

# 基于改进 U-Net 网络的细小裂纹检测

封晓晨<sup>1</sup> 李 宁<sup>1,2</sup> 顾玉宛<sup>1</sup> 符心宇<sup>1</sup> 王雨生<sup>1</sup> 徐守坤<sup>1\*</sup>

<sup>1</sup>(常州大学信息科学与工程学院 江苏 常州 213164)

<sup>2</sup>(河海大学计算机与信息学院 江苏 南京 210098)

**摘要** 针对复杂背景下细小裂纹图像检测难、噪声干扰多和裂纹宽度信息易丢失的问题,提出一种基于 U-Net 改进的方法。利用残差块解决网络退化,加入 BN 层改善梯度弥散,融入深度可分离卷积以及高尺度的转置卷积,实现特征信息由浅入深的传递;改进注意力机制,实现细节特征的优化;延伸 U-Net 特征向量长度,在底部加入由最大池化层、小尺度深度可分离卷积与上采样层构建的层融合模块,实现分辨率和感受野之间的平衡。实验结果表明,在客观标准下,改进的方法比 U-Net 的 IoU 的值提高 0.187 3, Recall 的值提高了 0.112 7, Precision 提高了 0.135 9, F1-score 提高了 0.068 7, 并且实验结果皆优于其他方法对于 U-Net 的改进,减少了伪分割现象,完成对细小裂纹分割,获得更加精细的裂纹宽度信息。

**关键词** 裂纹检测 U-Net 池化层 残差块 注意力机制

中图分类号 TP391.41

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2022.03.031

## DETECTION OF FINE CRACKS BASED ON IMPROVED U-NET

Feng Xiaochen<sup>1</sup> Li Ning<sup>1,2</sup> Gu Yuwan<sup>1</sup> Fu Xinyu<sup>1</sup> Wang Yusheng<sup>1</sup> Xu Shoukun<sup>1\*</sup>

<sup>1</sup>(School of Information Science and Engineering, Changzhou University, Changzhou 213164, Jiangsu, China)

<sup>2</sup>(School of Computer and Information, Hohai University, Nanjing 210098, Jiangsu, China)

**Abstract** In the complex backgrounds, image detection of fine cracks is difficult, noise interference is high, and crack width information is easy to lose. To solve these problems, we proposed an improved method based on U-Net. We used the residual block to solve network degradation, added BN layer to improve gradient dispersion, and integrated depth-wise separable convolution and high scale transpose convolution, so as to transfer the feature information from shallow to deep. The attention mechanism was improved to optimize the details. We extended the length of the U-Net feature vector, and added a layer fusion module at the bottom constructed by the max pooling layer, small scale depth-wise separable convolution and the upsampling layer, thus realizing the balance between resolution and receptive field. The experimental results show that in the objective standard, the improved method is 0.187 3 higher than the IoU value of U-Net, the Recall value is increased by 0.112 7, the precision is increased by 0.135 9, and the F1-score is increased by 0.068 7. The results are better than other improved methods for U-Net. The method reduces the false segmentation, completes the segmentation of fine crack and obtains the more detailed crack width information.

**Keywords** Crack detection U-Net Pooling layer Residual block Attention mechanism

## 0 引言

细小裂纹检测一直是裂纹检测领域的热点问题,由于其目标小且容易受噪声干扰,所以检测难度大。

建筑物上出现细小裂纹极易造成安全隐患,因此对细小裂纹进行检测具有重大的安全以及经济意义。传统的检测方法依靠人工视觉检测或者选用无损的传感器进行辅助检测,但是这种检测方法效率低、开支大,并且主观性较强,无法对裂纹的类别以及尺寸进行客观

