

DOI: 10.13382/j.jemi.B2104619

融合 PCA 与自适应 K-Means 聚类的水电机组 故障检测在线方法*

徐 雄¹ 林海军¹ 刘悠勇² 胡 边³

(1. 湖南师范大学工程与设计学院 长沙 410081; 2. 湖南大学电气与信息工程学院 长沙 410082;
3. 五凌电力有限公司 长沙 410004)

摘 要:灯泡贯流式水电机组在运行过程中,由于受水力因素、机械、工况等因素影响,很容易导致转轮叶片与转轮室发生故障,严重影响水电机组安全运行。在分析灯泡贯流式水电机组转轮叶片与转轮室故障信号特征的基础上,提出了一种基于 K 均值(K-Means)和莱特准则(Wright's criterion)的水电机组故障在线检测方法。该方法利用主元分析(PCA)对水电机组振动和噪声信号特征降维后,融合莱特准则改进传统 K 均值算法,以实现 K 值的自适应选择,对特征进行在线聚类,能快速准确识别水轮机变负荷状态与金属扫膛故障。将本文方法应用到五凌电力近尾洲水电站灯泡贯流式机组故障检测中,实验结果表明,采用该方法的故障在线检测准确率为 100%、变负荷在线检测准确率为 96.7%,运行近 10 个月没有出现故障误报和漏报,表明了该方法的有效性。

关键词:水电机组;故障在线检测;变负荷检测;自适应 K-Means 聚类;主元分析

中图分类号: TP206+.3 **文献标识码:** A **国家标准学科分类代码:** 510.40

On-line fault detection method of hydraulic turbine combining PCA and adaptive K-Means clustering

Xu Xiong¹ Lin Haijun¹ Liu Youyong² Hu Bian³

(1. College of Engineering and Design, Hunan Normal University, Changsha 410081, China;
2. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China;
3. Wuling Electric Power Co., Ltd., Changsha 410004, China)

Abstract: During the operation of the bulb tubular hydropower unit, due to hydraulic factors, machinery, working conditions and other factors, it is easy to cause the runner blades and runner chamber to malfunction, which seriously affects the safe operation of the hydropower unit. Based on the analysis of the fault signal characteristics of the runner blades and runner chamber of the bulb tubular hydropower unit, an online fault detection method for hydropower units based on K-Means and Wright's criterion is proposed. This method uses principal component analysis (PCA) to reduce the dimensionality of the vibration and noise signal characteristics of the hydropower unit, and integrates the Wright criterion to improve the traditional K-means algorithm to realize the adaptive selection of the K value, and perform online clustering of the features, which can quickly and accurately identify the variable load state of the turbine and the failure of the metal sweeping chamber. The method proposed in this paper is applied to the fault detection of the bulb tubular unit of Wuling Electric Power's Jinweizhou Hydropower Station. The experimental results show that the accuracy of the online fault detection using this method is 100% and the accuracy of the variable load online detection is 96.7%, there has been no fault false positives and false negatives in the past 10 months of operation, indicating the effectiveness of the method.

Keywords: hydropower unit; online fault detection; variable load detection; adaptive K-Means clustering; principal component analysis

0 引言

灯泡贯流式水电机组是水电能源转换的核心设备,通过水轮机将水能转换为机组大轴的旋转机械能,再由同轴发电机将其转换为电能^[1]。灯泡贯流式水电机组的安全可靠运行是保障水电厂正常发电的基础。因此,水电机组运行在线监测、故障检测与诊断尤为重要。

目前水电机组故障在线检测与诊断,通常采用振动诊断技术,这种方法主要聚焦于水电机组特征信号的低频部分,忽视了高频的特征信号^[2]。实际上,水电机组运行产生的声音信号复杂,既有低频的振动信号,也含有丰富的部分(如高频噪声)^[3]。当系统产生故障时,其噪声特征也会发生改变。因此,噪声信号为机组的运行状态监测与故障检测提供了有效的信号源。

近年来,基于声学状态监测与故障诊断已成为故障诊断领域一个新的发展方向。何志锋等^[4]通过分析三峡水电机组的声学测量结果,证实了声学方法辅助诊断水电机组运行故障的有效性。唐拥军等^[5]开展了噪声分析在水电机组故障诊断中的应用研究,验证了噪声反应了振动与压力传感器可能捕捉不到的信息,为机组故障诊断提供了有效的运行数据,提高了诊断准确率。

