

引文格式: 周登, 李雪峰, 严刚, 等. 基于电学成像与深度学习的蜂窝结构冲击损伤识别研究[J]. 航空制造技术, 2024, 67(13): 84-91.

ZHOU Deng, LI Xuefeng, YAN Gang, et al. Impact damage identification for honeycomb sandwich structure by using electrical tomography and deep learning[J]. Aeronautical Manufacturing Technology, 2024, 67(13): 84-91.

# 基于电学成像与深度学习的蜂窝结构冲击损伤识别研究\*

周登, 李雪峰, 严刚, 黄再兴

(南京航空航天大学航空航天结构力学及控制全国重点实验室, 南京 210016)

[摘要] 针对蜂窝夹层结构遭受外物冲击的情况, 提出结合电学成像和深度学习的方法, 对冲击损伤进行在线监测和识别, 为结构完整性评估和决策提供准确信息。首先通过丝网印刷技术, 使用碳油墨和银浆油墨在结构表面分别制备感应层和导电路径; 然后对不同数量、位置和尺寸的冲击损伤进行数值仿真, 获取对应的感应层电导率变化与边界电压变化数据样本, 由残差神经网络进行深度学习, 建立二者的映射关系; 最后在结构遭受冲击前后分别测量感应层的边界电压数据, 通过训练好的残差神经网络重建感应层电导率变化分布的图像, 实现损伤信息的识别。通过对蜂窝夹层结构进行低速冲击试验, 验证了所提出技术和方法的可行性和有效性。

关键词: 蜂窝夹层结构; 冲击损伤识别; 印刷感应层; 电学成像; 深度学习

DOI: 10.16080/j.issn1671-833x.2024.13.084



周登  
博士研究生, 研究方向为复合材料结构健康监测。

蜂窝夹层结构因其比强度高、比模量大等优点被广泛应用于航空航天飞行器结构中<sup>[1]</sup>。但在飞行器制造与服役期间, 不可避免会出现因工具跌落、砂石撞击、冰雹冲击等意外状况而造成的冲击损伤, 显著降低蜂窝夹层结构的强度和稳定性<sup>[2]</sup>。因此, 发展结构健康监测技术对蜂窝夹层结构进行在线监测, 及时识别获取冲击损伤的信息用于结构完整性评估和决策, 对提高飞行安全具有重要意义。

经过多年的发展, 国内外学者已提出了较多针对蜂窝夹层结构的损伤监测和识别方法<sup>[3-7]</sup>。如 Siivola 等<sup>[3]</sup>将分布式光纤传感器内置于夹层结构面板中, 通过传感器获得的应变数据来识别冲击损伤区域, 但应变对损伤不太敏感, 需要在结构中布置比较密集的光纤传感器。Sikdar 等<sup>[4]</sup>

采用超声导波对蜂窝夹层结构中的冲击损伤进行监测, 通过比较冲击前和冲击后在结构中传播的超声导波, 定义信号差异系数作为损伤指标, 结合概率成像算法对冲击损伤进行成像识别, 从而获得损伤的位置等信息; 但研究也表明, 蜂窝夹层会对面板中传播的导波产生一定的干扰, 影响损伤识别的效果。Rellinger 等<sup>[7]</sup>综合使用多种监测方法对蜂窝夹层结构的冲击损伤进行识别, 先由电涡流技术识别出落锤撞击点, 再通过红外热成像技术获取分层损伤情况, 最后使用激光扫描技术测量表面损伤尺寸, 结果表明, 这些方法的组合可以有效识别出蜂窝夹层结构受冲击后芯层、面板等部位多种形式的损伤, 但难以与结构集成, 无法实现对损伤的在线监测。

近年来, 电学成像这种非侵入方

\* 基金项目: 航空科学基金(2017ZA52005); 航空航天结构力学及控制全国重点实验室开放课题(MCMS-E-0423G02)。

式的低成本检测技术被应用到复合材料结构损伤监测中,其原理是通过获取导电物体的边界电压信息重建物体内部的电性能分布以反映损伤的状态<sup>[8]</sup>。如 Nonn 等<sup>[9]</sup>在碳纤维复合材料层合板周边布置了电极,输入电流并测量电极的电压,结合三维有限元仿真重建层合板内部各向异性的电导率分布从而确定损伤区域。Thomas 等<sup>[10]</sup>在炭黑改性的玻璃纤维圆柱壳结构的两端布置电极,通过对电流激励和电压测量模式进行改进,应用电学成像方法重建了冲击损伤引起的复合材料电导率变化分布图像,监测和识别出多个部位不同冲击能量造成的损伤。此外,也有研究者通过在复合材料结构表面或内部集成感应层,结合电学成像对损伤进行监测和识别。如 Yan 等<sup>[11]</sup>通过丝网印刷技术在玻璃纤维层合板上印制了智能传感层,并利用基于 Tikhonov 正则化的电学成像技术成功识别出了准静态压痕损伤,结果表明,智能传感层的电导率变化与实际损伤情况较为一致。束嘉俊等<sup>[12]</sup>将碳纳米管薄膜共固化在蜂窝夹层结构的面板中,并采用电学成像技术对高速冲击造成的损伤进行识别,结果表明,该方法可以有效重建冲击损伤的数量、位置和近似尺寸。

