

DOI: 10.19650/j.cnki.cjsi.J2007162

结合特征复用注意力与精细化分层残差的 细微裂纹密集连续检测*

潘云龙, 王森, 张印辉, 陈明方
(昆明理工大学机电工程学院 昆明 650500)

摘要: 细微裂纹的高效识别对结构体早期故障诊断具有重要意义。图像分割等方法在处理复杂且带有断裂的细微裂纹时难以达到满意效果。因此, 将细微裂纹的识别问题转变为密集连续的中心点预测问题, 利用精细化分层残差模块构造特征提取器并结合具有特征复用的注意力模块提出一种细微裂纹检测方法。首先使用相同的矩形框沿裂纹轨迹密集连续地标; 其次对不同的精细化分层残差模块进行消融实验, 得到有利于细微裂纹特征提取的骨干网络; 最后结合具有特征复用的注意力模块与骨干网络对比了六种不同的特征复用方式。实验结果表明, 本文方法的最高和平均精度分别为 61.0% 和 54.7%, 与原模型相比分别提升 4.9% 和 6.3%, 成功识别细微裂纹及其局部断裂区域并抑制背景干扰。

关键词: 细微裂纹; 中心点检测; 分层残差; 注意力模块

中图分类号: TP391.41 TH14 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Densely continuous detection of micro cracks based on feature reuse attention and refined layered residual

Pan Yunlong, Wang Sen, Zhang Yinwei, Chen Mingfang

(College of Mechanical and Electrical Engineering, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: The effective identification of micro cracks is of great significance to the early fault diagnosis of structures. The image segmentation method and other methods are difficult to achieve satisfied results in the detection of micro cracks with complex shapes and broken area. Therefore, transforms the problem of micro cracks identification into a series of dense and continuous central point prediction. A feature extractor is established by using the refined layered residual module, and the feature reuse attention module is also utilized to propose a micro cracks detection method. Firstly, the same rectangular bounding box is used to label the crack track densely and continuously. Secondly, the ablation experiments are implemented on the different refined hierarchical residual module to obtain the backbone network which is conducive to the feature extraction of micro cracks. Finally, six different feature reuse methods are compared by combining the attention module with feature reuse and backbone network. Experimental results show that the highest and average accuracy of the proposed method are 61.0% and 54.7%, respectively, which are 4.9% and 6.3% higher than the original model. The proposed method successfully identifies the micro cracks and their local broken areas, and suppresses background interference in practical application.

Keywords: micro cracks; center points detection; hierarchical residual; attention module

收稿日期: 2020-11-24 Received Date: 2020-11-24

* 基金项目: 国家自然科学基金 (52065035, 51965029, 61761024)、云南省教育厅科学研究基金 (2019J0045)、云南省级人培项目 (KKS201801018) 资助

0 引言

结构体在长期施加外界交变载荷的过程中,会以细微裂纹的方式呈现出早期故障。而细微裂纹在重复施加载荷后,更会导致其随机扩展和宽度、深度尺寸的扩大,这不仅影响结构体的正常运作甚至存在严重的安全隐患。因此,结构体一旦出现早期细微裂纹,应当需要及时对其进行有效的健康监测。常见的裂纹检测不仅需要复杂的设备仪器且应用场景有限^[1]。如利用激光超声波与结构体作用^[2]或超声脉冲反射^[3]获取细微裂纹非线性信号等方法均需要昂贵的设备支持。得益于计算机设备的发展,深度学习在图像领域得到广泛应用。将全卷积神经网络与多尺度结构化森林^[4]、空间金字塔^[5]等方法相结合可实现复杂背景下的结构体裂纹分割,但受限有效特征较为有限的细微裂纹。结合迁移学习与数据增强等策略的卷积神经网络虽然有利于训练细微裂纹分类器,但不适用于裂纹区域较小的裂纹^[6-7]。借助特征匹配的三维定位方法可实现精密微小缺陷的检测,但难以实现密集连续的小目标检测^[8]。此外,复杂背景下细微裂纹在图像中难以用肉眼察觉且局部位置存在模糊断点等问题,使得高效检测结构体表面的细微裂纹进一步面临挑战。

针对早期细微裂纹难以检测的问题,本文提出将细微裂纹近似为密集连续特征点组成的线,通过相同的矩形方框沿裂纹轨迹完成标注并利用中心点预测每一个细微裂纹特征点。其次,利用精细化分层残差模块搭建特征提取器来实现同尺度下多语义特征的兼顾,这有助于扩大各尺度中精细化裂纹块浅层粗糙特征的感受野。针对细微裂纹局部区域出现间隙、背景杂质干扰等问题,提出一种具有特征复用的注意力模块,并将其应用于细微裂纹及其相似背景的特征信息化区分。同时,利用输入特征或全局池化信息计算自适应权值并将结果加权到输出特征中实现特征复用,使注意力受自身特征分布的影响而自适应地调整输出特征的分布。实验表明,本文方法的最高精度和平均精度分别达到 61.0% 和 54.7%,相比原模型分别提升 4.9% 和 6.3%;并在线性检测方法比较中和实际检测中成功识别细微裂纹及其局部断裂区域并减少了背景杂质干扰。

1 相关工作

在实际工程应用中及时发现结构体表面的细微裂纹对早期维护具有重要意义,将测量仪器和图像处理技术相结合可完成裂纹识别及其量化分析^[9],但受限图像质量或裂纹特征。而 DeepLab 系列^[10-13]、FCN^[14]等深度

学习算法通过能完整的将裂纹轮廓从背景中分割出来,但像素级的处理具有较高的时间成本且处理速度较为缓慢;相比之下,目标检测算法弥补了像素级处理的不足但需要面临形态各异的细微裂纹带来的挑战。若将细微裂纹分成无数个相同的精细化裂纹块,并将密集连续的各块中心点进行轨迹连接,便可形成一条重合于细微裂纹的轨迹线。因此,利用相同的小矩形框依次对精细化裂纹块进行标注,再借助精细化裂纹块的中心点预测细微裂纹轨迹。精细化裂纹块的特征差异小且排列方式具有规律性,能够在大量减少多余背景的同时有效控制不同背景中细微裂纹的差异。

细微裂纹属于微缺陷的一种,有效地提取细微的缺陷特征是研究的难点之一。利用超声与数字全息高分辨率成像技术^[15]或结合磁光成像与灰度共生矩阵提取细微缺陷特征,并通过神经网络进行分类预测^[16]均可有效识别细微缺陷,但未能利用深度学习算法直接提取细微缺陷特征。基于 Mask-RCNN^[17]通过消融实验得到最优模型进一步优化网络^[18],为依靠深度学习算法实现缺陷检测提供实验思路。基于 Faster R-CNN^[19]筛选锚框训练工业 CT 图像缺陷实现卷积神经网络自动提取目标特征,可满足 9×9 pixel 以上的缺陷特征^[20]。若将微缺陷抽象成对图像某些候选区域的分类与回归时,锚框模型会在噪声背景下影响微弱信号的判别,从而产生大量错误候选框并导致错误检测^[21]。因此,本文考虑使用无锚框的 CenterNet^[22]深度学习算法进行细微裂纹的特征提取和中心点预测。这种方式不仅能解决锚框带来的负面影响,基于点的预测也能够有助于寻找精细化裂纹块的中心位置。

