

DOI:10.19651/j.cnki.emt.2313957

融合注意力机制与 GhostUNet 的路面裂缝检测方法<sup>\*</sup>赵志宏<sup>1,2</sup> 郝子晔<sup>1</sup> 何朋<sup>1</sup>

(1. 石家庄铁道大学信息科学与技术学院 石家庄 050043; 2. 石家庄铁道大学省部共建交通工程结构力学行为与系统安全国家重点实验室 石家庄 050043)

**摘要:** 路面裂缝是道路最为常见的缺陷,随着深度学习技术的发展,利用深度学习的方法对路面图像中的裂缝信息提取的方法愈来愈多。针对现有深度学习路面裂缝检测方法提取裂缝特征不完整导致精度低以及实时性不足的问题,提出一种融合注意力机制与 GhostUNet 的路面裂缝检测方法。本方法由编码器和解码器组成,将 U-Net 中的常规卷积改进为 Ghost 卷积,减少模型参数量;在编码和解码部分,为了提高对裂缝特征的提取能力,引入 ECA 注意力机制和残差连接,ECA 注意力模块可以过滤不相关的特征信息,利用残差连接可以避免网络退化现象。为评估本方法在裂缝检测方面的有效性,使用两个公开裂缝数据集,并进行消融实验和对比实验,实验结果 F1\_score、P 和 R 分别比 U-Net 平均提高了 14.48%、14.35% 和 14.45%;该模型相比 U-Net 参数量下降了 14.2 MB。该模型与同类模型比较,分割的准确率更高,参数量更少。

**关键词:** 裂缝检测;Ghost;U-Net;ECA;残差连接

**中图分类号:** TP391 **文献标识码:** A **国家标准学科分类代码:** 520.20

## Combining attention mechanism with GhostUNet method for pavement crack detection

Zhao Zhihong<sup>1,2</sup> Hao Ziye<sup>1</sup> He Peng<sup>1</sup>

(1. School of Information Science and Technology, Shijiazhuang Tiedao University, Shijiazhuang 050043, China;

2. State Key Lab of Mechanical Behavior and System Safety of Traffic Engineering Structures, Shijiazhuang

Tiedao University, Shijiazhuang 050043, China)

**Abstract:** Pavement crack is the most common defect of road. With the development of deep learning technology, more and more methods are used to extract the crack information from pavement images. Aiming at the problems of low accuracy and lack of real-time due to incomplete extraction of crack features by existing deep learning pavement crack detection methods, a road crack detection method combining attention mechanism and GhostUNet is proposed. This method is composed of encoder and decoder. The conventional convolution in U-Net is improved to Ghost convolution and the number of model parameters is reduced. In coding and decoding, in order to improve the ability to extract crack features, ECA attention mechanism and residual connection are introduced. ECA attention module can filter irrelevant feature information, and residual connection can be used to avoid network degradation. To evaluate the effectiveness of this method in fracture detection, two publicly available fracture data sets were used, and ablation and comparison experiments were conducted. The experimental results of F1\_score, P and R increased by 14.48%, 14.35% and 14.45%, respectively, compared with U-Net. The number of parameters in this model decreased by 14.2 MB compared with U-Net. Compared with similar models, this model has higher segmentation accuracy and fewer parameters.

**Keywords:** crack detection; Ghost; U-Net; ECA; residual connection

## 0 引言

传统路面裂缝检测方法主要是通过人工观测的方法,

容易受到主观因素的影响,效率低下,并且人工成本高,人工检测过程中还容易导致安全问题。如何实现自动化、高精度的路面裂缝检测是当前亟需解决的问题。

收稿日期:2023-06-25

\* 基金项目:国家自然科学基金(11972236)项目资助

早期路面裂缝检测主要采用数字图像处理的方法, Oliveira 等<sup>[1]</sup>提出阈值分割算法,利用裂缝图像像素灰度值与背景不同的特点实现裂缝检测。Nejad 等<sup>[2]</sup>提出一种利用小波变换的动态神经网络阈值选择的检测方法。这些传统方法容易受到噪声、阴影、光照不均等因素的影响,导致模型泛化性能不佳。

随着深度学习技术的进步,越来越多的研究开始将卷积神经网络技术用于路面裂缝检测。Cha 等<sup>[3]</sup>提出一种基于卷积神经网络的滑动窗口方法,通过对每个窗口的分类实现裂缝检测。Li 等<sup>[4]</sup>提出一种基于深度学习的桥梁裂缝检测算法,利用卷积神经网络实现对图像块的分类识别,再利用改进的窗口滑动算法实现裂缝检测,取得了较好的检测效果。刘新根等<sup>[5]</sup>提出一种基于级联网络的隧道衬砌裂缝识别算法,结合多尺度特征融合进行特征提取,解决裂缝特征较弱、浅层网络无法提取的问题。余加勇等<sup>[6]</sup>提出基于区域的卷积神经网络实例分割算法(mask region-based convolutional neural network, Mask R-CNN)的裂缝自动识别和定位模型,通过阈值分割和边缘检测等实现桥梁裂缝的识别和定位。Zhang 等<sup>[7]</sup>提出一种深度卷积神经网络的路面裂缝检测方法,利用有监督的卷积神经网络对图像中的每个像素块进行分类,检测结果优于利用人工特征提取的机器学习方法。

