

DOI:10.13296/j.1001-1609.hva.2026.09.019

融合多源数据与 CNN-Transformer 的变压器励磁涌流瞬态磁场预测

郜晓娜^{1,2}, 周鑫¹, 邓志强¹, 林小竺¹, 杨涵¹

(1. 贵州电网有限责任公司遵义供电局, 贵州 遵义 563000; 2. 贵州大学电气工程学院, 贵阳 550000)

摘要: 为解决变压器空载合闸时全域瞬态磁场难以现场实测、传统有限元分析计算效率低下、单一模型预测精度不足的问题,通过有限元仿真构建覆盖7组合闸角工况的560组有效样本数据集,采用随机森林完成输入特征重要性筛选,借助主成分分析将10 418维磁场数据压缩至300维,搭建CNN-Transformer混合预测模型,通过一维卷积提取励磁涌流局部瞬态特征,结合多头注意力机制捕捉全局时序依赖,实现全域瞬态磁场端到端快速重建。实验结果表明,该模型平均绝对误差低至0.004 2 T,平均绝对百分比误差为0.42%,决定系数达0.987,单样本预测耗时4.5 ms,计算效率较传统有限元方法提升超 10^5 倍,极端工况下全空间平均绝对误差为0.003 2 T,最大误差不超过0.01 T,全工况下决定系数均不低于0.982。该模型预测精度高、泛化能力强、计算效率高,可有效实现变压器励磁涌流瞬态磁场快速精准预测,为变压器状态评估与保护整定提供技术支撑。

关键词: 变压器; 励磁涌流; 瞬态磁场预测; CNN-Transformer; 主成分分析

Prediction of Transient Magnetic Field of Transformer Inrush Current Fusing Multi-source Data and CNN-Transformer

GAO Xiaona^{1,2}, ZHOU Xin¹, DENG Zhiqiang¹, LIN Xiaozhu¹, YANG Han¹

(1. Zunyi Power Supply Bureau, Guizhou Power Grid Corporation, Guizhou Zunyi 563000, China; 2. School of Electrical Engineering, Guizhou University, Guiyang 550000, China)

Abstract: To address the challenges of the difficulty in field measurement of the global transient magnetic field during no-load closing operation of transformer, the low computational efficiency of traditional finite element analysis, and the insufficient prediction accuracy of single models, a dataset comprising 560 valid samples with coverage of seven closing-angle conditions is constructed through finite element simulations. The random forest algorithm is employed to perform feature importance screening, and principal component analysis is utilized to compress the 10 418-dimensional magnetic field data to 300 dimensions. A CNN-Transformer hybrid prediction model is then established, where one-dimensional convolution is used to extract local transient features of the inrush current and the multi-head attention mechanism is adopted to capture global temporal dependencies, thereby enabling end-to-end rapid reconstruction of the global transient magnetic field. Experimental results show that the average absolute error of the model is as low as 0.004 2 T, the average absolute percentage error is 0.42%, and a coefficient of determination (R^2) of is 0.987. The prediction time per sample is 4.5 ms, which is more than 10^5 times faster than traditional finite element methods. Under extreme conditions, the global average absolute error is 0.003 2 T, with the maximum error not exceeding 0.01 T. The coefficient of determination under all operating conditions is not less than 0.982. The proposed model exhibits high prediction accuracy, strong generalization capability, and high computational efficiency.

收稿日期:2026-04-08; 修回日期:2026-06-11

基金项目:中国南方电网有限责任公司科技项目(GZKJXM20232581)。

Project Supported by Science and Technology Project of China Southern Power Grid Co., Ltd.(GZKJXM20232581).

ciency. It can effectively achieve fast and accurate prediction of the transient magnetic field during transformer inrush current, providing technical support for condition assessment and protection setting of transformer.

Key words: transformer; excitation inrush; transient magnetic field prediction; CNN - Transformer; principal component analysis

0 引言

电力变压器是输配电网中的核心关键设备,设备运行稳定性直接关系整体电网供电安全^[1-2]。变压器空载合闸过程中易产生幅值极高的励磁涌流^[3],不仅会造成电网电压暂态波动^[4]、绕组绝缘与机械结构承受冲击载荷^[5],还极易引发差动保护误动作,甚至诱发邻近运行变压器产生和应涌流^[6],进一步扩大电网扰动范围。在特高压换流站、光伏电站及海上油田电力系统等复杂运行场景下,铁心剩磁、系统阻抗、电力电子谐波等多重因素耦合^[7],使得励磁涌流的演化规律更为复杂,对其机理分析、精准辨识、特性推演提出更高要求^[8],开展相关研究具备重要的理论价值与工程现实意义。

现阶段励磁涌流抑制技术已有较多工程应用方案,谭正凯等^[9]依托选相合闸装置与断路器回路改造,通过精准控制合闸相位实现涌流峰值抑制,但方法适用场景固定,难以适配高剩磁极端工况。肖湃等^[10]将合闸电阻与选相合闸策略相结合,量化分析工况参数对换流变涌流的影响,抑制效果显著但依赖硬件改造,推广成本偏高。宋玉洁等^[11]通过动态可调电阻平滑侧端电压变化速率,从机理层面削弱磁通饱和带来的涌流效应,面对负载频繁波动的复杂电网环境,工况适配能力仍存在明显局限。

在励磁涌流智能识别研究层面,各类特征挖掘与深度学习方法得到广泛应用。王子伟等^[12]将电流信号经 GASF 变换转为图像特征,依托轻量化 AlexNet-SVM 模型实现涌流快速检测,面对强谐波干扰环境特征区分能力有所下降。栾云飞等^[13]基于直方图与余弦相似度提取电流分布特征,可适配光伏电站谐波背景,但特征维度单一,高剩磁合闸工况下识别可靠性不足。龙启等^[14]通过圆坐标表征变换构建电流轨迹样本,借助 VGG16 网络完成工况分类,模型结构繁琐不利于现场部署。韩志^[15]融合多域特征并结合随机森林算法完成识别建模,过度依赖人工特征设计,泛化能力受到制约。

针对现有研究普遍存在工况适配范围窄、人工特征主观性强,传统有限元仿真计算效率低、高维磁场数据冗余度大,单一网络模型无法兼顾涌流局部瞬态特征与全局时序演化规律等短板,依托有限

元仿真构建多组合闸角全覆盖的标准化时序数据集,采用随机森林完成输入特征重要性筛选,引入主成分分析实现高维磁场网格数据降维。搭建 CNN-Transformer 混合架构,利用一维卷积挖掘励磁涌流短时突变细节,通过多头注意力机制建模时序全局依赖关系,以端到端映射方式完成变压器全域瞬态磁场快速重建。该研究思路规避传统方法重复迭代仿真与人工特征设计的弊端,兼顾局部特征提取与长程时序建模优势,可为变压器励磁涌流机理分析、瞬态磁场快速推演及保护策略整定提供可靠技术支撑。

