

DOI: 10.19650/j.cnki.cjsi.J2513895

多线圈联合学习的核电厂控制棒驱动机构动作 状态异常检测方法*

林蔚青, 缪希仁, 江 灏, 叶铭新, 陈 静
(福州大学电气工程与自动化学院 福州 350108)

摘 要:控制棒驱动机构(CRDM)作为核电厂的关键执行部件,通过电磁-机械耦合控制多组线圈电流信号,以实现控制棒精准动作,其健康状态关乎反应堆安全运行。然而,现有 CRDM 异常检测方法主要聚焦于单组线圈建模,未充分考虑多线圈间的变化规律和动态模式。为此,提出一种多线圈联合学习(MCJL)模型,旨在精准检测控制棒动作过程中的潜伏性异常。首先,定义线圈节点和全连接边,并引入衰减邻接矩阵,以构建多线圈联动图结构,进而表征 CRDM 内部提升线圈、移动线圈和保持线圈间的动态耦合关系。其次,采用移动图卷积网络,以高效捕获多线圈间的局部时序依赖关系,并协同重构 3 组线圈的电流信号。最后,通过计算重构信号和真实信号间的残差,利用多尺度动态检测策略实现 CRDM 逐个动作周期的异常检测。对某地区压水堆机组的历史监测数据与模拟异常样本进行算例分析,表明该方法可有效捕获多线圈间的动态耦合关系并提取驱动机构动作的时序特征,实现电流信号的精准重构。相较于多种异常检测方法,所提 MCJL 模型在信号重构和异常检测方面具有更优越的性能,其动态阈值策略可灵活调整决策边界,具有较强的容错能力。

关键词:核电厂;控制棒驱动机构;异常检测;图卷积网络;动态阈值

中图分类号: TM623.7 TH132 **文献标识码:** A **国家标准学科分类代码:** 490.25

Anomaly detection method for motion status of control rod drive mechanism in nuclear power plants by multi-coil joint learning

Lin Weiqing, Miao Xiren, Jiang Hao, Ye Mingxin, Chen Jing

(College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China)

Abstract:Control rod drive mechanisms (CRDMs), as critical actuators in nuclear power plants, regulate control rod motion by manipulating multiple coil currents through electromagnetic-mechanical coupling. Their operational integrity is vital for ensuring reactor safety. However, existing anomaly detection approaches predominantly model individual coils, neglecting the dynamic interactions among coils and the evolving operational patterns. To address this gap, we propose a multi-coil joint learning (MCJL) model for accurately detecting latent anomalies during control rod operation. In this approach, coil nodes and fully connected edges are defined, and a decay adjacency matrix is introduced to construct a multi-coil interaction graph that captures the dynamic coupling among the lift, moving, and solid coils. A moving graph convolutional network is then employed to efficiently extract local temporal dependencies across coils while jointly reconstructing the current signals of all three coils. The residuals between the reconstructed and actual signals are subsequently calculated, enabling per-cycle anomaly detection using a multi-scale dynamic strategy. Experimental validation using historical data and simulated anomalies from a pressurized water reactor demonstrates that the proposed method effectively captures dynamic inter-coil coupling and temporal patterns, achieving high-precision signal reconstruction. Compared with existing methods, MCJL exhibits superior performance in both reconstruction and anomaly detection. Furthermore, its dynamic thresholding strategy provides flexible decision boundaries and strong fault tolerance.

Keywords:nuclear power plant; control rod drive mechanism; anomaly detection; graph convolution network; dynamic threshold

0 引 言

核电作为我国“双碳”战略与能源结构优化的重要

基荷电源,具有发电量稳定和高能源密度等特点^[1]。控制棒驱动机构(control rod drive mechanism, CRDM)是核电厂反应堆的关键执行部件,负责调节控制棒的位置,以控制堆芯功率与安全停堆。CRDM 依托磁力驱动原理运

行,通过对3组线圈(提升、移动和保持线圈)施加时序电流信号实现精确动作^[2]。若电流信号出现幅值偏低或过渡滞后等现象,可能使CRDM驱动力不足,控制棒无法达到目标位置^[3]。若未能及时识别并处理该类异常,可能导致控制棒掉落或操作失效等问题,严重影响反应堆的安全性及稳定性。

CRDM的动作主要通过电流的交替通断实现提升和下插动作。传统的CRDM异常检测方法常采用固定阈值法和变化率判别法进行检测。此外,运维人员定期开展动棒测试,以评估控制棒的动作状态并判断是否卡涩或失灵。然而,此类方法灵活性较差,难以辨识细微的驱动机构动作异常。随着核电厂数字化技术的快速发展,凭借数据分析技术开展CRDM动作状态异常检测研究,有助于提升堆芯关键设施的安全监测能力^[4-5]。

迄今,国内外学者围绕CRDM动作状态异常检测开展了相关研究^[6-7],早期研究主要聚焦于信号处理技术以构建异常判据。昌正科等^[8]基于步序及动作时间判据,实现CRDM在线诊断;彭翠云等^[9]采用时域和频域分析方法,提取CRDM运动异常的敏感特征量,并构建异常检测规则;谢细明等^[10]通过试验分析线圈电感值与动作部件状态的对应关系,并利用CRDM模拟异常以检验该方法的有效性。然而,上述方法对专业知识依赖较强,且检测精度有限,难以满足CRDM复杂系统的检测需求。

在特征不明显且具有潜伏性异常的检测任务中,数据驱动方法凭借卓越的特征提取能力和决策性能,展现出广泛的应用前景^[11]。针对核电厂CRDM线圈电流信号异常问题,Chen等^[12]基于长短期记忆的自编码器(long short-term memory-based auto-encoder, LSTM-AE)重构保持线圈的电流信号并计算残差序列,并结合极端梯度提升(extreme gradient boosting, XGBoost)算法识别线圈电流异常区域;Zhang等^[13]结合半软小波阈值、希尔伯特-黄变换和局部平均分解方法,从降噪后的电流信号中提取特征,并利用支持向量机(support vector machine, SVM)进行诊断;Xu等^[14]提出基于门控循环单元自编码器(gate recurrent unit-based autoencoder, GRU-AE)与随机森林(random forest, RF)的方法,以辨识CRDM电流信号中的潜伏性异常。上述研究表明,数据驱动方法并非简单地处理信号,而是解析信号中隐含的内在规律与特征,从而提高检测的精准度。

尽管现有研究已在CRDM异常检测方面取得一定进展,但仍面临技术瓶颈。在实际动作过程中,CRDM通过精准的时序控制,使提升线圈、移动线圈和保持线圈的电流信号交替通断,实现控制棒移动。其动作序列严格遵循电磁-机械耦合时序,展现出稳定的周期性变化规律与动态模式。然而,现有方法仅聚焦于单组线圈建模并分析信号的异常特性,未计及多线圈间的耦合关系,在反

