

引用格式: 吴项南, 程小劲, 李琪鑫, 等. CFRP 低速冲击损伤成像精度提升算法研究[J]. 航空材料学报, 2025, 45(1): 80-90.
WU Xiangnan, CHENG Xiaojin, LI Qixin, et al. Research on algorithm for improving imaging accuracy of CFRP low speed impact damage[J]. Journal of Aeronautical Materials, 2025, 45(1): 80-90.

CFRP 低速冲击损伤成像精度提升算法研究

吴项南¹, 程小劲^{1*}, 李琪鑫¹, 尚建华²

(1. 上海工程技术大学 机械与汽车工程学院, 上海 201620; 2. 东华大学 信息科学与技术学院, 上海 201620)

摘要: 碳纤维增强树脂基复合材料(carbon fiber reinforced polymer, CFRP)遭受低速冲击后会发生微小且隐蔽的损伤, 损伤的存在会显著降低 CFRP 材料的承载力和服役寿命。C 扫描是超声成像的常用方法, 针对 CFRP 低速冲击内部损伤的 C 扫描成像精度低这一问题, 使用梯度算子对原始图像进行处理, 并利用迁移学习的方法在 ResNet18 与 ResNet50 上进行损伤类型的分类训练。为了改善分类模型的性能, 提出基于卷积神经网络的成像精度提升算法——图像重建模型(image reconstruction model, IRM), 并基于结构相似性系数(structural similarity index, SSIM)提出采用性能指标 σ_{EOL} 验证图像性能的提升水平。迭代训练结果表明, 当迭代次数达到 200 次时, 不同种类冲击损伤的 σ_{EOL} 均大于 1。为了进一步提升成像精度, 引入 ResNet 残差连接思想, 并提出了 ResIRM 网络。与 IRM 相比, ResIRM 对不同类型撞击损伤的检测精度进一步提升, 针对全部冲击类型, 平均 σ_{EOL} 可提升 0.85%; 同时, 经 ResIRM 处理的图像分类模型的梯度显著性热力图表明, ResIRM 可以对损伤区域的特征起到强化作用。

关键词: 卷积神经网络; 无损检测; 损伤重建; 超声检测

doi: 10.11868/j.issn.1005-5053.2023.000189

中图分类号: V258; TP183

文献标识码: A

文章编号: 1005-5053(2025)01-0080-11

Research on algorithm for improving imaging accuracy of CFRP low speed impact damage

WU Xiangnan¹, CHENG Xiaojin^{1*}, LI Qixin¹, SHANG Jianhua²

(1. School of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai 201620, China; 2. School of Information Science and Technology, Donghua University, Shanghai 201620, China)

Abstract: Carbon fiber reinforced polymer(CFRP) composites has small and hidden damage after low-speed impact, and the existence of damage significantly reduces the bearing capacity and service life of CFRP materials. C-scan represents a conventional ultrasonic imaging method. To address the issue of low imaging precision in C-scan detection of internal damage caused by low-velocity impact in CFRP, gradient operators were employed to process the original images, and transfer learning methodology was utilized to conduct damage classification training on ResNet18 and ResNet50 architectures. To enhance the classification model's performance, an image reconstruction model(IRM) based on convolutional neural networks was proposed to improve imaging precision. Additionally, a performance metric σ_{EOL} , based on the structural similarity index(SSIM), was introduced to validate the level of image quality enhancement. The iterative training results demonstrate that when the iteration count reaches 200, the σ_{EOL} of different types of impact damage is greater than 1. To further improve imaging precision, the ResNet residual connection concept is incorporated, leading to the development of the ResIRM network. Compared to IRM, ResIRM exhibits enhanced detection precision for different types of impact damage, with an average σ_{EOL} improvement of 0.85% across all impact types. Furthermore, the gradient saliency heat maps of the classification model processed by ResIRM indicate that ResIRM effectively reinforces the features in damaged regions.

Key words: convolutional neural network (CNN); non-destructive testing (NDT); damage reconstruction; ultrasonic testing

碳纤维增强树脂基复合材料(CFRP)作为一种轻质高强度复合材料,具有密度小、比强度/比刚度高、耐腐蚀、抗疲劳、耐高温以及易于大面积整体成型加工等优点^[1],在航空航天、汽车制造、船舶和建筑等领域中得到广泛应用^[2]。多相体系的结构特点使得 CFRP 在受到低速冲击时极易发生微小且隐蔽的损伤,从而对其结构完整性和性能产生不可忽视的影响^[3],例如飞机起降时跑道上的碎石可能会给机身的 CFRP 材料结构造成低速冲击^[4],因此,对 CFRP 的低速冲击损伤进行准确的检测和评估至关重要。目前用于复合材料无损检测的方法主要有超声检测法^[5]、红外检测法^[6]、涡流检测法^[7]、射线检测法^[8]、声发射法^[3]、渗透检测法等^[9],不同的检测技术具有不同的特点和适用范围。针对低速冲击下的 CFRP 损伤检测,上述传统的无损检测技术在分辨率和灵敏度等方面受限,无法直接识别材料内部的微小缺陷。

深度学习技术的快速发展使其在材料损伤检测和评估领域展现出强大的潜力^[6]。Yang 等^[10]提出基于卷积神经网络(CNN)和人工神经网络(ANN)检测混凝土表面损伤的两步检测方案,CNN 进行损伤图像分类的准确率为 80.7%,而 ANN 实现表面损伤检测的准确率为 98.1%。Wei 等^[11]使用人工智能和红外热成像技术检测和分割曲面层压材料的撞击损伤图像,他们采用中波和长波红外对损伤图像进行分割,并对两个深度神经网络进行训练,结果表明中波图像模型和长波图像模型的 F1 分数分别为 92.74% 和 87.39%。Wang 等^[12]基于深度学习提出一种 DIC 图像分析方法,为 CFRP 的在线结构健康监测提供了一种新的途径。Hasebe 等^[13]基于机器学习方法,仅需借助外部损伤轮廓中

