

基于 EEMD-RVM 的土石坝渗流量时间序列预测模型

刘永涛^{1,2}, 郑东健^{1,2}, 孙雪莲³, 曹立林⁴

(1. 河海大学水利水电学院, 江苏 南京 210098; 2. 河海大学水文水资源与水利工程科学国家重点实验室, 江苏 南京 210098;
3. 中国电力工程顾问集团华东电力设计院有限公司, 上海 200063;
4. 江苏省连云港市通榆河北延送水工程管理处, 江苏 连云港 222023)

摘要: 为避免常规时间序列模型因不考虑非线性环境量而出现拟合及预测精度不高的现象, 建立了基于 EEMD-RVM 的土石坝渗流量时间序列预测模型。该模型采用集成经验模态分解法 (EEMD) 对量水堰渗流量监测值进行分解, 生成多组平稳本征模态函数 (IMF) 及剩余分量 R , 然后采用相关向量机 (RVM) 对若干组 IMF 序列和 R 进行训练拟合及预测, 最后将 IMF 序列和 R 进行等权求和得到渗流量预测值; 讨论了该模型训练集的样本数及时长、预测集个数的选择和突跳点的处理等相关情况。工程算例验证结果表明, EEMD-RVM 模型拟合预测精度高, 且预测精度明显高于 RVM 模型以及 GA-BP 模型, 验证了该模型的可行性。

关键词: 土石坝; 渗流量; 时间序列; 预测模型; EEMD 分解法; 相关向量机

中图分类号: TV641; TV223.4 **文献标志码:** A **文章编号:** 1006-7647(2021)03-0089-06

Time series prediction model of seepage flow of an earth-rock dam based on EEMD-RVM//LIU Yongtao^{1,2}, ZHENG Dongjian^{1,2}, SUN Xuelian³, CAO Lilin⁴ (1. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China; 2. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China; 3. East China Electric Power Design Institute Co., Ltd. of China Power Engineering Consulting Group, Shanghai 200063, China; 4. Tongyu River North Water Transmission Project Management Department, Lianyungang 222023, China)

Abstract: In order to avoid the phenomenon of over fitting and low prediction accuracy of conventional time series model which does not consider the non-linear and random environmental quantity, an integrated empirical mode decomposition (EEMD) method was used to decompose the actual monitoring seepage flow of the water measuring weir. Multiple groups of stable eigenmode functions (IMF) and residual quantities (R) were generated, and then the IMF series and R were fitted and predicted by the correlation vector machine (RVM). Finally, the IMF series and R were added by equal weight to get the predicted value of the seepage flow. The number and length of the training set, the choice of the prediction set number and the treatment of the jump points were also discussed. The results of an engineering application case show that the EEMD-RVM model has high prediction accuracy, and is significantly higher than RVM model and GA-BP model, which verifies the feasibility of the model.

Key words: earth-rock dam; seepage; time series; prediction model; EEMD decomposition method; RVM

土石坝由于其经济性、施工技术简便及对地形地质适应性强等优势在坝工领域应用最广泛。在国际大坝委员会的 3 次溃坝事故调查报告中^[1], 土石坝的溃坝数量占大坝溃坝总数的 70%, 其中约 25% 土石坝的溃决是由坝体渗透破坏导致。为保证运行期土石坝的渗流安全, 需结合监测资料对土石坝的渗流进行监控。运行期土石坝渗流监测内容一般为坝后渗流量与坝内渗压水头, 其中渗流量是土石坝运行性态的直接表征^[2]。因此, 研究土石坝渗流量的变化趋势对准确评价大坝安全具有重要意义。大型土石坝工程由于监测资料详实、可靠, 因此很多算法可以较好地实现环境量与渗流量之间的映射关系, 并且渗流量的预测精度较高, 能满足工程应用要求^[3,4]。而对于占我国大坝总数 90%^[5] 以上的中小型土石坝, 一般监测资料会存在不同程度的缺测, 特别是环境量。另一方面, 由于规律性不强的降雨、变