1 数据集构建与特征工程

1.1 基于有限元仿真的多源数据集生成

变压器空载合闸过程中产生的励磁涌流,会引发铁心深度饱和、绕组机械应力骤增、继电保护误动作等一系列工程问题,全域瞬态磁场分布的精准获取,是开展励磁涌流抑制、变压器状态评估与故障预警的核心前提^[16]。受现场测量条件限制,变压器内部全域瞬态磁场的全时序实测数据难以获取,高精度有限元仿真成为构建标准化、全工况数据集的可靠技术手段。提出的励磁涌流瞬态磁场预测方法全流程技术路线见图 1,该路线分为多源数据集构建与预处理、CNN-Transformer 混合预测模型建模、磁场重建与输出 3 个核心阶段,其中数据集构建是整个预测方法的基础环节。

单相变压器三维瞬态磁场仿真模型基于三维电磁有限元仿真平台搭建,该仿真模型为实验室小型单相变压器,额定容量 5 kVA,额定电压等级 0.4 kV/0.05 kV,铁心为叠片式三柱结构,有效截面积 12.5 cm²,绕组采用同心式圆筒结构,铁心选用宝钢 B27G120 型冷轧硅钢片,仿真模型的核心电气参数见表 1,参数设置与同类型工程研究保持一致,确保仿真模型与实际工程设备的电气特性匹配。为兼顾仿真计算精度与运算效率,对铁心、绕组等磁场变化剧烈的核心区域进行网格加密精细化剖分,在控制整体网格数量的同时,保证关键区域磁场求解的计算精度。




图1 研究方法全流程技术路线框图

Fig. 1 Block diagram of the full process of the research method

表1 单相变压器仿真模型核心电气参数

Table 1 Core electrical parameters of the single-phase transformer simulation model

序号	电气参数	数值
1	额定电压/V	50
2	电源频率/Hz	50
3	一次绕组电阻/ Ω	100
4	一次绕组匝数	300
5	二次绕组电阻/k Ω	10
6	二次绕组匝数	300
7	额定容量/kVA	5
8	电压等级/kV	0.40/0.05
9	铁心截面积/ cm^2	12.5
10	铁心结构	叠片式三柱结构
11	绕组形式	同心式圆筒绕组

励磁涌流仿真边界条件设置为变压器二次侧开路状态下的空载合闸,合闸角是决定励磁涌流幅值与波形特征的核心参数,为完整覆盖励磁涌流从最大到最小的全范围特征,仿真过程设置 0° 、 $\pi/6$ 、 $\pi/3$ 、 $\pi/2$ 、 $2\pi/3$ 、 $5\pi/6$ 、 π 共7组合闸角工况,完整覆盖励磁涌流全范围特征。仿真时长设置为0.04 s,对应50 Hz工频下的2个完整电压周期,时间步长固定为 5×10^{-4} s,完整捕捉合闸后励磁涌流从产生到衰减的

瞬态演化全过程,不同合闸角对应的一次绕组励磁涌流波形见图2。从波形特征可看出,合闸角为 0° 和 π 时励磁涌流幅值达到极值,合闸角为 $\pi/2$ 时涌流幅值最小,符合变压器空载合闸励磁涌流的经典物理规律,验证了仿真工况设置的合理性与有效性。




图2 不同合闸角下一次绕组励磁涌流波形图

Fig. 2 Waveform diagram of primary winding inrush current under different closing angles

单组时间步的仿真数据同步输出两类参数,一类为4维输入特征,包含对应时刻的一次绕组电流、一次绕组感应电压、二次绕组感应电压、合闸角;另一类为10 418维输出标签,对应变压器模型全域10 418个网格节点的磁通密度向量,与仿真模型的网格剖分结果完全对应。7组合闸角工况各包含80个时间步的有效数据,最终形成560组有效样本,数据集完整覆盖励磁涌流全工况特征,可为预测模型的训练与验证提供完备、高保真的数据支撑。

1.2 基于随机森林的输入特征重要性分析

输入特征与输出磁场分布间关联程度的量化,是提升预测模型精度与可解释性的核心环节,随机森林(random forest, RF)算法可通过决策树分裂过程中的信息增益变化,完成对输入特征重要性的稳定量化排序。RF由多棵独立的分类回归树集成构建,单棵决策树的节点分裂过程中,特征重要性通过节点分裂前后的基尼不纯度变化量进行量化,基尼不纯度的计算公式为

$$Gini = 1 - \sum_{k=1}^K p_k^2 \quad (1)$$

式(1)中, p_k 为节点内第 k 类样本的占比,针对回归任务,该指标对应节点内样本的方差变化量。RF^[17]最终输出的特征重要性,为所有决策树中该特征重要性的平均值,可有效规避单棵决策树的过拟合偏差,实现对多维度输入特征贡献度的客观量化。

针对数据集内4维输入特征,采用RF回归模型完成重要性排序,排序结果见表2。

表2 输入特征重要性排序表

Table 2 Ranking of input feature importance

序号	特征	重要性
1	一次绕组感应电压	9.40×10^{-3}
2	二次绕组感应电压	9.20×10^{-3}
3	一次绕组电流	9.74×10^{-1}
4	合闸角	7.50×10^{-3}

从表2数据可看出,一次绕组电流的特征重要性达到 9.74×10^{-1} ,在所有输入特征中占绝对主导地位,其余3项特征的重要性均处于 10^{-3} 量级,对磁场分布的影响程度相对有限。这一结果与励磁涌流的物理机理相当契合,铁心内部磁场强度与绕组电流直接相关,空载合闸过程中一次绕组电流的瞬态变化,是决定变压器内部磁场分布演化的核心物理量。该量化结果为预测模型的输入特征设计提供了数据驱动依据,模型训练过程中可通过对核心特征的权重优化,进一步提升模型的收敛速度与预测精度,同时也为变压器励磁涌流状态的现场监测提供了核心参量选取的参考。

1.3 基于主成分分析的高维磁场数据压缩

变压器全域瞬态磁场仿真数据的输出维度高达10 418维,对应模型中所有三维网格节点的磁通密度向量,直接将该高维向量作为预测模型的输出,会引发两方面的建模瓶颈。一方面,高维输出会大幅增加模型的参数量与计算复杂度,导致训练收敛速度慢、显存占用过高,难以在常规计算资源下完成高效训练;另一方面,高维数据中存在大量冗余信息,相邻网格节点的磁场分布具有强空间相关性,直接训练易使模型学习到噪声特征,反而降低预测精度与泛化能力。因此,采用数据降维方法在保留核心信息的前提下压缩输出维度,是提升预测模型性能的关键环节。

主成分分析(principal component analysis, PCA)^[18]是一种常用的线性降维方法,其核心思想是通过正交变换将高维相关变量映射为低维无关的主成分,同时保留原始数据中方差最大的信息。其实现流程为:先对原始数据进行去中心化处理,再计算协方差矩阵

$$\Sigma = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^T \quad (2)$$

式(2)中: x_i 为第*i*个样本; $\bar{x}$ 为样本均值。随后求解协方差矩阵的特征值与特征向量,按特征值降序排列后,选取前*K*个特征向量构建投影矩阵,将原始数据投影至低维空间,完成降维。