的凹陷深度和凹陷体积特征,即可预测低速冲击造成的 CFRP 内部损伤情况,预测的准确率约为 80%。

深度学习的优势在于可以从大量的数据中学习特征并实现该特征的自动提取和图像重建,进而提高图像重构的准确性和效率。同时,在图像重构过程中,还可以利用神经网络从有限的原始输入数据中学习获得更多的特征,使得重构缺陷图像更清晰,从而进一步提高缺陷的检测精度。目前,利用卷积神经网络提升 CFRP 低速冲击损伤成像精度方面的研究还不够完善,为此,本工作利用超声检测中的 C 扫描技术研究基于卷积神经网络的损伤成像精度提升算法,并评估改进后的网络结构的成像精度。

1 基于 ResNet 的损伤分类识别模型

本研究的原始数据来源于 Hasebe 等^[14]的研究成果,该文献报道了 CFRP 遭受 6 种冲头低速冲击而形成的冲击面表面图像、非冲击面表面图像、表面等深线以及超声 C 扫描后的内部损伤图像。相应的冲击实验是 CEAST 9350 落体塔冲击系统在不同的冲击条件下进行,6 种冲头类型如图 1^[13]所示,HemiA、HemiB 和 HemiC 是直径分别为 12.7、25.4 mm 和 31.8 mm 的半球形冲头,Coni60 和 Coni120 是垂直角度分别为 60°和 120°的圆锥形冲头,Flat 是直径为 15.9 mm 的平面冲头。低速冲击测试后,再使用 VR-5000 广域测量系统和超声 C 扫描系统 HIS3 测量 CFRP 的外部损伤情况。Hasebe 等使用机器学习预测了材料的内部损伤特征,但未对损伤分类模型进行研究。因此,为了提高检测的效率,本工作首先对造成低速冲击损伤的冲头类型进行识别,以迅速排查 CFRP 的撞




图 1 冲击实验的 6 种冲头形状^[13] (a)HemiA; (b)HemiB; (c)HemiC; (d)Coni60; (e)Coni120; (f)Flat

Fig. 1 Six types of impactor shapes for the impact test^[13] (a)HemiA; (b)HemiB; (c)HemiC; (d)Coni60; (e)Coni120; (f)Flat

击物的特征。

ResNet 模型^[15]是一种可以有效解决神经网络因层数增加而引起误差急剧增大的网络结构,较早期的 BP 神经网络,ResNet 引入了残差学习的概念,因而网络能够在深层次上保持较高的性能,可以有效改善深度神经网络的训练效果,该模型已在图像分类等领域取得较好的成果^[16]。因此,本工作基于经典的 ResNet18 模型和 ResNet50 模型,采用迁移学习的方法训练经过预训练的 ResNet18 和 ResNet50,从原始数据中提取 8 层层合板的数据,并根据冲击类型进行分类。

本工作首先对 C 扫描得到的冲击面方向上的 CFRP 损伤图像(图 2(a))做预处理,包括裁剪和灰度处理两部分,得到图 2(b)。在图 2(b)中,可以发现冲击区域的图像灰度值变化较大,即冲击区域的图像灰度的梯度较大。梯度是损失函数相对于模型参数的变化率,基于梯度的显著性(gradient-based saliency)可以度量网络训练过程中的某个特征^[17],它指明了实现损失函数最小化所需的参数更新方向。因此,本工作对图 2(b)进行梯度计算,然后做梯度归一化处理,得到灰度梯度反转图,如图 2(c)所示。




图 2 图像预处理示意图 (a)原始图像;(b)裁剪处理后的图像;(c)梯度处理后的图像

Fig. 2 Illustration of image preprocessing (a)original image; (b)image after cropping; (c)image after gradient processing

为了分析梯度处理后图像对分类模型性能的影响,以仅经过裁剪和灰度处理的图像为实验组并放入 ResNet18 模型和 ResNet50 模型进行训练,以经过预处理和梯度处理的图像为对照组,如图 3 所示。两次图像训练对应的超参数保持一致,且每次训练均使用三折交叉验证的方法进行训练及验证。表 1 为训练得到的图像分类模型性能,包括各模型的平均 Top-1 准确率、平均 Top-5 准确率和平均 F1 分数。从表 1 的 Cropped 行和 Gradient 行可知,相比只做预处理的图像而言,梯度处理后的图像经两种模型训练所得的分类准确率及 F1 分数均有提高,这表明梯度处理可使图像强化训练模型对缺陷特征的辨识能力,因此,后续研

究以灰度梯度反转图作为内部损伤的标签(label)图像。

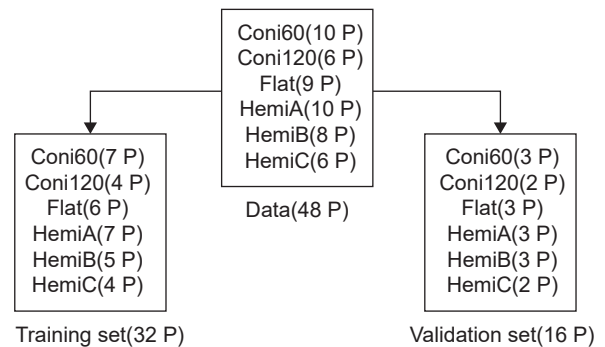


图 3 分类训练数据划分

Fig. 3 Classification training data splitting

表 1 图像分类模型性能比较(平均值)

Table 1 Comparison of image classification performance (average)

