

DOI: 10.19650/j.cnki.cjsi.J2614877

基于异质图注意力的可信参数辨识方法^{*}

刘金凤¹, 李金枝¹, Herbert Ho-Ching Lu²

(1. 哈尔滨理工大学测控技术与通信工程学院 哈尔滨 150080; 2. 西澳大学电气电子与计算机工程学院 珀斯 6009)

摘 要:在电力电子系统中,功率开关器件金属-氧化物-半导体场效应晶体管(MOSFET)的通态电阻变化是反映器件健康状态与损耗水平、系统运行效率以及可靠性的关键指标。针对现有 MOSFET 通态电阻参数辨识在复杂耦合工况下精度低、拓扑结构信息利用不足以及模型可解释性弱等问题,提出一种融合柯尔莫哥洛夫-阿诺德网络(KAN)与异质图 Transformer(HGT)的两阶段多参数辨识混合模型。首先,基于输出电压信号提取时域统计特征与频域小波包局部能量值,采用皮尔逊相关系数与互信息相结合的联合特征优选策略,筛选高敏感性、低冗余度的特征作为关键特征子集;其次,构建多个并行的 KAN 子网络,实现各 MOSFET 通态电阻的初步非线性映射;最后,构建反映电路物理语义的异质图,通过 HGT 对初步辨识残差进行拓扑感知的结构化补偿,捕获器件非线性特征与系统耦合关系,得到最终的辨识结果。实验结果表明,所提方法在三相空间矢量脉冲调制(SVPWM)整流系统对 MOSFET 通态电阻辨识的平均相对误差为 0.962%,优于传统神经网络与同质图模型,在硬件实验中辨识的平均相对误差为 1.992%,展现出良好的泛化性与鲁棒性。通过沙普利可加性解释(SHAP)分析与注意力可视化验证了特征选择的有效性,与模型决策的物理一致性,为电力电子器件的高精度、可解释智能诊断提供了新思路。

关键词: 多参数辨识;异质图神经网络;关键特征;SHAP

中图分类号: TH7 **文献标识码:** A **国家标准学科分类代码:** 510.99

A trustworthy parameter identification method based on heterogeneous graph transformer

Liu Jinfeng¹, Li Jinzhi¹, Herbert Ho-Ching Lu²

(1. School of Measurement-Control Technology and Communications Engineering, Harbin University of Science and Technology, Harbin 150080, China; 2. School of Electrical, Electronic and Computer Engineering, The University of Western Australia, Perth 6009, Australia)

Abstract: In power electronic systems, the variation in on-state resistance of the power switching device metal-oxide-semiconductor field-effect transistor (MOSFET) serves as a key indicator reflecting the device's health condition, power loss level, system operating efficiency, and reliability. To address the problems of low accuracy, insufficient utilization of topological structure information, and weak model interpretability in existing MOSFET on-state resistance parameter identification methods under complex coupling operating conditions, this article proposes a two-stage hybrid model for multi-parameter identification by fusing Kolmogorov-Arnold networks (KAN) and heterogeneous graph Transformer (HGT). Firstly, time-domain statistical features and frequency-domain wavelet packet local energy values are extracted from the output voltage signal. A combined feature optimization strategy based on the Pearson correlation coefficient and mutual information is utilized to select features with high sensitivity and low redundancy as the key feature subset. Secondly, multiple parallel KAN sub-networks are established to realize the preliminary nonlinear mapping of on-state resistance for each MOSFET. Finally, a heterogeneous graph reflecting the physical semantics of the circuit is constructed, and topology-aware structured compensation is performed on the preliminary identification residuals through HGT to capture the nonlinear characteristics of devices and the coupling relationship of the system, so as to obtain the final identification results. Experimental results show that the average relative error of the proposed method for MOSFET on-state resistance identification in the three-phase space vector pulse width modulation

收稿日期:2026-01-21 Received Date: 2026-01-21

^{*} 基金项目:黑龙江省自然科学基金(LH2023E086)项目资助

(SVPWM) rectifier system is 0.962%, which is superior to traditional neural networks and homogeneous graph models. The average relative error of identification in hardware experiments is 1.992%, showing favorable generalization and robustness. Finally, this article verifies the effectiveness of feature selection and the physical consistency of model decision-making through Shapley additive explanations (SHAP) analysis and attention visualization, which provides a new idea for the high-precision and interpretable intelligent diagnosis of power electronic devices.

Keywords: multi-parameter identification; heterogeneous graph neural network; key features; SHAP

0 引 言

随着新能源系统、电动汽车及高性能电源技术的快速发展,电力电子变换器的可靠性和智能维护需求日益突出。金属-氧化物-半导体场效应晶体管(metal-oxide-semiconductor field-effect transistor, MOSFET)作为电力电子变换器中开关电源的核心执行器件,其性能直接影响了系统工作的稳定性和使用寿命^[1]。其中,通态电阻是反映器件健康状态和性能退化的关键参数之一,随着器件老化,通态电阻增大导致导通损耗增加,不仅会降低系统的运行效率,还会加速器件结温升高,加剧热应力,进而缩短器件寿命^[2-3]。由于通态电阻的变化能够表征器件从早期老化到中期退化的典型软故障阶段,因此,对 MOSFET 通态电阻进行高精度的参数辨识具有关键意义,为电子系统的稳定运行与性能优化提供有力的支撑。

传统的参数辨识方法可分为 3 类:基于解析模型的方法、基于特征驱动的方法以及基于数据驱动的方法^[4]。其中,解析模型方法是通过构建电路结构的参数解析模型,基于某时刻测出的电流、电压信号来求解电路元器件此时的参数值^[5],依赖精确的物理建模与数学推导,具有机理清晰的优势,但在复杂和非线性工况下适用性受限。相比之下,基于特征驱动和数据驱动的方法具有更强的适应性和泛化能力,逐渐成为当前参数辨识研究与应用的主流方向。

特征驱动方法是对输出信号进行时域或频域变换与统计建模,构造能表征器件老化与漂移的人工特征,结合特征选择方法降维实现参数辨识。陈小涛等^[6]通过引入双参考激励对系统关键参数进行在线辨识,实现了非接触电压测量过程中传感器等效增益的自标定与测量精度提升。Amaral 等^[7]结合离散小波变换特征提取与卡尔曼滤波参数估计,提出优化预防性诊断算法,实现铝电解电容器的健康状态评估。朱琴跃等^[8]针对逆变器中绝缘栅双极型晶体管(insulated gate bipolar transistor, IGBT)微小故障难以辨识的问题,提出了一种基于多模态输出电压信号的故障特征提取方法,通过融合不同工作状态下的电压信息挖掘微弱故障特征,验证了该方法对 IGBT 早期微小故障的有效表征能力。朱文昌等^[9]通过变分模态分解提取多尺度故障特征并利用改进麻雀搜索算法优化

的极限学习机进行分类,实现了电力电子电路软故障的高精度诊断。然而,特征驱动方法在很大程度上依赖专家经验或依赖单一指标进行特征构造与筛选,特征维度较高且冗余性强,在工况变化、负载扰动或噪声增强的情况下,模型泛化能力和稳定性仍然受到一定限制。

