

DOI: 10.19650/j.cnki.cjsi.J2514525

一种用于油井管道脉冲涡流检测建模的 物理信息神经网络*

罗 斌¹, 师奕兵¹, 陶爱华², 冯 强¹, 张 伟¹

(1. 电子科技大学自动化工程学院 成都 611731; 2. 中海油田服务股份有限公司油田技术事业部 廊坊 065201)

摘 要:脉冲涡流检测方法作为一种无接触、无需耦合剂且环保安全的无损检测方法,常被用于检测金属管道的结构健康状态,脉冲涡流响应估计的及时性和准确性受到油井套管脉冲涡流检测的电磁建模方法的严重限制。传统的数学建模方法需要大量的先验知识,数学模型建立过程复杂且计算成本高。同时,基于纯数据驱动的神经网络方法缺乏物理信息约束,且不够稳健。在生产现场,常常需要一种兼顾效率和精度的脉冲涡流检测建模方法,提出了一种新的物理信息神经网络代理模型,填补了这一空白。将电磁物理定律作为先验知识嵌入到目标损失函数中,以监督深度神经网络的训练过程。此外,使用子神经网络来估计不同计算域的电磁响应,这些域根据其物理特性被分开,设计了一个界面损失函数,以补偿在预测双计算域的结果时各网络之间输出的不连续性,从而提高电磁响应估计的准确性和稳健性。利用有限元分析方法获得的电磁响应数据验证了所提出的物理信息神经网络的性能,并将所提出的物理信息神经网络与传统纯数据驱动的神经网络和插值算法的性能进行了对比。综合分析表明,物理信息神经网络模型能够准确估计油套管脉冲涡流检测中的电磁响应,其决定系数超过 0.95。此外,物理信息神经网络模型的推理速度比有限元分析快 52 倍以上。

关键词:物理信息神经网络;脉冲涡流检测;代理模型;电磁响应估计

中图分类号: TH878 文献标识码: A 国家标准学科分类代码: 460.40

A physical information neural network for modeling pulsed eddy current detection of oil well pipelines

Luo Bin¹, Shi Yibing¹, Tao Aihua², Feng Qiang¹, Zhang Wei¹

(1. School of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China;

2. Welltech Research and Design Institute of China Oilfield Services Co, Langfang 065201, China)

Abstract: Pulse eddy current testing, as a non-contact, environmentally friendly non-destructive testing method requiring no coupling agent, is widely used to assess the structural health of metallic pipelines. The timeliness and accuracy of pulse eddy current response estimation are severely constrained by electromagnetic modelling approaches for well casing pulse eddy current testing. Traditional mathematical modelling approaches demand substantial prior knowledge, entailing complex model construction and high computational cost. Meanwhile, purely data-driven neural network methods lack physical information constraints and exhibit insufficient robustness. Field operations frequently necessitate a pulsed eddy current modelling method balancing efficiency and precision. This research addresses this issue by proposing a novel physical information neural network surrogate model. Electromagnetic physical laws are embedded as prior knowledge within the objective loss function to guide the training process of deep neural networks. Furthermore, sub-neural networks are introduced to estimate electromagnetic responses across distinct computational domains, separated according to their physical characteristics. An interface loss function is designed to compensate for discontinuities in output between networks when predicting results across dual computational domains, thereby enhancing the accuracy and robustness of electromagnetic response estimation. The performance of the proposed physio-informative neural network was validated using electromagnetic response data obtained via finite element analysis. Its capabilities were compared against conventional purely data-driven neural networks and

收稿日期: 2025-09-23 Received Date: 2025-09-23

* 基金项目: 国家自然科学基金项目(U25B20244)、中国海油测井与定向钻井重点实验室开放基金项目(202517434042)资助

interpolation algorithms. Results show that the physical information neural network model accurately estimates electromagnetic responses in oil casing eddy current testing, achieving a coefficient of determination exceeding 0.95. Furthermore, the inference speed of the physical information neural network model surpasses that of finite element analysis by over 52 times.

Keywords: physics-informed neural network; pulsed eddy current testing; surrogate model; electromagnetic response estimation

0 引 言

套管是油井中常见的支撑和保护装置,被誉为“维持油井健康的生命线”。在长期高压运行条件下,结合地层压力,套管容易发生不可预测的变形和腐蚀。这对于油气生产和输送过程的安全性具有严重影响^[1]。脉冲涡流检测具有丰富的频谱成分、强穿透力和高检测效率的优势^[2-3]。因此,脉冲涡流检测(pulsed eddy current testing, PECT)已被广泛应用于导电油井套管的无损检测与评估^[4-7]。他利用脉冲电流产生交变磁场,称为一次磁场交变磁场在套管上产生涡流,涡流不断传播并衰减,产生二次磁场。可以通过估计该一次和二次场的叠加电磁场的参数来检测缺陷^[8-10]。因此,对涡流场进行准确建模以及对涡流场中的电磁响应参数(如磁通密度和磁矢量势)进行估算,对 PECT 至关重要。

近年来,PECT 的涡流场已通过基于物理的数学解析方法建模,以求解电磁响应^[11-13]。这些方法通常基于麦克斯韦方程组构建电磁响应的解析模型,因此具有有限的解空间^[14]。然而,解析模型的数学公式随着精度要求的提高而变得越来越复杂^[15]。此外,这些模型依赖于大量的先验数学知识和计算步骤,对硬件的计算性能更为敏感。作为替代方案,有限元分析(finite element analysis, FEA)通过耦合多个偏微分方程(partial derivate equations, PDEs)来求解电磁响应,并已成为近年来电磁响应估算的主要方法。FEA 在离散的精细时空网格上近似 PDEs,进而将每个计算网格的计算结果综合以确定所建模电磁场的整体特性^[16-17],FEA 方法可提供高保真电磁场模型及电磁响应的精确计算结果,无需推导大量数学和物理方程。然而,FEA 模拟需要进行大量重复计算以求解每个精细网格中的物理场属性。这导致 FEA 中网格越精细,解的精度越高,计算时间越长^[18]。因此,尽管基于物理和数学的电磁建模方法具有良好的可解释性,但在描述电磁系统中所有复杂非线性电磁行为时,通常受限于计算成本、建模复杂性等因素^[15]。迫切需要找到一种新方法,以实现 PECT 中套管电磁响应的实时准确预测。

随着深度学习(deep learning, DL)技术的发展,基于深度学习的物理场建模方法越来越受到关注,例如力学^[19-20]、计算电磁学^[21-22]、超声^[23-25]、热传导^[26-27]等。这些基于深度学习的物理场建模方法不仅能够准确预测不

同系统的响应,而且其推理速度比有限元分析方法快几倍甚至数百倍。理论上,通用逼近理论指出,只要有足够的隐藏单元,一个具有线性输出单元的单隐藏层神经网络可以任意好地逼近任何连续函数^[28]。因此,具有足够神经元的神经网络能够准确估计任何系统的复杂非线性特性。神经网络的这一特性使其非常适合估计 PECT 的非线性电磁响应问题。目前,基于数据驱动的深度学习方法智能电磁计算的主流。在这些方法中,通过监督式神经网络从大量模拟和测量数据中学习麦克斯韦方程,这些数据在不同的电磁响应、激励和边界条件下获取,从而建立输入到输出的直接映射。因此,数据驱动的方法需要大量已知或测量数据来训练能够准确映射电磁响应关系的神经网络^[29]。此外,这些方法对数据敏感且缺乏对所收集数据的鲁棒性。同时,数据收集过程耗时耗力,这严重限制了数据驱动方法对电磁响应的准确估计^[30]。另一个主要缺点是其网络架构缺乏物理意义。因此,其准确性不足,求解空间没有受到物理条件约束。

数据和物理混合驱动的前向和逆向计算是一种近年来提出的方法^[31-34]。与数据驱动方法相比,该范式方法将真实物理偏微分方程、边界条件(boundary conditions, BCs)和初始条件(initial conditions, ICs)融入损失函数,以指导神经网络(neural network, NN)的训练过程,并通过无监督或监督方法完成网络训练。这使 NN 满足特定物理定律的同时,提升了 NN 的可解释性^[35]。典型的混合驱动范式方法是物理信息神经网络(physics-informed neural network, PINN),该方法于 2019 年被提出^[36-38]。PINN 通过最小化结合数据损失和物理损失的损失函数来约束微分方程的解,其中包括物理定律残差(偏微分方程残差)、边界条件残差和初始条件残差,以引导网络的求解过程^[38]。这些正则化规则将神经网络的解空间限制在合理范围内,以找到正确且稳健的解来预测系统行为或响应。正是这些优势使 PINN 能够克服传统数学建模方法的局限性,即无法建模复杂非线性系统,同时解决数据驱动方法解空间不受物理条件约束的问题^[39]。

对于使用 PINN 估算电磁响应参数,目前仅有少数相关研究对此进行了先期探索。例如,Gong 等^[40]提出了一种用于求解二维电磁场的 PINN,该方法利用狄利克雷边界条件作为正则化项,并将在安培定律纳入损失函数,从而求解二维磁静场的响应参数。Kovacs 等^[41]通过最小化静态麦克斯韦方程的残差来实现磁矢量势估计方

法,用于解决磁静学问题,计算反问题中的磁化强度并计算退磁曲线。此外,Zhang等^[42]设计了一种无监督深度学习学习方法,将电磁仿真问题转化为优化过程以进行时域电磁仿真。上述技术验证了PINN在计算简单电磁场单一区域(具有简单规则边界)的电磁响应方面的可行性,并展现了准确性和鲁棒性,但尚未应用于实际工程问题。此外,定义了基于物理信息的稀疏神经网络(physics-informed sparse neural network, PISNN)以解决参数化磁场准静态问题。通过结合软约束(物理定律)与硬约束(监督数据),PISNN能够准确高效地预测永磁涡流装置内电磁参数的分布^[43]。Pu等^[44]基于PINN提出了一种永磁耦合器的性能分析方法,该方法将物理知识融入损失函数以指导网络训练过程。训练后的PINN建立了一种映射关系,能够以高精度和低计算成本映射电机内部磁场行为。类似地,Sun等^[15]设计了一种PINN架构以解决计算电机内部电磁响应的问题。他们在有限数据训练过程中使用偏微分方程监督神经网络,以提高解决电磁响应的准确性。

当前商用脉冲涡流检测设备通常使用简化物理模型或经验模型作为正演模型。简化物理模型通常包含解析模型和半解析模型,商用解析模型通常对其中的积分步骤进行离散化展开以提高计算速度^[45],虽在一定程度上损失了计算精度,但离散化后的模型计算速度通常能提高数十倍甚至上百倍,极大提高了现场应用能力;半解析模型通常使用截断域本征函数展开法(truncated region eigen-function expansion, TREE)建立,由Theodoulidis^[46]于2003年首次提出半解析模型融合了解析模型和数值计算方法,其建模灵活度更高,能实现一些规则形状缺陷的电磁响应建模^[47]。解析模型和半解析模型精确度高,但其建模过程复杂,模型通用性差,且较难实现复杂边界条件下的建模。商用经验模型一般是纯数据驱动的NN或统计学习方法,其计算速度很快,但与PINN相比,经验模型的训练过程依赖大量数据,且模型等同于“黑箱”,模型的解不受物理约束。

尽管上述方法解决了特定场景下电磁响应估计的问题,但将PINN应用于脉冲涡流电磁场中时间变化的电磁响应估计仍是一项具有挑战性的任务,因为该场由多个物理场组成。为填补这一空白,此研究提出了一种基于PINN的套管电磁响应估计新型代理模型,以验证PINN在脉冲涡流时间变化电磁响应估计问题中的有效性。此前尚未有文献研究利用PINN对复杂非线性变化套管电磁场进行电磁响应估计,这主要归因于脉冲涡流电磁场的非线性和时变特性。因此,所提方法是对PINN在脉冲涡流检测应用中可行性的创新性探索。此研究的新颖性和主要贡献包括:

1)提出了一种新型的PINN代理模型架构,用于高

效估计单层套管PECT的时变电磁响应。一些描述时变电磁场物理规律的PDEs被嵌入到损失函数中作为先验知识,以指导网络的训练。因此,神经网络的输出可以被视为嵌入的PDEs和其他约束的解。PINN将方程求解问题转化为神经网络的优化问题,这简化了解决过程,并大大提高了估计电磁响应的速度。

2)整个计算域根据不同的物理属性被划分为两个子域,每个子物理场的电磁响应均通过简单且独立的全连接神经网络进行单独表征。在两个计算域的界面处引入界面损失函数,并利用物理方程缓解因界面处电磁场不连续性导致的梯度剧烈变化现象,从而有效降低电磁响应评估的相对误差。

3)自适应损失函数权重在PINN的训练过程中通过多目标损失权重平衡策略自动更新,该策略包含5种损失类型:偏微分方程损失、边界条件损失、初始条件损失、数据损失和界面损失。自适应损失权重平衡策略基于当前时刻与过去时刻之间的相对变化量计算当前权重值。这种回溯策略为损失函数赋予记忆能力,并自动补偿不同损失项之间幅度的差异。

4)在多个实验中进行的系统性分析表明,PINN在估算套管PECT的复杂电磁响应方面具有准确性和鲁棒性。定量分析表明,PINN估算套管PECT的电磁参数的准确性与有限元分析相当。然而,PINN的计算速度比FEA快52倍以上。

1 模型建立

1.1 用于套管PECT响应估计的物理信息神经网络

此研究提出了一种基于PINN的代理模型架构,用于估计套管电磁响应,包括磁矢量势 \mathbf{A} 和磁通密度 \mathbf{B} ,这些是PECT中的关键参数,并对内部磁场的变化作出响应。

图1展示了基于PINN的磁场物理量预测的神经网络架构。该架构主要包含6个部分,构成了一种新型套管PECT响应估计方法。首先,建立了一个套管的PECT检测模型。其次,将套管物理实体简化为二维直角坐标计算域,并将计算域划分为独立的子域,以适应具有不同物理性质的介质。随后,通过离散采样将每个独立子域在空间和时间维度上离散化为数值点,离散的时间-空间坐标对作为深度神经网络(deep neural networks, DNNs)的输入,DNNs的输出即为预测的磁场物理参数磁矢量势 \mathbf{A} 和磁通密度 \mathbf{B} 。然后,利用自动微分机制获取磁场物理量的自动微分值。随后,电磁物理方程构成的控制方程和边界条件及初始条件被嵌入到损失函数中,以指导DNNs的训练过程。最后,采用多目标损失权重平衡算法,通过乘以自适应权重来确保收敛并最小化整体损失。