另一方面,目前基于信号分析、故障树分析、数据统计的诊断方法与基于神经网络的智能诊断方法等均获得了成功应用^[6-9]。基于信号分析的诊断方法反应迅速准确,但对某些时变非平稳信号计算量大、分析复杂^[6];基于故障树分析的诊断方法鲁棒性好,但故障准确率有待进一步提高^[7];基于神经网络的诊断方法是一种智能检测方法,但其性能受机组故障样本数量的影响^[8];基于数据统计的诊断方法不需要建立精确的过程模型,非常适合水轮机组非线性、非平稳故障信号分析^[9]。

主元分析法(principal component analysis, PCA)通过数据降维实现数据简化、压缩和特征变量提取等^[10]。K-Means 算法是一种无监督学习,主要用在系统检测、去除异常值等方面^[11]。由于传统 K-Means 算法需要预先指定初始聚类数目 k ,单纯采用 K-Means 算法进行故障检测时受限,故引入莱特准则^[12]实现 K 值的自适应选择。

综上所述,本文利用水电机组噪声信号,结合 PCA 和自适应 K-Means 聚类,采用莱特准则,提出一种水电机组故障在线检测方法,通过对五凌电力近尾洲水电站水电机组的故障在线检测试验,结果表明这种方法能准确识别水轮机变负荷状态与金属扫膛故障。

1 融合 PCA 与自适应 K-Means 聚类故障检测原理

1.1 灯泡贯流式水轮机组工作原理

如图 1 所示,灯泡贯流式水轮机组的水轮机主要由转轮室、贯流式转轮、发电机等组成。当水流进入机组导水渠后从灯泡体周围均匀通过到达转轮,推动转轮旋转产生感应电动势。




图 1 灯泡贯流式水轮机构造图

Fig. 1 Structure diagram of bulb tubular turbine

灯泡贯流式水轮机组是一个典型的集机械和电气于一体的系统,其故障主要分为以下两种类型:

1) 电气故障:包括水电站的主变压器温度过高,或者雷雨天气导致主变压器出现高压漏电与短路,或者灯泡头发电机绝缘部位破损而导致的发电机漏电故障等;

2) 机械故障:在运行过程中,机组转轮叶片受水力波动、轴线局部弯曲、叶片受力不平衡等的影响,或者由于异物的侵入并卡塞(如螺丝的掉落),在旋转过程中容易出现转轮叶片与转轮室出现扫膛故障,或者由于机组外部机械器材掉落撞击机组等。此类机械故障不加控制,将会诱发严重机组故障。

1.2 PCA-K-Means 故障检测原理

采用多路传感器(振动传感器、噪声传感器)采集水轮机组的噪声与振动信号,通过以太网实时传输至上位机;经计算信号的时域特征和小波包分解^[13]的能量系数获得多维信号特征,然后多维特征向量经 PCA 降维后并结合自适应 K-Means 算法,完成故障在线检测。PCA-K-Means 故障检测方法的信号处理流程如图 2 所示。

由于水轮机组故障信号具有非线性、非平稳的特点,采用时域分析和小波包分析进行故障特征提取,将一部分时域指标(如:均方根、方差、峭度、标准差等)和小波包能量作为故障特征向量。通过对比不同状态下的时域指标差别选择均方根作为故障特征向量。实验发现,不




图 2 水轮机组故障检测流程

Fig. 2 Flow of failure detection of hydraulic turbine unit

同水轮机组噪声与振动信号的均方根显著,因此采用均方根作为时域故障特征向量,记为 $T1$ 。采用小波基 $db5$ 对故障信号进行 3 层小波包分解,经过综合对比,采用后四维子频带的能量作为故障特征向量,即分别为 $T2$ 、 $T3$ 、 $T4$ 、 $T5$ 。因此,特征量 T 定义为 $T = [T1, T2, T3, T4, T5]$ 。

