

AVMD-KELM 方法在水闸结构振动趋势预测中的应用*

张建伟^{1,2,3}, 华薇薇^{1,2,3}, 侯 鸽^{1,2,3}, 赵 瑜¹, 郭西方⁴

(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) (4. 河南中原黄河工程有限公司 新乡, 453000)

摘要 采用自适应的变分模态分解(adaptive variational modal decomposition, 简称 AVMD)与核极限学习机(kernel extreme learning machine, 简称 KELM)联合的方法对水闸在泄流过程中的监测信号进行振动预测分析,用以辅助决策和及时预警。首先,基于互信息准则确定 AVMD 的分解模态数,克服变分模态分解(variatronal modal decomposition, 简称 VMD)盲目选取分解参数的缺点,利用 AVMD 把水闸振动信号分解成 K 个固态模量(intrinsic mode function, 简称 IMF);其次,通过 KELM 对各 IMF 分量分别进行预测;最后,将各测点对应的 IMFs 预测结果相加作为最终的预测值。结合某水闸在自由泄流工况下的振动数据,分别采用 AVMD-KELM 和 KELM 模型、支持向量机(support vector machine, 简称 SVM)模型对其振动趋势进行预测,并将预测结果进行对比分析。结果表明,AVMD-KELM 模型得到的预测结果与实测值更加接近,计算速度更快,精度更高,且误差较小,该方法可有效预测水闸结构的振动趋势。

关键词 自适应变分模态分解;核极限学习机;水闸;振动预测

中图分类号 TV66; TH825

引 言

作为一种低水头的泄流结构,水闸起着至关重要的作用,如水资源利用及蓄水灌溉等方面^[1-2]。水闸的流激振动系统是由结构与水体组成的流固耦合系统,其振动形式和机理比较复杂,实际工程中水流形态多变,建筑物形状多样,导致耦合系统的研究更加繁杂,无统一适用标准^[3]。许多水闸由于自身特性的原因,长时间处于动静悬殊以及泄流与不泄流交替的特殊环境中,容易发生破坏^[4]。为降低失事危险,提高水闸结构的运行效益,采用有效的方法利用有限的全面掌握水闸结构振动趋势值得重点关注^[5]。

VMD 是由 Dragomiretskiy 等^[6]提出的适用于多分量信号自适应分解的一种新方法。该方法的关键是求取最优解,经过迭代循环得到多个 IMFs。VMD 的分解过程能有效抑制模态混叠,收敛速度

快,具有较高的鲁棒性^[7]。VMD 对实测信号分解时, K 值的选取对结果的精确性有极大影响,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被分解出来。因此,模态总数 K 的选取至关重要。笔者利用互信息准则确定分解模态数 K ,减少人为因素的影响。KELM 是一种新型的单隐层神经网络学习算法^[8],其隐藏层不需要人为设定并利用最小二乘法进行计算输出权值。该算法不需要人工调节隐层参数,优于传统的神经网络,收敛速度快,极大减少样本训练时间且误差较小^[9]。

基于上述分析,笔者提出一种自适应的变分模态分解算法,并将其与 KELM 方法结合,建立 AVMD-KELM 模型对水闸的振动趋势进行预测,以便准确掌握水闸的运行状况,避免不安全的隐患,及时采取防范措施,提高水闸振动的安全水平。

* 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:2018-11-04;修回日期:2019-04-04

1 基本原理

1.1 变分模态分解

VMD的核心包括变分约束问题与迭代求最优解两部分。本质上,VMD采用变分约束将信号 $f(t)$ 分解,得到 K 个模态函数 $m_k(t)$,使各个IMF分量的带宽最小,且 K 个IMF分量相加结果为原信号 $f(t)$ 。变分约束模型^[10]表示为

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

其中: $\{m_k\} = \{m_1, m_2, \dots, m_k\}$ 表示分解后 K 个IMF分量。

为得到最优解,引用拓展的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: $\lambda(t)$ 为拉格朗日乘子; $\langle \cdot \rangle$ 表示内积运算。

采用对偶分解和交替方向乘子算法^[11]解决上述变分问题,不断迭代更新 m_k , ω_k 与 $\lambda(t)$,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 ω_k 如式(3)和式(4)所示

