

Crack Detection of Concrete Bridges Based on Improved U-Net Model

Zhen Huang¹, Xingtuo Zhang^{1,2,*}, Kaizhong Xie¹, Xiaojun Ke¹, Yiyi Zhang^{1,2,*}

¹Key Laboratory of Disaster Prevention and Structural Safety of Ministry of Education, Guangxi University, Nanning, China

²Guangxi Key Laboratory of Disaster Prevention and Engineering Safety, Guangxi University, Nanning, China

Email address:

593673987@qq.com (Zhen Huang), xingtuo.zhang@st.gxu.edu.cn (Xingtuo Zhang), xiekaizhong@163.com (Kaizhong Xie), xj-ke@163.com (Xiaojun Ke), yiyizhang@gxu.edu.cn (Yiyi Zhang)

*Corresponding author

To cite this article:

Zhen Huang, Xingtuo Zhang, Kaizhong Xie, Xiaojun Ke, Yiyi Zhang. Crack Detection of Concrete Bridges Based on Improved U-Net Model. *Science Discovery*. Vol. 10, No. 6, 2022, pp. 500-505. doi: 10.11648/j.sd.20221006.29

Received: November 2, 2022; Accepted: November 29, 2022; Published: December 8, 2022

Abstract: Bridge is an important part of traffic infrastructure, and its maintenance is related to smooth traffic and even the safety of people's lives and property. Automatic detection of concrete bridge cracks is an important part of bridge maintenance. However, it is still a challenging task due to the inhomogeneous strength of concrete bridge cracks, the complexity of the background, and the weakness of the target. Currently, traditional image processing-based technology cannot detect bridge cracks well, and the typical deep learning model is not very effective when directly used to detect bridge cracks. In response to this problem, this paper proposes a bridge crack detection model based on the improved U-Net deep learning model. Compared with the original U-Net model, the convolution block of our improved model is wider in the encoding stage, and the wider convolution block enables the model to learn more semantically discriminative information. Finally, the performance of the improved model is validated on a dataset with 600 images. Experimental results show that compared with other advanced detection models, the proposed method achieves better performance in terms of average intersection ratio and pixel accuracy. Therefore, the method proposed in this paper can detect concrete bridge cracks automatically, which provides a certain reference value for bridge crack maintenance engineers based on image recognition technology.

Keywords: Deep Learning, Bridge Crack Detection, U-Net, Convolutional Neural Networks

基于改进U-Net网络的混凝土桥梁裂缝检测

黄震¹, 张兴妥^{1,2,*}, 谢开仲¹, 柯晓军¹, 张懿议^{1,2,*}

¹广西大学工程防灾与结构安全教育重点实验室, 南宁, 中国

²广西大学防灾减灾与工程安全广西重点实验室, 南宁, 中国

邮箱

593673987@qq.com (黄震), xingtuo.zhang@st.gxu.edu.cn (张兴妥), xiekaizhong@163.com (谢开仲), xj-ke@163.com (柯晓军), yiyizhang@gxu.edu.cn (张懿议)

摘要: 桥梁是交通基础设施中的重要组成部分, 其维修保养关系着交通畅通甚至人民生命财产的安全。自动检测混凝土桥梁裂缝是桥梁养护中的重要一环。然而, 由于混凝土桥梁裂缝的强度不均匀性、背景的复杂性以及目标的弱小性, 它仍然是一项具有挑战性的任务。目前, 基于传统的图像处理技术不能很好地对桥梁裂缝进行检测, 而典型的深度学习模型直接用于桥梁裂缝的检测时效果也不甚理想。针对此问题, 本文提出了一种基于改进U-Net深度学习模型的桥梁

裂缝检测模型。相比于原始的U-Net，我们的改进模型在编码阶段的卷积块更宽，更宽的卷积块使得模型有能力学习到更多的语义分辨信息。最后，在具有600张图像的数据集中验证了改进模型的性能。实验结果表明，与其他先进的检测模型相比，提出的方法在均交并比以及像素准确率等指标下取得了更好的性能。因此，本文提出的方法可以较好地对混凝土桥梁裂缝进行自动检测，为基于图像识别技术的桥梁裂缝维护工程技术人员提供了一定的参考价值。