基于数据驱动方法通过分析和学习历史存储数据集隐藏的数据规律,结合智能算法建立输出特征与待辨识参数的关系。随着深度学习技术的发展,卷积神经网络(convolutional neural network, CNN)、多层感知机(multi-layer perceptron, MLP)等深度学习网络在无显式物理模型条件下实现了参数辨识,在精度上取得了显著提升。唐圣学等^[10]通过融合多域时频特征并利用群智能优化的学习模型,实现了棒控电源早期故障状态的高精度识别。杨东儒等^[11]提出了基于自注意力机制的深度学习模拟电路故障检测方案,实现了 Sallen-Key 型低通滤波电路故障诊断。姜月明等^[12]提出基于变异系数提取关键特征和 Elman 神经网络的开关电源多参数辨识方法,实现对开关电源中电解电容容值和电感的电感值及其等效电阻的参数辨识;Soualhi 等^[13]提出了一种基于新型模糊神经网络(neo-fuzzy neural network, NFNN)的电容器与超级电容器健康状态监测方法,实现对关键老化参数的在线估计。

然而,现有的数据驱动模型在电力电子中应用时,将电路元件视为孤立的“黑箱”,忽略了电路中元件的拓扑连接与功能语义差异,这种局限性导致模型在处理复杂异构的电力电子系统时泛化性能不足。为弥补传统深度神经网络在结构感知上的缺陷,图神经网络(graph neural network, GNN)逐渐被应用到电力系统与电力电子参数建模中,通过将系统拓扑结构、元件类型及连接关系显式引入学习模型,在提升预测精度的同时增强模型的物理一致性与可解释性。Li 等^[14]系统综述了图论与图神经网络在电力电子领域的应用潜力,分析了 GNN 在性能建模、参数预测与控制中的优势;Khamis 等^[15]提出了一种电路拓扑感知的同质图神经网络回归模型,将连续电路及处于连续导通模式/断续导通模式的开关变换器映射为图表示,强调模型可随拓扑与元件连接数量扩展,具备跨拓扑建模能力,克服了电路组件数量和连接方式对模型的限制。但这些研究主要是基于同质图,将不同元件与连接关系均视为同类型。这一假设削弱了关键元件特性的区分度,其物理语义与异构信息流动差异难以在同

质图中得到准确表达,从而限制了模型在复杂异构电力电子系统中的性能。而异质图可以充分挖掘异质电路图中不同类型节点与边之间的关系,Khamis等^[16]提出了一种面向电气回路机器学习任务的异质图表示框架,通过构建多类型节点与边的电路图模型,并结合异质图神经网络,实现了对电路的分类与回归预测;Dong等^[17]提出电路图神经网络(circuit graph neural network, CktGNN),将电路建模为多层次图结构,通过嵌套消息传递机制学习不同尺度的电路拓扑关系;Cao等^[18]提出了耦合边缘变分自编码器-异质图注意力神经网络,以异构信息为基础构建异质图模型,实现了电动舵机的故障诊断。然而,尽管引入图神经网络增强了模型对电路结构信息的感知能力,其本质仍属于数据驱动的深度神经网络,预测机理难以直观解释,模型可解释性不足的问题仍然存在。

综上,特征驱动方法依赖于专家经验或单一指标构造特征集,存在信息冗余与泛化能力不足的问题;数据驱动方法忽略电路结构,无法有效建立其内在拓扑关系;另外,数据驱动的本质依然是深度学习,预测机理难以直观解释,模型可解释性不足。上述局限共同导致现有方法难以兼顾精度、泛化性与可解释性的有效平衡。为此,本文基于三相空间矢量脉宽调制(space vector pulse width modulation, SVPWM)整流系统,提出具有明确物理导向与结构感知能力的智能参数辨识框架,主要研究内容为:

1) 融合特征筛选机制:基于皮尔逊相关系数(Pearson correlation coefficient, PCC)与互信息(mutual information, MI)融合的策略进行时频特征优选,兼顾线性与非线性关联特性。

2) 两阶段混合辨识框架:采用融合柯尔莫哥洛夫-阿诺德网络(Kolmogorov-Arnold networks, KAN)^[19]网络实现单器件非线性映射建模,并以异质图Transformer(heterogeneous graph Transformer, HGT)^[20]捕捉电路拓扑结构下的残差补偿,实现多器件协同辨识。

3) 结构化可解释性分析:引入沙普利可加性解释(Shapley additive explanations, SHAP)^[21]从特征选择机制和电路拓扑耦合关系两个维度开展可解释性分析,验证特征选择的有效性和拓扑图结构构建的有效性,增强参数辨识结果的物理一致性与工程可信度。

1 理论分析

1.1 特征提取与优选

1) 特征提取

为全面描述参数的变化情况,基于三相SVPWM整流电路的输出信号提取时域特征和频域特征。时域特征为统计特征,频域特征为利用小波包分析获取的输出信号的小波包局部能量值。

时域特征包括可反映输出波动强度的纹波幅值 r ,表征直流偏置水平的均值 m ,衡量信号离散程度的方差 σ^2 ,描述分布不对称性的偏度 s ,刻画尾部尖锐程度的峰度 k ,量化信号复杂度的信息熵 e 以及反映能量集中位置的频谱质心 c ,这些时域特征可以表征三相SVPWM整流电路输出电压在时域中的整体变化趋势及其统计特性。

开关电源的输出电压主要成分是带脉动的直流信号,但其存在的高频纹波特征是描述开关电源异常的重要指标参数。为同时提取并分析输出信号的低频和高频特征,本文采用小波包分解(wavelet packet decomposition, WPD)的方法进行频域分析。WPD是对传统离散小波变换(discrete wavelet transform, DWT)的推广。与仅分解低频分量的DWT不同,WPD对信号的低频和高频部分均进行递归分解,形成一个完整的二叉树结构,实现对全频带的均匀划分,有利于捕捉高频噪声等细微特征,提升特征区分度。

本文选取小波包局部能量 E_i 作为频域特征。 E_i 直接量化了信号在细分频带上的能量分布,对元器件参数状态变化敏感,且具有物理可解释性和强鲁棒性。局部能量 E_i 可通过第 i 个频带节点的小波包系数 $C_{i,k}$ 的平方和进行量化,其中, M_i 是该子带的系数长度:

$$E_i = \sum_{k=1}^{M_i} |C_{i,k}|^2 \quad (1)$$

本文选取Daubechies小波族中的db1小波作为基函数,利用其良好的时域局部化特性捕捉电力电子信号的快速瞬态。采用 $L=3$ 层分解,计算每个频带的局部能量,得到的小波包局部能量向量 $\mathbf{E}=[e_1, e_2, \dots, e_8]$ 。

2) 关键特征优选

由于不同特征在表征元器件参数变化时灵敏度不同,为解决特征冗余和灵敏度不均衡导致的辨识精度受限问题,基于三相SVPWM整流电路提取的时域和频域特征集,采用PCC与MI相结合的动态特征选择方法,以优选对目标参数变化敏感的关键特征。

PCC用于量化特征向量 $\mathbf{X}$ 与目标向量 $\mathbf{Y}$ 之间的线性相关程度,评估特征对参数变化的线性表征能力。其计算公式为:

$$\rho_{XY} = \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad (2)$$

其中, X_i 和 Y_i 分别代表输入输出特征中第 i 个样本的特征值, $\bar{X}$ 和 $\bar{Y}$ 表示输入和输出特征值的样本均值。

MI是信息论中的核心概念,用于度量两个变量 $\mathbf{X}$ 和 $\mathbf{Y}$ 间任意依赖关系的强弱,包括非线性、非单调关系。其本质是量化变量间共享的信息量,互信息的计算公式为:

$$I(\mathbf{X}; \mathbf{Y}) = \sum_{x \in \mathbf{X}} \sum_{y \in \mathbf{Y}} p(x, y) \log \left(\frac{p(x, y)}{p(x)p(y)} \right) \quad (3)$$

