

DOI: 10. 20040/j. cnki. 1000-7709. 2023. 20222408

# 基于 VMD-CIMFs-TCN 的水电机组振动预测

陈天涯<sup>1</sup>, 陈 盛<sup>1</sup>, 郑 阳<sup>1</sup>, 王卫玉<sup>2</sup>, 陈启卷<sup>1</sup>

(1. 武汉大学动力与机械学院, 湖北 武汉 430072; 2. 五凌电力科技有限公司, 湖南 长沙 410004)

**摘要:** 针对水电机组振动信号的非线性和非平稳性及预测的时效性要求, 提出了基于 VMD-CIMFs-TCN 的水电机组振动预测模型。首先采用 VMD 算法对振动信号进行分解得到信号失真度最小的 IMFs 分量, 实现对振动信号的精确分解; 其次通过计算各 IMFs 分量的功率谱熵和排列熵, 实现 IMFs 分量的聚合以减小预测过程模型的计算量; 最后利用 TCN 网络实现 CIMFs 的精确预测, 并将其相加得到最终的振动信号预测结果。分析表明, 该方法在保证预测精度的前提下缩短了预测所需的时间, 满足了预测模型的时效性。

**关键词:** 振动信号; 本征模态函数聚合; 变分模态分解; 时序卷积网络; 趋势预测

**中图分类号:** TV734      **文献标志码:** A      **文章编号:** 1000-7709(2023)09-0159-05

## 1 引言

水电机组振动信号可有效反映机组的运行状态, 通过对机组振动趋势的准确预测可得出机组下一时刻的状态信息, 有助于提早发现设备运行的异常状况, 及时制定维护方案。然而水电机组的振动信号具有明显的非线性和非平稳性, 往往较难精确预测振动信号。付文龙<sup>[1]</sup>利用 EEMD 将振动信号分解成 IMFs 分量, 并根据 IMFs 的频率信息和能量成分将其分成低频、中频、高频、低能和高能, 再根据频率成分和能量将 IMFs 重构采用 SVM 进行预测并取得了不错的效果; 傅质馨等<sup>[2]</sup>利用 EEMD 将水电机组水导轴承的振动信号分解成多个 IMF 分量, 并采用长短期记忆网络准确刻画了水导轴承的劣化趋势, 但 EEMD 分解后会残留高斯白噪声, 对预测结果产生影响; 袁成建等<sup>[3]</sup>对原始信号进行 VMD 分解, 对每个 IMFs 分量建立 GA-BP 网络进行预测, 再将各 IMFs 分量的合成信号与原始信号之间的误差同样利用 VMD-GA-BP 模型进行预测, 预测结果与振动信号预测结果相加得到最终预测结果, 但其运算量过大, 预测所需时间过长。为此, 本文提出了基于 VMD-CIMFs-TCN 的水电机组振动预测

模型, 在确保预测精度的前提下利用 IMFs 的聚合减小模型计算量, 实现了预测模型的实时性。

## 2 研究方法

### 2.1 VMD 算法

VMD 是一种以经典纳维滤波、希尔伯特变换和频率混合为基础的自适应、完全非递归的模态变分和信号处理的方法<sup>[4]</sup>。其分解过程本质上为变分问题的求解过程, 变分模型为:

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

式中,  $\{u_k\} = \{u_1, u_2, \dots, u_K\}$ 、 $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_K\}$  分别为信号分解出的  $K$  个 IMFs 分量和对应的中心频率;  $\|x(t)\|_2^2 = \langle x(t), x(t) \rangle$ ,  $\langle x(t), x(t) \rangle$  为内积;  $\partial_t$  为对时间  $t$  做偏导计算;  $\delta(t)$  为单位脉冲函数;  $j$  为虚数;  $*$  为卷积计算;  $f$  为原始信号。

为求解变分模型, 引入二次惩罚项  $\alpha$  和拉格朗日乘法算子  $\lambda(t)$  使变分模型无约束化。二次惩罚项可保证信号在重构时的高保真度, 拉格朗

