

深度图网络驱动的核电系统多级异常检测方法^{*}

张乐¹, 成玮¹, 张硕¹, 陈雪峰¹, 常丰田¹, 洪郡滢²,
马颖菲², 彭将³

(1. 西安交通大学机械制造系统工程国家重点实验室 西安, 710049)

(2. 中国核电工程股份有限公司 北京, 100840)

(3. 福建福清核电有限公司 福清, 350318)

摘要 针对深度学习方法未明确学习变量间关系结构、系统异常难以准确检测的问题, 提出一种深度图网络驱动的核电系统多级异常检测方法。首先, 利用无监督图对比学习方法挖掘系统变量时间序列间相关性, 构建与核电系统物理结构匹配的可解释性图结构; 其次, 基于变分图自编码器重构系统图结构, 以重构误差来表征系统运行状态, 从系统层面防止非线性突发性行为带来的安全性问题; 然后, 通过半监督图卷积节点分类模型识别系统内部各变量运行状态, 实现测点级异常检测; 最后, 以 PCTranACPI00 仿真机 2 种基准事故工况数据、国内某核电机组循环水系统监测数据来验证提出方法的有效性。结果表明, 系统级异常检测准确率达到 93%, 86% 和 90%, 证明所提出方法能够准确检测出系统异常情况, 可降低电厂单一仪表异常触发的非计划停机概率。

关键词 核电系统; 无监督深度图学习; 可解释性图结构; 多级异常检测; 变分图自编码器

中图分类号 TH133.31; TH17

引言

核能是蕴含巨大风险的能源, 其物理本质决定了核安全是核电发展的生命线。我国现役电厂设备监测方式包括在线监测和离线监测^[1-2]。离线监测主要指现场仪表校准、水压实验等, 其操作流程简单但时效性差。在线监测依靠分布式控制系统的自诊断层和主控室人工巡检共同完成, 其采用的固定阈值法在面对系统与系统、设备与设备复杂数据接口, 高维度、多变量数据时易产生误判漏判。系统监测主要通过设备状态, 设备与系统功能关系来实现, 系统中非能动设备监测数据有限, 且功能关系定义复杂、时效性差。

近年来, 深度学习方法有效地解决了高维数据异常检测问题。Li 等^[3]提出基于生成对抗网络的无监督多变量异常检测方法, 实现了水处理系统异常检测。Chen 等^[4]提出基于变分自编码器, 以重构概率作为异常分数实现互联网复杂 KPI 异常检测。Huang 等^[5]提出一种基于变分自编码器的序列到序列预测模型, 该模型通过生成对抗网络进行训练, 用

于航空发动机健康状态监测。由于上述方法未明确定义系统变量间相互关系, 当单一变量受到攻击时, 系统异常检测性能随之下降, 在建模多源高维、潜在相关的传感器数据时, 系统异常检测性能难以保证, 因此如何利用多变量时间序列间复杂关系提高系统异常检测性能成为关键。复杂网络法作为描述系统交互复杂性的重要手段, 广泛用于工业过程监控研究。同时, 图神经网络通过深度学习处理图域信息, 其高效的图特征学习模式被广泛应用。

笔者提出一种深度图网络驱动的核电系统多级异常检测方法。首先, 基于系统多变量时序数据, 设计无监督图对比学习方法构建系统图结构, 实现系统部件交互作用建模; 其次, 以图数据作为输入, 通过变分图自编码器的重构误差值来表征系统运行状态; 最后, 应用半监督图卷积节点分类模型识别系统内部各变量运行状态。通过部件交互作用建模, 使单一变量的异常特征在网络邻居节点的传递、聚合和迭代更新下被减弱, 进而提升系统异常检测的准确率, 降低电厂单一仪表异常触发的非计划停机概率。

^{*} 国家重点研发计划资助项目(2019YFB1705403); 王宽诚教育基金会资助项目; 中核集团领创项目(J201912021)
收稿日期: 2022-05-31; 修回日期: 2022-07-10