1.3 水轮机组故障信号的 PCA 方法

利用主元分析法 (PCA) 数据降维之前,首先要利用原始数据建立 PCA 模型。设原始数据特征矩阵 X_{nm} , 即

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

式中: n 为特征的个数; m 为数据集个数。

为了降低由于数据大小差异造成的不平衡,将原始数据矩阵标准化,即将矩阵中的数据减去相应的均值,然后除以数据的标准差,则第 i 个特征的均值 $\bar{x}_{i,m}$ 、方差 $\sigma_{i,m}^2$ 及标准化后的协方差矩阵分别 S_m 为:

$$\bar{x}_{i,m} = \frac{1}{m} \sum_{j=1}^m x_{j,i} \quad (2)$$

$$\sigma_{i,m}^2 = \frac{1}{m-1} \sum_{j=1}^m (x_{j,i} - \bar{x}_{i,m})^2 \quad (3)$$

$$S_m = \frac{1}{m} (X_m^T X_m) \quad (4)$$

式(2)~(4)中, m 为第 m 个数据; X_m 为标准化后的原始数据矩阵。

对协方差矩阵 S_m 进行正交分解后即可求得主元变量,即将分解后的特征值按照降序排列。因此,初始的主元向量矩阵 T_m 可表示为:

$$T_m = X_m P_k \quad (5)$$

式中: P_k 为主元特征向量矩阵。通过累计方差贡献率法^[14]确定主元数 k , 当前 k 个特征值之和占总和的比重

大于 90% 时,所对应的 k 值即为主元个数。

1.4 自适应 K-Means 聚类算法

传统 K-Means 算法需要人为确定 K 值,当样本集发生改变后,原来的 K 值并不总是合适。水轮机在状态变化时,信号发生显著变化。考虑利用莱特准则确定软阈值,可在线识别突变点,实现 K 值的自适应选择。由于残差 δ ^[15] 落在处于 3 倍标准差 $[-3\sigma, 3\sigma]$ 范围内的概率超过 99.7%。因此,本文认为残差处于该区域之外的数据为突变。

自适应 K-Means 聚类算法是基于莱特准则的在线迭代求解的聚类算法。对于实时时间序列 $X = \{x_i \in R^m, i = 1, 2, \dots, n\}$ 在线提取多维特征并对特征进行降维后,将已降维的特征数据输入聚类滑动窗 L_1 ($L_1 = 20$), 当聚类滑动窗 L_1 ($i \geq L_1$) 满后进行 $K=1$ 与 $K=2$ 在线聚类: 当 $K=1$, 计算窗 L_1 上的样本点 x_i 聚类中心的欧式距离 $D_{k=1}$, 并返回簇内样本距离的误差平方和 $SSE_{k=1}$; 当 $K=2$, 计算欧氏距离 $D_{k=2}$ 并返回误差平方和 $SSE_{k=2}$ 。窗 L_1 上的样本点 x_i 与聚类中心的欧氏距离 D 为:

$$D(x_j, u_j) = \sqrt{\sum_{j=i-L}^i (x_i - u_j)^T (x_i - u_j)} \quad (6)$$

聚类中心为:

$$u_k = \frac{\sum_{i=1}^{n_k} x_i}{n_k} \quad (7)$$

式中: u_k 为第 K 类的聚类中心, $\sum_{i=1}^{n_k} x_i$ 表示窗 L_1 内属于第 K 类的所有样本, n_k 表示划分到第 K 类的样本个数。

误差平方和 (SSE) 为:

$$SSE = \sum_{j=1}^K \sum_{i=1}^{n_K} D^2(x_i, \mu_j) \quad (8)$$

再计算两次聚类的误差平方和之差 $\Delta SSE = SSE_{k=1} - SSE_{k=2}$, 将 ΔSSE 不断输入莱特窗 L_2 ($L_2 = 20$) 上, 当莱特窗 L_2 ($i \geq L_1 + L_2$) 满后, 计算莱特窗 L_2 上 ΔSSE 的标准差为:

$$\sigma = \sqrt{\frac{\sum_{j=i-L_2}^i (\Delta SSE(i) - \overline{\Delta SSE(i)})^2}{L_2 - 1}} \quad (9)$$

式中:

$$\overline{\Delta SSE(i)} = \frac{1}{L_2} \sum_{j=i-L_2}^i \Delta SSE(j) \quad (10)$$