对于电学成像,重建算法对其使用效果具有重要的影响。当前在复合材料损伤识别中应用的电学成像技术大多使用基于正则化的算法,最常用的是 L2 范数与 L1 范数正则化。L2 范数正则化计算简单,但对重建结果过度平滑,导致识别精度偏低;而 L1 范数正则化虽然精度较高,但是计算时间相对较长。同时这些正则化方法对正则化参数的选取也较为敏感。随着计算机算力的飞跃及人工智能的再度兴起,深度学习方法因其超强拟合能力逐渐成为了各学科领域的研究热点,近年来也涌现出许多基于深度学习的电学成

像方法<sup>[13-18]</sup>。如 Tan 等<sup>[13]</sup>采用基于 LeNet 的卷积神经网络结构进行电学成像,结果表明,该方法优于传统的 LBP、Tikhonov 和 Landweber 算法。赵少峰等<sup>[15]</sup>采用基于二维卷积神经网络的电学成像方法对不同形状、大小和位置的目标物体进行仿真研究,结果表明,该方法可以有效重建图像,相对于 Tikhonov 和深度学习网络算法具有伪影少、分辨率高、成像质量高、抗噪声能力强等优势。Fan 等<sup>[17]</sup>采用基于密集连接的特征融合卷积神经网络的电学成像方法对碳纤维层合板的损伤进行识别,结果表明,该方法可以有效识别不同类型的损伤且优于 Tikhonov 和传统的卷积神经网络方法。

本文提出电学成像和深度学习结合的方法,对蜂窝夹层结构冲击损伤进行在线监测和识别。首先,通过丝网印刷技术在结构表面制备感应层,然后建立损伤对应的数据样本并由残差神经网络进行深度学习,最后,测量信息并通过训练好的残差神经网络重建感应层电导率变化分布的图像,实现损伤信息的识别。

## 1 电学成像方法

在电学成像中,通过 Maxwell 方程可以建立感应层内部电导率  $\sigma$  和电势  $\varphi$  的关系。

$$\nabla \cdot (\sigma \nabla \varphi) = 0 \quad (1)$$

本文采用相邻激励相邻测量的方式在感应层注入电流并测量边界电压,因而符合 Neumann 边界条件。

$$\begin{cases} \int_{E^+} \sigma \frac{\partial \varphi}{\partial \mathbf{n}} dS = +I, \text{ 电流注入电极处} \\ \int_{E^-} \sigma \frac{\partial \varphi}{\partial \mathbf{n}} dS = -I, \text{ 电流流出电极处} \end{cases} \quad (2)$$

式中,  $E$  为电极表面;  $\mathbf{n}$  为感应层边界  $S$  的单位法向矢量;  $I$  为电极处的电流。

结合式(1)和(2),在已知感应层内部电导率分布与边界条件的前

提下,可以求解感应层内电势分布,从而获得感应层的边界电压情况,此问题是电学成像的正问题,正问题是偏微分方程的边值问题,通常采用有限元方法进行求解。如果采用三角形单元对感应层进行划分,且默认单元内的电导率为常数,此时各单元的泛函为<sup>[19]</sup>

$$F^e(\varphi) = \frac{1}{2} \int_V (\sigma \cdot \nabla^2 \varphi) dV - \int_B \mathbf{J} \varphi dB \quad (3)$$

式中,  $V$  为单元场域;  $B$  为单元边界;  $\mathbf{J}$  为电流密度。

在三角形单元中建立坐标系,则单元电势分布函数  $\varphi^e$  可表示为

$$\varphi^e(x, y) = N_1(x, y) \varphi_1 + N_2(x, y) \varphi_2 + N_3(x, y) \varphi_3 \quad (4)$$

式中,  $N_1(x, y)$ 、 $N_2(x, y)$  和  $N_3(x, y)$  为单元上线性插值的基函数;  $\varphi_1$ 、 $\varphi_2$  和  $\varphi_3$  为三角形单元顶点处的电势值。

对  $F^e(\varphi)$  求极值,使其对单元各节点电势  $\varphi_i$  的一阶偏导数为 0。

$$\frac{\partial F^e(\varphi)}{\partial \varphi_i} = 0 \quad (i = 1, 2, 3) \quad (5)$$

