

融合物理信息与深度算子网络的变压器绕组 热-流场快速计算方法

李家豪¹, 王青于¹, 刘鹏¹, 吴泽华², 程建伟², 曾强³

- (1. 西安交通大学电工材料电气绝缘全国重点实验室, 710049, 西安;
2. 中国南方电网有限责任公司南方电网科学研究院有限责任公司, 510663, 广州;
3. 广东电网有限责任公司东莞供电局, 523009, 广东东莞)

摘要: 针对传统有限元方法在变压器绕组温度评估中计算成本高、求解速度慢、难以满足工程应用需求的问题,提出了一种基于物理信息深度算子网络的变压器稳态热-流场快速计算方法,可实现热-流场的高精度、高效率计算。该方法基于数值仿真获取不同工况下绕组热-流场的分布特征,构建高质量数据集;将深度算子网络结构与物理约束相结合,设计包含主干网络与分支网络的架构,引入热传导方程和流体连续性方程作为物理约束构建损失函数,实现对变压器绕组稳态热-流场的高精度预测。算例结果表明:在神经网络深度为 7 层、宽度为 50、学习率为 0.01、Tanh 激活函数及 Adam 优化器的超参数配置下,所提方法对温度、压强及径向、轴向油流速度的预测平均绝对误差分别为 0.1 °C、5.03 Pa、0.006 1 m/s、0.003 6 m/s;95% 以上节点相对误差低于 0.7%,单次预测耗时 0.12 s,较 Fluent 数值仿真加速约 10 000 倍。所提方法在保持热-流场预测精度的同时显著提升计算时效,可支撑变压器热管理与数字孪生的快速仿真需求。

关键词: 深度算子网络;物理信息;变压器;热-流场

中图分类号: TM411 **文献标志码:** A

DOI: 10.7652/xjtuxb202607021 **文章编号:** 0253-987X(2026)07-0228-11

A Fast Calculation Method for Thermal Flow Fields in Transformer Windings Based on PI-DeepONet

LI Jiahao¹, WANG Qingyu¹, LIU Peng¹, WU Zehua², CHENG Jianwei², ZENG Qiang³

- (1. State Key Laboratory of Electrical Insulation and Power Equipment, Xi'an 710049, China;
2. Electric Power Research Institute, China Southern Power Grid, Guangzhou 510663, China;
3. Dongguan Power Supply Bureau of Guangdong Power Grid Corporation, Dongguan, Guangdong 523009, China)

Abstract: To address the limitations of traditional finite element methods (FEM) in transformer winding temperature evaluation, such as high computational costs, slow solution speeds, and poor suitability for engineering applications, a fast calculation method for steady-state thermal flow fields in transformers is proposed based on a physics-informed deep operator network (PI-DeepONet). This method achieves high-precision and high-efficiency calculation of thermal flow fields. The distribution characteristics of the thermal flow fields in transformer windings under various operating conditions were obtained via numerical simulations, and a high-quality dataset

收稿日期: 2025-09-01。 作者简介: 李家豪(1999—),男,博士生;王青于(通信作者),女,副教授,硕士生导师。 基金项目: 广东省重点领域研发计划资助项目(2021B0101190003);南方电网有限责任公司总部科技资助项目(GDKJXM20222106)。

网络出版时间: 2026-04-03

网络出版地址: <https://link.cnki.net/urlid/61.1069.t.20260403.1414.002>

was constructed. By integrating the DeepONet architecture with physical constraints, a network comprising branch and trunk components was designed. The heat conduction and fluid continuity equations were incorporated into the loss function as physical constraints, enabling accurate prediction of the steady-state thermal flow field in transformer windings. Calculation case results demonstrate that under a hyperparameter configuration featuring a 7-layer depth, a 50-unit width, a learning rate of 0.01, a Tanh activation function, and the Adam optimizer, the mean absolute errors (MAE) for temperature, pressure, and radial/axial flow velocities are 0.1 °C, 5.03 Pa, 0.006 1 m/s, and 0.003 6 m/s, respectively. Relative errors for over 95% of the nodes are below 0.7%. Furthermore, a single prediction takes only 0.12 s, representing a speedup of approximately 10 000 times compared to Fluent-based numerical simulations. The proposed method significantly enhances computational efficiency while maintaining prediction accuracy of the thermal flow fields, supporting the rapid simulation requirements of thermal management and digital twin applications for transformers.

Keywords: deep operator network; physical information; power transformer; thermal flow field

近年来,随着大数据、云计算、人工智能等现代信息技术与能源技术的深度融合,数字化技术在各领域的快速发展推动了第四次工业革命。为了加速能源系统向数字化、智能化转型,国家能源局提出,要依托数字化、智能化电网支撑新型电力系统建设,并加快人工智能驱动的能源装备状态识别、可靠性评估及故障诊断技术的发展^[1-2]。作为新型电力系统发展的核心环节,电力装备的数字化升级已成为行业发展的关键方向^[3-4]。

油浸式电力变压器作为电力系统的核心设备,负责电能传输和电压转换任务,其安全运行至关重要。随着变压器使用年限的增加和负荷的增大,过热问题日益凸显。快速精准获取变压器绕组的温度分布对于设备状态监测与早期故障预警具有重要意义^[5-6]。因此,开展变压器绕组热-流场分布快速计算方法研究,具有一定的理论价值与工程意义。

