

基于SBFEM和深度学习的裂纹状缺陷反演模型

江守燕, 万 晨, 孙立国, 杜成斌

CRACK-LIKE DEFECT INVERSION MODEL BASED ON SBFEM AND DEEP LEARNING

Jiang Shouyan, Wan Chen, Sun Ligu, and Du Chengbin

在线阅读 View online: <https://doi.org/10.6052/0459-1879-21-360>

您可能感兴趣的其他文章

Articles you may be interested in

改进型扩展比例边界有限元法

IMPROVED EXTENDED SCALED BOUNDARY FINITE ELEMENT METHODS

力学学报. 2019, 51(1): 278-288

比例边界有限元法求解裂纹面接触问题

CRACK FACE CONTACT PROBLEM ANALYSIS USING THE SCALED BOUNDARY FINITE ELEMENT METHOD

力学学报. 2017, 49(6): 1335-1347

基于深度学习和细观力学的颗粒材料本构关系研究

CONSTITUTIVE RELATIONS OF GRANULAR MATERIALS BY INTEGRATING MICROMECHANICAL KNOWLEDGE WITH DEEP LEARNING

力学学报. 2021, 53(9): 2404-2415

基于LSTM模型的飞行器智能制导技术研究

RESEARCH OF LSTM MODEL-BASED INTELLIGENT GUIDANCE OF FLIGHT AIRCRAFT

力学学报. 2021, 53(7): 2047-2057

基于一类非局部宏-微观损伤模型的裂纹模拟

CRACKING SIMULATION BASED ON A NONLOCAL MACRO-MESO-SCALE DAMAGE MODEL

力学学报. 2020, 52(3): 749-762

基于卷积神经网络的涵洞式直立堤波浪透射预测

PREDICTION OF WAVE TRANSMISSION OF CULVERT BREAKWATER BASED ON CNN

力学学报. 2021, 53(2): 330-338



关注微信公众号, 获得更多资讯信息

基于 SBFEM 和深度学习的裂纹状缺陷反演模型¹⁾江守燕²⁾ 万 晨 孙立国 杜成斌

(河海大学力学与材料学院, 南京 211100)

摘要 结构内部缺陷的识别是结构健康监测的重要研究内容, 而当前以无损检测为主的结构安全检测多以定性分析为主, 定量识别缺陷的尺度较困难. 本文将比例边界有限元法 (scaled boundary finite element methods, SBFEM) 和深度学习相结合, 提出了基于 Lamb 波在结构中传播时的反馈信号定量识别结构内部裂纹状缺陷的反演模型. 通过随机生成缺陷信息 (位置、大小), 采用 SBFEM 模拟 Lamb 波在含不同缺陷信息的结构中的信号传播过程, SBFEM 仅需对结构边界离散可最小化网格重划分过程, 大大提高了计算效率. Lamb 波在含裂纹状缺陷结构中传播时观测点的反馈信号包含大量的裂纹信息, 基于这一特性可为深度学习模型提供足够多的反映问题特性的训练数据. 建议的缺陷反演模型规避了传统反分析问题的目标函数极小化迭代过程, 在保证计算精度的前提下大大减少了计算成本. 对含单裂纹和多裂纹板的数值算例进行分析, 结果表明: 建立的缺陷识别模型能够准确地量化结构内部的缺陷, 对浅表裂纹亦有很好的识别效果, 且对于含噪信号模型仍具有较好的鲁棒性.

关键词 无损检测, 比例边界有限元法, 深度学习, 反分析问题, 缺陷识别, 裂纹

中图分类号: TB115 文献标识码: A doi: 10.6052/0459-1879-21-360

CRACK-LIKE DEFECT INVERSION MODEL BASED ON SBFEM AND DEEP LEARNING¹⁾Jiang Shouyan²⁾ Wan Chen Sun Liguó Du Chengbin

(College of Mechanics and Materials, Hohai University, Nanjing 211100, China)

Abstract The identification of structural internal defects is an important research content of structural health monitoring. At present, the structural safety inspection based on non-destructive testing mainly focuses on qualitative analysis, so it is difficult to identify the scale of defects quantitatively. In this paper, an inversion model is proposed by combing the scaled boundary finite element methods (SBFEM) and deep learning. The identification of crack-like defects can be performed in structures based on the feedback signal of Lamb wave propagation. By randomly generating defect information, i.e. position and size, the SBFEM can be used to simulate the signal propagation process of Lamb wave in structures with defects. The SBFEM only needs to discretize the structure boundary, which can minimize the re-meshing process and greatly improve the computational efficiency. When Lamb wave propagates in a cracked structure, the feedback signal of the observation point can reflect crack information. Based on this characteristic, enough training data reflecting the characteristics of the problem can be provided for the deep learning model. The proposed defect inversion

2021-07-27 收稿, 2021-09-26 录用, 2021-09-27 网络版发表.

1) 国家重点研发计划 (2018YFE0122400), 中央高校基本科研业务费专项资金 (B210202097) 和国家自然科学基金 (51579084) 资助项目.

2) 江守燕, 副教授, 主要研究方向: 计算力学和虚拟仿真. E-mail: syjiang@hhu.edu.cn

引用格式: 江守燕, 万晨, 孙立国, 杜成斌. 基于 SBFEM 和深度学习的裂纹状缺陷反演模型. 力学学报, 2021, 53(10): 2724-2735

Jiang Shouyan, Wan Chen, Sun Liguó, Du Chengbin. Crack-like defect inversion model based on SBFEM and deep learning. *Chinese Journal of Theoretical and Applied Mechanics*, 2021, 53(10): 2724-2735

model avoids the iterative process of minimizing the objective function of the traditional inverse problems, and greatly reduces the computational cost on the premise of ensuring accuracy. Numerical examples of plates with single and multiple cracks are analyzed. The results show that the defect identification model can accurately quantify the defects in the structure. It also has a good identification effect for shallow cracks. The model also shows robustness to the noisy signal model.

