

DOI:10.20040/j.cnki.1000-7709.2023.20221389

基于 WOA-VMD-TCN 的水电机组振动趋势预测

王 璞¹, 姬联涛², 陈龙翔¹, 荆岫岩¹, 袁成建³, 李超顺³

(1. 国家电网有限公司, 北京 100031; 2. 中国电力科学研究院有限公司, 北京 100192;
3. 华中科技大学土木与水利工程学院, 湖北 武汉 430074)

摘要:水电机组振动趋势预测是保障机组正常运行的重要举措,但由于机组振动信号的复杂性和非平稳性使得准确预测成为难题。为此,提出一种基于自适应变分模态分解和时间卷积网络(TCN)的组合趋势预测模型。首先利用鲸鱼群算法(WOA)优化选择变分模态分解(VMD)参数,避免盲目选择参数的弊端,实现振动信号的最优自适应分解,然后对分解后的每个分量信号进行归一化处理并建立 TCN 进行趋势预测,最后将所得结果叠加即可得到原振动信号预测结果。以国内某电站实际运行数据对所提模型进行论证试验,结果表明所提模型具有较高的预测精度,可用于工程实际。

关键词: 振动信号; 鲸鱼群算法; VMD; 趋势预测; TCN

中图分类号: TV3 **文献标志码:** A **文章编号:** 1000-7709(2023)06-0175-05

1 引言

水电机组作为水电站的核心设备,是电网调峰调频的关键,其安全稳定运行不仅关系着整个电厂的安全甚至影响着电网的稳定。机组在运行过程中会受到水力、机械、电气等多方面的作用,在经过长期的运转后内部会出现疲劳老化、部件松动、绝缘破坏等现象,严重影响机组的安全稳定运行^[1]。研究表明,机组 80% 的故障问题均可由机组的振动信号来反映,因此构建机组的振动趋势预测模型,提前预知机组存在的问题,对于保障机组安全十分必要^[2]。目前较为常见的振动趋势预测方法包括回归模型、支持向量机和神经网络等。古丽等^[3]利用 ARMA 构建了输油泵的振动值趋势预测模型,较好地拟合了输油泵振动信号特征值;付文龙等^[4]利用 OVMD 和 SVR 预测了水力发电机组的振动趋势;陆丹等^[5]结合 EEMD 和 GA-BP 神经网络预测了水电机组振动状态趋势。上述方法虽然能在一定程度上预测机组的振动趋势,但预测精度还有待提高。为此,本文提出一种基于 WOA-VMD-TCN 的水电机组振动趋势预测模型,即先使用鲸鱼群算法(WOA)对变分

模态分解(VMD)参数进行优化选择,实现振动信号的自适应分解,避免了人工选择参数所导致的不确定性,然后对分解所得的每个 IMF 分量构建时间卷积网络,实现对每个分量信号的趋势预测,最后将所得结果进行叠加得到最终的振动趋势预测结果。试验表明所提的 WOA-VMD-TCN 可以实现振动信号的自适应分解并有效预测水电机组振动趋势,相较于其他模型具有更高的精度。

2 研究方法

2.1 鲸鱼群算法

鲸鱼群算法(WOA)模拟了座头鲸特有的猎物搜索方法和包围捕食机制,主要包括围捕猎物、气泡网捕食、搜索猎物三个过程^[6]。WOA 中每个座头鲸的位置表示一个潜在解,通过在解空间不断更新鲸鱼的位置,最终获得全局最优解。由于其拥有多种搜索策略,因此更易找到全局最优解,这使其相较传统算法具有更好的优势。

(1) 围捕猎物。鲸鱼的搜索范围是全局解空间,首先需要定位目标猎物,以便展开围堵。然而最优解即猎物在全局解空间中的方位是不确定的,对此 WOA 方法假定当前的最佳候选解为猎

收稿日期: 2022-07-08, 修回日期: 2022-08-16

基金项目: 国家自然科学基金项目(51879111)

作者简介: 王璞(1985-),男,高级工程师,研究方向为常规水电及抽水蓄能运行维护管理,E-mail:67699531@qq.com

通讯作者: 李超顺(1983-),男,教授,研究方向为水电、风电等清洁能源优化运行与控制、发电设备智能维护及人工智能的应用,E-mail:csli@hust.edu.cn