映异常特征及整体客观规律上存在局限性。例如,该方法难以识别CRDM中单组线圈的动作时序错乱异常。为确保准确且全面的检测效果,应充分挖掘CRDM整体的联动关系。

图卷积网络(graph convolutional network, GCN)作为一种先进的深度学习模型,能够传播多对象间的耦合信息,常用于建模空间或抽象实体间的复杂关系,在多个领域均展现出卓越性能,如机器视觉^[15]、局部油温预测^[16]、状态评估^[17]和交通预测^[18]。Lin等^[19]基于GCN提出一种知识引导的时空检测模型,利用核电厂一次回路中各类传感器的耦合关系建立拓扑图结构,并在多种工况下评估该方法的有效性。受此启发,CRDM中3组线圈的电流信号具有天然的动态耦合特性,理论上可借助GCN捕获多线圈间的联动关系。其中,邻接矩阵用于描述线圈间的联结连接,而图卷积运算能够提取其局部或全局关联特征。然而,现有研究主要聚焦于多传感器融合下的GCN建模,如何围绕CRDM场景并融入先验知识,以优化建模效果并提升异常检测能力,亟待进一步探索。

本研究以核电厂控制棒驱动机构为研究对象,提出一种多线圈联合学习(multi-coil joint learning, MCJL)模型,旨在精准检测控制棒动作过程中3组线圈(提升、移动和保持线圈)电流信号的异常情况。主要贡献总结为:

1)不同于传统单线圈建模方法,考虑多组线圈间的变化规律和动态模式,构建异常检测模型(MCJL),以精准识别CRDM动作状态异常。

2)基于图论定义线圈节点和全连接边,建立多线圈联动图结构。其中,通过衰减邻接矩阵消除自环计算过程并嵌入时间衰减机制,以客观表征3组线圈间的动态耦合特性。

3)设计多尺度动态检测策略,针对不同尺度信号的波动特性及线圈信号间的量纲差异,动态调整决策边界,确保异常检测的灵活性与准确性。

1 控制棒驱动机构动作状态分析

1.1 控制棒驱动机构动作原理

核电厂控制棒驱动机构(CRDM)作为反应堆控制系统核心执行装置,其通过插入或提升操作来调控堆芯中子通量场分布,实现堆芯功率动态平衡与紧急工况下的快速停堆。如图1(a)和(b)所示,每根棒束,对应一组驱动机构。CRDM布置于压力容器上封头,其机械结构主要由电磁线圈组件(含提升线圈、移动线圈和保持线圈)、磁路部件(衔铁)、传动机构(驱动杆)以及定位组件(移动钩爪与保持钩爪)构成。机构工作原理基于电磁感应效应,当特定线圈组通电激励时,将产生可控电磁场驱动衔铁及钩爪组件完成预设动作^[2]。




图 1 CRDM 结构及动作电流信号
Fig. 1 CRDM structure and motion current signals

CRDM 通过时序控制 3 组线圈 (提升、移动和保持线圈) 电流的交替通断实现控制棒的保持、下插和提升动作。初始状态下,保持线圈通电,控制棒由保持钩爪固定。图 1(c)和(d)分别为下插和提升动作单个周期的电流波形,具体步骤为:

- 1) 下插动作时,历经电磁状态转换 6 个步骤:①提升线圈通电,提升衔铁带动移动衔铁上升;②移动线圈通电,移动衔铁上升并带动移动钩爪进入控制棒凹槽;③保持线圈断电,保持衔铁下降,保持钩爪脱离控制棒凹槽,此时移动钩爪与控制棒啮合;④提升线圈断电,提升衔铁和移动衔铁同时下降,进而带动控制棒下插一步;⑤下插完成后,保持线圈通电,保持衔铁上升并带动保持钩爪进入控制棒凹槽;⑥移动线圈断电,移动衔铁下降,使移动钩爪脱离控制棒凹槽,此时保持钩爪与控制棒啮合,驱动机构恢复初始状态。
- 2) 提升动作时,通过反向时序激活电磁单元:①移动线圈通电,在电磁力的作用下,移动衔铁上升并带动移动钩爪进入控制棒凹槽;②保持线圈断电,保持衔铁失去电磁力而下降,保持钩爪脱离凹槽,此时移动钩爪与控制棒啮合;③提升线圈通电,提升衔铁上升,带动移动衔铁和控制棒提升一步;④提升完成后,保持线圈

通电,保持衔铁上升,保持钩爪进入控制棒凹槽;⑤移动线圈断电,移动衔铁下降,移动钩爪脱离凹槽,此时保持钩爪与控制棒啮合;⑥提升线圈断电,提升衔铁下降,此时控制棒由保持钩爪固定,驱动机构恢复初始状态。

综上,CRDM 展现出固有的周期性变化规律和动态模式,其动作序列严格遵循预设的电磁-机械耦合时序。因此,本文结合先验知识与数据驱动建模思想,联合学习多线圈间的动作关系和状态转换逻辑。

1.2 CRDM 动作状态异常分析

CRDM 动作异常可归因于 2 个方面^[8]:其一,电气控制设备故障引起线圈电流波形异常,可通过线圈电流幅值、纹波、过渡过程进行识别;其二,机械部件磨损或损坏造成的动作异常,可通过线圈电流波形中的动作关键点加以辨识。以保持线圈执行下插动作为例,如图 2 所示,上述异常伴随不同程度的电流特征变化,可归纳为 4 种典型类别^[12-14,20],即:

- 1) 电流大小异常:线圈电流偏离设定范围,表现为电流过载或欠载。过载情况下,线圈温度上升,加速绝缘老化;欠载则导致衔铁驱动力不足,钩爪无法完成正常啮合,影响控制棒动作。




图 2 线圈电流信号典型异常(以保持线圈为例)

Fig. 2 Typical abnormality of coil current signals (the solid coil as an example)

2) 电流过渡异常: 电流升降沿过渡时间异常延长, 破坏既定动作时序。电流切换滞后可能引发钩爪负荷传递错位, 使驱动杆与钩爪发生机械干涉, 严重情况下引发轴面划痕或滑棒事故。

3) 无动作点异常: 正常动作过程中, 衔铁位移及磁隙减小会导致电感瞬间增大, 并在电流上升段形成特征性“凹坑”波形。该特征消失表明钩爪未完成锁定, 可能由机械卡涩或电磁力不足所致。

4) 动作点衔接异常: 控制棒移动一步依靠 3 组线圈电流的精准配合和顺序衔接。若时序错乱, 可能出现钩爪受力异常, 进而导致拉扯、掉棒或升降失效。除图 2(d) 所示的“动作点偏移”异常外, 本文额外考虑现有 CRDM 异常检测研究中较少关注的“动作时序错乱”异常。如图 2(e) 所示, 线圈电流出现整体滞后现象, 将直接导致驱动机构丧失正常动作能力。