关键词：深度学习，桥梁裂缝检测，U-Net，卷积神经网络

1. 引言

随着城市化建设的发展越发迅速，道路桥梁的建设俨然成为城市建设与社会经济中不可或缺的重要组成部分，不仅为交通运输提供方便，而且促进了经济的发展桥梁在日常生活中发挥着重要作用。定期的桥梁检查对于保持桥梁的结构健康和可靠性非常重要[1]。混凝土结构应用于桥梁建造居多，因其材料来源广泛，造价相对较低，且具有高强度、耐久力大、可塑性强等特点，能够满足建筑工程

需求。但由于环境及自身收缩等因素，致使桥梁本身发生不同程度的病害，主要包括裂缝、钢筋腐蚀、混凝土中的气泡和孔隙、腐蚀以及地基的不均匀沉降等。中华人民共和国交通运输部印发的《公路桥涵养护规范》中规定对混凝土桥梁检查应包含以下几点：1)混凝土是否出现裂缝、表面风化、剥落等情况；2)预应力钢束锚固区段混凝土有无开裂，沿预应力筋的混凝土表面有无纵向裂缝；3)刚构的固结处，混凝土有无开裂、破损及钢筋腐蚀[2]。从该规范中可以看出，对混凝土桥梁裂缝的检查尤为重要。

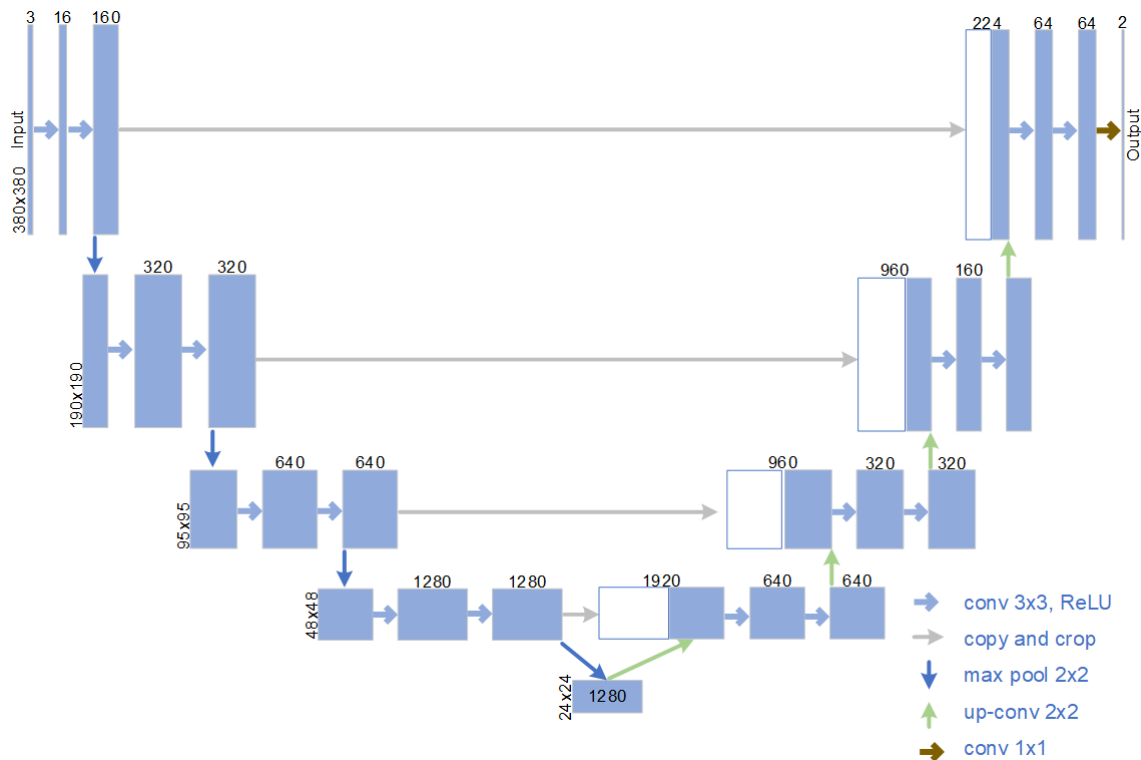


图1 提出的宽U-Net结构图。

桥梁裂缝是桥梁的主要损伤之一，其检测是桥梁养护的一项重要工作。传统的桥梁裂缝检测方法依赖于人工视觉检测，检测效率和准确性无法得到保证。近年来，机器学习和计算机视觉被应用于裂缝检测领域，并取得了良好的效果。密歇根大学的Qader为了克服利用人工来检测裂缝时效率低等问题[3]，对现有的几种图像检测方法进行了分析，包括傅里叶变换、几种边缘检测算子等，以实现裂缝自动化检测，实验结果表明基于傅里叶变换的方法相对可靠有效，但并没有体现出图像处理技术的优势所在[2]。普渡大学的研究学者开展了基于视觉的桥梁裂缝自动检测的研究[4]，通过自动处理和分析收集的图像，可以从图

