

DOI: 10.20040/j.cnki.1000-7709.2023.20222110

基于 OVMD-TVFEMD 二次分解和 HPO-ELM 的水电机组振动趋势预测

张楠^{1a}, 朱永奇^{1a}, 孙娜^{1b}, 赖昕杰², 李超顺³

(1. 淮阴工学院 a. 江苏省先进制造技术重点实验室; b. 自动化学院, 江苏淮安 223299; 2. 中国电建集团华东勘测设计研究院有限公司, 浙江杭州 311122; 3. 华中科技大学土木与水利工程学院, 湖北武汉 430074)

摘要: 针对已有水电机组振动趋势预测模型的局限性, 提出了一种基于最优变分模态分解(OVMD)、时变滤波器经验模态分解(TVFEMD)、猎人猎物优化算法(HPO)和极限学习机(ELM)的水电机组振动趋势预测方法。该方法先通过 OVMD 对原始水电机组振动信号进行自适应分解, 进一步采用 TVFEMD 对分解后的残差进行二次分解。然后建立各子序列的 HPO-ELM 振动趋势预测模型; 叠加重构所有子序列预测结果获得最终的预测振动信号。研究表明, 该方法预测效果明显优于传统方法, 有效提高了水电机组振动趋势预测精度, 具有较好的工程应用价值。

关键词: 水电机组振动趋势预测; 最优变分模态分解; 二次分解; 极限学习机; 优化算法

中图分类号: TV136 **文献标志码:** A **文章编号:** 1000-7709(2023)10-0204-04

1 引言

水电机组的振动信号可充分表征机组状态变化及故障发生, 因此其振动趋势的精准预测对机组运行状态评估、状态检修计划制定、保障机组和电力系统的安全稳定运行具有重要意义^[1-2]。薛小明等^[3]融合快速集成经验模态分解(FEEMD)、能量熵(EE)和支持向量回归(SVR), 提出了 FEEMD-EE-SVR 水电机组状态趋势预测模型; 陆丹等^[4]结合 EEMD 和神经网络理论, 提出了一种水电机组状态趋势预测模型。大量研究表明 VMD 比 EEMD 在信号分解方面更有优势。如杨华等^[5]提出了一种基于 VMD 和 Hilbert-Huang 的水电机组振动信号分析方法, 并分析了葛洲坝某台机组启动过渡过程振动信号问题; 付文龙等^[6]提出了一种基于最优变分模态分解(OVMD)与 SVR 的组合预测模型, 预测效果较好; 袁成建等^[7]利用 VMD、GA-BP 神经网络和误差校正策略, 建立了水电机组振动机组预测模型。

然而, VMD 的分解性能受模态个数和拉格朗日乘子更新步长等参数影响, 且以往方法通常丢弃 VMD 分解后的剩余残余项, 但其携带了丰富的振动信息, 从而造成振动信号分解不完整, 使模型精度受限。因此, 本文提出了一种基于 OVMD-TVFEMD 二次分解和 HPO-ELM 的水电机组振动趋势预测方法, 并通过实例验证了该模型具有较高的预测精度。

2 研究方法

2.1 最优变分模态分解

为解决传统经验模态分解(EMD)算法在信号分解时存在的端点效应和模态混叠等问题, 提出了变分模态分解算法(VMD)。VMD 通过对约束变分优化问题进行求解, 自适应匹配每种模态的最佳中心频率和有限带宽, 可将复杂非平稳信号分解为多个不同频率尺度且相对平稳的子序列。VMD 的具体求解过程见文献[8], 其变分约束优化问题为:

收稿日期: 2022-10-12, **修回日期:** 2023-01-24

基金项目: 江苏省自然科学基金项目(BK20201069); 江苏省高校自然科学基金面上项目(20KJD480003); 江苏省双创计划(JSSCBS(2020)31038)

作者简介: 张楠(1991-), 男, 讲师、硕导, 研究方向为水电、风电等清洁能源优化运行与控制、人工智能应用, E-mail: zhangnanhust@163.com

