第 50 卷 第 12 期：5248-5258　　高电压技术　　Vol.50, No.12: 5248-5258
2024 年 12 月 31 日　　High Voltage Engineering　　December 31, 2024
DOI: 10.13336/j.1003-6520.hve.20232043

基于 SMA-VMD 和能量熵的高压断路器故障诊断

范兴明，许洪华，李　涛，张　鑫
（桂林电子科技大学电气工程及其自动化系，桂林 541004）

摘　要：针对高压断路器机械故障特征难以从分合闸振动信号中有效提取的问题，提出了一种基于优化变分模态分解(variational modal decomposition，VMD)参数和提取能量熵(energy entropy，EE)作为故障特征值的方法。首先，利用黏菌优化算法(sticky mushroom optimization algorithm，SMA)以最小包络熵为适应度函数对 VMD 算法的参数组合[K, α]进行全局寻优。其次，根据寻优结果设定 VMD 算法参数对信号进行分解，得到 K 个固有模态分量(intrinsic modal components，IMF)。然后，计算各模态分量的能量熵，借助相关系数筛选与原始信号较相关的模态分量，构建特征向量并随机划分训练集、测试集。最后，将训练集输入支持向量机(support vector machine，SVM)中训练分类模型，利用已训练的模型对测试集样本进行分类。在 1 台 12 kV 高压断路器上进行实验验证，分类结果表明，该文提出的 SMA-VMD-EE 模型状态识别准确率为 95%，相较于 VMD-EE、PSO-VMD-EE、SMA-VMD-SE 模型的准确率均有所提高，验证了所提方法的有效性和可行性。

关键词：高压断路器；变分模态分解；黏菌优化算法；能量熵；故障诊断

Fault Diagnosis of High-voltage Circuit Breakers Based on SMA-VMD and Energy Entropy

FAN Xingming, XU Honghua, LI Tao, ZHANG Xin
(Department of Electrical Engineering & Automation, Guilin University of Electronic and Technology, Guilin 541004, China)

Abstract: To solve the problem that it is difficult to effectively extract the mechanical fault features of high-voltage circuit breakers from the tripping vibration signals, we propose a method based on optimizing the parameters of the variational modal decomposition (VMD) and extracting the energy entropy (EE) as the fault eigenvalues. Firstly, the parameter combination [K, α] of the VMD algorithm is globally optimized using the Sticky Mushroom Optimization Algorithm (SMA) with the minimum envelope entropy as the fitness function. Secondly, the parameters of the VMD algorithm are set to decompose the signal according to the optimization results to obtain K intrinsic mode function (IMF). Then, the energy entropy of each modal component is calculated, the modal components that are more relevant to the original signal are filtered with the help of the correlation coefficient, and the feature vectors are constructed and randomly divided into the training set and test set. Finally, the training set is input into the support vector machine (SVM) to train the classification model, and the trained model is used to classify the samples in the test set. Moreover, experimental validation is carried out on a 12 kV high-voltage circuit breaker. The classification results show that the state recognition accuracy of the proposed SMA-VMD-EE model is 95%, which is improved compared with the accuracy of VMD-EE, PSO-VMD-EE, and SMA-VMD-SE models, and the effectiveness and feasibility of the proposed method are verified.

Key words: high-voltage circuit breaker; variational mode decomposition; slime mould optimization algorithm; energy entropy; fault diagnosis

0　引言

高压断路器作为电路控制和保护的核心设备，其可靠性直接关系到电力系统的安全。据统计表明，机械故障是高压断路器的主要故障，占比达 60%以上[1-3]。断路器在分合闸过程中，操动机构的运动和撞击会引起振动响应，其各机械零部件相互作用所产生的冲击振动信号包含大量与设备状态相关的信息。因此，对断路器分合闸振动信号进行深入分析和特征提取，能够精确反映设备的运行状态，进而实现故障诊断并排除潜在隐患[4]。

基于振动信号识别高压断路器机械状态，通常包括采集信号、提取特征及故障诊断 3 个步骤，其中信号采集方面的工作已较为成熟，特征提取与故障识别是当前国内外学者研究的热点[5-6]。在振动信号特征提取方面，由于高压断路器分合闸动作产生的振动信号有着非平稳、非线性且带冲击性的特点，

基金资助项目：国家自然科学基金(61741126)；广西自然科学基金(2022GXNSFAA035533)。
Project supported by National Natural Science Foundation of China (61741126), Guangxi Natural Science Foundation (2022GXNSFAA035533).

因此对于振动信号的分析处理、特征提取存在着较高要求。传统的时域或频域分析很难准确提取信号的故障特征，而时频分析方法具有时间和频率局部化、多尺度分析等优点，常用于机械振动信号的分解及特征提取。例如，文献[7]利用多元经验模态分解(empirical mode decomposition，EMD)算法对有载分接开关(on-load tap changer，OLTC)振动信号进行分解，结合功率矩阵相似度准确检测出 OLTC 的机械状态。但 EMD 在进行信号分解时，仍然会有模态混淆和边界效应等缺陷并未得到很好的解决。针对 EMD 算法存在的问题，2014 年，Konstantin Dragomiretskiy 提出了变分模态分解算法(variational mode decomposition，VMD)，其通过一种非递归分解信号的新方法，将信号分解成多个中心频率不同的固有模态函数(intrinsic mode function，IMF)，该方法能有效地解决 EMD 存在的模态混淆以及端点效应等缺陷[8]。文献[9]提出了变分模态分解与边际谱能量熵的组合进行对断路器故障分类，结果表明能准确诊断出断路器常见的机械故障。

然而，在 VMD 分解信号前，需要人工设置合适的模态个数 K 和惩罚参数 α，K 值决定 IMF 分量的个数，α 值决定 IMF 分量的带宽[10]。因此在使用 VMD 分解信号时，需确定其最佳的参数组合[K, α]。文献[11]提出双阈值筛选法将信号分解为多个不同中心频率的窄带频段，并通过各频段的中心频率幅值来确定 VMD 参数 K 值。然而，如果设置 VMD 一个参数不变，只优化另一个参数，这会忽略两个参数之间的相互作用，导致最终结果陷入局部最优，因此需要考虑两个参数之间的影响。文献[12]提出自适应小生境递阶遗传算法(ANHGA)对 VMD 参数进行寻优，避免了人工经验设置参数的不足。

针对目前 VMD 分解信号需要人工设置关键参数，导致故障特征提取不充分，以及高压断路器故障特征表征不够精确的问题，本文提出一种以智能算法全局寻优变分模态分解(VMD)算法的关键参数，以实现信号的自适应分解，并引入模态分量能量熵作为故障诊断特征值，提高故障诊断准确率。首先，通过黏菌算法(slime mould algorithm，SMA)以最小包络熵为适应度函数，对 VMD 算法在不同状态下的参数组合[K, α]进行寻优，并使用该参数组合对信号进行 VMD 分解，计算其能量熵构建特征向量，最后采用支持向量机(support vector machine，SVM)实现高压断路器故障诊断分类。

1　基于优化 VMD 算法参数及故障诊断流程框架

本文采用黏菌算法(SMA)对 VMD 算法进行参数寻优，并引入能量熵作为特征值对高压断路器进行故障诊断，具体流程如图 1 所示。

基于参数优化 VMD 和能量熵的高压断路器故障诊断方法，具体诊断步骤为：

1）使用传感器采集高压断路器在正常状态和铁芯卡涩、弹簧疲劳、基座松动这 3 种故障状态下的合闸振动信号。

2）截取原始振动信号中含冲击部分的数据，并进行高通滤波、去噪预处理。

3）使用黏菌优化算法(SMA)以最小包络熵为适应度函数对变分模态分解(VMD)的关键参数 K 和 α 进行寻优。

4）代入寻优结果对不同状态的振动信号进行 VMD 分解得到 K 个模态分量，计算各模态分量的能量熵和相关系数，筛选前 5 个相关系数较高的模态分量，构建其能量熵特征向量矩阵。