为了进一步提高裂缝检测性能,研究人员将卷积神经网络和其它技术相结合。张华卫等<sup>[8]</sup>提出一种并行提取和注意力融合的方法,利用多尺度卷积和融合高低特征来提高裂缝检测精度。Liu 等<sup>[9]</sup>提出一种基于全卷积神经网络和深监督网络结合的方法,融合不同特征图提高了裂缝检测性能。Yang 等<sup>[10]</sup>引入特征金字塔机制将浅层特征与深层特征融合,提高了难样本的检测精度。曹锦钢等<sup>[11]</sup>通过在编码器和解码器之间引入注意力机制,提高路面裂缝检测的性能。孙美君等<sup>[12]</sup>提出一种弱监督学习下融合注意力机制的表面缺陷检测网络(surface defect detect network, SDD-Net),将浅层次和深层次的语义特征有效融合。张志华等<sup>[13]</sup>提出结合双注意力机制的路面裂缝检测方法,使用空洞卷积残差网络结合双注意力机制有效提高了感受野。上述神经网络方法存在的问题是不能兼顾检测对象的高低阶特征,造成路面裂缝检测精度低。

U-Net 模型最初用于解决生物医学影像问题,由于其性能优越逐渐应用到了图像分割的各个方面。杨秋媛等<sup>[14]</sup>提出一种混凝土裂缝检测方法,利用 U-Net 的编码器和解码器结构结合跳跃连接从复杂的混凝土建筑图像中分割出完整的裂缝图。张伯树等<sup>[15]</sup>提出一种改进的高分辨率网络(high resolution net, HRNet)的路面裂缝分割算法,主干网络采用密集上采样模块(dense upsampling convolution, DUC)并引入挤压和激励模块(squeeze and excitation-block, SE-Block)的方式,对不同特征层的融合重新标定权重。陈涵深等<sup>[16]</sup>提出一种有效的基于 U 型全卷

积神经网络的裂缝检测模型,在跳跃连接中加入 Dropout 层以及采用不同扩张系数的空洞卷积密集连接增大感受野,提高了分割精度和泛化能力。刘凡等<sup>[17]</sup>将一种并行注意力机制嵌入到 U-Net 中,能够获取更加丰富的裂缝特征。汪家宝等<sup>[18]</sup>提出一种基于混合损失函数的 ResNet34-UNet 路面裂缝分割方法,缓解了因裂缝形状特殊所带来的样本不平衡的问题。虽然提高了部分检测性能,但由于网络内部采用的依然为常规卷积,模型参数量较大,实时性不足。为了提高实时检测性能,一些轻量级网络如 MobileNet<sup>[19]</sup>和 ShuffleNet<sup>[20]</sup>也被应用到 U-Net 中作为主干网络提取裂缝特征。虽然这些轻量级模型降低了参数量,但是裂缝检测精度还达不到应用的要求,需要进一步提高。

综上所述,为了提高轻量级裂缝检测模型的检测精度,本文在 Ghost 卷积的基础上,提出一种融合轻量化通道注意力机制(efficient channel attention, ECA)和残差连接的路面裂缝检测方法。Ghost<sup>[21]</sup>卷积是一种新的卷积结构,其利用逐点卷积生成部分特征图,采用线性运算生成其余特征图,弥补了常规卷积生成冗余特征的缺点。引入 ECA 注意力机制和残差连接,可以提高网络学习特征的能力,加速训练过程,实现对路面裂缝的有效检测。本文主要贡献如下:

1) 基于 U-Net 结构,提出融合 ECA 注意力机制与 GhostUNet 的路面裂缝检测方法,在编码器和解码器中使用 Ghost 卷积替换常规卷积,减少了模型参数量,提高了路面裂缝检测的实时性。

