

基于物理信息神经网络模型的变压器油中溶解气体预测方法研究

董明¹, 陈骥¹, 常昊鑫¹, 胡一卓¹, 张崇兴¹, 张海滨², 董璇²

(1. 西安交通大学 电工材料电气绝缘全国重点实验室, 陕西 西安 710049; 2. 国电南瑞科技股份有限公司, 江苏 南京 211106)

摘要:油中溶解气体分析(DGA)是变压器状态监测和故障预警的核心方法。然而,传统基于数据驱动的DGA预测方法在准确性和泛化能力方面存在一定局限性。为了解决上述问题,提出一种基于物理信息神经网络(PINN)的变压器油中溶解气体预测方法。首先,构建典型缺陷模型的油纸绝缘实验平台,研究局部放电下DGA产气规律,并建立溶解气体与放电能量的关联模型。然后,构建物理信息约束方程组,利用该方程组嵌入时序预测模型并进行训练,以提高预测精度和可解释性。实验结果表明,相较于传统智能模型,PINN模型能够更准确地预测油中溶解气体浓度变化,并在数据稀缺的情况下仍能保持较高的稳定性和泛化能力。研究为提升变压器健康状态监测的智能化水平提供了一种新思路,有助于实现更精准的状态评估和早期故障预警。

关键词:电力变压器;油中溶解气体预测;物理信息神经网络;产气规律;人工智能

DOI:10.15938/j.emc.2025.12.001

中图分类号:TM407

文献标志码:A

文章编号:1007-449X(2025)12-0001-12

Research on prediction method of dissolved gas in transformer oil based on physical information neural network model

DONG Ming¹, CHEN Ji¹, CHANG Haoxin¹, HU Yizhuo¹, ZHANG Chongxing¹,
ZHANG Haibin², DONG Xuan²

(1. State Key Laboratory of Electrical Insulation and Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China;

2. NARI Technology Co., Ltd., Nanjing 211106, China)

Abstract: Dissolved gas analysis (DGA) is the core method for transformer condition monitoring and early fault warning. However, traditional data-driven DGA prediction methods have some limitations in accuracy and generalization. To address these limitations, a prediction method for dissolved gases in transformer oil based on a physics-informed neural network (PINN) was developed. An oil-paper insulation experimental platform with typical defect models was constructed to investigate the gas generation behavior of partial discharges in DGA, and a correlation model between dissolved gases and discharge energy was established. Physical information constraint equations were then formulated and embedded into a time-series prediction model, which was trained to enhance prediction accuracy and interpretability. Experi-

收稿日期: 2025-09-12

基金项目: 国家重点研发计划(2023YFB2406900)

作者简介: 董明(1979—),男,博士,教授,博士生导师,研究方向为电气设备状态监测及人工智能应用;

陈骥(2002—),男,硕士研究生,研究方向为油纸绝缘电弧放电诊断及预警;

常昊鑫(2001—),男,硕士研究生,研究方向为油纸绝缘电弧放电诊断及预警;

胡一卓(1996—),男,博士研究生,研究方向为油纸绝缘电弧放电诊断及预警;

张崇兴(1990—),男,博士,研究方向为电力设备智能状态感知技术和高压电力电子绝缘设计与评估方法;

张海滨(1976—),男,博士,高级工程师,研究方向为电力设备状态监测与诊断技术;

董璇(1983—),女,硕士,研究方向为电力设备状态监测与诊断技术。

通信作者: 董明

tal results indicate that, compared with traditional intelligent models, the proposed PINN model can predict the variation of dissolved gas concentrations in oil more accurately and can maintain high stability and generalization capability under data-scarce conditions. This study provides a new approach to improve the intelligence level of transformer health condition monitoring and supports more accurate state assessment and early fault warning.

Keywords: power transformer; prediction of dissolved gas in oil; physics-informed neural networks; gas production law; artificial intelligence

0 引言

电力变压器是电力系统中的关键设备,在电网中起到电压变换的作用,其运行状态直接关系到电网的供电可靠性及安全性,如何保证电力变压器运行安全一直是电网设备运行部门重点关心的核心问题^[1]。近年来,为了确保油浸式电力变压器安全运行,以油中溶解气体分析、局部放电检测^[2]等为代表的在线监测技术已广泛应用于高电压等级及大容量变压器设备的状态监测中,并在设备状态评估、运行状态预警以及维修决策制定等运维工作中发挥了巨大的作用。

根据国际电工委员会发布,在诸多检测方法中,溶解气体分析(dissolved gas analysis, DGA)^[3]被广泛认为是油浸式电力变压器运行状态评估中最重要且有效的检测方法。DGA具有抗干扰能力强、稳定性/可靠性高、故障机理明确等优点,能够通过特定气体(如氢气、甲烷、乙烷、乙炔、碳氧化物等)的种类和浓度比例提供丰富的诊断信息,精准识别不同故障类型(如热故障和电故障),尤其对潜伏性过热类故障的预警与诊断效果更优。此外,该方法具备非侵入性,能够在不影响设备正常运行的情况下完成检测,操作便捷且适用范围广,已成为国际上公认的油浸式电力变压器健康状态监测的核心技术^[4-5]。

DGA数据属于时序数据,数据不仅表示特定时间点的溶解气体浓度,还与前后时间点的测量值具有内在关联性。因此,通过对油中溶解气体进行产气预测,可以超前于故障发生而及时采取预防性维修,是开展变压器状态评估的重要方法。文献[6]提出一种基于时间序列和支持向量机的变压器故障预测模型,将自回归积分滑动平均模型和支持向量机相结合,具有较高的预测准确率。文献[7]使用具有“时序记忆力”的长短时记忆神经网络(long

short-term memory network, LSTM),采集变压器在正常、过载和放电3种状态下的声信号,预处理并且训练后能够准确反映变压器未来工况,但存在选择参数难的问题。因此,文献[8]选择使用联合算法,利用互补集合经验模态分解算法和猫群算法对LSTM进行优化,确保精度的同时实现了参数优化选取。LSTM^[9]存在梯度爆炸、计算开销大、预测速度慢等问题,为了解决上述问题,文献[10]设计了基于门控循环单元的预测模型,改善了传统时序预测模型的搜索能力和跳出局部最优能力,但该方法的预测精度受数据质量影响较大。文献[11]针对油中溶解气体浓度序列非线性、非平稳特性影响预测精度问题,提出黏菌算法-变分模态-门控循环单元(slime mould algorithm-variational mode decomposition-gated recurrent unit, SMA-VMD-GRU)模型,但重构误差未被补偿,拐点预测效果一般。此外,国内外众多学者开展油中溶解气体预测时还选择了时间卷积网络^[12-13]、灰色理论^[14]、深度信念网络^[15]等。然而上述预测模型大多均是基于数据分布假设的数据驱动方法,尤其是人工神经网络属于“黑盒”模型,预测准确性极大依赖数据数学分布模型、样本数据质量与规模,存在易过拟合、可解释性差等问题。