5）对特征向量矩阵中 4 种状态的样本进行标注类别，并随机划分训练集和测试集，输入训练集到支持向量机中训练分类模型并保存。

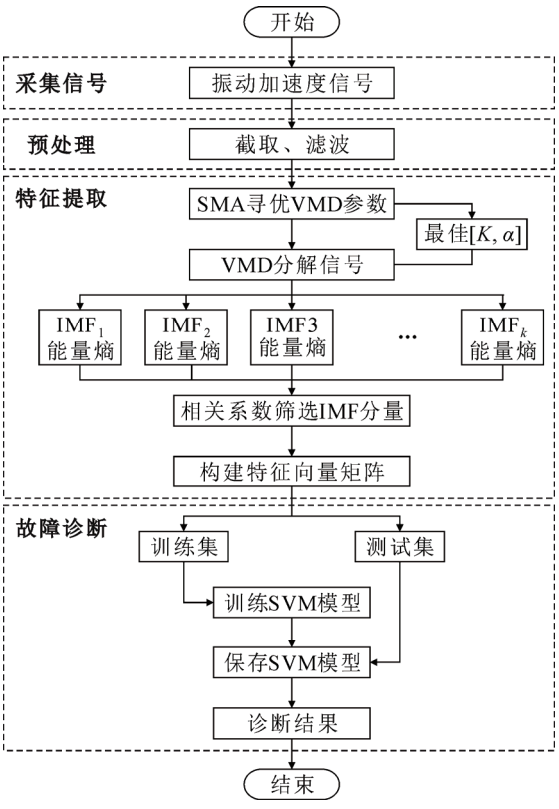


图 1　故障诊断流程图

Fig.1　Fault diagnosis flowchart

6）输入测试集至已训练的分类模型中，识别高压断路器工作状态，输出诊断结果。

2 优化 VMD 算法参数

2.1 变分模态分解

变分模态分解(VMD)算法是由维纳滤波和希尔伯特变换改进而来的，其分解过程包括变分模型的构建和求解[13]。

2.1.1 构建变分模型

假设VMD将原始信号$f(t)$分解成K个不同频带的固有模态函数IMF，则其第k个固有模态函数$u_k(t)$表示如下：

$$u_k(t)=A_k(t)\cos\left(\varphi_k(t)\right) \tag{1}$$

式中：$A_k(t)$和$\varphi_k(t)$分别为瞬时幅值和相位。

由于每个模态分量$u_k(t)$在中心频率ω_k处集中，因此可通过高斯平滑偏移信号来估计频带。其分解时对应的受约束变分模型为：

$$\min_{\{u_k\},\{\omega_k\}}\left(\sum_{k=1}^{K}\left\|\partial_t\left(\left(\delta(t)+\frac{\mathrm{j}}{\pi t}\right)*u_k(t)\right)\mathrm{e}^{-\mathrm{j}\omega_k t}\right\|_2^2\right) \tag{2}$$

其中，$u_k(t)$满足：

$$\sum_{k=1}^{K}u_k(t)=f(t) \tag{3}$$

式中：∂_t为函数对时间t求偏导；$*$为卷积算子；ω_k为$u_k(t)$的中心频率，$\mathrm{j}=\sqrt{-1}$。

2.1.2 求解变分模型

通过引入惩罚因子α和拉格朗日算子，重新构建变分模型。重构的模型如下所示：

$$\begin{aligned}&L\left(\{u_k\},\{\omega_k\},\lambda\right)=\\&\alpha\sum_{k=1}^{K}\left\|\partial_t\left(\left(\delta(t)+\frac{\mathrm{j}}{\pi t}\right)u_k(t)\right)\mathrm{e}^{-\mathrm{j}\omega_k t}\right\|_2^2+\\&\left\|f(t)-\sum_{k=1}^{K}u_k(t)\right\|_2^2+\left\langle\lambda(t),f(t)-\sum_{k=1}^{K}u_k(t)\right\rangle\end{aligned} \tag{4}$$

式中：$L(*)$为Lagrange函数；$\delta(t)$为单位脉冲函数；$\lambda(t)$为关于时间t的Lagrange算子项。

通过频域迭代方法搜寻式(4)的最优解，模态分量和中心频率根据交替方向算子不断迭代更新。其中模态分量更新公式为：

$$\hat{u}_k^{n+1}(\omega)=\frac{\hat{f}(\omega)-\sum_{i=1}^{k-1}\hat{u}_k(\omega)+\frac{\hat{\lambda}^n(\omega)}{2}}{1+2\alpha\left(\omega-\omega_k\right)^2} \tag{5}$$

式中：ω为频率参数；$\hat{u}_k^{n+1}(\omega)$表示$u_k(t)$在傅里叶域的第n次迭代值；$\hat{f}(\omega)$表示$f(t)$的傅里叶变换，$\hat{\lambda}^n(\omega)$表示ω_k第n次的迭代值。

中心频率更新式为：

$$\omega_k^{n+1}=\frac{\int_0^\infty\omega\left|\hat{u}_k(\omega)\right|^2\mathrm{d}\omega}{\int_0^\infty\left|\hat{u}_k(\omega)\right|^2\mathrm{d}\omega} \tag{6}$$

基于更新得到的模态和相对应的中心频率，对Lagrange算子进行更新：

$$\hat{\lambda}^{n+1}(\omega)=\hat{\lambda}^n(\omega)+\tau(\hat{f}(\omega)-\sum_{k=1}^{K}\hat{u}_k^{n+1}(\omega)) \tag{7}$$

当满足停止条件：

$$\sum_{\mathrm{k}=1}^{K}\frac{\left\|\hat{u}_k^{n+1}(\omega)-\hat{u}_k^n(\omega)\right\|_2^2}{\left\|\hat{u}_k^n(\omega)\right\|_2^2}<\varepsilon \tag{8}$$

则终止迭代，输出结果。式中：τ为Lagrange算子项步长；ε为收敛参数。

综上所述，VMD 算法是通过在频域中对信号进行分解，然后在循环迭代中更新每个模态的中心频率，最终通过傅里叶逆变换将分解得到的频域模态合成到时域中，从而实现信号的分解与重构。

由以上分析、推导可知：VMD 算法分解信号的充分性与K、α密切相关。K值过大会引起 VMD 过分解；过小则会导致欠分解。α过大，会导致频带信息丢失；反之，则会造成信息冗余[14]。因此模态个数K和二次惩罚因子α为 VMD 算法优化的关键参数。

2.2 智能优化算法

2.2.1 黏菌算法

黏菌优化算法(SMA)是一种模拟自然界中黏菌获取食物行为的新型启发式优化算法。由 Li Shimin 等于 2020 年提出，其核心思想为模拟自然界中多头绒泡菌在不同食物浓度下的觅食行为以及位置变化。黏菌个体以一种分散的方式移动，同时寻找食物和建立通道网络，主要包括接近食物、包围食物和获取食物 3 个部分，其目前在高压断路器故障诊断案例中应用较少，其具有自适应性强、全局寻优能力、分布式搜索多个模态的最优解等优点，适用于寻优 VMD 算法的参数[15]。

