

文章编号:1001-4888(2022)03-0305-10

一种基于 Lamb 波的智能结构损伤识别方法^{*}

骆英,毛雨欣

(江苏大学 土木工程与力学学院 国家级高端装备关键结构健康管理国际联合研究中心, 江苏镇江 212013)

摘要: 基于超声 Lamb 波的常规损伤检测方法依赖于精确的结构物理模型、烦琐的信号处理技术以及受限于不同的成像算法, 致使损伤成像的精度和效率难以兼顾。针对高端装备关键结构快速、精准的智能化损伤检测需求, 本文构建以压电片激励、激光多普勒测振仪拾振的检测平台以研究卷积神经网络自动提取 Lamb 波含损伤特征信息的方法。对结构内损伤待检测区域进行合理分区, 将对损伤的检测转化为基于卷积神经网络的图像分类任务。依据损伤所在位置、大小的变化建立数据库, 并使用数据增强技术扩大数据库; 构建基于卷积神经网络的智能结构损伤识别模型用以建立结构损伤区域与 Lamb 波信号特征的映射关系, 进而实现对板结构损伤的快速智能识别。实验验证结果表明: 将卷积神经网络运用于基于 Lamb 波的损伤识别方法中, 在实现快速、智能化的损伤检测方面有潜在的工程应用前景。

关键词: Lamb 波; 卷积神经网络模型; 数据增强技术; 结构损伤识别; 智能检测

中图分类号: TU317⁺.8; O347.4⁺¹ **文献标识码:** A **DOI:** 10.7520/1001-4888-21-134

0 引言

大型装备在长期服役过程中, 受内外因素如设计与制造、服役环境、载荷变化等影响, 其结构内会萌生各类损伤进而逐渐老化, 影响结构的承载能力, 最终造成重大经济损失和人员伤亡等灾难性后果^[1,2]。基于 Lamb 波的结构损伤检测方法具有传播距离远、检测范围大、成本低等优势, 是目前在板状、管道等结构无损检测和健康监测方面应用较为广泛的一种方法^[3,4]。常规的超声 Lamb 波检测方法依赖于精准的结构物理模型、复杂的信号处理技术, 更需要针对结构的复杂性和损伤类型研究相应的成像算法, 不能兼顾损伤成像精度与效率, 难以适应对高端装备日趋复杂结构及其各类损伤的快速精确评估、实时在线检测的需求, 因此, 在人工智能与大数据快速发展的时代背景下, 急需探索基于 Lamb 波损伤诊断理论的新智能检测方法, 使其具有自动提取 Lamb 波信号中与结构损伤相关的特征信息的能力, 进而达成对结构损伤实施即测即出结果的快速、智能识别与诊断。

学者们将机器学习引入无损检测中以实现对结构损伤的智能化识别。Zhang 等^[5]利用特征工程选取结构内敏感特征, 采用支持向量机作为学习模型对不同损伤状态进行分类。董珍一等^[6]利用特征工程优选峰值等时域特征信息作为 BP 神经网络输入, 用以预测表层裂纹深度。张传栋等^[7]筛选出变异系数较小的磁参量作为 BP 神经网络模型的输入, 采用最佳优化模型对钢轴表面硬度进行预测, 实现了钢轴表面硬度的无损检测。基于机器学习的方法能够根据损伤类别的特征进行快速的损伤识别, 但针对所输入的不同特征信息, 需要在特征工程中由人工进行选择, 从而增加了数据预处理时间和人为干扰

* 收稿日期: 2021-05-30; 修回日期: 2021-06-07

基金项目: 国家自然科学重点国际合作项目(No. 11520101001)

通信作者: 骆英(1960—), 男, 博士, 教授。主要从事新型无损检测技术及传感器机理研究方面的工作。Email: luoying@mail. ujs. edu. cn

因素,没有实现完全的智能化。

深度学习方法具有融合大量数据、自动提取与分类相关高层特征的能力,为基于 Lamb 波结构损伤识别方法在工程中的应用提供了潜在的新途径^[8]。Melville 等^[9]训练和测试了针对不同材料特性和结构厚度的神经网络,用于检测结构中是否存在损伤。Liu 等^[10]研究了一种基于深度学习模型的缺口型裂纹损伤评估方法,将缺口型损伤检测结果与分类相关联,其中每个类别代表被检测板结构缺口损伤的发生位置,但该方法仅能够识别激励/接收传感器所在直线上的损伤位置。Ewald 等^[11]利用小波变换对信号进行预处理获得小波系数矩阵,然后将其输入卷积神经网络(Convoluted Neural Network, CNN)进行训练,得到关于损伤裂纹在不同长度和不同角度下的分类结果。Xu 等^[12]设计并训练卷积神经网络从多个损伤指标中提取高层次特征,实现了基于多个特征融合的裂纹长度评估。综上所述,基于人工智能的损伤诊断方法在结构损伤检测领域显示出巨大潜力。

