

核电多回路系统多源传感器异常检测的 AAKR-SPRT 方法*

谢述帅, 成 玮, 张 乐, 聂泽琳, 陈雪峰, 李 芸

(西安交通大学航空动力系统与等离子体技术全国重点实验室 西安, 710049)

摘要 针对核电多回路耦合系统在升功率运行中异常传感器检测困难、检测延时及检测精度低等问题,提出了一种自联想核回归模型(auto-associative kernel regression,简称 AAKR)与修正序贯概率比检验(sequential probability ratio test,简称 SPRT)相结合的方法。首先,利用小波软阈值降噪方法对监测数据预处理,获取高质量的多源传感器解调信号;其次,采用 AAKR 构造传感器正常运行数据的估计值,并获取多源传感器测量值与估计值之间的残差;然后,运用滑动时间窗获取不同阶段残差向量的均值和方差,设计一种 SPRT 检测规则对传感器残差进行异常检测;最后,用核电一、二回路耦合系统模拟机实验数据进行方法验证与性能分析。结果表明,所提传感器异常检测方法的准确率达到 99.52%,异常检测延时降低了 81.73%,可有效提高现有核电厂传感器异常检测的稳定性。

关键词 核电系统;传感器异常检测;自联想核回归;序贯概率比检验;小波阈值降噪

中图分类号 TL362.3;TH17

引 言

随着现代工业的快速发展,多通道传感技术广泛应用于复杂机械的运行状态监测,通过多源传感信息监测以评估系统整体运行的健康状态^[1-2]。在核电厂运行过程中,实时准确地监测数据是核电厂健康状态评估的首要环节。然而,在核电厂实际运行过程中,因为一、二回路的传感器长期处于严苛的工作环境中,其功能和状态会偏离初始的设定,导致获取的实时监测数据偏离正常值,严重情况下将造成监测系统出现虚警和漏警现象。为解决这一问题,核电厂主要采用周期性校正或更换故障传感器,这种传统的方法效率低下且无法避免维修中带来的其他故障。近年来,基于系统实时运行状态的在线监测技术得到广泛的关注,该项技术通过对监测数据进行分析以评估传感器的健康状态^[3]。

目前,传感器异常检测主要分为基于统计分析方法和数据驱动方法。统计分析方法主要通过对正常数据的重构及假设检验判定传感器是否异常。金典等^[4]采用独立成分分析与序贯概率比检验(independent component analysis-sequential probability ra-

tio test,简称 ICA-SPRT)相结合的方法实现核电站主蒸汽系统压力传感器异常检测。张文安等^[5]提出了一种基于子图拉普拉斯谱(Laplacian spectrum of sub-graph,简称 LSSG)的异常传感器检测及识别方法。基于模型的方法具有解释性强、易于实施等优点,但不适用于高维复杂的数据分布。数据驱动方法主要通过机器学习或者深度学习对大量监测数据进行训练,以实现传感器异常检测。Debasish 等^[6]采用卷积神经网络监测故障类型,并使用卷积自编码器进行异常数据重构。宫文峰等^[7]针对汽车定位传感器易受攻击的问题,采用改进的一维卷积神经网络用于传感器异常检测。然而,基于数据驱动的传感器异常检测方法需要大量的正常与异常传感数据进行模型训练,才能获取足够的诊断精度。

综上所述,现有传感器异常检测方法存在以下不足:①现有传感器异常检测方法都是在恒定工况下实现异常检测;②现有传感器失效检测存在一定的监测延时现象。为了实现核电多回路耦合系统在变工况下的传感器异常检测,笔者提出了一种结合自联想核回归与修正序贯概率比检验相结合的方法用于多源传感器异常检测。

* 国家重点研发计划资助项目(2019YFB1705403);国家自然科学基金资助项目(52105121);王宽诚教育基金会资助项目

收稿日期:2023-11-22;修回日期:2024-03-21

1 多源传感器异常检测方法原理

本研究所提传感器异常检测方法流程图如图 1 所示。首先,采用小波阈值降噪完成多源传感器监测数据预处理;其次,采用 AAKR 模型计算传感器正常数据重构值,并获取残差向量;最后,采用恒定的滑动时间窗实现残差向量数据分割,以获取不同时间区间的均值和方差,并通过修正 SPRT 对残差进行检验,实现传感器异常诊断。




