

DOI:10.16136/j.joel.2022.01.0406

# 融入频域特征的航天复合材料缺陷智能检测

罗 钧\*, 李志学, 龚燕峰

(重庆大学 光电技术及系统教育部重点实验室, 重庆 400030)

**摘要:**针对传统人力无损检测识别方式存在的准确度与可靠性不足,且处理缺陷种类单一的问题,本文提出了一种融入频域特征的航天复合材料缺陷检测算法。首先,为了提高缺陷图像的特征提取效果,在特征提取骨干网络中添加图像的频域输入信息;其次,为了提高缺陷的可视化效果和检测精度,提出信息专注模块,并在面具 R-CNN(mask region-based convolutional neural network, Mask R-CNN)的基础上,改进分割掩模损失函数;最后,结合级联 R-CNN(cascade region-based convolutional neural network, Cascade R-CNN)结构,形成了新的实例分割网络。此外,在航天复合材料缺陷 X 射线图像数据集中对提出的实例分割网络进行了实验验证,模型检测的平均准确度达到了 95.3%,与 Mask R-CNN、级联面具 R-CNN(cascade mask region-based convolutional neural network, Cascade Mask R-CNN)等实例分割算法相比,取得了更为优良的效果。该研究成果已应用于实际工业生产中几种常见航天复合材料缺陷的智能检测。

**关键词:**X 射线成像;级联卷积神经网络;频域输入;信息专注;缺陷检测

**中图分类号:**TP391.41 **文献标识码:**A **文章编号:**1005-0086(2022)01-0067-08

## Intelligent detection of defects in aerospace composite materials incorporated in frequency domain features

LUO Jun\*, LI Zhixue, GONG Yanfeng

(Key Laboratory of Optoelectronic Technology and System of Ministry of Education, Chongqing University, Chongqing 400030, China)

**Abstract:** For the traditional human non-destructive testing and recognition methods, there are problems of insufficient accuracy and reliability as well as few kinds of defects to detect. To solve them, this paper proposes an aerospace composite material defect detection algorithm incorporating frequency domain features. The algorithm can be divided into three main steps. Firstly, the input information of the frequency domain of the image is added to the feature extraction backbone network which is used to improve the feature extraction effect of defect images. Secondly, a module of informational concentration is proposed in order to improve the visualization capability and detective accuracy of defects, and on the basis of mask region-based convolutional neural network (Mask R-CNN), the segmentation mask loss function is improved. Finally, combined with the cascaded neural network structure of cascade region-based convolutional neural network (Cascade R-CNN), a new instance segmentation network is formed. In addition, the proposed instance segmentation network was experimentally verified in the aerospace composite material defect X-ray image data set, and the average accuracy of the model detection reached 95.3%, which achieved better results than other instance segmentation algorithms, such as Mask R-CNN and cascade mask region-based convolutional neural network (Cascade Mask R-CNN). The research result has been applied to the intelligent detection of several common aerospace composite material defects in actual industrial production.

**Key words:** X-ray imaging; cascade convolutional neural network; frequency domain input; informational concentration; defective detection

\* E-mail: luojun@cqu.edu.cn

收稿日期:2021-06-11 修订日期:2021-07-28

基金项目:上海航天科技创新 SAST 基金(SAST2018-065)资助项目

# 1 引言

先进复合材料因其具有性能可设计、耐腐蚀和多功能一体化等众多优点,在航天领域应用广泛。目前,先进复合材料已经发展成为最重要的一类航天结构设计的原材料<sup>[1]</sup>,它对促进现代航天器的高性能化和小型化起到了至关重要的作用。在复合材料的制备过程中,由于制备环境中杂质的干扰、制备工艺方法参数的纰漏,导致制备的复合材料产生缺陷,并且复合材料在运输过程中由于撞击、环境腐蚀等因素的影响也会产生缺陷,这些缺陷通常都处于材料内部<sup>[2]</sup>。使用有缺陷的复合材料制造的航天设备性能往往会降低,同时随着材料内部缺陷的累积,设备寿命会大幅度缩减,无法满足设备产品的质量保障。因此,在复合材料构建形成相应的航天工业设备前,必须对复合材料内部进行缺陷检测。近些年的无损检测手段有 X 射线、红外热成像、超声波和电子散斑干涉法等。针对 X 射线无损检测,传统的利用设备进行目视识别的方法存在着较大的局限性,例如:需要人为地寻图和识图才能获得识别结果,这会花费较高的人力成本。且人力识别缺陷的效率较低,易受到主观因素的影响。

先进无损检测技术和图像处理算法的发展,使得一些新的方法被提出。张慧等<sup>[3]</sup>通过建立空耦 Lamb 波的三维传播模型,分析波的衰减特性,对碳纤维复合材料板进行检测,成像结果表明该方法在检测缺陷尺寸、形状和损伤程度等方面是有效的。张霁旻等<sup>[4]</sup>提出层析短时积分成像法,结合太赫兹信号的特点提出评价规则,利用该评价规则遴选出最优的小波去噪组合,并进行了相关缺陷检测实验。但是以上这些检测方法在缺陷检测精度和缺陷检测种类数等方面存在一定的不足。

