

DOI: 10.13382/j.jemi.B2205158

中央空调传感器双重降噪模糊故障检测方法*

高学金^{1,2,3,4} 张琳峰^{1,2,3,4}

(1. 北京工业大学信息学部 北京 100124; 2. 数字社区教育部工程研究中心 北京 100124;
3. 城市轨道交通北京实验室 北京 100124; 4. 计算智能与智能系统北京市重点实验室 北京 100124)

摘要:针对现有降噪方法存在噪声残留以及异常检测指标受噪声影响较大的问题,提出中央空调传感器双重降噪和模糊指标的故障检测方法。自适应噪声的完整经验模态分解(complete EEMD with adaptive noise, CEEMDAN)所具有的噪声残余等问题,用局部均值估计提取 k 阶模态替换模态估计完成初次降噪;而早期出现的虚假模式,先通过相关系数准则筛选含噪分量尽可能保留有效信息,然后计算奇异值差分谱确定降噪阶次进行奇异值分解(singular value decomposition, SVD)完成二次降噪。最后,结合能量和峭度系数提出模糊指标作为异常信号控制限进行故障检测。采用中央空调实验系统运行数据对所提方法进行验证,结果表明,该方法具有良好的降噪及敏感特征筛选能力,信噪比提升20.203 7 dB,均方误差平均减小48.75%,故障检测准确率平均提升8.67%,响应速度提升33.3%,抗噪性及检测效果提升明显。

关键词:中央空调传感器;故障检测;双重降噪;模糊指标;特征筛选

中图分类号: TN98; TU831.3 **文献标识码:** A **国家标准学科分类代码:** 510.8040

Double noise reduction fuzzy fault detection method for sensors in central air conditioning

Gao Xuejin^{1,2,3,4} Zhang Linfeng^{1,2,3,4}

(1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China; 2. Engineering Research Center of Digital Community, Ministry of Education, Beijing 100124, China; 3. Beijing Laboratory for Urban Mass Transit, Beijing 100124, China; 4. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124, China)

Abstract: The current noise reduction methods have noise residue and inadequate adaptability, so that the abnormal detection index is greatly affected by noise, a sensor fault detection method based on double noise reduction and fuzzy index for central air conditioning is proposed. Complete EEMD with adaptive noise (CEEMDAN) is used to extract k -order modes and replace modal estimation to achieve initial noise reduction. For the false mode appearing in the early stage, firstly, the noise-containing components are screened by the correlation coefficient criterion to retain the effective information as much as possible. Then, singular value difference spectrum is calculated to determine the order of denoising and singular value decomposition (SVD) to complete the secondary denoising. The experimental data of central air conditioning system are used to verify the proposed method, this method has good ability of noise reduction and sensitive feature screening, the SNR was improved by 20.203 7 dB, the mean square error was reduced by 48.75% on average, the fault detection accuracy was improved by 8.67% on average, and the response speed was improved by 33.3%.

Keywords: central air conditioning sensor; fault detection; double noise reduction; fuzzy indicators; feature selection

0 引言

中央空调工作环境往往十分嘈杂,导致采集到的信

号可能含有大量的噪声。从时域和频域的角度来看,噪声和信号两者之间缺少有效的划分方法。因此,信号处理中如果噪声信号占比较大,会导致所关注的故障信息变少或建模所采用的信号中有效信号较少而噪声信号较

多,使得建模精度低影响故障诊断精确率。

中央空调系统采集到的信号变量较多,包括温湿度、风速、流量、二氧化碳浓度等,但这些信号本质上都是典型的非平稳、非高斯信号。为降低噪声对信号分析的影响,现有的降噪方法主要分为两类:一类是时频分析方法,另一类是以经验模态分解(empirical mode decomposition, EMD)为代表的方法。He 等^[1]采用短时傅里叶变换(short time Fourier transformation, STFT)分析轴承信号,但其窗长设定的自适应性不强,只能粗略分析信号的时频结构。Samuel 等^[2]运用维格纳-威尔分布(Winger-Viller distribution, WVD)对发动机压力信号进行监测并提取出有效特征。不过 WVD 本质上是一种线性变换,实际频率之间会出现虚假分量从而导致误判。小波变换作为一种变换域去噪方法,可以减少去噪过程中的信号损失,保留有效数据^[3]。王一鹏等^[4]利用小波包提取混合特征并结合支持向量机对滚动轴承进行故障诊断。但小波变换作为一种非自适应性的算法,受到小波基函数的限制,采取不同的小波基函数结果相差较远且小波变换频段间存在着严重的能量泄露问题。Huang 于 1998 年提出经验模态分解,基函数直接由信号本身构造,自适应能力强,多用于处理非线性、非平稳信号,近年来被用于去噪领域方面的研究。Chen 等^[5]将 EMD 方法应用于声激发信号降噪分析,有效提高了信噪比。EMD 可同时获得时域和频域的高分辨,然而却存在模态混淆和畸变效应的缺陷,噪声对其影响也较大^[6-9],且计算量大,时间长,重构后的信号误差也较大。针对上述问题, Torres 等^[10]提出了自适应噪声的完整集合经验模态分解,提高了分解精度和速度。张勇等^[11]也利用该方法与特征熵结合对油气管道进行工况识别。童靳于等^[12]将其引入滚动轴承故障诊断。但在其分解的前期,信号会出现残余、虚假两种噪声残留问题。

奇异值分解通过矩阵分解将带噪声信号向量去除,提高信噪比,具有良好的不变性和稳定性^[13],极大地保留了有效信息。Song 等^[14]将 SVD 与局部均值分解相结合,有效抑制了局部均值分解乘积函数的数量,实现了有效的降噪处理。但在工况及环境较为复杂的情况下,故障信息所对应的奇异值分布分散,且难以选择合适的降噪阶次,因此对强噪声的降噪效果较差。

综上所述,目前各种单一的信号降噪方法均存在一定的局限性。因此,在单一降噪方法基础上研究二次降噪方法也是目前的研究趋势。Gao 等^[15]提出了一种基于 EEMD 及自相关滤波的双重降噪方法。CHowdhury 等^[16]提出一种基于小波阈值和优化变分模态分解的信号去噪方法。目前大多数双重降噪算法以经验模态分解为基础,但没有解决其方法本身存在的虚假噪声及噪声残留问题^[17-26]。经验模态分解及其相关算法虽然在信号处理

领域应用广泛,但在制冷空调的数据去噪方面却应用较少。

本文针对传统时频分析方法存在的共性问题即自适应性不足以及经验模态分解所存在的重构误差大及噪声残留的缺陷,提出一种中央空调传感器双重降噪故障特征提取方法。利用 CEEMDAN 方法分解原始数据信号,进行初步降噪并计算相关系数选取残留噪声较多的特征分量。再利用 SVD 方法的非线性噪声抑制能力针对 CEEMDAN 分解所残余的噪声对特征分量进行再次去噪,以此提高现场数据质量,方便后续对中央空调系统进行故障监测或维修决策等操作。传统异常信号检测指标根据 T^2 、SPE 统计量或残差阈值作为检测指标进行异常检测,未考虑中央空调工况等动态变化因素,受噪声影响较大,检测速度较慢^[27-34]。因此,根据传感器故障特性并结合时域参数的无量纲指标,构建模糊阈值检测指标,减小了噪声对检测阈值的影响并提高了异常信号的检测速率。