2) 为了能够有效地提取关于裂缝图像不同尺寸的特征信息,在编码器和解码器中引入 ECA 注意力模块,使得更好地提取裂缝特征信息,提高了路面裂缝检测的精度。

3) 为了抑制梯度爆炸或梯度消失问题,引入残差连接,将 ECA 注意力模块与残差连接融合,进一步提高了模型的裂缝检测效果。

## 1 理论基础

### 1.1 Ghost 卷积

现有基于 U-Net 模型存在参数量大,需要训练样本多等问题,如何减少 U-Net 模型的参数量且分割性能不受影响是难点,因此本文引入 Ghost 卷积降低模型参数量,提高模型实时性能。常规卷积运算过程中会产生大量参数,其生成特征图的冗余度很高。Ghost<sup>[21]</sup>卷积为了解决模型中间特征图存在的大量冗余问题,采用逐点卷积对输入图片进行通道数的压缩生成部分特征图,然后利用线性运算得到更多的特征图,将不同的特征图拼接到一起,组合成新的输出, Ghost 卷积结构如图 1 所示。

卷积神经网络中,卷积核大小为 3 的常规卷积参数量大小  $P$  可以表示为:




图 1 Ghost 卷积结构

$$P = C_{input} \times C_{output} \times k \times kP = C_{input} \times C_{output} \times 3 \times 3 \quad (1)$$

式中： $C_{input}$  代表输入通道数， $C_{output}$  代表输出通道数。

Ghost 卷积分为两部分，第 1 部分使用逐点卷积，第 2 部分选取卷积核大小为 3 的卷积操作，参数量大小  $G$  可表示为：

$$G = C_{input} \times 1 \times 1 \times \frac{C_{output}}{2} + 3 \times 3 \times \frac{C_{output}}{2} \quad (2)$$

常规卷积与 Ghost 卷积的参数量压缩率  $q$  可表示为：

$$q = \frac{C_{input} \times C_{output} \times 3 \times 3}{C_{input} \times 1 \times 1 \times \frac{C_{output}}{2} + 3 \times 3 \times \frac{C_{output}}{2}} = \frac{18 \times C_{input}}{C_{input} + 9} \quad (3)$$

由式(3)可知，卷积神经网络中深层特征通道数很大，则压缩率  $q > 1$ ，由此本文将常规卷积替换为 Ghost 卷积。

### 1.2 ECA 注意力模块

注意力机制的灵感来自人类视觉注意力，通过注意力权重将语义更加丰富的特征提取出来。通道注意力机制已被证明可以改善深度卷积神经网络。为了解决卷积池化过程中特征图不同通道由于其不同重要性带来的损失问题，挤压和激励网络（squeeze and excitation networks, SENet<sup>[22]</sup>）对输入特征图进行了通道压缩降维，但是压缩降维可能会影响模型的性能，导致精度下降。

为了改进 SENet 模块降维过程中带来的性能损失问题，ECA<sup>[23]</sup> 模块提出一种不降维的局部跨信道交互策略，使得通道与权重之间有了联系，在保证性能的同时降低模型复杂度。为提高对裂缝特征区域的学习能力，本文在实验部分通过引入 3 种不同注意力机制的实验对比分析，选取性能最优的 ECA 注意力机制进一步提高裂缝检测的精度。

ECA 注意力模块使用一种自适应方法<sup>[24]</sup>，该方法能够选择最优的一维卷积核大小，从而实现局部跨通道交互，这种方法使用大小为  $k$  的快速一维卷积进行有效实现，其中  $k$  表示覆盖局部跨通道交互的范围，ECA 注意力模块中的自适应方法可自动确定  $k$  的大小，从而避免了手动调整的过程。ECA 注意力模块结构如图 2 所示。

其计算公式如下：

$$ECA(x)_c = \sum_{i=1}^N a_{i,c} x_i \quad (4)$$




图 2 ECA 注意力模块结构

$$a_{i,c} = \frac{\exp(z_{i,c})}{\sum_{j=1}^N \exp(z_{j,c})} \quad (5)$$

$$z_{i,c} = \theta \left( \frac{1}{N} \sum_{j=1}^N x_{i,j} \right)_c \quad (6)$$

式中： $x$  是输入特征图，形状为  $R(C \times N)$ ， $R$  为实数域， $C$  为通道数， $N$  为特征图大小。 $\theta(\cdot)$  表示一个线性变换，它通过将所有通道的元素进行加权平均来计算每个通道的特征统计量。使用 Softmax 函数来计算所有通道的注意力权重  $a_{i,c}$ ，然后将输入特征图的各个通道进行加权处理，获得 ECA 注意力模块的输出。

### 1.3 残差连接

为了能够提取更多的深层特征，传统的卷积神经网络通常选择加深网络，然而这种方法可能会引发网络退化等问题。为了解决这个问题，He 等<sup>[25]</sup> 引入残差连接，将浅层特征与深层特征相加作为后续操作的输入，有效降低了输入特征的损失。引入 Ghost 卷积和 ECA 注意力模块后，虽然检测精度和实时性得到提升，但网络层数加深，在一定程度上会出现网络退化现象，因此本文引入残差连接。加入残差连接和 ECA 注意力模块的卷积结构如图 3 所示，残差连接的叠加方式为图像像素值的叠加，当维度相同时可直接相加，不同时则先进行特征维度转换再相加。