针对该10 418维磁场输出数据,选取前300个

主成分进行降维,经计算,前300个主成分的累积方差贡献率达到99.92%,能够完整保留原始磁场数据的核心空间分布特征。为验证主成分数量选择的合理性,对比了100、200、300、400维主成分的重建误差,结果显示300维时平均绝对误差为 1.2×10^{-5} T,继续增加维度对精度提升小于0.1%,综合考虑计算效率与预测精度,选取300维作为最优降维维度,输出维度从10 418维压缩至300维,压缩比约为34.7:1,大幅降低了数据维度。为验证降维方案的有效性,对低维数据进行逆PCA变换,重建得到原始高维空间的磁场分布,并与仿真真值对比。逆PCA重建利用降维时保留的特征向量与均值,将低维数据反向投影回原始空间。原始磁场与PCA重建磁场的三维空间分布对比见图3。PCA降维通过保留方差贡献率最高的主成分,完整捕获磁场核心分布特征,且变压器磁场相邻网格具有强空间相关性,降维仅剔除冗余噪声分量,未损失核心物理特征,因此可将重建误差控制在极低量级。图3(a)为仿真真值的三维磁场分布,铁心左右柱区域磁场强度最高,向边缘区域逐渐衰减,与变压器内部磁场分布的物理规律相符;图3(b)为PCA重建的磁场分布,其空间分布特征与仿真真值高度吻合,无明显失真;图3(c)为重建误差分布,误差量级仅为 10^{-5} T,绝大多数网格节点的误差接近零,仅不足3%的网格节点存在微小偏差,信息损失率低于0.08%,满足预测模型的精度要求。

2 CNN-Transformer混合预测模型构建与训练

2.1 模型整体架构设计

励磁涌流是强时变、非平稳的瞬态过程,其局部波动特征与全局演化规律共同决定变压器内部磁场分布,传统时序建模方法难以同时兼顾两类特征的有效提取,端到端混合预测架构可实现从电气量输入到全域磁场输出的直接映射。针对励磁涌流的瞬态特性,构建“局部特征提取—全局依赖建模—磁场重建”的3阶段预测架构,无需人工特征工程,直接完成四维电气时序特征到三维磁场分布的端到端映射。

局部特征提取环节,输入为[Batch, Seq=1, Features=4]的四维电气特征,包含一次绕组电流、一次绕组感应电压、二次绕组感应电压、合闸角,先通过全连接层完成维度映射,以Linear(4→64)的线性变换配合ReLU激活函数,将输入特征映射至64维隐空间,输出维度为[B, 1, 64]。映射后的特征接入两层一维卷积模块,两层卷积核尺寸均为3,第一层




图3 原始磁场与PCA重建磁场空间分布对比图

Fig. 3 Spatial distribution comparison of original magnetic field and PCA reconstructed magnetic field

完成64→128的通道升维,第二层完成128→256的通道升维,均采用ReLU激活函数,利用卷积核的局部感受野捕捉励磁涌流的短时波动特征,如电流峰值、上升沿变化等关键局部信息,最终输出 $[B, 1, 256]$ 的特征序列,为后续全局建模提供细粒度特征支撑。

局部特征输出后,接入4头自注意力Transformer

编码器^[19],编码器采用预归一化结构,特征先经LayerNorm层归一化后输入多头注意力模块,经残差连接与第二层LayerNorm归一化后接入前馈网络,最终输出维度保持为 $[B, 1, 256]$ 的全局特征。该模块通过4头注意力机制捕捉励磁涌流过程中不同特征维度的长程依赖关系,如合闸初期涌流峰值与后续衰减过程的关联、不同合闸角下的共性演化规律,适配励磁涌流多变量耦合的复杂演化特性,提升全局建模的鲁棒性。

输出与磁场重建环节,Transformer输出的全局特征先经全局平均池化与展平操作,将 $[B, 1, 256]$ 的特征序列压缩为 $[B, 256]$ 的一维特征向量,再通过全连接层完成256→300的维度映射,配合ReLU激活函数输出300维主成分系数,与降维阶段保留的PCA特征向量结合,经逆PCA变换重建出10418维的全域磁通密度向量,完成从低维隐特征到三维磁场分布的完整映射,该环节与数据预处理阶段的降维流程形成闭环,确保预测输出与仿真数据的维度与分布保持一致。上述卷积通道数、注意力头数、初始学习率等核心超参数均通过网格搜索结合5折交叉验证确定,以验证集预测误差最小化为寻优目标,保障模型超参数配置的合理性与最优性。

模型完整的端到端预测链路与内部层级结构见图4,图4(a)呈现了从4维输入特征到10418维磁场输出的完整数据流向,明确了3个核心模块的输入输出维度与衔接关系;图4(b)标注了各层级的线性变换维度、卷积核尺寸、通道数、注意力头数等核心设计参数,完整呈现了网络内部的维度变换逻辑与模块组成。

2.2 模型核心模块原理与实现

一维CNN局部特征提取模块^[20]的核心是通过一维卷积运算完成时序特征的层级化提取,第 l 层卷积层的输出特征计算式为

$$x_i^l = \text{ReLU} \left(\sum_{k=1}^K w_k^l * x_{i+k-1}^{l-1} + b^l \right) \quad (3)$$

式(3)中: w_k^l 为第 l 层卷积核的第 k 个权重; K 为卷积核尺寸(此处固定为3); b^l 为偏置项;*为一维卷积运算。模块采用两层卷积结构完成64→128→256的通道升维,激活函数选用ReLU函数,表达式为 $\text{ReLU}(x) = \max(0, x)$,可有效缓解梯度消失问题,同时增强网络对非线性特征的拟合能力,精准捕捉励磁涌流的短时波动特征。

Transformer编码器模块基于多头自注意力机制构建,自注意力的核心计算式为




图4 CNN-Transformer 混合模型整体架构图

Fig. 4 Overall architecture diagram of CNN-Transformer hybrid model

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (4)$$

式(4)中: Q 、 K 、 V 分别为查询、键、值矩阵; d_k 为键矩阵的维度。4个独立的注意力头将特征空间拆分为多个子空间并行计算,最终拼接各头输出完成全局特征融合,模块采用预归一化与残差连接设计,可有效捕捉励磁涌流非相邻时刻的特征关联,适配其强时变的演化特性。

逆PCA磁场重建模块与降维过程形成完整闭环,磁场重建计算式为

$$\hat{X} = Y \cdot W^T + \mu \quad (5)$$

式(5)中: Y 为网络输出的300维主成分系数; W 为降维阶段保留的前300维特征向量矩阵; μ 为原始数据的均值向量; $\hat{X}$ 为重建的10 418维全域磁场向量,可将维度变换的信息损失控制在可忽略范围内。

2.3 模型训练环境与参数设置

模型基于PyTorch深度学习框架搭建,训练平

台配置为NVIDIA RTX 3080 GPU,配合CUDA加速库完成并行计算,CPU采用3.60 GHz主频的多核处理器,内存配置为32 GB,可满足时序样本的批量加载与模型迭代训练需求,相比传统CPU训练平台,单轮训练耗时可压缩至秒级,大幅提升模型调优效率。