近年来,卷积神经网络(convolutional neural network, CNN)已经在管道、焊接件等多种缺陷检测应用领域占据主导地位<sup>[5]</sup>。目前,出现了一系列利用神经网络针对不同材料的缺陷检测方法。刘浩<sup>[6]</sup>针对工业铸件 X 射线检测,对 Caf-eNet 进行了改进并在 JetsonTX1 开发板上进行实验,减少了模型训练时间,提高了缺陷检测的精度。李维刚等<sup>[7]</sup>利用加权 K-means 算法对先验框参数进行聚类,并改进 YOLOv3 (you only look once v3) 的网络结构,将图像中的浅层和深层特征进行融合,在带钢表面缺陷数据集上达到了较高的平均检测精度。但是上述算法对较小的缺陷或深层缺陷的识别精度较低。

利用 CNN 对缺陷进行识别主要是利用目标检测功能。目标检测是在目标分类任务的基础上添加了目标定位的任务。在目标检测的基础上,又出现了新的网络结构面具 R-CNN(mask region-based convolutional neural network, Mask R-CNN)<sup>[8]</sup>。Mask R-CNN 是一种通用、灵活的图像实例分割网络结构。由于复合材料内部成像图的缺陷较小,为了增强其可视化检测效果,并进一步提高缺陷检测精度,本文将 Mask R-CNN 引入级联网络结构中,并融入图像的频域输入以及信息专注模块,对复合材料内部常见的裂纹、高密度夹杂、低密度夹杂、气孔共 4 种缺陷进行了检测识别,最终达到了平均 95.3% 的检测精度,该研究有利于航天工业领域的发展。

## 2 基于 Mask R-CNN 的检测方法

### 2.1 缺陷图像的频域输入

为了满足目前的 CNN 的输入要求,大量的真实图像的分辨率被压缩至  $224 \times 224$ 。图像在空域上的压缩往往使得 CNN 获得的图像特征有限,难以提取到更好的语义特征。针对该问题,频域学习<sup>[9]</sup>是一种很好的解决方法,即图像信息先通过离散余弦变换(discrete cosine transform, DCT)转化为 DCT 系数,继而将系数作为特征输入至深度 CNN 中进行处理。RGB(red-green-blue)图像频域转化流程图如图 1 所示。该图以  $224 \times 224$  的 RGB 三通道图像进行频域转化作为例子。首先利用 JPEG 标准在 YCbCr 空间进行  $8 \times 8$  大小的 DCT 变换, $224 \times 224$  的图像会形成  $(224/8) \times (224/8)$  个块(block),即为  $28 \times 28$  个 block,每个 block 中是  $8 \times 8$  共 64 个 DCT 信号。将所有 block 中相同的频率分量分组到一个通道中,可以形成尺寸为  $28 \times 28$  的特征图,共 64 个通道。由于 RGB 是三维的,进行 DCT 变换后为  $64 \times 3$  共 192 个通道。当高度为  $H$ ,宽度为  $W$ ,通道为  $C$  的 RGB 图像经过 block 大小为  $8 \times 8$  的频域转换后,形成  $(H/8) \times (W/8) \times 64 \times C$  的特征图。这与原始数据

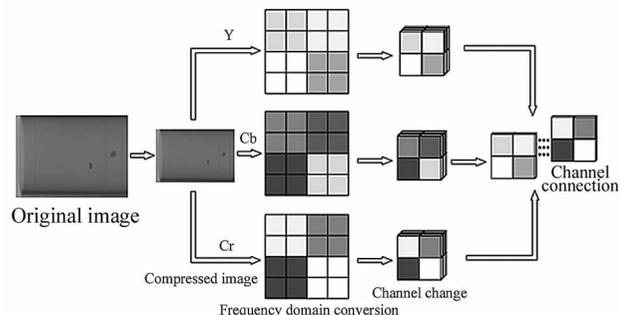


图 1 图像频域转化流程图

Fig. 1 Image frequency domain conversion flow chart

大小相同,而特征图缩小了64倍。空域图像通过频域转换后输入至特征提取网络中。

## 2.2 信息专注模块

信息专注模块在特征提取网络输出之后。如式(1)~式(3)所示,模块的主要作用是将特征提取网络中得到的信息  $O_1$  区域生成网络(region proposal network, RPN)模块学习到的信息  $O_2$  进行融合输出得到  $O_3$ ,之后利用  $O_3$  的特征去进一步校正生成的感兴趣的区域(region of interest, ROI)。如图2所示信息专注模块处理流程图,先将特征提取网络获得的缺陷图像特征进行  $1 \times 1$  的卷积操作,变换后进行批归一化(batch normalization, BN)处理和 Sigmoid 激活。BN 可以加快网络训练的速度,激活函数使得输出值为  $[0, 1]$  的范围。最后利用生成的特征图对 RPN 模块监督学习得到的特征进行重新加权。

$$B_N(x) = \gamma \left( \frac{x - \mu_c(x)}{\sigma_c(x)} \right) + \beta, \quad (1)$$

