

# 一种基于深度学习的超声导波缺陷重构方法

李奇<sup>1</sup>, 笄益辉<sup>1</sup>, 王彬<sup>1</sup>, 蒋浩<sup>1</sup>, Dianzi Liu<sup>2,\*\*</sup>, 钱征华<sup>1,\*\*</sup>

<sup>1</sup>南京航空航天大学机械结构力学及控制国家重点实验室/航空学院, 南京, 210016

<sup>2</sup>School of Engineering, University of East Anglia, UK

**摘要:** 超声导波检测因其传播效率高、耗能少等优势成为了无损检测领域的重要研究方向。目前已有的利用超声导波进行结构缺陷探测和量化重构的方法主要由相关的导波散射理论推导得出。然而, 由于导波散射问题本身的高复杂性, 使得在推导上述理论方法时引入一些近似假设, 降低了重构结果的质量。另外, 有些方法通过优化迭代的方式提高重构精度, 又会增加检测的时间成本。有鉴于此, 本文探索了一种将卷积神经网络与导波散射理论模型以局部融合的方式实现缺陷量化重构的新方法。应用样本数据训练后的神经网络实现缺陷量化重构, 弥补缺陷重构过程中的理论模型误差, 同时去除在实际检测过程中所存在的环境噪声。本文以利用 SH 导波重构平板中的减薄缺陷为研究对象, 通过数值模拟验证了该方法在缺陷重构时具有高效率和高精度的特点, 特别是对矩形缺陷的重构, 新方法的结果精度比波数空间域变换法的精度提高了近 200%。

**关键词:** 超声波检测 深度学习 卷积神经网络 缺陷重构

## Deep learning-assisted accurate defect reconstruction using ultrasonic guided waves

Qi Li<sup>1</sup>, Yihui Da<sup>1</sup>, Bin Wang<sup>1</sup>, Hao Jiang<sup>1</sup>, Dianzi Liu<sup>2</sup>, Zhenghua Qian<sup>1</sup>

<sup>1</sup>State Key Laboratory of Mechanics and Control of Mechanical Structures, College of Aerospace Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing, 210016, China

<sup>2</sup>School of Engineering, University of East Anglia, UK

**Abstract:** Ultrasonic guided wave technology has played a significant role in the field of nondestructive testing due to its advantages of high propagation efficiency and low energy consumption. At present, the existing methods for structural defect detection and quantitative reconstruction of defects by ultrasonic guided waves are mainly derived from the guided wave scattering theory. However, taking into account the high complexity in guided wave scattering problems, assumptions such as Born approximation used to

---

\*\* 通讯作者: Tel: 025-84895952, Email: [gianzh@nuaa.edu.cn](mailto:gianzh@nuaa.edu.cn) and Tel: (0044) 07737402623 (Mobile), Email: [dianzi.liu@uea.ac.uk](mailto:dianzi.liu@uea.ac.uk)

derive theoretical solutions lead to the poor quality of the reconstructed results. Other methods for example optimizing iteration, improve the accuracy of reconstruction, but the time cost in the process of detection has remarkably increased. To address these issues, a novel approach to quantitative defect reconstruction based on the integration of convolutional neural network with guided wave scattering theory has been proposed in this paper. The neural network developed by this deep learning-assisted method has the ability to quantitatively predict the reconstruction of defects, reduce the theoretical model error and eliminate the impact of noise pollution in the process of inspection on the accuracy of results. To demonstrate the advantage of the developed method for defect reconstruction, the thinning defect reconstructions in plate have been examined. Results show that this approach has high levels of efficiency and accuracy for reconstruction of defects in structures. Especially, for the reconstruction of the rectangle defect, the result by the proposed method is nearly 200% more accurate than the solution by the wavenumber spatial transformation method. For the signals polluted with gaussian noise, i.e., 15 db, the proposed method can improve the accuracy of reconstruction of defects by 71% as compared with the quality of results by the traditional wavenumber-space transform method. In practical applications, the integration of theoretical reconstruction models with the neural network technique can provide a useful insight into the high-precision reconstruction of defects in the field of non-destruction testing.

**Key words:** Ultrasonic detection, deep learning, convolutional neural network, defect reconstruction

## 引言

与用传统的体波检测方法对杆件、板壳、梁等弹性波导结构进行损伤检测相比，超声导波检测具有激发方式便捷、传播距离远、对缺陷有较高的敏感度和精度、低耗能和经济性等优势<sup>[1-3]</sup>。特别是对于铁路交通、石油管道、飞行器机身机翼等重要领域的无损检测，超声导波检测的高效率和高精度特征显得更加重要。因此，利用超声导波进行结构中的缺陷探测和缺陷形状高精度、量化重构已成为无损检测领域的研究热门。早在本世纪初，刘江伟<sup>[4]</sup>就利用 Lamb 波的 S0 模式在层状复合材料的反射信号对缺陷进行定位。Matt<sup>[5]</sup>则利用导波在层间传递能量较大、模态耦合对粘连条件的敏感性较大等特征对无人机翼片-桅杆键的复合-复合结构进行缺陷探测，主要研究了两种不同类型的粘结缺陷，即固化不良的粘结剂和粘界面缺陷。Yu<sup>[6]</sup>提出了一种基于特征导波的结构健康监测策略，利用适当的特征导波作为筛选工具对典型的刚性粘接复合材料蒙皮组件进行快速筛选。该方法主要通过一系列换能器捕捉发生在粘接处局部损伤的散射波，并与成像方法相结合，即利用这些散射信号通过合成聚焦算法实现损伤重建。Wang 等<sup>[7]</sup>利用 Born 近似，将被视作弱散射源的缺陷附近的总场用入