核心训练参数方面,优化器选用Adam自适应优化器,初始学习率设置为 1.2×10^{-3} ,采用分步衰减策略,每600轮训练后学习率衰减为原数值的30%,逐步降低学习率以适配模型训练后期的收敛需求。损失函数选用平均绝对误差 e_{MAE} (mean absolute error),表达式为

$$e_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |f(x_i) - y_i| \quad (6)$$

式(6)中: $f(x_i)$ 为模型预测的主成分系数; y_i 为PCA降维得到的真实主成分系数; n 为单组样本的特征维度。 $Batch Size$ 设置为64,最大训练轮次设置为2 000轮,同时引入早停正则化策略,监控验证集损失变化,若连续200轮验证集损失下降幅度小于 1×10^{-6} ,则提前终止训练,避免模型过拟合。

560组有效样本按7:2:1的固定比例划分为训练集、验证集、测试集,其中训练集392组、验证集112组、测试集56组,划分过程保证7种合闸角工况的样本在各子集中均匀分布,消除工况分布不均对模型泛化能力评估的干扰。模型训练过程的损失收敛曲线见图5,训练集与验证集损失随训练轮次增加同步快速下降,无明显过拟合现象,训练至1 400轮时验证集损失趋于平稳,触发早停机机制终止训练,最终训练集损失收敛至 10^{-3} 量级,验证了模型具备良好的收敛特性与泛化能力。




图5 模型训练过程损失函数收敛曲线图

Fig. 5 Loss function convergence curve during model training

2.4 模型性能评估指标

模型预测性能的量化评估需选取多维度指标,从绝对偏差、相对误差、拟合优度3个层面,全面检验模型对变压器瞬态磁场的预测精度与泛化能力,最终选取平均绝对误差、均方误差、均方根误差、平均绝对百分比误差、决定系数5项核心指标,构建完整的性能评估体系。

e_{MAE} 采用式(6)的计算式,反映预测值与仿真真值的绝对偏差均值,数值越小代表单网格节点的磁场预测精度越高,是瞬态磁场预测误差的核心量化指标。

均方误差 e_{MSE} (mean squared error)计算式为

$$e_{MSE} = \frac{1}{n} \sum_{i=1}^n [f(x_i) - y_i]^2 \quad (7)$$

式(7)中: $f(x_i)$ 为模型预测值; y_i 为仿真真值; n 为样本数量。该指标通过平方项放大较大预测偏差,对异常值更敏感,可有效检验模型对极端合闸角工况的预测稳定性。均方根误差 e_{RMSE} (root mean square error)为 e_{MSE} 的平方根,量纲与原始磁通密度数据一致,可直观反映预测误差的实际物理量级,适配工程化应用的误差评估需求。

平均绝对百分比误差 e_{MAPE} (mean absolute percentage error)计算式为

$$e_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{f(x_i) - y_i}{y_i} \right| \times 100\% \quad (8)$$

该指标消除了磁场幅值对误差的影响,以相对偏差形式反映模型的全局预测精度,数值越低代表全域磁场拟合效果越好。

决定系数 R^2 计算式为

$$R^2 = 1 - \frac{\sum_{i=1}^n [f(x_i) - y_i]^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (9)$$

式(9)中, $\bar{y}$ 为仿真真值的均值,取值范围为0~1,越接近1代表模型对输入输出映射关系的拟合能力越强,是模型泛化性能的核心评价指标。

3 实验验证与性能分析

3.1 多模型预测性能横向对比分析

在开展模型对比实验前,针对有限元仿真的时序参数开展敏感性分析,探究仿真时长与时间步长对波形保真度、模型预测精度、仿真效率的影响,以此确定最优仿真配置。设置3组仿真时长(0.02、0.04、0.06 s)与3组时间步长(1×10^{-4} 、 5×10^{-4} 、 1×10^{-3} s)进行交叉测试,评价指标包含励磁涌流波形失真度、模型 e_{MAE} 以及单工况仿真耗时,测试结果见表3。

表3 仿真时序参数敏感性分析结果

Table 3 Sensitivity analysis results of simulation time parameters

仿真时长/s	时间步长/s	波形失真度/%	e_{MAE}/T	单工况仿真耗时/min
0.02	1×10^{-4}	0.31	0.004 7	21.6
0.02	5×10^{-4}	0.45	0.004 8	8.3
0.02	1×10^{-3}	1.86	0.005 6	3.5
0.04	1×10^{-4}	0.28	0.004 3	32.4
0.04	5×10^{-4}	0.32	0.004 2	10.1
0.04	1×10^{-3}	1.72	0.005 4	4.2
0.06	1×10^{-4}	0.27	0.004 2	43.8
0.06	5×10^{-4}	0.30	0.004 2	14.7
0.06	1×10^{-3}	1.68	0.005 3	5.9

由表3可知,仿真时长为0.02 s时,无法完整覆盖励磁涌流衰减阶段,波形失真度偏高;时长增加至0.06 s后,波形与模型精度无明显提升,但仿真耗时大幅增加,计算冗余性显著。时间步长 1×10^{-4} s 求解精度最优,但计算效率极低; 1×10^{-3} s 步长过大,会造成涌流陡变段波形失真,直接降低模型预测精度。综合波形保真度、预测精度、仿真计算效率3项指标可以看出,研究所采用的0.04 s仿真时长、 5×10^{-4} s 时间步长,处于精度与效率的最优平衡

区间,印证了该组仿真参数设置合理性。

为验证PCA降维参数选择的合理性,对不同主成分数量下的数据重建误差与模型预测性能进行量化分析。研究对比了100、200、300、400、500共5种主成分数量下的模型性能,结果见表4。从统计数据可以看出,当主成分数量从100增加至300时,模型平均绝对误差从0.012 7 T降至0.004 2 T,预测精度提升显著;继续增加主成分数量至400、500时,精度提升幅度均小于0.1%,但单样本推理耗时分别增加12%和21%。综合考虑预测精度与计算效率,选取300作为最优主成分数量,能够在保证磁场信息完整保留的前提下,实现模型的高效推理。

表4 不同主成分数量下模型性能对比表

Table 4 Comparison table of model performance under different principal component numbers

主成分数量	e_{MAE}/T	$e_{MAPE}/\%$	单样本推理耗时/ms
100	0.012 7	1.28	3.2
200	0.005 8	0.58	3.9
300	0.004 2	0.42	4.5
400	0.004 1	0.41	5.0
500	0.004 1	0.41	5.4

为验证CNN-Transformer混合模型的预测性能,选取6种典型模型作为基线开展横向对比,对比模型覆盖3类主流时序建模方法。传统机器学习基线包括RF与XGBoost^[21],模型超参数设置完全一致,保证对比实验的公平性;深度学习基线包括全连接网络DNN(deep neural networks)^[22]与一维CNN,网络结构与参数量级与所提模型保持一致,仅缺少Transformer全局时序建模模块;前沿时序模型包括Informer^[23]与TimesNet^[24-25],采用其公开的标准结构与默认超参数,验证长程时序建模方法在变压器瞬态磁场预测场景的适用性。

