

基于物理信息神经网络的激光超声波场研究

颜鑫, 应恺宁, 戴鹭楠, 谭钧夫, 沈中华, 倪辰荫

Research on laser ultrasonic wavefield based on physical-informed neural network

引用本文:

颜鑫, 应恺宁, 戴鹭楠, 谭钧夫, 沈中华, 倪辰荫. 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]. *Chinese Journal of Liquid Crystals and Displays*, 2024, 48(1): 105–113.

您可能感兴趣的其他文章

1. 外腔式双波长喇曼激光器的耦合波理论

引用本文: 王聪, 吕冬翔. 外腔式双波长喇曼激光器的耦合波理论[J]. *激光技术*, 2023, 47(5): 579–586.

2. 基于DPMZM的微波光子倍频激光雷达仿真分析

引用本文: 阳琴, 陈孝林, 曾诚, 等. 基于DPMZM的微波光子倍频激光雷达仿真分析[J]. *激光技术*, 2023, 47(6): 729–735.

3. 激光脉冲初始相位对电子辐射的影响

引用本文: 和一凡, 申雨婷, 王文霄, 等. 激光脉冲初始相位对电子辐射的影响[J]. *激光技术*, 2023, 47(1): 103–107.

4. 铝合金化铣保护胶激光刻型热应力耦合分析

引用本文: 赵安安, 张鸿帅, 燕国强, 等. 铝合金化铣保护胶激光刻型热应力耦合分析[J]. *激光技术*, 2023, 47(3): 419–424.

5. 激光超声检测带涂层金属表面裂纹的数值研究

引用本文: 徐志祥, 黄建华, 王铮恭, 等. 激光超声检测带涂层金属表面裂纹的数值研究[J]. *激光技术*, 2018, 42(6): 801–805.

文章编号: 1001-3806(2024)01-0105-09

基于物理信息神经网络的激光超声波场研究

颜 鑫¹, 应恺宁², 戴鹭楠², 谭钧夫³, 沈中华², 倪辰荫^{1*}

(1. 南京理工大学 电子工程与光电技术学院, 南京 210094, 中国; 2. 南京理工大学 理学院, 南京 210094, 中国; 3. 南京理工大学 计算机科学与工程学院, 南京 210094, 中国)

摘要: 为了解决传统神经网络技术过于依赖数据资源, 同时也无法运用数据中暗含的物理先验知识等局限性问题, 采用物理信息神经网络(PINN)、基于超声传播的波动方程, 利用数值计算实验的数据训练出了正向激光超声单模态(表面波)波场的 PINN 模型; 建立了反向求解激光超声单模态波场参数的 PINN 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, 当探测点不包含激发点时, 正向 PINN 在数据量仅为 10% 的情况下可得到高精度的波场图像, 相比于原波场下降了一个数量级; 即使在包含激发点时, 反向 PINN 利用 25% 的波场数据不仅可以重建波场, 且不需要人为地分析就可以求解控制方程的参数, 与原波场数据的参数误差均在 5% 以内; 与传统神经网络相比, PINN 通过加入符合激光超声特性的控制方程, 降低了神经网络对于训练数据稀疏性的依赖; 与传统的激光超声波场建模相比, PINN 构建的物理模型更简单, 可自动求得控制方程的参数, 有着更好的鲁棒性。该研究可为波场重建和参数反演激光超声无损检测技术提供参考, 在激光超声领域有着广泛的应用前景。

关键词: 激光技术; 激光超声; 神经网络; 偏微分方程; 波场成像

中图分类号: O426; O436; TP183 文献标志码: A doi:10.7510/jjgs.issn.1001-3806.2024.01.017

Research on laser ultrasonic wavefield based on physical-informed neural network

YAN Xin¹, YING Kaining², DAI Lunan², TAN Junfu³, SHEN Zhonghua², NI Chenyin^{1*}

(1. School of Electronic Engineering and Optoelectronic Technology, Nanjing University of Science & Technology, Nanjing 210094, China; 2. College of science, Nanjing University of Science & Technology, Nanjing 210094, China; 3. College of Computer Science and Engineering, Nanjing University of Science & Technology, Nanjing 210094, China)

Abstract: In recent years, non-destructive detection technology based on deep learning has developed rapidly, but traditional neural network technology relies too much on data resources and cannot use the physical prior knowledge implied in the data, which has many limitations. In order to solve this problem, physical-informed neural networks (PINN) were used in this paper. Based on the wave equation of ultrasonic propagation, the forward PINN model of laser ultrasonic single-mode (surface wave) wave field was trained by using the data of numerical calculation, and the inverse PINN model for solving laser ultrasonic single-mode wave field parameters was further established; therefore, the forward imaging and inverse parameter deduction of laser ultrasonic field were carried out. The results show that when detection points do not contain the excitation point, the forward PINN can obtain a high-precision wave field image when the data volume is only 10%, which is an order of magnitude lower than the original wave field; even when the excitation point is included, the reverse PINN can not only reconstruct the wave field by using 25% of the wave field data, but also solve the parameters of the control equation without artificial analysis, and the error of the parameters with the original wave field data is within 5%. Compared with the traditional laser ultrasonic field modeling, the physical model built by PINN is simpler, which can automatically obtain the parameters of the control equation and has better robustness. This research can provide a reference for wave field reconstruction and parameter inversion laser ultrasonic nondestructive testing technology, so PINN has broad application prospects in the field of laser ultrasonic.