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

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

1.2 自适应的变分模态分解

采用VMD分解 $f(t)$ 之前,需要预设分解模态数 K ,其预设值对分解结果有直接的影响^[12]。不同结构的振动特性不同,使得 K 值难以确定。因此,采用互信息法自适应地选择 K 值,确保信号分解过程的合理性。

互信息(mutual information, 简称MI)能定量反映两个随机变量间的彼此关联性,更好地衡量两变量的相关水平^[13]。互信息表示如下

$$I(X, Y) = H(Y) - H(Y | X) \quad (5)$$

其中: $H(Y)$ 为 Y 的熵; $H(Y | X)$ 为条件熵。

当 $I(X, Y) = 0$ 时, X 与 Y 相互独立。 Y 表示原始信号, X 表示分解后的IMF。利用式(6)归一化计算,进而判断原信号是否完全被分解

$$\sigma_i = \frac{I_i}{\max(I_i)} \quad (6)$$

当 σ_i 低于 $\sigma = 0.02$ 时^[13],表示IMF分量和原信号几乎不相关,认为原信号中的有效成分全部被分解,此时结束运算。

1.3 核极限学习机

Huang等^[14]说明了原始的ELM算法,与传统的神经网络算法相比,ELM计算过程简单快速且泛化能力强。因为初始化设定ELM的隐含层参数及权值输入的随机性,使预测结果不稳定。为此,Huang等^[15]用核函数代替随机选取的映射,在ELM算法中融入核学习原理,从而提出了新的学习机算法即核极限学习机,该方法的收敛性强,计算速度优于SVM算法。KELM问题表述如下:任意设置隐藏层节点数 L ,隐藏层的输出函数为

$$\mathbf{h}(x) = [h_1(x), h_2(x), \dots, h_L(x)] \quad (7)$$

输出的权值为

$$\mathbf{b} = [b_1, b_2, \dots, b_L]^T \quad (8)$$

输入的训练样本为

$$\mathcal{N} = \{(x_i, t_i) \mid x_i \in R^d, t_i \in R^m, i = 1, 2, \dots, N\} \quad (9)$$

由标准化理论可得KELM的训练函数为

$$\begin{cases} \min: L_p = \frac{1}{2} \|\beta\|^2 + \frac{1}{2} \lambda \sum_{i=1}^n \|\xi_i\|^2 \\ \text{s. t. } : h(x_i) \beta = t_i^T - \xi_i^T \end{cases} \quad (10)$$

其中: β 为衔接隐含层及输出层节点的权重; ξ_i^T 为样本 x_i 输入与输出的误差; λ 为惩罚参数; $h(x_i)$ 为样本 x_i 隐含节点的输出函数。

由库恩-塔克(Karush-Kuhn-Tucher, 简称KKT)原理将式(10)等价于拉格朗日求解最值的问题

$$\begin{aligned} L_p = & \frac{1}{2} \|\beta\|^2 + \frac{1}{2} \lambda \sum_{i=1}^n \|\xi_i\|^2 - \\ & \sum_{i=1}^n \sum_{j=1}^n (h(x_i) \beta_j - t_{i,j} + \xi_{i,j}) \end{aligned} \quad (11)$$

极限学习机的输出函数为

$$\mathbf{f}(x) = \mathbf{h}(x) \mathbf{H}^T \left(\frac{I}{\delta} + \mathbf{H} \mathbf{H}^T \right)^{-1} \mathbf{A} \quad (12)$$

其中: \mathbf{A} 为输出矩阵。

在此引入核函数,利用核函数点乘来求解,避免了样本数据在低维空间无法映射到高维度求解的

问题。

$$\Omega_{ELM} = \mathbf{H}\mathbf{H}^T: \Omega_{ELM_{i,j}} = h(x_i)h(x_j) = K(x_i, x_j) \quad (13)$$

$$\mathbf{H}\mathbf{H}^T = \Omega_{ELM} = \begin{bmatrix} K(x_1, x_1) & \cdots & K(x_1, x_N) \\ \vdots & & \vdots \\ K(x_N, x_1) & \cdots & K(x_N, x_N) \end{bmatrix} \quad (14)$$

$$h(x)\mathbf{H}^T = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix}^T \quad (15)$$

