

# 基于图嵌图卷积神经网络的复合材料缺陷定位

董文利<sup>1</sup>,王 胜<sup>2</sup>,宗圣康<sup>2</sup>,马向东<sup>1</sup>,任 毅<sup>1</sup>,郑 凯<sup>1</sup>,张 辉<sup>2</sup>

(1. 江苏省特种设备安全监督检验研究院,南京 210036;2. 东南大学 机械工程学院,南京 211102)

**摘 要:** 针对复合材料层合板结构缺陷的快速检测定位,提出了一种基于超声导波的复合材料缺陷检测图嵌图卷积神经网络模型(G-GCN)。G-GCN 通过构建导波信号相互关系的时空特征高级表征图,由局部-全局变换构建局部图,以表征单个导波信号内的相互关系信息;再基于局部图构建全局图,表征多个导波信号之间的相互关系信息;然后利用全局图输入图卷积神经网络模型训练学习,输出相应的复合材料缺陷预测,实现极少量传感器条件下的快速精准缺陷检测与定位。最后搭建了超声导波复合材料检测试验平台,验证了 G-GCN 的先进性和可靠性。

**关键词:** 超声导波;无损检测;缺陷定位;卷积神经网络;复合材料

中图分类号: TG115.28      文献标志码: A      文章编号: 1000-6656(2023)07-0045-08

## Composite defect location based on Graph-in-Graph Convolutional Network

DONG Wenli<sup>1</sup>, WANG Sheng<sup>2</sup>, ZONG Shengkang<sup>2</sup>, MA Xiangdong<sup>1</sup>, REN Yi<sup>1</sup>, ZHENG KAI<sup>1</sup>, ZHANG Hui<sup>2</sup>

(1. Jiangsu Special Equipment Safety Supervision and Inspection Institute, Nanjing 210036, China;

2. College of Mechanical Engineering of Southeast University, Nanjing 211102, China)

**Abstract:** This paper proposed a Graph-in-Graph Convolutional Network (G-GCN) model based on ultrasound-guided waves for the rapid detection and localisation of structural defects in composite laminates. G-GCN was constructed an advanced representation map of the spatio-temporal characteristics of guided wave signals. The local map was constructed by local global transformation to represent the relationship information in a single guided wave signal. Then, the global map was constructed based on the local map to represent the relationship information between multiple guided wave signals. The global map input map was used to convolve neural network model training and learning, and the corresponding composite defect prediction was output. It realized fast and accurate defect detection and location with very few sensors. Finally, an experimental platform for nondestructive testing of ultrasonic guided wave composite materials was built to verify the advancement and reliability of G-GCN.

**Key words:** ultrasonic guided wave; nondestructive testing; defect location; convolution neural network; composite material

复合材料高压气瓶具有重量轻、强度高、抗疲劳性能好、工作寿命长等优点,但在工作过程中会受到各种因素影响而产生裂缝等缺陷。为确保服役中复

合材料的安全性,必须对其进行定期损伤状态评估,保证结构安全,且损伤检测须快速准确,不影响材料结构的正常运作。

超声无损检测具有灵敏度高,精度高,检测范围大等特点,是目前无损检测领域应用最广泛的技术<sup>[1-3]</sup>。AYMERICH 等<sup>[4]</sup>使用传统脉冲-回波方法和反向散射 C 扫描技术检测碳纤维复合材料结构中的分层和基体开裂损伤。与之相比,使用导波进行材料力学性能表征比基于体波的技术更有优势,这是因为导波技术不受频率范围的限制,并且易于实现。研究表明<sup>[5]</sup>,超声导波在传播中遇到分层缺陷时会产生模

收稿日期:2022-11-28

**基金项目:** 国家自然科学基金资助(52272433,11874110);国家市场监督管理总局项目(2022YJ11,2020MK03);江苏省重点研发计划资助(BE2021084)

**作者简介:** 董文利(1968—),女,高级工程师,主要从事无损检测的研究工作,1521714894@qq.com

**通信作者:** 张 辉(1977—),男,教授,主要从事多物理场无损检测理论及新技术的研究工作,seuzhanghui@seu.edu.cn

态转换,形成微弱的反射声波,而其他入射声波透过缺陷继续传播。复合材料板内导波与损伤的相互作用示意如图 1 所示,可见,在损伤区域处,形成两部分透射波,分别以特定速度在亚层内向前传播。

