实验的数据集。其中,1440 张样本图像作为训练集,使用 Python 语言对所有训练样本做归一化处理;以余下的 360 张图像作为测试集,通




图 3 部分训练集样本示例
Fig. 3 Partial training set

过测试集对训练好的模型进行预测,获得最终预测结果。

2 基于语义分割的路面裂缝图像分割模型

图像的语义分割是人工智能领域中非常重要的一部分,也是基于计算机视觉下实现图像理解的重要环节。因U-Net网络结构简单、训练速度快,即使是较少的数据样本也可以较好地进行实验,同时,后续分割网络改进大都以该网络为基础,因此提出一种基于U-Net的改进型裂缝分割网络模型。

2.1 U-Net模型结构

U-Net网络主要分为3个部分:下采样、跳跃连接、上采样。输入数据先通过下采样路径在经历卷积、池化运算后,逐渐减少输入图像的尺寸,上采样路径通过反卷积层对来自下采样的特征解码,恢复图像尺寸,在上采样过程中,通过跳跃连接将上下采样中相同的网络层进行拼接,使两者信息能更多地传递。因此,整个网络模型呈现出一个U型。整个结构分别采用了4次下采样、4次上采样,每个卷积核大小均为3,每经过一层池化层,特征图的尺寸均会降为原先的一半。

2.2 路面裂缝图像分割模型构建

U-Net能将底层和高层的信息相融合,对于复杂像素信息、特征不易寻找的情况,该网络模型能够较好地提取出像素信息和位置。然而,当输入图像中背景的像素数量大于前景时,网络不能较好地对输入图像的像素信息特征进行总结。此外,该网络模型对部分图像的预测结果与人工标注的结果出入较大,模型输入与输出的图像大小不一致,无法将两者的位置关系直接映射出来。因此,本文对传统的U-Net网络模型进行改进,以适应路面裂缝图像的分割工作。

2.2.1 分割模型结构

(1)增加网络层数

在原网络的基础上,在第一层加入卷积数为8的卷积层,二至五层分别为卷积数为64、128、256、512的卷积层,每层后面都加一层最大池化层。上采样与下采样相对应,增加同样通道数的卷积层,改进后模型共经历5次下采样、5次上采

样。通过增加网络层数可以获得更加细化的图像位置信息,能充分提取裂缝像素信息特征。此外,在下采样中每个卷积及下采样层后面均使用ReLU函数,以简化模型运算,提高网络模型整体泛化能力。

(2)添加归一化层

由于路面裂缝图像中会存在背景像素数量较多的情况,在外在环境的影响下,所收集的样本数据图像会存在差异化。在该情况下,采用原始网络模型训练将出现梯度下降等问题。同时,实验训练样本与测试样本分布有差异,也将导致模型的整体学习能力和训练速度下降。归一化中可学习的参数能避免网络层中学习的特征遭到破坏,以达到解决上述问题出现的目的。

(3)加入Dropout层

在下采样中对每个卷积组后添加一层Dropout层。Dropout层以随机概率 P 丢弃一部分神经元,其余神经元参数不断更新,随网络模型向前传播,再将得到的损失结果反向传播,以此减少模型对某一特征过拟合的可能性,从而增加网络的泛化性能。

(4)全0填充

为保持卷积后特征图的大小与输入尺寸一致,使最终得到的路面裂缝二值图像不受影响,在网络模型各卷积层中采用全0填充。为保持网络输入图像尺寸与输出一致,在输入图像周围进行全0填充,此时经过步长为1的卷积后的输出尺寸与输入大小一致。最终路面裂缝分割模型结构如图4所示。

2.2.2 模型算法过程

本文通过对U-Net网络模型进行改进,获得路面裂缝分割模型用于训练,以完成对目标图像的分割任务。整个训练分为前向传播与反向传播。前者是求解图像输入后,获得特征图的过程;后者是不断调整更新模型参数、优化损失函数,以减少损失值的过程。整个模型训练的目的是找到模型中参数为最优值的情况。在本文结构中,每张图像分为背景及裂缝,故将输入模型后输出的特征图输入到sigmoid激活函数,使每个裂缝像素的像素值处于(0-1),将得到的概率分布图输入到交叉熵函数,采用Adma优化算法实现模型的整体训练。算法过程如图5所示。