黏菌算法具体数学模型如下：

1）模拟黏菌个体感知到食物存在并开始朝着食物源移动。其中第i个黏菌位置更新式为：

$$X_i=\begin{cases}X_{\mathrm{b}}(t)+v_{\mathrm{b}}\cdot\left(W\cdot X_{\mathrm{A}}(t)-X_{\mathrm{B}}(t)\right),r<p\\v_{\mathrm{c}}\cdot X(t),r\geq p\end{cases} \tag{9}$$

式中：$X_{\mathrm{A}}(t)$和$X_{\mathrm{B}}(t)$代表随机的 2 个个体；W为权重

系数；$X(t)$代表当前位置；$X_b(t)$代表最佳位置；v_b 和 v_c 为[–a, a]和[–1,1]之间的数值；r 为[0,1]的随机值；p 为控制参数。

其中参数 p、a 和权重系数 W 的更新式为：

$$p = \tanh|S(i) - D_F| \tag{10}$$

$$a = \arctan h\left(-\frac{t}{T}+1\right) \tag{11}$$

$$W(I_{\text{ndex}}(i)) = \begin{cases} 1 + r_1 \lg\left(\dfrac{b_F - S(i)}{b_F - w_F}+1\right), 1 \le i < \dfrac{N}{2} \\ 1 - r_1 \lg\left(\dfrac{b_F - S(i)}{b_F - w_F}+1\right), \dfrac{N}{2} \le i \le N \end{cases} \tag{12}$$

$$I_{\text{ndex}} = \text{sort}(S) \tag{13}$$

式中：$S(i)$ 为第 i 个黏菌个体的适应度，i=1，2，…，N；D_F 为当前最佳适应度；b_F 和 w_F 分别表示在当前迭代中的最优适应度和最差适应度；t 为当前迭代次数；T 为最大迭代次数；I_{ndex} 为适应度序列；r_1 为[0,1]之间的随机数；N 为黏菌种群个数。

2）一旦黏菌个体接近食物，它们会开始形成一个环绕食物的群体，对目标进行包围。黏菌更新位置的公式如下：

$$X(t+1) = \begin{cases} r_{\text{and}} \cdot (U_B - L_B) + L_B, & r_{\text{and}} < z \\ X_b(t) + v_b \cdot \left(W \cdot X_m(t) - X_n(t)\right), & r_{\text{and}} < p \\ v_c \cdot X(t), & r_{\text{and}} \ge p \end{cases} \tag{14}$$

式中：U_B 与 L_B 表示寻优范围；r_{and} 表示介于[0,1]之间的任意值；$X_m(t)$和 $X_n(t)$表示随机选择 2 个黏菌个体的位置；z 为自定义的参数。

3）当黏菌抓取食物时，黏菌个体会依靠生物振荡器产生的传播波来改变静脉中的细胞质流动，通过 v_b、v_c 和 W 模拟黏菌静脉宽度与生物振荡器振荡频率的变化，不断调整位置并选择最佳路径与方向来获取食物，W 为正负反馈的自适应权重因子，模拟黏菌在不同食物浓度下振荡频率不断接近 1 的变化，v_b 在[–a, a]之间随机振荡，并随着迭代次数增加逐渐接近于零，v_c 在[–1, 1]之间振荡，最终趋于零，此时其数学模型达到最优。

2.2.2　适应度函数

使用优化算法对 VMD 算法参数进行寻优时，需根据适应度函数大小来评判最优解。包络熵作为一种可对信号稀疏性进行评判的指标，故障信息越多，包络熵越小[16]。因此计算每个序列的包络熵值，寻优其值最小序列则为分解的目标项，对应参数即为最佳参数。

各模态分量 $u(i)(i=1,2,3,\cdots,k)$ 经过希尔伯特变换后的包络熵计算如下式：

$$e_i = \frac{h(i)}{\sum_{i=1}^{K} h(i)} \tag{15}$$

$$E_e = -\sum_{i=1}^{K} e_i \lg e_i \tag{16}$$

式中：$h(i)$为 $u(i)$经 Hilbert 变换后的包络信号。

3　实验验证

3.1　振动传感器

高压断路器分合闸动作时间极短，传统采集冲击振动信号的传感器主要有压电加速度传感器、加速度计、应变计等，其都存在有可能对被测物体造成干扰、需要附着在测试结构上而导致测量位置有限、冲击测试易损坏等缺点。

激光测量基于多普勒原理，以红外激光为测量介质，获得被测物体的振动位移、速度、加速度等信息，其具有非接触式、不会对被测物体造成任何干扰、精度高等优点，更适用于采集高压断路器分合闸冲击性的振动信号。本文采用 KathMatic 公司的 KVD-4525L 型激光测振仪对高压断路器分合闸振动情况进行测量，设备具体参数如表 1 所示。

3.2　实验过程

为验证所提出方法的可行性，以 1 台 TY-3S-12/630-16 型三相独立永磁高压断路器为实验对象，搭建实验平台如图 2 所示。

信号采集系统主要由激光测振仪、无线路由器、上位机组成。实验中，经过对比线圈外壁、横梁、基座和外壳的振动信号幅值，最终选择振动信号较强的铁芯线圈外壁作为测点。当高压断路器分合闸动作时，激光测振仪同时采集测点上的位移变化，并将数据通过无线路由器传送至上位机。

表 1　激光测振仪参数

Table 1　Laser vibrometer parameters

参数	数值
测量距离/m	0.2~40
采集速度量程/(mm·s^{-1})	0~4 500
采样频率范围/MHz	0~2.5
激光波长/nm	1 310
位移分辨率/nm	0.02
尺寸/(mm×mm×mm)	90.5×50×24

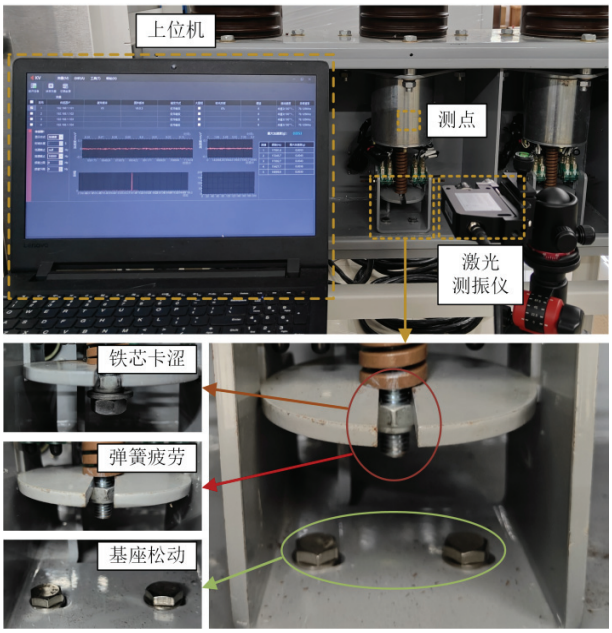


图 2 实验平台示意图

Fig.2 Schematic diagram of experimental platform

使用上述系统采集高压断路器在正常状态、铁芯卡涩、弹簧疲劳以及基座松动 4 种工况下的合闸振动信号。具体工况模拟方式及采集样本个数，如表 2 所示。

3.3 实验分析

以单相合闸振动信号为例，设置激光测振仪采样频率为 78.125 kHz，时域长度为 1 s。考虑到采样率较高，1 000 ms 时间段的数据较大，因此只截取振动信号含冲击部分的 128 ms(10 000 个数据点)进行分析。