Key words non-destructive testing, scaled boundary finite element methods, deep learning, inverse problems, defect identification, crack

引言

无损检测技术于 20 世纪 50~60 年代开始得到广泛应用, 在无损检测的初级阶段, 其技术和任务都较为简单, 在技术手段上可选择的并不丰富, 主要采用超声、射线等技术; 在任务上主要是检测结构或试件是否存在缺陷或者异常, 其基本任务是在不破坏结构或试件本身的情况下发现其中的缺陷, 以满足工程需要. 随着各方面技术的发展, 人们越来越关注缺陷的位置、尺寸和形状, 结构的无损检测技术需由定性阶段向定量阶段发展和提高^[1].

智能优化算法与计算力学方法相结合已广泛应用于缺陷检测的定量反演问题中^[2-12]. 文献 [2-4] 将扩展有限元法与遗传算法相结合进行缺陷反演, 但传统的遗传算法在目标函数最小化迭代过程中效率低下并且容易陷入局部最优解; Nanthakumar 等^[5]将扩展有限元法与多层坐标搜索方法相结合, 用于检测压电材料中的缺陷; 江守燕和杜成斌^[6]将扩展有限元法与人工蜂群算法相结合进行结构内部孔洞状和裂纹状缺陷的反演; 这些研究主要用于检测单个缺陷. Sun 等^[7]提出了一种基于扩展有限元法和改进的人工蜂群算法的结构多缺陷检测与量化新算法, 后来, Sun 等^[8]进一步提出了一种新的多尺度算法来检测结构中的多个缺陷, 该方法在收敛速度上有了显著地提高; 为了研究建模误差和测量噪声对检测结果的影响, Yan 等^[9]提出了一种贝叶斯方法, 可以有效地识别缺陷的数量, 并量化每个缺陷的参数不确定性; 王佳萍等^[10-11]将扩展有限元法与遗传算法和改进人工蜂群算法相结合进行结构内部多缺陷反演. 最近, Zhao 等^[12]和 Ma 等^[13]将扩展有限元法与蜂群和鱼群算法相结合, 通过引入聚类算法, 显著提高了反演分析的收敛性. 然而, 在这些研究中测量的响应被认为是静态响应, 即位移和应变. 在实际无损检测中, 安装在结构上的一组传感器很难记录

静态响应数据, 实际操作性也困难.

相比之下, 在实际问题中, 传感器较易测得结构的动态响应. 文献 [14-17] 为了检测结构的内部缺陷, 基于结构的动态响应构造了目标函数; 在时域中使用计算力学方法来解决正问题的方法已用于非均匀介质中的缺陷检测^[14]以及压电结构^[15], 动态载荷已被证明对裂纹检测问题更有效^[16]. Du 等^[18]最近的一项研究提出了一种基于时域动力扩展有限元法和改进的人工蜂群算法的多缺陷检测新策略; Ma 等^[19]开发了动态可变节点扩展有限元法, 采用三步算法检测多个复杂缺陷簇. 虽然动态变节点扩展有限元法^[19-20]大大减轻了正分析的计算工作量, 但动力分析的时间需求仍然大大超过静力分析, 特别是在目标函数极小化迭代过程中计算工作量巨大, 甚至难以迭代收敛.

为了降低计算成本, 将计算力学方法和机器(深度)学习相结合是一种行之有效的途径, 机器(深度)学习是人工智能和模式识别的一个快速发展的分支学科, 其理论和方法已广泛应用于解决工程和应用科学中的复杂问题^[21-22]. 此外, 超声波检测技术是结构无损检测最重要的手段之一, 已广泛应用于各种工程领域^[23-25], 传统的超声波检测技术主要通过对比回波信号的分析定性地反映缺陷的存在^[26], 难以准确定量缺陷, 且强信号中的反映结构微缺陷的信号成分较难提取^[27]. 基于神经网络模型的缺陷识别算法可有效提取结构中反映缺陷的信号成分^[28], 进而识别缺陷, 但由于基于试验的数据样本有限, 限制了缺陷识别正确率和精度的进一步提高.

本文提出一种将深度学习与比例边界有限元法(scaled boundary finite element methods, SBFEM)相结合的裂纹状多缺陷无损检测方法, SBFEM 仅需对结构边界离散可最小化网格重划分过程^[29], 大大提高了计算效率, 用于解决与深度学习所需的大量输入数据相关的问题. 首先, 在结构内部随机地

生成大量的模拟缺陷数据;其次,针对每个有效缺陷数据,采用 SBFEM 模拟 Lamb 波在结构内的传播过程,SBFEM 分析结果生成的数据用于深度学习的训练;最后,利用训练后的深度学习模型,根据实测的结构动响应定量识别缺陷的位置和大小.建议的方法避免了传统反分析问题的目标函数极小化迭代过程,为结构的无损检测提供了一条新的有效途径.

1 动力问题的比例边界有限元法

1.1 比例边界有限元法基本方程

SBFEM 是一种半解析的数值方法,它的半解析性为断裂问题的分析提供了很大的优势,裂尖局部无需网格细化,也无需引入解析的改进函数,裂尖的应力奇异性在求解过程中能被解析地表征^[29].对于有限域问题,SBFEM 和有限元法类似,先将 S 域离散成一个或者多个 S 单元,然后按照顺序将各个 S 单元组装起来,进而求解方程的基本未知量.如图 1 所示为 SBFEM 的 S 域以及 S 单元的示意图,图 1(a)为含有裂纹的任意多边形 S 域,模型将 S 域划分为 4 个多边形 S 单元,其中 S 单元 1 包含裂纹信息(即

裂纹 S 单元),裂纹 S 单元的构造如图 1(b) 所示.

