

DOI: 10.13382/j.jemi.B2306520

基于物理信息嵌入式神经网络的管壁导波成像*

陈世利 吕玲玲 童君开 刘洋

(天津大学精密测试技术及仪器国家重点实验室 天津 300072)

摘要:为了实现管壁腐蚀缺陷的定量化成像,提出了一种基于物理信息嵌入式卷积神经网络的成像算法,从超声导波信号重建管壁厚度。首先推导了超声导波在管壁上传播的二维声波模型,通过矩阵LU分解求解频域波动方程,可实现从管壁导波速度图到声场信号的正演;其次搭建了物理信息嵌入式卷积神经网络,包含3个迭代层,每个迭代层由正演模型和残差反演子网络组成;生成包含随机腐蚀缺陷的管道仿真数据集,搭建网络进行训练和反演,训练集、验证集和测试集的成像结果的平均Pearson相关系数分别为94.91%、86.47%和87.37%,缺陷图像一致度高;搭建了实验系统,在加工有不规则阶梯缺陷的管道上采集导波信号进行反演,成像结果良好,厚度图的均方误差为0.0057。算法将物理模型与神经网络结合在一起,实现了从导波信号到管道厚度图的高精度成像。

关键词:管道;无损检测;超声导波;神经网络;腐蚀

中图分类号: TB553; TN911.4 **文献标识码:** A **国家标准学科分类代码:** 460.40

Guided wave imaging of pipe wall based on physics embedded neural network

Chen Shili Lyu Lingling Tong Junkai Liu Yang

(State Key Laboratory of Precision Measuring Technology and Instruments, Tianjin University, Tianjin 300072, China)

Abstract: In order to realize quantitative imaging of pipe wall corrosion defects, an imaging algorithm based on physics embedded convolution neural network is proposed to reconstruct pipe wall thickness from ultrasonic guided wave signals. Firstly, the two-dimensional acoustic wave model of ultrasonic guided wave propagation on the pipe wall is derived. The wave equation in frequency domain can be solved by matrix LU decomposition to realize the forward modeling from the pipe wall guided wave velocity diagram to the acoustic field signal. Secondly, the physics embedded convolution neural network is built, including three iterative layers, each of which is composed of forward model and residual inversion subnetwork. The pipeline simulation data set containing random corrosion defects is generated, and the network is built for training and inversion. The average Pearson correlation coefficients of the imaging results of the training set, verification set and test set are 94.91%, 86.47% and 87.37% respectively, and the defect image consistency is high. The experimental system is built, and the guided wave signal is collected on the pipe with irregular step defects for inversion. The imaging results is remarkable, with a mean square error of 0.0057 for the thickness map. The algorithm combines the physical model with neural network to achieve high-precision imaging from guided wave signal to pipeline thickness map.

Keywords: pipeline; nondestructive testing; ultrasonic guided wave; neural network; corrosion

0 引言

作为能源运输的主要途径,管道在现代工业中具有重要作用,管道的安全、完整和可靠对于保障油气资源的

高效传输和能源的稳定供应非常重要^[1]。然而,由于腐蚀等原因,管道缺陷导致的油气泄漏、火灾爆炸等事故频发,不仅造成了重大经济损失,甚至威胁和伤害了人们的生命安全。为了实现对管道缺陷的无损检测,国内外学者进行了大量研究,开发出了多种管道探伤方法,比较典

型常用的有漏磁检测^[2]、射线检测^[3]、涡流检测^[4]、管道机器人^[5]和超声导波检测^[6],其中,漏磁和涡流限制于铁磁和导电材料,且只能检测试件表面的缺陷;射线对人体有危害;管道中机器人的运动控制较难;超声导波能量衰减减小,传播距离长,此特性适用于大范围长距离的探伤,除此之外,超声导波的传播速度与频厚积相关,频散特性也可以应用于对缺陷的检测。

基于超声导波的成像方法研究,在上世纪就开始了,He 等^[7]提出了圆形阵列中的最小二乘时间反转偏移,可以在板状结构上实现高分辨率的大面积损伤成像;Cantero-Chinchilla 等^[8]使用 time-of-flight 方法和贝叶斯算法实现了板材上缺陷的定位;Wang 等^[9]提出了一种模态分解算法检测碳纤维复合材料板的分层缺陷;Huthwaite^[10]提出了 HARBUT 方法,利用 time-of-flight 和衍射层析成像的互补优势,实现了直接、快速、准确的高分辨率成像算法,并应用于板状工件的无损检测;Rao 等^[11]基于全波形反演,实现了导波层析成像,基于模型数据和测量数据的波形失配值的局部优化,并迭代应用于从低频到高频的离散频率分量。以上方法均采用了迭代反演,计算时间较长。有研究人员将机器学习方法引进无损检测,例如 Lin 等^[12]提出了一种快速反演层析成像算法,在线反演阶段用学习到的梯度下降方向重建了测试示例的速度图;Tong 等^[13]提出了一种有监督的神经网络算法,实现了对平板腐蚀缺陷的反演;Zhang 等^[14]使用深度学习方法,检测了多层各向异性结构中的损伤;Huang 等^[15]使用能量映射深度转移学习,提高了铝板内部损伤检测的准确性。然而大部分研究都是对板材进行成像,而对于管道缺陷检测方法的研究,多是定性判别缺陷是否存在,而对管壁厚度的定量化研究较少,但很显然,管壁厚度是评价管道完好性的重要指标。近年来,将深度学习与物理信息结合起来解决物理和工程问题,已受到越来越广泛的关注。Li 等^[16]提出了一种多层残差卷积神经网络级联构成的网络,解决了非线性电磁逆散射问题;Raissi 等^[17]引入基于物理的神经网络,同时遵循非线性偏微分方程描述的物理定律,以解决监督学习任务。

为了实现管壁厚度的定量化成像,本文提出了一种物理信息嵌入式卷积神经网络,在管道上激励并采集导波信号,实现从导波频域信息到速度图的反演,进而通过频散曲线映射为管壁的厚度图,并利用数值仿真和物理实验,验证了所提出反演算法的成像效果。

