

## 基于改进 U-net 模型的路面裂缝智能识别

陈泽斌, 罗文婷, 李 林

(福建农林大学交通与土木工程学院, 福州, 350100)

**摘 要:** 路面裂缝快速检测及响应是道路养护部门的一项重要工作, 然而传统的裂缝检测方法耗时且准确度低。因此, 本文基于改进后的 U-net 模型实现对路面裂缝精准地自动识别。结合 Canny 边缘检测、Otsu 阈值分割算法和人为干预手段研发一款半自动标注软件, 用以实现路面裂缝的像素级标注。研究以路面 2D 激光图像为数据集, 并在此基础上通过数据增强进行数据集样本扩充, 从而构建模型训练原始样本库; 在实验分析阶段, 使用交叉熵损失函数判断预测值与真实值的误差大小, 并结合 Adam 算法优化模型。研究表明改进后的 U-net 模型在识别精度及泛化能力上均优于原 U-net 模型及全连接神经网络模型。该研究将为道路养护管理部门的路面病害快速检测提供技术支撑, 从而利于快速响应、采取措施保证路面的行车安全。

**关键词:** U-net; 人工智能; 2D 激光图像; 路面裂缝; 数据增强

**中图分类号:** U416.2 **文献标志码:** A

### Automatic Identification of Pavement Crack Using Improved U-net Model

CHEN Zebin, LUO Wenting, LI Lin

(College of Transportation and Civil Engineering, Fujian Agricultural and Forestry University, Fuzhou, 350100, China)

**Abstract:** Rapid detection of pavement cracks is important for road maintenance and rehabilitation, but the traditional crack detection method is time-consuming, labor-intensive and low accuracy. Therefore, an improved U-net neural network model is proposed in this study. By adjusting the model structure and fine-tuning parameters, the U-net model can accurately and automatically identify pavement cracks. In this paper, a new semi-automatic marking software is developed to label pavement cracks based on Canny edge detection and Otsu segmentation algorithms, and the labeled 2D laser images are used as the training dataset. In addition, data enhancement methods are used to augment the training database. In the experimental stage, the cross-entropy loss function is used to compute error differences between the predicted value and the true value based on Adam optimization algorithm. Findings show that the improved U-net model is better than the original U-net model and the fully connected neural network model in terms of detection accuracy and algorithm robustness. This study provides a solution for the rapid detection of pavement diseases, which will be beneficial to road maintenance management department which can rapidly take corrective measures to ensure road traffic safety.

**Key words:** U-net; artificial intelligence (AI); 2D laser image; pavement crack; data augmentation

**基金项目:** 国家重点研发计划(2018YFB1201601)项目资助; 国家自然科学基金青年项目(51608123)资助项目; 福建省高校杰出科研人才培养计划资助项目。

**收稿日期:** 2019-09-02; **修订日期:** 2019-12-05

## 引 言

路面病害是影响行车安全和行车舒适性的一大重要因素,裂缝则是最常见的一种表现形式,及时发现裂缝并进行修补可以有效地减小路面病害带来的损失,进而减少对路面行车安全的影响。裂缝检测主要包括裂缝识别、分割、严重程度判别和统计(测量面积或长度)。其中,精确快速的裂缝自动识别技术是裂缝检测的关键,也是该领域挑战的难点。目前,路面病害数据已基本实现自动化采集,诸如美国WayLink公司研发的数字化公路数据采集车<sup>[1]</sup>,武大卓越科技研发的ZOYON-RTM<sup>[2]</sup>,以及中公高科研发的CiCS等路面检测设备。然而在实际生产过程中,裂缝识别仍采用人工检测,该方法工作强度大、耗时长、效率低、存在主观性<sup>[3]</sup>。

近年来,随着图像处理技术的深入研究,涌现了大量的路面裂缝自动识别算法。基于阈值分割的算法<sup>[4]</sup>是早期的裂缝检测方法,典型的有Prewitt算法<sup>[5]</sup>和Canny算法<sup>[6]</sup>,此类算法通过确定最佳阈值将图像分割为前景和背景,从而提取出裂缝信息。但由于路面背景复杂多样,阈值的选取没有规律可循。文献<sup>[7]</sup>提出将路面图像划分为几个子区域并通过滑窗对裂缝区域进行识别和分类,但此算法缺乏泛化能力。随着深度学习的兴起,基于神经网络<sup>[8]</sup>的路面病害自动识别算法研究已成为一种主流趋势。使用全卷积神经网络进行路面裂缝自动分割<sup>[9]</sup>是经常用于裂缝分割的算法,其关键的跳跃融合操作是取得较好分割效果的基础,但对于形状纤细的目标,容易遗漏目标信息;为使得特征提取更加精确,张玉雪等通过融入视觉注意机制<sup>[10]</sup>促使模型进行裂缝目标识别时投入更多的注意力资源,但与此同时可能将部分与裂缝特征相似的噪声(标线边缘,修补块边缘)放大;Zhang等提出了ADA3D裂缝识别算法<sup>[11]</sup>,该算法更重视准确率,在一定程度上牺牲了召回率水平;阳恩慧等通过使用三维光影模型对路面裂缝进行识别<sup>[12]</sup>,此算法平衡了召回率和准确率,但其需要三维的图像数据,适用范围受局限。上述学者前期的研究为路面裂缝自动识别领域提供了清晰的研究思路,但同时也存在容易受路面噪声干扰、识别速度慢及适用范围小的缺陷。因此,如何批量、精准和快速地实现路面裂缝自动识别依旧是难题。