结合式(3)~(5),可以得到单元方程:

$$\mathbf{K}^e \varphi^e = \mathbf{C}^e \quad (6)$$

式中,  $\mathbf{K}^e$  为单元系数矩阵;  $\varphi^e$  为单元电势矩阵;  $\mathbf{C}^e$  为单元电流密度矩阵。

对感应层进行单元划分,并将各个单元方程按照“对号入座”的原则进行叠加,可得电学成像正问题的总有限元方程。

$$\mathbf{K} \varphi = \mathbf{C} \quad (7)$$

通过求解式(7),可以获得感应层内电势分布  $\varphi$ ,从而获得感应层的边界电压数据。

在感应层受到冲击损伤后,其损伤部位电导率会发生显著变化,可以通过测量感应层边界电压变化  $\Delta U$  来重建感应层内电导率变化分布  $\Delta \sigma$  的情况,以此识别冲击损伤,这属于电学成像的逆问题,该问题可以被表示为

$$\Delta U = A \Delta \sigma \quad (8)$$

式中,  $A$  为灵敏度矩阵, 可以由电学成像的正问题计算求得。

由于灵敏度矩阵具有很强的病态性, 因此, 传统的电学成像方法使用正则化方法来求得稳定的近似解:

$$\Delta \sigma^* = \underset{\Delta \sigma}{\operatorname{argmin}} (\|A \Delta \sigma - \Delta U\|_2^2 + R_\lambda(\Delta \sigma)) \quad (9)$$

式中,  $R_\lambda(\Delta \sigma)$  为正则化项;  $\lambda$  为正则化参数 ( $\lambda > 0$ )。通常选用 Tikhonov 正则化项进行求解, 但是该方法会造成解的过度平滑, 效果并不理想。

## 2 残差神经网络

深度学习是指通过深层非线性网络结构来表征样本数据并以此进行预测。此方法的非线性表达能力较强, 适用于电学成像逆问题的求解。残差神经网络是 He 等<sup>[20]</sup> 针对卷积神经网络中的退化现象提出的网络结构。与传统的卷积神经网络相比, 残差神经网络独创的快捷连接可以有效解决深度神经网络中的梯度消失和梯度爆炸现象, 在减小计算负担的同时大大提升准确率。本文通过残差神经网络 ResNet18 建立感应层边界电压变化  $\Delta U$  与电导率变化分布  $\Delta \sigma$  之间的映射关系, 由此完成冲击损伤的识别。

ResNet18 由 20 个卷积层、1 个最大池化层和 1 个全连接层组成, 其结构如图 1 所示。“conv”表示卷积层, 以第 1 层为例, “ $7 \times 7 \text{conv}, 64, s2$ ”表示该层使用 64 个  $7 \times 7$  大小的卷积核, 并以 2 为步长进行卷积操作; “maxpool”表示最大池化层, “ $3 \times 3 \text{maxpool}, s2$ ”表示使用  $3 \times 3$  大小的过滤器, 并以 2 为步长进行最大池化操作; “fc”表示全连接层; 弧线箭头表示快捷连接, 可以实现信息的跨层传递, 提高网络中信息传递的效率, 降低网络的训练难度。

该网络可以分成 6 个部分 (I ~ VI)。以输入大小为  $20 \times 20$  的边界




图 1 ResNet18 结构  
Fig.1 Structure of ResNet18

电压数据为例, 经过第 I 部分的操作变为 64 个  $5 \times 5$  大小的数据; 第 II 部分的操作不改变数据维度; 第 III 部分的操作使之变为 128 个  $3 \times 3$  大小的数据; 第 IV 部分的操作使之变为 256 个  $2 \times 2$  大小的数据; 第 V 部分的操作使之变为 512 个  $1 \times 1$  大小的数据; 第 VI 部分是全连接层, 输出数据的大小为  $m \times 1$ , 表示感应层被划分成  $m$  个单元后对应的电导率变化分布, 如表 1 所示。

## 3 数据集的生成与训练

使用有限元方法建立感应层的电学分析模型, 依据损伤情况设置感应层中对应单元的电导率变化值, 感应层被划分成  $m$  个单元, 感应层在损伤前后的电导率变化分布  $\Delta \sigma$  可表示为<sup>[21]</sup>

$$\Delta \sigma = [\Delta \sigma'_1, \Delta \sigma'_2, \dots, \Delta \sigma'_m]^T \quad (10)$$

$$\Delta \sigma'_k = \frac{\sigma_k^{\text{damage}} - \sigma_k^{\text{basis}}}{\sigma_k^{\text{basis}}} \quad (11)$$

式中,  $\Delta \sigma'_k$  为归一化的电导率变化值;  $\sigma_k^{\text{basis}}$  与  $\sigma_k^{\text{damage}}$  分别为感应层中第  $k$  个单元在无损伤状态和损伤后的电导率值。

感应层周围布置有  $n$  个电极, 在

表 1 ResNet18 参数  
Table 1 Parameters of ResNet18

划分部分	输出大小	数量
输入	$20 \times 20$	1
I	$5 \times 5$	64
II	$5 \times 5$	64
III	$3 \times 3$	128
IV	$2 \times 2$	256
V	$1 \times 1$	512
VI	$m \times 1$	1
输出	$m \times 1$	1

第  $i$  组相邻电极处施加电流激励, 可以测得第  $j$  组的边界电压值  $u_{ij}$ , 由此, 损伤前后边界电压变化  $\Delta U$  可表示为

$$\Delta U = \begin{bmatrix} \Delta u'_{11} & \Delta u'_{12} & \cdots & \Delta u'_{1n} \\ \Delta u'_{21} & \Delta u'_{22} & \cdots & \Delta u'_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \Delta u'_{n1} & \Delta u'_{n2} & \cdots & \Delta u'_{nm} \end{bmatrix} \quad (12)$$