物理驱动可减少标签数据,提升模型的泛化能力。物理信息约束将物理驱动与数据驱动相融合,受到了众多学者的广泛关注。RAISSI M团队^[16]在2019年提出一种将偏微分方程(partial differential equation, PDE)的物理信息嵌入神经网络损失函数中的方法,即物理信息神经网络(physics-informed-neural-network, PINN)。传统的机器学习方法只能捕捉变量之间的相关性,而PINN考虑了输入量与输出量之间的因果关系,改善了传统人工智能故障诊断模型可解释性差、对训练数据质量和数量要求高的缺点,在保证精度的同时还能符合科学规律,具有更

高的泛化能力^[17]。在生物医学研究中,SAHLI C F 等^[18]针对心房颤动的诊断开展了相关探索,采用 PINN 对心脏激活时间所服从的非线性波动方程进行建模求解。该方法能够有效揭示波阵面交汇的物理特征,其分类准确性优于传统的高斯法和插值法。在材料领域,FANG Z 等^[19]利用 PINN 对电磁超材料问题进行了探索,通过 PINN 求解频率领域的 Maxwell 方程,获得了材料内外部的电磁波分布,并通过增加材料内部的电磁波分布约束条件反向获得材料的磁导率、电容率等物理参数,大大提高了计算效率。此外,PINN 已在电力行业取得了一定应用,如短间隙流注放电模拟^[20]、同步发电机建模^[21]、锂离子电池温度预测^[22]、静态电压稳定预防^[23]、风电功率预测^[24]、电磁场分布预测^[25]等领域,但将该方法应用于 DGA 产气预测的研究仍为空白。

针对上述问题,本文开展如下工作:1) 在实验室内构建典型缺陷模型的油纸绝缘实验平台,获得典型故障条件下 DGA 产气规律;2) 研究油纸绝缘油中溶解气体与产气能量关联模型;3) 结合放电产气能量模型训练神经网络模型,构建油中溶解气体的信息物理神经网络模型,对油中溶解气体含量进行准确预测;4) 与其他方法相比较,验证本文所述方法的可行性。结果表明,依据产气能量和物理单调性关系作为物理约束条件训练神经网络模型,可以对油中溶解气体含量进行准确预测,改善数据驱动模型过于依赖数据样本的缺点,对推进油中溶解气体故障诊断技术、确保电力变压器安全运行具有重要意义。

1 典型放电故障产气模拟实验平台

1.1 放电实验平台

本文根据国际技术规范 IEC 60243^[26]搭建了如图 1 所示的实验室油纸绝缘典型放电故障产气模拟实验平台,由实验和测量系统两部分组成。

实验系统用于构建模拟典型放电故障环境。其中:调压器和试验变压器用于实现油纸绝缘放电故障所需激励能量的传输和转化;实验罐体由有机树脂制成,内置有预处理后的实验电极以及油纸绝缘系统;罐体顶部安装压力表和放气阀以及时调整罐体内部气压,确保实验过程中罐体不会爆炸。此外,罐体顶部及侧下方均安装油阀,以便于真空注油和消除气泡,并通过设置取油阀,实现不间断实验的前提下在线提取油样。

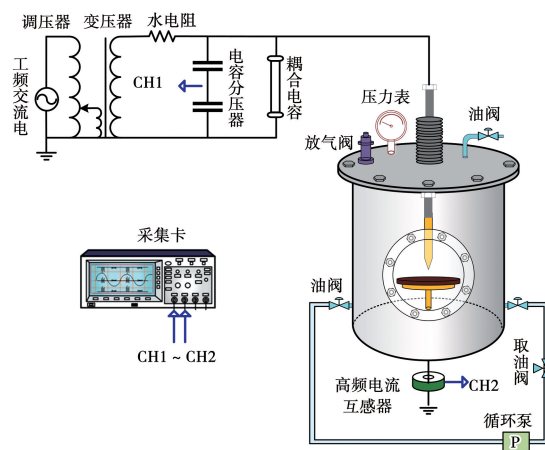


图 1 模拟放电实验平台

Fig. 1 Simulated discharge experimental platform

测量系统用于对实验过程中产生的电信号及其他物理参量进行实时监测和采集。其中:电容分压器额定电压为 100 kV,用于采集施加电压信号 CH1;Pearson Model 8600 高频电流互感器(high frequency current transformer, HFCT)用于采集脉冲电流信号 CH2,其有效带宽为 40 kHz ~ 130 MHz,灵敏度为 10 V/A。将 CH1 和 CH2 信号传输线同时接到 PicoScope5443D 采集卡上,实现电压电流的同步采集和保存。

此外,为了加速油中气体的溶解,同时模拟真实变压器中绝缘油的循环流动特性,油阀外接了循环泵,并在循环泵出口处安装三通油阀,在实验过程中可以在不阻断油流的情况下直接取油,既方便采集绝缘油样又不产生气泡,此外确保每次取油量保持一致。为了确保实验安全性和稳定性,所用高压线采取了防电晕处理,回路串接了水电阻。

1.2 缺陷设计与样品预处理

在实际应用中,尖端缺陷是变压器内部典型的绝缘劣化形式,其非均匀电场会显著增强放电强度并加速绝缘油的分解,从而产生特定成分的溶解气体。本文以尖端放电为例,设计了如图 2 所示的针板电极模型。其中,电极均由黄铜材料所制,针电极尖部距离绝缘纸板垂直距离为 2 mm,板电极接地。绝缘纸板为魏德曼公司生产的单层纸板,厚度为 1 mm,绝缘纸板紧贴板电极。绝缘油使用 25#克拉玛依矿物油。

开展产气实验前,对绝缘油、绝缘纸板进行真空干燥、脱水除气、真空浸油等预处理,并通过卡尔费休滴定仪测定其微水含量满足国家标准要求,并记

录预处理后的油中气体组分及其含量作为背景含量,后文仅以气体增量为产气分析依据。




图2 电极模型

Fig. 2 Electrode modelling

1.3 实验方法与采集方案

本实验开展油纸绝缘放电过程中产气特性探究。在正式实验前,对电极施加从0开始缓慢升高的电压,当首次出现稳定且可重复的放电信号时,记录该电压值,开展多次重复性实验取平均值作为该电极局部放电起始电压 U_{PDIV} , 根据经验设实验电压 $U_{TEV} = 1.3U_{PDIV}$ 。开展正式实验时,对电极直接施加数值为 U_{TEV} 的恒定电压,每20分钟通过取油阀提取一次油样,直至电极击穿。为了确保实验一致性,每次实验后,更换绝缘油/纸和电极模型,开展三次重复性实验。