收稿日期: 2022-11-15, 修回日期: 2022-12-19

基金项目: 湖北省博士后科技活动项目择优资助(2018-73)

作者简介: 陈天涯(1998-), 男, 硕士研究生, 研究方向为流体机械状态监测与故障诊断, E-mail: 347963359@qq.com

通讯作者: 陈启卷(1963-), 男, 博士、教授、博导, 研究方向为水电机组在线监测、诊断与控制 and 波力发电, E-mail: qjchen@whu.edu.cn

日算子  $\lambda(t)$  保证了约束的严格性,拉格朗日增广算子为:

$$L(\{u_k\}, \{\omega_k\}, \lambda) :=$$

$$\alpha \sum_{k=1}^K \|\partial_t \left[ \left( \delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \|_2^2 + \|f(t) - \sum_{k=1}^K u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \quad (2)$$

式中,  $L$  为拉格朗日增广算子;  $\lambda$  为拉格朗日乘数。

采用交替方向乘子法 (ADMM) 求解式 (2), 对  $u_k$ 、 $\omega_k$ 、 $\lambda$  进行迭代寻优, 计算公式为:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

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

$$\hat{\lambda}^{n+1}(\omega) = \hat{\lambda}^n(\omega) + \tau \left( \hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega) \right) \quad (5)$$

式中,  $\hat{u}_k^{n+1}$  为第  $n+1$  次迭代中的第  $k$  个 IMF 分量;  $\omega_k^{n+1}$  为  $\hat{u}_k^{n+1}$  对应的中心频率;  $\hat{\lambda}^{n+1}(\omega)$  为第  $n+1$  次迭代的拉格朗日算子值;  $\tau$  为信号的噪声容差。

到达迭代次数上限或收敛条件时结束迭代, 收敛条件为:

$$\sum_{k=1}^K \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \epsilon \quad (6)$$

式中,  $\epsilon$  为判别精度。

## 2.2 TCN 网络

时间卷积网络 (TCN) 是以卷积神经网络为基础改进得到的用于处理时间序列问题的网络<sup>[5]</sup>。TCN 模型引入因果卷积实现了时间序列预测的能力并避免了信息泄露; 引入了空洞卷积扩大了感受野并避免了计算量的爆发式增长; 引入了残差连接改善了网络退化问题。

## 2.3 熵与 IMFs 聚合

振动信号经 VMD 分解后可得多个 IMFs 分量, 将所有 IMFs 分量输入预测模型进行预测会导致模型计算量过大, 计算时间过长, 无法保证预测的实时性。因此本文提出了基于熵值计算的 IMFs 聚合方法, 通过功率谱熵<sup>[6]</sup>和排列熵<sup>[7]</sup>将 IMFs 分量划分为不同的区间, 将相同区间的 IMFs 分量进行聚合形成新的 CIMFs 分量, 减少了模型的计算量, 大大缩减了模型的预测时间。