现有变压器绕组温度场的快速计算方法主要采用“模态分解-代理模型”的范式^[5-7]。该方法虽已被验证有效,但仍存在一定的固有局限性。传统模态分解方法依赖大量预计算快照构建降阶基,计算成本高昂且对新工况的泛化能力有限;传统代理模型在处理高维非线性问题时计算成本显著增加。相较之下,深度算子网络(DeepONet)作为一种新兴的神经网络架构,在求解高维非线性问题方面展现出独特优势,为解决上述问题提供了新的研究路径。

DeepONet 通过数据驱动方式高效学习算子,具备更快的收敛速度、强泛化能力和良好的可扩展性^[8],在多个领域取得了较好的结果。魏蓉等^[9]首次将 DeepONet 应用于电磁轨道发射速度趋肤效应

的研究,验证了其在电磁场中的有效性。张宇娇等^[10]基于该框架开发了高效的电磁场计算方法,并通过数值模拟验证了其精度和效率。Sasaki 等^[11]将 DeepONet 应用于电机磁场分布的快速计算,并提出创新的电机拓扑优化方法。Xu 等^[12]利用 DeepONet 构建了地面沉降预警系统,提升了地质灾害监测时效性。Ahmed 等^[13]提出基于 DeepONet 的结构静态响应实时预测方法,改善了结构健康监测。Shukla 等^[14]则基于 DeepONet 开发了飞行器几何优化框架,显著提高了优化效率。

作为纯数据驱动的方法,DeepONet 仍存在物理可解释性不足与小样本下训练稳定性差等局限性。物理信息神经网络(PINN)是应对上述挑战的有效途径之一^[15-17]。该方法通过将控制方程的残差项嵌入损失函数,使网络在训练中遵循物理规律,从而减少对大规模数据的依赖,并增强解的物理合理性与可解释性。

基于以上分析,本文提出了一种物理约束 DeepONet(PI-DeepONet)方法,将 PINN 的物理约束机制和 DeepONet 的推理高效性有机结合。PI-DeepONet 通过在 DeepONet 框架中引入物理方程的残差项,强化了物理一致性,同时保留了 DeepONet 在跨工况快速推断的计算效率。该方法能够在保证物理规律约束的前提下,实现跨工况、快速且精确的热-流场预测。

1 理论基础

为了高效求解变压器绕组在边界条件变化下的温度场和流速场分布,本文采用 DeepONet 进行建

模求解,并在损失函数中引入物理约束项,以提高预测精度。本节将介绍 DeepONet 模型的基本原理以及在轴对称条件下热-流场的基本控制方程。

1.1 DeepONet 模型原理

DeepONet 是一种用于学习函数到函数映射(即算子)的神经网络模型。由于物理量分布通常遵循基本物理定律,DeepONet 可以直接学习物理场的控制方程,从而高效地求解问题。例如,对于求导算子,DeepONet 可以将函数映射到其导数空间^[18-20],这样算子学习的泛化能力远大于逼近函数的普通神经网络。

DeepONet 的网络结构如图 1 所示,主要由分支网络和主干网络组成。分支网络接收离散点 $x_1, x_2, \dots, x_n$ 处的函数值 $\{u(x_1), u(x_2), \dots, u(x_n)\}$ 作为输入,并输出特征向量 $\mathbf{b}$ 。主干网络则以自变量的离散点 $\mathbf{y}$ 作为输入,输出一个与 $\mathbf{b}$ 维度相同的向量 $\mathbf{t}$ 。网络的最终输出 $G(\mathbf{u}, \mathbf{y})$ 由 $\mathbf{b}$ 和 $\mathbf{t}$ 的点积计算得到。在求解物理场时, $\mathbf{u}$ 可代表初值条件、边界条件、系数或源项,输入 $\mathbf{y}$ 通常是物理场的节点坐标与时间信息^[21-22]。实际应用中,分支网络可以根据需要选择不同架构(如全连接或卷积神经网络),主干

网络通常使用全连接神经网络。




图 1 深度算子网络基本结构

Fig. 1 Deep operator network basic structure

1.2 热-流场控制方程

本文主要研究变压器绕组热-流场的稳态分布情况,所涉及的变压器绕组为二维轴对称结构,因此需要推导柱坐标系下的热-流耦合场控制方程。由于计算域关于旋转轴对称,本文假定对任意变量 ζ 和角度 θ 均满足 $\partial\zeta/\partial\theta = 0$,得到柱坐标系下的热-流耦合场控制方程^[23-24]如下

$$\begin{cases} \frac{\partial v_r}{\partial r} + \frac{v_r}{r} + \frac{\partial v_z}{\partial z} = 0 \\ \rho c_p \left(v_r \frac{\partial T}{\partial r} + v_z \frac{\partial T}{\partial z} \right) = \lambda \left(\frac{\partial^2 T}{\partial r^2} + \frac{\partial T}{r \partial r} + \frac{\partial^2 T}{\partial z^2} \right) + Q \\ \rho \left(v_r \frac{\partial v_r}{\partial r} + v_z \frac{\partial v_r}{\partial z} \right) = -\frac{\partial P}{\partial r} + \mu \left(\frac{\partial^2 v_r}{\partial r^2} + \frac{\partial v_r}{r \partial r} + \frac{\partial^2 v_r}{\partial z^2} - \frac{v_r}{r^2} \right) \\ \rho \left(v_r \frac{\partial v_z}{\partial r} + v_z \frac{\partial v_z}{\partial z} \right) = -\frac{\partial P}{\partial z} + \mu \left(\frac{\partial^2 v_z}{\partial r^2} + \frac{\partial v_z}{r \partial r} + \frac{\partial^2 v_z}{\partial z^2} \right) + F_z \end{cases} \quad (1)$$