图 1 传感器异常检测方法流程图

Fig.1 Flow chart of sensor anomaly detection method

1.1 小波阈值降噪

小波阈值降噪(wavelet threshold denoising, 简称 WTD)是一种计算量相对较少的降噪方法,其本质是对小波分解后的各层高频系数进行阈值量化处理,再将处理后的系数反变换重构出降噪后的信号。该方法的关键在于高频数据阈值量化,本研究主要采用软阈值量化方法^[8],其阈值函数为

$$\tilde{c}(i) = \begin{cases} \text{sign}[c(i)][|c(i)| - \beta(i)] & (|c(i)| \geq \beta(i)) \\ 0 & (|c(i)| < \beta(i)) \end{cases} \quad (1)$$

其中: $c(i)$ 为原始高频系数; $\tilde{c}(i)$ 为量化后的高频系数; $\beta(i)$ 为随分解尺度变化的阈值。

$$\beta(i) = \sigma i + \sqrt{2 \log N} / \log(i+1) \quad (2)$$

其中: σ 为待分解信号标准差; N 为采样信号数据长度; i 为分解尺度大小。

1.2 基于 AAKR 模型的信号重构

不同的统计建模技术被广泛应用于信号重建问题,如自联想核回归^[9]、主成分分析^[10]、偏最小二乘方法^[11]等。由于 AAKR 模型是相似性建模方法中的一种,属于非参数建模技术^[12]。同时,AAKR 主

要利用记忆矩阵实现记忆向量与待检测样本向量的相似性来获取当前样本的偏差,无需故障数据训练模型,适用于故障样本数据少的核电场景建模。因此,笔者选择 AAKR 模型用于传感器健康监测数据重构。AAKR 模型的训练主要包括核函数带宽选取、向量选取、记忆矩阵选取和距离选取。

向量选取时从训练数据中选择合适数量的状态向量作为模型的记忆矩阵。记忆矩阵用于保存历史状态样本点,记为 X ,数据结构为 $[m \times n]$ 的矩阵。对于 m 个观测点和 n 个观测值,记忆矩阵定义为

$$X = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,n} \\ x_{2,1} & x_{2,2} & \cdots & x_{2,n} \\ \vdots & \vdots & & \vdots \\ x_{m,1} & x_{m,2} & \cdots & x_{m,n} \end{bmatrix} \quad (3)$$

其中: $x_{i,j}$ 为第 i 个观测点中第 j 个观测值。

待检测数据向量定义为

$$\hat{x} = [\hat{x}_1, \hat{x}_2, \cdots, \hat{x}_n] \quad (4)$$

由于传统的欧氏距离仅关注监测信号中的突变信息,易受其他噪声干扰,并不适用于核电厂中调制严重的复杂信号。因此,笔者通过删除最大距离或性能最差的欧氏距离以获取更加稳健的距离函数,降低随机误差对模型的影响,提高模型的鲁棒性。第 i 个观测数据与记忆矩阵之间的距离公式为

$$d_i = \sqrt{\sum_{j=1}^n (x_{i,j} - \hat{x}_j)^2 - \max_{j=\{1,2,\cdots,n\}} [(x_{i,j} - \hat{x}_j)^2]} \quad (5)$$

其中: d_i 为第 i 观测点的观测数据和记忆矩阵的距离; $x_{i,j}$ 为第 i 个观测点中第 j 个观测值; $\hat{x}_j$ 为待检测数据向量第 j 观测值。

通过计算 m 个观测数据的距离,获取 m 个距离向量,则距离矩阵 d 计算如下

$$d = \begin{bmatrix} d(x_1, \hat{x}) \\ d(x_2, \hat{x}) \\ \vdots \\ d(x_m, \hat{x}) \end{bmatrix} \quad (6)$$

