

# 基于 BF-Net 与孪生分差的飞机结构裂纹检测方法<sup>\*</sup>

王叶子, 吕帅帅, 杨宇, 王彬文

(中国飞机强度研究所 西安, 710065)

**摘要** 针对目前飞机结构疲劳试验损伤检测中计算机视觉识别模型面临的主要问题是, 如何从同为毫米级的表面纹理、划痕、污迹中识别出疲劳裂纹, 提出了基于双向融合网络(bidirectional fusion network, 简称 BF-Net)和孪生分差的飞机结构裂纹检测方法。首先, 采用分级检测策略, 提取出可能出现裂纹的重点区域; 其次, 设计面向微小目标识别的 BF-Net, 通过自上而下和自下而上的特征融合操作从区域图像中自动获取高质量的裂纹特征信息; 最后, 采用孪生分差法, 基于重点区域的自身特征信息以及与模板间的特征差异信息来综合判别裂纹。试验结果表明, 该方法能够实现对微小裂纹的精确检测, 为飞机结构疲劳试验中裂纹的自动化检测提供了有效的技术途径。

**关键词** 裂纹检测; 计算机视觉; 深度学习; 双向融合网络; 孪生分差  
**中图分类号** TH878

## 引言

全尺寸飞机结构疲劳试验通过模拟飞机在服役期间的使用情况, 监测疲劳裂纹的萌生和扩展来暴露飞机结构的薄弱部位, 指导飞机结构设计的优化、使用寿命的确定和维护修理方案的制定<sup>[1-4]</sup>。如果裂纹损伤未能及时发现, 则可能因裂纹不受控扩展导致机身结构破坏、延长试验周期。因此, 在飞机结构疲劳试验中实现早期裂纹的精确检测十分关键。

人工目视是目前飞机结构疲劳试验中使用最为广泛的损伤检测方式。相较于渗透、超声、涡流以及 X 射线等无损检测手段<sup>[5-6]</sup>, 人工目视具有方便快捷等优势。但是, 复杂狭小的飞机内部结构通常会使得检测人员处于不适甚至危险的工作状态。另外, 由于无损检测通常需要试验中止, 导致微小裂纹处于闭合状态, 增加了损伤检测难度。因此, 若能利用计算机视觉实现准确实时的损伤自动识别, 将显著提升损伤检测效率, 保障试验安全。

由于深度卷积神经网络可以自动提取出图像中感兴趣目标的有效特征, 快速实现目标的准确分类和定位, 因此能够为飞机结构裂纹检测提供新的技术途径。在全机疲劳试验中采用机械臂和工业相机获取待检部位图像, 通过深度卷积神经网络基于图像进行裂纹识别, 可有效解决人工目视等无损检测技术存在的裂纹检测效率低、成本高和漏检率高等

问题。

近年来, 许多基于深度学习的裂纹检测算法陆续被提出。Cha 等<sup>[7]</sup>提出了一种基于卷积神经网络的裂缝识别方法, 所设计的分类网络在混凝土裂缝以及钢结构表面裂缝图像中取得了比传统的边缘检测方法<sup>[8]</sup>更优的识别效果, 并能克服强光、阴影等各种因素的影响, 在真实场景中准确识别混凝土裂缝。文献[9]基于单阶段目标检测网络 YOLOv2 进行路面裂纹检测, 采用迁移学习策略提升网络的训练速度和检测性能。Fan 等<sup>[10]</sup>提出了一种基于深度学习和自适应图像分割的道路裂缝识别算法, 通过卷积神经网络判断路面图像中是否存在裂纹, 并在网络分类结果的基础上采用自适应阈值法提取路面裂缝, 该算法的裂纹分类准确率达到 99.92%。Chen 等<sup>[11]</sup>针对水下部件金属表面的裂纹检测, 设计了朴素贝叶斯全卷积网络(naive Bayes-fully convolutional network, 简称 NB-FCN), 该网络通过融合多张符合时空相关性的视频帧来发现裂纹, 在自建金属部件数据集上, 检测精度达到了 98.6%。以上方法说明了基于深度神经网络进行裂纹检测具有良好的可行性。