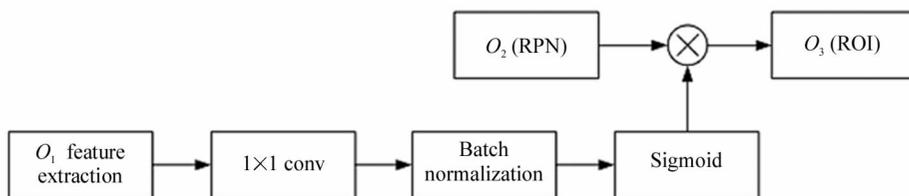


图2 信息专注模块处理流程图

Fig. 2 Informational concentration module process flow chart

## 2.3 Mask R-CNN 目标检测方法

Mask R-CNN 会对待检测图像上的目标分别进行与背景不同颜色的像素标注,这提供了额外的图像分割可视化效果。它主要分为特征提取网络、区域预测网络和功能网络3部分。

特征提取网络的功能是提取和组合图像中的特征信息,通常由 ResNet-50<sup>[10]</sup> 深度神经网络和特征金字塔网络(feature pyramid network, FPN)<sup>[11]</sup> 组成,其中 ResNet-50 用于获取缺陷图像中的特征;FPN 对 ResNet-50 提取到的不同级别层次的特征进行组合,有利于检测不同尺寸大小的目标,得到感兴趣的区域特征(ROI features)。令 ResNet-50 获取的不同级别的特征为  $F_1, F_2, F_3$  和  $F_4$ , FPN 可将其组合为新的特征  $R_1, R_2, R_3, R_4$  和  $R_5$ 。对于  $i$  分别为 1, 2, 3, 4 和  $M_5 = 0$ , 组合步骤如式(4)所示:

$$R'_i = \text{sum}(M_{i+1}, \text{conv}(F_i)),$$

$$M_i = \text{upsample}(R'_i),$$

$$R_i = \text{conv}(R'_i),$$

式中,  $\mu_c(x)$  和  $\sigma_c(x)$  是当前批所有特征图的每个通道计算得到的均值和方差,而  $\gamma$  和  $\beta$  是训练得到的仿射参数,利用  $\gamma$  和  $\beta$  可以恢复批归一化前的特征分布。

激活函数表示为:

$$\text{Sigmoid}(x) = \frac{1}{1 + \exp(-x)}, \quad (2)$$

$$O_3 = O_2 \cdot \text{Sigmoid}(B_N(C(O_1))), \quad (3)$$

式中,  $C(\cdot)$  是特征图的维度变换函数,目的是使特征  $O_1$  和  $O_2$  的通道数匹配。

信息专注模块在整个复合材料缺陷检测网络中具有以下两点作用:一是通过增强前景特征和抑制背景特征来细化特征分布,提高 RPN 模块生成的 ROI 框选的质量;二是通过信息专注模块的网络支路使得额外的梯度流从尾部功能模块流向 RPN 模块,即使得 RPN 模块接收来自尾部输出模块的额外监督,这可以稳定 RPN 模块的训练,有利于提升缺陷检测的精度。

$$R_6 = \text{pool}(R_5), \quad (4)$$

式中,  $\text{sum}(\cdot)$  表示特征求和,  $\text{conv}(\cdot)$  表示特征卷积,  $\text{upsample}(\cdot)$  表示特征扩充,  $\text{pool}(\cdot)$  表示特征池化。

RPN 模块通过提取的特征图来实现目标的区域位置预测功能。基于不同的宽高,Mask R-CNN 会生成相应的初始 Anchor Boxes。但是这些并不是表示目标位置的最佳边框,RPN 网络将根据回归输出对这些 Boxes 进行中心坐标、宽度和高度的修正,修正步骤如式(5)所示:

$$\begin{aligned} x &= x \times (1 + \Delta x), \\ y &= y \times (1 + \Delta y), \\ h &= h \times \exp(\Delta h), \\ w &= w \times \exp(\Delta w), \end{aligned} \quad (5)$$

式中,  $x, y$  表示预设定边框中心坐标点,  $w, h$  表示边框的宽度和高度。

利用上述公式对预设定的 Anchor Boxes 修正完成后,表示同一目标的边框数不止一个。通过前后景的置信度大小选出代表目标位置的最佳边框,同时利用非极大值抑制(non-maximum suppression,

NMS)算法滤除与最佳边框交并比(intersection over union, IoU)高于阈值的边框。

功能性网络的作用主要是目标分类、目标框选和目标分割。通过预测框选内的特征,采用全连接层和 Softmax 层对目标进行分类。目标框选则是进一步对预测框选进行回归修正,修正过程与式(5)相同。目标分割则是利用全卷积分割网络(fully convolutional network, FCN)<sup>[12]</sup>生成用于分割掩码的掩码层,能够有效地寻找到目标物体的边缘,将目标高质量地分割出来。