在比例边界坐标系 (ξ, η) 中, ξ 为径向坐标, η 为环向坐标.在比例中心 O 点处,径向坐标 $\xi = 0$,环向坐标 η 沿着边界,且在边界上 $\eta = 1$.S 单元中的任意一点在笛卡尔坐标系下的坐标 (x, y) 可由 ξ 和 η 表示为

$$\begin{cases} x = \xi N(\eta) x_s \\ y = \xi N(\eta) y_s \end{cases} \quad (1)$$

式中, $N(\eta)$ 为形函数矩阵,与有限元中的形函数类似,但只与环向坐标 η 有关; x_s 和 y_s 分别为 S 单元结点 x 方向和 y 方向坐标向量. SBFEM 位移模式可以表示为

$$u(\xi, \eta) = N(\eta) u(\xi) \quad (2)$$

式中, $u(\xi)$ 是沿径向的位移,由 N 个解析函数组成.

由 SBFEM 的位移模式式 (2) 并假定计算域为线弹性各向同性材料,根据虚功原理,不计阻尼,可推导出动力问题的 SBFEM 控制方程为

$$M\ddot{u} + Ku = F(t) \quad (3)$$

式中, M 为整体质量矩阵, K 为整体刚度矩阵, $F(t)$ 为整体荷载向量.上述方程形式上与有限元法完全一致,但 M , K 和 $F(t)$ 的组装方式与 SBFEM 动力刚度矩阵有关,与有限元法不同.采用动力刚度矩阵 $S(\omega, \xi)$ 表示的 SBFEM 方程为^[30]

$$\begin{aligned} & [S(\omega, \xi) - \xi E_1](\xi E_0)^{-1} [S(\omega, \xi) - \xi E_1^T] - \xi E_2 + \\ & \omega S(\omega, \xi)_{,\omega} + \omega^2 \xi^3 M_0 = 0 \end{aligned} \quad (4)$$

式 (4) 是关于 ξ 的解析方程,系数矩阵 E_0 , E_1 和 E_2 与 ξ 无关,仅与子域几何形状和材料参数有关, M_0 类似有限元法中的质量矩阵,它们的表达式参见文献 [31],可采用连分式法^[31]求解 SBFEM 的动力刚度矩阵.

1.2 Lamb 波

Lamb 波又称板波,其物理实质是薄板对声波波长的选择特性和多频率纵横波的合成特性,通常是指在自由边界固体板中的弹性波,当板的厚度与波长处于同一数量级时板中的纵波和横波发生耦合,在固体介质中形成一种特殊形式的弹性应力波.这种弹性应力波必须要满足板的两个表面边界条件,在板的两表面和中部都有质点的振动,声场遍及整个板的厚度.薄板两表面的质点振动是纵波和横波成分之和,运动轨迹为椭圆形,长轴与短轴的比例取决于材料的性质. Lamb 波在板中传播时,即有振动




图 1 比例边界有限元 S 域和 S 单元示意图

Fig. 1 Schematic diagram of S-domain and S-element in SBFEM

方向与板面垂直的横波, 又有振动方向与板面平行的纵波, 纵横波的合成波质点的振动与板共振, 并以特定的频率振动并获得最大能量的传输。

Lamb 波在传播中会出现多个模态, 这些模态可以根据板中质点振动的相位关系分为对称模态 S_i 和反对称模态 A_i 两类。在各向同性的板中, 纵波和横波的速度可根据拉梅常量计算。自由边界条件时, 对称模态下波的频率特征方程为

$$\left. \begin{aligned} \frac{\tan(qh)}{\tan(ph)} &= -\frac{4k^2 pq}{(q^2 - k^2)^2} \\ p^2 &= \frac{\omega^2}{c_L^2} - k^2 \\ q^2 &= \frac{\omega^2}{c_T^2} - k^2 \end{aligned} \right\} \quad (5)$$

反对称模态下为

$$\frac{\tan(qh)}{\tan(ph)} = -\frac{(q^2 - k^2)^2}{4k^2 pq} \quad (6)$$

式中, k 为波数, h 为板厚, c_L 为纵波波速, c_T 为横波波速, ω 为圆频率。

2 基于深度学习的缺陷识别模型

深度学习是一种表示学习^[32-33], 能够学到数据更高层次的抽象表示, 自动地从数据中提取特征^[34]。

2.1 卷积神经网络

卷积神经网络 (convolutional neural network, CNN) 是一种具有局部连接、权重共享等特性的深层前馈神经网络。CNN 被广泛应用于分类和回归问题的研究, 其中一维 CNN 在时间序列、电信号以及音频信号等领域的分析有着出色的表现, 故深度学习反演模型将采用一维 CNN。CNN 的基本结构由输入层、卷积层、池化层、全连接层及输出层构成^[35]。

卷积层中卷积核对前一层输出的特征矢量进行卷积操作, 利用非线性激活函数构建输出特征矢量, 每一层的输出均为对多输入特征的卷积结果, 第 j 个神经元第 l 层的输出 x_j^l 可表示为

$$x_j^l = f \left(\sum_{i \in M_j} x_i^{l-1} k_{ij}^l + b_j^l \right) \quad (7)$$

式中, M_j 为输入特征矢量集合; k_{ij}^l 为卷积核; b_j^l 为网络偏置; x_i^{l-1} 为第 l 层输入。在 CNN 中, 非线性激活函数通常选择修正线性单元 (rectified linear unit,