采集高压断路器 4 种状态合闸振动信号，并进行预处理得到的时域图如图 3 所示，操动机构中零部件的运动会产生振动，而振动以波的形式从振源向外传播，包括多阶段冲击衰减过程。在时域内，高压断路器合闸振动信号 4 种状态的波峰较分散且幅值各不相同，但仅从时域波峰幅值难以准确地区分故障类型，因此采用变分模态分解及能量熵提取信号中的故障特征。

采用黏菌优化算法对 4 种状态信号下 VMD 分解的参数进行寻优。选用相同的数据，经过多次试验对比不同的迭代次数和种群规模对算法性能的影响，最终确定将迭代次数和种群规模均设置为 20。为对 VMD 算法的参数进行充分寻优，设置 K 和 α 值寻优范围分别为[1, 20]和[1, 8 000]，并以最小包络熵作为适应度函数。

表 2 工作状态设置

Table 2 Operational state settings

标签	工作状态	模拟方式	样本数
1	正常合闸		15
2	铁芯卡涩	挂重物(1 个垫片和 1 个螺母)	15
3	弹簧疲劳	调节螺母减少弹簧预压缩	15
4	基座松动	松动基座螺丝	15

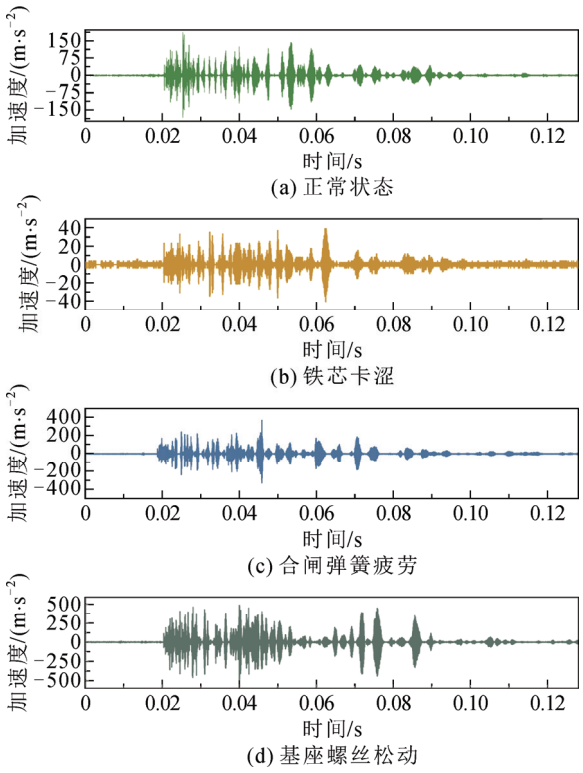


图 3 4 种工作状态时域图

Fig.3 Time-domain graphs for four operational states

如图 4 所示，正常状态、铁芯卡涩、弹簧疲劳和基座松动 4 种工作状态的适应度曲线分别在第 10、10、11、8 次迭代后保持稳定，其对应的最终寻优结果，如表 3 所示。

采用优化参数后的 VMD 算法，对 4 种状态的振动信号进行分解。以正常状态合闸振动信号为例，对该信号进行 VMD 分解后，得到 6 个模态分量。图 5 为分解得到的各模态分量时域、频谱图，并绘制其 3 维图对比图，如图 6 所示。

由图 5、图 6 可知，在时域中，变分模态分解能分解出原始信号中不同频率对应的时域波形，且原始信号可表示为各时域模态分量的叠加。

计算可得，各模态分量中心频率分别为 38 218、34 453、31 500、27 132、23 015、16 585 Hz。可见

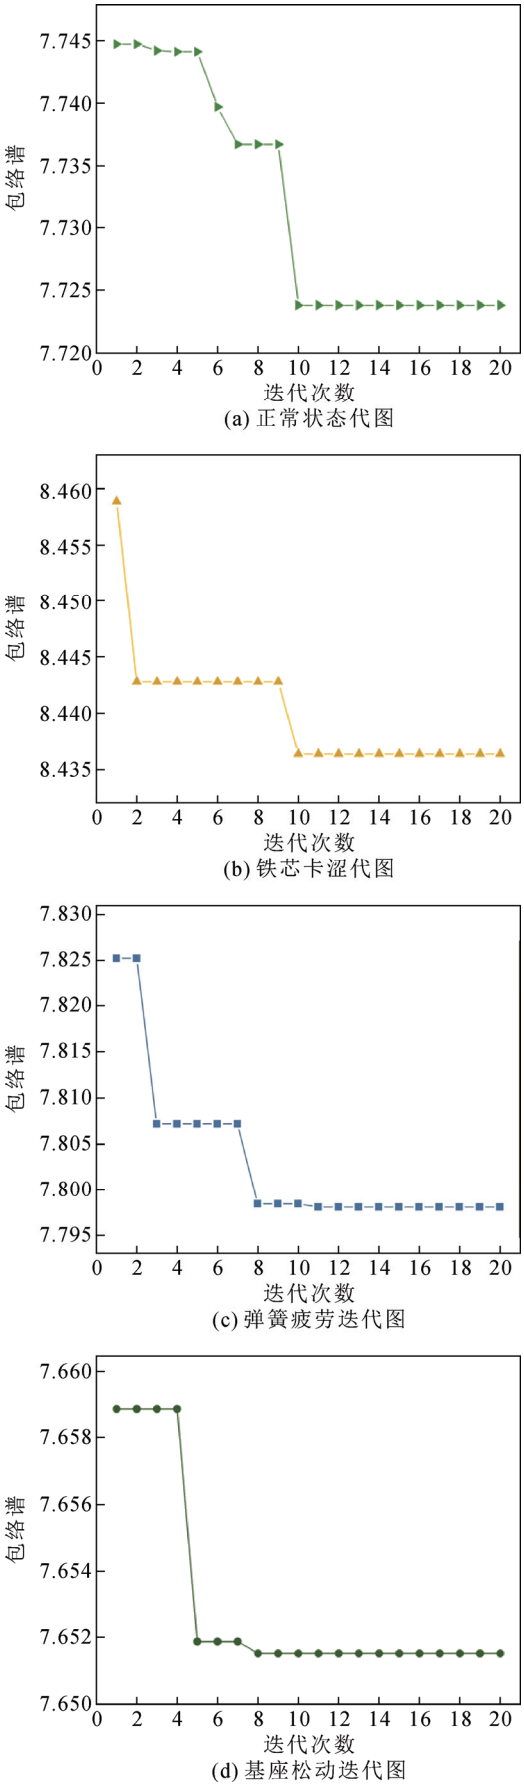


图 4　4 种状态寻优迭代图

Fig.4　Optimization iteration graph for four states

表 3　SMA 寻优 VMD 结果

Table 3　SMA optimized VMD results

参数	正常状态	铁芯卡涩	弹簧疲劳	基座松动
最佳适应度	7.723	8.436	7.798	7.651
最佳参数 K	6	6	8	5
最佳参数 α	1 069	1 330	955	763

各模态中心频率按照高频到低频依次递减，每个模态分量都具有一个紧密支撑的中心频率，并且主成分都分布在这些中心频率附近，表明每个模态分量的频带分配较合理，没有存在重叠的模态或混叠现象。计算证明了所提出的 SMA-VMD 方法，能对不同状态的振动信号进行充分分解，解决了 VMD 分解信号需要人工预先设定参数的问题，可用于高压断路器分合闸振动信号的自适应分解。

3.4　构建特征向量矩阵

3.4.1　筛选模态分量

由于不同状态振动信号经过优化算法寻优 VMD 参数后得到的 K 值不同，为保证在故障分类过程中特征向量维数的一致性，需要筛选出前 5 个与原始信号相关度较高的模态分量。因此本文采用相关系数判断各模态分量与原始信号的相关性，相关系数值越大，则表示相关性越高，包含原信号的信息越多[17]。

