

DOI:10.11918/202401015

一种热工监测参数的模态双分解降噪方法

卓越¹,倪何¹,肖鹏飞²,何超³

(1. 海军工程大学 动力工程学院, 武汉 430033; 2. 中国船舶集团有限公司第七〇三研究所, 哈尔滨 150078; 3. 安庆中船柴油机有限公司, 安徽 安庆 246001)

摘要: 针对热工监测参数普遍存在异常值、噪声和不规则扰动的问题,从提高监控系统调节控制的精确性和系统运行管理水平的目的出发,提出了一种基于中值模态分解(MREMD)和变分模态分解(VMD)的热工监测参数降噪方法,旨在尽可能保留原始数据有效信息的基础上,降低监测参数的噪声和扰动。首先,对监测参数进行 MREMD 分解,得到若干本征模态函数(IMF)。其次,通过引入混沌时间序列分析的排列熵筛选出包含噪声的 IMF 分量重构为原始数据的噪声部分,然后对噪声部分进行 VMD 分解,以分解所得本征模态函数的最优包络熵为适应度函数,使用北方苍鹰算法(NGO)对 VMD 分解参数进行寻优,在寻优范围内得到的最低包络熵本征模态函数即噪声部分所含的有效信息。最后,将此部分与 MREMD 分解所得包含趋势信息的低频 IMF 分量和残余分量求和重构,得到降噪后的监测信号。结果表明,通过算例验证,本研究提出的模态双分解降噪方法,与主流的各类型小波阈值降噪方法和移动均值滤波法相比,具有更高的信噪比和更低的信息熵及功率谱熵。

关键词: 数据降噪;中值模态分解(MREMD);C-C 算法;信息熵;变分模态分解(VMD)

中图分类号: TK39

文献标志码: A

文章编号: 0367-6234(2025)04-0162-09

A modal double-decomposition noise reduction method for thermal monitoring parameters

ZHUO Yue¹, NI He¹, XIAO Pengfei², HE Chao³

(1. College of Power Engineering, Naval University of Engineering, Wuhan 430033, China;

2. No. 703 Research Institute of China State Shipbuilding Company, Harbin 150078, China;

3. Anqing CSSC Diesel Engine Co., Ltd., Anqing 246001, Anhui, China)

Abstract: Aiming at the problem of outliers, noise and irregular disturbances prevailing in the monitoring parameters of the thermal system, a noise reduction method for monitoring parameter of the thermal system based on median regression empirical mode decomposition (MREMD) and variational mode decomposition (VMD) is proposed. The purpose is to enhance the accuracy of monitoring system regulation and the level of system operation management, while minimizing noise and disturbances in the monitoring parameters, all while preserving as much of the original data's effective information as possible. The method firstly performs MREMD of the monitoring parameters to obtain a number of intrinsic mode functions (IMF). Secondly, chaotic time series analysis is applied to filter out the IMF components containing noise using permutation entropy, reconstructing them as the noise portion of the original data. Then the noise part is decomposed by VMD, and the optimal envelope entropy of the IMF obtained by the decomposition is used as the fitness function. The northern goshawk optimization (NGO) algorithm is used to optimize the VMD decomposition parameters, yielding the IMF with the lowest envelope entropy within the optimization range, which contains the effective information of the noise portion. Finally, this part was reconstructed by summing with the low frequency IMF component and residual component obtained by MREMD decomposition which both are contained trend information, to obtain the monitoring signal after noise reduction. The results demonstrate that through case studies, the modal double-decomposition noise reduction method proposed in this paper has highest signal-to-noise ratio and lower information entropy and power spectral entropy compared to mainstream wavelet threshold denoising methods and moving average filtering techniques.

Keywords: data noise reduction; median regression empirica mode decomposition (MREMD); C-C algorithm; information entropy; variational mode decomposition (VMD)

收稿日期: 2024-01-04; 录用日期: 2024-04-19; 网络首发日期: 2024-11-18

网络首发地址: <https://link.cnki.net/urlid/23.1235.t.20241115.1651.002>

基金项目: 国家自然科学基金面上项目(51909254); 海军工程大学自主研发基金资助项目(425317T014)

作者简介: 卓越(1999—),男,硕士研究生

通信作者: 倪何, elegance2006@sina.com

热力系统是一系列高温、高压和高速设备的有机组合,系统各部件之间存在着机械、气(汽)动、热力、换热、质量流动等多种形式的联系,其中任何一个设备、任何一个过程状态的改变都会对系统造成多方面的影响,为保证系统的运行稳定性,工业上普遍采用综合控制系统对其运行过程进行控制、优化及故障分析。在这个过程中,监测系统获得的信号质量和信号所含信息量大小会直接影响综合控制系统的工作,进而决定整个系统的运行管理水平。