图 4 路面裂缝分割模型结构

Fig. 4 Structure of pavement crack segmentation model

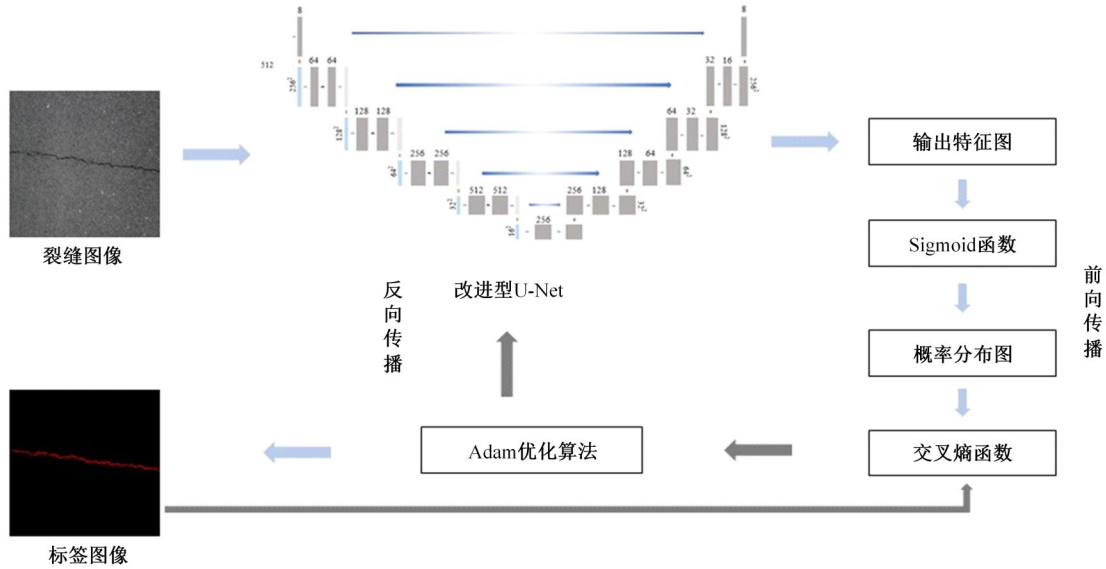


图 5 路面裂缝分割模型算法的实现

Fig. 5 Realization of pavement crack segmentation model

3 实验结果与分析

3.1 实验过程

(1)实验以 GAN-set 的 1440 张原始数据图像、对应的标签图像,作为模型输入图像。

(2)利用 Keras 框架进行分割网络模型搭建。将图像数据输入到网络模型中对模型进行训练,并将其损失函数值最小且稳定的训练结果保存。

(3)用 GAN-set 的 360 张测试样本图像对训练好的模型进行预测,将对应的人工标注标签作为预测结果的参考依据。

(4)经过模型预测结果与标签的对比及模型评价指标的结果,分析改进模型对整个路面裂缝的实际检测效果。

3.2 参数设置

模型具体参数配置表 2 所示。

表 2 改进型 U-Net 分割模型参数配置表

Table 2 Configuration parameters of improved U-Net segmentation model

参数配置	参数值
基础网络	U-Net
图片尺寸/像素	512×512
批处理量	8
GPU	Nvidia GeForce GTX 1650
求解器	Adam
Max-iter	2000
训练集	分割数据集-train
学习率	1e-4
显存/GB	64 GB
动量	0.95

3.3 评价指标

常用于衡量图像分割模型的评价指标为精度(Accuracy)。它是分割网络模型最主要、最流行的技术评价指标。主要分为两类:一类是基于像素精度(PA)的评价,一类是基于平均交并比(MIoU)。

基于像素精度的评价是最为基础的一种方式,它是指模型分类正确的图像像素所占图像总像素的比例,其公式如下^[31]:

$$PA = \frac{\sum_{i=0}^k p_{ii}}{\sum_{j=0}^k p_{ij}} \quad (1)$$

式中: k 为数据集中标记的类别; p_{ii} 为类别为 i 的像素被正确预测为 i 的数量; p_{ij} 指类别为 i 的像素被预测为 j 的数量。

平均像素精度(MPA)是对像素精度的一种改进,对每类PA作平均:

$$MPA = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij}} \quad (2)$$

式中: $k+1$ 为总分类类别(1为背景类别)。

交并比(IoU)是分割网络的标准评价指标, A 与 B 的交叠率,即为交并比:

$$IoU = \frac{area(A) \cap area(B)}{area(A) \cup area(B)} \quad (3)$$

式中: A 为表分割的结果; B 为真实值。

平均交并比的像素定义如下:

$$MIoU = \frac{1}{k+1} \frac{\sum_{i=0}^k p_{ii}}{\sum_{i=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (4)$$