其中, $p(x, y)$ 为 x 和 y 的联合概率分布, $p(x)$ 和 $p(y)$ 分别为 x 和 y 的边缘概率分布。MI 能够有效捕捉复杂的非线性关联, 弥补 PCC 的局限性。

该联合方法既能利用 PCC 识别线性敏感特征, 又能通过 MI 度量非线性依赖关系, 两者结合确保了线性与非线性敏感特征的全覆盖, 有效克服了单一指标的局限性, 降低了特征冗余度, 为高精度参数辨识模型构建提供了关键输入特征集。

1.2 基于 KAN-HGT 的多参数辨识混合模型

为实现对三相 SVPWM 整流电路中 6 个 MOSFET 通态电阻的高精度参数辨识, 本文提出一种融合 KAN 与 HGT 的两阶段辨识框架。在该框架中, 第 1 阶段利用多个并行的多输入单输出 KAN 子网络, 实现对每个 MOSFET 通态电阻的独立初步辨识; 第 2 阶段以初步辨识残差为学习目标, 通过基于电路拓扑构建的异质图, 利用 HGT 建模器件间的耦合关系, 实现精细化的结构补偿与残差回归。

1) 初步辨识模块构建

KAN 是一种基于 Kolmogorov-Arnold 表示定理构建的新的神经网络架构, 其核心思想是将多元函数分解为一系列可学习的一元函数叠加:

$$\text{KAN} = \sum_{k=1}^m \psi_k \left(\sum_{i=1}^n \phi_{k,i}(x_i) \right) \quad (4)$$

其中, $\psi_k(\cdot)$ 和 $\phi_{k,i}(\cdot)$ 是可学习的一元函数, 这种结构使模型以更直观、参数量更少的方式建立输入特征与输出参数之间的非线性映射, 从而在架构底层提升了模型的可解释性。

由于每个通态电阻的特征组成不同, 为每个 $R_{DS(on)}$ 构建独立的多输入单输出的 KAN 网络, 每个网络的输入为经 PCC 和 MI 提取的关键特征子集, 整体为多并行多输入单输出网络。相较于单一的多输入多输出网络具有更好的适应性, 有助于提升初步辨识的精度, 且避免了多任务学习中的梯度耦合问题。网络的输出为初步估计值 $\hat{R}_{DS(on),i}$, 其映射关系为:

$$\hat{R}_{DS(on),i} = \text{KAN}_i(\mathbf{x}_i), i = 1, 2, \dots, 6 \quad (5)$$

其中, $\mathbf{x}_i$ 为第 i 个通态电阻的关键特征子集, $\text{KAN}_i(\mathbf{x}_i)$ 为 $\mathbf{x}_i$ 对应的 KAN 子网络。

定义第 i 个通态电阻的辨识残差为:

$$\Delta R_{DS(on),i} = R_{DS(on),i}^{\text{true}} - \hat{R}_{DS(on),i} \quad (6)$$

其中, $\Delta R_{DS(on),i}$ 主要包含由器件间电气耦合引起的系统性偏差, 将作为第 2 阶段 HGT 的学习目标, 通过电路拓扑结构进行补偿。此外, KAN 最后一层激活层包含高度非线性的特征表达, 将其作为深层非线性特征 $\mathbf{h}_i^{\text{deep}}$, 用于后续图模型的特征构建。

2) 残差补偿模块构建

电力电子电路天然具有异质性, 包含多种物理元件

与连接关系, 传统图神经网络通常假设所有节点和边共享统一的特征空间与传播规则, 难以区分不同元件、线路类型在电路中的语义差异及其在拓扑结构中的作用。为充分挖掘异质电路图中各类节点与边之间的关联特征, 引入异质图模型 HGT 作为补偿辨识模块以进一步提升对 MOSFET 通态电阻参数的辨识精度。与传统的异质图注意力神经网络相比, HGT 能够显式建模不同节点与边关系间的语义差异, 具备在全局范围内捕获跨层级、跨类型节点间复杂依赖的能力, 更适用于元器件类型多样、物理耦合关系复杂的电力电子拓扑建模。

三相 SVPWM 整流电路拓扑图如图 1 所示。




图 1 三相 SVPWM 整流电路拓扑图

Fig. 1 Topology of the three-phase SVPWM rectifier circuit

忽略电源内阻和线路寄生电阻, 聚焦于 MOSFET 通态电阻的辨识, 将其抽象为一个异质图:

$$\mathbf{G} = (\mathbf{V}, \mathbf{E}, \mathbf{T}_v, \mathbf{T}_e) \quad (7)$$

其中, $\mathbf{V}$ 表示节点集合, 包含 5 类节点, 分别为电源 (U)、电感 (L)、交流节点 ($A/B/C$)、直流母线 (P/N) 与电容 (C_d), 其中电源、滤波电感和滤波电容属于储能元件节点, 提供系统静态物理参数信息, 交流节点和直流母线节点属于电气节点, 提供系统的结构与相位信息; $\mathbf{E}$ 表示边集合, 包括导线边与开关边, 导线边用于描述电源、电感、交流节点、直流母线和电容之间的固定物理连线, 开关边对应 6 个 MOSFET 的导通路径, 作为模型回归残差的预测目标, 即待辨识参数对应于为边结构, 而非节点, 因此, 本文将 HGT 由传统的节点回归形式扩展为一种边级回归框架, 以更符合 MOSFET 通态电阻残差的物理语义。

$\mathbf{T}_v$ 表示为节点类型集合, 每个节点 $s \in \mathbf{V}$ 对应唯一的类型:

$$\tau(s) \in \mathbf{T}_v \quad (8)$$

$\mathbf{T}_e$ 为边类型集合, 每条边 $e = (u, v) \in \mathbf{E}$ 对应类型:

$$\phi(e) \in \mathbf{T}_e \quad (9)$$

元关系是 HGT 建模异质性结构的重要基础, 它描述了信息传递起点的源节点类型 $\tau(u)$ 、连接关系的边类型 $\phi(e)$ 与信息传递终点的目标节点类型 $\tau(v)$ 的组合, 其中 $\tau(u)$ 和 $\tau(v)$ 都属于节点类型, 元关系表达式如式 (10) 所示。

$$\langle \tau(u), \phi(e), \tau(v) \rangle \quad (10)$$

而针对每种元关系, HGT 会分配独立的投影矩阵以实现类型感知的注意力分配与消息传递, 其注意力计算公式如式 (11) 所示。

$$\text{Attention} = \text{Softmax}\left(\frac{\text{Query}_{v, \tau(v)} \cdot \mathbf{W}_{\phi(e)}^{\text{ATT}} \cdot \text{Key}_{u, \tau(u)}^{\text{T}}}{\sqrt{d}}\right)$$

(11)

式 (11) 通过 $\tau(v)$ 的查询矩阵 **Query**、 $\tau(u)$ 的键矩阵 **Key** 以及 $\phi(e)$ 的语义关系矩阵 $\mathbf{W}^{\text{ATT}}$ 进行交互计算, $\sqrt{d}$ 为缩放因子, d 对应特征维度。

将三相整流电路抽象为异质图结构, 连接示意如图 2 所示。




图 2 异质图结构示意图

Fig. 2 Diagram of the heterogeneous graph structure

引入不同类型节点与边的连接关系, 为建模开关器件之间的系统性耦合效应提供结构化表达基础, 这些结构信息是单器件建模方式难以显式表征的部分。

为增强图结构对电路拓扑的表达能力, 为异质图中的节点和边设计合适的特征。节点特征 f_v 由常量特征

f_v^{const} 和结构特征 f_v^{struct} 两部分构成:

$$f_v = [f_v^{\text{const}} \parallel f_v^{\text{struct}}]$$

(12)