利用小矩形框标注虽然能有效缓解不同背景中细微裂纹间存在的特征差异问题,但要求深度学习算法能充分提取微小的精细化裂纹块特征,并满足大量密集连续的中心点预测。精细化裂纹块属于小目标,融合多种优化模型的方法、减少多余的背景信息或设计专用检测模型等都有利于小目标检测^[23]。由精细化分层残差模块^[24]构建的骨干网络将特征逐层提取与融合,能有效提升各网络层的感受野^[25-26],并在显著目标检测中优势明显。显著目标检测侧重于关注图像中某种类型的目标,如细微裂纹图像中包含大量背景信息而精细化裂纹块便是需要关注的显著目标。因此,利用精细化分层残差构建骨干网络有利于获得更多密集连续的精细化裂纹块特征。精细化裂纹块的特征与某些背景杂质是具有一定的相似性,有可能会影响细微裂纹特征的提取。而融合不同风格的注意力模块却有助于显著目标检测,并在小目标检测方面表现出色^[27]。如利用注意力结构自适应加权可优化分类器对时频特征的认识,实现齿轮箱端到端故障诊断^[28]。将视觉注意力提取的运动区域作为显著

区域可完成快速运动估计^[29],在深度学习网络中引入具有空间感知的自注意力,能够有效解决大规模密集目标特征的提取^[30]。因此,本文将具有特征复用的注意力模块与精细化分层残差模块构建的骨干网络相结合,突出细微裂纹块的表面特征并减少错误检测背景信息的概率。具有特征复用的注意力模块在自适应权值的作用下将更加关注特征映射的活跃区域,有利于进一步区分细微裂纹与近似裂纹的背景区域。

2 本文方法

2.1 基于点的细微裂纹检测

大多数目标检测算法利用矩形方框标识需要预测的目标,其中基于锚框的检测算法会尽可能多的寻找这些矩形方框的位置和类别。为防止同一目标被多个不同的矩形方框重复标记,这些算法通常会借助一个后处理方式从中筛选出一个最高概率得分的方框作为最佳预测结果。对于密集连续标注的细微裂纹来说,其相邻两矩形方框间的特征差异较小且所有矩形方框均有规律的沿着疲劳裂纹轨迹排列,所以矩形框出现的位置将特别集中。而利用交并比删除重复矩形方框的后处理方式将容易导致概率得分相对较低的真实方框大量丢失。

为防止密集连续的矩形方框大量丢失,本文首先利用无需后处理的 CenterNet 检测算法确定一系列密集连续矩形方框可能存在的位置,运用高斯滤波将方框的中

心位置转化为关键点,从而得到目标关键点热力图;其次通过最大池化筛选出关键点特征热力图中较为接近细微裂纹特征的关键点作为估计细微裂纹的中心点元素;最后通过一系列密集连续的中心点形成一条与细微裂纹相互重合的线。这条重合线相比于细微裂纹具有较高的可识别度,能清晰地描绘细微裂纹的疲劳轨迹。在寻找中心点的过程中,高斯核的表达式如下:

$$Y = e^{-\frac{(x-\hat{p}_x)^2 + (y-\hat{p}_y)^2}{2\sigma_p^2}} \quad (1)$$

式中: \hat{p} 表示中心点的位置; σ_p^2 是标准方差。利用最大池化筛选中心点的表达式如下:

$$\hat{Y} \in [0, 1]^{W \times H \times C} \quad (2)$$

式中: $\hat{Y} = 1$ 表示存在的目标中心点; $\hat{Y} = 0$ 表示只检测到背景; W, H 分别表示输入图像宽和高的尺寸; R 是尺寸的缩放比例; C 代表关键点的类型数。虽然通过密集连续的中心点与矩形方框角点的联系,可用于计算矩形方框的训练损失,但本文提出的细微裂纹检测方法只需预测其中心点即可。基于点的细微裂纹检测方法如图 1 所示,在第 k 个目标框中利用角点坐标 (x_1^k, y_1^k) 和 (x_2^k, y_2^k) 可将其中心点的坐标 P 和小目标的框边尺寸 S 表达为:

$$P^k = \left(\frac{x_1^k + x_2^k}{2}, \frac{y_1^k + y_2^k}{2} \right) \quad (3)$$

$$S^k = (|x_1^k - x_2^k|, |y_1^k - y_2^k|) \quad (4)$$

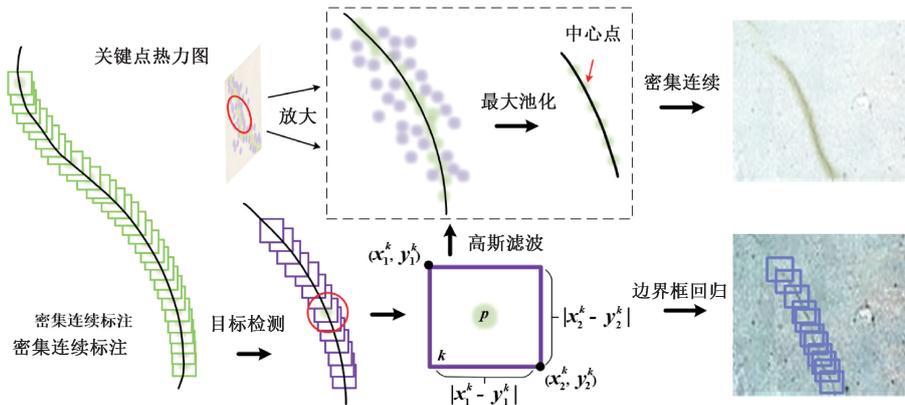


图 1 基于点的细微裂纹检测方法

Fig. 1 The micro crack detection method based on points

2.2 网络模型

如图 2 所示,本文将网络模型分为浅层网络,骨干网络,颈部和头部。首先,利用浅层网络初步提取精细化裂纹块特征,经最大池化送入由精细化分层残差模块搭建的骨干网络中,实现同尺度语义特征的兼顾并有助于扩大各尺度中精细化裂纹块浅层粗糙特征的感受野。在骨干网络中,相邻两精细化分层残差模块间通过最大池化

进行降采样并同时筛选出较为活跃的特征映射。其次,将具有特征复用的注意力模块放置在网络颈部,在骨干网络输出的高维特征映射中有助于裂纹特征活跃区域的自适应调整。最后,将 3 个可变形卷积模块^[31]放置在网络头部,最终结合中心点检测算法实现细微裂纹检测。

图 3 为精细化分层残差模块的结构。首先使用 1×1 的卷积核提取输入特征,再沿通道方向对提取结果进行

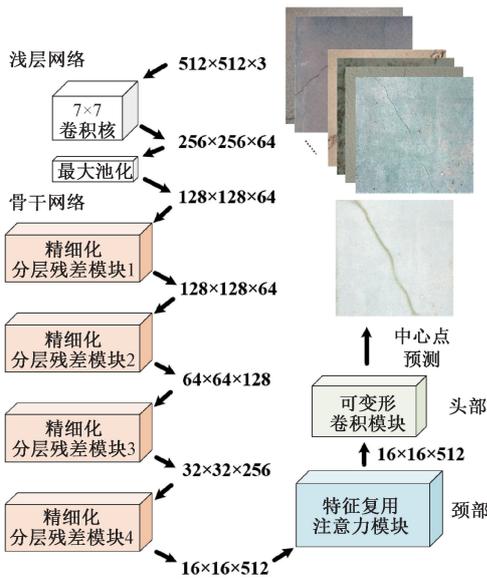


图2 网络模型结构

Fig. 2 The structure of network module

恒等均分,得到多个不同通道尺度的特征子块 X_i 。其次,通过多个卷积宽度相同的 3×3 卷积核分别提取 X_i 的特征并得到多个输出特征。最后,在通道维度上拼接所有输出特征得到重组特征 Y_i ,利用 1×1 卷积核压缩通道信息得到最终输出。精细化分层结构中各层间存在残差关系如下所示:

$$Y_j = \begin{cases} x_j, & j = 1 \\ x_j + y_{j-1}, & 1 < j \leq i \end{cases} \quad (5)$$