3.4 结果与分析

将改进型U-Net网络模型在Adma算法下进行训练,结果如图6所示。

改进型U-Net模型在初始迭代阶段的像素准确率出现了明显提升,经500次迭代后,其像素准确率便达到了90%,这是由于在研究中对每张图像进行两种类别像素的分割,分别为裂缝与背景,对于整张图像,裂缝像素所占的比例较小,因此PA指标能达到较高的值,迭代次数不断增加后,像素准确率随之提高,经过2000次迭代过程,均能取得较高的增长。同时,由损失函数的变化趋势可知,模型的收敛速度较快,最终逐渐趋于平缓,最后稳定在0.17。整体而言,模型具有良好的分割训练效果。

以下采用设置对照实验的方法,测试及分析




图6 改进型U-Net网络模型训练准确率与损失率变化曲线

Fig. 6 Curve of training accuracy and loss of U-Net network model

算法模型的可行性及有效性。由于数据样本较多,随机抽取8个样本在不同分割模型下的分割效果进行展示,定性比较模型分割结果。

将改进型U-Net网络模型与传统U-Net网络模型以及主流的语义分割算法FCN的分割结果作比较,结果如表3所示,在自制数据集上对常用的FCN网络模型、U-Net网络模型进行复现,并将其与本文模型在像素准确率、平均像素准确率、平均交并比、运行时间(Running time)上作性能对比分析。从表3中不同模型的裂缝分割效果来看,本文方法在PA、MPA、MIoU得分均较突出,平均像素精度及平均交并比分别达到了92.43%、83.43%,相比于基础U-Net网络模型、FCN网络模型有了明显的提升效果,本文方法具有一定的优势,模型运行速度较快,在网络复杂度高于原有网络的基础上,样本图像测试时间仍能保持相对平稳的水平。

限于篇幅,随机抽取8张测试图像做不同语义分割模型下的具体的图像分割效果展示,其分割情况如图7所示,其中图(a)为原始图像、图(b)为人工标注标签图、图(c)为转化后的标签图(Ground truth)、图(d)(e)(f)分别为本文方法、U-Net、FCN对应的裂缝分割结果图像。其中用红

表3 不同模型对路面裂缝分割的性能对比

Table 3 Performance comparison of pavement crack segmentation based on different models

算法模型	PA	MPA	MIoU	Running time/s
U-Net	0.9663	0.9125	0.7874	338
FCN	0.9644	0.9117	0.7865	647
改进型U-Net	0.9778	0.9243	0.8343	341




图 7 基于语义分割的路面裂缝分割结果可视化
 Fig. 7 Visualization of pavement crack segmentation result based on semantic segmentation

色矩形框代表在分割过程中误检测到的裂缝像素,白色矩形框代表漏检的情况。

如图 7 结果展示可知,U-Net 网络与 FCN 网络被标注的红框较多,即网络在背景像素较为复杂的情况下,容易出现误检的情况,相比于这两种网络,改进型 U-Net 网络能够较好地避免此类情况的发生。面对细小裂缝像素不能够很好地分割,出现漏检现象,在细节方面仍需要加强。相对于以上两种方法,改进型 U-Net 网络整体来说分割效果较好,可以获得与人工标注后转化的标签相似的分割效果,对裂缝漏检的情况较少,能够为路面裂缝检测工作提供新的思路。

表 4 为图 7 中 8 张测试图像在各语义分割模型下的 PA 以及 IoU 评估得分情况,可知,改进型 U-Net 网络模型在平均像素精度以及平均交并比分别达到了 93.42%、82.35%,比较各模型得分情况其效果最佳。

表 4 各模型 PA 和 IoU 评估得分情况

Table 4 PA and IoU score of different models

图像编号	改进型 U-Net		U-Net		FCN	
	PA	IoU	PA	IoU	PA	IoU
1	0.9505	0.8793	0.9378	0.8647	0.9382	0.8661
2	0.9151	0.7494	0.9073	0.7262	0.9071	0.7263
3	0.9206	0.8301	0.9191	0.7262	0.9204	0.8202
4	0.9465	0.8498	0.9353	0.8463	0.9347	0.8447
5	0.9671	0.9056	0.9663	0.9051	0.9613	0.9002
6	0.9395	0.8414	0.9259	0.8225	0.9248	0.8173
7	0.8858	0.7453	0.8664	0.6761	0.8543	0.6665
8	0.9487	0.8588	0.9321	0.8396	0.9304	0.8346
平均值	0.9342	0.8235	0.9238	0.8128	0.9214	0.8095

