

# IVMD 对泵站管道振动响应趋势的预测分析\*

张建伟<sup>1,2,3</sup>, 华薇薇<sup>1,2,3</sup>, 侯 鸽<sup>1,2,3</sup>

(1. 华北水利水电大学水利学院 郑州, 450046)

(2. 水资源高效利用与保障工程河南省协同创新中心 郑州, 450046)

(3. 河南省水工结构安全工程技术研究中心 郑州, 450046)

**摘要** 采用改进的变分模态分解(improved variational mode decomposition, 简称 IVMD)与支持向量机(support vector machine, 简称 SVM)相联合的方法,对泵站管道的振动响应趋势进行预测。首先,基于互信息准则确定 IVMD 的分解模态数,克服变分模态分解(variatronal mode decomposition, 简称 VMD)盲目选取分解参数的缺点,利用 IVMD 将机组和管道的振动序列分解为多个固有模量(intrinsic mode function, 简称 IMF),分别作为 SVM 模型的输入和输出;其次,利用粒子群优化(particle swarm optimization, 简称 PSO)分别寻找各模态分量对应 SVM 模型的最优参数并对各分量分别进行预测;最后,将各测点对应的 IMFs 预测结果重构作为最终的预测值。结合某大型泵站 2 号压力管道振动响应数据,分别采用 IVMD-SVM, PSO-SVM 和 BP 神经网络 3 种模型对管道振动响应趋势进行预测,并将预测结果进行对比分析。结果表明,IVMD-SVM 模型得到的预测结果和实测值更加接近,计算精度更高,且误差较小,该方法对管道及类似工程结构的振动趋势预测具有一定的参考价值。

**关键词** 振动;改进的变分模态分解;支持向量机;管道;预测

**中图分类号** TV93; TB53; TH113

## 引 言

管道结构普遍应用于水利工程、石油、消防等领域,主要在给水、排水、水力枢纽和各种工业装置中发挥重要作用。管道作为运输载体,在运行过程中受到与其连接设备的振动和内部液体激励等因素耦合作用影响,会出现各种损伤和断裂等问题,导致管道的安全运营受到威胁<sup>[1-2]</sup>。为了保障管道系统的安全运转,促进其发挥最大的综合效益,对管道的振动预测至关重要<sup>[3-5]</sup>。近年来,利用动力测试信号对结构工程的振动趋势预测是水利工程的热门话题,对真实信号的获取是振动趋势预测的前提,并将此信号进行泛化拟合回归,从而增加预测值的准确性。

VMD<sup>[6]</sup>是多分量信号自适应分解的新方法。VMD 方法中 IMFs 的频率及带宽是通过迭代循环求解约束变分问题的最优解得到的。与 EMD 等传统非平稳信号分解方法相比,VMD 的分解过程收敛速度更快,计算精度更高,且分解得到的 IMFs 能更好地反映管道和机组的振动特性。VMD 在信号

处理前需要预设分解模态数  $K$ ,  $K$  值过大或者过小都会对振动序列信号分解的准确性造成很大的影响。互信息法表征两个变量的依赖水平,与中心频率和相关系数等方法相比,该方法具有明确的衡量标准,避免了  $K$  值选取的主观性,因此,利用互信息准则自适应确定  $K$  值。针对小样本、非线性、高维数等问题,支持向量机经实践证明是行之有效的<sup>[7]</sup>。SVM 对模态的识别精度受内部参数影响,采用 PSO 来搜索其内部参数的最优值,解决 SVM 中人工选用参数的主观性。

基于上述分析,笔者利用管道与机组之间的相关特性提出了一种改进的 IVMD 算法,并将 IVMD 与 SVM 联合进行管道振动预测。

## 1 基本原理

### 1.1 变分模态分解

VMD 是一种多分量自适应信号分解的新方法,与传统信号分解方法相比,能够有效避免模态混

\* 国家自然科学基金资助项目(51679091);河南省高校科技创新人才计划资助项目(18HASTIT012);广东省水利科技创新基金资助项目(2017-16);华北水利水电大学研究生教育创新计划基金资助项目(YK2017-03)

