

基于改进变分模态分解的有载分接开关 机械状态监测*

王冠¹, 刘金鑫¹, 赵彤^{1†}, 张黎²

(1. 山东大学 电气工程学院, 山东 济南 250061; 2. 山东省特高压输变电技术与装备重点实验室, 山东 济南 250061)

摘要:为提高变压器有载分接开关(On-Load Tap-Changer, OLTC)机械状态智能诊断水平,提出了基于改进变分模态分解(Improved Variational Mode Decomposition, IVMD)-权重散度的OLTC机械状态特征提取方法,以及和声搜索算法(Harmony Search, HS)优化相关向量机(Relevance Vector Machine, RVM)的故障分类方法.本文进行模拟实验测得了多组不同工况下的OLTC机械振动信号,通过IVMD算法将振动信号分解为一系列有限带宽本征模态函数(Intrinsic Mode Function, IMF),计算IMF分量与原始振动信号的K-L散度(Kullback-Leibler Divergence, K-L),再乘上权重系数得到权重散度,以权重散度来表征多组OLTC机械振动信号的时频域复杂度.同时构建了RVM多分类模型,并通过和声搜索算法对RVM的核函数选择进行了优化,有效地实现了对于权重散度的分类.实验与数据分析结果表明,本文所提综合诊断方法精度较高,可准确提取机械故障特征,能够为OLTC智能故障诊断提供必要的参考.

关键词:有载分接开关;改进变分模态分解;相关向量机;和声搜索算法;机械状态

中图分类号:TM564.8

文献标志码:A

Mechanical Condition Monitoring of On-load Tap Changers Based on Improved Variational Mode Decomposition

WANG Guan¹, LIU Jinxin¹, ZHAO Tong^{1†}, ZHANG Li²

(1. School of Electrical Engineering, Shandong University, Jinan 250061, China;

2. Shandong Provincial Key Laboratory of UHV Transmission Technology and Equipment, Jinan 250061, China)

Abstract: In order to improve the intelligent diagnosis level of an on-load tap-changer (OLTC) mechanical condition, a feature extraction method was proposed based on improved variational mode decomposition (IVMD) and weight divergence. The harmony search (HS) algorithm was used to optimize the parameter selection of the relevance vector machine (RVM). The mechanical vibration signals of OLTC under different conditions were measured by simulation experiments. The OLTC vibration signals were then decomposed into a series of finite-bandwidth intrinsic mode function (IMF) by IVMD. Next, Kullback-Leibler divergence (K-L divergence) of the IMF and original vibration signal was calculated. The K-L divergence was multiplied by the weight coefficient to obtain the weight divergence, which represented the

* 收稿日期:2017-03-12

基金项目:国家自然科学基金资助项目(51207084), National Natural Science Foundation of China (51207084);山东省优秀中青年科学家科研奖励基金计划项目(BS2013NJ024), Promotive Research Fund for Excellent Young and Middle-aged Scientists of Shandong Province(BS2013NJ024)

作者简介:王冠(1978—),女,山东淄博人,山东大学讲师,博士

† 通讯联系人, E-mail: zhaotong@sdu.edu.cn

time-frequency domain complexity of the OLTC mechanical vibration signals. Simultaneously, the multi-classification model of RVM was constructed. The selections of kernel function parameters were optimized by HS, and the classification of weight divergence was realized effectively. The experimental and data analysis results show that the proposed integrated model exhibits high fault diagnosis accuracy. This model can accurately extract the characteristics of mechanical condition, and provide reference for the practical OLTC intelligent fault diagnosis.

Key words: on-load tap-changer; improved variational mode decomposition; relevance vector machine; harmony search algorithm; mechanical condition

电力变压器是重要的输变电设备,其安全稳定运行是电力系统安全稳定运行的前提与基础,然而有载分接开关(On-Load Tap-Changer, OLTC)故障率居高不下,一直是威胁变压器健康的一大原因。据统计资料显示^[1]: OLTC故障是造成变压器故障的主要原因,占变压器总故障的27%以上,且故障类型多为机械故障,如机构卡涩、滑档、拒动等。因此,以OLTC的机械状态诊断为研究对象,寻求更加高效且适用于工程应用领域的特征提取与模式识别算法,提高OLTC机械状态在线监测与故障诊断水平,以保证其安全稳定运行,具有重要的理论和现实意义。

