

基于物理信息神经网络的激光超声波场重构

宋英凡¹, 李 阳¹, 徐 斌¹, 邹 云¹, 杨 亮², 叶中飞³, 静丰羽⁴

(1. 郑州大学机械与动力工程学院 郑州, 450001)

(2. 中国科学院金属研究所 沈阳, 110016)

(3. 国网河南省电力公司电力科学研究院 郑州, 450052)

(4. 中国电建集团河南电力器材有限公司 漯河, 462000)

摘要 针对激光超声技术在结构健康监测中由于采样位置的物理限制和环境噪声干扰导致波场数据不完整的问题,提出了一种基于物理信息神经网络(physics-informed neural networks, 简称 PINNs)的方法,用于从有限的稀疏波场数据中重构完整的波场信息。首先,结合激光超声的物理特性,采用 PINNs 模型将波动方程作为物理约束嵌入神经网络中,通过将物理规律与数据驱动模型相结合,实现对不完整波场的高精度重建;其次,通过设计有效的损失函数,对波动方程残差与采样数据的拟合误差进行优化,确保网络在低采样率下仍能准确捕捉到波场的特征。实验结果表明:在 1% 的采样率下, PINNs 方法能够重建出完整波场,且重建精度达到 91% 以上;该方法在噪声干扰条件下也表现出了较强的鲁棒性,能够有效抑制噪声的影响,提高重建的精度。

关键词 物理信息神经网络;激光超声;兰姆波;波场重构

中图分类号 TH16;TB551

0 引言

激光超声(laser ultrasonic, 简称 LU)技术作为无损检测领域的前沿技术,凭借非接触式测量、高分辨率以及对材料微观变化的高灵敏度等特性,在材料检测与表征领域展现出显著优势^[1]。然而,其在实际应用中仍面临诸多挑战。由于试件表面存在几何复杂性、遮挡区域或空间受限等问题,激光束往往无法全面覆盖被测区域,导致获取的波场数据呈现空间不连续或局部缺失的特征^[2-3]。在这种情况下,依赖完整波场进行分析的传统方法将难以发挥应有的效果,需要一种能够基于局部观测信息重建完整波场的算法框架,通过采集到的局部波场数据来反演、重构出完整的波场,以提升激光超声技术在复杂环境下的适应性与可靠性。

近年来, Raissi 等^[4]提出的 PINNs 将物理偏微分方程显式嵌入神经网络训练过程中,在提高求解精度与泛化能力的同时,显著减少了对大规模训练数据的依赖。 Karniadakis 等^[5]进一步综述了 PINNs 在多领域中的应用,指出其相较于传统数值方法(如有限元法)在处理复杂边界条件、高维建模等方面具有明显优势。 Shukla 等^[6]将从 PINNs 获得的金属板的

估计波速场用作损伤指数,通过测量金属的超声表面声波来识别金属板中的表面裂纹,证明了使用 PINNs 进行金属结构损伤识别的可行性。颜鑫等^[7]将 PINNs 与超声波波动方程相结合,利用数值计算实验数据,训练出了正向激光超声单模态波场的 PINNs 模型,建立了反向求解激光超声单模态波场参数的 PINNs 模型,并对激光超声波场进行了正向成像和反向参数推演,结果表明,与传统神经网络相比, PINNs 通过引入物理约束显著降低了对数据稀疏性的依赖。上述研究充分表明 PINNs 在求解复杂物理问题方面具备优越性能,尤其在精度、稳定性、计算效率和泛化能力等维度表现出显著优势。然而,现有工作主要集中在仿真数据或单模态波场重建,对于实际工程中不完整波场的高效重构问题,仍缺乏可行且稳健的解决方案。

本研究针对激光超声兰姆波实验中波场数据不完整的问题,提出了一种融合物理约束与数据驱动的 PINNs 重构框架,在 1% 的极低采样率条件下,仅利用 126 个采样点的时空信号解决了不完整激光超声兰姆波波场的重构问题。首先,进行了激光超声实验,获取了一组完整的兰姆波波场数据和一组不完整的兰姆波波场数据;其次,论述了数据预处理方

法,包括对采集到的数据进行归一化、网格划分等操作,以提高数据质量,为后续分析做准备;最后,阐述了PINNs的网络结构设计和超参数选择,对波场重构结果进行了深入讨论及总结。