式中: r, z 为柱坐标系中的径向和轴向坐标, v_r 与 v_z 分别为径向油流速度与轴向油流速度; ρ 为密度; c_p 为比定压热容; T 为温度; λ 为热导率,本文认为所有材料的热导率均为各向同性; Q 为单位体积发热功率; P 为油流压力; μ 为流体黏度; F_z 为体积力沿轴向的分量,在只考虑重力作用时, $F_z = \rho g, g$ 为重力加速度。

2 基于 PI-DeepONet 的快速求解方法

2.1 方法框架

本研究提出了一种融合物理信息的深度算子神经网络,用于快速求解变压器绕组在多种边界条件下的热-流场分布问题。图 2 展示了预测方法框架的 3 个关键阶段。

在第 1 阶段,首先采用拉丁超立方采样方法在参数空间中进行采样,获得不同工况组合;随后利用 Fluent 仿真软件对各工况下的温度、压力和流速分

布进行高精度数值计算。所得结果作为模型训练数据,不仅保证了样本的多样性和代表性,也为后续模型训练提供了充分的物理信息。

第 2 阶段,使用 PI-DeepONet 模型进行训练。该模型利用 DeepONet 的算子学习能力,能够有效捕捉多物理场耦合机理。通过主干网络和分支网络的协同作用,DeepONet 实现了对复杂物理算子的高效回归,突破了传统神经网络对数据覆盖范围的依赖。训练过程中引入了物理约束项,包括数据误差、热-流场基本方程的残差损失(PDE)约束和边界条件监督损失,提升了模型的稳健性和预测精度。

第 3 阶段,实现了不同工况下变压器绕组热-流场的在线预测,输出结果包括温度分布、油流压强和流速等参数。该阶段可体现 PI-DeepONet 模型在热-流场快速预测中的高效性与准确性。




图 2 基于 PI-DeepONet 网络模型的变压器绕组热-流场预测流程

Fig. 2 Prediction process of thermal-flow field in transformer windings based on PI-DeepONet model

2.2 物理模型介绍

本研究以 220 kV 三绕组变压器为对象,分析其热-流耦合场。该变压器采用强迫油循环散热,结构如图 3 所示。为聚焦绕组区域内部油道的油流与温度分布,模型简化为铁芯、高压绕组、中压绕组、低压绕组、油道和挡油板结构,并细化至油道级别,以捕捉油流滞后现象及挡油板对油流的影响。由于研究对象为三绕组变压器,选取高、低负载工况进行研究。绕组和铁芯为主要热源,与绕组中的绝缘油进行热交换。本研究主要考虑热传导和热对流两种传




图 3 变压器绕组几何结构

Fig. 3 Geometric structure of transformer winding

热机制,通过能量守恒方程描述,并结合绕组与油流的温度分布和速度场,建立了温度场与流体场的双向耦合模型。

本文选取入口流速、环境温度和负载率作为关键变量^[7]。针对每个变量,选取了以下取值范围:入口流速为 0.05~0.40 m/s,环境温度为 10~40℃,负载率为额定负载的 50%~120%。铁芯和绕组的发热功率来自变压器的出厂试验数据。通过拉丁超立方采样方法,生成 100 种工况组合,使用 Fluent 仿真软件计算后作为训练集,另外随机选取 20 种工况作为测试集,评估模型性能,具体如图 4 所示。文中计算所用到的各项参数如表 1 所示。




图 4 训练样本与测试样本的工况组合

Fig. 4 Operating condition combinations for training and testing samples

表 1 仿真计算所需物性参数

Table 1 Physical property parameters used in the simulation		
材料	物性参数	数值和表达式
绝缘油	密度/(kg·m ⁻³)	-0.712T+1 098.7
	比定压热容/(J·kg ⁻¹ ·K ⁻¹)	4.782 7T+621.72
	动力黏度/(Pa·s)	1 573.7e ^{-0.037 T}
	导热系数/(W·m ⁻¹ ·K ⁻¹)	-8×10 ⁻⁵ T+0.132
绕组	密度/(kg·m ⁻³)	8 932
	比定压热容/(J·kg ⁻¹ ·K ⁻¹)	381
	导热系数/(W·m ⁻¹ ·K ⁻¹)	401
绝缘纸板	密度/(kg·m ⁻³)	980
	比定压热容/(J·kg ⁻¹ ·K ⁻¹)	1 200
	导热系数/(W·m ⁻¹ ·K ⁻¹)	0.206
挡板	密度/(kg·m ⁻³)	680
	比定压热容/(J·kg ⁻¹ ·K ⁻¹)	2 960
	导热系数/(W·m ⁻¹ ·K ⁻¹)	0.17

