

# 基于 Hilbert 算法和 DnCNN 的复合材料损伤层析成像方法

郑明铭, 程晓颖

(浙江理工大学 机械工程学院, 浙江 杭州 310018)

**摘要:**针对柔性压阻纤维传感器对于复合材料损伤成像质量较差,目标检测效果不如压电陶瓷的特点,提出了一种基于希尔伯特算法和去噪卷积神经网络算法的层析成像方法。利用柔性压阻纤维能接收兰姆波的特点,通过计算希尔伯特谱差值的方法进行成像。以成像实验数据作为数据集,和人为标记损伤位置点进行对比用来训练去噪神经网络,引入了结构相似度作为训练网络效果的评判标准,改进了压阻纤维传感器成像质量相对不高和传感路径相对较少的问题。结果表明,经过去噪卷积神经网络训练后的成像图像有更好的成像质量,结构相似度从 0.607 2 增长到了 0.973 4,证明去噪卷积神经网络在柔性传感器层析成像方面有显著的作用。

**关键词:**复合材料;层析成像;神经网络;去噪;损伤探测;希尔伯特算法

中图分类号: TP391.413;TH89

文献标志码: A

文章编号: 1003-7241(2025)12-0093-06

## Composites damage tomography method based on Hilbert algorithm and DnCNN

ZHENG Mingming, CHENG Xiaoying

(School of Mechanical Engineering, Zhejiang Scitech University of Technology, Hangzhou 310018, China)

**Abstract:** A method based on the Hilbert algorithm and denoising Convolutional Neural Network (CNN) algorithm for tomography is proposed to address the poor imaging quality and inferior target detection performance of flexible piezoresistive fiber sensors compared to piezoelectric ceramics. This paper utilizes the characteristic of flexible piezoresistive fiber to receive Lamb waves and performs imaging by calculating the difference of Hilbert spectrum. Using the imaging experimental data as a dataset and comparing it with manually marked damage locations, a denoising neural network is trained. Structural similarity is introduced as the evaluation standard for the training network's effectiveness, which improves the imaging quality of piezoresistive fiber sensors and addresses the issue of limited sensing paths. Results demonstrate that the imaging quality is significantly improved after training with the denoising convolutional neural network, with the structural similarity index increasing from 0.607 2 to 0.973 4. This underscores the significant role of denoising convolutional neural networks in tomographic imaging using flexible sensors.

**Keywords:** composites; tomography; neural network; denoising; damage detection; Hilbert algorithm

## 0 引言

碳纤维增强复合材料(carbon fiber reinforced composites, CFRP)因其卓越的性能和多功能特性备受瞩目,广泛应用于机械制造领域<sup>[1]</sup>。但是,随着碳纤维复合材料的广泛运用,它往往在使用过程中潜藏着不可见的内部损伤<sup>[2]</sup>,这对其力学性能产生显著影响,因此对复合材料损伤的无损检测显得尤为关键。在无损检测技术中,兰姆波层析成像是一种常见而有效的方法。通过分析接收的兰姆波希尔伯特幅值的变化,可以概率成像并准确定位损伤位置。此方法在 CFRP 的损伤检测中取得了成功应用<sup>[3]</sup>。然而,面对噪音环境的复杂情况,压阻纤维传感器因其和传统压电陶瓷(piezoelectric ceramics, PZT)传感器传感机制及本身结构不同的特点,更容易受到环境噪音的干扰导致成像质量较差。

在这一背景下,对成像图形进行去噪显得尤为重要。神经网络在图像处理领域取得了显著进展。Zhang 等<sup>[4]</sup>成

功应用去噪神经网络(denoising convolutional neural network, DnCNN)处理未知噪音水平下的高斯去噪,为神经网络在图像去噪方面的有效性提供了有力证据。随后, Wang 等<sup>[5]</sup>将 DnCNN 应用到电阻抗断层扫描领域,成功去除了重建图像中的伪影,能够恢复多个目标对象的位置的边缘。本文将神经网络引入复合材料的损伤无损检测中,有助于克服压阻柔性传感器容易受到噪音干扰,灵敏度不如 PZT 的缺点,为复合材料损伤的精确检测提供了新的途径。通过神经网络的训练,成像图像的质量得到显著改善,结构相似度大大提升,证明了神经网络在传感器层析成像方面的显著作用。这不仅提高了检测的准确性,还为复合材料的工程应用和科技研究提供了更为可靠的手段。