收稿日期:2017-03-30;修回日期:2018-06-03

叠和过分解等缺陷且利用价值较高<sup>[8]</sup>。VMD 方法由建立变分约束问题和迭代求取最优解两个过程组成,具体运算过程如下:利用变分约束将给定信号  $f$  分解为  $K$  个模态函数  $m_k(t)$ ,各个 IMF 分量的带宽特定有限,且每个模态函数都分布在中心脉动频率周围。变分约束模型表达式<sup>[9]</sup>如下

$$\begin{cases} \min_{m_k, \omega_k} \left\{ \sum_k \left\| \partial_t \left[ \left( \sigma(t) + \frac{j}{\pi t} \right) m_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_{k=1}^k m_k = f \end{cases} \quad (1)$$

其中:  $\{m_k\}$  为分解得到的  $K$  个 IMF 分量,  $\{m_k\} = \{m_1, m_2, \dots, m_k\}$ ;  $\sigma(t)$  为脉冲函数;  $\{\omega_k\}$  为各 IMF 分量的中心频率,  $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 。

为完成输入信号  $f$  的自适应分解,获取带宽之和最小的 IMF 分量,引入拓展的 Lagrange 表达式

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

其中:  $\alpha$  为惩罚因子,确保信号重构的准确性;  $\lambda(t)$  为拉格朗日乘子,用来强化约束的严谨性;  $\langle \cdot \rangle$  表示内积运算。

为解决上述变分约束问题,引用对偶分解和交替方向乘子算法<sup>[10]</sup>,一直更新  $m_k$ ,  $\omega_k$  与  $\lambda(t)$ ,使其循环迭代求取式(2)的鞍点,即为式(1)的最优解。模态分量函数  $m_k$  和中心频率  $\omega_k$  如式(3)和式(4)所示

$$m_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i \neq k} m_i(\omega) + \frac{\lambda(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \int_0^\infty \omega |m_k(\omega)|^2 d\omega / \int_0^\infty |m_k(\omega)|^2 d\omega \quad (4)$$

$$\lambda^{n+1} = \lambda^n + \tau(f(\omega) - \sum_k m_k^{n+1}(\omega)) \quad (5)$$

### 1.2 改进的变分模态分解

VMD 在对振动趋势序列信号进行分解时,模态总数  $K$  的确定至关重要,  $K$  值的选取极大影响结果的准确性<sup>[11]</sup>。若  $K$  值大于信号分解得到有用成分的个数,则会产生信息叠加的情况;若  $K$  值小于信号分解得到有用成分的个数,会导致部分有限带宽的固态模量不能完全被分解出来。

互信息(mutual information, 简称 MI)反映两个随机变量间的彼此关联性,能更好地辨别两变量的相关水平<sup>[12]</sup>。互信息表示如下

$$I(X, Y) = H(Y) - H(Y | X) \quad (6)$$

其中:  $H(Y)$  为  $Y$  的熵;  $H(Y | X)$  为  $X$  已知时  $Y$  的条件熵。

当  $I(X, Y) = 0$  时,  $X$  与  $Y$  相互独立。

计算 IVMD 分解后的各模态分量与原始信号的互信息  $I_k$ , 并利用式(7)进行归一化处理,进而判断各模态分量与原始信号的相关程度,即原信号是否完全被分解

$$\sigma_i = I_i / \max(I_i) \quad (7)$$

当  $\sigma_i \leq 0.02$  时,认为 IMF 分量中已不含有效的特征信息,原信号全被分解,停止整个运算过程。

采用互信息法自适应确定  $K$  值的具体算法流程如下:

- 1) 初始化  $n = n + 1$ , 令  $K = 1$ ;
- 2)  $K = K + 1$ , 执行外层循环;
- 3) 初始化  $m_k^1, \omega_k^1, \lambda^1$  和  $n$ , 令  $n = 0$ ;
- 4) 令  $n = n + 1$ , 执行内层循环;
- 5) 对一切  $\omega \geq 0$ , 根据式(3)和式(4)分别更新  $m_k$  和  $\omega_k$ ;
- 6) 由式(5)更新  $\lambda$ ;
- 7) 对于给定的判别精度  $e > 0$ , 若满足迭代条件  $\sum_k |m_k^{n+1} - m_k^n|_2^2 / |m_k^n|_2^2 < e$ , 终止进程, 否则循环步骤 2~步骤 6;
- 8) 循环步骤 2~步骤 7, 直至设定阈值  $\sigma$  大于原给定信号  $f$  分解得到的各 IMF 与  $f$  的归一化互信息值  $\sigma_i$ , 即  $I(f - \sum m_k, f) < \sigma$ , 结束循环。