则残差 δ 为:

$$\delta = \Delta SSE(i) - \overline{\Delta SSE(i)} \quad (11)$$

当残差 δ 满足式(12)时, 即

$$|\delta| > 3\sigma \quad (12)$$

莱特窗 L_2 停止滑动, 记录此时的残差 δ , 进行突变判断:

$$E = \begin{cases} \text{突变} & \begin{cases} \text{剔除第 } i+1 \text{ 个数据, } if(f(i) > 0) \& \& (f(i+1) > 0) \& \& (f(i+2) > 0) \\ \text{剔除第 } i+2 \text{ 个数据, } if(f(i) > 0) \& \& (f(i+1) < 0) \& \& (f(i+2) > 0) \& \& (f(i+3) > 0) \\ \text{剔除第 } i+2 \text{ 个数据, } if(f(i) > 0) \& \& (f(i+1) > 0) \& \& ((f(i+2) < 0) \& \& (f(i+3) > 0)) \end{cases} \\ \text{正常} & \begin{cases} \text{剔除第 } i \text{ 个数据, } if(f(i) > 0) \& \& ((f(i+1) < 0) \& \& (f(i+2) < 0)) \\ \text{其他} \end{cases} \end{cases} \quad (13)$$

式(13)中, $f(i) = |\delta(i)| - 3\sigma(i)$, $f(i+1) = |\delta(i+1)| - 3\sigma(i)$, $f(i+2) = |\delta(i+2)| - 3\sigma(i)$, $f(i+3) = |\delta(i+3)| - 3\sigma(i)$ 为莱特准则判别式, 大于0则表示满足莱特准则。 $\sigma(i)$ 是第 i 个数据输入时, 莱特窗 L_2 的方差; $\delta(i)$ 是第 i 个数据输入时, 莱特窗 L_2 的残差; $\delta(i+1)$ 是第 $i+1$ 个数据输入时, 莱特窗 L_2 的残差; $\delta(i+2)$ 是第 $i+2$ 个数据输入时, 莱特窗 L_2 的残差。当出现 $|\delta(i)| > 3\sigma(i)$ 时, 可利用上述模型进行判断是否出现突变。

当判别为突变时, 由于变负荷与扫膛故障的均方根有显著不同, 故采用硬阈值进行判别:

$$E_2 = \begin{cases} \text{故障, } RMS(i) > \lambda \\ \text{变负荷, } RMS(i) < \lambda \end{cases} \quad (14)$$

式中: $RMS(i)$ 是第 i 个数据输入时均方根特征值, λ 为硬阈值。当判别为突变时, 可利用上述模型进行判断是否出现故障。通过多次实验, 对比不同状态下均方根值取 $\lambda = 0.42$ 。

1.5 PCA-K-Means 算法步骤

基于 PCA-K-Means 的水轮机组故障检测算法流程如下:

步骤 1: 在线采集多路噪声数据, 计算特征 T , 并利用 PCA 对高维特征进行降维;

步骤 2: 利用在线 K-Means 算法对已降维的特征进行 $K=1$ 与 $K=2$ 聚类, 计算误差平方和之差 ΔSSE ;

步骤 3: 将 ΔSSE 输入滑动莱特窗, 利用式(13)与(14)进行在线故障检测。

2 水轮机故障检测实验

2.1 实验平台与实验现场

以五凌电力近尾洲水电站 3 号水轮发电机组为实验对象, 进行故障检测试验。3 号机组的故障检测系统主要包括: 振动传感器、噪声传感器、信号采集模块(安装在故障监测设备主箱体中)、信号处理器(工控机)等。信号采集模块实时采集水电机组的噪声信号与振动信号, 并通过以太网输入工控机, 进行故障检测。故障检测平台如图 3 所示。

如图 3 所示, 系统通过传感器采集模拟振动和噪声信号, 然后经调理电路以及采集卡输出数字信号, 利用网线传输到上位机进行处理分析。由于噪声传感器采集的信号中含有大量的高频干扰, 同时加速度传感器采集的