Image type	Top-1 acc/%		Top-5 acc/%		F1 score	
	ResNet18	ResNet50	ResNet18	ResNet50	ResNet18	ResNet50
Cropped	45.10	38.85	97.92	97.92	0.4309	0.2870
Gradient	48.65	39.09	93.87	87.87	0.4463	0.3151
ResIRM	61.27	48.90	95.83	91.79	0.5914	0.4216

2 基于 CNN 的内部损伤成像精度提升算法

2.1 卷积神经网络理论基础

卷积神经网络(convolutional neural networks, CNN)由 Lecun 等^[18]在 1998 年首次提出。对于本工作处理的灰度模式图像,输入层是一个由 0~255 的数字组成的矩阵, CNN 中的卷积指离散卷积,二维离散卷积的定义如式(1)所示。

$$(f * g)(m, n) = \sum_i \sum_j f(i, j)g(m-i, n-j) \quad (1)$$

式中: f 是输入矩阵; g 是权重系数矩阵。对于点 (m, n) , 二维离散卷积输出函数是将 $f(i, j)$ 与 $g(m-i, n-j)$ 的乘积相加, 其中, i 和 j 是在 f 函数定义域内进行求和运算的离散变量。在卷积层中, 本工作使用修正线性单元(rectified linear unit, ReLU), 离散变量大于零时, 该函数是线性变化的, 反之则函数输出始终为零。由于本研究的最终输

出目标是灰度图像, 因此使用 Sigmoid 函数将模型的预测结果限制在 0 到 1 之间。

2.2 损伤成像精度提升算法架构

基于 CNN 的内部损伤成像精度提升算法的架构如图 4 所示。首先, 以构建得到的数据集为对象, 建立一个卷积神经网络, 包括编码器和解码器两部分。在前向传播过程中, 输入图像通过编码器得到特征表达, 解码器负责图像重构。其中, 编码器由一系列的卷积层和 ReLU 激活函数组成, 它以卷积层和 ReLU 激活函数为特征提取器, 通过逐步缩小输入的单通道(灰度)图像的尺寸和增加特征通道的数量, 进而从输入图像中提取高级特征; 而解码器旨在借助转置卷积层对编码器的输出特征进行上采样, 并通过 ReLU 激活函数进行非线性激活, 另外, 解码器的最后一层借助 Sigmoid 激活函数限制图像中每个像素的强度。然后, 通过双三次插值方法调整解码器的输出图像尺寸, 以使其尺寸与输入图像相同。

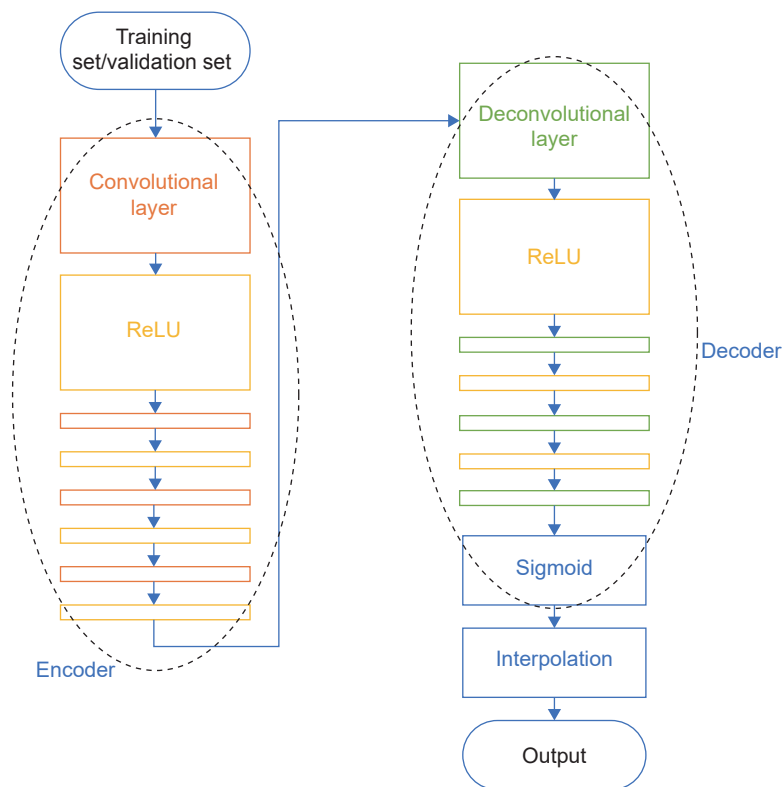


图 4 图像重建模型结构

Fig. 4 Image reconstruction model(IRM) architecture

算法执行时, 将训练集与验证集同时打包放入图像重建模型(image reconstruction model, IRM)进行训练, 通过观察训练集和验证集 Loss 的收敛情况, 迅速进行早停(early stopping)和参数调整等处理, 进而获得最佳的网络性能参数。训练结束后, 固化网络参数, 并借助预留集进行测试和预测, 最

终获得优化损伤图像。

2.3 损伤成像精度提升算法实验平台

使用的编程及实验平台为 Google 公司的 Colaboratory, 实验平台的内存为 12.7 GB、GPU 为 Tesla T4、磁盘空间为 78.2 GB, 深度学习框架为 Pytorch。

(1) 数据划分

首先,建立冲击面表面和非冲击面表面的图像数据集。然后,根据待测层合板的损伤类型构建相应的标签数据库,将冲击面表面的图像划分为训

练集,将非冲击面表面的图像划分为验证集,将经过预处理的内部缺陷图作为预留集进行评估,且训练集、验证集和预留集的图像均为48张,如图5所示。




图5 IRM的训练数据划分 (a)训练集;(b)验证集;(c)预留集

Fig. 5 Data splitting for IRM training (a) training set (impacted surface); (b) validation set (non-impacted surface); (c) hold-out test set (internal damage)