U-net模型<sup>[13]</sup>在医学上常用于医疗细胞图像分割,其关键的特征融合操作显著提升了图像分割精度。裂缝的轮廓与血管形似,因此,本文基于改进的U-net模型对路面裂缝进行自动识别,该模型通过卷积与反卷积等一系列运算自动学习裂缝的特征信息。

## 1 数据准备

### 1.1 采集设备

研究采用数字化公路数据采集车(Digital highway data vehicle, DHDV),进行路面图像数据的采集。DHDV集成了线扫激光、3D工业相机、光电编码器,以及惯导系统,数据采集在保持精度可达1 mm的情况下,速度可达30 km/h<sup>[14-15]</sup>。其中DHDV中的3D工业相机可以同时生成深度图(三维图像)及灰度图(二维图像),并且完全匹配,如图1所示,本文使用的数据为二维激光图像。DHDV外观如图2所示。

### 1.2 采集路段

研究所用数据的采集起点为福建省福州市闽侯县建平路,经纬度坐标为(119.182 451°, 26.060 926°),终点为桔园一路,经纬度为(119.243 158°, 26.048 827°),总长约为8.9 km。在该研究中,DHDV连续地在沥青路面上进行二维激光图像的采集,然后对获取的全部图像经过人工筛选,只保留存在裂缝的图像。最终从采集到的4 450幅图像中人工筛选出2 110张含有裂缝的图像。

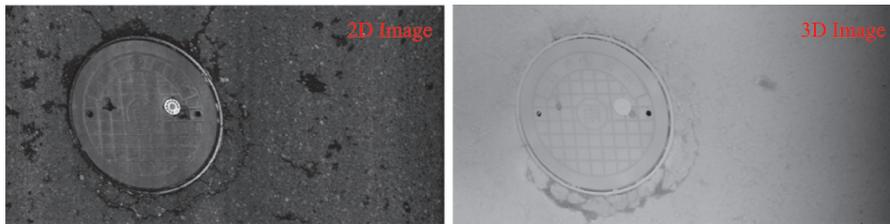


图1 DHDV采集的2D和3D图像

Fig.1 2D and 3D images collected by DHDV

### 1.3 训练库构建

裂缝形状纤细且不规则,采用多边形标注工具不能准确地表达出裂缝的特征,因此笔者研发一款半自动的像素级标注软件,主要用于裂缝图像的标注。首先利用自适应 Canny 边缘检测或 Otsu 阈值分割算法对框选的目标区域进行自动识别,再结合人为干预的手段对识别结果进行除噪和填充。自适应 Canny 边缘检测主要用于轮廓检测,当裂缝形状纤细时使用 Canny 边缘检测得到裂缝轮廓之间的空隙不大,再使用 OpenCV 中的“闭运算”先对图像进行膨胀再腐蚀,以填充前景物体中的空隙;当裂缝宽度较大时,“闭运算”的填充效果并不好,而 Otsu 阈值分割算法对于双峰图像(直方图中存在两个峰)有可观的分割效果,在框选的区域中,宽度大的裂缝更符合双峰图像标准。综上,当裂缝形状纤细时使用 Canny 边缘检测来获取标签图像,反之使用 Otsu 阈值分割算法。具体的操作流程如图 3 所示。



图2 数字化公路数据采集车

Fig.2 Digital highway data vehicle(DH-DV)

图4展示了使用半自动像素级标注软件标注的结果,基于该软件标注的裂缝轮廓清晰明显,形状纤细。其中图4上方两张图片代表采集的两张原始图像,下方的两张图片代表自动标注的结果。