近年来,已有大量专家学者投身于OLTC带电监测与故障诊断的研究中,最为普遍的技术路线是利用振动加速度传感器非介入地监测OLTC操作过程中所产生的振动信号,从振动信号中提取表征OLTC机械状态的有效信息,进而及时发现OLTC的潜伏性故障,达到提前预知及时检修的目的^[2-4]。其中,寻求有效的振动信号特征提取与模式识别方法是提高OLTC机械状态监测水平的关键所在,因此专家学者的研究多围绕特征提取与模式识别方法展开。文献[5-7]利用不同的小波分析方法,以及自组织映射法和遗传算法等,对OLTC振动信号进行了时域分析,然而,对于这种非平稳信号,传统时频分析方法效果不明显。文献[8]基于经验模态分解(EMD)与希尔伯特变换在时频域中对振动信号进行了分析,提高了对于各种不同振动信号的自适应能力。但EMD算法处理的信号存在模态混叠现象,导致分析结果不准确。文献[9]提出了基于集总经验模态分解(EEMD)的OLTC故障诊断方法,该方法解决了EMD算法中存在的模态混叠效应问题,但也导致了计算量大大增加,工程适用性差。

变分模态分解(VMD)是一种新型的自适应、多分辨率分解技术,既保留了EMD的自适应能力,又

避免了模态混叠问题,同时比EEMD算法更具有工程适用性^[10]。相关向量机(RVM)在具备支持向量机(SVM)的优势之外,突破SVM本身的局限性,具有更好的泛化性能,故障分类速度快,同时避免了复杂的参数设置问题^[11]。

基于上述分析,本文提出了基于改进变分模态分解(IVMD)-权重散度与和声搜索优化相关向量机(HS-RVM)的OLTC机械状态诊断方法。利用IVMD算法将原始振动信号分解为一组有限带宽的本征模态函数(IMF),计算IMF分量与原始振动信号的K-L散度,再乘上权重系数,以权重散度来表征振动信号复杂度。同时根据本文进行的实验,构建了RVM多分类模型,并通过和声搜索算法对RVM的核函数选择进行了优化,大大提高了RVM的分类准确度。实验结果表明,本文所提出的综合诊断方法精确度高,能有效提取机械故障特征,为OLTC智能故障诊断提供必要的参考。

1 IVMD-权重散度原理

1.1 变模态分解原理

对信号进行VMD处理的过程是对变分问题求解的过程,首先构造带约束条件的变分模型,然后搜寻模型的最优解来实现信号的自适应分离^[12]。

假设给定输入信号 y ,将 y 分解为 K 个本征模态函数 $u_k(t)$, $k=1,2,\dots,K$:

$$u_k(t) = A_k(t) \cos(\phi_k(t)) \quad (1)$$

式中: $A_k(t)$ 为 $u_k(t)$ 的瞬时幅值; $d\phi_k(t)/dt = \omega_k(t)$, $\omega_k(t)$ 为 $u_k(t)$ 的瞬时频率。

假设任意 $u_k(t)$ 都具有确定的中心频率 ω_k 和有限的带宽,则变分问题即为在约束条件下寻求 K 个本征模态函数 $u_k(t)$,约束条件有两个:①各模态之和等于输入信号;②本征模态函数的估计带宽之和

最小,带约束条件的变分问题如下:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\} \\ \text{s.t.} \sum_{k=1}^K u_k(t) = y(t) \end{cases} \quad (2)$$

为求取上述变分问题的最优解,引入二次惩罚因子 α 与拉格朗日乘法算子 $\lambda(t)$,把上述问题转化为无约束条件的变分问题,如式(3)所示.

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \\ & \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 + \\ & \left\| y(t) - \sum_k u_k(t) \right\|_2^2 + \\ & \langle \lambda(t), y(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (3)$$

通过乘法算子交替方向法来求解上述变分问题,更新 u_k^{n+1} , ω_k^{n+1} 和 λ^{n+1} ,寻找(3)式的鞍点,其中 u_k^{n+1} 的表达式为:

$$\begin{aligned} u_k^{n+1} = & \\ & \operatorname{argmin}_{u_k \in X} \left\{ \alpha \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \right. \\ & \left. \left\| y(t) - \sum_i u_i(t) + \frac{\lambda(t)}{2} \right\|_2^2 \right\} \end{aligned} \quad (4)$$

式中: ω_k 等同于 ω_k^{n+1} , $\sum_i u_i(t)$ 等同于 $\sum_{i \neq k} u_i(t)^{n+1}$.

利用 Parseval/Plancherel 傅里叶等距变换将(4)式转换到频域,将中心频率的取值问题扩展到频域,获得中心频率的更新方法,同时完成 λ 的更新,更新表达式如下:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{y}(\omega) - \sum_{i \neq K} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (5)$$

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

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau(\hat{y}(\omega) - \sum_K \hat{u}_k^{n+1}(\omega)) \quad (7)$$

整理上述思路,将该变分问题的求解过程简化如下^[13]:

- 1) 将 $\{\omega_k^1\}$, $\{u_k^1\}$, $\{\lambda^1\}$ 和 n 进行初始化.
- 2) 对每一模态,根据式(5)(6)得到 $u_k^{n+1}(\omega)$ 和 ω_k^{n+1} .