## 1 成像原理

本文是利用信号发生器激发兰姆波波形检测损伤,具体波形计算公式为

$$A(t) = \frac{1}{2} \left[ 1 - \cos\left(\frac{2\pi f_c}{n} t\right) \right] \sin(2\pi f_c t) \quad (1)$$

基金项目:“纺织之光”中国纺织工业联合会应用基础研究(J202103)

收稿日期:2024-03-29

式中,  $A$  为幅值,  $f_c$  为频率,  $n$  为信号窗口类的周期数,  $t$  为波传播的时间, 本文  $f_c = 100 \text{ kHz}$ ,  $n = 5$ 。

示波器会接收到信号发生器激发的兰姆波信号, 对接收信号进行希尔伯特-黄变换, 希尔伯特-黄变换由 EMD 分解和希尔伯特变换组成。利用经验模态分解 (empirical mode decomposition, EMD) 将接收信号分解为几个本征模态函数 (intrinsic mode functions, IMF), 然后将希尔伯特变换应用在 IMF 分量, 得到希尔伯特能谱<sup>[6-7]</sup>。EMD 分解最终可以将原始信号  $x_{ij}(t)$  表示为固有模态函数的分量之和加上最终残差  $r_n$ 。

$$x_{ij}(t) = \sum_{i=1}^n c_j + r_n \quad (2)$$

希尔伯特变换计算公式<sup>[8]</sup>为

$$H[c_i(t)] = \frac{1}{\pi} \int_{-\infty}^{\infty} \frac{c_i(t')}{t-t'} dt' \quad (3)$$

构造分析信号的方法为

$$z_i(t) = c_i(t) + jH[c_i(t)] = a_i(t)e^{j\varphi_i(t)} \quad (4)$$

瞬时频率计算公式为

$$\omega_i(t) = \frac{d\varphi_i(t)}{dt} \quad (5)$$

信号  $x_{ij}(t)$  可以用下式表示为

$$x_{ij}(t) = \text{Re} \sum_{j=1}^n a_i(t)e^{j\varphi_i(t)} = \text{Re} \sum_{j=1}^n a_i(t)e^{j\int \omega_i(t) dt} \quad (6)$$

Re 为实部, 式 (7) 为希尔伯特谱, 可以用等式表示为

$$H(\omega, t) = \text{Re} \sum_{j=1}^n a_i(t)e^{j\int \omega_i(t) dt} \quad (7)$$

$H(\omega, t)$  能准确地描述整个频带内信号振幅随时间和频率的变化, 如果  $x_{ij}(t)$  被认为是信号的能量密度, 那么  $H^2(\omega, t)$  在希尔伯特变换后也具有能量密度的物理意义。 $H^2(\omega, t)$  被称为希尔伯特能谱, 认为是信号能量的时频表现。如果忽略残差, 那么在希尔伯特变换之后信号的能量应该是守恒的, 因此可以获得以下方程。

$$\int_{-\infty}^{\infty} |x_{ij}(t)|^2 dt = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} H^2(\omega, t) d\omega dt \quad (8)$$

因此, 它可以定义为

$$E(\omega) = \int_{-\infty}^{\infty} H^2(\omega, t) dt \quad (9)$$

本文所用的兰姆波成像方法是计算希尔伯特边际谱幅值的差异值成像方法, 首先, 对损伤前信号  $x_{ij}(t)$  和损伤后信号  $y_{ij}(t)$  相关计算, 根据损伤前后得到的能谱值确定损伤因子  $DF_{HE}$

$$DF_{HE} = 1 - \frac{\min(E_u, E_d)}{\max(E_u, E_d)} \quad (10)$$

式中,  $E_u, E_d$  为兰姆波损伤前后的最大能谱值, 根据每个传感路径对应的  $DF_{HE}$  值, 对相邻区域的损伤概率进行成像。每条传感路径的概率需要叠加,  $N$  条传感路径的损伤概率  $P(x, y)$  分布在任意点  $(x, y)$  表达式为

$$P(x, y) = \sum_{i=1}^{N-1} \sum_{i+1}^N DF_{HE} S_{ij}(x, y) \quad (11)$$

$S_{ij}(x, y)$  为空间分布函数<sup>[9]</sup>, 定义为

$$S_{ij}(x, y) = \begin{cases} \frac{\beta - R_{ij}(x, y)}{\beta - 1} & \beta > R_{ij} \\ 0 & \text{otherwise} \end{cases} \quad (12)$$

式中,  $\beta$  为决定椭圆路径形状的形状因子,  $R_{ij}(x, y)$  为激发传感器与接收传感器的距离之和, 表达式为

$$R_{ij}(x, y) = \frac{\sqrt{(x_i - x)^2 + (y_i - y)^2} + \sqrt{(x_j - x)^2 + (y_j - y)^2}}{\sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}} \quad (13)$$