物位置。当最优搜索个体被确定后,其余搜索个体将会试图将其位置更新到最佳搜索个体处。该过程表现为:

$$D = |CX^*(t) - X(t)| \quad (1)$$

$$X(t+1) = X^*(t) - AD \quad (2)$$

其中 $A = 2ar_1 - a$; $C = 2r_2$
 式中, D 为包围步长; t 为迭代次数; $X^*(t)$ 为当前得到的最优解的位置向量; $X(t)$ 为搜索个体的位置向量; A 、 C 均为系数向量; a 为随着迭代过程的进行由 2 线性降到 0; r_1 、 r_2 均为 $[0, 1]$ 区间中的随机数。

(2) 气泡网捕食。座头鲸捕食主要有包围捕食和气泡网捕食两种机制。采用气泡网捕食时,座头鲸与猎物间的位置更新用对数螺旋方程表达,即:

$$X(t+1) = D' e^{bl} \cos 2\pi l + X^*(t)$$

$$D' = |X^*(t) - X(t)| \quad (3)$$

式中, D' 为当前搜索个体与当前最优解的距离; b 为螺旋形状参数; l 为值域在 $[-1, 1]$ 之间均匀分布的随机数。

由于靠近猎物过程中有两种捕食行为,因此 WOA 根据概率 p 来选择气泡网捕食或收缩包围,位置更新公式为:

$$X(t+1) = \begin{cases} X^*(t) - AD & p < 0.5 \\ D' e^{bl} \cos 2\pi l + X^*(t) & p \geq 0.5 \end{cases} \quad (4)$$

式中, p 为捕食机制概率,值域为 $[0, 1]$ 的随机数。

(3) 搜索猎物。为保证所有鲸鱼能在解空间中充分搜索,WOA 根据鲸鱼彼此之间的距离来更新位置,达到随机搜索的目的。因此,当 $|A| \geq 1$ 时,搜索个体会游向随机鲸鱼个体。

$$D'' = |CX_{rand}(t) - X(t)|$$

$$X(t+1) = X_{rand}(t) - AD \quad (5)$$

式中, D'' 为当前搜索个体与随机个体的距离; $X_{rand}(t)$ 为当前随机个体的位置。

2.2 WOA-VMD

变分模态分解(VMD)^[7]作为一种非递归的信号分解算法,可将复杂程度高、非线性强的非平稳时间序列分解为多个频率不同、相对平稳的子序列。相较于传统的经典递归算法 LMD、EMD,可在一定程度上规避模态混叠现象和边界效应等问题。然而,VMD 对信号的分解层数 K 和惩罚因子 α 需要人为选择, K 值选择过小会使信号分解不完全,造成模态混叠,选择过大则会出现失真现象; α 选择过小会出现频率交叉现象,而选择过大则会出现虚假分量现象^[8]。因此,有必要确定最佳的参数组合 $[K, \alpha]$ 。为此,本文提出一种使

用 WOA 优化 VMD 参数选择的自适应变分模态分解方法,即采用局部包络熵的极小值为适应度函数优化选取 VMD 分解参数。原始振动信号经 VMD 分解得到各个 IMF 分量,包络熵的计算公式为:

$$\begin{cases} E_i = - \sum_{j=1}^N p_{i,j} \lg p_{i,j} \\ p_{i,j} = a_i(j) / \sum_{j=1}^N a_i(j) \end{cases} \quad (6)$$

式中, i 为分解层数; $a_i(j)$ 为 IMF 分量经希尔伯特变换后得到的包络信号。

包络熵可以反映信号的随机性和复杂性,经过 VMD 分解的 IMF 分量信号的局部包络熵越小,分量信号越简单,复杂程度越低,规律性越强,因此选择包络熵极小值作为 WOA 算法的适应度函数。