1 激光超声实验及数据预处理

1.1 激光超声实验

本研究使用的激光超声设备为西安金波检测仪器有限公司有限责任公司研制的LUVI-LL2系统。该系统主要由激光发射器、步进位移平台、超声波探头、带通滤波器、信号采集卡以及PC电脑端等部分构成。图1为激光超声测试系统示意图。




图1 激光超声测试系统示意图
Fig.1 Schematic diagram of the LU testing system

实验中,采用脉冲激光发射器作为激励源,该激光器能发射激光功率为1.20 mJ、脉冲宽度为2 ns的脉冲激光。脉冲激光经透镜聚焦后,通过电动小镜反射至试样表面,从而激励产生超声波信号。使用中心频率为1 MHz的70°超声波斜探头接收超声波信号,并通过带通滤波器减少噪声干扰,以提高信号质量。检测时,将试样放置在二维步进位移平台上,该平台用于实现精确的位置控制和运动轨迹记录。平台控制器通过控制步进电机,使平台沿导轨精确移动,保障了检测过程的高精度和稳定性。激光产生的超声波信号由A/D采集卡记录,数据采样频率为125 MHz,采样长度为4 000点。本研究选用均匀无缺陷的铝合金6061板作为试样材料,试样尺寸为200 mm×200 mm×3 mm。激光超声实验参数见表1。由表可知,激光超声C扫描区域为20 mm×20 mm,扫描间隔为0.2 mm,即扫描区域内有101×101(共10 201)个采样点。

表 1 激光超声实验参数		
Tab.1 Laser ultrasonic experimental parameters		
实验	参数	取值
第 1 组	激光能量/mJ	1.20
	扫描间隔/mm	0.20
	扫描区域/mm ²	20.00 × 20.00
	采样频率/MHz	125.00
	信号长度	4 000.00
第 2 组	激光能量/mJ	1.20
	扫描间隔/mm	1.00 × 2.00
	扫描区域/mm ²	20.00 × 10.00
	采样频率/MHz	125.00
	信号长度	4 000.00

扫描示意图及三维数组矩阵如图2所示。其中,图2(a)为激光超声检测示意图。在检测过程中,超声波斜探头采集扫描区域内所有采样点的超声信号,再将采集的超声信号转换为三维矩阵,如图2(b)所示。该矩阵中, x 坐标和 y 坐标分别对应扫描位置, t 坐标表示信号时间。在扫描区域的每个采样点上都会生成对应的超声信号,时间步长为8 ns。




图2 扫描示意图及三维数组矩阵
Fig.2 Schematic of scanning and 3D array matrix

这些超声信号被存储在一个三维数组中,数组维度为 $[N_x, N_y, N_t] = [101, 101, 4\ 000]$ 。该三维数组总共包含10 201个采样位置,每个采样位置包含4 000个时间信号,单个超声信号的总时长为32 μs 。

完成第1组实验后,在保持试样及探头位置不变的前提下,调整扫描区域和扫描间隔进行第2组实验。第2组实验的扫描区域为第1组实验的中间区域,然后采用更大间隔进行扫描。其中: x 方向的扫描长度设定为20 mm,扫描间隔为1 mm; y 方向的扫描长度设定为10 mm,扫描间隔为2 mm。第2组激光超声实验的具体参数见表1,最终得到的三维数据数组为 $[N_x, N_y, N_t] = [21, 6, 4\ 000]$,如图2(c)所示。

为了可视化完整波场和不完整波场的兰姆波传播情况,本研究从三维数组矩阵中随机选取了第1 940个时间采样点($N_t = 1\ 940$),该点对应时间为15.52 μs 。 $t = 15.52\ \mu\text{s}$ 的可视化波场结果如图3所示。其中,各颜色表示波激励后第15.52 μs 时的法向位移幅值分布。图3(a)展示了完整的兰姆波波场,从图中可以看出其波形规则且连续,波前轮廓清晰可辨。图3(b)展示了不完整的兰姆波波场,从图中可以看出波前发生显著畸变,原本连续规整的波形出现破碎、缺失。




图3 $t = 15.52\ \mu\text{s}$ 的可视化波场结果

Fig.3 Visualization results of wavefield at $t = 15.52\ \mu\text{s}$

本研究将波场重构的问题简化为如图4所示的波场重建模型。第1组实验获取了整个波场数据(图4中的 $a+b+c$ 三部分);第2组实验只获取了部分稀疏波场数据(图4中的 b 部分)。本研究目标为:采用PINNs方法,只利用第2组稀疏波场数据来重构出完整波场,并和第1组完整波场数据进行比对。PINNs在拟合 b 部分波场数据的同时根据波动方程计算出 a 、 c 部分的波场数据,从而完成波形图中特定区域的波场重构任务。