1 深度图网络驱动的核电系统多级异常检测方法

1.1 基于图对比学习的图网络构建方法

复杂网络^[6]是描述交互复杂性引起的复杂行为范式的重要手段,因此构建核电系统图网络结构是首要问题。利用多元时间序列构建图网络的核心是变量之间相似性度量,现有的相似性度量方法不可避免地受到噪声干扰,导致出现不确定、冗余、错误和缺失等问题。图结构学习(graph structure learning,简称GSL)方法依赖下游任务标签来联合优化图神经网络参数和图结构数据,且学习到的边分布存在偏差。笔者提出图对比学习^[7-8]以无监督方式构建系统图网络,解决核电系统异常检测无标签数据、关系建模不足的问题。图对比学习框架如图1所示。




图1 图对比学习框架

Fig.1 Graph contrastive learning framework

为了描述图对比学习框架其组成模块功能,定义图数据及其表示。图数据 $\mathcal{G} = \{\mathcal{V}, \epsilon, \mathbf{X}\} = \{A, \mathbf{X}\}$ 以节点和边为基本元素,其中: $\mathcal{V} = \{v_1, v_2, \dots, v_n\}$, 为图中节点集; $\epsilon = \{e_1, e_2, \dots, e_m\}$, 为节点之间的边集; $\mathbf{X} \in \mathbb{R}^{n \times d}$, 为节点特征矩阵; $\mathbf{x}_n = \mathbf{X}[n, :]^T$, 为第 n 个节点的 d 维特征向量; $\mathbf{A} \in [0, 1]^{n \times n}$, 为邻接矩阵。不同于图像领域的图级对比学习范式,图对比学习方法是建立在节点层面的,即正例对来自学习图 \mathcal{G}_i 和锚图 \mathcal{G}_j 中同一节点的表示,负例对来自学习图 \mathcal{G}_i 和锚图 \mathcal{G}_j 中不同节点的表示。正例对中的锚图引导学习图中结构不断更新。

1.1.1 图数据初始化

由于核电系统无显式图结构,因此锚图初始化为 n 维单位对角阵 A_j , 其中: n 为系统变量个数; d 为时间序列长度。学习图 \mathcal{G}_i 通过余弦相似度方法进行初始化,具体如下:数据特征 $\mathbf{X}_i \in \mathbb{R}^{n \times d}$ 通过多层

感知网络(multi-layer perception,简称MLP)获得其隐层表示 E_i^l 为

$$E_i^l = \sigma(E_i^{l-1} \mathbf{W}^{(l)}) \quad (l = 1, 2, \dots, L) \quad (1)$$

其中: $\mathbf{W}^{(l)} \in \mathbb{R}^{d \times d}$, 为第 l 层权重参数矩阵; $\sigma(\cdot)$ 为非线性激活函数 ReLU; $E_i^{(0)}$ 为 \mathbf{X}_i 。

计算 E_i^l 中各变量隐层表示之间的余弦相似度,利用 k 近邻方法保留前 k 个值形成稀疏邻接矩阵 A_i^p , 进一步对其对称和归一化处理,得到初始化邻接矩阵 A_i 。

初始化后的学习图 \mathcal{G}_i 和锚图 \mathcal{G}_j 具有相同的数据特征 \mathbf{X}_i 和不同的邻接矩阵,分别为

$$\mathcal{G}_i = (A_i, \mathbf{X}_i) \quad (2)$$

$$\mathcal{G}_j = (A_j, \mathbf{X}_i) \quad (3)$$

1.1.2 图数据增强

节点特征去除 $\mathcal{T}_{fm}(\cdot)$: 以概率 $p^{(x)}$ 从伯努利分布中随机采样掩码向量 $\mathbf{c}^{(x)} \in \{0, 1\}^d$, 计算掩码向量与输入图(学习图 \mathcal{G}_i 和锚图 \mathcal{G}_j) 中各节点特征向量的哈达玛乘积,获得变换后特征矩阵 $\bar{\mathbf{X}}_i$ 。