相比于普通残差模块^[32],精细化分层残差模块每个特征子块 $X_j(1 < j \leq i)$ 都能学习来自 X_{j-1} 的特征。在不消耗大量运行时间的前提下,利用精细化分层结构可以从输入特征中够获取更多通道信息,这有助于进一步丰富骨干网络的感受野。因此,不同的精细化分层结构和卷积宽度将影响细微裂纹特征的感受野。此外,特征较为

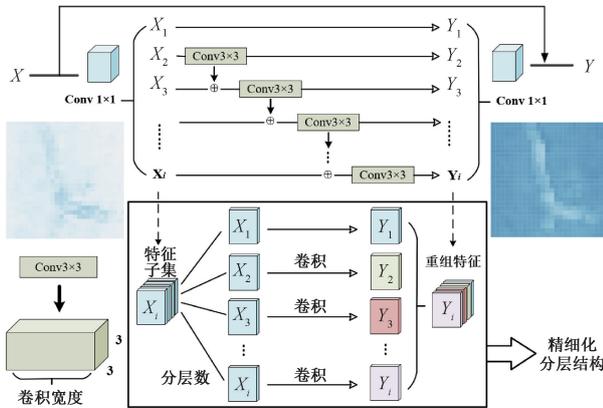


图3 精细化分层残差模块

Fig. 3 Refined hierarchical residual convolution block

单一的精细化裂纹块有着丰富的浅层粗糙信息,而所需深层特征较为有限,因此较深的骨干网络未必产生较好的检测效果。

可变形卷积模块如图4所示,将输出3个用途不同的特征映射,分别用于预测目标中心点、中心点偏置及目标框尺寸损失。因此,模型的损失函数可表示为:

$$L = L1 + L2 + L3 = \frac{1}{N} \sum_{xyc} (1 - \hat{Y}_{xyc})^\alpha \log(\hat{Y}_{xyc}) + \lambda_o \left(\frac{1}{N} \sum_{k=1}^N |\hat{S}_p - S| \right) + \lambda_s \left(\frac{1}{N} \sum_p |\hat{O}_p - (p - \bar{p})| \right) \quad (6)$$

其中, α, λ_s 和 λ_o 表示超参数; \hat{Y}_{xyc} 表示热力图的关键点; N 是关键点存在的总个数; \hat{O}_p 是中心点偏移量; $(p - \bar{p})$ 是单个中心点坐标损失; $\hat{S}_p - S$ 是单个目标边界框大小损失。

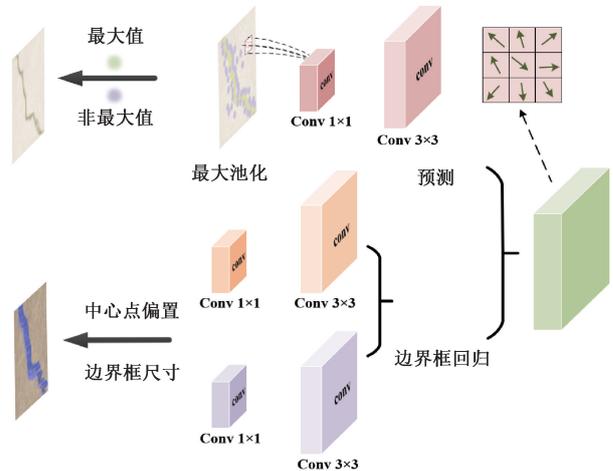


图4 可变形卷积模块

Fig. 4 Deformable convolution module

2.3 特征复用注意力机制

人类在观察某个场景时会通过场景中的部分信息判断总体情况,并非同时处理整个场景的信息^[33],而深度学习根据这一特点引入了注意力机制,让神经网络有区别的对待特征映射的各部分区域,使其关注重点信息并忽略次要信息。在结构体表面的细微裂纹中相邻两精细化裂纹块之间的特征差异性较小,且与背景杂质具有一定的相似性。本文利用注意力机制可关注活跃区域的特点计算自适应权值并加权在注意力机制的输出特征中。将注意力特征以权值的形式进行特征复用,使得注意力模块可结合自身特点实现自适应地调整活跃区域的比例,从而提升细微裂纹与背景杂质的区分能力。

通道注意力和空间注意力均可用于重新标定输入图像的特征,若沿通道维度依次进行拼接,则属于经典的注意力机制卷积模块^[34]。如图5所示,通道注意力和空间注意力均采用全局池化获取丰富的全局信息,区别在于

通道注意力沿通道方向逐层进行全局池化,而空间注意力侧重于同一位置不同通道的差异。在通道方向上逐层进行全局最大池化可提取每个通道中精细化裂纹块较为明显的纹理特征,而全局平均池化则将细微裂纹特征与背景信息相互融合。通道注意力利用多层感知机学习通道方向上的特征分布,并将输出结果相加后通过激活函数得到最终输出。相比之下,通道注意力有助于判断特征映射中哪些内容与细微裂纹特征有关;而空间注意力侧重于细微裂纹特征与背景之间的位置差异。

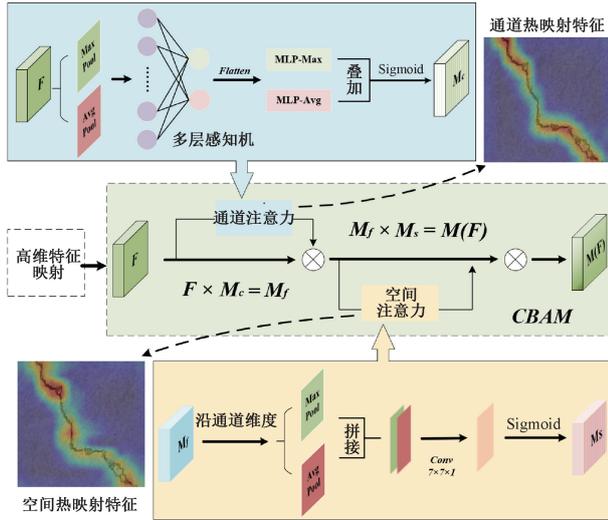


图 5 注意力机制卷积模块

Fig. 5 Convolution block of the attention module

为突出结构体表面细微裂纹的纹理特征,本文利用输入特征或全局池化特征计算自适应权值并将其加权在输出特征中。通道注意力受到自适应权值的影响将具有自适应调整输出特征的能力。若将输入特征沿通道方向进行归一化处理可得到输入特征在通道维度上的特征分布。将该特征分布作为一种权值与通道注意力的输出特征相乘,有助于调整通道维度的总体分布特点。由于全局最大池化可得到各通道中特征最活跃的区域,而全局平均池化有助于融合各通道的上下文信息使得特征分布更加均匀。利用全局池化信息可计算有利于放大活跃区域的另一种权值,并将其加权在多层感知机的输出中,有助于调整各层通道输出特征的分布特点。全局池化特征复用算法如算法 1 所示,输入特征复用算法如算法 2 所示,特征复用注意力算法如算法 3 所示。

算法 1 全局池化特征复用算法

输入变量: F

输出变量: FR_{M_C}

```
1: [ Max_Pool, Avg_Pool ] ← Global_Pooling ( F )
```

```
2: [ Max_out, Avg_out ] ← MLP ( Max_Pool, Avg_Pool )
3: while search_best_reused_methods do
4:   if Feature Reused Method_1 then
5:     W1 ← Max_out / ( Max_out + Avg_out )
6:     W2 ← Avg_out / ( Max_out + Avg_out )
7:   else if Feature Reused Method_2 then
8:     [ Sg_Max_out, Sg_Avg_out ] ← Sigmoid ( Max_out, Avg_out )
9:     W1 ← Sg_Max_out / ( Sg_Max_out + Sg_Avg_out )
10:    W2 ← Sg_Avg_out / ( Sg_Max_out + Sg_Avg_out )
11:   else if Feature Reused Method_3 then
12:     W1 ← Sigmoid [ Max_out / ( Max_out + Avg_out ) ]
13:     W2 ← Sigmoid [ Avg_out / ( Max_out + Avg_out ) ]
14:   else
15:     [ W1, W2 ] ← Other_Feature_Reused_Methods
16:   end
17: FR ← Multiply [ ( W1, W2 ), ( Max_out, Avg_out ) ]
18: [ FR_Max, FR_Avg ] ← FR
19: G ← Add ( FR_Max, FR_Avg )
20: FR_{M_C} ← Sigmoid ( G )
21: Return FR_{M_C}
```