常量特征 f_v^{const} 由各元件的静态物理参数组成, 表示各电气元件固有的物理参数, 用于刻画器件属性, 如相电压、频率、标称电感、标称电容等。结构特征 f_v^{struct} 依据电路拓扑关系为每个节点生成图结构特征, 用于刻画节点在能量流动路径中的相对位置与连接模式, 包括节点类型嵌入、结构位置编码, 节点度数编码以及用于区分交流节点 $A/B/C$ 和直流母线 P/N 的相位与极性编码。常量特征揭示器件属性, 结构特征表达拓扑功能, 两者共同构成节点在异质图中的完整特征表示。

边特征设计上, 导线边对应元件之间的固定连接关系, 用于支撑整体拓扑结构的构建, 不包含局部动态状态变化, 不作为残差建模的特征输入, 仅对开关边赋予特征。以边类型嵌入的边结构特征区分开关边与导线边。开关边特征 S_i 融合原始输入特征 x_i 、KAN 模型的深层特征 h_i^{deep} 和 KAN 预测输出 $\hat{R}_{DS(on), i}$ 这 3 类信息:

$$S_i = [x_i \parallel h_i^{\text{deep}} \parallel \hat{R}_{DS(on), i}]$$

(13)

原始输入特征用于反映开关器件在当前工况下的外部输入特性, KAN 模型的深层特征能够捕捉通态电阻的非线性响应模式与上下文结构信息, KAN 预测输出用于表征模型前向估计结果的残差信息作为基准参考。三者拼接后投影至 HGT 所需的统一维度, 构成完整的边特征输入, 使异质图模型在信息传播过程中能够同时结合电路结构及残差上下文, 实现对三相 SVPWM 整流电路内部耦合关系的建模, 各节点与边在异质图中的特征构成如表 1 所示。

表 1 异质图节点与边的特征构成与物理语义

Table 1 Feature composition and physical semantics of nodes and edges in the heterogeneous graph

特征类型	特征名称	特征说明
节点常量特征	相电压	三相电源节点的标称相电压, 描述输入侧电源幅值特性
节点常量特征	频率	交流电源的工频参数, 为电源节点的固有属性
节点常量特征	相位	三相电源 U_a, U_b, U_c 的相位角, 用 $(\sin\theta, \cos\theta)$ 表示
节点常量特征	标称电感	电感元件的固有参数, 表征交流侧滤波结构的电气特性
节点常量特征	标称电容	直流侧电容的固有参数, 用于描述储能及滤波能力
节点结构特征	节点类型嵌入	通过可训练向量区分电源、电感、电阻、电容等节点类型, 表示节点类型差异
节点结构特征	拓扑位置编码	基于电路图结构计算的结构性位置向量
节点结构特征	节点度数编码	节点的入度、出度与总度信息, 反映其拓扑中心性和连接模式
节点结构特征	交流相位编码	以三维 One-Hot 方式区分 A, B, C 三相, 用于结构特征增强
节点结构特征	直流极性编码	区分直流母线 P, N
开关边特征	原始优选特征	基于输出电压信号特征提取与特征选择获得的通态电阻相关特征子集
开关边特征	KAN 深层特征	KAN 模型最后一层隐藏表示, 用于刻画开关管的非线性动态行为与上下文特征
开关边特征	KAN 预测输出	KAN 对 MOSFET 通态电阻的初步预测值, 用于提供残差建模的基准
边结构特征	边类型嵌入	用于区分开关边与导线边的可训练边类型嵌入

该异质图作为图神经网络的输入, HGT 通过类型感知的多头注意力机制, 在异质图上聚合邻域信息。对于第 i 条开关边, 其输出的边嵌入 z_i 为:

$$z_i = \text{HGT}(\mathbf{G}, \mathbf{f}_v, \mathbf{S}_i) \quad (14)$$

z_i 通过一个轻量化 MLP 回归头得到最终的辨识误差 $\Delta \hat{R}_{DS(on),i}$:

$$\Delta \hat{R}_{DS(on),i} = \text{MLP}(z_i) \quad (15)$$

最终通态电阻估计为:

$$\hat{R}_{DS(on),i}^{\text{final}} = \hat{R}_{DS(on),i} + \Delta \hat{R}_{DS(on),i} \quad (16)$$

3) 基于两阶段混合模型的多参数辨识流程

混合模型的 KAN 模块采用多个并行的多输入单输出子网络, 分别完成对各电阻参数的初步估计, 子网络数量与待辨识参数数量一致。随后, 将 KAN 初步辨识产生的残差输入至 HGT 模块, 结合电路图结构信息与原始特征进行精细化补偿辨识。基于混合模型的多参数辨识整体结构如图 3 所示。




图3 KAN-HGT 两阶段参数辨识流程

Fig. 3 Two-stage parameter identification framework based on KAN-HGT

具体步骤为:

(1) 基于三相 SVPWM 整流电路输出的直流电压信号提取时域与频域特征, 通过 PCC 和 MI 进行联合特征优选, 构建每个 $R_{DS(on)}$ 的关键特征子集;

(2) 为每个待辨识的 $R_{DS(on)}$ 分别构建一个 KAN 子网络(共 6 个)。设置各网络的输入输出维度、网络层数与训练超参数。输入特征为步骤(1)所得的各电阻关键特征子集, 输出为初步辨识结果;

(3) 基于电路物理拓扑关系将三相 SVPWM 整流电路抽象为异质图结构, 在此基础上, 构建异质图中不同类型节点与边的特征表示, 并根据器件类型及其拓扑连接语义定义元关系, 用于描述不同节点类型之间的有向连接模式;

(4) 将 KAN 初步辨识的残差作为第 2 阶段 HGT 模块的学习目标, 结合步骤(3)构建的异质图结构与特征信息一起输入到 HGT 神经网络中, 通过多头图注意力机制实现特征聚合与残差连接, 最后经过轻量化 MLP 回归头, 完成对 6 个 $R_{DS(on)}$ 的高精度参数辨识。

2 实验验证

2.1 仿真数据提取与特征筛选

通过修改三相 SVPWM 整流电路中 6 个 MOSFET 通

态电阻的阻值, 构建不同参数组合以模拟器件软故障状态。通态电阻变化范围设定为 5% ~ 30%, 步长为 5%, 覆盖 MOSFET 从早期老化到中期退化的典型软故障阶段, 每个器件对应 6 种状态。各开关器件通态电阻变化相互独立, 理论上可形成 $6^6 = 46\ 656$ 种参数组合状态, 受实验资源和计算复杂度限制, 本文选取其中两类具有代表性的组合开展研究: 相同幅值任意器件组合的对称组合和不同幅值上下桥臂组合的非对称组合。

对称组合以变化幅度相同和变化器件数量不同为分层标准, 覆盖了从单器件到多器件乃至全器件变化的情况, 用于分析相同退化程度下不同器件组合对系统性能的影响, 共包含 378 种组合。非对称组合以桥臂位置 and 变化幅度差异为分层标准, 通过设置上下桥臂不同退化程度的组合, 研究非对称参数变化对电路性能的影响特性, 如桥臂电流不平衡引发的热风险及中点电位波动对输出电流畸变的影响, 共包含 270 种组合。结合一组正常工况数据, 最终构建包含 649 种参数状态的数据集。

利用仿真获取每组参数状态对应的输出电压信号, 采样周期为 0.1 ms, 采样点数为 5 000; 鉴于输出电压为带脉动的直流信号, 为确保数据有效性, 选取信号波动平稳部分, 截取稳态段的后 3 000 个采样点, 构成实验的原始数据集。