各模型的绝对预测误差与计算效率量化结果见表5,表5中涵盖平均绝对误差、均方误差、均方根误差3项核心精度指标,以及单样本端到端全链路预测耗时,全面反映各模型的预测精度与工程应用适配性。传统机器学习方法对高维时序特征的提取能力有限,整体预测精度偏低,RF与XGBoost的 e_{MAE} 均超过0.011 T,难以满足工程应用的精度要求。深度学习基线方法的预测精度有明显提升,DNN的 e_{MAE} 降0.008 2 T,CNN因引入局部时序特征提取模块,性能进一步优化, e_{MAE} 为0.007 1 T,但两类方法均未充分建模励磁涌流的长程时序依赖,精度提升存在明显瓶颈。前沿时序模型Informer与TimesNet的性能优于深度学习基线, e_{MAE} 分别为0.006 0 T与0.005 7 T,验证了长程时序建模对提升

预测精度的有效性。所提CNN-Transformer混合模型结合了局部特征提取与全局依赖建模的双重优势,在所有绝对误差指标上均取得最优表现, e_{MAE} 低至0.004 2 T,相比其他模型有显著的精度优势。

表5 各模型预测性能与计算效率对比表

Table 5 Comparison table of prediction performance and computational efficiency of each model

模型	e_{MAE}/T	e_{MSE}/T^2	e_{RMSE}/T	单样本端到端全链路 预测耗时/ms
RF	0.012 1	0.000 21	0.014 5	12.5
XGBoost	0.011 5	0.000 19	0.013 8	10.2
DNN	0.008 2	0.000 10	0.010 0	2.1
CNN	0.007 1	0.000 08	0.008 9	3.2
Informer	0.006 0	0.000 06	0.007 7	4.8
TimesNet	0.005 7	0.000 05	0.007 4	5.1
CNN-Transformer	0.004 2	0.000 03	0.005 5	4.5

计算效率方面,所有深度学习类模型的单样本端到端全链路预测耗时均处于毫秒级,该耗时包含原始电气信号预处理、特征映射、模型推理、逆PCA磁场重建的全流程计算时间,远低于传统有限元分析的小时级计算耗时,效率提升倍数超过10⁵,可满足工程场景的实时预测需求。所提模型因引入Transformer模块,单样本端到端全链路预测耗时略高于纯CNN基线,但仍控制在4.5 ms以内,相比精度提升的收益,计算效率的小幅下降在可接受范围。不同模型的 e_{MAPE} 与 R^2 对比雷达图见图6,可直观凸显所提模型的综合性能优势。

3.2 模型核心模块消融实验分析

为量化验证CNN-Transformer混合模型各核心组件的独立作用、结构设计合理性与模块间的协同增益,开展多组对照消融实验。所有对照模型的训练超参数、数据集划分规则与完整模型保持完全一致,消除无关变量对实验结果的干扰,保证对比实验的公平性与可靠性。消融实验共设置5组对照模型,分别为移除Transformer编码器、仅保留一维卷积结构CNN-Only模型,移除CNN特征提取模块、仅保留Transformer编码器的Transformer-Only模型,将CNN模块替换为等参数量全连接层的FC+Transformer模型,将Transformer编码器替换为LSTM时序模块的CNN+LSTM模型,以及将预归一化结构替换为后归一化结构的CNN-Transformer(Post-Norm)模型,与完整的CNN-Transformer混合模型形成对照。

消融实验结果见表6,CNN-Only模型仅能捕捉电气量的局部时序特征,无法建模励磁涌流合闸初期与衰减过程的长程演化依赖, e_{MAPE} 升至0.72%, R^2 降至0.964,相比完整模型出现明显精度下降。




图6 不同模型核心性能指标对比雷达图

Fig. 6 Comparison radar chart of core performance indicators of different models

Transformer-Only 模型缺乏对细粒度瞬态特征的有效提取,对涌流峰值、上升沿陡变等关键信息的捕捉能力不足, e_{MAPE} 进一步升至0.85%, R^2 降至0.953,验证了CNN局部特征提取模块的必要性。FC+Transformer模型因全连接层无法有效提取时序局部关联,精度显著低于CNN+Transformer结构, e_{MAPE} 为0.78%, R^2 为0.958。CNN+LSTM模型受限于循环网络的长程依赖建模瓶颈,精度优于单一结构模型,但仍弱于完整混合模型, e_{MAPE} 为0.63%, R^2 为0.970。后归一化结构的模型收敛稳定性弱于预归一化设计, e_{MAPE} 为0.49%, R^2 为0.981。完整的CNN-Transformer混合模型在所有评估指标上均取得最优表现, e_{MAPE} 低至0.42%, R^2 高达0.987,验证了CNN局部特征提取与Transformer全局建模的协同增益,以及多头注意力、预归一化等关键结构设计的合理性,为模型的高精度瞬态磁场预测提供了结构支撑。

为进一步解析模型内部机理,针对 $Seq=1$ 的输入特性,对4头自注意力权重进行可视化分析,结果见图7,4个注意力头均对绕组电流与合闸角赋予了更高的权重(权重值均在0.29~0.36之间),而对一次电压、二次电压的关注度相对较低,这与前文随机森林特征重要性分析的结论一致。不同注意力头

表6 消融实验各模型性能对比表

Table 6 Performance comparison table of each model in ablation experiment

模型	e_{MAE}/T	e_{MSE}/T^2	e_{RMSE}/T	$e_{MAPE}/\%$	R^2
CNN-Only	0.007 1	0.000 08	0.008 9	0.72	0.964
Transformer-Only	0.008 0	0.000 09	0.009 5	0.85	0.953
FC+Transformer	0.007 6	0.000 09	0.009 3	0.78	0.958
CNN+LSTM	0.006 2	0.000 06	0.007 8	0.63	0.970
CNN-Transformer (Post-Norm)	0.004 9	0.000 04	0.006 2	0.49	0.981
CNN-Transformer	0.004 2	0.000 03	0.005 5	0.42	0.987

的关注侧重略有差异,例如注意力头3对绕组电流(权重0.35)和合闸角(权重0.36)的关注尤为突出,而对电压类特征的权重仅为0.14~0.15,体现了多头注意力机制对不同特征维度的差异化建模能力。该结果表明,Transformer编码器并非构建时序长程关联,而是通过多头注意力自动学习不同电气特征对磁场分布的贡献度,建立输入特征间的全局依赖,弥补了CNN仅能提取局部特征的局限性,有效提升了模型的可解释性与预测性能。