### 1.3 支持向量机

SVM<sup>[7]</sup> 利用已知的少量数据,建立合适的数学模型并且保证拥有良好的学习能力,推广性更强。SVM 巧妙地使用了核函数,避免出现过度学习的现象,也不会因为维数过高出现计算过多的问题。结合以上优点, SVM 可作为管道科学合理的预测模型。

假设样本集  $(x_i, y_i)$  ( $i = 1, 2, \dots, n; x_i \in \mathbf{R}^n$ ) 表示  $n$  维向量,  $y_i \in \{\pm 1\}$  为样本输出向量。在线性可分时,构造最优分类超平面  $(w, x) + b = 0$ , 满足将样本集正确分为两个类别,且满足分类间隔。其中支持向量为离分类超平面最近的两种样本向量,计算可得分类间隔之和为  $2/\omega$ , 此时得到

$$\begin{cases} \min_{w, b} \Phi(w) = \|w\|^2 / 2 = (w, w) / 2 \\ \text{s. t. } y_i((wx_i) + b) \geq 1 \quad (i = 1, 2, \dots, n) \end{cases} \quad (8)$$

其中:  $w$  为权值向量;  $b$  为偏移值。

引入松弛变量  $\xi_i$ , 将约束降至  $y_i((wx_i) + b) \geq 1 - \xi_i$  ( $\xi_i \geq 0$ ), 定义惩罚参数  $C$  来实现  $\xi_i$  的最小化, 则目标函数演变为

$$\Phi(\mathbf{w}, \xi) = \min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \quad (9)$$

为解决约束问题,运用 Lagrange 函数来求取最优解

$$L(\omega, b, \beta_i) = \frac{1}{2} \|\omega\|^2 - \beta_i (y(\omega x) + b) - 1 \quad (10)$$

其中:  $\beta_i > 0$  为拉格朗日乘数。

由式(10)求解得到的鞍点为约束问题的最优解

$$\max L(\beta) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i y_j \beta_i \beta_j (x_i, y_j) \quad (11)$$

$$\text{s. t. } \sum_{i=1}^n \beta_i y_i = 0 \quad (0 \leq \beta_i \leq C, i=1, 2, \dots, n) \quad (12)$$

求解式(11)和式(12)得到决策函数为

$$f(\mathbf{x}) = \text{sgn}\{(\mathbf{w}^* \mathbf{x}) + b^*\} = \text{sgn}\left\{\sum_{i=1, j=1}^n \beta_i^* y_i (x_i, \mathbf{x}) + b\right\} \quad (\mathbf{x} \in \mathbf{R}^n) \quad (13)$$

粒子群算法是由随机解连续迭代求得最优解的过程<sup>[13]</sup>,在搜索参数的过程中具有较强的鲁棒性,且收敛速度快。具体的优化步骤如下:

1) 初始 PSO 参数,包括种群数目  $N$ 、迭代的最大次数  $n$ 、粒子群的初始参数  $c_1$  和  $c_2$ 、初始速度  $v$  和每个初始粒子个体最优位置  $p_i$  及全局最优位置  $p_g$ ;

2) 选取  $F(x) = \frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2$  为适应度函数,求解 PSO 中每个粒子的位置值;

3) 分别运用速度公式  $v_{id}(t+1) = wv_{id}(t) + c_1 r_1 (p_{id} - x_{id}(t)) + c_2 r_2 (p_{gd} - x_{id}(t))$  及位置公式  $x_{id}(t+1) = x_{id}(t) + v_{id}(t+1)$  得到粒子新的速度和位置。重新计算粒子的适应度值并根据适应度值更新  $p_i$  及  $p_g$ ;