边扰动 $\mathcal{T}_{ed}(\cdot)$: 以概率 $p^{(a)}$ 从伯努利分布中随机采样掩码矩阵 $\mathbf{M}_{ij}^{(a)} \in \{0, 1\}^{n \times n}$, 计算掩码向量与输入图(学习图 \mathcal{G}_i 和锚图 \mathcal{G}_j) 邻接矩阵的哈达玛乘积,获得变换后邻接矩阵 \bar{A}_i 和 \bar{A}_j 。

1.1.3 图数据编码及映射

将变换后图数据 $\bar{\mathcal{G}}_i = (\bar{A}_i, \bar{\mathbf{X}}_i)$ 和 $\bar{\mathcal{G}}_j = (\bar{A}_j, \bar{\mathbf{X}}_i)$ 分别输入到两层图卷积模型^[9] $f_\theta(\cdot)$, 获得节点表示向量 $H_i, H_j \in \mathbb{R}^{n \times d_1}$, θ 为共享的图卷积编码器训练参数。节点表示向量 H_i 和 H_j 通过映射网络 g_ϕ 得到隐变量 $Z_i, Z_j \in \mathbb{R}^{n \times d_1}$ 。 ϕ 为共享的映射网络训练参数,映射网络采用多层感知网络。

1.1.4 图对比学习损失函数

对称归一化温度尺度交叉熵损失^[10]被定义为图对比学习损失函数来最大化同一节点 v_a 隐变量 $z_{i,a}$ 和 $z_{j,a}$ (即正例对)之间的相似性,其中: $z_{i,a} = Z_i[a, :]^T$; $z_{j,a} = Z_j[a, :]^T$ 。

$$\mathcal{L} = \frac{1}{2n} \sum_{a=1}^n [l(z_{i,a}, z_{j,a}) + l(z_{j,a}, z_{i,a})] \quad (4)$$

$$l(z_{i,a}, z_{j,a}) = \log \frac{e^{\text{sim}(z_{i,a}, z_{j,a})/t}}{\sum_{k=1}^n e^{\text{sim}(z_{i,a}, z_{j,k})/t}} \quad (5)$$

其中: $\text{sim}(\cdot, \cdot)$ 为余弦相似度; t 为温度尺度参数; n 为节点数量; \mathcal{L} 为最大化的目标函数。

1.2 基于变分图自编码器的系统异常检测方法

变分图自编码器^[11] (variational graph auto-encoder, 简称 VGAE) 是基于图卷积网络的无监督图生成方法, 常用于边预测。该方法以无权、静态图网络作为输入, 不适用于核电时变系统异常检测问题。因此, 通过滑动窗口截取定长多变量时序数据, 以此作为图对比学习模型的输入构造图网络, 来模拟时变系统的数据流。基于系统正常运行时重构误差分布平稳, 异常运行时重构误差分布偏差较大的基本假设, 以正常图数据训练 VGAE 模型, 将训练好的模型进一步用于系统异常检测。

1.3 基于图卷积的测点异常检测方法

基于图卷积的测点级异常检测可进一步理解为测点正常或异常的二分类任务。训练数据 $G_i = (X_i, A_i)$ (含部分节点标签) 通过两层图卷积网络得到其隐层, 表示为 $H_i^{(2)} \in \mathbb{R}^{n \times 2}$, 计算函数 softmax 值得到预测标签。利用最小化预测标签与真实标签的交叉熵损失函数来优化模型参数, 将训练好的图卷积模型用于对测试数据进行节点分类, 实现异常测点识别。深度图网络驱动的核电系统多级异常检测方法流程如图 2 所示。