图 3 加入残差连接和 ECA 模块的卷积结构

## 2 方法原理

本文提出一种融合 ECA 注意力机制与 GhostUNet 的路面裂缝检测方法，将 U-Net 模型中的常规卷积替换为 Ghost 卷积，用于减小模型参数量和训练速度；在编码和解码部分加入了 ECA 模块和残差连接，用于增强特征提取能力。这样既提取了路面裂缝的局部特征信息，也确保

了模型的轻量化。

本方法结构如图 4 所示。该方法的结构包含编码器和解码器。编码器包含卷积层、ECA 模块、下采样和残差连接结构。卷积层主要包含 Ghost 卷积、批标准化和非线性 ReLU 函数 3 个部分,需要接连做两次相同的操作。ECA 模块和残差连接结构均位于卷积层之后。ECA 模块将输入特征依次送入通道注意力阶段获得该模块的输出特征。残差连接结构利用残差连接将浅层特征与深层特征融合共

同构成后续操作的部分输入,能够减少特征丢失,缓解网络退化。为了降低特征维度,采用最大池化操作(Maxpooling)对下采样部分进行处理。解码器部分包含带有 Ghost 卷积的卷积层、ECA 模块、残差连接结构和上采样。操作过程与编码部分保持一致。为恢复特征图维度,上采样采用  $2 \times 2 \times 2$  的转置卷积。在编码器和解码器之间的连接线用于特征融合。最后通过一个卷积核大小为 1 的常规卷积还原输出结果。

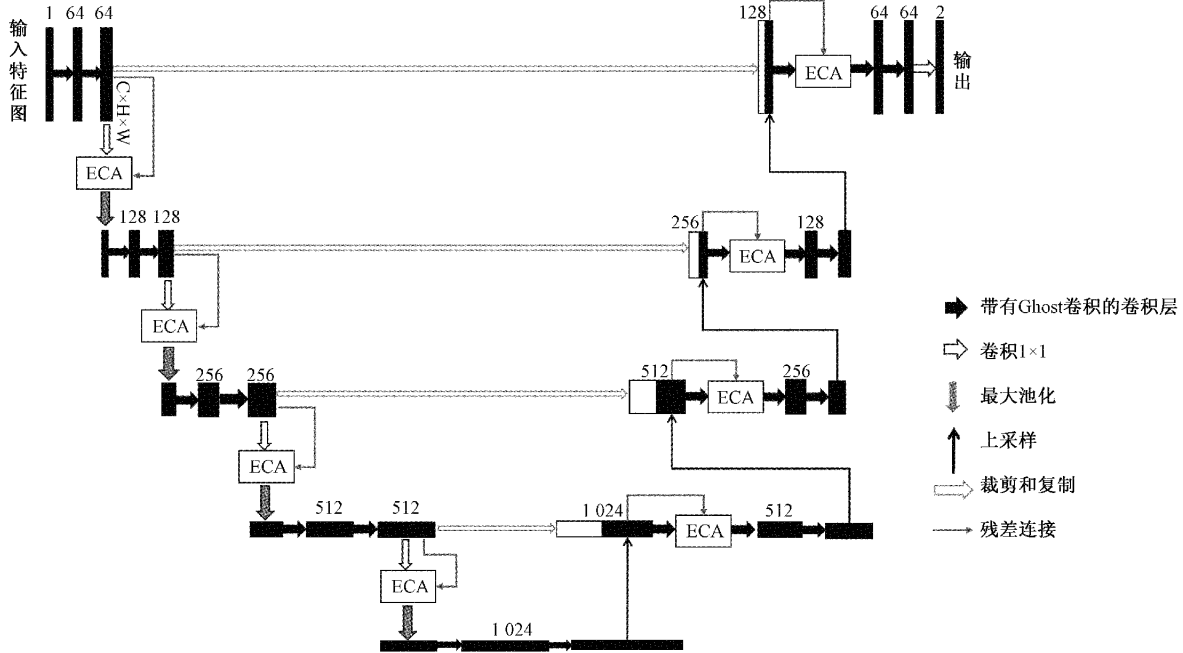


图 4 本文方法结构图

测试图像首先进行两次卷积层后生成通道数为 64 的特征图,再进行 ECA 注意力模块、最大池化采样和两次卷积层后生成通道数为 128 的特征图,经过连续 3 次带有 Ghost 卷积的卷积层和下采样后,生成了三种不同通道数的特征图,分别为 256、512 和 1 024。在解码部分,通过将第一次上采样生成通道数为 512 特征图与下采样产生的通道数为 512 的特征图拼接,形成一个具有 1 024 个通道数的特征图,使用残差连接将拼接后的通道数为 1 024 的特征图与经过 ECA 注意力模块处理的特征图相加,从而得到新的特征图,再进行两次卷积层,连续进行 3 次上采样和特征拼接后生成通道数为 64 的特征图,经过一次卷积核大小为 1 的常规卷积后输出结果。