收稿日期:2020-02-11。国家自然科学基金项目(61906021);江苏省教育厅 2018 年师资队伍第二批专项经费项目。

封晓晨,硕士生,主研领域:图像处理。李宁,副教授。顾玉宛,讲师。符心宇,硕士生。王雨生,硕士生。徐守坤,教授。

的分析评判。目前,常使用形态学法<sup>[1-3]</sup>、边缘检测法<sup>[4-5]</sup>、基于统计学<sup>[6-7]</sup>等方法进行裂纹检测,但这些方法对噪声干扰图像的裂纹检测精度小。Malarvel 等<sup>[8]</sup>提出基于 Otsu 算法的用于焊接缺陷分割的机器视觉方法,即使用最小概率加权背景组(LPWBG),通过调整威布尔分布自动选择用于分割焊接缺陷的期望阈值,该方法不能有效地去除噪声对裂纹分割的干扰。朱力强等<sup>[9]</sup>针对裂纹图像在光照不均以及裂纹方位不相同等问题,采用了裂纹图像的点集作为特征点集,通过点集配准算法将点集扩充后做归一化处理,提高了匹配的准确率,有效解决光照干扰问题。Shen<sup>[10]</sup>针对路面裂纹问题,通过灰度变换和图像平滑等形态学方法处理道路裂纹图像和投影来识别裂纹类别,能够分割出完整裂纹,但是存在噪声干扰问题。陈昊等<sup>[11]</sup>提出基于光流计算的轴承滚子缺陷检测方法,依靠金字塔分层策略细化,能够增强裂纹的细节信息。袁小翠等<sup>[12]</sup>提出对钢轨缺陷图像进行最大熵阈值分割方法,采取增强局部对比度,使用最大目标熵、较小的目标概率来得到更小阈值的方法,有效减少了图像噪声的干扰,但是忽略了对细节部分的分割。采用区域生长法<sup>[13]</sup>、水平集法<sup>[14]</sup>、主动轮廓模型<sup>[15]</sup>法等对细小裂纹的特征提取均不敏感。Withayachumnankul 等<sup>[16]</sup>采用方向滤波器核进行图像滤波,能够从粗糙表面提取细小裂纹区域,提高检测精度及灵敏度。Prasanna 等<sup>[17]</sup>用张量投票算法增强裂纹特征,提取简单裂纹特征效果较好,难以提取复杂裂纹特征,宽度信息不敏感。任子晖等<sup>[18]</sup>通过 Curvelet 变换增强血管特征,提高了神经网络对特征提取能力。传统的图像处理的方法可利用计算机将图像信号转换成数字信号并进行各种处理,同样卷积神经网络也可以通过训练后的网络模型对图像进行分类、分割、目标检测,景军锋等<sup>[19]</sup>应用深度卷积神经网络对色织物缺陷检测,对图像先进行高斯去噪,然后利用神经网络反向传播算法对图像进行训练,最后使用 Meanshift 算法对图像特征进行分割。

目前,大部分基于 U-Net 改进的方法都是通过增大感受野来获取全局特征信息,如 DUNet<sup>[20]</sup>通过添加空洞卷积扩大感受野,但是增大感受野会造成局部细节信息丢失,对细小裂纹的检测造成阻碍。本文算法不局限于感受野的扩大,提出一种基于 U-Net<sup>[21]</sup>的设计方法,该方法将最大池化层、上采样层和卷积核为小尺寸的深度可分离卷积进行相加融合,构建一种全新的模块扩大分辨率,扩展网络深度来增大感受野,通过多尺度连接维持感受野与分辨率平衡的状态。在最大

感受野的前提下,保持最大分辨率,从而实现对细小裂纹的检测,最后引入新的学习机制完成对有用的特征信息的捕捉,排除噪声干扰。

## 1 U-Net 网络

U-Net 网络是一种医学分割网络,具有良好的分割效果。本文算法采用 U-Net 网络作为分割裂纹图像的主干网络,该网络的框架结构与“U”型相似,并且进行端到端的训练,可以减少计算量。“U”型的左右两边对称,左边进行下采样操作用于扩大感受野来获取上下文信息,右边上采样操作能够精确地定位分割位置,U-Net 的上采样有大量的通道,因此网络的上下文信息可以向高层传递,并且在传递过程中扩大裂纹图像的多尺度信息。上采样操作只能恢复网络在池化的过程中丢失的部分特征信息,右边高层抽象的特征信息与左边的低层高分辨的特征信息融合,扩大了感受野,恢复在池化操作过程中损失的特征信息。

## 2 基于 U-Net 网络的改进方法

### 2.1 改进残差块

网络深度低,U-Net 对裂纹特征表达的精度不高,同时编码与解码的通道数相同,造成网络内存占用大、计算参数冗杂。Resnet<sup>[22]</sup>一直都作为优化网络性能的有效手段之一,将输入加入到输出中构造一个残差结构,可以使神经网络在不增加参数复杂度的同时提高计算能力,并且降低了超参数的数量。使用残差网络的目的是解决 U-Net 网络不断加深的过程中出现的网络退化问题。

如图 1 所示,图 1(a)是最原始的残差块结构,图 1(b)是改进后的残差块结构。本文算法的残差结构由深度可分离卷积(Depthwise Separable Convolutions)和高尺度转置卷积(Transposed Convolution)构成一个“weight layer”,深度可分离卷积可以分成深度卷积(depthwise convolution)和逐点卷积(pointwise convolution),深度卷积在每一个通道独立进行空间卷积,最后利用逐点卷积将深度卷积后的通道进行混合输出,可以提高网络训练速度,转置卷积是一种上采样操作可以减少由深度可分离卷积扩展的通道数,增大分辨率。“skip connection”使得输入  $X$  在经过两层“weight layer”后的输出可以与输入  $X$  直接相加,得到目标函数  $F(X) + X = H(X)$  将它转化为残差函数表示,如式(1)所示。

$$F(X) = H(X) - X \quad (1)$$

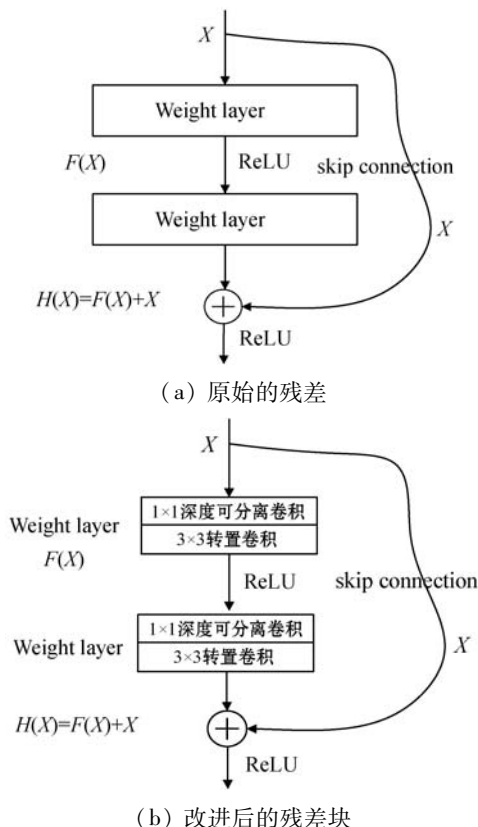


图 1 残差结构改进

此时只需要对  $F(X) = 0$  时的残差函数进行学习,不是真的为 0 而是将其逼近于 0,比学习  $H(X) = X$  的恒等映射容易,网络性能不会退化。