训练样本数量以及特征多样性对于神经网络模型的训练效果至关重要,样本数量不够或类别不平衡可能导致模型出现欠拟合现象。但目前在网上还没有公开的裂缝数据集,因此可以利用卷积神经网络具有平移、缩放、旋转不变性的特点,通过人工筛选得到 2 000 张训练图像,并利用弹性变形技术(旋转、镜像、裁剪和缩放)对原始图像及其对应的标签图像进行数据增强,从而扩充训练数据集。同时为确保新生成的数据样本图像尺寸大小不发生变化,对图像边界外的点使用最近点的像素值进行填充,图5展示了部分经过弹性变形技术增强后的图像。为测试模型的性能,研究将 DHDV 采集的 110 张未参与

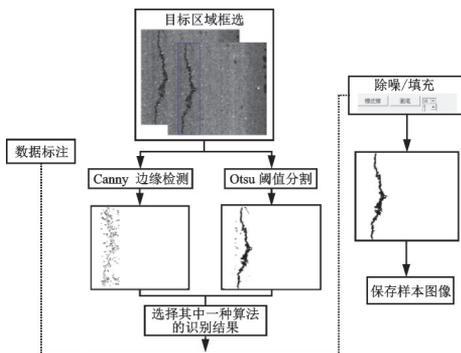


图3 数据标定流程图

Fig.3 Flowchart of imagine data labeling

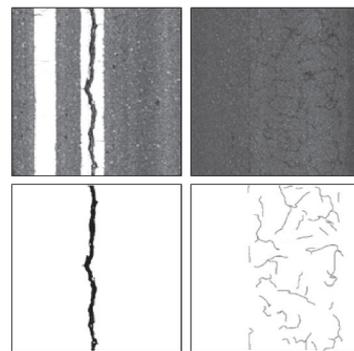


图4 训练样本标注结果

Fig.4 Labeling results of training samples

到训练过程的图像以及500张由福建省高速公路达通检测有限公司提供的图像(武大卓越RTM检测车采集图像)作为测试数据集,部分测试图像如图6所示。最终训练数据集,测试数据集图片数量分别为6 000幅和610幅。