ReLU), ReLU 的优势在于使一部分神经元的输出为 0, 提高网络的稀疏性, 缓解了过拟合问题的发生。同时将原本线性不可分割的多维特征映射到另一个空间中, 从而增强特征的线性可分离性。ReLU 的输出值 $a_i^{l+1}(j)$ 可表示为

$$a_i^{l+1}(j) = f[y_i^{l+1}(j)] = \max\{0, y_i^{l+1}(j)\} \quad (8)$$

式中, $y_i^{l+1}(j)$ 表示卷积层的输出值; $f(*)$ 表示激活函数 ReLU。

池化层主要作用是进行特征选择, 降低特征数量, 从而减少参数数量, 同时提高所提取特征的鲁棒性。卷积层虽然可以显著减少网络中连接的数量, 但特征映射组中的神经元个数并没有显著减少, 容易出现过拟合。为了解决这个问题, 可以在卷积层之后加上一个池化层, 从而降低特征维数, 避免过拟合。常用的池化函数有两种, 最大池化和平均池化, 最大池化变换函数如下所示

$$P_i^{l+1}(j) = \max_{(j-1)W+1 \leq t \leq jW} \{q_i^l(t)\} \quad (9)$$

式中, $q_i^l(t)$ 表示第 l 层第 i 个特征矢量中第 t 个神经元的值, $t \in [(j-1)W+1, jW]$; W 为池化核的大小; $P_i^{l+1}(j)$ 表示第 $l+1$ 层神经元对应的值。平均池化变换函数如下所示

$$P_i^{l+1}(j) = \text{avg}_{(j-1)W+1 \leq t \leq jW} \{q_i^l(t)\} \quad (10)$$

全连接层的每一个结点都与上一层的所有结点相连, 用来把前边提取到的特征综合起来。全连接层一般负责分类或者回归。

输出层通常使用 Sigmoid 函数, Sigmoid 函数的梯度平滑, 且输出值在 0~1 之间, 其函数表达式如下所示

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (11)$$

2.2 缺陷识别模型

缺陷反演的流程图如图 2 所示, 首先通过 SBFEM 模拟 Lamb 波在含有缺陷薄板中的传播过程, 将观测点的动力响应作为深度学习神经网络模型的输入, 缺陷信息作为模型的输出, 训练神经网络, 最后使用训练好的网络识别薄板内部未知缺陷。

论文结合 SBFEM 数值模拟和深度学习算法, 提出一种基于一维卷积神经网络的缺陷识别模型, 相对于结合普通的机器学习模型, 该模型有以下的优点: (1) 采用多个卷积层, 能够更好地学习到训练




图 2 缺陷识别流程图

Fig. 2 Flow chart of defect identification




图 3 深度学习网络结构图

Fig. 3 Deep learning network structure chart

表 1 搭建的卷积神经网络模型参数

Table 1 Parameters of convolution neural network model	
Parameter	Value
input layer size	$2000 \times 3000 \times 1$
convolution layer number	3
convolution kernel size	5×1
number of pooling layers	3
pooled core size	3×1
number of fully connected layers	2
optimizer	RMSprop
optimizer learning rate	0.000 1
number of batches	18
maximum number of iterations	24

数据的深层特征, 有利于提高模型的泛化能力. (2) 采用最大池化, 降低训练的计算量, 提高收敛速度. (3) 采用 dropout, 以一定的概率, 随机将某些神经元进行失效处理, 降低网络过拟合的风险, 能够提高整个网络的鲁棒性. (4) 模型采用的一维卷积神经网络可以直接接受原始信号的输入, 不需要对原始数据进行过多的前处理. 基于 Python 语言自主研制了相应的程序, 具体的深度学习网络结构如图 3 所示. 先通过 3 对卷积层和池化层学习输入数据的深层特征, 然后通过一个拉直层, 将数据转化为一维矩阵, 最后通过两个全连接层得到输出.

搭建的卷积神经网络模型结构参数如表 1 所示, 网络的结构对计算结果具有一定影响, 同时神经网络的一些相关超参数也会影响到计算结果, 这里的结构参数是通过模型的相关参数进行研究并考察验证集和测试集的准确率得出的优化组合.

虽然设定最大迭代次数为 24, 但模型引入了 early-stopping 机制, 当模型的损失函数在一定步数内不再显著变化时即停止模型训练, 用于防止深度学习的过拟合现象.

3 数值算例

3.1 单裂纹的反演

在本算例中, 待研究的对象为二维均质薄板, 板长 $L = 180 \text{ mm}$, 板厚 $H = 2 \text{ mm}$, 其几何尺寸如图 4(a) 所示. 板的边界为自由边界, 板的材料参数: 弹性模量 $E = 200 \text{ GPa}$, 泊松比 $\nu = 0.3$, 质量密度 $\rho = 7850$




图 4 单缺陷板几何尺寸及 SBFEM 边界离散

Fig. 4 Geometric dimension of single cracked plate and boundary discretization of SBFEM

kg/m^3 . 板的上表面处存在一单向开口裂纹, 裂纹的位置和大小通过 3 个参数确定, 即: 裂纹尖端坐标 x_c 、裂纹的半开裂角 α 、裂纹垂直向深度 d . 在板的最左端施加均匀分布的对称荷载 $F(t)$ 激发 Lamb 波, $F(t)$ 的表达式为

$$F(t) = \sin(2\pi ft) e^{-\frac{(t-\mu)^2}{2\sigma^2}} \quad (\text{GPa}) \quad (12)$$

式中, $\mu = 6 \mu\text{s}$, $\sigma = 2 \mu\text{s}$, $f = 0.6 \text{ MHz}$. 固定的信号观测点 P 设置在板的下表面距离左边界 $x_p = 90 \text{ mm}$ 处, 观测点的位置对反演结果影响较小, 因此, 对于实际问题可根据现场实际情况、传感器布置的方便性等影响因素选取合适的观测点.