### 2.2 注意力机制

使在噪声干扰较多的情况下,容易丢失对细节信息的分辨能力,造成裂纹图像的伪分割。注意力机制 (attention mechanism)<sup>[23]</sup> 对特征信息具有显著的聚焦能力,解决信息负载过重的问题,选择正确的特征信息输入到之后的神经网络中计算,应用在语义分割中可以有效提高图像分割的精度。引入注意力机制模块,在注意力机制中融合残差结构和卷积核大小为  $3 \times 3$  的深度可分离卷积,提高网络速度,并在其后添加转置卷积捕捉局部特征,捕捉全局的信息,并对整个网络进行 BN (Batch Normalization) 处理,提升网络泛化能力,减少伪分割现象。

该机制学习完特征后直接通过网络训练而生成。训练的模型选择性学习裂纹的特征信息,排除背景的干扰信息,通过注意力机制捕捉全局的信息来获得更大的感受野以及上下文信息,聚焦于裂纹信息的选择,并且对裂纹的检测边缘进行精细化处理,通过注意力机制优化网络。注意力机制的编码公式如式(2)所示。

$$C_m = \sum_{m=1}^{n'} a_{nm} h_m \quad (2)$$

式中: $h_m$  表示编码阶段的转换函数; $a_{nm}$  为权重; $n'$  表示

特征信息的长度。

权重公式如下:

$$a_{nm} = \frac{\exp(e_{nm})}{\sum_{k=1}^l \exp(e_{nk})}, e_{nm} = f(h'_{n-1}, h_m) \quad (3)$$

式中: $h'_{n-1}$  为解码阶段的转换函数; $f$  为对预测像素与真值像素的匹配度打分。

### 2.3 卷积池化层的融合

下采样会降低像素被正确标记的概率,U-Net 网络的上采样对恢复特征信息的能力有限,使得裂纹的宽度信息不明显,无法检测到细小裂纹的现象因此延伸 U-Net 框架,在 U 型底部添加卷积池化层的融合层,目的是减少计算量,提高网络速度,同时扩大特征图捕捉局部信息和细节信息。

如图 2 所示,图中的卷积池化层由步长为 2 的最大池化层、 $1 \times 1$  的深度可分离卷积与  $2 \times 2$  的上采样层构建。最大池化层可以减少后面卷积层中的参数量,降低过拟合,同时该操作会降低图像分辨率,池化后进行上采样操作可以复原损失的特征信息,将来自上一层的输出独立地输入到每一个卷积池化层中,将 4 个卷积池化层和 1 个深度可分离卷积输出的特征图进行层融合,通过层融合来拼接通道维度,减少网络模型的训练时间,扩大特征图,增大分辨率。深度可分离卷积有效减少参数计算量,同时设置该卷积的卷积核大小为  $1 \times 1$ ,缩小通道数目,并引入非线性激活函数 ReLU,提高网络的非线性表达,减少卷积过程中的梯度消失现象。卷积池化层将较大范围的感受野和高清晰的分辨率达到相对平衡,有效表达更加复杂的特征。

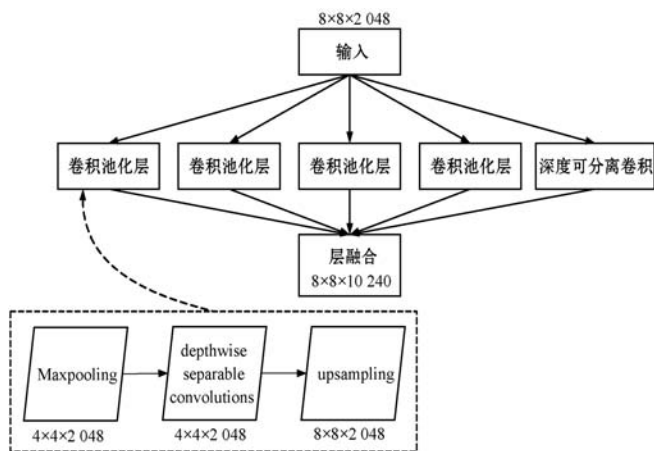


图 2 层融合模块

最大池化层的公式如下:

$$P_{ij}^L = \max(P_{mn}^{L-1}) \quad i \leq m, n \leq i + 2 \quad (4)$$

式中: $L$  为当前层; $L - 1$  为上一层; $i, j$  为当前像素位置; $m, n$  为对应的 pool 核覆盖的区域。

### 2.4 U-Net 改进后的网络结构

如图 3 所示,改进 U-Net 的模型结构。模型中 U-Net 的特征向量的深度为 2 048,U 型的左侧与右侧使用相同的卷积层,左侧进行下采样操作即 max pooling 层,压缩图像特征,同时在右侧对称位置使用上采样操作即 UpSampling 层,恢复图像的特征信息。其中,每个卷积层包含残差块、注意力机制和 2 个转置卷积层,并且在每一个网络层后面都标注了输出的特征图的尺寸和深度。输入大小为  $256 \times 256 \times 1$  的原图和它对应的标签大小为  $256 \times 256 \times 1$  的人工分割的 GT 图,经过神经网络训练,输出大小为  $256 \times 256 \times 1$  的测试结果图。输入的图像通过卷积层、最大池化层、ReLU 函数的训练过程如式(5)所示。

$$F_{ij}(X) = f_{m,s} \{ (X_{s_i+\alpha_i, s_j+\alpha_j}), 0 \leq \alpha_i, \alpha_j \leq m \} \quad (5)$$

式中: $X$  为  $(i, j)$  位置的数据向量; $F_{ij}(X)$  为相对应的输出; $m$  为卷积核的大小; $s$  为步长; $f_{m,s}$  为对应层类型的操作。

Concatenate 层通过融合多种尺度特征图的语义信息来增加通道数,以此降低算法的复杂度。在激活函数之前添加 BN 层,缓解上一层的输入分布向非线性函数的两端缓慢靠近,BN 层做一个  $N(0, 1)$  的正态分布的归一化处理,最后输入到激活函数 ReLU 的值,在反向传播中可以产生更明显的梯度,有效帮助网络进行收敛以此改善梯度弥散的现象。

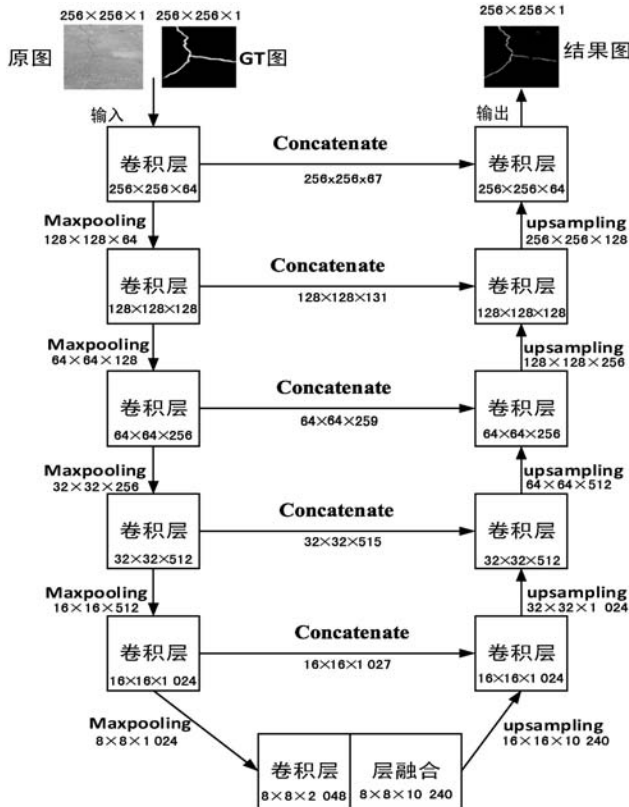
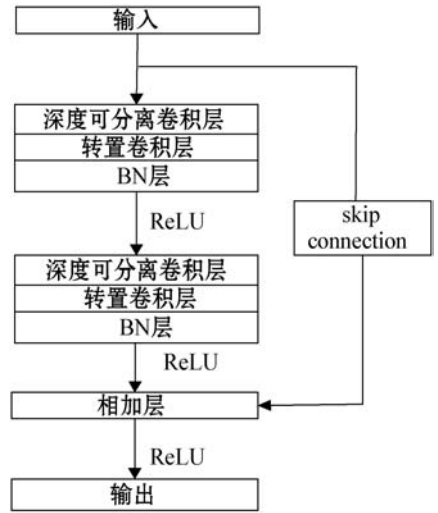
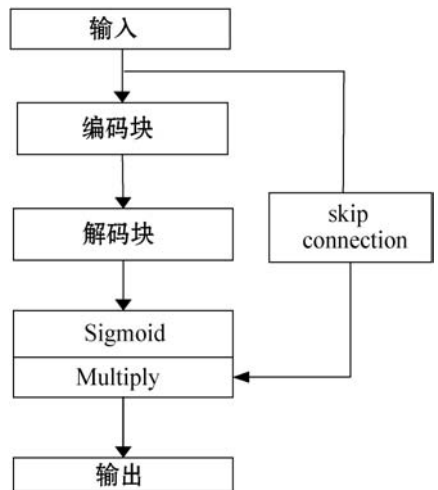