本文基于 Lamb 波和卷积神经网络构建智能结构损伤识别平台;合理规划板结构内的检测区域,将位置识别转化为区域识别;设置并利用十字型传感阵列的对称性获得整个区域的损伤位置识别,减少采集数据并获得更小区域的定位;构建基于卷积神经网络的智能结构损伤识别模型,建立结构损伤区域与 Lamb 波信号特征的映射关系,进而实现对板结构损伤的快速智能识别。相关成果可对工程实际中实现速度快、智能化的损伤诊断提供参考。

1 智能结构损伤识别系统的构建

本文搭建智能结构损伤识别平台,采用模拟与实验相结合的方式构建含结构损伤信息的导波数据库,再经预处理将导波数据转化为图像作为输入,设计、训练基于卷积神经网络的智能结构损伤识别模型,建立损伤区域与 Lamb 波信号特征的映射关系,完善模型并基于实际损伤对其进行验证与评估。图 1 为所构建的智能结构损伤识别系统结构框图。

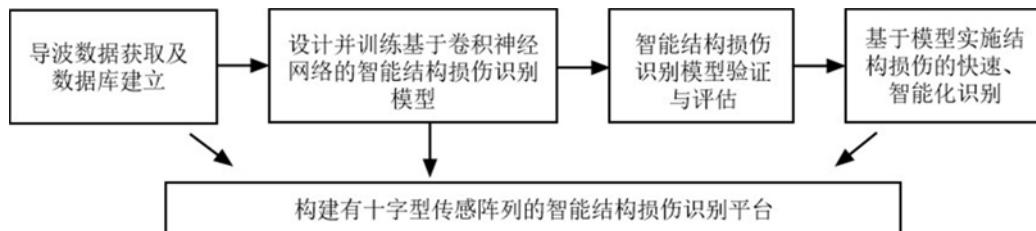


图 1 智能结构损伤识别系统框图

Fig. 1 Diagram of intelligent identification system for structural damage

2 智能结构损伤识别实验平台的搭建

为验证本文所提出的智能损伤识别方法的有效性,所构建的实验平台采用压电换能器(PZT)激励元件激励 Lamb 波,采用 PSV-500 扫描式激光多普勒扫描测振仪(SLDV)拾取(采集)含损伤信息的 Lamb 波 A0 模态信号(离面位移)。其中 PZT 激励、SLDV 拾振的检测平台的优势为:PZT 激励便于控制激励信号的频率和波形,而 SLDV 的非接触传感优势避免了 PZT 传感所带来的改变结构局部刚度和空间分辨率受限的问题。激励信号由信号发生器产生,经过功率放大器放大后加载于 PZT 晶片,对结构实施激励,同时激励信号作为参考触发信号连接 SLDV 系统实施同步扫描传感。

选取 200mm×200mm×1mm 正方形铝板为研究对象,其密度为 2700kg/m³,泊松比为 0.33,杨氏模量为 70GPa。围绕板中心 100mm×100mm 的区域预设图 2 所示十字型传感扫描阵列(水平方向采集点从左至右编号为 1~10,竖直方向由上至下编号为 11~20),将板结构划分为 4 个象限,其中第一象限划分 25 个 10mm×10mm 的损伤可能发生区域。

3 导波数据获取及数据库建立

应用 ABAQUS 软件模拟板结构在激励波作用下所形成的 Lamb 波与板结构内损伤相互作用的传

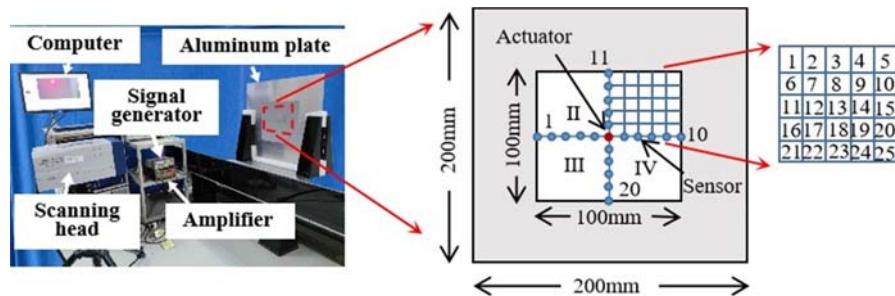


图2 智能结构损伤识别系统的数据拾取平台以及传感阵列和损伤区域布局

Fig. 2 Data picking platform of intelligent structural damage identification system
and sensor array and damage area layout

播过程,并提取在传感阵列处所获得的与损伤相关的超声导波信号作为模拟数据;借助图2中智能结构损伤识别系统的数据拾取平台获取包含损伤信息的实验数据。鉴于结构的对称性,仅采集图2中第一象限的数据训练模型便可覆盖对其他3个象限的损伤识别。导波数据库构建流程如图3所示。



