

DOI: 10.19650/j.cnki.cjsi.J2412821

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*

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

摘要:在核电厂安全监控体系中,堆外中子探测器扮演着关键角色。然而,现有针对探测器的故障检测方法侧重于提取时序特征,以及采用固定阈值方式加以辨识故障,未充分利用探测器之间蕴含的空间耦合关系且缺乏灵活性。为此,该文提出1种针对堆外中子探测器的时空动态检测模型(STDDM)。该模型由时序卷积网络(TCN)、图卷积网络(GCN)和动态阈值3个模块构成。其中,将TCN和GCN模块相组合,用于提取探测器间隐含的时空关系以重构探测器信号。在此基础上,计算重构与真实信号间的残差,根据个体探测器的残差均值以及整堆探测器残差标准差,设计动态阈值检测策略,使模型能够自适应于反应堆运行工况的变化。通过某地区核电厂真实数据加以验证,所提STDDM不仅能实时且精准地重构探测器信号,而且在不同故障情况下依然具有较强的故障容错能力,证明其在核电厂堆外中子探测器故障检测中的有效性和实用性。

关键词:核电厂;堆外中子探测器;故障检测;时序卷积网络;图卷积网络;动态阈值

中图分类号: TM623.7 TH86

文献标识码: A

国家标准学科分类代码: 490.25

Fault detection for ex-core neutron detectors in nuclear power plants using the spatial-temporal dynamic detection model

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

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

Abstract: In the safety monitoring systems of nuclear power plants, ex-core neutron detectors are essential. Existing fault detection methods for these detectors primarily focus on extracting temporal features and using fixed thresholds to identify faults. These methods do not fully leverage the spatial coupling relationships between detectors and lack flexibility. To address these limitations, this paper introduces a spatial-temporal dynamic detection model (STDDM) for fault detection in ex-core neutron detectors. The model comprises three components: a temporal convolutional network (TCN), a graph convolutional network (GCN), and dynamic thresholds. By combining the TCN and GCN, the model captures implicit spatial-temporal relationships between detectors to reconstruct detector signals. The residuals between the reconstructed and actual signals are then computed, with dynamic thresholds set based on the mean residual and the overall standard deviation of residuals across the reactor. This approach allows the model to adapt to varying reactor operating conditions. Tested with real data from a nuclear power plant, the STDDM not only provides accurate real-time signal reconstruction but also exhibits strong fault tolerance under various fault conditions, proving its effectiveness and practicality for fault detection in ex-core neutron detectors.

Keywords: nuclear power plant; ex-core neutron detector; fault detection; temporal convolutional network (TCN); graph convolutional network (GCN); dynamic threshold

0 引 言

核电作为一种清洁能源发电方式,在实现“双碳”目

标上发挥重要作用^[1]。为确保核电厂的安全运行,需要对核反应堆状态进行实时监测,堆外中子探测器作为一种关键核测设备,应用于监测各类核反应堆内部的中子通量密度。然而,由于工作环境的特殊性以及设备服

役时间的增长,中子探测器可能因长期的辐射、电子元件老化等因素,导致测量信号出现精度下降、漂移、偏置甚至完全失效等故障,进而影响核电厂的安全监测^[2]。随着核电厂数字化水平的提高,利用先进的数据分析技术和人工智能算法进行故障检测和健康监测,已经成为提高核电厂安全性和经济性的重要手段^[3-4]。因此,针对堆外中子探测器故障开发有效的检测方法尤为重要。

核电厂中的多数关键传感设备均设计了物理冗余并通过交叉检验来辨识故障^[5],但由于冗余传感器与一般传感器具有相同的硬件结构和相似的工作环境,可能发生共模故障^[6]使冗余传感器同时发生故障,导致冗余失效。此外,通过定期对传感器进行重新校准和维护也能减小测量偏差和故障概率^[7],然而,这些措施低效耗时甚至可能出现误校准,并且在早期的轻微性故障可能因重新校准而被掩盖,导致故障难以及时检测。

近年,国内外学者已对核电厂传感设备的故障检测开展相关研究。Lin等^[8]设计了一种顺序向后选择和逻辑判断方法来识别核电厂中的故障传感器,并且通过多元自回归算法对故障信号进行校正。Gautam等^[9]利用了扩展卡尔曼滤波器建立故障检测指标和故障特征,并结合了库尔贝克-莱布勒散度(kullback-leibler divergence, KLD)和指数加权移动平均,基于先验知识和约束条件建立模型,开发了一种故障决策控制图,对压力、温度传感器和中子探测器进行故障检测,该方法侧重于提取实际物理系统的局部信息,以准确描述传感器之间的因果关系。尽管这类方法对系统行为具有较好的解释性,但其普适性较差,需在长期测试中验证其完整性。

随着人工智能技术的不断发展,基于数据驱动的方法开始涌现,模型可利用有限的样本数据进行训练,以提取数据中潜在的特征规律。Li等^[10]将主成分分析技术(principal component analysis, PCA)运用到核电厂传感器的故障检测中,并结合了数据预处理和降低虚假故障报警的方法,以提高故障检测性能。Yu等^[6]改进传统的PCA方法提出了一种基于校正重构算法和循环主成分分析的检测模型(cyclic PCA-corrected reconstruction algorithm, CPCA-CRA),以提高多传感器故障的检测能力。Yellapu等^[11]提出了一种基于小波变换的多尺度PCA方法,从数据中提取有利于监测的特征来降低建模成本,并采用小波近似系数的广义似然比检验公式,以增强故障检测性能。Choi等^[12]采用改进的门控循环单元提取时间序列特征,建立传感器故障诊断容错模型,通过剔除故障传感器的影响,以提高核电厂在紧急情况下的故障容忍度。

然而,上述方法侧重于从时间维度提取故障特征,忽略了传感器间的潜在关联。为解决这一不足,Rao等^[13]结合树模型与支持向量机(ensemble of trees and support

vector machine, EOT-SVM)以提取核电厂一次回路中传感器间的空间关联性,用于估计传感器的测量误差。Yin等^[14]建立了基于相关参数的人工神经网络模型(relevant parameter-based artificial neural network, RPANN)融合多个传感器特征进行信号重构,并构建了基于时间序列的神经网络模型(time series-based artificial neural network, TSANN)用于故障检测。Xu等^[15]提出了一种基于虚拟冗余极端梯度提升树(virtual redundancy-based extreme gradient boosting, VR-XGBoost)的传感器信号重构模型,利用堆芯内中子探测器之间的相互关系建立了高精度的预测模型,并通过6 sigma 准则进行故障检测。Chen等^[16]设计了基于广义回归神经网络(generalized regression neural network, GRNN)的孪生模型(T-GRNN)用于表示传感器间的共同关系,并采用容错策略,多个传感器同时失效,也能保证其有效性。尽管这些方法利用了传感器间的潜在关系,但并没有显式地考虑传感器之间的空间或结构关系,无法有效捕捉传感器之间的连接信息。

图卷积神经网络(graph convolutional network, GCN)作为一种新兴的人工智能模型,在处理非欧几里得空间中具有显著关联性的数据时表现出优异的性能,应用于变量预测^[17-18]、机械故障诊断^[19-20]等领域中。在这些工作的启发下,考虑到堆外中子通量分布存在特殊的空间关系,堆外中子探测器作为中子通量测量设备,其在空间中也具有较强的耦合关系,利用GCN有望于表征这种复杂关系。

因此,本文结合时序卷积网络(temporal convolutional network, TCN)和图卷积神经网络,分别提取时间和空间尺度的特征,并基于动态阈值策略对堆外中子探测器进行故障检测。首先,根据堆外中子探测器的实际空间分布构建空间关系图;其次,构建信号重构模型和动态阈值故障检测策略;最后,根据模型重构信号和实际测量信号计算残差与动态阈值比较从而实现故障检测。

1 堆外中子探测器

反应堆内的核裂变反应会产生大量的中子,而中子通量与反应堆功率具有强相关性。堆外中子探测器位于反应堆压力容器外,能够测量泄露到堆外的中子通量,从而实现反应堆功率的监测^[21]。由于反应堆从启动到满功率运行过程中的功率变化范围较大,仅使用单一的中子探测器无法进行精确测量,通常采用3种不同量程的探测器,即源量程探测器、中间量程探测器以及功率量程探测器,不同探测器对不同通量范围敏感,并且量程范围相互重叠,可覆盖整个反应堆燃料周期^[22-23]。核电机组一般处于满功率或高功率运行状态,在此期间,功率量

程探测器发挥重要作用,它向控制室提供反应堆状态信息以便操纵员对核反应过程进行控制,同时向反应堆保护系统提供监测信号。因此,本文针对功率量程探测器开展故障检测研究。

堆外中子探测器布局与结构示意图如图 1 所示,功率量程探测器采用非补偿长电离室,分别布置在反应堆压力容器外的 4 个象限,在每个象限上沿轴向共有 6 个灵敏段分别用于测量不同高度的中子通量,每段包含 1 个中子电离室。