化的水位、坝体的时效变形等因素对渗流量变化影响较大,因此土石坝渗流的监测数据一般具有非线性及非平稳性,所以在不考虑环境量的情况下研究渗流量时间序列并准确预测比较困难。综上,在不直接考虑大坝环境量对渗流的影响前提下,为了更简便高效地进行中小型土石坝渗流量预测,以渗流量时间序列作为研究对象十分必要。

目前,在缺失环境量的情况下,为解决土石坝渗流量预测中的过拟合和结果不唯一等问题,一些学者在渗流量预测中引入了不同的学习算法^[6-7]。这些算法,无论是传统算法还是智能优化算法都存在诸多问题^[8],如参数初始值对预测结果的准确性影响较大、算法的鲁棒性总体较差、算法迭代过于复杂且收敛缓慢、预测结果容易陷入局部最优且总体精度较低,所以渗流量时间序列的预测算法在理论研究和应用中均有待提高。为解决智能算法在非平稳时间序列的上述难题,Huang 等^[9]提出了经验模态分解(empirical mode decomposition, EMD)算法,但 EMD 存在端点效应和模态混叠程度高的问题;针对 EMD 存在的问题,Wu 等^[10]对 EMD 进行改进,提出了集合经验模态分解(ensemble empirical mode decomposition, EEMD)算法。目前, EEMD 算法已应用于环境、水文、医学、地质等多个行业^[11-13],但将其应用到土石坝渗流量预测中的研究甚少。

Tipping^[14]建立的相关向量机理论(RVM)模型不仅解决了支持向量机(SVM)模型结构稀疏度不高的问题,还简化了核函数的计算程序,提高了计算效率。高杰等^[15]给出了基于 RVM 的边坡可靠度计算方法,解决了极限状态函数无法显式表达、难以求解导数的问题,并且计算速度快、精度高;平善明等^[16]通过 RVM 模型预测了短期风速,并较好地解决了由于间歇性和不稳定性导致风速拟合预测低的问题。

综上, EEMD 算法可以较好地解决大坝渗流监测值非平稳性所带来的过拟合问题, RVM 算法可以在大坝渗流值的训练拟合和预测过程中提高算法收敛速率、预测精度以及模型的健壮性。因此,笔者运用 EEMD 算法对大坝渗流监测序列进行模态分解,结合高斯核函数的 RVM 模型对分解分量进行拟合训练,构建基于 EEMD-RVM 土石坝渗流量时间序列的预测模型,在不考虑环境变量的前提下,以期提高土石坝渗流量预测的可靠性和精度。

1 土石坝渗流量预测模型

1.1 EEMD 原理

在原始时间序列中多次加入足够多的不同白噪声,再将新的时间序列进行多次 EMD 分解得到多组

本征模态函数;然后根据白噪声均值为零的特点对各组本征模态函数分量作平均,可得到 EEMD 分解的 IMF 分量 I 和剩余量 R ^[17]。过程如下:

首先,把高斯白噪声 M 次加入原始时间序列得时间序列:

$$x_i(t) = x(t) + n_i(t) \quad (i = 1, 2, \dots, M) \quad (1)$$

式中: $x(t)$ 为原始时间序列; $x_i(t)$ 为第 i 次添加白噪声的时间序列; $n_i(t)$ 为等长度白噪声信号。

然后,利用 EMD 算法分解新的时间序列,可得本征模态函数 $C_{i,j}(t)$ 及一个剩余项 $r_i(t)$:

$$x_i(t) = \sum_{j=1}^J C_{i,j}(t) + r_i(t) \quad (2)$$

式中: $C_{i,j}(t)$ 为第 i 次添加白噪声 EMD 分解所得到的第 j 个本征模态函数分量; $r_i(t)$ 为剩余项; J 为 IMF 分量的个数。