在对绝缘油取样时,先对取样所需的100 ml 玻璃注射器清洗烘干,并采用对应绝缘油多次润洗,对于提取出的油样,依托振荡脱气法经充分振荡使油气两相建立平衡,确保气体的溶解度与油样中溶解气体的浓度一致。然后采用安捷伦 GC 7890A 气相色谱仪测定绝缘油中特征气体浓度。该仪器的最低检出限是 $0.05 \mu\text{L/L}$,能够检测多种气体成分,适用于长期监测和故障诊断。并利用奥斯特瓦尔德系数换算为油中溶解气体的浓度。为了保证结论的有效性,缺陷样品在故障模拟实验结束后,更换绝缘油和绝缘纸板,进行5组重复性实验,各个特征参量取其平均值进行分析。上述全部操作均严格依照电力标准 DL/T 722—2014 开展。

2 实验结果分析

2.1 溶解气体产生情况分析

通过测试, U_{PDIV} 为 31.45 kV,因此 U_{TEV} 为 41 kV,实验一共持续 146 分钟,共开展 7 次取油,经气相

分析,油中溶解气体主要包括 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 、 CO 、 CO_2 ,由于 CO_2 来源广,干扰因素多,因此后文不针对 CO_2 开展分析。放电过程中,油中各溶解气体浓度随放电时间的变化情况如图3所示。由图可知,随着放电的进行,各类气体的浓度均不断增加,各类气体增量与总产气能量之间均呈现非负相关。前80分钟气体浓度增长缓慢,主要由于放电初期能量积累不足、油分解的阈值效应以及化学反应初期动力学限制,导致气体生成速率较低;而在80分钟后,伴随着持久放电导致的温升和放电强度增加,油分子裂解反应显著加剧进入高温高能状态,气体浓度迅速上升。 H_2 作为裂解的初级产物,其生成能势较低因此在后期迅速累积; C_2H_2 作为高能放电的标志产物,在放电后期因满足高能裂解条件而大量生成。此外, CH_4 对放电强度依赖性较小且相对稳定, C_2H_4 和 C_2H_6 作为中间产物,在后期进一步裂解为其他小分子气体,因此这几类溶解气体的生成量均较少; CO 在整个放电过程中含量均较低,是因为绝缘纸板受放电影响区域小,纤维素分解程度低。




图3 油中溶解气体浓度

Fig. 3 Dissolved gas concentration in oil

为了更直观地展现放电过程中各类油中溶解气体的生成情况和占比,绘制了油中溶解气体占比统计图如图4所示。图4的上半部分展示了溶解气体总量的变化趋势以及各类气体相比于全部气体的相对百分含量的变化趋势,下半部分以柱状图的形式展现了各类气体占比。可知,随着放电的进行,溶解气体总量呈现单调递增的趋势, C_2H_4 等高能气体的相对百分含量与放电强度呈现正相关,而 CO 、 C_2H_6 、 CH_4 等低能量气体的相对百分含量与放电强度呈现负相关,这是因为 CO 只能由绝缘纸板的纤

纤维素分解产生,其生成量较低,而 C_2H_6 、 CH_4 在强电场作用下进一步分解和重组生成其他小分子产物和自由基,其在所有气体中的相对百分含量有所降低。




图 4 溶解气体占比统计图

Fig. 4 Statistical chart of dissolved gas proportion

2.2 溶解气体产量与产气能量关联关系分析

变压器油的裂解伴随着复杂的链式反应,而任何平衡反应式均具有定量的化学反应焓变,因此油中溶解气体的定量生成也会伴随着特定的能量变化。在放电过程中,放电能量作用于绝缘油和绝缘纸板使其分子断裂并化合重组生成小分子气体产物。为了便于构建模型和分析,本文假定放电过程中释放出的放电能量全部作用于绝缘油和绝缘纸板导致特征气体生成;采集油样体积远小于实验罐体全部油样体积,每次取油后假设罐体中油量几乎不变;且假设在提取油样时气体生成物与其他产物处于平衡状态,气体不存在逸散。

通过查询手册得到特征气体标准状况下裂解生成所需能量如表 1 所示,其数值反映了各特征气体生成时在化学反应中的能量需求。本文定义产气能量为生成所有特征气体的所需能量总和。

综上,结合表 1 和油中溶解气体浓度,可以求得产气能量 Q_{gas} 为

$$Q_{\text{gas}} = \frac{\sum_{i=1}^6 H_i \Delta c_i}{24\ 500} \quad (1)$$

式中: H_i 是特征气体换算到 25 °C 时的裂解生成所

需能量; Δc_i 是特征气体的浓度; 24 500 为 25 °C 时的气体摩尔体积。

表 1 不同特征气体生成所需能量

Table 1 Energy required for generation of different characteristic gases

特征气体	三态	标准状况下/ (kJ/mol)	换算至 25 °C 时的状 况下/(kJ/mol)
H_2	气态	128.5	117.7
CH_4	气态	77.7	71.2
C_2H_6	气态	93.5	85.7
C_2H_4	气态	104.1	95.3
CO	气态	101.4	92.9
C_2H_2	气态	278.3	255.0

3 考虑 PINN 的油中溶解气体预测模型

3.1 物理信息神经网络基本思想

JO J 等^[27] 在已有人工神经网络的基础上进一步扩展,提出新的深度学习算法框架,期望借助 PINN 将深度学习算法更好地应用于传统数学物理和工程领域的建模和计算。PINN 的核心思想是利用神经网络的拟合能力,同时通过物理信息(如偏微分方程、守恒定律或实验约束)增强模型的物理一致性和泛化性。这一方法在传统数据驱动的机器学习框架中加入了物理约束项,避免了单纯依赖实验数据造成的过拟合问题,提升了对未见数据的预测精度,训练所得的神经网络不仅能逼近观测数据,且能够自动满足偏微分方法所遵循的对称性、不变性、守恒性、单调性等物理性质^[28]。

PINN 按照结构可以分为神经网络部分和物理约束部分。物理约束部分是指利用特定物理规律和规则作为附加约束条件,嵌入到网络训练的损失函数中。

通常,基于 PINN 的损失函数由数据驱动损失 L_{data} 、物理约束损失 L_{physics} 和边界条件损失 L_{boundary} 中的若干项进行加权叠加而得。因此, PINN 的损失函数为

$$L_{\text{Loss}} = \alpha_1 L_{\text{data}} + \alpha_2 L_{\text{physics}} + \alpha_3 L_{\text{boundary}} \quad (2)$$

式中 α_1 、 α_2 、 α_3 为权重系数,用于平衡数据拟合和物理约束的作用。

3.2 物理信息约束条件分析

PINN 的核心是将物理约束加入到损失函数中,

确保模型的输出符合一定的物理规律。本文所述物理约束条件包括能量守恒方程、单调性关系等,方程提出的依据包括物理定律、第2章实验现象规律和前提假设。

具体地,实验室开展放电实验的过程中,产气能量是一个累计量,即从初始时刻 t_0 到当前时刻 t 的所有产气能量之和。对于每个时间间隔 $[t, t + \Delta t]$,有以下关系:

$$\Delta Q_{\text{gas}}^{\text{total}}(t + \Delta t) = \Delta Q_{\text{gas}}^{\text{total}}(t) + \Delta Q_{\text{gas}}^{\text{pred}}(t + \Delta t) \quad (3)$$