相关系数 C 的定义如下：

$$C=\frac{E(u_k(t)\cdot f(t))-E(u_k(t))\cdot E(f(t))}{\sqrt{D(u_k(t))}\cdot\sqrt{D(f(t))}} \tag{17}$$

式中：E 和 D 表示数学期望和方差。

3.4.2　提取信号特征值

对于高压断路器机械故障诊断的特征值，常用的有时域特征、频域特征和信息熵等。由于 VMD 分解得到的各模态分量通常包含不同频段的信息，当高压断路器处于不同状态时，其合闸振动信号分解得到各模态分量的中心频率及幅值会有一定变化，进而导致各模态分量间能量具有较大差异[18]。因此本文引入单一特征能量熵(energy entropy，EE)作为故障诊断的特征值。与包络熵类似，计算各模态能量熵具体计算式如下：

$$E_k=\int_{-\infty}^{+\infty}\left|u_k(t)\right|^2\mathrm{d}t \tag{18}$$

$$p_k=\frac{E_k}{\sum_{k=1}^{K}E_k} \tag{19}$$

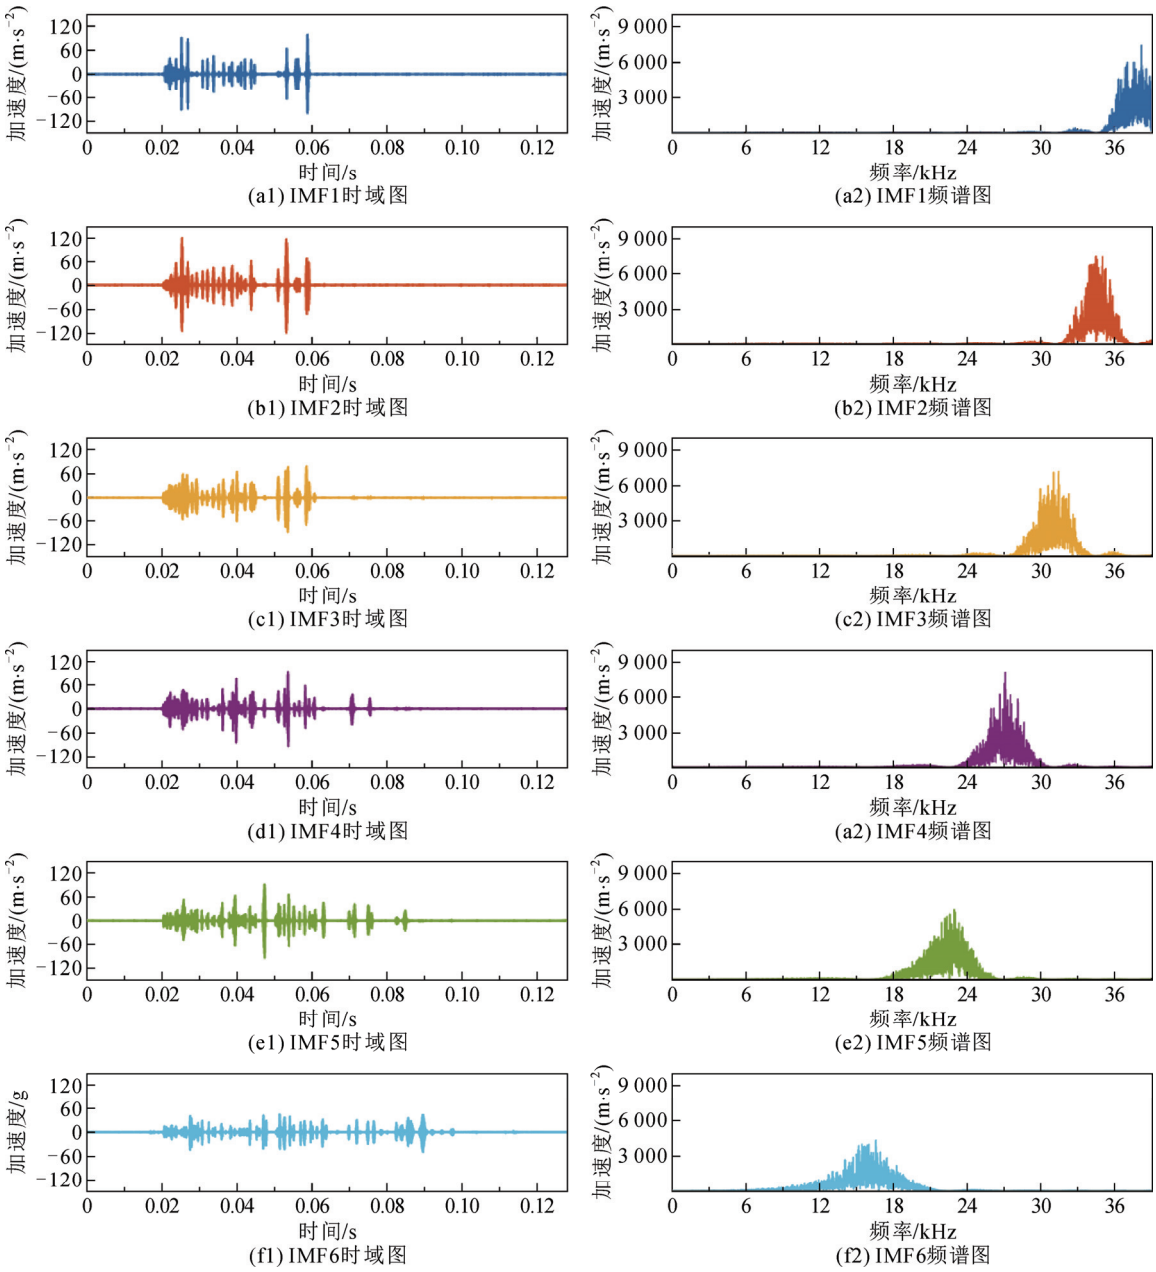


图 5 各模态分量时域图、频谱图

Fig.5 Time-domain and frequency-spectrum graphs for each modal component

式中：E_k 和 p_k 表示第 k 个模态分量的能量和能量占比。根据信息熵基本定义，能量熵计算式为：

$$H_k = -\sum_{k=1}^{K} p_k \lg p_k \tag{20}$$

式中：H_k 表示第 k 个模态分量的能量熵。

对 4 种不同状态的振动信号进行 VMD 分解，并对模态分量进行 Hilbert 变换，计算各模态分量的相关系数与能量熵。统计得到数据如表 4 所示，表中相关系数较高的 5 个模态分量用加粗字体标注。

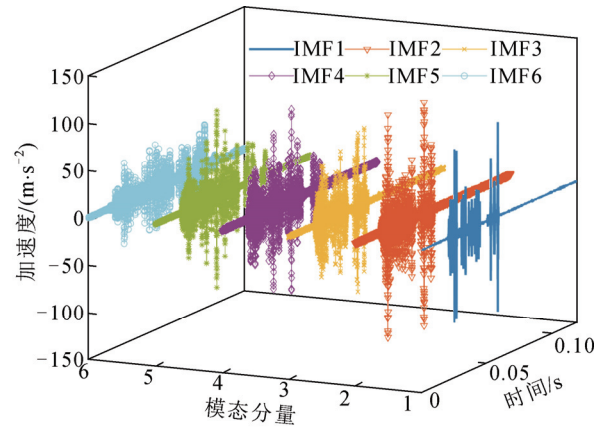
筛选前 5 个与原始信号相关度较高的模态分量，并按相关度从高到低重新排序，绘制其能量熵曲线对比图，如图 7 所示。

