DOI:10.20040/j.cnki.1000-7709.2026.20250203

基于 ICEEMDAN 和 CNN-LSTM-ATTENTION 的抽水蓄能机组振动预测

汪靖尧,冯 陈,张玉全,张永杰,罗依竟

(河海大学电气与动力工程学院,江苏 南京 211100)

摘要:抽水蓄能机组的大部分问题可通过振动信号来反映,但由于振动信号具有较强的非线性、非平稳性难以直接预测。为此,提出了一种基于改进的完全集合经验模态分解(ICEEMDAN)、卷积神经网络(CNN)、长短时记忆网络(LSTM)和注意力机制(Attention Mechanism)的抽水蓄能机组振动预测模型。该模型首先对振动信号进行 ICEEMDAN 分解,能避免模态混叠和噪声干扰;利用分解得到的 IMF 分量输入 CNN 提取特征数据,再利用 LSTM 深度挖掘时序特征;然后引入注意力机制,使模型聚焦关键输入信息,从而提高模型的预测性能;最后以国内某抽水蓄能电站的振动数据进行验证,并以均方误差、均方根误差、平均绝对误差及决定系数作为性能评价指标。结果表明,所提方法构建的模型相较于其他常规模型,具有更高的预测精度,适用于抽水蓄能机组的振动信号趋势预测。

关键词:抽水蓄能机组;振动预测;注意力机制;ICEEMDAN;CNN;LSTM

中图分类号:[TV734.2+1] **文献标志码**:A **文章编号**:1000-7709(2026)03-0194-06

Vibration Prediction of Pumped Storage Units Based on ICEEMDAN and CNN-LSTM-ATTENTION

WANG Jing-yao, FENG Chen, ZHANG Yu-quan, ZHANG Yong-jie, LUO Yi-jing

(College of Electrical and Power Engineering, Hohai University, Nanjing 211100, China)

Abstract: Most of the problems of pumped storage units can be reflected by vibration signals, but it is difficult to predict them directly due to their strong nonlinearity and non-stationarity. Therefore, a vibration prediction model for pumped storage units based on improved complete ensemble empirical modal decomposition (ICEEMDAN), convolutional neural network (CNN), long and short-term memory network (LSTM) and attention mechanism is proposed. The model firstly performs ICEEMDAN decomposition of the vibration signal, which can avoid modal aliasing and noise interference. The IMF components obtained from the decomposition are input into the CNN to extract the feature data, and the LSTM is used to deeply mine the temporal features. Then, the attention mechanism is introduced so that the model focuses on the key input information, thus improving the prediction performance of the model. Finally, the vibration data of a domestic pumped storage power station is used for validation, and the mean square error, root mean square error, average absolute error and coefficient of determination are used as the performance evaluation indexes. The results show that the proposed model has higher prediction accuracy compared with other conventional models, and it is suitable for predicting the trend of vibration signals of pumped storage units.

Key words: pumped storage units; vibration prediction; attention mechanism; ICEEMDAN; CNN; LSTM

1 引言

在当下绿色能源大发展的背景下,抽水蓄能电站发挥着调峰填谷、调频调相、旋转备用等快速响应的关键作用,是电力系统的稳定器、调节器和平衡器。由于机组运行工况复杂多变,且在运行

收稿日期:2025-02-07,**修回日期**:2025-05-28,**接受日期**:2025-05-30

基金项目:国家自然科学基金面上项目(52209110,U24B20107,52339006);湖北省自然科学基金项目(2024AFD353);江苏省创新支撑计划国际科技合作项目(BZ2023047)