现有基于深度学习的裂纹检测方法主要面向视觉面积较大的混凝土裂缝和路面裂缝等检测任务, 以及个别图像背景单一、干扰较少的金属裂纹检测任务。相比上述检测任务, 全机疲劳试验中的裂纹

\* 中国飞机强度研究所创新基金资助项目(BYST-CKKJ-20-027); 航空基金(青年基金)资助项目(2020Z061023001)

收稿日期: 2021-11-18; 修回日期: 2022-03-02

检测存在以下特点:①微小裂纹与待检部位间存在极大的尺寸差异,直接基于待检部位图像进行检测,易导致裂纹的漏检和错检<sup>[12]</sup>;②裂纹尺寸较小,普遍处于毫米级别,导致网络难以提取到足够的视觉特征信息;③裂纹检测背景较复杂,结构表面存在划痕、污迹、加工痕迹等与裂纹相似度较高的干扰成分。这些因素使得现有方法应用于飞机结构裂纹检测时具有较大的难度和局限性。

针对以上技术难题,笔者提出了一种基于双向融合网络和孪生分差的飞机结构裂纹检测方法。首先,采用分级检测策略,将易产生裂纹的应力集中区域分割为小图像块再进行识别,以缩小检测范围,减少微小裂纹的漏检与错检;其次,为提升模型对飞机结构裂纹的特征提取能力,设计了面向微小目标识别的BF-Net;最后,提出了孪生分差来增强算法对裂纹与背景干扰成分的判别性能。

## 1 面向全机疲劳试验的裂纹检测方法

### 1.1 分级检测策略

在全机疲劳试验中,飞机结构尺寸普遍较大,而待检测裂纹的尺寸均在毫米级,两者存在巨大的数量级差异。如果直接将飞机结构图像作为输入数据参与网络训练,由于微小裂纹在图像中的面积占比本身较小,加之卷积神经网络的降采样操作会进一步压缩裂纹的像素数量,从而导致神经网络难以提取到裂纹的视觉特征信息,发生漏检及错检。根据飞机结构的裂纹萌生和扩展机理可知,裂纹一般产生在应力集中区域,因此笔者提出了如下分级检测策略。

首先,通过受力分析确定飞机结构的应力集中区域,再将应力集中区域分割为小尺寸的图像块,基于小图像块进行后续的裂纹识别。基于应力集中区域的分级检测如图1所示。该飞机结构的应力集中区域也就是首先会萌生裂纹的部位,位于铆钉的周




图1 基于应力集中区域的分级检测

Fig.1 Hierarchical detection based on stress concentration area

边区域。因此,以图中左上角的铆钉为例,分割其周边区域为小面积图像块,此时的图像块与裂纹处于同等数量级,用分割所得图像块代替完整的结构图像作为卷积神经网络的输入数据。

基于应力集中区域的分级检测可以有效提升目标在待检图像中的面积占比,减少微小裂纹的漏检。此外,该策略能够显著降低图像中划痕等干扰成分的数量,有助于减少算法的错检概率。

### 1.2 双向融合网络

由于飞机结构裂纹整体呈细长型分布,裂口多处于闭合状态,即使采用了分级检测策略,其在待检图像中也属于视觉面积极小的小目标,导致神经网络难以提取到足够的裂纹特征信息。

在深度神经网络中,来自网络深层的特征图经过逐层特征提取后的感受野较大,具有更抽象的语义表达能力;来自网络低层的特征图则感受野较小,具有更精确的细节表达能力。多尺度特征融合技术<sup>[13]</sup>通过将深层特征图与低层特征图相结合,可以有效增强特征图的目标信息表征能力。

此外,注意力模块也是增强网络特征提取能力的常用方法<sup>[14]</sup>。作为深度神经网络中的重要概念,注意力模块能够模拟人类的注意力机制,即快速扫描全局视场然后筛选出需重点关注的目标区域。其通过权重的分配来获得特征图中对当前任务而言最关键的视觉信息,并抑制其他无关信息,可显著提升神经网络对特征信息的处理效率。