图3 导波数据库构建流程图

Fig. 3 Flow chart of guided wave database construction

3.1 模拟损伤数据的获取

选取直径分别为4mm、5mm、6mm、7mm、8mm的圆形损伤,以及轴向长度为8mm的方形、矩形、椭圆形损伤,置于图4所示损伤在区域中的方位,模拟形成相关损伤数据集。当被测定损伤小于所划分损伤区域时,将被测定损伤放置于该区域内不同位置可获得更多与位置信息相关的损伤数据。由此,针对每一个损伤区域,共可模拟获得18个损伤数据样本,按照对板结构预划分出的25个损伤区域,共可获得 $18 \times 25 = 450$ 个样本。诸样本均被纳入构建损伤区域与Lamb波中损伤位置、大小等特征之间的映射关系数据库。

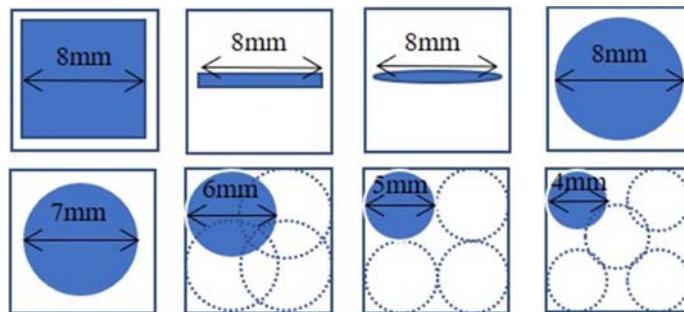


图4 损伤在待测区域中方位

Fig. 4 Location of damage in the area to be detected

Lamb波激励频率的选择、工程实际伴生的随机噪声等均影响损伤识别系统对损伤辨识的敏感度。考虑到每一次数据采集仅产生一组(20个传感点)信号数据,为满足卷积神经网络将损伤识别转化为图像特征提取与分类任务的需求,提高智能结构损伤识别模型对结构损伤的识别能力,采用如下的数据增强技术扩大数据库:分别选择中心频率为150kHz、200kHz、250kHz的激励波,并分别伴生有信噪比为35dB、30dB、25dB、20dB、15dB的高斯白噪声,综合作用后共可获得 $450 \times 3 \times 5 = 6750$ 个模拟数据样本。诸样本均被纳入构建损伤区域与含损伤位置、大小等特征量之间的映射关系数据库,以供训练智能结构损伤识别模型。

3.2 实验测试数据的获取与融合数据库的构建

分别将直径为4mm、5mm、6mm、8mm、10mm的磁石贴附于智能结构损伤识别实验平台的被测板上模拟结构真实损伤,拾取相关的实验损伤数据样本;每个损伤区域获得15个实验数据样本,第一象限共获 $15 \times 25 = 375$ 个实验数据样本,添加3个中心频率激励波伴生5个层次的高斯白噪声,共得 $375 \times 3 \times 5 = 5625$ 个实验数据样本。

综上,分别抽取一定比例的模拟数据集中的样本和实验数据集中的样本进行融合,得到融合数据库(为了保证能抽取到每个区域的样本,对模拟数据集和实验数据集进行样本抽取时,需要依次对每个区域的样本进行抽取)。网络训练过程中通过查看误差曲线趋势,不断增加样本抽取比例,最终当样本抽取比例为2/3时,误差曲线稳定于接近0的值,准确率曲线稳定于接近1的值。本文的融合数据库共有 $(6750 + 5625) \times 2/3 = 8250$ 个样本,以8:1:1的比例划分为训练集、验证集和测试集。

3.3 数据预处理

外部环境不变时,板结构中的损伤信号与其基线信号的唯一区别源于损伤反射波以及边界反射波的改变,为此将含损伤信息的信号与无损伤基线信号作差以提取损伤特征信号。

以第一象限15号区域为例,当板结构受中心频率为200kHz的波激励时,经由14号采集点拾取的损伤反射信号与基线信号作差(图5(a))后更有利于对损伤的识别。将所有采集点作差信号顺序排列成矩阵并进行可视化处理,得到如图5(b)所示的作差信号图(从左往右为1~20采集点,自上而下为时间序列),矩形框中为作差处理后所呈现的损伤反射波,其在时域所展现的分布趋势反映了传感点相对于损伤的位置关系。本文中信号在时域的采集长度为0.15ms,该采集长度的选取充分考虑了不同激励频率下导波所具有的不同传播速度,并保证能够采集到损伤散射信号的完整波形。同理可得板结构分别受中心频率150kHz、250kHz波激励下的相关作差信号图。最终,数据预处理得到的整张作差信号图即为模型的输入。