作者简介:汪靖尧(2001-),男,硕士研究生,研究方向为水电机组故障诊断,E-mail:1394212673@qq.com

通讯作者:冯陈(1992-),男,副教授,研究方向为水电能源优化运行,E-mail:windycity@hhu.edu.cn

中国知网 https://www.cnki.net

中受水力、机械、电磁等因素耦合影响,不可避免地会发生异常或故障。据相关研究表明,机组约80%的故障可通过其振动信号反映[1-2],因此对抽水蓄能机组的振动信号展开研究,通过建立精准的模型预测机组振动趋势,了解机组运行状态,对保证机组运行稳定性具有十分重要的意义。由于机组的振动信号具有较强的非线性和非平稳性,采用直接预测方式可能难以取得较好的预测结果。目前主流的方法是通过时频分析的方法对振动信号进行处理,包括小波变换(WT)、经验模态分解(EMD)、变分模态分解(VMD)等[3-4]。袁成建等[5]对振动信号进行 VMD 分解,利用 IMF 分量建立 GA-BP 网络并结合误差校正的方法进行预测,取得了较为精准的预测结果。毕扬等[6]对原始振动信号进行小波阈值去噪(WTD),并结合 BIGRU 神经网络建立预测模型,有效提高了预测精度。近年来,基于深度学习的预测方法被广泛应用于水电机组振动信号趋势预测领域。姜伟等[7]提出了一种基于样本熵重构和 RF-LSTM 的混合预测模型,实现了水电机组振动信号的趋势预测;邓玉敏等[8]提出了基于 CNN-BIGRU 的振动预测方法,与传统预测模型相比,该混合预测模型具有更高的预测精度。为进一步提高预测精度,准确预测机组振动趋势,本文提出了一种基于改进的完全集合经验模态分解(ICEEMDAN)和结合注意力机制的 CNN-LSTM 的振动信号预测模型,即采用 ICEEMDAN 方法对原始振动信号进行分解,能避免 EMD(经验模态分解)、EEMD(集合经验模态分解)等方法存在的端点效应和模态混叠问题,并将分解得到的 IMF 分量输入结合注意力机制的 CNN-LSTM 神经网络中进行趋势预测;试验结果表明,本文所提出的模型,相较于其他常规方法所构建的模型,具有更高的预测精度。

2　基础理论

2.1　改进的完全集合经验模态分解

改进的完全集合经验模态分解(ICEEMDAN)是一种改进的信号分解方法,继承和优化了 EMD(经验模态分解)、EEMD(集合经验模态分解)和 CEEMDAN(完全集合经验模态分解)的优点,能够有效克服这些方法的端点效应、模态混叠问题,并提高分解的鲁棒性和稳定性[9]。ICEEMDAN 能有效避免模态混叠,提取到不同尺度下的真实信号特征;相较于 EMD、EEMD 和 CEEMDAN,ICEEMDAN 对噪声的抗干扰能力更强,分解结果更加平稳。ICEEMDAN 在保证分解质量的同时,优化了噪声的添加方式,降低了计算复杂度。这使得它在处理非线性、非平稳信号时更具优势。其具体分解步骤如下。

步骤 1　向输入信号添加高斯白噪声:

$$X_1(k)=x+\varepsilon_1 E_1(\omega_k)\quad k=1,2,\cdots,n \tag{1}$$

式中,x 为原始信号;ε_1 为第 1 次分解时信号的噪声标准差;$E_1(\cdot)$ 为 EMD 分解得到的第 1 个 IMF 分量;ω_k 为第 k 个被添加的零均值单位方差白噪声。

步骤 2　计算首次分解得到的残差 r_1:

$$r_1=\frac{1}{n}\sum_{k=1}^{n}M(x_k) \tag{2}$$

式中,$M(\cdot)$为信号的局部均值。

步骤 3　计算第 1 个 IMF 分量 I_{IMF_1}:

$$I_{\mathrm{IMF}_1}=x-r_1 \tag{3}$$

步骤 4　计算残差 r_2 和第 2 个 IMF 分量 I_{IMF_2}:

$$r_2=\frac{1}{n}\sum_{k=1}^{n}M\left[r_1+\varepsilon_2 E_2(\omega_k)\right] \tag{4}$$