算法 2 输入特征复用算法

输入变量: F

输出变量: FR_{M_I}

```
1: while search_best_reused_methods do
2:   if Channel_Dimension then
3:     FR_F ← Softmax ( F, dimension = 1 )
4:   else if Batch_Dimension then
5:     FR_F ← Softmax ( F, dimension = 0 )
6:   end
7: FR_{M_I} ← Multiply ( F, FR_F )
8: Return FR_{M_I}
```

算法 3 特征复用注意力算法

输入变量: F, FR_{M_C}, FR_{M_I}

输出变量: FR_{CBAM}

```
1: while select_best_reused_function do
2:   if Reused_FR_{M_C} then
3:     Mt ← Multiply ( F, FR_{M_C} )
4:   else if Reused_FR_{M_I} then
5:     Mt ← Multiply ( F, FR_{M_I} )
6:   else if Reused_FR_{M_C}_and_FR_{M_I} then
```

```

7:      Mt ← Multiply ( F, FR_Mc, FR_Ml )
8:  end
9:  [ Max_Pool, Avg_Pool ] ← Global_Pool ( Mt )
10: Ms_Conv ← Concat ( ( Max_out, Avg_out ), dimension=1 )
11: Ms_Vec ← Conv_7×7×1 ( MS_Conv )
12: Ms ← Sigmoid ( Ms_Vec )
13: Return Ms
14: M ( F ) ← Multiply ( Mt, Ms )
15: FR_CBAM ← M ( F )
16: Return FR_CBAM

```

3 实验与讨论

3.1 实验准备

本文在台式机(Inter(R) Core(TM) i7-9700 CPU @ 3.00 GHz, GPU NVIDIA GeForce RTX 2080S, 16 GB 运行内存, Windows 10-64 bit, 深度学习框架为 PyTorch 1.2, 配置 CUDA 10.0 版本和 cudnn 7.6.4 神经网络加速库)上运行 CenterNet 及其改进模型。由于目前未有公开的结构体表面细微裂纹数据集, 本文使用尼康 D5300 型号相机在水泥地、墙体和瓷砖等表面进行拍摄, 共得到 620 张尺寸为 512×512 的多背景细微裂纹图像, 并从中随机抽取 400 张作为训练数据集、100 张作为验证数据集和 120 张作为测试数据集。使用 LabelImg 工具包密集连续的标注细微裂纹特征, 并将其转换为 COCO 格式后进行训练。训练使用迭代的训练策略, 并将损失函数的超参数 α , λ 和 λ_0 分别设置为 2, 0.1 和 1。设置初始学习率为 0.001, 权重衰减系数为 0.0005, 动量为 0.9。总迭代次数为 500 次并在迭代训练 360 次和 420 次后依次衰减 10 倍学习率。最后通过平均召回率、最高精度、平均精度和训练损失进行定量比较。训练损失如式(6)所示, 其余计算式如下:

$$AR = \frac{1}{N} \sum \frac{TP}{TP + FN} \quad (7)$$

$$P = \frac{TP}{TP + FP} \quad (8)$$

$$AP_{50} = \begin{cases} \text{Max}[P_1, P_2, \dots, P_i] & AP_{50} \in \text{Max} \\ \frac{1}{N} \sum_{i=1}^N P_i & i = [1, N]; \text{otherwise} \end{cases} \quad (9)$$

其中, N 是训练次数; TP 表示预测正确的正样本; FP 表示负样本预测为正样本; FN 表示正样本预测为负样本; AR 表示平均召回率; P 表示在交并比阈值为 0.5 时的精度。其中, AP_{50} 包含最高精度和平均精度, 模型每训练 20 次计算一次 AP_{50} 和 AR 。其中, 最高精度和平均精度

分别表示模型可拥有的最佳检测性能和总体检测性能。

3.2 实验结果的定量分析

如表 1 所示, 通过骨干网络的消融实验结果发现 RH-Res_50 的性能较好。骨干网络较浅的 RH-Res_26 由于缺乏足够的特征表达能力, 其检测效果较差; 而较深的 RH-Res_101 拥有较强的特征拟合能力, 虽然损失值收敛情况良好但精度相对较低。RH-Res_50 中卷积宽度和分层数分别为 26 和 4。本文在此基础上依次将卷积宽度调整为 48、14, 并在 2~8 范围内选用不同的 scale 值。当卷积宽度不变且分层数增加到 6 时, 检测精度略微提升而增加到 8 时性能反而下降。当卷积宽度减少为 14 时, 各个分层提取的细微裂纹特征较少, 虽然增加分层数可以获得更加丰富的融合特征, 但检测性能并没有得到提高。当卷积宽度增加到 48 时, 模型的检测性能提升明显。其中, 分层数为 2 时, 平均精度达到 48.4%; 当分层数为 6 时, 局部精度最高可达到 57.6%。因此, 本文选取拥有最高平均精度的 RH-Res_50+width48_scale_2 网络作为下一步特征复用注意力实验的骨干网络。

表 1 骨干网络消融实验结果

Table 1 The results of ablation experiment on backbone

方法	骨干网络	AR/%	AP ₅₀ /%		Min Loss (×10 ⁻³)		
			Max	Mean	L1	L2	L3
Res_34	3-4-6-3	26.3	54.2	46.9	464	295	193
RH-Res_26	2-2-2-2	25.8	54.1	44.7	494	368	200
RH-Res_50	3-4-6-3	26.6	55.1	47.3	459	310	192
RH-Res_74	3-12-6-3	26.9	54.5	46.7	515	414	204
RH-Res_101	3-4-23-3	24.6	53.6	44.7	456	324	191
RH-Res_50+width26_scale4		26.6	55.1	47.3	459	310	192
RH-Res_50+width26_scale6		26.3	55.9	48.0	458	302	191
RH-Res_50+width26_scale8		27.6	54.2	47.5	464	324	192
RH-Res_50+width48_scale2		27.2	56.1	48.4	458	313	191
RH-Res_50+width48_scale4		26.7	56.1	44.8	482	307	199
RH-Res_50+width48_scale6		27.3	57.6	47.2	459	318	190
RH-Res_50+width14_scale4		27.0	54.9	46.3	464	351	193
RH-Res_50+width14_scale6		26.0	52.8	44.6	455	308	192
RH-Res_50+width14_scale8		26.1	53.4	45.1	460	309	192

本文基于 RH-Res_50+width48_scale_2 分别比较 2 种不同的输入特征复用模块和 3 种不同的全局池化特征复用模块, 实验结果如表 2 所示。其中, 通道维度的输入特征复用模块在总体平均精度方面提升显著且精度变化较为稳定。全局池化特征复用模块中方法 2 和方法 3 都有助于模型性能的提升。其中, 方法 2 在精度方面提升较为显著。将通道维度的输入特征复用模块与全局池化

特征复用模块相结合,发现 FR_ M₁ C+FR_ M_C M3 模块的最高精度和平均精度达到 61.0% 和 54.7%,与 RH-Res_50+width48_scale_2 相比分别提升了 4.9% 和 6.3%。此外,本文在局部精度最高的 RH-Res_50+width48_scale_6 骨干网络中使用相同的特征复用模块,发现仍然有助于改善模型的性能。两个实验的训练损失变化曲线如图 6 所示,精度变化曲线图 7 所示。