4) 若寻优的迭代次数达到最大,则终止循环过程,得到的群体极值  $p_g$  为最佳参数,否则循环步骤 2。

## 2 预测模型

为解决其振动响应信号的非线性和非平稳性问题,得到更精确的预测结果,采用 IVMD 将原始给定信号分解。针对管道复杂的振动特性,利用机组和管道的相关性,建立 IVMD-SVM 预测模型,其关键步骤如下:

1) 依据原始观测数据,利用 IVMD 方法分别将机组和管道原始振动信号分解为  $K$  个 IMF<sub>s</sub>,作为

预测模型的输入样本和输出样本;

2) 分别构造各 IMF 对应的 SVM 预测模型,使用 PSO 搜索各模型参数的最优值并对各分量进行训练预测;

3) 将管道中各拾振器对应的预测结果相加重构得到管道最终的预测值。

## 3 管道振动预测

以某大型泵站 2 号管道为研究分析对象,内部均为 1200S-56 型卧式离心泵的 4 号机组和 5 号机组与 2 号管道的支管连接。两个机组一共设置 6 个测点,每个机组有 3 个测点,机组蜗壳顶部设置 1 个测点,蜗壳尾部左右各 1 个测点,每个测点位置布置 2 个拾振器(水平向、垂直向),共计 12 个拾振器,如图 1 所示。在管道的主管和两个支管上共选取 6 个测点,每个测点的  $x, y, z$  方向上各放置 1 个传感器,6 个测点水平方向的传感器号分别为 1, 3, 5, 7, 9, 11;垂向传感器号分别为 2, 4, 6, 8, 10, 12, 测点布置平面图如图 2 所示。原型实验研究对象的工况为 4 号机组稳定运行、5 号机组关闭,测试采样时间为 900s,采样频率为 512Hz。管道的原型观测虽然可以准确反映其真实的振动情况,但是由于所处的环境限制,管道上测点数量较少,无法对所有关键部位进行监测。一般都是依据泵站机组和管道振动的耦联作用以及两者具有的相关关系,采取智能算法来对管道结构进行预测。

机组与管道的两支管相连,机组在运行过程中产生的振动对管道有很大影响,管道与机组振动的




图 1 机组传感器布置平面图

Fig. 1 Layout plan of pipeline sensor

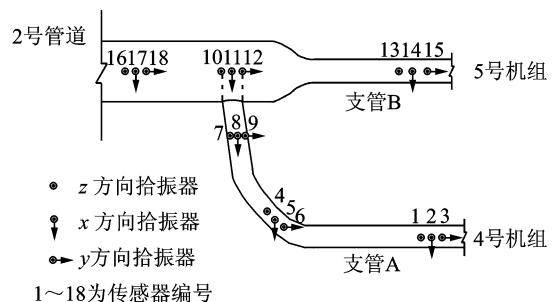


图 2 管道传感器平面布置图

Fig. 2 Layout plan of pipeline sensor

相关特性通过两者的相关系数来反映。管道与机组 6 个测点在水平和垂向的相关性系数见表 1。由表 1 可知,6 个测点水平方向的相关系数均大于竖直方向且各个测点的值不同,管道的  $x$  方向能更好表现振动特征,故选用管道  $x$  方向代表管道的平面振动特性并与机组水平方向互相对应。在 1,2,4,5,6 测点处,两者振动的相关系数均大于 0.60,其中最大为 0.74;而 3 号测点所在位置受两端支墩的影响,在某种程度上对振动能量的传播产生了约束,因此在 3 号测点处,管道和机组的相关系数最小。上述分析表明,机组和管道之间存在一定的相关性,可采用机组振动数据来预测管道的振动趋势。

表 1 机组和管道振动相关性系数

Tab. 1 Frequency division proportion of pipeline vibration to reach peak in each direction vibration

方向	测点					
	1	2	3	4	5	6
水平向	0.76	0.63	0.34	0.65	0.64	0.73
垂直向	0.67	0.63	0.17	0.58	0.57	0.74

选择 4 号机组 1~6 号传感器振动序列作为输入数据。由表 1 可知,在 6 个测点中,1 号测点和 6 号测点处管道和机组的相关系数较大,因此选择管道上 1,2,16,17 号传感器的振动序列为输出因数。为使预测结果更加全面准确,每隔 100 个数据点选取 50 个,机组和管道各选 900 个数据。