图 3 改进 U-Net 模型结构

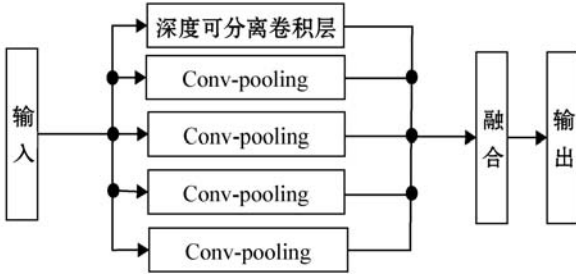
如图 4 所示,表示网络中每个结构的流程。如图 4(a)所示,改进后的残差块就是由深度可分离卷积、转置卷积层和 BN 层组成,输入通过 skip connection 与卷积过后的输出在相加层融合。如图 4(b)所示,注意力机制由“编码-解码”结构组成,编码器由最大池化层、卷积层组成,解码器由上采样层、卷积层组成。将残差块输出的特征信息输入到注意力机制中,软注意力机制在训练时会过度参数化,通过一个 skip connection 与 Sigmoid 函数分类后的输出共同构建残差结构,解决软注意力机制中冗余的参数计算问题,对卷积神经网络进行优化。如图 4(c)所示,Conv-pooling 网络层由最大池化层、深度可分离卷积、ReLU 激活函数、BN 处理层、上采样层组成,在 U-Net 底部构建的融合模块由 4 个相同的 Conv-pooling 和 1 个深度可分离卷积组成的网络结构。每个 Conv-pooling 层独立接收来自于上一层的相同的输入,最后将 4 个 Conv-pooling 和 1 个深度可分离卷积的输出进行融合。图中已标注出每一个卷积层输出维度。



(a) 残差块流程



(b) 注意力机制流程



(c) 层融合流程

图4 改进 U-Net 各部分结构流程

### 3 实验

本文实验环境配置参数: CUDA8.0, 12 GB 内存, GeForce GTX 1080 GPU, 64 bit Ubuntu。实验使用的仿真软件为 PyCharm, 在 TensorFlow 以及 Keras 框架下运行。

#### 3.1 数据集

从网络搜集混凝土裂纹图像以及自己采集的裂纹图像共 2 000 幅进行数据增强到 38 000 幅, 其中图片旋转、平移、扭曲的概率都设置成 0.5。将 38 000 幅图像统一处理成大小为  $256 \times 256 \times 1$  的灰度图像, 选择 20 000 幅图像作为训练集, 8 000 幅图像作为交叉验证集, 10 000 幅图像作为测试集, 实验的目的是验证本文网络模型能否检测出更多细小裂纹。

#### 3.2 性能评价指标

针对裂纹检测的研究利用准确率函数 (Accuracy), 指像素被正确分类的样本数占总分类样本数的比值, 如式(6)所示。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

式中:  $TP$  表示正确像素被正确分类;  $FN$  表示正确像素被错误分类;  $FP$  表示错误像素被分类为正确像素;  $TN$  表示错误像素被分类为错误像素。

二进制交叉熵损失函数 (BCELoss) 如式(7)所示。

$$BCELoss = \sum_{i=1}^m -[y_i \log f_i(x) + (1 - y_i) \log(1 - f_i(x))] \quad (7)$$

式中:  $y_i \in \{0, 1\}$ ;  $f_i(x) \in (0, 1)$ 。

重叠度 (Intersection-Over-Union, IoU) 指预测的像素和真实像素的交集与并集的比值, 重叠度的值反映了分割目标与真值的重叠度, 随着重叠度提高, 像素被正确标记的概率也随着提高, 该值大小与表示定位的准确度成正比, 如式(8)所示。

$$IoU = \frac{\text{target} \cap \text{prediction}}{\text{target} \cup \text{prediction}} \quad (8)$$

式中:  $\text{target}$  代表被标记的像素;  $\text{prediction}$  代表预测的像素。

ROC 曲线下面积 (Area Under Curve, AUC) 的值是一种衡量模型优劣的评价指标, 如式(9)所示。

$$AUC = \sum_{i=2}^m \frac{(x_i - x_{i-1}) \times (y_i + y_{i-1})}{2} \quad (9)$$

召回率  $R$  (Recall), 召回率是被预测为正例样本占真正例样本的比值, 如式(10)所示。

$$R = \frac{TP}{TP + FN} \quad (10)$$

精度  $P$  (Precision), 精度是正确预测的正样本数占所有被预测为正样本的数量的比值, 如式(11)所示。

$$P = \frac{TP}{TP + FP} \quad (11)$$

F-score 测量是 Precision 和 Recall 加权调和平均。本文算法选取  $\alpha = 1$  时, F1-score 的测量方法如式(12)所示。

$$F = \frac{(\alpha^2 + 1)P \times R}{\alpha^2(P + R)} \quad (12)$$

均绝对误差 (Mean Absolute Error, MAE), 它表示模型分割的图像和人工分割的图像之间的像素的绝对误差的平均值, 如式(13)所示。

$$MAE = \frac{1}{m} \sum_{x=1}^m |H(x) - F(x)| \quad (13)$$

式中:  $x$  表示输入;  $y$  表示输出;  $m$  表示被标记的数量;  $H(x)$  表示被分割的图像;  $F(x)$  表示人工分割的标准结果 GT 图像。