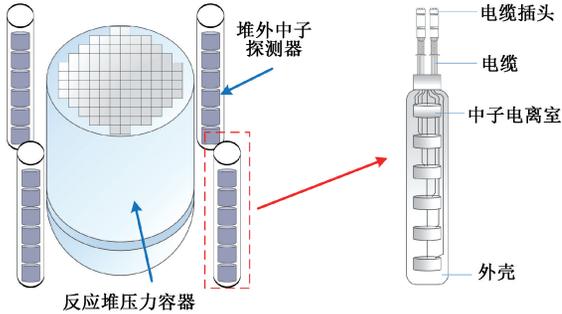


图 1 堆外中子探测器布局与结构示意图
Fig. 1 Layout and structure of the ex-core neutron detectors

每个灵敏段中包含 1 对表面涂有硼元素的阴极电极和阳极电极,并放置在充满惰性气体的圆柱形载体内^[24]。工作过程中,涂硼电极在中子辐照下发生反应,

生成的锂离子和 α 粒子将惰性气体电离,电离产生的电子和正离子在高压电场的作用下向两极移动,从而形成电压信号,再经过放大和修正后得到核功率值。

反应堆具有复杂的物理特性,燃料组成、堆芯形状、控制棒位置、反射层材料等都会影响中子的产生和吸收,导致泄露到堆外的中子通量在空间中呈不均匀分布。由此可见,堆外不同区域之间具有空间关联关系,而堆外中子探测器作为测量设备可以反映中子通量在空间上的分布,因此,相邻探测器可能会捕获到相似的中子通量变化且存在较强的空间耦合关系。

2 堆外中子探测器故障检测方法

2.1 STDDM 整体框架

堆外中子探测器作为核电厂中的关键设备,其故障将会干扰堆芯监测系统,对一次回路系统的稳定性和可靠性产生不利影响,针对堆外中子探测器的故障检测尤为重要。考虑到堆外中子探测器在实际的物理位置分布中具有较强的关联性,为有效结合其时间和空间维度上的特征,本文使用 TCN 捕捉时间特征;并使用 GCN 融合多个探测器特征,以提取空间特征;同时,结合动态故障阈值策略和故障隔离机制,构成堆外中子探测器时空动态检测模型 (spatial-temporal dynamic detection model, STDDM),整体框架如图 2 所示。具体步骤如下:

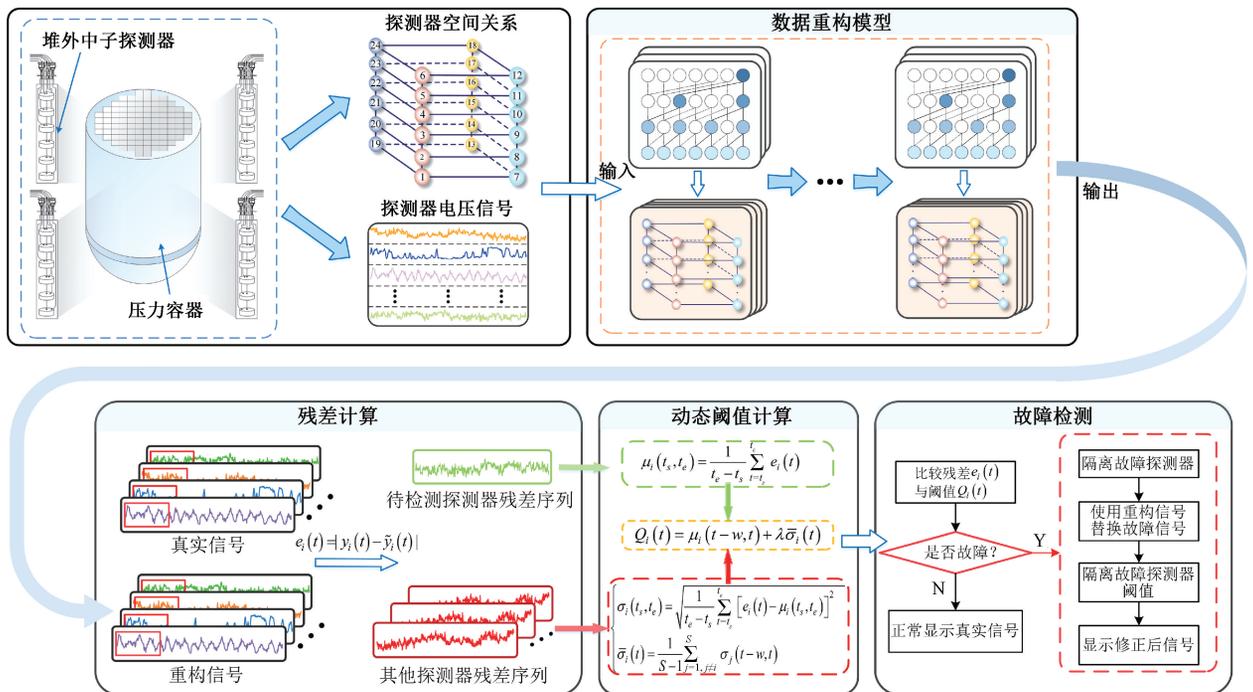


图 2 基于 STDDM 的堆外中子探测器故障检测框架

Fig. 2 Fault detection framework based on STDDM

1) 根据堆外中子探测器在三维空间的实际分布,构建探测器空间关系图 G ; 利用探测器真实电压信号构建探测器特征矩阵 X 。

2) 基于探测器空间关系图 G 和特征矩阵 X , 对信号重构模型进行训练, 并保存训练过程中性能较好的模型。在实时故障检测中, 将探测器数据流输入到信号重构模型中, 得到重构信号。

3) 计算重构与真实信号的残差。

4) 利用探测器历史残差计算动态阈值。

5) 比较当前时刻探测器残差和动态阈值的大小判断是否发生故障。若未检测到故障, 则不对真实信号进行干涉, 正常显示监测信息; 若检测到故障, 则采取故障隔离, 使用重构信号修正故障探测器。

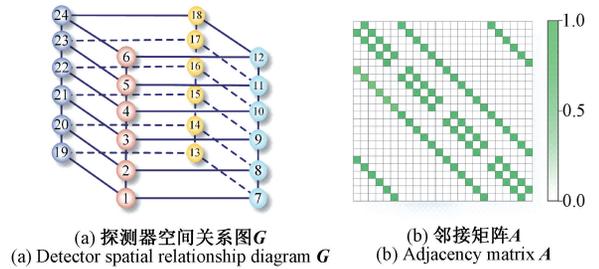
2.2 信号重构模型

定义探测器数量为 S , 探测器信号构成的时间序列长度为 L 。将每个探测器作为一个节点, 采用图结构表示三维空间中探测器的位置关系, 定义空间关系图 $G = (V, E, A)$, 其中, V 和 E 分别代表节点和边, A 为邻接矩阵 ($A \in \mathbf{R}^{S \times S}$), 表示节点之间的连接关系。式(1)所示为邻接矩阵的生成公式。

$$A_{mn} = \begin{cases} 0, & V_m \text{ 与 } V_n \text{ 之间不存在连接关系} \\ 1, & V_m \text{ 与 } V_n \text{ 之间存在连接关系} \end{cases} \quad (1)$$

其中, A_{mn} 表示邻接矩阵第 m 行第 n 列的元素, 当第 m 个节点 V_m 和第 n 个节点 V_n 存在连接关系时, A_{mn} 值为 1, 否则 A_{mn} 值为 0。同时, 将每个探测器信号序列作为图节点的特征, 构成探测器特征矩阵 $X (X \in \mathbf{R}^{L \times S})$ 。

本文中, 探测器数量 S 为功率量程探测器中灵敏段的数量, 即 S 的值为 24。依据第 1 节中介绍的堆外中子探测器原理与布局, 本文基于探测器实际空间分布构建三维的探测器空间关系图 G , 并将空间关系图的连接关系表示为邻接矩阵 A , 如图 3 所示。每个探测器节点仅与相邻探测器之间存在连接关系。



(a) 探测器空间关系图 G

(b) 邻接矩阵 A

(a) Detector spatial relationship diagram G

(b) Adjacency matrix A

图 3 探测器空间关系图及其邻接矩阵示意图

Fig. 3 Schematic diagram of the detector spatial relationship graph and its adjacency matrix