Mask R-CNN 根据功能性网络的输出与实际值之间的差异计算损失函数大小:

$$L = L_{cls} + L_{box} + L_{mask}, \quad (6)$$

式中,  $L_{cls}$  是缺陷分类的损失,  $L_{box}$  是缺陷回归框定位检测的损失,  $L_{mask}$  是缺陷分割的损失函数。

$L_{mask}$  通过缺陷区域的像素点进行二值分类来计算损失大小,采用的是二分类交叉熵损失函数,这主要考虑的是整体分割区域的像素,对分割边缘的准确度并不高。基于此引入改进的边缘分割损失函数  $L_{mask\_new}$ ,通过分割边界点的距离损失  $L_{dist}$ <sup>[13]</sup> 来修正分割图形的位置、形状和边界区域,使得 FCN 网络对边缘更加敏感,提高缺陷分割精度:

$$L_{mask\_new} = L_{mask} + L_{dist} = \alpha \sum_{p \in B} \hat{y}(p) M_{dist}(p) - \sum_{y \in N} \log_2 \hat{y} + (1 - y) \log_2 (1 - \hat{y}), \quad (7)$$

式中,  $\alpha$  是边缘损失权重大小,  $B$  是缺陷分割区域中边缘像素点集合,  $p$  是  $B$  中的像素点,  $\hat{y}$  是对边缘像素点的分类预测,  $M_{dist}(\cdot)$  表示  $p$  相对于真实边界点的距离,  $N$  表示缺陷分割区域中所有像素点集合。

### 2.4 Cascade R-CNN 目标检测方法

对于目标检测,仅仅提高 IoU 阈值可能会引发训练过拟合问题,导致最终形成的网络模型在测试时精度反而大幅度下降。级联 R-CNN(cascade region-based convolutional neural network, Cascade R-CNN)<sup>[14]</sup> 将多个功能性网络级联在一起,各功能性网络根据提取的特征图来进行计算,同时将一个功能性网络输出的回归框选输入到另一个功能性网络,在不用额外增加正样本数量的情况下达到提升检测精度的目的。

在 Mask R-CNN 实例分割网络基础上,利用航天复合材料缺陷图像的频域信息进行特征提取,将特征输出和 RPN 模块输出添加至信息专注模块,结合级联网络结构,共同构成本文最终采用的航天器复合材料缺陷检测网络,其整体结构如图 3 所示。