像中识别钢结构螺栓附近的裂缝。该方法利用多种不同角度拍摄的图像和这类故障的典型外观和特征的相关知识，可以成功地检测出螺栓附近的裂纹，但有些实际环境比较复杂，得到的图像存在缺陷。Prasanna等人基于机器学习和特征组合的方法设计了多特征分类器[5]，并用来对桥梁裂缝进行检测。但是他们所提出的方法检测出的裂缝图像中依旧存在噪声，并且裂缝的基本结构也受到破坏失去了连贯性。曼尼托巴大学和麻省理工大学的教授共同提出了一种基于视觉的裂缝检测方法，来解决广泛变化的现实环境对图像处理技术带来的问题[6]。他们发现基于神经网络的算法比传统边缘检测算法的表现更好，且鲁棒性更强，

更加适用于复杂的实际应用环境。张维峰提出了一种基于数字图像处理的桥梁裂缝检测方法[7],以含有裂缝的桥墩及其他混凝土试件作为研究对象,在各种图像处理算法的基础之上,通过分析图像裂缝的几何特征,设计了一种桥梁缺陷检测分析模型。实验结果表明,基于图像处理技术进行裂缝检测切实有效,但较差质量的裂缝图像会带来结果误差。胡世坤基于数字图像处理技术提出了一种裂缝图像增强方法,通过引入引导滤波器进一步提升路面裂缝检测算法的性能[8]。针对传统分割算法的不足,他们又提出了基于最近邻的均值漂移提取算法,最后通过投影法与阈值判断方法来对横向裂缝、纵向裂缝等裂缝进行分类,但在去噪时无法完全滤除所有的非裂缝区域。

尽管目前有许多学者提出了很多方法来检测桥梁裂缝,但是经典的机器学习或者深度学习模型主要针对的是图像中包含大尺寸、整体目标的分类任务或者检测任务,比如AlexNet[9]、GoogLeNet[10]、Faster R-CNN[11]等。如果将这些模型直接用于如图2(a)、图3(a)所示的桥梁裂缝,由于它们是具有拓扑结构的线性目标,效果将不会理想,只能得到一个目标区域块,而得不到裂缝具体细节。而且,通常训练目标检测网络需要大量的数据。因此,本文提出了一种基于U-Net[12]图像分割技术的桥梁裂缝检测模型。U-Net最开始被科研人员开发出来分割医学细胞图像。该模型仅仅需要30张训练集,就能取得很好的泛化性能。考虑到自然场景中的图像的复杂纹理,我们在U-Net的基础上设计了一种宽U-Net模型。新的模型跟U-Net模型区别在于:1)我们的模型更宽而不是更深;2)实验结果表明宽的模型可以达到更好的精度并避免模型加深时的过拟合。

本文的其余部分安排如下。第1节给出模型的详细结构及其描述。第2节描述了数据集、模型实现系列、评估指标以及实验结果与讨论。最后,在第3节中给出了本文的结论部分。

2. 提出的Wide U-Net

本节描述提出的宽U-Net模型。受宽残差网络[13]在图像识别任务中取得的成功的启发,我们提出了用于混凝土桥梁裂缝检测的Wide U-Net模型。Wide U-Net结构源自U-Net[12],其中所有卷积层替换为更宽的卷积层。图1显示了Wide U-Net的详细架构。Wide U-Net由两条路径组成,即收缩路径和扩展路径,它们都包含相同数量的卷积块。在收缩路径中,每两个卷积块使用下采样操作将图像大小减半。这有利于加快训练速度,降低计算复杂度。同时,下采样有利于提升感受野,感受野的提升有利于本文要解决的密集预测任务。