输出方程为

$$f(x) = \begin{bmatrix} K(x, x_1) \\ \vdots \\ K(x, x_N) \end{bmatrix}^T \left(\frac{I}{C} + \Omega_{ELM} \right)^{-1} \mathbf{A} \quad (16)$$

选取高斯径向基核函数作为 KELM 中的核函数

$$K(x, z) = \exp(-\gamma \|x - z\|^2) \quad (17)$$

此时, KELM 的关键在于对参数 C 和 γ 的寻优问题, 采用粒子群优化 (particle swarm optimization, 简称 PSO) 算法^[16]对参数进行寻优, 避免人工选取参数的缺点, 使预测结果更加精确。PSO 算法的重点是分别运用速度公式 $v_{id}(t+1) = \omega v_{id}(t) + c_1 r_1 (p_{id} - x_{id}(t)) + c_2 r_2 (p_{gd} - x_{id}(t))$ 、位置公式 $x_{id}(t+1) = x_{id}(t) + v_{id}(t+1)$ 得到粒子新的速度及位置。其中: ω 为权重参数, 一般从 0.9 到 0.4 递减; c_1, c_2 为学习因子, 一般 $c_1 = c_2 = 2$ 。

通过 PSO 对 KELM 中的 C 和 γ 参数进行寻优, 利用式(18)求出最佳的一组参数, 并将最优参数代入式(16)和式(17), 即为最终的模型公式

$$f(x) = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (18)$$

其中: y_i 为实测值; y'_i 为预测值; n 为训练集。

2 AVMD-KELM 预测模型

为得到水闸结构振动信号更精确的预测结果, 采用 AVMD 将原始信号分解, 建立 AVMD-KELM 预测模型, 关键步骤如下:

1) 根据原始观测数据, 利用 AVMD 方法处理原始信号, 依据互信息准则确定分解模态数 K , 并将信号 $f(t)$ 分解为 K 个 IMF 分量;

2) 构建各 IMF 对应的 KELM 模型, 选取各 IMF 数据作为模型的训练集和预测集, 对各 IMF 分量进行训练预测;


3) 将水闸中各测点对应的 IMFs 预测值相加重构, 即为最终水闸各测点振动的预测结果。

3 工程实例

于曹闸工程是河南省安阳市区的一座景观节制闸。考虑闸型选择与周边环境协调, 加之运行管理方面的安全性能, 选取闸孔为 7 孔且单孔宽为 10 m 的双扉门闸。蓄水过程中, 一扉闸门用来调节最低水位, 另一扉闸门控制蓄水高度, 在闸门顶部可溢流, 泄洪时两扉闸门全部开启。


3.1 拾振器的布置及振动数据的选取

选取节制闸 4 # 孔的闸墩及工作桥为分析对象, 在闸墩两侧的水平向各布置 4 个测点, 右侧闸墩顶部处为 4 号测点, 1, 2 和 3 号点均匀布置于右侧闸墩上部, 相距约 3 m; 8 号点布置在左侧闸墩顶部, 5, 6 和 7 号点均匀布置于左侧闸墩上部, 相距约 3 m, 且两闸墩的测点相互对称。竖直向共有 3 个测点布置于工作桥面, 3 个传感器测点均匀布置于工作桥面, 9, 10 和 11 号测点相距约 1 m, 具体位置如图 1 所示。原型观测对象工况为 4 # 孔右侧的 3 # 闸孔始终处于关闭不过流状态, 左侧 5 # 闸孔始终处于开启过流状态, 采样时间为 10 min, 采样频率为 100 Hz。信号监测中 11 个测点同时采样, 完整



(a) 闸墩右(左)侧传感器布置

(a) Sensor arrangement on the right (left) side of the pier



(b) 工作桥传感器布置

(b) Placement of working bridge sensor

图 1 传感器布置示意图

Fig. 1 Schematic diagram of sensor layout

记录闸门从开始到关闭的全过程。

闸门原型观测采用 DASP 振动测试系统采集数据,该系统如图 2 所示。原型观测试验传感器是中国地震工程力学研究所研制的 INV9822 型加速度传感器,频响范围为 0.5~4 000 Hz,灵敏度为 200 mV/g。现场部分测点采集系统如图 3 所示。