3.3 中心点实验分析

不同标注方式的检测效果如图 8 所示。首先将相同的矩形方框有规律地标注在细微裂纹轨迹上,再通过中心点检测算法得到细微裂纹表面的矩形方框中心点。当标注间距从 2 倍减少到 0.5 倍时,矩形方框将密集连续地分布在细微裂纹轨迹上,其中心点将连成一条宽于细微裂纹宽度且重合于裂纹轨迹的线,最终实现细微裂纹的识别。

表 2 不同特征复用模块对比

Table 2 Comparison of different features reused modules

特征复用模块	AR/%	AP ₅₀ /%		Min Loss (×10 ⁻³)		
		Max	Mean	L1	L2	L3
RH-Res_50+width48_scale2	27.2	56.1	48.4	458	313	191
+FR_ M ₁ Batch	24.4	52.9	42.3	462	286	192
+FR_ M ₁ Channel	26.4	55.5	51.4	460	291	192
+FR_ M _C Method_1	26.9	57.2	48.5	465	295	194
+FR_ M _C Method_2	28.3	60.1	52.9	458	289	192
+FR_ M _C Method_3	29.0	57.8	51.8	469	299	194
+FR_ M ₁ C+FR_ M _C M2	25.5	54.8	48.2	465	301	191
+FR_ M ₁ C+FR_ M _C M3	29.3	61.0	54.7	465	301	191
FR_ M ₁ C+FR_ M _C M3_48_6	28.8	57.2	51.7	480	334	196

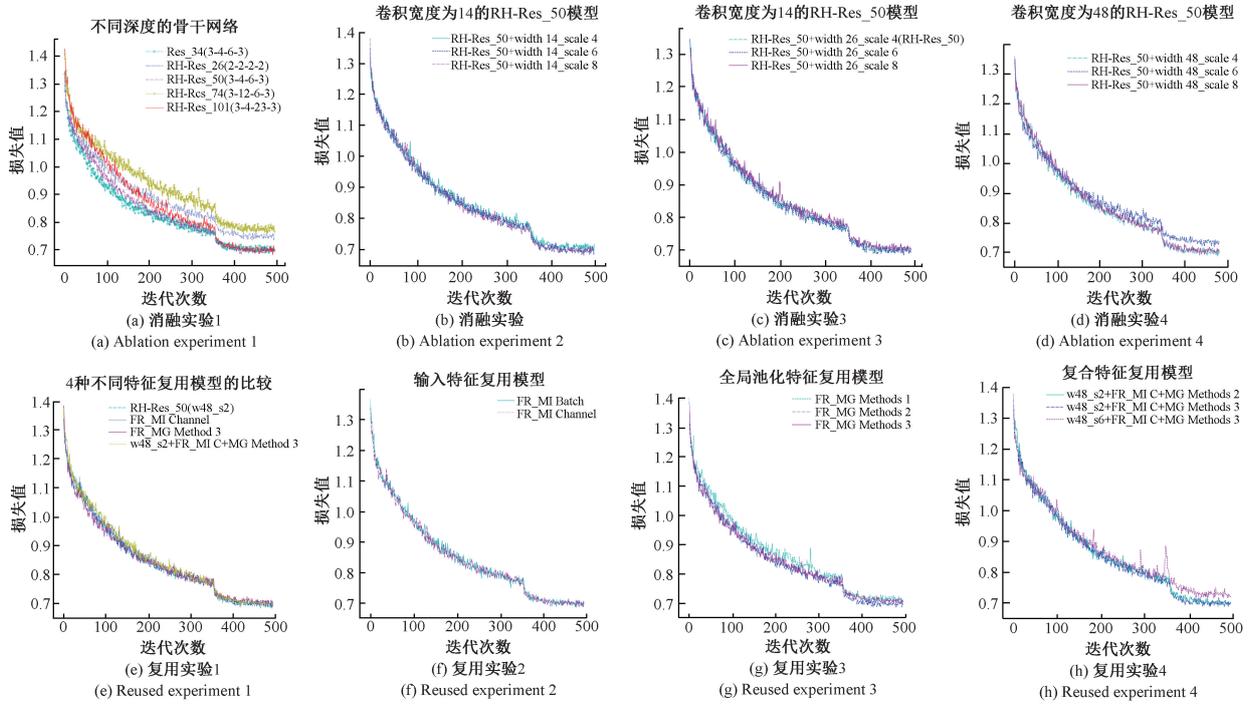
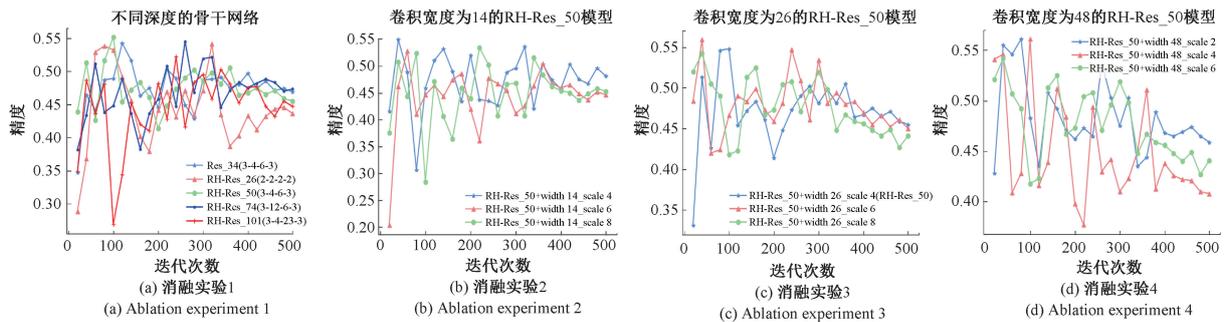


图 6 两个实验的损失曲线

Fig. 6 The loss curves of two experiments



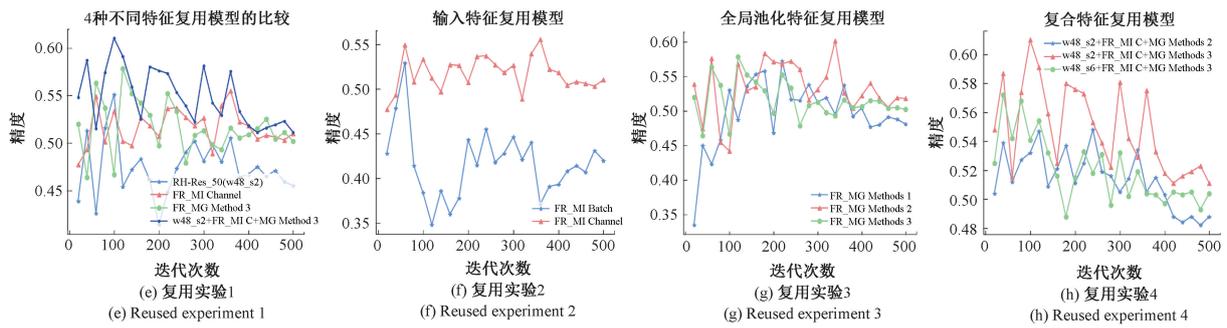


图7 两个实验的精度变化曲线

Fig. 7 The average precision curves of two experiments

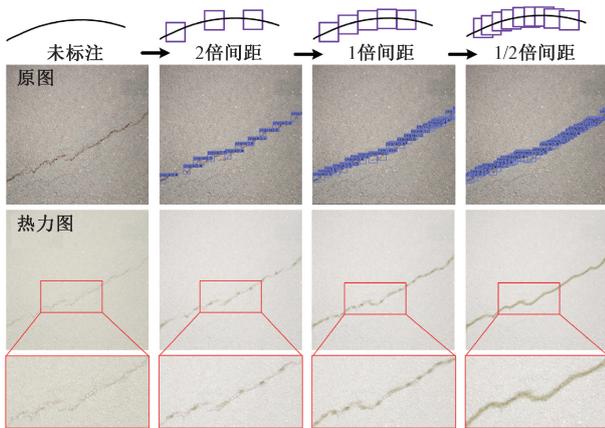


图8 不同标注方式的检测效果比较

Fig. 8 Comparison of detection effects of different labeling methods

在 512×512 的图像中细微裂纹宽度大多小于 5 pixel。如图 9 所示的细微裂纹宽度约为 2 pixel, 标注框的边长约为 5 pixel, 经过前向传播计算可以得到边界框及其对应的中心点。再经过高斯滤波处理, 中心点将变