为了预测输入图像中每个像素的标签,使用转置卷积操作将扩展路径中的特征逐渐上采样至其原始大小,该操作在每两个宽卷积块之后执行。Wide U-Net架构还允许将局部信息和全局特征结合起来,这对于锐化边缘特征是有意义的,这可以使得裂缝的最终分割更加精确。这是通过在收缩和扩展路径中连接一些卷积块的输出来完成的,如图1所示。

图1还展示了收缩路径中的第2个宽卷积块的输出与扩展路径中的第3个卷积块的输出连接。此外,收缩路径

中的第4个残差块的输出和扩展路径中的第一个卷积块的输出也被连接起来。这种结构可以使得收缩路径中的卷积输入包含低层次卷积块提取到的细节信息。由于混凝土桥梁裂缝检测问题(裂缝与背景)的互斥属性,在扩展路径的最后一个卷积块后附加一个1*1的卷积层来降低扩展路径输出的维度。最后,利用Softmax分类器获得给定输入的所有像素点的类别概率,即可得到最终的裂缝检测结果。

给定训练集 $T = \{x^{(\alpha)}, y_{i,j}^{(\alpha)}\}$, 对于第 α 张输入, 如果 $y_{i,j}^{(\alpha)} = 1$, 则该输入的 (i, j) 处像素的标签表示裂缝, 也即正样本。反之, 该像素点的标签是背景, 也即是负样本。假定 $z_{i,j}^{(\alpha)}$ 表示网络最后一层卷积层在 (i, j) 处的输出特征, 那么输入 $x^{(\alpha)}$ 在通过网络前向运算后在 (i, j) 处属于第 c 类别的概率为:

$$p(\hat{y}_{i,j}^{(\alpha)} = c | z_{i,j}^{(\alpha)}) = \frac{e^{z_{i,j}^{(\alpha)} c}}{\sum_{k=1}^K e^{z_{i,j}^{(\alpha)} k}} \quad (1)$$

且, 其相应的代价函数为:

$$J = -\frac{1}{H \times W} \left[\sum_{i=1}^H \sum_{j=1}^W 1\{y_{i,j}^{(\alpha)} = c\} \log \frac{e^{z_{i,j}^{(\alpha)} c}}{\sum_{k=1}^K e^{z_{i,j}^{(\alpha)} k}} \right] \quad (2)$$

在本文中, $K=2$, $1\{\}$ 是一个指示函数, 表示如果在 (i, j) 处其标签为 c , 那么取值为1。

3. 实验评估与讨论

本节介绍数据集, 训练细节, 评估准则以及实验结果与讨论。

3.1. 数据集

本文使用的数据集包含600张图像, 提供自论文[14]。数据集中图像大小为224*224。我们将数据集划分为训练集, 验证集与测试集。其中, 训练集占比80%, 测试集占比20%。而验证集是在训练集中再划分出12.5%。

3.2. 实现细节

实验平台是一台具有3.70-GHz中央处理器、32G内存和Windows 10操作系统的工作站。我们使用PyTorch[15]框架实现所有的网络模型, 并使用单张图形显卡(NVIDIA GeForce RTX 3060)对其进行加速训练。

表1 不同模型的性能比较。

| 模型 | PA | mIoU | 类别IoU | |
|--------------|-------|-------|-------|-------|
| | | | 背景 | 裂缝 |
| Unet [12] | 0.981 | 0.839 | 0.980 | 0.699 |
| FCN [17] | 0.979 | 0.830 | 0.978 | 0.682 |
| DeepLab [16] | 0.982 | 0.839 | 0.981 | 0.698 |
| PSPNet [18] | 0.970 | 0.735 | 0.969 | 0.501 |
| Ours | 0.982 | 0.847 | 0.982 | 0.713 |

在对深度学习网络进行训练的过程中, 学习率lr是优化时非常重要的一个因素。通常情况下, 在训练过程中学

习率都是要动态调整的，且是会逐渐衰减的。我们给每个网络设定最大训练世代epoch为200，然后使用Poly动态调整学习率的策略[16]：

$$\text{lr} = \text{base_lr} \times \left(1 - \frac{\text{epoch}}{\text{num_epoch}} \right)^{\text{power}} \quad (3)$$

其中，num_epoch表示当前迭代的世代量。base_lr设置为0.1，power设置为0.9。训练过程中使用随机梯度下降(SGD) 优化器，动量为0.9，权重衰减为0.0005。