射场代替,推导出位于远场的反射系数与缺陷形状函数成 Fourier 变换对的数学关系,重构出二维板中的减薄缺陷。刘科海<sup>[8]</sup>等基于加权分布诊断成像方法进一步发展损伤定位和尺寸评估的各项关键技术,提高稀疏传感网络的损伤定位精度,探索可用于飞行器复杂结构的高效率、高精度损伤诊断新策略和新方法。Da<sup>[9]</sup>等提出了一种管道中超声导波缺陷量化重构的新方法(QDFT),该方法从边界积分方程和波数域的傅立叶变换出发,利用 Born 近似,推导出缺陷形状函数,最后通过参考模型,重构出未知缺陷。

近些年,很多学者都对导波在无损检测领域的应用做了宝贵的探索研究,明确了其应用价值。然而,由于散射反演问题的高复杂性,特别是对于具有多种模态相互耦合的超声导波散射场,缺陷重构理论模型的构建尤其困难,若构建出不完善的理论模型,会对缺陷重构结果引入模型误差,或者在缺陷重构过程中导致极大的运算量。除此之外,由于现有的缺陷探测重构技术都需要和信号处理系统相配合<sup>[1]</sup>,实际测量中难免受环境噪声的影响,亦会影响缺陷重构结果的精度。有鉴于此,基于目前快速发展的深度学习算法在图像重构领域的应用,本文提出一种基于深度学习算法的超声导波缺陷重构方法,尝试以样本学习的方式,构造卷积神经网络,进而消除缺陷重构中的模型误差、环境噪声的影响并提高缺陷量化重构的计算效率。

自 2012 年 Hinton<sup>[10]</sup>在机器学习领域取得突破性的研究进展以来,深度学习在多个领域得到快速发展和广泛应用,并展现出强大的能力。在对图像的散射重构领域,深度学习算法已有诸多应用。Kyong 等<sup>[11]</sup>为了解决计算层析成像过程中的不适定问题,将深度卷积神经网络与 X 射线层析成像中传统的逆问题求解方法——反向投影算法(FBP)相结合,先利用反向投影算法处理二次采样的正弦图,得到初步的重构图像,然后将重构出的图像输入卷积神经网络进行后处理,输出质量较高的重构图像。David 等<sup>[12]</sup>研究了将 FBP 算法和 PWLS 迭代算法分别与卷积神经网络进行结合进行图像的重构,研究发现这种算法之间的局部融合可以提高图像重构过程中分辨率和方差之间的平衡,因此可以提高 CT 图像的质量;同时,用两种不同类型的图像重构方法进行这项研究(在图像重构领域,FBP 是一种典型的对正向算子直接求反的算法,PWLS 则是一种典型的迭代求反的算法),阐述了这些算法局部融合的普适性——若重构算法发生变化,则通过修改的后续的神经网络结构重新训练,依旧可实现提高重构图像质量的目的。Yu 等<sup>[13]</sup>为了解决图像重构中的多重散射问题,将散射反演过程分成了两步:先利用理论模型设计出反向传播算法,将测量域的数据变换到图像域,再设计出 U-net 结构的深度卷积神经网络作为散射解码器,完成对图像域数据的重构任务。研究发现这种基

于深度学习的图像重构方法在处理多重散射问题时具有更高的运算效率和重构质量。在 Michael<sup>[14]</sup>的综述文章中，列出了很多利用深度学习算法进行散射反演的研究工作，并说明了在图像的散射反演领域中，受限于样本数据量、散射反演问题的高复杂度等难以解决的问题，主流的利用深度学习算法进行散射反演任务的方法还是将传统的重构算法与深度学习算法相结合，先利用传统的理论方法进行预重构，然后将重构结果输入训练好机器学习模型进行后处理，最终得到高质量的重构结果。

对于同样属于散射反演问题的超声导波缺陷重构，参考深度学习算法特别是卷积神经网络算法在图像重构领域的应用方式，本文提出一种基于现有导波缺陷重构理论模型与深度学习算法相结合的方法，以数据信息挖掘配合理论推导的方式，实现高精度、高效率的超声导波缺陷量化重构。

## 1 基于波数空间域变换的超声导波缺陷重构




图 1 超声 SH 导波遇平板减薄缺陷发生反射和透射

Fig.1 Reflection and transmission of an incident guided SH-wave by a plate thinning.