1 管道中的声场理论

1.1 管道的近似平板导波模型

管道壁上的任意一点 P 位置可以表示为 (x, y, z) ,

其中 $x^2 + y^2 = r^2$,为管道半径,这个约束条件限制了管道壁的一个自由度。沿着轴向线管道可以展开为一个平板,近似平板的长为管道的周长,宽为管道的轴向长度。如图 1 所示,三维坐标系中管道壁上的点 P 可映射到二维坐标系近似平板上的点 P' , (x', y') 。

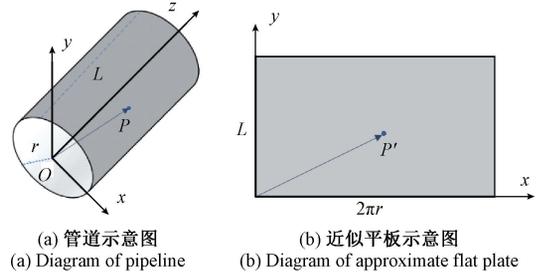


图 1 管道的近似平板转换图

Fig. 1 Approximate plate conversion diagram of pipeline

其两点的几何坐标映射关系为:

$$x = r \cos \frac{x'}{2\pi r}, y = r \sin \frac{x'}{2\pi r}, z = y' \quad (1)$$

从三维坐标系到二维坐标系的映射关系可以表示为:

$$P' = Tr(P) \quad (2)$$

由于管道的曲率结构,超声导波的传播是各向异性的。而佐治亚理工学院 Liu 等^[18]的研究表明,当管道的壁厚远远小于管道半径时(5%~10%),曲率误差可以忽略不计,即满足此条件下,用平板近似管道是合理的,对近似为平板的管道模型中 Lamb 波传播特性的研究从 20 世纪初兴起^[19-20]。平板结构中超声导波的传播规律,依循 Rayleigh-Lamb 方程,使用管道的材料和形状信息计算出近似平板的 Lamb 波的频散特性曲线后,就可以获得在特定激励频率和管壁厚度处的导波选定模态的相速度:

$$c(P) = c'(P') = c'(Tr(P)) = F(f \times d(Tr(P))) \quad (3)$$

其中, F 表示超声导波特定模态的频散特性曲线映射方程。经过上述分析,管道壁上传感器的三维位置坐标,可被映射为二维坐标系上的一点。

1.2 二维声波正演理论

正演模型是指从源的特性推导出场的分布特性,当板材或者管道等结构的物理参数确定后,就可以通过物理波动方程获得材料中的波场信息,这是从波场信息推导模型特性的反演过程的理论基础。弹性波和声波的物理模型,可以用矩阵形式的偏微分方程表示,在时间域,各向同性均匀介质中二维声波或者弹性波的描述方程,可以表示为:

$$\mathbf{H}(x)\ddot{p}(x,t) + \lambda(x)\dot{p}(x,t) + \mathbf{J}(x)p(x,t) = s(x,t) \quad (4)$$

其中, x 表示空间坐标; t 指的是时间值; $p(x, t)$ 表示声学模型中的压力波场; $\lambda(x)\dot{p}(x, t)$ 表示的是吸收声能, 以防止其从试块边界反射的阻尼层; $\mathbf{H}(x)$ 和 $\mathbf{J}(x)$ 分别表示质量矩阵和刚度矩阵; 最后一项 $s(x, t)$ 指代激励点源项。模型初始的边界条件定义如下:

$$\begin{cases} p(x, t=0) = 0 \\ \partial_t p(x, t=0) = 0 \end{cases} \quad (5)$$

式(4)描述的二维波动方程不存在解析解, 所以, 为了解式(4)中的时域偏微分方程, 学者们研究出了若干种不同的数值计算方法, 以求得波场的数值解, 其中比较典型的包括有限元法、有限差分法等。

对式(4)中的压力波场和激励点源项进行傅里叶变换, 即:

$$\begin{cases} P(x, \omega) = \int_{-\infty}^{+\infty} p(x, t) e^{-i\omega t} dt \\ S(x, \omega) = \int_{-\infty}^{+\infty} s(x, t) e^{-i\omega t} dt \end{cases} \quad (6)$$

其中, ω 表示角频率, 则可以从式(4)中推导出频域中的二维波动方程:

$$Q(x, \omega)P(x, \omega) = S(x, \omega) \quad (7)$$

其中, $Q(x, \omega)$ 表示由试块特性和频率决定的复阻抗矩阵, 定义为 $Q = -\omega^2 \mathbf{H} + i\omega \lambda + \mathbf{J}$ 。频域中的二维波动方程如式(7)所示, 是一个线性矩阵方程, 其中系数矩阵 $Q(x, \omega)$ 可分解为一个下三角矩阵与一个上三角矩阵的乘积, 即可直接求解 $P(x, \omega)$ 。对复阻抗矩阵的 LU 因子分解, 只需要进行一次, 并将其结果存储起来, 就可以计算不同发射源激励下的压力波场, 可避免重复计算, 能节省计算时间, 较为高效, 非常适用于多发射源模型。

方程中的矩阵 \mathbf{H} 、 \mathbf{J} 和 \mathbf{Q} , 都是从反映模型特性的参数中得到的, 一个常用的参数是导波波速。求解以上方程, 就可以得到从模型参数到压力波场的非线性映射, 定义为:

$$P = T(s) \quad (8)$$

其中, T 表示波动模型的正演函数; s 定义为 $s(x) = 1/c(x)^2$, 表示模型的平方慢速; $c(x)$ 表示不同空间点的波速。实际操作中, 会安装传感器对波场信息进行采样。对于一个激励, 可以通过投影算子, 从压力波场中提取离散化的波场数据 $D(s)$, 即:

$$D(s) = E_{p_{ij}} P = E_{p_{ij}} T(s) \quad (9)$$

基于以上二维波动理论, 在模型的导波波速分布图以及激励源与接收传感器的位置确定后, 即可通过矩阵运算求解波场的频域信息, 实现从模型导波速度分布图到波场的映射。

图 2 为管壁上含有一个随机腐蚀缺陷的管道正演得到的声场结果, 图 2(a) 为管壁厚度图, 可以看出含有腐蚀缺陷位置的厚度比完好区域的厚度小; 图 2(b) 为管壁