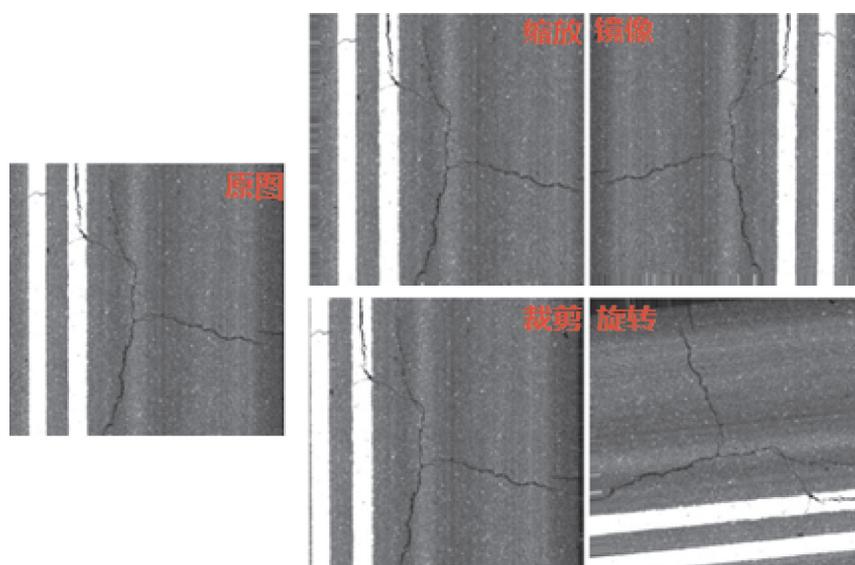


图5 路面裂缝图像数据集扩增样本

Fig.5 Samples of generated images

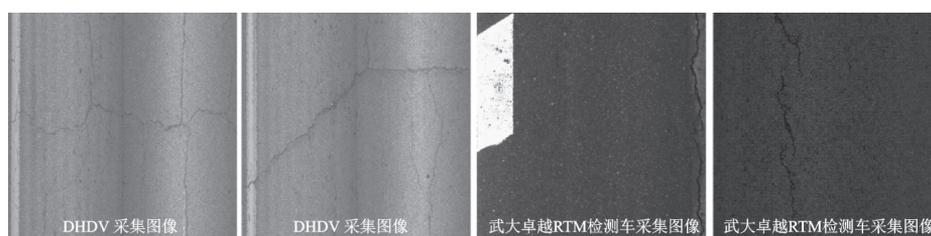


图6 测试数据集图像样本

Fig.6 Sample of test image

## 2 模型结构

### 2.1 U-net 基本模型

U-net模型是由Olaf Ronneberger在全卷积网络(Fully convolutional networks, FCNs)<sup>[16]</sup>基础上进行优化得到的,其在医疗细胞图像分割领域应用极其广泛。U-net与FCN算法都没有使用全连接层,取而代之的是卷积层,相比于全连接层,卷积层能够实现权重稀疏与权值共享,大大减少神经网络模型的参数量,进而提升模型训练的速度。之所以选择U-net是因为它比FCN等其他分割模型更具泛化能力;并且它没有使用预训练的分类模型,网络比较简单,这就使得模型训练以及识别时间可大幅缩减,更加适用于二分类的图像分割;同时在计算机条件允许下它可以接受任意大小的图像作为输入;更重要的是,U-net在进行浅层特征融合时不是加权求和而是进行叠加,这样就避免在进行卷积等一系列运算时丢失太多的目标特征信息,进而得到更加精确的分割效果。

### 2.2 U-net 模型调整

U-net是一个包含下采样和上采样的网络结构,在下采样阶段,经过不同程度的卷积,学习了深层次的裂缝特征;然后再经过上采样,使用反卷积结合下采样各层的信息以还原细节信息,逐步还原图像精度,经过一系列计算操作,最终输出的图像只包含背景和裂缝信息。为提高模型的泛化能力以及对裂缝特征的提取更加精确,本文对 U-net 架构进行调整。首先模型在训练过程中不再对图像进行裁剪,即保持输出与输入图像尺寸一致;其次在模型上采样阶段,每一次反卷积操作结束后不再是直接与其对应拥有相同特征映射维度的卷积层进行叠加,而是先进行一次卷积运算,再进行特征融合(图7中的特征融合操作),以提高识别准确率并降低漏检误检率;最后输出层的卷积运算使用 Sigmoid 激活函数,其他的卷积运算则使用修正线性单元(ReLU)进行非线性变换操作, Sigmoid 函数收敛速度虽比 ReLU 慢,但其能够将最终计算结果输出的置信度限制在[0, 1]范围内,方便利用概率去区分目标与背景,同时也可以获取信息的重要程度,因此更加适用于图像的二分类。ReLU 和 Sigmoid 函数计算公式分别如下

$$f(z) = \max(0, z) = \begin{cases} z & z > 0 \\ 0 & z \leq 0 \end{cases} \quad (1)$$

$$f(z) = \frac{1}{1 + e^{-z}} \quad (2)$$

最后对 Sigmoid 输出的置信度进行判断,若大于 0.5 则归于真实裂缝信息,若小于 0.5 归类噪声与背景信息,并将此步骤加入到训练过程中以便模型能够自动过滤明显噪声,进而学习到更加抽象的特征。调整后的 U-net 架构如图 7 所示。

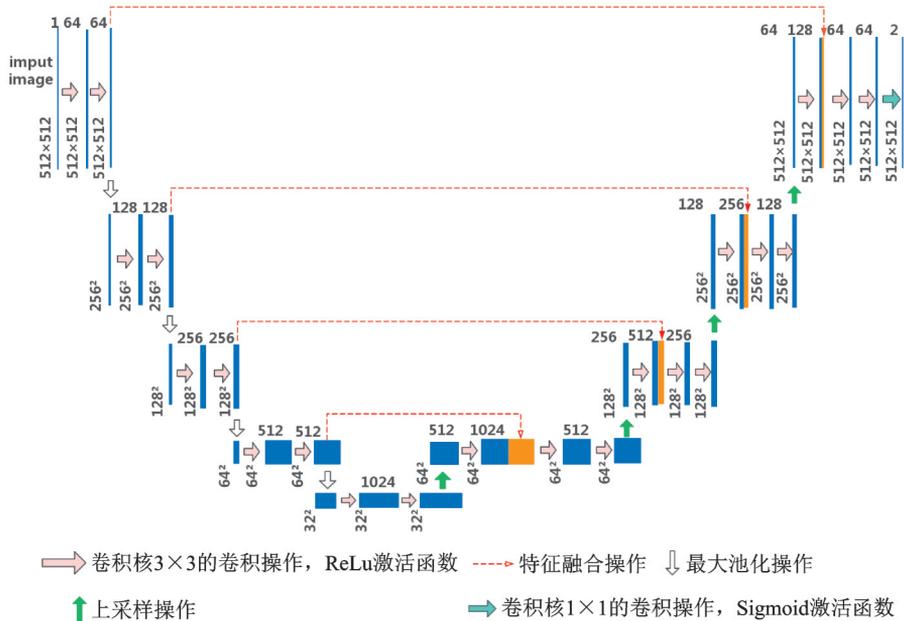


图7 改进后的 U-net 架构  
Fig.7 Structure of the improved U-net model

### 3 实验分析与结果

#### 3.1 实验设计

本研究是基于Python的代码调试及测试实验环境。其模型训练所采用的服务器为CPU: Intel i7-7700 @ 3.60 GHz, RAM: 16 GB; GPU: Nvidia GeForce RTX 2080ti, 12 GB。