为了实现微小裂纹的精确识别,笔者基于多尺度特征融合技术和注意力模型进行BF-Net的设计,网络整体结构如图2所示。以维度为 $200 \times 80 \times 3$ 的裂纹图像作为网络输入,说明BF-Net的构建步骤。

1) 采用ResNet50<sup>[15]</sup>作为基础网络,ResNet50是计算机视觉任务中一大主流基础网络,其残差结构可避免常规基础网络深度增加所导致的梯度消失问题。ResNet50网络包含5个由残差块组成的卷积模块,各卷积模块的输出特征图分别表示为 $C_1, C_2, C_3, C_4$ 和 $C_5$ 。将待测图像输入ResNet50网络,则 $C_1, C_2, C_3, C_4$ 和 $C_5$ 特征图的维度依次为 $100 \times 40 \times 64, 50 \times 20 \times 256, 25 \times 10 \times 512, 13 \times 5 \times 1024$ 和 $7 \times 3 \times 2048$ 。

2) 进行特征融合操作。由于 $C_1$ 和 $C_2$ 的尺寸较大,为节约计算成本,仅使用 $C_3, C_4$ 和 $C_5$ 层。采用卷积核为 $1 \times 1$ 的卷积层将特征图 $C_3, C_4$ 和 $C_5$ 的通道数转化为256, $C_5$ 经过卷积操作后直接得到维度为 $7 \times$

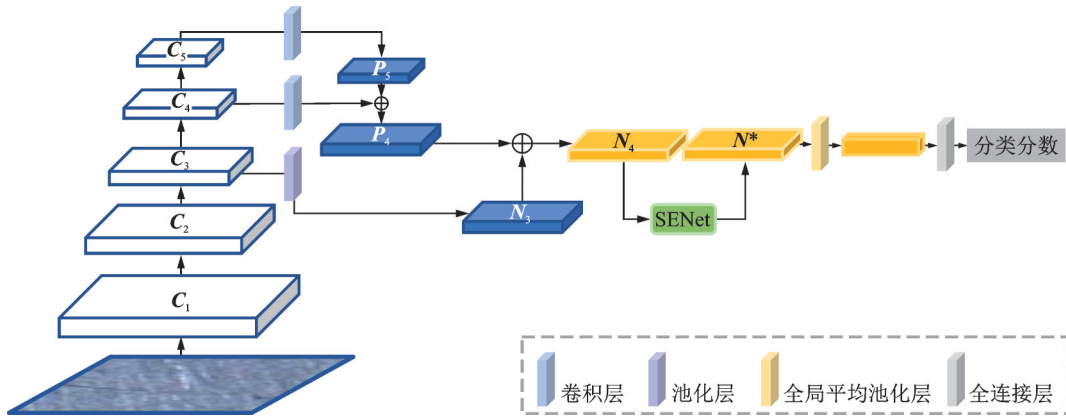


图 2 BF-Net 的整体结构示意图

Fig.2 The overall structure of BF-Net

$3 \times 256$  的特征图  $P_5$ 。

3) 对  $P_5$  进行上采样操作,输出维度为  $13 \times 5 \times 256$  的特征图。将该特征图与经过卷积操作后维度为  $13 \times 5 \times 256$  的  $C_4$  按元素相加,得到维度为  $13 \times 5 \times 256$  的  $P_4$ 。这一步通过将强语义信息的特征图  $P_5$  与弱语义信息的特征图  $C_4$  进行融合,使  $P_4$  在  $C_4$  的基础上获得更抽象的语义特征。

4) 采用池化层对  $C_3$  进行下采样操作,输出维度为  $13 \times 5 \times 256$  的特征图  $N_3$ ,将  $N_3$  与  $P_4$  按元素相加,得到维度为  $13 \times 5 \times 256$  的  $N_4$ 。这一步通过将具有更多细节信息的特征图  $N_3$  与低分辨率特征图  $P_4$  进行融合,使  $N_4$  在  $P_4$  的基础上获得了更精确的细节特征。