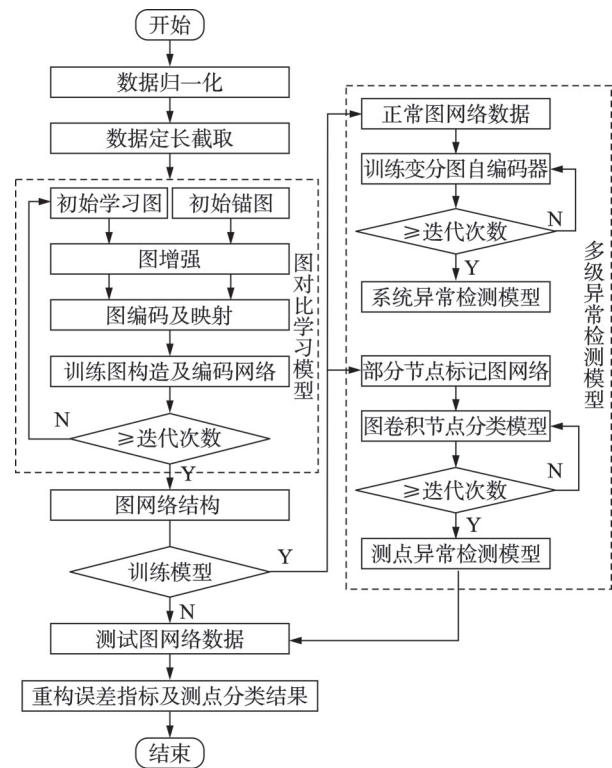


图 2 核电系统多级异常检测方法流程
Fig.2 Flowchart of multi-level anomaly detection method for nuclear power system

2 实例验证

2.1 数据描述

1) PCTranACP100 为压水堆核电机组瞬态分析仪, 可模拟反应堆不同故障瞬态并生成仿真数据。利用 PCTranACP100 模拟并生成 2 种故障瞬态, 模拟过程中可输出 70 个系统监测变量, 主要包括核岛 2 个支路(A 和 B)监测量以及堆芯反应性监测量(例如支路 A 和 B 的热端温度、冷端温度以及燃料反应性等)。模拟时长为 300 s, 异常发生时刻分别设置为 150 s 和 200 s。PCTranACP100 核电瞬态分析仪界面如图 3 所示。

2) 核电厂循环水系统负责热量交换, 是电厂的最终热阱。核电循环水泵如图 4 所示。笔者利用国内某核电厂三回路循环水泵异常停泵对应的系统监测数据验证所提出方法, 采集 3 d 的正常和异常监测数据, 采样频率为 1 Hz, 除去 6 个开关量共 30 个测点, 得到的循环水系统测点信息如表 1 所示。

3) 田纳西-伊斯曼化工反应过程基准数据集具有时变、强耦合和非线性特征, 广泛用于测试复杂工业过程的控制和故障诊断模型。

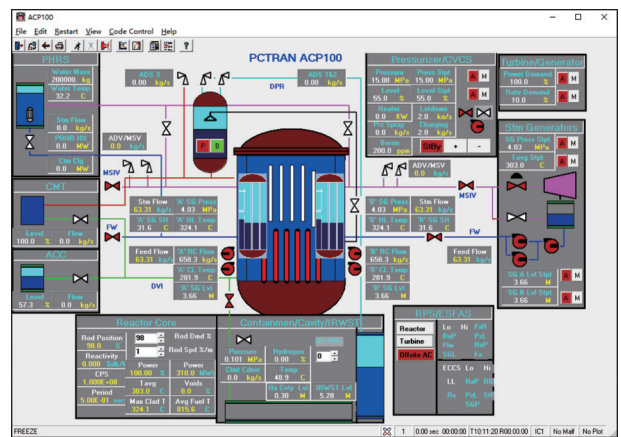


图 3 PCTranACP100 核电瞬态分析仪界面
Fig.3 Nuclear power transient analyzer of PCTranACP100




图 4 核电循环水泵
Fig.4 Circulating water pump for nuclear power plants

表1 循环水系统测点信息

Tab.1 Monitoring variables of circulating water system

序号	监测变量	数量
0	电机非驱动端三向振动	3
1	电机三相绕组温度1# 2#	6
2	电机导向轴承温度1# 2#	2
3	电机下部轴承温度1# 2#	2
4	电机推力轴承温度1# 2#	2
5	齿轮箱轴承处两向振动	2
6	齿轮箱导向轴承温度1# 2#	2
7	泵导向轴承温度	1
8	齿轮箱推力轴承温度1#2#3#4#	4
9	齿轮箱上导轴承温度1#2#	2
10	齿轮箱润滑油箱液位	1
11	低压供油口远传压力	1
12	高压供油口远传压力	1
13	润滑油远传流量	1