利用互信息法确定出 IVMD 的模态数  $K = 4$ ,管道和机组的每个拾振器经 IVMD 分解后各得 4 个 IMF 分量。图 3、图 4 为机组和管道 1 号拾振器振动序列经 IVMD 分解的模态分量。各个 IMF 分量与原给定振动序列的归一化互信息值见表 2、表 3。




图 3 机组 1 号拾振器振动信号的 IVMD 分解结果

Fig. 3 IVMD decomposition result of vibration signal of the unit 1




图 4 管道 1 号拾振器振动信号的 IVMD 分解结果

Fig. 4 IVMD decomposition result of vibration signal of the pipeline 1

表 2 机组 1 号拾振器各 IMF 归一化互信息值

Tab. 2 Each IMF normalized mutual information value of the 1 pickup device of the unit

IMF <sub>1</sub>	IMF <sub>2</sub>	IMF <sub>3</sub>	IMF <sub>4</sub>
1.000 0	0.159 1	0.063 0	0.064 0

表 3 管道 1 号拾振器各 IMF 归一化互信息值

Tab. 3 Each IMF normalized mutual information value of the 1 pickup device of the pipeline


IMF <sub>1</sub>	IMF <sub>2</sub>	IMF <sub>3</sub>	IMF <sub>4</sub>
0.528 0	1.000 0	0.905 6	0.840 1

由图 3、图 4 可知,各个 IMF 分量被较好地分解出来,且波动速率依次增高。由表 2、表 3 可知,4 个分量归一化值均大于阈值 0.02,满足分解要求。从分解后的各个分量组成的数据中分别随机选取 870 组作为训练样本,其余 30 组为预测样本。

构建机组和管道的 SVM 预测模型,并对分解得到的各个 IMF 分别进行训练预测。依据大量理论研究和试验数据<sup>[14-15]</sup>,设置模型的初始参数如下:最大迭代次数为 200;粒子种群数目为 20;初始学习因子  $C_1 = 1.5$ ;  $C_2 = 1.7$ 。使用 PSO 搜索各模型参数的最优值,通过模型进行训练预测,将各测点对应的预测值相加重构得到原始信号的预测结果。


笔者同时采用 BP 神经网络、PSO-SVM 两种模型与本研究方法预测结果进行对比,3 种模型的预测值与实测值比较结果如图 5 所示。

由图 5 可知,采用 BP 神经网络预测模型得到的结果和实测值吻合程度较差,其预测值无法确切反映管道真实的振动趋势。PSO-SVM 方法采用 PSO 搜索各模态分量对应支持向量机模型参数的最优值,避免选取参数的主观盲目性,提升了分类器



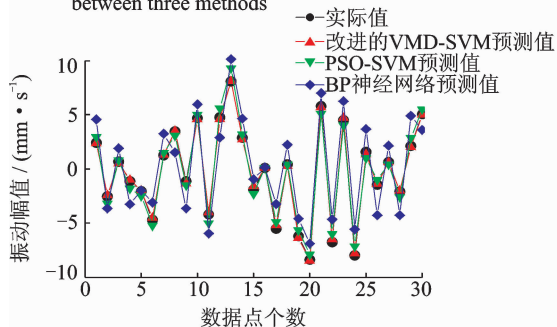
(a) 1号传感器3种方法预测结果对比

(a) Comparison of predicted results of No.1 sensor between three methods



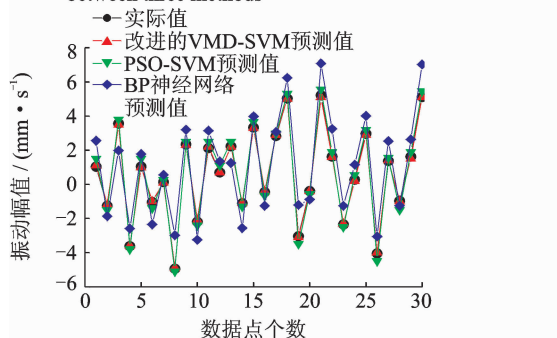
(b) 2号传感器3种方法预测结果对比

(b) Comparison of predicted results of No.2 sensor between three methods



(c) 16号传感器3种方法预测结果对比

(c) Comparison of predicted results of No.16 sensor between three methods



(d) 17号传感器3种方法预测结果对比

(d) Comparison of predicted results of No.17 sensor between three methods

图5 各拾振器3种方法预测结果对比

Fig. 5 Comparison of predicted results for each sensor between three methods

的精确度,但预测结果与真实值的吻合程度低于笔者提出的IVMD-SVM预测模型。IVMD-SVM方法的预测值与真实值更为接近,较好地反映管道振动趋势,保证了预测精密度,更接近工程要求。