最后,利用互不相关的随机序列之间均值为零的特性,将 M 组 $C_{i,j}(t)$ 分量及剩余项 $r_i(t)$ 求算术平均得到最终的 IMF 分量 I 及剩余量 $R(t)$ 。

$$I_j(t) = \frac{1}{M} \sum_{i=1}^M C_{i,j}(t) \quad (3)$$

$$R(t) = \frac{1}{M} \sum_{i=1}^M r_i(t) \quad (4)$$

式中: $I_j(t)$ 为 EEMD 最终分解分量; $R(t)$ 为最终剩余量。

1.2 RVM 模型原理

数据训练组为 $\{y_n, t_n\}_{n=1}^N$, 通过标准概率方程式,输入值 y_n 和目标值 t_n 可表达为^[16]

$$t_n = u(y_n; \omega) + \varepsilon_n \quad (5)$$

其中

$$\omega = (\omega_0, \omega_1, \dots, \omega_n)^T$$

$$u(y_n; \omega) = \sum_{n=1}^N \omega_n K(y, y_n) + \omega_0$$

式中: y_n 为输入向量值; t_n 为输出目标值; ω 为权重向量; ε_n 为零均值的高斯噪声且相互独立,方差为 σ^2 ; N 为样本数; $K(y, y_n)$ 为核函数。

设 t_n 为独立分布,数据序列完整概率为

$$p(t | \omega, \sigma^2) = (2\pi\sigma^2)^{-N/2} \exp\left(-\frac{1}{2\sigma^2} \|t - \Phi\omega\|^2\right) \quad (6)$$

其中

$$t = (t_1, t_2, \dots, t_N)^T$$

$$\Phi = (\phi(y_1), \phi(y_2), \dots, \phi(y_N))$$

$$\phi(y_n) = (1, K(y_n, y_1), K(y_n, y_2), \dots, K(y_n, y_N))^T$$

当训练序列中的参数增多时, σ^2 和 ω 的最大似然估计会出现过拟合现象,从而在预测过程中容易出现训练模型中的控制参数溢出现象。为避免发生上述现象,本文结合 SVM 原理及 Bayesian 先验特点,对一些参数附加约束条件^[18],以降低拟合及预测过程中的误差,提高模型精度。因此对权重 ω 赋

予一个均值为零的高斯分布:

$$p(\boldsymbol{\omega} | \boldsymbol{\alpha}) = \prod_{n=0}^N N(\omega_n | 0, \alpha_n^{-1}) \quad (7)$$

式中: $\boldsymbol{\alpha}$ 为超参数, 服从 Gamma 先验分布。

由 Bayesian 知识和先验分布 $p(\boldsymbol{\omega}, \boldsymbol{\alpha}, \sigma^2)$ 得后验分布 $\boldsymbol{\omega}$:

$$p(\boldsymbol{\omega} | \mathbf{t}, \boldsymbol{\alpha}, \sigma^2) = \frac{p(\mathbf{t} | \boldsymbol{\omega}, \sigma^2) p(\boldsymbol{\omega} | \boldsymbol{\alpha})}{p(\mathbf{t} | \boldsymbol{\alpha}, \sigma^2)} = (2\pi)^{-S/2} |\boldsymbol{\Sigma}|^{-1/2} \exp \left[-\frac{1}{2} (\boldsymbol{\omega} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\boldsymbol{\omega} - \boldsymbol{\mu}) \right] \quad (8)$$

其中 $\boldsymbol{\Sigma} = (\sigma^{-2} \boldsymbol{\Phi}^T \boldsymbol{\Phi} + \mathbf{A})^{-1}$ $\boldsymbol{\mu} = \sigma^{-2} \boldsymbol{\Sigma} \boldsymbol{\Phi}^T \mathbf{t}$

$\mathbf{A} = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$ $S = N + 1$

式中: $\boldsymbol{\Sigma}$ 为后验协方差; $\boldsymbol{\mu}$ 为后验均值。

对式(8)的 $\boldsymbol{\omega}$ 积分, 得到由 $\boldsymbol{\alpha}, \sigma^2$ 表示的边缘分布为

$$p(\mathbf{t} | \boldsymbol{\alpha}, \sigma^2) = (2\pi)^{-N/2} |\boldsymbol{\Psi}| \exp \left(-\frac{\mathbf{t}^T \boldsymbol{\Psi}^{-1} \mathbf{t}}{2} \right) \quad (9)$$