对于如图 1 所示的平板减薄缺陷重构问题，可在板的右侧激发超声 SH 导波，然后根据反射波信号计算出反射系数，再对波数域的反射系数进行傅立叶逆变换到空间域，即可重构出缺陷的形状<sup>[7]</sup>。主要步骤可以概括如下：

首先从平板中的波动方程以及对应的边界条件出发，推导出板中的位移场分布。假设本问题中入射的 SH 导波为一个自右向左传播的单纯模态，则入射波和反射波的位移形式可表示为：

$$\tilde{u}^{inc} = A_n^{inc} f_n(\beta_n x_2) e^{+i\xi_n x_1} \quad \tilde{u}^{ref} = A_n^{ref} f_n(\beta_n x_2) e^{-i\xi_n x_1} \quad (1)$$

反射系数则定义为两者的系数之比：

$$C^{ref} = A_n^{ref} / A_n^{inc} \quad (2)$$

然后通过动力学互易定理<sup>[15]</sup>，并结合平板中 Green 函数 $\tilde{U}(\mathbf{x}, \mathbf{X})$ ，可建立其边界积分方程：

$$\tilde{u}^{sca}(\mathbf{x}) = \int_S [\tilde{u}^{tot}(\mathbf{X}) \tilde{T}(\mathbf{X}, \mathbf{x}) - \mu \frac{\partial \tilde{u}^{tot}(\mathbf{X})}{\partial n(\mathbf{X})} \tilde{U}(\mathbf{X}, \mathbf{x})] ds(\mathbf{X}) \quad (3)$$

根据缺陷边界是自由边界有 $\mu \partial \tilde{u}^{tot} / \partial n = 0$ 。假设未知缺陷为一弱散射源，引入 Born 假定，

将(3)式中的总波场 $\tilde{u}^{tot}(\mathbf{X})$ 用入射波场 $\tilde{u}^{inc}$ 代替，可推导出：

$$\tilde{u}^{sca}(\mathbf{x}) \approx \int_S \tilde{u}^{inc}(\mathbf{X}) \mu \frac{\partial \tilde{U}(\mathbf{X}, \mathbf{x})}{\partial n(\mathbf{X})} ds(\mathbf{X}) \quad (4)$$

利用 Gauss 定理将缺陷表面积分改写成缺陷空隙中的体积分：

$$\tilde{u}^{sca}(\mathbf{x}) \approx \int_V \left[ -k^2 \tilde{u}^{inc}(\mathbf{X}) \mu \tilde{U}(\mathbf{X}, \mathbf{x}) + \mu \frac{\partial \tilde{U}(\mathbf{X}, \mathbf{x})}{\partial x_i} \frac{\partial \tilde{u}^{inc}(\mathbf{X})}{\partial x_i} \right] dV(\mathbf{X}) \quad (5)$$

代入 Green 函数式(具体推导过程见文献<sup>[7]</sup>)可得远场处的反射波：

$$\tilde{u}^{ref}(\mathbf{x}) = \frac{i}{2b} A_n^{inc} \int_V \frac{\xi_n^2 + k^2 \cos(2\beta_n x_2)}{\xi_n} e^{2i\xi_n x_1} dV(\mathbf{X}) \times \cos(\beta_n x_2) e^{-i\xi_n x_1} \quad (6)$$

比较式(1)和式(6)可以发现式(6)中的积分项对应于反射系数，将体积分表示为二重积分可推得：

$$C^{ref} = \frac{A_n^{ref}}{A_n^{inc}} = \frac{i}{2b} \frac{\xi_n^2 + k^2}{\xi_n} \int_{-\infty}^{+\infty} d(X_1) e^{2i\xi_n X_1} dX_1 \quad (7)$$

其中 $C^{ref}$ 即为反射系数， $d(X_1)$ 为缺陷的形状函数。由该式即可看出 $C^{ref}$ 与 $d(X_1)$ 成一对傅立叶变换对，通过对 $C^{ref}$ 进行傅立叶逆变换就能重构出缺陷。

在推导公式(7)的过程中，使用了一些近似方法。比如已经提到的将减薄缺陷假设为弱散射源( $d \ll b$ )，然后引入 Born 近似，将缺陷附近的总场近似为入射场；而在计算该有界板中的 Green 函数时，亦将远场处的 Green 函数入射项近似为 0。这些近似方法能帮助简化缺陷重构理论模型，提高重构效率，但也难免为重构出的结果引入模型误差，降低了重构精度。因此，本文提出一种将波数空间域变换法与深度学习中的卷积神经网络相结合的导波缺陷量化重构新方法，应用样本数据训练后的神经网络，实现了缺陷量化重构，既消除了模型误差和环境噪声的影响，又提高缺陷量化重构的精度。

## 2 基于深度学习的缺陷重构方法

通过理论模型计算得到重构的缺陷形状，常常含有模型误差和噪声。主要原因在于：一方面是理论重构模型本身不够完善，如在上述波数空间域变换法中引入了 Born 近似，使得重构出的结果难免含有模型误差；另一方面，在实际测量中，超声导波无损检测系统会受到环境噪声和测量误差的影响，使得重构出的缺陷不够精确。为了得到高精度的重构缺陷，本

研究中将深度学习中的卷积神经网络算法与导波缺陷重构理论方法以局部融合的方式进行结合,通过样本学习的方式,训练出能够弥补模型误差和去除系统噪声的深度学习神经网络,进而实现高精度的定量化重构缺陷。

## 2.1 卷积神经网络

深度学习中的卷积神经网络算法是一种具有权重共享、局部连接等特性的深层前馈神经网络<sup>[16]</sup>。在处理某些问题时,与传统的全连接神经网络相比,卷积神经网络有其独特的优势所在。比如,在处理高维数据如图像信号时,卷积神经网络的训练参数更少,进而能提高神经网络的训练效率,也更容易避免出现过拟合的现象<sup>[17]</sup>。除此之外,在二维图像或一维信号中的物体常常具有局部不变性<sup>[18]</sup>的特征,这个特征表现为尺度缩放、平移、旋转等操作并不会影响物体的语义信息,在处理这类问题时,卷积神经网络比全连接前馈神经网络更容易提取到这些局部不变特征。