由表 4 和图 7 可知，不同工作状态的模态分量能量熵具有良好的区分度，有利于后续模式识别，表明提出基于优化 VMD 参数并提取能量熵作为特征值，能很好地反映出高压断路器的状态变化。

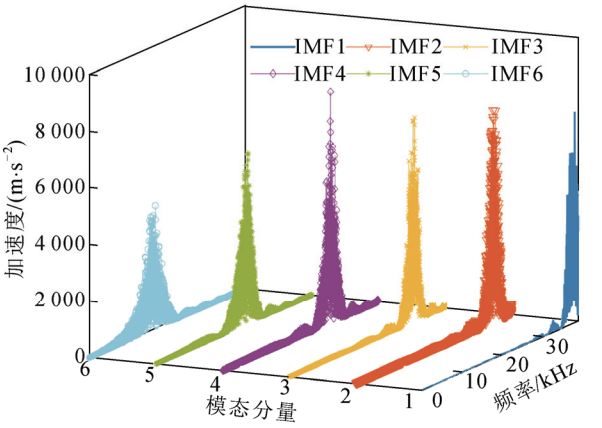
4 故障诊断结果分析

4.1 模式识别

在进行特征提取后，需对特征向量进行模式识别。SVM 作为一种广义线性和监督学习机制的分类器，由 Vapnik 等人于 20 世纪 90 年代后期提出，其



(a) 三维时域图



(b) 三维频谱图

图 6　各模态分量时域、频谱 3 维图

Fig.6　Time-domain and frequency-domain three-dimensional plots of each mode component

表 4　各模态相关系数与能量熵

Table 4　Correlation coefficients and energy entropy for each modal component

固有模态分量	相关系数|能量熵			
	正常状态	铁芯卡涩	弹簧疲劳	基座松动
IMF1	0.447|0.307	0.494|0.327	0.514|0.345	0.538|0.356
IMF2	0.558|0.344	0.502|0.315	0.501|0.300	0.561|0.334
IMF3	0.531|0.325	0.552|0.340	0.464|0.291	0.583|0.340
IMF4	0.453|0.288	0.466|0.305	0.394|0.235	0.426|0.291
IMF5	0.423|0.279	0.367|0.251	0.361|0.217	0.306|0.243
IMF6	0.267|0.188	0.271|0.189	0.334|0.194	
IMF7			0.378|0.257	
IMF8			0.181|0.121	

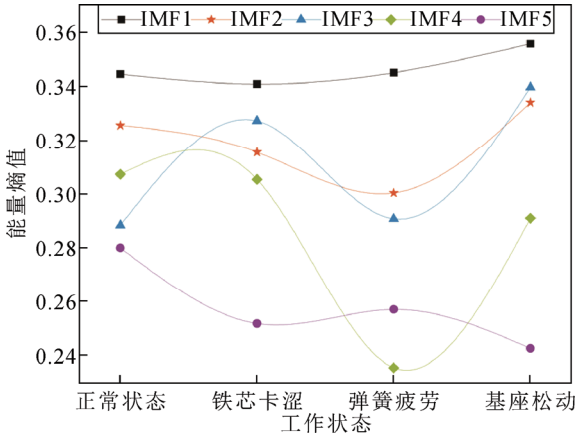


图 7　不同状态能量熵对比图

Fig.7　Energy entropy comparison for different states

主要用于二分类及扩展多分类任务，具体的公式推导及数学模型参考文献[19]。

由于高压断路器频繁分合闸会对设备造成不可逆的机械磨损和触头损耗，因此模拟故障实验采集的样本有限。在机器学习分类算法中，支持向量机相较于神经网络、随机森林、决策树等方法，只需要少量的样本进行训练分类模型，较适用于高压断路器的故障诊断。

4.2　故障诊断

采用上述优化 VMD 参数的方法，对高压断路器 4 种状态各 15 个样本，共计 60 个样本进行分解，筛选模态分量并计算其能量熵，构建成 60×5 的特征向量，在 4 种状态的样本中各随机选取 10 个样本构建训练集，其余 5 个样本组成测试集。

设置高压断路器正常状态、铁芯卡涩、弹簧疲劳、基座松动 4 种状态的类别标签分别为 1、2、3、4。将划分好的训练集输入到支持向量机中训练分类模型，然后把测试集输入到模型中进行分类。

针对多分类问题，核函数采用一对多策略，使用相同数据集，在相同参数下测试不同核函数，如线性核函数、多项式核函数和径向基核函数(radial basis function，RBF)对测试集的分类性能，经多次对比，最终选择径向基函数作为支持向量机的核函数[20]。通过网格搜索的机制，确定支持向量机参数[21]：惩罚系数 c_{best} 为 3.482，核函数半径 g_{best} 为 0.659。为验证 SMA-VMD 和能量熵(EE)模型的有效性，选用相同的样本数据，分别构建传统 VMD 和能量熵模型、粒子群算法(particle swarm optimization，PSO)-变分模态分解-能量熵模型、黏菌算法-变分模态分解-样本熵(sample entropy，SE)模型，并使用训练好的 SVM 模型对测试集样本进行分类。