通讯作者: 孙娜(1992-), 女, 讲师、硕导, 研究方向为水文水资源、人工智能应用, E-mail: sunna1347@126.com

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

式中, $\{u_k\}$ 、 $\{\omega_k\}$ 分别为输入信号分解后第 k 个模态函数和相应中心频率; K 为分解模态个数; δ_t 为狄拉克分布; ∂_t 为函数在时间 t 上的偏导数; t 为时间变量; G_{CIMF} 为原始信号。

由于分解模态个数 K 和拉格朗日乘子更新步长 τ 是影响 VMD 性能的主要因素, 可采用中心频率观察法确定模态个数 K , 并利用最小二乘误差指标 (LSEI) 确定更新步长 τ , 实现最优 VMD(OVMD)。LSEI 公式 R 为:

$$R = \min \frac{1}{N} \sum_{i=1}^N \left| \sum_{k=1}^K [u_k(t) - \sum_{k=1}^K u_k] \right| \quad (2)$$

式中, N 为分解信号的长度。

2.2 基于 OVMD-TVFEMD 二次分解

为充分利用时间序列经 OVMD 分解后剩余残差的丰富信息, 提出一种基于 OVMD-TVFEMD 的二次分解算法, 在 OVMD 分解原始机组振动信号的基础上, 进一步应用 TVFEMD 对 OVMD 分解后的残差部分进行二次分解。OVMD 分解后残余分量 R_{res} 为:

$$R_{\text{res}} = f(t) - \sum_{i=1}^k u_i(t) \quad (3)$$

TVFEMD 有效解决了 EMD 的模态混叠和噪声敏感问题, 且保留了原始 EMD 的优势, 其主要步骤如下。

步骤 1 通过 EMD 分解原始信号 $x(t)$, 获得若干个模态分量 IMF 和残差。

步骤 2 设 $\{v_i \mid i=1, 2, \dots\}$ 表示信号 $x(t)$ 的极大值点对应的的时间序列。设定一个使下式合理的变化率阈值以找出间断点 $r_i = v_i$ 发生的位置:

$$\frac{\max(\varphi'_{\text{bis}}(u_i : u_{i+1})) - \min(\varphi'_{\text{bis}}(u_i : u_{i+1}))}{\min(\varphi'_{\text{bis}}(u_i : u_{i+1}))} > \rho \quad (4)$$

式中, φ'_{bis} 为角分线频率。

步骤 3 依据 $\varphi'_{\text{bis}}(u_{i+1})$ 、 $\varphi'_{\text{bis}}(u_i)$ 的大小关系确定间断点 r_i 位于 $\varphi'_{\text{bis}}(t)$ 的上升沿还是下降沿, 对应的 $\varphi'_{\text{bis}}(r_{i-1} : r_i)$ 、 $\varphi'_{\text{bis}}(r_i : r_{i+1})$ 为最低值, $\varphi'_{\text{bis}}(t)$ 为峰值。通过在峰间插值, 推导出最终的局部截止频率, 防止出现模态混叠。

步骤 4 重构 $\varphi'_{\text{bis}}(t)$ 获得新信号 $f(t)$:

$$f(t) = \cos \left[\int \varphi'_{\text{bis}}(t) dt \right] \quad (5)$$

步骤 5 使用 B-spline 近似滤波器对 $x(t)$ 进行时变滤波, 获得局部均值函数 $m(t)$ 。

步骤 6 对于给定的带宽阈值 ζ , 计算停止准则, 如果 $\theta(t) < \zeta$ 可确定 $x(t)$ 为一个 IMF, 否则 $x_1(t) = x(t) - m(t)$, 重复执行步骤 1~5 得:

$$\theta(t) = B_{\text{Loughlin}}(t) / \varphi_{\text{avg}}(t) \quad (6)$$

式中, $B_{\text{Loughlin}}(t)$ 为两信号分量间的洛克林瞬间带宽; $\varphi_{\text{avg}}(t)$ 为单分量加权平均瞬时频率。

2.3 HPO-ELM 模型

ELM 是一种前馈神经网络, 其输入权重和隐藏层神经元阈值随机生成, 无需迭代更新。给定 M 组训练样本 $(x_j, y_j) \in R^n \times R^m$, 其中 x_j 为 n 维输入向量, y_j 为 m 维目标向量。隐含层有 L 个神经元, $G(a_i, b_i, x_i)$ 为激活函数, 其输出为:

$$f(X_j) = \sum_{i=1}^L \beta_i(a_i, b_i, X_j) = t_j \quad j = 1, 2, \dots, N \quad (7)$$