Key words: laser technique; laser ultrasonic; neural networks; partial differential equations; wave field image

0 引言

激光技术在检测领域^[1]应用十分广泛, 其中激光超声^[2-4]技术是无损检测^[5-8]领域的重要研究工具。激光超声与传统超声^[7]相比有许多优点: 激光超声不仅能够产生在固体中产生, 同样可以在液体、气体中产生;

基金项目: 江苏省研究生科研与实践创新计划资助项目 (KYCX22_0420)

* 通信作者: chenyin.ni@njust.edu.cn

收稿日期: 2023-01-16; 修回日期: 2023-03-14

并且依据材料的不同性质,激光声源能激发出纵波、横波和表面波等多模态波,是一种理想的声源。波场成像^[9-13]方法可用于表征和研究各种材料系统中的弹性场相互作用。其中基于激光超声的波场成像方法,即使用扫描激光测振系统^[11]来检测由超声激发源产生的材料表面上的运动,通过重复的激发超声,测振系统在不同的检测点能够得到一组离散的时间序列信号(离面位移-时间信号),这些随时间变化的数据展示了超声在材料内部传播的细节。基于激光超声的波场成像技术,利用可视化的超声波场图像对材料性质进行分析,并且有着激光超声无损检测高精度、非接触和无损伤的优点,因此有着重要的意义和应用背景。

近年来,随着深度学习算法的更新迭代和数据的爆炸式增长,深度学习已经在生物医学^[14]、自动驾驶^[15]、图像识别^[16]、自然语言处理^[17]等领域取得了突破性进展。传统深度学习算法的任务就是建立输入数据到输出数据直接的映射关系,即提供一个训练集,包括输入和其对应的输出,如果神经网络的输出结果是错的,它将会调整计算,并在训练集上不断重复计算,直至得到期望的结果。为了找出这种映射关系,通常需要数据对网络进行训练。当数据量过少时,模型无法得到准确的结果;而当数据量过于庞大时,又会导致模型的泛化能力过差,模型陷入过拟合。因此最终训练出来的模型好坏与数据息息相关。在许多物理模型之中,训练的数据之中往往暗含着物理定律,但是这些都没有体现在传统的深度学习算法之中。因此,为了规避数据稀疏性的影响,让神经网络也能够利用物理定律,布朗大学 RAISSI 等人^[18-20]提出了一种基于物理信息的神经网络(physical-informed neural networks, PINN),结合了数据驱动和物理模型的优势,能在少量数据下训练出符合物理规律的模型,避免了模型过拟合并提高了其泛化能力;在此基础上,RAISSI 教授证明了在构建物理系统的正向问题和反向问题上,可以使用偏微分方程作为先验信息来约束最小化过程,即 PINN 可以用于解决物理模型的正反问题。在正向问题中,可以得到偏微分方程的近似解;而在反向问题中,可以计算出偏微分方程所涉及的参数甚至是未知的函数。由于可在 PINN 中引入基于物理规律的表达式,许多学者已经将其在不同的领域进行了应用,例如流体力学^[21]、生物医学^[22]、材料领域^[23]等。PINN 在激光超声无损检测领域的应用目前仍处于起步阶段,但是激光超声信号满足波传播的物理定律,因此可以以此建立物理模型。

针对上述问题,本文作者开展了正向重建激光超声波场图像和反向推演波速的研究。首先,基于声波波动方程建立了 PINN 模型,并使用数值计算实验获得的激光超声信号作为输入数据,对所建模型进行了训练;其次,利用神经网络作为函数逼近器,在数值计算模型的表面波波场数据基础上,正向训练出表面波波场图像,减小了数据稀疏性对于神经网络的影响;最后,利用表面波数据进行 PINN 参数反演,神经网络自动推演出表面波波速,即建立的 PINN 模型可以用于反演偏微分方程(波动方程)里面的参数。

1 基于波动方程的 PINN 基本理论

1.1 PINN 基本理论

传统神经网络^[24-25]为一个多层的网络结构,分为“输入层”、“隐藏层”和“输出层”,如图 1 所示。在这 3 层结构中,“输入层”接收待训练的数据;“隐藏层”可以不止一层,每一层有多个神经元,其接收前一层的数据进行非线性运算,运算的结果为“输出层”的输入;最后“输出层”输出结果。其中“输入层”、“隐藏层”和“输出层”两两连接。




图 1 神经网络结构

Fig. 1 Structure of Neural network

图 1 中, $x_1 \sim x_n$ 为“输入层”的输入值,输入值在经过神经元后会进行非线性变化,如下式所示:

$$Z_j = \sigma \left(\sum_{j=1}^n w_j * x_j + b \right) \quad (1)$$

式中: $\sigma(\cdot)$ 表示激活函数; j 表示该层的神经元的个数; n 表示输入的个数; w_j 表示该层第 j 个神经元为输入值赋予的权重; x_j 为第 j 个神经元的输入,即为上一层的输出值; b 表示该隐藏层神经元带有的偏置; Z_j 为该层的输出值,也是下一层的输入值。

本文中基于波动方程建立 PINN 模型,与普通的神经网络相比,在激活函数的选择上面需要注意以下几点:首先,由于波动方程涉及到偏微分方程的运算,所以需要激活函数的 2 阶导数存在、且不为 0,例如激

活函数 ReLU 就不能运用;其次,例如 sigmoid 和 tanh 等存在 2 阶导数且不为 0 的激活函数都可以使用,而在实际训练模型的时候,由于检测到的振动幅度较小,使用 sigmoid 激活函数容易出现梯度消失的问题,因此实际使用中 tanh 较好,表达式如下式所示:

$$f(x) = \frac{1 - \exp(-2x)}{1 + \exp(2x)} \quad (2)$$

在神经网络中,“输入层”到“隐藏层”都会进行这种非线性变换,而在“隐藏层”到“输出层”中将进行线性变换,如下式所示:

$$Z_j = \sum_{j=1}^n w_j * x_j + b \quad (3)$$

“隐藏层”到“输出层”进行运算时,如式(3)所示,只进行线性运算。经由神经网络模型计算出来的预测值,将继续作为偏微分方程的输入,计算残差。

PINN 将利用控制超声波传播的线性 2 阶偏微分方程^[26-27],如下式所示:

$$u'' = c^2 \Delta u, (x \in \Omega, t \in [0, T]) \quad (4)$$

式中: $u(t, x)$ 是偏微分方程的解; t 是时间; c 表示波速; Ω 是表示实数集; u'' 是离面位移 u 对时间 t 求 2 次导数; Δu 表示对 u 进行拉普拉斯运算; T 代表求解时间域。网络结构原理如图 2 所示。