2.3 PI-DeepONet 模型

本文引入物理约束的思想构建了面向变压器绕组热-流场的 PI-DeepONet 模型,所构建的模型数据流程如图 5 所示。




图 5 融合物理信息的 DeepONet 模型详细结构

Fig. 5 Detailed structure of the physics-informed deepONet

本文构建的深度算子网络中的分支网络和主干网络均采用全连接网络。分支网络输入为负载率、环境温度和油流入口流速 3 个核心工况参数。主干网络输入为 201 536 个二维节点坐标,源自图 3 所示几何模型的有限元网格,这些坐标组成维度为 (201 536, 2) 的张量。输出张量的维度为 (201 536, 4),存储各节点的温度、压强、径向油流速度和轴向油流速度,实现多物理量同步计算。

$$\begin{cases} \frac{\partial v_r^*}{\partial r^*} + \frac{v_r^*}{r^*} + \frac{\partial v_z^*}{\partial z^*} = 0 \\ v_r^* \frac{\partial v_r^*}{\partial r^*} + v_z^* \frac{\partial v_r^*}{\partial z^*} = -\frac{\partial P^*}{\partial r^*} + \frac{\mu}{\rho L_\infty v_\infty} \left(\frac{\partial^2 v_r^*}{\partial (r^*)^2} + \frac{\partial v_r^*}{r^* \partial r^*} - \frac{v_r^*}{(r^*)^2} + \frac{\partial^2 v_r^*}{\partial (z^*)^2} \right) \\ v_r^* \frac{\partial v_z^*}{\partial r^*} + v_z^* \frac{\partial v_z^*}{\partial z^*} = -\frac{\partial P^*}{\partial z^*} + \frac{\mu}{\rho L_\infty v_\infty} \left(\frac{\partial^2 v_z^*}{\partial (r^*)^2} + \frac{\partial v_z^*}{r^* \partial r^*} + \frac{\partial^2 v_z^*}{\partial (z^*)^2} \right) + \frac{L_\infty g}{v_\infty^2} \\ v_r^* \frac{\partial T^*}{\partial r^*} + v_z^* \frac{\partial T^*}{\partial z^*} = \frac{1}{L_\infty v_\infty} \frac{\lambda}{\rho c_p} \left(\frac{\partial^2 T^*}{\partial (r^*)^2} + \frac{\partial T^*}{r^* \partial r^*} + \frac{\partial^2 T^*}{\partial (z^*)^2} \right) + \frac{L_\infty Q}{T_\infty v_\infty \rho c_p} \end{cases} \quad (3)$$

基于无量纲化后的热-流场基本方程,本小节给出应用于本文的物理约束损失函数。整体损失函数由多个子项组成,分别表示数值误差、方程残差和边界条件误差,具体形式如下

$$L_{\text{sum}} = \lambda_d L_d + \lambda_p L_p + \lambda_b L_b \quad (4)$$

式中: L_{sum} 为总损失函数; L_d 为数据误差损失项; L_p 为物理方程残差损失项; L_b 为边界条件损失项; λ_d 、 λ_p 、 λ_b 分别表示数据误差项、物理残差项和边界条件项对应的权重系数。经过多次试验,本文中最终确定,各项权重参数如下, $\lambda_d = 1$, $\lambda_p = \lambda_b = 0.05$ 。

数据误差项 L_d 用于度量网络预测结果与真实

训练过程中,通过对预测值进行自动微分处理,计算数值误差、物理损失和边界条件残差项,根据损失权重计算最终损失函数,并反馈给网络进行参数优化,以提高计算精度。

2.4 损失函数构建

由于各物理量的量级差异较大,可能导致物理信息损失函数的残差过大,从而无法准确反映物理约束。因此,需要对变量进行无量纲化处理。无量纲化处理是指通过选取特征参考量,将各物理量转换到相近的数量级,其作用类似于归一化。与一般归一化方法不同,该方法利用特征参考量构造与原物理量具有相同单位的系数,使无量纲化后的变量仍满足原有物理方程,从而在消除量纲和尺度影响的同时保留物理信息。本文引入特征速度 v_∞ 、特征长度 L_∞ 与特征温度 T_∞ ,对模型中的物理量进行无量纲化处理,表达式如下

$$\begin{aligned} v_r^* &= \frac{v_r}{v_\infty}; v_z^* = \frac{v_z}{v_\infty}; r^* = \frac{r}{L_\infty}; \\ z^* &= \frac{z}{L_\infty}; P^* = \frac{P}{\rho v_\infty^2}; T^* = \frac{T}{T_\infty} \end{aligned} \quad (2)$$

式中: v_r^* 、 v_z^* 、 r^* 、 z^* 、 P^* 、 T^* 分别为无量纲化的径向油流速度、轴向油流速度、径向坐标、轴向坐标、油流压强、温度;特征速度 v_∞ 取为 0.5 m/s,特征长度 L_∞ 取为 0.1 m,特征温度 T_∞ 取为 323.15 K。

式(1)无量纲化处理后表达式如下

值之间的偏差,其表达式为

$$L_d = \frac{1}{N_d} \sum_{i=1}^{N_d} \left(|\hat{T}_i^* - T_i^*|^2 + |\hat{P}_i^* - P_i^*|^2 + |\hat{v}_{r,i}^* - v_{r,i}^*|^2 + |\hat{v}_{z,i}^* - v_{z,i}^*|^2 \right) \quad (5)$$

式中: N_d 为数据采样点总数; i 为采样点编号; $\hat{T}_i^*$ 、 $\hat{P}_i^*$ 、 $\hat{v}_{r,i}^*$ 和 $\hat{v}_{z,i}^*$ 分别为第 i 个采样点处温度、压力、径向油流速度和轴向油流速度的无量纲预测值; T_i^* 、 P_i^* 、 $v_{r,i}^*$ 和 $v_{z,i}^*$ 分别为对应物理量的无量纲真实值。