1 算法综述

1.1 自适应噪声的完整集合经验模态分解

经验模态分解作为近年来强有力的数学工具,已广泛应用于一维数据信号的处理。通过从原始一维信号中自适应地选择基函数,解决了小波变换选择基函数的困难,是一种具备小波变换优点的自适应信号处理方法^[12]。CEEMDAN 解决了模态混叠以及计算量庞大等问题,避免了对后续分解所造成的影响。

假定原始信号为 $S(t)$, $g^i(t)$ 为第 i 次实验所加入的标准正态分布 WSG 序列,即 g^i 服从 $N(0, 1)$ 分布。那么当 $S(t)$ 第 i 次加入噪声得到信号序列:

$$S^i(t) = S(t) + g^i(t) \quad (1)$$

其中, $i = 1, 2, 3, \dots, N$, 表示实验次数即所加噪声的频次。假设 $S(t)$ 的输入值是 $r_1(t)$, 第 1 步对 $S^i(t)$ 进行一阶 EMD 分解:

$$S(t) + \xi_k g^i(t) = \text{IMF}_1^i(t) + r_1^i(t) \quad (2)$$

式中: ξ_k 表示第 K 阶段所添加白噪声的幅值系数,即 WSG 比系数。对 N 个 $\text{IMF}_1^i(t)$ 集合平均得到第 1 阶固有模态分量:

$$\overline{\text{IMF}_1(t)} = \frac{1}{N} \sum_{i=1}^N \text{IMF}_1^i(t) \quad (3)$$

$\overline{\text{IMF}_1(t)}$ 即为第 1 阶本征模态分量,将其去除得到残留分量为:

$$r_1(t) = S(t) - \overline{\text{IMF}_1(t)} \quad (4)$$

残留分量 $r_1(t)$ 添加分解得到的 IMF 分量 $E_1(g^i(t))$, 再次进行分解:

$$r_1(t) + \xi_1 E_1(g^i(t)) = \text{IMF}_2^i(t) + r_2^i(t) \quad (5)$$

$\text{IMF}_2^i(t)$ 为第 2 次加入噪声后的信号序列,对 N 个 $\text{IMF}_2^i(t)$ 集合平均得到第 2 阶残留分量:

$$\overline{\text{IMF}_2}(t) = \frac{1}{N} \sum_{i=1}^N \text{IMF}_2^i(t) \quad (6)$$

$\overline{\text{IMF}_2}(t)$ 为第 2 阶本征模态分量,去除后得第 2 阶段的残留分量 $r_2(t)$ 为:

$$r_2(t) = r_1(t) - \overline{\text{IMF}_2}(t) \quad (7)$$

不断重复上述步骤 K 次直到第 K 阶段的残留分量无法再进行 EMD 分解为止,即分量信号的极值点小于等于 2 个。此时 CEEMDAN 分解完成,第 K 个残留分量为:

$$r_k(t) = r_{k-1}(t) - \overline{\text{IMF}_k}(t) \quad (8)$$

$r_k(t)$ 、 $r_{k-1}(t)$ 分别表示第 k 次和第 $k-1$ 次分解后的残留分量, $\overline{\text{IMF}_k}(t)$ 为第 k 阶本征模态分量。将式(8)变形为由原始数据信号表示:

$$r(t) = S(t) - \sum_{i=1}^K \text{IMF}_i \quad (9)$$

由式(9)可知, $r(t)$ 为分解最后所剩残留分量,则原始信号可表示为其与 k 个 IMF 分量之和的形式:

$$S(t) = r(t) + \sum_{i=1}^K \text{IMF}_i \quad (10)$$

1.2 奇异值分解

奇异值分解采用线性代数中的矩阵正交分解方法,可以分解矩阵,因此也应用于空间去噪。将由 CEEMDAN 方法分解所得的 IMF 分量分解为如式(11)所示:

$$A = U \Sigma V^T \quad (11)$$

其中, $U_{m \times r}$ 为左奇异矩阵, $V_{n \times r}$ 为右奇异矩阵, Σ 为对角矩阵, r 为矩阵的秩。

$$\Sigma = \begin{bmatrix} \sigma_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \sigma_r \end{bmatrix} = \begin{bmatrix} \sqrt{\lambda_1} & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \sqrt{\lambda_r} \end{bmatrix} \quad (12)$$

对角线元素 σ_i 表示矩阵的奇异值,并按照奇异值从大到小排列,奇异值可以表示矩阵在其对应特征向量上所代表的信息,奇异值越大则说明其对应的特征向量在构成原矩阵过程中的贡献率越大。SVD 对非线性信号处理能力较强,但是 SVD 去噪方法需要对矩阵进行运算,如果需要进行去噪的矩阵过大,则会导致计算量十分庞大,对算法的时间复杂度造成很大影响,因此将其用作二次降噪算法,运算速度大幅提升。

2 中央空调传感器的双重降噪模糊故障检测方法

中央空调系统是一类典型的非平稳非线性系统,且

由于其现场工作环境嘈杂多变,导致其内部传感器所测得的原始数据往往包含大量的噪声数据,极大地影响传感器异常信号的检测,导致故障检测率不高。因此本文提出一种双重降噪方法对原始数据进行特征提取与去噪处理,以提高数据质量。

现有单一降噪方法存在自适应性或非平稳信号处理能力不强的问题,以经验模态分解为基础的双重降噪方法也未解决方法本身的模态分解及噪声残留问题。

CEEMDAN 方法主要从以下两方面解决经验模态分解算法所存在的模态混叠和噪声残留问题:首先是加入 EMD 分解后的含有辅助噪声的 IMF 分量,在得到的第 1 阶 IMF 分量后进行总体平均计算来获得第 1 阶 IMF 分量。这样就有效解决了白噪声从高频到低频的转移传递问题。其次 CEEMDAN 添加的分量是方向相反的,这样就会相互消除,因此可以解决 EMD 中随机噪声残留的问题。

CEEMDAN 还可以对所分解得到的 IMF 分量进行筛选,尤其是对于某些具有局部倾斜的信号,CEEMDAN 算法可以很好地做到消除局部倾斜,选择的规则如式(13)所示:

$$F = \sqrt{1/n \cdot \sum_{i=1}^n [I_k(i) - I(i)]^2} \quad (13)$$

式中: i 表示采样的数据时刻, n 表示总数据点个数, $I_k(i)$ 表示第 k 阶 IMF 分量, $I(i)$ 表示原始信号, F 对应选择的分量信号。

利用 CEEMDAN 方法对信号进行分解,在获取到有用特征信息的同时还过滤掉了无用的噪声干扰信号,但分解所得到的分量仍含有噪声;在前期阶段,会出现虚假现象,导致前几阶 IMF 模态分量中包含残余噪声和信号的相似尺度。

传统工业过程或设备运行过程的故障检测指标主要是通过计算预测值与实际观察值之间的残差并与对应的阈值进行比较看是否超过阈值来判断工作状态是否异常。

上述方法均是通过判断计算出的指标是否超过阈值进行信号异常检测。但阈值的设定一般需要人为进行设定,比较依赖人工经验且未考虑实际变化因素,因此阈值设定的可靠性不高,导致异常检测率较低。考虑到中央空调传感器的信号特性以及各类故障特性在时域参数上的不同表现,本文提出一种综合模糊评价指标。通过计算传感器在正常运行状态下以及故障状态下的时域特征参数,发现无量纲参数中能量和峭度系数这两个指标对异常信号比较敏感,各种故障类型的能量和峭度系数差异性较大,因此综合两指标作为异常信号的检测指标,避免了单一阈值指标检测的不足,提升了阈值设定的可靠性。下面是能量 E 和峭度系数 K 的表达式:

$$E = \int |\delta(k)|^2 dt = \sum_{k=1}^N |\delta(k)|^2 \quad (14)$$

$$K = \frac{1}{N} \sum_{k=1}^N \left(\frac{\delta(k) - \bar{\delta}}{\sigma} \right)^4 \quad (15)$$