导波速度图, 其中各个网格点的速度值通过对应位置的厚度在频散曲线中的映射得到; 图 2(c) 和 (d) 分别为换能器采集到的声场频域信息的实部和虚部, 声场信息是管壁厚度图与相速度图的对应映射。

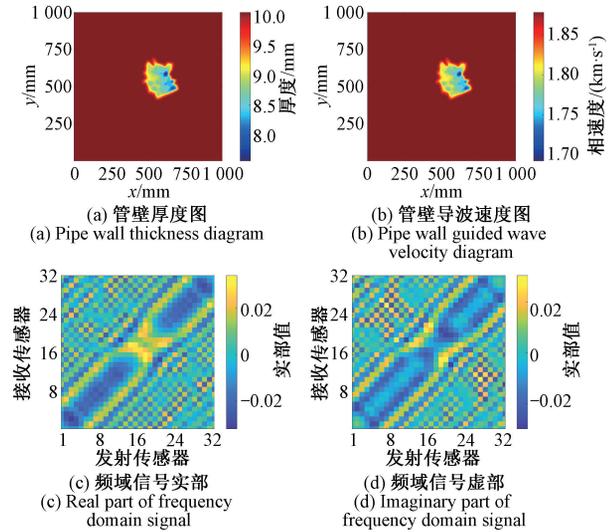


图 2 有缺陷管道正演结果

Fig. 2 Forward modeling results of defective pipelines

2 物理信息嵌入式卷积神经网络

2.1 正演卷积神经网络

提出的反演神经网络, 需要将正演模型嵌入到迭代网络中, 以计算正演数据与观测数据之间的残差。网络的训练过程, 需要进行大量样本的正演计算, 如果正演模型直接嵌入, 反演神经网络的训练时间会非常长。所以, 为提高训练效率, 本文提出了一种预训练的卷积神经网络, 以代替有限差分数值方法解得的二维正演模型。

神经网络是受动物大脑的生物神经网络结构启发构建的一种连接计算模型, 随着信息时代大数据的发展和计算机硬件性能的升级, 神经网络由于其具有强大的学习能力受到广泛关注。神经网络结构中含有大量节点, 节点之间通过权重系数连接, 每个节点是由输入数据、权重、偏差值等信息组成的线性回归模型, 输出还需要经过非线性激活函数, 即:

$$Y_j = \mathbb{R}(y_j) = \mathbb{R}\left(\sum_{i=1}^n w_{ij} X_i + bias_j\right) \quad (10)$$

其中, w_{ij} 表示的是节点 i 与 j 之间的连接权重; X_i 表示节点 i 的输出; $bias_j$ 指的是节点 j 的偏移值; \mathbb{R} 表示激活函数, 所有的输入与相应的权重系数相乘之后求和, 再加上偏移系数, 该值经过一个激活函数, 就得到该节点的输出, 此节点的输出又成为下一层神经节点的输入。连接权重和偏移值会在训练学习过程中不断调整更新, 以使网络更精确地预测结果。训练神经网络过程中使用样

本数据,是为了确定预测值与目标输出之间的差异,需要用损失函数来评估网络的精度,损失函数通常被定义为均方误差,即:

$$Loss = MSE = \frac{1}{n} \sum_{i=1}^n (Q_i - \hat{Q}_i)^2 \quad (11)$$

其中, i 表示样本编号; n 表示样本数量; Q_i 表示第 i 个样本的真实值; \hat{Q}_i 表示神经网络的预测值。每一轮训练通过梯度下降算法更新网络中的连接权重和偏移值,实现误差的反向传播,以最小化损失函数,经过网络中参数的不断调整,神经网络产生的预测值与目标输出之间越来越接近,一定轮次的训练,或者损失函数低于一定阈值之后停止训练,神经网络即可以实现此模型从输入到输出的映射预测。

相比于全连接神经网络,卷积神经网络使用较少的参数来表征模型,且通过构建深度学习网络,其学习能力和预测表现可与全连接神经网络相当。

典型的卷积神经网络的结构如图 3 所示,在输入层到输出层的映射中,卷积神经网络的隐藏层通常由卷积层、池化层和全连接层组成。

单个卷积层含有多个通道,输出数据的每个点都是由卷积核和该点周围输入数据的卷积运算得到,卷积核通常是包含权重系数和偏差的二维矩阵,实现了权值共享,以减少网络参数数量,也可以提取局部区域的数据特征,除此之外,非线性激活函数也应用于卷积层,如 sigmoid 函数、ReLU 函数等。

池化层通过预定的池化函数,将单个点的结果替换

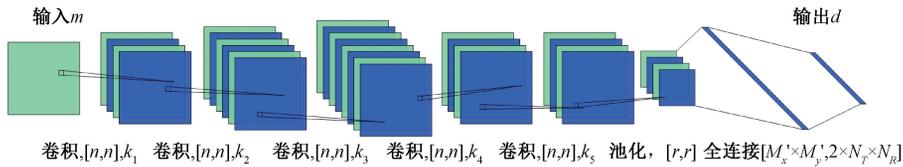


图 3 正演卷积神经网络的结构

Fig. 3 Structure of forward convolution neural network

在训练过程中,正演网络输入数据是模型的速度分布图 m ,输出数据是传感器采集到的波场数据 d_T ,代理卷积神经网络表示为 N_F ,由代理神经网络计算得到的数据为 d_F ,损失函数定义为从代理正演神经网络计算得到的数据与有限差分求解波动方程得到的波场频域数据之间的均方误差:

$$Loss(N_F) = \sum_{i=1}^N \| N_F(m_i) - d_T^i \|_2 = \sum_{i=1}^N \| d_F^i - d_T^i \|_2 \quad (13)$$

需要注意的是,传感器提取的频域信息是复数,故其输出数据分为实部和虚部两部分,因此,神经网络的输出数据量为 $2 \times N_T \times N_R$ 。

为其相邻区域的特征数据统计,可以压缩模型的数据量,防止神经网络的过拟合,常见的池化函数包括最大池化和均值池化等。

重塑层实现了一维与二维数据之间的转换,全连接层实现了从隐藏层到输出层的非线性映射,通常包含一层或者两层,需要通过输入输出数据的大小来确定全连接层。

基于局部感受野的卷积核极大地减少了网络参数的数量,同时,通过深度网络学习,有效地提取了模型特性,因此,卷积神经网络在深度学习得到了广泛应用。

通过式(7)定义的超声导波正演模型,对于每个速度图模型 m ,确定了激励源位置之后,可以得到每个传感器采集到的波场信号频域信息。正演神经网络的输入数据为网格化的速度分布图,维度为 $M_x \times M_y$,本文使用 N_T 个激励源和 N_R 个接收传感器,并将提取的信号频率设置为固定值,声场正演得到的数据维度为 $N_T \times N_R$ 。