## 2.4 基于 VMD-CIMFs-TCN 的振动预测模型

基于 VMD-CIMFs-TCN 的水电机组振动预测模型具体计算步骤如下。

**步骤 1** 根据 VMD 算法分解出的 IMFs 分量的中心频率和重构误差确定 VMD 分解的三个重要参数模态数  $K$ 、惩罚系数  $\alpha$  和收敛容差  $\tau$ 。

**步骤 2** 采用 VMD 算法对振动波形进行分解, 得到  $K$  个 IMFs 分量。

**步骤 3** 计算各个 IMFs 分量的功率谱熵和排列熵, 根据计算结果对 IMFs 分量进行聚合形成 CIMFs。

**步骤 4** 将聚合的 CIMFs 输入 TCN 模型中进行预测。

**步骤 5** 将预测结果相加得到最终的波形预测结果值。

该预测模型的流程见图 1。模型采用均方根误差 ( $R_{RMSE}$ ) 和平均绝对误差 ( $M_{MAE}$ ) 评价预测结果。

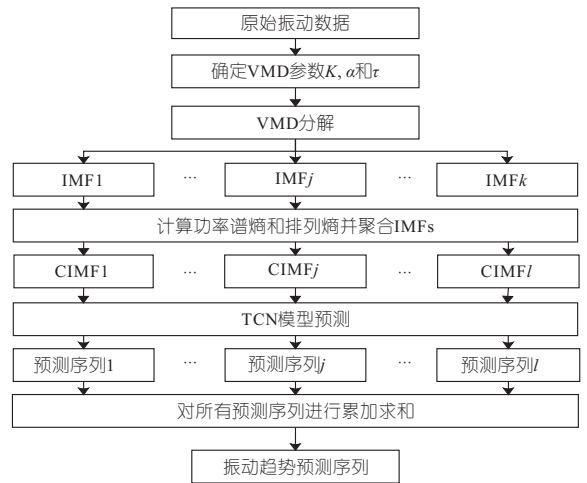


图 1 预测模型流程图

Fig. 1 Flow chart of forecast model

## 3 实例分析

### 3.1 数据来源

本文数据来源于某水电站的三号机组, 水轮机型号为 ZZA315-LJ-800, 发电机型号为 SF200-56/11 950, 额定功率 200 MW, 立轴半伞式机组。分析数据为机组轴向振动波形数据, 将波形数据按照 8 : 2 的比例划分为训练集和测试集, 具体数据见图 2。




图 2 原始振动波形

Fig. 2 Original vibration waveform

### 3.2 VMD 参数确定

VMD 分解所需确定的重要参数为模态数

$K$ 、惩罚系数  $\alpha$  和收敛容差  $\tau$ 。当  $K$  值较大时,分解出的 IMF<sub>s</sub> 分量会包含没用的虚假分量增加预测模型的计算时间,相邻的 IMF<sub>s</sub> 分量的中心频率会出现聚集现象;当  $K$  值较小时,会造成分解不充分,导致模态混叠现象。惩罚系数  $\alpha$  决定着 IMF<sub>s</sub> 分量的带宽影响数据的保真度,惩罚系数  $\alpha$  越小,各 IMF<sub>s</sub> 分量的带宽越大,过大的带宽会使得某些分量包含其他分量信号; $\alpha$  值越大,各 IMF<sub>s</sub> 分量的带宽越小,过小的带宽是使得被分解的信号中某些信号丢失。收敛容差  $\tau$  是 VMD 分解的停止条件之一,不同的  $\tau$  值会产生不同的分解残差,对 VMD 的分解结果产生影响。

为获得合适的 VMD 分解参数,通过 IMF<sub>s</sub> 分量的中心频率和分解结果重构后与原始信号的失真程度确定 VMD 分解的参数。首先计算  $K = 5, 6, 7, 8, 9$  时的各个 IMF<sub>s</sub> 分量的中心频率,见表 1。由表 1 可看出,当  $K = 9$  时 IMF7、IMF8 的中心频率相近,故  $K$  先确定为 8;根据表 2 的序号 1~5 可看出,在  $\alpha, \tau$  相同的情况下, $K = 8$  时模态函数的重构误差最小;序号 6~10 可确定惩罚系数  $\alpha = 900$  时信号失真程度最小;从序号 11~15 中可得知当  $K = 8, \alpha = 900$ 、收敛容差  $\tau = 0.5$  时,信号重构误差最小,VMD 分解结果见图 3。

表 1 各 IMF<sub>s</sub> 中心频率

Tab. 1 The central frequencies of each IMF<sub>s</sub>

模态数 $K$	中心频率					
5	108.428	66.707	34.049	21.820	3.852	
6	164.397	115.405	79.663	34.949	21.828	3.859
7	171.618	129.576	96.523	63.191	33.540	21.788 3.830
8	182.353	133.418	100.530	73.559	55.042	32.942 21.777 3.807
9	175.096	131.981	100.923	74.878	56.842	36.059 29.753 21.754 3.722

