

基于MDN和VMD-TPA-LSTM的 泵站主机组劣化趋势预测

夏臣智^{1,3}, 李英玉^{1,3}, 吴子豪², 李超顺², 黄富佳^{1,3}, 莫兆祥^{1,3}

(1. 南水北调(江苏)数智科技有限公司, 江苏 南京 210019; 2. 华中科技大学 土木与水利工程学院, 湖北 武汉 430074;

3. 江苏省泵站工程技术研究中心, 江苏 南京 210019)

摘要:为提高泵站主机组的安全稳定运行能力,解析其运行状态,获取机组设备的健康状况,准确预测其未来发展趋势,提出一种基于混合密度网络(Mixture Density Networks, MDN)和融合变分模态分解(Variational Mode Decomposition, VMD)与基于时序模式和注意力机制的长短期记忆网络(Temporal Pattern Attention-Long Short-Term Memory Network, TPA-LSTM)的泵站主机组劣化趋势预测模型。模拟结果表明,此法能够准确地表达机组的劣化趋势并可有效提高其预测精度。

关键词:趋势预测; 网络模型; 泵站机组; MDN; VMD; TPA-LSTM

中图分类号:TV675 文献标识码:A 文章编号:1007-7839(2024)09-0024-0006

Deterioration trend prediction of pump station host group based on MDN and VMD-TPA-LSTM

XIA Chenzhi^{1,3}, LI Yinyu^{1,3}, WU Zihao², LI Chaoshun²,
HUANG Fujia^{1,3}, MO Zhaoxiang^{1,3}

(1. South to North Water Diversion (Jiangsu) Shuzhi Technology Co., Ltd., Nanjing 210019, China;

2. Huazhong University of Science and Technology, School of Civil and Hydraulic Engineering, Wuhan 430074, China; 3. Jiangsu Pump Station Engineering Technology Research Center, Nanjing 210019, China)

Abstract: In order to improve the safe and stable operation capability of the pump station host group, analyze its operating status, obtain the health status of the unit equipment, and accurately predict its future development trend, a pump station host group degradation trend prediction model based on Mixed Density Networks (MDN), Variational Mode Decomposition (VMD), and Temporal Pattern Attention Long Short Term Memory Network (TPA-LSTM) based on temporal pattern and attention mechanism is proposed. The simulation results show that this method can accurately express the deterioration trend of the unit and effectively improve its prediction accuracy.

Key words: trend prediction; network model; pump station unit; MDN; VMD; TPA-LSTM

收稿日期: 2024-05-29

基金项目: 江苏省水利科技项目(2022001)

作者简介: 夏臣智(1990—),男,高级工程师,博士,主要从事泵站工程方面的研究工作。E-mail:xiachenzhi@foxmail.com

通信作者: 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

1 概述

近年来,随着工业自动化技术的迅猛发展和智能化水平的提高,泵站主机组在工业生产中扮演着愈发重要的角色。作为关键的能源转换设备,泵站主机组的运行状态直接影响着生产效率、能源利用率以及系统可靠性^[1]。因此,对泵站主机组的劣化趋势预测成为了一项关键任务,它有助于及早发现设备的故障迹象,从而采取适当的维护和修复措施,最大程度地减少停机时间和维修成本,提高生产效率和设备可靠性。泵站主机组的工作状态受到诸多因素的影响,包括但不限于运行负载、环境条件、设备磨损等,这些因素之间相互耦合,使得传统的预测方法往往难以准确捕捉设备的动态变化特征。泵站主机组的劣化趋势预测是一个具有挑战性的问题,因此,开发一种高效准确的泵站主机组劣化趋势预测方法对于提升设备运行效率和降低维护成本具有重要意义^[2]。

泵站主机组劣化趋势预测是近年来工程领域中备受关注的研究方向之一,众多学者利用机器学习、深度学习等先进技术开展了相关研究,取得了一系列重要成果。随着工业互联网技术的不断发展和普及,越来越多的研究者开始关注泵站主机组劣化趋势预测领域,如付波等^[3]提出了基于深度置信网络(Deep Belief Networks, DBN)的泵站主机组性能预测方法,通过对泵站主机组运行数据进行特征提取和选择,结合深度置信网络进行建模,实现了对泵站主机组性能参数的准确预测。此外,方娜等^[4]采用遗传算法和神经网络模型,对泵站主机组的运行状态进行建模和预测,为泵站主机组的故障诊断和维护管理提供了有效的技术支持。