正演神经网络的具体结构和参数如图 3 所示,包括了 5 层卷积层,1 层池化层,1 层全连接网络,其中二维卷积层的卷积核为 $n \times n$ 的矩阵,每一层含有 k_i 个通道,步幅为 1,并使用了填充,以保证输出与输入维度保持一致,激活函数为 LeakyReLU,定义如下:

$$y = \max(0, x) + leak \times \min(0, x) \quad (12)$$

其中, $leak$ 表示函数在负值区域的非零斜率,正数值保持不变,负值乘以一个较小的固定常数。池化函数选择平均池化,池化窗口大小为 $r \times r$ 。

2.2 残差反演子网络

在每个迭代层中,本文构建了一个残差反演卷积子网络,可实现从 d_{k-1} 与观测到的声场数据 d 之间残差 Δd 到相速度残差矩阵 Δm_k 的映射,其结构如图 4 所示,其中,包含 1 个全连接层、1 个上采样层和 5 个卷积层,该神经网络中的超参数与 2.1 节中的代理正演卷积神经网络中的含义相同,上采样层采用双线性插值算法, r 指定输出尺寸相对于输入的倍数。

2.3 物理信息嵌入式反演网络

如图 5 所示,物理信息嵌入式反演网络的初始输入为传感器采集的波场数据,表示为 d 。在第 k 个迭代层,上一层输出的相速度分布图 m_{k-1} 设置为输入,通过上述

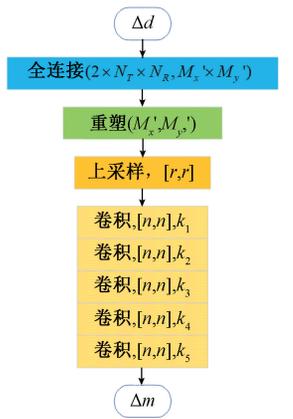


图 4 残差反演子网络的结构

Fig. 4 Structure of residual inversion subnetwork

预训练的代理正演神经网络,即可获得相应的声场数据 d_{k-1} ,通过该层的残差反演子网络可得到残差相速度分布图 Δm_k ,最后,可得到该迭代层对应的相速度分布图 $m_k = m_{k-1} + \Delta m_k$,此速度图又作为下一迭代层的输入。第 1 个迭代层的输入为预设的初始速度分布图。

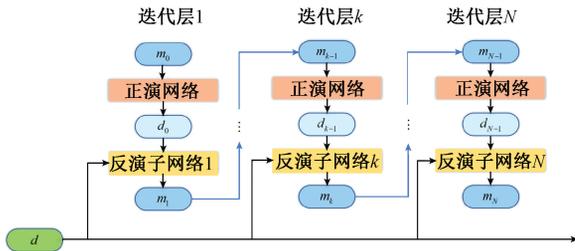


图 5 物理信息嵌入式反演网络的结构

Fig. 5 Structure of physics embedded inversion network

包含若干迭代层的整体反演算法的公式如下所示:

$$\begin{aligned}
 d_0 &= \Psi_F(m_0) \\
 m_1 &= m_0 + \Psi_I^1(d - d_0) \\
 &\vdots \\
 d_k &= \Psi_F(m_k) \\
 m_{k+1} &= m_k + \Psi_I^{k+1}(d - d_k) \\
 &\vdots \\
 d_{N-1} &= \Psi_F(m_{N-1}) \\
 m_N &= m_{N-1} + \Psi_I^N(d - d_{N-1})
 \end{aligned} \tag{14}$$

其中, m_0 为试块的初始速度分布图; m_k 和 d_k 为各迭代层对应的速度分布图和声场数据; Ψ_F 是前一节中预训练的代理正演神经网络,以实现从速度图到声场数据的映射。嵌入到每个迭代层的正演网络,具有相同的结构和参数,并且在反演训练过程中该网络参数保持不变,导波模型的物理信息通过这种方式集成到反演网络中。 $\Psi_I^k(k = 1, 2, \dots, N)$ 是每个迭代层中的残差反演子网络,

且每一层的反演子网络的结构相同,都如图 4 所示,但网络参数保持独立且彼此不同,训练整体反演网络的过程中, Ψ_I^k 中的连接权重和偏移值不断更新,以最小化损失函数。如图 5 所示,一个正演网络和一个残差反演子网络构成了一个迭代层,每一个迭代层的输出作为下一层的输入,若干个迭代层前后连接,即构建成了物理信息嵌入式反演神经网络,可实现从传感器声场数据到速度分布图的映射。整个反演神经网络的损失函数,被定义为最后一个迭代层输出的速度分布图与真实速度图之间的均方误差:

$$Loss(\mathbb{N}_I) = \sum_{i=1}^r \| m_N^i - m^i \|_2 \tag{15}$$

3 数值实验

3.1 仿真模型设置

仿真中的铝管半径为 15.9 cm,径向长度为 1 m,管壁厚度为 10 mm,管材的泊松比、杨氏模量、密度的材料特性提供如表 1 所示。如图 6 所示,管道模型的管壁上存在着位置、形状、大小和深度等都不规则的腐蚀缺陷,发射传感器阵列放置在距离管道左端面 10 cm 的位置,沿着圆周方向均匀分布,接收传感器阵列距离管道右端面 10 cm,也沿着圆周方向均匀分布。

表 1 仿真验证用铝管材料的参数

Table 1 Material parameters of simulated aluminum pipe		
泊松比	杨氏模量	密度
0.33	70.8 GPa	2 700 (kg · m ⁻³)