信号重构模型结构如图 4 所示, 可分为时序特征提取和空间信息融合两部分。

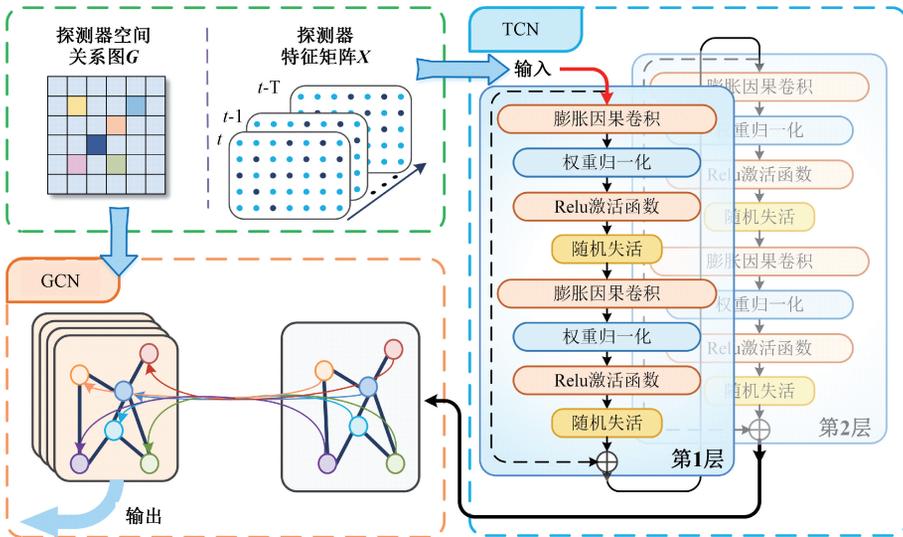


图 4 信号重构模型结构

Fig. 4 Structure of the signal reconstruction model

时序特征提取采用 TCN 模型, TCN 是为处理具有因果约束的序列建模任务而提出的通用卷积网络。相较于传统的循环神经网络 (recurrent neural network, RNN) 和长短期记忆网络 (long short-term memory, LSTM) 等循环结构, TCN 利用卷积操作捕获序列数据中的时序信息, 具

有高效的并行计算能力^[25-26]。不同于传统的卷积过程, TCN 结合因果卷积 (causal convolution) 和膨胀卷积 (dilated convolutions) 以组成膨胀因果卷积 (dilated causal convolution)。此外, TCN 中还具备残差连接结构, 以及权重归一化 (weight normalization) 和随机失活 (dropout) 等

正则化方法。

1) 因果卷积:每个卷积层 t 时刻的输出值仅依赖于 t 及其之前时刻的输入值,从而确保输出只取决于当前和过去的输入,而不受未来信息的影响,防止未来数据的“泄露”。

2) 膨胀卷积:为克服传统卷积神经网络对时间序列建模长度受限于卷积核大小的问题,在 TCN 中利用膨胀卷积以扩展感受野,从而更好地捕获长期依赖关系,膨胀卷积过程可表示为式 (2) 所示。

$$C_t = (f \otimes X_t) = \sum_{k=0}^{K-1} f(k) \cdot x_{t-d-k} \quad (2)$$

式中: X_t 和 C_t 分别表示 t 时刻的输入序列和输出特征; f 表示卷积核; \otimes 表示膨胀卷积操作; K 和 d 分别表示卷积核大小和膨胀因子; d 决定了卷积核中元素的间隔。通过改变 d 的大小能够改变输出的感受野。如图 5 所示,图中展示了 3 层卷积核大小为 2,膨胀因子 $d = [1, 2, 4]$ 的膨胀因果卷积,其中输出 y_t 包含了原始输入中 $\{x_{t-7}, \dots, x_{t-1}, x_t\}$ 的信息。

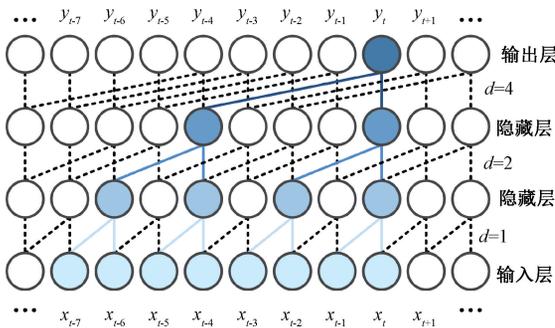


图 5 膨胀因果卷积

Fig. 5 Schematic diagram of dilated causal convolution

3) 残差连接:TCN 采用残差连接结构以防止深层网络带来的梯度消散问题,该结构可表示为式 (3)。

$$O_t = F(X_t) + h(X_t) \quad (3)$$

式中: X_t 和 O_t 分别表示 t 时刻残差连接模块的输入和输出; $F(\cdot)$ 表示一组包含膨胀因果卷积、权重归一化、激活函数、随机失活的变换操作; $h(\cdot)$ 为卷积核大小为 1 的卷积操作,用于特征降维从而匹配特征数量,以便进行加和操作。当 $F(X_t)$ 与 X_t 具有相同特征数量时, $h(\cdot)$ 退化恒等映射。

经过 TCN 获得高维时序特征后,利用 GCN 模型融合这些深层特征得到时空特征。在 GCN 中,每个探测器节点的特征变换通过聚合和更新两个步骤实现,传统的 GCN 计算如式 (4) 所示^[17-18]。

$$\begin{cases} H_t^{(l)} = (D^{-1/2}(I_N + A)D^{-1/2})X_t^{(l)} \\ Z_t^{(l)} = \sigma(H_t^{(l)}\theta^{(l)}) \end{cases} \quad (4)$$

式中: $X_t^{(l)}$ 、 $H_t^{(l)}$ 以及 $Z_t^{(l)}$ 分别为 t 时刻第 l 层 GCN 的输入特征矩阵、经过空间信息聚合后的特征矩阵以及输出特征矩阵; I_N 为单位矩阵,表示计算过程中考虑节点自身特征信息; σ 为激活函数; A 和 D 分别表示邻接矩阵和度矩阵; $\theta^{(l)}$ 表示第 l 层 GCN 的可学习权重矩阵。

但在探测器故障检测中,为了确保故障下模型依然能够通过周围探测器特征对故障探测器进行精准重构,本文所提 GCN 消除了空间关系图中的自环结构,即节点自身特征信息不参与图卷积计算,改进后信息聚合过程如式 (5) 所示。

$$H_t^{(l)} = \sigma((D^{-1/2}AD^{-1/2})X_t^{(l)}\theta^{(l)}) \quad (5)$$

GCN 利用图的邻接矩阵来指导信息的流动,能够结合局部节点特征与其邻居的信息,这有助于形成包含更广泛信息的复合特征表示,相对于独立考虑每个探测器的数据来说,能提供更深层次的洞察。图 6 以 #1 探测器为中心节点展示了 2 层图卷积的过程。在第 1 层 GCN 中,#1 探测器基于预定义的图结构从相邻的探测器(#2、#7、#19)中汇集信息;第 2 层图卷积中,#1 探测器不仅包含了相邻探测器的信息,还整合了相邻探测器的邻居探测器的信息(#3、#8、#13、#20)的信息,使得 #1 探测器具有更大的感受野。

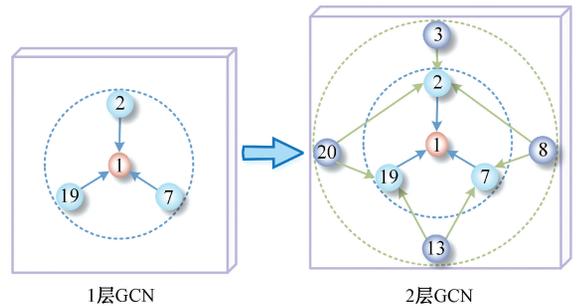


图 6 GCN 聚合空间信息

Fig. 6 Spatial information aggregation diagram of GCN

综上,信号重构模型可表示为映射函数 F ,表达式如式 (6) 所示。

$$Y_t = F[G; (X_{t-w}, \dots, X_{t-1}, X_t)] \quad (6)$$

其中, w 表示输入数据的时间窗口长度, $Y_t \in \mathbf{R}^{S \times 1}$ 表示探测器信号的重构矩阵。其通过融合探测器空间关系图 G 的空间信息和探测器特征矩阵 X 的时间特征,对 t 时刻的探测器信号进行重构。

2.3 动态阈值策略

常见的故障检测方法是在训练集或验证集上计算重构值与实际值的残差,并利用残差序列产生 1 个恒定的阈值,然后将其运用到在线检测中,通过比较实时产生的残差与固定阈值以辨识故障。然而该方法存在一定的局限性,当测试集与用于产生阈值的样本之间存在分布差

异,或者模型在测试集局部区域的重构能力较差时,恒定阈值方法无法根据工况的变化加以调整,将导致正常探测器被诊断为故障。因此,本文通过结合探测器残差的个体历史表现和系统残差的整体行为,产生动态阈值,以克服固定阈值方法所存在的问题。

实时故障检测中,记第 i 个探测器在 t 时刻的残差为 $e_i(t)$, 计算过程如式 (7) 所示。

$$e_i(t) = |y_i(t) - \tilde{y}_i(t)| \quad (7)$$

其中, $y_i(t)$ 和 $\tilde{y}_i(t)$ 分别表示第 i 个探测器在 t 时刻的实际信号和重构信号。

在非故障情况下,探测器残差的波动范围处于某一置信区间内,当某一探测器残差位于区间之外时,即可将其判断为故障。由式 (7) 中残差的定义可知,该置信区间的下界为 0,因此,仅需考虑区间上界,即残差阈值。

