

文章编号:

基于改进 Unet 模型的混凝土裂缝分割研究

潘远^{1,2}, 周双喜^{2*}, 杨丹²

(1. 华东交通大学交通运输学院, 江西 南昌, 330013; 2. 华东交通大学土木建筑学院, 江西 南昌, 330013)

摘要: 针对桥梁、隧道等环境下产生的混凝土裂缝情况复杂、干扰因素多的问题, 提出一种改进 Unet 模型 (A-Unet) 的裂缝检测方法。以 Unet 网络为基础, 研究了编码器的深度如何影响模型训练时间、检测精度。其次, 在解码过程中设计一种融合空间和通道注意力模块, 将高分辨率的浅层特征与上采样获得的深层特征信息赋予不同权重, 进一步增强裂缝特征。同时, 增加 dice 损失函数对模型进行评价, 减少因检测目标与背景数量相差较大, 导致评价不准确的问题。提出方法在测试数据集中进行评价, 精确度、MIou、召回率分别达到 94.70%、86.16%、91.34%。A-Unet 模型检测效果明显优于其他 5 种模型。结果表明: 利用该方法检测混凝土裂缝精度得到较大提升, 且节约了模型训练时间, 提高检测效率。

关键词: 混凝土裂缝; 深度学习; 注意力机制; 裂缝识别; 语义分割

中图分类号: TU528

文献标志码: A

本文引用格式:

Research on concrete crack segmentation based on improved Unet model

PAN Yuan^{1,2}, ZHOU Shuang-xi², Yang Dan²

(1. School of Transportation Engineering; East China Jiaotong University, Nanchang 330013, China; 2. School of Civil Engineering and Architecture, East China Jiaotong University, Nanchang 330013, China; 3. Guangdong Tobacco Jieyang City Co., Ltd, Jieyang, 522000)

Abstract: A crack detection method based on improved Unet model (A-Unet) is proposed to solve the problems of complex concrete cracks and many interference factors in bridges, tunnels and other environments. Firstly, Unet-based network, how the deep of the encoder affects the training time and detection accuracy of the model is studied. Secondly, in the decoder process, a fusion space and channel attention module is designed to give different weights to the high-resolution shallow features and the deep feature information obtained from the up-sampling to further enhance the crack features. At the same time, the dice loss function is added to evaluate the model to reduce the problem of inaccurate evaluation caused by the large difference between the number of detected objects and the background. The proposed method was evaluated in the test data set, the Precision, MIou and Recall rate reached 94.70%, 86.16% and 91.34% respectively. Also, the detection effect of A-Unet model is significantly better than the other five models. The results show that the accuracy of concrete crack detection by this method is greatly improved, and the model training time is saved, and the detection efficiency is improved.

Key words: concrete crack; deep learning; attention mechanism; crack identification; segmentation

Citation format:

混凝土裂缝在任何建筑结构中出现都可能导致重大安全事故。因此,对混凝土裂缝进行有效的检测具有重要意义。传统的裂缝检测方法主要是人工检测,该方法存在耗时长、精度低且对专业技术人员的要求较高,对于建筑结构大、时间紧的工程难以满足需求。为了寻找更有效的裂缝识别方法,早期一些学者们提出了图像处理的检测方法,主要有直方图[1]、边缘算法[2]、阈值分割[3]、小波变换[4]。这些方法通过对裂缝图像处理获取裂缝的位置、宽度,不仅可以降低对专业技术人员的专业要求,而且可以提高检测效率。然而,这些方法仍存在不足,对裂缝环境复杂地区的识别度仍然不够。

人工智能的迅速发展为混凝土裂缝的自动识别提供新方向。其中,基于卷积神经网络的深度学习在裂缝识别领域中得到广泛应用[5-9]。如大坝裂缝检测[10-11]、桥梁裂缝检测[12-13]、隧道裂缝检测[14-15]、路面裂缝检测[16]等。Unet 作为优秀的网络模型被广泛关注,它是一种 Encode-Decode 结构的网络,Unet 模型中的编码器可以结合实际应用选择不同的网络。编码器可从混凝土数据中提取主干特征,它类似于卷积神经网络。因而,拥有良好的编码器可以较大提升裂缝识别精度。通常将经典卷积网络作为 Unet 模型的编码器如:VGG[17]、Mobilenet[18]、ResNet[19]等网络。丁[20]等构建了基于深度学习与无人机的混凝土裂缝检测方法,进行多尺度特征融合对多种裂缝分割,分割误差小于 5%。周[21]等通过改进 Mask R-CNN 模型对钢纤维混凝土裂缝进行检测,进行迁移学习,提升了裂缝检测精度。Wang[22]等提出一种 I-UNet 的道路裂缝网络模型,采用空洞卷积来扩大感受野,实验表明 I-UNet 网络模型比 U-Net 网络模型的鲁棒性更强。Shi[23]等利用 VGG-Unet 模型采用分别对压缩分割和裁剪分割