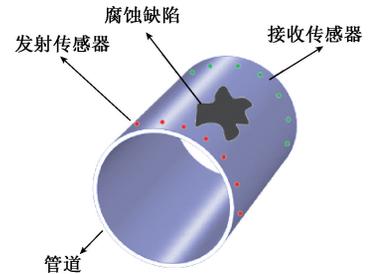


图 6 管道仿真模型示意图

Fig. 6 Diagram of pipeline simulation model

为了得到最佳的反演效果,应该选择激励信号的中心频率,使得导波模式的频散最强,使用近似平板计算得到的管道频散特性曲线如图 7 所示,可见,其中 A0 模式的超声导波在 50 kHz 处对厚度变化十分敏感,因此,本文工作中就将激励信号选择为以该频率为中心的 Ricker 小波。

仿真验证模型中,管壁的尺寸为 1 m × 1 m,将其网格化为 250 × 250 的网格布局,其中每个网格的尺寸为

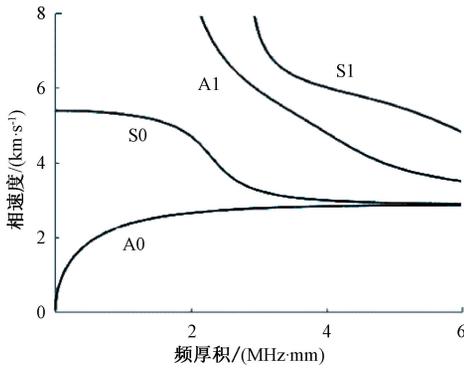


图 7 频散曲线图

Fig. 7 Dispersion curve

4 mm×4 mm, 在确定厚度信息的条件下, 可以通过管道的频散特性曲线获得每个网格点处的相速度, 管道速度图用二维矩阵表示。发射传感器的数量 N_T 和接收传感器的数量 N_R 都是 32 个。其中, 一个发射传感器激励声信号, 每个位置的接收传感器即采集该处的超声导波信号, 获得声场的频域信息, 正演得到的声场数据包含 $N_T \times N_R$ 个复数。根据前述的导波模型, 通过求解频域波动方程, 可从管道的速度分布图中获得波场的频域数据。本文生成了一个包含 1 024 个样本的训练集和一个包含 256 个样本的验证集, 每个样本由带腐蚀缺陷管壁的速度分布图 m_{true} 和对应的波场数据 D_{true} 组成。对于每个管道模型, 除了管道上的腐蚀缺陷外, 管道不同位置的各方面特性, 例如材质特性和几何形状都是相同的; 而腐蚀缺陷的位置、形状、厚度等, 则都是随机的, 且互不相同。除此之外, 本文还生成了一个独立的测试集, 以验证物理信息嵌入式卷积神经网络反演成像的泛化效果。

3.2 网络超参数的选择

神经网络的结构和训练, 由超参数进行配置, 包括学习率、批量大小、网络层数、激活函数等。超参数的选择, 对神经网络的训练速度和预测精度具有很大的影响。对于物理信息嵌入式卷积神经网络, 在其他超参数固定的情况下, 本文研究了卷积核尺寸、卷积层通道数量对管道厚度成像精度的影响, 为了优化此神经网络模型, 本文比较了 3 种不同超参数组合的表现, 这 3 种网络模型的超参数配置提供如表 2 所示。

表 2 卷积神经网络的不同超参数组合

Table 2 Different hyperparameter combinations of convolution neural networks

组合	n	k_1	k_2	k_3	k_4	k_5
组合 1	3	16	8	4	2	1
组合 2	5	16	8	4	2	1
组合 3	5	32	16	8	4	1

为了比较不同组合超参数下神经网络的成像效果, 本文以训练集和验证集的均方误差和平均反演精度来定量评估每种超参数组合的表现, 其中, 反演精度被定义为真实图像与反演结果之间的 Pearson 系数, 即:

$$\mu = \frac{Cov(m_{true}, m_{inv})}{\sqrt{Var[m_{true}] Var[m_{inv}]}} \quad (16)$$

所得到的仿真验证结果, 如表 3 所示。

表 3 网络的均方误差和反演精度

Table 3 MSE and inversion accuracy of networks

组合	均方误差		反演精度/%	
	训练集	验证集	训练集	验证集
组合 1	6.15×10^{-4}	1.73×10^{-4}	72.03	69.04
组合 2	1.49×10^{-4}	1.04×10^{-4}	92.27	84.18
组合 3	1.05×10^{-4}	0.98×10^{-4}	94.91	86.47

比较不同组合的结果, 可以发现, 随着卷积核尺寸和卷积层通道数量的增加, 物理信息嵌入式反演神经网络在训练集和验证集上的均方误差均会减小, 反演精度提高; 具体还看出, 相比组合 1, 组合 2 增大了卷积核尺寸, 量化指标具有很大的提升; 而组合 3 增加了各卷积层的通道数量, 成像表现有所提升, 但提升的并不大。在此导波反演物理模型中, 超参数卷积核尺寸比卷积层通道数量影响大。经过比较注意到, 组合 3 具有最小的训练均方误差和最高的反演精度, 图 5 所示的物理信息嵌入式神经网络中, 卷积核大小设置为 5, 每个卷积层的通道数分别为 1、32、16、8、1。训练过程中, 正演网络和反演网络的均方误差如图 8 所示, 需要说明的是, 该值为所有样本的均方误差之和, 训练集样本数量为 1 024, 验证集样本数量为 256, 训练集样本数量为验证集的 4 倍, 所以, 损失函数图中验证集所有样本的均方误差和比训练集的小。从图像曲线中可以看出, 训练集和验证集中, 正演卷积神经网络和物理信息嵌入式反演神经网络的损失整体一直在下降, 特别地, 训练过程中, 验证集的损失没有增加, 这表明神经网络的训练不存在过拟合。

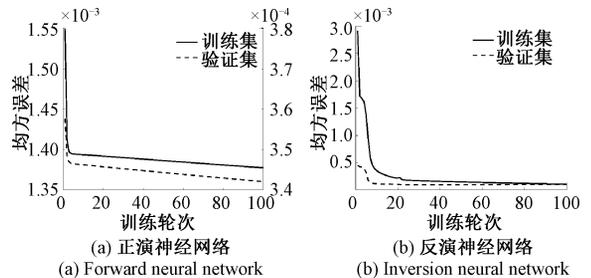


图 8 损失函数图

Fig. 8 Loss function diagram

3.3 成像结果

采用组合 3 的超参数组合,构建代理卷积正演神经网络完成训练之后,对 1 024 个训练样本和 256 个验证样本进行声场预测,传感器采集的导波信号的频域信息 Pearson 相关系数如表 4 所示,可见,所搭建的卷积神经网络较为精确地实现了从速度图到传感器数据的映射。