案例。该案例中, 第 1 束棒的移动线圈在下插阶段, 虽达到额定电流, 但钩爪吸合动作出现明显延迟。这种机械响应滞后直接反映在线圈电流波形上, 表现为典型的“动作点衔接异常”。




图 3 移动线圈电流异常案例

Fig. 3 Abnormal case of the moving coil current

图 3 展示了核电厂实际运行中记录的线圈电流异常

2 多线圈联合学习的 CRDM 异常检测方法

本研究 MCJL 模型旨在精准检测控制棒驱动机构 (CRDM) 的动作状态异常。如图 4 所示,步骤为:




图 4 多线圈联合学习模型检测流程

Fig. 4 Detection process of the multi-coil joint learning (MCJL) model

3) 引入衰减邻接矩阵,以消除自信息聚合过程,并结合时间衰减机制,进而建立多线圈联动图结构,以刻画 3 组线圈之间的动态耦合关系。

4) 采用移动图卷积网络在滑动窗口内执行图卷积运算,捕捉节点间的局部依赖关系,并协同重构多线圈电流信号。

5) 在 MCJL 模型的后处理阶段,基于多尺度动态检测策略计算 CRDM 单周期重构残差,通过动态统计量与阈值实现异常检测。

2.1 问题定义

针对核电厂控制棒驱动机构实际异常样本稀缺的问题,设计一种无监督学习的异常检测方法,通过学习正常动作状态下提升线圈、移动线圈和保持线圈间的动态耦合关系,实现异常信号的精准识别。

首先,将控制棒驱动机构原始数据集按固定周期划分,单个周期的信号数据为 $\mathbf{X} \in \mathbf{R}^{N \times L}$ 。其中, N 代表线圈数量,即为 3; L 代表一个动作周期的序列长度,即为 833。数据集分为训练集和测试集,训练集仅包含正常动作样本,测试集则包含正常样本及模拟异常样本。将测试数据输入训练好的模型,以实现驱动机构运行状态的判别 y_n 。其中, $y_n \in \{0, 1\}$ 表示第 n 个线圈在该周期的状态为正常 ($y_n = 0$) 或异常 ($y_n = 1$)。

2.2 多线圈联动图结构

本文构建多线圈联动图结构 ($\mathcal{G} = (\mathbf{Z}, \tilde{\mathbf{A}})$), 以表征驱动机构中提升线圈、移动线圈和保持线圈间的动态耦

1) 以 CRDM 单个动作周期的 3 组线圈电流信号为输入,对其进行滤波处理并计算 3 组一阶差分。

2) 将 CRDM 单周期信号及其差分分值划分为多段子序列,输入编码器后,定义线圈节点和全连接边,进而构建差分全连接图。

合关系。该图结构由差分全连接图和衰减邻接矩阵 2 个部分组成。

1) 差分全连接图。如图 5 所示,将单个周期的电流信号及其一阶差分 ($\mathbf{X} \in \mathbf{R}^{2N \times L}$) 划分为多个子序列 ($\{\mathbf{X}_l\}_{l=1}^T$)。单个子序列可表征局部时域信息,使后续模块学习每个子序列内的短期依赖关系。其中, $\mathbf{X}_l \in \mathbf{R}^{2N \times l}$ 代表 $\mathbf{X}$ 中的第 l 个子序列; l 代表子序列长度; T 代表子序列的数量,其通过截断操作 ($\lceil L/l \rceil$) 计算获得。每个 $\mathbf{X}_l$ 包含 N 个线圈信号和一阶差分 ($\mathbf{X}_l = \{\mathbf{x}_{l,i}\}_{i=1}^{2N}$, $\mathbf{x}_{l,i} \in \mathbf{R}^l$)。




图 5 子序列分割与差分全连接图构建

Fig. 5 Subsequence segmentation and differential fully connected graph construction

采用编码器 $f_e(\cdot | \mathbf{W}_e)$ 处理分割的子序列,该编码器由一维卷积构建,在每个信号上操作并提取特征 $(\mathbf{x}'_{t,i})$,此过程由式(1)表示。为了标记不同子序列的相对位置,采用式(2)的正弦位置编码加以特征增强 $(\mathbf{z}_{t,i} = f_p(t) + \mathbf{x}'_{t,i})$ 。

$$\mathbf{x}'_{t,i} = f_e(\mathbf{x}_{t,i} | \mathbf{W}_e) \quad (1)$$

$$\vec{p}_t^{(m)} = f_p(t)^{(m)} := \begin{cases} \sin(\omega_k \cdot t), & m = 2k \\ \cos(\omega_k \cdot t), & m = 2k + 1 \end{cases} \quad (2)$$

式中: $\omega_k = 1/10\,000^{2k/d}$; $f_p(t)^{(m)}$ 表示位置编码; d 代表编码维度; m 代表特征矩阵中的第 m 个特征; $m = 2k$ 和 $m = 2k + 1$ 分别表示偶数和奇数维度。

图(graph)是一种抽象的数学结构,可表示不同对象(节点)间的联结关系(边)。鉴于不同线圈间存在固定的变化规律和动态模式,设计一种差分全连接图 $\mathcal{G} = (\mathbf{Z}, \mathbf{A})$,由线圈节点和全连接无向边构成。其中, $\mathbf{Z} = \{\{\mathbf{z}_{t,i}\}_{i=1}^N\}_{t=1}^T$ 表示多线圈特征矩阵; $\mathbf{A}$ 为邻接矩阵,其元素反映不同时刻子序列之间的相关性。

定义 1: 线圈节点。将提升线圈、移动线圈和保持线圈的电流信号分别抽象为 3 种节点,并将 3 组线圈的一阶差分作为补充节点,以增强电流信号的关键点变化特征。因此,差分全连接图合计有 6 个线圈节点 $(C_1 \sim C_6)$ 。

定义 2: 全连接边。借鉴文献[21]的方法,通过自适应邻接矩阵自主学习两两线圈节点间的相关性。计算公式如式(3)所示。

$$\mathbf{A} = \mathcal{D}(\mathbf{E}_1 \cdot \mathbf{E}_2^T) \quad (3)$$

式中: $\mathcal{D}$ 代表 $L2$ 范数归一化,将相关性约束在 $[0, 1]$ 范围; $\mathbf{E}_1 \in \mathbf{R}^{N \times l \times d_e}$ 和 $\mathbf{E}_2^T \in \mathbf{R}^{d_e \times N \times l}$ 代表随机初始化的嵌入矩阵,均为可训练参数; d_e 为嵌入维度。