至此,通过自上而下和自下而上的双向特征融合操作,获得了包含丰富目标信息的特征图  $N_4$ 。为了减少冗余特征信息和生成高质量的特征表达,将  $N_4$  再输入挤压激励网络(squeeze-and-excitation networks,简称 SENet)<sup>[16]</sup>中。图 3 为 SENet 的结构示意图。其包括空间维度上的特征压缩操作、针对通道特征向量的激励操作以及在通道维度上对特征图  $N_4$  进行的权重重分配操作,并输出维度为  $13 \times 5 \times 256$  的特征图  $N^*$ 。具体过程表示为

$$s = \text{Avgpool}(N_4) \quad (1)$$

$$e = \sigma(W_2 \varepsilon(W_1 s)) \quad (2)$$




图 3 SENet 的结构示意图

Fig.3 Detailed structure of SENet

$$N^* = e \cdot N_4 \quad (3)$$

其中: Avgpool 表示全局平均池化操作;  $s$  为压缩后尺寸为  $1 \times 1 \times 256$  的通道特征向量;  $W_1$  表示输出维度为  $1 \times 1 \times 256/r$  的全连接层操作;  $\varepsilon$  为激活函数 Relu;  $W_2$  表示输出维度为  $1 \times 1 \times 256$  的全连接层操作;  $\sigma$  为激活函数 Sigmoid;  $e$  为包含权重信息、尺寸为  $1 \times 1 \times 256$  的通道特征向量。

在上述操作中,SENet 根据每张特征图对识别结果的贡献程度对其进行权重的重新分配,从而使网络更加关注裂纹信息所在通道的特征图。

最后,对  $N^*$  进行全局平均池化操作,得到维度为  $1 \times 1 \times 256$  的特征向量,再将其输出网络末端的全连接层进行分类,获得一维向量,即裂纹图像的分类分数。

在 BF-Net 中采用双向特征融合操作,使得用于最终分类的特征图获得丰富的语义特征信息和细粒度特征信息,从而让网络能够充分学习到裂纹的特征表示,有效提高微小裂纹的识别准确率。后续采用的注意力模块 SENet 通过对冗余特征信息进行抑制,对关键特征信息进行加强,进一步提升网络对微小裂纹的特征表达能力。

### 1.3 孪生分差

飞机结构的表面存在诸多划痕、污迹及加工痕迹等干扰因素,其在外形上与裂纹具有极高的相似性,如果直接基于输入图像进行裂纹识别,则会导致较高误判率。上述干扰因素和疲劳裂纹的区别在于:干扰因素始终存在于结构表面,即随着疲劳试验开展,干扰因素的视觉特征不会呈现明显变化;而疲劳裂纹只会在疲劳试验开展过程中产生,一旦裂纹萌生并扩展,该结构的视觉特征会发生显著变化。因此,在全机疲劳试验中,度量同一部位的当前图像



和初始无裂纹图像(疲劳试验开始前或早期所采集的图像)之间的特征差异,能够为裂纹与干扰因素的准确判别提供可靠的技术途径。

孪生神经网络<sup>[17]</sup>是一种将度量学习与深度神经网络相结合的目标分类算法,该算法将2个样本分别输入2个相同的网络进行特征提取,然后通过对比损失计算2个样本间的特征距离,来衡量2个样本的相似程度,常用于解决分类任务中存在的类间相似性问题。由于孪生神经网络需要基于大量的样本对训练来实现对比损失的收敛,因此不适用于飞机结构裂纹检测这种小样本二分类任务。

笔者借鉴孪生神经网络原理,提出了孪生分差法来增强算法对裂纹与背景干扰成分的判别性能。孪生分差法示意图如图4所示,将同一被检测区域对应的模板(即无裂纹图像)和当前待测图像分别输入已训练好的BF-Net中,并输出各自的分类分数,计算2个分类分数的差值绝对值,从而得到孪生分差。如果待测图像和模板间的孪生分差大于设定的阈值,则认为被检测区域有裂纹产生;如果孪生分差小于等于设定的阈值,则认为被检测区域没有裂纹生成。具体过程可表示为

$$d(i, t) = \| \text{score}_i - \text{score}_t \| \quad (4)$$

$$R = \begin{cases} 1 & (d > \varphi) \\ 0 & (d \leq \varphi) \end{cases} \quad (5)$$