式中: $\Delta Q_{\text{gas}}^{\text{total}}(t)$ 表示当前时刻的累计产气能量; $\Delta Q_{\text{gas}}^{\text{pred}}(t + \Delta t)$ 表示预测的下一时刻新增产气能量。

下一时刻新增产气能量 $\Delta Q_{\text{gas}}^{\text{pred}}(t + \Delta t)$ 可以通过预测的产气量 $c_i^{\text{pred}}(t + \Delta t)$ 计算得到,即

$$\Delta Q_{\text{gas}}^{\text{pred}}(t + \Delta t) = \sum_{i=1}^n [c_i^{\text{pred}}(t + \Delta t) - c_i(t)] \Delta H_i \quad (4)$$

联立式(3)和式(4),得到能量守恒公式为

$$\Delta Q_{\text{gas}}^{\text{total}}(t + \Delta t) = \Delta Q_{\text{gas}}^{\text{total}}(t) + \sum_{i=1}^n [c_i^{\text{pred}}(t + \Delta t) - c_i(t)] \Delta H_i \quad (5)$$

此外,基于2.1节分析和2.2节假设,可以认为,各类溶解气体浓度 c_i 随产气能量的增加而非负增长,即在增量上存在不等式:

$$\frac{\partial c_i}{\partial Q_{\text{gas}}} \geq 0 \quad (6)$$

此外,由实验规律可知,所有溶解气体的预测浓度 $c_i^{\text{pred}}(t)$ 都为非负数;且随着裂解反应的进行, C_2H_6 会进一步裂解成更小的烃类,其在所有溶解气体中的相对百分比会随着产气能量的增加逐渐降低,存在非正相关关系,即存在:

$$\left. \begin{aligned} c_i^{\text{pred}}(t) &\geq 0, \forall i, \forall t; \\ \frac{\partial}{\partial Q_{\text{gas}}} \left[\frac{c_i(t)}{\sum_k c_k(t)} \right] &\leq 0, i \in \{\text{C}_2\text{H}_6\} \end{aligned} \right\} \quad (7)$$

式中 $\sum_k c_k(t)$ 表示所有溶解气体浓度的总和。

综上,模型的损失函数可由多个部分组成。

其中,由数据拟合产生的误差损失项为

$$L_{\text{data}} = \sum_{i=1}^6 \sum_{j=1}^T [c_i^{\text{pred}}(t_j) - c_i^{\text{exp}}(t_j)]^2 \quad (8)$$

式中: $c_i^{\text{pred}}(t_j)$ 为模型预测的气体 i 在时间 t_j 的浓度; $c_i^{\text{exp}}(t_j)$ 为实验测得的气体 i 在时间 t_j 的浓度。

由能量守恒定律产生的物理约束损失项为

$$L_{\text{physics}} = \left\| \sum_{j=1}^T [\Delta Q_{\text{gas}}^{\text{total}}(t_j + \Delta t) - \Delta Q_{\text{gas}}^{\text{total,pred}}(t_j + \Delta t)] \right\|^2 \quad (9)$$

式中: $\Delta Q_{\text{gas}}^{\text{total}}(t_j + \Delta t)$ 为通过式(3)计算得到的下一时刻产气能量; $\Delta Q_{\text{gas}}^{\text{total,pred}}(t_j + \Delta t)$ 为预测得到的下一时刻产气能量。

此外,由惩罚非单调行为而构成的损失项为:

$$\left. \begin{aligned} L_{\text{increasing}} &= \sum_{i=1}^6 \sum_{j=1}^T \max \left[0, -\frac{\partial c_i^{\text{pred}}}{\partial Q_{\text{gas}}}(t_j) \right]; \\ L_{\text{non-negative}} &= \sum_{i=1}^6 \sum_{j=1}^T \max \left[0, -c_i^{\text{pred}}(t_j) \right]^2; \\ L_{\text{relative-trend}} &= \sum_{i \in \{\text{C}_2\text{H}_6\}} \sum_{j=1}^T \max \left\{ 0, \frac{\partial}{\partial Q_{\text{gas}}} \left[\frac{c_i^{\text{pred}}(t_j)}{\sum_k c_k^{\text{pred}}(t_j)} \right] \right\}^2; \\ L_{\text{monotonicity}} &= L_{\text{increasing}} + L_{\text{non-negative}} + L_{\text{relative-trend}} \end{aligned} \right\} \quad (10)$$

式中 $L_{\text{increasing}}$ 、 $L_{\text{non-negative}}$ 、 $L_{\text{relative-trend}}$ 分别是基于式(6)和式(7)构建的惩罚函数。

综上,将各部分损失项加权求和,得到最终的损失函数为

$$L_{\text{loss}} = L_{\text{data}} + \alpha L_{\text{physics}} + \beta L_{\text{monotonicity}} \quad (11)$$

式中 α 、 β 为权重系数。

3.3 考虑 PINN 的预测模型构建方法

结合上文理论分析,可构建出基于 PINN 的 DGA 产气预测模型,模型的通用基本结构示意图如图5所示。

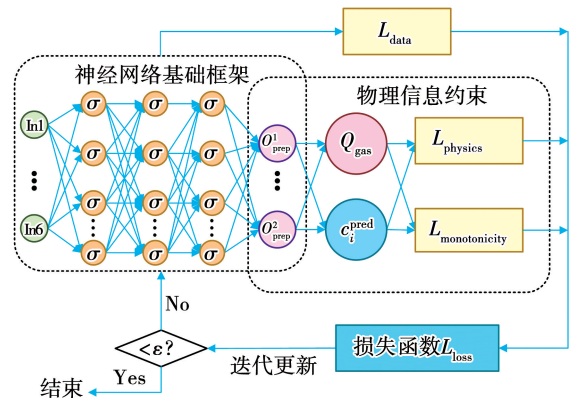


图5 考虑 PINN 的油中溶解气体预测模型结构示意图
Fig. 5 Structure diagram of dissolved gas prediction model in oil considering PINN

在本文示例中,神经网络选择 LSTM。具体地,模型的输入层维度是 6 维,分别包括当前油中溶解

气体浓度 $\{c_1(t), c_2(t), \dots, c_6(t)\}$; 输出层维度是 7 维, 即 6 种油中溶解气体的浓度和产气能量的预测值 $\{c_1(t + \Delta t), c_2(t + \Delta t), \dots, c_6(t + \Delta t), Q_{\text{gas}}(t + \Delta t)\}$ 。

此外, 激活函数选择 ReLU 函数; 设置 Dropout = 0.1, 以防止出现过拟合情况; Batch Size 取 32; 采用“遗传优化算法 + 交叉验证”探究迭代轮次 (Epochs)、学习率 (Learning Rate)、LSTM 层数等超参数的最优数值; 采用 Kaiming 初始化方法对模型参数进行初始设置; 采用 Adam 优化器对模型参数进行梯度下降、动态更新; 训练集占数据总量比值为 75%; 受文献[29]启发, 作者将损失函数权重系数 α, β 同样作为模型的“可训练参数”, 被包含在优化器中进行联合学习和动态调整, 其调整过程完全自适应, 以提升模型在不同物理约束配置下的适应能力, 减少了人工调参的主观干扰。