$$I_{\mathrm{IMF}_2}=r_1-r_2 \tag{5}$$

步骤 5　重复迭代,直至达到终止条件时结束运算,第 i 个残差 r_i 和第 i 个 IMF 分量 I_{IMF_i} 的计算公式为:

$$r_i=\frac{1}{n}\sum_{k=1}^{n}M\left[r_{i-1}+\varepsilon_i E_i(\omega_k)\right] \tag{6}$$

$$I_{\mathrm{IMF}_i}=r_{i-1}-r_i \tag{7}$$

2.2　卷积神经网络

卷积神经网络(CNN)是一种深度学习模型,广泛应用于计算机视觉任务,如图像分类、目标检测和语音识别等。CNN 主要结构包括卷积层、池化层和全连接层。其中,主要通过卷积层提取输入数据中的局部特征,逐层抽象数据的高层次特征。池化层是对卷积后的特征进行降维,以减少特征的空间维度并减小计算量,同时保留最重要的信息。在卷积层和池化层提取特征后,通常会通过全连接层将所有特征融合在一起。全连接层是一个传统的多层感知机(MLP)结构,负责将抽象的特征转化为预测结果。一维卷积的计算公式为:

$$y_j^k=g\left(\sum W_{ij}^k X_i^{k-1}+b_j^k\right) \tag{8}$$

式中,y_j^k 为神经元的输出;g 为激活函数;$\sum$ 为对所有权重与输入的乘积进行求和,即线性组合部分;W_{ij}^k 为第 k 层中连接第 $k-1$ 层第 i 个神经元与第 k 层第 j 个神经元的权重;X_i^{k-1} 为第 $k-1$ 层中第 i 个神经元的输出,作为当前层的输入;b_j^k 为神经元的偏置。

中国知网　https://www.cnki.net

由于 CNN 在局部特征提取上的优势，近年来被广泛应用于时序数据预测任务中。CNN 通过对时间序列数据的多次卷积操作，能够逐渐抽象出不同尺度的时序特征。这些特征有助于捕捉数据中的规律和趋势，从而提高预测的精度。与传统的机器学习方法不同，CNN 不依赖人工特征选择。通过训练，CNN 能自动从原始时序数据中提取出有效特征，减少了特征提取的复杂性。同时，CNN 可灵活处理不同类型的时间序列数据。

2.3 长短时记忆网络(LSTM)

长短时记忆网络(LSTM)是递归神经网络(RNN)的一种变种，专门设计用于解决标准 RNN 中的长期依赖问题。标准 RNN 在处理长时间序列时容易遭遇梯度消失或梯度爆炸问题，LSTM 通过引入特殊的结构(即门控机制)来控制信息的流动，从而有效地捕捉长期依赖关系[10]。

LSTM 由多个 LSTM 单元(或称为记忆单元)组成，每个单元内部有细胞状态和多个门，这些门控制着信息的存储和更新。LSTM 主要由三个门和一个细胞状态构成，分别为输入门、遗忘门、输出门和细胞状态 C_t。

LSTM 的计算过程如下：

$$i_t=\sigma(W_i[h_{t-1},x_t]+b_i) \tag{9}$$

$$f_t=\sigma(W_f[h_{t-1},x_t]+b_f) \tag{10}$$

$$o_t=\sigma(W_o[h_{t-1},x_t]+b_o) \tag{11}$$

$$\widetilde{C}_t=\tanh(W_C[h_{t-1},x_t]+b_C) \tag{12}$$

$$C_t=f_t\odot C_{t-1}+i_t\odot\widetilde{C}_t \tag{13}$$

$$h_t=o_t\odot\tanh(C_t) \tag{14}$$

式中，x_t 为输入；h_{t-1} 为前一时刻的输出；i_t、f_t、o_t 分别为 t 时刻的输入门、遗忘门和输出门的输出；$\widetilde{C}_t$ 为候选记忆元；W_i、W_f、W_o、W_C 均为权重参数；b_i、b_f、b_o、b_C 均为偏置参数；$\odot$ 为按元素相乘；σ 为 sigmoid 激活函数，输出值在 0～1 之间，表示保留多少信息；tanh 为双曲正切激活函数，输出范围为[−1,1]，用来生成当前时间步的候选状态。