定义 $\mu_i(t_s, t_e)$ 和 $\sigma_i(t_s, t_e)$ 分别为第 i 个探测器的残差序列在时间窗口 $[t_s, t_e]$ 内的均值和标准差,计算过程如式 (8) 所示,两者分别体现探测器残差在某一时间段内的平均水平和波动程度,当故障发生时,随着残差的增大, $\mu_i(t_s, t_e)$ 和 $\sigma_i(t_s, t_e)$ 也将随之增大,因此两者能够反映故障行为。

$$\begin{cases} \mu_i(t_s, t_e) = \frac{1}{t_e - t_s} \sum_{t=t_s}^{t_e} e_i(t), (t_e \geq t_s) \\ \sigma_i(t_s, t_e) = \sqrt{\frac{1}{t_e - t_s} \sum_{t=t_s}^{t_e} [e_i(t) - \mu_i(t_s, t_e)]^2} \end{cases} \quad (8)$$

使用 $Q_i(t)$ 表示第 i 个探测器在 t 时刻的残差阈值,其计算方法如式 (9) 所示。

$$\begin{cases} Q_i(t) = \mu_i(t - w_{th}, t) + \lambda_i \bar{\sigma}_i(t) \\ \bar{\sigma}_i(t) = \frac{1}{S - 1} \sum_{j=1, j \neq i}^S \sigma_j(t - w_{th}, t) \end{cases} \quad (9)$$

其中, $\mu_i(t - w_{th}, t)$ 表示第 i 个探测器在长度为 w_{th} 的历史窗口内的残差均值,在非故障时能够反映探测器在正常工作条件下的典型行为; $\bar{\sigma}_i(t)$ 表示除第 i 个探测器之外,其它探测器的标准差的均值,它代表当前整个系统内残差的波动性和噪声水平,能够为阈值的确定提供系统级的动态变化信息,进而使阈值设置具有更强的适应性; λ_i 为第 i 个探测器的调节因子,用于调整系统平均波动水平对阈值的影响程度,在本文中 λ_i 根据验证集产生。

在检测到探测器故障之后,采用重构信号替换故障信号,并且将动态阈值恒定为故障时刻的阈值。另外,为避免非故障下的单个异常残差值影响检测效果,在故障检测过程中对残差序列采用移动平均滤波,以滑动窗口为单位开展故障检测。

3 算例分析

3.1 算例数据集

本文数据集来自某地区商用压水堆核电机组历史监测数据,原始数据集涵盖变功率(包含功率上升和功率下降)和满功率 2 种运行工况。数据集所含特征为中子通量经过堆外中子探测器转换后输出的电压信号,每个探测器对应 1 个一维特征,整个数据集共包含 24 个特征;数据采样频率为每分钟采样 1 次。

从原始数据集中选取变功率工况下功率变化范围为 40%~100% 的 30 000 个点,并按照 8:2 的比例划分为训练集和验证集用于信号重构模型的训练。除去用于模型训练的数据后,从原始数据集分出 30 000 个功率变化范围为 75%~100% 的变功率采样点和 30 000 个满功率采样点,分别作为变功率测试集和满功率测试集。

由于缺乏实际场景下故障探测器数据样本,本文结合堆外中子探测器工作环境以及检修记录,并根据相关文献资料^[6,10,16,27-28]进行故障模拟设置,将探测器故障分为以下 4 种典型故障:精度下降、漂移、偏置和失效。

1) 精度下降故障表现为探测器输出信号噪声水平升高,信号质量下降,其数学模型如式 (10) 所示。在原始信号的基础上,向故障开始时刻 t_{fs} 后的 T_f 个连续时间步长内添加噪声。

$$x_{i,n}[t] = \begin{cases} x_{i,h}[t] + x_{i,n}[t] \cdot U(-c, c), & 0 \leq t - t_{fs} < T_f \\ x_{i,h}[t], & \text{其他} \end{cases} \quad (10)$$

式中: $x_{i,h}[t]$ 和 $x_{i,n}[t]$ 分别为第 i 个探测器的正常(无故障)测量值和可能存在精度下降故障的值; $U(-c, c)$ 为 $[-c, c]$ 上的均匀分布; c 表示噪声水平。

2) 漂移故障表现为输出信号逐渐偏离正常值,在故障早期呈现潜伏性异常变化,其数学模型如式 (11) 所示。

$$x_{i,d}[t] = \begin{cases} x_{i,h}[t] + x_{i,h}[t] \cdot \frac{d(t - t_{fs} + 1)}{T_f}, & 0 \leq t - t_{fs} < T_f \\ x_{i,h}[t] + x_{i,h}[t] \cdot d, & t - t_{fs} \geq T_f \\ x_{i,h}, & \text{其他} \end{cases} \quad (11)$$

式中: $x_{i,d}[t]$ 为第 i 个探测器在漂移故障下可能的故障值; d 为最大漂移程度;在故障开始时刻 t_{fs} 后的 T_f 个连续时间步长上,漂移故障随时间线性增加,当漂移故障到达最大程度时,信号开始保持不变。

3) 偏置故障下表现为输出信号产生小幅度跳变,造成信号偏差,其数学模型如式 (12) 所示。

$$x_{i,b}[t] = \begin{cases} x_{i,h}[t] + x_{i,h}[t] \cdot b, & 0 \leq t - t_{fs} < T_f \\ x_{i,h}[t], & \text{其他} \end{cases} \quad (12)$$

式中: $x_{i,b}[t]$ 为第 i 个探测器在偏置故障下可能的故障值; b 表示偏置程度, 在故障开始时刻 t_{fs} 后的 T_f 个连续时间步长上, 向原始信号注入固定比例的偏置量。

4) 失效故障表现为探测器信号突降为 0, 产生明显阶跃, 探测器完全丧失测量功能, 其数学模型如式 (13) 所示。

$$x_{i,f}[t] = \begin{cases} 0, & 0 \leq t - t_{fs} < T_f \\ x_{i,h}[t], & \text{其他} \end{cases} \quad (13)$$

其中, $x_{i,f}[t]$ 为第 i 个探测器在失效故障下可能的故障值, 在故障开始时刻 t_{fs} 后的 T_f 个连续时间步长上, 故障探测器的读数保持为 0。

以上 4 种故障的故障程度设置如表 1 所示。

表 1 模拟故障程度
Table 1 Level of simulated faults

故障类型	故障范围
精度下降	$[-15\%, 15\%]$
漂移	$[-15\%, -2\%], [2\%, 15\%]$
偏置	$[-15\%, -2\%], [2\%, 15\%]$
失效	突降为 0

3.2 评价指标

本文采用平均绝对误差 (mean absolute error, MAE)、均方根误差 (root mean squared error, RMSE) 和对称平均百分比误差 (symmetric mean absolute percentage error, SMAPE) 评价不同模型对探测器信号的重构性能。模型对第 i 个探测器的 3 种性能指标计算公式如式 (14) 所示, 其中 N 为样本数。

$$\begin{cases} MAE_i = \frac{1}{N} \sum_{n=1}^N |y_i(n) - \tilde{y}_i(n)| \\ RMSE_i = \sqrt{\frac{1}{N} \sum_{n=1}^N [y_i(n) - \tilde{y}_i(n)]^2} \\ SMAPE_i = \frac{1}{N} \sum_{n=1}^N \frac{2|y_i(n) - \tilde{y}_i(n)|}{|y_i(n)| + |\tilde{y}_i(n)|} \times 100\% \end{cases} \quad (14)$$

同时, 为了衡量不同模型的故障检测性能, 通过混淆矩阵计算指标。将故障样本作为正例, 正常样本作为负例, 故障检测结果将包含以下 4 种情况: 真正例 (true positive, TP)、真负例 (true negative, TN)、假正例 (false positive, FP) 和假负例 (false negative, FN)。通过混淆矩阵计算检测结果中故障和正常两个类别的精确率 (precision, P)、召回率 (recall, R) 和 F1 分数 (F1 score,

F1), 计算如式 (15) 所示。考虑到类别不平衡问题, 为了更公平地评估模型对每个类别的分类效果, 通过计算每个指标的宏平均作为最终评价指标。

$$\begin{cases} P = \frac{TP}{TP + FP} \times 100\% \\ R = \frac{TP}{TP + FN} \times 100\% \\ F1 = \frac{2PR}{P + R} \end{cases} \quad (15)$$

此外, 计算实际工程问题中关注的漏报率 (miss alarm rate, MAR) 和误报率 (false alarm rate, FAR) 指标, 如式 (16) 所示。MAR 衡量模型未能识别出的故障的比例, 较高的 MAR 意味着较多故障未被发现。FAR 衡量被错误标记为故障的比例, 较大的 FAR 意味着较多的正常探测器被错误地识别为故障。

$$\begin{cases} MAR = \frac{FN}{TP + FN} \times 100\% \\ FAR = \frac{FP}{TN + FP} \times 100\% \end{cases} \quad (16)$$