相比于BP神经网络(Backpropagation neural network)单一的全连接型神经元构架,卷积神经网络则含有三种类型的神经元连接层:卷积层、池化层和全连接层<sup>[19-21]</sup>,如图2所示。卷积层的主要作用是进行特征提取,以训练卷积核的方式,实现对图像或一维信号中具有不变性的底层特征的提取,因为本文所研究的对象是一维的缺陷形状信号,所以搭建出的卷积神经网络中的卷积核也是一维的数值序列。池化层的主要作用是在保留信号中特征信息的情况下,实现对信号的降维操作,以此降低网络的复杂度,提高计算效率。卷积神经网络中的全连接层主要分布于网络的后半部分,常作为网络的输出层,通过控制输出层的结构,可以改变整个神经网络所具有的功能,进而通过调控使得输出层输出无限个连续值,获得具有回归功能的神经网络。




图 2. 典型卷积神经网络结构图

Fig.2 Typical convolutional neural network structure diagram.

本文所搭建的神经网络将输出层设置为多维且能输出连续值的神经元结构,以此实现输出一维缺陷形状信号的功能。完成上述神经网络的搭建后,给网络中的待定参数一个初值,

网络就能实现运算功能。而网络的训练过程，就是通过迭代运算更新网络中的待定参数，使得网络实现某种功能。本文利用均方差函数(MSE)做为性能函数来评估神经网络计算出的重构缺陷的质量，训练的过程就是通过调整待定参数的值来获得极小的性能函数值。神经网络的层状结构，决定了其具有方便调整网络中参数的优势。通常使用链式法则，逐层向内求导，然后对每一个参数进行优化<sup>[22]</sup>。网络训练过程中的优化算法也多种多样，较为常见的有随机梯度下降法、共轭梯度下降法、牛顿法等等<sup>[23]</sup>。本文使用 Tensorflow<sup>[24]</sup>中的卷积神经网络为基础，开发了适用于定量化重构缺陷的神经网络。

综上所述，选择卷积神经网络作为此次研究中的机器学习算法的原因在于：1. 运算对象是含有多种几何形状的平板减薄缺陷，使用卷积神经网络可以更好的提取出这些几何形状中的不变性特征；2. 对于处理高维度缺陷信号，卷积神经网络的运算效率较高；3. 卷积神经网络算法相关的研究较为成熟，多种可选择的网络结构、性能函数以及优化算法都有助于以深度学习为基础的缺陷重构方法的研究。

## 2.2 有监督学习的缺陷重构算法（WNSTConvNet）

利用超声波进行缺陷探测的物理过程为：声波沿介质传播的过程中遇到缺陷发生散射，产生对应的透射波场或反射波场，利用透射波或反射波中蕴含的缺陷信息，即可实现缺陷探测或缺陷重构，因此，超声波缺陷重构可归结为一个散射问题。对于散射问题，可用下式简单表示：

$$y = Tx + \xi \quad (8)$$

其中 $x$ 表示散射源，或者说重构对象，在本文中就表示板中的减薄缺陷； $y$ 表示散射场信号； $T$ 是一个算子，算子 $T$ 的属性取决于具体的散射问题本身； $\xi$ 为误差。散射反演的任务是在知道 $y$ 的情况下计算出 $x$ 。传统的解决该问题的主要方式分为两种，第一种方式是直接求解，即直接构建反问题模型，上述的波数空间域变换法就属于这种方式，用式子表示这类方法为：

$$x = \hat{T}^{-1}y \quad (9)$$

其中 $\hat{T}^{-1}$ 为构建出的理论重构模型。这种方法的优势在于对于简单结构的缺陷重构，能在短时间内完成散射反演问题的计算；劣势是由于散射反演问题是一个不适定问题，会导致重构模型很难计算出较为精确的结果，特别是当散射问题变得复杂时，重构模型的构建也会变得极其困难，重构精度会进一步受到影响。

第二种解决散射反演问题的传统方式为基于迭代求解的方法，如 QDFT 方法<sup>[9]</sup>，可以表示为：

$$O\{y\} = \arg \min_x f(T\{x\}, y) \quad (10)$$

其中函数 $f$ 为误差函数，用以表征散射正问题模型的计算结果，即 $T\{x\}$ 和 $y$ 之间的误差。基于迭代的方法的优势在于能求解出精度较高的结果；劣势在于优化迭代的过程需要进行大量的计算，时间成本较高。

第三种解决散射反演问题的方法为基于机器学习的方法，即通过样本训练的方式构建出反问题模型，用式子可表示为：

$$L = \arg \min_{\theta} \sum_{n=1}^N f(x_n, L_{\theta}\{y_n\}) + g(\theta) \quad (11)$$

其中 $x_n$ 和 $y_n$ 表示一对训练样本，组合表示为 $(x_n, y_n)$ ； $N$ 表示一共有 $N$ 对训练样本； $L_{\theta}$ 为搭建的神经网络，用于进行反演计算， $\theta$ 为神经网络中的待定参数，是训练过程中迭代更新的对象；函数 $f$ 为误差函数，用以表征样本 $x_n$ 和 $L_{\theta}\{y_n\}$ 之间的差异；函数 $g$ 为正则化项，作用是对参数 $\theta$ 的值进行限制以降低训练出的模型 $L_{\theta}$ 的复杂度，防止过拟合。利用机器学习的方法解决散射反演问题的优势在于当神经网络的训练完成后，既能实现较高的重构精度，计算速度也非常快；劣势在于用于训练网络的样本数据的获取以及网络的训练过程较困难，难以训练出较完善的散射重构神经网络。