后的图像进行缺陷检测,对于大尺寸的缺陷裁剪分割效果较好,对于小尺寸的缺陷效果欠佳。Gao[24]等构建 UNet-MSAM 网络模型,通过添加多尺度特征融合对图像进行裂缝检测,比不添加多尺度特征的检测精度效果好。Yang[25]等在 Unet 模型中的编码器采用 ResNet 残差网络进行特征提取,利用残差网络作为编码器的 Unet 模型检测效果有所提升。用于完成其他任务的优秀模型不能完全适用于复杂环境下的裂缝检测。优秀模型的结构深度及参数量可能导致裂缝识别性能的不足或冗余。因此,根据检查任务来选择合适的网络深度是一个挑战。

本文以经典 Unet 网络模型为基础,提出一种改进的 Unet 网络模型, A-Unet(Advances Unet)。通过编码器的选择和添加注意力机制两方面的优化,提高裂缝特征的识别能力,在有效抑制干扰的同时提高裂缝识别的精度和效率。

1 研究方法

基础Unet网络模型最早用于细胞检测,该网络可能并不完全适用于裂缝检测。因此,为了选择具有高检测精度和速度的最佳模型,提出适用于混凝土裂缝检测的Unet网络模型。A-Unet框架通过添加残差模块及模型深度、解码器中添加注意力模块两部分改进。A-Unet网络应用于混凝土裂缝识别的流程如图1所示。研究方法分为3部分:

- (1) 对裂缝图像数据进行预处理主要包括:数据获取、数据裁剪、数据直方图均衡化及人工标记数据;
- (2) 获取A-Unet模型参数,主要包括:训练数据集进行迁移学习[26],获取混凝土目标参数,验证数据集对目标参数进行微调;
- (3) 利用训练得到的目标参数进行混凝土图像语义分割,并对模型进行评价。

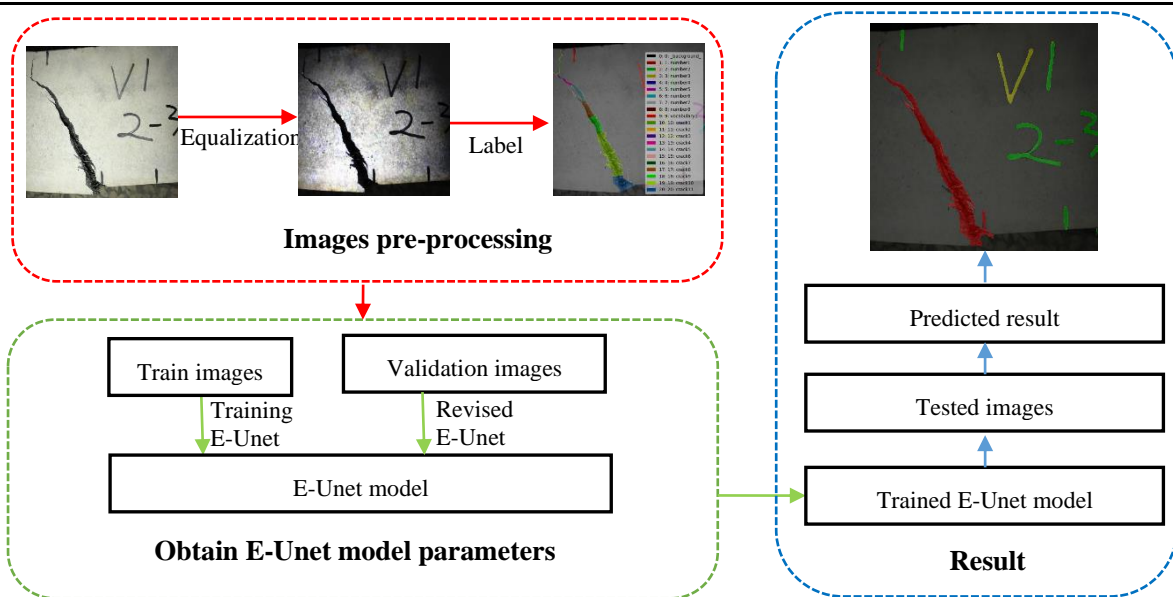


图 1 A-Unet 网络在混凝土裂缝识别中的流程

Fig. 1 Flowchart of A-Unet network in concrete crack recognition

1.1 A-Unet 网络结构

Unet 网络通过编码器-解码器实现裂缝识别端到端的语义分割, 编码器主要通过卷积实现特征提取, 该编码器提取特征信息不全且易造成过拟合现象, 导致目标分割不准确。将浅层特征与解码过程提取的深层特征直接进行叠加, 该操作的缺陷在于进行叠加的两个特征层置于同等地位, 导致目标分割精度低、边缘模糊。针对 Unet 存在的不足, 将残差模块引入编码器中, 并在解码过程中对浅层特征添加注意力模块, 得到 A-Unet 网络(图 2)。A-Unet 是一个 U 型网络, 从左到右依次分为编码过程、跳跃连接、解码过程三部分。编码过程从上到下共有 5 个阶段, 每个阶段由卷积网络、残差模块、批归一化层、Relu 激活函数及大小为 2×2 的最大池化层组成。解码过程共有 5 各阶段, 每个阶段包含 2 个 3×3 的卷积网络、1 次叠层、注意力模块。该注意力模块融合通道(Channel)和空间(Spatial)两维度的注意力模块, 融合注意力机制(简称 CS)较大程度上降低了各种干扰因素, 提高裂缝特征在模型中的权重。如图 3 所示, 首先, 在编码器中提取的 5 个裂缝特征层中分别添加通道注意力, 提高与裂缝特征相关的通道权重, 降低与裂缝特征无关的通道权重。下一次模型训练时, 将更多的关注权重大的通道, 进一步提取深层次裂缝特征。同时,