基于 PCC 和 MI 两种度量指标构建联合评估体系,在此之前将原始数据集按照训练集:验证集:测试集=8:1:1的比例划分,确保数据集的独立性。首先计算训练集上所有时域和频域特征与目标参数之间的皮尔逊相关系数 ρ_{XY} 和互信息 I ;接着在验证集上进行网格搜索,选择在整体平均相对误差与特征维度之间取得最佳平衡时的阈值;最后根据预设的最佳阈值筛选出与参数变化关联紧密的候选特征,每个通态电阻的优选特征如表 2 所示。

2.2 多参数辨识性能分析

采用决定系数 (R-square, R^2)、均方误差 (mean square error, MSE)、均方根误差 (root mean square error, RMSE)、平均绝对误差 (mean absolute error, MAE)、平均相对误差 (mean relative error, MRE) 和最大相对误差 (maximum relative error, Max-re) 共 6 类指标对模型进行

表 2 各 MOSFET 通态电阻的关键特征
Table 2 Key features of the on-state resistance for each MOSFET

通态电阻编号	优选特征	特征数量
$R_{DS(on),1}$	$e_1 \sim e_4, e_7, e_8, r, m, s, k$	10
$R_{DS(on),2}$	$e_1 \sim e_8, m, \sigma^2, s, e$	12
$R_{DS(on),3}$	$e_1, e_3, e_4, e_5, e_7, e_8, r, m, \sigma^2, s, k, e, c$	13
$R_{DS(on),4}$	$e_4 \sim e_8, r, s, k$	8
$R_{DS(on),5}$	$e_1, e_5 \sim e_8, r, m$	7
$R_{DS(on),6}$	$e_2 \sim e_5, e_7, e_8, r, m, e, c$	10

性能评估。为了避免由于网络不稳定造成辨识结果的不确定性,针对每个待辨识参数都进行 10 次独立辨识,最终结果取 10 次实验的平均值,辨识结果如表 3 所示。

表 3 多参数辨识结果评估
Table 3 Evaluation of multi-parameter identification results

多参数辨识结果	R^2	$MSE(10^{-6})$	RMSE	MAE	MRE/%	Max-re/%
$R_{DS(on),1}$	0.958	1.871	0.001 37	0.001 05	0.960	4.164
$R_{DS(on),2}$	0.965	1.705	0.001 31	0.001 00	0.938	4.273
$R_{DS(on),3}$	0.964	1.690	0.001 30	0.000 98	0.905	5.159
$R_{DS(on),4}$	0.963	1.810	0.001 35	0.001 04	0.979	4.100
$R_{DS(on),5}$	0.953	2.108	0.001 45	0.001 11	1.050	4.480
$R_{DS(on),6}$	0.960	1.758	0.001 33	0.001 01	0.940	4.314
平均值	0.961	1.824	0.001 35	0.001 03	0.962	4.415

从表 3 可得,所提方法在所有待辨识参数上均取得优异性能。为了更直观地表示本文提出辨识方法的有效

性,绘制了 KAN 与 KAN-HGT 模型的预测误差箱线图如图 4 所示。




图 4 KAN 与 KAN-HGT 预测误差箱线图
Fig. 4 Prediction error box plots of KAN and KAN-HGT

KAN-HGT 的误差箱体相较于 KAN 显著缩小,上须线均控制在 0.005 以内,且离群点数量大幅减少,表明 HGT 残差补偿机制有效提升了辨识的一致性与稳定性。

结合辨识结果与箱线图,KAN-HGT 在误差幅度、样本间稳定性以及器件间一致性方面均显著优于单独使用 KAN 的模型。说明 HGT 引入的补偿机制能够有效改善初

始辨识结果,使 MOSFET 通态电阻的参数辨识更加精确。

2.3 对比分析

1) 基于不同特征参数辨识

为验证本文提出的 PCC 与 MI 联合特征优选方法的有效性,设计 3 类不同的特征与本文提出的关键特征作对比实验:(1)全部的时域特征与频域特征;(2)仅使用 PCC 进行特征提取;(3)仅使用 MI 进行特征提取;(4)本文融合策略。

用上述 4 类特征分别训练第 1 阶段的 KAN 神经网络,针对每个待辨识参数都进行 10 次独立辨识,结果用测试集的平均相对误差来表示,不同特征类型的参数辨识结果如表 4 所示。

表 4 基于不同特征类型的参数辨识结果
Table 4 Parameter identification results based on different feature types

平均相对误差/%	第 1 类特征	第 2 类特征	第 3 类特征	本文特征
$R_{DS(on),1}$	7.652	5.242	5.690	4.454
$R_{DS(on),2}$	8.001	5.725	6.091	4.413
$R_{DS(on),3}$	6.915	5.754	5.433	4.277
$R_{DS(on),4}$	6.848	6.162	5.802	4.459
$R_{DS(on),5}$	7.252	6.253	6.571	4.250
$R_{DS(on),6}$	7.271	5.745	5.909	4.807
平均值	7.323	5.814	5.916	4.443

表 4 结果表明,本文特征的辨识精度显著优于其他对比方法。第 1 类采用全部时域与频域特征,由于包含了部分与待辨识参数无关的冗余及噪声信息,导致模型过拟合,辨识误差较大;第 2 类与第 3 类特征分别仅采用皮尔逊相关系数或互信息进行筛选,前者侧重于线性关联特征,后者侧重于非线性依赖特征,二者虽通过降维提升了部分性能,但因筛选视角单一,遗漏了部分关键信息,辨识精度相近但均有限;融合策略辨识结果优于单一指标或全特征输入,这验证了其在抑制冗余、保留敏感信息方面的优势。

2) 基于不同模型架构的参数辨识

为验证本文提出的 KAN-HGT 模型的优势,设计了包括纯数据驱动模型、纯图模型和两阶段混合模型 3 类对比试验,具体如下:

纯数据驱动:MLP-Only、ConvNeXt-Only^[22]和 KAN-Only;

纯图模型:纯图注意力神经网络(graph attention network-Only,GAT-Only);CktGNN-Only^[17]和 HGT-Only;

两阶段混合模型:MLP-GAT、KAN-GAT、MLP-HGT、KAN-CktGNN、ConvNeXt-HGT 和 KAN-HGT。

用于实验的特征均为本文提取的关键特征,针对每个待辨识参数进行 10 次辨识,参数辨识结果使用测试集的平均相对误差来表示。不同模型架构的参数辨识结果如表 5 所示。

根据表 5 中结果,本文提出的 KAN-HGT 模型在参数辨识精度上显著优于其他对比方法。

表 5 基于不同模型架构的参数辨识结果
Table 5 Parameter identification results based on different model architectures

平均相对误差/%	MLP-Only	ConvNeXt-Only	KAN-Only	GAT-Only	CktGNN-Only	HGT-Only	MLP-GAT	KAN-GAT	MLP-HGT	KAN-CktGNN	ConvNeXt-HGT	KAN-HGT
$R_{DS(on),1}$	5.242	4.861	4.325	3.897	3.504	3.548	3.388	2.905	2.271	3.086	2.067	1.035
$R_{DS(on),2}$	5.725	5.321	4.297	3.677	3.687	3.308	3.565	2.682	2.043	2.956	1.992	1.078
$R_{DS(on),3}$	5.754	4.875	4.252	4.340	4.035	3.698	3.552	3.382	2.942	2.735	2.146	0.965
$R_{DS(on),4}$	5.576	4.926	4.338	3.413	3.753	3.380	3.087	3.025	3.260	3.144	2.004	0.945
$R_{DS(on),5}$	6.155	5.035	4.112	3.912	3.546	3.543	3.553	3.007	3.334	2.984	1.845	0.987
$R_{DS(on),6}$	6.015	4.878	4.168	3.957	3.888	3.165	3.247	3.271	2.316	2.888	2.168	1.006
平均值	5.745	4.983	4.248	3.866	3.736	3.440	3.399	3.045	2.694	2.966	2.037	1.002