绘制 4 种模型的测试集分类结果图和混淆矩阵，如图 8 所示。图 8(a)中，下方为测试集样本编

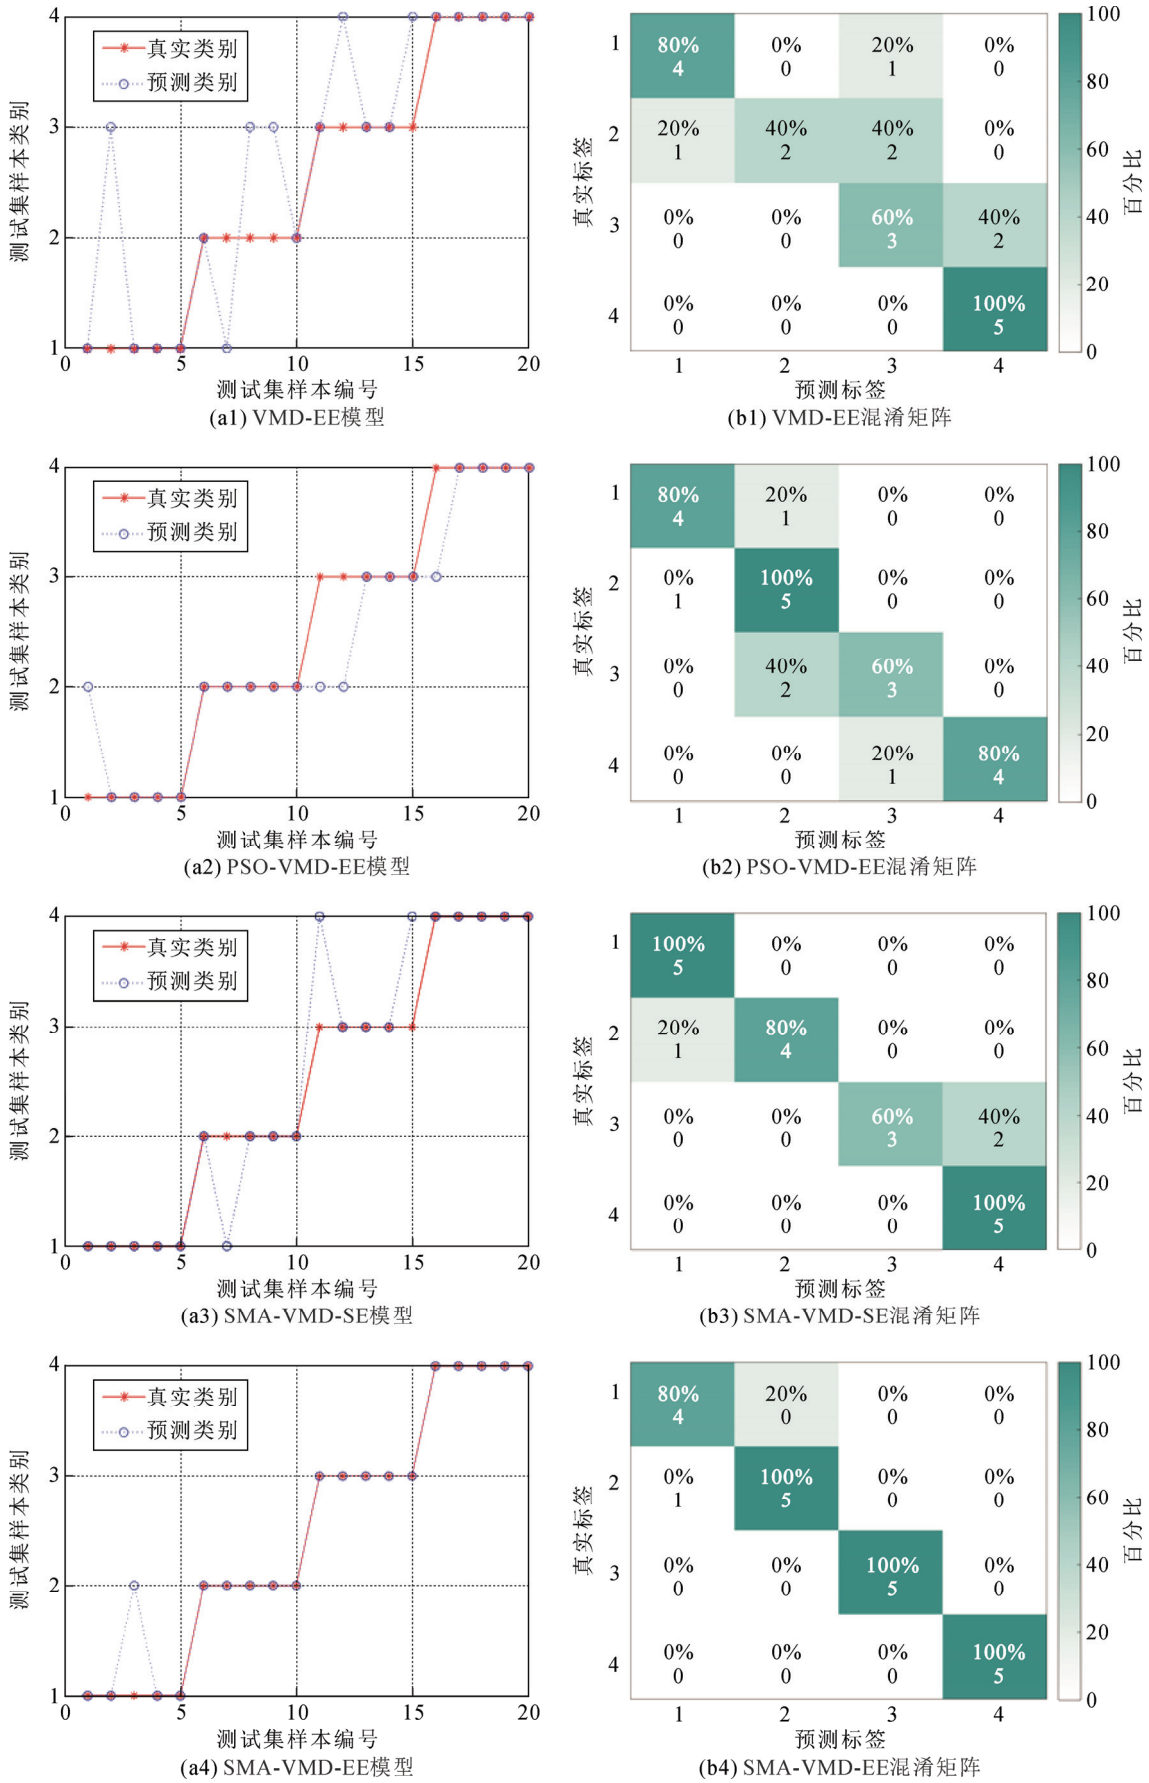


图 8 各模型测试集分类结果图

Fig.8 Classification results graphs for each model on the test dataset

号，左侧为样本标签，标签 1—4 分别表示正常状态、铁芯卡涩、弹簧疲劳和基座松动 4 种状态。在图 8(b)混淆矩阵中，横轴和纵轴分别代表 4 种状态类别，对角线上的数值表示对不同工作状态分类的正确数量，而非对角线数值则表示分类的错误数量。

统计最终诊断结果，如表 5 所示，本文所提出的方法在分类测试集样本时，仅出现 1 个分类错误，相较于未优化 VMD 并提取能量熵、粒子群算法优化 VMD 提取能量熵、SMA 优化 VMD 提取样本熵的方法，其分类识别准确率都有明显提升，证明了 SMA-VMD-EE 模型的优越性。

表 5　测试集样本分类准确率对比

Table 5　Comparison of classification accuracy of test set samples

模型对比	样本数	诊断错误数	准确率/%
VMD-EE	20	6	70
PSO-VMD-EE	20	4	80
SMA-VMD-SE	20	3	85
SMA-VMD-EE	20	1	95

5　结论

1）本文提出一种基于黏菌优化算法(SMA)寻优变分模态分解算法(VMD)关键参数的方法，实现了对高压断路器合闸振动信号的自适应充分分解，且分解得到的各模态分量在频域上具有独立的中心频率，有效解决了在经验模态分解算法(EMD)中较为常见的模态混叠问题，从而提升了信号分解的精度和可靠性。

2）基于参数优化 VMD 算法对信号进行分解，并提取能量熵作为高压断路器故障诊断的特征值。实验结果表明，高压断路器不同工作状态下的模态分量能量熵具有较好的区分度，能够有效反映设备的状态变化。此外，选用单一能量熵作为特征值，有助于减少特征向量矩阵的维度，从而避免了维度灾难。

3）通过实验模拟了高压断路器的 3 种典型机械故障类型，最终分类结果表明，本文提出的 SMA-VMD-EE 故障诊断模型的准确率达到了 95%，表明该方法能够有效识别高压断路器的机械故障，为高压断路器机械故障诊断的研究提供了新的思路，具有一定的工程应用参考价值。

参考文献　References

[1] JANSSEN A, MAKAREINIS D, SÖLVER C E. International surveys on circuit-breaker reliability data for substation and system studies[J]. IEEE Transactions on Power Delivery, 2014, 29(2): 808-814.

[2] 杨秋玉，阮江军，庄志坚，等. 高压断路器机械振动信号的参数自适应降噪方法[J]. 高电压技术，2021，47(12)：4274-4287.
YANG Qiuyu, RUAN Jiangjun, ZHUANG Zhijian, et al. Parameter adaptive noise reduction method for mechanical vibration signals of high-voltage circuit breakers[J]. High Voltage Engineering, 2021, 47(12): 4274-4287.

[3] 邵　阳，武建文，马速良，等. 用于高压断路器机械故障诊断的 AM-ReliefF 特征选择下集成 SVM 方法[J]. 中国电机工程学报，2021，41(8)：2890-2900.
SHAO Yang, WU Jianwen, MA Suliang, et al. Integrated SVM method with AM-ReliefF feature selection for mechanical fault diagnosis of high voltage circuit breakers[J]. Proceedings of the CSEE, 2021, 41(8): 2890-2900.