表 4 正演神经网络精度

Table 4 Accuracy of forward neural network (%)

	实部精度	虚部精度
训练集	82.95	79.24
验证集	82.69	79.18

随机选取了 4 个测试样本,其真实厚度图和经过反演网络得到的厚度图的比较结果,如图 9 所示,其中,每组图像从左往右依次展示了管壁的真实厚度图和物理信息嵌入式神经网络重建的厚度图。

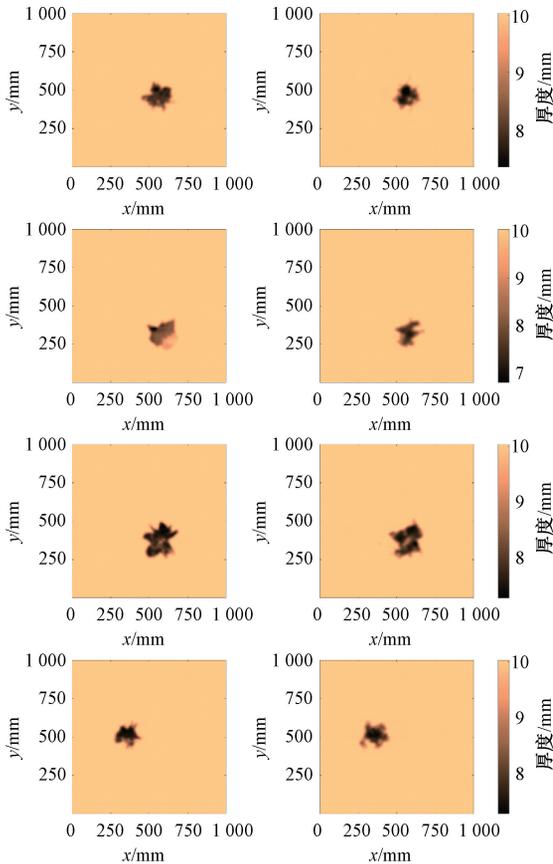


图 9 4 组样本的反演结果(编号 8、22、58、90)

Fig. 9 Inversion results of four groups of samples (No. 8, 22, 58, 90)

从成像结果中可以看出,腐蚀缺陷的位置处的管壁厚度会减小,表明物理信息嵌入式卷积神经网络可以准确地反映腐蚀特性,如位置、大小和厚度等信息,图像对

比表明,物理信息嵌入式神经网络可以实现管壁腐蚀缺陷的高精度量化成像。此外,100 个测试样本的成像时间为 92 s,单个样本反演耗时约为 0.92 s,显示了良好的实时性。

反演网络训练完成后,1 024 个训练样本、256 个验证样本和 100 个测试样本的成像精度如表 5 所示。相比训练集,验证集和测试集的反演精度虽然有所下降,但仍然比较精确。从数值结果可以看出,此方法实现了从声场数据到管壁速度图的高精度重建,之后通过频散特性曲线将导波速度映射成厚度,即可实现对管壁厚度图的成像。

表 5 反演精度

Table 5 Inversion accuracy

	训练集	验证集	测试集
平均反演精度/%	94.91	86.47	87.37

4 管道实验

4.1 实验管道

参照第 3 章的管道仿真模型,实验用到的铝管材质为 6061,外壁直径为 320 mm,内壁直径为 300 mm,管壁厚度为 10 mm,周向展开长度约为 1 m,径向长度为 1 m,如图 10 所示。

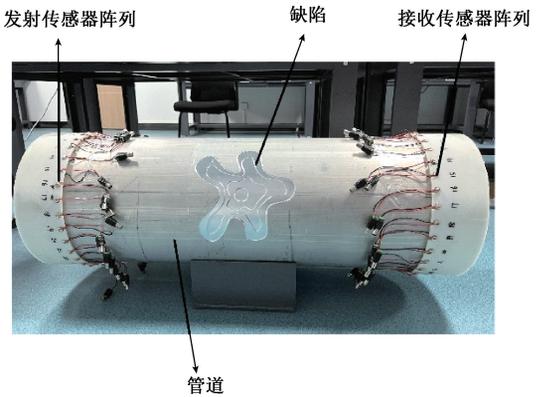


图 10 管道实验装备

Fig. 10 Equipment for pipeline experiment

实验中,用于激励和接收超声导波的传感器为压电传感器,其基于压电效应而制成,可实现电能和机械能的转换。实验中使用的压电陶瓷换能器材料为 PZT-5H,直径 10 mm,高 12 mm,上端面为正极,下端面为负极,负极的导电体延伸到侧面一点,使用镀锡铜导线焊接压电传感器的正负极,正极直接焊接在圆柱陶瓷的上端面,负极导线焊接在侧面的负极点处。实验与仿真的条件是相对应的,使用了 64 个同型号的压电传感器,其中 32 个为发射传感器,32 个为接收传感器。

以电化学腐蚀方式,可在管道壁上生成真实的腐蚀缺陷,但其操作难度较高,腐蚀时间较长,腐蚀结果不可控,缺陷的形状与厚度不规则,难以提取缺陷的量化信息得到真实的厚度图。所以,为了评估物理信息嵌入式反演神经网络的成像效果,本文模拟腐蚀厚度变化,使用 SolidWorks 预置了阶梯状缺陷模型,使用四轴加工中心在管壁上进行加工。管壁上的缺陷如图 10 所示,包含 4 层台阶,最中间的缺陷为一个直径 32 mm 的圆,往外为 3 个面积依次扩大的不规则形状,可通过曲线样条点提取形状信息,从最中间向外的曲面上,管壁的厚度依次为 6、7、8、9 mm。