纯数据驱动模型由于完全忽略了电路拓扑结构信息,仅从特征数据中学习映射关系,无法有效利用元器件间的物理约束,导致辨识误差较大,而 KAN 神经网络使用可学习的激活函数,其拟合效果相较于 MLP 和

ConvNeXt 更强,故辨识效果优于另外两种。纯图模型通过引入图结构,利用电路的拓扑结构信息,使辨识精度有所提升,但 GAT 中构建的是同质图,把所有节点和边当作同一类型,相较于 HGT 中构建的异质图,同质图削弱

了关键元件特性的区分度,所以 GAT 的辨识效果逊于 HGT,而 CktGNN-Only 专为电路设计,利用图分解引入一定的电路先验,效果略优于 GAT。混合模型结合初步辨识和补偿辨识两部分,效果普遍优于独立的辨识网络。其中两组同质图 GAT 组合架构相较于异质图 HGT 组合架构效果略差,KAN-HGT 通过结合异质图的结构建模能力和 KAN 网络的函数拟合优势,能同时捕捉参数间的拓扑约束关系与复杂非线性特征,从而实现了最优的辨识精度。

为进一步验证两阶段混合架构相较于单独使用 HGT 的优势,本文在上述对比基础上,补充了 KAN、HGT 与 KAN-HGT 在辨识精度与训练时间上的综合对比。结果如表 6 所示,其中训练时间为模型在相同硬件环境下的平均单次训练耗时。

表 6 模型的辨识精度与训练时间对比

Table 6 Comparison of identification accuracy and training time of different models

模型	辨识误差/%	训练时间/s
KAN-Only	4.213	152.109
HGT-Only	3.426	250.375
KAN-HGT	1.011	211.269

表 7 基于不同图结构的参数辨识结果

Table 7 Parameter identification results based on different graph structures

平均相对误差/%	移除电源节点	移除电感节点	移除电容节点	同质图(GAT)	完整异质图
$R_{DS(on),1}$	2.710	3.139	3.388	2.841	0.996
$R_{DS(on),2}$	2.943	3.315	3.565	2.656	1.036
$R_{DS(on),3}$	3.547	3.301	3.552	2.288	0.979
$R_{DS(on),4}$	3.368	3.679	4.087	2.545	1.029
$R_{DS(on),5}$	3.167	3.812	4.553	2.871	0.945
$R_{DS(on),6}$	2.815	3.578	3.947	2.291	1.050
平均值	3.092	3.471	3.849	2.582	1.006

了关键元件特性的区分度,模型需要在特征中隐式区分不同元件,无法准确建模电路中的异构关系,导致误差略有增大,验证了异质图的优势。而移除任一储能元件节点使图结构不完整均导致误差显著上升,验证了所提图结构的完整性与物理合理性。

2.4 硬件实验与泛化性验证

为验证所提出的 KAN-HGT 两阶段参数辨识网络在真实系统中的泛化能力,搭建如图 5 所示的硬件实验平台进行泛化性实验,平台共包括三相整流电路模块、电子负载、电源模块、DSP 模块以及上位机等多个关键模块。

KAN-Only 因为其较好的非线性映射能力,可以在较短时间内达到最优效果,而 HGT-Only 因为要完成非线性映射以及后续的系统耦合,训练时间最长。两阶段的 KAN-HGT,在各自对应阶段完成任务,训练时间介于 KAN-Only 与 HGT-Only 之间,且精度相较于二者达到了更低的误差。

综上所述,本文提出的 KAN-HGT 两阶段架构是基于解析复杂任务、发挥各自优势、提升整体性能的设计思想,通过分工明确的建模策略,在精度、训练效率之间取得了更好的平衡。

3) 基于不同图结构的参数辨识

为验证异质图构建的必要性以及本文构建图结构的完整性,设计了 4 种图结构变体与本文构建的完整异质图做对比实验:(1)移除电源节点;(2)移除电感节点;(3)移除电容节点;(4)同质图(使用 GAT)。

实验均为两阶段 KAN-HGT,用于实验的特征为本文提取的关键特征集,针对每个待辨识参数都进行 10 次辨识,参数辨识结果使用测试集的平均相对误差来表示。不同图结构的参数辨识结果如表 7 所示。

根据表 7 中结果,完整保留电源、电感、电容等异质节点及其连接关系,能够最充分地刻画电路的物理拓扑与元件语义,在参数辨识精度上显著优于其他对比方法。同质图虽保留了完整拓扑,但不区分节点与边类型,削弱




图 5 硬件实验平台

Fig. 5 Hardware experimental platform

在硬件实验中选用英飞凌型号为 IRF3710PBF 的 MOSFET 作为实验对象,标称通态电阻值为 $R_{DS(on)} = 23\text{ m}\Omega$ 。取 6 个 MOSFET 分为 3 组,放入不同温度的高温老化实验箱内进行退化,冷却到室温后,对每只器件进行参数真值测量:采用标准静态导通测试流程,使用四线 Kelvin 取样消除引线与接触电阻影响,得到各器件的通态电阻值作为参考真值,便于后续进行辨识误差统计,元器件参数如表 8 所示。

表 8 硬件实验元器件参数

Table 8 Parameters of hardware experimental components

元器件	老化温度/℃	参数值/mΩ	参数偏差比例/%
$R_{DS(on),1}$	80	24.15	+5
$R_{DS(on),2}$	80	24.84	+8
$R_{DS(on),3}$	100	25.99	+13
$R_{DS(on),4}$	100	26.91	+17
$R_{DS(on),5}$	120	27.83	+21
$R_{DS(on),6}$	120	28.98	+26

将 6 个 MOSFET 随机组合 20 组,通过替换元器件的方式注入到三相 SVPWM 整流电路中,利用 DSP 模块中集成的 AD 转换单元获取三相整流电路在不同参数组合下的输出电压,采样数据经过 DSP 处理后通过接口传输给上位机。从硬件实验平台获取的输出电压数据充当实测集,以全面评估验证所构建模型的参数辨识精度和泛化能力。结果用 20 组数据每个 MOSFET 通态电阻的平均相对误差来表示,硬件实验参数辨识结果如表 9 所示。

表 9 硬件实验参数辨识结果

Table 9 Hardware experimental parameter identification results

平均相对误差/%	KAN	KAN-HGT
$R_{DS(on),1}$	5.353	1.994
$R_{DS(on),2}$	5.139	1.863
$R_{DS(on),3}$	4.932	2.081
$R_{DS(on),4}$	5.114	1.984
$R_{DS(on),5}$	5.267	1.836
$R_{DS(on),6}$	5.425	2.194
平均值	5.205	1.992

由于实际运行中,存在采样误差和环境因素的影响,导致硬件实验的相对误差率略高于仿真实验的结果,但仍能够有效地表明本文提出的参数辨识方法具有较好的多元器件参数辨识效果。

2.5 可解释性分析

为了验证本文所提出模型的可行性,本节从特征选择机制和电路拓扑耦合关系两个维度开展系统性可解释性分析。揭示模型内部特征作用机制与结构依赖关系,确保辨识结果不仅高精度,且具备清晰的物理解释路径。

1) 特征选择的可解释性分析

本文采用 PCC 与 MI 相结合的策略筛选关键特征,旨在同时捕捉特征与目标之间的线性与非线性关联。为进一步验证该策略的合理性,使用 SHAP 方法量化各特征在 KAN 初步辨识模型中的边际贡献,实现对模型的后验解释。