(2) 数据增强

数据增强^[19](data augmentation)是对训练集进行变换,以使其更丰富。针对训练集和验证集数量较少的问题,在网络读取时,通过随机旋转图片(最大旋转角度45°)和随机水平翻转图片扩充训练集。

(3) 损失函数及评估指标

如式(2)所示,本工作以均方误差MSE^[20]作为损失函数 $L(\text{mse})$,它是一种广泛用于回归问题的损失函数(loss function),通过对重建图像和目标图像中的每个像素值的差进行平方、取平均而求得。

$$L(\text{mse}) = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (2)$$

式中: n 表示输入数据的个数; x_i 是单个的样本数据; \hat{x}_i 是与 x_i 相匹配的重建数据。

在评估指标选择方面,本工作选择结构相似性指数(SSIM)^[21],它是一种比较两幅图像结构相似性的指标,与传统的均方误差(MSE)不同,SSIM由三个子指标组成:亮度、对比度和结构。亮度用于分析比较局部均值结果,对比度用于分析比较局部标准偏差,结构指数则表示局部皮尔逊相关系数^[22]。本文使用的算法逻辑与图像恢复(image restoration)处理算法有着较强的相似性,对于图像恢复度量,Wang的研究表明,保持信号的结构是一个重要的评判准则,因此,算法可以通过测量结构的失真情况度量图像的恢复程度。非结构失真(亮度变化、对比度变化、伽马失真和空间位移)一般是由图像获取和显示过程中的仪器条件或环境情况引起的,这些失真不会改变视觉场景中对象图像的结构,而

噪声、模糊和有损压缩等造成的失真将会严重影响图像的结构。如果将人类视觉系统视为一个理想的信息提取器,用以识别视觉场景中的对象,那么它必须对结构失真高度敏感,并能够自动补偿非结构失真。因此,借助SSIM评估两幅图像的重构效果^[23]。

为了更直观地评估图像重构效果,提出评价指标 σ_{EOL} ,如式(3)所示:

$$\sigma_{\text{EOL}} = \frac{\text{SSIM between estimated and label}}{\text{SSIM between original and label}} \quad (3)$$

式中:SSIM between estimated and label为重构图像与特征图像的SSIM;SSIM between original and label为原始图像与特征图像的SSIM。实验中,当重构图像与特征图像的SSIM比原始图像与特征图像的SSIM大(σ_{EOL} 的分子大于分母),则 σ_{EOL} 大于1,即可判定具有图像重构的提升效果。

2.4 损伤成像精度提升算法实验结果

使用IRM模型对预留集进行处理,保持超参数不变,当迭代次数达到154时,训练集的Loss和验证集的Loss已经达到0.001;当迭代次数为220次至240次时,Loss在小范围内发生振荡。

分别以迭代50、200次和400次作为训练结果,冻结参数,损伤成像精度提升算法的实验结果如表2所示。迭代50次后, σ_{EOL} after 50 epochs列中部分重构图片的 σ_{EOL} 下降,即模型没有达到最佳性能点。迭代200次后,虽然 σ_{EOL} after 200 epochs列中部分重构图片的 σ_{EOL} 相比迭代50次的结果有所降低,但全部图片的 σ_{EOL} 均高于1,因此该模型

表 2 迭代后的模型对每张图片的 σ_{EOL}
Table 2 σ_{EOL} of model for each image after epochs

Impactor type	Image number	σ_{EOL} after 50 epochs	σ_{EOL} after 200 epochs	σ_{EOL} after 400 epochs	σ_{EOL} after ResIRM process	σ_{EOL} improvement	Average σ_{EOL} improvement
Coni60	c8-7	1.0046	1.0008	1.0008	1.0115	0.0107	0.0097
	c8-8	1.0009	1.0002	1.0005	1.0104	0.0102	
	c8-9	1.0015	1.0003	1.0006	1.0104	0.0101	
	c8-9t	<u>0.9986</u>	1.0002	1.0006	1.0098	0.0096	
	c8-10	1.0003	1.0002	1.0004	1.0096	0.0094	
	c8-10t	<u>0.9943</u>	1.0002	1.0009	1.0084	0.0082	
	c8-11	1.0043	1.0005	1.0008	1.0115	0.0011	
	c8-12	1.0015	1.0002	1.0006	1.0106	0.0104	
	c8-42	1.0103	1.0044	<u>0.9994</u>	1.0132	0.0088	
	c8-43	1.0103	1.0048	<u>0.9988</u>	1.0130	0.0082	
Coni120	c8-32	1.0061	1.0018	1.0008	1.0119	0.0101	0.0100
	c8-33	1.0056	1.0015	1.0008	1.0118	0.0103	
	c8-34	1.0059	1.0017	1.0008	1.0118	0.0101	
	c8-35	1.0073	1.0021	1.0007	1.0124	0.0103	
	c8-36	1.0079	1.0024	<u>0.9996</u>	1.0126	0.0102	
	c8-37	1.0103	1.0040	<u>0.9982</u>	1.0131	0.0091	
	Flat	c8-11t	<u>0.9950</u>	1.0001	1.0008	1.0071	
c8-12t		<u>0.9945</u>	1.0002	1.0009	1.0083	0.0081	
c8-13		1.0044	1.0006	1.0008	1.0117	0.0111	
c8-14		1.0018	1.0002	1.0006	1.0109	0.0107	
c8-15		1.0009	1.0002	1.0005	1.0104	0.0102	
c8-16		1.0037	1.0004	1.0005	1.0113	0.0109	
c8-17		1.0010	1.0002	1.0006	1.0106	0.0104	
c8-18		1.0010	1.0002	1.0006	1.0105	0.0103	
c8-19		1.0173	1.0101	<u>0.9662</u>	1.0148	0.0047	
HemiA		c8-1	1.0040	1.0005	1.0008	1.0111	0.0106
	c8-2	1.0006	1.0002	1.0005	1.0101	0.0099	
	c8-3	<u>0.9997</u>	1.0002	1.0005	1.0097	0.0095	
	c8-4	1.0052	1.0003	1.0002	1.0115	0.0112	
	c8-5	1.0014	1.0002	1.0005	1.0105	0.0103	
	c8-6	1.0016	1.0002	1.0006	1.0107	0.0105	
	c8-6t	<u>0.9949</u>	1.0002	1.0009	1.0084	0.0082	
	c8-8t	<u>0.9951</u>	1.0002	1.0009	1.0087	0.0085	
	c8-38	1.0081	1.0035	<u>0.9995</u>	1.0124	0.0089	
	c8-39	1.0108	1.0047	<u>0.9986</u>	1.0132	0.0085	