WOA 优化 VMD 具体流程见图 1。

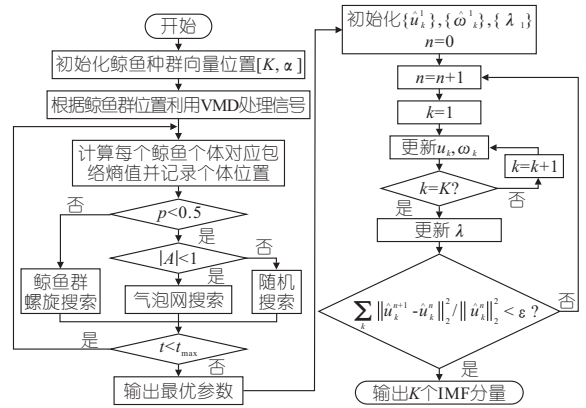


图 1 WOA-VMD 步骤
 Fig. 1 WOA-VMD steps

2.3 时间卷积网络 TCN

时间卷积网络(TCN)是采用因果卷积和空洞卷积的深度学习模型,能够适应时序数据的时序性,为时序建模提供视野域。因果卷积中某个时刻 t 的输出只取决于 t 时刻之前的输入,而与未来时刻的信息无关^[9]。通常希望能够尽可能地利用较长的时间信息,然而追溯的时间信息越久,网络的隐藏层就越多,网络就越复杂,不利于训练。对此,提出了空洞卷积。因果空洞卷积结构见图 2。




图 2 因果空洞卷积
 Fig. 2 Dilated causal conv

空洞卷积^[10]与普通卷积不同的是空洞卷积

根据给定的参数 d 来间隔选择输入以增加接受域的大小,让每个卷积的输出都包含了较大范围的信息。图 2 中 d 依次为 1、2、4。对于时间序列输入 x_t ,因果空洞卷积计算公式为:

$$F(t) = \sum_{i=0}^{k-1} f(i)x_{t-di} \quad (7)$$

式中, d 为空洞系数; k 为卷积核大小; $f(i)$ 为卷积核中第 i 个元素。

为了避免网络训练出现梯度消失和网络退化,TCN 网络采用残差连接。整个残差网络使用跳跃连接来加速训练过程,避免深度模型梯度消失及网络退化问题。TCN 架构中的残差模块见图 3。




图 3 TCN 残差块

Fig. 3 TCN residual block

每个残差模块包含两个因果空洞卷积层,并加入权重归一化来解决梯度爆炸问题;另外为了避免网络过于复杂,使用 Relu 激活函数来引入非线性;最后利用 Dropout 正则化来避免网络过拟合。

3 WOA-VMD-TCN 水电机组振动趋势预测模型

由于水电机组工作环境复杂,受干扰较多,因此机组振动信号呈现较强非线性和非平稳性。如果采取直接预测的方式,往往难以满足工程实际需要。为此,结合鲸鱼群算法解决寻优问题的能力,及 VMD 对非平稳信号的强大处理能力和 TCN 的时序数据处理能力,提出了基于 WOA-VMD-TCN 的水电机组振动趋势预测模型。其整体流程见图 4。首先,采用 WOA 优化选取 VMD 分解参数 $[K, \alpha]$,自适应地分解振动信号,避免人工选择参数导致的不确定性。然后就所得




图 4 WOA-VMD-TCN 流程图

Fig. 4 WOA-VMD-TCN flow chart

每个 IMF 分量进行归一化处理并构建时间卷积网络进行预测。最后将所有结果叠加得到原始振动信号预测结果。

WOA-VMD-TCN 具体实施步骤如下。

步骤 1 以局部包络熵作为适应度函数,使用鲸鱼群算法对 VMD 分解参数 K, α 进行优化选择。

步骤 2 利用选定参数的 VMD 对原始振动信号进行信号分解,得到多个 IMF 分量。

步骤 3 对分解所得各分量进行归一化处理。

步骤 4 对归一化后的数据划分输入矩阵和输出矩阵。设各 IMF 分量序列为 $\{x_1, x_2, x_3, \dots, x_n\}$, n 为总的时间序列长度。设输入数据长度为 m ,则可构建输入输出矩阵为:

$$\begin{bmatrix} x_1 & x_2 & \dots & x_m & x_{m+1} \\ x_2 & x_3 & \dots & x_{m+1} & x_{m+2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{n-m} & x_{n-m+1} & \dots & x_{n-1} & x_n \end{bmatrix} \quad (8)$$