在卷积运算过程采用全零的填充方式用以避免丢失图像的边界信息,训练过程使用神经网络模型应用广泛的交叉熵损失函数计算损失值(Loss)以描述模型在训练过程中预测结果与真实标签的误差值大小,计算公式如式(3)所示。学习率决定了参数每次更新的幅度,如果幅度过大,可能导致参数在极优值的两侧来回移动,如果过小可能导致收敛速度过慢。因此研究采用Adam算法优化U-net模型,Adam优化器既拥有Momentum算法解决优化过程中参数摆动幅度过大的功能,又具备RMSProp算法使得模型收敛速度更快的能力,是两者的结合。在训练过程中,Adam优化器根据反向传播算法在每一轮迭代时更新参数以减小Loss。由于裂缝纤细的轮廓特征,故在本研究中设置Adam算法的初始学习率为 $10^{-6}$ ,求一阶矩估计(期望)时的指数衰减率 $\beta_1 = 0.9$ ,求二阶矩估计(平方值的期望)时的指数衰减率为 $\beta_2 = 0.999$ 。Loss越小表明识别结果与真实值偏差越小,若Loss值较大或变化明显,则需微调参数(初始学习率、迭代轮数以及网络深度等)。Loss值随迭代轮数增加的变化趋势如图8所示,经反复调参得出当迭代轮数为150时Loss为0.024并且趋于稳定,此时模型性能达到最佳。

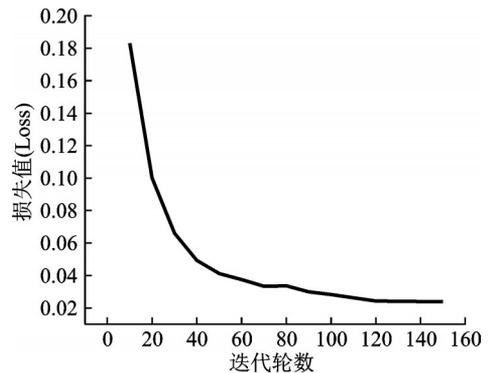


图8 损失值收敛变化趋势  
Fig.8 Trend of loss value

$$H(p, q) = - \sum p(x) \log q(x) \quad (3)$$

式中: $p(x)$ 表示输入 $x$ 点标签的真实值经过Sigmoid激活函数后的输出结果; $q(x)$ 表示 $x$ 点的预测值经过Sigmoid激活函数后的输出结果; $H(p, q)$ 表示交叉熵,即损失值。

#### 3.2 识别结果对比

当迭代150轮后,损失值与准确率均不再发生明显的变化,此时模型性能达到最佳,停止训练。U-net模型在进行识别时可能会出现漏检(如图9(a)中椭圆所示)和误检(如图9(b)中矩形框所示)。漏检情况经常出现在细小的裂缝区域,造成漏检的主要原因是由于U-net在下采样过程中可能会遗漏掉纤细的裂缝信息;出现误检的主要原因是模型将一些与裂缝具有高度相似性的目标错误地识别为裂缝像素。例如,修补块或标线的边缘信息。

导致漏检或误检现象发生的主要原因有两点:(1)模型对裂缝特征的提取不够精确,(2)训练样本量不足。针对此情况,研究首先应用数据增强技术扩充数据集,然后对比使用扩充数据集前后训练的模型在测试数据集(610张图像)上的准确率 $P$ (Precision)、召回率 $R$ (Recall)及 $F$ 值( $F$ -measure), $F$ 值越高表明识别效果越好<sup>[17-18]</sup>,具体的计算公式分别如式(4)~(6)所示。观察表1可知,采用原始数据集训练U-net模型,由于样本数量不足可能导致模型出现欠拟合现象,其直接表现就是 $P, R$ 和 $F$ 值较低。而当使用扩充后的数据集训练模型时,所得各项指标均高于前者,并且不会出现欠拟合或过拟合现象。由此可知,足量以及丰富的样本对于模型识别效果起着至关重要的作用,这也证明研究采用数据增强技术扩充数据集是十分必要的。