其中: $\text{score}_i$ 和 $\text{score}_t$ 分别为待测图像和对应模板的分类分数; $d$ 为孪生分差; $\varphi$ 为设定的分类阈值; $R$ 为待测图像的诊断结果( $R$ 为1表示图像中出现裂纹, $R$ 为0则表示没有裂纹)。

相比只关注样本间特征差异的孪生神经网络以及只关注样本自身特征信息的常规分类网络,基于孪生分差的裂纹检测方法能够同时基于样本自身特征信息,即BF-Net的分类结果和样本间的特征差异,即基于待测图像和无裂纹模板间的分值差异来综合判断待测图像中是否产生了裂纹,因此更适用于飞机疲劳裂纹的判别。此外,孪生分差法无需额外进行神经网络的训练,是一种简洁高效的提升裂纹检测准确率的方法。




图4 孪生分差法示意图

Fig.4 The schematic diagram of siamese difference

## 2 试验与分析

### 2.1 试验数据集

为了验证算法的有效性,构建了飞机结构裂纹数据集并进行试验测试。图像采集自飞机结构元件级疲劳试验和全尺寸疲劳试验中的45个待检测结构,包含了铆钉、孔边和开槽等常见的应力集中区域类型,以增强算法的泛化能力和鲁棒性。图5为元件级疲劳试验中的图像采集装置。所用采集设备为海康威视工业相机,图像像素为2000万。使用工业相机持续记录试验过程,拍摄频率为两秒一张,以保证及时观察到萌生阶段的微小裂纹图像。此外,图像采集过程中保持相机与待检测结构的相对位置不变,便于待测图像与模板图像的精确匹配。




图5 元件级疲劳试验中的图像采集装置

Fig.5 Image acquisition device in element level fatigue test

疲劳试验中飞机结构会持续发生微幅振动,导致在同一部位采集的图像之间存在一定的亮度和清晰度变化,并且裂纹随着结构振动一直处于裂口张合和扩展的动态过程。图6为疲劳试验中的裂纹图像变化示例。因此,每个待检测结构均保留了10张及以上的裂纹图像和10张及以上的初始无裂纹图像,以丰富样本多样性,提升神经网络的泛化能力。

待检测结构图像采集完成后,基于分级检测策略对图像进行分割,获得1140个待检测区域,并根据待检测区域小图中是否存在裂纹,进行逐一标注。将待检测区域进行随机划分,获得包含660个待检测区域的训练集,以及包含480个待检测区域的测试集。



图6 疲劳试验中的裂纹图像变化示例

Fig.6 Example of crack image variation in fatigue test

## 2.2 试验设置

本研究的网络训练和算法测试基于深度学习框架 Keras 完成,输入图像的尺寸均预处理为  $200 \times 80 \times 3$ 。训练采用的基础网络为经 Imagenet 数据集预训练的模型 ResNet50,损失函数为二值交叉熵损失函数,采用的优化算法是 Adam,训练次数设置为 30,每个训练批次所采用的样本数设置为 60,学习率的初始值设为 0.000 1。本研究所有试验的上述参数设置均保持一致,以便于不同试验间的裂纹识别效果对比。

## 2.3 模型训练与测试

为了分析笔者提出的飞机结构裂纹检测方法的检测性能,以及 2 个主要技术手段(BF-Net 和孪生分差)各自对算法性能的影响,进行了对比试验。试验所用算法依次为基础网络 ResNet50, BF-Net, “ResNet50+孪生分差”和“BF-Net+孪生分差”。

使用飞机结构裂纹训练集分别对基础网络 ResNet50 和 BF-Net 进行迭代训练,获得已训练好的 2 种网络模型。由于孪生分差法基于训练完毕的网络模型进行综合判断,因此无需额外进行网络训练。

训练完毕后,使用测试集对以上 4 种算法进行测试。测试时,对于每一个待检测区域,先选择 1 张初始无裂纹图像作为孪生分差法中的模板图像,然后在剩余的待检测区域图像中,分别选择 3 张有裂纹图像和 3 张初始无裂纹图像作为待测图像。测试集包含 480 个待检测区域,共获得 480 张模板图像和  $480 \times 6 = 2\ 880$  张待测图像。