3.3 模型参数与关键参数分析

1) 模型参数设置

本文基于 PyTorch 深度学习框架进行模型编程, 并使用专用服务器进行模型训练和测试, 服务器主要配置为 Intel (R) Xeon (R) w5-2465X 处理器和 NVIDIA GeForce RTX 4090 显卡以及 64 GB 运行内存。STDDM 参数如表 2 所示。

表 2 STDDM 参数
Table 2 Parameters of STDDM

参数类型	参数名称	参数值
训练参数	批大小	32
	学习率	0.002
	训练次数	200
	输入长度	20
	重构长度	1
TCN 参数	层数	2
	卷积核大小	3
	膨胀因子	[3, 6]
	输出维度	32
GCN 参数	层数	3
	隐藏层神经元个数	32
故障检测参数	动态阈值计算窗口大小	10 000
	故障检测滑动窗口大小	20
	故障检测滑动窗口步长	5

2) 输出长度与膨胀因子敏感性分析

对于不同的输入长度,TCN 能够捕捉不同的时间依赖特性,而不同的膨胀因子可能影响模型捕捉长期依赖的能力,进而影响重构性能。因此,针对这 2 个模型参数进行敏感性分析,不同输入长度和膨胀因子组合在变功率测试集上的 MAE 指标如图 7 所示。

结果表明,当较大的输入长度使用小膨胀因子,或者较小的输入长度使用大膨胀因子,都将导致模型性能变差。究其原因,采用小的膨胀因子处理较长输入序列时,模型无法捕捉大尺度的全局规律;反之,采用过大的膨胀因子时,模型在时间序列上捕捉全局特征的能力加强,但忽略了局部精细特征的学习,这两种情况均会影响模型对时间序列中潜在规律的学习,导致重构效果变差。

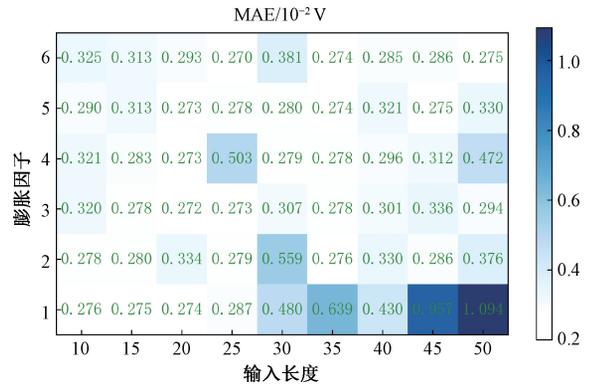


图 7 输入长度和膨胀因子敏感性分析

3.4 堆外中子探测器故障检测分析

1) 单一探测器故障

本文从变功率测试集上选取某个功率上升段数据,

共 5000 个采样点,并以 1~4 号(#1~#4)堆外中子探测器为例,分别在第 1800 个点设置精度下降、漂移、偏置和失效 4 种故障,利用 STDDM 进行故障检测。图 8 展示了故障探测器及其周围部分探测器的重构和故障检测效果。

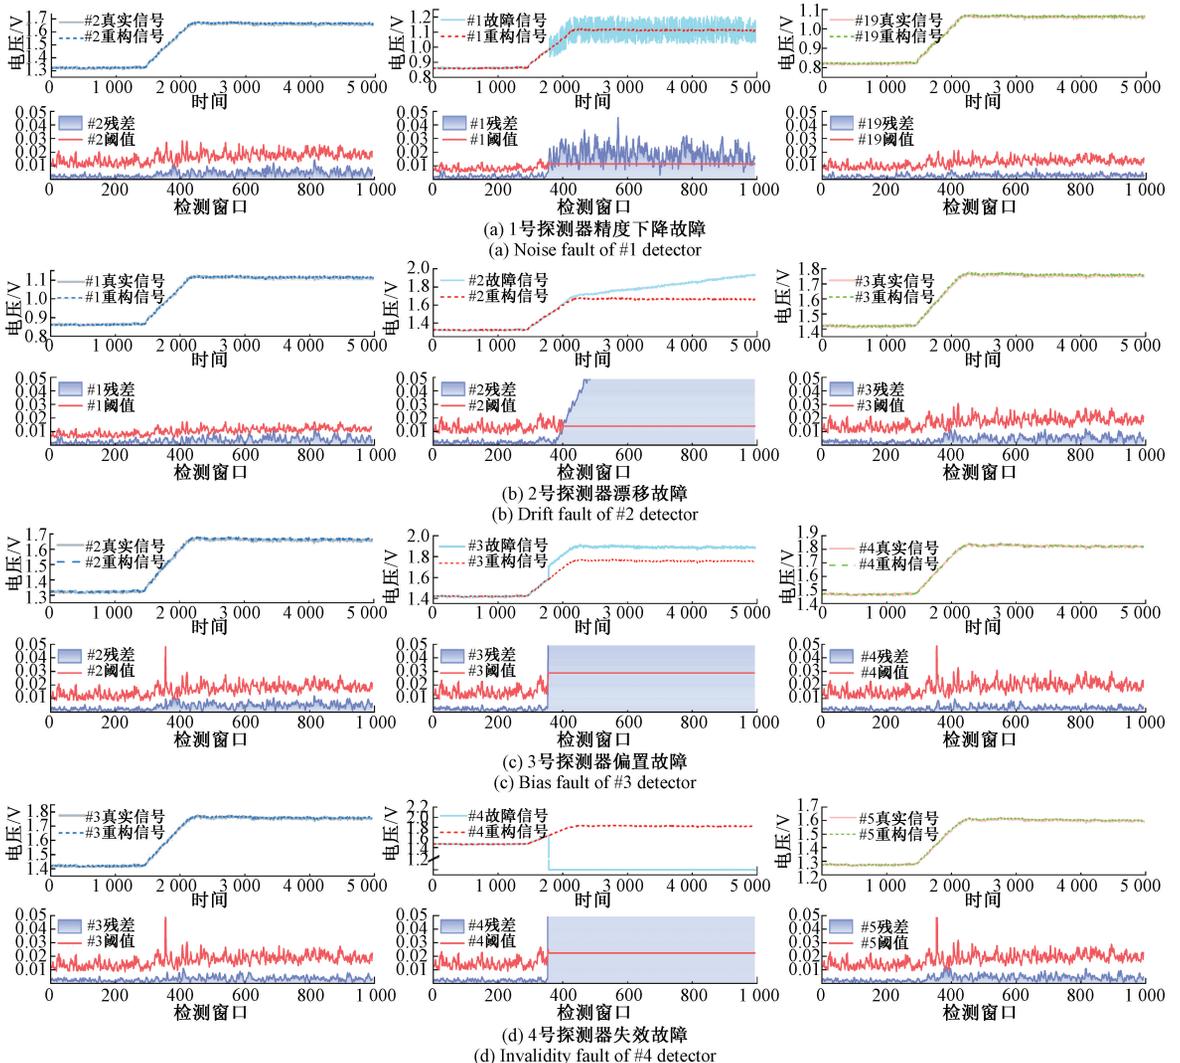


图 8 不同故障下故障探测器与周围部分探测器的重构与检测效果

Fig. 8 Reconstruction and detection performance of fault detectors and adjacent detectors under various fault conditions

以其中#1 探测器精度下降为例,故障信号存在明显噪声,由于周围探测器均为正常,在重构#1 探测器信号时,信号重构模型通过融合周围探测器的时空特征对其进行精确重构,并通过滑动窗口计算残差和动态阈值。在故障时刻,#1 探测器残差出现明显增大,超过动态阈值并产生故障报警,进而触发故障隔离机制,利用重构信号替换故障信号,并将动态阈值恒定在故障时刻。此外,由于 GCN 融合了邻居探测器的信息,受到#1 故障探测器影响,其相邻的#2 和#19 等正常探测器在故障时刻经过 GCN 融合空间信息后将包含#1 故障探测器的少量故障特征,影响重构效果,残差在该时刻附近均产生了小幅度的上升,但由于动态阈值的作用,阈值随之增大。采取故障隔离之后,#2 和#19 探测器相比于故障发生前的拟合效果变差,导致残差增大,此时动态阈值再次发挥作用,自适应地将阈值增大,避免正常探测器的误报。同理,其它3种故障情况与精度下降类似,说明了信号重构模型能够有效地融合故障探测器周围的探测器特征进行信号重构,并且动态阈值能够避免故障探测器对正常探测器信号重构的扰动。