KESSLER 等<sup>[6-7]</sup>用导波技术对碳纤维复合材料的基体开裂等缺陷实现结构状态评估。MICHEL 等<sup>[8]</sup>对比分析多分辨率信号处理对损伤前后的超声导波信号,完成复合材料层合板的延时-叠加损伤成像定位。随后,延时-叠加损伤成像定位法成为研究重点<sup>[9-13]</sup>,且学者们提出了多种导波信号处理方法<sup>[14-16]</sup>用于提取复杂信号中的缺陷信息。邹兰林

等<sup>[17]</sup>通过小波分析方法获取超声波信号特征向量并构建神经网络,检测桩基缺陷以及缺陷类型。杨志学等<sup>[18]</sup>利用小波去噪以及小波变换对电缆缺陷点反射回来的信号进行处理,实现了 20 m 范围内的缺陷检测。徐浩等<sup>[19]</sup>等通过蜂窝夹层结构有限元模型进行大量的导波传播仿真,形成训练数据库,训练支持向量机脱黏层分类机器学习模型,进行蜂窝夹层结构截面内脱黏层诊断。然而,这些方法都需要在空间上布置密集分布的换能器阵列来充分收集导波信号,而且可检测区域有限,无法满足工程大型结构监测的需求。




图 1 复合材料与损伤的相互作用示意

文章提出了一种不受超声信号收集传感器阵列数量与分布限制的复合材料缺陷检测与定位方法,实现了极少量传感器条件下的缺陷快速精准检测与定位。该方法不仅注重高层次的缺陷特征提取,更聚焦于导波信号内缺陷相互关系的信息提取。为实现这一目的,设计了局部-全局变换和图卷积神经网络两部分模型。

1 图卷积神经网络与模型架构

1.1 图卷积神经网络

图卷积神经网络的研究对象为图数据,这些数据不具备规则的空间结构。图数据的结构十分特殊,包含有节点与边的集合,节点是研究的对象特征,边是节点与节点之间的关系结构。

对图数据进行深度学习有 3 个步骤:① 对节点的特征信息进行抽取变换;② 聚集邻居节点特征信息,融合节点局部结构信息;③ 对两步的信息聚集做

非线性变换,增加模型的表达能力。图卷积神经网络典型结构如图 2 所示。文章将基于图卷积神经网络开发针对导波信号特性的图嵌图卷积神经网络模型。

1.2 导波图构建的局部-全局转换

导波图构建的局部-全局转换方法提取并评估单个导波信号内各波分量间的相互关系信息,并分辨聚合来自其他导波信号的特征信息,实现导波信号信息的最大化提取,避免信息丢失。

导波图构建的局部-全局转换方法的步骤(见图 3),具体如下所述。

首先,对于一个导波信号进行最大-最小式归一化。随后,归一化导波信号将被分割成不重叠的信号时段,时段长度固定为导波激励信号的时域长度  $T$ ,窗函数宽度为  $T$ 。

图数据表示为  $G = (V, \xi, W)$ ,  $V$  为节点,  $\xi$  为边,  $W$  为边权重。将分割时段视为一个节点,获取节点  $p$  与  $q$  之间的关系权重,表征节点相互关系信息。通过

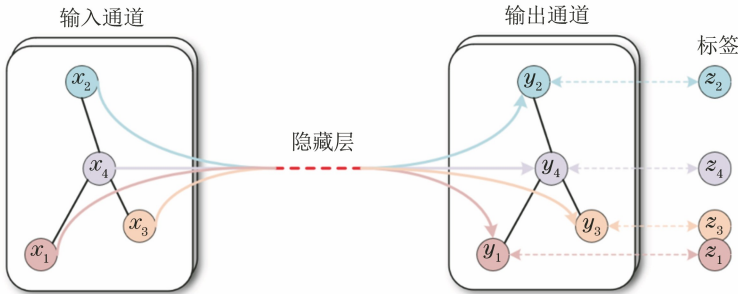


图 2 图卷积神经网络典型结构




图3 导波图构建局部-全局转换方法的步骤

测量信号时段间的时频特性差异计算边权重  $W_{pq}$ 。

在定义了节点、边、权重后,通过分析每两个信号时段之间的相互关系,获得局部图。局部图描述单个导波信号内的相互关系信息变化。通过将单个信号的局部图转换为新的节点特征,构造由全部导波信号组成的全局图。

基于此,设计了一种局部图的特征提取方法,将这些局部图转换为全局图的节点。

首先将边权重矩阵  $W$  转换成图拉普拉斯矩阵<sup>[20-21]</sup>,  $L$  表示为

$$L = D - W \tag{1}$$

式中:  $D$  为  $W$  的对角矩阵,  $D_{pp} = \sum_q W_{pq}$ 。

图拉普拉斯矩阵  $L$  为对称矩阵,对其作特征值分解。使用此方法,获得包含所有提取特征值  $(\lambda_1, \lambda_2, \dots, \lambda_Q)$  的新特征向量,成功提取局部图的关键信息,进而使用新的特征向量来表征局部图。将新