图4 波场重建模型

Fig.4 Wavefield reconstruction model

1.2 实验数据处理

为了让后续的数据处理更加规范且便于分析,本研究对实验数据进行归一化操作,即

$$Z_s = \frac{z}{\max(|z|)} \quad (1)$$

其中: Z_s 为归一化后的数据; z 为实验数据; $\max(|z|)$ 为实验数据中各个数据点的最大绝对值。

归一化的主要目的是将不同尺度的数据映射至统一区间,从而避免由于量纲或幅值差异造成某些特征在模型训练过程中占据主导地位。本研究采用最大值归一化方法,通过将原始数据 z 除以数据的最大绝对值 $\max(|z|)$,将数据映射到 $[-1, 1]$ 区间^[8]。由于该方法计算简单且无需引入额外的学习参数,能够保持数据的相对幅值关系,因此适用于波场重建等深度学习任务的数据预处理^[9]。

考虑到原始采集信号长度较大,若直接处理全部4 000个时间步长,将增加计算量及处理的复杂度。图5展示了 $x = 10\ \text{mm}$ 、 $y = 10\ \text{mm}$ 处的A扫图像。由图可以看出,信号中部分时段包含较多冗余信息或低信噪比数据,这不利于模型训练及分析效果。为降低计算负担并保留主要有效波形响应,对每个空间采样点仅截取第1 500至2 300个时间步长,随后对该区间进行时间域下的等间隔抽样,即每隔1个时间步保留1个数据点,最终获得400个时间步长的信号。这一片段覆盖了主激励响应及其主要




图5 $x = 10\ \text{mm}$ 、 $y = 10\ \text{mm}$ 处的A扫图像

Fig.5 A-scan image at $x = 10\ \text{mm}$ and $y = 10\ \text{mm}$

传播过程,能够为后续波场重建提供充分且高效的数据支持。

2 物理信息神经网络

PINNs通过嵌入物理模型,为训练过程提供了物理约束和先验知识,从而使得模型能够在保证物理一致性的前提下进行学习。在二维介质中传播的声波,尤其是当介质密度变化较小时,其波场的传播特性可以通过二维波动方程来描述^[10],即

$$\frac{\partial^2 u}{\partial t^2} - \alpha^2 \left(\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} \right) - f = 0 \quad (2)$$

其中: u 为未知的位移场; f 为外力; α 为声波速度。

由于在实验中试样没有受到任何外力作用,因此外力 f 被设为0^[8]。

对于均匀无缺陷材料,该波动方程能够较为准确地模拟声波的传播行为,可以有效捕捉声波的传播特性,包括波的频率、波速以及介质的物理属性,适用于激光超声的响应^[6]。

在PINNs中,采用前馈全连接神经网络作为基本架构。基于TensorFlow框架^[11],利用自动微分技术能够高效计算关于自变量的导数。在输入层中,首先对输入数据 z 进行线性变换,然后引入非线性激活函数 σ ,以生成第 l 层的输出 H ,从而逐步完成网络的信息传递与特征提取,即

$$H(z^{l-1}) = \sigma(\mathbf{w}^l z^{l-1} + \mathbf{b}^l) \quad (3)$$

其中: $\mathbf{w}^l$ 、 $\mathbf{b}^l$ 和 z^{l-1} 分别为第 l 层的权重矩阵、偏置向量和输入。

在本研究中,神经网络的隐藏层使用非线性双曲正切激活函数 $\sigma = \tanh(\cdot)$ 作为激活函数,而输出层则使用线性恒等函数作为激活函数,并采用Xavier方法对PINNs中的可调参数进行初始化,从而有效避免梯度消失或梯度爆炸的问题。为了优化网络

的性能并找到最佳的权重和偏置值,本研究使用Adam优化算法,该算法能够自适应调整学习率,从而加速网络的收敛过程。在训练过程中,学习率被设定为 1×10^{-4} 。

通过将偏微分方程嵌入神经网络中,预处理后的训练数据被输入网络,从而使网络能够有效地学习波传播的规律。为了优化模型的精度,定义了多个残差项,并通过最小化这些残差项来进行优化^[12]。

偏微分方程的误差计算公式为

$$R_{\text{PDE}} = \frac{\partial^2 u}{\partial t^2} - \alpha^2 \left(\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} \right) \quad (4)$$