2.4 注意力机制

注意力机制(Attention Mechanism)是一种模仿人类视觉和认知的机制，在深度学习中广泛应用。其核心思想是在处理输入信息时，模型并非对所有输入都给予相同的关注度，而是将更多的“注意力”集中在输入的关键部分上。注意力机制可直接对输入序列的所有位置进行关注，能够有效捕捉长距离的依赖关系，而不容易受到梯度消失问题的影响。由于传统的 RNN 和 LSTM 模型通常是序列化计算，而注意力机制可并行计算不同时间步之间的信息，极大提高计算效率[11-12]。

3 振动预测模型建立

3.1 基于 ICEEMDAN 和 CNN-LSTM-ATTENTION 的振动预测模型

对抽水蓄能机组的振动信号进行 ICEEMDAN 模态分解，以分解得到的 IMF 分量作为模型的特征输入。将 CNN 与 LSTM 结合起来，并引入注意力机制，构建一种基于 ICEEMDAN 和 CNN-LSTM- ATTENTION 的预测模型，其中，CNN 层用以提取时间序列数据的局部特征；LSTM 层用以进行序列建模并捕捉长期依赖性；注意力层自动关注重要历史信息并进行加权求和。CNN-LSTM-ATTENTION 模型结构见图 1。

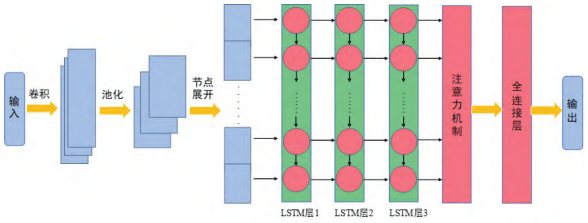


图 1 CNN-LSTM-ATTENTION 模型结构

Fig. 1 CNN-LSTM-ATTENTION model structure

基于 ICEEMDAN 和 CNN-LSTM-ATTENTION 的预测模型的具体流程见图 2，其具体步骤如下。

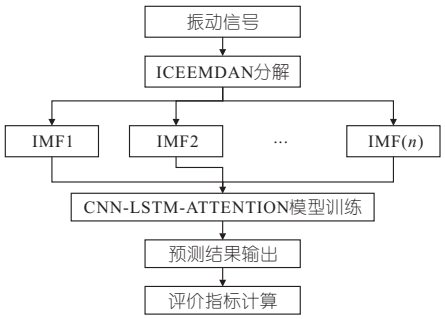


图 2 基于 ICEEMDAN 和 CNN-LSTM-ATTENTION 的振动预测模型流程

Fig. 2 Flow of vibration prediction model based on ICEEMDAN and CNN-LSTM-ATTENTION

步骤 1 对抽水蓄能机组的振动信号进行 ICEEMDAN 分解，获得相应的 IMF 分量。

步骤 2 对 IMF 分量进行归一化处理，并按照比例划分训练集和测试集。

步骤 3 将处理好的数据输入模型的第一层网络层，即 CNN 层。CNN 通过卷积层对输入的时间序列数据进行特征提取。

步骤 4 LSTM 层接收 CNN 层提取的特征

中国知网 https://www.cnki.net

作为输入,并通过其内部状态进行序列建模,输出当前时间步的预测值。

步骤 5　注意力层接收 LSTM 层的输出作为输入,并计算每个时间步的注意力权重。这些权重代表了不同时间步对预测结果的贡献程度。然后,模型使用这些权重对 LSTM 层的输出进行加权求和,得到最终的预测结果。

步骤 6　将预测结果与实际值进行对比,通过性能指标评价预测模型性能的好坏。

3.2　模型评价指标

为衡量模型的预测精度,采用均方根误差(R_{RMSE})、平均绝对误差(M_{MAE})、决定系数(R^2)和平均绝对百分比误差(M_{MAPE})进行评价。其中,R_{RMSE}、M_{MAE}、M_{MAPE} 的值越小或 R^2 的值越接近 1,模型预测的结果精度越高,性能越好。