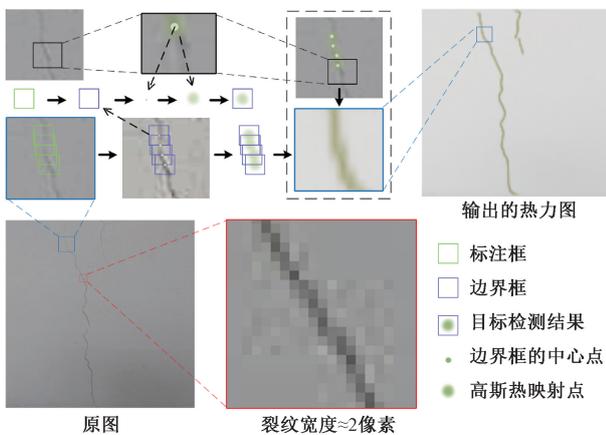


图9 细微裂纹的检测过程

Fig. 9 Illustration of micro crack detection process

成一个直径小于边界框边长但大于裂纹宽度的热映射点。这些热映射点有规律地分布于热力图中, 其中心点与边界框中心点重合。利用热映射点的特点可解决细微甚至模糊的细微裂纹难以用肉眼识别的问题。

3.4 实验结果的定性分析

本文选取残差网络 (Res₃₄)、两种精细化分层残差网络以及具有特征复用模块的精细化分层残差网络进行定性比较。其中, 两种精细化分层残差分别是卷积宽度为 26、分层数为 4 的 RH-Res_{50_w26_s4} 和卷积宽度为 48、分层数为 2 的 RH-Res_{50_w48_s2}。在 RH-Res_{50_w48_s2} 骨干网络的基础上同时嵌入通道维度的输入特征复用模块和第 3 种全局池化特征复用模块将得到本文方法。

1) 热力图检测结果比较

细微裂纹在局部区域存在不同程度的裂纹间隙。如图 10 第 3 行图组实线所示, 具有背景杂质的图像中 RH-Res_{50_w26_s4} 无法识别受背景干扰的间隙区域, 其余方法均察觉到间隙存在但本文方法的误差相对较小。如图 10 第一和第四行图组实线框所示, 较模糊的间隙区域只有本文方法可进行有效识别, 其余方法均将间隙区域标记为裂纹。如图 10 第 2 行图组实线框所示, 在背景杂质相对较少且间隙明显的区域, 未使用特征复用注意力模块的网络所识别的间隙区域较为粗糙。由于精细化分层残差网络比普通残差网络有着更大的模型感受野。而较大的模型感受野使得高维特征映射中细微裂纹和背景特征的信息增加, 因此容易将部分裂纹间隙区域错误标记为裂纹特征。本文方法利用特征复用注意力模块有选择的关注大感受所提供的特征信息, 有助于前向传播计算出的中心点落在裂纹轨迹内, 所以输出的热映射点相对细致。同理, 如图 10 第 2 组图实线框所示, 本文方法在处理细微裂纹的末端位置时表现较好。如图 10 第 4 组图虚线框所示, 本文方法实现了微小甚至模糊的裂纹间隙识别。

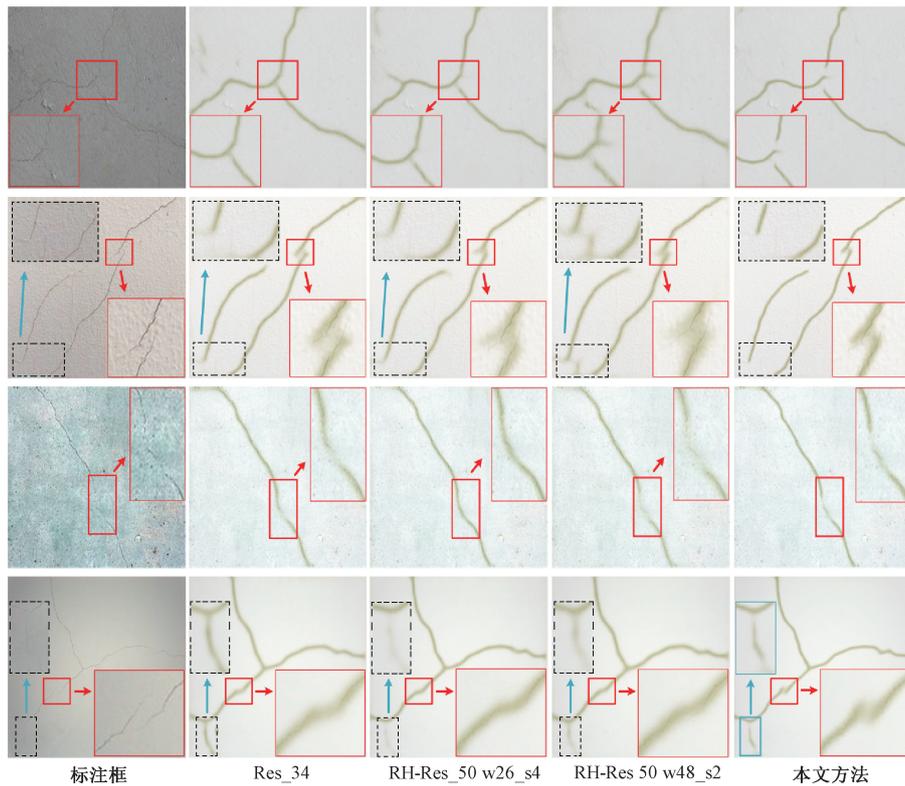


图 10 热力图检测结果

Fig. 10 Detection results of heatmap

2) 边界框回归结果分析

在经典的目标检测模型中每个回归的边界框都对应一个独立的目标,并在训练过程中逐渐接近于标注的边界框(GT)。在本文提出的细微裂纹检测方法中,回归的边界框不再是对应某个独立的目标,而是目标的局部区域。由于标注框中的精细化裂纹特征大多为块黑色细线,而且不同的标注框间特征差异小。因此在训练过程中细微裂纹上的各个精细化裂纹块难以有效进行端到端回归。如图 11 第 4 行图组所示,虚线框中的标注框有规律地排列,而实线框中回归的边界框位置与 GT 是存在一定差异的。另一方面,如图 11 第 3 行图组黑色框所示,在同一条裂纹上,回归的边界框大小仍然存在差异。因此,所提方法在目标检测模型性能评估中并未达到较高精度。但在密集连续的前提下,边界框位置和大小回归误差并不会给热力图带来太大影响。

细微裂纹图像中有效的裂纹特征极为有限,如宽度为 4 个像素的裂纹在高维特征映射中仅占 1/8 个像素,且与背景纹理或黑色斑块具有一定的相似性。如图 11 中标记的圆圈和箭头所示,Res_34 在裂纹末端位置出现少量漏检,RH-Res_50_w26_s4 和 RH-Res_50_w48_s2 在图像边缘区域出现错误预测的情况较为严重。本文将注意力模块具有选择性的关注图像局部区域的特点与具有