其中,

$$\Delta u'_{ij} = \begin{cases} 0, & \text{测量电极遇到激励电极} \\ \frac{u_{ij}^{\text{damage}} - u_{ij}^{\text{basis}}}{u_{ij}^{\text{basis}}}, & \text{其他情况} \end{cases} \quad (13)$$

式中,  $\Delta u'_{ij}$  为归一化的边界电压变化值;  $u_{ij}^{\text{basis}}$  与  $u_{ij}^{\text{damage}}$  分别为无损状态和损伤后测得的边界电压值。

以此方式获得的电导率变化分布  $\Delta\sigma$  是 1 个  $m \times 1$  的向量, 边界电压变化  $\Delta U$  是 1 个  $n \times n$  的矩阵, 便于后续导入残差神经网络进行训练。

由于通过残差神经网络建立  $\Delta U$  与  $\Delta\sigma$  之间的映射关系属于回归问题, 因此损失函数为

$$L(\Delta\sigma, \Delta\sigma^*) = \frac{1}{2} (\Delta\sigma - \Delta\sigma^*)^T (\Delta\sigma - \Delta\sigma^*) \quad (14)$$

式中,  $\Delta\sigma^*$  为通过残差神经网络求解得到的电导率变化分布。

设置适当的超参数并进行训练, 可以获得网络的各项参数, 据此可进行电学成像。同时本文使用图像相关系数 (ICC) [13-17] 对单个样本的成像效果进行评估。ICC 越接近 1, 说明预设损伤和识别损伤图像的相关程度越高, 识别效果越好。ICC 的定义为

$$\text{ICC} = \frac{\sum_{k=1}^m (\Delta\sigma_k^* - \overline{\Delta\sigma^*})(\Delta\sigma_k - \overline{\Delta\sigma})}{\sqrt{\sum_{k=1}^m (\Delta\sigma_k^* - \overline{\Delta\sigma^*})^2 \sum_{k=1}^m (\Delta\sigma_k - \overline{\Delta\sigma})^2}} \quad (15)$$

式中,  $\Delta\sigma_k^*$  与  $\Delta\sigma_k$  分别为感应层中第  $k$  个单元处识别和预设的电导率变化值;  $\overline{\Delta\sigma^*}$  与  $\overline{\Delta\sigma}$  分别为感应层中识别和预设的电导率变化平均值。

## 4 试验研究

### 4.1 结构与感应层

本文制备的蜂窝夹层结构由蜂窝芯层、面板和胶膜构成, 如图 2 所示。面板采用两种预浸料进行铺层, 靠近蜂窝芯层部分的面板使用威海光威复合材料有限公司生产的 T300-3K 碳纤维预浸料, 铺层顺序为  $[\pm 45 / (0, 90)]_4$ , 在此基础上, 在外侧加铺 3 层斜纹高强度玻璃布预浸料, 铺层顺序为  $[(0, 90) / \pm 45 / (0, 90)]$ , 上、下共计 22 层; 蜂窝芯层采用 Nomex® 芳纶纸蜂窝, 厚度为 15

mm; 胶膜为环氧树脂胶膜。固化切割后的蜂窝夹层结构尺寸为 300 mm × 300 mm, 厚度为 19.3 mm。

印刷感应层由感应区、电极和导电路路组成, 其设计如图 3 所示。感应区是 1 个尺寸为 200 mm × 200




图 2 蜂窝夹层结构示意图

Fig.2 Schematic diagram of honeycomb sandwich structure






图 3 印刷感应层设计图

Fig.3 Design of printed sensing layer



(a) 感应层制备流程



(b) 带有感应层的蜂窝夹层结构

图 4 印刷感应层的制备

Fig.4 Fabrication of printed sensing layer

mm 的正方形, 在感应区的各边均匀布置 5 个半径为 2.5 mm 的圆形电极并与导电路路连接。导电路路的末端分布在感应区的两侧, 可以通过导线将印刷感应层与电学成像测试系统连接到一起。印刷时, 感应区使用导电碳油墨, 电极和导电路路则使用银浆油墨。

如图 4 (a) 所示, 感应层的制备流程大致可分为两步: 第 1 步, 将蜂窝夹层结构固定到丝网印刷工作台上, 并将绘有感应区的丝网印版固定在试验件上, 用刮板将导电碳油墨均匀地印刷到试验件的表面, 然后将印有感应区的试验件放到 50 °C 的烘箱中, 加热 120 min 使碳油墨固化; 第 2 步, 待试验件冷却至室温后, 将绘有电极和导电路路的丝网印版放置到试验件的相应位置上, 并将银浆油墨印刷到试验件的表面, 再将印刷后的试验件放入 50 °C 的烘箱中, 加热 120 min 固化银浆油墨。冷却后得到带有印刷感应层的蜂窝夹层结构如图 4 (b) 所示。