### 3 实验数据与设置

实验选用 Pytorch 深度学习框架,处理器为 Intel(R) Xeon(R) Silver 4214R CPU@2.40 GHz, GPU 配置为 Tesla V100S 32 G。采取两个公开路面裂缝数据集,分别为 DeepCrack 和 CFD。DeepCrack 数据集有 537 张,其中 240 张为训练集,60 张为验证集,237 张为测试集;CFD 数据集为 118 张,其中 23 张作为测试集,为避免模型训练过

拟合,将剩余的图像利用随机翻转、随机镜像等数据增强技术手段来增加数据,经过数据增强后,228 张为训练集,57 张为验证集。

#### 3.1 评价标准

针对本文提出的轻量级路面裂缝检测方法进行评估,本文选取了查准率 (precision,  $P$ ), 召回率 (recall,  $R$ ),  $F1\_score$  作为评价指标。计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (7)$$

$$R = \frac{TP}{TP + FN} \quad (8)$$

$$F1\_score = 2 \times \frac{P \times R}{P + R} \quad (9)$$

式中:  $TP$  为检测到的图像区域是裂缝的像素个数,  $FP$  为图像区域内误检裂缝的像素个数,而  $FN$  为图像区域没有检测到裂缝的像素个数。

#### 3.2 损失函数

实验选用均方误差 (mean squared error, MSE), 作为优化模型参数的损失函数。均方误差将预测值与其对应的真实值之间的差值求平方后求和,最后求取平均。均方



误差越小,实际值和预测值之间的差异就越小。公式如下:

$$MSE = \frac{1}{N} \sum_{i=1}^m (y_i - y'_i)^2 \quad (10)$$

式中:  $N$  为样本的总数,  $y_i$  为第  $i$  个样本的实际值,  $y'_i$  为第  $i$  个样本的预测值。

### 3.3 模型设置

在本文模型的训练中,轮次为 40,批量大小为 2,优化器选用 Adam,初始学习率设置为 0.003,激活函数采用 ReLU 函数。该函数的优点是不需要进行除法和指数运算,因此其反向传播梯度求导的速度比 Sigmoid 函数更快。计算公式如下:

$$ReLU(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (11)$$

## 4 实验与结果

### 4.1 不同注意力机制对比实验

为了验证本文方法引入 ECA 注意力机制对特征关键信息的提取性能,与空间和通道注意力机制(convolutional block attention module,CBAM)和 SENet 注意力机制进行对比实验,两种注意力机制放置位置均与本文方法相同,实验结果如表 1 所示。由表 1 可以看到,与其他两种方法对比,本文方法在裂缝检测方面性能更好。在 DeepCrack 数据集上, F1\_score 值相比 GhostUNet + CBAM、GhostUNet+SENet 分别提升 2.44%和 1.94%。在 CFD 数据集上 F1\_score 值分别提升 1.44%和 5.34%,因此本文引入 ECA 注意力机制是有效的。

表 1 不同注意力机制的对比实验结果

数据集	方法	P/ %	R/ %	F1_score/ %
DeepCrack	GhostUNet+ CBAM	77.67	78.74	78.2
	GhostUNet+ SENet	78.58	78.81	78.7
	本文方法	<b>82.26</b>	<b>79.09</b>	<b>80.64</b>
	GhostUNet+ CBAM	56.62	<b>70.67</b>	62.87
CFD	GhostUNet+ SENet	<b>73.59</b>	49.19	58.97
	本文方法	61.74	67.1	<b>64.31</b>

### 4.2 与其他裂缝检测算法对比实验

本文方法基于 U-Net 模型,是一种结合编码器和解码器的全卷积网络的方法。为验证本文改进模型的有效性,选取近些年性能优异、同样为编码器—解码器结构或全卷积网络的模型作为对比方法。分别在 DeepCrack 和 CFD

数据集上,将这些与本文方法网络结构相似的裂缝检测算法 DeepCrack<sup>[26]</sup>、HED<sup>[27]</sup>、U-Net<sup>[28]</sup>、RCF<sup>[29]</sup>、SegNet<sup>[30]</sup> 进行对比实验。

1)DeepCrack: DeepCrack<sup>[26]</sup> 是一种用于像素级裂缝分割的算法,其主干网络是 VGG-16 的前 13 层,由全卷积网络和深监督网络组成。在编码和解码部分相同尺度的特征通过相互融合,可有效学习到多尺度特征。