综上, PINN-LSTM 预测模型的主要工作流程包括以下几个步骤:

1) 输入训练数据, 初始化网络参数, 确保梯度传播的稳定性。

2) 基于 PINN 物理约束定义网络损失函数。

3) 开始迭代, 通过神经网络逼近函数, 利用“遗传优化算法 + 交叉验证”探究最优超参数, 并利用 Adam 优化器来优化模型内部参数和损失函数权重系数 α, β , 迭代结束后进行评估。

本节所述神经网络预测模型均基于 Pytorch 1.8.1 + cpu 框架搭建, 语言版本为 Python 3.9, 模型训练和测试平台为 Intel i9 - 12900 (3.19 GHz), 运行内存为 256 GB。

3.4 实例验证与对比评价

本文开展多次重复性试验, 共获得 500 组实验数据, 其中随机选取训练集 375 组, 测试集 125 组。模型的最优参数为: 学习率为 $5e - 3$, 迭代轮次为 50, LSTM 层数为 4, 损失函数权重系数 α, β 分别取为 0.121 6 和 0.039 8。

使用前文所述方法和模型开展气体预测, 并定义决定系数 E_{R^2} 、均方根误差 E_{RMSE} 、平均绝对百分比误差 E_{MAPE} 、模型参数量、推理时间、模型计算量、训练时间、模型文件大小等指标对预测效果进行评价, 部分评价指标的计算公式为:

$$E_{R^2} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}; \quad (12)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}; \quad (13)$$

$$E_{\text{MAPE}} = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\hat{y}_i} \times 100\%。 \quad (14)$$

式中: n 为样本总个数; y_i 为样本真实值; \hat{y}_i 为样本预测值; \bar{y} 为样本真实值平均值。

由于篇幅有限, 本文仅以 H_2 的预测结果为例进行详细分析。为了进一步验证 PINN 的优势, 将本文所述方法与下述 3 种方法进行对比。

1) LSTM 法: 在本文使用方法的基础上, 不考虑式(8)、式(9)、式(10)对损失函数的约束, 对同样的数据集开展建模和预测。

2) BiLSTM 法: 不考虑式(8)、式(9)、式(10)对损失函数的约束, 使用双向长短期记忆网络 (bi-directional long short-term memory, BiLSTM) 预测模型, 对同样的数据集开展建模和预测。

3) BPNN 法: 不考虑式(8)、式(9)、式(10)对损失函数的约束, 使用反向传播人工神经网络 (back propagation neural network, BPNN) 预测模型, 对同样的数据集开展建模和预测。

图 6 对比了不同模型在油中溶解气体浓度预测任务中的表现。由图 6(a) 可以看出, PINN 方法的预测结果较为精确, 几乎所有数据点均分布在 20% 偏差的置信区间内, 训练集和测试集的决定系数均处于较高值, 且测试集的表现尤为优异, 其数据在“ $y = x$ ”辅助线周围分布紧密, 证明 PINN 方法通过在损失函数中显式嵌入物理守恒约束, 使得模型能够在数据稀缺或测量噪声较大的情况下, 依然严格遵循气体演化的具体物理规律, 从而保证预测稳定性与合理性, 降低了模型对高质量数据、高数量数据的依靠。此外, 通过图 6(b) 和图 6(c) 可以看出, 未考虑 PINN 的时序预测模型, 其预测效果明显不及本文所述方法, 在部分区间内存在较大的预测偏差, 且测试集的预测结果相对于“ $y = x$ ”辅助线较为分散。造成这一差异的主要原因在于: 未考虑物理约束的传统时序预测模型主要依赖数据驱动的模式进行学习, 难以捕捉油中溶解气体的内在物理机制, 最终导致其预测结果在数据分布外推时易产生较大偏差, 泛化能力较弱; 由于 BP 神经网络无法捕捉数据间的时序关系, 因此在图 6(d) 中, 无论是训练集还是测试集, 其预测效果均较差。由此可以表明, 当数据规模较小时, 只依靠数据驱动的传统无法有效实现油中溶解气体高质量预测。