式中, a_i, b_i 分别为输入权重和隐藏层神经元阈值; β_i 为输出层权重。

式(7)的矩阵形式为:

$$H\beta = T \quad (8)$$

根据最小二乘准则, 可计算输出层权重:

$$\beta = H^+ T \quad (9)$$

ELM 的输入权重及隐藏层阈值随机给定, 模型的稳定性和性能受初始参数影响较大, 易陷入局部最优值。猎人猎物优化算法 (HPO) 模仿狮子等肉食动物捕食鹿、羚羊等猎物的行为^[9]。为提高 ELM 建模精度, 本文提出一种基于 HPO 的 ELM 建模方法, 利用 HPO 优化 ELM 的输入权重及隐藏层阈值, 通过不断迭代更新获得全局最优值, HPO-ELM 的算法流程见图 1。

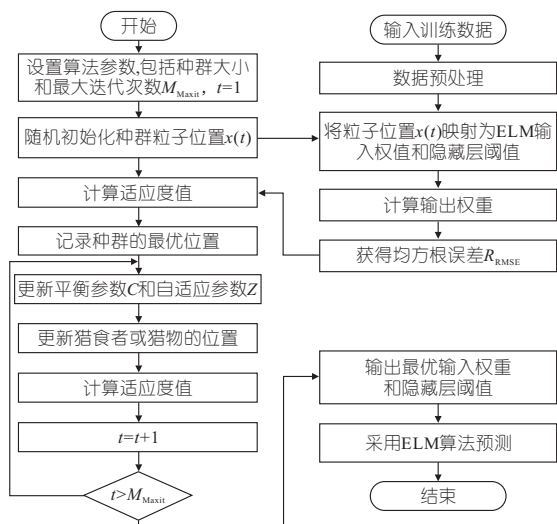


图 1 HPO-ELM 流程图

Fig. 1 Flow chart of HPO-ELM

3 基于 OVMD-TVFEMD-HPO-ELM 的水电机组振动趋势预测模型

基于 OVMD-TVFEMD-HPO-ELM 的水电机组振动趋势预测模型,建模过程如下。

步骤 1 收集原始水电机组振动信号,采用 OVMD 将机组振动信号分解为 K 个子序列。为提高 VMD 的分解性能,采用中心频率观察法和最小二乘误差指标 LSEI 确定 VMD 的模态数 K 和拉格朗日乘子更新步长 τ 。

步骤 2 根据式(3)计算各 IMF 分量合成信号与原振动信号之间的误差,获得 OVMD 分解后机组振动信号的残余分量,为充分利用残余分量的丰富信息,使用 TVFEMD 对残余分量进行二次分解,得到多个 IMF 子序列。

步骤 3 对经 OVMD 一次分解和 TVFEMD 二次分解后得到的所有 IMF 分量划分输入、输出矩阵。设 IMF 分量信号时间序列为 $\{x_1, x_2, \dots, x_n\}$, n 为总的时间序列长度。设网络的输入层神经元个数为 m ,则可构建输入输出矩阵为:

$$\begin{bmatrix} x_1 & x_2 & \cdots & x_m & x_{m+1} \\ x_2 & x_3 & \cdots & x_{m+1} & x_{m+2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{n-m} & x_{n-m+1} & \cdots & x_{n-1} & x_n \end{bmatrix} \quad (10)$$

其中矩阵前 m 列是输入值,第 $m+1$ 列是输出值,取其中前 80% 作为训练集,而后 20% 作为测试集。

步骤 4 使用 ELM 对每个 IMF 分量进行预测,为提高 ELM 的建模精度,以预测误差为目标函数,采用 HPO 对 ELM 的输入权重及隐藏层阈值进行优化,获得最优预测结果。最后将所有 IMF 分量的预测结果进行叠加,得到机组振动预测最终结果。

4 实例验证

收集国内某大型水电机组 414 次发电过程上导轴承 x 向摆度监测数据,计算每次发电过程的峰峰值,获取机组长期振动信号(图 2)。由图 2 可知,水电机组振动序列具有明显的非平稳性。