在 5 个裂缝特征层中分别添加空间注意力, 提高与裂缝特征相关的空间位置权重, 降低与裂缝特征无关的空间权重, 进一步提取深层次裂缝特征。最后, 将通道注意力获取的裂缝特征与空间注意力获取的裂缝特征融合, 获取多方位的特征。

(1) 通道注意力。假设浅层裂缝特征图为 F , 对 F 进行全局平均池化, 同时进行格式转化维度为 $1 \times 1 \times C$ 的特征图 P (其中 C 为通道数)。之后进行两次全连接, 一次 Sigmoid 函数将特征范围锁定在 0-1 之间, 即每个通道的权值大小。最后, 将获得的权值大小乘以特征图 F , 生成特征图 M 实现对浅层特征图添加通道注意力机制。

(2) 空间注意力。首先在特征图 F 上每个特征点所在通道中分别取出最大值和平均值, 生成最大值特征图和平均值特征图。其次, 将这两个特征图进行叠加之后进行一次通道数为 1 的卷积, 使用一次 Sigmoid 函数。最后, 将获得的权值大小乘以特征图 F , 生成特征图 N 实现对浅层特征图添加空间注意力机制。

(3) 叠加。将特征图 M 和特征图 N 进行叠加, 生成特征图 Q 。特征图 Q 具有通道和空间两部分的权重分布, 因此获得了多方位的特征, 能更好的侧重目标区域, 忽略各种干扰。

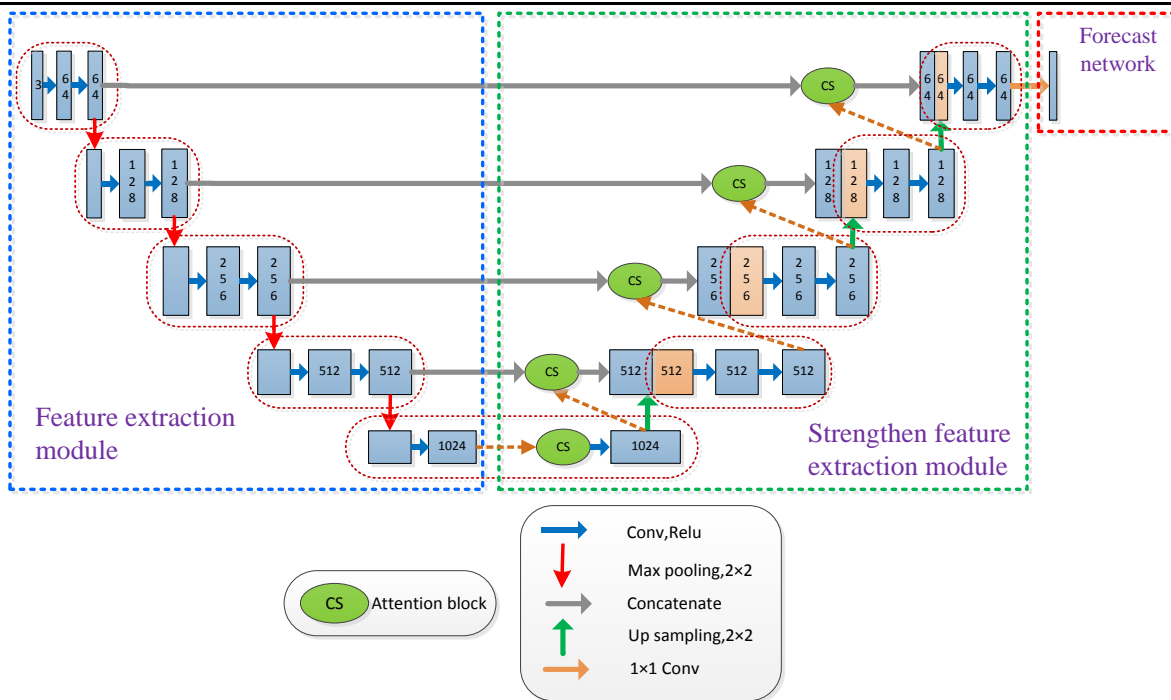


图 2 A-Unet 模型结构

Fig.2 A-unet model structure




图 3 融合注意力模块 (CS)

Fig.3 Fusing the attention module

2 结果与讨论

2.1 数据集制作

钢筋混凝土常年裸露于室外，钢筋混凝土裂缝环境复杂，通常伴随着其他缺陷，如腐蚀、锈蚀等影响。因此，本文自制钢纤维混凝土试块并在裂缝周围模拟 2 种缺陷，一种缺陷为数字 (number)、另一种缺陷为单词 (vocabulary)。首先，制作混凝土试块。试验原材料分别为：P·O42.5 普通水泥、5-20mm 碎石、中砂、减水剂、平直型镀铜钢纤维等。将制作好的混凝土试块加载不同大小、方向的荷载，从而获取不同大小、方向的