4　实例分析

为验证本文所提模型的预测性能,选取国内某抽水蓄能电站 2023 年 6 月 1 日～7 月 31 日其监控系统的监测数据。以上导 X 向摆度数据为例(图 3),为进行精确预测,避免机组启停时刻带来的异常影响,试验数据选取机组发电稳态下开机 1 h 后至停机 1 h 前的监测数据,共选取 300 条,以此作为试验验证。

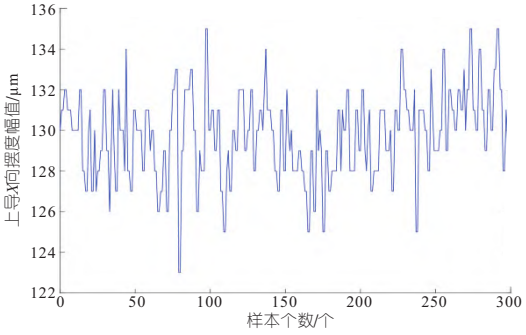


图 3　抽水蓄能机组上导 *X* 向摆度振动序列

Fig. 3　Vibration sequence of *X*-direction pendulum of pumped storage unit upper guide

4.1　ICEEMDAN 分解

考虑到抽水蓄能机组振动信号具有非线性非平稳性的特征,直接进行趋势预测难以获得较为精确的结果。因此对振动信号进行 ICEEMDAN 模态分解,以分解得到的 IMF 分量作为模型的特征输入,不仅能丰富输入数据的维度,同时相较于 EMD、EEMD 等方法能有效避免模态混叠、减少噪声干扰。提取的本征模态分量(IMF)见图 4。

4.2　模型参数设置

为验证所提方法预测性能的优越性,将所提方法与 LSTM、ICEEMDAN-LSTM、ICEEMDAN-CNN-LSTM、EMD-CNN-LSTM-ATTENTION 各模型的预测结果进行对比。统一各个模型的测试集与训练集、参数设置为时间步长为 12、最大迭代次数为 100 次、初始学习率为 0.01、学习率下降因子为 0.5、激活函数为 Relu、损失函数为 MSE、模型优化器为 Adam。

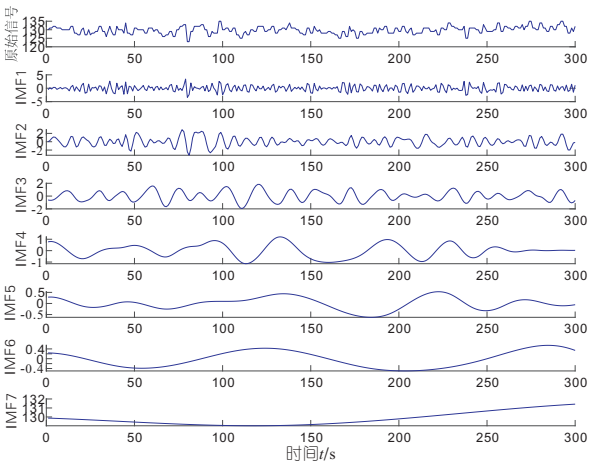


图 4　振动序列分解结果

Fig. 4　Vibration sequence decomposition results

4.3　预测结果对比

对所提方法构建的模型和 3 个作为对比试验的模型进行多次训练,对预测结果取平均值,使各模型预测结果更为符合实际预测情况,以此减小误差,提高预测准确性。分别计算各模型的评价指标来评估模型性能的优劣,计算结果见表 1。由表 1 可看出:①所提方法中,LSTM 预测模型直接选用机组的振动信号作为模型输入,模型输入特征过于单一,因此 LSTM 预测模型难以捕捉时序数据的依赖性,无法实现精准预测,相较于其他模型,该模型在所有评价指标上均表现较差。这也说明对抽水蓄能机组的振动信号不做任何预处理直接输入模型进行预测,难以实现精确预测抽水蓄能机组振动趋势。②通过 LSTM 和 ICEEMDAN- LSTM 的预测结果评价指标表现可知,通过 ICEEMDAN 分解方法对原始信号进行分解,增加模型的输入特征数量,可有效提升模