### 4.2 训练网络

根据印刷感应层的形状与尺寸

建立有限元模型,如图5所示。该模型的电极数量为20,各边节点数为81,使用三角形单元进行划分,单元数量为12800个。

蜂窝夹层结构的冲击损伤有多种形式,作为初步研究,本文仅考虑冲击能量较大、蜂窝夹层结构面板被冲破的情况。这时对于表面印刷的感应层,表现为孔洞形式的损伤,因而将损伤形状简化为圆形。假设在同一感应层最多存在3处损伤,损伤半径在5~30 mm之间,损伤区域单元的电导率下降50%<sup>[16]</sup>。本文对单、双、三孔损伤情况建立冲击损




图5 有限元模型示意图  
Fig.5 Schematic diagram of finite element model

伤样本,如图6所示。以单孔损伤为例,在有限元模型中随机生成符合上述条件的圆形,并将该圆形对应单元的电导率变化数值设为-0.50,如图6(a)所示。通过求解电学成像的正问题,可以获得相应的边界电压变化,对边界电压施加信噪比为60 dB的高斯白噪声并进行归一化处理,如图6(d)所示。通过该方法可以建立单个样本中感应层损伤的尺寸和位置、对应的电导率变化分布 $\Delta\sigma$ 、边界电压变化 $\Delta U$ 这三者之间的对应关系。同样地,可以建立双孔损伤和三孔损伤的样本,如图6(b)、(e)和图6(c)、(f)所示。由此,可以分别建立单孔损伤、双孔损伤和三孔损伤的样本各30000个,将这90000个样本打乱重排后按照6:2:2的比例分成训练集、验证集与测试集。

本文使用的计算机处理器为Intel Core i7-10875H,内存为16 G,显卡为NVIDIA GeForce RTX 2060;训练平台为Matlab深度学习工具箱Deep Network Designer。批量大小设为128,初始

学习率设为0.001,每进行8420次迭代后学习率降至原先的20%。使用Adam优化求解器进行训练,其过程如图7所示。经过98000次迭代训练,训练集和验证集的损失函数分别降至0.0659和0.0863。

为了评估训练效果,对测试集分别使用深度学习方法与Tikhonov正则化方法进行成像并计算各样本的ICC值,如图8所示。可以看出,使用深度学习方法成像的样本ICC值较为集中,大部分样本的ICC值大于0.6,仅有少量样本成像效果较差;而使用Tikhonov正则化方法成像的样本ICC值则更为分散,出现了大量成像效果不佳的样本。通过计算可得,两者的平均ICC值分别为0.88与0.59,说明本文使用的深度学习方法的成像效果较好,所获取的ResNet18网络结构的各项参数可以用于实际损伤识别。