数值计算时, 采用 Gauss-Lobatto-Legendre 积分的高阶单元, 板边界被离散成 889 个结点, 25 个子域, 8984 个自由度, 部分离散单元如图 4(b) 所示. 连分式展开阶数取 5, 数值计算的总时间 t 为 $90 \mu\text{s}$, 每个时间步 Δt 为 $0.03 \mu\text{s}$.

建立缺陷预测模型时, 将观测点 P 的动位移作为神经网络的输入, 对应的缺陷参数 (x_c, α, d) 作为输出. 训练过程中, 暂用 2000 组数据作为深度学习模型的训练集, 从训练集中随机划分 10% 的数据对作为神经网络的验证集, 根据验证集准确率确定网络模型参数后使用 10 组待反演数据作为测试集. 2000 组训练数据的生成过程包括: (1) 在待检测薄板域内

随机生成 2000 组缺陷信息, 即参数 (x_c, α, d) , 本算例中 $x_c \in (0 \text{ mm}, 180 \text{ mm})$, $d \in (0 \text{ mm}, 1 \text{ mm})$, $\alpha \in (0^\circ, 5^\circ)$; (2) 对于每组缺陷参数, 在板的最左端施加式 (12) 给出的均匀分布的对称荷载 $F(t)$ 激发 Lamb 波, 采用 SBFEM 计算观测点 x_p 的竖向动位移响应 $y(t)$. 每组缺陷参数与观测点的动位移响应 $y(t)$ 构成一组训练数据.

训练结束后, 将实测的观测点处的动位移响应 $y(t)$ 作为网络模型的输入, 本算例中的实测响应通过 SBFEM 数值计算获取 (图 5), 在深度学习模型中进行一次正向传播, 得出相应的缺陷参数的预测值, 该预测值就是薄板内未知缺陷的反演值. 值得指出的是文中用于预测的缺陷信息都没有用于训练过程. 图 6 给出了网络的精度和损失函数随训练过程的变化曲线, 从图中可以看出, 训练集和验证集经过约 10 代训练后, 网络模型的精度基本趋于稳定, 且经过若干代训练以后, 训练集和验证集的损失函数亦迅速下降.





图 5 实测的观测点动位移响应


Fig. 5 Measured dynamic displacement responses of observation point

在实际的反演过程中, 由于神经网络初始化的随机性, 比如 dropout 层的随机性等, 以及 GPU 计算产生的随机性, 会导致每次反演的结果不同, 为了解决随机性对反演结果的影响, 反演过程将独立运行 1000 次, 然后运用统计学方法来获得缺陷的反演值, 测试集中 10 组数据的反演结果如图 7 所示, 其中某一次反演结果直方图及正态分布拟合曲线如图 8 所示, 横坐标表示的是参数的反演值, 纵坐标表示 1000 次反演结果在一定范围内的次数, 同时对这 1000 次反演的结果进行正态分布拟合, 并绘制正态分布拟合曲线, 图 8 中的实线就是正态分布拟合曲线, 以正态分布拟合曲线的期望值 μ 作为反演的结果, 该次缺陷参数的最终反演结果如表 2 所示.

为探究模型对裂纹尺度的反演能力, 尤其是对



(a) 训练集和验证集精度
(a) Accuracy of training and validation sets




(b) 训练集和验证集损失函数
(b) Loss function of training and validation sets

图 6 网络的精度和损失函数随训练过程变化曲线


Fig. 6 Accuracy and loss function varies as epoch increases

浅表裂纹的反演能力, 将待反演的裂纹深度比 $\delta = d/H$ 设置为: 0.01, 0.02, 0.03, 0.04, 0.05, 0.1, 0.2, 0.3, 0.4 和 0.5 共 10 个不同水平. 待反演裂纹位置仍为距离板左端 90 mm 处, 裂纹半开裂角为 2.5° . 不同深度反演裂纹的结果如图 9 所示, 从图中可看出, 反演深度比 $\delta < 0.05$ 时, 裂纹位置的反演精度会降低, 而裂纹的半开裂角和裂纹的深度反演精度仍较好. 由此可见, 裂纹的位置信息对模型反演精度的影响较大, 建议的模型对反演深度比 $\delta > 0.05$ 的裂纹具有较好的反演精度. 深度比 $\delta < 0.05$ 时, Lamb 波透过裂纹时发生的变化较小, 导致观测点测得的响应与健康板的响应相差不大, 因而会影响模型的反演结果.


在深度学习反演模型中, 虽然对样本的要求是尽可能大, 但是过大的样本数量会提高计算成本, 同时会降低反演的效率. 为了探究不同数量的样本对反演能力的影响, 将反演样本数量设置为 1000,



(a) 裂纹尖端坐标
(a) Crack tip coordinates



(b) 裂纹半开裂角
(b) Half crack angle



(c) 裂纹深度
(c) Crack depth

图 7 测试集反演结果图

Fig. 7 Inversion results of test sets

1250, 1500 和 2000 共 4 个不同水平. 不同样本数量下的缺陷反演结果如图 10 所示, 从图 10 中可以看出, 样本的数量对反演精度有较大影响, 样本数量过少时, 网络出现过拟合的情况, 反演结果与真实值相差较大, 而当样本数量达到 1500 时模型能够很好地反演出缺陷.