尽管在泵站主机组劣化趋势预测领域取得了一系列重要进展,但仍然存在一些挑战和问题亟待解决。例如,当前大多数研究方法主要关注于单一数据源或特定的预测模型,缺乏对多模态数据的综合利用和深度挖掘。此外,现有方法在建模过程中往往忽略了泵站主机组的非线性特性和时变性,导致预测精度和泛化能力有限。因此,未来的研究方向之一是开发多源数据融合和深度学习相结合的泵站主机组劣化趋势预测方法,以提高预测精度,进一步推动工业生产的智能化和可持续发展^[5]。

本文针对泵站机组的特性提出一种基于MDN和VMD-TPA-LSTM的泵站主机组劣化趋势预测方法。该方法结合了MDN对多模态数据分布的拟合

能力和VMD-TPA-LSTM对时序特征的自动提取能力,能够有效地捕捉泵站主机组工作状态的复杂动态特征,提高预测精度和泛化能力。同时,本文还通过实验验证了所提方法的有效性和可行性,表明其在泵站主机组劣化趋势预测任务中具有显著的优势和应用前景。

2 理论基础

2.1 MDN网络

混合密度网络(MDN)是一种用于建模和预测复杂概率分布的神经网络模型,通过将神经网络的输出分解为多个混合分量,并对每个混合分量参数化为均值、方差和权重,从而能够灵活地适应不同的概率分布,并实现对复杂非线性关系的建模和预测^[6]。以回归问题为例,输入和输出均是可能有多维度的矢量。

目标值的概率密度可以表示成多个核函数的线性组合,其计算式为

$$p(t|x) = \sum_{i=1}^m \alpha_i(x) \phi_i(t|x) \quad (1)$$

式中: x 为输入值; t 为输出值; $\alpha_i(x)$ 为混合系数,可认为是 x 的一种先验概率; ϕ_i 为目标向量 t 的第 i 个核,这里的核函数可以有多种选择,本文选取最经常使用的形式即高斯分布,因为足够数量的混合高斯分布在原理上可以近似任何一个分布; m 为高斯混合分布选取的核个数。

核函数 ϕ 计算式为

$$\phi_i(t|x) = \frac{1}{(2\pi)^{c/2} \sigma_i(x)^c} \exp \left\{ -\frac{\|t - \mu_i(x)\|^2}{2\sigma_i(x)^2} \right\} \quad (2)$$

式中: c 为 t 的维度,这里的每一个核函数都是一个多元的高斯分布; $\sigma_i(x)$ 为1个标量; $\sigma_i(x)$ 为与目标值 t 同维度的矢量,表示回归的预测值;其余符号含义同上。

2.2 VMD算法

变分模态分解(Variational Mode Decomposition, VMD)是一种基于信号自适应分解的方法,用于将非线性和非平稳信号分解为多个模态分量。VMD通过优化一个能量函数,迭代求解信号的各个模态分量和相关的带宽参数,从而实现信号的分解^[7]。

给定一个信号 $x(t)$,VMD的基本原理是将其表示为一组模态函数 $u_k(t)$ 的线性组合,即,

$$x(t) = \sum_{k=1}^K u_k(t) \quad (3)$$

其中, K 为模态数量。为了获得模态函数 $u_k(t)$, VMD 引入了拉格朗日乘子和 KKT 条件, 转化为最小化能量函数, 即,

$$\sum_{t=1}^N \left| x(t) - \sum_{k=1}^K u_k(t) \right|^2 + \lambda \sum_{k=1}^K \Omega(u_k) \quad (4)$$

式中: λ 为正则化参数; $\Omega(u_k)$ 为 $u_k(t)$ 的带宽惩罚项, 通常选择 $\Omega(u_k) = \frac{1}{2} \|Fu_k\|_2^2$, 其中 F 为离散傅里叶变换。