特征向量视为嵌入全局图中的节点构建全局图。其边权重表示为

$$W_{pq}^{\text{global}} = \begin{cases} 1, \text{节点 } \langle p, q \rangle \text{ 连接} \\ 0, \text{节点 } \langle p, q \rangle \text{ 未连接} \end{cases} \tag{2}$$

全局图实现了两个不同层次的导波信号相互关系信息评估与提取,并且将其转化为合理的拓扑图表示。

### 1.3 图卷积神经网络模型架构

图卷积神经网络模型的基本组成是图卷积层。图卷积层对节点的特征向量做谱图卷积操作,表示为

$$h = (x *_{\mathcal{G}} f)_{\theta} = U(U^T x U^T f) \tag{3}$$

式中:  $x$  为节点的特征向量;  $*_{\mathcal{G}}$  为图卷积操作;  $f$  为  $\Delta$  的本征函数;  $\theta$  表示模型每层的可学习参数;  $U$  为图拉普拉斯矩阵的特征向量矩阵;  $U^T x$  可以看作是节点特征  $x$  的图上傅里叶变化形式。

式(3)的计算量较大,可以通过使用新的可学习卷积核  $f_{\theta} = U^T f$  进行简化。卷积核  $f_{\theta}$  可进一步通过切比雪夫多项式展开近似简化,以加速运算。

通过卷积核的近似简化,可得到谱图卷积。最后,通过使用非线性激活函数处理图卷积结果以构建图卷积层。图卷积层间的堆叠构成了整个图卷积神经网络模型。

文章设计了缺陷分类模型与缺陷回归模型。分类模型将缺陷位置分类为不同的结构区域,使用收集的导波信号集对未知缺陷进行分类定位。回归模型则是直接使用导波信号集预测未知缺陷的具体位置。

图卷积神经网络分类与回归模型如图4所示(图中 ChebConv 表示切比雪夫卷积函数),分类模




图4 图卷积神经网络分类与回归模型



型包含 3 层图卷积层,其中两层用于图数据特征提取,一层用于特征分类,表示为

$$Z = \text{Softmax}\{\text{Che}\{\sigma\{\text{Che}\{\sigma\{\text{Che}[H, \mathbf{W}^{(0)}]\}, \mathbf{W}^{(1)}\}\}, \mathbf{W}^{(2)}\}\}, \quad (4)$$

式中:  $Z$  为输出结果;  $\sigma$  为非线性激活函数(ReLU),  $o(z) = \max(0, z)$  [22],  $z$  为特征值;  $\text{Che}(\cdot)$  为切比雪夫卷积函数;  $H$  为输入;  $\mathbf{W}^{(0)}$ ,  $\mathbf{W}^{(1)}$  和  $\mathbf{W}^{(2)}$  为每层的权重矩阵;  $\text{Softmax}(\cdot)$  为分类 Softmax 函数 [23]。

回归模型同样包含三层图卷积层,两层用于图数据特征提取,但最后一层用于特征分类,表示为

$$Z' = \text{Linear}\{\text{Che}\{\sigma\{\text{Che}\{\sigma\{\text{Che}[H, \mathbf{W}^{(0)}]\}, \mathbf{W}^{(1)}\}\}, \mathbf{W}^{(2)}\}\} \quad (5)$$

式中:  $Z'$  为输出结果;  $\text{Linear}(\cdot)$  为线性回归函数。  
图卷积神经网络模型训练通过最小化模型输入和输出之间的损失函数来优化评估模型中的可学习参数。损失函数的选择是基于模型优化方向的,文中分类模型使用交叉熵损失函数,回归模型使用均方差损失函数。