图 2 PINN 结构图

Fig. 2 Structure of PINN

图 2 表示 PINN 先建立一个神经网络的位移逼近函数 $u(t, x)$, 之后建立偏微分方程的残差 f , f 的值越趋近于 0 表示神经网络的预测值越符合物理模型, 表达式为:

$$f: = u'' - c^2(x) \Delta u \quad (5)$$

式中:“: =”表示更新参数。定义 PINN 的损失函数为:

$$L = \lambda M_u + M_f \quad (6)$$

式中: $\lambda > 0$ 为惩罚项系数, 通过改变 λ , 可以调整神经网络的逼近函数, 从而达到帮助神经网络快速收敛的效果; M_u 为神经网络预测值 u_p 和真实值 u 的均方根误差; M_f 为偏微分方程的残差 f 的均方根误差, 其表达式分别为:

$$M_u = \frac{1}{N_u} \sum_1^{N_u} |u_p - u|^2 \quad (7)$$

$$M_f = \frac{1}{N_f} \sum_1^{N_f} |f(t, x)|^2 \quad (8)$$

式中: N_u 表示预测值的总个数; N_f 表示偏微分方程采集点的个数。

1.2 优化算法

由第 1.1 节可知, 多层神经网络在训练中需要经过多次迭代计算, 每次迭代根据当前神经网络的权重和偏置计算输入数据前向运算的结果, 根据建立的损失函数来计算神经网络的输出与目标输出之间的误差, 此时需要反向传播计算损失相对于参数的梯度, 使用梯度下降算法更新参数以减少下一次迭代的损失。

梯度下降算法更新公式为:

$$\theta_i^{(k+1)} = \theta_i^{(k)} - \alpha \frac{\partial L}{\partial \theta_i^{(k)}} \quad (9)$$

式中: θ 为待更新参数; α 为学习率, 决定了梯度更新的步长; L 为损失误差; ∂ 为偏导数符号;上标 k 为迭代的次数;由于神经网络之中需要迭代更新的参数往往为多个, 下标 i 对应不同的参数。由式(9)可以看出, 如果学习率过小, 损失函数的变化速度会很慢;如果学习率过大, 可能会使损失函数直接越过全局最优解, 陷入局部最优解。本文中采用自适应矩估计 (adaptive moment estimation, Adam) 优化算法^[28], 收敛速度比传统的梯度下降算法更快, 不易陷入局部最优。

本文中均采用 4 层神经网络, 每层有 128 个神经元, 激活函数为 tanh, 优化器为 Adam。

2 激光超声数值计算模型及参数设置

为利用 PINN 进行波场成像及参数反演, 首先使用仿真软件进行数值计算以获取波场数据。在数值计算模型中, 利用固体力学和固体传热两个模块^[29], 模拟了激光入射在铝材料上导致局部吸收能量形成热弹激光超声这一过程^[30-31]。本文中通过固定超声激发点, 会在材料表面产生超声信号, 而通过移动扫查探测点可以测得不同位置的离面位移信号, 即物体表面质点震动离开表面原位的距离, 从而进行数值计算实验研究。通过设置不同的激发点位置和探测点扫查范围, 得到了两组数据。

数值计算的第 1 组数据如图 3 中激发位置与扫查范围 1 所示。样品材料设置为铝, 长度为 6.0 mm, 厚度为 1.0 mm, 其中激发点位于上表面中心处, 位置设




图3 数值计算模型(固定激发、多点探测)

Fig. 3 Numerical calculation setup for fixed generation and multiple point detection

为0点。测量范围在整个上表面 $[-3.0\text{ mm}, 3.0\text{ mm}]$ 区域,每步扫描步长为 $50.0\text{ }\mu\text{m}$,共包含121个扫描点,时间步长数据采集间隔为 $0.02\text{ }\mu\text{s}$,101个总时间步长点共 $2.0\text{ }\mu\text{s}$ 。数据以 (N_x, N_t) 的形式排列,大小为 (121×101) ,其中 N_x 为 x 方向的网格点, N_t 为总时间步长。B扫图像 $u(t, x)$ 如图4a所示,其中横坐标表示时间,纵坐标表示探测点的位置,两条直线分别为掠面纵波、表面波。直线的斜率表示为该波的波速。可以发现:在 $x=0.0\text{ mm}$ 处,由激发光辐照产生的热膨胀离面位移远远大于其它探测点的离面位移,由热膨胀引起的离面位移为纳米级,图4a中为一条黄绿色的横线(即图4a中激发点处热膨胀信号),而超声传播过程中的离面位移数量级为 0.01 nm ,热膨胀信号至少比超声信号引起的离面位移大两个数量级。

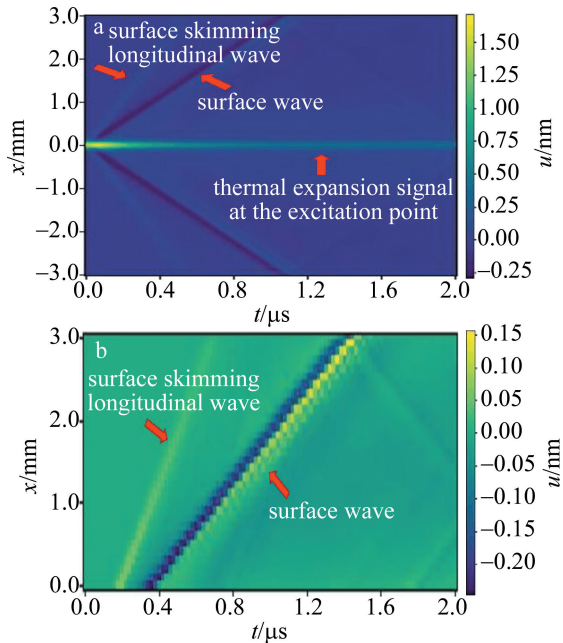


图4 激光超声多模式B扫图像

a—探测点包含激发点 b—探测点不包含激发点

Fig. 4 B-scan image of laser ultrasonic multi-mode

a—when detection points include the excitation point b—when detection points exclude the excitation point