观测信号的拟合误差计算公式为

$$R_{\text{st}} = u(x, y, t) - u_k(x, y, t) \quad (5)$$

其中: u_k 为已知的位移场。

PINNs工作流程如图6所示,构建了2个神经网络分别计算位移 u 和波速 α 。尽管本研究中的铝合金材料可近似视为均匀介质,波速基本恒定,但为提升模型在更复杂场景中的适应性和推广能力,笔者设计了独立的神经网络对波速场进行联合重建,以便更有效地处理潜在的非均匀性或未知材料属性。网络1包括:1个输入层,输入3个变量 (x, y, t) ;6个隐藏层,每层包含64个神经元;1个输出层,输出为 u 。网络2包括:1个能接收2个输入变量 (x, y) 的输入层;6个包含32个神经元的隐藏层;1个产生结果 α 的输出层。

网络1以稀疏分布的 21×6 个位置的时空坐标作为输入,输出不同时刻对应的位移值,这些位移值反映了特定时空点上的波动情况,为后续波场求解提供基础数据。为构建时空域中的训练数据分布,本研究采用Sobol低差异序列算法对空间域 $(0, 1)$ 进行采样。基于此采样策略,共获得 1×10^6 个高密度数据点,这些采样点被整合为网络1第2部分的




图6 PINNs工作流程示意图

Fig.6 Schematic of the PINNs workflow

输入。在每次迭代中,网络1以100为批量大小进行数据处理,即每次处理100组数据。最后,将输出结果放入偏微分方程的计算中,以确保得到符合物理规律的波场解。

网络2接收来自整个波场网格的空间坐标作为输入,通过隐藏层对输入的空间坐标进行特征提取和转换,最后输出与波场相关的计算结果,用于辅助全域波场的求解。

网络1和网络2在偏微分方程的计算中协同工作:网络1基于稀疏点的时空坐标得到位移值并参与偏微分方程计算,网络2利用整个波场网格的空间坐标进行相关计算,二者的计算结果相互补充和配合,使得网络能够在完整的 $[101, 101, 4\ 000]$ 网格坐标集上进行位移计算,从而实现全域波场的求解。

损失函数由两部分组成:①从偏微分方程计算得出的误差;② 21×6 个位置处观测数据的实际值与预测值之间的误差。训练过程的目标是最小化这两部分误差的均方误差总和^[12]。当损失误差低于设定阈值或迭代次数超过预定限制时训练结束,即

$$\text{MSE}(\theta) = \lambda_1 \text{MSE}_{\text{PDE}} + \lambda_2 \text{MSE}_{\text{st}} \quad (6)$$

其中: θ 为神经网络中所有权重和偏置的集合; λ_1 、 λ_2 为用于平衡不同损失函数的加权超参数。

$$\text{MSE}_{\text{PDE}} = \frac{1}{N_{\text{PDE}}} \sum_{i=1}^{N_{\text{PDE}}} |R_{\text{PDE}}(x_i, y_i, t_i)|^2 \quad (7)$$

这是一组随机选择的偏微分方程训练数据上评估的损失项,且 (x_i, y_i, t_i) 均属于0~1的范围。类似地,观测数据的总损失项定义为

$$\text{MSE}_{\text{st}} = \frac{1}{N_{\text{st}}} \sum_{i=1}^{N_{\text{st}}} |R_{\text{st}}(x_i, y_i, t_i)|^2 \quad (8)$$

其中: $R_{\text{st}}(x_i, y_i, t_i)$ 为在空间-时间坐标 (x_i, y_i, t_i) 处观测信号的预测值与实际观测值的残差,其具体定义见式(5); N_{st} 为观测数据损失计算的样本总数($21 \times 6 \times 400$ 个时空信号)。

通过对所有样本残差的平方取平均,构建起观测数据的均方误差损失项,用于约束模型输出与实际观测信号的拟合程度。

针对超声波波场重构逆问题的求解需求,式(6)中的超参数选择至关重要,因为其会显著影响模型的性能和收敛行为。这些超参数的值是依据PINNs相关文献中的常规做法,通过反复实验选定的^[8]。在本研究中,超参数配置如下: $\lambda_1=20$, $\lambda_2=7\ 000$ 。其中: λ_1 控制偏微分方程残差项的权重,以确保对超声波传播原理的严格遵循; λ_2 则加强了对稀疏实验测量数据的拟合,从而提高了波场重构的精度。