为验证所提出的基于 OVMD-TVFEEMD-HPO-ELM 的水电机组振动趋势预测模型的有效性,对比分析 ELM、OVMD-ELM、OVMD-RES-ELM、OVMD-TVFEEMD-ELM、OVMD-TVFEEMD-HPO-ELM。其中 OVMD-ELM 表




图 2 水电机组振动信号

Fig. 2 Vibration signal of hydropower unit

示对原始振动序列进行 OVMD 分解,不考虑残差序列。OVMD-RES-ELM 表示考虑 OVMD 分解后的残差序列 RES,对残差序列不分解直接建立 ELM 模型。OVMD-TVFEEMD-ELM 表示利用 TVFEMD 对残差序列进行二次分解。模型评价指标选用均方根误差(R_{RMSE})、平均绝对误差(M_{MAE})、平均绝对百分比误差(M_{MAPE}):

不同 K 值下 VMD 分解后各分量的归一化中心频率见表 1。由表 1 可看出,相近的中心频率在 $K=7$ 时出现,即此时出现了过度分解,因此 K 应选用 6。计算不同 τ 下的指标 LSEI,当指标 LSEI 最小时,对应的 τ 为 0.98。

表 1 K 取不同值时的中心频率

Tab. 1 Normalized center frequencies with different K

模态数	模态 1	模态 2	模态 3	模态 4	模态 5	模态 6	模态 7
$K=2$	9.13×10^{-6}	0.334 7					
$K=3$	8.65×10^{-6}	0.166 3	0.397 3				
$K=4$	8.56×10^{-6}	0.137 0	0.291 4	0.450 0			
$K=5$	7.41×10^{-6}	0.056 7	0.167 5	0.303 3	0.457 6		
$K=6$	7.51×10^{-6}	0.061 0	0.153 1	0.246 2	0.356 5	0.466 7	
$K=7$	7.52×10^{-6}	0.060 2	0.149 0	0.228 0	0.317 7	0.400 7	0.472 4