图 2 DASP 振动响应测试框图

Fig. 2 Block diagram of DASP vibration response test



图 3 闸墩部分传感器布置

Fig. 3 Partial sensor layout of pier

闸门的左右闸墩为对称结构,且测点均匀对称分布,本次预测选取测点 2,5,7,9 为分析对象。振动监测数据共 4 组,为使预测结果更加全面准确,每 100 个数据点选取 50 个,每组各取 4 096 个数据点,前 3 000 个为训练样本数据,余下 1 096 个为预测数据。以 5 号测点为例,监测数据的振动情况如图 4 所示(为了更加直观地观察结构振动趋势,振幅图每隔 25 个时间间隔取点画图,取前 160 组数据)。




图 4 5 号测点振动监测数据

Fig. 4 Vibration monitoring data at point 5

3.2 AVMD 分解结果

以 5 号测点为例,对其进行 AVMD 分解,利用互信息法确定出分解的模态数 $K=4$,分解得到的 4 个 IMF 分量如图 5 所示。由图 5 可以看出,AVMD

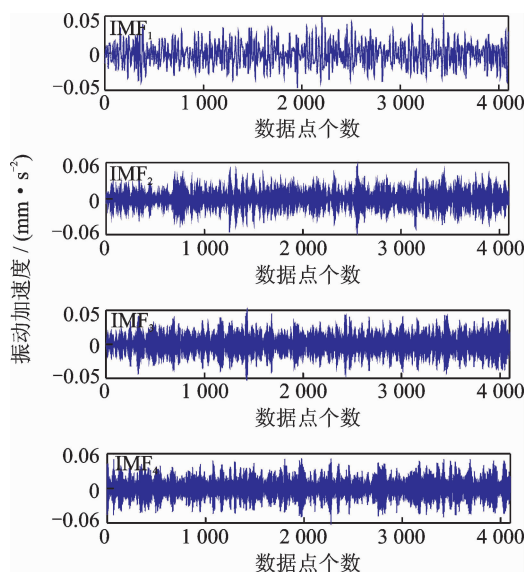


图 5 5 号测点振动数据 AVMD 分解结果

Fig. 5 AVMD decomposition result of vibration data of point 5

将原始序列分解为波动速率不同的 4 个分量,其中 m_4 波动速率最快, m_3 次之, m_1 波动速率最慢。各个 IMF 分量与原给定振动序列的归一化互信息值见表 1,由表 1 可知,测点的 4 个分量归一化值均大于阈值 $\sigma=0.02$ 时,满足分解要求。

表 1 5 号测点 IMF 归一化互信息值

Tab. 1 The IMF normalized the mutual information value of 5 point

IMF ₁	IMF ₂	IMF ₃	IMF ₄
1.000 0	0.042 3	0.047 1	0.627 0

3.3 AVMD-KELM 模型预测结果及对比

采用 KELM 模型对 AVMD 分解得到的各 IMF 分量进行预测分析,并将各测点对应的预测值相加重构,获得各测点预测结果。为验证 AVMD-KELM 模型的有效性,将其分析结果与 KELM 模型、SVM 模型相比并进行分析,其中 KELM 模型和 SVM 模型直接对水闸的原始振动序列进行预测。为了保证对比结果的准确性和有效性,3 种预测模型中的核函数均为高斯径向基核函数,模型中的参数均采用 PSO 优化,其预测值与实测值比较结果如图 6 所示。

由图 6 可知,3 种模型的振动预测结果与实测信号的吻合程度均在可接受范围内,且在预测过程中,KELM 模型预测速度比 SVM 模型更快。为了更加科学客观地对预测结果进行分析,如表 2 所示,笔者引用均方根误差 (root mean squared error, 简