其中: $x_i = [x_{i,1}, x_{i,2}, \cdots, x_{i,n}]$,为第 i 个观测点的观测向量。

通过距离矩阵进行相似性量化,通过距离矩阵 d 计算高斯核为

$$w_i = \frac{1}{\sqrt{2\pi h^2}} e^{-d_i^2/2h^2} \quad (7)$$

其中: h 为核函数带宽; $d_i = d(x_i, \hat{x})$ 。

综合核函数带宽,分配测试数据的权重矩阵 w 为

$$w = [w_1, w_2, \cdots, w_m]^T \quad (8)$$

输出预测无误差样本向量的加权平均,将其转化为如下方程形式

$$\tilde{x} = \frac{\sum_{i=1}^m (w_i x_i)}{\sum_{i=1}^m w_i} \quad (9)$$

其中: $\tilde{x}$ 为测试数据 $\hat{x}$ 的估计值; w_i 为第 i 观测点样本权重; x_i 为第 i 个观测点的观测向量。

1.3 基于修正SPRT的传感器异常检测

SPRT是一种二元随机假设检验,其按顺序分析过程观测值,并确定观测值是否与给定概率定律表示的零条件假设一致^[13]。在本研究中,序列向量 $r = \{r_1, r_2, \dots, r_n\}$ 为传感器实测值与重构值的残差向量,其服从高斯分布。不失一般性,假设事件 H_0 表示传感器正常情况下的残差分布, $H_0 \sim (\mu_0, \sigma_0^2)$; H_1 表示传感器异常时的残差分布, $H_1 \sim (\mu_1, \sigma_1^2)$ 。在SPRT传感器异常检测中,通常假定 $\sigma_1^2 = \sigma_0^2$,则似然比为

$$L(t) = \ln \frac{P(\{x_1, x_2, \dots, x_n\} | H_1)}{P(\{x_1, x_2, \dots, x_n\} | H_0)} \quad (10)$$

其中: $P(\{x_1, x_2, \dots, x_n\} | H_s)$ 为事件 H_s 的条件概率密度函数。

因残差向量 r 服从高斯分布,故式(10)可化为

$$L(t) = \exp \left[-\frac{1}{2\sigma_0^2} \sum_{i=1}^n (x_i - \mu_1)^2 + \frac{1}{2\sigma_0^2} \sum_{i=1}^n (x_i - \mu_0)^2 \right] \quad (11)$$

传感器异常检测时,将似然比 $L(t)$ 与上限 $A = (1 - \beta)/\alpha$ 和下限 $B = \beta/(1 - \alpha)$ 进行对比。其中: α 为误警率; β 为漏警率。当 $L(t) \leq B$ 时,接受 H_0 假设;当 $L(t) \geq A$ 时,接受 H_1 假设;当 $B < L(t) < A$ 时,继续抽样。为了便于计算,对式(10)取对数,即

$$\ln L(i) = \ln L(i-1) + \gamma(i) \quad (12)$$

其中: $\gamma(i) = \left(-(x_i - \mu_1)^2 + (x_i - \mu_0)^2 \right) / 2\sigma_0^2$, 记 $\text{SPRT}(i) = \ln L(i)$ 。

为了便于SPRT与上限值 A 和下限值 B 进行比较,同时对 A 和 B 取对数,即 $\ln A = \ln((1 - \beta)/\alpha)$, $\ln B = \ln(\beta/(1 - \alpha))$ 。

在异常检验过程中,由于 $\text{SPRT}(i)$ 始终在0上下波动,当 $\text{SPRT}(i-1) < 0$ 时,可能会使 $\text{SPRT}(i) < 0$,导致传感器检测结果为正常,出现漏警现象。此外,对于变工况的工作环境,残差向量 $r = \{r_1, r_2, \dots, r_n\}$ 的方差大,降低了检测准确率。因

此,笔者对于传统SPRT算法进行修正。首先,采用滑动时间窗获取不同阶段残差向量的均值和方差;其次,对式(11)进行修订以实现传感器微弱故障的检测。修订公式为

$$\hat{L}(t) = \exp \left[-\frac{1}{2s_0} \sum_{i=1}^n (x_i - \bar{x}_1)^2 + \frac{1}{2s_0} \sum_{i=1}^n (x_i - \bar{x}_0)^2 \right] \quad (13)$$

其中: $\bar{x}_0, \bar{x}_1$ 分别为滑动窗内正常传感器和异常传感器的样本均值; s_0 为滑动时间窗内正常传感器残差样本标准差。

最后,给出以下决策规则:

- 1) 假设传感器初始状态正常,令 $\text{SPRT}(0) = 0$;
- 2) 当 $\text{SPRT}(i-1) < 0$ 时, $\text{SPRT}(i) = 0$;
- 3) 当 $\text{SPRT}(i) < \ln A$ 时,接受 H_0 假设,继续检验;
- 4) 当 $\text{SPRT}(i) \geq \ln A$ 时,接受 H_1 假设,则传感器故障。

2 实验分析

2.1 数据集描述

实验数据通过核电厂一、二回路耦合系统模拟机中相关仪表获取,主要包括压力、流量和温度等13个仪表。仿真实验台架结构图如图2所示。试验台运行工况主要有以下4种:6 kW→7 kW(工况1); 8 kW→9 kW(工况2); 10 kW→11 kW(工况3); 12 kW→13 kW(工况4)。实验中采样频率为10 Hz,共有234个数据集样本。实验数据集描述见表1。实验获取的传感器数据集主要包括升功率过程中各种工况下正常传感器数据和异常传感器数据(缺失、卡滞及漂移等)。每种工况下,系统的传感器故障分为单一传感器故障和多传感器故障。




图2 仿真实验台架结构图

Fig.2 Structure diagram of simulation experiment bench

表 1 实验数据集描述

Tab.1 Experimental dataset description

工况	样本长度	正常样本	异常样本	样本总计
1	3 882	13	78	91
2	4 436	13	52	65
3	3 127	13	26	39
4	7 006	13	26	39

2.2 评价指标

为了定量评估所提方法的性能,采用均方误差(mean-square error,简称MSE)和平均绝对误差(mean-average error,简称MAE)评估AAKR模型的重构精度。MSE和MAE计算如下

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (\tilde{x}_i - x_i)^2 \quad (14)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |\tilde{x}_i - x_i| \quad (15)$$

其中: N 为样本数量; $\tilde{x}_i$ 为模型重构值; x_i 为传感器实测值。

此外,还采用查准率(precision ratio,简称PR)和F1均值评估方法对异常传感器检测的性能,该指标的计算方式见文献[7]。

2.3 实施过程

本实验数据集包含4种工况下单个和多个传感器失效。首先,采用核函数带宽为0.12的AAKR模型对传感器正常运行数据进行重构;其次,采用窗大小为100的滑动时间窗划分数据,并计算每个窗口内正常数据残差的均值 μ_0 和标准差 s_0 ,时间步为100;最后,获取每种工况下不同传感器的残差分布,用SPRT检验每个通道残差分布的均值 μ_1 。其中:SPRT中误警率 α 取0.01;漏警率 β 取0.001^[4]。当似然比大于或等于报警阈值 $\lambda_{\text{up-th}}$ 时,即 $\lambda(i) \geq \lambda_{\text{up-th}} = \ln A = \ln((1-\beta)/\alpha) = 2.996$,表明SPRT在第 i 点发现了故障。一般情况下根据实际检测需求, α, β 可取0.1,0.05,0.01,0.005。

2.4 实验结果与分析

为了验证所提AAKR模型的重构性能,分别对不同工况下不同传感器监测值进行重构。传感器正常值与重构值获取的残差如图3所示。可以看出,所提AAKR的重构值与正常值的残差小于0.01,具有良好的重构效果。此外,为了测试AAKR模型对




图3 传感器正常值与重构值获取的残差

Fig.3 Residual obtained by sensor normal value and reconstruction value

故障传感器数据重构精度,笔者对传感器数据缺失、数据卡滞、零点漂移和前向量程漂等典型故障进行了重构残差分析。异常传感器重构残差如图4所示。某种工况下进行多组实验,分别获取异常传感器的监测数据和该型号正常传感器的监测数据,两者之间的差值为实际残差。某种工况下异常传感器数据通过AAKR模型重构后获得重构数据,其与该传感器正常运行数据的差值为重构残差。由图4可以看出,在不同故障传感器的残差分布图中,重构残差与实际残差具有相同的分布趋势,这有利于提高SPRT传感器失效检测精度。