## 2 实验分析

### 2.1 压电陶瓷 (PZT)

PZT 晶片也称为换能片, PZT 是具有压电效应的陶瓷。在本文中用信号发生器和信号放大器与 PZT 相连, 利用 PZT 的压电效应产生兰姆波信号进行损伤探测。



图1 压电陶瓷

### 2.2 柔性压阻传感器

本文用来接收兰姆波信号的是课题组研制的柔性压阻传感器<sup>[10]</sup>实质上是纳米填料压阻纤维膜, 纤维膜上的每一根纤维都附着许多纳米填料。PZT 粘贴在同一块碳纤维增强复合材料板上, 信号发生器连接 PZT 激发动态兰姆波信号, 波信号使 CFRP 板发生动态振动变化让纤维内部的纳米填料距离发生变化产生压阻效应<sup>[11-12]</sup>和隧穿效应<sup>[13]</sup>, 从而使纤维膜传感器的电阻发生变化, 将这个传感器外接电路连接示波器便能收到波形信号。这种传感器相对于 PZT 来说是柔性的, 可以附着在一些曲面复合材料上。




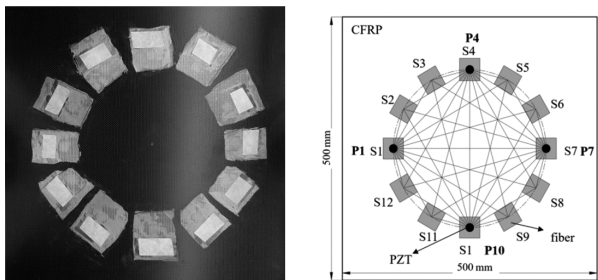
图2 纤维上纳米填料的隧穿电阻效应

### 2.3 传感器布置

如图3在一块 CFRP 板 (500 mm×500 mm×2 mm) 上以中心点为圆心, 300 mm 为半径布置 12 个传感阵列, 每个纤维进行编号。在 CFRP 板子背面再布置四个 PZT 位置同 S1, S4, S7, S10, 激发点位置编号为 P1, P4, P7, P10。P1 先激发信号, 而 S2-S12 收集信号, 随后 P4 来激发信号, 其余纤维膜接收信号, 同理 P7, P12 依次激发信号, 这样可以在圆形阵列范围内检测 CFRP 板的损伤前情况, 之

后在 CFRP 上放置一块圆柱体重物块模拟复合材料损伤<sup>[14]</sup>,以同样的操作得到损伤后的信号数据,对比损伤前后的数据就能得到损伤的位置。

能计算损伤因子  $DF_{HE}$  并进行成像。



(a) 传感器阵列实际照片 (b) 传感器阵列路径示意图  
图 3 压阻纤维传感器阵列

### 2.4 信号处理

压阻纤维接收到中心频率为 100 kHz 的波信号以后进行带通滤波。将接收的信号转化为图 4 频域图,按照频谱域图设置带通频率为 70–130 kHz,图 5 未滤波信号滤波前后的示意图。




图 4 压阻纤维接收信号的频谱图 (P1-S5 路径)




图 5 滤波前后信号对比 (P1-S5 路径)

如图 6 实验中在坐标 (140, 315) 位置放置重物块,图 7(a)是 P7-S2 路径波形对比图,当重物块在探测路径上,能发现收到的兰姆波信号幅值会明显降低,图 7(b)则是 P1-S11 路径接收信号的波形对比图,而当重物块不在探测路径上,信号幅值并不会会有明显的改变。

将图 7 的信号经过 EMD 分解和希尔伯特变化以后,能得到如图 8 所示的希尔伯特能谱图,不难发现波信号经过重物块的路径后能值峰值会变小很多。而没有经过重物块路径峰值基本不变,得到峰值以后经过公式 (10) 就

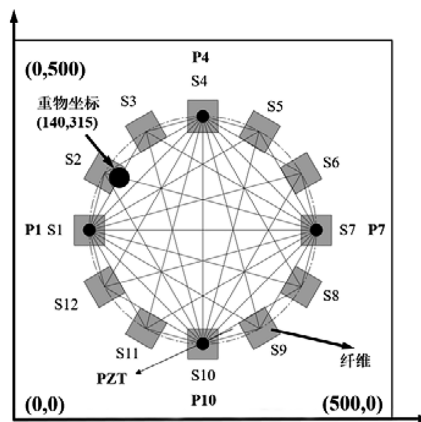




图 6 重物放置位置示意图




(a) P7-S2 路径




(b) P1-S11 路径

图 7 经过不同路径的兰姆波信号对比



(a) P7-S2 路径



(b) P1-S11 路径

图 8 不同路径的希尔伯特能谱图

以同样的方法对 CFRP 上 38 条不重复路径计算损伤因子得到最终的成像图。下图是重物坐标为 (140, 315) 的压阻纤维和 PZT 对比成像结果,PZT 作为传统的压电传感器,成像结果更为清晰。压阻纤维成像结果较差的原