2) 多个探测器故障

在实际场景中,除单个探测器故障外,仍需考虑多个探测器故障的情况,根据故障在堆芯外布局和故障点的集中程度,多故障又可分为分散式和集中式故障^[15]。其

中,集中式故障表现为故障探测器在空间中位置较为集中,如同一纵向或横向平面上多个探测器同时发生故障,这将导致模型输入特征中包含较多故障特征,进而影响重构性能。

考虑到堆外中子探测器不同于堆内探测器,堆外探测器更易于人员进行及时维修与更换,本文中仅考虑2个探测器同时故障的情况。从变功率测试集上选取某个功率上升段数据,共5000个采样点,并以#1和#24号探测器同时发生精度下降和失效故障为例模拟分散式情况;以#1和#2探测器同时发生漂移和偏置故障为例模拟集中式情况。多故障下,故障探测器及其周围部分探测器的重构与检测效果如图9所示。分散式情况的故障检测效果与单故障情况相似,由于故障探测器之间较为分散,重构模型受故障干扰较小,仅是与故障点相邻的小范围区域内的探测器重构受到故障影响,故障检测方法正常发挥作用。对于集中式故障情况,#1和#2号探测器同时发生故障,由于两个故障探测器在空间中的距离较近,形成局部故障点,从故障点向周围辐射的较大区域内的正常探测器经过 GCN 融合空间信息后将包含更多的故障特征。但信号重构模型不仅融合了故障探测器特征,还融合了其它正常探测器特征,通过融合多个探测器的空间特征,缓解了故障对重构的影响,并且在动态阈值和故障隔离的双重作用下,能够降低发生误报警的可能性。

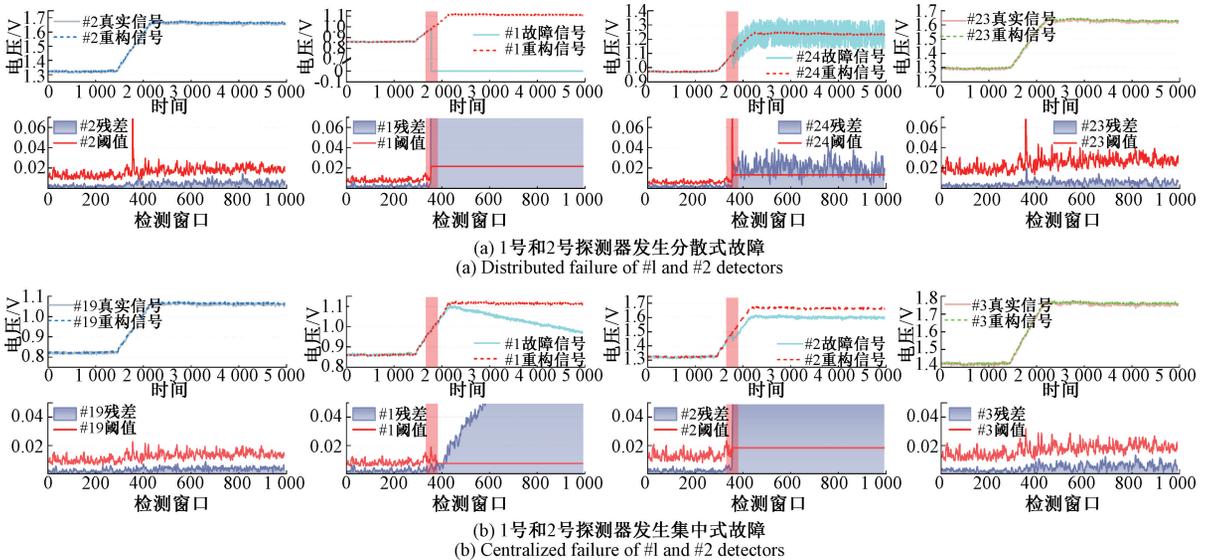


图9 多故障下故障探测器与周围部分探测器的重构与检测效果

Fig. 9 Reconstruction and detection performance of fault detectors and neighboring detectors under multiple fault conditions

3.5 动态阈值与固定阈值对比

以#6 探测器偏置故障为例,分别使用传统的 3σ 固定阈值检测方法和本文的动态阈值检测方法进行故障检测,2种方法对比如图10所示。受到#6 探测器故障影

响,在故障时刻附近,与#6 相邻的#5、#12 以及#24 探测器的重构精度均出现明显下降,残差呈现上升趋势。在某些时刻,正常探测器的残差超过 3σ 所产生的固定阈值从而产生误报警,而动态阈值能够实时更新故障检测阈

值,当模型重构精度下降或重构性能受到故障干扰时,动态阈值能够适应其带来的影响,及时调整阈值大小,避免

产生误报警。此外,动态阈值能够跟随残差的变化趋势,从而减小漏报警的可能性。

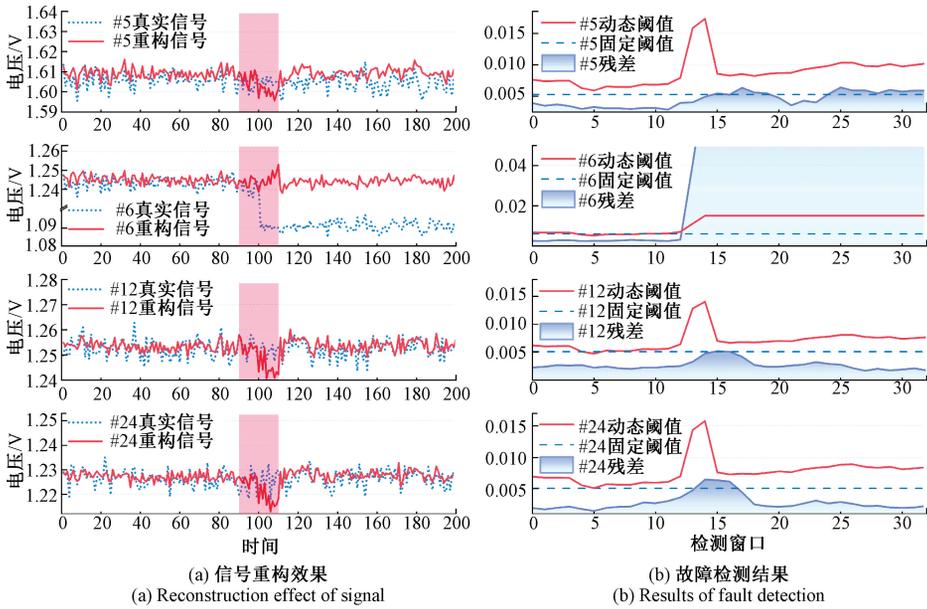


图 10 动态阈值与固定阈值比较

Fig. 10 Comparison of dynamic and fixed thresholds

3.6 不同模型信号重构性能比较

探测器的信号重构精度与故障检测性能密切相关。为了验证 STDDM 融合时空特征的优越性,本文选取 VR-XGBoost^[15]、T-GRNN^[16]、CPCA-CRA^[6]、RPANN^[14]、EOT-SVM^[13] 以及 S-GRU^[29] 模型进行实验对比,构建数据重构模型。由于上述对比模型无法与 STDDM 一样同时输出所有探测器的重构信号,为确保实验的公平性,以上对比

模型针对 24 个探测器分别构建子模型。图 11 所示为不同模型在每个探测器上的 SMAPE 误差,可以明显看出所有重构方法在满功率下的性能均优于变功率,这是由于满功率工况下功率水平基本平稳,而变功率工况下,不同功率水平的探测器信号之间存在差异,导致探测器之间的关联关系具有动态性和不稳定性,模型难于准确捕捉这种变化关系。

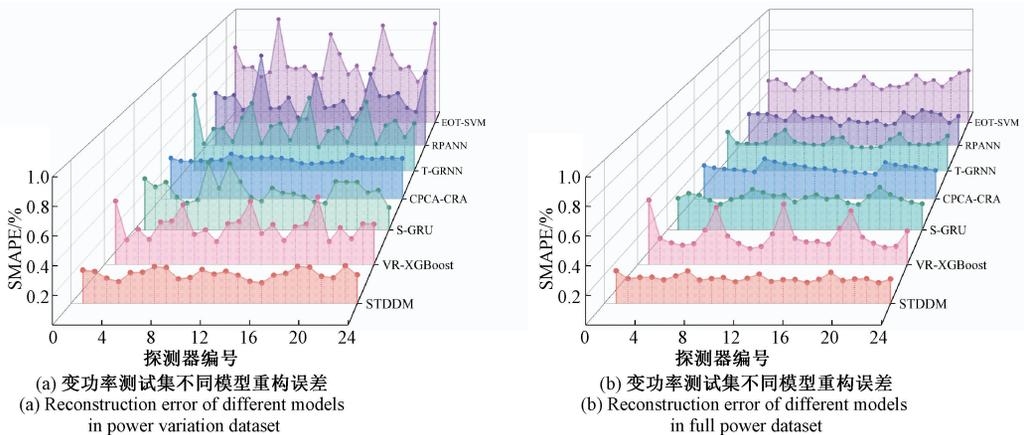


图 11 探测器信号重构误差对比

Fig. 11 Comparison of detector signal reconstruction errors

EOT-SVM、RPANN、T-GRNN 由典型的数据驱动模型

设计而来,具有非线性逼近能力,但是对于变功率下的信

号重构稳定性不足,不同探测器重构性能差异较大。CPCA-CRA 将探测器信号分解为主成分空间和残差空间,并对这 2 个空间进行重构,S-GRU 基于循环神经网络,能够有效建模探测器信号的时间序列特征,这 2 个模型在变功率和满功率测试集上的性能表现均较稳定,但由于缺少空间信息,无法捕捉特征的空间依赖关系,重构精度仍难以达到 STDDM 的水平。VR-XGBoost 作为 1 种集成学习模型,由许多强学习器组成,它在 2 个测试集上表现良好,但由于缺少获取时空规律的模块,VR-XGBoost 在重构某些探测器信号时容易产生过拟合现象。结果表明,融合时空信息的 STDDM 在变功率和满功率下均能达到较低的 SMAPE,且每个探测器的 SMAPE 水平较为平稳。