其中, $\delta(k)$ 为待计算信号, N 为数据个数, $\bar{\delta}$ 为平均值, σ 为标准差。

将上述检测指标按照下列规则进行模糊化处理:

$$E' = \begin{cases} 5 & E \geq 10 \\ 4 & E \geq 7 \\ 3 & E \geq 5 \\ 2 & E \geq 3 \\ 1 & E \geq 1 \\ 0 & E < 1 \end{cases} \quad K' = \begin{cases} 5 & K \geq 15 \\ 4 & K \geq 6 \\ 3 & K \geq 4 \\ 2 & K \geq 2 \\ 1 & K \geq 1 \\ 0 & K < 1 \end{cases} \quad (16)$$

采用模糊化处理过的能量和峭度系数构建异常评价模糊指标 U :

$$U = \begin{cases} k_1 E' + (1 - k_1) K' & E' = 5, 4, 3 \\ k_2 E' + (1 - k_2) K' & E' = 2, 1, 0 \end{cases} \quad (17)$$

其中, $k_1 = 0.6, k_2 = 0.4$ 。

经过大量实验,发现传感器时域参数中的无量纲指标能量和峭度系数两个指标对异常信号比较敏感,且因其无量纲特性,与设备转速、工况等没有关系,噪声对其值影响较小,因此选用这两项指标进行动态构建模糊评价指标。

由于传感器实际工作中变化复杂,难以建立一个固定统一的检测指标。因此利用上述两指标动态构建检测阈值 U ,当信号能量较大时,加大能量的权重,将其作为主要的检测指标;若当峭度系数较大时,则加大峭度系数对综合指标的贡献,将其作为主要的检测指标。通过实验测试将权重设置为 $k_1 = 0.6, k_2 = 0.4$ 效果较好。最后通过计算信号的模糊指标 U ,当 $U < 2$ 时认为传感器工作正常; $U \geq 2$ 则认定其发生异常状况。

综上所述,本文所提出的基于自适应噪声的完整集合经验模态分解结合奇异值分解的特征提取方法的具体步骤如下:

步骤 1) 采集中央空调相关传感器运行的原始信号,选取采样区间,对原始时域信号进行 CEEMDAN 分解并使用信号的局部均值来提取 k 阶模态,在分解得到的 IMF 分量中根据相关系数选取含噪声成分较多的分量;

步骤 2) 根据筛选出的相关分量得到特征矩阵;

步骤 3) 对特征矩阵计算奇异值差分谱确定降噪阶次,进行奇异值分解降噪;

步骤 4) 对降噪处理后的信号建立小波预测器模型并计算模糊指标进行故障检测。

针对 CEEMDAN 方法分解信号所具有的噪声残余等问题,采取奇异值分解方法对分解出来的模态分量进行二次降噪处理。下面对解决噪声残留有效性进行验证。

3 解决噪声残留有效性的验证

为证明本文所提降噪方法的有效性,本文采用信噪比(signal noise ratio, SNR)、均方误差(mean square error, MSE)、平均绝对误差(mean absolute error, MAE)以及标准偏差(standard deviation, STD)4 个指标对去噪效果进行评价,具体每个指标介绍如下:

SNR 用来计算信噪比,代表信号中有用信号和噪声的比例,其大小越大越好。公式如式(19)所示:

$$SNR = 10 * \lg \left(\sum_{i=1}^N \frac{y_i^2}{(x_i - y_i)^2} \right) \quad (18)$$

MSE 用来计算参数估计值与参数真值之差平方的期望值,在去噪处理算法中就是去噪后的数据与未处理数据值之间的运算,其大小越小越好。具体公式如下:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - x_i)^2 \quad (19)$$

MAE 用来计算去噪后数据和未处理数据之间绝对误差的平均值。公式如下:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - x_i| \quad (20)$$

STD 表示数据的标准偏差,衡量去噪后数据与未去噪数据的离散程度。标准差越小,说明去噪后数据偏离越少。计算如下:

$$STD = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{x}_i)^2}{N - 1}} \quad (21)$$

式中: y_i 均表示未去噪的信号, x_i 均表示处理后的数据。

由于中央空调系统本身具有大量传感器,目前中央空调系统所用传感器大多为数字非接触式传感器,传感器典型故障类型相同且输出信号均表现为非线性非平稳特性,因此本文仅选取最重要、使用最多且最容易发生故障的温度传感器作为研究对象。中央空调类型为典型单风道一次回风变风量系统,其温度系统控制流程如图 1 所示。

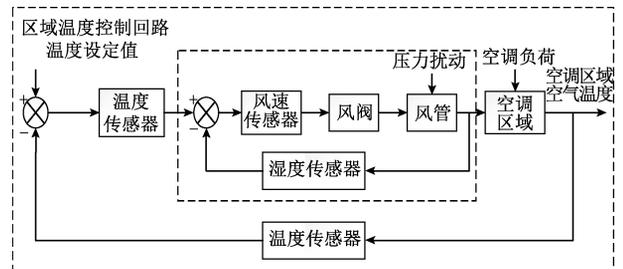


图 1 区域温度控制流程

Fig. 1 Flow chart of regional temperature control

从 TRNSYS 中选取合适的空调系统模块进行区域建模,以 Type56 为主要的房间模型模拟 4 个空调区域。所研究的传感器模块则自己使用 FORTAIN 语言编写加入,以方便引入故障发生器,获取故障数据。为方便和中央空调实验系统所采集到的数据进行整合研究,仿真所采集传感器类型为温度传感器。

空调系统传感器的故障形式有多种,主要分为硬故障和软故障。硬故障故障特征明显,容易检测,主要指完全失效故障。软故障则具有渐变性,故障特征不明显,难以检测,主要包括偏差故障、漂移故障及精度下降故障^[25-30]。

实际情况下,任何传感器的测量值都会伴随些许误差。测量的误差一种是系统误差,另一种是随机误差(即噪声)。可表示为:

$$y_i = y'_i + u_i + v_x \quad (22)$$

式中: y_i 为某时刻传感器显示的测量值, y'_i 为该时刻的真实值, u_i 指系统误差, v_x 为随机误差。自由噪声是测量过程中系统本身随机产生的,而故障则会引起系统误差。

仿真所采集的数据为中央空调空气处理系统在夏季正常制冷工况下的运行数据 600 组数据,温度设定为 26 °C,具体运行数据如图 2 所示。

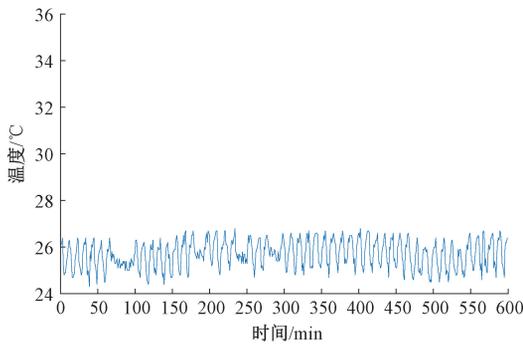


图 2 传感器正常运行数据
Fig. 2 The sensor runs properly

1) 完全失效故障

完全失效故障表现为传感器所显示的数值不随实际运行情况改变而改变,一直保持不变(非正常值),一般为传感器读数最大值或 0。在 300 组数据时设置故障发生器使传感器完全失效,得到测量结果如图 3 所示,300 采样点以后传感器测量值为一非正常值且不随真实值而改变,证明所引入的故障是有效的。