数值计算的第2组数据如图3中激发位置与扫描范围2所示。样品表面宽度为 6.0 mm ,深度为 1.0 mm ,其中激发点位于上表面中心点左侧 1.0 mm 处。波场成像测量范围在上表面 $[0.0\text{ mm}, 3.0\text{ mm}]$ 区域,模拟扫描步长 $100.0\text{ }\mu\text{m}$ (31个扫描点),时间步长数据采集间隔为 $0.02\text{ }\mu\text{s}$ (101个总时间步长点共 $2.0\text{ }\mu\text{s}$)。B扫图像如图4b所示,与图4a的区别在于此时的探测点不包含激发点,但都有掠面纵波和表面波,其斜率代表各自的波速。其中热膨胀处的离面位移为纳米级,而由于超声传播特性而引起的离面位移也为纳米级,因此,激发点无法体现出超声传播所引起的离面位移变化。

需要指出的是,激光超声具有多模式激发的特性,针对这一特性,本文作者提出的PINN模型可以加入不同的控制方程表示不同模式的特点。为了研究方便,先从单模式超声传播着手,研究激光超声中波场成像原理。因此,本文中PINN模型只对单个波进行建模分析,由此,作者先对波场数据进行预处理操作。由图4可知,B扫图像包含掠面纵波、表面波等多个超声波模式。从时域信号幅值来看,除激发点外,表面波幅值比其它模式声波大一个数量级,所以选取表面波模式进行分析。取表面波信号最大幅值处为其到达时间,处理后的单模式数据如图5所示。横坐标均为时间,纵坐标均为探测点的位置,直线的斜率为波速。

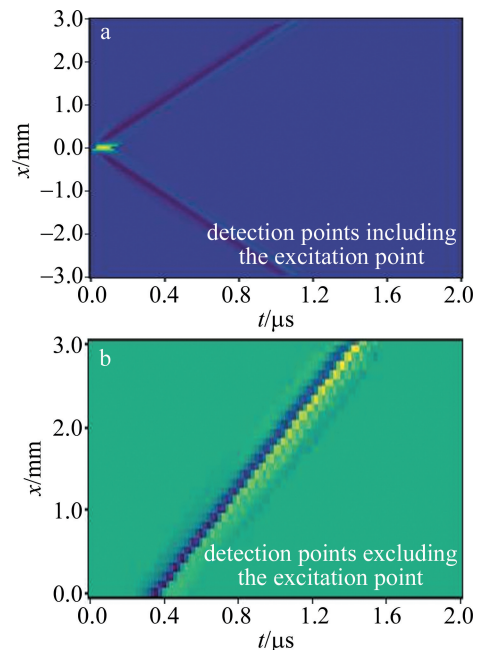


图5 激光超声单模式B扫图像

Fig. 5 B-scan image of laser ultrasonic single-mode

在训练PINN模型时,为验证PINN模型能用少量

数据重建波场的可行性,在均匀采样、扫描距离和总时长均一定的前提下,增大扫描步长和时间步长,再将少量数据输入 PINN 中进行训练,最后与原始扫描步长和时间步长的波场数据进行对比。

3 结果与讨论

本节中使用数值模型中获得的 2 组计算数据,对上文建立的基于波动方程的 PINN 模型进行训练,从而正向得到激光超声单模态(表面波)波场图像的结果,进而反向推演激光超声单模态波场参数。

3.1 单模态激光超声波场的正向计算

为了利用少量的波场 $u(t, x)$ 数据重建波场图像,首先进行第 1 组数值计算数据(数据大小为 121×101 , 共 12221 个数据点)训练 PINN 模型。图 6a 为正向 PINN 模型重建出来的 B 扫图像,其中横坐标为时间,纵坐标为探测点的位置。从图 6a 中可明显看出,在 $x=0.0 \text{ mm}$ 处的离面位移远远大于其它探测点处的离面位移,这是由于数值模型中激发点的离面位移远远大于其它点,在训练模型过程中被作为了主要特征。

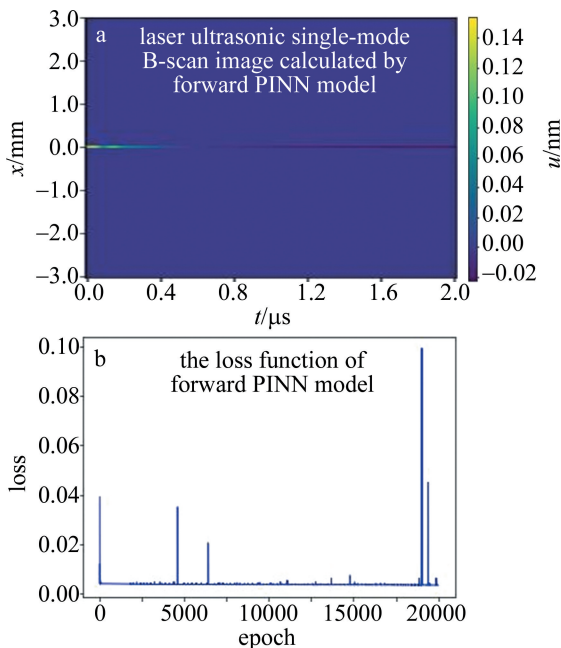


图 6 探测点包含激发点时正向 PINN 训练结果

Fig. 6 Forward PINN training results when detection points include the excitation point

图 6b 中给出了 PINN 模型训练过程中的损失函数的变化过程。图中横坐标表示迭代次数,纵坐标表示损失函数的值。由图 6b 可知,训练数据包含探测点时,损失函数的值基本平稳无法下降。这是由于 $x=0.0 \text{ mm}$ 处的离面位移主要由激发源导致的热膨胀引