4 结 论

(1) 鉴于实际采集到的路面裂缝图像样本数量不能满足深度学习的要求的问题,提出一种 APCDCGAN 网络模型,在基于图像处理的样本扩增基础上进行样本的再次扩增,有效缓解了模型因数据不足引起的过拟合现象。

(2) 针对传统 U-Net 网络模型不易捕捉复杂像素的信息与特征,提出一种改进型 U-Net 网络语义分割模型,从而适应路面裂缝图像背景像素数量较多的情况,提高模型泛化性能。

(3) 相比传统 U-Net 网络及 FCN 分割模型,改进型 U-Net 网络大大降低了因障碍物、遮挡物等因素造成的复杂背景情况下分割效果差的几率,能较准确地完成分割任务。在 PA、MPA、

MIoU 三个模型性能评估指标上的得分均较突出,平均像素精度及平均交并比分别达到了 92.43%、83.43%,具有较为理想的检测效果。

(4)本文提出的基于改进型 U-Net 网络路面裂缝图像语义分割模型在 PA、MPA、MIoU 以及运行速度上均表现较好,在背景像素较大的情况下能较为准确地将目标像素分割出来。但在细小裂缝像素方面分割效果差,出现漏检的情况,下一步可致力于提高模型细节处理能力,以更好满足路面裂缝检测工作。

参考文献:

- [1] Zhang D J, Li Q Q. A review of pavement high speed detection technology[J]. Journal of Geomatics, 2015, 40(1): 1-8.
- [2] Shi Y, Cui L M, Qi Z Q, et al. Automatic road crack detection using random structured forest[J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(12): 3434-3445.
- [3] Xu W, Tang Z M, Lv J Y. Pavement crack detection based on image saliency[J]. Journal of Image and Graphics, 2013, 18(1): 69-77.
- [4] Hendrickson C T. Applications of advanced technologies in transportation engineering[J]. Journal of Transportation Engineering, 2004, 130(3): 272-273.
- [5] 伯绍波, 闫茂德, 孙国军, 等. 沥青路面裂缝检测图像处理算法研究[J]. 微计算机信息, 2007, 23(15): 280-282.
Bo Shao-bo, Yan Mao-de, Sun Guo-jun, et al. Researched on crack detection image algorithm for asphalt pavement surface[J]. Microcomputer Information, 2007, 23(15): 280-282.
- [6] Li Q, Liu X. Novel approach to pavement image segmentation based on neighboring difference histogram method[J]. IEEE Computer Society, 2008, 2: 792-796.
- [7] Kirschke K R, Velinsky S A. Histogram-based approach for automated pavement-crack sensing[J]. Journal of Transportation Engineering, 1992, 118(5): 700-710.
- [8] Velinsky S A, Kirschke K R. Design considerations for automated pavement crack sealing machinery[C]// Application of Advanced Technologies in Transportation Engineering, Beijing, China, 2015: 76-80.
- [9] 徐志刚, 赵祥模, 宋焕生, 等. 基于直方图估计和形状分析的沥青路面裂缝识别算法[J]. 仪器仪表学报, 2010, 31(10): 2260-2266.
Xu Zhi-gang, Zhao Xiang-mo, Song Huan-sheng, et al. Asphalt pavement crack recognition algorithm based on histogram estimation and shape analysis[J]. Chinese Journal of Scientific Instrument, 2010, 31(10): 2260-2266.
- [10] 刘娜, 宋伟东, 赵泉华. 形态学和最大熵图像分割的城市路面裂缝检测[J]. 辽宁工程技术大学学报: 自然科学版, 2015, 34(1): 57-61.
Liu Na, Song Wei-dong, Zhao Quan-hua. Morphology and maximum entropy image segmentation based urban pavement cracks detection[J]. Journal of Liaoning Technical University (Natural Science Edition), 2015, 34(1): 57-61.
- [11] 杨国俊, 齐亚辉, 石秀名. 基于数字图像技术的桥梁裂缝检测综述[J/OL]. [2022-01-04]. DOI: 10.13229/j.cnki.jdxbgxb.20221475
- [12] Cha Y J, Choi W, Buyukozturk O. Deep learning-based crack damage detection using convolutional neural networks[J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5): 361-378.
- [13] Long J, Shelamer E, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [14] 张祥甫, 刘健, 石章松, 等. 基于深度学习的语义分割问题研究综述[J]. 激光与光电子学进展, 2019, 56(15): 20-34.
Zhang Xiang-fu, Liu Jian, Shi Zhang-song, et al. Review of deep learning based semantic segmentation[J]. Laser & Optoelectronics Progress, 2019, 56(15): 20-34.
- [15] 王森, 伍星, 张印辉, 等. 基于深度学习的全卷积网络图像裂纹检测[J]. 计算机辅助设计与图形学学报, 2018, 30(5): 115-123.
Wang Sen, Wu Xing, Zhang Yin-hui, et al. Image crack detection with fully convolutional network based on deep learning[J]. Journal of Computer-Aided Design & Computer Graphics, 2018, 30(5): 115-123.
- [16] 张振海, 季坤, 党建武. 基于桥梁裂缝识别模型的桥梁裂缝病害识别方法[J]. 吉林大学学报: 工学版, 2023, 53(5): 1418-1426.
Zhang Zhen-hai, Ji Kun, Dang Jian-wu. Crack identification method for bridge based on BCEM model[J]. Journal of Jilin University (Engineering and Technology Edition), 2023, 53(5): 1418-1426.
- [17] 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, Paris, France, 2015: 234-241.
- [18] Wang G. A semidefinite relaxation method for ener-