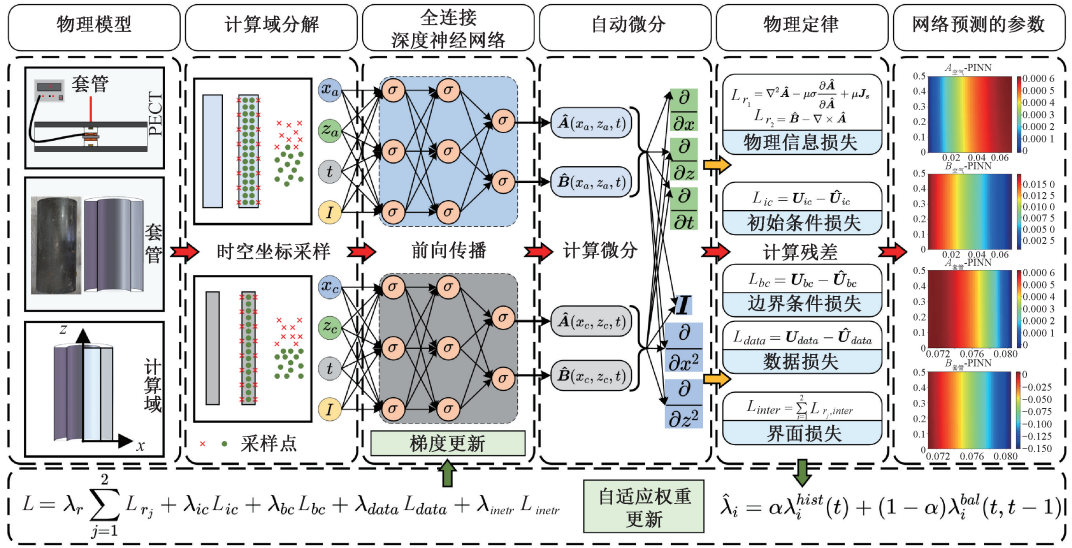


图 1 建立的 PINN 代理模型架构

Fig. 1 Architecture of PINN surrogate model

搭建的 PINN 架构包括一个包含 5 个隐藏层的全连接网络,每一层拥有 30 个神经元,空间坐标 x 和 z 及时间坐标 t 共 3 个输入,输出磁矢势 \hat{A} 和磁通密度 \hat{B} ,每个损失函数的权重 λ 称为超参数,使用多目标损失权重平衡算法进行自适应更新。

该方法依赖于回溯策略赋予的记忆能力,通过平衡损失函数不同大小的问题,进一步提升电磁响应估计的准确性。所提出的 PINN 架构遵循物理定律并确保估计结果的准确性。该方法的目标并非优化神经网络模型架构,而是聚焦于符合物理定律的预测。换言之,深度神经网络的输出结果可视为电磁物理方程的解。基于 PINN 的电磁响应估计框架将复杂的方程求解转化为神经网络优化问题,简化了解决过程,从而提升了响应预测速度。

1.2 PINN 使用的物理控制方程

图 2 为套管测试系统脉冲涡流测试的示意图。该系统通常由电流源、激励线圈、接收线圈和计算机组成,用于计算电磁参数和响应。如图 3 所示(Ω_1 和 Ω_2 分别代表空气和套管区域),套管的物理模型在笛卡尔坐标系中简化为二维区域,其电磁响应也在二维区域内进行估算。为简化计算域,线圈厚度被忽略。脉冲涡流的电磁响应遵循麦克斯韦方程组。因此,套管 PECT 的电磁响应可通过测量数据及由麦克斯韦方程组推导的偏微分方程进行估算^[2]。

此研究中,可通过如式(1)和(2)两个偏微分方程估算两个关键电磁响应参数磁矢势 \hat{A} 和磁通密度 \hat{B} ,即:

$$\mathbf{B} = \nabla \times \mathbf{A} \quad (1)$$

$$\nabla^2 \mathbf{A} - \mu \sigma \frac{\partial \mathbf{A}}{\partial t} = -\mu \mathbf{J}_s \quad (2)$$

其中, μ 为磁导率, σ 为电导率, \mathbf{J}_s 为电流密度。在




图 2 脉冲涡流管道测试系统结构示意图

Fig. 2 Diagram of the structure of the PEC pipeline testing system




图 3 计算域的划分

Fig. 3 Division of computational domains

轴对称二维检测模型中,磁矢势仅存在周向分量 A_φ ,故上述偏微分方程变换为如式(3)和(4)的形式,即:

$$\mathbf{B} = \nabla \times \mathbf{A}_\varphi \quad (3)$$

$$\nabla^2 A_\varphi - \mu \sigma \frac{\partial A_\varphi}{\partial t} = -\mu J_s \quad (4)$$

在不同区域中,公式的形式有所不同,空气域中,该公式退化为泊松方程,如式(5)所示。

$$\nabla^2 A_\varphi = 0 \quad (5)$$

套管域中,磁矢势满足亥姆霍兹方程,如式(6)所示。

$$\nabla^2 \mathbf{A}_\varphi - \mu\sigma \frac{\partial \mathbf{A}_\varphi}{\partial t} = 0 \quad (6)$$

其中, μ 为套管磁导率, σ 为套管电导率。

这些微分方程描述了套管的电磁物理特性,其残差项可用于监测网络输出,这些残差项可以表示如式(7)和(8)所示。

$$\hat{R}_{r_1, r_2}^1 = \hat{\mathbf{B}} - \nabla \times \hat{\mathbf{A}}_\varphi \quad (7)$$

$$\begin{cases} \hat{R}_{r_1}^2 = \nabla^2 \hat{\mathbf{A}}_\varphi \\ \hat{R}_{r_2}^1 = \nabla^2 \hat{\mathbf{A}}_\varphi - \mu\sigma \frac{\partial \hat{\mathbf{A}}_\varphi}{\partial t} \end{cases} \quad (8)$$

其中,上标 $\hat{\cdot}$ 表示神经网络的估计输出,下角标 $r_1 \sim r_2$ 表示不同的计算域,上角标 1 和 2 代表每个区域内由不同物理方程计算的残差。由于不同计算子域中的介质具有不同的物理参数,因此需要对各子域内的控制方程进行独立求解。具体方法将在 1.3 节详细阐述。

1.3 具有界面损失的计算域划分

如 1.2 节所述,提出的 PINN 框架包含两个区域(见图 1 和 3),分别对应管道内部空气区域(以下简称空气域)和金属套管所在区域(以下简称套管域),在两个区域中分别建立深度神经网络以计算该区域的磁场物理量,划分的两个区域称为计算域。两个计算域各自独立构建了独立的 DNN 神经网络,称为两个子神经网络,通过联合损失函数进行同步训练,从而实现对整个套管 PECT 系统电磁响应的精准评估。这种分域处理方式通过聚焦不同区域简化了整体网络架构,并通过适配特定子域优化了电磁响应估计精度。然而,物理信息与数据中的不连续性可能导致界面域(空气域与套管域)出现较大误差。因此,这种基于计算域独立划分的响应估计方法存在一个根本性难题:如何将两个独立神经网络整合为统一的预测机制来实现电磁响应预测?

为解决这一问题,采用物理信息约束的界面损失函数来整合两个独立的神经网络。通过这种方式,每个独立网络都会为各自的计算域输出估计响应值,并通过界面损失函数进行整合。

在涡流检测中,若存在相邻的介质 1 和 2,则在两种介质的交界面存在切向边界条件如式(9)所示,和法向边界条件如式(10)所示。

$$\begin{cases} \mathbf{n}_{12} \times (\mathbf{E}_2 - \mathbf{E}_1) = 0 \\ \mathbf{n}_{12} \times (\mathbf{H}_2 - \mathbf{H}_1) = \mathbf{J}_f \end{cases} \quad (9)$$

$$\begin{cases} \mathbf{n}_{12} \times (\mathbf{B}_2 - \mathbf{B}_1) = 0 \\ \mathbf{n}_{12} \times (\mathbf{D}_2 - \mathbf{D}_1) = \rho_{12} \end{cases} \quad (10)$$

其中, ρ_{12} 为表面电荷密度, \mathbf{J}_f 为表面电流密度,

\mathbf{n}_{12} 为垂直于交界面的法向单位矢量。若两种介质的导电性有限, \mathbf{J}_f 则会迅速消失,如式(11)所示。

$$\mathbf{n}_{12} \times (\mathbf{H}_2 - \mathbf{H}_1) = 0 \quad (11)$$

由于法向边界条件中的方程可分别由切向边界条件中的方程结合旋度运算导出,因此只需使用式(9)和(10)中两个不相关的方程即可。此研究中使用关于磁场强度 \mathbf{H} 和磁感应强度 \mathbf{B} 的方程分别作为切向边界条件和法向边界条件,如式(12)和(13)所示。

$$\mathbf{n}_{12} \times (\mathbf{H}_2 - \mathbf{H}_1) = 0 \quad (12)$$

$$\mathbf{n}_{12} \times (\mathbf{B}_2 - \mathbf{B}_1) = 0 \quad (13)$$

由式可知,在套管脉冲涡流检测中于空气域和套管域的交界面处存在切向边界方程,如式(14)所示。

$$\begin{cases} \boldsymbol{\rho}_0 \times (\mathbf{H}_z^{(2)} - \mathbf{H}_z^{(1)}) \big|_{\rho=b_2} \\ \boldsymbol{\rho}_0 \times (\mathbf{H}_\varphi^{(2)} - \mathbf{H}_\varphi^{(1)}) \big|_{\rho=b_2} \end{cases} \quad (14)$$

其中, $\boldsymbol{\rho}_0$ 为径向单位矢量。在二维轴对称套管检测中 $\mathbf{B}_\varphi = 0$,因此可得如式(15)所示的关系为:

$$\boldsymbol{\rho}_0 \times \left(\frac{\mathbf{B}_z^{(2)}}{\mu^{(2)}} - \frac{\mathbf{B}_z^{(1)}}{\mu^{(1)}} \right) \bigg|_{\rho=b_2} = 0 \quad (15)$$

根据式对上式进行化简,可得在交界面 $\rho = r_3$ 处磁矢势 \mathbf{A} 的切向边界方程如式(16)所示。

$$\frac{1}{\rho} \frac{\partial}{\partial \rho} (\mathbf{A}_\varphi^{(1)}) \big|_{\rho=b_2} = \frac{1}{\rho} \frac{\partial}{\partial \rho} (\mathbf{A}_\varphi^{(2)}) \big|_{\rho=b_2} \quad (16)$$

同理,可由式得脉冲涡流检测中交界面处的法向边界方程如式(17)所示。

$$(\mathbf{B}_\rho^{(2)} - \mathbf{B}_\rho^{(1)}) \big|_{\rho=b_2} \quad (17)$$

由于 \mathbf{A}_ρ 和 \mathbf{A}_z 均为 0,可得磁矢势 \mathbf{A} 得法向边界方程如式(18)所示。

$$\mathbf{A}_\varphi^{(1)} \big|_{\rho=b_2} = \mathbf{A}_\varphi^{(2)} \big|_{\rho=b_2} \quad (18)$$

通过式(17)和(18)所示交界面处的边界方程可以建立物理信息损失函数,整合两个区域的子神经网络输出的响应值,式(19)和(20)给出了界面损失函数表达式,其中 μ_r 为套管的相对磁导率。

$$\hat{R}_{inter1} = \hat{\mathbf{A}}^{(1)} - \hat{\mathbf{A}}^{(2)} \quad (19)$$

$$\hat{R}_{inter1} = \frac{\partial(r\hat{\mathbf{A}}^{(1)})}{\partial r} - \frac{\partial(r\hat{\mathbf{A}}^{(2)})}{\mu_r \partial r} \quad (20)$$

由式(19)和(20)可知,界面损失函数描述了磁场强度和磁感应强度在空气域和套管域的交界面处的连续性,而磁感应强度的连续性又可根据物理公式推至磁矢势的连续性,通过训练降低这一损失函数,可以降低交界面处磁场物理量的不连续性。

根据上述描述,指导网络训练过程的目标损失函数包含 5 个主要组成部分,旨在使两个神经网络能够准确估计套管脉冲涡流的电磁响应。PINN 训练的目标函数如式(21)所示。

$$\mathbf{x} = \lambda_r \sum_{j=1}^2 \mathbf{x}_{r_j} + \lambda_{ic} \mathbf{x}_{ic} + \lambda_{bc} \mathbf{x}_{bc} + \lambda_{data} \mathbf{x}_{data} + \lambda_{inter} \mathbf{x}_{inter} \quad (21)$$

整个损失函数包含 5 个部分, $\sum_{j=1}^2 \mathbf{x}_{r_j}$, \mathbf{x}_{ic} , \mathbf{x}_{bc} , \mathbf{x}_{data} 和 \mathbf{x}_{inter} , 分别代表两个子域内的物理信息损失(也称偏微分损失)、初始条件损失、边界条件损失、数据损失和界面损失, 其中初始条件是 $t=0$ ms 时计算域各采样点的初值, 边界条件是各时间点计算域边界上的采样点数据。 λ_r 、 λ_{ic} 、 λ_{bc} 、 λ_{data} 和 λ_{inter} 是可以自适应调节的超参数。每一项损失都会随着时间 t 进行计算, 以估计每一个子网络中空间坐标点 $\mathbf{X} = \{x, z\}$ 处的电磁响应参数。因此, 每个网络的输入都是一个三维时空数据对 $\mathbf{X} = \{x, z, t\}$, 因此输入层被配置为 3 个神经元。两个区域中的物理信息损失函数 $\sum_{j=1}^2 \mathbf{x}_{r_j}$ 源自偏微分方程式(7)和(8), 其定义如式(22)所示。

$$\sum_{j=1}^2 \mathbf{x}_{r_j} = \frac{1}{N_{a,r}} \sum_{j=1}^2 \sum_{i=0}^{N_{a,r}} |\hat{\mathbf{R}}_{a,r_j}^i|_{\Omega_1 \times [0, T]}^2 + \frac{1}{N_{c,r}} \sum_{j=1}^2 \sum_{i=0}^{N_{c,r}} |\hat{\mathbf{R}}_{c,r_j}^i|_{\Omega_2 \times [0, T]}^2 \quad (22)$$