其中 $\boldsymbol{\Psi} = \sigma^2 \mathbf{I} + \boldsymbol{\Phi} \mathbf{A}^{-1} \boldsymbol{\Phi}^T$

式中: $\boldsymbol{\Psi}$ 为中间变量; $\mathbf{I}$ 为单位向量。

最大化求解超参数边缘分布, 通过迭代计算 $\boldsymbol{\alpha}$ 和 σ^2 , 可得优化参数:

$$\alpha_m^{\text{new}} = \gamma_m / \mu_m^2 \quad (m = 1, 2, \dots, N) \quad (10)$$

$$(\sigma^2)^{\text{new}} = \|\mathbf{t} - \boldsymbol{\Phi} \boldsymbol{\mu}\|^2 / \left(N - \sum_{m=1}^N \gamma_m \right) \quad (11)$$

式中: α_m^{new} 为迭代更新的 α_m ; $(\sigma^2)^{\text{new}}$ 为迭代更新的 σ^2 ; μ_m 为式(8)的第 m 个后验平均值; γ_m 为 α_m 相关的参数, $\gamma_m = 1 - \alpha_m M_{mm}$; M_{mm} 为后验权值协方差矩阵 $\boldsymbol{\Sigma}$ 的第 m 个对角元素。

通过式(10)和(11)迭代计算 α_m^{new} 和 $(\sigma^2)^{\text{new}}$, 直到所有参数满足条件或者达到最大迭代次数, RVM 模型输出最优解, 即完成学习预测过程。则待测样本 $\mathbf{y}^*$ 对应的目标预测值 t^* 为

$$t^* = \boldsymbol{\mu}^T \boldsymbol{\varphi}(\mathbf{y}^*) \quad (12)$$

通过快速序列稀疏 Bayesian 算法计算超参数和噪声方差, 则模型高斯核函数为^[19]

$$\mathbf{K}(\mathbf{y}, \mathbf{y}_n) = \exp(-g \|\mathbf{y} - \mathbf{y}_n\|^2) \quad (13)$$

其中 $g = \frac{1}{2\sigma_m^2}$

式中: σ_m 为函数的宽度参数。

1.3 土石坝渗流量预测模型构建

在不考虑环境量的前提下, 本文综合利用 EEMD 算法和 RVM 算法的优点和特性将其串联, 构建基于 EEMD-RVM 土石坝渗流量时间序列的预测模型。首先运用 EEMD 模型对土石坝渗流量监测序列进行模态分解, 然后通过 RVM 模型对分解的各分量进行拟合训练, 再将预测时间 t 代入训练好的分量函数得到分量预测值, 最后将每个分量的预

测结果相加求和则可得到渗流量预测结果。该模型具体实现过程如图 1 所示。




图 1 基于 EEMD-RVM 土石坝渗流量预测模型

2 算例验证

2.1 EEMD 分解渗流量时间序列

以某土石坝为例, 该坝位于我国东南地区, 最大坝高 120.0 m, 坝顶高程 760.00 m, 坝顶长度 259.8 m, 坝顶宽度 9.0 m。坝址以上控制流域面积 453 km², 水库校核洪水位(洪水频率 0.05%) 759.10 m, 设计洪水位(洪水频率 1%) 756.20 m, 正常蓄水位 755.00 m, 总库容 2.65 亿 m³, 为多年调节水库。该坝渗流量采用量水堰人工测读, 监测频率为一周一次, 选取 2015 年 1 月 7 日至 2017 年 8 月 31 日的 129 个渗流量监测值作为计算训练组; 选取 2017 年 9 月 15 日至 12 月 29 日的 15 个渗流量监测值为预测组。训练渗流量时间序列样本的时间作为输入值, 相应的渗流量作为输出值, 基于 EEMD-RVM 建立土石坝渗流量的预测模型。