表 1　各模型评价指标结果对比

Tab. 1　Comparison of the results of the evaluation indicators of each model

模型	M_{MAE} /μm	R_{RMSE} /μm	R^2	M_{MAPE} /%
LSTM	1.698 3	2.136 1	0.100 5	1.185 0
ICEEMDAN- LSTM	1.394 4	1.703 8	0.288 3	0.978 3
ICEEMDAN-CNN-LSTM	0.792 1	0.841 2	0.837 5	0.556 0
EMD-CNN-LSTM- ATTENTION	0.314 7	0.336 2	0.972 3	0.220 8
ICEEMDAN-CNN-LSTM- ATTENTION	0.100 9	0.130 9	0.995 8	0.071 2

中国知网　https://www.cnki.net

型的预测精度；再进一步使用 CNN-LSTM 组合模型之后，通过 CNN 层对时序数据进行自适应的特征提取，M_{MAE}、R_{RMSE}、M_{MAPE} 分别降低了 43.19%、50.63%、43.17%，同时 R^2 提高了 0.549 2，可见 CNN-LSTM 组合模型在对振动信号进行趋势预测时更具优势且预测结果更为精准。③通过本文所提方法构建的模型与 ICEEMDAN-CNN-LSTM 模型进行对比，M_{MAE}、R_{RMSE}、M_{MAPE} 分别降低了 87.26%、84.44%、87.19%，同时 R^2 提高了 0.158 3，这表明在对 CNN-LSTM 模型引入注意力机制后，优化了传统模式，突出关键输入信息，避免模型因输入的长度增加导致预测性能下降，有效提高了模型的预测精度。④通过本文所提方法构建的模型与 EMD-CNN-LSTM-ATTENTION 模型进行对比，M_{MAE}、R_{RMSE}、M_{MAPE} 分别降低了 67.94%、61.06%、67.75%，这表明 ICEEMDAN 模态分解方法相较于 EMD，能避免模态混叠和噪声干扰，进一步提升模型的预测精度。由此可见，本文所提的 ICEEMDAN-CNN-LSTM- ATTENTION 组合模型在进行抽水蓄能机组振动信号趋势预测时具备良好的预测效果。

图 5 展示了所提模型预测值与真实值的结果对比图。由图 5 可知，除个别点外，模型的预测结果与真实值基本吻合，说明模型预测结果可极大程度上正确反映抽水蓄能机组的真实振动趋势。图 6 展示了本文所提方法构建的模型与各模型的预测结果误差对比图，更为直观地反映了本文所提方法的优越性。

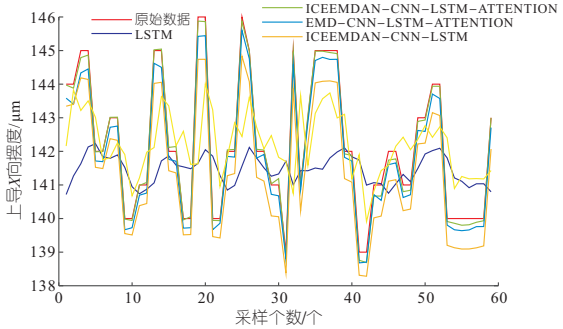


图 5 机组振动信号预测结果对比

Fig. 5 Comparison of predicted results of unit vibration signals

5 结论

a. 针对抽水蓄能机组振动信号具有较强非线性非平稳性难以直接进行预测的问题，本文提出了一种基于 ICEEMDAN-CNN-LSTM-ATTENTION 的组合预测模型。首先对振动信号进行 ICEEMDAN 分解，在降低振动信号非线性非平稳性的同时，避免模态混叠和噪声干扰；以 IMF 分量输入 CNN-LSTM 模型，通过 CNN 自动对时序数据进行抽象特征的提取，输入 LSTM 深度挖掘数据的时序依赖性并引入注意力机制，使模型聚焦关键输入信息，从而提高模型的预测性能。