3) 根据(7)式更新拉格朗日乘子.

4) 对于给定判别精度 $e > 0$,判断下式,若满足停止迭代,否则返回步骤 2).

$$\sum_{k=1}^K \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < e \quad (8)$$

1.2 改进变模态分解

通过 VMD 算法对 OLTC 机械振动信号处理前,需给出分解模态数 K ,其选取的合理与否会直接影响分解结果.若分解模态数 K 小于被处理信号中有用成分的个数,会造成 OLTC 振动信号分解不充分;若分解模态数 K 大于被处理信号中有用成分的个数,则会出现过分解现象,产生一些无用的虚假分量,干扰原信号中有用成分的分析.因此, K 值的确定在 VMD 算法中占有至关重要的地位^[14].为解决上述问题,本文对 VMD 算法进行了改进,提出了分解品质因数,更加科学地选取 K 值.

由 1.1 知,VMD 分解得到 K 个子模态.计算 K 个 IMF 的信息熵,设为 $[S_1, S_2, \dots, S_K]$.信息熵代表了一组数据所携带信息量的多少,因此所得结果能够区分 IMF 分量之间的信息差异.

定义 IMF 分量之间的信息差异系数 C 如(9)式:

$$C = (S_1 - S)^2 + (S_2 - S)^2 + \dots + (S_K - S)^2 \quad (9)$$

式中: S 为 K 个 IMF 信息熵的平均值. C 值越大,表明分解得到的 IMF 分量差异越明显.

原始信号与重构信号之间误差 Δ 定义为下式:

$$\Delta = \operatorname{sum}[\operatorname{abs}(y - \operatorname{IMF}_1 - \operatorname{IMF}_2 - \dots - \operatorname{IMF}_K)] \quad (10)$$

式中:sum 为求和;abs 为取绝对值; y 为原始输入信号. Δ 越小,表明重构信号越接近原始信号.

则 VMD 分解品质因数定义为:

$$Q = C/\Delta \quad (11)$$

品质因数越高,VMD 处理结果越优,即在差异系数 C 和误差 Δ 之间寻找一个平衡点,希望分解得到的 IMF 分量区别度较高的同时重构信号能够接近原始信号.根据 Q 值即可确定分解层数 K .

1.3 权重散度原理

IVMD 能够将振动信号自适应地分解为多个频段的 IMF 分量,为进一步提取 OLTC 振动信号中包含的故障信息,在 IVMD 的基础之上,提出了权重散度的概念,权重散度由权重系数与 K-L 散度两部分构成.

首先介绍 K-L 散度,K-L 散度即相对熵,可以

用来表征两个信号之间的差异.散度值越大表明两个信号之间的差异越大.因此本文引入了K-L散度,通过散度值来衡量IMF分量与原始信号之间的差异.

文献[15]中对K-L散度的原理及求解过程进行了详细的描述,本文将OLTC振动信号的K-L散度求解过程简述如下:

1)给定两个信号,OLTC原始振动信号 $X = \{x_1, x_2, \dots, x_n\}$ 和IMF分量 $Y = \{y_1, y_2, \dots, y_n\}$,这里设两个信号的概率分布函数分别为 $p(x), q(x)$.

2)定义(12)为概率分布函数 $p(x)$ 的核密度估计,同理 $q(x)$ 亦可得.

$$p(x) = \frac{1}{nh} \sum_{i=1}^n k \left[\frac{x_i - x}{h} \right], x \in R \quad (12)$$

式中: $k[*]$ 为高斯核函数; h 为平滑参数.

3)通过式(13)计算两个信号的K-L距离.

$$\delta(p, q) = \sum_{x \in N} p(x) \log \frac{p(x)}{q(x)} \quad (13)$$

4)最终通过式(14)得到K-L散度.

$$D(p, q) = \delta(p, q) + \delta(q, p) \quad (14)$$

上述IMF分量 $Y = \{y_1, y_2, \dots, y_n\}$ 对应着一定的主频率,本文将IMF分量主频的 $1/10^4$ 的倒数定义为权重系数,权重系数乘上K-L散度即可得到权重散度.本文中权重散度是检测OLTC运行状态的重要判据,其揭示的是信号中频率的分布特征.

2 和声搜索优化多分类相关向量机

2.1 二分类相关向量机基本原理

给定训练样本集 $\{x_n, t_n\}_{n=1}^N$,其中 $x_n \in R^d$, $t \in \{0, 1\}$ 为分类编号.RVM给出输出函数^[16]:

$$y(x; \omega) = \sum_{i=1}^N \omega_i K(x, x_i) + \omega_0 \quad (15)$$

式中: $K(x, x_i)$ 为核函数; ω_i 为权重.