[4] 刘会兰，许文杰，赵书涛，等. 面向高压断路器故障分类的电流-振动信号类聚几何敏感特征优选方法[J]. 电工技术学报，2023，38(1)：26-36.
LIU Huilan, XU Wenjie, ZHAO Shutao, et al. Optimization method of clustering geometric sensitive features of current vibration signals for fault classification of high voltage circuit breakers[J]. Transactions of China Electrotechnical Society, 2023, 38(1): 26-36.

[5] 万书亭，马晓棣，陈　磊，等. 基于振动信号短时能熵比与 DTW 的高压断路器状态评估及故障诊断[J]. 高电压技术，2020，46(12)：4249-4257.
WAN Shuting, MA Xiaodi, CHEN Lei, et al. State evaluation and fault diagnosis of high-voltage circuit breaker based on short-time energy entropy ratio of vibration signal and DTW[J]. High Voltage Engineering, 2020, 46(12): 4249-4257.

[6] MA S L, YUAN Y, WU J W, et al. Multisensor decision approach for HVCB fault detection based on the vibration information[J]. IEEE Sensors Journal, 2021, 21(2): 985-994.

[7] 段若晨，王丰华，周荔丹，等. 利用窄带噪声辅助多元经验模态分解算法检测换流变压器用有载分接开关机械状态[J]. 电工技术学报，2017，32(10)：182-189.
DUAN Ruochen, WANG Fenghua, ZHOU Lidan, et al. Mechanical condition detection of on-load tap-changer in converter transformer based on narrowband noise assisted multivariate empirical mode decomposition algorithm[J]. Transactions of China Electrotechnical Society, 2017, 32(10): 182-189.

[8] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.

[9] 杨秋玉，阮江军，黄道春，等. 基于 VMD-Hilbert 边际谱能量熵和 SVM 的高压断路器机械故障诊断[J]. 电机与控制学报，2020，24(3)：11-19.
YANG Qiuyu, RUAN Jiangjun, HUANG Daochun, et al. Mechanical fault diagnosis for high voltage circuit breakers based on VMD-Hilbert marginal spectrum energy entropy and SVM[J]. Electric Machines and Control, 2020, 24(3): 11-19.

[10] 李　豪，岳朋朋，向大为，等. 基于 PSO-VMD 瞬时频率的三电平 Buck-Boost 变流器开路故障检测方法[J]. 高电压技术，2022，48(5)：1903-1912.
LI Hao, YUE Pengpeng, XIANG Dawei, et al. Open-circuit fault detection method for three-level Buck-Boost converter based on PSO-VMD instantaneous frequency[J]. High Voltage Engineering, 2022, 48(5): 1903-1912.

[11] 朱永利，贾亚飞，王刘旺，等. 基于改进变分模态分解和 Hilbert 变换的变压器局部放电信号特征提取及分类[J]. 电工技术学报，2017，32(9)：221-235.
ZHU Yongli, JIA Yafei, WANG Liuwang, et al. Feature extraction and classification on partial discharge signals of power transformers based on improved variational mode decomposition and Hilbert transform[J]. Transactions of China Electrotechnical Society, 2017, 32(9): 221-235.

[12] 蔡宇琦，方瑞明，彭长青，等. 基于 ANHGA-VMD 和耦合隐马尔可夫模型的有载分接开关机械故障诊断[J]. 高电压技术，2021，47(11)：3949-3959.
CAI Yuqi, FANG Ruiming, PENG Changqing, et al. Mechanical fault diagnosis of on-load tap-changer based on ANHGA-VMD and coupled hidden Markov model[J]. High Voltage Engineering, 2021, 47(11): 3949-3959.

[13] 杨童亮，胡　东，唐　超，等. 基于 SMA-VMD-GRU 模型的变压器油中溶解气体含量预测[J]. 电工技术学报，2023，38(1)：117-130.
YANG Tongliang, HU Dong, TANG Chao, et al. Prediction of dissolved gas content in transformer oil based on SMA-VMD-GRU model[J]. Transactions of China Electrotechnical Society, 2023, 38(1): 117-130.

[14] 张淑清，李　君，姜安琦，等. 基于 FPA-VMD 和 BiLSTM 神经网络的新型两阶段短期电力负荷预测[J]. 电网技术，2022，46(8)：3269-3279.
ZHANG Shuqing, LI Jun, JIANG Anqi, et al. A novel two-stage model based on FPA-VMD and BiLSTM neural network for short-term power load forecasting[J]. Power System Technology, 2022, 46(8): 3269-3279.

[15] LI S M, CHEN H L, WANG M J, et al. Slime mould algorithm: a new method for stochastic optimization[J]. Future Generation Computer Systems, 2020, 111: 300-323.

[16] 姜　飞，林政阳，王文烨，等. 考虑最小平均包络熵负荷分解的最优 Bagging 集成超短期多元负荷预测[J]. 中国电机工程学报，2024，44(5)：1777-1788.
JIANG Fei, LIN Zhengyang, WANG Wenye, et al. Optimal bagging ensemble ultra short term multi-energy load forecasting considering least average envelope entropy load decomposition[J]. Proceedings of the CSEE, 2024, 44(5): 1777-1788.

[17] 上官鑫，秦文萍，夏福良，等. 基于暂态电压 Pearson 相关性的 MMC 多端柔性直流配电网单极接地故障保护方案[J]. 高电压技术，2020，46(5)：1740-1749.
SHANGGUAN Xin, QIN Wenping, XIA Fuliang, et al. Pole-to-ground fault protection scheme for MMC multi-terminal flexible DC distribution network based on Pearson correlation of transient voltage[J]. High Voltage Engineering, 2020, 46(5): 1740-1749.

[18] 舒　畅，金　潇，李自品，等. 基于 CEEMDAN 的配电变压器放电故障噪声诊断方法[J]. 高电压技术，2018，44(8)：2603-2611.
SHU Chang, JIN Xiao, LI Zipin, et al. Noise diagnosis method of distribution transformer discharge fault based on CEEMDAN[J]. High Voltage Engineering, 2018, 44(8): 2603-2611.

[19] VAPNIK V N. The nature of statistical learning theory[M]. New York, USA: Springer-Verlag, 1995.

[20] 康佳宇，张沈习，张庆平，等. 基于 ANOVA 和 BO-SVM 的变压器故障诊断方法[J]. 高电压技术，2023，49(5)：1882-1891.
KANG Jiayu, ZHANG Shenxi, ZHANG Qingping, et al. Fault diagnosis method of transformer based on ANOVA and BO-SVM[J]. High Voltage Engineering, 2023, 49(5): 1882-1891.

[21] 王智勇，郭凤仪，冯晓丽，等. 基于电流信号特征的弓网电弧识别方法[J]. 电工技术学报，2018，33(1)：82-91.
WANG Zhiyong, GUO Fengyi, FENG Xiaoli, et al. Recognition method of pantograph arc based on current signal characteristics[J]. Transactions of China Electrotechnical Society, 2018, 33(1): 82-91.



范兴明
1978—，男，博士，教授，博导
主要从事智能化电器和高电压新技术方面的研究工作
E-mail: fanxm_627@163.com

FAN Xingming
Ph.D., Professor



张　鑫(通信作者)
1976—，女，硕士，高级实验师
主要从事智能化电器和高电压新技术方面的研究工作
E-mail: zhangxin_wt@163.com

ZHANG Xin
Corresponding author

收稿日期　2023-11-15　修回日期　2024-02-07　　编辑　卫李静