物理方程残差项用于约束预测结果满足控制方程和区域物理特性,表达式为

$$L_p = L_c + L_e + L_m + L_s \quad (6)$$

式中: L_c 表示连续性方程残差项; L_e 表示能量方程残差项; L_m 表示动量方程残差项; L_s 表示固体区域速度约束项。

式(6)中的各子项可进一步表示为

$$L_c = \frac{1}{N_f} \sum_{i \in \Omega_f} |R_c^{(i)}|^2 \quad (7)$$

$$L_e = \frac{1}{N_s} \sum_{i \in \Omega_s} |R_{e,s}^{(i)}|^2 + \frac{1}{N_f} \sum_{i \in \Omega_f} |R_{e,f}^{(i)}|^2 \quad (8)$$

$$L_m = \frac{1}{N_f} \sum_{i \in \Omega_f} (|R_{m,r}^{(i)}|^2 + |R_{m,z}^{(i)}|^2) \quad (9)$$

$$L_s = \frac{1}{N_s} \sum_{i \in \Omega_s} (|\hat{v}_{r,i}^*|^2 + |\hat{v}_{z,i}^*|^2) \quad (10)$$

式中: Ω_f 、 Ω_s 分别表示流体区域和固体区域; N_f 、 N_s 分别为流体区域和固体区域中的采样点数; $R_c^{(i)}$ 为第 i 个流体域采样点处连续性方程的无量纲残差; $R_{e,s}^{(i)}$ 和 $R_{e,f}^{(i)}$ 分别为第 i 个固体域采样点和流体域采样点处能量方程的无量纲残差; $R_{m,r}^{(i)}$ 和 $R_{m,z}^{(i)}$ 分别为第 i 个流体域采样点处径向动量方程和轴向动量方程的无量纲残差。由于固体区域不存在流动,因此通过 L_s 对固体域速度进行零约束。上述残差的具体表达式均可由式(3)所示无量纲控制方程直接得到,本文不再逐项展开。

边界条件损失项用于约束网络预测结果满足入口与出口边界条件,其表达式为

$$L_b = L_{in,v} + L_{in,T} + L_{out,p} \quad (11)$$

式中: $L_{in,v}$ 为入口速度边界损失项; $L_{in,T}$ 为入口温度边界损失项; $L_{out,p}$ 为出口压力边界损失项。

各子项可分别写为

$$L_{in,v} = \frac{1}{N_{in}} \sum_{i \in \Gamma_{in}} (|\hat{v}_{r,i}^* - v_{r,in}^*|^2 + |\hat{v}_{z,i}^* - v_{z,in}^*|^2) \quad (12)$$

$$L_{in,T} = \frac{1}{N_{in}} \sum_{i \in \Gamma_{in}} |\hat{T}_i^* - T_{in}^*|^2 \quad (13)$$

$$L_{out,p} = \frac{1}{N_{out}} \sum_{i \in \Gamma_{out}} |\hat{P}_i^* - P_{out}^*|^2 \quad (14)$$

式中: Γ_{in} 、 Γ_{out} 分别为入口边界和出口边界; N_{in} 、 N_{out} 分别为入口边界和出口边界上的采样点数; $v_{r,in}^*$ 、 $v_{z,in}^*$ 分别为入口边界给定的径向和轴向无量纲速度; T_{in}^* 为入口边界给定的无量纲温度; P_{out}^* 为出口边界给定的无量纲压力。

3 结果与讨论

本文以 2.2 节中的油浸式变压器绕组简化模型为对象,验证所提方法的有效性。PI-DeepONet 模型训练所使用的计算机配置为 Intel Xeon W9-3495X 处理器、NVIDIA RTX A4000 显卡。PI-DeepONet 模型在 PyTorch 框架下搭建。

3.1 网络结构超参数的选择

为确定最优网络结构,本小节讨论了隐藏层深度 D 和宽度 W 对 PI-DeepONet 模型收敛性能的影响。主干网络和分支网络均采用全连接结构,二者的隐藏层结构相同,学习率设置为 0.01,优化器选用 Adam。本文测试了 9 种不同的网络结构,网络深度分别为 3、5、7,宽度为 20、50、100,训练轮次为 20 000,训练结果如图 6 所示。从网络深度来看,深度为 7 的网络表现最佳,其次为深度为 3 的网络,深度为 5 的网络收敛精度较差。从网络宽度来看,固定深度时,宽度增大提高了收敛精度。综合考虑收敛稳定性和计算精度,本文选择深度为 7、宽度为 50 的网络架构进行后续研究。




图 6 不同网络结构的损失函数收敛曲线

Fig. 6 Loss function convergence curves for different network structures

3.2 激活函数对网络收敛性能的影响

激活函数的选择对包含物理约束的网络收敛至关重要。不同激活函数下 PI-DeepONet 模型的物理项损失函数收敛过程如图 7 所示。从图 7 可以看出,




图 7 不同激活函数下 PI-DeepONet 模型的物理项损失函数收敛曲线

Fig. 7 PDE loss function convergence curves for different activation functions

Tanh 函数在物理项损失函数的收敛过程中表现较为优异,ReLU 与 HardTanh 两种激活函数表现较差,这是因为它们的一阶导数为常数(0 和 1),二阶导数为 0,导致其在 PINN,尤其是在包含高阶项的物理问题求解中表现较差^[25]。综上所述,Tanh 函数是在包含物理约束项的神经网络中更为推荐的激活函数。

3.3 快速计算结果分析

使用 3.1~3.2 小节确定的最优网络结构和激活函数,对测试集中的 20 个案例进行了热-流场预测。为了评估预测精度,本文引入了平均绝对误差(设为 E_{MAE}),表达式如下

$$E_{MAE} = \frac{\sum_{i=1}^N |\hat{x}_i - x_i|}{N} \quad (15)$$

式中: $\hat{x}_i$ 为第 i 个预测值; x_i 为第 i 个实际值; N 为所有计算节点的个数。

对测试集中的所有案例进行了预测计算,各变量的预测值与商用软件计算值之间的平均绝对误差如图 8 所示。基于 PI-DeepONet 的快速计算方法在测试集中的表现较为优异。温度预测的 E_{MAE} 最大值为 0.1 °C,压力为 5.03 Pa,轴向油流速度为 0.003 6 m/s,径向油流速度为 0.006 1 m/s,表明 PI-DeepONet 模型具有较高的预测精度。