表 3 详细给出了上述模型在 2 个测试集上平均误

差。由表 3 对比分析可知,在平均 RMSE、平均 MAE 和平均 SMAPE 这 3 个评价指标上,STDDM 均取得了最优的数据重构精度,并且相比于其它模型,STDDM 在 2 个数据集上的误差水平十分接近,说明其在变功率下依然能够保持与满功率时相近的重构性能,模型能够有效捕捉变功率下的动态变化关系,具有较强的稳定性。以对比模型中性能较好的 VR-XGBoost 的误差为基准,STDDM 的 3 项重构指标在变功率下分别下降 32.2%、29.5% 和 31.7%,在满功率下分别下降 13.2%、14.8% 和 20.1%。综上,实验结果表明,STDDM 能够通过融合探测器时间和空间信息达到较优的信号重构性能,并且对于功率变化有较强的适应能力。在此后的故障检测中,重构信号被用于计算与真实信号之间的残差,进而反应故障情况,同时用于纠正故障信号。

表 3 不同模型数据重构精度对比

Table 3 Comparison of data reconstruction accuracy across different models

模型	变功率测试集			满功率测试集		
	RMSE/ 10^{-2} V	MAE/ 10^{-2} V	SMAPE/%	RMSE/ 10^{-2} V	MAE/ 10^{-2} V	SMAPE/%
EOT-SVM	0.914 6	0.733 2	0.562 4	0.724 8	0.582 7	0.383 4
RPANN	0.703 5	0.561 5	0.423 5	0.516 3	0.392 9	0.255 6
T-GRNN	0.635 2	0.518 2	0.387 0	0.474 5	0.381 8	0.254 7
CPCA-CRA	0.724 5	0.445 0	0.325 8	0.497 6	0.393 2	0.253 0
S-GRU	0.554 0	0.435 1	0.313 0	0.492 4	0.389 0	0.253 0
VR-XGBoost	0.501 1	0.385 6	0.289 1	0.387 2	0.315 8	0.221 8
STDDM	0.339 8	0.272 0	0.197 4	0.336 1	0.269 1	0.177 2

3.7 不同模型故障检测性能比较

为了验证 STDDM 在单一探测器以及多探测器故障情况下的优势,将其与 VR-XGBoost^[15]、T-GRNN^[16]、S-GRU^[29]、CPCA-CRA^[6] 和 TSANN^[14] 故障检测模型进行对比,在 2 个测试集上分别设置实验,共开展以下 4 组实验:变功率测试集单一探测器故障、满功率测试集单一探测器故障、变功率测试集多个探测器故障、满功率测试集多个探测器故障。每组实验中分别在测试集 [10 000, 20 000] 的采样点范围内的随机时刻模拟 1 000 次故障。对于单一探测器故障实验,在数据集上随机选择 1 个探测器并随机模拟成 4 种故障之一;对于多探测器故障实验,随机选取 2 个探测器并随机模拟成 4 种故障中的 2 种,从而确保故障样本充分涵盖了集中式和分散式故障情况。图 12 和表 4 分别展示了 2 个数据集上单一探测器故障和多个探测器故障时不同检测模型的性能差异,采用宏平均 P、宏平均 R、宏平均 F1 分数以及漏报率和误报率指标衡量检测效果。

所有模型在变功率数据集上的故障检测性能均略低于满功率数据集,一方面是由于模型在变功率下的重构性能较差导致故障检测中难以提供精确的重构信号,在某些时刻的重构信号将偏离真实信号导致残差增大,进而产生错误判断;另一方面,在变功率情况下探测器信号具有上升或下降趋势,在这种非平稳变化过程中发生的微小故障难以在早期被检测出来,从而产生遗漏。而基于动态阈值的方法能够自动调整阈值大小,故本文方法在 2 个数据集上均取得了较低的漏报率和误报率。

多故障下,由于故障点增多,相较于单故障情况,将有更多探测器重构受故障影响,VR-XGBoost、TSANN 和 S-GRU 通过统计学方法计算恒定的阈值,在故障检测中缺乏灵活性,无法抵抗因重构精度下降而产生的误报警,并且过大的阈值还将导致更多的故障被忽略,因此表现出较高的漏报率和误报率。对比其它故障检测模型,在 2 个不同工况数据集中,STDDM 对于单一故障和多故障的检测都表现出优势。一方面得益于 STDDM 融合探测器时间和空间特征信息的能力,不仅使信号重构精度得

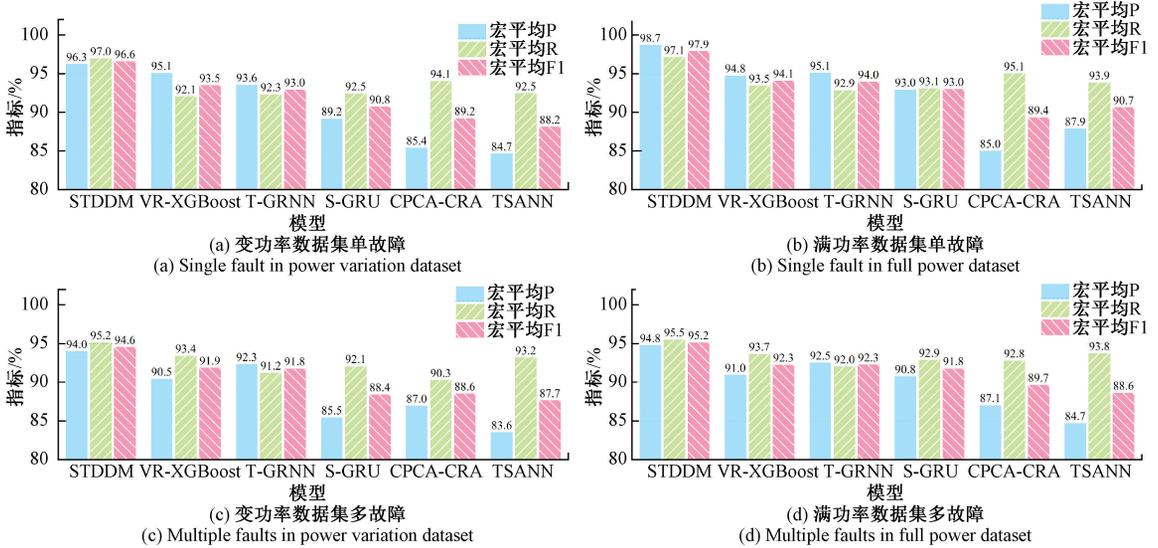


图 12 单、多探测器故障下不同模型检测精度对比

Fig. 12 Comparison of fault detection accuracy of different models under single and multiple detector faults

表 4 单、多探测器故障下不同模型漏报率与误报率对比

Table 4 Comparison of miss alarm rate and false alarm rate of different models under single and multiple detector faults (%)

模型	单一探测器故障				多个探测器故障			
	变功率测试集		满功率测试集		变功率测试集		满功率测试集	
	MAR	FAR	MAR	FAR	MAR	FAR	MAR	FAR
TSANN	14.1	0.966 3	11.6	0.718 9	11.4	2.247 3	10.5	2.038 6
CPCA-CRA	10.9	0.935 2	8.9	0.996 1	17.9	1.461 4	12.9	1.562 5
S-GRU	14.5	0.595 9	13.4	0.357 5	14.1	1.807 9	13.2	0.996 0
T-GRNN	15.1	0.313 5	14.0	0.230 6	16.8	0.746 0	15.2	0.742 0
VR-XGBoost	15.7	0.226 7	12.8	0.253 9	12.1	1.058 5	11.7	0.993 4
STDDM	5.9	0.193 0	5.7	0.060 9	9.1	0.627 7	8.4	0.538 6

到提升,而且减小故障对探测器重构的影响;另一方面,在动态阈值的作用下,故障检测阈值自适应变化,进一步降低了误报和漏报的风险。综合以上故障检测的实验结果,证明 STDDM 方法在面对多种复杂故障时能够达到较好的检测精度,并且具有较强的鲁棒性。

4 结 论

本文提出一种针对核电厂堆外中子探测器故障的 STDDM 检测方法,其结合时序卷积网络、图卷积网络以及动态阈值策略。此方法旨在克服现有故障检测方法未能充分利用探测器之间空间耦合关系的不足并解决传统固定阈值检测方法在面对复杂动态系统时的误报和漏报问题。实验分析结果表明,STDDM 通过整合时序和空间特征,有效地捕获中子探测器网络中的时空依赖关系,相