则分类编号 t_n 与输入向量 x_n 可表示为式(16):

$$t_n = y(x_n, \omega) + \varepsilon_n \quad (16)$$

式中: ε_n 为噪声,服从均值为0方差为 σ^2 的高斯分布.

则整个样本的似然估计函数可表示为式(17):

$$P(t_n | \omega, \delta^2) = N(y(x_i, \omega_i), \delta^2) \quad (17)$$

在最大化式(17)的过程中,通过最大似然法求 ω 与 σ^2 ,但为了防止过度学习现象的出现,RVM为权值 ω 定义高斯先验概率分布,对参数进行了约束:

$$p(\omega | \alpha) = \prod_{i=0}^N N(\omega_i | 0, \alpha_i^{-1}) \quad (18)$$

式中: α 为 $N+1$ 维超参数.这样就把对 ω 的求解转化为对于 α 的求解,当 α 趋于无穷大的时候, ω 趋于0.

2.2 多分类相关向量机模型

与传统的支持向量机方法相比,相关向量机具有其独特的优势,一方面避免了复杂参数设定问题,另一方面其解具有更强的稀疏性.另外,传统意义上的SVM方法只能够实现对于样本的定性诊断,然而RVM则能够通过式(16)对诊断进行定量描述,其诊断结果更具有工程实际意义.然而RVM在本质上仍属于二分类器,只能够对二分类问题输出归属概率.OLTC的故障分类问题则属于多类型数据分类问题.将RVM应用于OLTC的故障定位,则首先需要对RVM进行多分类扩展,本文选用了传统的“二叉树”模型,来对RVM进行多分类扩展.根据本文实验所需分类的结果,图1为所建立的OLTC机械故障多分类模型,随着后续实验的进行,在此模型的基础上能够进行扩展,实现更多故障类型的分类.图1中分类器RVM1分离正常状态和故障状态,输出0为正常状态,1为故障状态;RVM2分离机构卡涩和松动故障,输出0为机构卡涩,1为松动故障;RVM3分离主弹簧松动和主触头松动,输出0为主弹簧松动,输出1为主触头松动.本文中正常状态、机构卡涩、主弹簧松动和主触头松动分别被定义为0, 1, 2, 3状态.

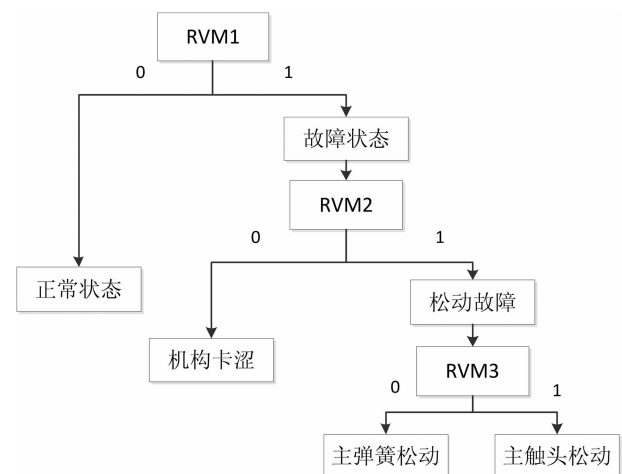


图1 OLTC机械故障多分类模型

Fig.1 OLTC mechanical fault multi-classification model

2.3 和声搜索算法优化相关向量机

和声搜索算法模拟了音乐演奏的原理,由Geem等人于2001年提出,该算法具有较强的全局

搜索能力,而且避免了复杂的参数设定问题,在许多优化问题中都表现出了比遗传算法、模拟退火算法更加优异的性能.本文利用该算法对相关向量机的核函数参数选择问题进行了优化,提升 OLTC 故障分类模型的分​​类准确度.文献[17]中对和声搜索算法的原理进行了详细的描述,本文不再赘述.

利用和声搜索算法,对相关向量机核函数参数选择进行优化,即选择最佳的核函数参数,使得相关向量机故障分类准确率最高.相关向量机选择了高斯核函数.具体实现过程简述如下:

1)定义适应度值函数与和声维数.由第 2.2 小节的多分类模型知,本文的优化目标是 RVM1, RVM2, RVM3 的核函数参数,因此定义三个模型的分​​类准确度的平均值为适应度值函数,和声维数设置为 3.

2)参数初始化.需要进行设置的参数有:和声记忆库 HM 容量,记忆库取值概率 HMCR,音调微调概率 PAR,音调微调带宽 b_w ,最大迭代次数 T_{max} .

3)初始化和声库.产生 HMS 个和声,构成了初始的和声库.调用相关向量机计算原始记忆库(HM)中的各个体适应度值.