### 4.3 试验结果

为了验证本文制备的感应层以及深度学习算法对损伤识别的有效

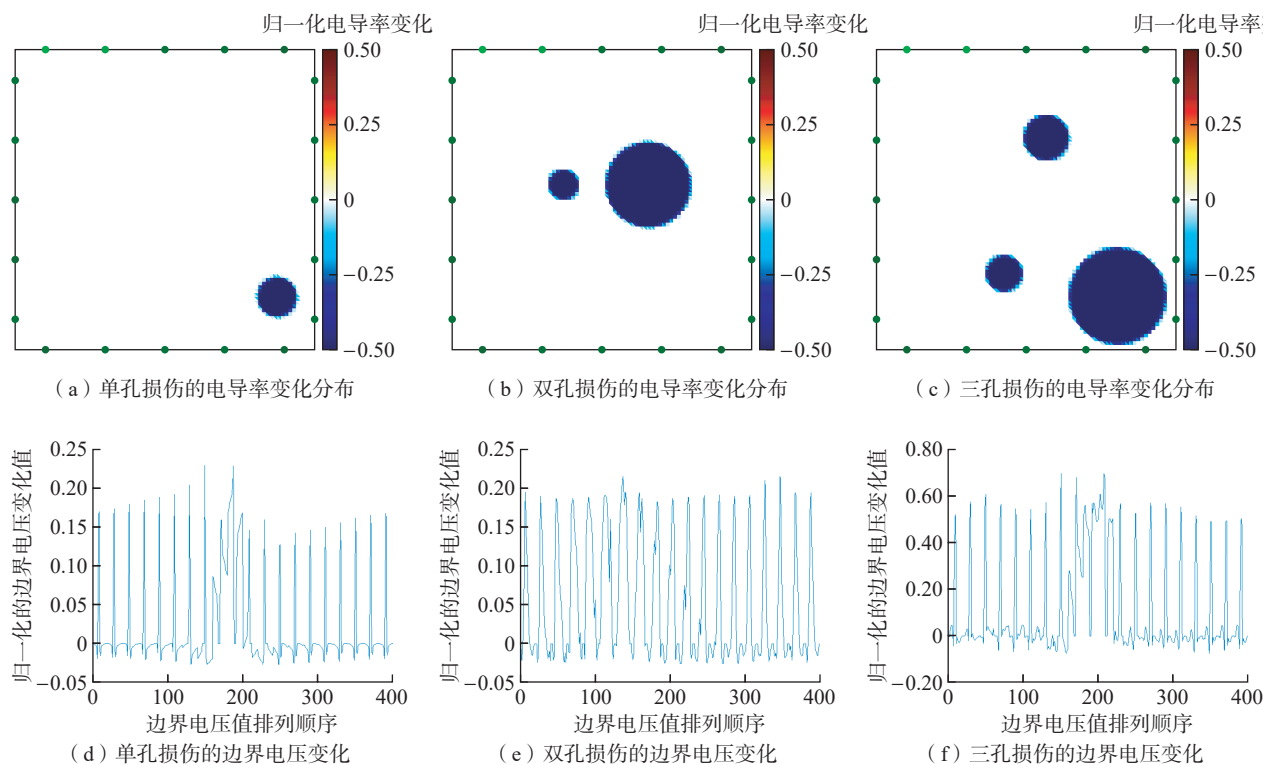


图6 冲击损伤样本示例

Fig.6 Samples of impact damage

性,使用 Instron CEAST 9350 落锤试验机对带有印刷感应层的蜂窝夹层结构进行低速冲击试验,选用直径





图7 训练过程中的损失曲线


Fig.7 Loss curves in the training process

为 16 mm 的落锤冲头,以 35 J 与 45 J 的能量依次对结构的两个位置(冲击点 I 和冲击点 II)进行低速冲击并记录冲击载荷。经过两次低速冲击后的结构损伤情况如图 9 (a) 所示。两次冲击的最大冲击载荷分别为 5314.9 N 和 5416.1 N,如图 9 (b) 所示。

通过测量损伤前后的边界电压,可以获得其边界电压变化  $\Delta U$ ,将之代入训练后的 ResNet18 网络,可得相应的电导率变化分布  $\Delta\sigma$ ,由此重建感应层损伤的图像如图 10 所示,




(a) 深度学习方法



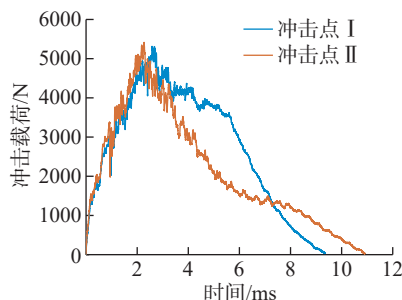
(b) Tikhonov正则化方法

图8 ICC值散点图

Fig.8 Scatter plot of ICC value



(a) 损伤情况



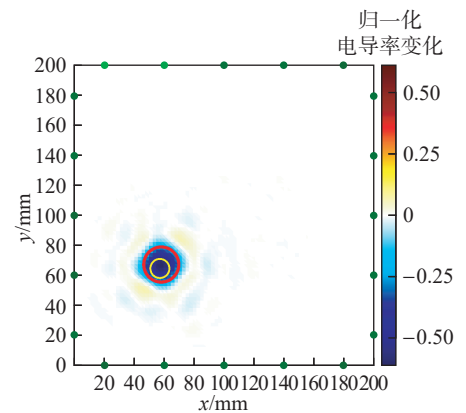
(b) 冲击载荷随时间的变化曲线

图9 冲击试验结果


Fig.9 Results of impact test

测量实际损伤的位置与尺寸并在图中以黄色圆圈标示。从图 10 可以看出,经过训练的 ResNet18 网络成功识别出了单个和两个电导率显著降低的区域,即为损伤区域,且损伤的位置和尺寸与实际情况较为一致。

使用 Tikhonov 正则化也可求得相应的电导率变化,由此重建感应层损伤的图像如图 11 所示。为了定量分析识别效果,在图 10 和 11 中建立以感应层左下角为原点,下边界为  $x$  轴,左边界为  $y$  轴的坐标系;对重建图像进行二值化处理,提取轮廓并拟合成圆形,以此作为识别损伤,并在图中以红色圆圈进行标示。将两种成像方法的识别损伤和实际损伤信息绘制成表格,如表 2 所示。表 2 中给出了损伤中心位置坐标  $(x_i, y_i)$ 、损伤半径  $r_i$ 、识别损伤与实际损伤中心位置的圆心距  $d_i$  ( $i=1,2$ ) 以及识别