图 3 为不同模型结果对比。由图 3 可知,本文所提出的模型具有较高的预测精度。表 2 展示

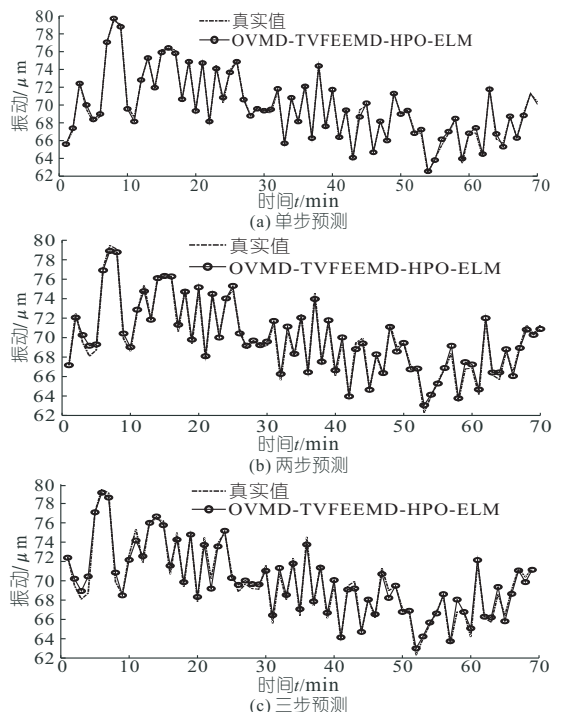


图 3 不同模型结果对比

Fig. 3 Comparison of results of different models

表 2 不同模型评价指标对比

Tab. 2 Comparison of evaluation indicators of different models

模型	单步预测				两步预测				三步预测			
	R_{RMSE}	M_{MAE}	M_{MAPE}	R	R_{RMSE}	M_{MAE}	M_{MAPE}	R	R_{RMSE}	M_{MAE}	M_{MAPE}	R
ELM	3.239 6	2.661 1	3.803 4	0.534 4	3.490 3	2.758 6	3.947 7	0.461 8	3.578 1	2.890 1	4.127 5	0.428 4
EMD-ELM	2.177 0	1.635 0	2.306 1	0.831 4	2.537 9	2.091 4	2.993 9	0.739 9	2.667 2	2.231 2	3.182 9	0.710 7
CEEMDAN-ELM	1.535 3	1.257 4	1.811 1	0.915 8	1.981 2	1.650 8	2.378 9	0.850 9	2.300 6	1.913 1	2.747 9	0.796 1
OVMD-ELM	0.810 1	0.656 2	0.944 2	0.977 8	0.977 1	0.763 6	1.089 1	0.966 3	1.555 9	1.291 4	1.856 7	0.917 4
OVMD-RES-ELM	0.709 4	0.556 1	0.797 4	0.983 9	0.860 1	0.661 1	0.939 9	0.975 7	1.277 8	1.043 2	1.491 3	0.948 1
OVMD-TVFEEMD-ELM	0.474 8	0.363 0	0.524 1	0.993 0	0.519 6	0.397 3	0.564 6	0.991 2	0.854 6	0.676 6	0.964 9	0.977 3
OVMD-TVFEEMD-HPO-ELM	0.293 3	0.228 8	0.330 5	0.997 2	0.395 4	0.315 5	0.455 2	0.995 4	0.585 7	0.489 9	0.703 3	0.989 4

了各模型在不同预测步数下的评价指标,通过对比各模型的评价指标可得如下结果。

(1)对比 ELM 与 EMD-ELM 的预测结果可发现,基于 EMD 的混合模型预测性能有显著提升,可知 EMD 有助于削弱原始振动信号的非平稳性,提高模型预测精度。在单步预测时 ELM 的各评价指标分别为 3.239 6、2.661 1、3.803 4、0.534 4,而 EMD-ELM 的评价指标分别为 2.177 0、1.635 0、2.306 1、0.831 4, R_{RMSE} 、 M_{MAE} 、 M_{MAPE} 分别减小了 32.80%、38.56%、39.37%, R 增加了 55.58%。此外,对比 EMD-ELM 与 CEEMDAN-ELM,后者在所有预测步数下均获得更优预测结果,且指标 R_{RMSE} 在不同预测步数时下降率为 29.48%、21.94%、13.74%。进一步对比 CEEMDAN-ELM 与 OVMD-ELM,OVMD-ELM 的预测性能显著优于 CEEMDAN-ELM。通过对比模型可知,EMD 的模态混叠现象是制约混合预测模型性能的原因之一,且 OVMD 的分解效果优于 CEEMDAN,时频分解方法性能越优,混合模型预测精度则越高。

(2)模型 OVMD-RES-ELM 考虑了 OVMD 分解后的残差序列,与 OVMD-ELM 模型相比,考虑残差的模型在单步和多步预测时性能进一步提升。OVMD-RES-ELM 较 OVMD-ELM 在不同预测步数时 R_{RMSE} 下降了 12.43%、11.97%、17.87%,说明经过 OVMD 分解后的残差序列包含原始序列的重要信息。模型 OVMD-TVFEEMD-ELM 将 OVMD 分解后的残差序列采用 TVFEEMD 进行二次分解,不同预测步数下的评价指标均得到有效改善,其中单步预测时,OVMD-TVFEEMD-ELM 较 OVMD-RES-ELM 的 R_{RMSE} 、 M_{MAE} 、 M_{MAPE} 分别减小了 33.07%、34.72%、34.27%。两步预测时,OVMD-TVFEEMD-ELM 较 OVMD-RES-ELM 的 R_{RMSE} 、 M_{MAE} 、 M_{MAPE} 分别减小了 39.58%、39.90%、39.92%。由此可知,OVMD 分解后的残差仍具有一定的非平稳性和非线性,对其进一步分解能有效降低序列的复杂性,进而提升模型