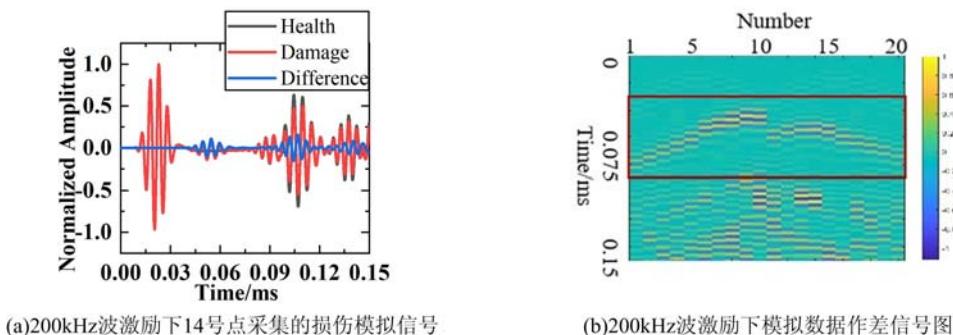


图5 各中心激励频率波作用下15号区域的损伤模拟信号图

Fig. 5 Diagram of analog signal of damage in the 15th region under the excitation of each center frequency wave

4 智能结构损伤识别模型的构建与网络训练

通过模拟与实验结合的方式建立用于模型训练的数据库后,需设计、训练卷积神经网络模型用以建立结构损伤位置、损伤大小与Lamb波信号特征的映射关系。

充分考虑两层卷积后连接一层池化的架构模式能够很好地控制用于网络输入的Lamb波数据图片的尺寸,可以在后续卷积和池化的工作过程中抓取更多维度的损伤信息特征,并避免关键信息的丢失情况。本文设计了如图6所示的多个卷积+池化的卷积神经网络模型。

如图6所示的卷积神经网络由输入层、卷积层、池化层、全连接层及输出层构成。卷积层的功能是用于特征提取,假设卷积神经网络输入图像后,第*i*层卷积神经网络的特征图为 K_i 。卷积运算可以表示为

$$K_i = f(K_{i-1} * \omega_i + b_i) \quad (1)$$

式中: ω_i 为第*i*层卷积核的权重向量; b_i 为第*i*层卷积核的偏置向量; f 为激励函数; $*$ 为卷积运算。

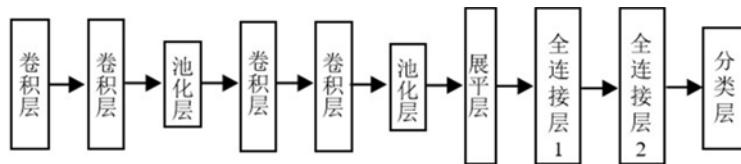


图 6 用于板结构损伤检测的卷积神经网络基本模型

Fig. 6 Basic model of convolution neural network for damage detection of plate structure

池化层连接于卷积层之后,用来对卷积层提取的特征图进行二次特征提取,并降维。其运算可以表示为

$$K_i = f(\text{down}(K_{i-1}) + c_i) \quad (2)$$

式中 c_i 为下采样的偏置向量。

全连接层对多个卷积层和池化层特征图中的特征进行整合,根据特征的高层含义对输入图像进行分类。具体来说,给出某一输入 x ,其属于第 $j(j \in [1, 2, \dots, k])$ 类信息的概率 p_j ,可以用 Softmax 函数来表示:

$$p_j(y = j | x) = \frac{e^{\omega_j^T x + b_j}}{\sum_{i=1}^k e^{\omega_i^T x + b_i}} \quad (3)$$

在 Lamb 波损伤检测中, p 是网络的输出 $p = [p_1, p_2, \dots, p_i, \dots, p_k]$, 受 Lamb 波与损伤之间相互作用的影响,代表着对损伤信息的预测。 k 为需要划分的总类别数,此函数输出一个大小为 $1 \times k$ 的概率向量,向量中元素的和等于 1。

网络训练依随最小化期望输出 $y = [y_1, y_2, \dots, y_i, \dots, y_k]$ 与网络输出 $p = [p_1, p_2, \dots, p_i, \dots, p_k]$ 之间的差异(误差函数),不断更新网络参数。误差函数为

$$L(x, \theta) = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^k y_j^{(i)} \log p_j \quad (4)$$

式中: $y_j^{(i)}$ 为由 N 个样本组成的训练库中样本 i 的期望输出; θ 为权重与偏置组成的系数矩阵。

本文采用 Adam 优化器,将由模拟和实验方法所获得的与损伤位置、激励频率、噪声条件相关的作差信号图放入模型中进行训练,根据训练集与测试集的误差曲线趋势调整超参数,结果见表 1。