表 2 (续)
Table 2 (Continued)

Impactor type	Image number	σ_{EOL} after 50 epochs	σ_{EOL} after 200 epochs	σ_{EOL} after 400 epochs	σ_{EOL} after ResIRM process	σ_{EOL} improvement	Average σ_{EOL} improvement
HemiB	c8-25	1.0193	1.0097	<u>0.9488</u>	1.0149	0.0052	0.0058
	c8-26	1.0198	1.0102	<u>0.9493</u>	1.0151	0.0049	
	c8-27	1.0198	1.0105	<u>0.9502</u>	1.0152	0.0047	
	c8-28	1.0204	1.0107	<u>0.9480</u>	1.0154	0.0047	
	c8-29	1.0200	1.0107	<u>0.9503</u>	1.0153	0.0046	
	c8-30	1.0190	1.0092	<u>0.9535</u>	1.0150	0.0058	
	c8-40	1.0097	1.0041	1.0000	1.0127	0.0086	
	c8-41	1.0113	1.0052	<u>0.9967</u>	1.0134	0.0082	
HemiC	c8-19	1.0173	1.0101	<u>0.9662</u>	1.0148	0.0047	0.0065
	c8-20	1.0042	1.0009	1.0008	1.0111	0.0102	
	c8-21	1.0160	1.0079	<u>0.9697</u>	1.0143	0.0064	
	c8-22	1.0184	1.0096	<u>0.9534</u>	1.0143	0.0047	
	c8-23	1.0160	1.0079	<u>0.9738</u>	1.0145	0.0066	
	c8-24	1.0160	1.0079	<u>0.9758</u>	1.0146	0.0067	

可以提升缺陷损伤成像精度;由于预留集没参与模型的训练及验证,因此模型的泛化能力也得以证明。迭代 400 次后,较迭代 200 次的结果而言, σ_{EOL} after 400 epochs 列中大部分图片的性能均降低,此时模型发生了过拟合。综上所述,在训练的过程中,训练集和验证集的 Loss 在迭代 200 次以后几乎不变,因此选取迭代 200 次作为最佳性能点。

3 损伤成像精度提升算法改进

3.1 IRM 网络结构改进

2.4 节的实验结果表明,IRM 的结构复杂、训练时间长,需要大量迭代才能达到最优性能;其次,网络训练过程中梯度逐渐下降,导致训练中网络寻找局部最优解的过程逐步放慢。因此,为了优化训练的性能,以此为切入点,引入残差模块。借助 ResNet^[15] 的残差连接思路,在图像输出前将输入图像与神经网络处理后的输出图像相减,改进后的神经网络命名为 ResIRM,结构图如图 6 所示。

改进后的神经网络 ResIRM,其损失函数 Loss 的收敛速度较快,可以从 Loss 的折线图(图 7)推测该神经网络的性能。图 7(a)表明模型在第 5 次迭代达到收敛。图 7(b)表明训练集和验证集的

Loss 在第 10 次迭代左右收敛,因此可选择第 10 次迭代作为训练的结束时刻,冻结网络并进行性能验证。图 7(c)表明网络在第 10 次迭代收敛。

3.2 ResIRM 结果评估

为评估改进后的神经网络 ResIRM 的重建效果,重新计算每张图片重建前后的 SSIM 及 σ_{EOL} 。图 8 中,第一列为仅做裁剪处理的 6 种冲击损伤原始图像,第二列是 ResIRM 重建后的图像,第三列是标签图像及 σ_{EOL} 结果。在图 8(a)中,原始图像右侧边界的轮廓是模糊的,而处理得到的图像更加清晰;图 8(b)~(f)原始图像经过处理后,损伤区域的轮廓特征也得到强化;对于图 8(c)而言,模型对损伤图像边缘的形变进行了强化。

ResIRM 处理后的各图像的 σ_{EOL} 结果如表 2 的“ σ_{EOL} after ResIRM process”列所示,借助神经网络 ResIRM 优化后, σ_{EOL} 全部大于 1。将表 2 中的“ σ_{EOL} after ResIRM process”与 2.4 节中第 200 个迭代后得到的性能最优解 σ_{EOL} (表 2 中的“ σ_{EOL} after 200 epochs”)进行比较,然后再求平均值,可得到 ResIRM 对每类冲击损伤图像的优化程度。其中,Coni120 的平均提升效果为 0.0100 即 1%,Coni60 的平均提升效果为 0.97%,HemiA 的平均提升效果为 0.96%,Flat 的平均提升效果为 0.93%,HemiC 的平均提升效果为 0.65%,HemiB 的