起,其幅值比其它探测点处获得的离面位移高了一个数量级,因此 PINN 模型会将 $x=0.0 \text{ mm}$ 点的数据作为主要训练特征。而 PINN 模型是基于波动方程构建残差损失的, $x=0.0 \text{ mm}$ 处的热膨胀引起的离面位移并不能在波动方程中体现,因此与损失函数矛盾且损失函数无法下降。

针对这一问题,使用扫描路径不包含激发点的第 2 组数值计算数据(大小为 31×101 , 共 3131 个数据点,扫描步长为 $100.0 \mu\text{m}$,时间步长为 $0.02 \mu\text{s}$)中约 10% 的数据(大小为 16×21 , 共 336 个数据点,扫描步长为 $200.0 \mu\text{m}$,时间步长为 $0.1 \mu\text{s}$)训练 PINN 模型。与上述情况不同,其损失函数可以收敛,下降趋势如图 7 所示。




图 7 探测点不包含激发点时的正向 PINN 模型损失函数

Fig. 7 Loss function of forward PINN model when detection points do not contain the excitation point

图 7 表示第 2 组数据作为训练数据时, PINN 模型训练过程中的损失函数的变化过程。除个别跳变点之外, PINN 模型的损失函数逐渐接近零,平稳地趋近于收敛。这表明当探测点不包含激发点时,第 1 组数据中作为主要干扰信息的热膨胀源不存在,正向 PINN 模型可以利用波场数据重建波场图像。对于训练出来的 PINN 模型,图 8 表现了其重建 B 扫图像的结果。其中图 8a 表示 PINN 模型重建出来的 B 扫图像,图 8b 表示 PINN 模型预测的数据与数值计算数据的相对误差图。由图 8b 可知,将 PINN 计算的数据与数值计算数据进行对比,误差主要集中在表面波到达时刻点附近,波场数据 $u(t, x)$ 的平均误差为 0.0123 nm ,其误差相比于原始波场数据下降了一个数量级(超声传播过程中引起的离面位移为纳米级)。图 8c 和图 8d 为随机选取了 $x=0.5 \text{ mm}$, $x=1.0 \text{ mm}$ 的时间-位移波形图像。可以看出, PINN 拟合的表面波与数值模拟实验的表面波数据的波形基本一致。

由上述可知,在训练正向 PINN 模型时,探测点包含激发点时,由于激发点处产生的大幅度热膨胀,导致

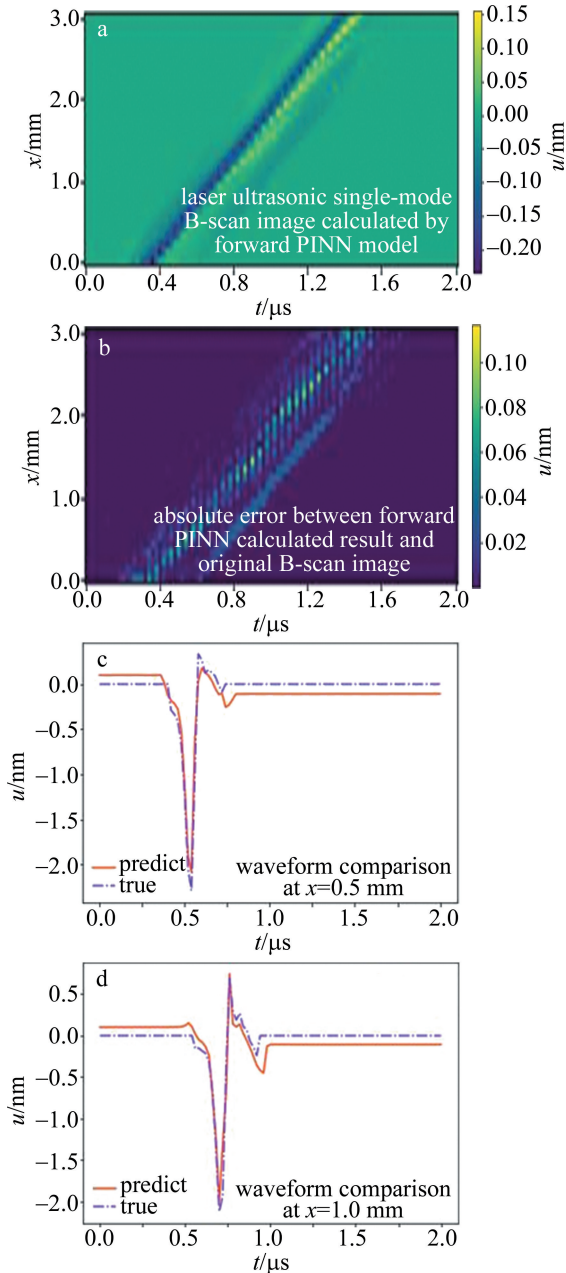


图8 探测点不包含激发点时前向 PINN 训练结果

Fig. 8 Forward PINN training results when detection points do not contain the excitation point

待训练数据的内部数据规律与 PINN 模型内置的波动方程信息不对应。由此可知,训练 PINN 模型时主要特征需要符合模型中作为判据的物理信息(在本例中,是式(5)的波动方程)。本文中,当与物理规律无关的干扰源高于波场数据引起的离面位移一个数据量级乃至以上时,式(6)中的损失项 M_u 中激发点的数据将作为主要特征,与损失项 M_f 中的波动方程相矛盾, PINN 模型将不收敛。

3.2 单模态激光超声参数的反向推演

在正向利用 PINN 模型重建波场图像之后,下面

进行单模态激光超声信号参数的反向推演。对于给定的波场 $u(t, x)$, 目标是识别未知参数波速 c 。反向 PINN 模型对于噪声信息有着更好的鲁棒性,因此,即使探测点包含了激发点,也可以反演出波速 c 。使用第 1 组数值计算模型的数据中约 25% 的数据量(大小为 61×51 , 共 3111 个数据点,扫描步长为 $100.0\text{ }\mu\text{m}$, 时间步长为 $0.04\text{ }\mu\text{s}$) 进行训练反向 PINN 模型。图 9a 中给出了 PINN 重建出来的 B 扫图像,横坐标为时间,纵坐标表示探测点的位置,图中的斜线为表面波到