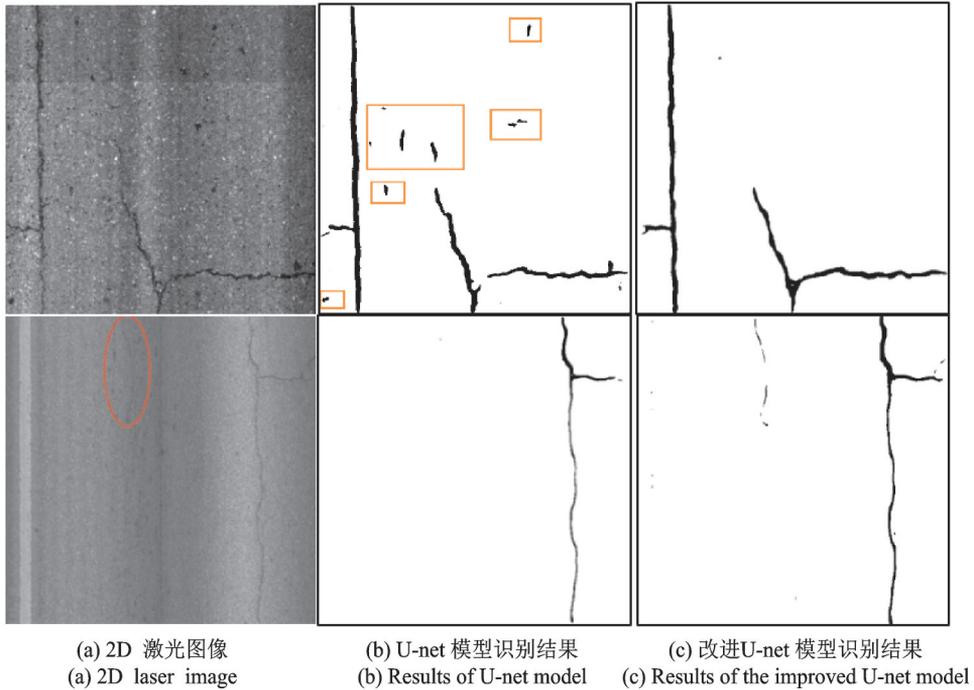


图9 原始及改进U-net模型裂缝识别结果对比

Fig.9 Cracks identification based on the original and the improved U-net models

然后对 U-net 模型结构进行调整。在模型的上采样阶段,首先是对输入的特征图进行反卷积,再结合下采样阶段对应的信息进行特征融合,从而还原细节信息。本文在模型上采样阶段,每次反卷积操作结束之后增加一层卷积层,再进行特征融合,这使得模型能够提取更深层次的特征,同时剔除明显的噪声信息。从图 9(c)中可看出经调整后的 U-net 虽然不能完全解决漏检和误检问题,但在一定程度上提高了模型的性能,特别是对于误检现象。

表1 数据集扩增前后裂缝识别结果评价指标对比  
Table 1 Results of cracking identification based on original dataset and expended dataset

训练样本的 数量/幅	原始数据集/ 扩充数据集	准确率/ %	召回率/ %	F 值/%
2 000	原始数据集	72.5	68.9	70.65
6 000	扩充数据集	90.83	89.97	90.40

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \quad (4)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \quad (5)$$

$$F = \frac{2PR}{P + R} \quad (6)$$

式中: $N_{TP}$ 代表被正确识别出来的裂缝区域像素的数量; $N_{FP}$ 代表被误判为裂缝像素的数量; $N_{FN}$ 代表属于裂缝像素,但未被识别出来的像素的数量。

为评估模型的泛化能力,研究将测试数据集分为3类:(1)DHDV与武大卓越RTM检测车采集的图像融合,用“Ⅰ”表示;(2)单独由DHDV采集的110幅图像组成,用“Ⅱ”表示;(3)用“Ⅲ”代表武大卓越RTM检测车采集的500幅裂缝图像。测试数据集融合了武大卓越RTM检测车采集的2D激光图像

之后,能更好地检测模型的泛化能力。使用扩充训练数据集训练的模型在这3类测试数据集上的性能表现如表2所示。从表2可看出改进后的U-net模型在这3类数据集上表现的性能均优于FCN模型,其 $P, R$ 及 $F$ 值波动值都低于3%,同时,U-net对每张图像的平均识别时间为132 ms,远远快于FCN的2 000 ms。由此可见U-net模型具有较快的识别速度以及较高的鲁棒性。

表2 原始U-net模型及改进U-net模型裂缝识别结果评价指标对比

Table 2 Results of cracking identification based on the original and the improved U-net models

模型-测试数据集	准确率/%	召回率/%	$F$ 值/%	平均识别时间/ ms
改进后的U-net-I	89.82	88.72	89.82	132
改进后的U-net-II	90.83	89.97	90.40	132
改进后的U-net-III	88.20	88.65	88.42	132
FCN-I	58.00	48.10	52.59	2 000
FCN-II	65.09	49.41	55.34	2 000
FCN-III	47.65	46.34	46.99	2 000