图7 Transformer多头注意力权重热力图

Fig. 7 Heatmap of Transformer multi-head attention weights

3.3 瞬态磁场预测结果可视化与误差特性分析

为直观验证模型的高精度瞬态磁场预测能力,从测试集中选取极端工况样本开展可视化分析,典型工况设定为合闸角 $5\pi/6$ 、时刻0.009 5 s,该工况下励磁涌流达到峰值区间,双铁心变压器内部磁场集中分布特征显著,空间梯度高,磁场分布的非线性特征极强,对模型的细粒度特征提取与长程时序全局建模能力构成较大挑战,具有典型的工程验证意义。针对非7个典型合闸角、非训练时间步长的任意工况与时刻,模型基于连续工况拟合与时序插值特性,可实现任意合闸角、任意时刻的瞬态磁场精准预测,预测误差无显著上升,具备优异的连续工况泛化与时序推演能力。

磁场预测结果的空间分布对比见图8,图8(a)为基于有限元分析的磁场仿真真值,图8(b)为CNN-Transformer混合模型的预测结果。对比可见,模型预测值与仿真真值的空间分布高度一致,均能准确捕捉左右两个铁心柱的高磁通密度集中区域,磁场峰值的位置、幅值、分布范围的相对偏差均小于1.2%,铁心边缘、铁心与空气域过渡区等磁场变化复杂的区域,模型预测结果也与仿真真值保持良好的一致性,未出现明显的分布偏差与峰值偏移,直观验证了模型对极端工况下瞬态磁场的精准预测能力。图8(c)为该典型工况下的绝对误差空间分布云图,误差统计结果显示,全空间的平均绝对误差为0.003 2 T,最大绝对误差不超过0.01 T,且误差高值仅零星分布在铁心与空气的交界面等磁场梯度极高的局部区域,占全空间网格节点比例不足8%,铁心主磁路区域的预测误差普遍低于0.002 T,说明模型的预测误差整体处于极低水平,整体预测精度满足工程应用要求。

从误差分布的物理成因来看,高误差区域均对应变压器铁心的结构突变位置,该类区域的磁场分布受麦克斯韦方程边界条件约束极强,磁场空间变化率远超主磁路区域,本身具有极强的非线性与不连续性,是瞬态磁场仿真与预测的核心难点。而模型在该类区域仍能将最大误差控制在0.01 T以内,远低于工程应用中0.05 T的允许误差阈值,充分体现了混合模型对强非线性磁场特征的拟合能力。

对全测试集56组不同合闸角、不同时刻的样本开展误差统计,结果表明所有样本的平均绝对误差均控制在0.004 T以内,无异常波动样本,进一步验证了模型在任意合闸角、任意时刻下的预测稳定性与泛化能力,可适配变压器空载合闸全工况、全时段的瞬态磁场快速预测需求。

3.4 全工况泛化能力与工程应用价值分析

变压器空载合闸过程中,合闸角直接决定励磁涌流的峰值与演化特性,不同合闸角下铁心内部磁场的非线性分布特征差异显著,是验证模型全场景适配能力与泛化性能的核心测试场景。全工况泛化性能验证覆盖 0° 、 $\pi/6$ 、 $\pi/3$ 、 $\pi/2$ 、 $2\pi/3$ 、 $5\pi/6$ 、 π 共7种典型合闸角工况,完整覆盖从极限涌流到无涌流的全工况范围,核心性能指标的变化规律见图9。

模型预测误差与合闸角对应的励磁涌流强度呈现显著的双峰分布特性, e_{MAE} 与 e_{MAPE} 的变化趋势完全同步。合闸角为 0° 时,两项误差指标均达到全工况峰值, e_{MAE} 为5.1 mT、 e_{MAPE} 为0.52%;合闸角为 $5\pi/6$ 时形成第二个误差峰值, e_{MAE} 为5.0 mT、 e_{MAPE} 为




图8 典型工况下磁场仿真真值、模型预测值及绝对误差分布云图

Fig. 8 Cloud chart of magnetic field simulation truth, model prediction value and absolute error distribution under typical working conditions

0.51%,对应励磁涌流极限工况,磁场非线性特征最强。随着合闸角向 $\pi/2$ 偏移,涌流幅值逐步降低,预测误差同步下降, $\pi/6$ 时 e_{MAE} 降至4.7 mT、 e_{MAPE} 为0.48%, $\pi/3$ 时 e_{MAE} 为4.3 mT、 e_{MAPE} 为0.44%,在 $\pi/2$ 处达到局部谷值, e_{MAE} 为4.0 mT、 e_{MAPE} 为0.41%; $2\pi/3$ 工况下误差小幅回升, e_{MAE} 为4.2 mT、 e_{MAPE} 为0.43%,合




图9 不同合闸角工况下模型核心性能指标对比图

Fig. 9 Comparison chart of core performance indicators of the model under different closing angle conditions

闸角为 π 时,励磁涌流幅值最低,模型预测精度达到最优, e_{MAE} 降至3.7 mT, e_{MAPE} 低至0.38%。

决定系数 R^2 的变化趋势与误差指标完全反向,全工况下均保持在较高水平,合闸角为0与 $5\pi/6$ 时 R^2 为0.982, $\pi/6$ 时升至0.984, $\pi/3$ 与 $2\pi/3$ 时稳定在0.985, $\pi/2$ 时达到0.986,合闸角为 π 时 R^2 最高达到0.988,无明显精度衰减,验证了模型对不同涌流强度的稳定适配能力。励磁涌流全时段预测分析结果表明,从合闸初始瞬态到涌流衰减稳态的完整过程中,模型预测误差无明显时域漂移,全时段精度保持稳定。

传统有限元分析需经历三维网格划分、材料参数设置、多物理场迭代求解等完整离线流程,研究中该方法单工况瞬态磁场求解耗时约15 min,其计算成本主要体现在前期模型构建与离线求解阶段,难以支撑实时仿真需求。相比之下,所提方法需前期投入有限元仿真数据生成与模型离线训练成本,完成训练后,单样本端到端在线推理耗时仅为4.5 ms,无需重复网格剖分与迭代计算,在在线推理阶段,计算效率较传统有限元求解提升约 2×10^5 倍。从变压器数字孪生实时应用角度来看,该模型的毫秒级推理能力能够支持励磁涌流过程中磁场的动态更新与在线监测,可直接适配数字孪生实时感知、励磁涌流抑制方案快速验证、铁心绝缘状态动态预警等工程场景;而有限元方法受限于计算耗时,仅适用于离线工况分析,难以支撑数字孪生系统的实时交互需求。

3.5 实测验证与复杂工况泛化分析

为验证所提模型在真实运行环境下的预测适用性,采用实验室10 kV配电变压器空载合闸实验平台开展局部磁场实测验证,通过在变压器铁心柱上、中、下3个关键位置布置磁通密度传感器,获取空载合闸过程中的局部磁场实测数据,将相同工况下的模型预测值与实测值进行对比分析,结果见表7。

表7 模型预测值与实测磁场数据对比表

Table 7 Comparison between model predicted values and measured magnetic field data

测点位置	实测磁通 密度/T	模型预测磁通 密度/T	绝对误差/T	相对误差/%
铁心上柱	0.826	0.819	0.007	0.85
铁心中柱	1.243	1.235	0.008	0.64
铁心下柱	0.791	0.784	0.007	0.89