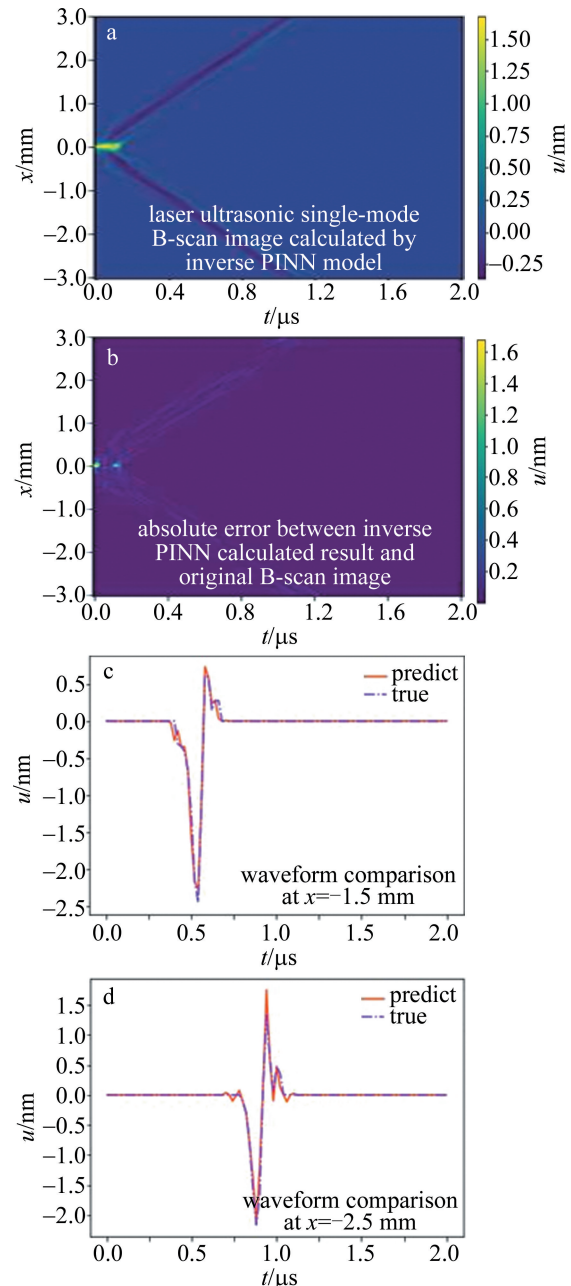


图9 探测点包含激发点时反向 PINN 训练结果

Fig. 9 Inverse PINN training results when detection points include the excitation point

达每个探测点时刻,在 $x=0.0\text{ mm}$ 处为激发点。图 9b 表示 PINN 模型预测的波场数据与真实数据的绝对误差分布。由图 9b 可知,其误差主要也是集中在激发点附近和表面波到达时刻附近,这是由于训练的数据之中包含一部分噪声的干扰,波场数据 $u(t, x)$ 的平均绝对误差为 0.0046 nm , 计算误差与原波场数据相比下降了 4 个数量级。图 9c 和图 9d 为随机选取 $x = -1.5\text{ mm}, x = 2.5\text{ mm}$ 时的时间-位移图像,波形基本一致。

表 1 中给出了反向推演的波速结果。从表中可知, PINN 反演出来的波速与真实波速相比,误差为 3.28% 。

表 1 真实波速和 PINN 反演波速(包含激发点)

Table 1 True wave velocity and velocity inversed by PINN (including the excitation point)

| real velocity | velocity inversed by PINN | relative error |
|-------------------------------|-------------------------------|----------------|
| $2.925\text{ mm}/\mu\text{s}$ | $2.829\text{ mm}/\mu\text{s}$ | 3.28% |

由于已经证明了反向推演参数对于干扰数据有更好的鲁棒性,接下来讨论小数据训练 PINN 模型时波场成像质量的问题。利用给定的波场数据 $u(t, x)$, 在数据中不包含激发点数据的情况下,识别未知参数波速 c 。本次使用了第 2 组数值计算模型的数据中约 21% 的数据量进行训练 PINN 模型(大小为 31×21 , 共 651 个数据点,扫描步长为 $100.0\ \mu\text{m}$, 时间步长为 $0.1\ \mu\text{s}$)。图 10a 为 PINN 模型重建的 B 扫图像;图 10b 表示 PINN 预测的波场数据与真实数据的绝对误差。平均绝对误差为 0.0046 nm , 相比于原波场数据,平均绝对误差下降了一个数量级。图 10c 和图 10d 为随机选取的 $x = 1.0\text{ mm}, x = 2.0\text{ mm}$ 时的时间-位移波形图像,将 PINN 预测的数据与真实的数据进行对比, PINN 拟合的表面波与真实数据的表面波基本一致。

如表 2 所示, PINN 反演出来表面波波速,与真实表面波波速误差为 1.80% 。

表 2 真实波速和 PINN 反演波速(不含激发点)

Table 2 True wave velocity and velocity inversed by PINN (excluding the excitation point)

| real velocity | velocity inversed by PINN | relative error |
|-------------------------------|--------------------------------|----------------|
| $2.925\text{ mm}/\mu\text{s}$ | $2.8704\text{ mm}/\mu\text{s}$ | 1.80% |

经过两组不同的数据训练出来的 PINN 模型均可以反演出波速,且误差均在 5.00% 以内。第 1 组数据其探测点包含了激发点, PINN 模型仍可以反演出模型;第 2 组数据训练出的反向 PINN 模型的误差比正向 PINN 模型的误差低了一个数量级,显示出了 PINN 对噪声的鲁棒性(抗干扰性)很强。这是由于反向训