## 2 缺陷检测与定位方案

系统完整的结构缺陷检测与定位过程如图 5 所示。

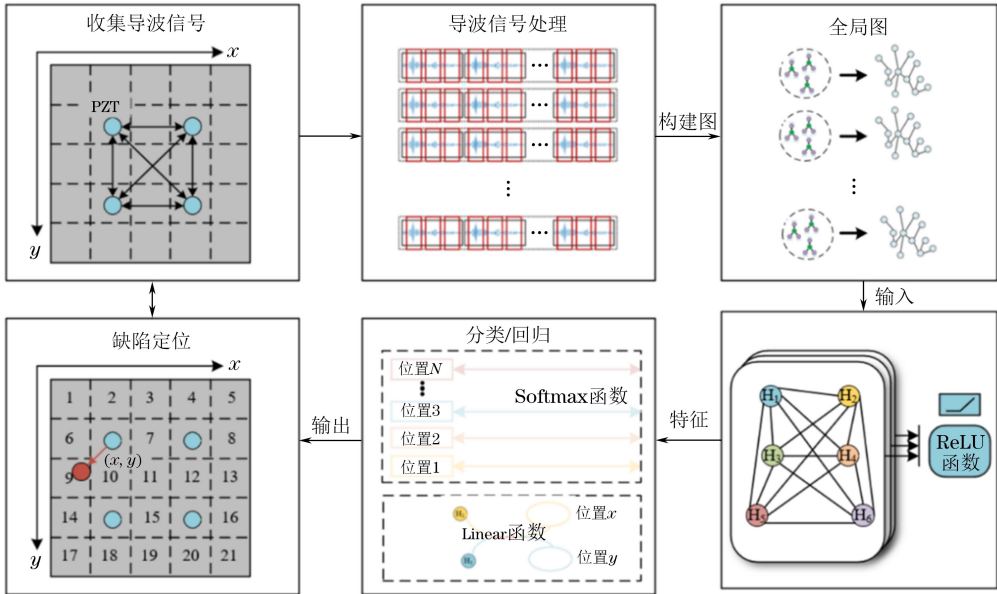


图 5 基于图嵌图卷积神经网络的缺陷检测与定位方案

导波信号采集的方法包括:① 所有 PZT 作为致动器激发信号,其他 PZT 作为传感器记录接收信号;② 增加导波信号时域记录长度覆盖边界反射导波信号;③ 提取隐藏在导波信号中相互关系信息。

试验搭建的超声无损检测试验平台如图 6 所示。平台上安装了 12 对致动器-传感器 PZT,记录




图 6 超声无损检测试验平台

固定时域长度的导波信号。采用 Tek AFG3052C 函数/任意波形发生器输出调制信号,经过宽频功率放大器放大,施加于 PZT 产生波形。采用四通道数字示波器显示并存储激励波形,记录接收波形。使用质量为 0.3 kg,直径为 25 mm 的砝码作为模拟缺陷 [22]。

文章以尺寸 500 mm×500 mm×4 mm(长×宽×高)铝板结构为例,将板结构划分为 25 个相等区域[见图 7(a)]。使用同样尺寸的另一板材[见图 7(b)]收集缺陷信号,但缺陷位置是随机设置的。此时收集的缺陷信号不参与模型训练,而是测试 G-GCN 是否对其他板材的随机缺陷位置检测依旧有效。

导波激励信号选择窄带调制信号,可以得到含有较少模式的响应信号,有利于响应波形的分析。因此,试验采用 5 周期的经汉宁窗调制的正弦信号作为激励信号,中心频率设置为 200 kHz。由示波

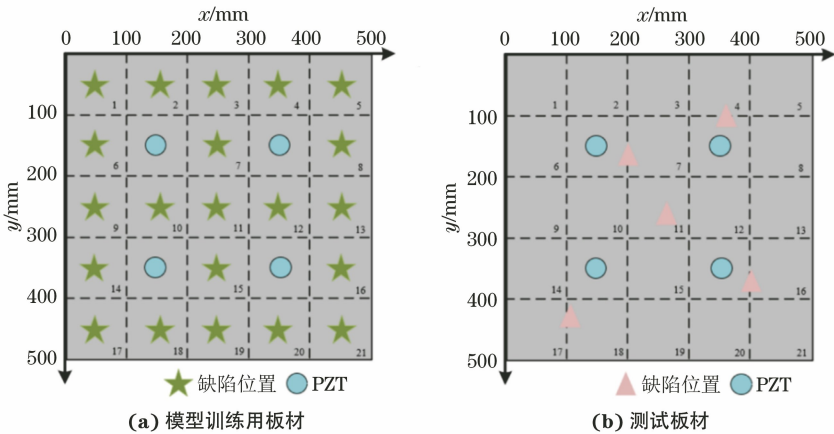


图 7 两块板材的模拟缺陷位置与 PZT 放置位置示意

器收集其他 PZT 的响应信号。每个模拟缺陷位置均收集 12 组导波信号,构成对应于同一缺陷位置的导波数据集。考虑到收集过程中的操作不确定性和环境噪声,每个模拟缺陷位置的收集操作重复 2 次,以扩大数据集规模。