图 8 单裂纹 1000 次反演结果正态分布拟合图

Fig. 8 Fitting diagram of normal distribution of 1000 inversion results of single crack

表 2 单开口裂纹的反演结果和误差

Table 2 Inversion results and errors of single crack			
Identified parameters	True results	Identified results	Error /%
x_c/mm	90	90.021	0.023
$\alpha/(^{\circ})$	2.5	2.495	0.200
d/mm	1	0.961	3.900






图 9 不同深度裂纹的反演结果


Fig. 9 Inversion results of cracks with different depths



(a) 裂纹尖端坐标
(a) Crack tip coordinates



(b) 裂纹半开裂角
(b) Half crack angle



(c) 裂纹深度
(c) Crack depth

图 10 不同样本数量的缺陷反演结果

Fig. 10 Inversion results with different training samples

3.2 多裂纹的反演

为了研究模型反演多裂纹时的适用性, 研究板中存在两个开口裂纹情况下的反演效果. 本算例中, 板的尺寸、裂纹的参数范围、边界条件、材料参数以及荷载条件均与 3.1 节相同, 为了使 Lamb 波充分地反演在裂纹边界上反射, 观测点 P 处能够捕获反射信号, 数值计算的总时间 t 为 $90 \mu\text{s}$, 每个时间步 Δt 为 $0.03 \mu\text{s}$. 含两个裂纹板的示意图如图 11 所示, 两裂纹





图 11 多裂纹板示意图

Fig. 11 Schematic diagram of multi crack plate

的反演参数为: 第一个裂纹尖端坐标 x_{c1} 、裂纹的半开裂角 α_1 、裂纹垂向深度 d_1 ; 第二个裂纹尖端坐标 x_{c2} 、裂纹的半开裂角 α_2 、裂纹垂向深度 d_2 . 观测点 P 设置在板的下表面 $x_p = 90 \text{ mm}$ 处.

在本算例中, 暂使用 2000 组训练数据, 这些数据是由 SBFEM 计算 2000 个缺陷板得到的动力响应, 2000 个缺陷板的缺陷信息及其对应的观测点动力响应作为深度学习神经网络模型的训练集数据, 验证集从训练集中随机分配 10%, 根据验证集准确率确定网络模型参数后使用 10 组待反演数据作为测试集. 训练结束后, 用待反演板的动力响应作为输入, 在深度学习模型中进行一次正向传播, 得出相应的预测值, 该预测值就是未知缺陷薄板的反演值. 同样地, 使用统计学方法来获得缺陷的反演值, 测试集反演结果如图 12 所示, 最终反演结果如表 3 所示.

此外, 为探究不同的样本数对多裂纹反演结果的影响, 研究了样本数分别为 1000, 1250, 1500 和 2000 共 4 个不同水平时反演的结果, 如表 4 所示. 从



(a) 裂纹尖端坐标
(a) Crack tip coordinates

图 12 多裂纹测试集反演结果图

Fig. 12 Inversion results of multi crack on test sets




图 12 多裂纹测试集反演结果图 (续)

Fig. 12 Inversion results of multi crack on test sets (continued)

表中可以看出, 与单缺陷相同, 样本的数量对反演精度有较大影响, 本节建立的多裂纹反演的模型, 在样本数量大于 1500 时, 能够保证一定的反演精度, 将多裂纹的相关参数准确地反演出来.

表 4 不同样本数量时多裂纹反演结果

Table 4 Inversion results and errors of multi cracks with different training samples

Identified parameters		True results	Number of training samples							
			1000	Error /%	1250	Error /%	1500	Error /%	2000	Error /%
crack 1	x_{c1}/mm	61.200	59.899	2.126	61.479	0.456	61.287	0.142	61.277	0.126
	$\alpha_1/(\circ)$	2.500	2.529	1.160	2.504	0.160	2.504	0.160	2.501	0.040
	d_1/mm	1.000	0.917	8.300	0.920	8.000	0.984	1.600	0.995	0.500
crack 2	x_{c2}/mm	133.200	132.243	0.718	131.777	1.068	133.358	0.119	133.137	0.047
	$\alpha_2/(\circ)$	2.000	2.533	26.650	2.518	25.900	2.055	2.750	2.063	3.150
	d_2/mm	0.800	0.733	8.375	0.724	9.500	0.824	3.000	0.780	2.500

表 3 多裂纹的反演结果和误差

Table 3 Inversion results and errors of multi cracks

Identified parameters		True results	Identified results	Error /%
crack 1	x_{c1}/mm	61.200	61.277	0.126
	$\alpha_1/(\circ)$	2.500	2.501	0.040
	d_1/mm	1.000	0.995	0.500
crack 2	x_{c2}/mm	133.200	133.137	0.047
	$\alpha_2/(\circ)$	2.000	2.063	3.150
	d_2/mm	0.800	0.788	2.500

4 模型鲁棒性分析

在实际的问题中, 由于传感器的精度、实验环境等问题, 可能会导致测量的结果混入噪声. 为了分析噪声的干扰对缺陷反演结果的影响, 在待反演信号中混入不同程度的噪声, 来验证文中提出的反演模型的鲁棒性. 本算例与 3.2 相同, 不同的是在观测点 P 测得的动力响应真实值的基础上, 加入一定水平的高斯白噪声, 来模拟含有噪声的数据. 含有噪声的动力响应计算公式如下所示

$$\boldsymbol{X}^m = \boldsymbol{X}^{\text{clean}} + \omega \cdot \boldsymbol{RMS}_X \cdot \boldsymbol{p} \tag{13}$$

式中, $\boldsymbol{X}^{\text{clean}}$ 表示通过 SBFEM 计算的含有缺陷板的真实位移, ω 为高斯白噪声变量, $\boldsymbol{RMS}_X$ 为真实位移的均方根, $\boldsymbol{p}$ 为噪声水平.

考虑到在实际工程中, 如果测得的动响应中存在较大的噪声干扰, 会进行去噪处理, 所以在本节的鲁棒性分析中, 最大的噪声水平为 10%. 其他参数与 3.2 节中相同, 同样运行 1000 次, 反演结果如

表 5 和表 6. 在待反演信号中添加不同程度的噪声, 模型能够反演出缺陷. 但随着噪声水平的增长, 缺陷识别的精度会有所下降.