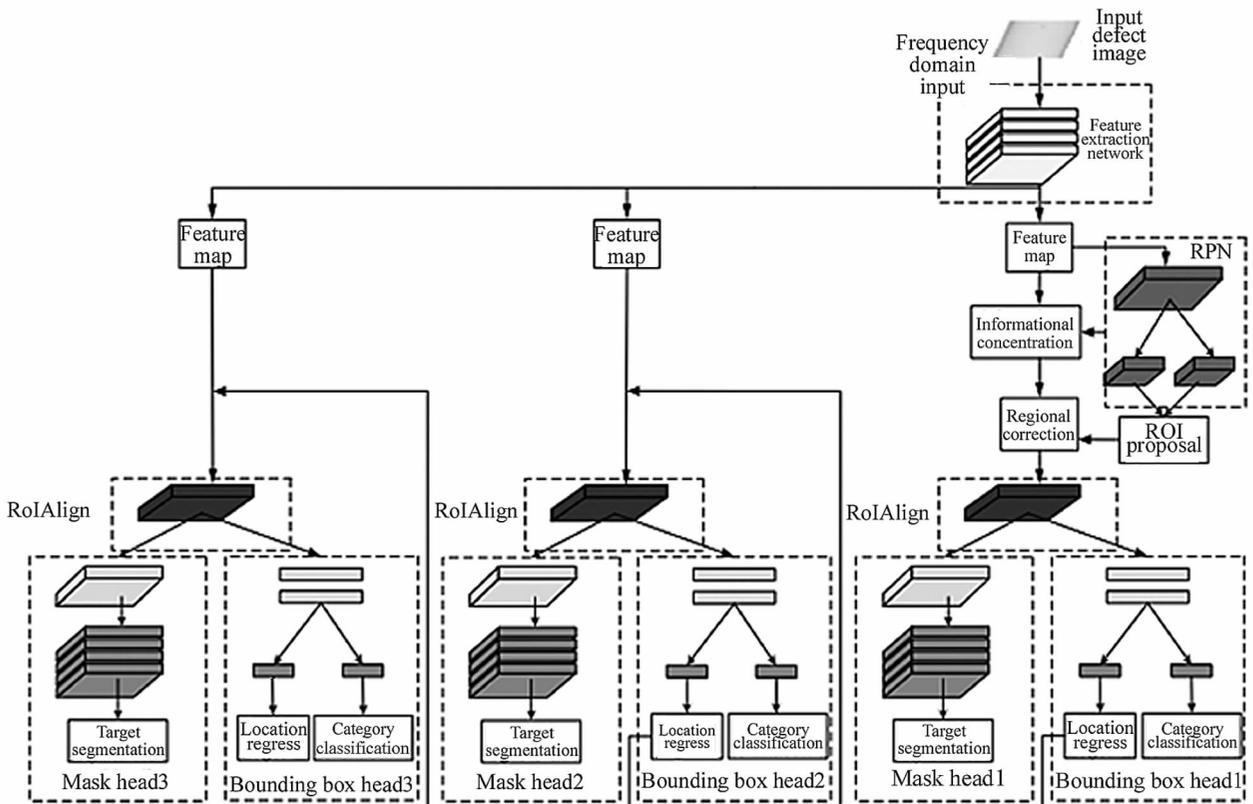


图 3 本文网络整体结构

Fig. 3 Overall structure of the network in this thesis

### 3 实验过程和结果

为了验证本文设计的目标检测网络在复合材料缺陷检测上的效果,本文进行了以下两组实验:

实验(1):为了证明本文设计的深度神经网络结构具有比更快地 R-CNN(faster region-based convolutional neural network, Faster R-CNN)<sup>[15]</sup>、Mask R-CNN、YOLOv3<sup>[16]</sup>、Cascade R-CNN 和级联面具 R-CNN(cascade mask region-based convolutional neural network, Cascade Mask R-CNN)更高精度的复合材料缺陷检测能力,在相同的实验环境和参数下,6种结构先利用相同的复合材料缺陷训练集进行训练,再在相同的缺陷测试集上进行测试。通过比较检测的平均多类均值准确度(mean average precision,  $mAP$ )、平均一张图像检测时间(average detection time, ADT)和图像检测召回率(Recall),可验证其性能,计算公式如下:

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i, \quad (8)$$

式中,  $AP_i$  是第  $i$  类缺陷所有图像的平均检测精度,  $mAP$  即是对所有种类缺陷的检测精度再计算均值。

$$R_c = \frac{TP}{TP + FN}, \quad (9)$$

式中,  $TP$  是网络检测的缺陷实例的类别、定位等参数信息与图像实际标注 Ground Truth 一致,  $FN$  是指在标注中含有类别、定位等参数信息的缺陷实例未被网络检测到,  $R_c$  是召回率。

实验(2):为了证明本文采用的①频域输入、②信息专注模块、③级联网络结构和④分割边缘损失函数在复合材料缺陷检测上的有效性,在 Mask R-CNN 的基础上,分别进行了仅添加①、仅添加②、仅添加③、仅添加④和添加①②③④模块后在相同环境参数下利用复合材料缺陷图像进行训练测试的实验,并对检测结果  $mAP$  进行了比较。

所有实验均在 Linux(Ubuntu16.04)系统上进行,本文的算法基于 PyTorch,PC 硬件设备为 CPU Intel(R) Core(TM) i7-6800K @3.4 GHz、GPU GeForce GTX 1080 Ti(11 GB 显存)和 16 GB DDR 4 内存。

#### 3.1 数据集及预处理

航天器复合材料缺陷图像数据集主要包含常见的裂纹(crack)、高密度夹杂(high\_inclusion)、低密度夹杂(low\_inclusion)和气孔(voids)共4类缺陷。裂纹的颜色较暗,形状修长。高密度夹杂的颜色很亮,

低密度夹杂的颜色较暗,形状不规则。气孔的颜色较暗,形状为圆形或者椭圆形。现场采集到的样本数据集一共有2800多张图像。为了防止网络在训练过程中发生过拟合的现象,本文对缺陷图像采用了样本扩充方法,主要分为两部分:第一部分是直接对部分样本进行过采样,改变样本图像的明亮度、灰度和目标角度等信息,这没有改变缺陷的本质特征,只是缺陷和背景的亮度、灰度同时改变了,有利于增强模型对不同对比度 X 射线缺陷的检测能力,除此之外还有向其中增加噪声,高斯模糊等操作,丰富数据的多样性。第二部分是直接在原始样本上对目标缺陷在不覆盖其他缺陷的前提下进行随机位置的复制粘贴。最后实验采用的数据集一共有7200张图像。

数据集是在上海卫星设备研究所利用数字 X 射线摄影(digital radiography, DR)设备实地采集的,DR 采集设备如图4所示。为了确保实验能够顺利进行,对图像进行了预处理,主要步骤为:首先将图像进行统一的标准化处理,使得样本图像更好地适应网络模型,提高特征提取的效果。之后对航天器缺陷图像进行缺陷标注,生成相应的 json 格式配置文件。最后将各图像的配置文件的配置汇总,将图像随机生成训练集和测试集。其中训练集图像数量为6400张,测试集图像数量为800张,训练集和测试集满足相同的分布,数据集分配情况如表1所示。