首先对渗流量监测数据进行平稳化处理, 基于 EEMD 算法进行分解、重组。EEMD 算法分解参数有 2 个: 高斯白噪声标准差 S (一般为 0.01 ~ 0.40) 和添加白噪声次数 M (一般为 50 ~ 200)。对于平稳性较好的渗流序列, S 、 M 均可以取小点, 具体取值由序列特征决定。

取 2015 年 1 月 7 日至 2017 年 8 月 31 日的渗流量监测数据为训练组。在原始监测时间序列添加 100 组白噪声序列, 每组高斯白噪声标准差 S 设为 0.2 进而可得 I 分量 6 个和剩余分量 1 个, 分解结果如图 2 所示。

2.2 RVM 对各分量的训练拟合

EEMD 分解得到渗流量的分量后, 采用 RVM 算法对分量进行训练拟合。RVM 算法相关参数参考前人研究成果^[20] 取定: 惯性因子取值范围 0.3 ~ 0.8, 核




图2 EEMD 分解的 IMF 分量及 R 分量结果

参数中 g 取值 $0.01 \sim 1.0$, 学习因子 C_1 取值为 $1.2 \sim 2.5$, 学习因子 C_2 取值为 $1.5 \sim 2.55$, 核函数的位置因子 ν 取值为 0.01 , 速度因子 γ 取值为 1.00 。

通过 RVM 模型可拟合 6 个 I 分量及剩余分量 R 的函数, 通过对比实测值与 RVM 模型拟合值得到拟合误差, 进而通过快速序列稀疏 Bayesian 算法对拟合结果进行误差处理, 然后对各个分量的拟合值求和得渗流量拟合值。该坝渗流量的拟合结果如图 3 所示, 拟合结果的判定系数为 0.98 , 表明该模型的拟合精度高。




图3 EEMD-RVM 模型渗流量拟合过程线

2.3 渗流量预测结果及误差分析

将预测集的 2017 年 9 月 15 日至 12 月 29 日的 15 个时间点代入已训练好的各 I 分量及 R 分量的函数求得各分量值, 再把各分量的值相加得到土石坝渗流量的最终预测结果。为分析该模型的精度, 给出传统的 GA-BP 模型以及 RVM 模型预测结果, 各模型预测结果如图 4。3 种模型渗流量预测值的相应平均残差结果如图 5 所示, 其中 EEMD-RVM 模型、GA-BP 模型与 RVM 模型 3 种模型的预测渗流




图4 3 种模型渗流量预测结果对比




图5 3种模型预测结果残差对比

量的平均绝对值残差分别为 0.222 L/s、0.674 L/s 和 0.653 L/s,平均相对误差分别为 14.9%、49.7% 和 48.8%。由此说明,EEMD-RVM 模型可以大幅提高渗流量预测精度,并且对突跳值更敏感,整体预测结果更好,对环境量存在缺测的中小型土石坝水库的渗流量预测提供了新方法。

由实例计算可知 EEMD-RVM 渗流预测模型的精度和可靠性较高,为了增加该模型的适用性以及方便大坝管理人员的实际应用,对模型的样本数和相关预测情况进行说明。

a. 一般研究大坝渗流预测问题,在训练过程中训练集有大样本和小样本 2 种。本文模型研究的是大样本情形。对于大样本训练,一般取一年以上,这样可以较完整地捕捉到降雨、水位等年变化因素对渗流影响的规律特性。又由于大坝的渗流特性随着运行时间的增加而渐变,所以如果训练样本过多,则不能较好地反映当前的大坝渗流情况。因此,建议本文模型的训练样本取 1~2 a。对于小样本,由于渗流实测资料较少,所以一般取所有测量值为研究对象。

b. 对于预测时长的确定,时长并不是越长越好,因为时长越长必然带来误差增加,以至后期误差较大的预测值不具有工程指导意义。在水工建筑物的预测研究中,一般取训练集时长的 10%~20% 为预测集的时长。由于渗流的不稳定性,大坝的渗流预测比其他预测,如位移、应力的预测更难。所以为了提高渗流预测的精度,建议预测时长取训练集时长的 10%~15%。