大感受野的骨干网络相结合以减少漏检和错检。因为精细化分层残差所扩大的感受野中也包含背景信息,这对于裂纹特征的判断是具有一定影响的,但也为特征复用注意力模块提供了丰富的信息参考。精度是反映目标检测模型性能的统计量,而本文方法所提升的精度主要表现在控制边界框位置和大小回归误差、边界框的中心点与裂纹轨迹的偏置误差两个方面。

3.5 与其他方法比较

本文引入 Steger、Canny 和 Prewitt 3 种线性检测方法与热力图及其在阈值为 0.5 时的二值图进行比较。如图 12 所示,原图(a)中包含粗裂纹和细微裂纹。如方框所示,由于 Canny 和 Prewitt 线性检测方法更关注边缘信息,容易受到背景污渍的影响。其中,裂纹检测结果容易出现局部断裂且细微裂纹的检测结果并不易于肉眼观察。其次分别将原图(b)及其热力图和二值图送入 Steger 高斯线性检测器,实验结果表明该方法在背景清晰且裂纹特征较明显时适用。线性检测与本文方法的区别在于线性检测方法偏向像素级处理。一方面在调整阈值时不同场景中裂纹的检测效果各异,另一方面图像中的背景污渍、凹槽等非裂纹目标容易与裂纹混淆。而基于深度学习算法的本文方法属于图像级处理,利用特征提取器获取高维特征映射并从中学习或预测裂纹特征。

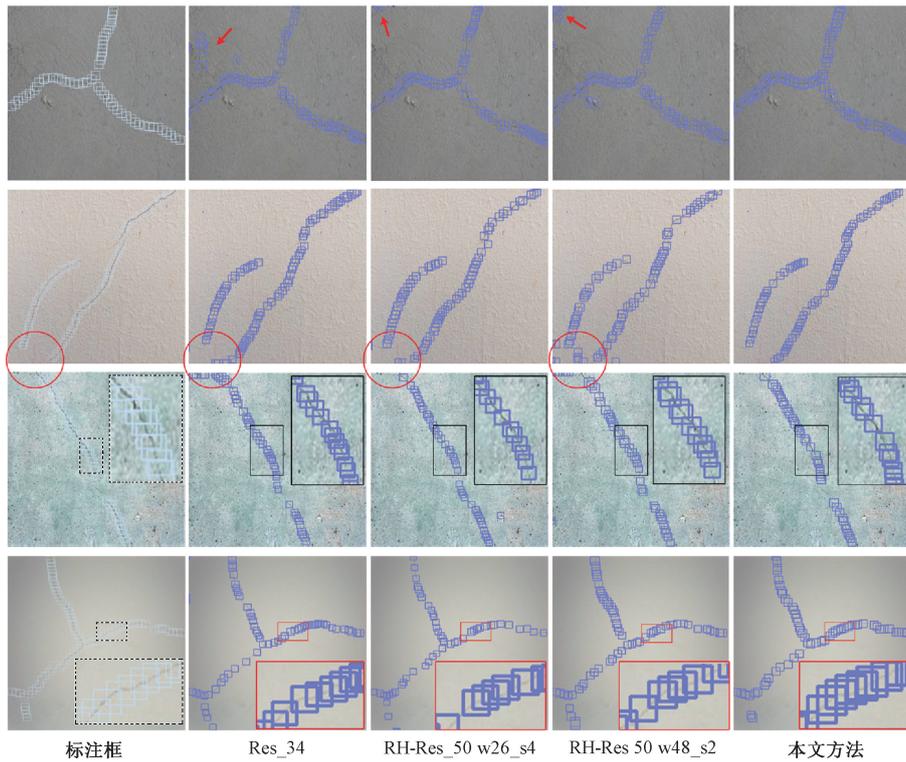


图 11 边界框回归结果

Fig. 11 Regression results of bounding boxes

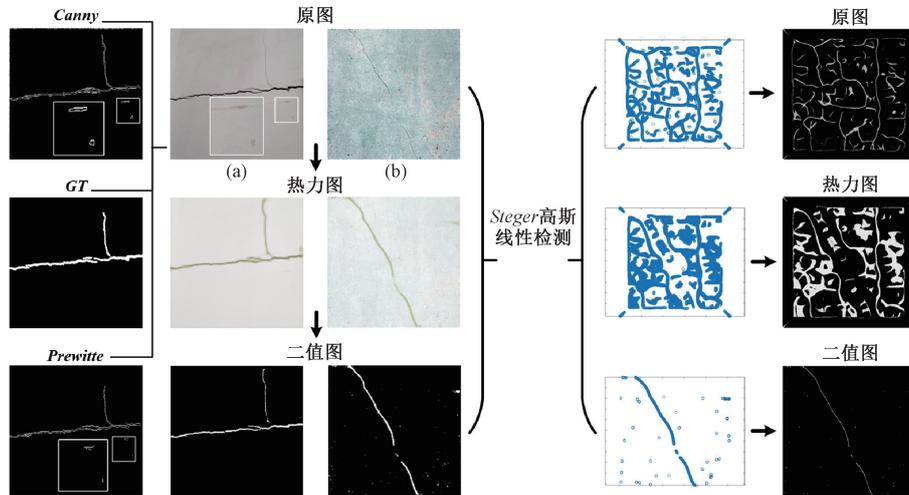


图 12 不同方法定性比较

Fig. 12 Qualitative comparison of different methods

4 结 论

针对图像分割等方法难以实现细微裂纹的有效识别问题,本文利用中心点预测算法将传统的裂纹检测问题转变为密集连续的中心点预测问题,并提出一种结合精细化分层残差骨干网络和特征复用注意力模块的中心点

预测模型。通过精细化分层残差构建的骨干网络实现同尺度语义特征的兼顾,有助于扩大各尺度下特征映射的感受野;提出一种具有特征复用的注意力模块,利用输入特征和全局池化特征计算自适应权值并将结果加权至输出特征中,在有效突出细微裂纹甚至是肉眼难以察觉的超细微裂纹特征的同时减少背景杂质带来的干扰。实验结果表明,本文方法的最高精度和平均精度分别达到

61.0%和54.7%,相比原模型提升了4.9%和6.3%;在定性比较中识别多种不同的细微裂纹间隙、排除黑色斑块等背景杂质并成功识别出肉眼难以察觉的超细微裂纹。本文方法在对比实验中也存在一些可供后续研究的方向。首先密集连续的小目标框在标注过程中受限于裂纹形状等不确定因素的影响难以统一尺寸;其次切分后的裂纹特征差异较小,使用目标检测的评估方式会出现精度和召回率偏低但定性检测效果良好的情况,因此可基于本文方法进一步研究新的评估方式;最后自适应加权思想本质上是利用输入特征得到权值再对输出特征加权以强化某些特征,该思想也可尝试于其他特征提取模块。