#### 3.3 网络模型的训练与分析

本节首先选取 5 种网络模型分别是本文算法、U-Net、Resnet U-Net、Attention resnet、DUNet 进行训练。Resnet U-Net 是在 U-Net 框架下使用 Resnet 级联; Attention resnet 是在 Resnet U-Net 的框架下添加注意力机制, 优化裂缝宽度; 本文算法增加残差块、注意力机制、融合模块; DUNet 在 U 型底部添加空洞卷积 (Dilated Convolution), 在标准卷积里注入空洞, 使网络模型具有更大的感受野。选用 20 000 幅图像进行网络训练, 同时选用 8 000 幅图像进行交叉验证。用来训练的 5 种卷积神经网络的训练参数设置: 优化方法 (optimizer): Adam; 损失函数 (loss): BCELoss; 学习率 (learning-rate): 0.004; 批量大小 (batch size): 2; 迭代次数 (Epoch): 100; 训练迭代期 (iteration): 20 000。

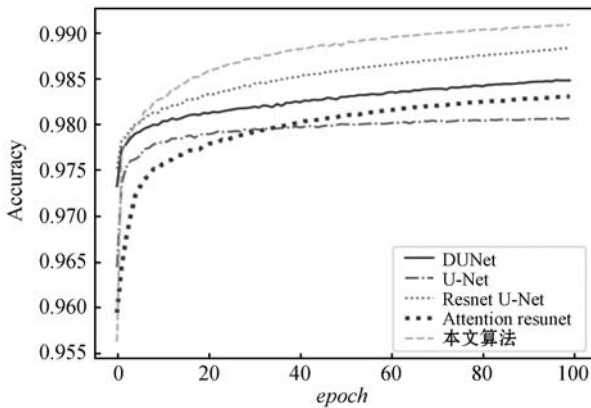
表 1 为本文算法与其他四组算法在  $\text{epoch} = 100$  时, 准确率 (Accuracy)、损失 (Loss)、重叠度 (IoU)、ROC 曲线下面积 (AUC) 的比较。可以看出本文算法的 AUC 值与其他四组算法比较, 提升幅度基本持平, 与 U-Net 的差值最大为 0.0073; 本文算法加入残差块和转置卷积后, IoU 值比其他四种算法提升最大, 因此定位准确度

最高, Resnet U-Net 的 IoU 值居第二, 表示 IoU 的提升与网络深度与关; 本文算法在 Accuracy 值比较其他三组算法大, Loss 值的最小, 并且 Accuracy 提升值与 loss 下降值成反比, 表示该网络的泛化性能比较好。


表 1 5 种网络模型训练的定量比较

网络模型	评价指标			
	Accuracy	Loss	IoU	AUC
U-Net	0.980 6	0.048 0	0.610 0	0.991 3
Resnet U-Net	0.988 3	0.027 0	0.746 4	0.997 6
Attention resunet	0.983 0	0.038 0	0.660 6	0.995 6
DUNet	0.984 8	0.036 5	0.680 9	0.995 5
本文算法	<b>0.990 8</b>	<b>0.021 0</b>	<b>0.797 3</b>	<b>0.998 6</b>

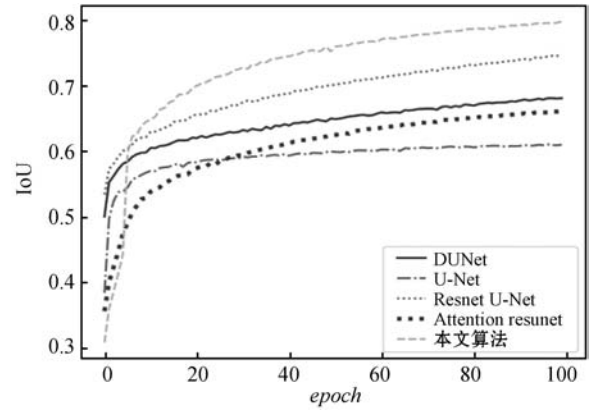
图 5 展示了评价指标 Accuracy、Loss、IoU、AUC 与迭代次数的曲线图。图 5 直观地表现本文算法与其他 4 种深度网络在训练阶段变化过程, 并且在训练到  $epoch = 15$  后, 各项指标一直优于其他三种网络。本文算法的 Accuracy 初始值为 0.956, 幅度缓慢而稳定提升至 0.990 8; Loss 降低幅度最大, 随着迭代次数的增加从 0.117 0 逐渐下降到 0.021 0; 本文算法的 IoU 初始值位 0.314 3 提升至 0.797 3, 在迭代次数的中后期提升幅度较大; AUC 的初始值为 0.931 6 提升至 0.998 6, 升幅缓慢。



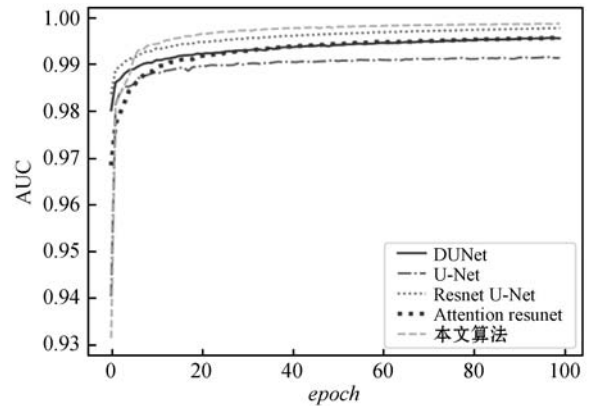
(a) Accuracy



(b) Loss



(c) IoU



(d) AUC

图 5 5 种网络模型的训练曲线

### 3.4 检测结果比较及分析

本节为进一步验证本文算法对裂纹检测的有效性, 将形态学的低帽变换、Otsu 分割算法、canny 边缘检测算法这三组传统算法与上述 5 种网络模型的测试结果进行定量均值比较与分析。