以 $R_{DS(on),1}$ 为例(其余器件行为类似),图 6 分别展示了原始特征集的 PCC、MI 指标以及 SHAP 重要性排序结果。




图 6 特征重要性排序对比

Fig. 6 Comparison of feature importance rankings

在全部特征中,特征 e_5 在 SHAP 归因中表现突出,尽管其在统计相关性排序中并不占优。这说明 e_5 属于交互增强型特征,其个体预测能力有限,但在复杂的模型结构中能通过协同效应提升预测精度。相比之下,均值和偏度等特征虽在统计层面表现显著,但因其携带的信息与其他强特征重叠或共线冗余,导致其在 SHAP 边际贡献评价中被弱化。

整体来看,统计指标与模型解释之间存在排序差异,主要是因为统计指标更关注特征与目标变量的直接线性和非线性关联,而 SHAP 更注重特征在模型内部的实际贡献。在优选特征子集内, e_2 、 e_4 、 e_8 、 e_3 、 e_7 、纹波幅值、 e_6 等特征依旧保持较高的 SHAP 值,说明本文的筛选策略具有一定的合理性和稳定性。

为验证 e_5 与其他特征的交互关系,绘制了 e_5 与 e_2 的依赖图如图 7 所示。




图 7 e_5 特征依赖图
Fig. 7 Feature dependency graph of e_5

样本点随 e_5 取值增加呈现明显的上升趋势,表明 e_5 对模型输出具有正向贡献。图 7 中样本点的颜色映射了特征 e_2 的取值大小,低 e_2 样本与高 e_2 样本点分别在左下与右上区域聚集,反映出 e_5 与 e_2 之间存在正相关。在 e_5 取值相同的区间内,高 e_2 样本对应的 SHAP 值普遍高于低 e_2 样本,这说明 e_2 对模型中 e_5 的影响具有调节作用,模型对 e_5 的依赖程度会随 e_2 的变化而改变,表现出特征交互效应,揭示了两者在模型决策过程中的协同贡献机理。

但 SHAP 重要性排序高低,仅表明该特征对模型预测结果的影响程度大小,不代表这种影响是否有利,即不直接等同于对模型性能有正向或反向帮助,也不代表特征本身对预测目标有积极或消极作用。故这里对 $R_{DS(on),1}$ 的特征进行特征剔除和补充验证。

在独立的 KAN 神经网络中设置 3 组不同的特征子集,每组运行 10 次比较 3 组特征的参数辨识结果。3 组特征子集分别是:

第 1 组保持原优选特征不变($e_1 \sim e_4$, e_7 , e_8 , r , m , s , k);第 2 组添加 e_5 (SHAP 重要性排名第 1);第 3 组剔除偏度 s 和均值 m (SHAP 重要性排名最低);辨识结果如表 10 所示。

表 10 $R_{DS(on),1}$ 特征剔除与补充辨识结果
Table 10 Feature removal and supplementation identification results of $R_{DS(on),1}$

平均相对误差/%	第 1 组	第 2 组	第 3 组
1	4.073	4.210	4.090
2	4.211	4.120	4.609
3	3.782	4.291	4.687
4	3.924	4.152	6.298
5	3.972	3.913	3.453
6	3.771	4.386	3.993
7	3.938	4.014	5.181
8	4.187	4.338	3.488
9	4.082	4.028	5.654
10	4.191	4.036	4.871
平均值	4.013	4.149	4.632

第 2 组添加 e_5 后误差略有增加,辨识波动区间与第 1 组相近,整体较为稳定。第 3 组剔除偏度和均值之后误差增大,且可以观察到 10 次结果中出现极好极坏的情况,波动也明显增大,说明偏度和均值这两项虽在 SHAP 全局重要性中靠后,但对模型稳定性和鲁棒性起到护栏作用。综上分析,本文提出的融合皮尔逊与互信息的特征优选策略有效保留了主要敏感特征,而 SHAP 分析进一步揭示了特征交互与稳定性机制,验证了本文提出特征优选方法的可靠性。

2) 电路拓扑耦合分析

基于边的注意力权重分析,验证 HGT 模型在边级回归任务中利用了电路拓扑的耦合信息,而非把每条开关边当作独立的样本。选取直接建模原始电路拓扑邻接关系的第 1 层 HGT 的注意力权重进行分析,开关导通路径之间的注意力热力图如图 8 所示。

图中横纵轴分别代表 6 个 MOSFET 开关边($Q_1 \sim Q_6$),从冷色到暖色表示注意力权重由低到高。为了突出开关之间的相互作用,在可视化时关闭了自环,开关边的注意力是在其邻接的电源、电感、交流节点和直流母线等异质节点信息基础上计算并聚合得到的,因此边与边之间的影响实际上已经隐含了周围异质拓扑结构的综合作用。




图8 HGT第1层开关导通路径间注意力热力图

Fig. 8 Attention heatmap between switching conduction paths in the first layer of HGT

从图8中可以看出,互补对管对应的开关组合($Q_1 \sim Q_4$ 、 $Q_3 \sim Q_6$ 、 $Q_5 \sim Q_2$)颜色最暖,说明重点关注了上下桥臂之间的互补导通关系,是整流电路中最强的耦合关系。同极性节点(上桥臂 $Q_1 \sim Q_3 \sim Q_5$ 、下桥臂 $Q_2 \sim Q_4 \sim Q_6$)之间的影响强度处于中等水平,表明模型能够捕捉同极性开关间因共母线电压和负载回路带来的耦合效应。跨相、异极性节点之间注意力权重较低,说明模型并未在无物理连接的节点间传播信息,体现出较好的结构选择性。

热力图出现部分不对称,主要因为HGT采用基于元关系的有向注意力机制,不同传播方向在各自邻域内独立归一化。从而导致信息沿 $Q_i \rightarrow Q_j$ 与 $Q_j \rightarrow Q_i$ 两个方向传播时的重要性并不完全相同。这种不对称性进一步反映了电路异质拓扑中不同传播方向及相间耦合作用的差异。

综上,HGT通过异质图注意力机制,有效学习了电力电子电路中的物理耦合规律,而非将各器件视为独立样本,充分体现了拓扑感知建模的优势。

3 结论

本文围绕电力电子系统中功率器件参数辨识精度不高、拓扑结构利用不足以及模型可解释性欠缺等核心问题,提出了一种融合KAN与HGT的两阶段参数辨识方法。通过构建包含时域统计特征与小波包频域特征的多维特征集合,结合PCC与MI的联合特征优选策略进行关键特征提取,显著提升了特征集的敏感性与辨识有效性。利用并行多输入单输出KAN子网络实现

MOSFET通态电阻的初步辨识,再通过电路物理结构构建异质图模型,引入HGT对残差进行结构化补偿,实现了精确参数辨识。最后用SHAP从特征选择机制和电路拓扑耦合关系两个维度开展可解释性分析,确保参数辨识结果具有物理一致性与工程可信度。实验结果表明,所提出的KAN-HGT框架在 R^2 、MAE、MRE等多个性能指标上均显著优于传统神经网络、同质图模型和其他组合式辨识方法,表明该方法能够有效处理电力电子系统中多参数辨识任务,在硬件实验中也表现出良好的稳定性与鲁棒性。该方法为构建兼具高精度、结构感知与可解释性的电力电子系统参数辨识模型提供了一种有效途径。