其中矩阵的前 m 列为网络的输入,最后 1 列为网络的输出,矩阵前 $0.8(n-m)$ 行作为训练数据,用来训练所搭建的神经网络,后 $0.2(n-m)$ 作为测试数据^[11],用来测试网络的预测效果。

步骤 5 针对每个 IMF 分量构建 TCN 进行预测。网络输入层神经元数由输入数据长度 m 决定,输出层包含 1 个神经元,隐藏层神经元 h 计算公式^[12]为:

$$h = \lfloor \sqrt{m+1} \rfloor + c \quad (9)$$

式中, c 为 1~10 之间的整数; $\lfloor \sqrt{m+1} \rfloor$ 为不超过 $\sqrt{m+1}$ 的最大整数值,通过训练集训练获得训练集均方误差,确定隐藏层节点数。

步骤 6 对各 IMF 分量预测进行反归一化操作。

步骤 7 将反归一化后的预测结果进行累加得到最终的预测结果。

步骤 8 将预测结果与实际数据进行比较,计算误差指标评估预测模型性能。

4 实例分析

为验证所提 WOA-VMD-TCN 水电机组趋势预测模型的预测性能,选取国内某水电站 3 号机组 2018 年 10 月 1 日到 2019 年 10 月 1 日间监测系统上导轴承 x 向摆度实时监测数据,共 326 次开停机过程,对每次开停机过程上导 x 向摆度峰峰值取均值,构建机组振动趋势序列,以此为基础进行验证试验。

4.1 时序数据处理

构建 WOA-VMD 对原始振动序列进行自适

应分解,设置 VMD 参数寻优范围模态分量个数 K 为 3~15,惩罚因子 α 为 500~3 000。经过 WOA 算法优化后所得分解参数 $K=13, \alpha=1 600$,分解得到 12 个 IMF 分量和 1 个残差分量。随后,对分解所得各分量进行归一化处理,以提高 TCN 对时序数据的处理效率,最后将各分量预测所得结果进行反归一化操作,然后累加便可得到振动信号预测结果。

4.2 试验结果

对经 WOA-VMD 分解得到的 IMF 分量构造输入输出矩阵,并建立 TCN 进行预测。将各 IMF 分量预测所得结果累加得到原始振动信号预测结果。另外,为验证所提 WOA-VMD-TCN 水电机组振动趋势预测模型的优越性,分别设计了不同分解参数的 VMD-TCN 模型进行验证。各模型参数设置及预测结果误差见表 1。由表 1 可看出,WOA-VMD 所得的分解参数 $K=13, \alpha=1 600$ 的预测结果误差均小于其他几组参数,当 K 值增大到 15 时,预测结果误差变化很小, M_{MAE} 只减小了 1.1%,因此可认为 $K=13$ 时信号已分解完全。由此可得,WOA-VMD-TCN 预测模型可以实现振动信号的最优自适应分解预测。

表 1 不同参数 VMD-TCN 预测结果误差
Tab.1 Prediction error of VMD-TCN with different parameters

参数	M_{MAE}	R_{RMSE}	$M_{MAPE}/\%$
$K=13, \alpha=1 600$	0.322 9	0.388 6	0.470 3
$K=13, \alpha=800$	0.478 5	0.617 9	0.702 4
$K=13, \alpha=2 400$	0.501 3	0.641 6	0.728 5
$K=12, \alpha=1 600$	0.391 8	0.493 9	0.567 6
$K=11, \alpha=1 600$	0.426 2	0.534 4	0.628 4
$K=15, \alpha=1 600$	0.319 2	0.382 4	0.470 0