2.2 模型参数设置

2.2.1 提出方法

系统级异常检测过程需对系统多变量时序数据进行滑窗截取。其中:窗口宽度 W 设为 20(3 600);滑动步长 S_t 设为 20(3 600);图对比学习中 k 近邻值设为 5;掩码概率 $p^{(x)}$ 和 $p^{(a)}$ 设为 0.2 和 0.1;温度尺度 t 设为 0.2;初始化学习图的感知网络、编码网络 $f_\theta(\cdot)$ 和映射网络 $g_\varphi(\cdot)$ 的层数均为 2;编码网络 $f_\theta(\cdot)$ 的维度为 $20 \times 16 \times 8(3\ 600 \times 512 \times 64)$;映射网络 $g_\varphi(\cdot)$ 的维度为 $8 \times 8 \times 8(64 \times 64 \times 64)$;变分图自编码器的维度为 $20 \times 16 \times 8(3\ 600 \times 32 \times 8)$;括号内表示用于循环水系统监测数据时的参数。由于测点级异常检测过程不需要对系统多变量时序数据进行滑窗处理,故图卷积节点分类模型的输入维度为时序总长度 R ,即 $R \times 16 \times 2$,网络层数为 2。表 2 为超参数设置。

表2 超参数设置

Tab.2 Hyperparameter settings

超参数	数值
学习率	0.01
训练次数	40
批大小	32
验证集比例	0.2
阈值分位数	0.95

2.2.2 对比方法

1) 自编码器(auto-encoder, 简称 AE):编码网络隐层维数为 32-16-4(16-8-4),解码网络层维数为

16-32-70(8-16-30)。其中,70,30 分别为模型的输入维数,即系统测点数。

2) 长-短时记忆网络(long short term memory, 简称 LSTM):包含 2 层堆叠的长短期记忆网络和 1 层线性输出层,其建模时间序列的依赖性,设预测步长均为 5,隐层神经元个数为 100。

3) 长短时自编码器(LSTM-AE):其预测步长均设为 10,隐层神经元个数设为 100。

2.3 实验结果

2.3.1 评价指标

基于系统级监测指标,重构误差计算系统的健康系数。0 表示正常,1 表示异常,计算原理见文献[12]。选用接受者操作特征曲线下面积(area under the curve, 简称 AUC)作为评价指标。接受者操作曲线(ROC)横坐标代表假阳率(false positive rate, 简称 FRP),纵坐标代表真阳率(true positive rate, 简称 TPR)。显然,曲线下面积越大,模型性能越优。

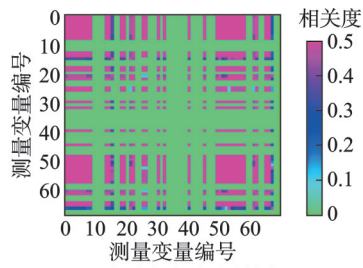
$$\begin{cases} \text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} \\ \text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \end{cases} \quad (6)$$

其中:TP 表示实际为正类,且被正确分类为正类的样本数量;TN 表示实际为负类,且被正确分类为负类的样本数量;FP 表示实际为负类但被错误分类为正类的样本数量;FN 表示实际为正类,但被错误分类为负类的样本数量。


2.3.2 图网络建模结果

构建图对比学习框架分别学习 PCTranACP100 仿真-回路系统、真实电厂三回路循环水系统监测变量之间的相关性关系,并与余弦相似度建模结果进行对比。图 5 为 PCTranACP100 仿真数据图网络。图 6 为循环水系统图网络。图 5,6 中的左图为 2 个数据集在正常工况下的余弦相似度度量图,显然,采用余弦相似度度量方法构造的网络因受噪声影响,产生大量冗余边,网络较稠密,难以和真实物理结构形成匹配关系,可解释性差。图 5,6 中的右图为 2 个数据集正常工况下图对比学习建模图,噪声影响被降低,网络具有稀疏性、低秩性,符合真实世界物理网络基本特性。