裂缝。有些裂缝细且长，有些裂缝宽度较大但形状及裂缝边缘更粗糙。如图 4 所示，(a)为细长条状的混凝土试块，(b)为不规则裂缝的混凝土试块。其次，对获取的混凝土试块，进行图像裁剪。原始图像大部分为背景，在图像处理过程中不仅无作用且耗费大量模型训练时间，因此原始图像进行裁剪，图像大小剪裁为 $512 \times 512 \times 3$ 大小。本试验共制作 116 个大小为 $100 \text{ mm} \times 100 \text{ mm} \times 400 \text{ mm}$ 棱柱试块，基于迁移学习进行裂缝参数调整，因此，不需要大量训练图像。获取的 116 张图像，其中 90 图像数据作为训练及验证集，26 张图像作为测试集。




图 4 混凝土裂缝获取 (a) 细长条裂缝 (b) 不规则裂缝

Fig. 4 Concrete cracks obtained (a) Slender cracks (b) Irregular cracks

由于钢筋混凝土图像的整体亮度都偏暗，而且由于钢筋混凝土图像的整体亮度都偏暗，而直方图均衡化[27]可以扩展亮度从而调整对比度，对于目标和背景像素值相近的图像效果显著。因此，对图像数据输入网络模型前，先对图像进行直方图均衡

化凸显裂缝的局部特征。图 5 (e) 为经过直方图均衡化后的图像。由图可知，原始裂缝图像中的裂缝灰度值虽然比背景要暗很多，但是区别没有特别明显。而图 5 (e) 中预处理后图像中的裂缝与背景的差异增大，裂缝呈黑色，而背景仍然比较亮，说明预处理图像对裂缝识别有增强作用。同时，RGB 三个波段(图 5b-d、图 f-h)预处理后的灰度直方图都发生了变化，因此对其直方图进行均衡处理，可增强细节信息表达。最后，对增强后的数据使用 labelme 软件进行标签制作如图 6 所示其中(a)为原始图像、(b)为原始图像 R 波段直方图、(c)为原始图像 G 波段直方图、(d)为原始图像 B 波段直方图、(e)为预处理后图像、(f)为预处理后图像 R 波段直方图、(g)为预处理后图像 G 波段直方图、(h)为预处理后图像 B 波段直方图。




图 5 混凝土裂缝预处理直方图对比(a) 原始图像(b)、(c)、(d) 原始图像 RGB 直方图(e) 直方图均衡化后图像(f)、(g)、(h)直方图均衡化后 RGB 直方图

Fig.5 Contrast of histogram of Concrete Crack Pretreatment (a) Original image (b), (c), (d) RGB histogram of the original image (e) After histogram equalization Image (f), (g), (h) After histogram equalization RGB histogram



图 6 标签制作(a)原始图像(b)标签图像

Fig.6 Label (a) original image (b) label image

3.2 试验参数设置

本研究在同一台计算机上完成网络模型的训练、测试。计算机配置为：AMD 锐龙 73800X 处理器，NVIDIA GeForce RTX 2060 显卡。环境配置如下：Python3.6, CUDA10.1, Tensorflow2.2.0。在训练过程中，数据样本的 90% 进行训练，并将 90% 数据样本进行验证。采用 Voc 数据集在 Unet 模型中得到的训练权重作为训练权重，即迁移学习。为加快训练速度，初始训练时设置一个较大的学习率 0.0001，随着迭代次数的增加，损失函数趋于平稳后学习率改为 0.00001。优化器为 Adam, momentum 设置为 0.9。每个模型样本迭代 100 次，损失值趋于平稳。

3.3 精度评价指标

对于语义分割任务，交并比 (MIoU)、召回率 (Recall)、精确率 (Precision) 3 个指标来评价分割结果。交并比是指裂缝的真实像元数和预测像元数相交并的比值。召回率是指样本中裂缝的像元数有多少被预测出来。精确率是指预测为裂缝的像元占总裂缝像元的比值。TP(true positive)是指将目标检测为正确目标的像元数；FP(false positive)是指将背景检测为目标的像元数；FN(false negative)是指将目标检测为其他目标的像元数；TN(true positive)是指将背景预测为背景的像元数，计算公式见表 2。

表 2 精度评价公式

Tab.2 Accuracy evaluation formula

Evaluation indicators	Formula
MIoU	$MIoU = 2P/P \cup G$
Recall	$Recall = TP / (TP + FN)$
Precision	$Precision = TP / (TP + FP)$

3.4 试验结果

3.4.1 网络深度试验

编码器的深浅直接影响特征提取，对残差模块引入的数量进行讨论，在编码器中分别添加残差模块 Res36、Res48、Res99、Res138 进行对比，其中数字代表残差模块的个数。图 7 显示了 4 种不同深度网络模型的损失曲线。基于迁移学习的权重，在前几次迭代中损失值较大，为更好的显示整个损失曲线的趋势，去除前 10 次迭代的损失值。4 种网络模型的训练损失曲线经过几十个世代后都趋于平稳，损失值基本都趋近于 0，说明 4 种网络对混凝土裂缝训练都取得较好的效果(图 7)。Unet-Res36、Unet-Res138 损失值在迭代 50 次左右都出现不同层