- gy-based source localization in sensor network[J]. IEEE Transactions on Vehicular Technology, 2011, 60(5): 2293-2301.
- [19] Zhang Z, Liu Q, Wang Y. Road extraction by deep residual U-Net[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(5): 749-753.
- [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] 朱苏雅, 杜建超, 李云松, 等. 采用U-Net卷积神经网络的桥梁裂缝检测方法[J]. 西安电子科技大学学报, 2019, 46(6): 1-8.
Zhu Su-ya, Du Jian-chao, Li Yun-song, et al. Method for bridge crack detection based on the U-Net convolutional networks[J]. Journal of Xidian University, 2019, 46(6): 1-8.
- [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] 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: 117-127.
- [24] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets[C]//Proceedings of the 2014 Conference on Advances in Neural Information Processing Systems 27, Montreal, Canada, 2014: 2672-2680.
- [25] Zhang K, Zhang Y, Cheng H D, et al. CrackGAN: a labor-light crack detection approach using industrial learning[J]. ArXiv: Computer Vision and Pattern Recognition, 2019(1909): 08216.
- [26] 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): 112-122.
- Li Liang-fu, Sun Rui-yun. Bridge crack detection algorithm based on image processing under complex background[J]. Laser & Optoelectronics Progress, 2019, 56(6): 112-122.
- [27] Perez L, Wang J. The effectiveness of data augmentation in image classification using deep learning[J]. ArXiv: Computer Vision and Pattern Recognition, 2017(1712): 04621.
- [28] 梁俊杰, 韦舰晶, 蒋正锋. 生成对抗网络GAN综述[J]. 计算机科学与探索, 2020, 14(1): 1-17.
Liang Jun-jie, Wei Jian-jing, Jiang Zheng-feng. Generative adversarial networks GAN overview[J]. Journal of Frontiers of Computer Science and Technology, 2020, 14(1): 1-17.
- [29] Zhu W, Miao J, Qing L, et al. Unsupervised representation learning with deep convolutional generative adversarial networks computer science[J]. Computer Science, 2015(11): 331-347.
- [30] 谢钊. 基于U-net神经网络的混凝土路面图像裂缝识别算法研究[D]. 重庆: 重庆邮电大学软件工程学院, 2020.
Xie Yi. Research on image crack recognition of concrete pavement based on U-net[D]. Chongqing: School of Software Engineering, Chongqing University of Posts and Telecommunications, 2020.
- [31] 李瀚超, 蔡毅, 王岭雪. 全局特征提取的全卷积网络图像语义分割算法[J]. 红外技术, 2019, 41(7): 595-599.
Li Han-chao, Cai Yi, Wang Ling-xue. Image semantic segmentation based on fully convoluted network with global feature extraction[J]. Infrared Technology, 2019, 41(7): 595-599.