3.3. 评估准则

本文采用以下两种最常见的关于分割网络的评估准则来评估所有网络模型的性能。

a) mean Intersection over Union (mIoU)，即“均交并比”。mIoU表示类别的真实标签和预测值的交集和并集的比值：

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

其中， i 表示真实值， j 表示预测值， p_{ij} 表示将 i 预测为 j 的像素个数。因此，分子即为交集，分母即为并集。

b) Pixel Accuracy (PA)，即像素准确率。PA表示预测正确的像素占总像素的比例：

$$\text{PA} = \frac{\sum_{i=0}^k p_{ii}}{\sum_{i=0}^k \sum_{j=0}^k p_{ij}} \quad (5)$$

3.4. 实验结果

我们所提出的方法在实验上与目前先进的分割模型进行了比较，其中包括 U-Net、FCN、DeepLab 和 PSPNet。表1展示了我们的方法与其他一些先进的模型对比实验结果。可以从表中看到，我们所提出的方法总体上明显优于其他四种先进方法。特别在于mIoU这项指标上，我们的方法以84.7%的得分取得较大的优势，比U-Net高出了0.8个百分点，由此证实了此方法的有效性。对于PA这项指标，我们的方法也仍然在所有网络中占据着一定优势。除此之外，表1显示所提出方法在class IoU这项指标下，其背景以及裂缝的IoU值分别以98.2%、71.3%取得了最高得分，这表明我们的方法相较于其他方法在分割性能上的优越性，特别是在这种目标裂缝与背景比例高度不平衡的像素数量的情况下。

图2和图3展示了利用所有方法检测混凝土桥梁裂缝的案例结果。图2是所有方法在横向裂缝情形下的检测结果，图3是所有方法对分叉裂缝的检测结果。图2(b)是对应于图2(a)的真实标签。图2(c)、(d)、(e)是为自然场景分割所开发的模型，可以发现这些方法在桥梁裂缝检测场景下并不占优势，这是因为相比于复杂的自然场景图像，本文处理的特定场景下的图像类别含量少但是却存在类别极不平衡的情况。因此为检测自然场景图像开发的模型应用在特定领域时会出现过拟合，最终泛化结果不佳。而U-Net和我们的模型较DeepLab、FCN以及PSPNet而言表现出了较好的性能。我们的方法比U-Net每个卷积块具有更宽，从图2(f)、(g)以及图3(f)、(g)的对比中可以发现更宽的网络表现出了更好的性能但却没有出现过拟合的现象。对于带分叉裂缝的检测而言，我们的模型很好地检测出了全部裂缝，这对于后续计算裂缝宽度以及长度是有用的，而其他方法出现了断裂的情况，将造成后续处理结果不准确。