4.2 超声导波收发系统

实验中使用的超声导波信号激励和采集设备是多通道收发系统 CUI-16,如图 11 所示。上位机是使用 LabVIEW 软件编写的可视化界面,可设置发射信号的参数;显示各通道采集的信号波形;采样数据,等。下位机使用多通道板卡制作,可接收上位机指令、实现高压信号发射与电压信号的接收和采集。设备有 16 个发射通道和 16 个接收通道,发射通道激励的频率范围为 10 kHz~25 MHz,激励电压可调范围为 0~350 V。实验中激励的信号为频率为 60 kHz 的 Ricker 波,激励电压为 100 V。接收通道的采样频率范围为 1.25~50 MHz,采样点最多设置为 10 000,各通道通过 BNC 接口与发射传感器或者接收传感器连接,实现电能和压电片机械能的转换。



图 11 多通道超声导波收发系统

Fig. 11 Multi-channel ultrasonic guided wave transceiver system

4.3 数据处理

接收通道的采样频率为 12.5 MHz,采样点为 10 000 个,采集的信号时长为 800 μs,图 12 为 16 号接收传感器接收到的由 1 号发射传感器激励出声波信号的波形,可以看出,其存在多个波包,为了获得第 1 个到达的 A0 模式导波信号的频域信息,首先进行了数据处理,以提取出该模式的波形。

管道上发射传感器 (Srcx,Srcy) 与接收传感器 (Recx,Recy) 之间的距离为:

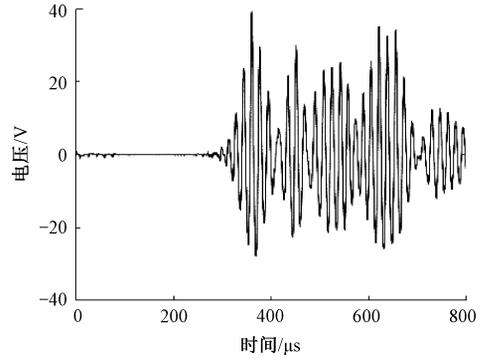


图 12 采集信号

Fig. 12 Signal collected

$$Dis = Abs((Srcx - Recx)^2 + (Srcy - Recy)^2) \quad (17)$$

A0 模式导波的群速度 $v = 3\,000\text{ m/s}$,可以得到波包到达的时间:

$$t = Dis/v \quad (18)$$

为了精确地提取到达时间范围内的波包,对原始数据进行希尔伯特变换,将时域离散信号转换为解析信号输出,可查找包络信号的峰值位置,在原始信号上添加梯形时间窗口,即可提取出仅含选定模式的波包信号。以上信号经过梯形窗口提取后的波形如图 13 所示。

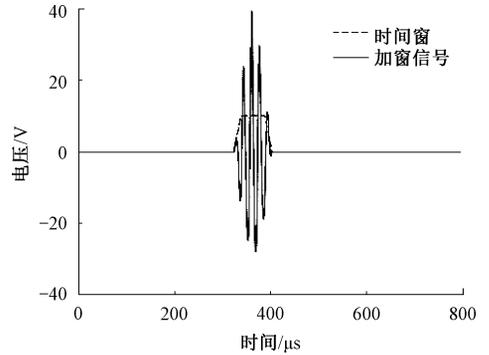


图 13 提取的 A0 模式导波信号

Fig. 13 Extracted A0 mode guided wave signal

接着,对提取后的波形进行傅里叶变换,获得频谱信号在特定频率处的复数值,如此,便将 32×32 个时域信号转换为为了频域信号。

4.4 成像结果

在仿真正演数据基础上,使用不同频率的实验导波信号丰富了数据集,将归一化的频域信息作为训练完成的物理信息嵌入式卷积神经网络的输入,可得到管道缺陷的厚度成像结果,如图 14 所示。

从成像结果可以看出,从导波数据中反演得到的缺陷与真实的缺陷之间,在位置、形状和厚度上显示出有良好的一致性,厚度图的均方误差为 0.005 7,相关系数为 90.34%。

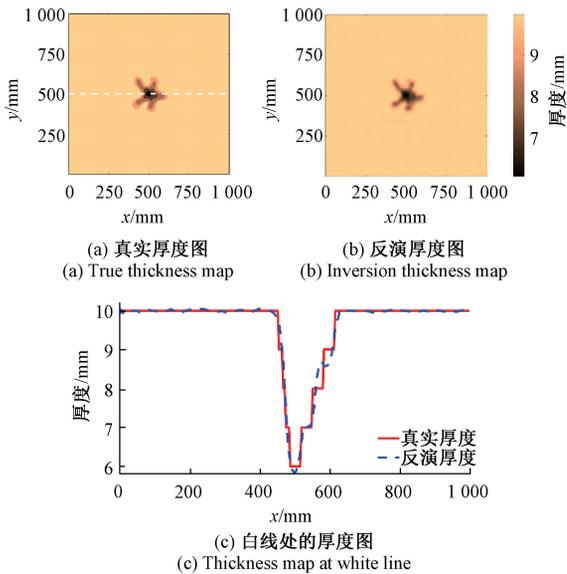


图 14 管道实验成像结果

Fig. 14 Imaging results of pipeline experiment

5 结 论

本文提出了物理信息嵌入式卷积神经网络,将超声导波物理理论与深度学习方法结合起来,实现了从声场信号到管壁厚度图的反演。运用二维波动理论求解管道中的声波正演模型并生成用于训练的数据集,搭建了神经网络,并比较了不同超参数组合的表现以优化网络性能,仿真测试集的成像结果相关度达到了 87.37%,在加工了不规则缺陷的管道上,对采集到的信号进行了反演,得到图像的均方误差为 0.0057,表明反演得到的厚度图与真实厚度图之间的一致性较高。仿真验证和物理实验结果都体现了物理信息嵌入式卷积神经网络在管道厚度定量成像上良好的表现,表明该算法在无损检测领域具有应用潜力。

参考文献

[1] 高鹏. 2021 年中国油气管道建设新进展[J]. 国际石油经济, 2022, 30(3): 12-19.
GAO P. New progress in China's oil and gas pipeline construction in 2021 [J]. International Petroleum Economics, 2022, 30(3): 12-19.

[2] 王学彬, 王黎明, 吴博, 等. 管道三维漏磁检测仿真分析及研究 [J]. 国外电子测量技术, 2020, 39(8): 29-33.
WANG X B, WANG L M, WU B, et al. Simulation analysis and research on three-dimensional magnetic flux leakage detection of pipeline [J]. Foreign Electronic Measurement Technology, 2020, 39(8): 29-33.