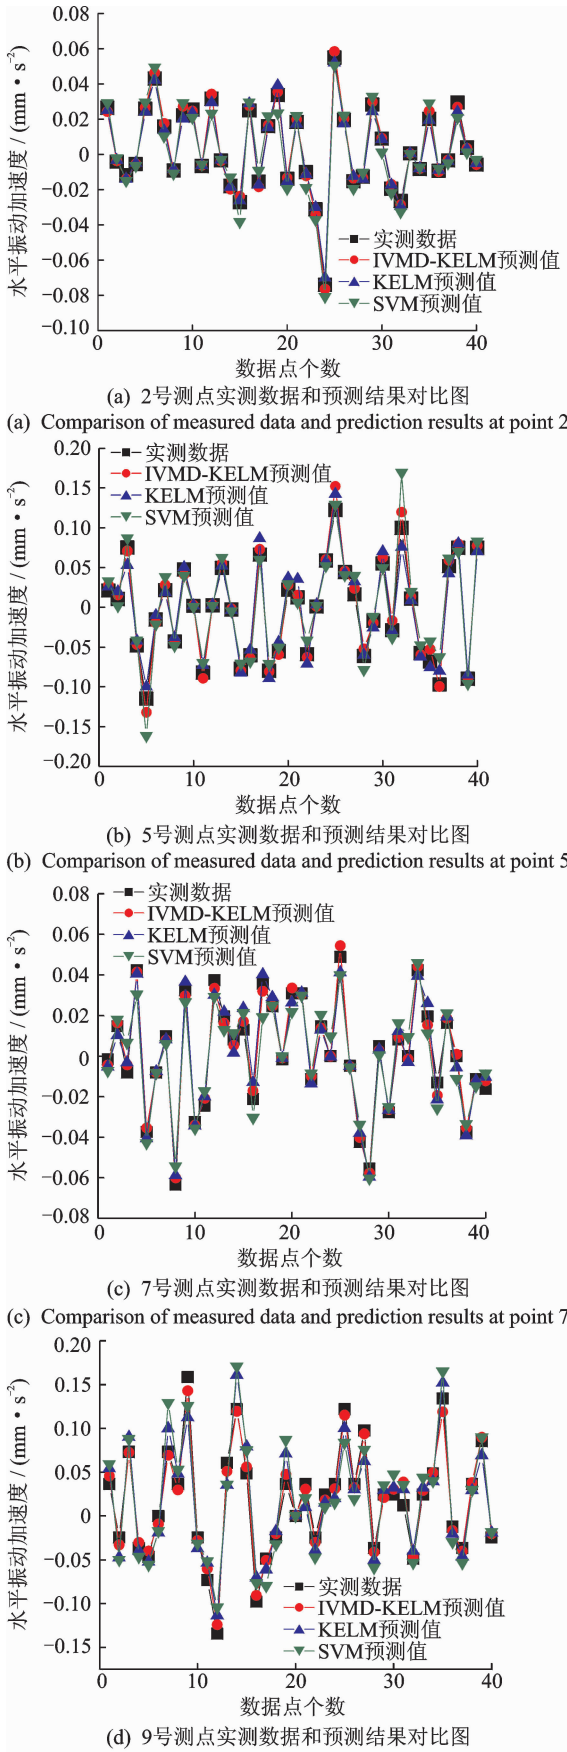


图 6 各实验测点实测数据和预测结果对比图

Fig. 6 Comparison between the measured data and the predicted results of each test point

称 RMSE)和平均相对误差(mean relative error,简称 MRE)两种评价指标对模型预测结果进行定量分析^[16]。

表 2 3 种模型预测结果的 RMSE 与 MRE 指标值对比

Tab. 2 Comparison of RMSE and MRE index values of three model prediction results

测点	RMSE			MRE/%		
	AVMD-KELM	KELM	SVM	AVMD-KELM	KELM	SVM
2	0.105	0.313	0.298	7.1	12.1	11.9
5	0.175	0.259	0.304	7.8	11.5	12.0
7	0.272	0.635	0.681	8.3	19.2	20.3
9	0.318	0.661	0.713	9.6	20.3	21.6

RMSE 与 MRE 值越小,表明预测效果越好。从表 2 的对比结果可以看出,AVMD-KELM 模型预测的 RMSE 与 MRE 结果均小于 KELM 和 SVM 预测模型,AVMD-KELM 预测结果的 MRE 均控制在 10%以内,整体预测数据和实际数据误差在接受范围之内。这表明本研究方法适用于水闸结构振动预测,且工程实用性更强。