其中, $N_{*,r}$ 是采样空间域 Ω_* 内的时空采样点的数量, 并且 $t \in [0, T]$, $T = 50$ ms 是所需求解的时间周期。

$\sum_{j=1}^2 \hat{\mathbf{R}}_{*,r_j}$ 表示偏微分方程的残差, 由神经网络和自动微分机制计算得出。下标 $*_a$ 和 $*_c$ 分别代表空气域和套管域。在式(22)的基础上, 各计算域内的物理信息损失由 4 个偏微分方程残差项组成, 在 DNN 的训练中起着重要的作用。剩余的损失项函数由如式(23)~(25)所示。

$$\mathbf{x}_{ic} = \frac{1}{N_{a,ic}} \sum_{i=0}^{N_{a,ic}} |\mathbf{U}_{a,ic}^i - \hat{\mathbf{U}}_{a,ic}^i|_{\Omega_1 \times \partial T}^2 + \frac{1}{N_{c,ic}} \sum_{i=0}^{N_{c,ic}} |\mathbf{U}_{c,ic}^i - \hat{\mathbf{U}}_{c,ic}^i|_{\Omega_2 \times \partial T}^2 \quad (23)$$

$$\mathbf{x}_{bc} = \frac{1}{N_{a,bc}} \sum_{i=0}^{N_{a,bc}} |\mathbf{U}_{a,bc}^i - \hat{\mathbf{U}}_{a,bc}^i|_{\partial \Omega_1 \times T}^2 + \frac{1}{N_{c,bc}} \sum_{i=0}^{N_{c,bc}} |\mathbf{U}_{c,bc}^i - \hat{\mathbf{U}}_{c,bc}^i|_{\partial \Omega_2 \times \partial T}^2 \quad (24)$$

$$\mathbf{x}_{data} = \frac{1}{N_{a,data}} \sum_{i=0}^{N_{a,data}} |\mathbf{U}_{a,data}^i - \hat{\mathbf{U}}_{a,data}^i|_{\Omega_1 \times T}^2 + \frac{1}{N_{c,data}} \sum_{i=0}^{N_{c,data}} |\mathbf{U}_{c,data}^i - \hat{\mathbf{U}}_{c,data}^i|_{\Omega_2 \times T}^2 \quad (25)$$

其中, \mathbf{U}_* 表示神经网络训练过程中的参考值, $\hat{\mathbf{U}}_*$ 表示深度神经网络对于电磁响应参数的估计值(包括 $\hat{\mathbf{A}}_\varphi$, $\hat{\mathbf{B}}_r$ 和 $\hat{\mathbf{B}}_z$)。下标 $*_{ic}$ 、 $*_{bc}$ 和 $*_{data}$ 分别代表了初始条件、边界条件和各子区域内的采样数据。 $N_{*,ic}$ 、 $N_{*,bc}$ 、 $N_{*,data}$

和 $N_{*,bc}$ 代表了在区域 Ω_1 或 Ω_2 和 $\partial \Omega_1$ (图 4 中的 b_1) 或 $\partial \Omega_2$ (图 4 中的 b_3) 得到的时空采样点的数量, 其中 $N_{*,ic}$ 在时间 $t=0$ ms 时进行采集, $N_{*,data}$ 和 $N_{*,bc}$ 则在所有时间点上均进行采集。

在式(21)中, 最后 1 项是界面损失函数, 由物理信息方程构成, 其中引用的物理方程由式(19)和(20)表达, 如式(26)所示。

$$\mathbf{x}_{inter} = \frac{1}{N_{inter}} \sum_{j=1}^2 \sum_{i=0}^{N_{inter}} |\hat{\mathbf{R}}_{a,inter_j}^i|_{\partial \Omega_1 = \partial \Omega_2}^2 \times T + \frac{1}{N_{inter}} \sum_{j=1}^2 \sum_{i=0}^{N_{inter}} |\hat{\mathbf{R}}_{c,inter_j}^i|_{\partial \Omega_1 = \partial \Omega_2}^2 \times T \quad (26)$$

其中, N_{inter} 代表交界面处的采样点数量。界面损失函数通过最小化偏微分方程残差, 解决了由于界面不连续而导致的梯度急剧变化的问题。

1.4 神经网络表征电磁响应

神经网络在约束空间内根据物理条件和数据限制寻找最优解。这意味着上述方程的最优解可以通过神经网络来描述。通常采用简单的全连接神经网络、卷积神经网络^[48-49]以及循环神经网络^[50]作为代理模型来模拟物理场。此研究中使用的是前向全连接神经网络, 其中相邻层的神经元完全连接, 各层输出直接作为下一层的输入。一个典型的前向神经网络可定义为如式(27)所示的形式, 即:

$$\mathbf{x}_L = \mathbf{x}_0 \circ \mathbf{x}_1 \circ \mathbf{x}_2 \cdots \circ \mathbf{x}_{L-1} \quad (27)$$

其中, \mathbf{x}_0 和 \mathbf{x}_L 代表神经网络的输入层和输出层。隐藏层称为 \mathbf{x}_h , $h = 1, 2, 3, \dots, L-1$ 。从数学上讲, 两个相邻层的连接方式如式(28)所示。

$$\mathbf{x}_l = \sigma_l(\mathbf{W}_l \cdot \mathbf{x}_{l-1} + \mathbf{b}_l) \quad (28)$$

其中, $\sigma_l(\cdot)$ 是激活函数, \mathbf{W}_l 和 \mathbf{b}_l 分别是权重矩阵和偏置矩阵。因此, 代理建模通过逐层映射实现, 建立了输入输出映射关系。为了建立用于 PECT 电磁响应估计的代理模型, 可将神经网络视为满足如下条件的黑盒代理模型 $x_L(\mathbf{X}, \boldsymbol{\theta})$, 如式(29)所示。

$$\mathbf{U}(\mathbf{X}) \approx \hat{\mathbf{U}}(\mathbf{X}, \boldsymbol{\theta}) \triangleq x_L(\mathbf{X}, \boldsymbol{\theta}) \quad (29)$$

其中, \mathbf{X} 是输入的时空坐标对, $\boldsymbol{\theta}$ 表示神经网络的训练参数 (\mathbf{W}, \mathbf{b}) 。因此, 式(21)的等式就变成了一个优化问题, 如式(30)和(31)所示。

$$\mathbf{x}(\boldsymbol{\theta}) = \lambda_r \sum_{j=1}^2 \mathbf{x}_{r_j}(\boldsymbol{\theta}) + \lambda_{ic} \mathbf{x}_{ic}(\boldsymbol{\theta}) + \lambda_{bc} \mathbf{x}_{bc}(\boldsymbol{\theta}) + \lambda_{data} \mathbf{x}_{data}(\boldsymbol{\theta}) + \lambda_{inter} \mathbf{x}_{inter}(\boldsymbol{\theta}) \quad (30)$$

$$\boldsymbol{\theta}^* = \operatorname{argmin} \mathbf{x}(\boldsymbol{\theta}) \quad (31)$$

其中, $\boldsymbol{\theta}^*$ 表示最优权重 \mathbf{W}^* 和最优偏置 \mathbf{b}^* 。此外, 整个损失函数的每一项都包含由 DNN 预测的值 $\hat{\mathbf{U}}(\mathbf{X}, \boldsymbol{\theta})$, 例如初始条件损失函数 \mathbf{x}_{ic} 可以表示为如式(32)和(33)所示的形式, 即:

$$x_{ic}(\boldsymbol{\theta}_a, \boldsymbol{\theta}_c) = \frac{1}{N_{a,ic}} \sum_{i=0}^{N_{a,ic}} |U_{a,ic}^{i}(X_{a,ic}) -$$

$$\hat{U}_{a,ic}(X_{a,ic}, \boldsymbol{\theta}_{a,ic})|^2_{\Omega_1 \times \delta T} + \frac{1}{N_{c,ic}} \sum_{i=0}^{N_{c,ic}} |U_{c,ic}^{i}(X_{c,ic}) - \hat{U}_{c,ic}(X_{c,ic}, \boldsymbol{\theta}_{c,ic})|^2_{\Omega_2 \times \delta T} \quad (32)$$

$$\boldsymbol{\theta}_a^*, \boldsymbol{\theta}_c^* = \arg \min x_{ic}(\boldsymbol{\theta}_a, \boldsymbol{\theta}_c) \quad (33)$$

此外,偏微分方程式(3)可以用神经网络的预测值表示,如式(34)所示。

$$\begin{aligned} \hat{\mathbf{R}}_1 &= \hat{\mathbf{B}} - \nabla \times \hat{\mathbf{A}} = x_L^B(\mathbf{X}, \boldsymbol{\theta}) - \nabla \times x_L^A(\mathbf{X}, \boldsymbol{\theta}) = \\ & x_{L-1}^B \circ \dots \circ x_2^B \circ x_1^B \circ x_0^B - \nabla \times x_{L-1}^A \circ \dots \circ x_2^A \circ x_1^A \circ x_0^A = \\ & \sigma_L(\mathbf{W}_L^B \cdot x_{L-1}^B + \mathbf{b}_L^B) - \nabla \times \sigma_L(\mathbf{W}_L^A \cdot x_{L-1}^A + \mathbf{b}_L^A) = \\ & \sigma_L(\mathbf{W}_L^B \cdot \sigma_{L-1}(\mathbf{W}_{L-1}^B \cdot x_{L-2}^B + \mathbf{b}_{L-1}^B) + \mathbf{b}_L^B) - \nabla \times \\ & \sigma_L(\mathbf{W}_L^A \cdot \sigma_{L-1}(\mathbf{W}_{L-1}^A \cdot x_{L-2}^A + \mathbf{b}_{L-1}^A) + \mathbf{b}_L^A) = \dots \dots = \\ & \sigma_L(\mathbf{W}_L^B \cdot \dots \sigma_1(\mathbf{W}_1^B \cdot \mathbf{X} + \mathbf{b}_1^B) + \mathbf{b}_L^B) - \nabla \times \\ & \sigma_L(\mathbf{W}_L^A \cdot \dots \sigma_1(\mathbf{W}_1^A \cdot \mathbf{X} + \mathbf{b}_1^A) + \mathbf{b}_L^A) \end{aligned} \quad (34)$$

通过上述分析,将神经网络的输出输入到物理偏微分方程中,计算当前方程的残差,该残差被用作目标函数来指导神经网络的训练过程。因此,管道 PECT 电磁响应估计问题转化为神经网络的优化问题:通过持续训练和优化,使神经网络的参数 $\boldsymbol{\theta}$ 满足方程式(21)~(26)。同时,包含控制方程、初始条件和边界条件的方程解由神经网络表示。这种将方程求解问题转化为优化问题的方法简化了电磁参数求解过程,避免了对数学建模知识的高要求,大幅提升了求解速度并提高了建模结果的时效性。

1.5 多目标损失权重平衡算法

根据 1.2~1.4 节的描述,求解套管脉冲涡电流电磁响应问题可转化定义为式(21)的优化问题。该损失函数是一个包含 24 个子项的多目标优化问题,其中包含偏微分方程残差的损失项,以及对应初始条件、边界条件和数据残差等各数据拟合项的损失项。在多目标优化中,不同目标项之间的平衡是关键问题。由于损失函数中占比较大的目标项会主导梯度更新方向,容易导致过度拟合问题。为此,引入了基于随机回溯的相对损失平衡算法^[51]。该算法计算各权重项的步骤如式(35)、(36)和(37)所示。

$$\lambda_i^{bal}(t, t') = m \cdot \frac{\exp\left(\frac{x_i(t)}{\Gamma x_i(t')}\right)}{\sum_{j=1}^m \exp\left(\frac{x_j(t)}{\Gamma x_j(t')}\right)}, i \in \{1, \dots, m\} \quad (35)$$

$$\lambda_i^{hist}(t) = \rho \lambda_i(t-1) + (1-\rho) \lambda_i^{bal}(t, 0) \quad (36)$$

$$\lambda_i(t) = \alpha \lambda_i^{hist} + (1-\alpha) \lambda_i^{bal}(t, t-1) \quad (37)$$

其中, α 表示指数衰减率, ρ 是伯努利随机变量,

$E[\rho]$ 接近于 1。中间变量 $\lambda_i^{bal}(t, t')$ 根据时间步 t 和 t' 之间各项的相对变化量计算缩放系数。 λ_i^{hist} 携带历史信息。最终,缩放系数 $\lambda_i(t)$ 通过指数衰减获得。上述因子 α 决定了缩放系数的权重。 T 是温度超参数,当 $T \rightarrow \infty$ 时,它会重新校准 softmax 输出均匀值。相反,当 $T \rightarrow 0$ 时,softmax 转换为 argmax 函数,并将较小的权重项按 K 倍缩放,而其他项则按零因子缩放。 m 表示损失项的数量。

新提出的多目标损失权重平衡算法通过自动调整各损失项的权重,使不同项的历史与当前变化差异相匹配,从而实现多目标优化问题的收敛。具体而言,该算法通过为每个损失项应用自适应权重来增强损失函数的收敛性。这些权重会根据各损失项的历史差异自动更新。基于随机回溯的相对损失平衡算法避免使用梯度统计量,因此相比其他基于梯度的平衡方法(如 Wang 等^[52] 2021 年的学习率退火法和 Chen 等^[53] 2018 年的梯度范数法)具有更高的效率。

2 实验验证

2.1 PINN 的结构和训练方法

提出的 PINN 框架基于 PyTorch 平台实现。所有测试集均在配备英特尔® Xeon® Gold 6248R 中央处理器、英伟达 GeForce RTX A6000 显卡及 512 GB 内存的服务器系统上完成训练与测试。所有数据集及对比方法均采用 PyTorch 框架实现。在进行单域电磁响应估计时,式(21)中未引入界面损失函数,仅保留前 4 项损失项。界面损失函数仅在进行双域电磁响应估计时引入。