受限于传感器采样频率、精度和外部环境干扰,采样数据会包含一定的噪声和扰动,目前较成熟的方法是在传感器的信号处理模块加入均值滤波以降低原始数据的噪声,但是这种方法存在边界效应模糊,细节丢失比较严重,只能减弱噪声而无法去掉噪声的缺点。针对该问题,Charbonnier 等^[1]针对传统滤波中固定调谐参数会滤去数据中蕴含的部分信息项,从而对数据降噪过程造成干扰的问题,提出了一种先对原信号进行线性分段,再根据实时噪声方差自适应调整调谐参数的方法,有效降低强噪声干扰。Huang 等^[2]提出一种经验模态分解(empirical mode decomposition, EMD)方法,把信号分解成一些本征模态函数(intrinsic mode function, IMF)分量^[3],然后对分解得到的各阶 IMF 分量进行 Hilbert 变换,得出时频平面上的信号幅值分布谱图(Hilbert 谱),最后选取低频 IMF 分量重构的降噪方法。Zhang 等^[4]提出了先用正交小波变换算法对原始数据进行滤波和特征识别,再使用 EMD 方法进行趋势提取的小波—EMD 融合数据降噪方法;在原始数据趋势为非线性时,该模型可以消除 EMD 算法造成的多变效应误差,提高降噪效果。在热工信号处理领域,郑奕扬等^[5]在对蒸汽动力系统单参数进行处理时,采用了中值模态分解(median regression empirical mode decomposition, MREMD)和奇异值分解相结合的方法,分别去除最高频分量和排列熵最低的分量,对剩余分量进行重构,以达到去除原始数据噪声和干扰的目的。但是仅舍去最高频分量,既可能造成高频分量所含信息丢失,也可能造成中间频率模态混叠。针对该问题,肖鹏飞等^[6]将原始数据经过 MREMD 分解所得 IMF 分量筛选为高、低频分量之后对高频分量进行改进阈值的小波降噪,再对所有分量进行奇异值分解并使用 k -means 聚类法将低排列熵的分量重构为原始数据趋势项。由于其降噪目的是得到

运行数据趋势项,以便于对运行数据未来趋势进行预测,因此其舍弃了较多的波动细节而更侧重于对整体运行趋势的提取。

从上述研究现状的分析可见,监测数据降噪方法大多是普适方法,但是在不同专业领域的适用性或者说应用效果不一样。例如:对于机械系统,代表其故障模式的异常振动信号可能会集中在高、中、低等各个频域^[7],因此在机械振动信号处理方面,为防止特征信号的丢失,一般采用针对性的特征提取方法^[8];在高精度导航领域,由于振动造成的噪声通常集中在超低频部分,因此必须采用被动隔振、主动隔振和振动补偿等特殊的降噪方法^[9-10];而对于本文研究的热工监测参数,目前除了通用的滤波降噪外,其频域特征的降噪和特征提取通常采用忽略信号短时波动和振荡,再对监测数据进行模态分解并筛选出低频信号重构的方法提取数据的趋势信息^[5-6]。众所周知,对于热工控制系统而言,系统的控制指令是根据监测参数实时下达的。在这种应用场景下,为保障控制系统能够根据运行状态参数的波动做出精确且实时的调整,本文研究一种可以在保留信号波动部分有效信息并同时去除其噪声的方法具有一定的理论和实际工程应用价值。

1 基于模态双分解的热工参数降噪方法

热力系统通常存在着大惯性、大迟延、时变、耦合、非线性等特性^[11],对应监测得到的热工信号也通常具有低频、迟延、非平稳、耦合、非线性、含噪、多尺度等特征^[12]。在频域分布上,这类信号具有噪声和扰动大多集中于信号的高频部分、有效趋势信息集中于低频部分,而中间频率部分混叠有效信息和噪声的特点。本文针对热工监测信号的上述特点,为有效剥离出杂糅在中间频域内的有效信息并去除噪声和扰动,提出了一种基于 MREMD 和变分模态分解(variational mode decomposition, VMD)的热工信号降噪方法。该方法,通过引入混沌时间序列中的 C-C(cross-correlation)算法结合排列熵理论作为 IMF 分量的评价指标,能够在尽可能保留原始信号信息量的基础上降低干扰和噪声,适用于一些需要监测参数(例如温度、压力、水位、流量、流速等)的短期波动信息,同时又需要避免噪声干扰的热工监测系统,其具体流程见图 1。




图 1 基于模态双分解的热工参数降噪方法流程

Fig. 1 Flow chart of thermal parameter noise reduction method based on modal double decomposition

Step1 对热力系统运行参数进行 MREMD, 得到若干 IMF 分量和残余分量。

Step2 计算各 IMF 分量经 C-C 算法优化时间延迟和重构维数的排列熵值, 对各 IMF 分量的排列熵值进行 k-means 聚类, 将 IMF 分量划分为包含噪声和扰动的高频 IMF 分量和包含趋势信息的低频 IMF 分量, 对高频 IMF 分量求和重构后得到原始数据的噪声分量。

Step3 使用 VMD 提取 Step2 所得原始数据噪声分量中的信息部分, VMD 分解参数由北方苍鹰算法 (northern goshawk optimization, NGO) 得到, 将原始数据噪声部分分解为若干 IMF 分量, 为与本文中 MREMD 所得的 IMF 分量做区分, VMD 分解所得的 IMF 分量记为 IMF*。

Step4 记录北方苍鹰算法 (NGO) 中最优适应度时 IMF* 分量的适应度, 选取最佳适应度的 IMF* 分量与 Step2 中的低频 IMF 分量和 Step1 的残余分量重构为降噪后的原始数据。

上述各步骤中涉及的具体算法如下。

1.1 MREMD 分解

MREMD 是在经验模态分解的基础上, 采用自

回归 (autoregressive model, AR) 模型对信号端点延拓, 并用优化包络线拟合的方法改善了 EMD 未对有效分量和干扰分量进行定量区分, 容易造成预测误差的问题。具体步骤如下:

Step1 设研究的时间序列为 $s_0(t)$, 通过 AR 模型将 $s(t)$ 两端拓延至原序列左右端点均处于延拓后时间序列的相邻两个极值点之间。

$s_t = \phi_0 + \phi_1 s_{t-1} + \phi_2 s_{t-2} + \dots + \phi_p s_{t-p} + \mu_t$ (1)
式中: s 为均值点, $\phi_0, \phi_1, \dots, \phi_p$ 为 $p+1$ 个实数, $\mu_t(p+1, p+2, \dots, N)$ 为零均值的白噪声序列。