图3 检测系统平台示意图


Fig.3 Schematic diagram of detection system platform

信号含有严重的噪声干扰, 为了克服上述干扰, 现场的信号采集装置首先通过信号调理电路对噪声、振动信号进行放大滤波, 然后再利用信号采集卡对振动噪声信号进行采集。

图 4 为检测系统各类传感器安装示意图。图 4(a)中, 加速度和噪声传感器及同步数据采集卡构成前端数据采集装置, 安放在水电机组不同部位的各个位置。图 4(b)为声音传感器和振动传感器及其安装位置。其中, 噪声传感器为麦克风式传感器, 性能等级为 SJ/T10724-2013 二级, 标称灵敏为 50 mV/Pa。噪声传感器使用支架固定在水轮机组附近墙面并朝向水轮机组。加速度传感器为磁吸式传感器, 电压灵敏度为 101.6 mV/g, 频率范围为 1~500 Hz、输出幅度为 +5 Vp。加速度传感器安装水轮机组上, 其下方垫有绝缘体防止出现电容干扰机组正常运行。



(a)声音传感器(左)与振动传感器(右)
(a)Sound sensor (left) and vibration sensor (right)



(b)传感器布设与设备安装
(b)Sensor layout and equipment installation

图4 传感器安装

Fig.4 Sensor installation

2.2 水轮机变负荷检测试验

机组的工况主要分为平稳状态,变负荷状态(即功率调整状态)。当发电机组处于功率调整状态时,各个部位的振动与噪声信号都会出现较大突变。调整机组负荷,同时采集机组各个部位的噪声与振动信号,试验步骤如下:

- 1) 机组稳定在 8 MW 负荷工况,持续运行 2 min;
- 2) 将机组负荷从 8 MW 上升到 20 MW;
- 3) 让机组在 20 MW 负荷下,稳定运行 2 min;
- 4) 将机组负荷从 20 MW 负荷降到 8 MW;
- 5) 让机组在 8 MW 负荷下稳定运行 2 min。

水轮机的变负荷状态包括升负荷与甩负荷。其中,平稳状态指机组负荷维持在 8 和 20 MW 的阶段;升负荷指机组负荷逐渐从 8 MW 升到 20 MW 的过程;甩负荷指机组负荷逐渐从 20 MW 下降到 8 MW 的过程。

图 5 为排水环变负荷过程图。图 5(a) 中,一个完整的变负荷包括:过程①:机组稳定在 8 MW 负荷工况(稳态);过程②:机组负荷从 8 MW 上升到 20 MW(升负荷);过程③:机组负荷稳定在 20 MW 负荷工况(稳态);过程④:从 20 MW 负荷降到 8 MW(降负荷);过程⑤:机组回到在 8 MW 负荷工况(稳态)。图 5(b) 中,变负荷过程均方根特征变化过程①~⑤与图 5(a) 变负荷过程原始信号各个过程对应。


排水环变负荷特征数据包括:稳态、升负荷、稳态、降负荷与稳态,共 2 128 组特征数据。图 6 为排水环变负荷在线检测结果图。图中,星号 * 识别为机组处于变负荷状态;b 处点 550、551、552 与 553 残差曲线都高于 3 倍标准差曲线满足式(13)突变判别条件,故判定出现变负荷。同理,c 处点 1 601、1 602 与 1 603 一样判定为变负荷。

2.3 水电机组故障检测试验


对 3 号机组排水环进行变负荷与金属扫膛故障实验,并利用融合 PCA 与自适应 K-Means 聚类方法进行在线检测。图 7 为水电机组灯泡头与灯泡体金属扫膛故障现场实验。

如图 7 所示,分别在灯泡头、灯泡体以及排水环附近进行金属扫膛故障模拟。当有异物与转轮室内壁有刮擦时,在转轮室及叶片上的作用力表现为短时间的冲击,该作用力会导致机组内部局部变形或者产生刮痕,并引起水轮机产生尖锐的刮擦声。图 8 为金属扫膛故障原始信号及其均方根特征信号。由图 8 可知,扫膛故障信号的均方根具有明显的周期性,其可作为水轮机组的故障特征信息。

排水环扫膛故障试验中,共采集 500 组样本数据,图 9 为排水环扫膛故障在线检测结果。图中,菱形◇识别为机组发生扫膛。b 处点 91、93 与 94 残差曲线都高于