2)HED: HED<sup>[27]</sup> 是一个有效的边缘检测网络,通过以全卷积网络和 VGG16 模型为基础进行多尺度、多层次的特征学习。

3)U-Net: U-Net<sup>[28]</sup> 是一种基于编码器和解码器的全卷积网络,本文方法以此为基础,由于其结构简单,而且通过拼接的方式实现特征融合,选取 U-Net 作为对比方法可以更加直观地对比分割效果。

4)RCF: RCF<sup>[29]</sup> 是一种基于 HED 改进的边缘检测方法。其结构为全卷积网络,利用多尺寸特征融合结构丰富了特征,可依靠反向传播训练学习。

5)SegNet: SegNet<sup>[30]</sup> 是一种进行像素级图像分割的编码器—解码器的全卷积网络。其通过将特征图的池化索引传递到上采样层来保存检测图像更加丰富的细节。

在 DeepCrack 数据集上的实验结果如表 1 所示,从表 2 结果中可以看出,本文方法在 DeepCrack 数据集上的 F1\_score 值相比 DeepCrack<sup>[26]</sup>、HED<sup>[27]</sup>、U-Net<sup>[28]</sup>、RCF<sup>[29]</sup> 和 SegNet<sup>[30]</sup> 分别提升了 26.14%、16.74%、13.94%、15.44%、3.64%,虽然 R 值比 SegNet 降低了 2.11%,但是 F1\_score 值为 80.64。综合考虑,该方法的裂缝检测精度最高。

表 2 在 DeepCrack 上的对比实验结果

方法	P/%	R/%	F1_score/%
DeepCrack <sup>[26]</sup>	53.5	55.5	54.5
HED <sup>[27]</sup>	59.3	69.2	63.9
U-Net <sup>[28]</sup>	69.4	64.1	66.7
RCF <sup>[29]</sup>	60.1	71.3	65.2
SegNet <sup>[30]</sup>	73.2	<b>81.2</b>	77.0
本文方法	<b>82.26</b>	79.09	<b>80.64</b>

在 CFD 数据集上的实验结果如表 3 所示。由表 3 知,与其他方法对比,本文方法在裂缝检测方面表现更为卓越。其中 F1\_score 值相比 DeepCrack<sup>[26]</sup>、HED<sup>[27]</sup>、U-Net<sup>[28]</sup>、RCF<sup>[29]</sup> 和 SegNet<sup>[30]</sup> 分别提升 11.31%、21.31%、15.01%、19.11%和 14.81%。但在 CFD 上的实验结果不如 DeepCrack 上的结果,这是因为 CFD 数据集中有大量的细小裂缝图像,增加了检测难度,这是所有方法面临的挑战。

表 3 在 CFD 上的对比实验结果

方法	P/%	R/%	F1_score/%
DeepCrack <sup>[26]</sup>	46.7	61.5	53.0
HED <sup>[27]</sup>	38.2	49.2	43.0
U-Net <sup>[28]</sup>	45.9	53.2	49.3
RCF <sup>[29]</sup>	41.5	49.5	45.2
SegNet <sup>[30]</sup>	42.0	60.2	49.5
本文方法	<b>61.74</b>	<b>67.1</b>	<b>64.31</b>

### 4.3 消融实验

为了进一步验证本文方法中的各个模块针对特征关键信息的提取性能是否有提升,本文针对 DeepCrack 数据集和 CFD 数据集进行了一系列消融实验。

在 DeepCrack 数据集上的消融实验结果如表 4 所示,原始 U-Net<sup>[28]</sup>的 P 值为 69.4%,R 值为 64.1%,F1\_score 值为 66.7%,将 U-Net 中的常规卷积替换为 Ghost 卷积和引入 ECA 模块后,P,R 和 F1\_score 明显提高,其原因是引入 ECA 模块后模型的特征提取能力增强,保留了路面裂缝中的局部特征信息。而引入残差连接结构后,在不改变卷积运算量的前提下将浅层特征与深层特征融合,进一步减少了特征的丢失,缓解了网络退化问题。从结果来看本文方法虽然 P 值低于 GhostUNet+ECA,但是综合来看 F1\_score 值最高,检测效果最好。GhostUNet+ECA 总体实验效果低于本文方法,这是因为 GhostUNet+ECA 因为网络层数的加深导致训练过拟合。

表 4 在 DeepCrack 上的消融实验结果

方法	P/%	R/%	F1_score/%
U-Net <sup>[28]</sup>	69.4	64.1	66.7
GhostUNet	69.93	66.37	68.1
GhostUNet+ECA	<b>84.06</b>	74.21	78.83
本文方法	82.26	<b>79.09</b>	<b>80.64</b>

在 CFD 数据集上的消融实验结果如表 5 所示,从结果来看由于 CFD 数据集充斥着很多细小裂缝,导致每种方法的检测精度不高。但本文方法 F1\_score 值相较 U-Net<sup>[28]</sup>提升 15.01%,与 GhostUNet 和 GhostUNet+ECA 相比分别提升 10.86%和 5.16%,这是因为引入 ECA 模块和残差连接后,减少了局部特征的丢失,使得对细小裂缝的提取效果增强,结果显示本文方法检测效果更好。