因主要有两个,一是传感机制灵敏度的不同,PZT 是依靠压电效应能接收到传达的波,而压阻纤维是依靠压阻效应和隧穿效应。二是 PZT 因为其自身压电效应和逆压电效应的特点同时可以作为激发器和接收器使用。如图 10 所示,虚线为同样是 12 个 PZT 的情况下多余的传感路径,

PZT 所有路径总共为 66 条,这也是图 9(b)中传感网络比图 9(a)显得较为密集的原因<sup>[13]</sup>,PZT 因其优点已经被广泛运用,但压阻纤维有其自身柔性的特点可以在非平面接收信号。也为了加强压阻纤维的图像质量,引用 DnCNN 神经网络进行图像去噪。




图 9 层析成像结果

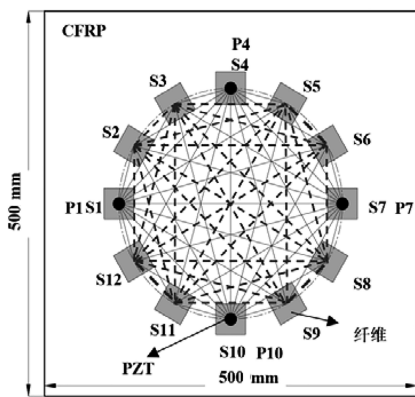


图 10 PZT 和压阻纤维传感器路径对比图

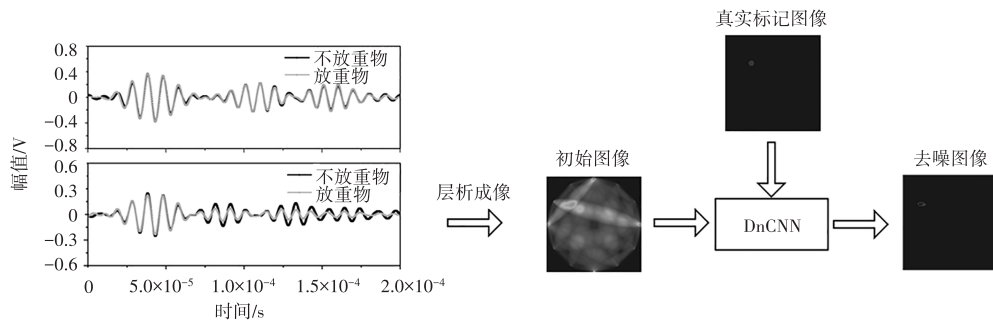


图 11 去噪神经网络方法

一个层数为  $D$  的 DnCNN 网络如图 12 所示。第一层,使用 64 个大小为  $3 \times 3 \times c$  的滤波器来提取特征, $c$  表示图像通道的数量选择 ReLU 作为激活函数,公式表达为

$$H(x) = \begin{cases} 0 & x < 0 \\ x & x \geq 0 \end{cases} \quad (14)$$

通过 ReLU 引入非线性因素,避免梯度消失。对于层数 2 到  $(D - 1)$ ,使用 64 个大小为  $3 \times 3 \times 64$  的滤波器,并在卷积和 ReLU 之间添加归一化层 (batch normalization, BN)。最后一层就是  $3 \times 3 \times 64$  的卷积层,用于重建残差映射  $\mathfrak{R}(y)$ ,本实验中 DnCNN 神经网络层数  $D$  为 12。




图 12 网络结构

均方误差(MSE)提供了一种具有良好特性的相似性度量,常用于深度学习回归问题。因此,期望残差图像和估计残差图像之间的平均MSE可以作为损失函数来学习网络中的可训练参数。MSE为

$$l(\theta) = \frac{1}{2N} \sum_{i=1}^N \| \mathfrak{R}(y_i; \theta) - (y_i - x_i) \|_F^2 \quad (15)$$

其中 $l$ 代表损失函数, $\mathfrak{R}$ 为网络结构,用于预测重建图像中因不适应性而引起的噪声。 $y_i, x_i$ 分别表示初始重构图像和真实标记图像, $\theta$ 为网络参数。