Step2 设延拓后的 $s_0(t)$ 存在 z 个极值点, 对相邻极值点求均值, 得序列 $\{s_{mi}, 0\}$, 其中 $i=1, 2, \dots, z-1$, 再通过对均值序列进行 3 次样条插值可得

$$h_{1,0}(t) = s_0(t) - m_{1,0}(t) \quad (2)$$

式中: $m_{1,0}(t), s_0(t) - m_{1,0}(t)$ 为 $s_0(t)$ 的信号均值序列, $h_{1,0}(t)$ 为 $s_0(t)$ 的 1 阶信号分量。

Step3 对 $h_{1,0}(t)$ 重复 Step1、Step2 进行迭代计算, 设 l 次迭代后 $h_{1,l}(t)$ 满足以下终止条件, 则此时停止迭代, 终止条件为

$$\begin{cases} \frac{|\sigma_{l-1} - \sigma_l|}{s_\sigma^M} \leq 0.200 \\ P(\vartheta_l | \vartheta_l \leq \vartheta_0) \geq 0.950 \\ P\{|s_z| | (|s_z| \leq s_\sigma^M)\} \geq 0.685 \end{cases} \quad (3)$$

式中: $z=1, 2, \dots, z+1, \sigma^*, \sigma_i$ 分别为第 $l-1$ 次迭代后 $h_{1,l-1}(t)$ 的均值点序列标准差, σ_i 为第 l 次迭代后 $h_{1,l}(t)$ 的均值点序列标准差, s_z 为延拓后信号序列的第 z 个极值点, P 为条件概率, θ_0, θ_l 分别为初始信号和第 l 次迭代后的信号均值点与 s_σ^M 的比值, 即

$$\begin{cases} \vartheta_0 = \left(\frac{s_{1,0}^m}{s_\sigma^M}, \frac{s_{2,0}^m}{s_\sigma^M}, \dots, \frac{s_{k,0}^m}{s_\sigma^M} \right) \\ \vartheta_l = \left(\frac{s_{1,l}^m}{s_\sigma^M}, \frac{s_{2,l}^m}{s_\sigma^M}, \dots, \frac{s_{k,l}^m}{s_\sigma^M} \right) \end{cases} \quad (4)$$

式中: $s_{1,0}^m, s_{2,0}^m, s_{3,0}^m$ 为未进行迭代时初始信号 $s_0(t)$ 的均值点, $s_{1,l}^m, s_{2,l}^m, s_{3,l}^m$ 为第 $l-1$ 次迭代后信号分量 $h_{1,l-1}(t)$ 的均值点。

Step4 $h_{1,l}(t)$ 即为 1 阶 IMF 分量, $x_0(t) - \text{IMF}_1$ 为一阶残余信号 R_1 , 将 R_1 作为原始信号重复 Step1 ~ Step3, 直到残余分量成为单调函数或分离不出新的 IMF 分量为止, 计算过程如下:

$$\begin{cases} R_1 = x_0 - \text{IMF}_1 \\ R_2 = R_1 - \text{IMF}_2 \\ \vdots \\ R_n = R_{n-1} - \text{IMF}_n \end{cases} \quad (5)$$

式中: n 为能够分解的最大 IMF 分量个数, R_n 为原始信号 $s_0(t)$ 的 n 阶残余信号,称为残余分量。

经过上述分解后,原始信号 $s_0(t)$ 可表示为所有 IMF 分量和残余分量之和,即

$$s_0(t) = \sum_{i=1}^n \text{IMF}_i + R_n \quad (6)$$

1.1.1 排列熵及其相空间重构参数选取

原始信号经 MREMD 后得到的 IMF 分量可分为包含噪声和扰动的高频 IMF 分量、包含趋势信息的低频 IMF 分量以及同时包含噪声和趋势信息的中间频率分量。针对 IMF 分量的划分标准选取问题,由于各 IMF 分量主要表现在频谱上的不同,与原始信号之间量纲差距较大,诸如均方根误差等以量纲为基础的评价标准不能有效评价 IMF 分量的优劣。本文选取排列熵作为评价 IMF 分量信号质量的标准,对各阶 IMF 分量进行划分。

排列熵作为定量评价时间序列随机性的指标,与传统的近似熵和样本熵相比,具有计算速度快、抗噪能力强、不依赖数据长度的优点,常用于衡量时间序列复杂度^[13-14]。具体算法如下。

Step1 设一段时间序列为 $y(k)$,对原始数据进行相空间重构:

$$\mathbf{Y} = \begin{bmatrix} y(1) & y(1+\tau) & \cdots & y(1+(m-1)\tau) \\ y(2) & y(2+\tau) & \cdots & y(2+(m-1)\tau) \\ y(j) & y(j+\tau) & \cdots & y(j+(m-1)\tau) \\ \vdots & \vdots & & \vdots \\ y(k) & y(k+\tau) & \cdots & y(k+(m-1)\tau) \end{bmatrix} \quad (7)$$

式中: m 为嵌入维数, τ 为延迟时间, k 为重构分量个数。

Step2 将每一个重构分量按照首元素顺序重新排列,得到向量中各元素位置的列,索引构成一组符号序列 $S(l)$ 为

$$S(l) = \{j_1, j_2, \cdots, j_m\}, l = 1, 2, \cdots, k \text{ 且 } k \leq m \quad (8)$$