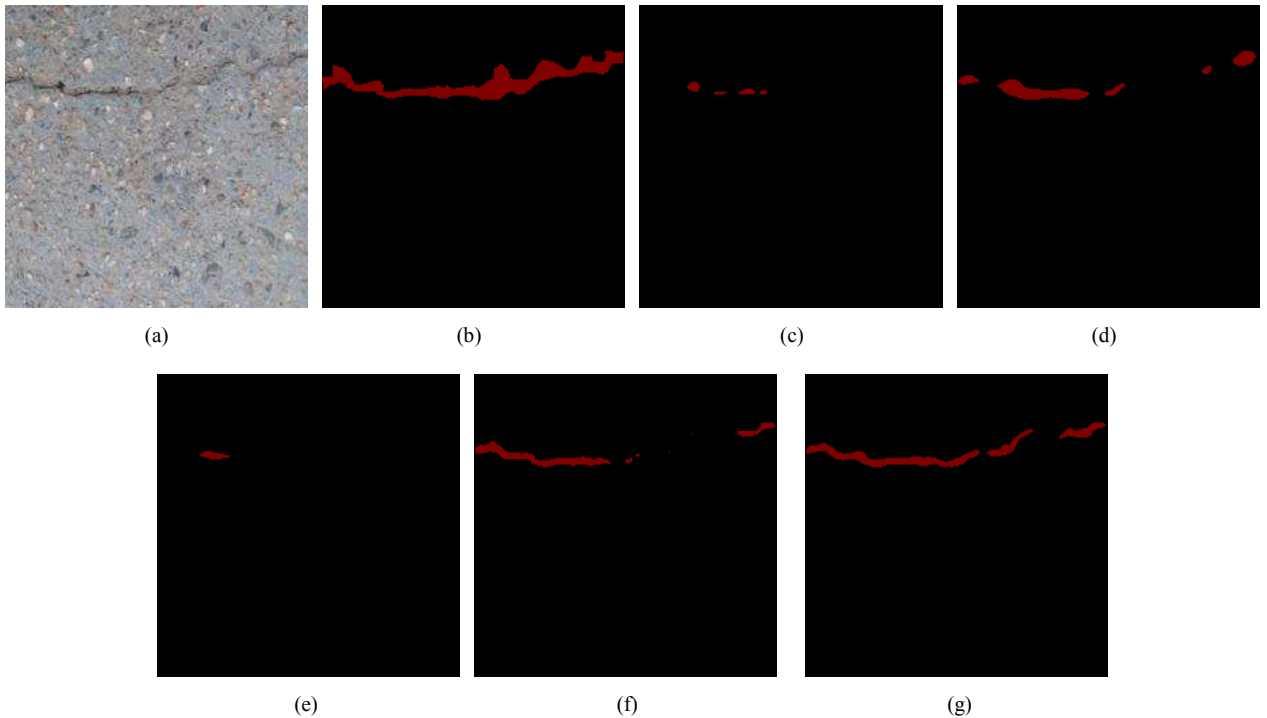


图2 混凝土桥梁横向裂缝检测结果。(a)输入图像；(b)真值标签；(c)DeepLab；(d)FCN；(e)PSPNet；(f)U-Net；(g)提出的模型。

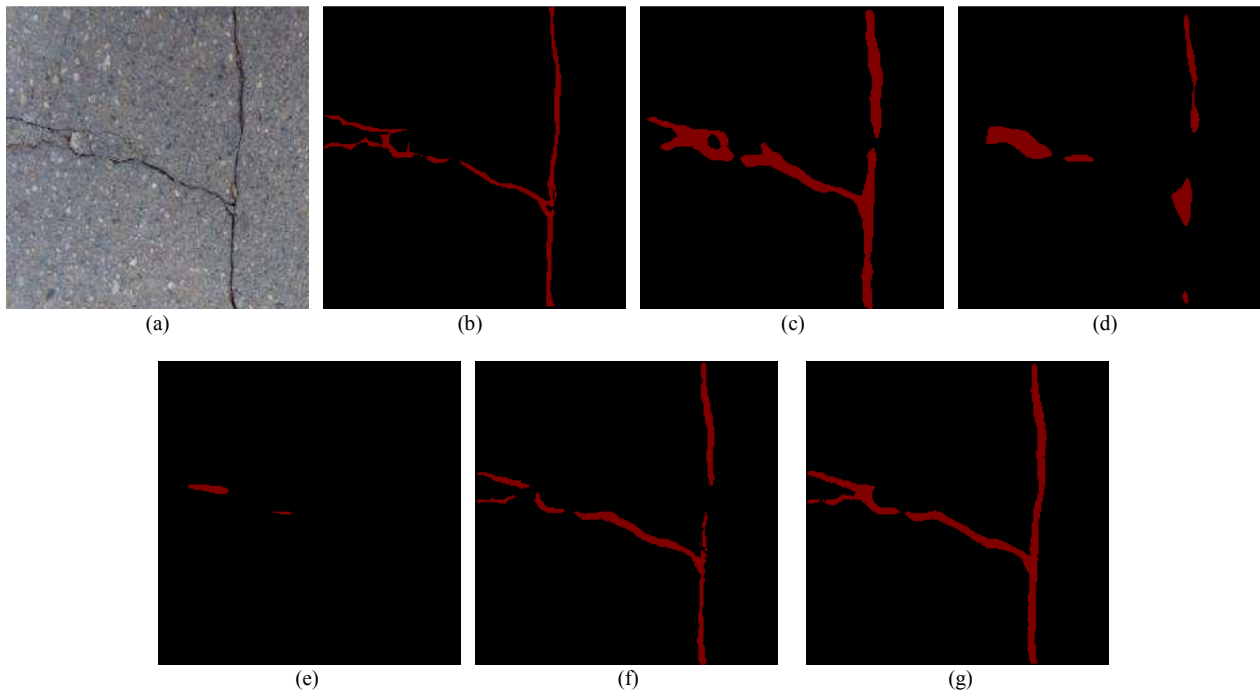


图3 混凝土桥梁分叉裂缝检测结果。(a)输入图像；(b)真值标签；(c)Deeplab；(d)FCN；(e)PSPNet；(f)U-Net；(g)提出的模型。

4. 结论

本文提出了一种基于深度学习的桥梁裂缝自动检测算法。为了提升裂缝检测的准确性，我们设计的模型在编码器阶段具有更宽的卷积块，更宽的卷积块可以学习到更多的语义识别信息。实验结果表明，和其他裂缝检测算法相比，本文提出的算法具有更好的检测效果和更强的泛化能力。