图 8 测试集不同变量预测误差

Fig. 8 Prediction error of different variables in the test set

为对比 PI-DeepONet 模型在计算精度上的优越性,本文分别使用 PI-DeepONet 模型与仅包含数据损失项的 DeepONet 模型进行了训练。两种模型

的超参数设置相同,仅在损失函数上有所不同。图 9 展示了入口流速为 0.35 m/s、运行负载率为 0.53、入口油流温度为 10.95 °C 时不同模型的计算结果。

从图 9 可见,PI-DeepONet 模型的预测结果较准确地反映了变压器实际温度分布的整体规律。相对误差分析结果表明,绕组边缘竖直区域的预测误差相对较大,主要原因在于神经网络更擅长拟合连续变化的物理场,而绕组边缘处温度梯度较大,从而导致局部预测精度有所下降。在该工况下,PI-DeepONet 模型预测的热点温度为 29.47 °C,与数值计算结果仅相差 0.015 °C,最大相对误差为 3.35%,平均相对误差为 0.23%。与之相比,传统 DeepONet 模型的预测精度略低,其热点温度预测值为 30.45 °C,与数值计算结果相差 0.995 °C,最大相对误差为 8.09%,平均相对误差为 1.17%。

从压力预测结果来看,PI-DeepONet 模型能够准确地捕捉压力分布的整体规律,预测最大值为 7 839.69 Pa,与有限元结果仅相差 3.16 Pa,相对误差最大为 2.69%,均值为 0.03%。根据图 9(b)的压力预测误差分布显示,绕组纵向油道附近的误差相对较大。相比之下,纯 DeepONet 模型的压力预测最大相对误差为 7.44%,均值为 1.52%。

在轴向油流速度预测方面,PI-DeepONet 模型的预测值为 2.34 m/s,与 CFD 计算结果的相对误差仅为 0.43%,最大相对误差为 4.70%,平均相对误差为 0.02%。其中,低压绕组右侧油道区域的相对误差略大,而左侧轴向速度较高区域的预测精度较高。传统 DeepONet 模型的最大相对误差为 6.65%,平均相对误差为 0.85%。对于径向油流速度,PI-DeepONet 模型的预测同样能够较准确地刻画整体分布特征。

预测结果与有限元计算结果相比,最大相对误差为 3.14%,均值仅为 0.04%。纯 DeepONet 模型对应的最大相对误差为 5.03%,均值为 0.91%。

为了评估模型预测精度,对各计算节点处的相对误差分布进行了统计分析,结果如图 10 所示。预测结果的相对误差在各区间内的分布比例,定义为计算域内相对误差落入该区间的节点数占总节点数的比例。由图 10(a)可以看出,PI-DeepONet 模型 4 种变量预测误差中,94.02%的数据点相对误差在 0.7% 以下,表明该模型在大多数区域具有较高精度。由图 10(b)可以看出,使用纯 DeepONet 模型时,约 96.82% 的计算节点的误差在 2% 以内,68.51%






图9 某工况下不同模型对各待求物理量预测结果云图

Fig. 9 Contour map of predicted results for various variables under a specific operating condition

的节点误差在 0.7% 以内。误差较大的节点主要集中在流固界面区域, PI-DeepONet 模型在一定程度上减小了该区域的预测误差。综上, PI-DeepONet 模型对各变量的预测精度优于未加物理约束的 DeepONet 模型。



(a) PI-DeepONet 模型误差分布



(b) DeepONet 模型误差分布

图 10 某工况下各物理量预测相对误差分布

Fig. 10 Distribution of relative prediction errors for various variables under a specific operating condition

在计算效率方面, Fluent 仿真软件计算采用与 PI-DeepONet 模型完全一致的 220 kV 三绕组几何模型与 201 536 节点结构化网格, 物性参数见表 1; 湍流模型选用 SST $k-\omega$, 收敛残差判据设为 10^{-6} (各物理量波动小于 0.1%); 计算硬件平台与前文训练阶段所用一致, 采用 40 核并行计算, 单次工况迭代约 2 500 次收敛, 耗时约 1 200 s。PI-DeepONet 模型训练后单次预测耗时 0.12 s, 而 Fluent 仿真在相同硬件条件下耗时约 1 200 s, 计算速度提升约 10 000 倍, 验证了本文方法的高效性。

4 结 论

本文提出了一种融合物理信息与深度算子网络

的变压器绕组稳态热-流场快速计算方法, 主要结论如下。

(1) 所提出的 PI-DeepONet 模型通过引入分支网络和主干网络, 实现了对变压器绕组运行参数与空间计算域的解耦编码, 并利用物理约束损失函数显著提升了网络的收敛性与预测精度。与传统有限元方法相比, 该方法在保证高精度的同时, 大幅提升了计算效率, 能够高效获得变压器绕组稳态工况下的温度、压强及油流速度分布。