差分全连接图($\mathcal{G}$)不仅能刻画同一时间点上各节点之间的耦合关系,还可反映不同时刻节点间的关联性,这有助于建立多线圈间跨时间尺度的联动机制。

2) 衰减邻接矩阵。多线圈联合学习的核心在于建模驱动机构内线圈间的动态耦合关系。当某一线圈电流信号出现异常时,模型仍可通过其他线圈间的关联模式实现异常信号的鲁棒重构。

值得注意的是,传统邻接矩阵构建方式包含自环计算过程,易导致线圈信号重构过度依赖自身信息,且未能体现随时间推移而逐渐减弱的时序相关性。实际上,信号间的相关性在时间间隔扩大时呈现明显衰减趋势。为此,在差分全连接图($\mathcal{G}$)中融入衰减邻接矩阵,不仅消除自信息聚合过程,且嵌入时间衰减机制,从而精准刻画不同时刻节点间关联强度的衰减规律。

图6为衰减邻接矩阵计算的示意图。该邻接矩阵 $(\mathbf{A} \in \mathbf{R}^{(3 \times 3) \times (3 \times 3)})$ 包含 3 个时刻(各含 3 个线圈节点 $C_1 \sim C_3$)。一方面,将各子矩阵对角线元素置零以消除自身信息;另一方面,为不同时刻的子矩阵引入衰减因子

(η),用于控制不同时刻节点间关联强度的衰减速率。以 $t+2$ 时刻的 C_1 节点为例,其与前 3 列(同时刻的节点)的关联强度最高;中间 3 列($t+1$ 时刻的节点)关联强度按 η 衰减;最后 3 列(t 时刻的节点)关联强度按 η^2 进一步衰减。




图6 衰减邻接矩阵计算示意图

Fig. 6 Diagram of the decay adjacent matrix calculation

简而言之,上述过程可表示为邻接矩阵($\mathbf{A}$)与衰减矩阵($\mathbf{A}_{\text{decay}}$)的 Hadamard 积,即:

$$\tilde{\mathbf{A}} = \mathbf{A} \cdot \mathbf{A}_{\text{decay}} \quad (4)$$

最终,生成具有时间渐变特性的衰减邻接矩阵($\tilde{\mathbf{A}}$)和多线圈联动图($\mathcal{G} = (\mathbf{Z}, \mathbf{A})$)。

2.3 移动图卷积网络

在多线圈联动图结构表征驱动机构系统的动态耦合关系后,采用移动图卷积网络(moving graph convolutional network, MGCN)捕捉线圈节点之间的局部依赖关系。

在 MGCN 中,移动窗口的宽度(w_m)和步长(S_m)共同控制时序遍历的密度。以图7中4个时刻(各含4个线圈节点 $C_1 \sim C_4$)为例, $w_m = 2$ 和 $S_m = 1$, 4 个线圈节点进行局部图卷积运算。如式(5)所示,通过衰减邻接矩阵($\tilde{\mathbf{A}}$)与线圈特征矩阵($\mathbf{Z}'_t$)的 Hadamard 积运算,实现跨线圈特征的聚合。

$$\mathbf{O}_t = \theta[\mathbf{W}_m(\tilde{\mathbf{A}} \cdot \mathbf{Z}'_t)] \quad (5)$$

式中: $\mathbf{W}_m$ 代表可训练权重; θ 为 leaky ReLU 激活函数; $\mathbf{O}_t$ 特征聚合后的输出矩阵。

随后,使用平均池化层、拼接操作及全连接层,生成 3 组线圈的重构信号。

2.4 多尺度动态检测策略

在 CRDM 动作状态异常检测中,MCJL 模型对 3 组线圈的电流信号进行重构,并计算重构残差。传统方法常采用静态阈值来判断残差是否超限。然而,该方法存在固有局限性:若阈值设置过高,则难以捕捉细微异常,如 CRDM 无动作点异常和动作点衔接异常;若阈值过




图7 移动图卷积网络示意图

Fig. 7 Diagram of the MGCN

低,则可能因正常间歇性系统波动产生误报警。为此,本文在 MCJL 模型的后处理阶段构建多尺度动态检测策略,使其能够针对不同尺度信号的波动特性及线圈信号间的量纲差异,动态调整决策边界,确保异常检测的灵活性与稳定性。

首先,获得单个动作周期的重构值,并计算相应的重构残差 ($e_{t,i} \in \mathbf{R}^{N \times L}$)。其次,通过 2 种统计量(均值和标准差)量化每个线圈的重构偏差与波动特征。一方面,计算近 w 个周期内每个时刻的均值($\mu_{t,i}$),反映历史重构效果的偏差程度;另一方面,计算对应的标准差($\sigma_{t,i}$),衡量历史重构结果的离散程度。标准差越大,说明信号波动幅度较大,反之亦然。上述过程可由式(6)~(8)表示,即:

$$e_{t,i} = |\hat{y}_{t,i} - y_{t,i}| \quad (6)$$

$$\mu_{t,i} = \frac{1}{w} \sum_{w_i=1}^w e_{t-w_i,i} \quad (7)$$

$$\sigma_{t,i} = \sqrt{\frac{1}{w-1} \sum_{w_i=1}^w (e_{t-w_i,i} - \mu_{t,i})^2} \quad (8)$$

式中: $\hat{y}_{t,i} \in \mathbf{R}^{N \times L}$ 和 $y_{t,i} \in \mathbf{R}^{N \times L}$ 分别代表第 i 个线圈在 t 时刻的重构值和真实值; w 为参与计算动态阈值的周期数。

如式(9)所示,动态阈值($Q_{t,i}$)由均值和标准差构成,该方法可有效平衡异常检测的灵敏度与鲁棒性。

$$Q_{t,i} = \mu_{t,i} + \lambda_i \cdot \sigma_{t,i} \quad (9)$$

式中: λ_i 表示第 i 个线圈的置信因子,其值由核密度估计(kernel density estimation, KDE)在验证集上的残差置信度确定^[22]。KDE 作为一种非参数概率密度估计方法,可提高阈值设定的合理性。

最后,在动态阈值检测过程中引入容错机制以提高鲁棒性,即当连续 10 个残差值超出动态边界($e_{t,i} > Q_{t,i}$)时,判定 CRDM 在该周期发生动作异常。

3 算例分析

本研究数据来源于某地区商用压水堆机组停堆调试期间的控制棒驱动机构(CRDM)线圈电流信号。根据 CRDM 移动最大速度为 72 步/min,经计算可得单步动作时间为 833 ms,即每个动作周期为 $60\,000/72 \approx 833.33$ ms^[8]。

针对 CRDM 的提升线圈、移动线圈和保持线圈电流信号开展异常检测实验,从原始数据中选取 20 组控制棒正常数据,每组包含下插与提升阶段电流信号各 100 个周期,合计 4 000 个完整动作周期(对应 3 332 000 个采样点)。对总样本以 6:1:3 比例划分为训练集、验证集和测试集。