度的波动，随后验证损失曲线又趋于平稳并接近 0。然而，Unet-Res36 和 Unet-Res48 验证曲线较为平稳且损失值一直处于较低水平，相比其他 2 种网络模型，Unet-Res36 和 Unet-Res48 网络模型的损失曲线表现更佳。

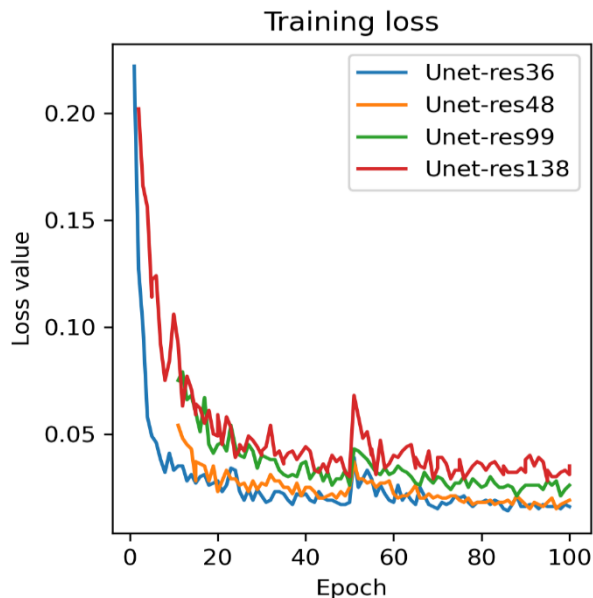


图 7 训练数据集的损失曲线

Fig. 7 the loss curve of the training data set

图 8 总结了 4 种深度网络模型精度指标。随着网络深度的增加，MIoU 值由 82.21% 首先增加到 84.29% 后略微下降到 83.53% 及 83.63%。Accuracy 值由 93.41% 先增加到 94.42% 后降低到 92.59%。Recall 值在 4 种网络模型中并没有明显变化，大致上呈现网络深度越深 Recall 值越大，在 Unet-Res138 时为最大值 89.19%。同时，通过对比 3 种精度评价指标可以发现，Unet-Res48 在 MIoU 和 Precision 这两个指标中的精度表现最佳，Recall 表现略逊于 Unet-Res138 网络，降低 0.49% (图 8a)。所有的网络模型都能较好的识别各类缺陷，Crack 识别精度最高达到 95%。对于所有缺陷，Unet-Res48 网络模型的识别精度都等于或优于其他 3 种网络模型 (图 8b)。总体而言，Unet-Res48 网络模型的综合表现最佳。综合考虑分析可知，网络模型对裂缝的识别并不是深度越深越好，而是在一定范围内取得最佳识别效果。

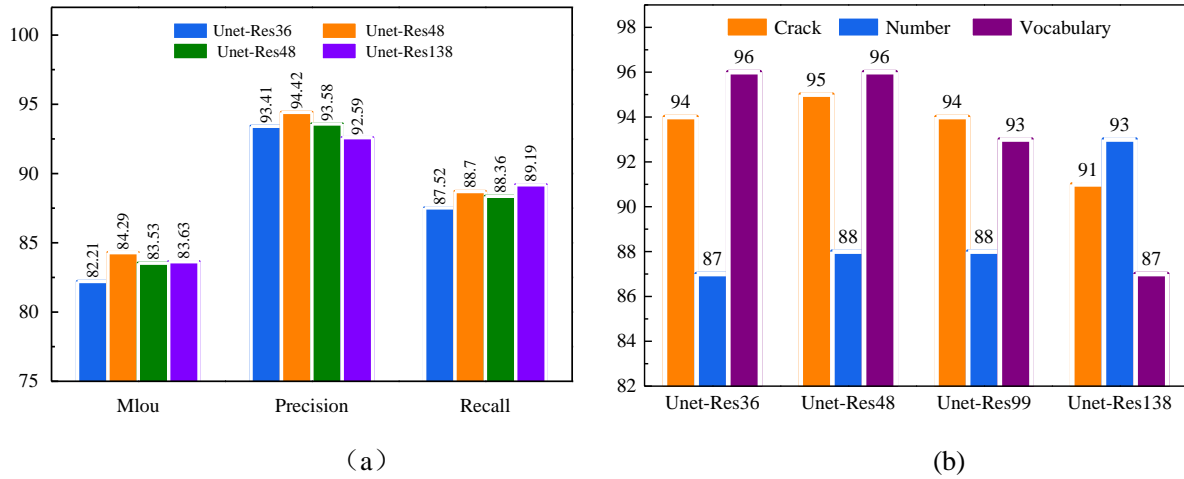


图 8 不同残差网络精度对比图(a)4 种网络深度的 3 种精度对比(b)4 种网络深度的 3 种类别精度对比

Fig. 8 Comparison of network accuracy of different residuals (a) Comparison of three accuracy levels for four network depths (b) Comparison of three classification accuracy levels for four network depths

Unet-Res36 由于残差网络较浅，在提取目标特征的能力不足，错检、漏检目标较多，如图 9 所示，其中 (a) 为原始图像，(b) 为 Unet-Res36，(c) 为 Unet-Res48，(d) 为 Unet-Res99，(e) 为 Unet-Res138。随着网络残差网络的加深 (图 9c、d)，Unet-Res48 及 Unet-Res99 模型提取目标特征的能力不断增强，目标检测的准确度得到较大改善。其中，微小裂缝在一定程度上也被精确识别。然而，进一步增加网络深度并未提高目标识别精度，相反检测精度下降，