Step3 计算每一种符号序列出现的概率为

$$H_{pe} = - \sum_{j=1}^k f_j \ln(f_j) \quad (9)$$

Step4 对 H_{pe} 进行归一化处理以使其在实际应用中更直观方便,即

$$0 \leq H_{pe} = \frac{H_{pe}}{\ln(m!)} \leq 1 \quad (10)$$

式中: f_j 为符号序列出现的概率, H_{pe} 为排列熵值。

1.1.2 C-C 算法

由于热工监测参数是非线性、非稳定的时间序列,其 MREMD 所得 IMF 分量同样具有混沌时间序

列特征,因此在计算各 IMF 分量的排列熵时,本文采用混沌系统分析中的 C-C 算法计算相空间重构的时间延迟 τ_b 和嵌入维数 m 。C-C 算法采用了交叉关联函数来度量重构数据与原始数据之间的关联程度,并根据关联程度来调整相空间重构参数。通过不断迭代和调整参数,C-C 算法可以逐步优化相空间重构结果,减小降维和重构过程中的信息丢失,并尽可能地保留原始数据的特征,提高相空间重构数据的表示精度和可解释性^[15]。计算过程如下。

将 IMF 分量时间序列 $\{s_M(i)\} = s_M^1, s_M^2, \cdots, s_M^\tau$ 分解成 τ 个子序列为

$$\begin{cases} s_M^1 = \{s_{M(i)} \mid i = 1, \tau + 1, \cdots, G - \tau + 1\} \\ s_M^2 = \{s_{M(i)} \mid i = 1, \tau + 2, \cdots, G - \tau + 1\} \\ \vdots \\ s_M^\tau = \{s_{M(i)} \mid i = \tau, 2\tau, \cdots, G\} \end{cases} \quad (11)$$

然后计算 τ 个子序列,即

$$S(m, G, r, \tau) = \frac{1}{\tau} \times \sum_{s=1}^{\tau} [C_s(m, \frac{N}{\tau}, r, \tau) - C_s^m(m, \frac{N}{\tau}, r, \tau)] \quad (12)$$

当 $N \rightarrow \infty$ 时,有

$$S(m, r, \tau) = \frac{1}{\tau} \sum_{s=1}^{\tau} [C_s(m, r, \tau) - C_s^m(m, r, \tau)] \quad (13)$$

由于 IMF 分量中部分元素存在一定的相关性,因此 $S(m, r, \tau) \neq 0$,其最大偏差为

$$\Delta S(m, \tau) = \max\{S(m, r_j, \tau)\} - \min\{S(m, r_j, \tau)\}, \\ m = 2, 3, 4, 5; j = 1, 2, 3 \quad (14)$$

按照数据长度 K ,计算 IMF 分量时间序列的标准差 σ ,再利用下式分别计算 3 个统计量 $\bar{S}(\tau)$ 、 $S_{cor}(\tau)$ 、 $\Delta S(\tau)$ 为

$$\begin{cases} \bar{S}(\tau) = \frac{1}{16} \sum_{m=2}^5 \sum_{j=1}^4 S(m, r_j, \tau) \\ \Delta \bar{S}(\tau) = \frac{1}{4} \sum_{m=2}^5 \Delta S(m, \tau) \\ S_{cor}(\tau) = \Delta \bar{S}(\tau) + |\bar{S}(\tau)| \\ r_j = j\sigma/2 \end{cases} \quad (15)$$

取迭代过程中 $S_{cor}(\tau)$ 的最小值为相空间重构的最佳时间延迟值,由 $\bar{S}(\tau)$ 、 $S_{cor}(\tau)$ 与 τ 之间的相关性,利用下式求取相空间重构的嵌入维数 m 为

$$m = \frac{\tau_w}{\tau_d} + 1 \quad (16)$$

式中 τ_d 为 $\bar{S}(\tau)$ 第 1 个极小值所对应的时间延迟值。

针对各阶 IMF 分量的排列熵值,采用 k -means 聚类分析算法^[16]将各 IMF 分量按照熵值大小分为两类,分别作为原始数据噪声部分和信息部分。选取排列熵低类的 IMF 分量求和重构为原始数据的高频噪声分量,对此部分进行 VMD 分解降噪。

1.2 变分模态分解

对于筛选得到的高频 IMF 分量,传统方法是将其直接舍去以达到降噪的目的,但是由于高频 IMF 除噪声和扰动外,还可能包含了周期性波动等原始数据信息,直接舍去会引起信息丢失。针对该问题,本文采取对原始数据 MREMD 所得高频 IMF 分量再进行 VMD,筛选出高频 IMF* 分量中的信息部分,将其与 MREMD 所得低频分量和残余分量重构的方式,可以在尽可能保留原始数据信息的情况下,去除噪声和不规则扰动。

VMD 是一种完全非递归的变分模态分解,由 Dragomiretskiy 等^[17]于 2014 年提出。整体思路为:假设任何的信号都是由 K 列具有特定中心频率、有限带宽的数个本征模态函数组成。以经典维纳滤波为基础,以下列两项为约束条件:1) 要求每个模态分量中心频率的带宽之和最小;2) 所有的模态分量之和等于原始信号。对变分问题进行求解,找到各中心频率在频域中对应的有效成分,得到本征模态函数,具体步骤见文献^[17]。

在 VMD 分解中,惩罚因子 α 和分解层数 K 需自行确定,其值的选择会直接影响 VMD 方法的分解效果。针对该问题,本文提出利用北方苍鹰算法(NGO)在一定迭代范围内,寻找 K 和 α 的最优解。

北方苍鹰算法是 Dehghani 等^[18]受北方苍鹰捕猎行为的启发,于 2021 年提出的全局寻优算法,该算法结构新颖、参数少、收敛快。具体寻优过程分为猎物识别与攻击(勘探阶段)、追逐及逃生(开发阶段)。具体算法步骤如下。

首先,对苍鹰种群进行初始化,即

$$\mathbf{X} = \begin{bmatrix} X_1 \\ \vdots \\ X_i \\ \vdots \\ X_N \end{bmatrix} = \begin{bmatrix} X_{1,1} & \cdots & X_{1,j} & \cdots & X_{1,m} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ X_{i,1} & \cdots & X_{i,j} & \cdots & X_{i,m} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ X_{N,1} & \cdots & X_{N,j} & \cdots & X_{N,m} \end{bmatrix}_{N \times m} \quad (17)$$