预测性能,验证了所提二次分解策略的有效性。

(3)对比分析所提出的 OVMD-TVFEEMD-HPO-ELM 模型,采用 HPO 智能优化算法优化 ELM 的输入权重和隐藏层阈值。由评价指标可知,经 HPO 优化后的 OVMD-TVFEEMD-ELM 组合模型预测精度最高。其中,单步预测时,OVMD-TVFEEMD-HPO-ELM 较 OVMD-TVFEEMD-ELM 的 R_{RMSE} 、 M_{MAE} 、 M_{MAPE} 分别减小了 38.22%、36.96%、36.94%, R 增加了 0.42%。两步预测时,OVMD-TVFEEMD-HPO-ELM 较 OVMD-TVFEEMD-ELM 的 R_{RMSE} 、 M_{MAE} 、 M_{MAPE} 分别减小了 23.90%、20.59%、19.38%, R 增加了 0.42%。三步预测时,OVMD-TVFEEMD-HPO-ELM 较 OVMD-TVFEEMD-ELM 的 R_{RMSE} 、 M_{MAE} 、 M_{MAPE} 分别减小了 31.47%、27.59%、27.11%, R 增加了 1.24%。试验结果说明 HPO 优化算法可有效获得 ELM 最优输入权重和隐含层阈值,提高模型的预测性能。

5 结论

a. 本文提出了一种 OVMD-TVFEEMD 二次分解策略,利用 TVFEEMD 对经过 OVMD 分解后的残余分量进行二次分解。

b. 针对原始 ELM 随机初始化输入权重和隐含层阈值导致算法不稳定,难以获得最优效果的问题,提出采用 HPO 算法优化输入权重和隐含层阈值。通过对比试验分析可知,与其他模型相比所提的 OVMD-TVFEEMD-HPO-ELM 模型具有较高的预测精度,可实现水电机组振动趋势的精准预测。

参考文献:

- [1] 杨彬,王卫玉,张培,等.基于 CEEMDAN 和混合灰狼算法优化 SVM 的水电机组故障诊断方法[J].水电能源科学,2022,40(3):195-198.
- [2] 陈畅,张毅,段炼达,等.基于改进预测模型的水电机组状态趋势预测[J].水电能源科学,2022,40(1):163-167.

- [5] 胡金弘. 水泵水轮机 S 特性及压力脉动的分析与改进[D]. 武汉: 武汉大学, 2021.
- [6] AREFI M H, GHAEINI-HESSAROEYEH M, MEMARZADEH R. Numerical modeling of water hammer in long water transmission pipeline [J]. Applied water science, 2021, 11(8): 140-150.
- [7] BERGANT A, SIMPSON A R, TIJSSELING A S. Water hammer with column separation: A historical review [J]. Journal of fluids and structures, 2006, 22(2): 135-71.
- [8] ZHANG X, CHENG Y, YANG Z, et al. Water column separation in pump-turbine after load rejection: 1D-3D coupled simulation of a model pumped-storage system [J]. Renewable energy, 2020, 163(1): 1-29.
- [9] NICOLET C, ALLIGNÉ S, BERGANT A, et al. Simulation of water column separation in Francis pump-turbine draft tube [J]. IOP conference series: Earth and environmental science, 2012, 15(2): 022002.
- [10] YANG Z, CHENG Y, XIA L, et al. Evolutions of flow patterns and pressure fluctuations in a prototype pump-turbine during the runaway transient process after pump-trip [J]. Renewable energy, 2020, 152(1): 1149-1159.
- [11] ZHANG X, CHENG Y, YANG J, et al. Simulation of the load rejection transient process of a Francis turbine by using a 1-D-3-D coupling approach [J]. Journal of hydrodynamics, 2014, 26(5): 715-724.
- [12] 冯俊, 毛秀丽, PAVESI GIORGIO, 等. 水泵水轮机甩负荷瞬态过程叶间流场分析 [J]. 水电能源科学, 2020, 38(10): 136-139, 33.
- [13] 江振瑜, 祝宝山. 水泵水轮机飞逸工况下转轮内部流动分析研究 [J]. 水电能源科学, 2022, 40(11): 181-184, 72.
- [14] 李浩亮, 何启源, 赵威. 混流式水泵水轮机轴向水推力计算方法 [J]. 水电能源科学, 2020, 38(1): 151-155.