4)生成新和声.如果满足 $rand1 < HMCR$,则根据(19)式从记忆库(HM)中随机选取一个个体.

$$x_i^{new} = \begin{cases} x_i^{new} \in (x_i^1, x_i^2, \dots, x_i^{HMS}), & \text{if } rand1 < HMCR; \\ x_i^{new} \in X_i, & \text{otherwise.} \end{cases} \quad (19)$$

根据(20)式对选取的个体进行微调;如果不满足 $rand1 < HMCR$,则在变量的取值范围里重新生成一个新解.

$$x_i^{new} = \begin{cases} x_i^{new} + rand2 * b_w, & \text{if } rand2 < PSR(\text{连续}); \\ x_i(k+m), m \in \{-1, 1\}, & \text{if } rand2 < PAR(\text{离散}); \\ x_i^{new}, & \text{otherwise.} \end{cases} \quad (20)$$

5)更新和声记忆库.计算由步骤 3 所产生的新解的适应度值,并根据下式进行记忆库(HM)的更新.

$$\text{if } f(x') > f(x^{worst}) = \min_{j=1,2,\dots,HMS} f(x^j), \text{ then } x^{worst} = x' \quad (21)$$

6)判断算法是否终止.若满足最大迭代次数则算法终止,获取最优的核函数参数,输出核函数参数下的运行结果.否则,算法转到步骤 3 继续执行.

图 2 所示为和声搜索优化多分类相关向量机模

型的算法流程.

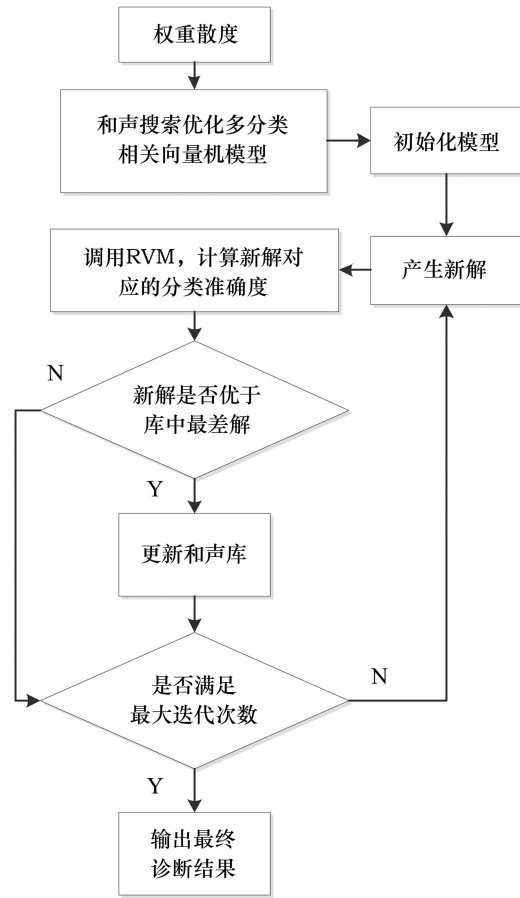


图 2 故障分类算法流程图

Fig.2 Fault classification algorithm flow chart

3 实验与数据分析

在实验室环境下,利用压电加速度传感器 YD70C(灵敏度:2 pC/ms²),DHF-10 型电荷放大器以及泰克示波器对一台复合式 SYJZZ 型 OLTC 进行模拟实验.图 3 所示为实验室内某次 OLTC 振动信号测试.

本文共模拟了机构卡涩、主弹簧松动和主触头松动三种类型的故障.其中主触头松动故障是将主触头的固定螺丝拧松;主弹簧松动是将两根主弹簧中的一根断开连接;机构卡涩是在瞬转拨盘上绑入一根铁丝,影响拨盘与槽轮的咬合.实验过程中的采样频率设置为 50 kHz.

拾取正常运行、主触头松动、主弹簧松动、机构卡涩 4 种工况下 OLTC 操作过程中的机械振动信号波形.本文共选取了 85 组 OLTC 振动信号测试实验数据(均来自同一个采集点,同一个传感器,同一个数据通道),其中正常工况下的数据为 20 组,机构




图3 实验室内的某次振动测试

Fig.3 Vibration test in the laboratory

卡涩工况下的数据为 21 组,主弹簧松动工况下的数据为 24 组,主触头松动工况下的故障为 20 组。

图 4 给出了 4 组典型的不同工况下的振动信号(选择开关 1 档切换到 2 档过程)。




图4 不同工况下的振动信号

Fig.4 Vibration signals under different conditions

由图 4 标记处可知,OLTC 机械振动信号主要由 5 个波峰组成,清晰地刻画了储能弹簧释放瞬间到开关选择完成的过程.不同工况下,OLTC 机械振动信号波峰之间对应的时间间隔以及信号的幅值均发生变化,验证了振动信号特性与 OLTC 的运行