如表 2 所示, 在 8 种算法的评价结果中, 本文算法在召回率、精度、F1 分数和绝对误差均表现最优。采用小卷积核的深度可分离卷积使速度得到提升, 因此消耗时间最少为 0.139 5 s, Resnet U-Net 加深网络所消耗的时间最长为 1.345 0 s, 表示深度可分离卷积可以提高网络速。Attention resunet 在引入注意力机制后, 精度提升 0.135 9, 网络消耗的时间有减少到 1.085 1 s。本文算法的 MAE 值约为传统算法的十分之一, 约为其他深度网络的二分之一。从表 2 的评价指标来看, 本文算法对裂纹的像素被标记的正确率得到了提升, 像素得到正确分类和定位。

表 2 8 种分割算法的定量均值比较

网络模型	评价指标				
	R	P	F1	MAE	时间/s
U-Net	0.804 9	0.786 7	0.851 1	0.028 2	0.329 0
Resnet U-Net	0.893 9	0.722 5	0.901 7	0.016 6	1.345 0

续表 2

网络模型	评价指标				
	<i>R</i>	<i>P</i>	F1	MAE	时间/s
Attention resunet	0.844 5	0.858 4	0.851 2	0.021 2	1.085 1
DUNet	0.861 3	0.871 6	0.865 9	0.022 0	0.172 2
低帽变换	-	-	-	-	1.400 3
Otsu	0.588 3	0.755 6	0.639 4	0.129 9	1.239 3
canny	0.376 8	0.552 3	0.382 1	0.150 1	1.167 3
<b>本文算法</b>	<b>0.917 6</b>	<b>0.922 6</b>	<b>0.919 8</b>	<b>0.012 9</b>	<b>0.139 5</b>

图 6 为 8 种算法的部分实验仿真图。对算法进行定性比较,每组图像的前两幅分别是原图和人工分割的 GT 图像。从图 6(a)到图 6(f)的图像分割的结果来看,虽然 Resnet U-Net 的网络层数深,使得噪声干扰比其他三组都小,但是分割出的裂纹出现断裂现象。Attention resunet 通过注意力机制来提升像素的定位能力,有效辨别特征信息的正确性。DUNet 检测裂纹图像清晰,但是表达出的特征同样出现断裂情况。本文算法通过添加融合层,扩大分辨率,获得更多的局部裂纹特征,因此从图 6(a)来看,图像中分割出更多细小的裂纹,引入注意力机制获取真实的裂纹宽度信息。从图 6(b)的 U-Net 测试结果来看,端到端训练容易丢失全局特征,在相同训练条件下,比其他三组网络分割出的裂纹噪声干扰大。图 6(a)的 Resnet U-Net 不能有效分割出细小裂纹,但抗干扰性好,分割出的图像平滑。图 6(e)的 Attention resunet 比起 Resnet U-Net 的裂纹分割更加完整和清晰,表明在网络引入注意力机制,使得特征捕捉能力持续提升。图 6(c)的 DUNet 增加空洞卷积用来处理细节特征,有轻微噪声干扰,但是全局信息处理不好,不能完整地分割裂纹图像。图 6(d)的低帽变换通过处理亮背景下的暗物体,突出裂纹,但是分割出的裂纹界限不明显。图 6(e)的 Otsu 分割算法噪声干扰严重产生了伪分割现象,不能有效对裂纹的像素点进行分割。图 6(f)的 canny 算法检测出的裂纹的轮廓虚化,裂纹不明显。


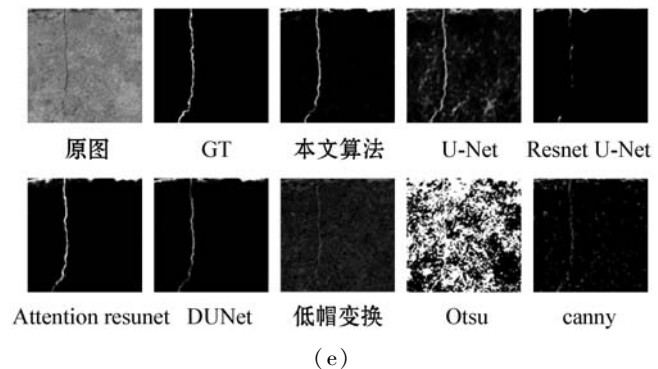






图 6 本文方法与其他方法的图像分割结果比较



综上所述,本文算法对细小裂纹具有良好的分割性能,减少噪声干扰,对像素精确定位。在复杂的背景下依然可以排除干扰,识别真正的裂纹信息,对裂纹进行完整分割,在裂纹监测中具有一定的应用价值。