为了进一步验证所提方法的性能和优势,将其与现有的自回归滑动平均(auto regressive moving average,简称ARMA)模型^[3]、独立成分分析和序贯概率比检验(independent component analysis-sequential probability ratio test,简称ICA-SPRT)模型^[4]、LSSG模型^[5]和一维全局均值池化卷积神经网络(one-dimensional global average pooling convolutional neural networks,简称1DGAP-CNN)模型^[7]等算法进行对比分析。4种工况下不用方法重构精度如表2所示。可以看出:所提方法具有良好的重构精度,其误差最低;1DGAP-CNN神经网络方法重构精度最差,这是因为本实验数据集为小样本变工况数据集,不利于神经网络模型训练,导致重构误差偏大。




图4 异常传感器重构残差

Fig.4 Reconstruction residual of abnormal sensor

表2 4种工况下不同方法重构精度
Tab.2 Reconstruction accuracy without method under four operating conditions

工况	评价指标	ARMA	ICA-SPRT	LSSG	1DGAP-CNN	所提方法
1	MSE	0.078	0.063	0.086	0.124	0.012
	MAE	0.092	0.098	0.102	0.184	0.047
2	MSE	0.082	0.083	0.094	0.118	0.017
	MAE	0.096	0.102	0.101	0.124	0.045
3	MSE	0.081	0.079	0.098	0.121	0.029
	MAE	0.096	0.087	0.113	0.133	0.060
4	MSE	0.103	0.091	0.109	0.119	0.045
	MAE	0.101	0.107	0.113	0.122	0.083

为了验证所提方法在4种升功率工况下进行异常传感器检测的性能,使用本研究修正SPRT算法对异常传感器残差进行检验。以6 kW→7 kW运行工况异常传感器检测为例,6个子数据集中传感器判别为异常状态。工况1传感器异常状态判别结果如表3所示。可以看出,所提方法对每种子数据集中传感器的健康判别结果都符合实际传感器健康状态。工况1异常传感器残差检测结果如图5所示。可以看出,SPRT算法监测指标均在传感器异常时刻超过设定阈值,因此能够及时有效地检测出异常传感器。

此外,工况4(12 kW→13 kW升功率工况)传感器异常状态判别结果和残差检测结果分别如表4和图6所示。可以看出,所提方法在多源传感器异常状态检测中仍具有良好的性能。

表3 工况1传感器异常状态判别结果

Tab.3 Results of distinguishing abnormal state of sensor under working condition 1

子数据集	实际异常传感器	异常检测结果
1	6(零点漂移)	6异常
2	6(数值缺失)	6异常
3	4(零点漂移)	4异常
4	6(数值卡滞)	6异常
5	6(零点漂移)	6异常
6	6(非线性漂移)	6异常




图5 工况1异常传感器残差检测结果

Fig.5 Residual detection results of multiple abnormal sensors in condition 1

表4 工况4传感器异常状态判别结果

Tab.4 Results of distinguishing abnormal state of sensor under working condition 4

子数据集	实际异常传感器	异常检测结果
1	4,6(前向量程漂移)	4,6异常
2	4,6(前向量程和零点漂移)	4,6异常

为了进一步验证所提方法对传感器异常检测的性能优势,将其与现有4种方法进行了对比分析。5种传感器异常检测方法在4种工况中的性能如表5所示。由异常检测的F1得分可以看出:ARMA,




图 6 工况 4 多个异常传感器残差检测结果

Fig.6 Residual detection results of multiple abnormal sensors in condition 4

表 5 5 种传感器异常检测方法在 4 种工况中的性能

Tab.5 Performance of five sensor anomaly detection methods under four operating conditions

%						
工况	评价指标	ARMA	ICA-SPRT	LSSG	1DGAP-CNN	所提方法
1	PR	96.89	97.29	97.23	93.38	99.82
	F1	95.27	96.93	95.92	90.56	99.61
2	PR	94.03	95.29	96.38	91.93	99.79
	F1	92.74	92.38	93.67	89.04	99.53
3	PR	94.37	96.17	95.02	93.78	99.76
	F1	91.29	94.55	93.41	90.12	99.59
4	PR	93.38	94.29	93.09	88.31	99.69
	F1	90.14	91.02	91.76	85.19	99.34
F1 均值		92.86	94.22	93.69	88.73	99.52