状态之间的关联性。

3.1 IVMD 分解过程

以图 4 中主触头松动振动信号为例展示 IVMD 分解过程,图 5 所示为原始信号时频图。




图5 主触头松动信号时频图

Fig.5 Time-frequency diagram of main contact looseness signal

分别以模态数 $K = 2 \sim 15$ 对图 5(a)所示信号进行 IVMD 处理,带宽约束 α 取默认值 2 000,保真度 τ 选为 0.3.得到如图 6 所示的分解品质因数曲线。




图6 品质因数曲线

Fig.6 The curve of quality factor

从图 6 中能够看出,当 $K = 3$ 时 VMD 分解品质因数最高,此时各 IMF 分量之间区别度较高,同时重构信号与原始信号之间误差较小.因此选取分解模态数 $K = 3$ 。

$K = 3$ 时的分解结果如图 7 所示,左侧为信号时域图,右侧为对应的频谱。

从图 7 中能够看出,图 5(b)中较突出的 3 个波峰被自适应地分离了出来,各模态的频谱分析图中都只有一个明显的主要频率,各模态中心频率之间不存在混叠现象.各 IMF 分量时域图与原始信号相

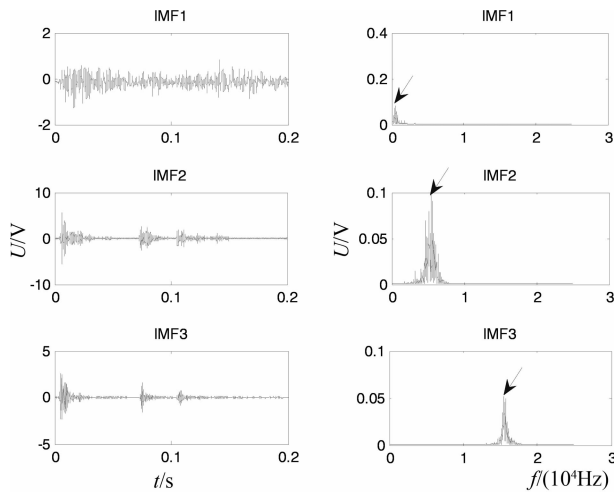


图 7 IVMD 分解结果

Fig.7 The decomposition results of IVMD

比,信号复杂度下降.将 IMF 分量进行重构,并与原始信号进行对比,如图 8 所示,从图中能够看出重构信号与原始信号相比误差较小,因此分解过程符合理想预期.




图 8 重构信号与原始信号对比

Fig.8 Comparison between reconstructed signal and original signal

为了说明 EMD 在有载分接开关振动信号处理中存在的局限性,图 9 给出了 EMD 分解得到的 IMF1 的时频图(EMD 对分解结果排序按照从高频到低频,与 VMD 排序方式相反).

从图 9(b)能够看出,EMD 分解结果存在模态混叠现象,没有唯一确定的中心频率,包含较广的频率范围的信号,得到的 IMF 分量复杂度仍较高,因此不能有效分离出高频信号,适用性较差.

3.2 权重散度分析

在 IVMD 分解的基础之上,本文提出了权重散度法进一步提取 OLTC 振动信号的特征,计算每个 IMF 分量与原始信号的 K-L 散度,能够表征出各频率信号在原始信号中所占有的分量,再乘上各 IMF 分量主频的 $1/10^4$ 的倒数作为权重系数.

计算求得 85 组 OLTC 振动信号的权重散度分




图 9 EMD 分解结果

Fig.9 EMD decomposition results

布,如图 10 所示.

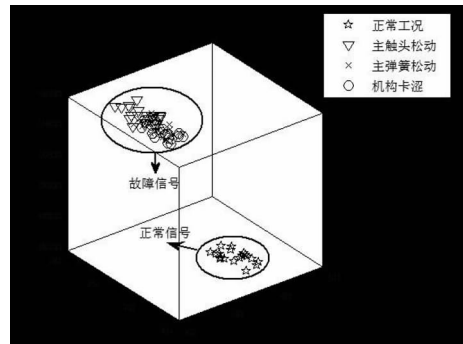


图 10 不同工况权重散度分布

Fig.10 Distribution of weight divergence under different conditions

从图 10 能够看出正常信号与故障信号的权重散度有着明显的不同.分析计算数据,对于正常工况,低频信号是其主要成分,因此正常信号的 IMF1 和 IMF2 权重散度较故障信号都要小,而高频部分恰恰相反.相比正常信号而言,故障信号包含着更多的高频信号,因此其权重散度在中高频部分低于正常信号.且能看出三种不同故障类型的信号权重散度有一定的一致性.综上所述,本文所提 IVMD-权重散度模型能够较好地表征出信号在不同频段中的分布情况,也不难看出,故障信号与正常信号的区分比较容易,而故障与故障之间的信号区分比较困难.