鉴于实际场景中 CRDM 异常样本的稀缺性,本文依据历史检修记录、实际异常案例及相关研究^[8,12-14,20]等信息,采用图 8 所示的 ANSYS Maxwell 仿真与数据增强方式,生成符合第 1.2 节所述异常模式的模拟样本。在测试集随机注入上述 4 种典型的异常样本,保持 1:1 的正常和异常样本比例。




图8 控制棒驱动机构 ANSYS Maxwell 仿真

Fig. 8 ANSYS Maxwell simulation of the CRDM

根据 CRDM 的磁力驱动原理,在 ANSYS Maxwell 仿真中设定不同的参数,以生成不同偏离程度的电流信号异常样本,数据类型为浮点数。具体的仿真异常注入过程为:调节输入电压幅值和线圈电阻,模拟电流大小异常;调节线圈电感值,模拟电流过渡异常;调节驱动部件的质量或机械阻尼系数,模拟无动作点异常;增大机械阻尼系数,模拟动作点衔接异常。

3.1 实验环境及模型参数

实验环境配置如下: Intel Xeon w5-2465X 16 核 CPU、NVIDIA RTX 4090 GPU(搭配 CUDA 12.2 及 CUDNN 8.9.3 加速库)。模型开发基于 Python 3.8 的 Scikit-Learn 0.24.0 与 PyTorch 2.0.1+cu118 框架。

为检验不同模型对 CRDM 线圈电流重构和异常检测的性能,采用平均绝对误差(mean absolute error, δ_{MAE})、对称平均绝对百分比误差(symmetric mean absolute percentage error, δ_{SMAPE})和相对绝对误差(relative absolute error, δ_{RAE})的 3 种指标以评估不同模型的重构精度。采用准确率(precision, δ_{pre})、召回率(recall, δ_{rec})和 $F1$ 值(δ_{F1})的 3 种指标以衡量不同方法的异常检测性能。其中, δ_{MAE} 、 δ_{SMAPE} 和 δ_{RAE} 指标越小,表明模型的重构精度越高; δ_{pre} 、 δ_{rec} 和 δ_{F1} 指标越大,表明异常检测性能越好。本文所提 MCJL 模型参数如表 1 所示,其余对比模型均在验证集上进行参数调优。

表 1 MCJL 模型参数设置

Table 1 Parameter settings of the MCJL model

参数类型	参数名称	参数值	参数名称	参数值
重构参数	输入长度	833	输出长度	833
	批量大小	32	学习率	0.0002
	迭代次数	200	随机失活率	0.1
	子序列长度(l)	33	滑动步长	20
	嵌入维度(d)	2	衰减因子(g)	0.8
检测参数	检测窗口宽度	833	KDE 置信度	99%

3.2 CRDM 动作状态异常检测分析

为验证本研究方法在 CRDM 动作状态异常检测中的有效性,以控制棒的下插过程为例,开展多类型异常检测实验。如图 9 所示,无论在 CRDM 正常还是异常动作情况下,MCJL 模型均能够通过联合学习 3 组线圈固有的变化规律与动态模式,实现精准的信号重构。图 9 下侧的子图中,重构残差和动态阈值由“2.4 多尺度动态检测策略”的式(6)~(9)计算获得。由于控制棒驱动机构的 2 个动作周期为 1 666 个采样点,对应 1 666 个采样点的重构残差和动态阈值。在第 1 个动作周期中,重构残差位于动态阈值下方,说明 CRDM 动作正常;在第 2 个动作周期中,重构残差局部超出动态阈值边界(虚线框处),说明提升线圈在该周期动作出现异常。由此检测出提升线圈在图 9(a)~(d)的第 2 个周期发生电流大小异常、电流过渡异常、动作时序错乱(超前和滞后)异常。此外,MCJL 模型在部分区间的重构精度略有波动,导致局部残差有所增大,但动态阈值机制具有一定的容错能力,从而有效避免误报警。

图 10 和 11 分别展示了移动线圈和保持线圈的 4 种异常模式(电流大小异常、电流过渡异常、无动作点异常和动作点偏移)。其中,电流大小异常和电流过渡异常的




图 9 提升线圈电流信号重构与动作异常检测效果

Fig. 9 Effect of signal reconstruction and operating anomaly detection for the lift coil




图 10 移动线圈电流信号重构与动作异常检测效果

Fig. 10 Effect of signal reconstruction and operating anomaly detection for the moving coil




图 11 保持线圈电流信号重构与动作异常检测效果

Fig. 11 Effect of signal reconstruction and operating anomaly detection for the solid coil

信号畸变特征较为明显,对应的残差值大幅超出阈值边界。而无动作点异常和动作点偏移虽在电流信号上表现为细微的偏差,但仍会导致驱动机构动作失效,因而在实际工程中检测难度较高。本研究 MCJL 模型不仅能精准重构 CRDM 正常状态的电流信号,且能有效检测上述 2 类异常情况。上述案例分析表明,本文 MCJL 模型对于 CRDM 动作状态异常的检测具有一定灵活性和有效性。

3.3 多线圈电流信号重构性能对比

CRDM 线圈电流的重构精度直接决定异常检测的可靠性。为评估 MCJL 模型重构性能的优越性,构建 9 个模型加以对比,包括卷积自编码器 (convolutional auto-encoder, CAE)、门控循环单元自编码器 (gated recurrent unit-AE, GRU-AE)、卷积神经网络变分自编码器 (convolutional neural network - variational autoencoder, CNN-VAE)、门控循环单元变分自编码器 (GRU-VAE)、时间卷积网络 (convolutional temporal network, TCN)、变换器 (Transformer)、时间图卷积网络 (temporal graph convolutional network, T-GCN)、多尺度自适应图神经网络 (multi-scale adaptive graph neural network, MSAGNN) [23]

和自适应图卷积递归网络 (adaptive graph convolutional recurrent network, AGCRN) [24]。为降低模型测试的随机性,每组实验重复执行 5 次,并计算各指标的均值与标准差 ($\bar{\delta}_{MAE}$ 、 $\bar{\delta}_{SMAPE}$ 和 $\bar{\delta}_{RAE}$)。