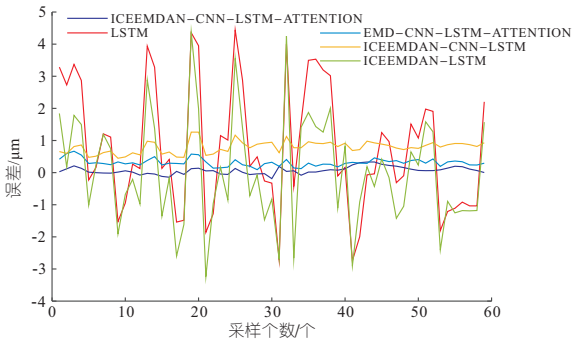


图 6 机组振动信号预测结果误差

Fig. 6 Unit vibration signal prediction result error

b. 通过抽蓄电站实测数据进行验证，并对比 LSTM、ICEEMDAN-LSTM、ICEEMDAN-CNN-LSTM、EMD-CNN-LSTM- ATTENTION 各模型结果表明，本文所提方法构建的模型无论相较于单一模型还是其他组合模型，均具有更高的预测精度，能对机组的振动趋势实现精准有效的预测，具有一定的工程应用价值。

参考文献：

[1] 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.(GUI Z H，ZHANG H，SUN H F，et al. Research and application of early warning model for vibration deterioration of hydropower units[J]. Journal of hydraulic engineering，2018，49(2)：216-222.(in Chinese))

[2] 王璞，姬联涛，陈龙翔，等. 基于 WOA-VMD-TCN 的水电机组振动趋势预测[J]. 水电能源科学，2023，41(6)：175-179.(WANG P，JI L T，CHEN L X，et al. Prediction of vibration trend of hydroelectric unit based on WOA-VMD-TCN[J]. Water resources and power，2023，41(6)：175-179.(in Chinese))

[3] 高金林，伍盛金，赖兴全，等. 基于 ICEEMDAN 和 CNN 的水电机组故障诊断[J]. 中国农村水利水电，2024(8)：216-221.(GAO J L，WU S J，LAI X Q，et al. Fault diagnosis of hydroelectric units based on ICEEMDAN and CNN[J]. China rural water and hydropower，2024(8)：216-221.(in Chi-

中国知网 https://www.cnki.net

nese))

[4] 杨雄，聂赛，章志平，等. 基于 TPA 机制改进的 VMD-GRU 抽水蓄能机组振动预测[J]. 水电与抽水蓄能，2023，9(1)：31-38.(YANG X，NIE S，ZHANG Z P，et al. Vibration forecasting of pumped storage units based on VMDGRU model with TPA mechanism[J]. Hydropower and pumped storage，2023，9(1)：31-38.(in Chinese))

[5] 袁成建，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.(YUAN C J，DENG Y M，ZHANG X G，et al. A prediction of vibration trend of the hydroelectric unit based on VMD-GA-BP and error correction[J]. China rural water and hydropower，2023(1)：176-180，184.(in Chinese))

[6] 毕扬，郑波，张亚武，等. 基于 MIC 与 BiGRU 的水电机组振动趋势预测[J]. 水利学报，2021，52(5)：612-621，632.(BI Y，ZHENG B，ZHANG Y W，et al. Vibration trend prediction of hydroelectric generating unit based on MIC and BiGRU[J]. Journal of hydraulic engineering，2021，52(5)：612-621，632.(in Chinese))