c. 在渗流实测过程中,不可避免会出现突跳值的情况。对于突跳值的预测,一直是研究的难题。一般突跳值有 2 种:突增和突减。其中渗流的突增往往对于大坝安全更不利,建议增加预测值的安全裕度以对工程管理提供可靠的支持。本文算例在预测过程中的 2 个突跳点(2017-11-22 和 2017-12-15)的预测相对误差分别为 7.06% 和 15.21%,对于该坝建议对突跳点的预测值增加 5%~15% 的安全裕度。由于每座大坝的渗流情况不同,可以对过去渗流情况进行训练并比较预测值与实测值的误差,分析出突跳点的预测误差。根据预测误差情况,可以

调控预测结果和提高预测值的安全裕度以方便工作人员更好地管理和决策。

3 结 论

a. EEMD 算法将渗流量时间序列分解处理为平稳子序列,可以有效地提高非平稳渗流监测数据的分析精度。

b. EEMD-RVM 模型与 RVM 模型及 GA-BP 模型的结果对比可知:常规模型对渗流量时间序列的预测误差较大,EEMD-RVM 模型较大幅度地提高了预测精度,表明该模型在土石坝渗流量时间序列中具有较高的可靠性。

c. 通过实例和验证结果可得,EEMD-RVM 模型在工程应用上可行,操作性较高,精度满足要求。对于环境量监测缺失较为严重的中小型土石坝,特别是中小型病险坝,该模型可以快速进行渗流量预测研究,为提高中小型土石坝的渗流安全提供了新的途径和方法。

参考文献:

- [1] 郇能惠,杨泽艳.中国混凝土面板堆石坝的技术进步[J].岩土工程学报,2012,34(8):1361-1368. (LI Nenghui, YANG Zeyan. Technical advances in concrete face rockfill dams in China [J]. Journal of Geotechnical Engineering, 2012, 34(8):1361-1368. (in Chinese))
- [2] 吴中如.水工建筑物安全监控理论及其应用[M].北京:高等教育出版社,2003
- [3] 李俊,苏怀智,周仁练.基于关联规则的土石坝渗流推理预测方法及应用[J].水利水电科技进展,2019,39(5):89-94. (LI Jun, SU Huaizhi, ZHOU Renlian. Seepage prediction method based on association rules and its application to earth-rock dams [J]. Advances in Science and Technology of Water Resources, 2019, 39(5):89-94. (in Chinese))
- [4] 王宇,陈超,陈祥勇.土石坝渗流安全预测预警研究[J].水利水电技术,2018,49(11):68-74. (WANG Yu, CHEN Chao, CHEN Xiangyong. Study on prediction and early-warning of seepage safety for earth-rockfill dam [J]. Water Resources and Hydropower Engineering, 2018, 49(11):68-74. (in Chinese))
- [5] 李浩平,贾志营,黄耀英,等.基于重要贡献度的中小型土石坝安全评价指标体系研究[J].水利水电技术,2018,49(5):103-108. (LI Haoping, JIA Zhiying, HUANG Yaoying, et al. Important contribution degree-based study on safety evaluation index system of small and medium-size earth rockfill dam [J]. Water Resources and Hydropower Engineering, 2018, 49(5):103-108. (in Chinese))