表 1 超参数设置

Tab. 1 Hyper-parameters setting

超参数类别	值	超参数类别	值
批次 batch size	32	卷积层 1 和卷积层 2 的卷积核	大小: 3×3 , 通道数: 16
Epoch	50	卷积层 3 和卷积层 4 的卷积核	大小: 3×3 , 通道数: 32
学习率	0.001	一阶矩估计衰减速率 β_1	0.9
激活函数	ReLU 函数	二阶矩估计衰减速率 β_2	0.999
损失函数	交叉熵损失函数	优化器的常数 ϵ	10^{-8}

通过优化式(4)所示损失函数 $L(x, \theta)$ 来更新参数 θ ,寻求最佳参数组合使得真实损伤信息与预测损伤信息一致。网络训练成功的标志为训练集和验证集的误差曲线均逐渐下降并最终趋近于 0,训练集和验证集的准确率曲线应逐渐上升并最终趋近于 1。历经时长 20 小时,网络训练完成,训练结果如图 7 所示。图 7 中,横坐标 Epoch 指所有的数据送入网络中完成一次前向计算及反向传播。由图可知,误差曲线逐渐下降并最终趋近于 0,准确率曲线逐渐升高并最终趋近于 1,这标志着卷积神经网络的训练成功。

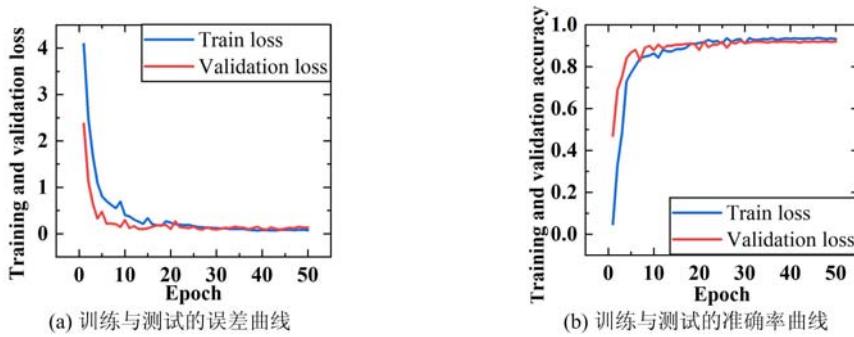


图7 卷积神经网络的训练结果

Fig. 7 Training results of convolutional neural network

5 智能结构损伤识别模型的验证与评估

5.1 基于模拟数据对智能结构损伤识别模型的验证与评估

5.1.1 基于不同信噪比条件下划定区域的损伤数据对模型有效性的验证

为了检验模型的预测能力,建立包含损伤(第一象限15号区域)的数值模型,采用中心频率为150kHz的波激励,并在接收信号中添加不同信噪比的噪声,以此数值模型作为对象实施损伤预测。预测结果以图8(a)所示的概率形式返回,其中每个区域的第一个数字代表损伤区域编号,第二个数字代表经模型预测损伤位于此区域的概率(小于1)。结果表明,模型对信号中添加不同信噪比噪声的数据均能正确预测真实损伤区域。然而当信号信噪比较低时,损伤信息将被噪声埋没,CNN针对该区域所识别出来的特征图将难以与预测图相匹配,导致预测精度降低。这一趋势与图8(b)给出的随着SNR的降低预测精度降低的结果相一致,其中SNR指信噪比,为实验中得到的原始信号的强度与所添加噪声强度的比值。

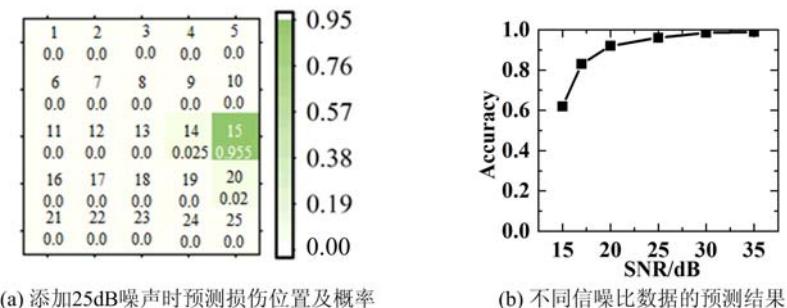


图8 中心频率为150kHz的波激励下损伤位于15号区域时不同信噪比数据的预测结果

Fig. 8 The prediction results of the model for different signal-to-noise ratio data of damage area 15 under the excitation of 150kHz center frequency wave

5.1.2 跨区域损伤数据对模型有效性的验证

为验证模型对跨预设区域损伤的预测能力,取跨14号区域和15号区域作为损伤的发生位置,以中心频率为250kHz的波激励下添加35dB噪声的数据为例,加载该模型进行损伤预测,预测结果以如图9所示的概率形式返回。

图9中区域颜色越深代表模型预测损伤在此区域的概率越大,各个区域的概率值相加应等于1。其中位于15号区域和14号区域的概率值分别为0.395和0.32,其和为0.715,远大于其他区域的概率值。综合15号区域与14号区域的预测概率值,可判定损伤必跨于14号和15号区域中间,说明该模型预测损伤位置与真实损伤位置一致。