本文为了充分利用已有的传统缺陷重构理论，将理论模型方法（第一类方法的波数空间域变换法 WNST）与第三类机器学习方法以局部融合的方式相结合以解决超声导波缺陷重构问题，将这个新方法命名为 WNSTConvNet。用式子表示所提出的新方法为：

$$L = \arg \min_{\theta} \sum_{n=1}^N f(x_n, L_{\theta}\{\hat{T}^{-1}y_n\}) + g(\theta) \quad (12)$$

由式(12)可知，在本文提出的新方法中，训练样本对为 $(x_n, \hat{T}^{-1}y_n)$ ，其中 $x_n$ 为真实的缺陷形状， $\hat{T}^{-1}$ 为理论重构模型， $\hat{T}^{-1}y_n$ 就表示预重构缺陷。因此第一种散射反演计算方法的重构结果即为第三种方法的训练样本。在研究中，选择均方误差函数(MSE)作为优化过程中的性能函数，即式中的函数 $f$ ，表征训练样本对中 $x_n$ 和 $\hat{T}^{-1}y_n$ 之间的差异大小，训练或者说机器学习的过程，就是通过不断的修正卷积神经网络中的待定参数 $\theta$ ，使得在整个样本集上的平均均方误差达到极小值。式中的正则化项 $g(\theta)$ 选用 L2 正则化函数，即计算参数 $\theta$ 的平方和的一半。基于深度学习算法对结构缺陷高精度的诊断训练流程以及所设计的网络结构如图 3 所示。






图 3. 卷积神经网络结构以及训练流程

Fig.3 Convolutional neural network structure and training process.

从图 3 可以看出，深度学习的神经网络所处理的是一维信号，所以在网络设计的过程中选择用一维模式的卷积神经网络。神经网络训练过程的描述如下：传感器数据经过波数空间域变换法(WNST)处理后，得到预重构的缺陷，并作为神经网络的输入样本，输入样本经过神经网络的计算后，得到网络输出，以计算均方误差的方式将网络输出样本与真实缺陷相比较，然后更新网络中的待定参数 $\theta$ ，迭代运算多次直到整个样本集上的平均均方误差值趋于收敛。网络训练完成后，若有一新的缺陷散射信号，经过预重构以及卷积神经网络处理后，可得到高质量的重构缺陷。在网络结构设计中，非线性激活函数部分选择使用运算效率高的 ReLU 函数<sup>[25]</sup>，同时，为了解决网络训练过程中会遇到的梯度消失问题，在激活函数前会进行批归一运算<sup>[26]</sup>，提高训练效率；而为了解决过拟合问题，在网络的末端添加 Dropout 层<sup>[27]</sup>，舍弃部分训练参数，提高网络的鲁棒性。同时，添加 L2 正则化项，对训练参数加以限制，提高网络的泛化性能。

### 3 实验验证和结果

本文设计并制作了三组样本数据用于训练具有深度学习的神经网络，并利用训练好的神经网络进行缺陷重构。

#### 3.1 样本数据的准备

本次研究通过仿真运算制作了三个训练样本集。第一个为三角形缺陷样本集，包含 400 组样本，每组样本由两部分组成，及输入样本和对应的参考样本。参考样本为真实的等腰三角形缺陷，该等腰三角形的底边长和高为随机大小，范围分别控制在(0,2)以及(0.1,0.3)之间；

输入样本为参考样本(真实缺陷)所对应的重构缺陷结果, 是利用导波散射正问题模型仿真计算得反射系数 $C^{ref}$ 再经过波数空间域变换法重构而获得。这样设计样本数据的目的是使得通过训练得到的神经网络能够感知重构缺陷尺度和形状变化, 提高神经网络的泛化性能。在 400 组样本中, 300 组样本用于神经网络的训练, 70 组用于训练过程中的验证, 30 组用于训练完成之后的测试。

第二个训练样本集为矩形缺陷样本集, 由 400 个随机大小形状的真实矩形缺陷(底边长和高的尺度范围分别是(0,2)以及(0.1,0.3))及其对应的仿真重构缺陷组成。矩形缺陷样本集中的训练、验证、测试集比例与三角形样本集相同。

第三个样本集为含噪声的矩形缺陷样本集, 用以模拟在实际检测中系统受到环境噪声的影响。该样本集由 400 个随机形状大小的矩形缺陷(尺度范围与第二个训练样本集中的矩形缺陷相同)及其对应的含噪声仿真缺陷组成。噪声的添加方法是: 首先, 计算每一个输入样本所对应的有效功率, 然后根据有效功率的大小, 添加信噪比为 15dB 的全频段高斯白噪声, 进而产生含噪声的输入样本集。

### 3.2 神经网络的训练

通过仿真计算出训练样本后, 分别将每个样本集合中的 300 组输入样本和 70 组验证样本进行卷积神经网络的训练, 同时把 30 组与训练样本不同的数据作为测试集, 用以验证网络的泛化性能, 防止过拟合。本次研究中神经网络的搭建以 Tensorflow 中的工具包为基础, 构建了适用于量化重构缺陷的神经网络, 其迭代过程中的优化算法使用的是一阶梯度优化的算法 (Adam)。在实验中, 根据预训练的训练集和验证集损失函数变化情况设置神经网络训练时在样本集上的遍历次数, 如图 4 所示, 最终的样本训练遍历次数则设置为 160 次。




图 4. 训练集和验证集损失函数变化趋势图

Fig.4 The variation trend of loss function of training dataset and validation dataset.