表 5 引入 5% 噪声的反演结果
Table 5 Inversion results with 5% noise

Identified parameters		True results	Identified results	Error/%
crack 1	x_{c1}/mm	61.200	61.813	1.002
	$\alpha_1/(^{\circ})$	2.500	2.453	1.880
	d_1/mm	1.000	0.972	2.800
crack 2	x_{c2}/mm	133.200	132.881	0.239
	$\alpha_2/(^{\circ})$	2.000	2.160	8.000
	d_2/mm	0.800	0.780	2.500

表 6 引入 10% 噪声的反演结果
Table 6 Inversion results with 10% noise

Identified parameters	True results	Identified results	Error/%	
crack 1	x_{c1}/mm	61.200	61.992	1.294
	$\alpha_1/(^{\circ})$	2.500	2.597	3.880
	d_1/mm	1.000	0.925	7.500
crack 2	x_{c2}/mm	133.200	132.424	0.583
	$\alpha_2/(^{\circ})$	2.000	2.407	20.350
	d_2/mm	0.800	0.718	10.250

5 结论

结合 SBFEM 和深度学习建立了结构内裂纹状缺陷的反演模型, 可以定量识别结构内多裂纹的位置和尺度. SBFEM 仅需对结构边界进行离散, 通过设置比例中心的位置位于裂纹尖端可最小化网格重剖分, 模拟波动问题时计算效率极高, 可以快速地为深度学习模型提供足够多的训练数据. 深度学习模型能够学习到样本的深层特征, 大大提高了反演精度. Lamb 波在含缺陷薄板中传播时, 缺陷的存在对波传播信号有明显影响, 仅采用一个观测点的动位移响应便能得到较好的反演结果, 相比于传统的无损检测方法为加快目标函数的最小化迭代过程需要布置较多的传感器, 文中建议的基于 SBFEM 和深度学习的反演模型避免了传统反分析问题的目标函数最小化迭代过程, 同一结构模型的训练数据可存储为数据库供多次反复使用. 对含单裂纹和多裂纹板的数值算例进行分析, 结果表明, 建立的缺陷识别模型能够准确地量化结构内部的缺陷, 对浅表裂纹亦有很好的识别效果, 且对于含噪信号模型仍具有

较好的鲁棒性.

当前的研究在进行多裂纹反演时是在预先已知裂纹数量的情况下, 在后续的研究中将进一步拓展建议的模型用于未知裂纹数量情况下的缺陷反演. 此外, 后续的研究也将设计相关试验, 进一步验证反演模型.

参 考 文 献

1 吴中如, 顾冲时. 重大水工混凝土结构病害检测与健康诊断. 北京: 高等教育出版社, 2005 (Wu Zhongru, Gu Chongshi. Disease Detection and Health Diagnosis of Large Hydraulic Concrete Structures. Beijing: Higher Education Press, 2005)

2 Rabinovich D, Givoli D, Vigdergauz S. Crack identification by “arrival time” using XFEM and a genetic algorithm. *International Journal for Numerical Methods in Engineering*, 2009, 77: 337-359

3 Waisman H, Chatzi E, Smyth AW. Detection and quantification of flaws in structures by the extended finite element method and genetic algorithms. *International Journal for Numerical Methods in Engineering*, 2010, 82: 303-328

4 Chatzi EN, Hiriyyur B, Waisman H, et al. Experimental application and enhancement of the XFEM-GA algorithm for the detection of flaws in structures. *Computers & Structures*, 2011, 89: 556-570

5 Nanthakumar SS, Lahmer T, Rabczuk T. Detection of flaws in piezoelectric structures using extended FEM. *International Journal for Numerical Methods in Engineering*, 2013, 96: 373-389

6 江守燕, 杜成斌. 基于扩展有限元的结构内部缺陷 (夹杂) 的反演分析模型. *力学学报*, 2015, 47(6): 1037-1045 (Jiang Shouyan, Du Chengbin. Numerical model for identification of internal defect or inclusion based on extended finite element methods. *Chinese Journal of Theoretical and Applied Mechanics*, 2015, 47(6): 1037-1045 (in Chinese))

7 Sun H, Waisman H, Betti R. Nondestructive identification of multiple flaws in structures using XFEM and a topologically adapting enhanced ABC algorithm. *International Journal for Numerical Methods in Engineering*, 2013, 95: 871-900

8 Sun H, Waisman H, Betti R. A multiscale flaw detection algorithm based on XFEM. *International Journal for Numerical Methods in Engineering*, 2014, 100: 477-503

9 Yan G, Sun H, Waisman H. A guided Bayesian inference approach for detection of multiple flaws in structures using the extended finite element method. *Computers & Structures*, 2015, 152: 27-44

10 王佳萍, 杜成斌, 江守燕. 扩展有限元与遗传算法相结合的结构缺陷反演分析. *力学与实践*, 2017, 39(6): 591-596 (Wang Jiaping, Du Chengbin, Jiang Shouyan. The inverse analysis of internal defects (inclusions) in structures using a combined XFEM and GA method. *Mechanics in Engineering*, 2017, 39(6): 591-596 (in Chinese))

11 王佳萍, 杜成斌, 王翔等. 基于 XFEM 和改进人工蜂群算法的结构内部缺陷反演. *工程力学*, 2019, 36(9): 34-40 (Wang Jiaping, Du Chengbin, Wang Xiang, et al. Inverse analysis of internal defects in structures using extended finite element method and improved artificial bee colony algorithm. *Engineering Mechanics*, 2019, 36(9): 34-40 (in Chinese))

12 Zhao W, Du C, Jiang S. An adaptive multiscale approach for identifying multiple flaws based on XFEM and a discrete artificial fish swarm algorithm. *Computer Methods in Applied Mechanics and Engineering*, 2018, 339: 341-357