如 1.3 节所述,每个子域的电磁响应通过空气和套管域的独立子网络进行估算。因此,在 PINN 分离 DNN(如图 2 所示),分别用于估计两个电磁响应参数:磁矢势 \mathbf{A} 和各子域的磁通密度 \mathbf{B} 。DNN 的输入数据采用三维格式,包含离散时空坐标对,其中时间 t 、空间信息 x (计算域宽度)和 z (计算域高度)均以三维形式呈现。子网络由 5 个隐藏层构成,每层包含 30 个神经元并使用 Tanh 激活函数。输入层设有 3 个神经元以匹配原始数据,输出层配置 2 个神经元用于估算各子域的电磁响应。

整个数据集包含每个子域空间轴上的 50 个点和时间轴上的 101 个点,具体而言,空气域的 x 轴取值范围为 0~71 mm,套管域的 x 轴取值范围为 71~80.5 mm,即管道厚度为 9.5 mm,两个计算域的 z 轴范围均为 0~500 mm,每个计算域中,在 x 和 z 轴上均匀采样 50 个点,时间坐标 t 的取值范围为 0~50 ms,均匀采样 101 个点,采样间隔为 0.5 ms。这些数据点由网格坐标对生成,其中包含边界条件、初始条件、随机采样点和界面条件。具体而言,每个子域的总数据点数为 252 500;包含 5 050 个

边界点、2 500 个初始点、空气域和套管域分别采集的 239 900 个网格坐标点,以及交界面处的 5 050 个点。为降低训练成本,每个计算子域的 252 500 个数据点被分为两部分:前 150 000 个点用于训练神经网络,后 102 500 个点作为测试集。换言之,训练集占总数据集的 60%,测试集占 40%。

为确保物理信息神经网络(PINN)高效收敛,训练过程需要进行 10 万次迭代。采用均方误差损失函数作为评估指标来监控训练阶段的收敛情况。当损失函数值低于设定阈值或趋于稳定时,即判定获得最佳结果并存储最优网络权重。使用 Adam 优化器进行 PINN 优化,初始学习率为 0.001,每迭代 100 次后学习率按 1/100 比例递减。整个训练与预测流程如算法 1 所示。

算法 1: PINN 的训练和预测过程

PINN 训练过程

- 1: 加载时间-空间坐标对 $X_{train} = \{X_a, X_c\}$ 和真实电磁响应参数 $U = \{A_a, A_c, B_a, B_c\}$ 。
- 2: 设置训练循环次数 $e = 0$ 和单次训练样本数量 E 。
- 3: 分别构建空气域和套管域的子神经网络并初始化神经网络参数 $\theta = \{\theta_a, \theta_c\}$ 。
- 4: 当 $e < E$ 时,进行如下 5~9 循环:
- 5: 在无真实数据监督的情况下利用公式计算各区域内的偏微分方程残差 x_j 和交界面偏微分方程残差损失 x_{inter} 。
- 6: 利用已知数据 U 计算初始条件损失 x_{ic} ,边界条件损失 x_{bc} 和数据残差损失 x_{data} 。
- 7: 利用多目标损失权重平衡算法更新各损失函数的权重 λ_i 。
- 8: 更新网络参数 θ ,以最小化自适应权重损失 x 。
- 9: $e = e + 1$,结束循环并返回神经网络参数 θ 。

PINN 预测过程

- 1: 加载时间-空间坐标对 $X_{train} = \{X_a, X_c\}$ 以预测电磁响应参数 $\hat{U} = \{\hat{A}_a, \hat{A}_c, \hat{B}_a, \hat{B}_c\}$ 。
- 2: 加载神经网络参数 $\theta = \{\theta_a, \theta_c\}$ 。
- 3: 将时-空坐标数据对输入神经网络中,进行前向传播得到电磁响应参数 \hat{U} 。
- 4: 得到两个子域中的各网格点上的电磁响应数据。

图 4(a)展示了训练损失的变化趋势。与纯数据驱动型人工神经网络类似,PINN 的损失函数在早期呈现振荡收敛特性,后期逐渐趋于稳定状态。在物理约束条件下,网络能更早达到稳态,通常在 6 万次迭代时即可基本收敛;相比之下,数据驱动型人工神经网络需约 7 万次迭代才能稳定。数据驱动型卷积神经网络(convolutional neural network, CNN)收敛速度更快,但其损失值较大且难以进一步优化。值得注意的是,由于引入物理约束等限制条件,网络输出在训练初期无法同时满足所有约束条件,导致早

期损失函数值较高。此外,图 4(b)展示了包含界面损失与不包含界面损失的训练损失曲线对比。可以看出,界面损失并未对整体损失函数产生显著影响。然而引入界面损失能有效解决数据断层问题,从而显著提升网络对电磁响应的预测精度。图 4(c)和(d)分别展示了偏微分方程残差损失、初始条件损失、边界条件损失、数据损失、交界面损失以及各损失项的权重因子 λ_i 在训练过程中的变化曲线。图 4(c)显示 5 种损失函数在训练初期均呈现竞争关系并伴随波动,但随着训练进入后期,残差数据损失逐渐占据主导地位并决定网络优化方向。同时,图 4(d)中各损失项的权重在训练初期也出现波动,这正是由引入的多目标损失权重平衡策略自动计算得出的结果。由于网络初始状态不稳定,任何对权重的反向更新都可能不够精准,导致需要较大的损失权重。由于当前损失基本上是相同的或对比上一个时刻变化较少,因此每个损失项的权重因子趋于稳定,因为网络趋向于一个稳态。

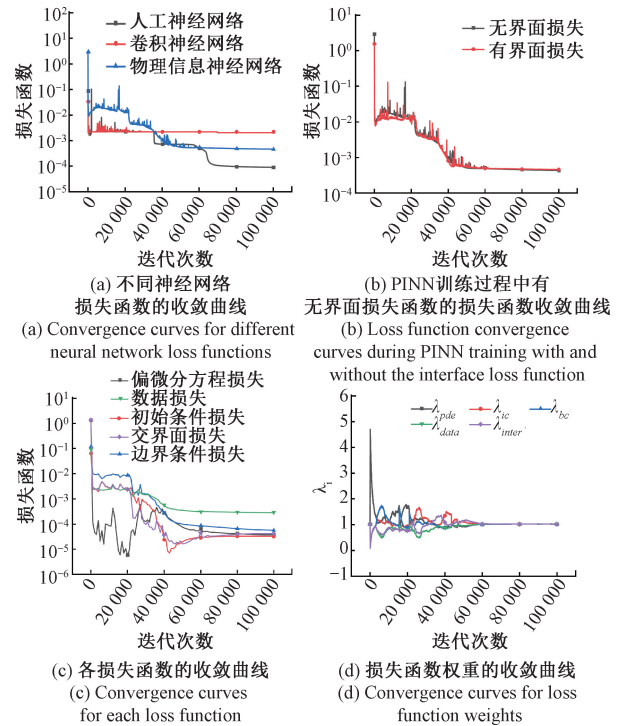


图 4 PINN 训练相关参数迭代曲线

Fig. 4 Iteration curve of PINN training parameters

2.2 有限元数值仿真

在有限元数值仿真中,采用有限元分析法计算套管 PECT 有限元分析模型的电磁响应。基于这些已知数据,对 PINN 及其他神经网络的电磁响应估计性能进行验证。有限元模拟在 2.1 节所述的同一硬件平台上完成。由于套管具有对称性,仅需计算其一半区域,因此采用套管剖面构建二维模型。图 5 展示了套管剖面(图 5(a))

及计算关注域(图5(b))中的空气与套管区域),图5(c)则呈现了有限元网格配置。

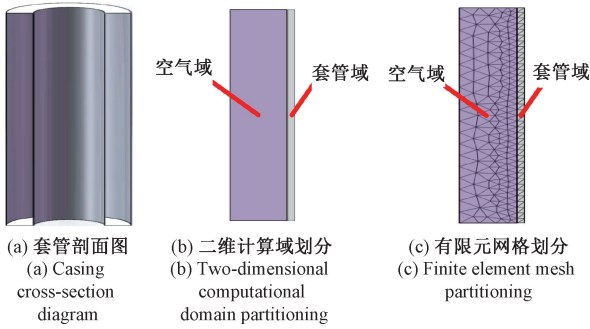


图5 计算域划分和有限元仿真网格划分

Fig. 5 Calculational-domain partitioning and finite-element mesh partitioning

表1列出了实验所用套管的物理参数。为确保收敛精度,在空气与套管区域的界面边界处采用了更精细的网格划分。根据上述网格配置,共生成871个网格单元。该有限元模拟方法能精准估算不同关注区域的电磁响应,包括磁矢势 \mathbf{A} 和磁通密度 \mathbf{B} ,为提出的PINN训练与验证提供了参考数据。

表1 管道物理参数

Table 1 Physical parameters of the pipeline

参数	符号	参数值	单位
管道内径	r_i	142	mm
管道外径	r_o	161	mm
管道长度	L	0.5	m
激励线圈匝数	N_d	863	
真空磁导率	μ_0	$4 \times \pi \times 10^{-7}$	H/m
管道相对磁导率	μ_r	74.7	
管道电导率	σ_r	5×10^6	S/m
激励电流幅度	I	1	A
激励电流上升时间	t_r	1	μs

2.3 不同方法间的对比和评估指标

与此同时,通过一系列对比实验,将提出的物理信息神经网络(PINN)框架、纯数据驱动的全连接人工神经网络(artificial neural network, ANN)以及纯数据驱动的卷积神经网络(CNN)进行横向比较,以进一步验证其性能优势。其中,ANN架构与深度神经网络(DNN)相同,但未设置任何物理约束条件。CNN采用 1×1 卷积核提取电磁响应特征并生成最终电磁响应结果,其输入为时空坐标数据,输出为电磁响应估计值,仿真数据则作为参考基准。

使用4个指标来客观评估所有方法的性能,其中包括均方根误差(root mean square error, RMSE)、平均绝对

误差(mean absolute error, MAE)、相对误差(relative error, RE)和决定系数(coefficient of determination, R^2)。这些评估指标分别定义如式(38)~(41)所示。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (38)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (39)$$

$$RE = \frac{\sum_{i=1}^N \|\hat{y}_i - y_i\|_2}{\sum_{i=1}^N \|y_i\|_2} \quad (40)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{\sum_{i=1}^N (\bar{y}_i - y_i)^2} \quad (41)$$

其中, N 为样本数量, \hat{y} 和 y 分别表示预测值与真实值, $\|\dots\|_2$ 表示 L_2 范数。在上述4个指标中, RMSE、RE和MAE越接近0越好,而 R^2 指标则越接近1表示预测效果越优。PINN通过上述4个指标进行了综合评估,具体细节详见第3章。

3 实验结果

为了进一步说明所提出的PINN的有效性,文中详细描述并分析了几个测试。这些测试包括一个简单的单计算域和一个复杂的双计算域,并通过从简单到复杂的计算测试,全面分析了PINN的优势和劣势。

3.1 单计算域响应估计

表2和3展示了基于纯数据驱动的人工神经网络(ANN)、卷积神经网络(CNN)以及提出的物理信息神经网络(PINN)在空气域电磁响应预测中的表现。针对磁矢势 \mathbf{A} 的预测,与有限元分析(FEA)基准相比, PINN预测的决定系数比纯数据驱动的ANN高出约0.022,相对误差为0.034,显示出良好的预测精度。而CNN的决定系数仅为0.890,明显低于ANN和PINN。此外,纯数据驱动方法(ANN和CNN)的平均绝对误差(MAE)均高于PINN,其均方根误差(RMSE)也更高。ANN预测的相对误差是PINN的两倍。CNN的预测精度显著低于ANN和PINN,其均方根误差和MAE值均为最大。对于磁通密度 \mathbf{B} 的预测, PINN仍保持高精度,决定系数达0.998,比纯数据驱动的ANN高出0.010,与CNN持平。同时, PINN的RMSE和RE均大幅低于ANN和CNN,展现出优于数据驱动方法的预测性能。ANN的MAE值高达 3.909×10^{-4} ,几乎是PINN的5倍。

此外,图6和7展示了不同方法的预测结果。前两行显示各方法的预测结果,后两行则是预测结果的误

表 2 不同方法的计算性能对比 (参数 A , 空气域)

Table 2 Comparison of computational performance of different methods (parameter A , air domain)

方法	RMSE	MAE	RE	R^2
人工神经网络	3.133×10^{-5}	2.315×10^{-5}	0.070	0.972
卷积神经网络	6.212×10^{-5}	5.057×10^{-5}	0.139	0.890
物理信息神经网络	1.478×10^{-5}	1.041×10^{-5}	0.034	0.994

表 3 不同方法的计算性能对比 (参数 B , 空气域)

Table 3 Comparison of computational performance of different methods (parameter B , air domain)

方法	RMSE	MAE	RE	R^2
人工神经网络	5.600×10^{-4}	3.909×10^{-4}	0.056	0.988
卷积神经网络	5.592×10^{-4}	3.892×10^{-4}	0.056	0.988
物理信息神经网络	2.069×10^{-4}	8.320×10^{-5}	0.021	0.998




图 6 磁矢量势 A 的预测结果 (空气区域, 第 1 和第 3 行 $t=0.5$ ms, 第 2 和第 4 行 $t=15$ ms)

Fig. 6 Estimation results of magnetic vector potential A (air region, first and third rows at $t=0.5$ ms, second and fourth rows at $t=15$ ms)

差图。具体而言,图 6 和 7 的第 1 列展示有限元分析参考值,第 2~4 列分别对应 ANN、CNN 和 PINN 的预测结果。可以看出,纯数据驱动的人工神经网络在 $t=0.5$ ms 和 $t=15$ ms 时刻的空气域电磁响应估计中呈现出两种截然不同的趋势。当 $t=0.5$ ms 时,ANN 的预测值高于真实参考值,因此真值减去预测值为负值,而到 $t=15$ ms 时,预测值与真实值的差异变小。同时,右上方区域的预测值相较于真实值更小。相比之下,PINN 模型在 $t=0.5$ ms 和 $t=15$ ms 时均展现出更优的预测性能,其误差较小。另一方面,CNN 模型在磁矢势和磁通密度的预