[3] RAKVIN M, MARKUČIĆ D, HIŽMAN B. Evaluation of pipe wall thickness based on contrast measurement using Computed Radiography (CR) [J]. Procedia Engineering, 2014, 69: 1216-1224.

[4] 周兆明, 杜铁成, 万夫, 等. 多频涡流检测连续油管焊缝晶粒尺寸的试验研究 [J]. 电子测量与仪器学报, 2022, 36(2): 188-195.
ZHOU ZH M, DU T CH, WAN F, et al. Experimental study on multi-frequency eddy current detection of grain size of coiled tubing offset weld [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(2): 188-195.

[5] 景丽暄, 耿明, 凌人, 等. 挂轨式管道泄漏检测机器人设计 [J]. 电子测量技术, 2022, 45(14): 55-58.
JING L X, GENG M, LING R, et al. Design of rail-mounted pipeline leak detection robot [J]. Electronic Measurement Technology, 2022, 45(14): 55-58.

[6] 黄祺凯, 石文泽, 卢超, 等. 基于编码压缩的钢板电磁超声 Lamb 波检测方法研究 [J]. 仪器仪表学报, 2022, 43(2): 117-127.
HUANG Q K, SHI W Z, LU CH, et al. Research on steel plate electromagnetic ultrasonic Lamb wave detection method based on encoding compression [J]. Chinese Journal of Scientific Instrument, 2022, 43(2): 117-127.

[7] HE J, ROCHA D C, SAVA P. Guided wave tomography based on least-squares reverse-time migration [J]. Structural Health Monitoring, 2020, 19(4): 1237-1249.

[8] CANTERO-CHINCHILLA S, CHIACHÍO J, CHIACHÍO M, et al. A robust Bayesian methodology for damage localization in plate-like structures using ultrasonic guided-waves [J]. Mechanical Systems and Signal Processing, 2019, 122: 192-205.

[9] WANG B, SHI W, ZHAO B, et al. A modal decomposition imaging algorithm for ultrasonic detection of delamination defects in carbon fiber composite plates using air-coupled Lamb waves [J]. Measurement, 2022, 195: 111165.

[10] HUTHWAITE P, SIMONETTI F. High-resolution guided wave tomography [J]. Wave Motion, 2013, 50(5): 979-993.

[11] RAO J, RATASSEPP M, FAN Z. Guided wave tomography based on full waveform inversion [J]. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 2016, 63(5): 737-745.

[12] LIN M, LIU Y. Guided wave tomography based on supervised descent method for quantitative corrosion imaging [J]. IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control, 2021, 68(12): 3624-3636.

- [13] TONG J, LIN M, WANG X, et al. Deep learning inversion with supervision: A rapid and cascaded imaging technique[J]. *Ultrasonics*, 2022, 122: 106686.
- [14] ZHANG B, CHEN Z, YANG D, et al. An intelligent ultrasonic guided wave deep imaging detection method considering the propagation characteristics of each direction[J]. *Measurement Science and Technology*, 2022, 34(1): 014006.
- [15] HUANG L, HONG X, YANG D, et al. Energy mapping deep transfer learning method for aluminum plate back damage detection using laser ultrasonic guided waves[J]. *Measurement*, 2022, 205: 112167.
- [16] LI L, WANG L G, TEIXEIRA F L, et al. DeepNIS: Deep neural network for nonlinear electromagnetic inverse scattering [J]. *IEEE Transactions on Antennas and Propagation*, 2018, 67(3): 1819-1825.
- [17] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations [J]. *Journal of Computational Physics*, 2019, 378: 686-707.
- [18] LIU G, QU J. Guided circumferential waves in a circular annulus[J]. *Journal of Applied Mechanics-transactions of The Asme*, 1998, 65(2): 424-430.
- [19] HUTHWAITE P, SEHER M. Robust helical path separation for thickness mapping of pipes by guided wave tomography [J]. *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, 2015, 62(5): 927-938.
- [20] WANG Z, HUANG S, 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*, 2020, 70: 1-10.

作者简介



陈世利, 分别在 1997 年和 2003 年于天津大学获得学士和博士学位, 现为天津大学精密仪器与光电子工程学院副教授, 主要研究方向为无损检测技术、管道泄露检测。
E-mail: slchen@tju.edu.cn

Chen Shili received his B. Sc. and Ph. D. degrees both from Tianjin University in 1997 and 2003, respectively. Now he is an associate professor in the School of Precision Instruments and Opto-Electronics Engineering at Tianjin University. His main research interests include non-destructive testing and pipeline leak detection.



吕玲玲, 2020 年于天津大学获得学士学位, 现为天津大学精密仪器与光电子工程学院硕士研究生, 主要研究方向为超声导波和智能无损检测。

E-mail: 3016210103@tju.edu.cn

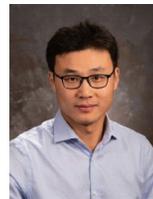
Lyu Lingling received her B. Sc. degree in 2020 from Tianjin University. Now she is a M. Sc. candidate in the School of Precision Instruments and Opto-Electronics Engineering at Tianjin University. Her main research interests include ultrasonic guided wave and intelligent nondestructive testing.



童君开, 2017 年于天津大学获得学士学位, 2020 年于天津大学获得硕士学位, 现为天津大学精密仪器与光电子工程学院博士研究生, 主要研究方向为超声导波和智能无损检测。

E-mail: 3016210103@tju.edu.cn

Tong Junkai received her B. Sc. degree in 2017 from Tianjin University, received his M. Sc. degree in 2020 from Tianjin University. Now he is a Ph. D. student in the School of Precision Instruments and Opto-Electronics Engineering at Tianjin University. His main research interests include ultrasonic guided wave and intelligent nondestructive testing.



刘洋 (通信作者), 2014 年于美国宾夕法尼亚州立大学获得博士学位, 现为天津大学精密仪器与光电子工程学院教授, 主要研究方向为超声传感器与超高分辨率成像技术。

E-mail: liuyang5199@gmail.com

Liu Yang (Corresponding author) received his Ph. D. degree from Pennsylvania State University in 2014. Now he is a professor in Tianjin University. His main research interests include ultrasonic sensor and ultra-high resolution imaging technology.