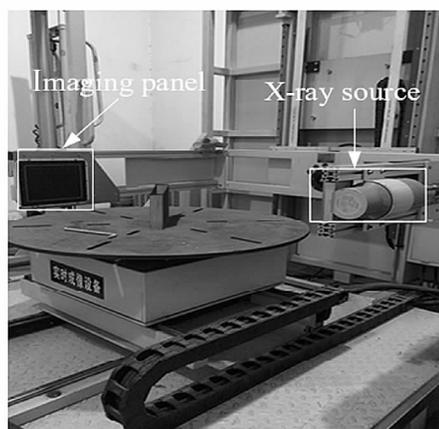


图4 DR采集设备

Fig. 4 DR acquisition equipment

表1 数据集分配情况

Tab. 1 Allocation of dataset

Dataset type	High_inclusion	Low_inclusion	Crack	Voids	Total
Training set	1553	1642	1509	1696	6400
Testing set	194	205	189	212	800
Total	1747	1847	1698	1908	7200

### 3.2 训练参数设置

实验在不同的网络结构上使用的特征提取网络均是在 ImageNet 数据集上预训练的 ResNet-50 模型(YOLOv3 使用的是 Darknet53)。在复合材料缺陷数据集上训练采用相同的参数,即:batch 大小设置为 1,训练集迭代次数为 100 000 个 iter,分割边缘损失权重大小设置为 0.7,学习率初始设置为 0.02,之后在第 50 000 个 iter 和第 80 000 个 iter 时降低学习率至 0.01 和 0.002。网络参数根据损失函数大小进行更新,本文使用基于动量 Nesterov momentum 的随机梯度下降算法优化参数,能提供更快的收敛速度和更稳定的收敛曲线,其中 momentum 设置为 0.9。

### 3.3 实验结果与分析

图 5 所示为各模型精度随迭代次数在航天器复合材料缺陷数据集上的变化情况。实验训练过程中每迭代 2 000 次后模型保存为 pth 格式文件并进行一次数据记录。在测试数据集上所有网络模型的识别精度、识别时间和召回率等检测结果和对比实验结果如表 2 和图 6 所示。

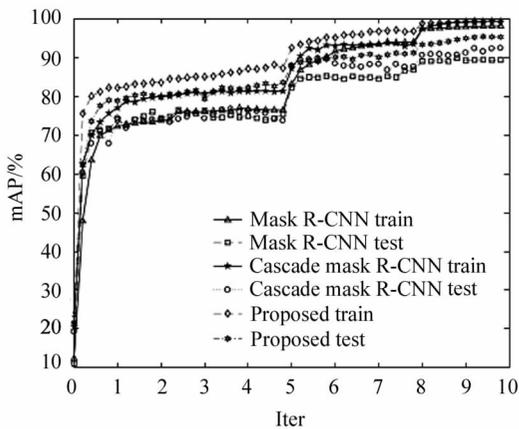


图 5 各模型精度随迭代次数变化

Fig. 5 Accuracy of each model varies with the number of iterations

表 2 网络模型的复合材料缺陷检测结果

Tab. 2 Composite material defect detection result based on network model

Network model	mAP/%	ADT/ms	Recall/%
Faster R-CNN	90.6	156	92.7
YOLOv3	72.2	43	74.3
Mask R-CNN	89.4	187	91.1
Cascade R-CNN	92.7	228	95.6
Cascade mask R-CNN	91.5	271	94.9
Proposed	<b>95.3</b>	295	<b>97.5</b>

从图 5 可以得出,本文提出的模型相比 Mask R-CNN 和 Cascade Mask R-CNN 在航天器复合材料缺陷上检测精度更高。从表 2 和图 6 可以看出,二阶目标检测网络不仅检测效果比一阶网络效果好,而且图像检测的召回率更高,在针对较小的目标对象检测时,二阶网络相比一阶网络具有一定的优势,但是一阶网络 YOLOv3 检测速度更快。Faster R-CNN 和 Cascade R-CNN 由于不进行图像分割,与常见实例分割网络相比仅进行缺陷检测的精度更高,检测时间更低,召回率也会更高。而本文提出的模型与检测精度最高的 Cascade R-CNN 相比,整体效果表现良好,平均每张图片测试耗时多出 67 ms,而缺陷检测精度提升了 2.5%左右,且额外提供了图像分割