### 3.3 实验结果

神经网络训练完成后，将测试集的样本数据输入神经网络进行缺陷重构测试，为了定量化表征重构出的缺陷与真实缺陷的差异，即重构缺陷的质量，定义信噪比函数 (SNR)<sup>[28]</sup>:

$$SNR(\mathbf{x}, \hat{\mathbf{x}}) \triangleq \max_{\alpha \in \mathbb{R}} \left\{ 10 \log_{10} \left( \frac{\|\mathbf{x}\|_2^2}{\|\mathbf{x} - \alpha \hat{\mathbf{x}}\|_2^2} \right) \right\} \quad (13)$$

其中 $\mathbf{x}$ 为真实的缺陷， $\hat{\mathbf{x}}$ 为重构出的缺陷，SNR 的值越大，表示重构出的缺陷质量越好。注意，在本次研究中用以表征缺陷形状向量 $\mathbf{x}$ 或 $\hat{\mathbf{x}}$ 实际是整个检测范围内的缺陷形状空间分布，包括缺陷区和无缺陷区。这样设计的目的是既能研究缺陷区内重构缺陷的质量，也能观察和研究重构结果中无缺陷区部分的噪声和误差大小。

### 3.3.1 三角形样本集

将三角形样本集中的训练样本和验证样本输入卷积神经网络进行训练，训练完成后，从测试集中取出一个新的三角形缺陷，先利用平板中导波散射正问题程序仿真计算出该缺陷产生的反射系数，然后分别用波数空间域变换法 (WNST) 和 WNSTConvNet 法进行重构计算，最后将两种方法重构出的结果与真实的缺陷相对比，并通过计算 SNR 定量化比较两种方法的重构效果。图 4 和图 5 分别表示两个不同的测试缺陷以及它们所对应的重构结果，表 1 表示这两个实验结果的 SNR 值以及 30 个测试样本的平均 SNR 值。由图 5 和图 6 可以看出，波数空间域变换法 (WNST) 可以较准确的重构出缺陷的位置，但重构缺陷的深度与实际的深度存在差异，并且在无缺陷区域存在较多的误差信号，卷积神经网络的处理可以较好的解决这两个问题。从表 1 可以看出 WNSTConvNet 重构出的结果具有更高的 SNR 值，即更高的重构质量。




图 5. 三角形缺陷样本 1 的重构结果

Fig.5 Reconstruction results of triangle defect sample 1.




图 6. 三角形缺陷样本 2 的重构结果

Fig.6 Reconstruction results of triangular defect sample 2.

表 1. 三角形缺陷样本集两种方法的重构结果 SNR (dB) 值对比

Table 1 SNR(dB) comparison of two methods on triangular dataset

方法	测试样本的SNR值(dB)		
	样本1	样本2	测试样本均值
WNST	5.82	11.67	10.43
WNSTConvNet	21.44	20.13	19.86

### 3. 3. 2 矩形样本集

在实际中，矩形缺陷也是常见的缺陷形状之一，在本研究中通过仿真计算出 400 对矩形缺陷的样本数据。矩形缺陷样本集的重构结果如图 7、图 8 所示，重构结果的 SNR 值如表 2 所示。通过对比表 2 和表 1 的结果可以看出，波数空间域变换法重构矩形缺陷的效果比重构三角形缺陷的效果好，而利用 WNSTConvNet 方法重构两种类型的缺陷时，其重构结果的测试集平均 SNR 值基本相同，说明算法有较好的鲁棒特性，并且均高于对应的 WNST 法重构结果的平均 SNR 值。在矩形缺陷重构算例中，结果 (SNR 值) 的精度从 8.33dB 提高到 23.85dB，增加了约 200%。因而，WNSTConvNet 法对矩形缺陷的重构也具有更高的精度，优于 WNST 法。




图 7. 矩形缺陷样本 1 的重构结果

Fig.7 Reconstruction results of rectangular defect sample 1.




图 8. 矩形缺陷样本 2 的重构结果

Fig.8 Reconstruction results of rectangular defects sample 2.

表 2. 矩形缺陷样本集两种方法的重构结果 SNR (dB) 值对比  
Table 2 SNR(dB) comparison of two methods on rectangular dataset

方法	测试样本的SNR值(dB)		
	样本1	样本2	测试样本均值
WNST	9.62	8.25	8.33
WNSTConvNet	23.54	23.18	23.85

### 3.3.3 含噪声的矩形缺陷样本集

由于神经网络所关注的是“端对端”的映射关系,所以训练网络的过程能赋予其处理噪

声信号的能力，因此神经网络在信号处理中的去噪领域有诸多应用。为了验证本研究中的卷积神经网络也具有自适应去噪声的功能，设计了含噪声的矩形缺陷样本集。训练完成的网络对含噪声缺陷的处理结果如图 8 所示，整个测试集上的平均 SNR 值如表 3 所示。根据图 9 和表 3 可以看出训练完成后的卷积神经网络可以有效去除预重构缺陷中含有的 15dB 的噪声。对比两种方法，WNST 的结果 (SNR 值) 精度仅是 6.62dB，说明噪声的加入导致缺陷重构的精度较低，而 WNSTConvNet 缺陷重构方法的结果精度为 23.56dB，很接近没有噪音影响的重构精度 23.85dB（如表 2 所示），说明此神经网络具有较好泛化性。




图 9. 含高斯白噪声矩形缺陷重构结果

Fig.9 Reconstruction results of rectangular defects with gaussian white noise.