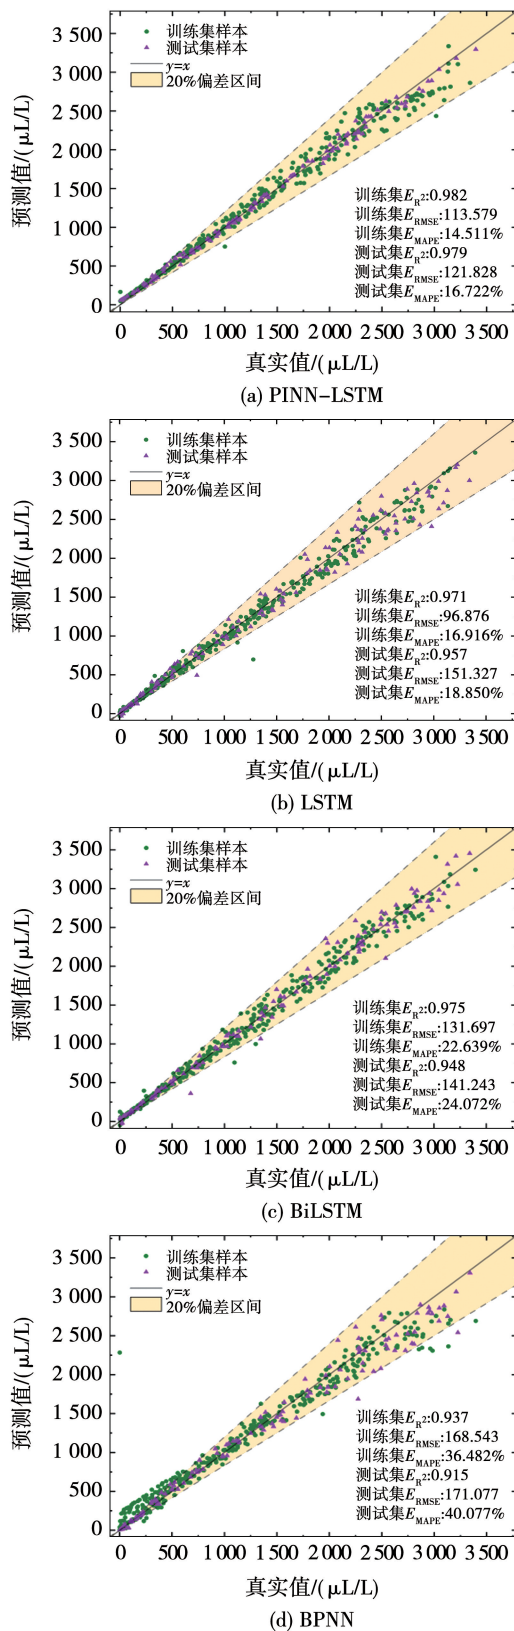


图6 不同方法预测结果

Fig. 6 Prediction results of different methods

图7以折线图的形式展现了测试集上的预测效果和误差绝对值曲线。由图7(a)可知,虽然测试集

只有125组数据样本,但本文所述方法的预测值曲线与真实值曲线仍然可以保持较高的吻合度,整体变化趋势保持一致,且浮动较小,误差绝对值始终维持在较低水平,表明训练集对模型训练之后,模型并未出现严重的过拟合和欠拟合现象。而由图7(b)和图7(c)可知,部分时刻的预测情况出现了不同程度的偏差,相比于单向LSTM, BiLSTM在一定程度上提升了预测精度,其预测曲线比LSTM更加平滑,误差曲线的整体波动较小;然而与PINN-LSTM相比,预测精度仍然存在一定差距,尤其在数据突变区间具有较大程度的偏差。造成此差异的本质原因是传统基于机器学习的时序预测模型仅依赖数据驱动机理进行推理,在数据分布外推时的稳定性较差,尤其在数据不足时难以保证物理一致性和高精度预测。此外,图7(d)所示曲线的误差在序列中呈现出较大波动,表明BPNN对数据的时间依赖关系建模能力不足,难以捕捉数据间的动态变化,因而局部区域偏差较大,模型陷入了过拟合。

本文采用部分依赖图展示了单一特征对机器学习模型预测结果的边际效应。图8为放电能量与产气量单调性关系部分依赖图,即放电能量逐步增加的过程中,各类溶解气体浓度的变化趋势。

由图8(a)可以看出,本文所用方法严格地保持了气体浓度与放电能量的单调递增关系,表明PINN方法通过在优化过程中施加显式单调性约束,可以自适应地调整预测趋势以符合气体浓度随能量增加的真实物理规律,显著提高了预测结果的合理性和物理一致性。由图8(b)和图8(c)可以看出,对于未考虑物理约束的LSTM和BiLSTM模型,其特征气体预测曲线在部分区间内出现了不同程度的突变,气体浓度在放电能量增加时出现异常下降或增幅不稳定的现象,虽然保证了放电能量数值不变,但部分特征气体含量突增,其余特征气体含量突减,表明模型并未严格遵守单调性关系,无法真实反映特征气体真实的生成趋势和物理规律。而在图8(d)中,BPNN仅依靠数据分布模型进行推理,完全与特征气体生成规律相悖,甚至在总能量较低的区间内,部分特征气体的含量预测数值出现了负数。综上,再次证明PINN在数据总量较小情况下的优势所在,通过嵌入先验确定的物理规律,大幅提高了模型的

可解释性、稳定性和泛化性。

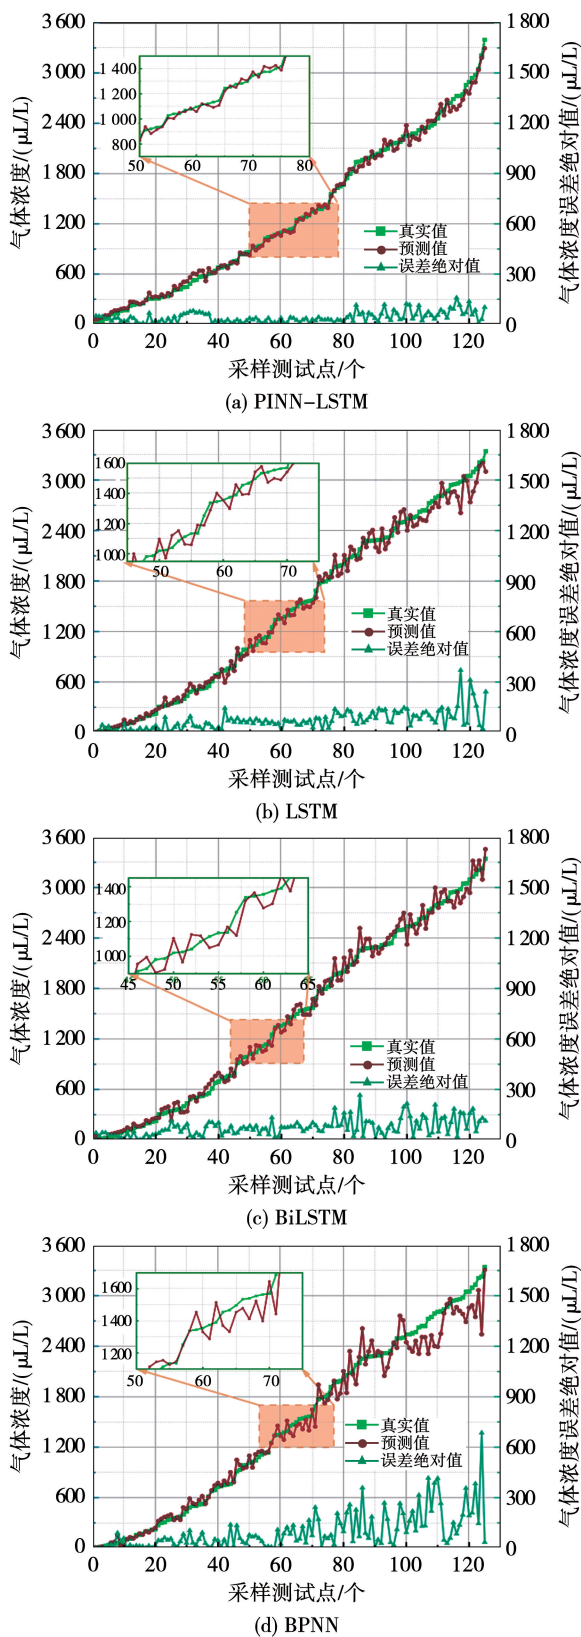


图 7 不同预测方法对气体浓度演化趋势对比图

Fig. 7 Comparison plot of gas concentration evolution trend by different prediction methods




图 8 放电能量与产气量单调性关系部分依赖图

Fig. 8 Partial dependence plot of monotonicity relationship between discharge energy and gas production

为了突出 PINN 方法对小规模数据的学习能力,对比各方法的优化效率与模型稳定性,图9展示了不同模型在对同一训练集的训练过程中,误差(Error)随迭代轮次(Iteration)的收敛情况。可以看出,本文提出方法在训练初期能够以更快的速率降低误差,并在较少的迭代轮次内迅速收敛至稳定状态,其他对比方法的误差收敛速率较慢,且部分方法在训练后期存在明显波动,表明其在小样本环境下难以稳定优化,甚至陷入局部最优和过拟合陷阱。通过对比可以验证,相较于单一依靠数据驱动的机器学习模型, PINN 通过在损失函数中引入物理约束,使得模型能够在数据规模相对较小的情况下仍能有效减少搜索空间,加速参数优化,并保持高效学习和较稳定收敛。