## 4 结 语

针对裂纹检测中出现的细小裂纹图像不容易检测、噪声干扰、部分信息丢失的问题,本文算法从 U-Net 和残差结构设计、注意力机制、层融合模块三方面对 U-Net 进行改进,构建一种新的网络模型。实验结果表明,本文方法可减少噪声的干扰,提升训练速度,缩短训练时间,检测到细小裂纹,获取裂纹真实的宽度信息。同时,由于光线遮挡裂纹而出现图像灰度不均的问题,导致检测出的裂纹特征被遮挡,图像裂纹产生断裂现象。目前,提出的网络模型尚未解决这一问题,下一步将着重研究如何通过卷积神经网络解决裂纹在训练过程中出现的断裂现象。

## 参 考 文 献

- [ 1 ] Medeiros A G, Guimarães M T, Peixoto S A, et al. A new fast morphological geodesic active contour method for lung CT image segmentation[J]. *Measurement*, 2019, 148: 106687.
- [ 2 ] 刘千,葛阿雷,史伟.形态学与 RCF 相结合的唐卡图像边缘检测算法[J]. *计算机应用与软件*, 2019, 36(6): 196 - 201, 242.
- [ 3 ] 梁礼明,盛校棋,蓝智敏,等.基于多尺度滤波的视网膜血管分割算法[J]. *计算机应用与软件*, 2019, 36(10): 190 - 196, 204.
- [ 4 ] Xu J, Wen X, Zhang H, et al. Automatic extraction of lineaments based on wavelet edge detection and aided tracking by hillshade[J]. *Advances in Space Research*, 2020, 65(1): 506 - 517.
- [ 5 ] 邱东,李佳禧,杨宏韬,等.基于信息测度和核函数极限学习机的图像边缘检测[J]. *计算机应用与软件*, 2019, 36(10): 156 - 161.
- [ 6 ] Ghosh P, Mali K, Das S K. Use of spectral clustering combined with Normalized Cuts(N-Cuts) in an iterative k-Means clustering framework (NKSC) for superpixel segmentation with contour adherence[J]. *Pattern Recognition and Image Analysis*, 2018, 28(3): 400 - 409.
- [ 7 ] Hu F, Xia G S, Wang Z F, et al. Unsupervised feature learning via spectral clustering of multidimensional patches for remotely sensed scene classification[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(5): 2015 - 2030.
- [ 8 ] Malarvel M, Sethumadhavan G, Bhagi P C R, et al. An improved version of Otsu's method for segmentation of weld defects on X-radiography images[J]. *Optik*, 2017, 142: 109 - 118.
- [ 9 ] 朱力强,王春薇,王耀东,等.基于特征点集距离描述的裂缝图像匹配算法研究[J]. *仪器仪表学报*, 2016, 37(12): 2851 - 2858.
- [ 10 ] Shen G. Road crack detection based on video image processing[C]//3rd International Conference on Systems and Informatics(ICSIAI), 2016: 912 - 917.
- [ 11 ] 陈昊,张奔,黎明,等.基于图像光流的轴承滚子表面缺陷检测[J]. *仪器仪表学报*, 2018, 39(6): 198 - 206.
- [ 12 ] 袁小翠,吴禄慎,陈华伟.钢轨表面缺陷检测的图像预处理改进算法[J]. *计算机辅助设计与图形学学报*, 2014, 26(5): 800 - 805.
- [ 13 ] 闫东阳,明冬萍.基于自动多种子区域生长的遥感影像面向对象分割方法[J]. *工程科学学报*, 2017, 39(11): 1735 - 1742.
- [ 14 ] Zhang K, Zhang L, Lam K M, et al. A level set approach to image segmentation with intensity inhomogeneity[J]. *IEEE Transactions on Cybernetics*, 2016, 46(2): 546 - 557.
- [ 15 ] 孙文燕,董恩清,曹祝楼,等.一种基于模糊主动轮廓的鲁棒局部分割方法[J]. *自动化学报*, 2017, 43(4): 611 - 621.
- [ 16 ] Withayachumnankul W, Kunakornvong P, Asavathongkul C, et al. Rapid detection of hairline cracks on the surface of piezoelectric ceramics[J]. *International Journal of Advanced Manufacturing Technology*, 2013, 64: 1275 - 1283.
- [ 17 ] Prasanna P, Dana K J, Gucunski N, et al. Automated crack detection on concrete bridges[J]. *IEEE Transactions on Automation Science and Engineering*, 2016, 13(2): 591 - 599.
- [ 18 ] 任子晖,邱天舒.基于 Curvelet 变换与遗传神经网络的血管分割算法[J]. *计算机应用与软件*, 2019, 36(11): 235 - 242.
- [ 19 ] 景军锋,范晓婷,李鹏飞,等.应用深度卷积神经网络的色织物缺陷检测[J]. *纺织学报*, 2017, 38(2): 68 - 74.
- [ 20 ] Jin Q G, Meng Z P, Pham T D, et al. DUNet: A deformable network for retinal vessel segmentation[J]. *Knowledge-Based Systems*, 2019, 178: 149 - 162.
- [ 21 ] Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention, 2015: 234 - 241.
- [ 22 ] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2016.
- [ 23 ] Mnih V, Heess N, Graves A, et al. Recurrent models of visual attention[C]//27th International Conference on Neural Information Processing Systems, 2014.