表 3. 含噪声矩形缺陷重构结果的 SNR 值

Table 3 SNR(dB) values of reconstruction results of rectangular defects with gaussian white noise

方法	测试样本的SNR均值(dB)
WNST	6.62
WNSTConvNet	23.56

## 4 讨论

以上的实验结果为验证 WNSTConvNet 缺陷重构方法的有效性和鲁棒性提供了有力证据。相比基于导波散射理论的缺陷重构方法 WNST，结合了样本数据训练的 WNSTConvNet 方法在缺陷重构的细节处理上具有更大的优势，重构出的结果更接近真实的缺陷形状，这对工程中的高精度缺陷探测领域具有重要意义。同时，具有自适应去噪声功能的 WNSTConvNet 方法，其鲁棒性可以体现在有效去除缺陷重构系统中样本混杂环境噪声的能力，一方面能进一步提

高重构缺陷的质量,另一方面,去除检测区域中无缺陷区的噪声对检测系统对缺陷的精确定位具有重要意义。利用 WNSTConvNet 方法重构缺陷时,在网络训练完成后,进行一次重构运算的时间少于 1 秒,具有较高的重构效率。

有监督深度学习的缺陷重构方法的劣势在于用不同数据集训练出的神经网络之间的交互性较差。比如,使用上述三角形缺陷样本集训练出的神经网络重构矩形缺陷时效果较差,表现出该重构模型具有较强的“主观特性”,泛化性能较差。在实际应用中针对该问题的解决方式是将多种典型形状类型的缺陷样本放在一起训练神经网络,或者在缺陷重构模型前添加一个分类器,然后将分出的不同类型预重构缺陷输入对应的卷积神经网络进行计算重构,这些都是需要进一步深入研究的内容。另外,使用神经网络重构缺陷需要准备大量的样本数据。目前,在工程中相关的样本数据量较少且通过实验获取样本数据的成本较高,而利用计算机仿真获取样本数据训练神经网络,然后将训练好的网络用于实测,是目前一种可行的获取数据方法。

本文中提出的基于深度学习的导波缺陷重构方法是将解决散射反演问题的第一类理论模型方法与第三类机器学习方法相结合,对于其中导波缺陷重构理论方法以及机器学习模型的类型没有具体的限制。在本文中,只选择了波数空间域变换法(WNST)与卷积神经网络进行结合构建出 WNSTConvNet 方法进行研究,对于其它以这种形式相结合的缺陷重构机器学习模型的构建具体重要的指导意义。

## 5 结论

本文提出了一种基于深度学习的超声导波缺陷量化重构方法(WNSTConvNet),是将平板减薄缺陷的 SH 波量化重构理论方法-波数空间域变换法(WNST)与卷积神经网络以局部融合的方式进行结合。神经网络结构是一维模式的卷积神经网络,在训练时添加了 L2 正则化项和 Dropout 层防止过拟合,在每个卷积层进行批归一化防止梯度消失。

通过设计实验,将 WNSTConvNet 的重构结果与波数空间域变换法的结果进行对比,验证了 WNSTConvNet 法有效且具有更高的重构精度和稳定性。对于三角形缺陷和矩形缺陷,WNSTConvNet 法的结果精度都维持在 20dB 左右,体现出算法有很好的鲁棒特性。特别是矩形缺陷的重构,WNSTConvNet 的结果精度比 WNST 提高了近 200%。考虑含 15dB 高斯白噪声的矩形缺陷算例,WNSTConvNet 方法构建的卷积神经网络可以实现去除噪声的目的,说明此神经网络具有较好泛化性。

该方法在重构缺陷时具有较高的计算速度,对于本文中研究的平板减薄缺陷的 SH 波重

构问题, 可在 1 秒内完成缺陷的重构运算, 是一种高精度、高效率的缺陷定量化重构方法, 具有较高的应用价值。

该方法尚需完善之处: 应用交互性较差, 即对于特定的问题有较好的重构效果, 若研究的问题超过了所训练网络的适用范围, 则需要有针对性的重新获取样本数据并训练新的网络。另外, 深度学习算法对样本数据的质量和数量要求较高, 而在实际工程应用, 很难获取大量的有效样本数据。针对这些问题, 后续的工作会对提高 WNSTConvNet 方法在应用时的普适性、增加样本数量等方面做进一步的研究。