式中: $\mathbf{X}$ 为苍鹰的种群矩阵, X_{ij} 为第 i 个苍鹰的第 j 维位置, N 为种群数量, m 为求解问题的维度。

苍鹰种群的目标函数值可以用目标函数值向量

表示:

$$\mathbf{F} = \begin{bmatrix} F_1 \\ \vdots \\ F_i \\ \vdots \\ F_N \end{bmatrix}_{N \times 1} = \begin{bmatrix} F(X_1) \\ \vdots \\ F(X_i) \\ \vdots \\ F(X_N) \end{bmatrix}_{N \times 1} \quad (18)$$

式中: $\mathbf{F}$ 为北方苍鹰种群的目标函数向量, F_i 为第 i 个北方苍鹰的目标函数值。

北方苍鹰在捕猎时对猎物的选择是随机的,即 NGO 算法的勘探能力。这个阶段是对搜索空间进行全局搜索,目的是确定最优区域。这一阶段用下式描述:

$$P_i = X_k,$$

$$(i = 1, 2, \dots, N; k = 1, 2, \dots, i-1, i+1, \dots, N) \quad (19)$$

$$x_{i,j}^{\text{new},P_1} = \begin{cases} x_{i,j} + r(p_{i,j} - I_{x_{i,j}}), & F_{p_i} < F_i \\ x_{i,j} + r(x_{i,j} - p_{x_{i,j}}), & F_{p_i} \geq F_i \end{cases} \quad (20)$$

$$X_i = \begin{cases} x_{i,j}^{\text{new},P_1}, & F_i^{\text{new},P_1} < F_i \\ X_i, & F_i^{\text{new},P_1} \geq F_i \end{cases} \quad (21)$$

式中: P_i 为第 i 个猎物的位置, F_{p_i} 为第 i 个猎物位置的目标函数值, k 为 $[1, N]$ 范围内的随机整数, $x_{i,j}^{\text{new},P_1}$ 为第 i 个北方苍鹰的新位置, $x_{i,j}^{\text{new},P_1}$ 为第 i 个北方苍鹰的第 j 维的新位置, F_i^{new,P_1} 为基于第 1 阶段更新后第 i 个北方苍鹰的目标函数值, r 为 $[0, 1]$ 范围内的随机数, I 为 1 或 2 的随机整数。

在北方苍鹰攻击猎物后,猎物会试图逃跑,北方苍鹰需要继续高速追逐猎物,即算法对搜索空间的局部搜索。假设这种狩猎活动接近于一个半径为 R 的攻击位置,称为该攻击范围的开发阶段,此阶段过程用下式描述:

$$x_{i,j}^{\text{new},P_2} = x_{i,j} + R(2r - 1)x_{i,j} \quad (22)$$

$$R = 0.02(1 - t/T) \quad (23)$$

$$X_i = \begin{cases} x_{i,j}^{\text{new},P_2}, & F_i^{\text{new},P_2} < F_i \\ X_i, & F_i^{\text{new},P_2} \geq F_i \end{cases} \quad (24)$$

式中: t 为当前迭代次数, T 为最大迭代次数, $x_{i,j}^{\text{new},P_2}$ 为第 i 个北方苍鹰的新位置, $x_{i,j}^{\text{new},P_2}$ 为第 i 个北方苍鹰的第 j 维的新位置, $x_{i,j}^{P_2}$ 为基于第 2 阶段更新后第 i 个北方苍鹰的第 j 维位置, F_i^{new,P_2} 为基于第 2 阶段更新后第 i 个北方苍鹰的目标函数值。

由于本文所提出的 C-C 算法优化相空间重构参数的排列熵计算过程较为复杂,而 NGO 算法在寻

优过程中需要对适应度函数反复迭代,因此优化相空间重构参数的排列熵作为 NGO 适应度函数会引起计算时间过长的问題,造成算力浪费,虽然可以作为高、低频信号序列的评价与划分标准,却不适合用于 NGO 优化 VMD 的适应度函数。

包络熵通过度量信号在频谱上的能量分布,可以用于衡量信号复杂性和不确定性,进而定量分析信号的频谱特征和频域信息。包络熵的值越高,表示信号的频谱能量分布越平均,频域信息的分散程度越大;反之包络熵的值越低,表示信号的频谱能量分布越集中,频域信息的集中程度越高^[19]。由于该方法计算简单,因此本文选取各 IMF* 分量的包络熵作为 NGO 寻优的适应度函数,计算方法如下:

$$E_p = - \sum_{j=1}^m p_j \lg p_i \tag{25}$$

$$p_j = l(j) / \sum_{j=1}^m l(j) \tag{26}$$

$$l(j) = \sqrt{[x(j)]^2 + \{H[x(j)]\}^2} \tag{27}$$

式中: E_p 为 IMF* 分量的包络熵, $x(j)$ ($j=1,2,\cdots,m$)为 VMD 分解所得 IMF* 分量, $l(j)$ 为 $x(j)$ 通过希尔伯特解调后所得的包络信号序列, H 为信号的 Hilbert 变换。

2 算例验证

船舶蒸汽动力系统内部存在大量的传热、传质、相变现象,热工和水力转换类型较为齐全;同时,其运行状态变化过程相对缓慢,存在明显的趋势性特征而鲜有突变,其监控参数也存在噪声和扰动。从频谱分析,船舶蒸汽发电系统大部分监控参数的高频部分为噪声和扰动,低频部分为包含运行趋势特征在内的有效信息,因此本文以某型船舶蒸汽动力系统为例,分别选取含噪声仿真信号和实际运行信号,通过计算含噪声仿真信号的信噪比和均方根误差,实际运行信号的信息熵和功率谱熵,从两种评价指标的角度,对本文所提的热工监测参数降噪方法进行验证。