测结果均低于 ANN 模型,且其误差值均大于 ANN 方法的预测结果。

表 4 和 5 列出了套管区域电磁响应的预测结果。对于磁矢势 A ,ANN 和 PINN 展现出相近的预测精度,均超过 0.980。同时,RMSE 和 MAE 处于同一量级,二者相对误差与决定系数的差异均小于 0.002。然而在预测磁通密度 B 时,ANN 与 PINN 存在显著差异:ANN 的预测效果更优,其决定系数比 PINN 高出约 0.043,展现出更好的预测精度。因此,PINN 的 RMSE 和 MAE 值比 ANN 高出 10 倍以上。




图7 空气区域的磁通密度 B 预测结果(第1、第3行 $t=0.5$ ms, 第2、第4行 $t=15$ ms)

Fig. 7 Estimation results of magnetic flux density B in the air region (first and third rows at $t=0.5$ ms, second and fourth rows at $t=15$ ms)

表4 不同方法的计算性能对比(参数A,套管域)

Table 4 Comparison of computational performance of different methods (parameter A, casing domain)

方法	RMSE	MAE	RE	R^2
神经网络	2.544×10^{-5}	1.720×10^{-5}	0.055	0.984
卷积神经网络	1.599×10^{-4}	1.326×10^{-4}	0.347	0.385
物理信息神经网络	2.651×10^{-5}	1.825×10^{-5}	0.057	0.983

表5 不同方法的计算性能对比(参数B,套管域)

Table 5 Comparison of computational performance of different methods (parameter B, casing domain)

方法	RMSE	MAE	RE	R^2
神经网络	1.048×10^{-3}	2.302×10^{-4}	0.013	0.999
卷积神经网络	1.261×10^{-2}	6.757×10^{-3}	0.160	0.924
物理信息神经网络	9.593×10^{-3}	5.337×10^{-3}	0.121	0.956

的预测略优于 PINN。同时, PINN 对磁通密度 B 的预测在 $t = 0.5$ ms 时刻(第1、第3行)出现较大误差。当 $t = 15$ ms 时, PINN 的误差主要出现在边界区域。这可能是因为初始网络过度关注区域内点的残差优化,而忽视了边界点的训练。另一个值得注意的现象是, CNN 对磁矢势的预测效果极差, 决定系数仅为 0.385; 而对磁通密度的预测效果则达到 0.924。这很可能是网络的过拟合问题, 导致它只能更准确地预测磁通密度, 而不能预测磁矢势。

除了纯数据驱动的神经网络之外, 还展示了传统空间插值与回归算法——多项式混沌展开算法 (polynomial chaos expansion, PCE) 在空间磁矢势与磁通密度估计中的表现, 并与提出的 PINN 的预测性能进行了对比。

图 10~13 为 0.5、15.5 和 30.5 ms 处该算法对两个计算域的磁场物理量进行插值计算的结果, 每张图中第 1 行是 PCE 插值得到的预测结果, 第 2 行是 FEM 真值, 第 3 行是 PCE 预测结果与真值之间的绝对误差, 从图中可以直观看出, PCE 插值算法对套管域物理量的预测能力有较大缺陷。

结合图 8 和 9 的可视化结果可见, ANN 对磁矢势 A

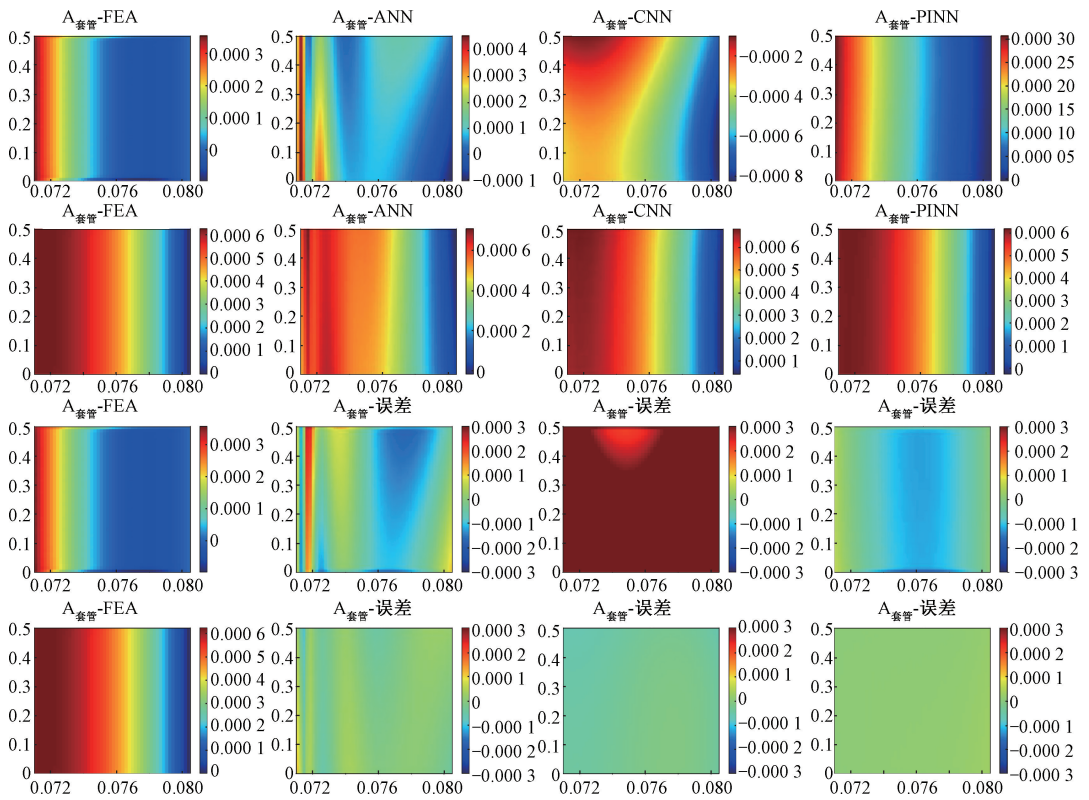


图 8 套管区域的磁矢势 A 预测结果 (第 1、第 3 行 $t=0.5$ ms, 第 2、第 4 行 $t=15$ ms)

Fig. 8 Estimation results of magnetic vector potential A in the casing region (first and third rows at $t=0.5$ ms, second and fourth rows at $t=15$ ms)

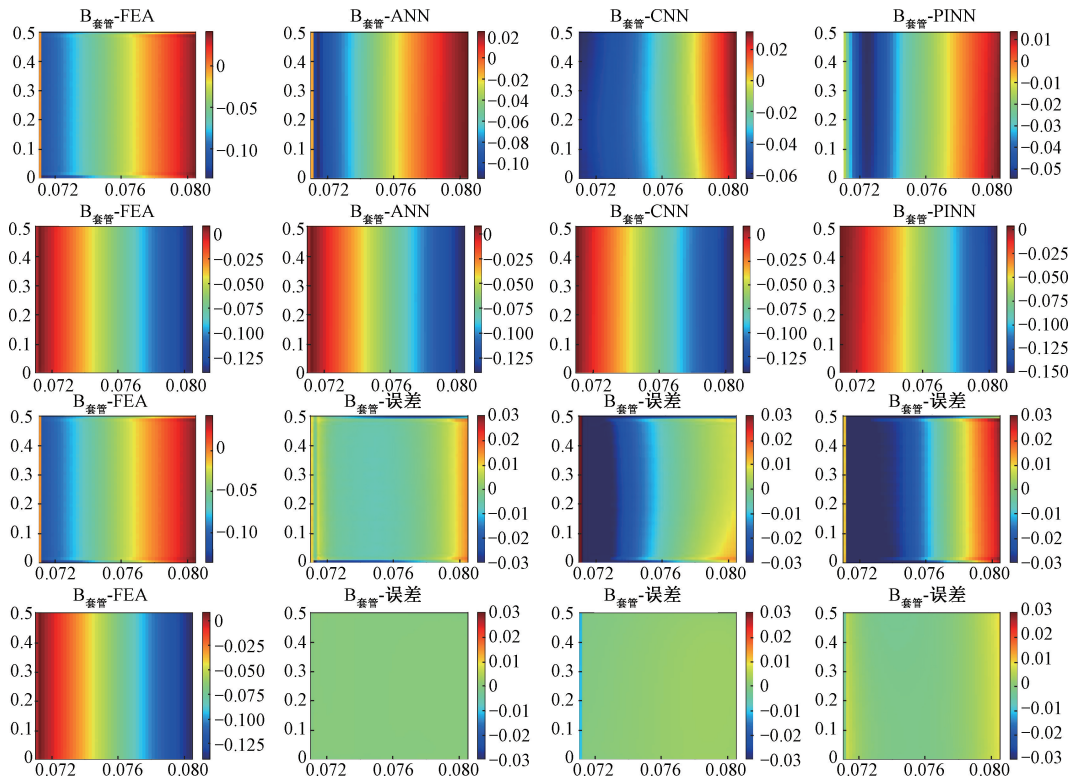


图 9 套管区域的磁通密度 B 预测结果 (第 1 和第 3 行 $t=0.5$ ms, 第 2 和第 4 行 $t=15$ ms)

Fig. 9 Estimation results of magnetic flux density B in the casing region (first and third rows at $t=0.5$ ms, second and fourth rows at $t=15$ ms)

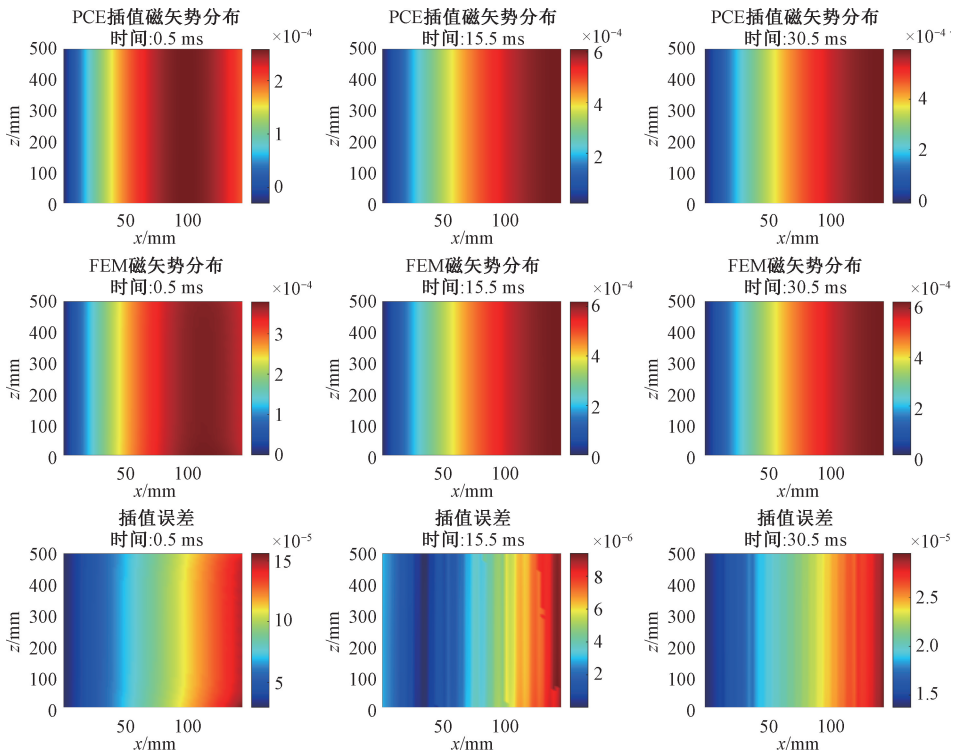


图 10 PCE 算法对空气域磁矢势的预测结果

Fig. 10 Prediction results of magnetic vector potential in the air domain using PCE algorithm




图 11 PCE 算法对套管域磁矢势的预测结果

Fig. 11 Prediction results of magnetic vector potential in the casing domain using the PCE algorithm

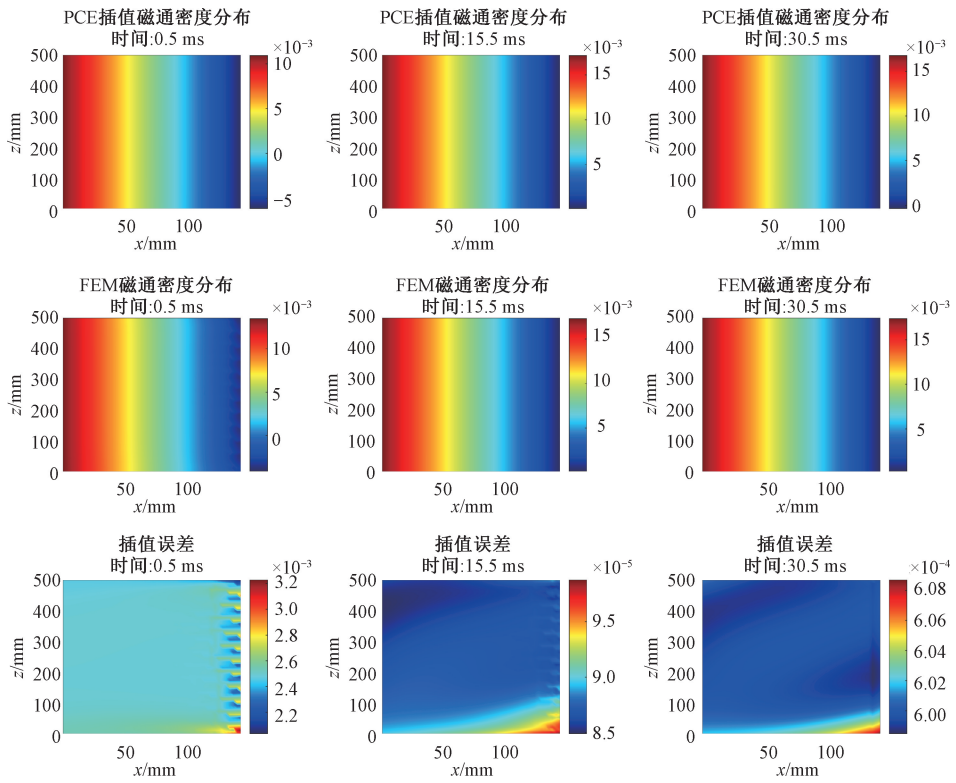


图 12 PCE 算法对空气域磁通密度的预测结果

Fig. 12 Prediction results of magnetic flux density in air domain using the PCE algorithm