ICA-SPRT, LSSG 和 1DGAP-CNN 在 4 种工况下平均得分分别为 92.86%, 94.22%, 93.69% 和 88.73%, 本研究所提方法得分为 99.52%; 在多传感器同时故障时, 其他 4 种方法检测精度有所下降, 而本研究方法仍具有 99.34% 的检测精度。因此, 所提方法具有更高的检测精度和稳定性。

2.5 消融实验

本研究所提方法主要是通过以下 4 个步骤实现传感器异常检测: ①原始采集监测信号; ②小波阈值降噪; ③基于 AAKR 模型的信号重构; ④修正 SPRT 实现传感器异常检测。为了充分说明所提方法中各模块的重要程度, 进行了相关消融实验。模型 1(无 WTD 模型): 无小波阈值降噪, 其他 3 个步骤不变; 模型 2(传统 SPRT 模型): 未对 SPRT 进行

修正, 采用传统的 SPRT 检验方法, 其他 3 个步骤不变。通过 MSE 和 F1 指标衡量消融实验各模型的性能。消融实验结果如表 6 所示。可以看出: 在没有增加小波阈值降噪时, 相比于 MSE 值更大, 表明样本重构精度下降, 这将导致残差误差增大, 从而影响 SPRT 算法的检验精度; 采用传统 SPRT 检验会导致检测精度有所下降, 出现漏检问题。本研究所提方法通过使用 WTD 预处理传感器监测的原始数据, 并对传统 SPRT 进行修正, 4 种工况实验结果表明, 所提方法在异常检测性能方面具有更小的 MSE 值和更高的 F1 值。采用 SPRT 方法对部分异常传感器残差进行了检测, 结果如图 7 所示。可以看出, 所提方法均比传统 SPRT 监测方法更及时地检测到传感器异常。由于仪表 6 计算获取的 SPRT 数值过大, 从给出的局部放大图可以看出, 相比于传统的 SPRT 方法, 修正的 SPRT 方法能更及时地检测出传感器异常, 异常检测延时降低了 81.73%。

表 6 消融实验结果

Tab.6 The result of Ablation experiment

模型	指标	工况 1	工况 2	工况 3	工况 4
无 WTD	MSE	0.067	0.083	0.105	0.097
	F1/%	92.85	93.03	93.47	92.31
传统 SPRT	MSE	0.013	0.017	0.076	0.042
	F1/%	93.35	92.87	92.32	91.79
所提方法	MSE	0.012	0.017	0.029	0.045
	F1/%	99.61	99.53	99.59	99.34




图 7 异常传感器残差检测结果

Fig.7 Residual detection results of abnormal sensor

3 结 论

1) 针对核电厂一、二回路耦合系统中由于传感器工况环境复杂恶劣等导致传感器检测维护不便的

问题,利用小波阈值降噪预处理耦合系统的复杂调制数据,以获取高质量传感器监测数据。

2) 提出了AAKR结合修正SPRT的方法,对核电厂变工况下传感器异常进行检测,并利用修正SPRT算法对残差进行检验。

3) 通过核电厂一、二回路耦合系统模拟机,在4种不同升功率工况下获取实验数据并进行分析。结果表明,AAKR模型对降噪后的监测数据具有很好的重构性能,修正SPRT算法对单一传感器故障和多源传感器同时故障都具有良好的检测精度。

4) 通过与ARMA,ICA-SPRT,LSSG和IDGAP-CNN这4种方法进行对比,表明所提方法具有更好的检测精度和鲁棒性,能有效监测核电厂多回路耦合系统中多源传感器的运行状态,并对异常传感器进行及时精准的检测,具有一定的工程应用价值。