4 结 论

1) 基于 AVMD-KELM 模型得到各测点的预测值与实测值较为吻合, RMSE 最大为 0.318, MRE 最大为 9.6%。与 KELM 和 SVM 预测模型对比分析, AVMD-KELM 模型对水闸振动趋势的预测较为理想。

2) 利用互信息法定量来确定 K 值大小,并采用 AVMD 算法将水闸结构振动信号较好地分离成 K 个 IMF 分量。KELM 利用最小二乘法可直接求出输出层所需要的权值,节省大量的训练样本时间,具有强大的泛化性能。在预测过程中, KELM 模型比 SVM 模型的预测速度快。与单一的 KELM 模型相比, AVMD-KELM 预测模型大幅度降低了振动信号复杂因素的干扰,各 IMF 分量能更好地反映水闸结构的振动情况,提高了水闸结构运行的安全水平。

参 考 文 献

[1] 宋小波,蔡欣,杨杰. 基于改进 AHP 法的水闸安全性模糊综合评价[J]. 水电能源科学, 2013, 31(2): 174-177.

Song Xiaobo, Cai Xin, Yang Jie. Fuzzy comprehensive

- evaluation of sluice safety based on improved AHP method[J]. *Water Resources and Power*, 2013, 31(2): 174-177. (in Chinese)
- [2] 陆恒. 综合检测技术在水闸安全鉴定中的运用[J]. *科技与创新*, 2018(14): 37-39.
Lu Heng. Application of comprehensive inspection technology in safety appraisal of sluices [J]. *Science and Technology & Innovation*, 2018(14): 37-39. (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] 乔双. 水利工程泄水建筑物磨蚀破坏的防治与修补[J]. *黑龙江水利科技*, 2018, 46(2): 152-153, 205.
Qiao Shuang. Prevention and repair of erosion and erosion of water conservancy works [J]. *Heilongjiang Hydraulic Science and Technology*, 2018, 46(2): 152-153, 205. (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 modal decomposition[J]. *Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [7] 张建伟, 侯鸽, 华薇薇, 等. 基于VMD-HHT边际谱的水工结构损伤诊断[J]. *振动、测试与诊断*, 2018, 38(4): 852-858.
Zhang Jianwei, Hou Ge, Hua Weiwei, et al. Damage diagnosis of hydraulic structure based on VMD and HHT marginal spectrum [J]. *Journal of Vibration, Measurement & Diagnosis*, 2018, 38(4): 852-858. (in Chinese)
- [8] Huang Guangbin, Ding Xiaojian, Zhou Hongming. Optimization method based extreme learning machine for classification[J]. *Neurocomputing*, 2010, 74: 155-163.
- [9] Zhang Yingwei, Zhang Pengchao. Optimization of nonlinear process based on sequential extreme learning machine[J]. *Chemical Engineering Science*, 2011, 20: 4702-4710.
- [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): 1-8.
Liu Changliang, Wu Yingjie, Zhen Chenggang. Rolling bearing fault diagnosis based on variational modal decomposition and fuzzy C means clustering[J]. *Proceedings of the CSEE*, 2015, 35(13): 1-8. (in Chinese)
- [11] Hestenes M R. Multiplier and gradient methods[J]. *Journal of Optimization Theory and Applications*, 1969, 4(5): 303-320.
- [12] 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 modal 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)
- [13] 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.
- [14] Miche Y, Sorjamaa A, Bas P, et al. OP-ELM: optimally pruned extreme learning machine [J]. *IEEE Transactions on Neural Networks*, 2010, 21(1): 158-162.
- [15] Huang Guangbin, Zhou Hongming. Extreme learning machine for regression and multiclass classification [J]. *IEEE Transactions on Systems, Man, and Cybernetics-part B; Cybernetics*, 2012, 42(2): 513-529.
- [16] 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)



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《Operation conditions monitoring of flood discharge structure based on variance dedication rate and permutation entropy》(《Nonlinear Dynamics》2018, Vol. 93, No. 4)等论文。

E-mail: zjwecivil@126.com