[7] 姜伟，卢俊泽，许颜贺. 基于样本熵重构与 RF-LSTM 模型的水电机组状态趋势预测[J]. 大电机技术，2024(2)：74-80.(JIANG W，LU J Z，XU Y H. State trend prediction of hydropower unit based on sample entropy reconstruction and RF-LSTM model[J]. Large electric machine and hydraulic turbine，2024(2)：74-80.(in Chinese))

[8] 邓玉敏，张雪桂，马历，等. 基于 CNN-BiGRU 的水电机组振动趋势预测[J]. 中国农村水利水电，2022(9)：213-217.(DENG Y M，ZHANG X G，MA L，et al. Vibration trend prediction of hydropower units based on CNN-BiGRU[J]. China rural water and hydropower，2022(9)：213-217.(in Chinese))

[9] 石化波，王刚，曾怀恩. 一种 ICEEMDAN-CNN-SVR 滑坡位移组合预测模型[J]. 三峡大学学报(自然科学版)，2025，47(1)：37-43.(SHI H B，WANG G，ZENG H E. A combined ICEEMDAN-CNN-SVR landslide displacement prediction model[J]. Journal of China Three Gorges University (natural sciences)，2025，47(1)：37-43.(in Chinese))

[10] 单亚辉，王浩，吴根平，等. 基于卷积-长短期记忆神经网络的抽水蓄能机组健康性能趋势预测[J]. 水电能源科学，2023，41(8)：185-187，184.(SHAN Y H，WANG H，WU G P，et al. A health performance tendency prediction model of pumped storage unit based on convolution neural network-long short-term memory neural network[J]. Water resources and power，2023，41(8)：185-187，184.(in Chinese))

[11] 陈星，沈紫菡，许钦，等. 基于 CNN-LSTM-Attention 的月生活需水预测研究[J]. 三峡大学学报(自然科学版)，2024，46(5)：1-6.(CHEN X，SHEN Z H，XU Q，et al. Research on monthly water demand prediction based on CNN-LSTM-attention[J]. Journal of China Three Gorges University (natural sciences)，2024，46(5)：1-6.(in Chinese))

[12] SUN Y，ZHOU Q B，SUN L，et al. CNN-LSTM-AM：A power prediction model for offshore wind turbines[J]. Ocean engineering，2024，301：117598.

(上接第 171 页)

[6] 刘光彪，李少林，吴双利，等. 旭龙水电站大坝安全监测信息综合管理系统设计研究[J]. 水利水电快报，2024，45(5)：105-110，116.(LIU G B，LI S L，WU S L，et al. Design and research on the comprehensive management system for dam safety monitoring information of Xulong Hydropower Station[J]. Express water resources & hydropower engineering，2024，45(5)：105-110，116.(in Chinese))

[7] 李长臻. 基于 CFD 的长短叶片混流式水轮机尾水管三维数值模拟[D]. 昆明：昆明理工大学，2011.(LI C Z. Three-dimensional numerical simulation of draft tube of Francis turbine with long and short blades based on CFD[D]. Kunming：Kunming University of Science and Technology，2011.(in Chinese))

[8] 梁兴，郭磊. 水轮机内部三维湍流计算方法概述[J]. 人民黄河，2010，32(3)：90-91.(LIANG X，GUO L. Overview of three-dimensional turbulence calculation method in hydraulic turbine[J]. Yellow River，2010，32(3)：90-91.(in Chinese))

[9] 路志伟. 两河口水电站水轮机水力设计与性能分析研究[D]. 陕西：西安理工大学，2017.(LU Z W. Hydraulic design and performance analysis of the turbine for Lianghekou Hydropower Station[D]. Xi'an：Xi'an University of Technology，2017.(in Chinese))

[10] 国家市场监督管理总局，国家标准化管理委员会. 水轮机基本技术条件：GB/T 15468—2020[S]. 北京：中国标准出版社，2020.(State Administration for Market Regulation，Standardization Administration of the People's Republic of China. Fundamental technical requirements for hydraulic turbines：GB/T 15468—2020[S]. Beijing：Standards Press of China，2020.(in Chinese))

中国知网　https://www.cnki.net