参 考 文 献

- [1] GUOL YUYX, GAOHL, et al. Online remaining useful life prediction of milling cutters based on multisource data and feature learning[J]. IEEE Transactions on Industrial Informatics, 2022, 18(8): 5199-5208.
- [2] 李立力, 刘纲, 张亮亮, 等. 加权PCA残差空间的加速度传感器故障诊断[J]. 振动、测试与诊断, 2021, 41(5): 1007-1013.
LI Lili, LIU Gang, ZHANG Liangliang, et al. Accelerometer fault diagnosis with weighted PCA residual space [J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(5): 1007-1013. (in Chinese)
- [3] HALLER P, GENGE B, FORLONI F, et al. VetaDetect: vehicle tampering detection with closed-loop model ensemble[J]. International Journal of Critical Infrastructure Protection, 2022, 37: 100525.
- [4] 金典, 谢珊, 丁军, 等. 核电站主蒸汽系统冗余压力传感器异常检测[J]. 厦门大学学报(自然科学版), 2019, 58(4): 582-588.
JIN Dian, XIE Shan, DING Jun, et al. Fault detection for redundant pressure sensors in main steam system in nuclear power plants[J]. Journal of Xiamen University (Natural Science), 2019, 58(4): 582-588. (in Chinese)
- [5] 张文安, 洪毅, 史秀纺, 等. 基于子图拉普拉斯谱的异常传感器检测及识别方法[J]. 传感技术学报, 2021, 34(6): 804-810.
ZHANG Wenan, HONG Yi, SHI Xiufang, et al. Anomalous sensor detection and recognition based on Laplacian spectrum of sub-graph[J]. Chinese Journal of Sensors and Actuators, 2021, 34(6): 804-810. (in Chinese)
- [6] DEBASISH J, JAYANT P, SUDHEENDRA H, et al. CNN and convolutional autoencoder (CAE) based real-time sensor fault detection, localization, and correction, mechanical systems and signal processing

- [J]. Mechanical Systems and Signal Processing, 2022, 169: 108723.
- [7] 宫文峰, 王元哲, 陈辉, 等. 基于深度学习的无人驾驶汽车导航传感器异常诊断方法[J]. 机械工程学报, 2021, 57(24): 268-278.
GONG Wenfeng, WANG Yuanzhe, CHEN Hui, et al. Anomaly diagnosis for navigation sensors of unmanned autonomous vehicles based on deep learning[J]. Journal of Mechanical Engineering, 2021, 57(24): 268-278. (in Chinese)
- [8] 张松, 胡传皓, 李承洋, 等. 小波包软阈值降噪法在航空 γ 能谱中的应用[J]. 核技术, 2022, 45(9): 58-64.
ZHANG Song, HU Chuanhao, LI Chengyang, et al. Apply wavelet packet soft threshold noise reduction method to aviation gamma energy spectrum[J]. Nuclear Techniques, 2022, 45(9): 58-64. (in Chinese)
- [9] JIANG X M, TANG W J, ZHAO H X, et al. Toward smart condition monitoring of rotatory machines: an optimized probabilistic signal reconstruction methodology for fault prediction with multisource uncertainties[J]. IEEE Access, 2022, 10: 60862-60875.
- [10] LIU J P, WANG J, LIU X F, et al. MWRSPCA: online fault monitoring based on moving window recursive sparse principal component analysis[J]. Journal of Intelligent Manufacturing, 2022, 33(5): 1255-1271.
- [11] QIN Y H, LOU Z J, WANG Y Q, et al. An analytical partial least squares method for process monitoring[J]. Control Engineering Practice, 2022, 124: 105182.
- [12] 蒋佳伟, 胡以怀, 李方玉, 等. 基于AAKR模型的船用低速柴油机状态监测方法[J]. 舰船科学技术, 2021, 43(2): 158-162.
JIANG Jiawei, HU Yihuai, LI Fangyu, et al. Ship low-speed diesel engine condition monitoring method based on AAKR model[J]. Ship Science and Technology, 2021, 43(2): 158-162. (in Chinese)
- [13] GAO G L, ZHONG Y M, GAO S E, et al. Double-channel sequential probability ratio test for failure detection in multisensor integrated systems [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-14.



第一作者简介:谢述帅,男,1994年8月生,博士生。主要研究方向为智能故障诊断与剩余寿命预测。曾发表《Incremental contrast hybrid model for online remaining useful life prediction with uncertainty quantification in machines》(《IEEE Transactions on Industrial Informatics》2024, Vol. 20, No. 12)等论文。
E-mail: xiess@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