(a) 单孔损伤电学成像结果



(b) 双孔损伤电学成像结果

图10 ResNet18 损伤识别结果

Fig.10 Results of damage identification by ResNet18

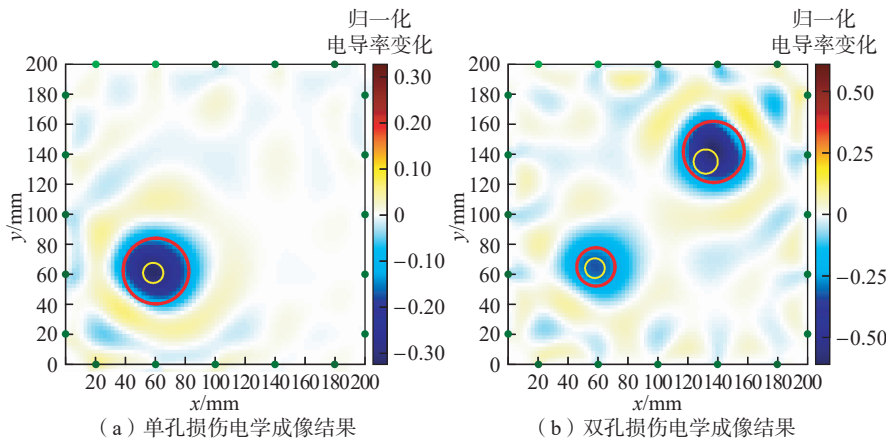


图 11 Tikhonov 正则化损伤识别结果

Fig.11 Results of damage identification by Tikhonov regularization

表 2 识别损伤和实际损伤信息

Table 2 Information of identified and actual damage

成像方法	损伤情况	冲击点 I					冲击点 II				
		$x_1/mm$	$y_1/mm$	$r_1/mm$	$d_1/mm$	$\delta_1/\%$	$x_2/mm$	$y_2/mm$	$r_2/mm$	$d_2/mm$	$\delta_2/\%$
—	实际损伤	57.38	64.34	6.44	—	—	130.78	134.79	7.82	—	—
ResNet18	单孔损伤	58.45	67.19	11.97	3.04	85.87	—	—	—	—	—
	双孔损伤	59.83	65.13	12.72	2.57	97.52	134.84	140.52	14.25	7.02	82.23
Tikhonov 正则化	单孔损伤	59.33	65.73	21.22	2.39	229.50	—	—	—	—	—
	双孔损伤	58.16	65.36	12.68	1.28	96.89	136.31	141.36	20.18	8.59	158.06

损伤半径的相对误差  $\delta_i$  ( $i=1,2$ )。

可以看出,本文使用基于 ResNet18 网络的电学成像方法效果明显优于传统的基于 Tikhonov 正则化的电学成像方法,前者的识别损伤更接近实际损伤,且伪像更少。由于感应层自身电导率以及冲击造成的损伤区电导率变化并不均匀,且在测量边界电压时有噪声影响,因此该方法识别的损伤尺寸与实际尺寸仍有一定的偏差,后续将提高感应层电导率的均匀性、改进样本的多样性以减小识别误差。

## 5 结论

本文提出在蜂窝夹层结构表面制备印刷感应层并结合电学成像和

深度学习的方法对冲击损伤进行监测和识别。建立了感应层的有限元模型,计算获取损伤对应的感应层电导率变化与边界电压变化数据样本,由残差神经网络进行深度学习并建立二者的映射关系,通过训练好的残差神经网络重建感应层电导率变化分布的图像,实现损伤信息的识别。对制备了感应层的蜂窝夹层结构进行了低速冲击和电学成像试验,主要得出如下结论。

(1) 利用丝网印刷制备感应层并结合电学成像对蜂窝夹层结构进行冲击损伤识别是可行的,损伤识别的结果能够较好地反映损伤的个数、位置和尺寸。

(2) 与传统基于 Tikhonov 正则

化方法的电学成像相比,采用基于深度学习 ResNet18 的电学成像可以更好地重建感应层中电导率变化的图像,并提取损伤信息,特别是在损伤尺寸的定量识别方面,基于深度学习的电学成像方法具有明显的优势。

## 参考文献

[1] 林晓虎,杨庆生. 航空航天夹层结构抗冲击性能的研究现状[J]. 航空制造技术, 2013, 56(10): 71-74.

LIN Xiaohu, YANG Qingsheng. Research review on anti-impact property of sandwich structures in aerospace[J]. Aeronautical Manufacturing Technology, 2013, 56(10): 71-74.

[2] 陈韩青,徐志远,屈仲毅,等. 蜂窝夹层结构无损检测方法研究综述[J]. 材料导报, 2024, 38(10): 22090208-15.

CHEN Hanqing, XU Zhiyuan, QU Zhongyi, et al. Review of nondestructive testing methods for honeycomb sandwich structures[J]. Materials Reports, 2024, 38(10): 22090208-15.

[3] SHIVOLA J T, MINAKUCHI S, MIZUTANI T, et al. Evaluation of damage detectability in practical sandwich structure application conditions using distributed fiber optic sensor[J]. Structural Health Monitoring, 2016, 15(1): 3-20.

[4] SIKDAR S, MIRGAL P, BANERJEE S, et al. Damage-induced acoustic emission source monitoring in a honeycomb sandwich composite structure[J]. Composites Part B: Engineering, 2019, 158: 179-188.

[5] FIBOREK P, KUDELA P. Model-assisted guided-wave-based approach for disbond detection and size estimation in honeycomb sandwich composites[J]. Sensors, 2021, 21(24): 8183.

[6] SU C, ZHANG W, LIANG L, et al. Damage imaging identification of honeycomb sandwich structures based on lamb waves[J]. Materials, 2023, 16(13): 4658.

[7] RELINGER T, UNDERHILL P R, KRAUSE T W, et al. Combining eddy current, thermography and laser scanning to characterize low-velocity impact damage in aerospace composite sandwich panels[J]. NDT & E International, 2021, 120: 102421.