比于 VR-XGBoost、T-GRNN、TSANN 等模型,STDDM 在不稳定的变功率测试集上仍具有较高的重构精度。此外,相较于固定阈值方法,通过引入动态阈值策略,STDDM 能够根据探测器重构残差的历史表现自适应地调整阈值,不仅减少了因阈值设置不当而导致的误报和漏报,还增强了模型在不同运行状态下的稳健性,在单一探测器故障以及多探测器故障时具备优越的检测性能。综上所述,本文所提出的 STDDM 显现了较高的重构精度和故障检测准确度,验证了该方法的有效性和工程适用性。

参考文献

[1] 任大伟,肖晋宇,侯金鸣,等. 双碳目标下我国新型电力系统的构建与演变研究[J]. 电网技术,2022,46(10):3831-3839.
REN D W, XIAO J Y, HOU J M, et al. Construction and evolution of China's new power system under dual

- carbon goal [J]. *Power System Technology*, 2022, 46(10):3831-3839.
- [2] 方华松,金心明,李建文,等. 核电站传感器老化管理技术初探[J]. *仪表技术与传感器*, 2009(S1):422-424,436.
- FANG H S, JIN X M, LI J W, et al. Preliminary study on aging management of sensors in nuclear power plant[J]. *Instrument Technique and Sensor*, 2009(S1):422-424,436.
- [3] RUAN D, D' HONDT P, GOVAERTS P, et al. Intelligent systems and soft computing for nuclear science and industry[M]. *Intelligent Systems and Soft Computing for Nuclear Science and Industry*, 2015.
- [4] 胡梦岩,孔繁丽,余大利,等. 数字孪生在先进核能领域中的关键技术与应用前瞻[J]. *电网技术*, 2021, 45(7):2514-2522.
- HU M Y, KONG F L, YU D L, et al. Key technology and prospects of digital twin in field of advanced nuclear energy[J]. *Power System Technology*, 2021, 45(7):2514-2522.
- [5] DORR R, KRATZ F, RAGOT J, et al. Detection, isolation, and identification of sensor faults in nuclear power plants[J]. *IEEE Transactions on Control Systems Technology: A Publication of the IEEE Control Systems Society*, 1997,5(1):42-60.
- [6] YU Y, PENG M J, WANG H, et al. Improved PCA model for multiple fault detection, isolation and reconstruction of sensors in nuclear power plant [J]. *Annals of Nuclear Energy*, 2020, 148:107662.
- [7] COBLE J, RAMUHALLI P, BOND L, et al. A review of prognostics and health management applications in nuclear power plants [J]. *International Journal of Prognostics and Health Management*, 2015, 6 (SP3):1-22.
- [8] LIN T H, WU SH CH. Sensor fault detection, isolation and reconstruction in nuclear power plants[J]. *Annals of Nuclear Energy*, 2019, 126:398-409.
- [9] GAUTAM S, TAMBOLI P K, ROY K, et al. Sensors incipient fault detection and isolation of nuclear power plant using extended kalman filter and kullback-leibler divergence[J]. *ISA Transactions*, 2019, 92:180-190.
- [10] LI W, PENG M J, WANG Q ZH. Improved PCA method for sensor fault detection and isolation in a nuclear power plant[J]. *Nuclear Engineering and Technology*, 2019, 51(1):146-154.
- [11] YELLAPU V S, VAJPAYEE V, TIWARI A P. Online fault detection and isolation in advanced heavy water reactor using multiscale principal component analysis[J]. *IEEE Transactions on Nuclear Science*, 2019, 66(7):1790-1803.
- [12] CHOI J, LEE S J. RNN-based integrated system for real-time sensor fault detection and fault-informed accident diagnosis in nuclear power plant accidents[J]. *Nuclear Engineering and Technology*, 2022, 55(4):814-826.
- [13] RAO N S V, GREULICH C, RAMUHALLI P, et al. Estimation of sensor measurement errors in reactor coolant systems using multi-sensor fusion [J]. *Nuclear Engineering and Design*, 2021, 375:111024.
- [14] YIN Y, XU F Q, PANG B. Online intelligent fault diagnosis of redundant sensors in PWR based on artificial neural network[J]. *Frontiers in Energy Research*, 2022, 10:1011362.
- [15] XU Y, CAI Y Z, SONG L. Anomaly detection for in-core neutron detectors based on a virtual redundancy model[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72:3525811.
- [16] CHEN J, LU Y ZH, JIANG H, et al. Twin model-based fault detection and tolerance approach for in-core self-powered neutron detectors [J]. *Nuclear Science and Techniques*, 2023, 34(8).
- [17] 董雷,陈振平,韩富佳,等. 基于图卷积神经网络与 K-means 聚类的居民用户集群短期负荷预测[J]. *电网技术*, 2023, 47(10):4291-4301.
- DONG L, CHEN ZH P, HAN F J, et al. Short-term load forecasting of residential user groups based on graph convolutional neural network and K-means clustering[J]. *Power System Technology*, 2023, 47(10):4291-4301.
- [18] 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.
- [19] YANG CH Y, ZHOU K B, LIU J. SuperGraph: Spatial-temporal graph-based feature extraction for rotating machinery diagnosis[J]. *IEEE Transactions on Industrial Electronics*, 2022, 69(4):4167-4176.
- [20] 余晓霞,汤宝平,魏静,等. 强背景噪声条件下自适应图卷积神经网络的航空发动机附件机匣故障诊断方法[J]. *仪器仪表学报*, 2021, 41(8):78-86.
- YU X X, TANG B P, WEI J, et al. Fault diagnosis for aero-engine accessory gearbox by adaptive graph convolutional networks under intense background noise conditions[J]. *Chinese Journal of Scientific Instrument*,

- 2021,41(8):78-86.
- [21] 周旭华,李富,韩松,等. 堆外探测器读数与堆内功率分布的关系研究[J]. 核电子学与探测技术,2010,30(2):166-170.
ZHOU X H, LI F, HAN S, et al. Study on the relationship between ex-core detector readings and in-core power distribution[J]. Nuclear Electronics & Detection Technology, 2010,30(2):166-170.
- [22] 毛欢,熊文彬,阙骥,等. 核电站堆外核测量系统的原理及工程实践[J]. 核电子学与探测技术,2014(6):758-761,783.
MAO H, XIONG W B, QUE J, et al. Principles and engineering practice of the ex-core nuclear measurement system in nuclear power plants[J]. Nuclear Electronics & Detection Technology, 2014(6):758-761,783.
- [23] 杜颖. 核电厂核探测技术的应用[J]. 核安全,2018,17(5):47-52.
DU Y. Application of nuclear detection technology in nuclear power plant[J]. Nuclear Safety, 2018,17(5):47-52.
- [24] 杨道广,陆双桐. 百万千瓦级核电站 M310 堆型国产化堆外核探测器综述[J]. 核电子学与探测技术,2013,33(7):860-864.
YANG D G, LU SH T. Overview of the localization of ex-core nuclear detectors for the million-kilowatt M310 reactor type in nuclear power plants [J]. Nuclear Electronics & Detection Technology, 2013, 33 (7): 860-864.
- [25] BAI SH J, KOLTER J, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. [2024-04-23].
- [26] 高学金,马东阳,韩华云,等. 基于 DAE 和 TCN 的复杂工业过程故障预测[J]. 仪器仪表学报,2021,42(6):140-151.
GAO X J, MA D Y, HAN H Y, et al. Fault prediction of complex industrial process based on DAE and TCN[J]. Chinese Journal of Scientific Instrument, 2021,42(6):140-151.

- [27] 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/OL]. 中国电机工程学报,2024;1-15[2024-04-23].
LIN W Q, MIAO X R, CHEN J, et al. Fault detection and isolation for in-core self-powered neutron detectors using spatial-temporal information fusion [J/OL]. Proceedings of the CSEE, 2024;1-15[2024-04-23].
- [28] PENG X J, LI Q, WANG K. Fault detection and isolation for self powered neutron detectors based on principal component analysis [J]. Annals of Nuclear Energy, 2015, 85:213-219.
- [29] LIU B, XU Q, CHEN J Y, et al. A new framework for isolating sensor failures and structural damage in noisy environments based on stacked gated recurrent unit neural networks[J]. Buildings, 2022, 12(8):12081286.

作者简介



江灏,分别于2011年和2013年于厦门大学获得硕士和博士学位,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 received his M. Sc. degree and Ph. D. degree both from Xiamen University in 2011 and 2013, respectively. He is currently a professor at Fuzhou University. His main research interests include power fault identification and intelligent sensing systems.



陈静(通信作者),分别于2013年和2016年于厦门大学获得硕士和博士学位,现为福州大学副教授,主要研究方向为电力大数据和智能电网。

E-mail:chenj@fzu.edu.cn

Chen Jing (Corresponding author) received her M. Sc. degree and Ph. D. degree both from Xiamen University in 2013 and 2016, respectively. She is currently an associate professor at Fuzhou University. Her main research interests include power big data and smart grid.