2) 偏差故障

偏差即系统误差 u_i 为一常数。

$$u_i = C \quad (23)$$

同样在 300 采样点时设置故障发生器给系统增加 3 °C 的温度补偿,得到测量结果图 4 所示。

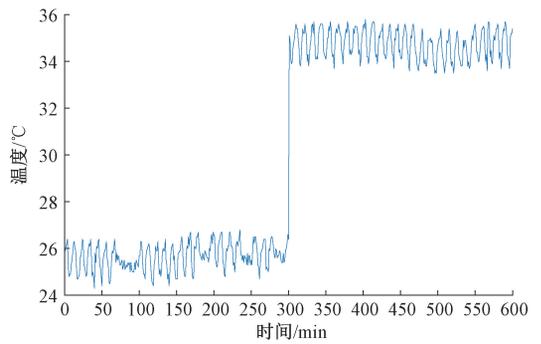


图 3 传感器完全失效故障
Fig. 3 Complete sensor failure

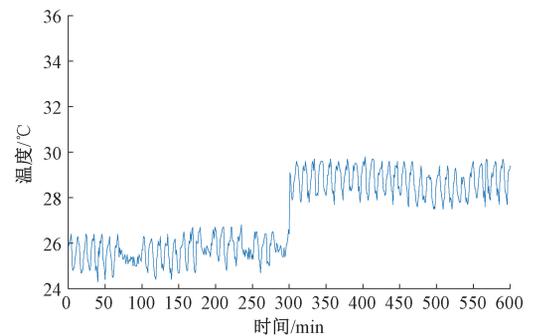


图 4 传感器偏差故障
Fig. 4 Sensor deviation fault

3) 漂移故障

漂移故障表现为测量值随时间发生线性变化。

$$u_i = k(t - t_s) \quad (24)$$

式中: t_s 、 t 为某发生漂移故障时刻, k 代表漂移系数,可为正为负。具体结果如图 5 所示。

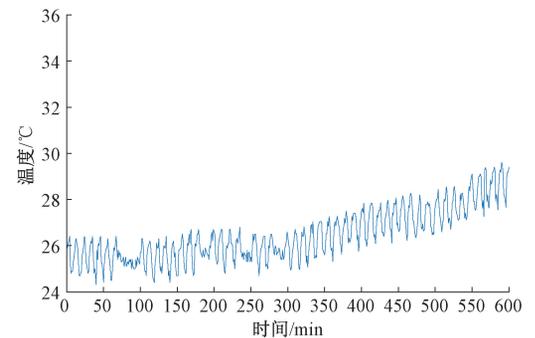


图 5 传感器漂移故障
Fig. 5 Sensor drift fault

可以看出 300 采样点后在故障发生器中引入漂移系数为 0.01 的漂移故障,且数值随时间逐渐变大,说明产生了漂移故障。

4) 精度下降故障

偏差和漂移故障发生时传感器测量值的平均值会出现偏差。发生精度下降故障测量值的方差会发生变化而平均值不会改变。其故障特性为：

$$u_i \sim N(0, \sigma^2) \tag{25}$$

图 6 所示为传感器精度下降故障运行数据：

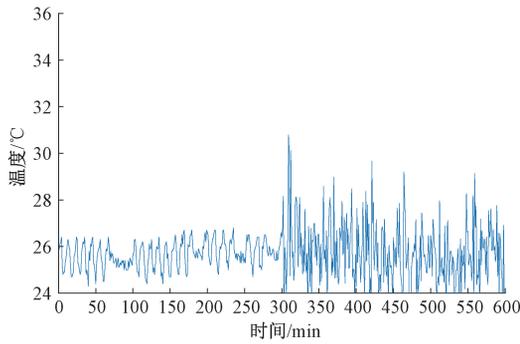


图 6 传感器精度下降故障

Fig. 6 Sensor precision failure

从图 6 中可以看出 300 采样点后传感器测量值方差变大,可以判断精度发生了下降。

3.1 中央空调实验系统介绍

实验数据采用实验室 HY-31C 型中央空调实验系统装置,如图 7 所示。



图 7 HY-31C 型中央空调实验系统

Fig. 7 HY-31C central air conditioning experimental system

该系统由冷水机组、压缩机、冷却塔、通风管道、冷冻水箱、冷凝水箱、测量仪表、PLC 电气控制柜、数据采集系统等组成。测量仪表包括 7 组温湿度传感器两组风速传感器和一组流量传感器等。由于中央空调系统本身具有大量传感器,本文仅选取最常使用并且最容易发生故障的温度传感器作为研究对象。HY-31C 型实验装置所安装的 TS-FTD 管道式温度传感器具体参数说明如表 1 所示。

表 1 TS-FTD 管道式温度传感器参数

Table 1 TS-FTD pipe temperature sensor parameters

参数名称	量程/℃	精度/℃	分辨率/℃	漂移量/℃/Y
参数值	0~50	±0.5	0.1	<0.04 ℃/Y

装置的工作面传感器布局如图 8 所示。

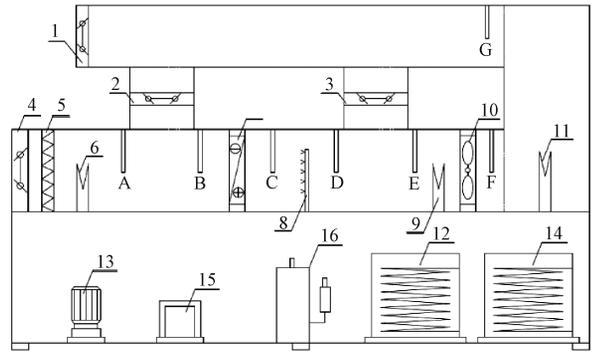


图 8 系统装置传感器布局

Fig. 8 System device sensor layout

图 8 中数字 1~16 分别代表了空调系统中的不同部件:包括通风调节装置、加热装置、蒸发器、水泵、压缩机、冷凝器等。字母 A~G 代表了各类传感器:其中传感器 A~F 位于新风口管道,传感器 G 位于出风口管道。

温度传感器 B、D 对温度传感器 C 有很大的影响,同时与湿度、风速等也有一定关联。所以把分布在不同位置的多个同类或不同类传感器所提供的测量数据联合建模形成样本空间,最后获得所检测对象的预测数据。

实验同样采集的数据为中央空调空气处理系统在夏季正常制冷工况下的运行数据 600 组数据,每组数据之间的采样时间间隔为 1 min,总采集时长为 10 h。因本方法主要为验证去噪以及模糊指标对故障检测准确率的提升,因此选取最容易获取的完全失效故障类型进行实验验证。采取手动人为断掉传感器的线来模拟传感器完全失效故障,具体操作如下：