3 结果分析与讨论

PINNs训练过程中总损失及各损失项的收敛特性如图7所示。从整体趋势来看,总损失随着训练轮次的增加逐步下降,表明模型在不断优化。然而,不同损失项的下降趋势存在显著差异。其中,数据拟合损失 R_{st} 在训练初期迅速下降,并在后期趋于稳定,说明数据拟合部分对模型的优化较为高效,能够在较短时间内拟合数据分布。相比之下,物理约束损失 R_{PDE} 在初始阶段波动较大,随后进入缓慢下降趋势,并在后期逐渐趋稳。这种震荡现象可能是由于物理约束方程的复杂性,导致优化过程不稳定,使模型难以迅速收敛。




图7 PINNs训练过程中总损失及各损失项的收敛特性
Fig.7 Convergence characteristics of the total loss and individual loss components during PINNs training

$t=14.56\ \mu\text{s}$ 时刻的波场结果如图8所示。图8(a)展示了第1组实验获取的完整LU波场,其作为重构结果的基准参考。由图可以看出:兰姆波自下而上传播,且波包能量主要集中在后几个波包中;兰姆波前形状较为连续,但存在明显的噪声干扰,这是由于LU实验过程中试样表面质量不均匀、脉冲激光能量不稳定等因素导致。图8(b)展示了第2组实验获得的稀疏不完整LU波场,其作为PINNs模型的输入数据。由图可以看出,经稀疏采样后,波场中的波前发生了较大变形,已经丧失了精确的波形信息,无法准确描述出兰姆波的传播情况。图8(c)展示了通过PINNs方法重构得到的完整波场,由图可以看出,重构后的兰姆波波形清晰、连续且信噪比高,能够清楚地看出兰姆波的传播状态。对比图8(a)和(c)可见,PINNs方法显著提升了波场清晰度并有效抑制了噪声,体现出该方法在提高波场信噪比方面的优势。图8(d)展示了图8(a)和(c)之间的逐点绝对误差分布,结果表明:误差主要集中在波场的下部区域(即波场模型的c部分)。这是因为输入数据主要来自波场的中部区域,导致模型在波场下部的重构精度相对较低。考虑到LU实验中固有的背景

噪声,这些误差处于可接受范围,进一步验证了PINNs方法在波场重构中的稳定性和可靠性。另外,由于波动方程针对的是均质材料,未考虑材料的各向异性和非线性,则实际波场中的非线性分量会被消除,导致重构误差变大。




图8 $t=14.56\ \mu\text{s}$ 时刻的波场结果

Fig.8 Wavefield results at $t=14.56\ \mu\text{s}$

图9、10分别为 $t=15.20\ \mu\text{s}$ 和 $t=15.84\ \mu\text{s}$ 时刻的波场结果。通过对不同时刻下PINNs方法重构波场进行综合评估,能够更深入地了解该模型在捕捉动态波传播现象时的表现。综合观察图8、图9和图10中多个时刻波场数据可知,随着时间的推移,兰姆波逐渐向上传播,波场的演变和传播趋势逐步清晰展现。此外,图9(d)和图10(d)中的误差分布与图8(d)相似,较大的误差区域主要集中在波场的底部区域。这表明在这些区域内,重建的波场与真实波场之间仍存在一定的偏差。

为定量表征波场重构精度,本研究采用皮尔逊相关系数(Pearson correlation coefficient,简称PCC)^[13]作为评价指标,其数学表达式为

$$\text{PCC} = \frac{\sum_{i=1}^n (X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum_{i=1}^n (X - \bar{X})^2 \sum_{i=1}^n (Y - \bar{Y})^2}} \quad (9)$$

其中: X 、 Y 分别为完整波场和重构波场的数据序列; $\bar{X}$ 、 $\bar{Y}$ 为各自序列的平均值。

皮尔逊相关系数通过计算完整波场与重构波场的线性相关性函数值进行客观量化评估^[14]。不同时




图9 $t=15.20\ \mu\text{s}$ 时刻的波场结果

Fig.9 Wavefield results at $t=15.20\ \mu\text{s}$




图10 $t=15.84\ \mu\text{s}$ 时刻的波场结果

Fig.10 Wavefield results at $t=15.84\ \mu\text{s}$

刻的皮尔逊相关系数见表2。

本研究通过皮尔逊相关系数量化评估了物理信息神经网络的波场重构性能。如图8~10及表2的定量数据所示,3个特征时刻的PCC值均稳定保持在0.91以上,说明重构波场与完整数据间保持了91%的统计相关性,展现出较高的波形保真度。