表 2 展示了 3 组线圈的重构误差对比结果。整体上看,相较于常规时序模型,基于图卷积网络的 4 种模型 (T-GCN、MSAGNN、AGCRN 和 MCJL) 表现出更低的重构误差,证明多线圈联合学习的有效性。其中,CAE 和 GRU-AE 模型受限于传统自编码器的结构约束,重构误差偏大;而引入变分推断机制的 CNN-VAE 和 GRU-VAE 通过改进时序处理模块,获得了一定程度的性能提升。TCN 模型通过膨胀卷积机制、Transformer 模型通过注意力机制,均在长时序模式捕捉方面展现出独特优势。进一步分析发现,T-GCN 模型通过 GRU 与 GCN 的协同架构,实现了多线圈耦合关系的有效建模,从而提升了重构精度。MSAGNN 和 AGCRN 模型涵盖自适应图结构、多尺度时空特征提取等高阶模块,能够自主推理不同线圈间的动态模式,并取得较低的重构误差。与上述模型相比,本文所提 MCJL 模型在 3 组线圈的重任务构中,均展现出优越的精确度。

表 2 不同模型对控制棒驱动机构线圈电流的重构精度对比
Table 2 Comparison of reconstruction accuracy for CRDM coil current using different models

对比模型	提升线圈			移动线圈			保持线圈		
	$\delta_{MAE}/10^{-1} \text{ A}$	$\delta_{SMAPE}/\%$	$\delta_{RAE}/10^{-2}$	$\delta_{MAE}/10^{-2} \text{ A}$	$\delta_{SMAPE}/\%$	$\delta_{RAE}/10^{-2}$	$\delta_{MAE}/10^{-2} \text{ A}$	$\delta_{SMAPE}/\%$	$\delta_{RAE}/10^{-2}$
CAE	3.20±0.16	5.98±1.29	2.48±0.17	13.17±0.25	2.97±0.31	3.65±0.06	14.91±0.28	4.01±0.19	4.71±0.09
GRU-AE	2.98±0.46	4.17±10.79	2.28±0.41	13.98±4.71	3.11±6.33	3.87±1.29	10.63±2.42	5.32±8.52	3.37±0.86
CNN-VAE	3.09±0.17	5.84±1.30	2.39±0.18	9.88±0.47	3.35±0.24	2.74±0.13	9.59±0.66	3.52±0.31	3.09±0.31
GRU-VAE	2.80±0.13	5.24±1.30	2.15±0.11	9.60±0.45	2.99±0.49	2.66±0.12	9.22±0.55	3.51±0.52	2.96±0.29
TCN	2.49±0.05	4.34±1.12	1.90±0.04	9.27±0.38	1.97±0.40	2.57±0.10	8.73±0.24	1.83±0.20	2.75±0.07
Transformer	2.64±0.06	3.54±1.31	2.02±0.05	7.03±0.37	1.83±0.25	1.96±0.11	6.05±0.26	2.18±0.32	1.94±0.14
T-GCN	2.43±0.09	2.91±0.67	1.87±0.11	5.91±0.14	<u>1.12±0.10</u>	1.64±0.04	6.02±0.18	1.90±0.26	1.93±0.08
MSAGNN	2.01±0.08	2.79±0.95	1.49±0.19	6.10±0.54	1.49±0.08	1.52±0.15	<u>4.94±0.24</u>	<u>1.59±0.12</u>	1.81±0.19
AGCRN	1.71±0.07	<u>2.65±0.28</u>	1.30±0.11	<u>5.28±0.60</u>	1.38±0.05	<u>1.46±0.17</u>	5.64±0.22	1.98±0.16	<u>1.79±0.13</u>
MCJL *	<u>1.75±0.14</u>	2.07±0.45	<u>1.37±0.18</u>	3.33±0.41	0.72±0.09	0.93±0.12	4.03±0.37	1.01±0.08	1.32±0.20

注:加粗和下划线字体分别代表各指标的最优值和次优值。

为直观证明 MCJL 模型的重构准确性,图 12 展示了多个模型在 CRDM 下插阶段单个动作周期的重构曲线。鉴于线圈电流信号具有长时序特性,在电磁-机械耦合作用过程中会呈现局部非平稳波动特征。部分模型 (如 CAE、CNN-VAE 和 GRU-VAE) 在提升线圈电流下降过程中出现较大拟合偏差。虽然 TCN 和 Transformer 模型缓解了该问题,但对局部动态趋势的跟踪能力仍显不足。相比之下,MCJL 能适应不同程度的动态波动,具备更稳定的重构性能。这得益于多线圈联动图结构和移动图卷积网络的协

同作用,实现多线圈间局部时序特征的有效表征与捕获。

3.4 控制棒驱动机构异常检测性能对比

本文所提 MCJL 模型采用多尺度动态检测策略进行 CRDM 动作状态异常检测。为验证本文方法的准确性,在 MCJL 模型重构结果的基础上,进一步构建 7 种无/半监督检测模型,包括 k 均值 (k-means) 聚类、基于密度的噪声空间聚类 (density-based spatial clustering of applications with noise, DBSCAN)、局部离群因子 (local outlier factor, LOF)、单类支持向量机 (one-class support




图 12 不同模型重构效果可视化

Fig. 12 Visualization of reconstruction performance for different models

vector machine, OCSVM)、支持向量数据描述 (support vector data description, SVDD)、孤立森林 (isolation forest, I-Forest)、含容错机制的四分位距 (interquartile range, IQR)。此外,参照 CRDM 异常检测相关研究,分别构建长短期记忆自编码器与极限梯度提升组合模型 (long short-term memory autoencoder with extreme gradient boosting, LSTM-AE-XGB)^[12]、GRU-AE 与随机森林组合模型 (GRU-AE with random forest, GRU-AE-RF)^[14]。鉴于现有研究仅针对单一线圈进行建模,本节实验将建模对象扩展至 3 组线圈,进行更完备的对比分析。

表 3 展示了不同模型在 CRDM 动作异检测中的 3 种性能指标。由于 3 组线圈电流均为长序列信号,其单线圈信号存在多尺度波动特性,且多线圈间具有量纲差异性,

导致传统检测模型 (如 k-means、DBSCAN、LOF、OCSVM 和 SVDD) 难以构建精准的决策边界,对不同线圈的检测效果参差不齐。GRU-AE-RF 和 LSTM-AE-XGB 模型虽采用有监督检测方式,但由于二者的基础重构性能受限,导致检测性能存在瓶颈。相比之下,本文所提 MCJL 模型通过动态检测策略,结合核密度估计实现决策边界的动态调整,确保了异常检测的灵活性与稳定性。实验数据显示,该模型对于 3 组线圈的平均检测指标 ($\delta_{pre} = 95.05\%$ 、 $\delta_{rec} = 94.34\%$ 和 $\delta_{F1} = 94.54\%$) 均优于其他模型。

3.5 消融实验

为检验 MCJL 模型中各个模块的贡献,本节开展消融实验,将完整的 MCJL 模型与 5 个变体加以对比,即:

- 1) 变体 1: 消除“子序列分割”步骤;

表 3 不同模型的异常检测性能对比

Table 3 Comparison of anomaly detection performance across different models (%)