注: M_{MAE} 、 R_{RMSE} 、 M_{MAPE} 分别为平均绝对误差、均方根误差、平均绝对百分比误差。

为了进一步验证 WOA-VMD-TCN 预测模

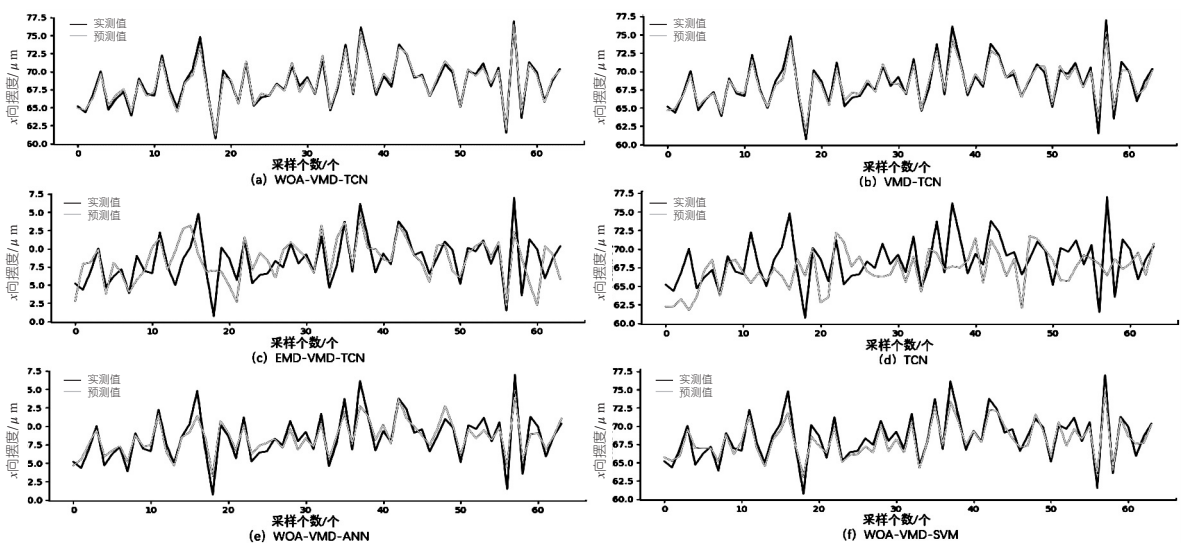


图 5 各模型预测结果对比

Fig. 5 Comparison of prediction results of each model

型的有效性,分别设计了 WOA-VMD-ANN、WOA-VMD-SVM、VMD-TCN、EMD-TCN 及 TCN 五种预测算法作为对比试验组,其中 VMD-TCN 参数为 $K=13, \alpha=2 400$ 。各模型预测误差见表 2。由表 2 可看出,所提 WOA-VMD-TCN 模型各项误差指标均明显低于其他模型。对比分析 WOA-VMD-TCN、VMD-TCN、EMD-TCN 及 TCN 可知,经过 WOA-VMD 分解处理后振动信号的预测误差有大幅度降低,相比 TCN、EMD-TCN、VMD-TCN 模型 M_{MAE} 分别降低了 88.7%、84.0%、35.6%。通过对比 WOA-VMD-TCN、WOA-VMD-SVM、WOA-VMD-ANN 可知,在经过 WOA-VMD 相同处理后 WOA-VMD-TCN 模型的预测结果精度明显高于 WOA-VMD-SVM、WOA-VMD-ANN, M_{MAE} 分别降低了 64.6%、67.4%。由此可见,所提 WOA-VMD-TCN 组合模型在水电机组振动趋势预测方面具有优异性能,预测精度大幅提高。

表 2 各模型预测误差

Tab.2 The prediction error of each model

模型	M_{MAE}	R_{RMSE}	$M_{MAPE}/\%$
WOA-VMD-TCN	0.322 9	0.388 6	0.470 2
VMD-TCN	0.501 3	0.641 6	0.728 5
WOA-VMD-SVM	0.888 5	1.107 3	1.293 6
WOA-VMD-ANN	0.992 7	1.245 4	1.449 0
EMD-TCN	2.017 2	2.696 3	2.943 6
TCN	2.859 6	3.569 2	4.166 9

为了更直观地展现所提模型的优异性能,将 WOA-VMD-TCN、VMD-TCN、EMD-TCN、WOA-VMD-SVM、WOA-VMD-ANN 及 TCN 预测结果绘制曲线图,见图 5。对比图 5(a)、(b)、(c)、(d)可看出,信号经过 WOA-VMD 分解后的