表2 不同时刻的皮尔逊相关系数

Tab.2 PCC at different time instances

$t/\mu\text{s}$	14.56	15.20	15.84
PCC	0.915	0.938	0.947

4 结 论

1) 将二维波动方程作为物理约束,构建了PINNs模型,该模型在极低空间采样率下依然具有较强的波场恢复能力,突破了传统方法对高密度采样数据的依赖。

2) 在仅1%空间观测数据的情况下,模型依然能够实现91%以上的重构精度,充分验证了其在小样本条件下的有效性与鲁棒性。

3) 物理约束条件的引入能够有效抑制实验数据中不符合波动方程的信号成分,提高了波场重构图像的信噪比。

4) 目前的研究仍局限于理想条件下的均匀无缺陷薄板材料,对复杂结构或含缺陷介质的适应性尚待进一步验证。因此,本研究的主要目标在于搭建理论框架与方法基础,后续工作将进一步扩展至实际工程样本,以增强其实用性和通用性。

参 考 文 献

- [1] 丁雷,戴磊,耿开胜,等.面向复杂曲面的激光超声机器人检测系统[J].振动、测试与诊断,2025,45(4): 819-824.
DING Lei, DAI Lei, GENG Kaisheng, et al. Laser ultrasound robot inspection system for complex curved surfaces[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(4): 819-824. (in Chinese)
- [2] ZAREI A, PILLA S. Laser ultrasonics for nondestructive testing of composite materials and structures: a review[J]. Ultrasonics, 2024, 136: 107163.
- [3] ZHANG X, CHEN L, LIU G, et al. An improved modal tracking algorithm for dispersion analysis of arbitrary prestressed plates[J]. Thin-Walled Structures, 2024, 205: 112582.
- [4] 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.
- [5] KARNIADAKIS G E, KEVREKIDIS I G, LU L, et al. Physics-informed machine learning[J]. Nature Reviews Physics, 2021, 3(6): 422-440.
- [6] SHUKLA K, DI LEONI P C, BLACKSHIRE J, et al. Physics-Informed neural network for ultrasound nondestructive quantification of surface breaking cracks [J]. Journal of Nondestructive Evaluation, 2020, 39(3): 61.

- [7] 颜鑫,应恺宁,戴鹭楠,等.基于物理信息神经网络的激光超声波场研究[J].激光技术,2024,48(1): 105-113.
YAN Xin, YING Kaining, DAI Lunan, et al. Research on laser ultrasonic wavefield based on physical-informed neural network[J]. Laser Technology, 2024, 48(1): 105-113. (in Chinese)
- [8] RASHT-BEHESHT M, HUBER C, SHUKLA K, et al. Physics-informed neural networks(PINNs) for wave propagation and full waveform inversions[J]. Journal of Geophysical Research: Solid Earth, 2022, 127(5): e2021JB023120.
- [9] GOODFELLOW I, BENGIO Y, COURVILLE A, et al. Deep learning[M]. Cambridge: MIT Press, 2016: 37-300.
- [10] CHO S, CHOI W, JI J, et al. Analysis on strategies for modeling the wave equation with physics-informed neural networks[J]. Geophysics and Geophysical Exploration, 2023, 26(3): 114-125.
- [11] BAYDIN A G, PEARLMUTTER B A, RADUL A A, et al. Automatic differentiation in machine learning: a survey[J]. Journal of Machine Learning Research, 2017, 18(1): 5595-5637.
- [12] NOSRATI H, EMAMI-NIRI M. Manipulating the loss calculation to enhance the training process of physics-informed neural networks to solve the 1D wave equation[J]. Engineering with Computers, 2024, 40(3): 1741-1769.
- [13] KALINA J, VIDNEROVÁ P. Properties of the weighted and robust implicitly weighted correlation coefficients[C]//Artificial Neural Networks and Machine Learning-ICANN 2023. Cham: Springer, 2023: 200-212.
- [14] SCHOBER P, BOER C, SCHWARTE L A. Correlation coefficients: appropriate use and interpretation[J]. Anesthesia and Analgesia, 2018, 126(5): 1763-1768.



第一作者简介:宋英凡,男,2000年4月生,硕士生。主要研究方向为激光超声兰姆波波场重构。

E-mail: 2458945521@qq.com

通信作者简介:李阳,男,1988年9月生,博士、副教授、硕士生导师。主要研究方向为激光超声无损检测及超声导波。
E-mail: yangli@zzu.edu.cn