参考文献

- [1] PEYGHAMI S, PALENSKY P, BLAABJERG F. An overview on the reliability of modern power electronic based power systems[J]. IEEE Open Journal of Power Electronics, 2020, 1: 34-50.
- [2] 姜月明. DC-DC变换器软故障诊断及参数辨识研究[D]. 哈尔滨: 哈尔滨工业大学, 2021.
JIANG Y M. Research on soft fault diagnosis and parameter identification of DC-DC converter [D]. Harbin: Harbin Institute of Technology, 2021.
- [3] 石欣, 张夏恒, 朱雅亲, 等. 基于VMD-NARX的MOSFET剩余使用寿命预测方法[J]. 仪器仪表学报, 2023, 44(9): 275-286.
SHI X, ZHANG X H, ZHU Y Q, et al. Remaining useful life prediction method for MOSFET based on VMD-NARX [J]. Chinese Journal of Scientific Instrument, 2023, 44(9): 275-286.
- [4] LIANG J P, ZHANG K, AL-DURRA A, et al. A state-of-the-art review on wind power converter fault diagnosis[J]. Energy Reports, 2022, 8: 5341-5369.
- [5] YAO K, LI H, LI L, et al. A noninvasive online monitoring method of output capacitor's C and ESR for DCM flyback converter[J]. IEEE Transactions on Power Electronics, 2019, 34(6): 5748-5763.
- [6] 陈小涛, 张文斌, 索春光, 等. 基于双路参考激励信号参数辨识的非接触电压测量方法[J]. 仪器仪表学报, 2025, 46(3): 20-29.
CHEN X T, ZHANG W B, SUO CH G, et al. Non-contact voltage measurement method based on parameter identification of dual reference excitation signals [J]. Chinese Journal of Scientific Instrument, 2025, 46(3): 20-29.

- [7] AMARAL A M R, LAADJAL K, MARQUES CARDOSO A J. Optimized preventive diagnostic algorithm for assessing aluminum electrolytic capacitor condition using discrete wavelet transform and Kalman filter[J]. *Electronics*, 2024, 13(16): 3265.
- [8] 朱琴跃, 李姚霖, 谭喜堂, 等. 基于逆变器多模态输出电压的 IGBT 微小故障特征提取[J]. *电机与控制学报*, 2023, 27(1): 65-79.
ZHU Q Y, LI Y L, TAN X T, et al. Extraction of IGBT incipient fault features based on multi-mode output voltage of inverter[J]. *Electric Machines and Control*, 2023, 27(1): 65-79.
- [9] 朱文昌, 李振璧, 姜媛媛. 联合 VMD 与 ISSA-ELM 的电力电子电路软故障诊断[J]. *电子测量与仪器学报*, 2022, 36(5): 223-233.
ZHU W CH, LI ZH B, JIANG Y Y. Soft fault diagnosis of power electronic circuits combined with VMD and ISSA-ELM[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(5): 223-233.
- [10] 唐圣学, 马晨阳, 勾泽. 基于时频特征融合与 GWO-ELM 的棒控电源早期故障状态辨识方法[J]. *仪器仪表学报*, 2023, 44(1): 121-130.
TANG SH X, MA CH Y, GOU Z. Early fault state identification method of rod control power supply based on time-frequency feature fusion and GWO-ELM [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(1): 121-130.
- [11] 杨东儒, 魏建文, 林雄威, 等. 基于自注意力机制的深度学习模拟电路故障诊断[J]. *仪器仪表学报*, 2023, 44(3): 128-136.
YANG D R, WEI J W, LIN X W, et al. Deep learning analog circuit fault diagnosis based on self-attention mechanism[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(3): 128-136.
- [12] 姜月明, 俞洋, 彭喜元. 基于关键特征提取和 Elman 神经网络的开关电源多参数辨识[J]. *电子测量与仪器学报*, 2021, 35(7): 11-19.
JIANG Y M, YU Y, PENG X Y. Multi-parameter identification of switching power supply based on key feature extraction and Elman neural network[J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(7): 11-19.
- [13] SOUALHI A, MAKDESSI M, GERMAN R, et al. Heath monitoring of capacitors and supercapacitors using the neo-fuzzy neural approach [J]. *IEEE Transactions on Industrial Informatics*, 2017, 14(1): 24-34.
- [14] LI Y ZH, XUE CH, ZARGARI F, et al. From graph theory to graph neural networks (GNNs): The opportunities of GNNs in power electronics[J]. *IEEE Access*, 2023, 11: 145067-145084.
- [15] KHAMIS A K, AGAMY M. Circuit topology aware GNN-based multi-variable model for DC-DC converters dynamics prediction in CCM and DCM[J]. *Neural Computing and Applications*, 2024, 36(33): 20807-20822.
- [16] KHAMIS A K, AGAMY M. A heterogeneous graph framework for ml applications in electric circuits [C]. *IECON 2024-50th Annual Conference of the IEEE Industrial Electronics Society*. Chicago, 2024: 1-6.
- [17] DONG Z H, CAO W D, ZHANG M H, et al. CktGNN: Circuit graph neural network for electronic design automation [J]. *ArXiv preprint arXiv: 2308.16406*, 2023.
- [18] CAO X M, YANG R F, GUO CH X, et al. Conditional enhanced variational autoencoder-heterogeneous graph attention neural network: A novel fault diagnosis method for electric rudders based on heterogeneous information[J]. *Sensors*, 2024, 24(1): 272.
- [19] LIU Z M, WANG Y X, VAIDYA S, et al. KAN: Kolmogorov-Arnold networks[J]. *ArXiv preprint arXiv: 2404.19756*, 2024.
- [20] HU Z N, DONG Y X, WANG K S, et al. Heterogeneous graph transformer[J]. *ArXiv preprint arXiv: 2003.01332*, 2020.
- [21] LUNDBERG S M, LEE S I. A unified approach to interpreting model predictions [C]. *Advances in Neural Information Processing Systems*, 2017.
- [22] LIU ZH, MAO H Z, WU CH Y, et al. A ConvNet for the 2020s [C]. *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022: 11976-11986.

作者简介



刘金凤, 2001 年于东北农业大学获得学士学位, 2004 年于东北农业大学获得硕士学位, 2011 年于哈尔滨理工大学获得博士学位, 现为哈尔滨理工大学副教授, 主要研究方向为电力电子驱动控制与仿真等。

E-mail: liujinfeng@hrbust.edu.cn

Liu Jinfeng received her B.Sc. degree from Northeast Agricultural University in 2001, M.Sc. degree from Northeast Agricultural University in 2004, and Ph.D. degree from Harbin

University of Science and Technology in 2011. She is currently an associate professor at Harbin University of Science and Technology. Her main research interests include power electronics, drive control, simulation and so on.



李金枝 (通信作者), 2024 年于河南工程学院取得学士学位, 现为哈尔滨理工大学硕士研究生, 主要研究方向为功率器件参数辨识。

E-mail: ljzhhjy@163.com

Li Jinzhi (Corresponding author) received her B. Sc. degree from Henan University of Engineering in 2024. She is currently a master's student at Harbin University of Science and Technology. Her main research interest includes parameter identification of power devices.



Herbert Ho-Ching Iu, 1997 年于香港大学获得学士学位, 2000 年于香港理工大学获得博士学位, 现为西澳大利亚大学教授, 主要研究方向为功率器件驱动控制、忆阻器建模与逻辑电路应用。

E-mail: herbert.iu@uwa.edu.au

Herbert Ho-Ching Iu received his B. Sc. degree from The University of Hong Kong in 1997, and received his Ph. D. degree from The Hong Kong Polytechnic University in 2000. He is currently a professor at The University of Western Australia. His main research interests include power device drive control, memristor modeling and logic circuit applications.