出现漏检、错检的情况 (图 9e)。由图 8、9 我们可知，残差网络对混凝土裂缝的识别能力并不是层次越多识别效果越好。出现这种情况的原因可能是裂缝本身的图像特征较明显且与背景差异性较大，因此不需要过度提取裂缝特征。如果过于注重深层次裂缝特征提取，反而会导致特征不明显导致识别精度有所下降。通过试验分析可知，Res48、Res99 的网络深度最适合裂缝特征提取作为 Unet 网络的编码器。




图 9 不同残差网络深度对裂缝识别的效果图 (a) 为原始图像，(b) 为 Unet-Res36 (c) 为 Unet-Res48 (d) 为 Unet-Res99 (e) 为 Unet-Res138

Fig. 9 Effect diagram of crack recognition by different residual network depth. (a) original images (b) Unet-Res36 (c) Unet-Res48 (d) Unet-Res99 (e) Unet-Res138

3.4.2 注意力机制对比试验

选取最佳编码器后，在 Unet 网络上采样层分别添加 CS 注意力机制，取名为 A-Unet。由于编码器的深度不同，为便于区分在 A-Unet 末尾加上网络的层数，如 A-Unet48 代表编码器为 Res48 的网络。为更好的比较注意力模型对混凝土裂缝识别的影响，在 Unet-Res 模型基础上，对不同深度网络分别添加常用的通道注意力机制 eca 及空间注意力机制 cbam 进行对比试验，从而验证 CS 模块的有效性。

图 10 显示了添加不同注意力机制后各网络模型的精度图。添加了注意力模块的网络模型对目标的识别综合精度比未添加注意力模块的网络模型的综合精度普遍更高(图 10)。除了 Unet-Res99-eca、

Unet-Res138-cbam 网络模型的综合精度比 Unet-Res99、Unet-Res138 略低，说明添加注意力机制对目标识别有所助益。另外，所有添加了 CS 注意力模块的网络精度都相应的比未添加注意力模块或添加其他注意力模块的网络精度要高，表明结合通道和空间注意力机制能更好的提取目标物。通过对比网络模型可知 A-Unet99 的综合精度评价分值最高，说明 A-Unet99 对混凝土裂缝识别效果最佳。而 A-Unet48 的综合精度值排在第 2 位，综合精度略低于 A-Unet99，这与前述使用 Res48 残差网络作为编码器为最优有些冲突。可能的原因是添加注意力机制后，编码器能更好的将空间、通道之间的裂缝特征紧密联系在一起。因此，相应的增加网络深度可以适当提高识别精度。

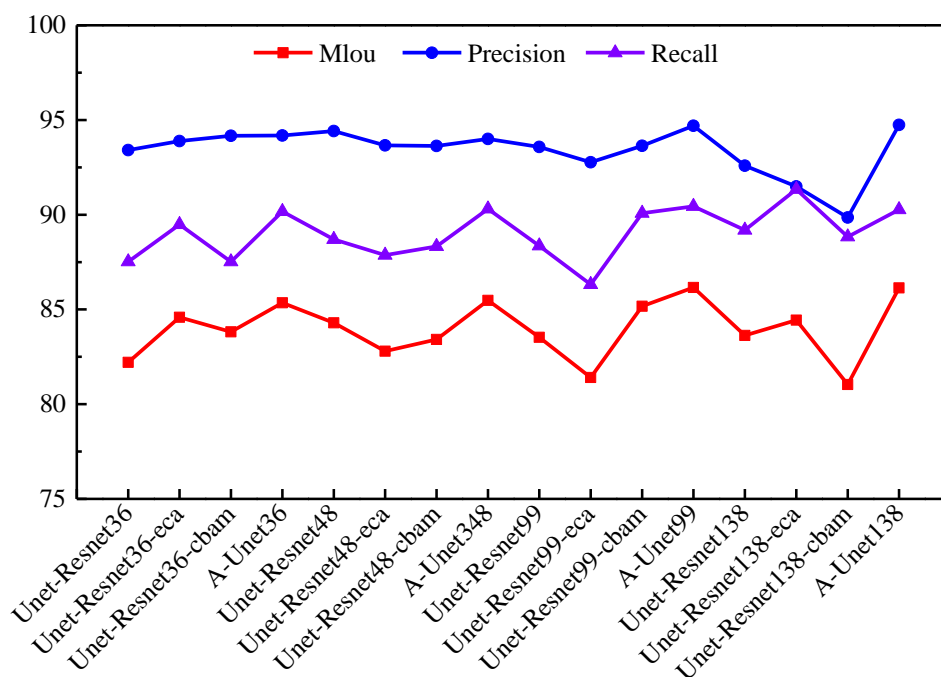


图 10 不同注意力机制网络模型的精度

Fig. 10 The precision of the network model of different attention mechanism

图 11 显示了以 Res99 为编码器，添加各注意力模块的预测结果。A-Unet99 具有较高的检测精度，误检、漏检的现象肉眼很难分辨出，其他网络存在多处误检、漏检现象。其中，Unet-Res99-cbam 表现