使用本单位自研仿真机,在汽轮给水泵以及电动给水泵断电情况下,对主机进气阀开度从 50% 渐增至 80% 的变工况过程进行仿真,仿真得到的锅炉汽包水位变化的纯净信号见图 2,对纯净信号增加幅度为原始信号 0.1 倍的白噪声后,见图 3。

对含噪声的仿真信号进行 MREMD 分解,得到 6 个 IMF 分量和 1 个残余分量,见图 4。




图2 锅炉汽包水位变化的纯净信号

Fig. 2 Pure signal of boiler drum water level




图3 锅炉汽包水位变化的含噪声信号

Fig. 3 Noise-containing signal of boiler drum water level change




图4 MREMD 分解得到的 IMF 分量和残余分量 R_n

Fig. 4 MREMD decomposed IMF components and residual amount R_n

根据式(7)~(10)所示方法,计算 $IMF_1 \sim IMF_6$ 分量的排列熵,相空间重构参数由式(11)~(16)所示 C-C 算法得到,各 IMF 分量的统计量 $S_{cor}(\tau)$ 见图 5。




图 5 各 IMF 分量的统计量 $S_{\text{cor}}(\tau)$ 迭代过程图

Fig. 5 Statistical $S_{\text{cor}}(\tau)$ iteration process diagram for each IMF component

取图 5 中 $S_{\text{cor}}(\tau)$ 最小值所对应的时间延迟值为各 IMF 分量的最佳时间延迟值;再根据式(16)计算出各 IMF 的最佳嵌入维数;然后将其代入式(7) ~ (10)中,计算得到各 IMF 分量的排列熵值。各 IMF 分量的最佳延迟时间、最佳嵌入维数以及排列熵值见表 1。

表 1 各 IMF 分量的最佳延迟时间、最佳嵌入维数以及排列熵值

Tab. 1 Optimal delay time, optimal embedding dimension and permutation entropy for each IMF component			
IMF 分量	时间延迟/s	嵌入维数	排列熵
IMF ₁	7	3	0.999 7
IMF ₂	7	2	0.988 0
IMF ₃	8	3	0.993 7
IMF ₄	11	7	0.606 5
IMF ₅	6	2	0.995 1
IMF ₆	7	2	0.928 5

对排列熵进行 k -means 聚类,选取高排列熵类的 IMF₁、IMF₂、IMF₃、IMF₅ 分量求和重构为仿真信号的噪声部分,见图 6。




图 6 提取出的噪声部分

对噪声数据进行 VMD 分解,VMD 分解的结构参数由 NGO 得到,NGO 种群设置为 20,迭代次数为

15,适应度函数为式(25) ~ (27)所示的包络熵,适应度变化见图 7。




图 7 NGO 寻优过程适应度变化

Fig. 7 Fitness change of NGO optimization process

根据 NGO 全局寻优结果,取 VMD 分解的最优惩罚系数 α 为 3 000,最优分解层数 K 为 10,最优适应度为 3.826 4。最优适应度时各 IMF* 分量的包络熵见表 2,各 IMF* 分量见图 8。

表 2 最优适应度时各 IMF* 分量的包络熵

Tab. 2 Envelope entropy of each IMF* component at optimal fitness

IMF* 分量	IMF ₁ *	IMF ₂ *	IMF ₃ *	IMF ₄ *	IMF ₅ *
包络熵	3.826 4	5.091 4	5.701 2	5.022 0	5.649 8
IMF* 分量	IMF ₆ *	IMF ₇ *	IMF ₈ *	IMF ₉ *	IMF ₁₀ *
包络熵	5.855 9	5.919 1	5.915 6	5.929 5	5.878 0




图 8 VMD 分解得到的 IMF* 分量

Fig. 8 IMF* components decomposed from VMD

取 VMD 分解所得的 IMF_1^* 分量和 MREMD 分解所得的低排列熵类 IMF_4 、 IMF_6 分量和残余分量一起重构为降噪后的仿真信号,降噪后的信号、纯净信号和含噪声信号的对比见图 9。

本文计算降噪后信号的信噪比和降噪信号与纯净信号的均方根误差,作为降噪效果评价标准如下:

$$\begin{cases} R_{SN} = 10\lg(P_s/P_n) \\ E_{RMS}(s,h) = \sqrt{\frac{1}{K} \sum_{i=1}^K (s_i - h_0)^2} \end{cases} \quad (28)$$

式中: R_{SN} 为降噪后信号的信噪比, E_{RMS} 为降噪信号与纯净信号的均方根误差, P_s 为纯净信号功率, P_n 为噪声功率, K 为数据长度, s_i 为降噪后信号, h_0 为纯净信号。

经计算,降噪后信号的信噪比为 34.163 7,均方根误差为 0.011 9。改进阈值的小波降噪^[20]、传统软阈值小波降噪和硬阈值小波降噪^[21]、移动均值滤波^[22]等方法进行对比,结果见表 3。

表 3 基于模态双分解的降噪方法与其他降噪方法的对比

降噪方法	原始数据	模态双分解降噪	小波降噪			移动均值滤波
			改进阈值	硬阈值	软阈值	
信噪比	25.014 9	34.252 4	25.320 3	32.250 2	33.500 8	27.284 5
均方根误差	0.034 1	0.011 8	0.033 0	0.014 8	0.012 9	0.026 3