- [6] 孙培学,赵坤鹏. 基于熵权法的组合模型在大坝渗流预测中的应用[J]. 水电能源科学, 2013, 31(12): 70-73. (SUN Peixue, ZHAO Kunpeng. Application of combination model based on entropy method in dam seepage forecasting [J]. Water Resources and Power, 2013, 31(12): 70-73. (in Chinese))
- [7] 徐强,肖明,陈俊涛,等. 渗流监测数据缺失处理与渗透稳定判断[J]. 岩土力学, 2019, 40(4): 1526-1534. (XU Qiang, XIAO Ming, CHEN Juntao, et al. Solution to seepage monitoring data deficiency and judgement of seepage stability [J]. Rock and Soil Mechanics, 2019, 40(4): 1526-1534. (in Chinese))
- [8] 李鹏桦,苏亮渊,贾亚杰,等. 基于多因素影响的 BP-RBF 神经网络渗流预测模型[J]. 人民黄河, 2018, 40(4): 132-135. (LI Penghua, SU Liangyuan, JIA Yajie, et al. BP-RBF neural network seepage model under the influence of various factors [J]. Yellow River, 2018, 40(4): 132-135. (in Chinese))
- [9] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings Mathematical Physical & Engineering Sciences, 1998, 454: 903-995.
- [10] WU Z, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
- [11] NAJMUL H. A methodological approach for predicting COVID-19 epidemic using EEMD-ANN hybrid model [J]. Internet of Things, 2020, 11: 100228.
- [12] 李旭东,周婉,赵志高,等. 基于 EEMD 和 IGSA-SOM 神经网络的滚动轴承故障诊断[J]. 水利水电快报, 2020, 41(5): 46-52. (LI Xudong, ZHOU Wan, ZHAO Zhigao, et al. Fault diagnosis of rolling bearings based on EEMD and IGSA-SOM neural network express [J]. Water Resources & Hydropower Information, 2020, 41(5): 46-52. (in Chinese))
- [13] 付文涛,胡丁梅,王守华,等. 基于 EEMD-GM-ELM 模型的滑坡位移预测[C]//中国卫星导航系统管理办公室学术交流中心. 第十一届中国卫星导航年会论文集: S01 卫星导航行业应用. 北京: 中科北斗汇(北京)科技有限公司, 2020: 89-93.
- [14] TIPPING M. Sparse bayesian learning and the relevance vector machine [J]. Journal of Machine Learning Research, 2001(1): 211-244.
- [15] 高杰,马春辉,王建娥,等. 基于 RVM-AFOSM 模型的边坡可靠度分析[J]. 人民黄河, 2019, 41(11): 85-88. (GAO Jie, MA Chunhui, WANG Jiane, et al. Slope reliability analysis based on relevance vector machine (RVM) and advanced first order second moment (AFOSM) [J]. Yellow River, 2019, 41(11): 85-88. (in Chinese))
- [16] 平善明,赵玲玲,苏小红. 基于相关向量机和残差分析的短期风速预测[J]. 智能计算机与应用, 2018, 8(3): 246-249. (PING Shanming, ZHAO Lingling, SU Xiaohong. Short-term wind speed forecasting method based on RVM and residual analysis [J]. Intelligent Computer and Applications, 2018, 8(3): 246-249. (in Chinese))
- [17] 张金良,王明雪. 基于 EEMD, SVM 和 ARMA 组合模型的电价预测[J]. 电力需求侧管理, 2020, 22(3): 63-68. (ZHANG Jinliang, WANG Mingxue. Electricity price forecasting based on EEMD, SVM and ARMA combination model [J]. Power Demand Side Management, 2020, 22(3): 63-68. (in Chinese))
- [18] BISHOP C M. Pattern recognition and machine learning [M]. New York: Springer, 2007.
- [19] 邴其春,龚勃文,杨兆升,等. 一种组合核相关向量机的短时交通流局域预测方法[J]. 哈尔滨工业大学学报, 2017, 49(3): 150-155. (BING Qichun, GONG Bowen, YANG Zhaosheng, et al. A short-term traffic flow local prediction method of combined kernel function relevance vector machine [J]. Journal of Harbin Institute of Technology, 2017, 49(3): 150-155. (in Chinese))
- [20] 曹恩华,包腾飞,刘永涛,等. 基于 EMD-RVM-Arima 的大坝变形预测模型及其应用[J]. 水利水电技术, 2018, 49(12): 59-64. (CAO Enhua, BAO Tengfei, LIU Yongtao, et al. EMD-RVM-Arima based prediction model of dam deformation and its application [J]. Water Resources and Hydropower Engineering, 2018, 49(12): 59-64. (in Chinese))

(收稿日期: 2020-06-12 编辑: 刘晓艳)