### 3.3 评估方法

为了评估训练网络的效果,引入结构相似度作为评估标准,结构相似度(structural similarity, SSIM)通常是指一种用于测量两个图像之间相似性的图像质量评价指标。较高的结构相似度表明图像之间更相像,而较低的分则表示它们之间存在比较多的差异。结构相似度时常被用于图像质量评估,图像压缩算法的优化,以帮助衡量图像处理和传输过程的质量损失。SSIM公式为

$$SSIM(X, Y) = \frac{(2\mu_x\mu_y + C1)(2\sigma_{xy} + C2)}{(\mu_x^2 + \mu_y^2 + C1)(\sigma_x^2 + \sigma_y^2 + C2)} \quad (16)$$

$\mu_x$ 和 $\mu_y$ 分别表示图像 $X$ 和 $Y$ 的均值, $\sigma_x$ 和 $\sigma_y$ 表示图像 $X$ 和图像 $Y$ 的标准差, $\sigma_{xy}$ 代表图像 $X$ 和图像 $Y$ 的协方差, $C1$ 和 $C2$ 是常数,是为了避免分母为0。本文中就是通过计算去噪后的图形和标记图形的SSIM来判断训练模型参数的好坏。

### 3.4 建立数据集

本文构建的DnCNN模型基于深度学习框架PyTorch实现,软件为Pycharm,环境为python3.7, GPU处理器采用NVIDIA GeForce RTX 3060 Laptop GPU。本实验中所有数据集都为实验数据集,在CFRP板传感阵列中放置重物测试信号进行成像,成像图训练集数量为116个,测试集有29张。因为是以计算SSIM为标准,所以按图13去掉矩形框外无用像素点只取实际成像区域。




图13 实际成像区域(矩形框内)

### 3.5 训练结果

层数为12层, batchsize为8, epoch为200, 学习率为0.001。图14(c)为训练集输出图像结果,虽然最终显示的损伤形貌与实际损伤图14(b)形貌不同,但是可以发现去噪的图像显示出真实的损伤位置,且对比成像中心位置和实际放置重物得到误差在3mm以内。之后再对测试集进行训练对比评估模型的去噪性能,如表1所示测试集图像SSIM从0.6072提升到了0.9734,这也证明了

DnCNN对层析成像图形去噪的有效性。




图14 部分训练结果

表1 测试集平均SSIM值

方法	层析成像	层析成像+DnCNN
SSIM	0.6072	0.9734

## 4 结束语

本文将DnCNN用于兰姆波层析成像,基于希尔伯特边缘谱幅值变化,用研制的压阻纤维层析成像的带噪音实验图像作为训练数据集,成功地对质量不高的层析成像数据进行了去噪,图像的结构相似度从0.6072提升到了0.9734,误差在3mm以内。针对于曲面复合材料无法布置足够数量PZT导致层析成像质量不高的情况,本文所用的去噪神经网络可以解决这种问题,在不改变探测方法的情况下,能够有效地去除噪音带来的影响,使得成像质量大大提升。

## 参考文献

- [1] 陶洋, 张祝辉, 杨莹雪, 等. C/C三维纺织复合材料细观结构及力学性能研究进展[J]. 材料工程, 2023, 52(4): 73-86.
- [2] 杨红娟, 杨正岩, 杨雷, 等. 碳纤维复合材料损伤的超声检测与成像方法研究进展[J]. 复合材料学报, 2023, 40(8): 4295-4317.
- [3] SU C, JIANG M, LIANG J, et al. Damage identification in composites based on hilbert energy spectrum and lamb wave tomography algorithm[J]. IEEE Sensors Journal, 2019, 19(23): 11562-11572.
- [4] ZHANG K, ZUO W, CHEN Y, et al. Beyond a gaussian denoiser: residual learning of deep CNN for image denoising [J]. IEEE Transactions on Image Processing, 2017, 26(7): 3142-3155.
- [5] WANG Q, ZHANG H, ZHANG R, et al. EIT image reconstruction method based on DnCNN [Z]. 2021 IEEE International Instrumentation and Measurement Technology Conference (I2MTC). 2021: 1-5. 10.1109/i2mtc50364.2021.9459865
- [6] ALICKOVIC E, KEVRIC J, SUBASI A. Performance evaluation of empirical mode decomposition, discrete wavelet transform, and wavelet packed decomposition for automated epileptic seizure detection and prediction [J]. Biomedical Signal Processing and Control, 2018, (39): 94-102.

(下转第137页)