对于复合材料层合板的试验验证,此处使用 MOLL<sup>[24]</sup> 的试验数据集。复合材料层合板试样由预浸料 Hexply © M21/34%/UD134/T700/300 组成,具有准各向同性叠层,纤维增强铺层顺序为 [45/0/-45/90/-45/0/45/ 90]S。模拟缺陷是直径为 10 mm,厚度为 2.35 mm,质量为 0.5 g 的小型铝制硬盘。在采集信号过程中,选用了 4 个 PZT 采集的导波信号集,并且选用了 28 个不同模拟缺陷的位置。

3 缺陷定位结果与对比

选取其他几个模型进行对比,包括 CNN 模型<sup>[22]</sup>,MRF-GCN 模型<sup>[21]</sup>和 Graph WaveNet 模型<sup>[25]</sup>。

所有模型均使用 Adam 优化器进行训练,初始学习率为 0.001。此处只使用其中 3 个 PZT 构成的传感器阵列中收集的导波信号。G-GCN 将以总样本数的 60%用于训练,20%用于验证,20 %用于测试。

首先测试分类模型,所用缺陷分类模型结构和参数如表 1 所示。

基于此结构,对铝板数据集模型进行训练,得到结果如表2所示,可见,G-GCN在有限且不平衡的导波数据集上实现了完美的收敛;MRF-GCN在缺

表 1 缺陷分类模型结构与参数

成分	层	激活函数	输出维数
1	输入	—	33
2	ChebConv1 (K=3)	ReLU	30
3	ChebConv2 (K=3)	ReLU	25
4	ChebConv3 (K=3)	Softmax	22

表 2 铝板缺陷分类结果对比

模型	训练精度/ %	验证精度/ %	测试精度/ %	训练时间/ s
CNN	100.00	97.50	86.36	53.66
MRF-GCN	24.15	17.95	17.31	530.31
Graph WaveNet	61.54	66.67	33.33	13 671.55
G-GCN	100.00	100.00	100.00	11.01

陷分类中精度很低,说明仅考虑导波信号之间的相互关系信息无法进行损伤分类;Graph WaveNet 模型同样精度很低,且训练时间最长,表明自适应构图并不适用于导波信号的特征提取。从以上比较中可以得出结论,相互关系信息对于缺陷检测至关重要,不适当的关系信息提取反而会导致错误结果。

缺陷分类模型在另一块板材的随机缺陷位置预测对比结果如图 8 所示。由图 8 可以看出,分类模型倾向于将位于划分区域边界上的缺陷归属为相邻区域缺陷类别;G-GCN 模型预测能力比其他几种模型更加优秀。

对于缺陷回归模型,所用模型结构和参数如表 3 所示。

表 3 缺陷回归模型结构与参数

成分	层	激活函数	输出维数
1	输入	—	33
2	ChebConv1 (K=3)	ReLU	30
3	ChebConv2 (K=3)	ReLU	25
4	ChebConv3 (K=3)	Linear	2

基于此结构,对铝板数据集进行模型训练,得到结果如表 4 所示。

使用可决系数( $R^2$  系数)<sup>[26]</sup> 评估模型回归的精度。从表 4 可以看出,G-GCN 的精度依旧是最高的,且足够稳定。同样,其在另一块板材的随机缺陷位置定位结果如图 9 所示。