- 1) 假设设置 A 点传感器故障。
- 2) 找到 A 点传感器拆掉输出的信号线,如图 9 所示,即可使其完全失效。



图 9 传感器模拟故障示意图

Fig. 9 Schematic diagram of sensor simulation fault

3.2 基于 CEEMDAN 的信号降噪处理

使用系统在正常工作环境的情况下所采集的湿度、风速以及 3 组相邻位置的温度传感器数据构成样本空间：

$$\text{样本空间: } (X_i, Y) = [X_1, X_2, X_3, X_4, Y]^T \quad i = 1, 2, 3, 4 \quad (26)$$

其中, X_1 为湿度传感器测量信号, X_2 为风速传感器测量信号, X_3, X_4, Y 为 3 组不同位置温度传感器数据, Y 为待检测传感器的数据。

对采集到的原始数据信号使用 CEEMDAN 方法进行分解即初次降噪, 分解后的各个 IMF 分量分别选取高频、中频、低频 3 类频率的 IMF 分量作为故障信号的特征信号。分解结果如图 10 所示。

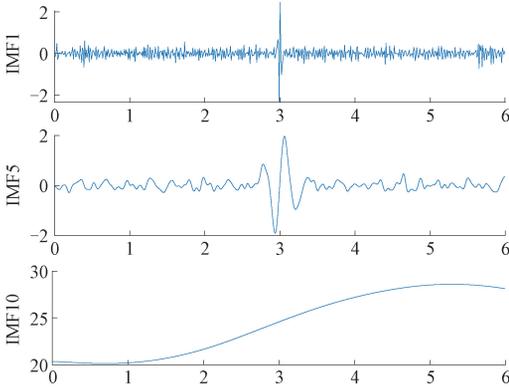


图 10 CEEMDAN 分解高频、中频、低频 IMF 分量
Fig. 10 Breaking down IMF components

计算各个分量与原始信号的相关系数, 所得结果如表 2 所示。

表 2 分解所得各分量与未去噪信号 $y(t)$ 相关系数

Table 2 Correlation coefficients between the decomposed components and the non-denoised signal

IMF1	IMF2	IMF3	IMF4	IMF5
0.052 3	0.105 9	0.080 7	0.106 7	0.097 8
IMF6	IMF7	IMF8	IMF9	IMF10
0.124 3	0.148 8	0.053 7	0.910 0	0.918 3

计算相关系数筛选出包含噪声较多的模态分量, 然后利用奇异值分解方法对建立的特征矩阵二次降噪。最后, 将经 CEEMDAN 初次处理的模态分量与奇异值分解二次去噪后的模信号重构, 得到纯净的数据。

3.3 基于 SVD 的信号双重降噪重构

对上述 IMF 分量进行选取后得到特征矩阵, 对特征矩阵进行 SVD 降噪重构即二次降噪, 主要针对初次降噪所存在的残留噪声, 利用 SVD 良好的非线性噪声抑制能力进行再次处理, 进一步提升信号的信噪比, 增强有效信息, 降噪阶次的选取最为关键, 过低可能会过滤掉故障信息, 过高则可能无法更好地去除噪声, 因此采取奇异值差分谱理论进行确定, 图 11 为不同降噪阶次与正则化值的变化图。

从图 11 中可以看出, 在降噪阶次在 3、4 的时候, 正

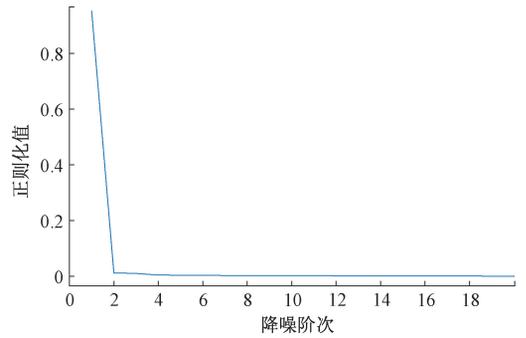


图 11 SVD 降噪阶次选取

Fig. 11 SVD noise reduction order selection

则化值变化速度减慢趋于稳定, 因此降噪阶次选择为 3 和 4 进行 SVD 降噪重构。

经实验验证选择降噪阶次为 3 时信号平滑度最好, 图 12 为降噪阶次为 3 时 SVD 降噪效果对比图, 实线代表原始数据, 因其受噪声及干扰的影响波动较大对其进行 SVD 降噪重构, 重构后的信号如虚线所示, 明显看出降噪后的信号变化波动变小且更加平滑, 信号信噪比变大。

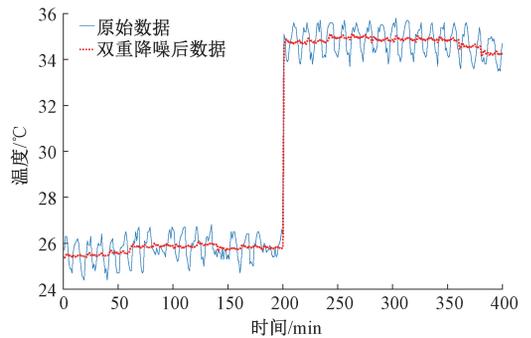


图 12 SVD 降噪重构

Fig. 12 SVD noise reduction reconstruction

从分解所得结果图可以看出, 经过双重去噪后所得到的信号变化幅度较小, 信号平滑度也较好, 更有利于后续对其进行预测并进行故障检测。接下来使用所提出的模糊指标方法计算处理过后的信号参数并进行故障检测。

3.4 相关去噪方法对比

移动平滑去噪基于统计学规律, 是数字滤波方法的一种, 比模拟滤波有更好的去噪效果, 也可以减少随机干扰的影响, 是一种去噪的有效方式。小波去噪利用小波变换来进行数据去噪和特征提取, 提升了检测模型的精度及检测速率。小波变换作为一种非自适应性的算法, 近年来也常被应用于数据去噪和特征提取相关的研究。经验模态分解由于其强大的自适应性也多用于数据去噪。以上几种方法在去噪和特征提取两方面均有良好的效果, 因此, 将本文所提方法的检测结果与移动平滑滤