图9 不同模型迭代过程中误差变化对比
Fig. 9 Comparison of error changes in iteration process of different models

图10所示的雷达图则更加直观地展示了4种方法在算力方面的指标对比。可以看出,在迭代轮次相同的情况下, PINN 方法在训练时间、模型大小、参数规模等维度相较对比模型有所增加,但在工程实践中,常依托高性能计算平台,利用大规模历史样本完成模型参数学习与结构优化,并将训练完成的模型固化后部署于在线监测系统中,用以对实时

采集的数据进行快速决策与状态识别,即“离线训练+在线推理”模式,因此实际开展在线监测时会更关注推理时间。而本文所述方法的推理时间最短,这与图9所示的高效率学习也是对应的。




图10 4种不同模型的性能指标对比雷达图
Fig. 10 Radar chart of performance index comparison of four different models

此外,表2列举了不同方法对其余5种特征气体进行预测时的决定系数 E_{R^2} 、均方根误差 E_{RMSE} 、平均绝对百分比误差 E_{MAPE} 。可以看出,本文提出方法在多个维度上表现卓越。具体而言,在决定系数方面, PINN 方法相较于传统机器学习模型更贴近真实值,反映出其较强的数据拟合能力和对潜在物理规律的有效刻画;在均方根误差和平均绝对百分比误差方面, PINN 方法的误差控制能力优于其他方法,表明其不仅能够精准学习数据特征,同时能够在较宽泛的数据分布范围内保持高鲁棒性。需要指出的是,本文所述方法在整体上具有更好的预测效果,但仍有某些特征气体评价指标的表现效果和对比方法差距不大,这可能是因为该特征气体本身浓度偏低、波动幅度有限,导致模型预测中微小偏差在相对指标上被放大,也有可能是由于 PINN 中物理约束项的引入,导致模型在物理一致性优先优化下,牺牲了部分低权重气体的数值拟合精度。

表2 其余特征气体预测评价指标对比

Table 2 Comparison of evaluation indexes for prediction results of other characteristic gases

预测模型	CH ₄			C ₂ H ₆			C ₂ H ₄			C ₂ H ₂			CO		
	E_{R^2}	E_{RMSE}	$E_{MAPE}/\%$	E_{R^2}	E_{RMSE}	$E_{MAPE}/\%$	E_{R^2}	E_{RMSE}	$E_{MAPE}/\%$	E_{R^2}	E_{RMSE}	$E_{MAPE}/\%$	E_{R^2}	E_{RMSE}	$E_{MAPE}/\%$
PINN-LSTM	0.95	17.22	8.89	0.94	3.09	12.15	0.93	32.06	12.12	0.92	137.26	8.81	0.92	1.71	10.45
LSTM	0.93	18.91	9.44	0.91	3.55	13.70	0.89	34.65	13.36	0.89	144.73	9.30	0.89	2.37	12.07
BiLSTM	0.87	19.41	14.08	0.88	4.34	13.32	0.90	41.63	14.41	0.88	189.31	15.69	0.85	2.95	16.86
BPNN	0.75	21.34	18.02	0.72	5.89	18.41	0.71	48.73	17.96	0.75	198.53	20.95	0.81	4.21	19.77

4 结 论

针对传统 DGA 预测方法的局限性,本文提出一种基于物理信息神经网络的变压器油中溶解气体预测方法,通过实验室搭建油纸绝缘放电实验平台,研究典型缺陷下的 DGA 产气规律,提出物理约束公式并嵌入神经网络模型,得到以下结论:

1) 与传统直接利用机器学习算法开展预测工作的方法不同, PINN 能够进一步揭示神经网络内部“黑盒”结构和数据之间的因果关系,工作流程的可解释性更强,模型具有更好的可信度和可扩展性。

2) 本文所提出的考虑 PINN 方法在数据量稀缺的情况下,仍可保证较高的预测精度,较传统机器学习模型具有更短的推理时间,同时具备更强的物理一致性和泛化能力。

3) 相较于单纯依赖数据驱动的智能方法,配备物理约束的模型整体预测结果更为稳定,误差波动更小,评价指标更优,表现出更强的鲁棒性,有助于提升电力设备的智能化运维水平,为电网的安全稳定运行提供更可靠的保障。

同时,本文研究内容尚存在一定的局限性。气体动力学方程通常基于变压器油中溶解气体的扩散、化学反应和热力学变化来建立,在数据量有限的情况下,有助于更快地训练和更稳健的收敛。然而,在实验采样时间间隔较长的情况下,可能无法捕捉气体浓度的动态变化,导致预测结果的时间分辨率较差。鉴于实验条件和模型复杂程度考虑,本文并未充分调用气体动力学方程。总体而言,本文所提出的基于 PINN 的 DGA 新型预测方法为变压器故障诊断与状态评估提供了新的研究思路和技术支撑。

参 考 文 献:

- [1] 罗智荣, 黄丰, 郭淳, 等. 基于多物理场仿真的油浸式变压器振动特性分析及影响因素研究[J]. 智慧电力, 2024, 52(11): 48.
LUO Zhirong, HUANG Feng, GUO Chun, et al. Vibration characteristics analysis and influencing factors of oil-immersed transformer based on multi-physical field simulation[J]. Power System Technology, 2024, 52(11): 48.
- [2] 席英杰, 张崇兴, 董明, 等. 基于蒙特卡洛模拟的声电联合局部放电定位阵列设计及快速定位方法研究[J]. 电网技术, 2023, 47(7): 3029.
XI Yingjie, ZHANG Chongxing, DONG Ming, et al. Acoustic-electric joint sensor array design and fast partial discharge localization technology based on monte carlo simulation[J]. Power System Technology, 2023, 47(7): 3029.
- [3] 江军, 张文乾, 李波, 等. 电力变压器油中溶解气体离群值识别和数据重构[J]. 电工技术学报, 2024, 39(17): 5521.
JIANG Jun, ZHANG Wenqian, LI Bo, et al. Outlier detection and data reconstruction of dissolved gas in oil for power transformers[J]. Transactions of China Electrotechnical Society, 2024, 39(17): 5521.
- [4] ZHU R, ANDRESEN M, LANGWASSER M, et al. Smart transformer/large flexible transformer[J]. CES Transactions on Electrical Machines and Systems, 2020, 4(4): 264.
- [5] 辛保安, 李明节, 贺静波, 等. 新型电力系统安全防护体系探究[J]. 中国电机工程学报, 2023, 43(15): 5723.
XIN Baoan, LI Mingjie, HE Jingbo, et al. Research on security defense system of new power system [J]. Proceedings of the CSEE, 2023, 43(15): 5723.
- [6] 黄新波, 蒋卫涛, 朱永灿, 等. 基于时间序列和支持向量机的变压器故障预测[J]. 高电压技术, 2020, 46(7): 2533.
HUANG Xinbo, JIANG Weitao, ZHU Yongcan, et al. Transformer fault prediction based on time series and support vector machine [J]. High Voltage Engineering, 2020, 46(7): 2533.
- [7] 于达, 张玮, 王辉. 基于 LSTM 神经网络的油浸式变压器异常声纹诊断方法研究[J]. 智慧电力, 2023, 51(2): 47.
YU Da, ZHANG Wei, WANG Hui. Prediction method for power transformer running state based on LSTM network[J]. Smart Power, 2023, 51(2): 47.
- [8] 彭继慎, 夏玲云, 王毅增. 基于 CEEMD 联合 TGSCSO-LSTM 算法的变压器油中气体浓度预测方法[J]. 电气工程学报, 2024, 19(4): 409.
PENG Jishen, XIA Lingyun, WANG Yizeng. Prediction method of gas concentration in transformer oil based on CEEMD and TGSCSO-LSTM [J]. Journal of Electrical Engineering, 2024, 19(4): 409.
- [9] 邱婷婷, 曹文平, 刘孝宇, 等. 多时间尺度小波变换和 LSTM 自编码器电弧故障检测方法[J]. 电机与控制学报, 2024, 28(4): 139.
QIU Tingting, CAO Wenping, LIU Xiaoyu, et al. Multi time scale wavelet transform and LSTM autoencoder arc fault detection method [J]. Electric Machines and Control, 2024, 28(4): 139.
- [10] 杜江, 范志远, 范仲华, 等. 电力变压器油中溶解气体异常数据识别与含量预测研究[J]. 电网技术, 2025, 49(2): 846.
DU Jiang, FAN Zhiyuan, FAN Zhonghua, et al. Research on abnormal data identification and content prediction of dissolved gas in power transformer oil [J]. Power System Technology, 2025, 49(2): 846.
- [11] 杨童亮, 胡东, 唐超, 等. 基于 SMA-VMD-GRU 模型的变压器油中溶解气体含量预测[J]. 电工技术学报, 2023, 38(1): 120.
YANG Tongliang, HU Dong, TANG Chao, et al. Prediction of dissolved gas content in transformer oil based on SMA-VMD-GRU