### 4.4 检测效果可视化对比

为了直观地比较本文方法与 U-Net、GhostUNet 和 GhostUNet+ECA 三种网络模型针对 DeepCrack 和 CFD

数据集检测效果,裂缝区域提取可视化效果如图 5 所示。

表 5 在 CFD 上的消融实验结果

方法	P/%	R/%	F1_score/%
U-Net <sup>[28]</sup>	45.9	53.2	49.3
GhostUNet	53.47	53.43	53.45
GhostUNet+ECA	55.35	63.5	59.15
本文方法	61.74	67.1	64.31

从检测效果来看,本文提出的改进方法是 4 种方法中最优的,在 DeepCrack 和 CFD 数据集上的裂缝检测表现更优,能够更清晰地定位裂缝区域,噪声少,对复杂裂缝的检测效果最完整,能够清晰辨别出裂缝。DeepCrack 数据集中,U-Net 检测的第 3 张裂缝区域在上部分呈现模糊的情况,这是因为 U-Net 模型在深层次特征融合方面效果不佳。GhostUNet 对两种数据集检测的效果也不理想,在 DeepCrack 数据集检测的第 2 张图像没有清晰检测出裂缝区域,这是因为 GhostUNet 模型特征提取能力较低,没有关注深层特征信息,无法完整提取特征位置信息。GhostUNet+ECA 对 DeepCrack 数据集上的检测效果也不理想,第 2 张检测图像部分裂缝无法检测出来;在 CFD 数据集上,第一张检测图像检测效果包含了大量噪声,检测效果不佳。这是因为未引入残差连接导致的训练过拟合,以至于检测结果不好。而本文方法在两个数据集上的检测效果与 3 种模型相较更出色,裂缝信息检测完整。

### 4.5 参数量比较

传统的 U-Net 结构,随着网络层数的加深,所需要的参数量会越来越庞大,导致模型训练的时间变长。将常规卷积替换为 Ghost 卷积,卷积的计算量会减少,将本文方法分别与 U-Net<sup>[28]</sup>、GhostUNet 和 GhostUNet+ECA 模型进行参数量对比,对比结果如表 6 所示。

表 6 4 种模型参数量对比结果

模型	参数量/MB
U-Net <sup>[28]</sup>	31
GhostUNet	<b>13.37</b>
GhostUNet+ECA	16.8
本文方法	16.8

由表 6 结果可知,Ghost+UNet 模型的参数量相较本文方法的参数量减少了 3.43 MB,这是因为此模型没有添加注意力模块;而模型 GhostUNet+ECA 与本文方法的参数量相同,这是因为本文方法仅引入残差连接机制,并不改变模型的参数量;但从消融实验可以看出本文方法在参数量等于 GhostUNet+ECA 模型的同时,检测精度更高。




图 5 4 种模型对两个数据集的裂缝区域可视化结果

## 5 结 论

本文提出基于注意力机制的 GhostUNet 路面裂缝检测方法,主要有以下结论:

为了能够精确识别路面裂缝区域同时兼顾实时性,将 U-Net 模型中的常规卷积改进为 Ghost 卷积,通过与 U-Net 等模型的参数量实验对比,本文方法的参数量减小了 14.2 MB,达到了轻量化的作用。

在上采样和下采样中引入 ECA 注意力和残差连接,加强了对路面裂缝的高低层特征融合感知能力,有效避免网络退化现象,并综合相关性能指标,本文方法在两个裂缝数据集上 F1\_score、P 和 R 的实验结果分别比 U-Net 平均提升了 14.48%、14.35% 和 14.45%,提升了路面裂缝检测的精度,使得本文方法具有较强的鲁棒性。

进行消融实验,在两个不同的路面裂缝数据集上评估不同模块的性能表现,以验证它们对模型的有效性。本文方法 F1\_score 值相比 U-Net、GhostUNet 和 GhostUNet+ECA 模型平均提高了 14.48%、11.7% 和 3.49%,结果表明本文方法引入模块的检测效果有效。

虽然本文方法在路面裂缝检测方面表现优异,但仍存在漏检问题,主要是因为损失函数的影响未考虑充分。因此,未来的研究方向之一是选择更合适的损失函数,以提高模型的性能并进一步增强其泛化能力。

## 参考文献

[1] OLIVEIRA H, CORREIA P L. Automatic roadcrack segmentation using entropy and image dynamic thresholding [C]. 17th European Signal Processing

Conference, 2009: 622-626.