实测验证结果表明,模型在真实变压器工况下的局部磁场预测绝对误差均低于0.01 T,相对误差均小于1%,预测结果与实测数据的吻合度较高,能够准确反映铁心表面磁场的实际分布规律。受限于现场测量条件,仅能获取铁心表面局部磁场数据,无法实现全域磁场的全覆盖实测,但局部测点的验证结果已能够证明模型在真实运行环境中的预测可靠性,可为工程场景下的变压器磁场监测与状态评估提供有效支撑。

为进一步验证模型在复杂电网环境下的泛化能力,构建了包含铁心剩磁、背景谐波、系统阻抗波动的多类型拓展测试工况,覆盖实际电网中典型扰动因素,各复杂工况下模型的预测性能见表8。

表8 复杂工况下模型泛化性能测试表

Table 8 Model generalization performance test under complex working conditions

工况类别	扰动参数	e_{MAE}/T	$e_{MAPE}/\%$	R^2
铁心剩磁	剩磁率15%	0.004 4	0.44	0.985
电网谐波	3次谐波含量5%	0.004 5	0.45	0.984
电网谐波	5次谐波含量5%	0.004 6	0.46	0.983
系统阻抗	额定阻抗的0.8倍	0.004 3	0.43	0.986
系统阻抗	额定阻抗的1.2倍	0.004 2	0.42	0.987

测试结果显示,在铁心剩磁、谐波干扰、系统阻抗波动的复杂工况下,模型平均绝对误差控制在0.005 T以内,平均绝对百分比误差不超过0.5%,决定系数高于0.98,预测精度无显著衰减,具备优异的复杂工况适应能力与泛化性能,可满足实际复杂电网环境的应用需求。

4 结论

针对变压器空载合闸全域瞬态磁场难以现场实测、传统有限元方法计算效率低下、单一模型预测精度不足的工程难题,构建了融合多源仿真数据、特征优化处理与CNN-Transformer混合架构的励磁涌流瞬态磁场预测方法,经多组对照实验、极端工况验证与全工况泛化测试,所得核心结论如下。

1)基于精细化三维有限元仿真生成覆盖全合闸角范围的标准化数据集,配合随机森林特征重要性

筛选、PCA 高维磁场数据降维处理,在可忽略信息损失的前提下,破解了高维输出带来的建模复杂度瓶颈,为模型训练提供了高适配、高保真的数据支撑。

2)所搭建的CNN-Transformer混合架构,实现了励磁涌流局部瞬态特征提取与全局长程时序依赖建模的协同互补,经消融实验验证,模块组合与结构设计具备合理性,可适配强非线性、强时变的瞬态过程,预测性能全面优于6类主流对比模型。

3)该模型在7种典型合闸角全工况下均保持稳定的预测精度,全域最大误差符合工程应用阈值,单样本预测耗时压缩至毫秒级,计算效率较传统有限元方法提升超 10^5 倍,可直接适配变压器数字孪生、状态预警等工程场景,具备较强的实用价值与推广潜力。

Transformer架构属于典型的数据密集型深度学习模型,对训练样本的规模与工况覆盖度具有较高要求,现有560组仿真样本虽能够覆盖典型合闸角工况,但样本总量与运行场景维度仍存在一定局限,会在一定程度上制约模型在复杂电网工况下的泛化上限。未来研究可通过拓展铁心剩磁、系统阻抗、电网谐波等多元影响因素,进一步扩充数据集规模与工况覆盖范围,持续优化模型的泛化性能与工程适配能力。

参考文献:

- [1] 董理科,白鹭,武娜,等.基于知识图谱的电力变压器故障预测方法研究[J].高压电器,2022,58(11):151-159.
Dong Like, Bai Lu, Wu Na, et al. Research on fault prediction method of power transformer based on knowledge map[J]. High Voltage Apparatus, 2022, 58(11): 151-159.
- [2] 邱晟璇,王松,刘子瑞,等.基于FRA法和CNN的变压器绕组故障诊断研究[J].大电机技术,2025(3):108-116.
Qiu Shengxuan, Wang Song, Liu Zirui, et al. Research on fault diagnosis of transformer windings based on FRA method and CNN [J]. Large Electric Machine and Hydraulic Turbine, 2025(3): 108-116.
- [3] 郭文,黄著,周鸣中,等.基于CatBoost算法的空载变压器励磁涌流预测[J].电气传动,2026,56(2):34-42.
Guo Wen, Huang Zhu, Zhou Mingzhong, et al. No-load transformer excitation inrush current prediction based on CatBoost algorithm [J]. Electric Drive, 2026, 56(2): 34-42.
- [4] 莫仕勋,杨皓.一种考虑J-A磁滞的变压器电磁暂态模型[J].实验室研究与探索,2023,42(3):119-124.
Mo Shixun, Yang Hao. A transformer electromagnetic transient model considering J-A hysteresis[J]. Research and Exploration in Laboratory, 2023, 42(3): 119-124.
- [5] 范贺明,刘亚楠,胥莹.变压器空载合闸冲击绕组松动信号智能检测方法[J].信息技术,2025(11):112-116.
Fan Heming, Liu Yanan, Xu Ying. Intelligent detection method for loose signal of no-load closing impact winding of transformer[J]. Information Technology, 2025(11): 112-116.
- [6] 胡文旺,邓超平,江伟,等.计及变压器负载的和应涌流产生机理与仿真分析[J].电网与清洁能源,2025,41(10):76-83.
Hu Wenwang, Deng Chaoping, Jiang Wei, et al. Principle and simulation analysis of the transformer sympathetic inrush considering transformer load[J]. Power System and Clean Energy, 2025, 41(10): 76-83.
- [7] 孔煜斌.电力变压器剩磁的仿真拟合及验证[J].兵器材料科学与工程,2025,48(2):150-156.
Kong Yubin. Simulation fitting and verification of power transformer remanence[J]. Ordnance Material Science and Engineering, 2025, 48(2): 150-156.
- [8] Sun Y, Zhang L, Zhang Z, et al. Overview of research status of DC bias and its suppression in power transformers[J]. Energies, 2022, 15(23): 8842.
- [9] 谭正凯,刘海光,李铁华,等.基于选相合闸控制的变压器励磁涌流抑制方法研究与应用[J].石油和化工设备,2025,28(12):70-73.
Tan Zhengkai, Liu Haiguang, Li Tiehua, et al. Phase-selective closing strategy for transformer inrush current mitigation: implementation and analysis[J]. Petro-Chemical Equipment, 2025, 28(12): 70-73.
- [10] 肖湃,张海龙,杜志叶,等.特高压换流变压器励磁涌流选相合闸抑制方法研究[J].高压电器,2023,59(5):146-153.
Xiao Pai, Zhang Hailong, Du Zhiye, et al. Research on phase selection closing suppression method of exciting inrush current of UHV converter transformer[J]. High Voltage Apparatus, 2023, 59(5): 146-153.
- [11] 宋玉洁,李振兴.基于动态可调电阻的变压器励磁涌流抑制方法[J].中国电力,2025,58(12):147-154.
Song Yujie, Li Zhenxing. Transformer excitation inrush current suppression method based on dynamically adjustable resistors[J]. Electric Power, 2025, 58(12): 147-154.
- [12] 王子伟,疏佳铭,陆斌,等.基于GASF及双输入AlexNet-SVM的变压器励磁涌流检测[J].机械与电子,2025,43(8):30-39.
Wang Ziwei, Shu Jiaming, Lu Bin, et al. Transformer inrush current detection based on GASF and dual-input AlexNet-SVM[J]. Machinery & Electronics, 2025, 43(8): 30-39.
- [13] 栾云飞,张禄亮,季天瑶,等.基于直方图和余弦相似度的光伏电站主变压器励磁涌流识别[J].电测与仪表,2025,62(7):181-189.
Luan Yunfei, Zhang Luliang, Ji Tianyao, et al. Histogram and cosine similarity based magnetizing inrush current identification for main transformer in photovoltaic power station[J]. Electrical Measurement & Instrumentation, 2025, 62(7): 181-189.
- [14] 龙启,杨旭,薛淑鹏,等.基于圆坐标表征法的换流变压器励磁涌流辨识研究[J].电力系统保护与控制,2025,53(9):118-129.
Long Qi, Yang Xu, Xue Shupeng, et al. Research on identification of converter transformer inrush current based on circular coordinate representation method[J]. Power System Protection and Control, 2025, 53(9): 118-129.