针对 ResNet50 和 BF-Net,直接基于这 2 880 张待测图像依次进行测试。采用孪生分差算法,即“ResNet50+孪生分差”和“BF-Net+孪生分差”,使用 1 张待测图像搭配 1 张对应区域模板图像的方法,组成 2 880 组待测样本对进行对比测试。

为了更加全面精确地评价模型性能,采用准确率和  $F_1$  分数这 2 种评价指标。准确率指模型预测正确的样本量占总样本量的百分比,是分类任务中最常见的评价指标。

$$R_e = \frac{TP}{TP + FN} \quad (6)$$

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

其中:TP 为预测正确的正样本数量;FN 为预测错

误的正样本数量;FP 为预测错误的负样本数量; $R_e$  为召回率; $P_r$  为精确率。

$F_1$  分数是模型召回率与精确率的调和均值,能够反映模型的综合性能,定义公式为

$$F_1 = \frac{2R_e P_r}{R_e + P_r} \quad (8)$$

## 2.4 试验结果与分析

各组算法的裂纹检测结果对比如表 1 所示。相比基础网络 ResNet50, BF-Net 的检测准确率提升了 2.16%,  $F_1$  分数提升了 3.81%,说明双向融合操作和注意力机制的加入能够有效提升网络的特征提取能力。对比 ResNet50 和“ResNet50+孪生分差”,以及 BF-Net 和“BF-Net+孪生分差”的检测结果,孪生分差法使 2 个模型的检测准确率分别增加了 1.14% 和 1.37%,  $F_1$  分数分别增加了 1.65% 和 1.59%,说明结合样本自身特征和样本间的特征差异进行综合判断的识别效果要优于仅基于样本自身特征进行裂纹识别。所提出的裂纹识别方法“BF-Net+孪生分差”在真实裂纹测试集上的检测性能最佳,证明了本研究方法的有效性。

表 1 各组算法的裂纹检测结果对比

Tab.1 The crack detection results of each algorithm		
算法	检测准确率/%	$F_1$ 分数
ResNet50	92.12	0.899 5
BF-Net	94.28	0.937 6
ResNet50+孪生分差	93.26	0.916 0
BF-Net+孪生分差	95.65	0.953 5

图 7 为元件级疲劳试验中 ResNet50 与本研究方法的检测结果对比。图 7(a)中由于无裂纹待测图像上有黑色标记, ResNet50 将该特征判断为裂纹(分类分数为 0.998)。本研究方法中 BF-Net 输出的分类分数为 0.79,倾向于判断该特征是裂纹,但通过计算待测图像与模板图像之间的孪生分差进行综合判断,最终输出为“无裂纹”。图 7(b)的待测图像中萌生了微小裂纹, ResNet50 的输出结果为“有裂纹”(分类分数为 0.96);本研究方法也输出为“有裂纹”。

图 8 为全机疲劳试验中基础网络 ResNet50 与本研究方法的检测结果对比。图 8(a)中的待测图像为裂纹扩展尖端,受结构振动影响,画面较为模糊, ResNet50 的输出为“无裂纹”(分类分数为



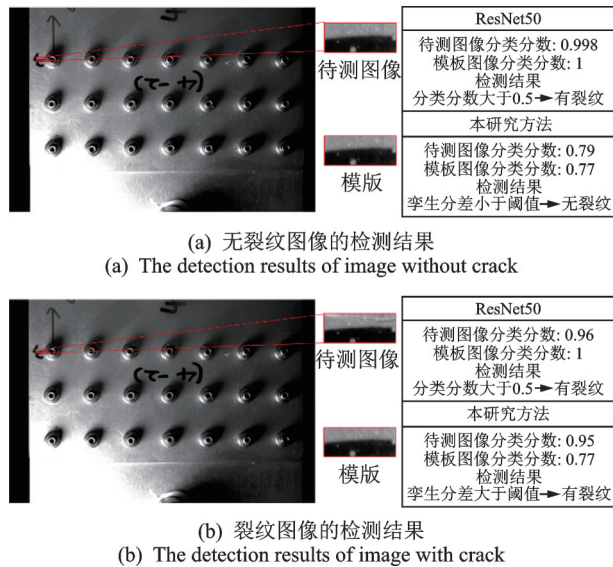


图7 元件级疲劳试验中 ResNet50 与本研究方法的检测结果对比

Fig.7 The detection results comparison of ResNet50 and the proposed method in element level fatigue test