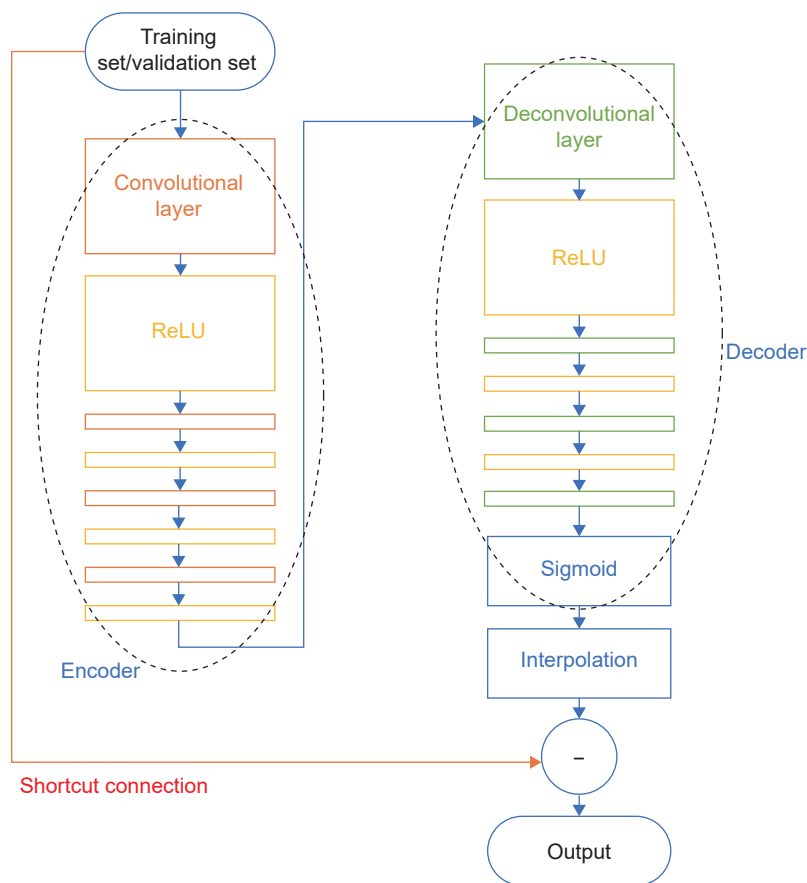


图 6 ResIRM 神经网络结构

Fig. 6 ResIRM architecture




图 7 ResIRM 网络 Loss 折线图 (a)迭代 50 次损失折线图; (b)迭代 20 次损失折线图; (c)迭代 10 次损失折线图

Fig. 7 Line chart of loss during epochs of ResIRM (a) loss during 50 epochs of ResIRM; (b) loss during 20 epochs of ResIRM; (c) loss during 10 epochs of ResIRM

平均提升效果为 0.58%，因此，综合上述全部冲击类型，引入残差连接的 ResIRM 对 σ_{EOL} 的平均提升效果为 0.85%，能够有效提高 CFRP 内部缺陷损伤的成像精度。

4 损伤分类识别模型性能提升验证

4.1 ResIRM 处理后图像的分类模型性能评估

基于分类模型 ResNet^[15] 对经过 ResIRM 处理

的图像进行分类训练，并以原始图像和梯度处理后的图像为对照组，数据划分方式和图 3 一致，且三次训练的超参数保持一致；每类图像训练过程中，仍使用三折交叉验证的方法进行训练及验证，最后计算交叉验证训练后各模型的平均 Top-1 准确率、Top-5 准确率和 F1 分数，平均 Top-1 准确率和 F1 分数越高，成像的精度越好。实验结果如表 1 中的“ResIRM”行所示。