- 13 Ma C, Yu T, Lich VL, et al. An effective computational approach based on XFEM and a novel three-step detection algorithm for multiple complex flaw clusters. *Computers & Structures*, 2017, 193: 207-225
- 14 Zhang C, Nanthakumar SS, Lahmer T, et al. Multiple cracks identification for piezoelectric structures. *International Journal of Fracture*, 2017, 206: 151-169
- 15 Zhang C, Wang C, Lahmer T, et al. A dynamic XFEM formulation for crack identification. *International Journal of Mechanics and Materials in Design*, 2016, 12: 427-448
- 16 Sun H, Waisman H, Betti R. A sweeping window method for detection of flaws using an explicit dynamic XFEM and absorbing boundary layers. *International Journal for Numerical Methods in Engineering*, 2016, 105: 1014-1040
- 17 江守燕, 赵林鑫, 杜成斌. 基于频率和模态保证准则的结构内部多缺陷反演. *力学学报*, 2019, 51(4): 1091-1100 (Jiang Shouyan, Zhao Linxin, Du Chengbin. Identification of multiple flaws in structures based on frequency and modal assurance criteria. *Chinese Journal of Theoretical and Applied Mechanics*, 2019, 51(4): 1091-1100 (in Chinese))
- 18 Du C, Zhao W, Jiang S, et al. Dynamic XFEM-based detection of multiple flaws using an improved artificial bee colony algorithm. *Computer Methods in Applied Mechanics and Engineering*, 2020, 365: 112995
- 19 Ma C, Yu T, Lich LV, et al. Detection of multiple complicated flaw clusters by dynamic variable-node XFEM with a three-step detection algorithm. *European Journal of Mechanics - A/Solids*, 2020, 82: 103980
- 20 Yu T, Bui TQ. Numerical simulation of 2-D weak and strong discontinuities by a novel approach based on XFEM with local mesh refinement. *Computers & Structures*, 2018, 196: 112-133
- 21 Li X, Liu Z, Cui S, et al. Predicting the effective mechanical property of heterogeneous materials by image based modeling and deep learning. *Computer Methods in Applied Mechanics and Engineering*, 2019, 347: 735-753
- 22 Li X, Ning S, Liu Z, et al. Designing phononic crystal with anticipated band gap through a deep learning based data-driven method. *Computer Methods in Applied Mechanics and Engineering*, 2020, 361: 112737
- 23 何存富, 孙雅欣, 吴斌等. 超声导波技术在埋地锚杆检测中的应用研究. *岩土工程学报*, 2006, 28(9): 1144-1147 (He Cunfu, Sun Yaxin, Wu Bin, et al. Application of ultrasonic guided waves technology to inspection of bolt embedded in soils. *Chinese Journal of Geotechnical Engineering*, 2006, 28(9): 1144-1147 (in Chinese))
- 24 徐镇凯, 袁志军, 胡济群. 建筑结构检测与加固方法. *工程力学*, 2006, 23(SII): 117-130 (Xu Zhenkai, Yuan Zhijun, Hu Jiqun. The inspection and strengthening methods on building structures. *Engineering Mechanics*, 2006, 23(SII): 117-130 (in Chinese))
- 25 刘宏业, 刘申, 吕炎等. 纤维增强复合板中声弹 Lamb 波的波结构分析. *工程力学*, 2020, 37(8): 221-229 (Liu Hongye, Liu Shen, Lv Yan. Wave structure analysis of acoustoelastic Lamb waves in fiber reinforced composite lamina. *Engineering Mechanics*, 2020, 37(8): 221-229 (in Chinese))
- 26 Gravenkamp H, Birk C, Song C. Simulation of elastic guided waves interacting with defects in arbitrarily long structures using the Scaled Boundary Finite Element Method. *Journal of Computational Physics*, 2015, 295: 438-455
- 27 张维峰, 冯华. 结构裂纹故障振动检测的小波分析. *力学与实践*, 2010, 32(1): 20-23 (Zhang Weifeng, Feng Hua. The wavelet analysis of vibration detection for structure's crack fault. *Mechanics in Engineering*, 2010, 32(1): 20-23 (in Chinese))
- 28 吴斌, 齐文博, 何存富等. 基于神经网络的超声导波钢杆缺陷识别. *工程力学*, 2013, 30(2): 470-476 (Wu Bin, Qi Wenbo, He Cunfu, et al. Recognition of defects o steel rod using ultrasonic guided waves based on neural network. *Engineering Mechanics*, 2013, 30(2): 470-476 (in Chinese))
- 29 Song C. The Scaled Boundary Finite Element Method: Introduction to Theory and Implementation. John Wiley & Sons. Ltd, 2018
- 30 Song C, Wolf JP. The scaled boundary finite-element method—alias consistent infinitesimal finite-element cell method—for elastodynamics. *Computer Methods in Applied Mechanics and Engineering*, 1997, 147: 329-355
- 31 陈灯红, 杜成斌. 基于 SBFE 和改进连分式的有限域动力分析. *力学学报*, 2013, 45(2): 297-301 (Chen Denghong, Du Chengbin. Dynamic analysis of bounded domains by SBFE and the improved continuedfraction expansion. *Chinese Journal of Theoretical and Applied Mechanics*, 2013, 45(2): 297-301 (in Chinese))
- 32 Bengio Y, Courville A, Vincent P. Representation learning: A review and new perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(8): 1798-1828
- 33 Goodfellow I, Bengio Y, Courville A. Deep Learning. Cambridge: MIT Press, 2016
- 34 LeCun Y, Bengio Y, Hinton G. Deep Learning. *Nature*, 2015, 521(7553): 436-444
- 35 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述. *计算机学报*, 2017, 40(6): 1229-1251 (Zhou Feiyan, Jin Linpeng, Dong Jun. Review of convolutional neural network. *Chinese Journal of Computers*, 2017, 40(6): 1229-1251 (in Chinese))