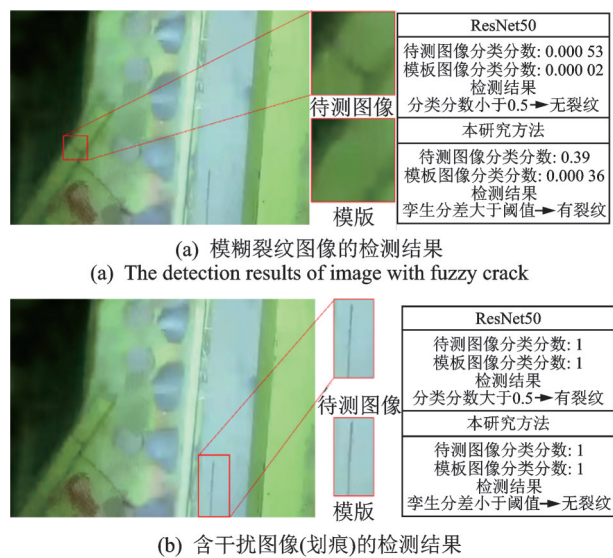


图8 全机疲劳试验中 ResNet50 与本研究方法的检测结果对比

Fig.8 The detection results comparison of ResNet50 and the proposed method in full-scale fatigue test

0.000 53)。本研究方法中 BF-Net 输出的分类分数为 0.39, 倾向于该图像不是裂纹图像, 但通过孪生分差法对待测图像与模板图像进行分类分数的对比判断, 最终输出为“有裂纹”。图 8(b) 中的待测图像为划痕, 由于划痕与裂纹视觉特征极为相似, 2 个网络均将其判断为“有裂纹”(分类分数为 1); 模板图像的分类分数为 1, 因为裂纹在试验过程中生成, 不会存在于模板图像中, 而划痕可能预先存在于模板图

像中, 说明该部位图像为划痕图像。因此, 待测划痕图像与模板图像的孪生分差小于阈值, 本研究方法的最终输出为“无裂纹”。

通过上述分析可知, 本研究方法在真实应用场景中具有更高的检测准确性, 并且对飞机结构疲劳试验中普遍存在的清晰度变化、污迹和划痕等干扰成分具有良好的鲁棒性。

当检测场景较复杂时, BF-Net 输出的分类分数不够理想(理想情况下, 裂纹图像的分类分数应趋近于 1, 无裂纹图像的分类分数趋近于 0), 比如对图 7 中的无裂纹模板图像分类分数为 0.77(受笔迹干扰), 对图 8 中裂纹图像分类分数仅为 0.39(裂纹成像模糊)。这也是因为相比 ResNet50, BF-Net 能够更准确客观地反映出不同图像间的细微特征差异。例如: 图 7(b) 中出现微小裂纹的待测图像分数高于模板图像; 图 8(a) 中的待测裂纹图像分数也显著高于模板图像, 说明了 BF-Net 具有更强的裂纹特征提取能力。因此, 面向复杂检测场景时, 即使 BF-Net 不能直接给出正确检测结果, 仍然可以通过其输出的分类分数获得真实的特征分布情况, 从而结合孪生分差法, 实现对待测图像的正确判断。