与表 1 中 Cropped 行数据相比，损伤图像经过

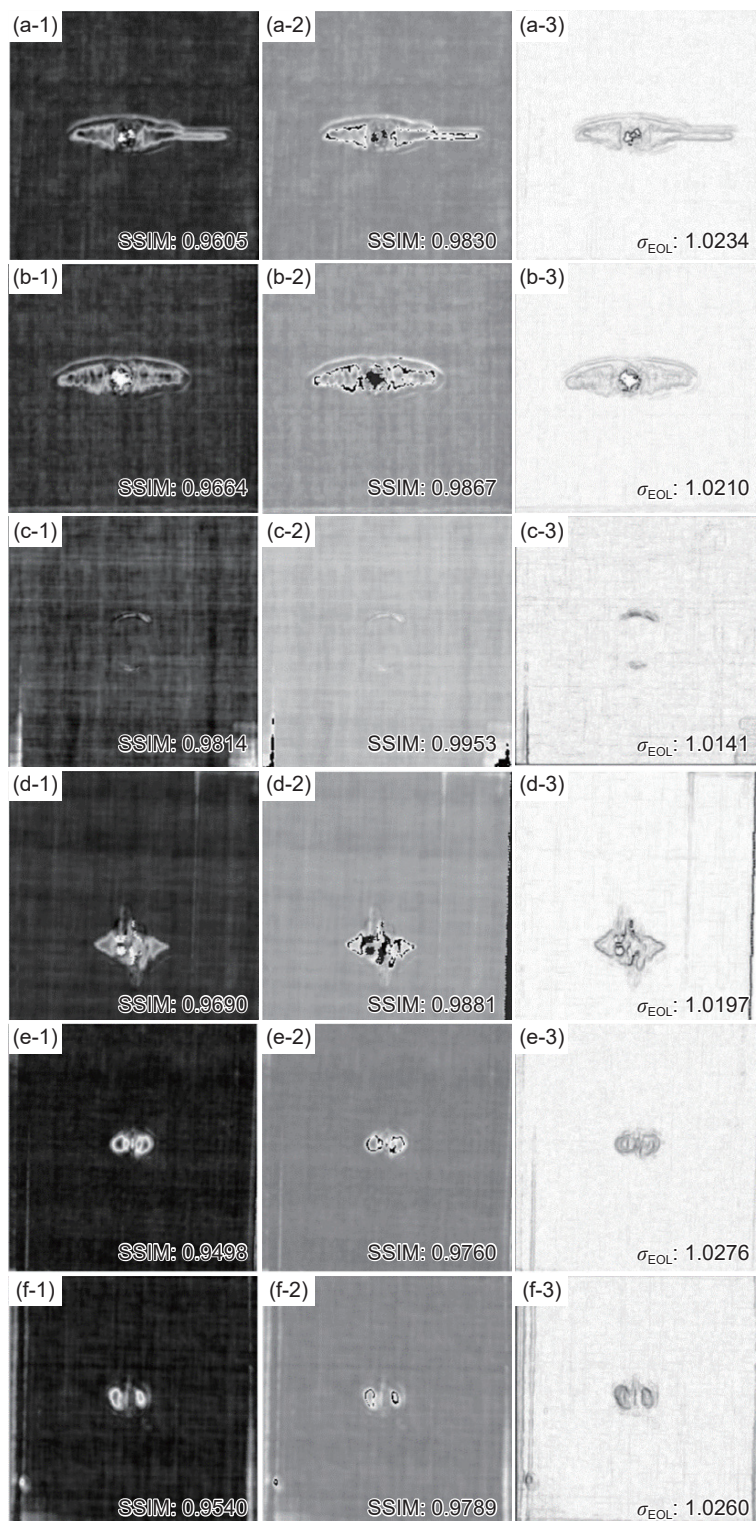


图 8 ResIRM 重建结果图 (a)Coni60_c8-43; (b)Coni120_c8-33; (c)Flat_c8-12t; (d)HemiA_c8-1; (e)HemiB_c8-26; (f)HemiC_c8-21; (1)原始图像; (2)ResIRM 重建图像; (3)标签图像及 σ_{EOL}

Fig. 8 ResIRM reconstruction output (a)Coni60_c8-43; (b)Coni120_c8-33; (c)Flat_c8-12t; (d)HemiA_c8-1; (e)HemiB_c8-26; (f)HemiC_c8-21; (1)original image; (2)ResIRM estimated image; (3)label image and σ_{EOL}

ResIRM 处理后, ResNet18 中的平均 Top-1 准确率提升 16.17%, 平均 F1 分数提升 0.1606; ResNet50 中的平均 Top-1 准确率提升 10.05%, 平均 F1 分数提升 0.1346。上述结果说明本工作提出的损伤成

像精度提升算法对于损伤分类识别这一目标是有利的。经过训练, 分类模型的平均 Top-1 准确率均得到提高, 与此同时, 平均 Top-5 的准确率降低 (如表 1 中的 Top-5 准确率), 这表明模型在最有

信心的预测方面具有较好的预测效果,但相似类别则区分能力较弱,这与图像重建后相似类别图像的相似度直接相关;对于本研究而言,则更为关注模型预测单一最可能缺陷类别的性能,因此 Top-1 准确率是评价算法性能的重要指标。其次, ResNet18 与 ResNet50 模型的 F1 分数的提高,说明模型的精确率 (precision) 和召回率 (recall) 得到同步提升,这也表明模型能够从数据中提取得到更有效和更显著的特征信息,可以在预测时得到更加准确的结果。

4.2 ResIRM 处理后图像的分类模型的梯度显著性分析

梯度显著性热力图可将神经网络对输入图像的敏感程度进行可视化显示^[24],通过计算模型输出变量与输入变量的梯度值确定对模型分类的决策最为关键的区域。针对 4.1 节的训练结果,基于 ResNet18 分类模型绘制各模型对于同一张损伤特征的梯度显著性热力图,以 Coni120_c8-35 为例,




图 9 ResNet18 梯度显著性热力图(c8-35) (a)冲击损伤原始图像;(b)梯度处理后图像;(c)ResIRM 处理后图像;
(1)输入图像;(2)显著性热力图

Fig. 9 ResNet18 gradient saliency heatmap(c8-35)
(a)original image of impact damage;(b)image after gradient processing;(c)image after ResIRM processing;
(1)input image;(2)saliency heatmap

图 9(a-1)~9(c-1)依次为仅做裁剪处理的冲击损伤原始图像、梯度处理后的图像和 ResIRM 处理后的图像,9(a-2)~9(b-3)依次为相应的梯度显著性热力图,颜色越亮的区域表明模型认为该区域对分类结果的影响程度越大。从图 9 可知,经 ResIRM 处理后的样本显著性热力图在图像中央区域亮度最高、亮点最密集,较仅做裁剪的原始图像以及梯度处理的图像而言,ResIRM 处理图像对应的梯度显著性热力图中亮点区域与缺陷的形状最为相似;同时,ResIRM 处理图像更为关注图像中央区域的梯度变化情况,“认为”缺陷主要分布在图像的中央区域,因此,ResIRM 能够强化分类模型对损伤分布特征的敏感度。

5 结论

(1)提出一种基于卷积神经网络的成像精度提升算法 IRM,并基于 SSIM 引入性能指标 σ_{EOL} 用于验证图像的性能提升水平。在对图像重建模型进行迭代训练时,在第 200 次迭代时,可以得到 σ_{EOL} 均大于 1 的效果,证明了上述算法可以有效改善受低速冲击后 CFRP 内部损伤的成像精度。

(2)基于 ResNet 的残差结构的思想,得到优化网络结构 ResIRM,网络性能得到进一步提升,Coni120、Coni60、HemiA、Flat、HemiC 和 HemiB 的平均提升效果分别为 1%、0.97%、0.96%、0.93%、0.65% 和 0.58%,全部缺陷的平均 σ_{EOL} 可提升 0.85%。

(3)通过分析 ResIRM 处理图像在分类模型中的梯度显著性,证明成像精度提升算法对缺陷区域的特征具有较好的强化作用。

参考文献:

- [1] JEROEN V, ADIL H O, ERIK V, et al. Probabilistic ultrasound C-scan imaging of barely visible impact damage in CFRP laminates[J]. *Composite Structures*, 2022, 284: 115209.
- [2] 鄢国洪. 碳纤维复合材料的特性及其切削加工刀具研究[J]. *制造技术与机床*, 2015(8): 93-97.
YAN G H. Research on machining features and cutting tools of carbon fiber-reinforced plastics[J]. *Manufacturing Technology & Machine Tool*, 2015(8): 93-97.
- [3] 刘增华,董拓灿,彭秋玲,等. 碳纤维复合材料板的声发射源定位[J]. *无损检测*, 2016, 38(10): 48-52.
LIU Z H, DONG T C, PENG Q L, et al. Acoustic emission source localization of carbon fiber composite plate[J]. *Nondestructive Testing*, 2016, 38(10): 48-52.