波、小波去噪以及 EMD-DFA 三种方法的检测结果进行比较。结果分别如图 13~15 所示。

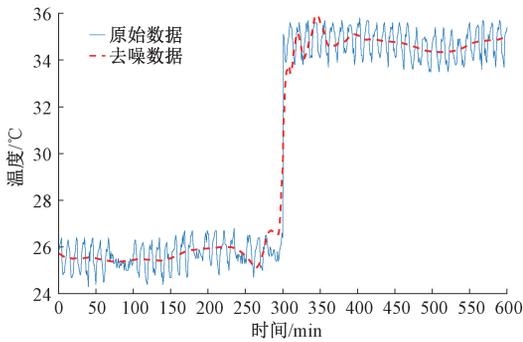


图 13 移动平滑滤波去噪效果图

Fig. 13 Moving smoothing filter denoising effect picture

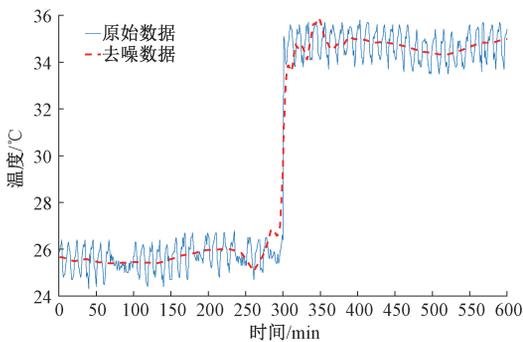


图 14 小波自适应阈值去噪效果图

Fig. 14 Image of wavelet adaptive threshold denoising

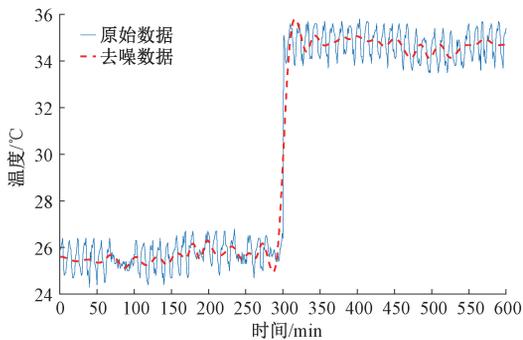


图 15 EMD-DFA 方法去噪效果图

Fig. 15 Denoising effect of EMD-DFA method

移动平滑滤波方法分解后所得到的信号平滑度较高,但其本质上是一种低通滤波方法,过滤掉原始时间序列信号中的频率较高的噪声,保留了低频的信号,也就导致无法最大地将无用的噪声信号去除。而且此方法在计算低频分量时由于使用到了窗函数,因此缺少对未来时刻数据的参考,这就会导致一定的时间滞后性。

小波自适应阈值使用自适应方法确定小波系数的阈

值,根据每一级尺度的不同自适应寻找相应的阈值进行去噪,因此所获得的信号更加接近原始信号,但当信号中含有较多噪声值时计算速度过慢,在中央空调系统中对检测速度有较高的要求,是否适用于此场景还需进一步研究。

利用了 EMD 方法良好的自适应性以及非线性信号的处理能力,与 DFA 小波阈值降噪方法结合进行了双重降噪,但没有解决 EMD 方法本身的模态混叠问题及早期噪声残留问题,从表 3 可以看出,此方法所得信号信噪比原始信号稍低,就是因为早期分解所残余的噪声所导致的。

表 3 各类去噪方法去噪后信号噪声指标对比

Table 3 Comparison of signal noise indicators after denoising by various denoising methods

方法	SNR	MSE	MAE	STD
原始信号	34.429 3	0.336 4	0.478 5	4.584
移动滤波	37.416 2	0.169 1	0.336 0	4.561
小波阈值	51.626 6	0.387 0	0.688 7	4.511
EMD-DFA	33.021 5	0.533 9	0.533 9	4.550
双重去噪	54.660 0	0.006 4	0.062 6	4.572

以上为经过各种去噪方法去噪后的效果图,为进一步证明所提双重去噪方法的有效性,分别计算原始信号和移动滤波去噪、小波自适应阈值去噪以及本文所提双重去噪方法处理过后的信号的 SNR、MSE、STD 指标,如表 3 所示。

从表 3 可以得知,4 类方法在去噪方面都有着不错的效果,但相比较而言,双重去噪方法最后所得到的结果信噪比更高且均方误差更小,信噪比平均提升 39.12%,均方误差平均减小 48.75%,说明去噪后所得到的有用信号最多,噪声信号少,其他指标也相比其他 3 种方法更小,说明去噪所得到的信号与原始信号也更为接近,更能保留原始信号中的信息,也证明了双重去噪方法的有效性。

4 故障检测实验验证及性能分析

4.1 基于模糊指标的传感器故障检测

计算其时域特征参数指标如表 4 所示。

表 4 传感器异常信号参数

Table 4 Abnormal signal parameters of the sensor

状态	X_p	σ^2	C	S	K
正常	2.500 0	0.351 0	0.097 3	0.141 6	1.986 5
偏差	2.300 0	0.387 0	0.080 0	0.182 6	1.771 9
漂移	4.660 0	0.983 5	0.170 9	0.111 3	2.713 6
精度	7.177 1	1.820 4	0.278 2	0.055 0	2.746 6
失效	2.300 0	0.387 0	0.066 2	0.182 6	1.771 9

接下来计算能量 E 和峭度系数 K , 并按照所提方法进行模糊处理得到检测结果如表 5 所示。

表 5 传感器异常信号的模糊指标判别

Table 5 Fuzzy index discrimination of sensor abnormal signal

状态类型	E	K	U	结论
正常状态	0.351 0	1.986 5	0.6	正常
偏差故障	0.387 0	1.771 9	2.8	异常
漂移故障	0.983 5	2.713 6	2.4	异常
精度下降	1.820 4	2.746 6	2.6	异常
完全失效	0.387 0	1.771 9	2.2	异常

通过上述计算结果可以明显看出, 正常状态计算所得模糊指标值较小, 而故障状态数据计算所得模糊指标值均在 2 以上, 因此选用 2 作为模糊阈值控制限进行异常信号的检测。

4.2 相关故障检测方法对比

对移动滤波去噪和小波自适应阈值去噪方法处理后的数据使用残差阈值进行故障检测, 为更好地对比不同检测方法的效果, 检测模型均采用小波神经网络建立小波预测器进行预测来求得残差值的大小, 小波神经网络具有良好的非线性逼近能力以及自适应性, 多用于非线性信号的故障检测中, 因所用原始数据相同, 因此神经网络中各参数值设定均保持一致, 所得检测效果如图 16~18 所示。