表 2 VMD 分解失真程度

Tab. 2 The distortion levels of variational mode decomposition

序号	参数	$R_{RMSE}$	$M_{MAE}$
1	$K = 6, \alpha = 800, \tau = 0.5$	0.518	0.405
2	$K = 7, \alpha = 800, \tau = 0.5$	0.679	0.540
3	$K = 8, \alpha = 800, \tau = 0.5$	0.389	0.308
4	$K = 9, \alpha = 800, \tau = 0.5$	0.774	0.623
5	$K = 10, \alpha = 800, \tau = 0.5$	0.996	0.796
6	$K = 8, \alpha = 600, \tau = 0.5$	0.365	0.289
7	$K = 8, \alpha = 700, \tau = 0.5$	0.486	0.382
8	$K = 8, \alpha = 800, \tau = 0.5$	0.388	0.308
9	$K = 8, \alpha = 900, \tau = 0.5$	0.300	0.242
10	$K = 8, \alpha = 1000, \tau = 0.5$	1.378	1.115
11	$K = 8, \alpha = 900, \tau = 0.3$	0.709	0.555
12	$K = 8, \alpha = 900, \tau = 0.4$	0.623	0.494
13	$K = 8, \alpha = 900, \tau = 0.5$	0.300	0.242
14	$K = 8, \alpha = 900, \tau = 0.6$	0.659	0.525
15	$K = 8, \alpha = 900, \tau = 0.7$	0.525	0.411




图 3 VMD 分解图

Fig. 3 Variational mode decomposition

### 3.3 熵值计算与 IMF<sub>s</sub> 聚合

分别计算各个 IMF<sub>s</sub> 分量的功率谱熵和排列熵并将熵值归一化,计算结果见表 3(功率谱熵表征各 IMF<sub>s</sub> 分量的频率成分分布情况)。由表 3 可看出,IMF1、IMF2 功率谱熵值大,信号频率成分分布广;IMF3-6 功率谱熵中等;IMF7、IMF8 功率谱熵小,信号频率组成简单,故根据功率谱熵大小将 IMF<sub>s</sub> 分量分成三类。同理根据排列熵大小可将 IMF 分量分成三类:IMF1-5 排列熵值大分为一类;IMF6 排列熵中等分为一类;IMF7-8 排列熵值小分为一类。根据聚合策略将 8 个 IMF 分量进行聚合,聚合结果见表 4。由表 4 可看出,8 个 IMF 分量聚合成为 4 个 CIMF 分量,其中 CIMF1 包含 IMF1、IMF2,其功率谱熵和排列熵均为高;CIMF2 包含 IMF3、IMF4、IMF5,其功率谱熵为中,排列熵为高;CIMF3 仅由 IMF6 构成,其功率谱熵和排列熵均为中;CIMF4 由 IMF7、IMF8 聚合而成,其功率谱熵和排列熵均为低,聚合后的 CIMFs 见图 4。

表 3 各 IMF<sub>s</sub> 分量功率谱熵及排列熵值

Tab. 3 The power spectral entropy and permutation entropy of IMF<sub>s</sub>

IMF 分量编号	功率谱熵	排列熵	IMF 分量编号	功率谱熵	排列熵
1	$1.000(H_{psdE})$	$0.962(H_{perE})$	5	$0.493(M_{psdE})$	$0.873(H_{perE})$
2	$0.719(H_{psdE})$	$1.000(H_{perE})$	6	$0.529(M_{psdE})$	$0.517(M_{perE})$
3	$0.567(M_{psdE})$	$0.983(H_{perE})$	7	$0.000(L_{psdE})$	$0.138(L_{perE})$
4	$0.545(M_{psdE})$	$0.869(H_{perE})$	8	$0.252(L_{psdE})$	$0.000(L_{perE})$