图10展示了FCN及改进的U-net模型对DHDV和武大卓越RTM检测车采集图像的识别效果。在裂缝连续且缝宽大的时候(图10第1行),两个模型都能够识别出裂缝轮廓信息;然而当裂缝形状纤细且分布零散时(图10第2行),改进的U-net模型依旧能够精确地识别出裂缝信息,而FCN模型识别效果较差。实验结果表明改进的U-net模型具有较高的泛化能力。

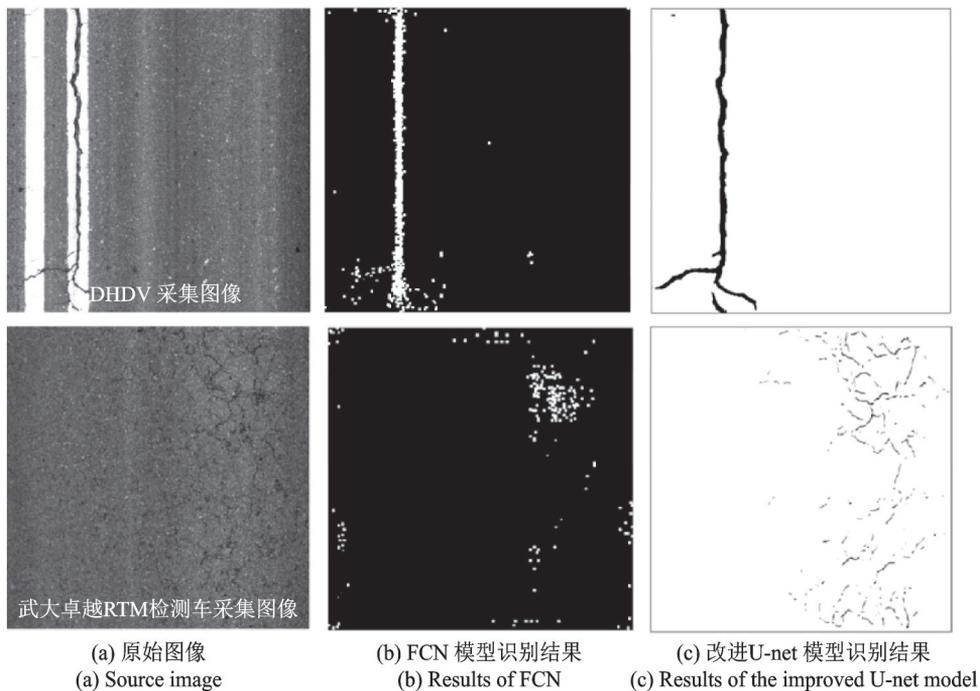


图10 FCN模型与改进后U-net模型裂缝识别结果对比

Fig.10 Results of cracking identification based on FCN model and the improved U-net model

## 4 结束语

研究以 DHDV 采集的二维激光图像为训练数据集基础结合数据增强技术进行数据库扩充,通过调整 U-net 模型架构和参数微调进而实现对路面裂缝精准的自动识别。

(1)U-net 不同于其他的分割模型,它没有全连接层和预训练的分类模型,这使得模型更加简化,收敛速度更快;特征融合操作对于精准识别形状纤细的裂缝是非常有效的一步。

(2)经验证,通过对 U-net 模型架构进行调整,裂缝的识别精度整体上优于 FCN 算法,在融合 DHDV 以及达通检测公司采集图像的测试数据集上, $F$  值为 89.92%,同时在计算机条件下接受任何尺寸图像批量输入,并且每张图像的平均识别时间仅为 132 ms。这可大大提升公路养护部门,特别是高速公路检测作业的工作效率。

(3)改进后的 U-net 模型对于复杂背景条件下的路面裂缝识别精度高,并且在第“Ⅲ”类(武大卓越 RTM 检测车采集的图像)测试数据集上的  $F$  值为 88.42%。由此可见,改进后的 U-net 模型泛化能力强。

(4)大量和多样性的训练样本对于 U-net 神经网络的训练是至关重要的,虽然研究利用数据增强技术进行数据集扩充在一定程度上解决了此问题,但如果能够获取更多真实数据或者以更智能的算法来解决问题,漏检、误检问题将会更好地得到解决,模型性能也将大大提升。因此,下一步的研究工作是如何解决数据样本不足问题,例如使用生成对抗网络模型(Generative adversarial networks, GAN)以图生图,进而提高模型性能。