由表 3 可知,与含噪声的原始仿真信号相比,本文提出的基于模态双分解的降噪方法可以有效提高信号的信噪比,与纯净信号更为接近;相较于改进阈值的小波降噪、硬阈值小波降噪和软阈值小波降噪、移动均值滤波等降噪方法,基于模态双分解的降噪方法降噪所得信号具有最高信噪比和最低的均方根误差,降噪效果提升较为明显。

取某型船舶蒸汽动力系统实际运行过程中主汽轮机排汽温度一段时间长度为 2 000 s 的监控参数,取样频率为 1 Hz,采用本文所提方法进行降噪,效果见图 10。由于为实际数据,无法获得纯净信号,因此以信息熵、功率谱熵作为评价指标^[23-24],结果见表 4。

表 4 基于模态双分解的降噪方法与其他降噪方法的对比

降噪方法	原始数据	模态双分解降噪	小波降噪			移动均值滤波
			改进阈值	硬阈值	软阈值	
信息熵	0.970 1	0.960 7	0.969 7	0.964 3	0.964 3	0.970 0
	1.408 9	1.328 4	1.401 5	1.337 7	1.337 7	1.399 3

由表 4 可知,针对实际运行数据,本文提出的基于模态双分解的降噪方法具有最低的信息熵和功率谱熵,证明了该方法在实际应用中也具有一定的优越性,具有实际工程应用价值。




图 9 降噪后的信号、纯净信号和含噪声信号的对比

Fig. 9 Comparison of denoised signal with clean signal and noisy signal




图 10 降噪后的信号与原始信号对比

Fig. 10 Comparison of denoised signal with original signal

3 结 论

1) 提出了基于 MREMD 分解和排列熵的热工监测参数噪声提取方法,针对 MREMD 分解产生的各

IMF 分量,采用混沌时间序列分析的 C-C 算法计算相空间重构的最佳延迟时间和嵌入维度,以此参数计算各 IMF 的排列熵值,然后对排列熵值进行 k -means 聚类,筛选出大于阈值的 IMF 分量重构为原始运行数据的噪声分量。

2) 为提取噪声分量中包含的有效信息,提出了基于 NGO-VMD 的噪声分量信息提取方法。对重构后的噪声分量进行 VMD 分解,其中分解层数 K 和惩罚系数 α 由 NGO 得到,保留最高评价值的 IMF* 作为噪声分量的信息值与低频 IMF 分量和残余分量重构为降噪后的原始数据。

3) 以某型船舶蒸汽动力系统仿真信号和实际运行信号为例,通过对其进行模态双分解降噪并设置对比试验,从信噪比与均方根误差和信息熵与功率谱熵两种评价角度,验证了本文所提算法的正确性。