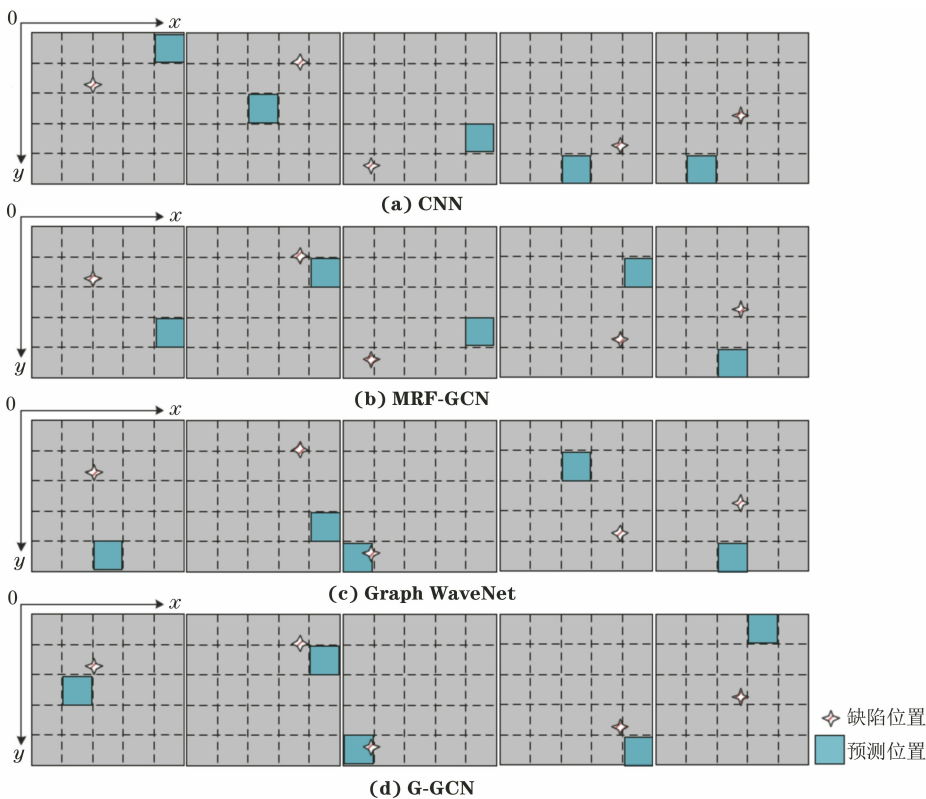


图 8 缺陷分类模型的随机缺陷位置预测对比结果

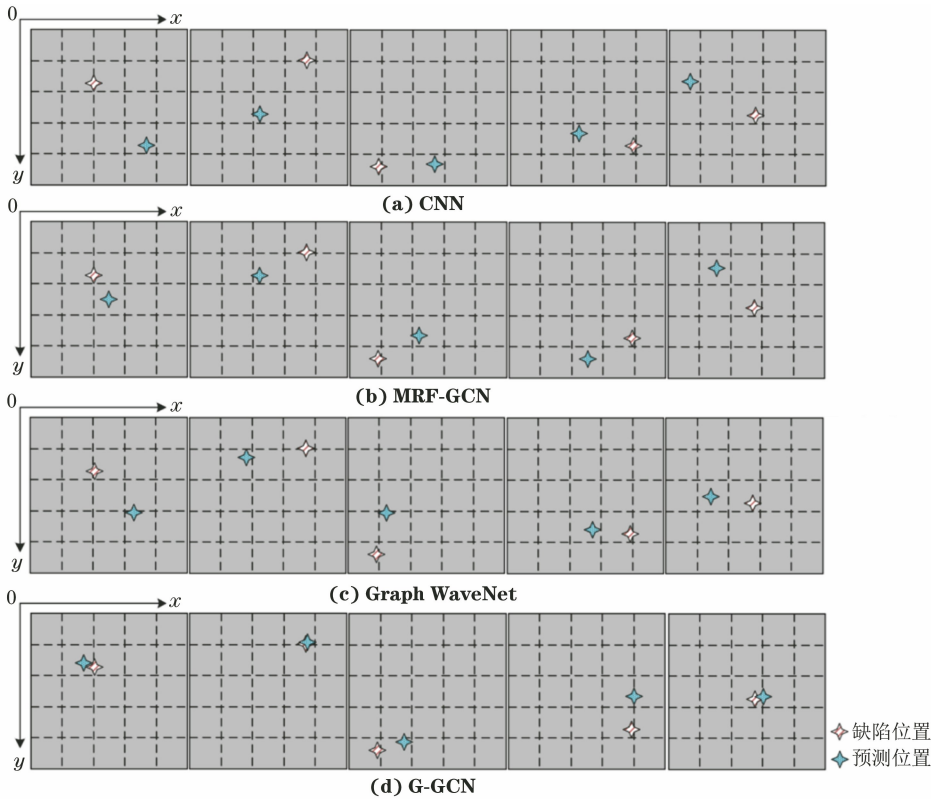


图 9 缺陷回归模型的随机缺陷位置预测对比结果

由图 9 可知,相比于分类模型,回归模型的随机缺陷定位精度更高。该节所使用的导波数据集规模小且不平衡,G-GCN 以外的模型无法有效提取与缺

陷相关的信息,且基于 GCN 的模型预测结果却更加稳定。

基于以上结果,缺陷回归模型更适用于复合材

料层合板的缺陷检测与定位。以复合材料数据集总样本数的 60 %用于训练,20 %用于验证,20 %用于测试,其缺陷检测与定位结果如表 5 所示。

表 4 铝板缺陷回归结果对比

模型	训练 $R^2$	验证 $R^2$	测试 $R^2$	训练时间/s
	系数	系数	系数	
CNN	0.983 5	0.881 9	0.704 9	260.46
MRF-GCN	0.932 4	0.809 3	0.833 1	340.26
Graph WaveNet	0.803 8	0.937 9	0.878 4	4 051.76
G-GCN	0.995 0	0.993 5	0.991 5	328.51