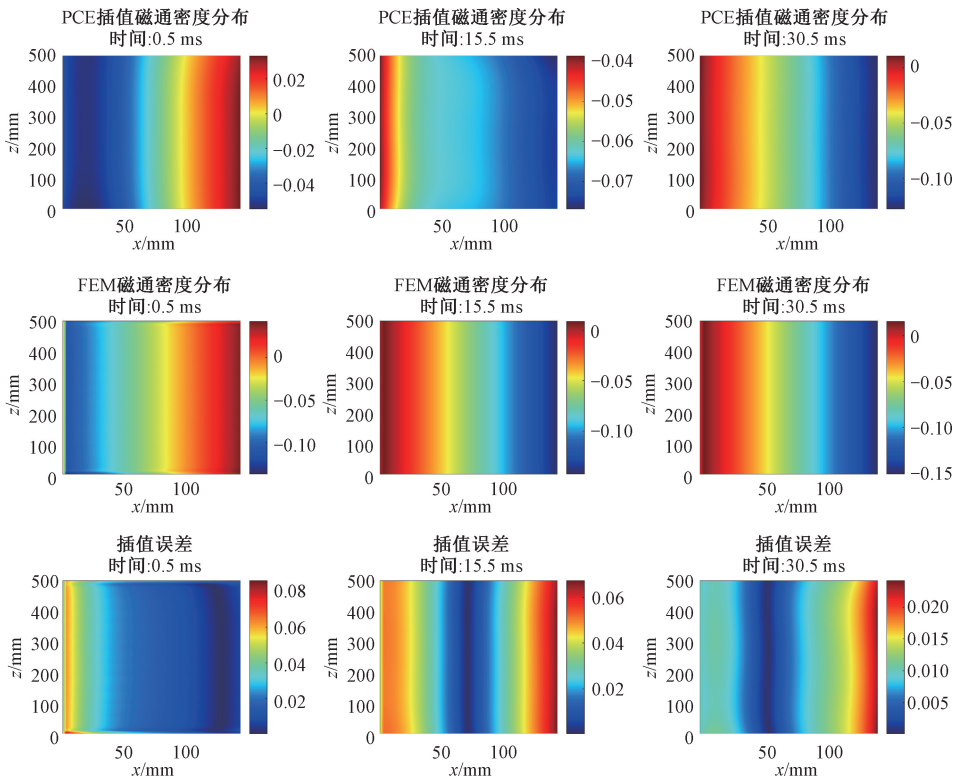


图 13 PCE 算法对套管域磁通密度的预测结果

Fig. 13 Prediction results of magnetic flux density in casing domain using the PCE algorithm

表6~8为PCE插值算法预测结果的评估指标,PCE插值算法对15.5和30.5 ms处空气域的磁场物理量预测结果较好,决定系数高达0.999,且相对误差低至1%以下,显示出比PINN更加优秀的拟合能力。但PCE算法对套管域的电磁物理量拟合能力较差,30.5 ms处对磁矢势和磁通密度的拟合结果的决定系数约为0.95,15.5 ms处的拟合结果的决定系数仅为0.619和0.304,这表明该算法无法有效预测套管域的磁场物理量。同时,注意到0.5 ms处PCE算法完全无法对两个计算域中的磁场物理量做出有效的预测,其预测结果的相对误差均在30%以上,与之相比,PINN由于不完全依赖数据驱动,其对磁场物理量的预测能力不受到时间点的影响。

表6 0.5 ms时PCE预测结果评估

Table 6 Evaluation of PCE prediction results at 0.5 ms

区域	RMSE	MAE	RE	R^2
空气域A	9.513×10^{-5}	8.853×10^{-5}	0.323	0.283
套管域A	4.767×10^{-5}	3.374×10^{-5}	0.366	0.833
空气域B	2.502×10^{-3}	2.501×10^{-3}	0.357	0.753
套管域B	2.549×10^{-3}	2.021×10^{-2}	0.457	0.658

表7 15.5 ms时PCE预测结果评估

Table 7 Evaluation of PCE prediction results at 15.5 ms


区域	RMSE	MAE	RE	R^2
空气域A	4.667×10^{-6}	3.825×10^{-6}	0.010	0.999
套管域A	1.177×10^{-4}	1.088×10^{-4}	0.251	0.619
空气域B	8.744×10^{-5}	8.742×10^{-5}	0.009	0.999
套管域B	3.736×10^{-2}	3.294×10^{-2}	0.472	0.304

表8 30.5ms时PCE预测结果评估

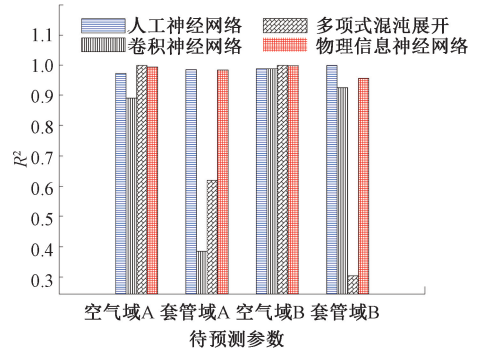
Table 8 Evaluation of PCE prediction results at 30.5ms

区域	RMSE	MAE	RE	R^2
空气域A	2.180×10^{-5}	2.134×10^{-5}	0.048	0.987
套管域A	4.118×10^{-5}	3.797×10^{-5}	0.085	0.955
空气域B	5.999×10^{-4}	5.999×10^{-4}	0.059	0.986
套管域B	1.115×10^{-2}	9.685×10^{-3}	0.135	0.949


为了更加直观地展示ANN、CNN、PCE和PINN对磁场物理量的预测结果差异,将4种方法对两个计算域的4个磁场物理量的预测结果绘制在图14中,可以看出搭建的PINN架构对磁场物理量表现出出色的预测能力,由于评估结果中RMSE的分布差距过大,无法较好地在同一张图中展示,故该图只展示了RE、MAE和 R^2 这3个评价指标。



(a) 不同方法对磁场参数的预测结果的平均绝对误差
(a) Mean absolute error of magnetic field parameter predictions for different methods



(b) 不同方法对磁场参数的预测结果的决定系数
(b) Coefficient of determination for the prediction results of magnetic field parameters for different methods



(c) 不同方法对磁场参数的预测结果的相对误差
(c) Relative error in the prediction results of magnetic field parameters for different methods

图14 不同方法对磁场参数的预测结果对比
Fig. 14 Comparison of prediction results for magnetic field parameters obtained for different methods

此外,在不同计算域选取观测点以实时监测电磁磁通密度变化。如图15所示,当施加脉冲激励电流时,磁矢势和磁通密度在极短时间内发生剧烈波动,而PINN凭借其内嵌的物理信息,能够近乎同步捕捉这些变化。在套管域中,可以观察到PINN的预测值在某些时刻与参考值存在显著偏差,尤其是磁通密度的预测结果,这与表4和5中的统计分析结果相吻合。不过,PINN的预测趋势基本与参考值的变化保持一致,这也证明了该模型在电磁参数预测方面的可行性。

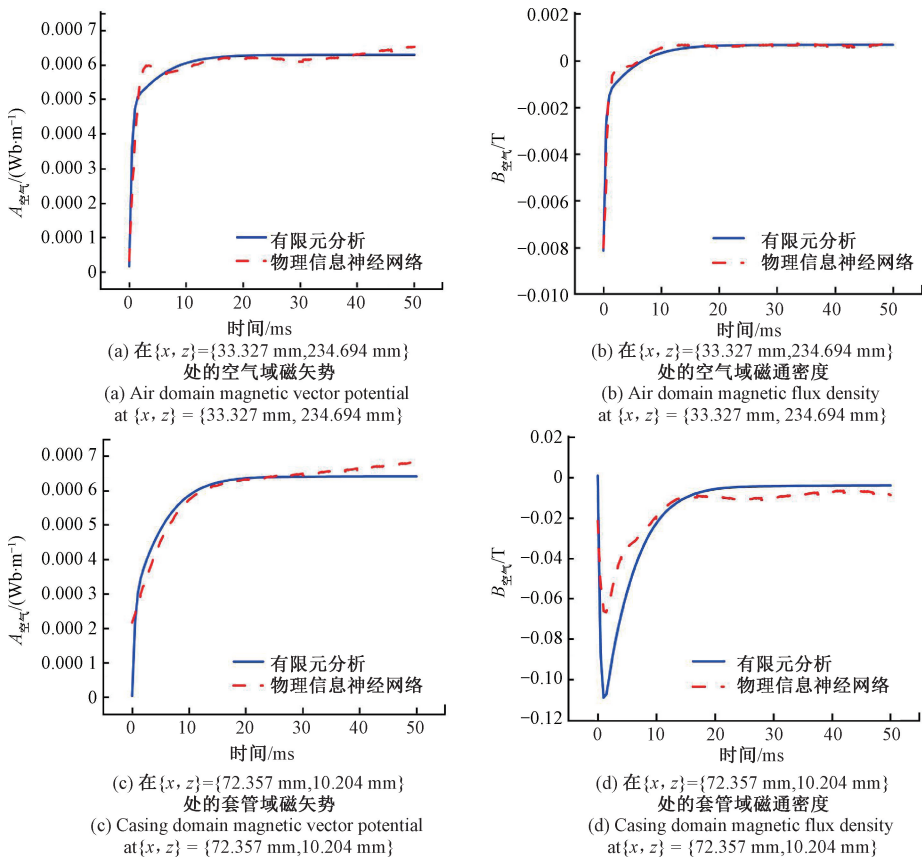


图 15 PINN 监测磁矢势和磁通密度随时间变化

Fig. 15 PINN monitors the time-dependent variations in magnetic vector potential and magnetic flux density

PINN 的一大创新点是将物理公式引入了训练过程,提出的 PINN 架构通过对网络的输出做偏微分计算,根据物理方程计算物理信息损失,将该损失反向传播,更新网络参数,使得网络参数受到物理方程约束。图 16 给出

了不同时间点下两个计算域内 PDE 损失函数的空间分布,第 1 行为空气域结果,第 2 行为套管域结果,第 1~3 列分别为 0.5、15 和 30 ms 时的 PDE 损失函数分布。可以看出,当前网络架构下,较大的 PDE 损失分布在计算域

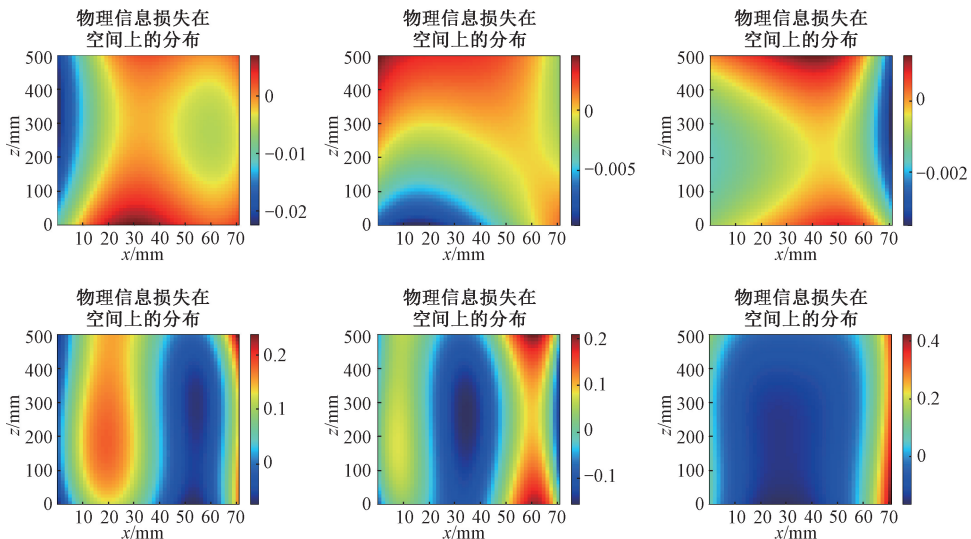


图 16 PDE 损失在空间上的分布

Fig. 16 PDE loss functions spatial distribution

的上下边界附近,这是由于 FEA 数据在这些位置会施加截断边界条件,使得该处的数据无法满足计算域内的物理约束方程,故 PDEs 损失函数在这些位置出现较大的幅值。

3.2 双计算域响应估计

表 9 和 10 展示了两个区域的电磁响应估计结果。针对每个指标,计算了两个区域的平均值。

表 9 不同方法的计算性能对比(参数 A,双计算域平均)

Table 9 Comparison of computational performance among different methods (parameter A, average of dual computational domains)

方法	RMSE	MAE	RE	R^2
人工神经网络	2.875×10^{-4}	2.220×10^{-4}	0.626	-2.571
卷积神经网络	1.335×10^{-4}	1.154×10^{-4}	0.292	0.440
物理信息神经网络	3.773×10^{-5}	2.930×10^{-5}	0.083	0.958

表 10 不同方法的计算性能对比(参数 B,双计算域平均)

Table 10 Comparison of computational performance among different methods (parameter B, average of dual computational domains)

方法	RMSE	MAE	RE	R^2
人工神经网络	2.464×10^{-3}	1.310×10^{-3}	0.056	0.989
卷积神经网络	2.318×10^{-2}	1.923×10^{-2}	0.318	0.493
物理信息神经网络	6.420×10^{-3}	3.484×10^{-3}	0.087	0.961

在磁矢势 A 的预测中,ANN 的表现明显逊色于 PINN,其决定系数为负值,表明 ANN 的拟合效果极差。同时,ANN 的决定系数仅为 0.626,在工程应用的电磁响应估计中显然不够理想。相比之下,PINN 的决定系数达到 0.958,而其决定系数仅为 0.083,相较于纯数据驱动

的方法显示出更高的预测精度。在均方根误差和平均绝对误差方面,纯数据驱动的 ANN 模型比 PINN 模型大十倍左右。纯数据驱动的方法无法准确估计两个域中的电磁响应。

然而值得注意的是,在磁通密度 B 的预测方面,ANN 的表现甚至优于 PINN。ANN 取得了 0.989 的决定系数和 <0.060 的相对误差,而 PINN 的决定系数仍维持在 0.961 以上,这与磁矢势 A 的预测结果处于同一水平。纯数据驱动型 ANN 能获得如此预测效果的一个可能原因是:两种网络在训练过程中共享相同的损失函数。这种损失函数本身并不涉及实际物理意义,只是数据中容易过拟合的残留特征。因此,这也可能导致网络解空间产生偏差,阻碍找到具有实际物理意义的解决方案。提出的物理信息神经网络要求其输出必须遵循已添加的物理约束条件。换言之,具有实际物理意义的最优解必须存在于物理约束下的合理解空间内。CNN 无法准确预测磁矢势和磁通密度,两者的决定系数均低于 0.500,这在实际工程中并不适用于电磁参数的预测。