对比模型	提升线圈			移动线圈			保持线圈		
	δ_{pre}	δ_{rec}	δ_{F1}	δ_{pre}	δ_{rec}	δ_{F1}	δ_{pre}	δ_{rec}	δ_{F1}
k-means	92.73	73.38	78.67	60.06	77.50	67.68	87.11	62.50	66.75
DBSCAN	92.83	74.63	79.64	87.55	72.13	74.40	68.06	82.50	74.59
LOF	86.09	90.00	85.50	89.86	84.50	85.56	68.03	82.25	74.47
OCSVM	94.02	85.13	87.63	91.76	88.63	89.26	81.74	75.13	77.37
SVDD	93.90	84.38	87.06	93.71	92.75	92.98	81.67	78.25	79.58
GRU-AE-RF	94.68	88.63	90.30	92.35	90.38	90.81	82.40	84.00	82.90
LSTM-AE-XGB	95.67	92.38	93.26	93.34	93.25	93.29	80.61	83.00	81.22
I-Forest	95.44	91.63	92.66	93.91	93.75	93.81	86.73	87.38	86.96
IQR	<u>96.25</u>	<u>94.00</u>	<u>94.59</u>	<u>94.42</u>	<u>94.13</u>	<u>94.22</u>	<u>91.37</u>	<u>91.13</u>	<u>91.23</u>
MCJL *	97.27	96.25	96.51	94.62	94.38	94.45	93.25	92.38	92.65

注:加粗和下划线字体分别代表各指标的最优值和次优值。

- 2) 变体2:消除“衰减因子(η)”,即 $\eta=1$;
- 3) 变体3:“全连接边”改为“局部连接边”;
- 4) 变体4:去除“一阶差分节点”;
- 5) 变体5:“MGCN”替换为普通GCN。

如图13所示,“子序列分割”步骤的缺失(变体1)导致重构精度显著降低,这是因为模型难以在长时序的CRDM电流信号中区分关键信息,无法有效收敛。消除“衰减因子”(变体2)削弱了模型对子序列间重要性的区分能力,从而影响性能。变体3的精度下降证明全连接拓扑能有效建模线圈间在不同时间尺度的复杂关联性。变体4因缺失“一阶差分节点”,模型难以充分提取信号波动特征和隐含变化规律,导致性能下降。相较于变

体5,本文MCJL模型具有移动图卷积,有助于捕捉线圈间的局部时序特征。定量分析证实了各模块协同作用的影响,这表明结合CRDM先验知识与数据驱动建模思想,有助于多线圈电流信号的高精度重构。

3.6 自信息消除的必要性分析

本文所提MCJL模型通过多线圈联动图表征CRDM中3组线圈间的动态耦合关系,其中,引入衰减邻接矩阵消除自身信息聚合过程。这意味着每个线圈仅依赖于其他2组线圈的信号来重构自身信号。当单个线圈出现电流信号异常时,模型仍能通过3组线圈间的动态关联模式实现异常信号的鲁棒重构。为证明消除自信息的必要性,本节将MCJL模型与3种变体进行比较,即:




图13 MCJL模型中的不同模块有效性验证

Fig. 13 Effectiveness validation of each module in the MCJL model

- 1) MCJL-A:不消除自身信息。
- 2) MCJL-B:仅在过去时刻具有自信息。
- 3) MCJL-C:仅在当前时刻具有自信息。

以移动线圈下插阶段出现电流大小异常为例,图14展示了3种变体与MCJL模型的重构曲线。





图14 消除自信息有效性验证

Fig. 14 Effectiveness validation of self-information elimination

由于MCJL-A模型未消除自身信息,在训练过程中,模型易依赖于自身信息重构信息,而忽略其他线圈的耦合关系。在发生电流信号异常时,重构信号会跟随异常信号,导致重构残差较小、异常特征不显著。同理,MCJL-B和MCJL-C模型分别仅消除当前时刻或过去时刻的自信息,重构效果仍不够理想。相比之下,本文MCJL消除自环计算过程,即使某个线圈发生信号异常,也能表现出精确的重构性能。简而言之,去除自信息使模型更聚焦于学习多线圈间的协同模式,从而增强异常特征的表达能力。较大的重构残差有助于放大异常特征,提升早期检测的敏感性与准确性。

4 结 论

针对现有 CRDM 异常检测方法忽略多线圈间动态耦合关系的问题,提出一种多线圈联合学习(MCJL)模型,以检测控制棒动作过程中的异常。该模型由多线圈联合图结构、移动图卷积网络和多尺度动态检测策略3个部分构成。基于某商业压水堆机组的历史监测数据和模拟异常样本开展研究,结论为:

1) MCJL 模型突破了常规模型仅利用单一线圈建模的局限,通过构建多线圈联动图结构,能够有效提取线圈间的动态耦合特征,实现多组电流信号的高精度重构。

2) 相较于多种对比模型,MCJL 在信号重构与异常检测方面表现更优,尤其动态阈值策略可灵活调整决策边界,具有较强的容错能力。

3) 实验表明,MCJL 模型消除自信息聚合过程,有助于模型聚焦于学习多线圈间的协同模式,从而增强异常特征的表达能力。

综上,本文方法具有一定工程适用性,可为核电厂智能化转型提供技术储备与应用支撑。

参考文献

- [1] 江灏,叶铭新,林蔚青,等. 基于时空动态检测的核电厂堆外中子探测器故障检测方法[J]. 仪器仪表学报,2024,45(9):131-144.
- JIANG H, YE M X, LIN W Q, et al. Fault detection for ex-core neutron detectors in nuclear power plants using the spatial-temporal dynamic detection model[J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 131-144.
- [2] 李梦书,唐诗涵,郑杲,等. 反应堆控制棒驱动系统电气性能动态参数模型研究[J]. 核动力工程,2024,45(4):248-254.
- LI M SH, TANG SH H, ZHENG G, et al. Research on dynamic parameter model of electrical performance of reactor control rod drive system[J]. Nuclear Power Engineering, 2024, 45(4):248-254.
- [3] 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, et al. Early fault state identification method of the rod control system power equipment based on time-frequency characteristics fusion and GWO-ELM[J]. Chinese Journal of Scientific Instrument, 2023, 44(1):121-130.
- [4] 李润培,桂林,吴龙,等. 核电站控制棒驱动机构电源系统建模及故障分析[J]. 电力系统自动化,2023,47(3):114-121.