参考文献

- [1] CHARBONNIER S, PORTET F. A self-tuning adaptive trend extraction method for process monitoring and diagnosis[J]. Journal of Process Control, 2012, 22 (6): 1127. DOI: 10.1016/j.jprocont.2012.03.010
- [2] HUANG N E, HU Kun, YANG A C C, et al. On holo-Hilbert spectral analysis: a full informational spectral representation for nonlinear and non-stationary data[J]. Philosophical Transactions Series A, Mathematical, Physical, and Engineering Sciences, 2016, 374 (2065): 20150206. DOI:10.1098/rsta.2015.0206
- [3] WANG Jun, DU Guifu, ZHU Zhongkui, et al. Fault diagnosis of rotating machines based on the EMD manifold[J]. Mechanical Systems and Signal Processing, 2020, 135: 106443. DOI:10.1016/j.ymssp.2019.106443
- [4] ZHANG Anbing, LIU Xinxia, SHI Cuimei. The denoising and trend extraction based on the fusion method of wavelet and EMD[C]//2009 International Conference on Computational Intelligence and Software Engineering. Wuhan: IEEE, 2009: 1. DOI:10.1109/CISE.2009.5363240
- [5] 郑尧扬,倪何,金家善. 基于 MSOP 的蒸汽动力系统单参数运行稳定性评估方法[J]. 上海交通大学学报, 2021, 55(11): 1438. ZHENG Yiyang, NI He, JIN Jiashan. An operation stability assessment method of a single-parameter in steam power system based on MSOP[J]. Journal of Shanghai Jiao Tong University, 2021, 55(11): 1438. DOI:10.16183/j.cnki.jsjtu.2020.256
- [6] 肖鹏飞,倪何,金家善. 基于 MWSA 的热力系统单参数时序预测方法[J]. 上海交通大学学报, 2023, 57(1): 36. XIAO Pengfei, NI He, JIN Jiashan. Sequential prediction method of single parameter for thermal system based on MWSA[J]. Journal of Shanghai Jiao Tong University, 2023, 57(1): 36. DOI:10.16183/j.cnki.jsjtu.2021.300
- [7] 王卫玉,何葵东,金艳,等. 基于 CEEMDAN 样本熵和 PSO-SVM 的水电机组振动信号特征提取[J]. 武汉大学学报(工学版), 2022, 55(11): 1167. WANG Weiyu, HE Kuidong, JIN Yan, et al. Feature extraction of vibration signal of hydropower unit based on CEEMDAN sample entropy and PSO-SVM[J]. Engineering Journal of Wuhan University, 2022, 55(11): 1167. DOI:10.14188/j.1671-8844.2022-11-011
- [8] 李瑞,范玉刚. 基于 CEEMDAN 多尺度排列熵和 SO-RELM 的高压隔膜泵单向阀故障诊断[J]. 振动与冲击, 2023, 42(5): 127. LI Rui, FAN Yugang. Fault diagnosis of one-way valve of high-pressure diaphragm pump based on CEEMDAN multi-scale permutation entropy and SO-RELM[J]. Journal of Vibration and Shock, 2023, 42(5): 127. DOI:10.13465/j.cnki.jvs.2023.05.016
- [9] GONG Wenbin, LI An, MA Jinxiu et al. An ultralow-frequency vertical isolation system based on composite feedforward and feedback control[J]. IEEE Sensors Journal, 2023, 23 (23): 29109. DOI: 10.1109/JSEN.2023.3321920
- [10] GONG Wenbin, LI An, HUANG Chunfu, et al. Effects and prospects of the vibration isolation methods for an atomic interference gravimeter[J]. Sensors, 2022, 22(2): 583. DOI: 10.3390/s22020583
- [11] 刘鑫屏. 热力发电过程建模与状态参数检测研究[D]. 北京: 华北电力大学, 2010
- LIU Xiping. Research on the modeling and state parameter detection of thermal power generation process[D]. Beijing: North China Electric Power University, 2010
- [12] 孟令虎. 复杂热力系统信号滤波技术研究[D]. 北京: 华北电力大学, 2019. MENG Linghu. Research on the signals filtering technology of complex thermal system[D]. Beijing: North China Electric Power University, 2019
- [13] 王非,徐伟. 基于 Choi-Williams 分布和排列熵的开关柜局部放电类型识别[J]. 电子测量与仪器学报, 2023, 37(10): 32. WANG Fei, XU Wei. Partial discharge type identification of switchgear based on Choi-Williams distribution and permutation entropy[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(10): 32. DOI:10.13382/j.jemi.B2306683
- [14] 赵家浩,廖晓娟,唐锡雷. 基于改进多元多尺度加权排列熵的齿轮箱故障诊断[J]. 组合机床与自动化加工技术, 2022(12): 48. ZHAO Jiahao, LIAO Xiaojuan, TANG Xilei. Gearbox fault diagnosis based on improved multivariate multiscale weighted permutation entropy[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2022 (12): 48. DOI: 10.13462/j.cnki.mmtamt.2022.12.012
- [15] 陆振波,蔡志明,姜可宇. 基于改进的 C-C 方法的相空间重构参数选择[J]. 系统仿真学报, 2007, 19(11): 2527. LU Zhenbo, CAI Zhiming, JIANG Keyu. Determination of embedding parameters for phase space reconstruction based on improved C-C method[J]. Journal of System Simulation, 2007, 19(11): 2527. DOI:10.16182/j.cnki.joss.2007.11.036
- [16] 陈发堂,陈永钦,陈峰,等. 基于 K-means 与 Gale-Shapley 算法的 D2D 干扰管理方案[J]. 应用科学学报, 2023, 41(6): 958. CHEN Fatang, CHEN Yongtai, CHEN Feng, et al. D2D interference management scheme based on K-means and gale-shapley algorithm[J]. Journal of Applied Sciences-Electronics and Information Engineering, 2023, 41 (6): 958. DOI: 10.3969/j.issn.0255-8297.2023.06.004
- [17] DRAGOMIRETSKIY K, ZOISSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531. DOI:10.1109/TSP.2013.2288675
- [18] DEGHANI M, HUBÁLOVSKÝ Š, TROJOVSKÝ P. Northern goshawk optimization: a new swarm-based algorithm for solving optimization problems[J]. IEEE Access, 2021, 9: 162059. DOI:10.1109/ACCESS.2021.3133286
- [19] 韩朋朋,贺长波,陆思良. 基于 VMD 与增强包络谱的轴承早期故障诊断方法[J]. 机电工程, 2022, 39(7): 895. HAN Pengpeng, HE Changbo, LU Siliang. Bearing incipient fault diagnosis based on VMD and enhanced envelope spectrum[J]. Journal of Mechanical & Electrical Engineering, 2022, 39 (7): 895. DOI:10.3969/j.issn.1001-4551.2022.07.004
- [20] 徐晨,赵瑞珍,甘小冰. 小波分析·应用算法[M]. 北京: 科学出版社, 2004. XU Chen, ZHAO Ruizhen, GAN Xiaobing. Wavelet analysis and application algorithm[M]. Beijing: Science Press, 2004
- [21] CHANG Fengxiang, HONG Wenxue, ZHANG Tao, et al. Research on wavelet denoising for pulse signal based on improved wavelet thresholding[C]//2010 First International Conference on Pervasive Computing, Signal Processing and Applications. Harbin: IEEE, 2010: 564. DOI:10.1109/PCSPA.2010.142
- [22] 叶结和,刘勇,徐国成,等. 基于非接触测量的搭接激光焊缝表面质量评估[J]. 中国激光, 2019, 46(10): 1002008. YE Jiehe, LIU Yong, XU Guocheng, et al. Evaluation of surface quality of lap laser weld joints based on noncontact measurement[J]. Chinese Journal of Lasers, 2019, 46(10): 1002008. DOI: 10.3788/CJL201946.1002008
- [23] 俎海东,李晓波,张万福,等. 基于自适应变分模态分解的滚动轴承故障特征提取方法研究[J]. 热能动力工程, 2024, 39(2): 194. ZU Haidong, LI Xiaobo, ZHANG Wanfu, et al. Fault feature extraction method for rolling bearings based on adaptive variational mode decomposition[J]. Journal of Engineering for Thermal Energy and Power, 2024, 39 (2): 194. DOI:10.16146/j.cnki.rndlge.2024.02.024
- [24] 熊瑞伟,钟晓阳,李庶林,等. 基于改进的 HHT-SVM 微震信号特征提取及分类识别研究[J]. 中国安全生产科学技术, 2023, 19(10): 13. XIONG Luwei, ZHONG Xiaoyang, LI Shulin, et al. Research on feature extraction and classification and identification of microseismic signals based on improved HHT-SVM[J]. Journal of Safety Science and Technology, 2023, 19 (10): 13. DOI: 10.11731/j.issn.1673-193x.2023.10.002