- [15] 韩志. 基于多元信息融合的变压器励磁涌流识别研究[J]. 微型电脑应用, 2023, 39(12): 215-219.
Han Zhi. Research on transformer inrush current identification based on multivariate information fusion[J]. Microcomputer Applications, 2023, 39(12): 215-219.
- [16] 马云龙, 李秀广, 周秀, 等. 基于高压真空快速断路器的变压器励磁涌流抑制技术研究[J]. 高压电器, 2022, 58(10): 136-142.
Ma Yunlong, Li Xiuguang, Zhou Xiu, et al. Research on excitation inrush current suppression technology of transformer based on high voltage vacuum fast circuit breaker[J]. High Voltage Apparatus, 2022, 58(10): 136-142.
- [17] Peng Qingjun, Du Hantao, Zheng Zezhong, et al. Prediction of magnetic fields in single - phase transformers under excitation inrush based on machine learning[J]. Sensors, 2025, 25(13): 4150.
- [18] Chu Wenchao, Wang Qiong, Yang Bo, et al. Analysis and study of excitation inrush current characteristics of high-impedance power transformer[C]//2025 2nd International Conference on Smart Grid and Artificial Intelligence (SGAI), 2025: 1592-1596.
- [19] Wang Jianting, Gao Yonglin, Liu Yaxing, et al. Application of a multi-scale feature-enhanced transformer for segmentation in complex intercropping scenarios[J]. Smart Agricultural Technology, 2026(14): 102137.
- [20] Qazi E U H, Almorjan A, Zia T. A one-dimensional convolutional neural network(1D-CNN)based deep learning system for network intrusion detection[J]. Applied Sciences, 2022, 12(16): 7986.
- [21] Zhang Ping, Jia Yiqiao, Shang Youlin. Research and application of XGBoost in imbalanced data[J]. International Journal of Distributed Sensor Networks, 2022, 18(6): 15501329221.
- [22] Ren Weiqing, Qu Yuben, Dong Chao, et al. A survey on collaborative DNN inference for edge intelligence[J]. Machine Intelligence Research, 2023, 20(3): 370-395.
- [23] 肖白, 李森, 焦明曦, 等. 基于霜冰优化组合模态分解及Informer的空间负荷预测[J]. 电力建设, 2026, 47(4): 108-121.
Xiao Bai, Li Sen, Jiao Mingxi, et al. Spatial load forecasting based on RIME-optimized combination modal decomposition and Informer [J]. Electric Power Construction, 2026, 47(4): 108-121.
- [24] 郑玉周, 杜金龙, 武永强, 等. 基于改进热路模型和PINN的变压器直流偏磁温升预测及绝缘寿命评估[J]. 电力电容器与无功补偿, 2026, 47(2): 107-117.
Zheng Yuzhou, Du Jinlong, Wu Yongqiang, et al. Prediction of DC-bias temperature rise in transformer and insulation life assessment based on an improved thermal circuit model and PINN[J]. Power Capacitor & Reactive Power Compensation, 2026, 47(2): 107-117.
- [25] 张楚, 王熠炜, 张越, 等. 基于改进堆优化算法和TimesNet神经网络的锂电池剩余寿命预测方法[J]. 太阳能学报, 2025, 46(11): 98-108.
Zhang Chu, Wang Yiwei, Zhang Yue, et al. Lithium-ion battery remaining useful life prediction method based on improved heap optimization algorithm and TimesNet neural network[J]. Acta Energiae Solaris Sinica, 2025, 46(11): 98-108.
- 郜晓娜(1983—), 女, 硕士研究生, 工程师, 主要研究方向为调度运行(通信作者)(E-mail: xiaonagao83@outlook.com)。

(上接第185页)

- [17] Lan Z, Chen M, Goodman S, et al. ALBERT: a lite BERT for self-supervised learning of language representations[EB/OL]. [2026-04-02]. <https://arxiv.org/abs/1909.11942>.
- [18] Graves A, Schmidhuber J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks: The Official Journal of the International Neural Network Society, 2005, 18(5/6): 602-610.
- [19] Lafferty J D, McCallum A, Pereira F C N. Conditional random fields: probabilistic models for segmenting and labeling sequence data[C]//Proceedings of the Eighteenth International Conference on Machine Learning, 2001: 282-289.
- [20] Bordes A, Usunier N, Garcia-Durán A, et al. Translating embeddings for modeling multi-relational data[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems, 2013: 2787-2795.
- [21] Lin X V, Socher R, Xiong C. Multi-hop knowledge graph reasoning with reward shaping[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, 2018: 3243-3253.
- [22] Williams R J. Simple statistical gradient-following algorithms for connectionist reinforcement learning[J]. Machine Learning, 1992, 8(3): 229-256.
- [23] Xiong W, Hoang T, Wang W Y. DeepPath: a reinforcement learning method for knowledge graph reasoning[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, 2017: 564-573.
- [24] Das R, Dhuliawala S, Zaheer M, et al. Go for a walk and arrive at the answer: reasoning over paths in knowledge bases using reinforcement learning[EB/OL]. [2026-04-02]. <https://arxiv.org/abs/1711.05851>.
- 吴婉豪(2002—), 女, 硕士研究生, 主要研究方向为变压器缺陷检测与诊断方法。
- 任富强(1990—), 男, 博士, 副研究员, 主要研究方向为新型电力系统构建背景下电力设备多场耦合分析及可靠性提升、绝缘劣化机理、绝缘状态评估、人工智能在电力设备中的应用(通信作者)(E-mail: renfuqiang@sdu.edu.cn)。