5.2 基于实验数据对智能结构损伤识别模型的验证与评估

为检验本文所确定的智能损伤识别模型对板结构中实际损伤所在位置的预测能力,应用所搭建的

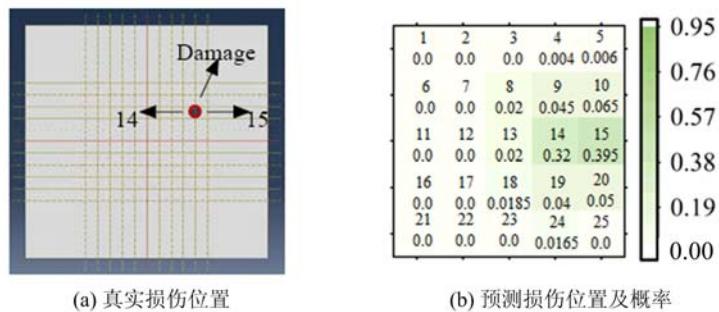


图9 中心频率为250kHz的波激励下损伤位于14号与15号区域中间的预测结果

Fig. 9 The prediction result of damage located in the middle of area 14 and 15 under the excitation of 250kHz center frequency wave

检测平台,采集中心频率为200kHz的波激励下位于第一象限8号区域的损伤数据进行预测,预测结果以概率形式返回,得到如图10所示的损伤预测图。图中颜色最深处为8号区域,此区域概率值为0.93,相比其周边区域的概率值高1个数量级,并显示出损伤发生在8号区域,与实际磁石放置于8号区域一致。

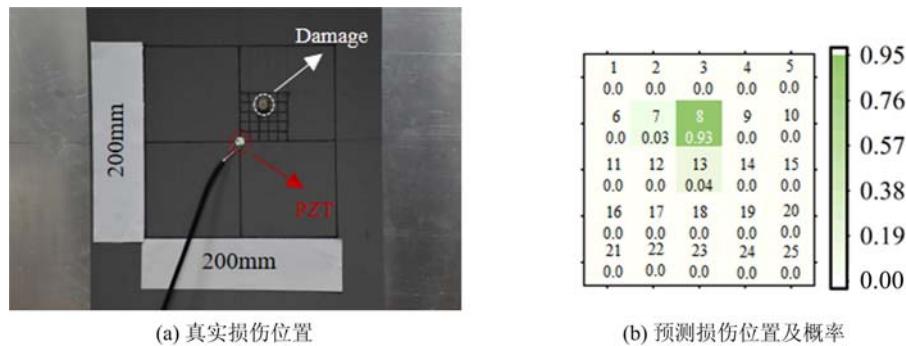


图10 中心频率为200kHz的波激励下模型对数据库中实验数据的预测结果

Fig. 10 Prediction results of the model for the experimental data in the database under the excitation of 200kHz center frequency wave

5.3 智能结构损伤识别模型对损伤大小的识别结果

在损伤位置识别为15号区域的基础上,利用针对损伤位置训练好的模型在包含损伤大小的数据集上进行迁移学习,并将网络中分类层的值设置为损伤大小的类别数。以中心频率为200kHz的波激励下不同噪声水平的分类结果为例,评估模型对损伤大小检测的性能。

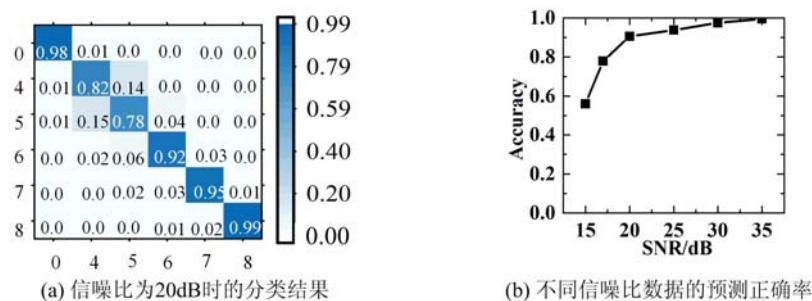


图11 不同噪声水平下的损伤大小分类结果

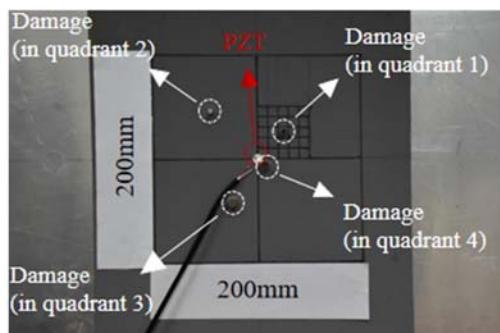
Fig. 11 Classification of damage sizes under different noise levels