- [2] NEJAD F M, ZAKERI H. An optimum feature extraction method based on wavelet-radon transform and dynamic neural network for pavement distress classification[J]. Expert Systems with Applications, 2011, 38(8):9442-9460.
- [3] CHA Y J, CHOI W, BIYTIKOZTURK O. Deep learning-based crack damage detection using convolutional neural networks [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5): 361-378.
- [4] LI L F, MA W F, LI L, et al. Research on detection algorithm for bridge cracks based on deep learning[J]. Acta Automatica Sinica, 2019, 45(9): 1727-1742.
- [5] 刘新根,陈莹莹,王雨萱,等.基于级联神经网络的隧道衬砌裂缝识别算法研究[J].铁道学报,2021,43(10): 127-135.
- [6] 余加勇,李锋,薛现凯,等.基于无人机及 Mask R-CNN 的桥梁结构裂缝智能识别[J].中国公路学报,2021, 34(12):80-90.
- [7] ZHANG L, YANG F, ZHANG Y D, et al. Road crack detection using deep convolutional neural network [C]. IEEE International Conference on Image Processing(ICIP). Phoenix, AZ, USA, 2016: 3708-3712.
- [8] 张华卫,贾文娟,张金龙,等.并联提取与特征融合注意力网络下的裂缝检测 [J]. 电子测量技术, 2022, 45(10):102-111.
- [9] LIU Y, YAO J, LU X, et al. DeepCrack: A deep

- hierarchical feature learning architecture for crack segmentation[J]. *Neurocomputing*, 2019, 338(3): 139-153.
- [10] YANG F, ZHANG L, YU J, et al. Feature pyramid and hierarchical boosting network for pavement crack detection [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(4): 1525-1535.
- [11] 曹锦纲, 杨国田, 杨锡运. 基于注意力机制的深度学习路面裂缝检测[J]. *计算机辅助设计与图形学学报*, 2020, 32(8): 1324-1333.
- [12] 孙美君, 吕超章, 韩亚洪, 等. 弱监督学习下的融合注意力机制的表面缺陷检测[J]. *计算机辅助设计与图形学学报*, 2021, 33(6): 920-928.
- [13] 张志华, 温亚楠, 慕号伟, 等. 结合双注意力机制的道路裂缝检测[J]. *中国图象图形学报*, 2022, 27(7): 2240-2250.
- [14] 杨秋媛, 李宁, 石林, 等. 基于空洞卷积与动态多核融合池化的裂缝检测[J]. *计算机工程与设计*, 2022, 43(12): 3529-3537.
- [15] 张伯树, 张志华, 张洋. 改进的 HRNet 应用于路面裂缝分割与检测[J]. *测绘通报*, 2022, 540(3): 83-89.
- [16] 陈涵深, 姚明海, 瞿金显. 基于 U 型全卷积神经网络的路面裂缝检测[J]. *光电工程*, 2020, 47(12): 67-77.
- [17] 刘凡, 王君锋, 陈峙宇, 等. 基于并行注意力 UNet 的裂缝检测方法[J]. *计算机研究与发展*, 2021, 58(8): 1718-1726.
- [18] 汪家宝, 牟怿. 基于混合损失 ResNet34-UNet 的路面裂缝分割方法[J]. *武汉轻工大学学报*, 2022, 41(6): 71-75, 113.
- [19] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted residuals and linear bottlenecks[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 4510-4520.
- [20] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: An extremely efficient convolutional neural network for mobile devices [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 6848-6856.
- [21] HAN K, WANG Y, TIAN Q, et al. GhostNet: More features from cheap operations[C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 1580-1589.
- [22] JIE, SHEN, SAMUEL, et al. Squeeze-and-excitation networks[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 7132-7141.
- [23] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 11534-11542.
- [24] 汤森, 闫文君, 方伟, 等. 基于视频图像的战斗机起落架检测[J]. *中国电子科学研究院学报*, 2022, 17(8): 729-735.
- [25] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. *IEEE Conference on Computer Vision and Pattern Recognition(CVPR)*, 2016: 770-778.
- [26] LIU Y, YAO J, LU X, et al. DeepCrack: A deep hierarchical feature learning architecture for crack segmentation[J]. *Neurocomputing*, 2019, 338(3): 139-153.
- [27] XIE S, TUZ. Holistically-nested edge detection[C]. *IEEE International Conference on Computer Vision*, 2015: 1395-1403.
- [28] RONNEBERGER O, FISCHER P, BROXT. U-net: Convolutional networks for biomedical image segmentation[C]. *International Conference on Medical Image Computing and Computer-assisted Intervention*, 2015: 234-241.
- [29] LIU Y, CHEN M M, HU X, et al. Richer convolutional features for edge detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 41(8): 1939-1946.
- [30] 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.

### 作者简介

郝子晔, 硕士, 主要研究方向为计算机视觉、目标检测及图像分割。

E-mail: conan\_ye2022@163.com