预测精度有较大的提升;对比图 5(a)、(e)、(f)可明显看出 WOA-VMD-TCN 预测模型的拟合程度最高,与真实值几乎重合。

综上所述,所提出的 WOA-VMD-TCN 组合趋势预测模型在水电机组振动信号预测精度上较其他模型有显著提升,预测效果优异。

5 结论

针对水电机组振动趋势难以精确预测的难题,提出一种利用鲸鱼群算法优化的自适应 VMD 分解与 TCN 相结合的水电机组振动趋势组合预测模型。通过对比试验分析表明,经 WOA 优化后的 VMD 可以实现振动信号的自适应分解,有效避免人工选择参数导致的不确定性影响。相较于现有的常用模型,所建 WOA-VMD-TCN 模型预测精度更高,能对机组振动趋势进行有效预测,对机组的状态检修有一定的参考作用。

参考文献:

[1] 游鹏,纪鸿铸,唐武强. 巨型水轮发电机组振动分析[J]. 水电与新能源, 2021,35(6): 35-38.
 [2] 桂中华,张浩,孙慧芳,等. 水电机组振动劣化预警模型研究及应用[J]. 水利学报, 2018,49(2):216-222.
 [3] 古丽,邹永胜,李开鸿,等. ARMA 模型在输油泵振动特征值趋势预测中的研究[J]. 流体机械, 2021,49(1): 22-28.

[4] 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.
 [5] 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.
 [6] 赵春华,胡恒星,陈保家,等. 基于深度学习特征提取和 WOA-SVM 状态识别的轴承故障诊断[J]. 振动与冲击, 2019,38(10): 31-37.
 [7] 胡晓,肖志怀,刘东,等. 基于 VMD-CNN 的水电机组故障诊断[J]. 水电能源科学, 2020,38(8): 137-141.
 [8] 钟奎. 基于 WOA 和 LSSVM 的短期风电功率预测[D]. 南昌:南昌大学, 2021.
 [9] 李扬帆,张凌浩,雷勇,等. 基于时间卷积网络和门控循环单元的短期用电量预测方法[J]. 水电能源科学, 2021,39(8):198-201.
 [10] 李亚平,李素杰,马波,等. 基于 TCN 的滚动轴承振动趋势与剩余寿命预测研究[J]. 现代制造工程, 2021(9):124-131.
 [11] YALONG L, FAN Y, WENTING Z, et al. Combined optimization prediction model of regional wind power based on convolution neural network and similar days[J]. Machines, 2020,8(4):2-12.
 [12] DING N, LI H, YIN Z, et al. Journal bearing seizure degradation assessment and remaining useful life prediction based on long short-term memory neural network[J]. Measurement, 2020,166 (pre-publi- sh).

Prediction of Vibration Trend of Hydroelectric Unit Based on WOA-VMD-TCN

WANG Pu¹, JI Lian-tao², CHEN Long-xiang¹, JING Xiu-yan¹, YUAN Cheng-jian³, LI Chao-shun³

(1. State Grid Corporation of China, Beijing 100031, China; 2. China Electric Power Research Institute, Beijing 100192, China; 3. School of Civil and Hydraulic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: Prediction of the vibration trend of hydropower units is an important measure to ensure the normal operation of the unit. However, due to the complexity and non-stationarity of the vibration signal of the unit, accurate prediction becomes a difficult problem. To this end, this paper proposes a combined trend prediction model based on adaptive variational modal decomposition and temporal convolutional network (TCN). Firstly, the Whale Swarm Algorithm (WOA) was used to optimize the parameters of Variational Mode Decomposition (VMD) to avoid the drawbacks of blindly selecting parameters, and to achieve adaptive decomposition of vibration signals. And then each decomposed component signal was normalized to establish TCN for trend prediction. Finally the original vibration signal prediction was obtained by superimposing the results. The proposed model was demonstrated and tested with the actual operation data of a domestic power station. The results show that the proposed model has high prediction accuracy and can be used in engineering practice.

Key words: vibration signal; whale swarm algorithm; VMD; trend prediction; TCN