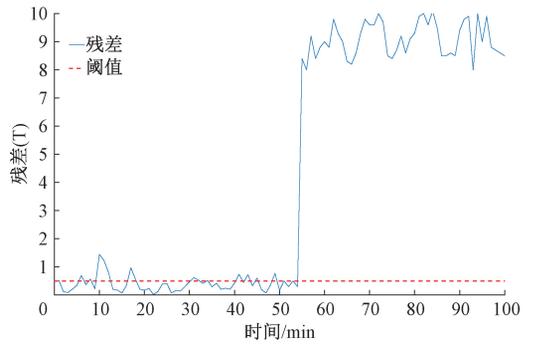


图 17 小波自适应阈值去噪故障检测效果图

Fig. 17 Wavelet adaptive threshold denoising fault detection effect picture

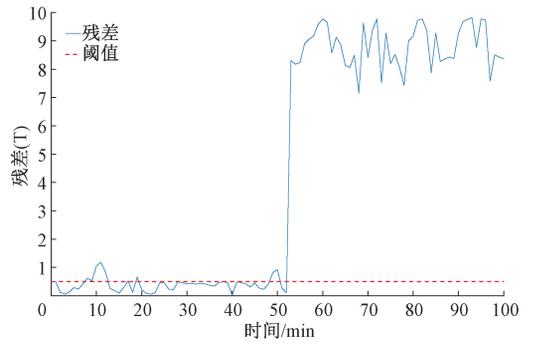


图 18 EMD-DFA 去噪故障检测效果图

Fig. 18 EMD-DFA denoising fault detection effect picture

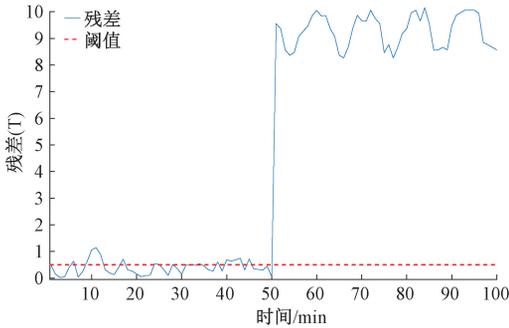


图 16 移动平滑去噪故障检测效果图

Fig. 16 Mobile smoothing denoising fault detection effect picture

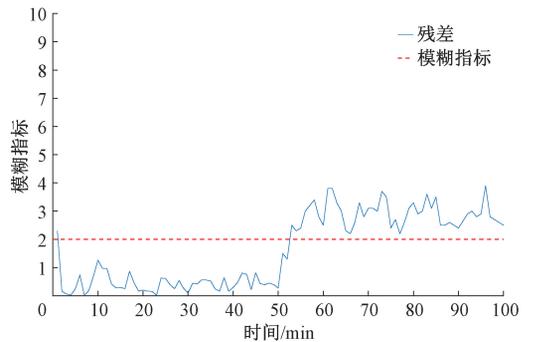


图 19 双重去噪-模糊指标故障检测效果图

Fig. 19 Double denoising-fuzzy index fault detection effect picture

原始数据信号因包含大量噪声, 检测结果较差。在以上 3 种方法去噪后检测效果有所提高, 但因存在噪声残留和模态混叠等问题, 在分解前期检测结果不太理想。

利用双重去噪方法去噪后的数据使用所提出的能量和峭度系数的模糊指标进行故障检测, 所得结果如图 19 所示。

从图 19 中可以看出分解早期的噪声残留问题得到了解决, 响应速度也变快了, 所得到的结果大部分都得到了准确检测。说明所提的双重降噪方法对现有去噪方法所存在的噪声残留及模态混叠等问题得到了解决, 所提

模糊指标的适应性及抗噪性相对传统残差阈值指标也得到了提升。

通过计算各种故障检测方法的误报漏报率以及检测率, 结果如表 6 所示。

从表 6 可以看出, 双重降噪结合模糊指标的故障检测方法在异常信号检测率上相比其他去噪传统阈值方法平均提升 8.67%, 响应速度也有着明显的提高。一方面

表 6 不同方法传感器异常信号检测指标对比

Table 6 Comparison of sensor abnormal signal detection indicators by different methods

评价 指标	双重 去噪	平滑滤波 去噪	小波自适应 应阈值	EMD-DFA 去噪
误报/%	1	5	4	2
漏报/%	2	11	8	5
检测/%	97	84	88	93
速度/N	3	3	5	4

双重降噪方法通过 CEEMDAN 和奇异值分解两次降噪,解决了传统经验模态分解的模态混叠和噪声残留问题,计算速度更快,所提取的有用信号更多;另一方面,采取无量纲时域指标能量和峭度系数的模糊指标代替残差阈值进行故障诊断,也避免了噪声对阈值设定的影响,加强了检测指标的抗噪性,因此在包含噪声信息较多的中央空调传感器故障检测中所提方法有着不错的效果。

5 结 论

本文针对强噪声下现有降噪方法存在噪声残留及故障检测阈值受噪声影响较大、传感器故障检测精度不高等问题,提出一种基于双重降噪和模糊指标的中央空调传感器故障检测方法。首先使用 CEEMDAN 方法对原始数据进行初次分解去噪并得到特征矩阵;针对 CEEMDAN 方法分解信号所具有的噪声残余等问题,利用奇异值分解的非线性噪声抑制能力对分解出来的含噪较多的分量进行二次降噪处理。最后提出模糊指标代替故障检测阈值对中央空调系统传感器进行故障检测实验。实验使用 HY-31C 型中央空调实验系统数据进行验证,得到结论如下:

1) 双重降噪方法恰好弥补了 CEEMDAN 所存在的噪声残留以及 SVD 方法在数据量过大时计算速度慢的问题,在降噪方面信噪比相对原始信号提升 20.2307 dB,对于移动平滑滤波、小波自适应阈值降噪等单一降噪方法效果提升 8.82% 以上,针对以 EMD 为基础的二次降噪方法在分解早期所具有的噪声残留问题也有所解决,极大地减少了原始数据中的噪声信号,提高了原始数据的信噪比,均方误差也平均降低了 48.36%。

2) 针对阈值设定依靠人为经验设定困难且噪声对阈值的影响较大的问题,提出了模糊指标代替残差阈值进行判定,动态考虑了无量纲时域参数能量和峭度系数对异常信号的区别性,相比传统阈值判定方法对检测率平均提升 8.67%,响应速度平均提升 33.3%,抗噪性也得到了提升。

3) 所提方法可以降低噪声对故障检测的影响,有利于快速发现故障,证明了该方法对中央空调传感器信号去噪和特征提取的有效性,对后续相关控制容错方面的

研究有很大帮助。

参考文献

- [1] HE B, ZHANG J, CHEN T, et al. Penalized reconstruction-based multivariate contribution analysis for fault isolation [J]. *Industrial & Engineering Chemistry Research*, 2013, 52(23): 7784-7794.
- [2] SAMUEL R T, CAO Y. Nonlinear process fault detection and identification using kernel PCA and kernel density estimation [J]. *Systems Science & Control Engineering an Open Access Journal*, 2019, 4(1): 1-9.
- [3] RAMACHANDRAN P, ZOPH B, LE Q V. Swish: A self-gated activation function [J]. *Research Gate*, 2019, 28(3): 994-1003.
- [4] 王一鹏, 陈学振, 李连玉. 基于小波包混合特征和支持向量机的机床主轴轴承故障诊断研究 [J]. *电子测量与仪器学报*, 2021, 35(2): 59-64.
WANG Y P, CHEN X ZH, LI L Y. Research on machine tool spindle bearing fault diagnosis based on wavelet packet mixing feature and support vector machine [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(2): 59-64.
- [5] CHEN X, WU S, SHI C, et al. Sensing data supported traffic flow prediction via denoising schemes and ANN: A comparison [J]. *IEEE Sensors Journal*, 2020, 42(99): 11-20.
- [6] YAO Z, LIU X, YANG W, et al. A coarse-to-fine denoising method for dynamic calibration signals of pressure sensor based on adaptive mode decompositions [J]. *Measurement*, 2020, 163: 107935.
- [7] 范勇, 王鹏, 张宇超. 基于改进 EMD 与 SOM 神经网络的自动机驱动机构故障诊断研究 [J]. *国外电子测量技术*, 2020, 39(8): 5-10.
FAN Y, WANG P, ZHANG N CH. Research on fault diagnosis of automata driving mechanism based on improved EMD and SOM neural network [J]. *Foreign Electronic Measurement Technology*, 2020, 39(8): 5-10.
- [8] KIM Y, RYU H, LEE S, et al. Joint demosaicing and denoising based on interchannel nonlocal mean weighted moving least squares method [J]. *Sensors*, 2020, 20(17): 4697-4707.
- [9] ZHANG Y, WANG R, LI S, et al. Temperature sensor denoising algorithm based on curve fitting and compound kalman filtering [J]. *Sensors*, 2020, 20(7): 1959-1968.
- [10] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise [C]. *IEEE International Conference on Acoustics, Speech and Signal*