Evolutions and Influence of Cavitation in Simultaneous Load Rejection Transients of Two Pump-turbines with Splitter Blades

WU Wei-dong¹, LI Lei¹, LIU Xu-yang¹, LIU Ke², CHENG Yong-guang², TANG Mao-jia²

(1. Luoning Pumped-storage Company Ltd., State Grid Xinyuan Company LTD., Luoning 471700, China; 2. State Key Laboratory of Water Resources and Hydropower Engineering Science, Wuhan University, Wuhan 430072, China)

Abstract: The load rejection process is one of the most dangerous transients in pumped storage hydropower plants. The current design criteria of plant guarantee that the lowest pressure in draft-tube inlet is higher than the saturation pressure during transients, but there is still local cavitation inside the pump-turbines. The one-dimensional pipeline and three-dimensional pump-turbine coupled computational fluid dynamics simulation method was used to simulate the simultaneous load rejection process in a pumped-storage hydropower plant. The results show that a spiral cavitation cavity is in the center of the draft-tube inlet, and five wedge-shaped cavitation cavities are in the outlets of runner channels. The collapse of the spiral cavitation cavity in the draft-tube leads to instantaneous pulse impacts on the pressure and runner forces. There is no obvious impact when the wedge cavities collapse.

Key words: pump-turbine; simultaneous load rejection; guide-vane closure; cavitation cavity; axial forces; pressure pulsations; CFD

(上接第 207 页)

- [3] 薛小明, 曹苏群, 李超顺, 等. 基于能量熵重构与支持向量回归的水电机组状态趋势预测 [J]. 水电能源科学, 2019, 37(9): 139-142, 135.
- [4] 陆丹, 肖志怀, 刘东, 等. 基于 EEMD-GA-BP 的水电机组状态趋势预测 [J]. 中国农村水利水电, 2021(8): 186-194.
- [5] 杨华, 陈云良, 徐永, 等. 基于 VMD-HHT 方法的水电机组启动过渡过程振动信号分析研究 [J]. 工程科学与技术, 2017, 49(2): 92-99.
- [6] 付文龙, 周建中, 张勇传, 等. 基于 OVMD 与 SVR 的水电机组振动趋势预测 [J]. 振动与冲击, 2016, 35(8): 36-40.
- [7] 袁建成, 邓玉敏, 张雪桂, 等. 基于 VMD-GA-BP 和误差校正的水电机组振动趋势预测 [J]. 中国农村水利水电, 2023(1): 176-180, 184.
- [8] DRAGOMIRETSKIY K, ZOOSO D. Variational mode decomposition [J]. IEEE transactions on signal processing, 2014, 62(3): 531-544.
- [9] NARUEI I, KEYNIA F, SABBAGH MOLAHOSSEINI A. Hunter-prey optimization: algorithm and applications [J]. Soft computing, 2022, 26: 1279-1314.

Vibration Trend Prediction of Hydropower Units Based on OVMD-TVFEMD Secondary Decomposition and HPO-ELM

ZHANG Nan^{1a}, ZHU Yong-qi^{1a}, SUN Na^{1b}, LAI Xin-jie², LI Chao-shun³

(1a. Jiangsu Key Laboratory of Advanced Manufacturing Technology; b. Faculty of Automation, Huaiyin Institute of Technology, Huaian 223299, China; 2. Power China Huadong Engineering Corporation Limited, Hangzhou 311122, China; 3. School of Civil and Hydraulic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: In order to address the limitations of the existing vibration trend prediction model for hydroelectric units, a vibration trend prediction method for hydroelectric units based on optimal variational mode decomposition (OVMD), time-varying filter empirical mode decomposition (TVFEMD), hunter-prey optimization algorithm (HPO), and extreme learning machine (ELM) is proposed. This method first applies OVMD to adaptively decompose the original vibration signal of the hydroelectric unit, and then further employs TVFEMD to perform a secondary decomposition of the residuals obtained from the first decomposition. Subsequently, vibration trend prediction models HPO-ELM are established for each subsequence. The final predicted vibration signal is obtained by aggregating and reconstructing the prediction results of all the sub-sequences. The research results demonstrate that this method outperforms traditional methods in terms of prediction accuracy for the vibration trend of hydroelectric units, and it has good engineering application value.

Key words: vibration trend prediction of hydropower unit; OVMD; secondary decomposition; ELM; optimization algorithm