### 参考文献

- [1]何存富; 郑明方; 吕炎; 邓鹏; 赵华民; 刘秀成; 宋国荣; 刘增华; 焦敬品; 吴斌. 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, 1713-1735.
- [2]Su, Z.; Ye, L.; Lu, Y. Guided Lamb waves for identification of damage in composite structures: A review[J]. Journal of Sound and Vibration **2006**, 295, 753-780.
- [3]Rose, J.L. A baseline and vision of ultrasonic guided wave inspection potential[J]. Journal of Pressure Vessel Technology **2002**, 124, 273.
- [4]刘江韦; 刘镇清. 关于用 Lamb 波的反射对层状复合材料进行无损检测的研究[J]. 无损探伤 **1998**, 1, 34-35.
- [5]Matt, H.; Bartoli, I.; Scalea, F.L.D. Ultrasonic guided wave monitoring of composite wing skin-to-spar bonded joints in aerospace structures[J]. The Journal of the Acoustical Society of America **2005**, 118, 2240-2252.
- [6]Yu, X.; Fan, Z.; Puliyakote, S.; Castaings, M. Remote monitoring of bond line defects between a composite panel and a stiffener using distributed piezoelectric sensors[J]. Smart Materials and Structures **2018**, 27, 035014.
- [7]Wang B, Hirose S. Inverse problem for shape reconstruction of plate-thinning by guided SH-waves[J]. The Japanese Society for Non-Destructive Inspection, 2012, 53(10): 1782-1789.
- [8]刘科海. 飞行器关键构件的超声导波损伤诊断成像方法研究[D]. 大连理工大学, 博士论文, **2016**.
- [9]Da Y, Dong G, Wang B, et al. A novel approach to surface defect detection[J]. International



Journal of Engineering Science, **2018**, 133(DEC.):181-195.

- [10]Hinton, G.E.; Srivastava, N.; Krizhevsky, A.; Sutskever, I.; Salakhutdinov, R.R. Improving neural networks by preventing co-adaptation of feature detectors[J]. Computer Science **2012**, arXiv: 1207.0580.
- [11]Jin K H , Mccann M T , Froustey E , et al. Deep Convolutional Neural Network for Inverse Problems in Imaging[J]. IEEE Transactions on Image Processing, **2017**:1-1.
- [12]D. Boubilil, M. Elad, J. Shtok, and M. Zibulevsky, Spatially-adaptive reconstruction in computed tomography using neural networks[J]. IEEE Trans. Med. Imag., vol. 34, no. 7, pp. 1474–1485, July **2015**.
- [13]Yu Sun, Zhihao Xia, Ulugbek S. Kamilov.Efficient and accurate inversion of multiple scattering with deep learning[J]. Computer Vision and Pattern Recognition. 10.1364/OE.26.014678
- [14]M. T. McCann, K. H. Jin and M. Unser, Convolutional Neural Networks for Inverse Problems in Imaging: A Review[J]. IEEE Signal Processing Magazine, vol. 34, no. 6, pp. 85-95, Nov. **2017**, doi: 10.1109/MSP.2017.2739299.
- [15]笮益辉. 基于超声导波的管道缺陷分析与重构方法研究[D].南京航空航天大学,**2018**.
- [16]Y. Jia et al., in CAFFE: Convolutional Architecture for Fast Feature Embedding[J], **2014**, arXiv preprint arXiv:1408.5093.
- [17]Y. LeCun, Y. Bengio, and G. Hinton, Deep learning[J]. Nature, vol. 521, no. 7553, pp. 436–444, May **2015**
- [18]A. Krizhevsky, I. Sutskever, and G. E. Hinton, “Imagenet classification with deep convolutional neural networks[J],” in Proc. 25th Int. Conf. Neural Information Processing Systems, Lake Tahoe, NV, **2012**, pp. pp. 1097–1105.
- [19]Gao Li-Gang, Chen Pai-Yu, Yu Shi-Meng.Demonstration of convolution kernel operation on resistive cross-point array[J]. IEEE Electron Device Letters, **2016**, 37(7):870-873
- [20]Gu Jiu-Xiang, Wang Zhen-Hua, Jason Kuen, et al. Recent advances in convolutional neural networks[J]. arXiv:1512. 07108v5, **2017**
- [21]Sainath T N , Mohamed A , Kingsbury B , et al. Deep convolutional neural networks for LVCSR[J]//Proceedings of the IEEE International Conference on Acoustics, Speech and Signal

- Processing. Vancouver, Canada, **2013**:8614—8618
- [22]LeCun Y, Botou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, **1998**, 86(11):2278-2324
- [23]Duchi J, Hazan E, Singer Y. Adaptive subgradient methods for online learning and stochastic optimization [J] . Journal of Machine Learning Research, **2011**, 12 (7):257-269.
- [24]Abadi, M. *et al.* TensorFlow: large-scale machine learning on heterogeneous distributed systems[J]. Preprint at <https://arxiv.org/abs/1603.04467> (**2016**).
- [25]Nair V, Hinton G E, Farabet C. Rectified linear units improve restricted Boltzmann machines[J]//Proceedings of the 27th International Conference on Machine Learning. Haifa, Israel, **2010**:807-814
- [26]Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[J]. arXiv:1502.03167, **2015**
- [27]Yoo H-J. Deep convolution neural networks in computer vision: A review[J] . IEIE Transactions on Smart Processing and Computing, **2015**, 4(1):35-43
- [28]D. Boubilil, M. Elad, J. Shtok and M. Zibulevsky, "Spatially-Adaptive Reconstruction in Computed Tomography Using Neural Networks[J]," in IEEE Transactions on Medical Imaging, vol. 34, no. 7, pp. 1474-1485, July **2015**, doi: 10.1109/TMI.2015.2401131.