(2) 在对比不同激活函数性能后, 最终选择 Tanh 作为激活函数, ReLU 和 HardTanh 因存在自身局限性, 不适用于此类高阶物理信息问题的求解。

(3) 在本文所提的模型框架下, 温度预测的最大平均绝对误差为 0.1 °C, 压强预测的最大平均绝对误差为 5.03 Pa, 轴向油流速度预测的最大平均绝对误差为 0.003 6 m/s, 径向流速预测的最大平均绝对误差为 0.006 1 m/s, 验证了 PI-DeepONet 模型在相关物理场预测中的高精度表现。

本研究提出的模型具有一定的通用性, 尽管本文以强迫油循环冷却变压器为研究对象, 但该思路和计算流程可推广至不同电压等级和冷却方式的油浸式变压器。在实际应用中, 可以根据设备结构和运行条件, 调整几何模型及损失函数中的边界条件, 以满足不同变压器的快速计算需求。未来将研究基于 PI-DeepONet 模型的变压器暂态温度场快速预测方法, 以支持数字孪生场景下的实时热-流场计算。

参考文献:

- [1] 国家能源局电力可靠性管理和工程质量监督中心. 2022 年全国电力可靠性年度报告 [EB/OL]. (2023-10-18)[2025-05-13]. <https://prpq.nea.gov.cn/%20ndbg/9875.html>.
- [2] 江秀臣, 许永鹏, 李曜丞, 等. 新型电力系统背景下的输变电数字化转型 [J]. 高电压技术, 2022, 48(1): 1-10.
Jiang Xiuchen, Xu Yongpeng, Li Yaocheng, et al. Digitalization transformation of power transmission and transformation under the back-ground of new power system [J]. High Voltage Engineering, 2022, 48(1): 1-10.
- [3] 盛戈皞, 钱勇, 罗林根, 等. 面向新型电力系统的数字化电力设备关键技术及其发展趋势 [J]. 高电压技术, 2023, 49(5): 1765-1778.
Sheng Gehao, Qian Yong, Luo Linggen, et al. Key technologies and development trends of digital power

- equipment for new type power system [J]. High Voltage Engineering, 2023, 49(5): 1765-1778.
- [4] 吴泽华, 吴宝英, 赵林杰, 等. 面向输变电设备数字孪生的多物理场正反演快速仿真关键技术综述 [J]. 电网技术, 2024, 48(10): 4215-4230.
- Wu Zehua, Wu Baoying, Zhao Linjie, et al. Review of forward and reverse multi-field simulation technology for digital twin of electrical power equipment [J]. Power System Technology, 2024, 48(10): 4215-4230.
- [5] 李元, 王晨, 张冠军. 传热学与电学问题的迁移类比研究: (2) 工程实践 [J]. 西安交通大学学报, 2021, 55(9): 1-8.
- Li Yuan, Wang Chen, Zhang Guanjuan. Analogical transfer between heat transfer and electrodynamics: (2) engineering practices [J]. Journal of Xi'an Jiaotong University, 2021, 55(9): 1-8.
- [6] 张志宇, 寇家俊, 张重远, 等. 基于本征正交分解和克里金代理模型的油浸式变压器绕组温度场快速计算方法 [J]. 电工技术学报, 2025, 40(7): 2215-2225.
- Zhang Zhiyu, Kou Jiajun, Zhang Zhongyuan, et al. A fast calculation method for temperature field of oil immersed transformer windings based on proper orthogonal decomposition and Kriging surrogate model [J]. Transactions of China Electrotechnical Society, 2025, 40(7): 2215-2225.
- [7] 赵庆贤, 刘云鹏, 刘刚, 等. 基于 POD-DNN 降阶模型的油浸式变压器绕组稳态温升快速计算方法 [J]. 中国电机工程学报, 2025, 45(6): 2423-2436.
- Zhao Qingxian, Liu Yunpeng, Liu Gang, et al. Fast calculation of steady temperature rise of oil-immersed transformer windings based on POD-DNN reduced order model [J]. Proceedings of the CSEE, 2025, 45(6): 2423-2436.
- [8] Lu Lu, Jin Pengzhan, Pang Guofei, et al. Learning nonlinear operators via DeepONet based on the universal approximation theorem of operators [J]. Nature Machine Intelligence, 2021, 3(3): 218-229.
- [9] 魏蓉, 陈锦培, 仲林林. 基于深度算子网络的电磁轨道发射速度趋肤效应的快速计算方法 [J]. 电工技术学报, 2025, 40(5): 1344-1354.
- Wei Rong, Chen Jinpei, Zhong Linlin. A fast computational method for velocity skin effect of electromagnetic rail launch based on deep operator network [J]. Transactions of China Electrotechnical Society, 2025, 40(5): 1344-1354.
- [10] 张宇娇, 赵志涛, 赵常威, 等. 基于深度算子网络的电磁场快速计算方法 [J]. 高电压技术, 2025, 51(3): 1484-1494.
- Zhang Yujiao, Zhao Zhitao, Zhao Changwei, et al. Rapid calculation method for electromagnetic fields based on deep operator network [J]. High Voltage Engineering, 2025, 51(3): 1484-1494.
- [11] Sasaki H, Iwata K, Sato T, et al. Prediction of motor characteristic maps via deep operator networks for topology optimization [J]. IEEE Transactions on Magnetics, 2024, 60(12): 1-5.
- [12] Xu Chen, Cao B T, Yuan Yong, et al. A multi-fidelity deep operator network (DeepONet) for fusing simulation and monitoring data: application to real-time settlement prediction during tunnel construction [J]. Engineering Applications of Artificial Intelligence, 2024, 133(PB): 108156.
- [13] Ahmed B, Qiu Yuqing, Abueidda D W, et al. Physics-informed deep operator networks with stiffness-based loss functions for structural response prediction [J]. Engineering Applications of Artificial Intelligence, 2025, 144: 110097.
- [14] Shukla K, Oommen V, Peyvan A, et al. Deep neural operators as accurate surrogates for shape optimization [J]. Engineering Applications of Artificial Intelligence, 2024, 129: 107615.
- [15] 张振, 苏欣荣, 袁新. 基于物理信息神经网络的气膜冷却湍流模型反演学习 [J]. 动力工程学报, 2024, 44(9): 1459-1465.
- Zhang Zhen, Su Xinrong, Yuan Xin. PINN-based inversion learning of turbulence model for film cooling [J]. Journal of Chinese Society of Power Engineering, 2024, 44(9): 1459-1465.
- [16] 金立军, 王飞龙, 王金玉. 基于物理信息网络的开关柜三维温升场域重建与缺陷热源反演 [J]. 中国电机工程学报, 2026, 46(4): 1685-1697.
- Jin Lijun, Wang Feilong, Wang Jinyu. Three-dimensional temperature rise field reconstruction and defect heat source inversion of switchgear based on physical information network [J]. Proceedings of the CSEE, 2026, 46(4): 1685-1697.
- [17] 张宇娇, 孙宏达, 赵志涛, 等. 基于物理信息神经网络的电磁场计算方法 [J]. 电工技术学报, 2024, 39(17): 5251-5261.
- Zhang Yujiao, Sun Hongda, Zhao Zhitao, et al. Electromagnetic field calculation method based on physical informed neural network [J]. Transactions of China Electrotechnical Society, 2024, 39(17): 5251-5261.
- [18] 杨立. 使用 DeepONet 模型求泊松方程解算子 [D]. 成都: 电子科技大学, 2024: 16-21.
- [19] 席梓严, 戴玉婷, 黄广靖, 等. 基于深度算子神经网络