表 5 复合材料层合板缺陷回归结果对比

模型	训练 $R^2$	验证 $R^2$	测试 $R^2$	训练时间/s
	系数	系数	系数	
CNN	-0.277 1	-0.350 7	-0.143 0	256.42
MRF-GCN	0.868 0	-0.107 6	-0.356 1	1 198.53
Graph WaveNet	-0.243 3	-0.452 6	-0.699 9	7 296.70
G-GCN	0.995 4	0.987 7	0.961 4	3 063.91

在复合材料数据集上的结果表明只有 G-GCN 模型可以满足要求,其他模型在复合材料数据集上  $R^2$  系数为负数,是极差的精度表现。这不仅是因为复合材料结构上的复杂性,更是因为使用的模拟缺陷体积小、质量轻,对导波波场变化的影响微小,普通深度学习模型并不具备足够的学习能力,而 G-GCN 模型显示出优秀的性能,可以应用在复合材料的微小缺陷检测中。

4 结语

提出了一种基于超声导波的损伤检测和定位方法图嵌图卷积神经网络 G-GCN 模型。G-GCN 模型实现了导波相互关系信息的充分提取,并且建立了相应高层次时空信息图谱特征表示。同时,搭建了超声导波检测试验平台,在金属铝板和复合材料层合板上进行了试验验证,表明 G-GCN 优于其他现有方法,且 G-GCN 精度高、速度快,非常适合实时复合材料的缺陷检测与定位。

需要补充的是,虽然结果显示 G-GCN 模型的预测能力比其他几种模型更加优秀,但该方法对随机缺陷的定位精度是建立在充分收集导波信号的基础上的,因此需要对导波信号的充分收集进行进一步优化。

参考文献:

[1] ROSE J L. Ultrasonic Guided Waves in Solid Media [M]. Cambridge:Cambridge University Press,2014.  
[2] CASTAINGS M,HOSTEN B,KUNDU T. Inversion

of ultrasonic, plane-wave transmission data in composite plates to infer viscoelastic material properties[J]. NDT & E International,2000,33(6): 377-392.  
[3] CASTELLANO A,FOTI P,FRADDOSIO A,et al. Mechanical characterization of CFRP composites by ultrasonic immersion tests: experimental and numerical approaches [J]. Composites Part B: Engineering,2014,66:299-310.  
[4] AYMERICH F,MEILI S. Ultrasonic evaluation of matrix damage in impacted composite laminates[J]. Composites Part B:Engineering,2000,31(1):1-6.  
[5] 王奔. 改性复合材料层间力学性能超声导波评价技术研究[D]. 镇江:江苏大学,2020.  
[6] KESSLER S S,SPEARING S M,SOUTIS C. Damage detection in composite materials using Lamb wave methods[J]. Smart Materials and Structures,2002,11(2):269-278.  
[7] LEMISTRE M,BALAGEAS D. Structural health monitoring system based on diffracted Lamb wave analysis by multiresolution processing [J]. Smart Materials and Structures,2001,10(3):504-511.  
[8] MICHAELS J E. Detection, localization and characterization of damage in plates with an in situ array of spatially distributed ultrasonic sensors [J]. Smart Materials and Structures,2008,17(3): 035035.  
[9] MICHAELS J E, MICHAELS T E. Guided wave signal processing and image fusion for in situ damage localization in plates[J]. Wave Motion,2007,44(6): 482-492.  
[10] HALL J S,MICHAELS J E. Computational efficiency of ultrasonic guided wave imaging algorithms [J]. IEEE Transactions on Ultrasonics,Ferroelectrics,and Frequency Control,2011,58(1):244-248.  
[11] HALL J S,MCKEON P,SATYANARAYAN L,et al. Minimum variance guided wave imaging in a quasi-isotropic composite plate[J]. Smart Materials and Structures,2011,20(2):025013.  
[12] NOKHBATOLFOGHAHAI A,NAVAZI H M,GROVES R M. Using the hybrid DAS-SR method for damage localization in composite plates[J]. Composite Structures,2020,247:112420.  
[13] NANDYALA A R,DARPE A K,SINGH S P. Damage localization in cross-ply laminated composite plates under varying temperature conditions using Lamb waves [J]. Measurement Science and Technology,2020,31(6):064003.



[14] MUSTAPHA S, YE L, DONG X J, et al. Evaluation of barely visible indentation damage (BVID) in CF/EP sandwich composites using guided wave signals [J]. Mechanical Systems and Signal Processing, 2016, 76/77:497-517.

[15] WANG Z, HUANG S L, WANG S, et al. Multihelical lamb wave imaging for pipe-like structures based on a probabilistic reconstruction approach [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70:1-10.

[16] BANG S S, LEE Y H, SHIN Y J. Defect detection in pipelines via guided wave-based time-frequency-domain reflectometry [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70:1-11.