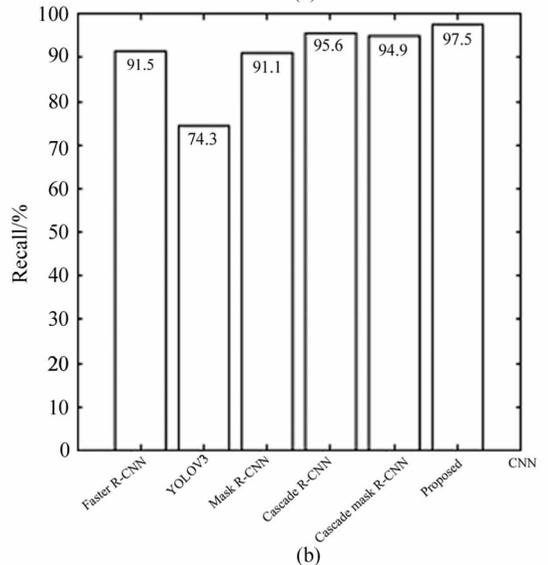
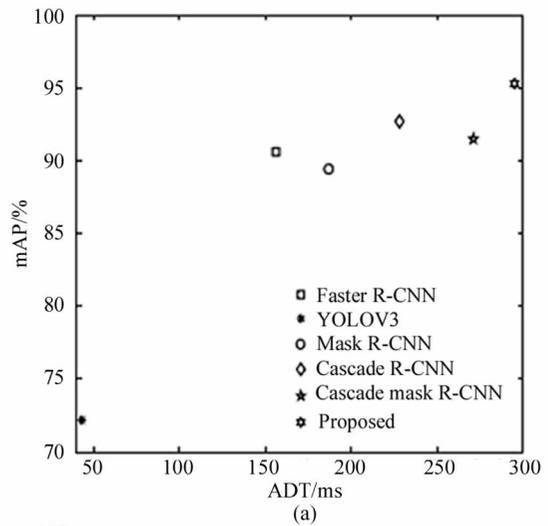


图 6 各模型测试对比实验结果:(a) 模型测试的 ADT 和 mAP 对比;(b) 模型测试的 Recall 对比

Fig. 6 Experiment results of test comparison in each model;

(a) Comparison of ADT and mAP for model testing;

(b) Comparison of Recall for model testing

的可视化效果,有利于实际生产中进行部署应用,同时缺陷图像检测的召回率也得到了 2%左右的提升。

本文提出的模型缺陷检测结果示意图如图 7 所示,而基础 Mask R-CNN 模型与是否添加频域学习、信息专注模块、级联网络结构和改进分割损失函数共 5 组实验在复合材料缺陷测试数据集上的缺陷检

测结果如表 3 所示。

由表 3 可以看出,与基础 Mask R-CNN 模型相比,无论是缺陷图像的频域输入,还是信息专注模块、级联网络结构和分割边缘损失函数对提升复合材料缺陷检测的识别精度都有一定的有效性,其中利用图像的频域信息的精度提升效果最为明显,这

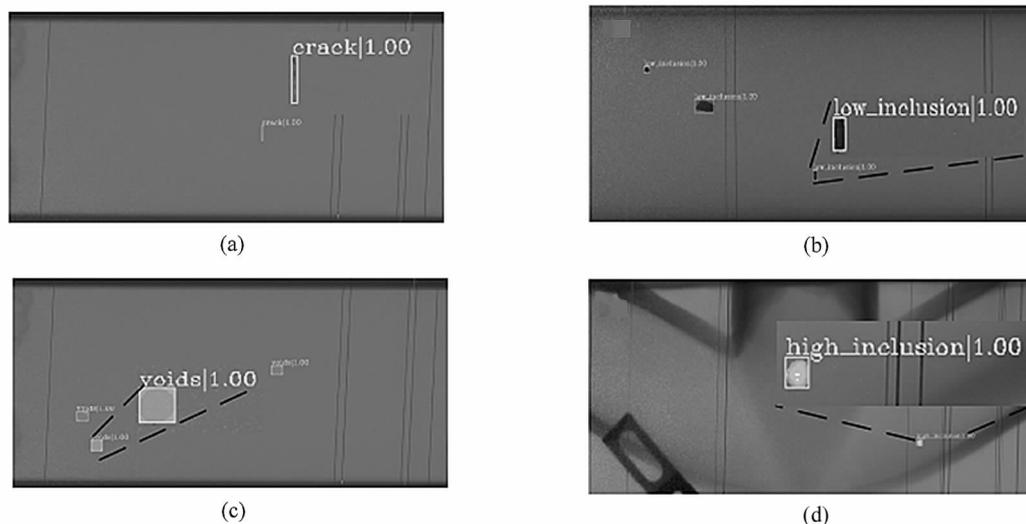


图 7 Proposed 模型缺陷检测结果示意图:(a) 裂纹缺陷检测;(b) 低密度夹杂缺陷检测;  
(c) 气孔缺陷检测;(d) 高密度夹杂缺陷检测

Fig. 7 Result diagram of the defect detection in proposed model:(a) Defect detection of crack;  
(b) Defect detection of low\_inclusion; (c) Defect detection of voids; (d) Defect detection of high\_inclusion

表 3 各模块的复合材料缺陷检测结果

Tab. 3 Results of composite defect detection in each module

Experimental group	Frequency Domain input	Informational Concentration module	Cascade structure	Segmentation edge loss function	mAP/%
1	✓	/	/	/	92.1
2	/	✓	/	/	91.7
3	/	/	✓	/	91.5
4	/	/	/	✓	90.6
5	✓	✓	✓	✓	<b>95.3</b>