(a) 变负荷过程原始信号
(a) Raw signal of variable load process



(b) 变负荷过程均方根特征变化
(b) RMS characteristic change of variable load process

图 5 排水环变负荷过程

Fig. 5 Drainage ring variable load process




图 6 排水环变负荷在线检测结果

Fig. 6 The results of online detection of the variable load of the drainage ring

3 倍标准差曲线,且由图 8(b) 可知,各点的均方根均 λ 大于 0.42,满足式(13)故障判定条件,故判别出现故障。同理,c 处点 174、175 与 176 有类似的故障判别结论。



图7 灯泡头(左)与灯泡体(右)金属扫膛故障实验图
Fig. 7 The test diagram of the metal sweeping failure of the bulb head (left) and the bulb body (right)





图8 排水环金属扫膛故障数据
Fig. 8 Data diagram of the failure data of the metal sweep bore of the drainage ring

2.4 不同故障检测方法对比

采取 2.2~2.3 节的方法对灯泡头与灯泡体进行实验,连续采样一周,共获得 49 210 万个原始数据。采用本文提出的方法进行故障在线检测和变负荷在线检测,




图9 排水环金属扫膛故障在线检测结果
Fig. 9 The results of online detection of the metal sweeping bore fault of the drainage ring

其检测结果如表 1 所示。

表 1 PCA 与自适应 K-均值算法在线检测结果
Table 1 Online detection results of PCA and adaptive K-means algorithm (%)

部位	变负荷检测率	故障检测率
灯泡头	100	100
灯泡体	90	100
排水环	100	100
平均检测率	96.7	100

由表 1 可知,分别采用 PCA-a-K-Means 的在线检测方法对灯泡头、灯泡体与排水环进行变负荷和故障在线检测,其中变负荷平均检测准确率为 96.7%,故障平均检测准确率为 100%,两种情况下的在线检测准确率高,均能满足实际要求。

表 2 为 PCA-a-K-Means (融合 PCA 与自适应 K-Means 聚类在线检测方法)、a-K-Means (自适应 K-Means 聚类方法)、PCA-K-Means (融合 PCA 与传统 K-Means 聚类方法) 3 种方法的变负荷在线检测和故障在线检测结果比较。

表 2 不同算法的检测结果比较
Table 2 Comparison of detection results of different algorithms (%)

算法	变负荷检测率	故障检测率
PCA-a-K-Means	96.7	100
a-K-Means	88	85
PCA-K-Means	66.5	73.3

由表 2 可知,PCA-a-K-Means 比 a-K-Means 和 PCA-K-Means 的在线检测准确率更高,检测效果更明显。

3 结 论

本文基于 K 均值 (K-Means) 和莱特准则 (Wright's criterion), 提出了一种灯泡贯流式水电机组在线故障检测方法。该方法首先获取水电机组噪声信号, 提取信号特征并经过融合 PCA 降维后, 利用莱特准则改进传统 K 均值算法, 实现 K 值的自适应选择, 并对故障特征进行在线聚类。将该算法应用在五凌电力近尾洲水电站 3 号机组故障在线检测, 连续工作 10 个月, 未发生故障误报和漏报, 获得了良好的故障检测效果。