- [4] 张彦中, 宁荣昌. CFRP层板的落重冲击分层损伤研究[J]. 航空材料学报, 1996, 16(2): 57-62.
ZHANG Y Z, NING R C. Study on delamination of CFRP laminates subjected by drop-weight impact[J]. Journal of Aeronautical Materials, 1996, 16(2): 57-62.
- [5] İSMAIL E P, ERDAL E. Deep learning-based detection of aluminum casting defects and their types[J]. *Engineering Applications of Artificial Intelligence*, 2023, 118: 105636.
- [6] 胡博振. 基于深度学习时空特征提取的红外缺陷检测研究[D]. 成都: 电子科技大学, 2021.
HU B Z. A study on infrared defect detection based on spatiotemporal feature extraction using deep learning[D]. Chengdu: University of Electronic Science and Technology of China, 2021.
- [7] BULL D J, HELFEN L, SINCLAIR I, et al. A comparison of multi-scale 3D X-ray tomographic inspection techniques for assessing carbon fibre composite impact damage[J]. *Composites Science and Technology*, 2013, 75: 55-61.
- [8] 张逸. 基于卷积神经网络的复合材料缺陷数字射线图像识别研究[D]. 南京: 南京航空航天大学, 2020.
ZHANG Y. A study on digital radiographic image recognition of composite material defects based on convolutional neural networks[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2020.
- [9] 刘松平, 郭恩明, 刘菲菲, 等. 面向大型复合材料结构的高效超声自动扫描成像检测技术[J]. 航空制造技术, 2012(18): 79-82.
LIU S P, GUO E M, LIU F F, et al. High efficient ultrasonic automatic scanning imaging inspection technique for large-scale composites structure[J]. *Aeronautical Manufacturing Technology*, 2012(18): 79-82.
- [10] YANG A Y, CHENG L. Two-step surface damage detection scheme using convolutional neural network and artificial neural network[C]//2020 IEEE 23rd International Conference on Information Fusion(FUSION), 6-9 July 2020. New York: IEEE Press, 2020.
- [11] WEI Z A, FERNANDES H C, HERRMANN H G, et al. A Deep learning method for the impact damage segmentation of curve-shaped CFRP specimens inspected by infrared thermography[J]. *Sensors*, 2021, 21: 395.
- [12] WANG Y S, LUO Q T, XIE H, et al. Digital image correlation (DIC) based damage detection for CFRP laminates by using machine learning based image semantic segmentation[J]. *International Journal of Mechanical Sciences*, 2022, 230: 107529.
- [13] HASEBE S, HIGUCHI R, YOKOZEKI T, et al. Internal low-velocity impact damage prediction in CFRP laminates using surface profiles and machine learning[J]. *Composites Part B*, 2022, 237: 109844.
- [14] HASEBE S, HIGUCHI R, YOKOZEKI T, et al. Dataset for surface and internal damage after impact on CFRP laminates[J]. *Data in Brief*, 2022, 43: 108462.
- [15] HE K M, ZHANG X, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV. New York: IEEE Press, 2016: 770-778.
- [16] SERGEY I, CHRISTIAN S. Batch normalization: accelerating deep network training by reducing internal covariate shift[J]. *ArXiv*, 2015, 2: 1502.03167.
- [17] SUN X F, YANG D Y, LI X Y, et al. Interpreting deep learning models in natural language processing: a review[J]. *ArXiv*, 2021, 10: 2110.10470.
- [18] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-324.
- [19] CONNOR S, TAGHI M K. A survey on image data augmentation for deep learning[J]. *Journal of Big Data*, 2019, 6(1): 57-62.
- [20] PISHRO-NIK H. Introduction to probability, statistics, and random processes [M/OL]. Greece: Kappa Research LLC, 2014. [https://www.probabilitycourse.com/chapter9/9_1_5_mean_squared_error_MSE.php].
- [21] ZHOU W, BOVIK A C, SHEIKH HR, et al. Image quality assessment: from error visibility to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600-612.
- [22] PENG J Y, SHI C Y, LAUGEMAN E, et al. Implementation of the structural SIMilarity (SSIM) index as a quantitative evaluation tool for dose distribution error detection[J]. *Medical Physics*, 2020, 47(4): 1907-1919.
- [23] WANG Z, BOVIK A C. Mean squared error: love it or leave it? a new look at signal fidelity measures[J]. *IEEE Signal Processing Magazine*, 2009, 26(1): 98-117.
- [24] 郁嘉辰. 基于深度学习的图像显著性检测研究[D]. 金华: 浙江师范大学, 2022.
YU J C. A study on image saliency detection based on deep learning[D]. Jinhua: Zhejiang Normal University, 2022.

收稿日期: 2023-11-03; 录用日期: 2024-04-05

基金项目: 国家自然科学基金面上项目 (52173219)

通讯作者: 程小劲(1978—), 男, 博士, 副研究员, 研究方向为激光光电子及其相关技术, 联系地址: 上海市松江区广富林街道龙腾路 333 号(201620), E-mail: xjcheng@sues.edu.cn

(本文责编: 王俊丽)