[8] TALLMAN T N, SMYL D J. Structural health and condition monitoring via electrical impedance tomography in self-sensing materials: A review[J]. Smart Material

Structures, 2020, 29(12): 123001.

[9] NONN S, SCHAGERL M, ZHAO Y J, et al. Application of electrical impedance tomography to an anisotropic carbon fiber-reinforced polymer composite laminate for damage localization[J]. Composites Science and Technology, 2018, 160: 231–236.

[10] THOMAS A J, KIM J J, TALLMAN T N, et al. Damage detection in self-sensing composite tubes via electrical impedance tomography[J]. Composites Part B: Engineering, 2019, 177: 107276.

[11] YAN G, ZHENG Y F. A printed electrical impedance tomography sensor for detection of damage in composites[J]. International Journal of Applied Electromagnetics and Mechanics, 2020, 64(1–4): 1011–1017.

[12] 束嘉俊, 周登, 严刚, 等. 基于电学成像的蜂窝夹层结构超高速撞击损伤监测[J]. 中国空间科学技术, 2022, 42(4): 69–76.

SHU Jiajun, ZHOU Deng, YAN Gang, et al. Monitoring of hypervelocity impact damage to honeycomb sandwich structures by using electrical tomography[J]. Chinese Space Science and Technology, 2022, 42(4): 69–76.

[13] TAN C, LV S H, DONG F, et al.

Image reconstruction based on convolutional neural network for electrical resistance tomography[J]. IEEE Sensors Journal, 2019, 19(1): 196–204.

[14] FU R, WANG Z C, ZHANG X Y, et al. A regularization-guided deep imaging method for electrical impedance tomography[J]. IEEE Sensors Journal, 2022, 22(9): 8760–8771.

[15] 赵少峰, 李静. 基于二维卷积神经网络的电阻抗成像算法[J]. 仪表技术与传感器, 2022(7): 85–88, 105.

ZHAO Shaofeng, LI Jing. Electrical impedance tomography algorithm based on two-dimension convolution neural network[J]. Instrument Technique and Sensor, 2022(7): 85–88, 105.

[16] 范文茹, 王勃, 李靓瑶, 等. 基于电阻抗层析成像的CFRP结构损伤检测[J]. 北京航空航天大学学报, 2019, 45(11): 2177–2183.

FAN Wenru, WANG Bo, LI Jingyao, et al. Damage detection of CFRP structure based on electrical impedance tomography[J]. Journal of Beijing University of Aeronautics and Astronautics, 2019, 45(11): 2177–2183.

[17] FAN W R, QIAO L. Convolutional neural network method for damage detection of CFRP in electrical impedance tomography[J].

Measurement Science and Technology, 2023, 34(2): 025401.

[18] KO Y F, CHENG K S. U-Net-based approach for automatic lung segmentation in electrical impedance tomography[J]. Physiological Measurement, 2021, 42(2): 025002.

[19] 魏颖, 夏靖波, 王师, 等. 电阻层析成像(ERT)敏感场的仿真计算[J]. 东北大学学报, 2000, 21(4): 372–375.

WEI Ying, XIA Jingbo, WANG Shi, et al. Simulation & computing study of electrical resistance tomography (ERT) sensitive field[J]. Journal of Northeastern University, 2000, 21(4): 372–375.

[20] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016.

[21] ADLER A, DAI T, LIONHEART W R B. Temporal image reconstruction in electrical impedance tomography[J]. Physiological Measurement, 2007, 28(7): S1–S11.

通讯作者: 严刚, 副教授, 博士, 研究方向为复合材料结构健康监测和飞行器结构强度。

## Impact Damage Identification for Honeycomb Sandwich Structure by Using Electrical Tomography and Deep Learning

ZHOU Deng, LI Xuefeng, YAN Gang, HUANG Zaixing

(State Key Laboratory of Mechanics and Control for Aerospace Structures, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

**[ABSTRACT]** Aiming at the situation of honeycomb sandwich structure impacted by external objects, this study proposes a method to detect and identify the impact damage with electrical tomography and deep learning, and provide precise information for structural integrity evaluation and decision-making. The sensing layer and corresponding circuits are first printed on the surface of honeycomb sandwich structure with carbon ink and silver ink through silk-screen printing technique. Then numerical simulation is performed by considering impact damage with different quantities, positions and sizes to obtain training data of conductivity change and boundary voltage change of the corresponding sensing layer. Deep learning is carried out by a residual neural network to establish the mapping relationship between conductivity change and boundary voltage change of the sensing layer. Finally, the boundary voltage data of the sensing layer is measured before and after impact, and tomographic image of the conductivity change caused by impact damage is reconstructed by a trained residual neural network, identifying the locations and sizes of the damage. Low velocity impact test for a honeycomb sandwich structure is conducted to demonstrate the feasibility and effectiveness of the proposed method.

**Keywords:** Honeycomb sandwich structure; Impact damage identification; Printed sensing layer; Electrical tomography; Deep learning

(责编 向阳)