3.3 HS-RVM 分析

将计算得到的 85 组信号对应的权重散度作为分类模型的输入,选取 40 组为训练样本,每种状态各 10 组数据,其他数据作为测试样本.

使用 HS-RVM 模型对训练集和测试集进行诊断,采用如下参数:HM=20, HMCR=0.9, PAR_{min}

$=0.4$, $PAR_{max} = 0.9$, $b_{wmin} = 0.0001$, $b_{wmax} = 1$, $T_{max} = 200$. 分类结果如表 1 所示, 适应度曲线如图 11 所示.




图 11 适应度值曲线

Fig.11 Fitness value curve

表 1 诊断结果

Tab.1 Diagnostic results

数据样本	OLTC 运行状态	故障诊断结果				准确率
		正常	机构 卡涩	主弹簧 松动	主触头 松动	
训练集	正常	10	0	0	0	92.5%
	机构卡涩	0	10	0	0	
	主弹簧松动	0	1	8	1	
	主触头松动	0	1	0	9	
测试集	正常	10	0	0	0	84.4%
	机构卡涩	0	9	0	2	
	主弹簧松动	0	1	11	2	
	主触头松动	0	1	1	8	

从表 1 中的数据能够看出 HS-RVM 对权重散度计算结果有着较强的分类能力, 并且在区别正常工况和故障工况时准确率为 100%, 然而 HS-RVM 在区分故障与故障状态时诊断率较低, 这也是由于三种故障类型的信号权重散度相似度较高造成的.

从图 11 的适应度曲线可以看出, 和声搜索算法有效地实现了对于相关向量机的优化, 随着迭代次数的增加, 适应度值不断增加, 最后保持不变, 同时输出最终的核函数参数筛选结果. 验证了和声搜索算法的优化性能.

为突出 HS-RVM 模型的性能, 本文利用相同的数据样本对模拟退火算法优化相关向量机 (SA-RVM)、未优化相关向量机进行了实验, 其中未优化相关向量机核函数参数设置为 0.5, 得到实验对比结果如表 2 所示.

表 2 不同分类器测试集诊断结果

Tab.2 Test set diagnostic results of different classifiers

分类模型	OLTC 运行状态	故障诊断结果				准确率
		正常	机构 卡涩	主弹簧 松动	主触头 松动	
RVM	正常	10	0	0	0	68.9%
	机构卡涩	0	6	2	3	
	主弹簧松动	0	1	10	3	
	主触头松动	0	2	3	5	
SA-RVM	正常	10	0	0	0	77.8%
	机构卡涩	0	7	2	2	
	主弹簧松动	0	1	12	1	
	主触头松动	0	1	3	6	
HS-RVM	正常	10	0	0	0	84.4%
	机构卡涩	0	9	0	2	
	主弹簧松动	0	1	11	2	
	主触头松动	0	1	1	8	

从表 2 数据对比中能够看出, 通过对核函数参数的优化, HS-RVM 比 RVM 在分类性能上得到了很大的提高, 同时与 SA-RVM 分类模型相比, 本文所提分类方法在分类准确度上更具优势.

4 结 论

针对当前 OLTC 机械状态诊断中存在的问题, 提出了基于 IVMD-权重散度与 HS-RVM 模型的 OLTC 机械状态诊断方法, 得到了如下的结论:

1) 提出了分解品质因数的概念, 实现了 VMD 分解过程的优化, 并应用到 OLTC 机械振动信号分解中, 有效避免了 EMD 算法存在的模态混叠现象, 提升了特征提取准确度.

2) 本文所提权重散度计算方法能够有效地表征振动信号复杂度, 描述了不同振动信号的频率分布情况.

3) 通过二叉树法构建了相关向量机的多分类模型, 并利用和声搜索算法对核函数参数进行了优化, 提升了 OLTC 故障分类的准确度.

4) 实验结果表明, 本文所提机械状态诊断模型准确率较高, 应用性良好. 同时, 该模型不仅适用于有载分接开关的机械状态诊断, 还能够为其他工程领域的研究提供参考.