为对振动预测效果进行更直观的定量分析,引入平均相对误差(mean relative error,简称MRE)和根均方误差(root mean square error,简称RMSE)作为预测效果的评价指标<sup>[15]</sup>。MRE与RMSE的计算结果越小,表明预测成果越理想

$$MRE = \frac{1}{N} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (14)$$

$$RMRE = \sqrt{\frac{1}{N} \sum_{k=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right|^2} \quad (15)$$

其中:  $Y_i$  为实测值;  $\hat{Y}_i$  为预测值。

由表4、表5可知,IVMD-SVM方法与BP神经网络、PSO-SVM预测方法相比,MRE值和RMSE值都较小,在4个拾振器的预测中都具有更高的精度。分析对比3种方法的误差,IVMD-SVM方法的预测误差最小,这是由于IVMD将原始振动序列分解为相对稳定的单一分量,且这些分量具有一定的规律,预测效果更好。由此说明,IVMD-SVM方法对管道的振动预测具有更高的推广价值。

表4 MRE方法振动效果评定指标对比

Tab. 4 Comparison of the evaluation indexes of the vibration effect of MRE method

拾振器	平均相对误差/%		
	IVMD-SVM	PSO-SVM	BP神经网络
1	1.26	3.0	19.9
2	1.02	2.9	22.6
16	3.82	7.6	24.1
17	2.13	4.7	27.2

表5 RMSE方法振动效果评定指标对比

Tab. 5 Comparison of the evaluation indexes of the vibration effect of RMSE method

拾振器	根均方误差		
	IVMD-SVM	PSO-SVM	BP神经网络
1	0.028	0.038	0.246
2	0.031	0.048	0.290
16	0.060	0.289	0.356
17	0.029	0.075	0.424

## 4 结论

1) 分解模态数  $K$  的确定在IVMD方法中占有至关重要的地位。利用互信息法来确定  $K$  值,并通过各个IMF分量与原振动信号的归一化互信息值来定量,与中心频率方法相比,互信息法操作简单,计算量小,有一定的衡量标准,避免了  $K$  值选取的盲目性。

2) IVMD方法能克服模态混叠现象,并且有效地将原始振动序列分解为  $K$  个相应平稳的单一IMF。对分解得到的各IMF分别构造对应的SVM

预测模型,并把各测点对应的预测值进行重构,有效避免原始振动序列的非平稳性对预测结果的影响。

3) 将 IVMD-SVM 方法、BP 神经网络和 PSO-SVM 方法进行对比分析表明,IVMD-SVM 方法的预测结果误差较小,且预测值与真实值更为接近,预测精度更高。该方法的提出为管道工程振动及类似流激振动趋势的预测提供一定参考。