- LI R P, GUI L, WU L, et al. Modeling and fault analysis of power supply system for control rod driving mechanism in nuclear power plant[J]. Automation of Electric Power Systems, 2023, 47(3):114-121.
- [5] 蒋翔宇,冯毅雄,洪兆溪,等. 基于多级数据融合的核电站运行功能健康状态评估[J]. 机械工程学报,2024,60(4):200-211.
- JIANG X Y, FENG Y X, HONG ZH X, et al. Health status assessment on the operation function of nuclear power plants based on multi-level data fusion[J]. Journal of Mechanical Engineering, 2024, 60(4):200-211.
- [6] JIANG X J, ZHOU W, HOU J, et al. Construction of fault diagnosis system for control rod drive mechanism based on knowledge graph and Bayesian inference[J]. Nuclear Science and Techniques, 2023, 34(2):21.
- [7] LIU ZH L, LI T X, ZHU ZH F, et al. Noise reduction method for the vibration signal of reactor CRDM based on CEEMDAACN-SK[J]. Electronics, 2023, 12(22):4681.
- [8] 昌正科,董治国,常乐莉. 压水堆核电站 CRDM 故障诊断研究与实践[J]. 自动化仪表,2013,34(6):58-61.
- CHANG ZH K, DONG ZH G, CHANG Y L. Study and realization of fault diagnosis for CRDM in PWR nuclear power station[J]. Process Automation Instrumentation, 2013, 34(6):58-61.
- [9] 彭翠云,何攀,彭霄微,等. 基于结构噪声检测的控制棒驱动机构运行故障分析方法研究[J]. 核动力工程,2020,41(3):214-216.
- PENG C Y, HE P, PENG X W, et al. Research on methods of failure analysis for control rod drive mechanism based on structure noise detecting technique[J]. Nuclear Power Engineering, 2020, 41(3):214-216.
- [10] 谢细明,彭航,张倬,等. 核反应堆控制棒驱动机构动作部件状态检测研究[J]. 核动力工程,2019,40(2):90-94.
- XIE X M, PENG H, ZHANG ZH, et al. Study on monitoring of action assembly of control rod drive mechanism in nuclear power reactors[J]. Nuclear Power Engineering, 2019, 40(2):90-94.
- [11] 林蔚青,缪希仁,陈静,等. 时空信息融合的堆芯自给能中子探测器故障检测与隔离方法[J]. 中国电机工程学报,2024,44(23):9310-9323.
- LIN W Q, MIAO X R, CHEN J, et al. Fault detection and isolation method for in-core self-powered neutron detectors based on spatiotemporal information fusion[J]. Proceedings of the CSEE, 2024, 44(23):9310-9323.
- [12] CHEN J, LIU Z SH, JIANG H, et al. Anomaly detection

- of control rod drive mechanism using long short-term memory-based autoencoder and extreme gradient boosting[J]. Nuclear Science and Techniques, 2022, 33(10):127.
- [13] ZHANG L M, LI Q, LUO J D, et al. A novel method for diagnosis and de-noising of control rod drive mechanism within floating nuclear reactor[J]. Ocean Engineering, 2022, 244:110398.
- [14] XU Y, CAI Y Z, SONG L. Latent fault detection and diagnosis for control rods drive mechanisms in nuclear power reactor based on GRU-AE[J]. IEEE Sensors Journal, 2023, 23(6): 6018-6026.
- [15] 纪泽源, 于潇颖, 付文兴. 基于图神经网络特征点匹配的视觉 SLAM 算法[J]. 仪器仪表学报, 2024, 45(9): 34-43.
- JI Z Y, YU X Y, FU W X. Visual SLAM algorithm based on graph neural network feature point matching[J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 34-43.
- [16] 林蔚青, 缪希仁, 肖洒, 等. 基于时空特征挖掘的特高压变压器热状态参量预测方法[J]. 中国电机工程学报, 2024, 44(4): 1649-1662.
- LIN W Q, MIAO X R, XIAO S, et al. Forecasting method for thermal state parameters in ultra-high voltage transformers based on spatial-temporal features mining[J]. Proceedings of the CSEE, 2024, 44(4): 1649-1662.
- [17] 李文悦, 何怡刚, 邢致恺, 等. 基于双输入残差图卷积网络的电力变压器健康状态评估方法[J]. 电子测量与仪器学报, 2024, 38(11): 15-24.
- LI W Y, HE Y G, XING ZH K, et al. Health evaluation of power transformer based on double input residual graph convolutional network[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(11): 15-24.
- [18] 谭会生, 杨威, 严舒琪. 交通速度预测时空图卷积网络及其 FPGA 实现研究[J]. 电子测量技术, 2024, 47(18): 108-119.
- TAN H SH, YANG W, YAN SH Q, et al. Research on spatio-temporal graph convolutional network for traffic speed prediction and their FPGA implementation[J]. Electronic Measurement Technology, 2024, 47(18): 108-119.
- [19] LIN W Q, MIAO X R, CHEN J, et al. Fault detection and isolation for multi-type sensors in nuclear power plants via a knowledge-guided spatial-temporal model[J]. Knowledge-Based Systems, 2024, 300: 112182.
- [20] 曾杰, 彭翠云, 何攀, 等. 控制棒驱动机构电流监测与故障诊断技术研究[J]. 核动力工程, 2019, 40(1): 172-175.
- ZENG J, PENG C Y, HE P, et al. Research on current monitoring and fault diagnosis technology for control rod drive mechanism[J]. Nuclear Power Engineering, 2019, 40(1): 172-175.
- [21] LIN W Q, MIAO X R, CHEN J, et al. ST-SAM: Spatial-temporal state adaptation model for neutron detector fault detection and isolation in nuclear power plants[J]. IEEE Transactions on Industrial Informatics, 2025, 21(2): 1110-1119.
- [22] YU W K, ZHAO CH H. Robust monitoring and fault isolation of nonlinear industrial processes using denoising autoencoder and elastic net[J]. IEEE Transactions on Control Systems Technology, 2020, 28(3): 1083-1091.
- [23] CHEN L, CHEN D H, SHANG Z J, et al. Multi-scale adaptive graph neural network for multivariate timeseries forecasting[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(10): 10748-10761.
- [24] BAI L, YAO L N, LI C, et al. Adaptive graph convolutional recurrent network for traffic forecasting[C]. Advances in Neural Information Processing Systems, 2020, 33: 17804-17815.

作者简介



林蔚青, 2022 年于福州大学获得硕士学位, 现为福州大学电气学院博士生, 主要研究方向为电气设备在线监测与故障诊断。
E-mail: 220110008@fzu.edu.cn

Lin Weiqing received his M. Sc. degree from Fuzhou University in 2022. He is currently a Ph. D. student at Fuzhou University. His main research interests include online monitoring and fault diagnosis for power equipment.



江灏 (通信作者), 2013 年于厦门大学获得博士学位, 现为福州大学教授, 主要研究方向为电力故障辨识和智能感知系统。
E-mail: jiangh@fzu.edu.cn

Jiang Hao (Corresponding author) received his Ph. D. degree from Xiamen University in 2013. He is currently a professor at Fuzhou University. His main research interests include power fault identification and intelligent sensing systems.