- model[J]. Transactions of China Electrotechnical Society, 2023, 38(1): 120.
- [12] LUO D, FANG J, HE H, et al. Prediction for dissolved gas in power transformer oil based on TCN and GCN[J]. IEEE Transactions on Industry Applications, 2022, 58(6): 7818.
- [13] 倪未希, 刘宇阳, 陈俐. 散热工况下永磁同步电机转子温度的卷积神经网络预测[J]. 电机与控制学报, 2025, 29(1): 15.
NI Weixi, LIU Yuyang, CHEN Li. Rotor temperature prediction of PMSM under cooling conditions using convolutional neural network[J]. Electric Machines and Control, 2025, 29(1): 15.
- [14] ZHANG N. Research on transformer fault based on grey system theory[C]//2022 7th International Seminar on Computer Technology, Mechanical and Electrical Engineering (ISCME 2022), November 25 - 27, 2022, Hangzhou, China. 2023: 012031.
- [15] 苏磊, 陈璐, 徐鹏, 等. 基于深度信念网络的变压器运行状态分析[J]. 高压电器, 2021, 57(2): 56.
SU Lei, CHEN Lu, XU Peng, et al. Operation condition analysis of transformer based on deep belief network[J]. High Voltage Apparatus, 2021, 57(2): 56.
- [16] PERDIKARIS P, KARNIADAKS G E. Physics informed deep learning: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational Physics, 2019, 378: 686.
- [17] LU L, MENG X, MAO Z, et al. Deep XDE: A deep learning library for solving differential equations[J]. SIAM Review, 2021, 63(1): 208.
- [18] SAHLI C F, YANG Y, PERDIKARIS P, et al. Physics-informed neural networks for cardiac activation mapping[J]. Frontiers in Physics, 2020, 8: 42.
- [19] FANG Z, ZHAN J. Deep physical informed neural networks for metamaterial design[J]. IEEE Access, 2019, 8: 24506.
- [20] 彭长志, 董旭柱, 阮江军, 等. 基于物理信息神经网络的短间隙流注放电模拟[J]. 高压电器, 2023, 59(9): 90.
PENG Changzhi, DONG Xuzhu, RUAN Jiangjun, et al. Short-gap streamer discharge simulation based on physics-informed neural network[J]. High Voltage Apparatus, 2023, 59(9): 90.
- [21] 杨珂, 王鑫, 凌佳杰, 等. 基于物理信息神经网络的同步发电机建模[J]. 中国电机工程学报, 2024, 44(12): 4924.
YANG Ke, WANG Xin, LING Jiajie, et al. Modeling of synchronous generator based on physics-informed neural network[J]. Proceedings of the CSEE, 2024, 44(12): 4924.
- [22] 陈来恩, 曾小勇, 曾子豪, 等. 基于物理信息与深度神经网络的锂离子电池温度预测[J]. 中国电力, 2024, 57(11): 18.
CHEN Laien, ZENG Xiaoyong, ZENG Zihao, et al. Temperature prediction of lithium-ion batteries based on physical information and deep neural networks[J]. Electric Power, 2024, 57(11): 18.
- [23] 明巧, 刘友波, 邱高, 等. 基于物理引导神经网络的静态电压稳定预防控制策略在线计算[J]. 电网技术, 2025, 49(7): 2680.
MING Qiao, LIU Youbo, QIU Gao, et al. Online computation of static voltage stability preventive control strategy based on physics guided neural network[J]. Power System Technology, 2025, 49(7): 2680.
- [24] 张维通, 闫正兵, 张正江, 等. 基于物理信息的时间卷积神经网络风电功率预测[J]. 计算机测量与控制, 2024, 32(11): 101.
ZHANG Weitong, YAN Zhengbing, ZHANG Zhengjiang, et al. Temporal convolutional neural network for wind power prediction based on physical information[J]. Computer Measurement & Control, 2024, 32(11): 101.
- [25] FUJITA K. Physics-informed neural networks with data and equation scaling for time domain electromagnetic fields[C]//2022 Asia-Pacific Microwave Conference (APMC), November 29, 2022, Yokohama, Japan. 2022: 623 - 625.
- [26] IEC Technical Committee 15E. Electric strength of insulating materials-Test methods-Part 1: Tests at power frequencies; IEC 60243 - 1 - 2013[S]. Geneva: The International Electrotechnical Commission, 2013.
- [27] JO J, JEONG Y, KIM J, et al. Thermal conductivity estimation using physics-informed neural networks with limited data[J]. Engineering Applications of Artificial Intelligence, 2024, 137(PA): 109079.
- [28] KARNIADAKIS G E, KEVREKIDIS I G, LU L, et al. Physics-informed machine learning[J]. Nature Reviews Physics, 2021, 3(6): 422.
- [29] WANG S, TENG Y, PERDIKARIS P. Understanding and mitigating gradient flow pathologies in physics-informed neural networks[J]. SIAM Journal on Scientific Computing, 2021, 43(5): A3055.

(编辑:邱赫男)