为进一步说明建模网络的有效性,将网络连接关系与物理系统结构进行对比分析。仿真-回路系统图网络与实际测点匹配关系如图 7 所示。红色数字标签表示网络中相互连接的节点与其所属于子系统的位置。数字标签 1 处表示冷却剂平均温度、A/B




(a) 余弦相似度度量图
(a) Graph of cosine similarity




(b) 图对比学习建模图
(b) Graph of contrastive learning modeling

图 5 PCTranACP100 仿真数据图网络

Fig.5 Graph networks of PCTranACP100 simulation data



(a) 余弦相似度度量图
(a) Graph of cosine similarity




(b) 图对比学习建模图
(b) Graph of contrastive learning modeling

图 6 循环水系统图网络


Fig.6 Graph networks of circulating water system

支路热段温度的关联强度;标签 2 处表示 A/B 支路冷段温度, A/B 支路冷段流量的关联强度;标签 3 处代表了蒸汽发生器、稳压器等主回路辅助系统变量间的关联关系,由于涉及变量位置分散,导致关联性较弱;标签 4 处代表堆芯中子通量功率和热功率等,因固有的热转换关系,网络表现出强关联。

图 8 为循环水系统图网络与实际测点匹配关系。数据标签 0~9 对应表 1 中测点序号。标签 0 代表电机非驱动端三向振动,三向振动变量在网络图中表现出强连接关系;标签 1 代表 2 处三相绕组温




(a) 实际物理结构测点配置
(a) Physical structure configuration of measurement points



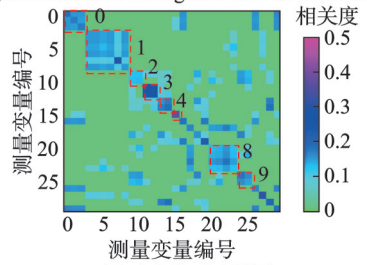
(b) 图对比学习建模图
(b) Graph of contrastive learning modeling

图 7 仿真-回路系统图网络与实际测点匹配关系

Fig.7 Matching relationships between simulation primary loop system graph network and actual measuring points



(a) 实际物理结构测点配置
(a) Physical structure configuration of measurement points



(b) 图对比学习建模图
(b) Graph of contrastive learning modeling

图 8 循环水系统图网络与实际测点匹配关系

Fig.8 Matching relationships between circulating water system graph network and actual measuring points

度测量值,共 6 个监测变量,网络同样识别出 6 个变量之间的强关联关系;标签 2, 3, 4, 8, 9 等位置处测点的关联性强度均与物理位置相匹配。实验结果说明,图对比学习框架构建的系统图网络可反映真实物理连接关系,噪声影响小,具有可解释性。

2.3.3 系统级异常检测结果

仿真-回路系统及循环水系统异常检测结果如图 9 所示。图 9(a)显示了仿真-回路系统在 2 种异常瞬态及正常满功率运行工况下的异常检测结果,异常时刻为 150 s 和 200 s。可以看出,重构误差在正常运行工况下保持平稳,在异常时刻突然增大后又逐渐恢复平稳。考虑到 2 种瞬态物理变化引发的系统内部监测变量变化程度不同,检测效果也不同。对于冷却剂热端小破口失水事故,从热端破口处流失的冷却剂具有较高的空泡率(蒸汽体积占汽液混合物的体积比),意味着少量的冷却剂损失,回路降压速率慢,可通过注入系统完成冷却液达到重新平稳状态。因此,异常瞬态后系统会重新达到稳定状态。从图 9(b)可看出,重构误差在停泵故障时出现突然增大趋势,然后保持在较高水平,这说明系统检测指标在实际电厂数据异常检测中同样具有较好的灵敏度和准确性。