除此之外,在同样的训练集数据上训练了纯数据驱动的 DNN,该神经网络的框架与提出的 PINN 框架完全相同,在损失函数中去除了初始条件损失函数、边界条件损失函数、界面损失函数和物理信息损失函数,仅保留数据损失函数,以此验证所提 PINN 在磁矢势 A 和磁通密度 B 的预测中的有效性。表 11 给出了两种方法对双计算域磁矢势 A 的拟合结果,表 12 给出了两种方法对双计算域磁通密度 B 的拟合结果。从表 11 的结果数据中可以看到,纯数据驱动的 DNN 对空气域的磁矢势 A 的拟合结果较好,评估指标中相对误差小于 PINN 的拟合结果,但套管域中 DNN 的拟合结果很差,其决定系数仅为 0.33,完全无法对套管域的磁矢势 A 做出较好估计,而对双计算域的磁通密度 B 能够做出良好评估。

表 11 不同方法的计算性能对比(参数 A)

Table 11 Comparison of computational performance among different methods (parameter A)

方法	空气计算域				套管计算域			
	RMSE	MAE	RE	R^2	RMSE	MAE	RE	R^2
数据驱动神经网络	4.151×10^{-5}	3.292×10^{-5}	0.093	0.951	1.682×10^{-4}	1.054×10^{-4}	0.370	0.330
物理信息神经网络	2.630×10^{-5}	1.120×10^{-5}	0.088	0.969	4.916×10^{-5}	4.740×10^{-5}	0.078	0.947

表 12 不同方法的计算性能对比(参数 B)

Table 12 Comparison of computational performance among different methods (parameter B)

方法	空气计算域				套管计算域			
	RMSE	MAE	RE	R^2	RMSE	MAE	RE	R^2
数据驱动神经网络	6.468×10^{-4}	5.412×10^{-4}	0.065	0.984	6.876×10^{-4}	2.34110^{-3}	0.087	0.977
物理信息神经网络	2.286×10^{-3}	4.280×10^{-3}	0.076	0.972	1.055×10^{-2}	2.688×10^{-3}	0.098	0.950

图 17 展示了 15 ms 处使用纯数据驱动 DNN 在双计算域中对磁矢势 \mathbf{A} 和磁通密度 \mathbf{B} 的拟合结果,第 1~4 列分别为空气域磁矢势、套管域磁矢势、空气域磁通密度和套管域磁通密度,第 1~3 行分别为有限元仿真结果、DNN 预测结果和两者间的误差,从

图 17 中可以看出,由于用于训练的数据样本量较小,在没有物理方程对训练过程进行约束的情况下,纯数据驱动的 DNN 对套管域的磁矢势预测性能较差,在空气域接近套管边界的位置处,该 DNN 预测性能同样较差。




图 17 15 ms 时 DNN 对磁矢势和磁通密度的预测结果

Fig. 17 Prediction results of magnetic vector potential and magnetic flux density by DNN at 15 ms

3.3 计算结果讨论

1) 激活函数的影响

激活函数在神经网络构建中起着关键作用,尤其在提升网络非线性特征方面。激活函数通常遵循神经元特性来约束其输出数据,从而增强网络的非线性建模能力。由于不同激活函数具有不同的数学特性,本节将对多种激活函数进行验证与分析,以确保所提出的 PINN 模型具备最佳的电磁响应预测能力。对比实验选取了 PINN 领域常用的 4 种激活函数:ReLU、Sigmoid、Swish 和 Tanh。图 18 展示了不同激活函数的对比结果。显然,ReLU 激活函数无法准确预测电磁响应。根据定义,ReLU 在 $(0, +\infty)$ 区间内是线性函数,其二阶导数恒为 0。此外,通过式 (8) 计算的偏微分方程残差无效,梯度也恒为 0。这最终导致反向传播无法更新网络参数。Sigmoid 激活函数的结果与 Tanh 几乎一致。这是因为两者曲线形态基本相同,区别仅在于 Sigmoid 和 Tanh 的取值域分别为 $(0, 1)$ 和 $(-1, 1)$ 。换句话说,Sigmoid 函数的取值范围只有 Tanh 函数的一半,因此无法对负值区间进行有效表征,这会导致其电磁响应预测精度下降。Swish 激活函数作为 Sigmoid 的变体,在保留门控机制的同时引入了负值

域,从而扩展了 Sigmoid 的数值范围。但研究发现,Swish 函数需要消耗约 16.9 GB 的显存,而 Tanh 仅需 9.6 GB,额外存储空间的消耗是以增加训练时间为代价的。

2) 多目标损失权重平衡算法的影响

此外,通过对比实验验证了引入的多目标损失函数权重平衡策略,并与手动调节和无权重方法进行对比以证明其有效性。表 13 和 14 展示了 3 种权重平衡方法的对比实验结果。第 1 种方法没有给偏微分方程残差损失、初始条件损失、边界损失、数据损失和界面损失分别添加权重,而是将这些损失项直接相加构成总损失函数。手动调节法要求用户手动设置各损失项的权重参数: $\lambda_r = 0.001$ 、 $\lambda_{ic} = 1$ 、 $\lambda_{bc} = 1$ 、 λ_{data} 和 $\lambda_{inter} = 0.001$ 。与自适应方法不同,手动调节法在初始设置后不可再调整,而自适应方法则支持后续优化。从表 13 和 14 可以看出,采用多目标损失权重平衡策略后,电磁响应预测效果显著优于其他方法。相较于单纯累加损失值的方法,磁势矢量 \mathbf{A} 的决定系数提升了 0.630,磁通密度 \mathbf{B} 的决定系数提高了 0.112。具体而言,手动调节法在磁势矢量 \mathbf{A} 上表现更优;对于磁通密度 \mathbf{B} ,手动调节法的结果与自适应法基本持平,两者决定系数均超过 0.960。这也说明了引入的多目标减重权重平衡策略的有效性。

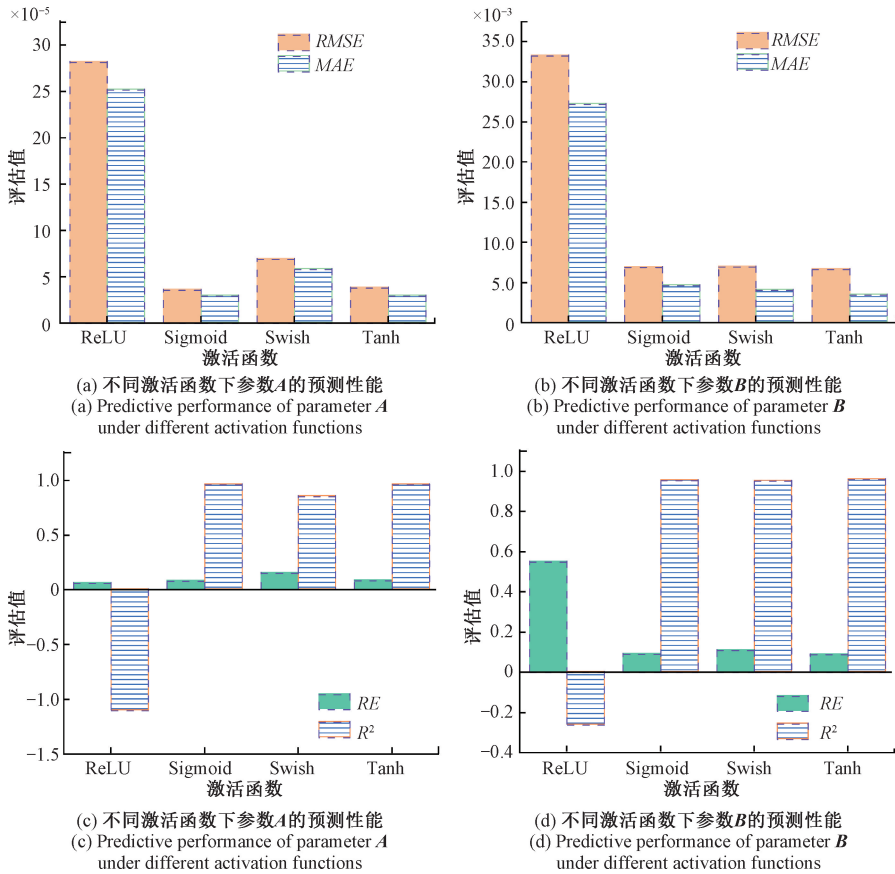


图 18 不同激活函数的电磁参数预测性能比较

Fig. 18 Comparison of electromagnetic parameter prediction performance with different activation functions

表 13 不同损失函数权重均衡策略性能对比 (参数 A, 双计算域平均)

Table 13 Comparison of performance of different loss function weight balancing strategies (parameter A, average of dual computational domains)

方法	RMSE	MAE	RE	R ²
无策略	1.518×10 ⁻⁴	1.230×10 ⁻⁴	0.333	0.328
手动	7.634×10 ⁻⁵	6.278×10 ⁻⁵	0.167	0.807
自适应	3.773×10 ⁻⁵	2.930×10 ⁻⁵	0.083	0.958

表 14 不同损失函数权重均衡策略性能对比 (参数 B, 双计算域平均)

Table 14 Comparison of performance of different loss function weight balancing strategies (parameter B, average across dual computational domains)

方法	RMSE	MAE	RE	R ²
无策略	1.264×10 ⁻²	9.697×10 ⁻³	0.175	0.849
手动	6.374×10 ⁻³	3.492×10 ⁻³	0.087	0.962
自适应	6.420×10 ⁻³	3.484×10 ⁻³	0.087	0.961

3) 界面损失的影响

为进一步阐明界面损失的重要性,进行了消融实验,结果详见表 15 和 16。当不存在界面损失时,式(21)中的损失函数将不包含末项。显然,引入界面损失显著提升了网络预测电磁响应的能力。对于磁势矢量 **A**, 加入界面损失后决定系数提高了 0.123,同时 RMSE、MAE 和 RE 均有所降低。然而,对于磁通密度 **B**, 两种方法的预测精度在有界面损失的情况下基本持平。界面损失的引入不仅大幅提升了网络的整体预测能力,还避免了因不连续性问题引发的预测偏差。

表 15 有无界面损失函数的对比 (参数 A, 双计算域平均)

Table 15 Comparison with and without interface loss function (parameter A, average of dual computational domains)

交界面损失	RMSE	MAE	RE	R ²
无	7.718×10 ⁻⁵	6.519×10 ⁻⁵	0.171	0.835
有	3.773×10 ⁻⁵	2.930×10 ⁻⁵	0.083	0.958

表 16 有无界面损失函数的对比 (参数 B , 双计算域平均)Table 16 Comparison with and without interface loss function (parameter B , average of dual computational domains)

交界面损失	RMSE	MAE	RE	R^2
无	5.505×10^{-3}	2.471×10^{-3}	0.095	0.967
有	6.420×10^{-3}	3.484×10^{-3}	0.087	0.961

4) 预测时间比较

表 17 还列出了 FEA 与 PINN 方法在推理时间上的对比结果。

表 17 FEA 和 PINN 计算时间对比

Table 17 Comparison of computation time between FEA and PINN

方法	计算时间/s
有限元分析	2.000
物理信息神经网络	0.038

对比实验所用的计算硬件平台参数与 2.1 节中所述完全相同,FEA 划分网格方式与 2.2 节中所述相同,网格数量为 871 个,在相同硬件平台上进行相同数量的电磁响应计算时,FEA 的运算耗时远超提出的 PINN 方法,FEA 运算需约 2 s 完成。相比之下,PINN 仅用 0.038 s 即可获得全部结果,速度比 FEA 快了 52 倍有余。这不仅彰显了 PINN 框架在实时预测方面的卓越性能,也证明该框架能更高效地适应实时问题的预测与优化需求。

4 结 论

本研究提出了一种基于物理信息的神经网络替代模型,创新性地解决了传统数学方法耗时长且需高度先验知识的难题,为评估 PECT 套管电磁响应提供了新思路。该方法同时克服了纯数据驱动方法可解释性差、鲁棒性不足的缺陷。所提出的物理信息神经网络框架通过偏微分方程表征电磁场特性,对深度神经网络进行物理约束,将方程求解问题转化为神经网络的优化问题。基于嵌入式物理约束条件,该架构可使神经网络输出结果精准估算磁矢势和磁通密度。针对空气域与套管域不同的物理特性,采用独立子神经网络分别估计各区域响应,并通过界面损失函数整合不同域,有效缓解了界面或方程间的不连续性问题。此外,研究还引入多目标损失权重平衡策略,显著降低了误差并提升了预测精度。对比实验表明,PINN 不仅能精准且稳健地预测脉冲涡流的电磁响应,其估计速度更

是比 FEA 快 52 倍以上。这一结果验证了该技术在脉冲涡流检测电磁响应评估中的可行性与应用潜力。此外,这种融合数据驱动与物理先验知识约束的混合神经网络,为脉冲涡流检测分析提供了全新思路,作为代理模型尤其适用于非线性信号快速建模。