- 络的翼型失速颤振预测 [J]. 力学学报, 2024, 56(3): 626-634.
- Xi Ziyang, Dai Yuting, Huang Guangjing, et al. Airfoil stall flutter prediction based on DeepONet [J]. Chinese Journal of Theoretical and Applied Mechanics, 2024, 56(3): 626-634.
- [20] 尹掀浪, 苏晶晶, 张升, 等. 基于 PI-DeepONet 算法与稀疏测点数据的两类饱和软土固结行为预测 [J]. 铁道科学与工程学报, 2025, 22(10): 4542-4552.
- Yin Xianlang, Su Jingjing, Zhang Sheng, et al. Prediction of two types of saturated soft soil consolidation behavior based on the PI-DeepONet algorithm and sparse measurement data [J]. Journal of Railway Science and Engineering, 2025, 22(10): 4542-4552.
- [21] 黄子杰. 基于深度算子网络的非饱和土壤水分运动模拟研究 [D]. 杭州: 浙江大学, 2024: 17-24.
- [22] 王非凡. 基于深度算子网络的飞行器热防护不确定性量化分析 [D]. 北京: 华北电力大学, 2024: 33-35.
- [23] 陈思, 盛戈俾, 张立静, 等. 基于绕组等效热参数的干式变压器温度场分布快速仿真方法 [J]. 高电压技术, 2025, 51(1): 97-109.
- Chen Si, Sheng Gehao, Zhang Lijing, et al. Fast simulation method of temperature field distribution for dry-type transformer based on equivalent thermal parameters of windings [J]. High Voltage Engineering, 2025, 51(1): 97-109.
- [24] 李元, 陈智秋, 刘志濠, 等. 伴随网格自适应剖分优化变压器内部温度仿真模型计算效率方法 [J]. 西安交通大学学报, 2026, 60(3): 166-174.
- Li Yuan, Chen Zhiqiu, Liu Zhihao, et al. Adjoint-based adaptive mesh refinement method for optimizing computational efficiency of transformer internal temperature simulation models [J]. Journal of Xi'an Jiaotong University, 2026, 60(3): 166-174.
- [25] Wang Jiangyu, Peng Xingjie, Chen Zhang, et al. Surrogate modeling for neutron diffusion problems based on conservative physics-informed neural networks with boundary conditions enforcement [J]. Annals of Nuclear Energy, 2022, 176: 109234.
- (编辑 武红江)

~~~~~

(上接第 227 页)

- [22] 王新, 杨敏, 金泱, 等. 基于热老化的发电机定子线棒局部放电特性研究 [J]. 绝缘材料, 2021, 54(4): 58-63.
- Wang Xin, Yang Min, Jin Yang, et al. Partial discharge characteristics of typical defects in generator stator after thermal ageing [J]. Insulating Materials, 2021, 54(4): 58-63.
- [23] 陈向荣, 黄小凡, 王启隆, 等. 温度和频率对环氧树脂/碳化硅晶须复合材料交流非线性特性的影响 [J]. 电工技术学报, 2022, 37(15): 3897-3912.
- Chen Xiangrong, Huang Xiaofan, Wang Qilong, et al. Effect of temperature and frequency on AC nonlinear properties of epoxy resin/silicon carbide whisker composites [J]. Transactions of China Electrotechnical Society, 2022, 37(15): 3897-3912.
- [24] GB/T 311.1—2012 绝缘配合 第 1 部分: 定义、原则和规则 [S].
- [25] 赵禹来. 模拟高海拔大气条件发电机定子绕组电晕起始电压研究 [D]. 重庆: 重庆大学, 2020.
- (编辑 武红江)