[17] 邹兰林, 叶知秋. 小波分析结合神经网络的桩基缺陷检测[J]. 无损检测, 2022, 44(7):50-54.

[18] 杨志学, 汪正山, 叶雅婷, 等. 基于超声导波的长距离高压多芯电缆缺陷检测[J]. 无损检测, 2018, 40(12):57-62.

[19] 徐浩, 王中枢, 马寅魏, 等. 基于超声导波和机器学习的蜂窝夹层结构脱黏诊断[J]. 无损检测, 2022, 44(10):44-47.

[20] WANG Y M, KANG Y H, WU X J. Application of STFT and HOS to analyse magnetostrictively generated pulse-echo signals of a steel pipe defect[J]. NDT & E International, 2006, 39(4):289-292.

[21] LI T F, ZHAO Z B, SUN C, et al. Multireceptive field graph convolutional networks for machine fault diagnosis [J]. IEEE Transactions on Industrial Electronics, 2021, 68(12):12739-12749.

[22] ZHANG S Y, LI C M, YE W J. Damage localization in plate-like structures using time-varying feature and one-dimensional convolutional neural network [J]. Mechanical Systems and Signal Processing, 2021, 147:107107.

[23] YANG C Y, ZHOU K B, LIU J. SuperGraph: spatial-temporal graph-based feature extraction for rotating machinery diagnosis [J]. IEEE Transactions on Industrial Electronics, 2022, 69(4):4167-4176.

[24] MOLL J, KATHOL J, FRITZEN C P, et al. Open guided waves: online platform for ultrasonic guided wave measurements [J]. Structural Health Monitoring, 2019, 18(5/6):1903-1914.

[25] WU Z H, PAN S R, LONG G D, et al. Graph WaveNet for deep spatial-temporal graph modeling [C]//Proceedings of the twenty-eighth international joint conference on artificial intelligence, California: International Joint Conferences on Artificial Intelligence Organization, 2019.

[26] RAUTELA M, GOPALAKRISHNAN S. Ultrasonic guided wave based structural damage detection and localization using model assisted convolutional and recurrent neural networks[J]. Expert Systems with Applications, 2021, 167:114189.

~~~~~

(上接第 44 页)

[4] 管练武. MEMS 捷联惯性导航系统辅助的管道检测定位技术研究[D]. 哈尔滨:哈尔滨工程大学, 2016.

[5] 苏林, 马雪莉, 薛鹏. 管道惯性测绘系统研制及应用[J]. 管道技术与设备, 2020(2):22-24.

[6] 于希宁, 彭鑫, 冯丽丽, 等. 基于惯性的组合导航管道中心线测绘及缺陷定位[J]. 化学工程与装备, 2021(5):215-216.

[7] CHOWDHURY M S, ABDEL-HAFEZ M F. Pipeline inspection gauge position estimation using inertial measurement unit, odometer, and a set of reference stations[J]. ASCE-ASME J Risk and Uncert in Engrg Sys Part B Mech Engrg, 2016, 2(2):021001.

[8] 杨理践, 李瑞强, 高松巍, 等. 管道内检测导航定位技术[J]. 沈阳工业大学学报, 2012, 34(4):427-432.

[9] 牛小骥, 旷俭, 陈起金. 采用 MEMS 惯导的小口径管道内检测定位方案可行性研究[J]. 传感技术学报, 2016, 29(1):40-44.

[10] 马义来, 陈金忠, 周汉权, 等. 基于微机械惯导的管道多功能内检测系统研发[J]. 石油机械, 2021, 49(4):133-137.

[11] 严恭敏. 捷联惯导算法与组合导航原理[M]. 西安:西北工业大学出版社, 2019.

[12] 陈嘉扬. MEMS 捷联惯导与组合导航算法设计与仿真[D]. 广州:广东工业大学, 2021.

[13] 杨理践, 李晖, 靳鹏, 等. 管道地理坐标测量系统 SINS 安装误差标定[J]. 仪器仪表学报, 2015, 36(1):40-48.

[14] SAVAGE P G. Strapdown inertial navigation integration algorithm design part 1: attitude algorithms [J]. Journal of Guidance, Control, and Dynamics, 1998, 21(1):19-28.

[15] SAVAGE P G. Strapdown inertial navigation integration algorithm design part 1: attitude algorithms [J]. Journal of Guidance, Control, and Dynamics, 1998, 21(1):19-28.

[16] NOURELDIN A, KARAMAT T B, GEORGY J. Fundamentals of Inertial Navigation, Satellite-based Positioning and their Integration [M]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013.