最差，只添加空间注意力模块不能提高检测精度，反而混淆了目标和背景，说明添加注意力模块时需要针对具体任务选择合适的注意力模块。




图 11 不同注意力机制网络模型的裂缝结果(a)原始图像(b)Unet-Res99(c) Unet-Res99-cbam (d) Unet-Res99-eca(e)A-Unet99

Fig. 11 Crack results of different attention mechanism network models (a) original images (b) Unet-Res99(c) Unet-Res99-cbam (d) Unet-Res99-eca (e)A-Unet99

3.4.3 A-Unet 网络模型对比试验

为更好的评估 A-Unet 网络模型,在保证环境配置与训练数据集不变时,分别采用 Unet-VGG16、Deeplabv3+、Mask-R-CNN、PSPnet、T-M-R-CNN^[20]5种语义分割模型与本文 A-Unet48、A-Unet99 模型进行对比。由表 4 可知, A-Unet48、A-Unet99 模型的精度比其他模型的精度高出许多, A-Unet99 的精度比 Deeplabv3+的精度高达 16.22%,比 T-M-R-CNN²⁰的精度高出 3.39%,说明 A-Unet 网络模型能更好的提取裂缝特征。

对比参数训练时间可知 Deeplabv3+、pspnet 训练时间最短,但它们的识别精度较低,其他网络训练时间都比 A-Unet 的参数训练时间要长。其中, T-M-R-CNN 识别精度为 91.31%,但是所需的训练时长为 896 分钟,训练时间紧较长。A-Unet48、A-Unet99 网络所需的训练时间仅为 331、357 分钟,在大大减少训练时长的情况下,识别精度最佳。试验说明, A-Unet 网络在效率及精确度两方面表现突出。

表 3 不同网络模型精度、训练时间对比

Tab.3 comparison of precision and training time of different network models

Methods	Precision/%	Recall/%	MIou/%	Training time(min)	Epoch
Mask-R-CNN	87.64	83.62	80.56	398	100
Unet-VGG16	92.62	86.53	81.30	403	100
T-M-R-CNN ²⁰	91.31	88.67	83.45	896	100
Deeplabv3+	78.48	46.58	42.77	15	150
PSPnet	74.27	42.54	38.19	105	150
A-Unet50	94.00	90.31	85.48	331	100
A-Unet101	94.70	90.44	86.16	357	100

4 结论

本文提出适合混凝土裂缝识别的 A-Unet 网络模型, 实现像素级裂缝识别。通过研究残差网络的深度对混凝土裂缝识别的影响。设计空间及通道多维连接的 CS 注意力机制模块, 有效增强目标特征提取。得出以下结论: 1. 随着编码器网络的加深, 模型的性能先得到一定的提升, 随后性能下降。2. 添加融合注意力模块的 A-Unet 模型总体性能得到提升, 最高精度达到 94.7%。3. 与其他方法相比, 用于训练模型的训练时间、迭代次数更少、检测精度更高。未来, 采用更多复杂环境下的裂缝图像进行训练, 包括不同的损伤类型进一步提高 A-Unet 性能。

参考文献:

- [1] Kirschke K R, Velinsky S A. Histogram-based approach for automated pavement-crack sensing [J]. Journal of Transportation Engineering, 1992.
- [2] Abdel-Qader I, Abudayyeh O, Kelly M E. Analysis of Edge-Detection Techniques for Crack Identification in Bridges[J]. Journal of Computing in Civil Engineering, 2003, 17(4):255-263.
- [3] Oliveira H, Correia P L. AUTOMATIC ROAD CRACK SEGMENTATION USING ENTROPY AND IMAGE DYNAMIC THRESHOLDING[C]// 2009 17th European Signal Processing Conference. IEEE, 2009.
- [4] Oliveira H, Correia P L. AUTOMATIC ROAD CRACK SEGMENTATION USING ENTROPY AND IMAGE DYNAMIC THRESHOLDING[C]// 2009 17th European Signal Processing Conference. IEEE, 2009.
- [5] Ellenberg, A, Kontsos, et al. Bridge related damage quantification using unmanned aerial vehicle imagery.[J]. Structural Control & Health Monitoring, 2016.
- [6] Qz A, Kb A, Skb B, et al. Real-Time Detection of Cracks on Concrete Bridge Decks Using Deep Learning in the Frequency Domain[J]. Engineering, 2020.
- [7] Gibb S, La H M, Louis S. A Genetic Algorithm for Convolutional Network Structure Optimization for Concrete Crack Detection[C]// 2018:1-8.
- [8] [1] Sharma M. Concrete Crack Detection using the integration of Convolutional Neural Network and Support Vector Machine. 2018.
- [9] 杨传礼, 张修庆. 基于机器视觉和深度学习的材料缺陷检测应用综述[J]. 材料导报, 2022, 36(16):226-234. (Yang Chuanli, Zhang Xiuqing. Material defect detection based on machine vision and deep learning[J]. Materials Report, 2022, 36(16): 226-234.)
- [10] 王泽娇, 张起睿, 方冬冬, 王新鹏. 基于深度学习的大坝裂缝检测方法研究[J]. 水利规划与设计, 2022(01):90-94. (Wang Zejiao, Zhang Qirui, Fang Dongdong, Xin Peng Wang. Study on dam crack detection method based on deep learning [J]. Water Planning and Design, 2022(01):90-94.)
- [11] Fan X N, Cao P F, Shi P F. An underwater dam crack image segmentation method based on multi-level adversarial transfer learning[J]. Neuro computing, 2022.
- [12] 谭国金, 欧吉, 艾永明, 杨润超. 基于改进 DeepLabv3+模型的桥梁裂缝图像分割方法[J/OL]. 吉林大学学报(工学版):1-7[2022-10-31]. (Tan Guojin, ou ji, Ai Yongming, Yang Runchao. Bridge crack image segmentation method based on improved DeepLabv3 + Model [J/OL]. Journal of Jilin University Science (engineering edition) 1-7[2022-10-31].)
- [13] Gang L A, Xi A, Jian Z B, et al. Pixel-level bridge crack detection using a deep fusion about recurrent residual convolution and context encoder network - ScienceDirect[J]. Measurement, 2021, 176.
- [14] Song Q, Wu Y, Xin X, et al. Real-time Tunnel Crack Analysis System via Deep Learning[J]. IEEE Access, 2019, PP(99):1-1.
- [15] Zhou Q, Qu Z, Li Y X. Tunnel Crack Detection With Linear Seam Based on Mixed Attention and Multiscale Feature Fusion[J]. in IEEE Transactions on Instrumentation and Measurement, 2022.
- [16] Hu G X, Hu B L, Yang Z, et al. Pavement Crack Detection Method Based on Deep Learning Models[J]. Wireless Communications and Mobile Computing, 2021, 2021(1):1-13.
- [17] Mateen M, Wen J, Nasrullah, et al. Fundus image classification using VGG-19 architecture with PCA and SVD[J]. Symmetry, 2018, 11(1).
- [18] Srinivasu P N, Sivasai J G, Ijaz M F, et al. Classification of Skin Disease Using Deep Learning Neural Networks with MobileNet V2 and LSTM[J]. Sensors, 2021, 21(8):2852.
- [19] Ds A, Rhp A, Ab A, et al. Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer[J]. Procedia Computer

- Science, 2021, 179:423-431.
- [20] 丁威,俞珂,舒江鹏.基于深度学习和无人机的混凝土结构裂缝检测方法[J].土木工程学报,2021,54(S1):1-12. (Ding Wei, Yu Ke, Shu Jiangpeng. Concrete structure crack detection method based on deep learning and UAV [J]. Journal of Civil Engineering, 2021,54 (S1): 1-12)
- [21]周双喜,袁海强,邓芳明.基于改进 Mask R-CNN 钢纤维混凝土裂缝检测模型[J].华东交通大报,2021,38(06):37-45.(Zhou Shuangxi, Yuan Haiqiang, Deng Fangming. Based on the improved Mask R-CNN steel fiber concrete crack detection model [J]. East China Jiaotong University News, 2021,38 (06): 37-45)
- [22] [1]Leipeng, Wang X H, Ma Y, et al. Computer vision-based Road Crack Detection Using an Improved I-UNet Convolutional Networks[C]// 第 32 届中国控制与决策会议. 2020.
- [23] Shi J, Dang, J,Cui, M. Improvement of Damage Segmentation Based on Pixel-Level Data Balance Using VGG-Unet. Appl. Sci. 2021, 11, 518.
- [24] Gao X, Jin B. Research on Crack Detection Based on Improved UNet.2020 7th International Conference on Information Science and Control Engineering (ICISCE), 2020,
- [25]Yang Y L, Zhao Z H, Su L L. Research on Pavement Crack Detection Algorithm based on Deep Residual Unet Neural Network [J] J. Phys.: Conf. Ser. 2022.
- [26] 张永志,辛全忠,王永亮,孔祥明,刘昉,杨再胜.基于迁移学习的钢金相组织分类与识别方法的研究[J].材料导报 ,2021,35(24):24152-24157. (Zhang Yongzhi, Xin Quanzhong, Wang Yongliang, Kong Xiangming, Liu Fang, Yang Zaisheng. Research on the classification and recognition method of steel metallographic structure based on transfer learning [J]. Materials Guide, 2021,35 (24): 24152-24157).
- [27]Tan X, Triggs B. Enhanced Local Texture Feature Sets for Face Recognition Under Difficult Lighting Conditions[C]// Amfg. IEEE, 2007:1635-1650.



第一作者: 潘远 (1987-), 女, 助理实验师, 博士研究生, 研究方向为混凝土材料与检测技术研究, 2009 年本科毕业于华东交通大学, 2012 年硕士毕业于辽宁工程技术大学。
E-mail: yuanpan227@126.com



通信作者: 周双喜 (1973-), 男, 教授, 博士, 硕士生/博士生导师, 南昌市 521 学术技术带头人, 研究方向为混凝土材料与检测技术研究, 1998 年本科毕业于济南大学, 2003 年硕士毕业于桂林理工大学, 2006 年博士毕业于中国建筑材料科学研究院。 E-mail : 18820358448@green.55@163.com