- Processing, IEEE, 2021(78):4144-4147.
- [11] 张勇,杨文武,王明吉,等. 基于 CEEMDAN-HD-云模型特征熵的油气管道工况识别[J]. 电子测量技术, 2021, 44(21):89-94.
ZHANG Y, YANG W W, WANG M J, et al. Oil and gas pipeline condition identification based on CeEMdan-HD-cloud model feature entropy [J]. Electronic Measurement Technology, 2021, 44(21):89-94.
- [12] 童靳于,苏缪涎,郑近德,等. 自适应噪声均值优选集成经验模态分解及其在滚动轴承故障诊断中的应用[J]. 电子测量与仪器学报, 2021, 35(2):41-49.
TONG J Y, SU M ZH, ZHENG J D, et al. Adaptive noise mean optimization integrated empirical mode decomposition and its application to rolling bearing fault diagnosis [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2):41-49.
- [13] PENG Y, LIU Y, ZHANG C, et al. A novel denoising model of underwater drilling and blasting vibration signal based on CEEMDAN[J]. Arabian Journal for Science and Engineering, 2021, 46(5):4857-4865.
- [14] SONG P, TAN Y, GENG X, et al. Noise reduction on received signals in wireless ultraviolet communications using wavelet transform [J]. IEEE Access, 2020, 65(99):89-97.
- [15] YANG B, XIA H, ANNOR-NYARKO M, et al. Application of total variation denoising in nuclear power plant signal pre-processing [J]. Annals of Nuclear Energy, 2020, 135: 106981.
- [16] CHOWDHURY M H, SHUZAN N I, MURSHED M N, et al. A survey of the noise-correcting tools for dynamic mode decomposition [J]. ArXiv Preprint, 2021, arXiv:2103.02338.
- [17] 余博,田福庆,汤健,等. 基于 Teager 能量算子和 EEMD 的滚动轴承故障诊断方法[J]. 北京工业大学学报, 2017, 43(6):859-864.
SHE B, TIAN F Q, TANG J, et al. Rolling bearing fault diagnosis method based on teager energy operator and EEMD [J]. Journal of Beijing University of Technology, 2017, 43(6):859-864.
- [18] SUBRAHMANYA N, SHIN Y C. A data-based framework for fault detection and diagnostics of non-linear systems with partial state measurement[J]. Engineering Applications of Artificial Intelligence, 2019, 26(1):446-455.
- [19] CHANG S G, YU B, VETTERLI M. Adaptive wavelet thresholding for image denoising and compression [J]. IEEE Transactions on Image Processing, 2020, 9(9):1532-1546.
- [20] 徐喆,王超. 自适应的 KEEMD 方法及其在光谱去噪中的应用[J]. 北京工业大学学报, 2016, 42(4):513-520.
XU ZH, WANG CH. Adaptive KEEMD method and its application in spectral denoising [J]. Journal of Beijing University of Technology, 2016, 42(4):513-520.
- [21] HENG A, ZHANG S, TAN A C C, et al. Rotating machinery prognostics: State of the art, challenges and opportunities [J]. Mechanical Systems and Signal Processing, 2019, 23(3):724-739.
- [22] 刘泽锐,邢济收,王红军,等. 基于 VMD 与快速谱峭度的滚动轴承故障诊断[J]. 电子测量与仪器学报, 2021, 35(2):73-79.
LIU Z R, XING J SH, WANG H J, et al. Rolling bearing fault diagnosis based on VMD and fast spectrum kurtosis [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2):73-79.
- [23] 田宇,高强,李栋,等. 测距传感器性能评估与故障诊断方法研究[J]. 电子测量与仪器学报, 2020, 34(10):172-178.
TIAN Y, GAO Q, LI D, et al. Research on performance evaluation and fault diagnosis of distance sensor [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(10):172-178.
- [24] 范勇,王鹏,张宁超. 基于改进 EMD 与 SOM 神经网络的自动机驱动机构故障诊断研究[J]. 国外电子测量技术, 2020, 39(8):5-10.
FAN Y, WANG P, ZHANG N CH. Research on fault diagnosis of automata driving mechanism based on improved EMD and SOM neural network [J]. Foreign Electronic Measurement Technology, 2020, 39(8):5-10.
- [25] FAN M, ZENG Z, ZIO E, et al. A sequential bayesian approach for remaining useful life prediction of dependent competing failure processes [J]. IEEE Transactions on Reliability, 2019, 68(1):317-329.
- [26] ZHONG K, HAN M, HAN B. Data-driven based fault prognosis for industrial systems: A concise overview[J]. IEEE/CAA Journal of Automatica Sinica, 2020, 7(2):330-345.
- [27] ZHAO C H, GAO F R. Critical-to-fault-degradation variable analysis and direction extraction for online fault prognostic [J]. IEEE Transactions on Control Systems Technology, 2019, 25(3):842-854.
- [28] 程阳洋,李锋,汤宝平,等. 量子基因链编码双向神经网络用于旋转机械剩余使用寿命预测[J]. 仪器仪表学报, 2020, 41(7):164-174.
CHENG Y Y, LI F, TANG B P, et al. Quantum gene

- chain coding bidirectional neural network for residual useful life prediction of rotating machinery[J]. Chinese Journal of Scientific Instrument, 2020, 41 (7): 164-174.
- [29] WU Q H, DING K Q, HUANG B Q. Approach for fault prognosis using recurrent neural network[J]. Journal of Intelligent Manufacturing, 2020, 31(97): 1-13.
- [30] 王震, 黄如意, 李霁蒲, 等. 一种用于故障分类与预测的多任务特征共享神经网络[J]. 仪器仪表学报, 2019, 40(7): 169-177.
- WANG ZH, HUANG R Y, LI J P, et al. Multi-task feature sharing neural network used for fault diagnosis and prognosis[J]. Chinese Journal of Scientific Instrument, 2019, 40(7): 169-177.
- [31] YANG W S, YAO Q F, YE K J, et al. Empirical mode decomposition and temporal convolutional networks for remaining useful life estimation[J]. International Journal of Parallel Programming, 2019, 48(5): 1-19.
- [32] WANG Y J, ZHANG Y C, LI H G. Adapted receptive field temporal convolutional networks with bar-shaped structures tailored to industrial process operation models [J]. Industrial & Engineering Chemistry Research, 2020, 59(13): 5482-5490.
- [33] 黄南天, 王达, 刘座铭, 等. 复杂噪声环境下电能质量复合扰动特征选择[J]. 仪器仪表学报, 2018, 39(4): 82-90.
- HUANG N T, WANG D, LIU Z M, et al. Feature selection of composite power quality disturbances under complex noise environment [J]. Chinese Journal of Scientific Instrument, 2018, 39(4): 82-90.

- [34] 施文, 陆宁云, 姜斌, 等. 数据驱动的地铁车门微小故障智能诊断方法[J]. 仪器仪表学报, 2019, 40(6): 192-201.

SHI W, LU N Y, JIANG B, et al. Data-driven intelligent incipient fault diagnosis for subway vehicle door system [J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 192-201.

作者简介



高学金 (通信作者), 2002 年于河北科技大学获得学士学位, 2010 年于北京工业大学获得博士学位, 现为北京工业大学教授, 博士生导师, 主要研究方向为发酵过程建模、监控与故障诊断研究。

E-mail: gaouxuejin@bjut.edu.cn

Gao Xuejin (Corresponding author), received his B. Sc. degree from Hebei University of Science and Technology in 2002 and Ph. D. degree from Beijing University of Technology in 2010. He is currently a professor and doctoral supervisor at Beijing University of Technology. His main research interests include fermentation process modeling, monitoring and fault diagnosis.



张琳峰, 北京工业大学 2019 级控制科学与工程专业硕士研究生, 主要研究方向为工业设备监控与故障诊断研究。

E-mail: zlf_1220@163.com

Zhang Linfeng, master candidate of Control Science and Engineering, Beijing University of Technology, grade 2019, His main research interests include industrial equipment monitoring and fault diagnosis.