表明本文的算法改进是有效的。

## 4 结 论

本文在 Mask R-CNN 网络的基础上结合级联网络结构,将空域图像输入转为频域输入来提升图像的特征提取效果,提出信息专注模块来稳定 RPN 的训练,同时利用分割边缘损失函数提高图像分割精度。将本文提出的网络模型用于复合材料内部的缺陷检测,实验证明本文模型在测试数据集上能达到 95.3% 的平均识别准确度,能用于解决实际航天复合材料内部缺陷检测,具有一定的实用意义。但是,

目前的网络模型也有一定的局限性,并不能达到实时检测缺陷的要求。接下来将进一步把研究重点放在通过损失最小的精度,实现轻量化模型的问题上,以保证缺陷检测的网络模型能满足实时性的要求。

## 参考文献:

[1] XING L Y, BAO J W, LI S M, et al. Development status and challenges of advanced resin matrix composites[J]. Acta Materiae Compositae Sinica, 2016, 33 (7): 1327-1338.  
邢丽英,包建文,礼嵩明,等.先进树脂基复合材料发展

- 现状和面临的挑战[J]. 复合材料学报, 2016, 33(7): 1327-1338.
- [2] ZHANG L G, ZHANG Z G. Analysis of main defects in advanced composite materials[J]. *Fiber Reinforced Plastics/Composites*, 2001, 27(2): 42-45, 55.  
张立功, 张佐光. 先进复合材料中主要缺陷分析[J]. 玻璃钢/复合材料, 2001, 27(2): 42-45, 55.
- [3] ZHANG H, LIU Y Z, YU L, et al. Simulation and imaging study of air-coupled Lamb wave scanning for composite plate defects[J]. *Chinese Journal of Scientific Instrument*, 2019, 40(1): 150-157.  
张慧, 刘玉振, 于露, 等. 复合板缺陷的空耦 Lamb 波扫描仿真与成像研究[J]. 仪器仪表学报, 2019, 40(1): 150-157.
- [4] ZHANG J Y, REN J J, CHEN S H, et al. Application of wavelet denoising in terahertz nondestructive testing[J]. *Chinese Journal of Lasers*, 2020, 47(1): 326-333.  
张霁昉, 任姣姣, 陈思宏, 等. 小波去噪在太赫兹无损检测中的应用[J]. 中国激光, 2020, 47(1): 326-333.
- [5] LI S B, YANG J, WANG Z, et al. Overview of the development and application of defect detection technology[J]. *Acta Automatica Sinica*, 2020, 46(11): 2319-2336.  
李少波, 杨静, 王铮, 等. 缺陷检测技术的发展与应用研究综述[J]. 自动化学报, 2020, 46(11): 2319-2336.
- [6] LIU H. Research and implementation of deep learning method for casting defects detection based on X-ray[D]. Taiyuan: Taiyuan University of Science and Technology of China, 2018: 42-45.  
刘浩. 基于 X 射线的铸件缺陷检测的深度学习方法及实现[D]. 太原: 太原科技大学, 2018: 42-45.
- [7] LI W G, YE X, ZHAO Y T, et al. Strip steel surface defect detection based on improved YOLOv3 algorithm[J]. *Acta Electronica Sinica*, 2020, 48(7): 1284-1292.  
李维刚, 叶欣, 赵云涛, 等. 基于改进 YOLOv3 算法的带钢表面缺陷检测[J]. 电子学报, 2020, 48(7): 1284-1292.
- [8] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE, 2017: 2980-2988.
- [9] XU K, QIN M, SUN F, et al. Learning in the frequency domain[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 14-19, 2020, Virtual. New York: IEEE, 2020: 1737-1746.
- [10] 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), June 27-30, 2016, Las Vegas, United States. New York: IEEE, 2016: 770-778.
- [11] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 22-25, 2017, Hawaii, United States. New York: IEEE, 2017: 2117-2125.
- [12] LONG J, SHELLHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 8-10, 2015, Boston, United States. New York: IEEE, 2015: 3431-3440.
- [13] ZHU Q, DU B, YAN P. Boundary-weighted domain adaptive neural network for prostate MR image segmentation[J]. *IEEE Transactions on Medical Imaging*, 2019, 39(03): 753-763.
- [14] CAI Z, VASCONCELOS N. Cascade R-CNN: delving into high quality object detection[C]//2018 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 18-22, 2018, Salt Lake City, United States. New York: IEEE, 2018: 6154-6162.
- [15] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and machine intelligence*, 2016, 39(6): 1137-1149.
- [16] Redmon J, Farhadi A. YOLOv3: an incremental improvement[EB/OL]. (2018-04-08)[2021-06-10]. <https://arxiv.org/abs/1804.02767>.

#### 作者简介:

罗 钧 (1963—), 男, 教授, 博士生导师, 主要研究方向为模式识别和人工智能、精密机械与测试计量、智能信息处理。