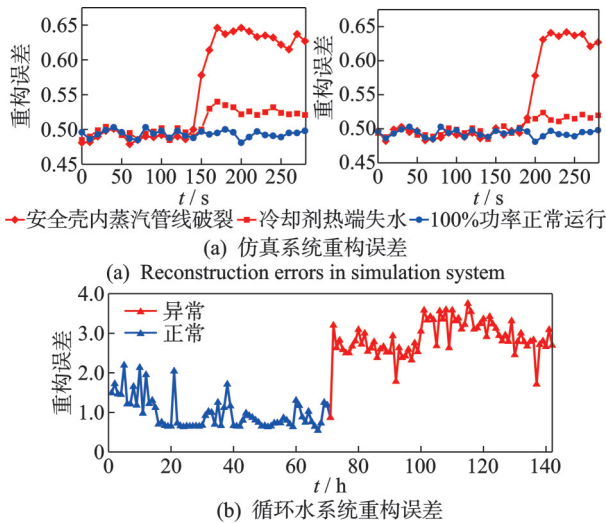


图 9 仿真-回路系统及循环水系统异常检测结果
Fig.9 Anomaly detection results of simulation primary loop system and circulating water system

为证明重构误差指标对噪声干扰的鲁棒性,对安全壳内蒸汽管线破裂工况下,异常时刻为 150 s 的异常数据添加信噪比分别为 20, 22, 24, 26, 28 和 30 dB 的高斯白噪声。由信噪比(signal-to-noise ratio, 简称 SNR)来衡量的不同噪声干扰下重构误差曲线及检测准确率如图 10 所示。可以看出,噪声影响下正常重构误差值较 9(a)中的结果整体增大并伴随波动,即正常重构误差的分布出现偏差,但在异常时刻均表现出明显的增加趋势,异常检测准确率受波动值的影响有不同程度的降低。




图 10 不同噪声干扰下重构误差曲线及检测准确率
Fig.10 Reconstruction error curves and detection accuracy under different noise disturbances

2.3.4 测点级异常检测结果

系统性异常检测是融合多监测变量信息的综合性评估结果,传感器和探测器等仪器故障对系统可靠性影响较小。因此,需进一步对系统内部各变量进行异常识别,系统内部变量异常检测结果如图 11 所示。其中:A 为仿真数据集安全壳内管线破裂瞬态数据;B 为冷却剂热端失水事故瞬态数据;C 为循环水系统数据。安全壳内蒸汽管线破裂工况下测点异常检测准确率为 91.4%,漏警率为 38%,虚警率为 1.7%。冷却剂热端失水事故工况下测点异常检测准确率为 85.7%,漏警率为 0%,虚警率为 31.2%。循环水系统测点异常检测准确率为 85%,漏警率为 0%,虚警率为 13.3%,对安全壳内蒸汽管线破裂工况下漏警率较高的原因进一步分析可知,在该工况下异常测点数量远小于正常测点数量,训练数据集存在类不平衡问题,导致半监督图卷积节点分类模型训练不够充分,少量异常测点被分类为正常,最终造成漏警率偏高。




图 11 内部变量异常检测结果
Fig.11 Anomaly detection results from internal variables of the systems

笔者采用田纳西-伊斯曼基准数据集(te1~te10)以及数据 A, B, C 来验证所提出方法的有效性,不同方法对比结果如表 3 所示。对于 te1~te10 异常工况数据,提出方法虽未在所有工况下取得最优的检测性能,但平均性能最优、方差值最小。这说明了所提

出方法的异常检测稳定性,同时也说明了AE, LSTM和LSTM-AE方法由于需预先设定残差阈值,在实际应用中受人为因素和先验知识的影响,准确度存在较大波动。此外,所提出方法在数据集 \mathcal{A} , \mathcal{B} , \mathcal{C} 中分别取得93%, 86%和90%的检测准确率,均优于对比方法。

表3 不同方法准确率对比结果

Tab.3 Comparison results of the accuracy of different methods

数据集	所提出方法	AE	LSTM	LSTM-AE
te1	0.952	0.995	0.962	0.976
te2	0.919	0.995	0.975	0.982
te3	0.882	0.836	0.525	0.535
te4	0.935	0.914	0.948	0.535
te5	0.940	0.882	0.650	0.987
te6	0.994	0.924	0.983	0.672
te7	0.924	0.978	0.997	0.987
te8	0.949	0.829	0.960	0.988
te9	0.933	0.914	0.447	0.979
te10	0.908	0.928	0.758	0.825
μ	0.934	0.920	0.820	0.846
σ^2	± 0.001	± 0.002	± 0.020	± 0.010
\mathcal{A}	0.930	0.915	0.920	0.919
\mathcal{B}	0.860	0.798	0.774	0.830
\mathcal{C}	0.90	0.741	0.758	0.735
μ	0.897	0.818	0.817	0.828
σ^2	± 0.0005	± 0.015	± 0.013	± 0.017