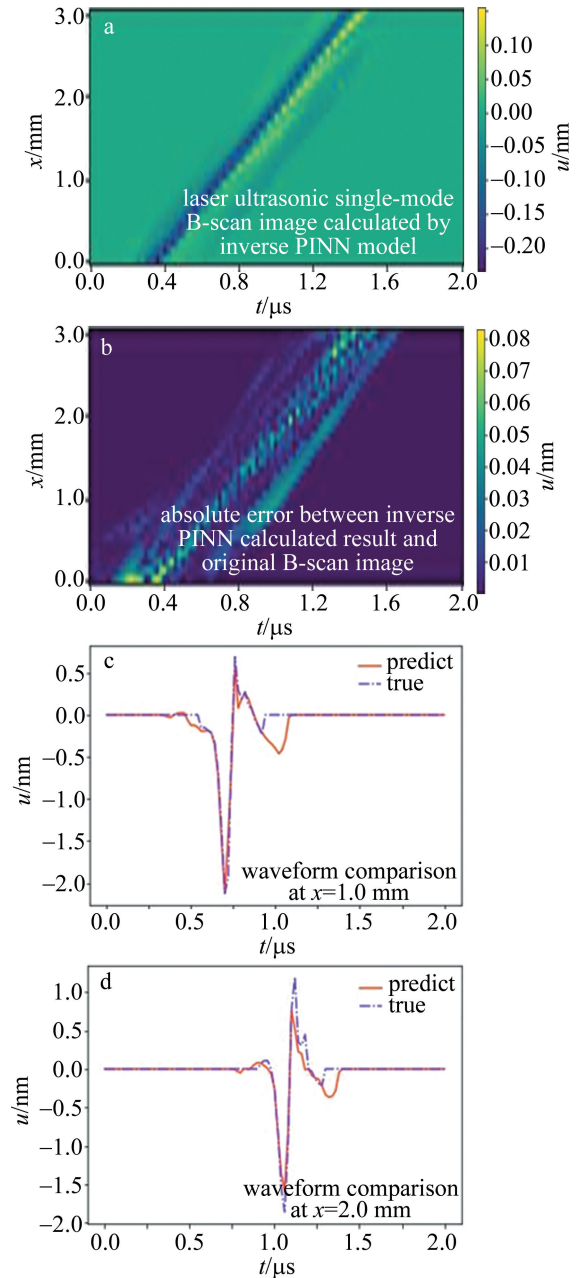


图 10 探测点不包含激发点时反向 PINN 训练结果

Fig. 10 Inverse PINN training results when detection points do not contain the excitation point

练 PINN 模型时,波速是未知参数,参与训练时以波动方程为主要特征进行训练,通过调节惩罚项系数 λ 调节神经网络模型,而在正向训练 PINN 时,由于激发点处热膨胀导致离面位移比其它探测点高了多个数量级,波动方程的残差损失无法作为主要特征,因此在正向过程中无法重建包含探测点的波场图像。同时,由于波动方程作为主要特征学习时,神经网络能够减小其它干扰噪声的影响,所以第 2 组数据的反向成像质量也优于正向过程。

需要指出的是,本文中目前只利用描述激光超声

传播的波动方程进行波场重建以及反演内部参数,并依此对单模态超声信号进行分析。在激光超声检测技术中,还可进一步针对激光超声多模态特性,分别对不同模态的激光超声信号建立独立的控制方程来重建不同模态激光超声信号的波场及参数反演。此外,在其它光学研究领域,这一将物理信息嵌入神经网络的方法同样适用于基于麦克斯韦方程物理信息的研究场景,如光电器件仿真领域。这些基于物理信息的神经网络模型可为激光仿真技术的研究提供其它可行思路。

4 结 论

介绍了 PINN 用于正向求解波动方程和反向推演参数的原理,利用神经网络的逼近理论和自动微分技术,PINN 可以帮助人们避免许多传统神经网络会遇到的问题,例如:数据量过于稀少、模型的泛化性不够等;进一步证明了 PINN 求解波动方程时,在数据量稀疏的情况下完成对波场的正向重建,以及自动反向求解波动方程的波速;最后,将其应用到激光超声领域,实现了对于表面波波场的正向重建和反向波速推演,并将结果与数值计算模型的数据进行对比。研究结果表明:重建的波场数据精确度较高,与原波场数据的绝对误差下降了至少一个数量级;在反向的过程中,PINN 模型自动推演表面波波速,无需进行人为分析,且对噪声有着抗干扰性。