### 参 考 文 献

- [1] 张建伟,江琦,朱良欢,等. 基于改进 HHT 的泵站管道工作模态辨识[J]. 农业工程学报,2016,32(2):71-76.  
Zhang Jianwei, Jiang Qi, Zhu Lianghuan, et al. Modal parameter identification for pipeline of pumping station based on improved Hilbert-Huang transform [J]. Transactions of the Chinese Society of Agricultural Engineering, 2016, 32(2): 71-76. (in Chinese)
- [2] 刘晓霞. 基于有限元分析双层海底管道断裂失效问题[J]. 管道技术与设备,2016(5):14-16.  
Liu Xiaoxia. Subsea pipe-in-pipe fracture failure problem based on finite element method[J]. Pipeline Technique and Equipment, 2016(5): 14-16. (in Chinese)
- [3] 李火坤,杨敏,陈林,等. 泄洪闸闸墩原型振动测试、预测与安全评价[J]. 振动、测试与诊断,2014,34(5):938-946.  
Li Huokun, Yang Min, Chen Lin, et al. Operational safety evaluation of sluice pier [J]. Journal of Vibration, Measurement & Diagnosis, 2014, 34(5): 938-946. (in Chinese)
- [4] 练继建,张夔,刘防,等. 厂顶溢流式水电站振源特性研究[J]. 振动与冲击,2013,32(18):8-14.  
Lian Jijian, Zhang Yan, Liu Fang, et al. Vibration source characteristics of a roof overflow hydropower station [J]. Journal of Vibration and Shock, 2013, 32(18): 8-14. (in Chinese)
- [5] 王海军,毛柳丹,练继建. 基于 RVM 方法的水电站厂房结构振动预测研究[J]. 振动与冲击,2015,34(3):23-27.  
Wang Haijun, Mao Liudan, Lian Jilian. Structural vibration prediction for a hydropower house based on RVM method [J]. Journal of Vibration and Shock, 2015, 34(3): 23-27. (in Chinese)
- [6] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. Transactions on Signal Processing, 2014, 62(3): 531-544.
- [7] 张松兰. 支持向量机的算法及应用综述[J]. 江苏理工学院学报,2016,22(2):14-17.  
Zhang Songlan. A survey of improved algorithm and application on support vector machine [J]. Journal of Jiangsu University of Technology, 2016, 22(2): 14-17. (in Chinese)
- [8] 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):297-302.  
Zhang Ning, Zhu Yongli, Gao Yanfeng, et al. An online detection method of transformer winding deformation based on variational mode decomposition and probability density estimation [J]. Power System Technology, 2016, 40(1): 297-302. (in Chinese)
- [9] 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):1-8.  
Liu Changliang, Wu Yingjie, Zhen Chenggang. Rolling bearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering [J]. Proceedings of the CSEE, 2015, 35(13): 1-8. (in Chinese)
- [10] Hestenes M R. Multiplier and gradient methods [J]. Journal of Optimization Theory and Applications, 1969, 4(5): 303-320.
- [11] 唐贵基,王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用[J]. 西安交通大学学报,2015,49(5):73-81.  
Tang Guiji, Wang Xiaolong. Parameter optimized variational mode decomposition method with application to incipient fault diagnosis of rolling bearing [J]. Journal of Xi'an Jiaotong University, 2015, 49(5): 73-81. (in Chinese)
- [12] 胡爱军. Hibert-Huang 变换在旋转机械振动信号分析中的应用研究[D]. 保定:华北电力大学,2008.
- [13] 尹玉娟,王媚,张金江,等. 一种自主核优化的二值粒子群优化:多核学习支持向量机变压器故障诊断方法[J]. 电网技术,2012,36(7):249-254.  
Yin Yujuan, Wang Mei, Zhang Jinjiang, et al. An autonomous kernel optimization method to diagnose transformer faults by multi-kernel learning support vector classifier based on binary particle swarm optimization [J]. Power System Technology, 2012, 36(7): 249-254. (in Chinese)
- [14] 张建伟,江琦,刘轩然,等. 基于 PSO-SVM 算法的梯级泵站管道振动响应预测[J]. 农业工程学报,2017,11(33):75-81.  
Zhang Jianwei, Jiang Qi, Liu Xuanran, et al. Application of improved VMD in vibration response prediction of pumping station pipeline [J]. Transactions of the Chinese Society of Agricultural Engineering, 2017, 11(33): 75-81. (in Chinese)
- [15] 李润求,施式亮,念其锋,等. 基于 PSO-SVM 的煤矿瓦斯爆炸灾害风险模式识别[J]. 中国安全科学学报,2013,23(5):38-43.  
Li Runqiu, Shi Shiliang, Nian Qifeng, et al. Research on pattern recognition of gas explosion disaster risk in coal mines based on PSO-SVM [J]. China Safety Science Journal, 2013, 23(5): 38-43. (in Chinese)



**第一作者简介:**张建伟,男,1979年3月生,博士,教授。主要研究方向为水工结构耦联振动与安全。曾发表《Signal denoising method for vibration signal of flood discharge structure based on combined wavelet and EMD》(《Journal of Vibration and Control》2017, Vol. 23, No. 15)等论文。  
E-mail: zjwcivil@126.com