致谢

本文为广西大学学科交叉科研项目（合同编号：2022JCB008）阶段性成果之一。

参考文献

- [1] ZHANG Lei, YANG Fan, ZHANG Daniel-Yimin, et al. Road Crack Detection Using Deep Convolutional Neural Network [C]//Proceedings of IEEE International Conference on Image Processing. Phoenix, AZ, USA: IEEE, 2016: 3708-3712.
- [2] JTG 5120-2021, 公路桥涵养护规范 [S].
- [3] ABDEL-QADER Ikhlas, PASHAIE-RAD Sara, ABUDAYYEH Osama, et al. PCA-based Algorithm for Unsupervised Bridge Crack Detection [J]. Advances in Engineering Software, 2006, 37 (12): 771-778.
- [4] YEUM Chul-Min, DYKE Shirley J. Vision-based Automated Crack Detection for Bridge Inspection [J]. Computer-Aided Civil and Infrastructure Engineering, 2015, 30 (10): 759-770.
- [5] PRASANNA Prateek, DANA Kristin-J., GUCUNSKI Nenad, et al. Automated Crack Detection on Concrete Bridges [J]. IEEE Transactions on Automation Science and Engineering, 2014, 13 (2): 591-599.
- [6] CHA Young-Jin, CHOI Wooram, BUYUKOZTURK Oral. Deep Learning-based Crack Damage Detection Using Convolutional Neural Networks [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32 (5): 361-378.
- [7] 张维峰,刘萌,杨明慧.基于数字图像处理的桥梁裂缝检测技术[J].现代交通技术, 2008, 5 (5): 34-36.
- [8] 胡世昆. 基于数字图像处理技术的路面裂缝检测算法研究 [D]. 南京:南京邮电大学, 2012.
- [9] KRIZHEVSKY Alex, SUTSKEVER Ilya, HINTON Geoffrey E. ImageNet Classification with Deep Convolutional Neural Networks [J]. Communications of the ACM, 2012, 60 (6): 84-90.
- [10] SZEGEDY Christian, LIU Wei, JIA Yang-qing, et al. Going Deeper with Convolutions [C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Boston, MA, USA: IEEE, 2015: 1-9.
- [11] REN Shao-qing, HE Kai-ming, GIRSHICK Ross, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39 (6): 1137-1149.
- [12] RONNEBERGER Olaf, FISCHER Phillip, BROX Thomas. U-Net: Convolutional Networks for Biomedical Image Segmentation [C]//NAVAB N, HORNEGGER J, WELLS W M, et al. Lecture Notes in Computer Science: Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015. Cham: Springer, 2015: 234-241.

- [13] ZAGORUYKO Sergey, KOMODAKIS Nikos. Wide Residual Networks [C]//Proceedings of the British Machine Vision Conference. York: BMVA Press, 2016: 87.1-87.12.
- [14] 李良福, 马卫飞, 李丽, 等. 基于深度学习的桥梁裂缝检测算法研究. 自动化学报, 2019, 45 (9): 1727-1742.
- [15] PASZKE Adam, GROSS Sam, MASSA Francisco, et al. PyTorch: An Imperative Style, High-Performance Deep Learning Library [C]//Proceedings of the 33rd International Conference on Neural Information Processing Systems. NY, USA: Red Hook, 2019: 8026-8037.
- [16] CHEN Liang-Chieh, PAPANDREOU George, KOKKINOS Iasonas, et al. DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40 (4): 834-848.
- [17] LONG Jonathan, SHELHAMER Evan, DARRELL Trevor. Fully Convolutional Networks for Semantic Segmentation [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Boston, USA: IEEE, 2015: 3431-3440.
- [18] ZHAO Heng-shuang, SHI Jian-ping, QI Xiao-juan, et al. Pyramid Scene Parsing Network [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017: 6230-6239.