如图11(a)所示的混淆矩阵表示模型针对损伤大小的检测结果,横、纵坐标中0、4、5、6、7、8表明针对损伤大小的检测分类问题共有6类,分别为直径0mm、4mm、5mm、6mm、7mm、8mm的圆形通孔损伤,损伤程度分别占据区域面积的0%、12.57%、19.6%、28.27%、38.48%、50.27%。混淆矩阵对角线

上的值为每一类样本被模型正确预测的概率。以图11(a)第六列为为例,真实损伤直径为8mm的样本,通过分类器预测之后,有99%的概率被正确预测为8mm损伤,该结果表明模型针对直径为8mm的损伤检测取得了较好的识别准确度。由图11(a)对角线上的值可知,其他列同样取得了较好的结果。直径4mm和直径5mm的损伤,其损伤程度相差最小,故在检测分类中出现相互分类错误情况,正确率比其他的略低。如图11(b)所示,模型对信号中添加不同信噪比噪声的数据均能正确预测真实损伤大小,然而当信号信噪比较低时,损伤信息将被噪声埋没,CNN针对该区域中不同直径的损伤所识别出来的特征图将难以与预测图相匹配,导致预测精度降低。

6 基于智能结构损伤识别模型的实验验证

为检验智能结构损伤识别模型对板结构任意位置损伤的识别能力,随机选取4个象限中不同区域作为损伤的发生位置。具体损伤设置分别为:第一象限13号区域放置直径为5mm的磁石,第二象限5号区域放置直径为6mm的磁石,第三象限3号区域放置直径为10mm的磁石,第四象限21号区域放置直径为8mm的磁石。



(a) 板结构随机选取的损伤位置

1	2	3	4	5
0.0	0.0	0.0	0.08	0.87
6	7	8	9	10
0.0	0.0	0.0	0.01	0.04
11	12	13	14	15
0.0	0.0	0.0	0.0	0.0
16	17	18	19	20
0.0	0.0	0.0	0.0	0.0
21	22	23	24	25
0.0	0.0	0.0	0.0	0.0

(b) 第一象限预测结果

1	2	3	4	5
0.0	0.0	0.0	0.08	0.87
6	7	8	9	10
0.0	0.0	0.0	0.01	0.04
11	12	13	14	15
0.0	0.0	0.0	0.0	0.0
16	17	18	19	20
0.0	0.0	0.0	0.0	0.0
21	22	23	24	25
0.0	0.0	0.0	0.0	0.0

(c) 第二象限预测结果

1	2	3	4	5
0.0	0.05	0.85	0.042	0.0
6	7	8	9	10
0.0	0.012	0.038	0.008	0.0
11	12	13	14	15
0.0	0.0	0.0	0.0	0.0
16	17	18	19	20
0.0	0.0	0.0	0.0	0.0
21	22	23	24	25
0.0	0.0	0.0	0.0	0.0

(d) 第三象限预测结果

1	2	3	4	5
0.0	0.0	0.0	0.0	0.0
6	7	8	9	10
0.0	0.0	0.0	0.0	0.0
11	12	13	14	15
0.0	0.0	0.0	0.0	0.0
16	17	18	19	20
0.05	0.03	0.0	0.0	0.0
21	22	23	24	25
0.84	0.08	0.0	0.0	0.0

(e) 第四象限预测结果

图12 模型对不同象限实验数据的预测结果

Fig. 12 The prediction results of the model for experimental data in different quadrants

采集损伤分别位于4个象限时的实验信号并进行相应的数据预处理,加载训练好的模型分别对4个象限中的损伤位置进行预测,预测结果以概率形式返回,得到如图12所示损伤预测图。由智能结构损伤识别模型对损伤位于不同象限的预测结果可知,预测损伤位置均与真实损伤位置一致,验证了模型对损伤位置预测的有效性。

多次测试性实验证结果表明,利用训练好的模型对实验数据进行预测时,预测结果与真实损伤位置相同。由此可见,本文建立的智能结构损伤识别模型可对实验中真实损伤进行有效预测,且预测时间较短,通常为0.001s左右,达到了即测即出的效果。

7 结论

本文构建智能结构损伤识别平台,重点研究了卷积神经网络自动提取损伤特征的方法。训练智能结构损伤识别模型对结构损伤进行有效识别时,达到了即测即出的检测效果。模型的确立及其训练需

要提供大量的数据样本和一定的时间,但模型经训练和验证相对完备后,可达成对结构损伤快速、智能化的检测。数值模拟和实验结果表明,将基于卷积神经网络的深度学习方法运用于结构损伤识别,在实现快速、智能化的损伤检测方面有潜在的工程应用前景。

参考文献:

- [1] 郑跃滨,周凯,雷振坤,等.基于同心压电传感器的单模态Lamb波信号提取方法[J].实验力学,2020,35(4):547—556 (ZHENG Yuebin, ZHOU Kai, LEI Zhenkun, et al. Single mode signal extraction method of Lamb wave using a concentric PZT transducer[J]. Journal of Experimental Mechanics, 2020, 35(4):547—556 (in Chinese))
- [2] 胡海峰.板状金属结构健康监测的非线性超声理论与关键技术研究[D].长沙:国防科学技术大学,2011 (HU Haifeng. Research on theory and key technologies of nonlinear ultrasonics for health monitoring of plate-like metallic structures[D]. Changsha: National University of Defense Technology, 2011 (in Chinese))
- [3] 骆英,陈力,徐晨光,等.激光超声导波分频段时域滤波及频率波数域逆时损伤成像[J].振动与冲击,2019,38(13):87—94 (LUO Ying, CHEN Li, XU Chenguang, et al. Time-reversal damage imaging in $f-k$ domain method based on laser ultrasonic guide wave time-domain filtering in multi-band[J]. Journal of Vibration and Shock, 2019, 38(13):87—94 (in Chinese))
- [4] 何存富,郑明方,吕炎,等.超声导波检测技术的发展、应用与挑战[J].仪器仪表学报,2016,37(8):1713—1735 (HE Cunfu, ZHENG Mingfang, LÜ Yan, et al. Development, applications and challenges in ultrasonic guided waves testing technology[J]. Chinese Journal of Scientific Instrument, 2016, 37(8):1713—1735 (in Chinese))
- [5] Zhang Z, Pan H, Wang X, et al. Machine learning-enriched Lamb wave approaches for automated damage detection[J]. Sensors, 2020, 20(6):1790—1817.
- [6] 董珍一,林莉,孙旭,等.基于BP神经网络的超声表面波定量表征金属表层裂纹深度研究[J].仪器仪表学报,2019,40(8):31—38 (DONG Zhenyi, LIN Li, SUN Xu, et al. Study on the quantitative characterization of metal surface crack depth through BP neural network combined with SAW technique[J]. Chinese Journal of Scientific Instrument, 2019, 40(8):31—38 (in Chinese))
- [7] 张传栋,何存富,刘秀成,等.基于BP神经网络的钢轴表面硬度磁巴克豪森噪声定量检测技术[J].实验力学,2020,35(1):1—8 (ZHANG Chuandong, HE Cunfu, LIU Xiucheng, et al. Magnetic barkhausen noise technology for surface hardness evaluation in steel shaft based on BP neural network[J]. Journal of Experimental Mechanics, 2020, 35(1):1—8 (in Chinese))
- [8] Harley J B, Sparkman D. Machine learning and NDE: past, present, and future [C]. AIP Conference Proceedings, 2019.
- [9] Melville J, Alguri K S, Deemer C, et al. Structural damage detection using deep learning of ultrasonic guided waves[C]. American Institute of Physics Conference Series, 2017.
- [10] Liu H, Zhang Y. Deep learning based crack damage detection technique for thin plate structures using guided Lamb wave signals[J]. Smart Materials and Structures, 2019, 29(1):015032—015071.
- [11] Ewald V, Groves R M, Benedictus R. DeepSHM: a deep learning approach for structural health monitoring based on guided Lamb wave technique[C]//Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2019. SPIE, 2019:84—99.
- [12] Xu L, Yuan S F, Chen J, et al. Guided wave-convolutional neural network based fatigue crack diagnosis of aircraft structures[J]. Sensors, 2019, 19(16): 3567—3585.

An intelligent structural damage identification method based on Lamb wave

LUO Ying, MAO Yuxin

(National Center for International Research on Structural Health Management of Critical Components, Jiangsu University, Zhenjiang 212013, Jiangsu, China)

Abstract: Conventional damage detection methods based on ultrasonic Lamb wave rely on accurate physical models, cumbersome signal processing techniques and limited by different imaging algorithms, which makes it difficult to balance the accuracy and efficiency of damage imaging. Aiming at the rapid and accurate intelligent damage detection requirements of key structures of high-end equipment, the method of automatically extracting Lamb wave damage features information based on the constructed convolution neural network by using the detection platform of piezoelectric excitation and Scanning Laser Doppler Vibrometer pickup. The area of damage to be detected in the structure is divided reasonably, and the damage detection is transformed into an image classification task based on convolution neural network. The database was established according to the change of the location and size of the damage, and the data enhancement technology is used to expand the database. The intelligent damage identification model based on convolution neural network is used to establish the mapping relationship between damage area and Lamb wave signal features, so as to realize the rapid and intelligent identification of damage. The experimental testing prove that the application of convolutional neural network to damage recognition based on Lamb waves has potential engineering application prospects in realizing fast and intelligent damage detection.

Keywords: Lamb wave; convolutional neural network model; data enhancement technology; structural damage identification; intelligent detection