### 参考文献:

- [1] WANG K C P, HOU Z Q, GONG W G. Automated road sign inventory system based on stereo vision and tracking[J]. *Computer Aided Civil and Infrastructure Engineering*, 2010, 25(6): 68-477.
- [2] WANG K C P. Elements of automated survey of pavements and a 3D methodology[J]. *Journal of Modern Transportation*, 2011, 19(1): 51-57.
- [3] 彭博,蔡晓禹,李少博.基于三维虚拟路面的裂缝自动检测算法[J].*重庆交通大学学报(自然科学版)*,2018(1): 46-53.  
PENG Bo, CAI Xiaoyu, LI Shaobo. Automatic crack detection algorithm based on 3D virtual pavement[J]. *Journal of Chongqing Jiaotong University(Natural Science)*, 2018(1): 46-53.
- [4] OTSU N. A threshold selection method from gray-level histograms[J]. *IEEE Transactions on Systems, Man and Cybernetics*, 1979, 9(1): 2-66.
- [5] PREWITT M S J. Object enhancement and extraction[J]. *Picture Processing & Psychopictorics*, 1970, 15(3): 75-149.
- [6] CANNY J. A computational approach to edge detection[J]. *Pattern Analysis and Machine Intelligence*, 1986, 8(6): 679-681.
- [7] LI Lin, WANG K C P. Bounding box-based technique for pavement crack classification and measurement using 1 mm 3D laser data[J]. *Journal of Computing in Civil Engineering*, 2016, 30(5): 136-142.
- [8] 金玉,宋彦,戴礼荣.基于卷积神经网络的语种识别系统[J].*数据采集与处理*,2019,34(2):322-330.  
JIN Ma, SONG Yan, DAI Lirong. Language identification based on convolutional neural network[J]. *Journal of Data Acquisition and Processing*, 2019, 34(2): 322-330.
- [9] 李丽.复杂背景下的路面裂缝检测算法研究[D].西安:陕西师范大学,2018.  
LI Li. Research on pavement crack detection algorithm in complex background[D]. Xi'an: Shanxi Normal University, 2018.
- [10] 张玉雪,唐振民,钱彬.融入视觉注意机制的路面裂缝检测与识别[J].*计算机工程*,2018,44(4): 287-293.  
ZHANG Yuxue, TANG Zhenmin, QIAN Bin. Pavement crack detection and recognition fusing with visual attention mechanism [J]. *Computer Engineering*, 2018, 44(4): 287-293.

- [11] ZHANG A, WANG K C P. Automated pixel-level pavement crack detection on 3D asphalt surfaces using a deep learning network[J].Computer Aided Civil and Infrastructure Engineering, 2017, 32(10): 805-819.
- [12] 阳恩慧,张傲南,丁世海.基于三维光影模型的公路路面裂缝自动识别算法[J].西南交通大学学报, 2017, 52(2): 288-294.  
YANG Enhui, ZHANG Aonan, DING Shihai. Automatic detection method for highway pavement cracking based on the 3D shadow modeling[J].Journal of Southwest Jiaotong University, 2017, 52(2): 288-294.
- [13] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[J].Medical Image Computing and Computer-Assisted Intervention, PTIII, 2015, 9351: 241-241.
- [14] LUO Wenting, WANG K C P, LI Lin. Surface drainage evaluation for rigid pavements using IMU and 1mm 3D texture data[J]. Transportation Research Record: Journal of the Transportation Research Board, Pavement Management, 2014, 3(4): 121-128.
- [15] LUO Wenting, WANG K C P, LI Lin. Hydroplaning on sloping pavements based on inertial measurement unit(IMU) and 1 mm 3D laser imaging data[J].Periodica Polytechnica Transportation Engineering, 2016, 44(1): 42-49.
- [16] EVAN S, TREVOR D. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [17] DAVIS J, GOADRICH M. The relationship between precision recall and ROC curves [C]//Proceeding of the 23rd International Conference on Machine Learning. Pittsburgh:ACM, 2006: 233-240.
- [18] FAWCETT T. An introduction to ROC analysis[J]. Pattern Recognition Letters, 2006, 27(8): 861-874.

## 作者简介:



陈泽斌(1996-),男,硕士研究生,研究方向:路面病害自动化检测、图像处理等,  
E-mail: 947743057@qq.com。



罗文婷(1983-),女,讲师,研究方向:路面病害智能检测、道路基础设施全息感知, E-mail: luowenting531@gmail.com。



李林(1984-),男,讲师,研究方向:高精三维激光传感器的研发,道路、隧道、机场跑道病害检测, E-mail: 18805915371@163.com。

(编辑:夏道家)