3 结论

1) 不同于相似度量法和基于任务联合优化的图网络建模方法,图对比学习建模的图结构可有效降低噪声干扰,独立于下游任务,具有可解释性。

2) 通过部件交互作用建模,使得单一变量的异常特征在网络邻居节点的传递、聚合和迭代更新下被减弱,系统异常检测准确率得到有效提升,分别达到93%, 86%和90%,可以降低电厂单一仪表异常触发的非计划停机概率。

参 考 文 献

- [1] D'AURIA F S, GLAESER H, LEE S, et al. Best estimate safety analysis for nuclear power plants: uncertainty evaluation: safety report series[R]. Vienna: International Atomic Energy Agency, 2008.
- [2] 许勇, 蔡云泽, 宋林. 基于数据驱动的核电设备状态评估研究综述[J]. 上海交通大学学报, 2022, 56(3): 267-278.
XU Yong, CAI Yunze, SONG Lin. Review of research on condition assessment of nuclear power plant equip-

ment based on data-driven[J]. Journal of Shanghai Jiao Tong University, 2022, 56(3): 267-278. (in Chinese)

- [3] LI D, CHEN D, JIN B, et al. MAD-GAN: multivariate anomaly detection for time series data with generative adversarial networks[C]//International Conference on Artificial Neural Networks. [S. l.]: Springer, 2019: 703-716.
- [4] CHEN W, XU H, LI Z, et al. Unsupervised anomaly detection for intricate kpis via adversarial training of vae [C]//IEEE Conference on Computer Communications. Paris, France: IEEE, 2019: 1891-1899.
- [5] HUANG Y, TANG Y F, VAN-ZWIETEN J. Prognostics with variational autoencoder by generative adversarial learning[J]. IEEE Transactions on Industrial Electronics, 2021, 69(1): 856-867.
- [6] 姜洪权, 高建民, 陈富民, 等. 基于复杂网络理论的流程工业系统安全性分析[J]. 西安交通大学学报, 2007, 41(7): 806-810.
JIANG Hongquan, GAO Jianmin, CHEN Fumin, et al. Safety analysis to process industry system based on complex networks theory[J]. Journal of Xi'an Jiaotong University, 2007, 41(7): 806-810. (in Chinese)
- [7] LIU Y X, ZHENG Y, ZHANG D K, et al. Towards unsupervised deep graph structure learning [EB/OL]. (2022-01-22)[2024-06-13]. <https://arXiv.org/abs/2201.06367>.
- [8] YOU Y N, CHEN T L, SUI Y D, et al. Graph contrastive learning with augmentations [J]. Advances in Neural Information Processing Systems, 2020, 33: 5812-5823.
- [9] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[EB/OL].(2016-09-09) [2024-06-13]. <https://arXiv.org/abs/1609.02907>.
- [10] SOHN K. Improved deep metric learning with multi-class n-pair loss objective [J]. Advances in Neural Information Processing Systems, 2016, 29: 1857-1865.
- [11] KIPF T N, WELING M. Variational graph auto-encoders [EB/OL]. (2016-11-21) [2024-06-13]. <https://arXiv.org/abs/1611.07308>.
- [12] YANG C Z, LIU J Q, ZENG Y Y, et al. Real-time condition monitoring and fault detection of components based on machine-learning reconstruction model [J]. Renewable Energy, 2019, 133: 433-441.



第一作者简介:张乐,女,1995年3月生,博士生。主要研究方向为核电系统运维与健康管理。

E-mail: zhangle0028@stu.xjtu.edu.cn

通信作者简介:成玮,男,1983年6月生,博士、教授、博士生导师。主要研究方向为高端装备智能运维与健康管理。

E-mail: chengw@mail.xjtu.edu.cn