### 3 结 论

1) 采用分级检测策略, 提升微小裂纹在待检图像中的面积占比, 降低划痕等干扰成分在待检图像中的数量。

2) 设计了面向微小目标识别的 BF-Net, 显著提升了网络对飞机结构裂纹的特征提取能力。

3) 提出了孪生分差法来增强算法对裂纹与划痕等背景干扰成分的判别性能。

4) 基于真实裂纹检测图像的实验结果表明, 所提出的裂纹检测方法能够实现对飞机结构裂纹的精确检测, 具有一定的工程应用前景。

### 参 考 文 献

- [1] 孙侠生, 苏少普, 孙汉斌, 等. 国外航空疲劳研究现状及展望[J]. 航空学报, 2021, 42(5): 45-70.  
SUN Xiasheng, SU Shaopu, SUN Hanbin, et al. Current status and prospect of overseas research on aeronautical fatigue[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(5): 45-70. (in Chinese)
- [2] ANWAR W, TAHIR M, KHAN T A. Effect of crack plane orientations on damage tolerant fatigue life of

- critical aerospace structures [C]//International Bhurban Conference on Applied Sciences and Technology. Islamabad, Pakistan: IEEE, 2017: 100-104.
- [3] 王彬文,陈先民,苏运来,等.中国航空工业疲劳与结构完整性研究进展与展望[J].航空学报,2021,42(5): 6-44.  
WANG Binwen, CHEN Xianmin, SU Yunlai, et al. Research progress and prospect of fatigue and structural integrity for aeronautical industry in China [J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(5): 6-44. (in Chinese)
- [4] YOUNIS H B, KAMAL K, SHEIKH M F, et al. Prediction of fatigue crack growth rate in aircraft aluminum alloys using radial basis function neural network [C]//International Conference on Advanced Computational Intelligence. Xiamen, China: IEEE, 2018: 825-830.
- [5] ALATAWNEH N, UNDERHILL P R, KRAUSE T W. Low-frequency eddy-current testing for detection of subsurface cracks in CF-188 stub flange [J]. IEEE Sensors Journal, 2018, 18(4): 1568-1575.
- [6] GAO Y, GHASR M T, YING K, et al. Millimeter wave differential probe system for surface crack detection in painted aircraft fuselage [C]//IEEE International Instrumentation and Measurement Technology Conference. Auckland, New Zealand: IEEE, 2019: 1-6.
- [7] CHA Y J, CHOI W, ORAL B. Deep learning-based crack damage detection using convolutional neural networks [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5): 361-378.
- [8] CANNY J. A computational approach to edge detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1986, 8(6): 679-698.
- [9] MANDAL V, UONG L, YAW A. Automated road crack detection using deep convolutional neural networks [C]//IEEE International Conference on Big Data. Seattle, WA, USA: IEEE, 2018: 5212-5215.
- [10] FAN R, BOCUS M J, ZHU Y L, et al. Road crack detection using deep convolutional neural network and adaptive thresholding [C]//IEEE Intelligent Vehicles Symposium. Paris, France: IEEE, 2019: 474-479.
- [11] CHEN F C, JAHANSHAHI M R. NB-FCN: real-time accurate crack detection in inspection videos using deep fully convolutional network and parametric data fusion [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(8): 5325-5334.
- [12] 吕帅帅,杨宇,王彬文,等.基于改进Mask-RCNN的飞行器结构裂纹自动检测方法[J].振动、测试与诊断, 2021, 41(3): 487-494.  
LYU Shuaishuai, YANG Yu, WANG Binwen, et al. An automatic crack detection method for structure test based on improved Mask-RCNN [J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(3): 487-494. (in Chinese)
- [13] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017: 2117-2125.
- [14] JIAO L C, ZHANG F, LIU F, et al. A survey of deep learning-based object detection [J]. IEEE Access, 2019, 9(5): 128837-128868.
- [15] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [16] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [17] CHOPRA S, HADSELL R, LECUN Y. Learning a similarity metric discriminatively, with application to face verification [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). San Diego, CA, USA: IEEE, 2005: 539-546.



**第一作者简介:**王叶子,女,1996年8月生,硕士。主要研究方向为计算机视觉与结构健康监测。曾发表《Feature-reflowing pyramid networks for object detection in multi-class remote sensing images》(《IEEE Geoscience and Remote Sensing Letters》2020, Vol.19)等论文。  
E-mail:kivib@mail.nwpu.edu.cn

**通信作者简介:**吕帅帅,女,1987年1月生,硕士。主要研究方向为结构健康监测与智能结构设计。  
E-mail:647817545@qq.com