参 考 文 献

- [1] ZHOU H, ZHANG B, FENG Q B, *et al.* Numerical study on defect detection by exciting ultrasound with ring-shaped light source[J]. *Laser Technology*, 2021, 45(2):168-173(in Chinese).
周航,张斌,冯齐波,等. 环形能源的发现声进行缺陷检测的数值研究[J]. *激光技术*, 2021, 45(2):168-173.
- [2] SHEN Zh H, YUAN L, ZHANG H Ch, *et al.* *Laser ultrasonic in solids*[M]. Beijing: Post & Telecom Press, 2015: 9-10(in Chinese).
沈中华,袁玲,张宏超,等. 固体中的激光超声[M]. 北京:人民邮电出版社, 2015: 9-10.
- [3] YUAN Y Q, CHEN S Zh. *Modern ultrasonic principles and applications* [M]. Nanjing: Nanjing University Press, 1996: 323-403(in Chinese).
袁易全,陈思忠. 近代超声原理与应用[M]. 南京:南京大学出版社, 1996: 323-403.
- [4] WANG Y Q, WANG Y X, MA Sh B. Crack detection based on laser ultrasound diffraction transverse wave[J]. *Laser Technology*, 2019, 43(4): 546-550(in Chinese).
王玉庆,王云霞,马世榜. 基于衍射横波的裂纹激光超声检测方法[J]. *激光技术*, 2019, 43(4): 546-550.
- [5] ZHANG Sh Y. Laser ultrasound and non-destructive evaluation of materials[J]. *Journal of Applied Acoustics*, 1992, 11(4): 1-6(in Chinese).
张淑仪. 激光超声与材料无损评价[J]. *应用声学*, 1992, 11(4): 1-6.
- [6] ZHANG Sh Y. High technology of ultrasonic nondestructive testing [J]. *International Academic Development*, 1998 (8):58-60(in Chinese).
张淑仪. 超声无损检测高新技术[J]. *国际学术动态*, 1998 (8): 58-60.
- [7] ZHANG X R. Evaluation of composites and nano-structured materials by laser ultrasound[J]. *Journal of Applied Acoustics*, 2000,19(5): 1-9(in Chinese).
章肖融. 用激光超声评估复合材料[J]. *应用声学*, 2000, 19(5): 1-9.
- [8] TRTNIK G, GAMS M. Recent advances of ultrasonic testing of cement based materials at early ages[J]. *Ultrasonics*, 2014, 54(1): 66-75.
- [9] BLACKSHIRE J L. Ultrasonic propagation and damage sensing in a bonded PMC/SiC-foam [C]// 2014 IEEE International Ultrasonics Symposium (IUS). Chicago, USA:IEEE, 2014: 248-251.
- [10] BLACKSHIRE J L, SATHISH S. Near-field ultrasonic scattering from surface-breaking cracks[J]. *Applied Physics Letters*, 2002, 80(18): 3442-3444.
- [11] DAWSON A J, MICHAELS J E, MICHAELS T E. Isolation of ultrasonic scattering by wavefield baseline subtraction[J]. *Mechanical Systems and Signal Processing*, 2016, 70: 891-903.
- [12] FLYNN E B. Embedded multi-tone ultrasonic excitation and continuous-scanning laser doppler vibrometry for rapid and remote imaging of structural defects [C]//EWSHM-7th European Workshop on Structural Health Monitoring. Nantes, France: Université de Nantes, 2014:1561-1567.
- [13] POHL J, MOOK G. Laser-vibrometric analysis of propagation and interaction of lamb waves in CFRP-plates[J]. *CEAS Aeronautical Journal*, 2013, 4(1): 77-85.
- [14] NIELSEN M, LUND O. NN-align. An artificial neural network-based alignment algorithm for MHC class II peptide binding prediction[J]. *BMC Bioinformatics*, 2009, 10:296.
- [15] LIN Y, WU Y, GUO D, *et al.* A deep learning framework of autonomous pilot agent for air traffic controller training[J]. *IEEE Transactions on Human-Machine Systems*, 2021, 51(5): 442-450.
- [16] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. *Advances in Neural Information Processing Systems*, 2017, 60(6): 84-90.
- [17] LI H. Deep learning for natural language processing: Advantages and challenges[J]. *National Science Review*, 2018, 5(1): 22-24.
- [18] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics informed deep learning (Part I): Data-driven solutions of nonlinear partial differential equations[J/OL]. (2017-11-28)[2023-02-27]. <https://arxiv.org/abs/1711.10561>.
- [19] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics informed deep learning (Part II): Data-driven discovery of nonlinear partial differential equations[J/OL]. (2017-11-28)[2023-02-27]. <https://arxiv.org/abs/1711.10566>.
- [20] 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.

- [21] RAISSI M, YAZDANI A, KARNIADAKIS G E. Hidden fluid mechanics: Learning velocity and pressure fields from flow visualizations[J]. *Science*, 2020, 367(6481): 1026-1030.
- [22] SAHLI COSTABAL F, YANG Y B, PERDIKARIS P, *et al.* Physics-informed neural networks for cardiac activation mapping[J]. *Frontiers in Physics*, 2020, 8: 00042.
- [23] FANG Z, ZHAN J. Deep physical informed neural networks for metamaterial design[J]. *IEEE Access*, 2019, 8: 24506-24513.
- [24] HASTIE T, TIBSHIRANI R, FRIEDMAN J H, *et al.* The elements of statistical learning: Data mining, inference, and prediction[M]. New York, USA: Springer-Verlag New York Inc, 2009: 389-415.
- [25] MURPHY K P. Machine learning: A probabilistic perspective[M]. Cambridge, USA: MIT Press, 2012: 995-1005.
- [26] MOSELEY B, MARKHAM A, NISSEN-MEYER T. Solving the wave equation with physics-informed deep learning[J/OL]. (2020-06-21)[2023-02-27]. <https://arxiv.org/abs/2006.11894>.
- [27] SHUKLA K, LEONI P, BLACKSHIRE J, *et al.* Physics-informed neural network for ultrasound nondestructive quantification of surface breaking cracks[J]. *Journal of Nondestructive Evaluation*, 2020, 39: 1-20.
- [28] KINGMA D P, BA J. Adam: A method for stochastic optimization[J]. (2014-12-22)[2023-02-27]. <https://arxiv.org/abs/1412.6980>.
- [29] NI C, DONG L, SHEN Z, *et al.* Numerical simulation study of defect detections by using laser array generated giant acoustic waves[J]. *International Journal of Thermophysics*, 2015, 36(5/6): 1236-1243.
- [30] SONG Y, MA Sh B, ZHANG K F. Finite element analysis of thermo-elastic laser ultrasonic excitation and defect detection[J]. *Laser Technology*, 2021, 45(2): 246-251 (in Chinese).
宋艳, 马世榜, 张开飞. 热弹激光超声激励及缺陷检测的有限元分析[J]. *激光技术*, 2021, 45(2): 246-251.
- [31] XU B Q. Numerical modeling of laser ultrasound in layered systems using finite element method and determination the materials parameters using the neural networks[D]. Nanjing: Nanjing University of Science & Technology, 2004: 58-79 (in Chinese).
许伯强. 层状材料的激光超声有限元模拟和神经网络方法反演材料参数的研究[D]. 南京: 南京理工大学, 2004: 58-79.