参考文献


- [1] FU Y W, YU R Q, PENG X W, et al. Investigation of casing inspection through tubing with pulsed eddy current[J]. Nondestructive Testing and Evaluation, 2012, 27(4): 1-22.
- [2] SILVA M I, MALITCKII E, SANTOS T G, et al. Review of conventional and advanced non-destructive testing techniques for detection and characterization of small-scale defects[J]. Progress in Materials Science, 2023, 138 (3): 101155.
- [3] SOPHIAN A, TIAN G Y, FAN M B. Pulsed eddy current non-destructive testing and evaluation: A review[J]. Chinese Journal of Mechanical Engineering, 2017, 30: 500-514.
- [4] ZHANG W, SUN H, TAO AI H, et al. Local defect detection of ferromagnetic metal casing based on pulsed eddy current testing[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-9.
- [5] ZHU J ZH, MIN Q X, WU J B, et al. Probability of detection for eddy current pulsed thermography of angular defect quantification[J]. IEEE Transactions on Industrial Informatics, 2018, 14(12): 5658-5666.
- [6] CHEN X L, NIU H. Pulsed eddy current testing for gap measurement of metal casing[J]. Measurement Science and Technology, 2022, 33(7): 075108.
- [7] 杨超, 孙虎, 唐超. 电磁脉冲涡流检测下金属管道缺陷检测研究[J]. 电子测量与仪器学报, 2025, 39(4): 132-140.
YANG CH, SUN H, TANG CH. Research on metal pipe defect detection based on electromagnetic pulsed eddy current testing[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(4): 132-140.
- [8] CHEN X L, LEI Y ZH. Time-domain analytical solutions to pulsed eddy current field excited by a probe coil outside a conducting ferromagnetic pipe[J]. NDT & E International, 2024, 68: 22-27.
- [9] NAFIAH F, TOKHI M O, SHIRKOOHI G, et al. Determining feature extraction parameters for pulsed eddy current sensor: A minimisation problem approach[J]. IEEE Sensors Journal, 2021, 21(22): 26124-26131.
- [10] 李超月, 王璇, 牛卫飞, 等. 金属保护层对脉冲涡流

- 检测影响实验研究[J]. 电子测量技术, 2023, 46(14): 24-29.
- LI CH Y, WANG X, NIU W F, et al. Experimental study on the influence of metal protective layer on pulsed eddy current testing[J]. Electronic Measurement Technology, 2023, 46(14): 24-29.
- [11] LIU CH Z, DANG B, WANG H Y, et al. Synthesized magnetic field focusing for the non-destructive testing of oil and gas well casing pipes using pulsed eddy-current array [J]. IEEE Transactions on Magnetics, 2022, 58(9): 1-10.
- [12] PENG J Q, XU ZH Y, CHEN H Q, et al. Detection of brazing defects in stainless steel core plate using the first peak value of pulsed eddy current testing signals[J]. Construction and Building Materials 2023, 408(5): 133636.
- [13] XIA Z H, YAN J J, HUANG R CH, et al. Fast estimation of metallic pipe properties using simplified analytical solution in eddy-current testing [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 72: 1-13.
- [14] LIN C Y, HUANG R Y, TENG M G, et al. Pulsed eddy current sensor for cascade electrical conductivity and thickness estimation in nonferrous metal plates[J]. IEEE Sensors Journal 2023, 23(8): 8323-8334.
- [15] SON S, LEE H, JEONG D, et al. A novel physics-informed neural network for modeling electromagnetism of a permanent magnet synchronous motor[J]. Advanced Engineering Informatics, 2023, 57: 102035.
- [16] TSUBOI H, SESHIMA N, SEBESTYEN I, et al. Transient eddy current analysis of pulsed eddy current testing by finite element method[J]. IEEE Transactions on Magnetics, 2004, 40(2): 1330-1333.
- [17] 魏义敏, 孙小龙, 冷孝丽, 等. 基于分段互感式涡流探头的电梯钢带内部钢丝断丝检测方法[J/OL]. 仪器仪表学报, 1-11[2025-10-30].
WEI Y M, SUN X L, LENG X L, et al. Detection method for broken wires inside elevator belts based on segmented mutual inductance eddy current probe[J/OL]. Chinese Journal of Scientific Instrument, 1-11[2025-10-30].
- [18] XUE ZH AN, FAN M B, CAO B H, et al. A fast numerical method for the analytical model of pulsed eddy current for pipelines[J]. Insight-Non-Destructive Testing and Condition Monitoring, 2020, 62(1): 27-33.
- [19] KIM S, SHIN H. Deep learning framework for multiscale finite element analysis based on data-driven mechanics and data augmentation[J]. Computer Methods in Applied Mechanics and Engineering, 2023, 414(1): 116131.
- [20] BAI J SH, RABCZUK T, GUPTA A, et al. A physics-informed neural network technique based on a modified loss function for computational 2D and 3D solid mechanics[J]. Computational Mechanics, 2023, 71(3): 543-562.
- [21] COLOMBO D, LI W CH, SANDOVAL-CURIEL E, et al. Deep-learning electromagnetic monitoring coupled to fluid flow simulators[J]. Geophysics, 2020, 85(4): WA1-WA12.
- [22] YAO H M, JIANG L J, SHA W E I. Enhanced deep learning approach based on the deep convolutional encoder-decoder architecture for electromagnetic inverse scattering problems [J]. IEEE Antennas and Wireless Propagation Letters, 2020, 19(7): 1211-1215.
- [23] SAFAEI M, SOLEYMANI S A, SAFAEI M, et al. Deep learning algorithm for supervision process in production using acoustic signal[J]. Applied Soft Computing, 2023, 146: 110682.
- [24] SCHMID J D, BAUERSCHMIDT P, GURBUZ C, et al. Physics-informed neural networks for acoustic boundary admittance estimation[J]. Mechanical Systems and Signal Processing, 2024, 215(1): 111405.
- [25] 陈世利, 吕玲玲, 童君开, 等. 基于物理信息嵌入式神经网络的管壁导波成像[J]. 电子测量与仪器学报, 2023, 37(8): 136-145.
CHEN SH L, LYU L L, TONG J K, et al. Guided wave imaging of pipe wall based on physics embedded neural network [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 136-145.
- [26] XU J X, WEI H, BAO H. Physics-informed neural networks for studying heat transfer in porous media[J]. International Journal of Heat and Mass Transfer, 2023, 217: 124671.
- [27] ZHAO X Y, GONG ZH Q, ZHANG Y Y, et al. Physics-informed convolutional neural networks for temperature field prediction of heat source layout without labeled data[J]. Engineering Applications of Artificial Intelligence, 2023, 117: 105516.
- [28] HORNIK K, STINCHCOMBE M, WHITE H. Multilayered feedforward networks are universal approximators[J]. Neural Networks, 1989, 2(5): 359-366.
- [29] SUN L N, GAO H, PAN SH W, et al. Surrogate modeling for fluid flows based on physics-constrained deep learning without simulation data [J]. Computer Methods in Applied Mechanics and Engineering, 2020,

- 361(1): 112732.
- [30] CHEN M K, LUPOIU R, MAO CH K, et al. High speed simulation and freeform optimization of nanophotonic devices with physics-augmented deep learning[J]. *ACS Photonics*, 2022, 9(9): 3110-3123.
- [31] XIA Z H, MENG T, HUANG R CH, et al. Physics-guided deep learning for plate permeability estimation with single to multiple frequency transformation of eddy-current testing[J]. *IEEE Transactions on Industrial Informatics*, 2024, 20(4): 6109-6118.
- [32] BELTRAN-PULIDO A, BILIONIS I, ALIPRANTIS D. Physics-informed neural networks for solving parametric magnetostatic problems[J]. *IEEE Transactions on Energy Conversion*, 2022, 37(4): 2678-2689.
- [33] HU Y D, WANG X H, ZHOU H, et al. A priori knowledge-based physics-informed neural networks for electromagnetic inverse scattering[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2024, 62: 1-9.
- [34] 梁健, 封善斋, 甄明吉, 等. 结合几何误差模型和神经网络的三坐标测量机全面误差补偿方法[J]. *仪器仪表学报*, 2025, 46(7): 150-159.
LIANG J, FENG SH ZH, ZHEN M J, et al. Comprehensive error compensation method for coordinate measuring machine based on geometric error model and neural network[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(7): 150-159.
- [35] TANG J S, QIAN L F, MA J, et al. Knowledge-dominated and data-driven rigid-flexible coupling dynamics for rotating flexible structure[J]. *Knowledge-Based Systems*, 2024, 296: 111853.
- [36] 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.
- [37] 马炳图, 杜钦君, 张婷, 等. 基于 HBF 神经网络观测器的 PMSM 无模型预测电流控制[J]. *仪器仪表学报*, 2025, 46(8): 376-386.
MA B T, DU Q J, ZHANG T, et al. PMSM model-free based on HBF neural network observer predictive current control[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(8): 376-386.
- [38] 米洁, 马超, 周海龙, 等. 物理知识引导的卷积神经网络故障诊断预测方法[J]. *仪器仪表学报*, 2025, 46(8): 19-32.
- MI J, MA CH, ZHOU H L, et al. Physical-guided convolutional neural network model for fault diagnosis[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(8): 19-32.
- [39] CUOMO S, DI COLA V S, GIAMPAOLO F, et al. Scientific machine learning through physics-informed neural networks: Where we are and what's next[J]. *Journal of Scientific Computing*, 2022, 92(3): 88.
- [40] GONG ZH, CHU Y, YANG SH Y. Physics-informed neural networks for solving 2-D magnetostatic fields[J]. *IEEE Transactions on Magnetics*, 2023, 59(11): 1-5.
- [41] KOVACS A, EXL L, KORNEILL A, et al. Magneto-statics and micromagnetics with physics informed neural networks[J]. *Journal of Magnetism and Magnetic Materials*, 2022, 548: 168951.
- [42] ZHANG P, HU Y Y, JIN Y CH, et al. A maxwell's equations based deep learning method for time domain electromagnetic simulations[J]. *IEEE Journal on Multiscale and Multiphysics Computational Techniques*, 2021, 6: 35-40.
- [43] WANG D ZH, WANG S H, KONG D SH, et al. Physics-informed sparse neural network for permanent magnet eddy current device modeling and analysis[J]. *IEEE Magnetics Letters*, 2023, 14: 1-5.
- [44] PU H Y, TAN B, YI J, et al. A novel key performance analysis method for permanent magnet coupler using physics informed neural networks[J]. *Engineering with Computers*, 2024, 40(4): 2259-2277.
- [45] SUN H, ZHANG SH L, DENG Y, et al. PECT analytical modeling fast calculation method of multilayer ferromagnetic casings[J]. *IEEE Sensors Journal*, 2024, 24(18): 28909-28920.
- [46] THEODOULIDIS T P. Model of ferrite-cored probes for eddy current nondestructive evaluation[J]. *Journal of Applied Physics*, 2003, 93(5): 3071-3078.
- [47] ZHU Y ZH, CHEN B CH, LUO Y, et al. Inductance calculations for coaxial iron-core coils shielded by cylindrical screens of high permeability[J]. *IET Electric Power Applications*, 2019, 13(6): 795-804.
- [48] FANG ZH W. A high-efficient hybrid physics-informed neural networks based on convolutional neural network[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 33(10): 5514-5526.
- [49] GAO H, SUN L N, WANG J X. PhyGeoNet: Physics-informed geometry-adaptive convolutional neural networks for solving parameterized steady-state pdes on irregular

- domain[J]. *Journal of Computational Physics*, 2021, 428: 110079.
- [50] ZHANG R Y, LIU Y, SUN H. Physics-informed multi-lstm networks for metamodeling of nonlinear structures[J]. *Computer Methods in Applied Mechanics and Engineering*, 2020, 369: 113226.
- [51] BISCHOF R, KRAUS M A. Multi-objective loss balancing for physics-informed deep learning[J]. *Computer Methods in Applied Mechanics and Engineering*, 2025, 439: 117914.
- [52] WANG S F, TENG Y J, PERDIKARIS P. Understanding and mitigating gradient flow pathologies in physics-informed neural networks[J]. *SIAM Journal on Scientific Computing*, 2021, 43(5): A3055-A3081.
- [53] CHEN ZH, BADRINARAYANAN V, LEE C Y, et al. Gradnorm: Gradient normalization for adaptive loss balancing in deep multitask networks[C]. *International Conference on Machine Learning*. PMLR, 2018: 794-803.

作者简介



罗斌, 2019 年于电子科技大学获得学士学位, 2022 年于电子科技大学获得硕士学位, 现于电子科技大学攻读博士学位, 主要研究方向为油气井管道无损检测、脉冲涡流无损检测等。

E-mail: 202211060902@uestc.edu.cn

Luo Bin received his B. Sc. and M. Sc. degrees both from University of Electronic Science and Technology of China in 2019 and 2022, respectively. He is currently pursuing his Ph. D. degree at University of Electronic Science and Technology of China. His main research interests include non-destructive testing of oil and gas well pipelines, pulsed eddy current non-destructive testing.



师奕兵, 1985 年于成都电讯工程学院 (现电子科技大学) 无线电技术系获学士学位, 1988 年获电子科技大学信号、电路与系统学科硕士学位, 2002 年获电子科技大学测试计量技术及仪器学科博士学位。现为电子科技大学自动化工程学院教授、博士生导师, 主要研究方向为现代测试理论与技术、测试信号获取与处理、电路及系统测试与可测性设计、测井技术及仪器。

E-mail: ybshi@uestc.edu.cn

Shi Yibing received his B. Sc. degree from Chengdu Institute of Telecommunication Engineering (now University of Electronic Science and Technology of China) in 1985, received his M. Sc. degree from University of Electronic Science and Technology of China in 1988, and his Ph. D. degree from University of Electronic Science and Technology of China in 2002. He is currently a professor in the School of Automation Engineering at University of Electronic Science and Technology of China. His main research interests include modern testing theory and technology, test signal acquisition and processing, circuit and system testing and design for testability, well logging technology and instruments.



陶爱华, 2000 年于武汉大学获得学士学位, 2003 年于华中科技大学获得硕士学位, 现为中海油田服务股份有限公司高级工程师, 主要研究方向为油气井井筒完整性检测技术与装备。

E-mail: taoaih@cosl.com.cn

Tao Aihua received his B. Sc. degree from Wuhan University in 2000, received his M. Sc. degree from Huazhong University of Science and Technology in 2003. He is currently a senior engineer at Welltech Research and Design Institute of China Oilfield Services Co. His main research interests include wellbore integrity detection technology and equipment for oil and gas wells.



张伟 (通信作者), 2002 年于电子科技大学获得学士学位, 2005 年于电子科技大学获得硕士学位, 2010 年于电子科技大学获博士学位, 现为电子科技大学自动化工程学院副教授, 主要研究方向为无损检测与成像、微弱信号高精度采集与处理等。

E-mail: weizhang@uestc.edu.cn

Zhang Wei (Corresponding author) received his B. Sc., M. Sc. and Ph. D. degrees all from University of Electronic Science and Technology of China in 2002, 2005 and 2010, respectively. He is currently an associate professor in the School of Automation Engineering at University of Electronic Science and Technology of China. His main research interests include non-destructive testing and imaging, high-precision acquisition and processing of weak signal.