参考文献

- [1] LIU D, LI C, TAN X, et al. Damping characteristics analysis of hydropower units under full operating conditions and control parameters: Accurate quantitative evaluation based on refined models[J]. Applied Energy, 2021, 292: 116881.
- [2] 张长伟, 陈启卷, 李德红, 等. 考虑尾水位影响的水电机组三维振动区精细划分[J]. 水电能源科学, 2021, 39(3): 134-137.
ZHANG CH W, CHEN Q J, LI D H, et al. Fine division of three-dimensional vibration zone of hydropower unit considering the influence of tail water level[J]. Hydropower Energy Science, 2021, 39(3): 134-137.
- [3] XUE L, JUN J Y. A method of eliminating the vibration signal noise of hydropower unit based on NA-MEMD and approximate entropy[J]. Proceedings of the Institution of Mechanical Engineers, 2017, 231(2): 317-328.
- [4] 何志锋, 孙建平. 声学测量在水电机组故障诊断中的应用[C]. 第十八次中国水电设备学术讨论会论文集 2011:4 福建.
HE ZH F, SUN J P. Application of acoustic measurement in fault diagnosis of hydroelectric generating unit[C]. Proceedings of the 18th China Hydropower Equipment Symposium, 2011: 4.
- [5] 唐拥军, 周喜军, 张飞. 噪声分析在水电机组故障诊断中的应用[J]. 中国农村水利水电, 2017(8): 206-208.
TANG Y J, ZHOU X J, ZHANG F. Application of noise analysis in fault diagnosis of hydropower units[J]. China Rural Water and Hydropower, 2017(8): 206-208.
- [6] 刘丽华. 基于时变非平稳时间序列分析的故障诊断方法研究[D]. 北京: 北京化工大学, 2008.
LIU L H. Research on fault diagnosis method based on time-varying non-stationary time series analysis [D]. Beijing: Beijing University of Chemical Technology, 2008.
- [7] CAO C, LI M, LI Y, et al. Intelligent fault diagnosis of hot die forging press based on binary decision diagram and fault tree analysis [J]. Procedia Manufacturing, 2018, 15: 459-466.
- [8] 陈仁祥, 唐林林, 孙健, 等. 一维深度子领域适配的不同转速下旋转机械复合故障诊断[J]. 仪器仪表学报, 2021, 42(5): 227-234.
CHEN R X, TANG L L, SUN J, et al. Compound fault diagnosis of rotating machinery at different speeds adapted to one-dimensional depth subdomain [J]. Chinese Journal of Scientific Instrument, 2021, 42(5): 227-234.
- [9] WEI L, ZHANG C, ZHU F J, et al. Fault diagnosis of rotating machinery with a novel statistical feature extraction and evaluation method [J]. Mechanical Systems and Signal Processing, 2015: 50-51.
- [10] 李慧霞, 林海军, 邵耿荣, 等. 基于递推主元分析法的汽车衡称重传感器零点故障检测方法[J]. 电子测量与仪器学报, 2020, 34(1): 32-42.
LI H X, LIN H J, SHAO G R, et al. Zero fault detection method of truck scale load cell based on recursive principal component analysis method [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(1): 32-42.
- [11] 胡叶, 张爱军. 基于 K-means 的室内行人导航步态识别方法[J]. 国外电子测量技术, 2021, 40(3): 32-36.
HU Y, ZHANG AI J. Gait recognition method for indoor pedestrian navigation based on K-means [J]. Foreign Electronic Measurement Technology, 2021, 40(3): 32-36.
- [12] 李海涛, 曹纯. 基于 DBSCAN 的椭圆拟合算法的磁罗盘校正[J]. 电子测量技术, 2019, 42(18): 65-68.
LI H T, CAO CH. Magnetic compass correction based on DBSCAN ellipse fitting algorithm [J]. Electronic Measurement Technology, 2019, 42(18): 65-68.
- [13] 孙抗, 郭景蝶, 马星河. 高压电缆局部放电小波包-峰度法在线检测与定位[J]. 电子测量与仪器学报, 2017, 31(7): 1099-1106.
SUN K, GUO J D, MA X H. On-line detection and location of partial discharge of high-voltage cables by wavelet packet-kurtosis method[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(7): 1099-1106.
- [14] 刘丽云, 吕玉海, 牛鲁娜, 等. 基于 K-means 聚类的 TE 过程故障诊断与识别[J]. 自动化与仪器仪表, 2020(7): 5-11.
LIU L Y, LYU Y H, NIU L N, et al. TE process fault

diagnosis and identification based on K-means clustering[J].

Automation and Instrumentation, 2020(7): 5-11.

- [15] 杨志良,孙兴丽,姚金杰,等. 基于小波阈值的桥梁形变参数去噪方法[J]. 国外电子测量技术,2021,40(3):68-71.

YANG ZH L, SUN X L, YAO J J, et al. De-noising method of bridge deformation parameters based on wavelet threshold [J]. Foreign Electronic Measurement Technology, 2021, 40(3): 68-71.

作者简介



徐雄,2018 年于湖南工程学院获得学士学位,现为湖南师范大学硕士研究生,主要研究方向为智能检测。

E-mail:2755348648@qq.com

Xu Xiong received his B. Sc. degree in 2018 from Hunan Institute of Engineering.

Now he is a M. Sc. candidate in Hunan Normal University. His main research interest includes intelligent detection.