参考文献

- [1] 王梦云. 2004 年度 110 kV 及以上变压器事故统计分析[J]. 电力设备, 2005, 6(11): 35-41.
WANG Mengyun. Statistics and analysis of 110 kV and the above transformer fault in 2004 [J]. Electrical Equipment, 2005, 6(11): 35-41. (In Chinese)
- [2] LI Qingmin, ZHAO Tong, ZHANG Li, et al. Mechanical

- fault diagnostics of on-load tap changer within power transformers based on hidden Markov model[J]. IEEE Transactions on Power Delivery, 2012, 27(2): 596-601.
- [3] 赵彤, 李庆民, 陈平. OLTC 振动信号特征提取的动力学分析方法[J]. 电工技术学报, 2007, 22(1): 41-46.
ZHAO Tong, LI Qingmin, CHEN Ping. Dynamic analysis method for feature extraction of mechanical vibration signals of on-load tap changers[J]. Transactions of China Electrotechnical Society, 2007, 22(1): 41-46. (In Chinese)
- [4] 周翔, 王丰华, 傅坚, 等. 基于混沌理论和 K-means 聚类的有载分接开关机械状态监测[J]. 中国电机工程学报, 2015, 35(6): 1541-1548.
ZHOU Xiang, WANG Fenghua, FU Jian, *et al.* Mechanical condition monitoring of on-load tap changers based on chaos theory and K-means clustering method [J]. Proceedings of the CSEE, 2015, 35(6): 1541-1548. (In Chinese)
- [5] KANG P J, BIRTHWHISTLE D. Condition assessment of power transformer on-load tap changers using wavelet analysis and self-organizing map: field evaluation [J]. IEEE Transactions on Power Delivery, 2003, 18(1): 78-84.
- [6] SIMAS E F, ALMEIDA L A L, ANTONIO C. Vibration monitoring of on-load tap changers using a genetic algorithm [C]//Proceedings of the IEEE Instrumentation and Measurement Technology Conference, Ottawa, Canada, 2005.
- [7] RIVAS E, BURGOS J C, PRADA J C G. Condition assessment of power OLTC by vibration analysis using wavelet transform[J]. IEEE Transactions on Power Delivery, 2009, 24(2): 687-694.
- [8] 张惠峰, 马宏忠, 陈凯, 等. 基于振动信号 EMD-HT 时频分析的变压器有载分接开关故障诊断[J]. 高压电器, 2012, 48(1): 76-81.
ZHANG Hui Feng, MA Hongzhong, CHEN Kai, *et al.* Fault diagnosis of power transformer on-load tap changer based on EMD-HT analysis of vibration signal[J]. High Voltage Apparatus, 2012, 48(1): 76-81. (In Chinese)
- [9] 洪祥, 马宏忠, 高鹏, 等. 基于 EEMD 的有载分接开关触头松动故障诊断[J]. 华电技术, 2012, 34(1): 12-15.
HONG Xiang, MA Hongzhong, GAO Peng, *et al.* Fault diagnosis of on-load tap changer contact loosening based on EEMD [J]. Huadian Technology, 2012, 34(1): 12-15. (In Chinese)
- [10] 刘长良, 武英杰, 甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断[J]. 中国电机工程学报, 2015, 35(13): 3358-3365.
LIU Changliang, WU Yingjie, ZHEN Chenggang. Fault diagnosis of rolling bearings based on the variational modal decomposition and fuzzy C mean clustering[J]. Proceedings of China Electric Machinery Engineering, 2015, 35(13): 3358-3365. (In Chinese)
- [11] 梁永亮, 李可军. 一种优化特征选择: 快速相关向量机变压器故障诊断方法[J]. 电网技术, 2013, 37(11): 3262-3267.
LIANG Yongliang, LI Kejun. A transformer diagnosis method based on optimized feature selection methods and fast relevance vector machine [J]. Power System Technology, 2013, 37(11): 3262-3267. (In Chinese)
- [12] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE Transactions on Signal Process, 2014, 62(3): 531-544.
- [13] 张宁, 朱永利, 高艳丰, 等. 基于变分模态分解和概率密度估计的变压器绕组变形在线检测方法[J]. 电网技术, 2016, 40(1): 298-302.
ZHANG Ning, ZHU Yongli, GAO Yanfeng, *et al.* An on-line detection method of transformer winding deformation based on variational mode decomposition and probability density estimation[J]. Power System Technology, 2016, 40(1): 298-302. (In Chinese)
- [14] 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): 222-235.
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): 222-235. (In Chinese)
- [15] 韩中合, 朱霄珣, 李文华. 基于 K-L 散度的 EMD 虚假分量识别方法研究[J]. 中国电机工程学报, 2012, 32(11): 112-117.
HAN Zhonghe, ZHU Xiaoxun, LI Wenhua. A false component identification method of EMD based on Kullback-Leibler divergence[J]. Proceedings of the CSEE, 2012, 32(11): 112-117. (In Chinese)
- [16] WIDODO A, KIM B E Y, SON C J, *et al.* Fault diagnosis of low speed bearing based on relevance vector machine and support vector machine [J]. Expert Systems with Applications, 2009, 36(3): 7252-7261.
- [17] ALIA O M, MANDAVAR R. The variants of the harmony search algorithm: an overview [J]. Artificial Intelligence Review, 2011, 36(1): 49-68.