参考文献

- [1] 周志新. 机械裂纹无损检测方法综述[J]. 机电工程, 2017,34(10):1138-1143.
ZHOU ZH X. Review of nondestructive testing methods for mechanical cracks [J]. Mechanical and Electrical Engineering, 2017, 34(10):1138-1143.
- [2] 刘永强,杨世锡,刘学坤. 基于激光超声的金属构件表面微裂纹定量检测技术研究[J]. 振动与冲击, 2019, 38(19):14-19.
LIU Y Q, YANG SH X, LIU X K. Research on quantitative detection technology of surface micro cracks of metal components based on laser ultrasound [J]. Vibration and Shock, 2019, 38(19):14-19.
- [3] 冯玮,杨辰龙,边成亮,等. 基于递归分析的微裂纹缺陷超声检测技术研究[J]. 振动与冲击, 2020, 39(10):154-155,157-162.
FENG W, YANG CH L, BIAN CH L, et al. Research on ultrasonic testing technology of microcrack defects based on recursive analysis [J]. Vibration and Shock, 2020, 39(10):154-155,157-162.
- [4] 王森,伍星,张印辉,等. 基于全卷积神经网络和结构化森林的结构体裂纹分割方法[J]. 仪器仪表学报, 2020, 41(8):170-179.
WANG S, WU X, ZHANG Y H, et al. Structural crack segmentation method based on full convolution neural network and structured forest [J]. Chinese Journal of Scientific Instrument, 2020, 41(8):170-179.
- [5] YUPENG R, JISHENG H, ZHIYOU H, et al. Image-based concrete crack detection in tunnels using deep fully convolutional networks [J]. Construction and Building Materials, 2020, 234:117367.
- [6] QIAONING Y, WEIMIN S, JUAN C, et al. Deep convolution neural network-based transfer learning method for civil infrastructure crack detection[J]. Automation in Construction, 2020, 116:103199.
- [7] CAO V D, HIDEHIKO S, SUICHI H, et al. A vision-based method for crack detection in gusset plate welded joints of steel bridges using deep convolutional neural networks[J]. Automation in Construction, 2019, 102:217-229.
- [8] 余永维,杜柳青,曾翠兰,等. 基于深度学习特征匹配的铸件微小缺陷自动定位方法[J]. 仪器仪表学报, 2016,37(6):1364-1370.
YU Y W, DU L Q, ZENG C L, et al. Automatic location method of casting micro defects based on deep learning feature matching [J]. Chinese Journal of Scientific Instrument, 2016, 37(6):1364-1370.
- [9] ARUN M, SUMATHI P. Crack detection using image processing: A critical review and analysis [J]. Alexandria Engineering Journal, 2018, 57:787-798.
- [10] LIANGCHIEH C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[J]. Computer Science, 2014(4):357-361.
- [11] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, 40(4):834-848.
- [12] CHEN L C, PAPANDREOU G, SCHROFF F, et al. Rethinking atrous convolution for semantic image segmentation [J]. Computer Vision and Pattern Recognition (cs. CV), 2017, Arxiv:1706.05587v1.
- [13] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous aeparable convolution for semantic image segmentation [J]. Computer Vision and Pattern Recognition (cs. CV), 2018, Arxiv:1802.02611v3.
- [14] EVAN S, JONATHAN L, TREVOR D. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, DOI: 10.1109/tpami.2016.2572683.
- [15] 王星,高磊,王岩,等. 内部微缺陷的超声与数字全息成像检测系统设计[J]. 红外与激光工程, 2020, 49(7):133-143.
WANG X, GAO L, WANG Y, et al. Design of ultrasonic and digital holographic imaging system for detecting internal micro defects [J]. Infrared and Laser Engineering, 2020,49(7):133-143.
- [16] 何翔,李亮玉,王天琪,等. 基于磁光成像的低碳钢WAAM成形件表面缺陷检测与分类[J]. 仪器仪表学报, 2020,41(4):255-262.
HE X, LI L Y, WANG T Q, et al. Surface defect detection and classification of low carbon steel WAAM parts based on magneto-optical imaging [J]. Chinese Journal of Scientific Instrument, 2020, 41(4):255-262.
- [17] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[J]. IEEE Transactions on Pattern Analysis and Machine

- Intelligence, 2020, 42:386-397.
- [18] 韩明, 吴庆祥, 曾雄军. 基于深度学习的齿轮视觉微小缺陷检测[J]. 计算机系统应用, 2020, 29(3): 100-107.
- HAN M, WU Q X, ZENG X J. Gear vision micro defect detection based on deep learning [J]. Application of Computer System, 2020, 29(3): 100-107.
- [19] REN S, HE K, GKIOXARI G, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39:1137-1149.
- [20] 常海涛, 苟军年, 李晓梅. Faster R-CNN 在工业 CT 图像缺陷检测中的应用[J]. 中国图象图形学报, 2018, 23(7): 1061-1071.
- CHANG H T, GOU J N, LI X M. Application of faster R-CNN in flaw detection of industrial CT image [J]. Chinese Journal of Image and Graphics, 2018, 23(7): 1061-1071.
- [21] FANG F, LI L, GU Y, et al. A novel hybrid approach for crack detection[J]. Pattern Recognition, 2020, 107: 107474.
- [22] ZHOU X, WANG D, KRHENBUHL P. Objects as points[J]. Computer Vision and Pattern Recognition, 2019, ArXiv:1904.07850v2.
- [23] KANG T, YIQUAN W, FEI Z. Recent advances in small object detection based on deep learning: A review[J]. Image and Vision Computing, 2020, 97, 103-910.
- [24] GAO S, CHENG M M, ZHAO K, et al. Res2Net: A new multi-scale backbone architecture [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(2): 652-662.
- [25] ZHOU W, CHEN Y, LIU C, et al. GFNet: Gate fusion network with Res2Net for detecting salient objects in RGB-D Images [J]. IEEE Signal Processing Letters, 2020, 27: 800-804.
- [26] LUO R, HUANG H, WU W, et al. Salient object detection based on backbone enhanced network [J]. Image and Vision Computing, 2020, 95: 103876.
- [27] LIANG Y, QIN G, SUN M, et al. MAFNet: Multi-style attention fusion network for salient object detection[J]. Neurocomputing, 2020, 422: 22-33.
- [28] 孔子迁, 邓蕾, 汤宝平, 等. 基于时频融合和注意力机制的深度学习行星齿轮箱故障诊断方法[J]. 仪器仪表学报, 2019, 40(6): 221-227.
- KONG Z Q, DENG L, TANG B P, et al. Deep learning planetary gearbox fault diagnosis method based on time frequency fusion and attention mechanism [J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 221-227.
- [29] 丁绪星, 杨凌云, 冯友宏. 一种基于视觉注意力的快速运动估计算法[J]. 仪器仪表学报, 2009, 30(12): 2539-2543.
- DING X X, YANG L Y, FENG Y H. A fast motion estimation algorithm based on visual attention [J]. Chinese Journal of Scientific Instrument, 2009, 30(12): 2539-2543.
- [30] 张堃, 姜朋朋, 华亮, 等. 大视场大规模目标精确检测算法应用研究[J]. 仪器仪表学报, 2020, 41(4): 191-199.
- ZHANG K, JIANG P P, HUA L, et al. Application research of large field of view large scale target accurate detection algorithm [J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 191-199.
- [31] ZHU X, HU H, LIN S, et al. Deformable ConvNets v2: More deformable, better results [C]. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018, ArXiv:1904.07850v2.
- [32] 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, ArXiv: 1512.03385v1.
- [33] LIN L, LUO H, HUANG R, et al. Recurrent models of visual co-attention for person re-identification[J]. IEEE Access, 2019, 7: 8865-8875.
- [34] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [J]. Computer Vision and Pattern Recognition (cs. CV), 2018, Arxiv: 1807.06521v2.

作者简介



潘云龙, 2019 年于东莞理工学院城市学院获得学士学位, 现为昆明理工大学硕士研究生, 主要研究方向为机器视觉和深度学习算法。

E-mail: pyl7998@126.com

Pan Yunlong received his B. Sc. degree from City College of Dongguan University of Science and Technology in 2019. He is currently pursuing his M. Sc. degree at Kunming University of Science and Technology. His main research interests include machine vision detection and deep learning algorithms.



王森 (通信作者), 2007 年于郑州轻工业学院获得学士学位, 分别于 2014 年和 2017 年于昆明理工大学获得硕士和博士学位, 现为昆明理工大学讲师、硕士生导师, 主要研究方向为图像处理、计算机视觉和深度学习。

E-mail: wangsen0401@126.com

Wang Sen (Corresponding author) received his B. Sc. degree from Zhengzhou University of Light Industry in 2007, and received his M. Sc. and Ph. D. both from Kunming University of Science and Technology in 2014 and 2017, respectively. He is currently a lecturer and a master advisor at Kunming University of Science and Technology. His research interests include image processing, computer vision and deep learning.