表 4 IMF<sub>s</sub> 分量聚合结果

Tab. 4 The result of IMF<sub>s</sub> clustering

CIMF 分量	所包含的 IMF 分量	功率谱熵与排列熵值大小
CIMF1	IMF1, IMF2	$H_{psdE}, H_{perE}$
CIMF2	IMF3, IMF4, IMF5	$M_{psdE}, H_{perE}$
CIMF3	IMF6	$M_{psdE}, M_{perE}$
CIMF4	IMF7, IMF8	$L_{psdE}, L_{perE}$




图 4 IMF<sub>s</sub> 分量聚合结果

Fig. 4 The result of IMF<sub>s</sub> clustering

### 3.4 预测结果及分析

将聚合后的 CIMFs 分量输入 TCN 网络中, 各 CIMFs 预测结果和原始信号的振动趋势预测结果见图 5, 其中 ‘\*’ 为实际波形, ‘o’ 为预测波形。由图 5 可看出, CIMF1 信号波动频率较高, 预测结果并不十分理想, 而 CIMF3、CIMF4 因其信号较平稳则有不错的预测效果。由图 6(a) 可看出, 预测序列和实际序列的波形基本吻合, 两者之间误差较小, 预测序列和实际序列的均方根误差为 1.88, 因此证明了本文所提方法在水电机组振动趋势预测上精确性。




图 5 CIMFs 预测结果

Fig. 5 Prediction of CIMFs




图 6 预测结果

Fig. 6 The prediction result

图 6(b) 为 VMD 分解后直接输入 TCN 网络中预测的结果, 因 IMF<sub>s</sub> 分量的波动性较聚合后的 CIMFs 分量较小, 故在预测结果上其预测结果与实际误差较小, 均方根误差为 1.11, 但两者预

测在耗时上相差较大, 可见本文所提方法较原始预测方法耗时时间减少一倍。

为验证本文所提方法的优越性, 将 VMD-BP、VMD-ELM 分别与 VMD-CIMFs-BP、VMD-CIMFs-ELM 进行对比以证明该方法在尽量保证预测精度的前提下缩短了预测时间; 将 VMD-CIMFs-BP、VMD-CIMFs-ELM 与本文所提方法进行对比以证明 TCN 网络预测效果的优越性, 计算结果见表 5。由表 5 可看出, 在确保预测精度的前提下, 本文所用的 IMF<sub>s</sub> 聚合方法可减少模型预测所用的时间; 且 TCN 网络的预测能力强于 BP、ELM。

表 5 不同预测模型对比分析

Tab. 5 Comparison of different forecast model

预测模型	$R_{RMSE}$	$M_{MAE}$	耗时/s	提速/%
VMD-TCN	1.114	0.892	16.24	49.4
VMD-CIMFs-TCN	1.529	1.108	8.21	
VMD-ELM	4.191	3.447	1.54	53.9
VMD-CIMFs-ELM	5.553	4.415	0.71	
VMD-BP	2.132	1.787	6.13	46.5
VMD-CIMFs-BP	3.201	2.490	3.28	

## 4 结论

- a. 本文提出的 IMF<sub>s</sub> 聚合方法可保证在预测精度的情况下大大缩短模型预测所需的时间。
- b. 时序卷积神经网络(TCN)在水电机组振动信号预测方面较 BP、ELM 有较大的优势。
- c. 本文提出的基于 VMD-CIMFs-TCN 的水电机组振动预测模型在保证预测精度的前提下缩短了预测所需的时间, 满足了预测模型的时效性。

## 参考文献:

- [1] 付文龙. 水电机组振动信号分析与智能故障诊断方法研究[D]. 武汉: 华中科技大学, 2016.
- [2] 傅质馨, 殷贵, 朱俊澎, 等. 基于 EEMD 和 LSTM 的水电机组劣化度预测方法研究[J]. 太阳能学报, 2022, 43(2): 75-81.
- [3] 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.
- [4] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. IEEE transactions on signal processing, 2013, 62(3): 531-544.
- [5] BAI S J, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. <http://arXiv.org/abs/1803.01271>, 2018.