通过最小化上述能量函数, 可以得到最优的模态函数 $u_k(t)$ 和对应的带宽参数。VMD 算法的求解过程通常采用迭代优化算法, VMD 的求解过程具体包括以下几个步骤。

(1) 初始化: 随机初始化模态函数 $u_k(t)$ 和带宽参数。

(2) 交替优化: 交替进行以下步骤直至收敛: 一是固定 $u_k(t)$, 优化带宽参数, 根据固定的 $u_k(t)$ 情况, 通过梯度下降或其他优化方法更新带宽参数; 二是固定带宽参数, 优化 $u_k(t)$ 根据固定带宽参数的情况, 通过求解拉格朗日乘子和 KKT 条件更新模态函数 $u_k(t)$ 。

(3) 收敛判断: 根据收敛准则判断算法是否收敛, 若未收敛则继续迭代。

2.3 TPA-LSTM 网络

TPA-LSTM 是在传统 LSTM 模型之上添加了时序注意力机制, 该机制通过自适应学习之前隐含状态的注意力权重, 增强了模型在非线性序列数据中捕捉长期相关性的能力。

2.3.1 TPA 机制

注意力机制 (Attention Mechanism, AM) 通常结合神经网络模型进行序列预测, 使模型能够更有效地关注历史数据与当前输入数据的相关部分。时序模式注意力机制 (Temporal Pattern Attention Mechanism, TPA) 由 Shun-Yao Shih 等提出, 其通过使用 CNN 滤波器从输入数据中提取固定长度的时序模式, 再通过评分函数来确定各时序模式的权重, 最终根据这些权重生成输出信息^[8-9]。TPA 机制的实现包括 3 个步骤, 即时序模式的提取、权重计算和 TPA 输出。

2.3.2 LSTM 模型

LSTM 通过独特的结构设计, 解决了传统递归神经网络在训练中遇到的梯度消失和梯度爆炸问题。LSTM 网络模型由输入层、隐藏层和输出层组成, 其中隐藏层包含特殊的 LSTM 单元, 包括一个独立的记忆单元和 3 个门 (输入门、遗忘门、输出门),

用于控制记忆单元的状态^[10-11]。

上述计算过程由如下计算式表示:

$$\begin{cases} f_t = \sigma(\omega_{xf} X_t + \omega_{sf} s_{t-1} + b_f) \\ i_t = \sigma(\omega_{xi} X_t + \omega_{si} s_{t-1} + b_i) \\ o_t = \sigma(\omega_{xo} X_t + \omega_{so} s_{t-1} + b_o) \\ \tilde{c}_t = \tanh(\omega_{xc} X_t + \omega_{sc} s_{t-1} + b_c) \\ c_t = f_t \otimes c_{t-1} + i_t \otimes \tilde{c}_t \\ s_t = o_t \otimes \tanh(c_t) \end{cases} \quad (5)$$

式中: f_t, i_t, o_t, c_t 分别为遗忘门、输入门、输出门和记忆模块; $\omega_{xf}, \omega_{xi}, \omega_{xo}, \omega_{xc}$ 分别为输入 X_t 与遗忘门、输入门、输出门和记忆模块间的权重矩阵; $\omega_{sf}, \omega_{si}, \omega_{so}, \omega_{sc}$ 分别为前一个单元的输出 s_{t-1} 与当前遗忘门、输入门、输出门和记忆模块间的权重矩阵; b_f, b_i, b_o, b_c 分别为当前遗忘门、输入门、输出门和记忆模块间的偏置; σ 为激活函数; \tilde{c}_t 为选值向量, 聚合了所处时刻的全部信息; s_t 为隐藏态, 同时也是每个时刻的输出结果^[12-13]。

2.3.3 TPA-LSTM 网络

TPA-LSTM 模型利用 TPA 机制来处理 LSTM 模型的隐含层输出值。与传统的 LSTM 模型相比, 更加关注过去各个时刻的隐含层输出值与当前时刻隐含层输出值之间的关系。通过计算这些关系, 确定过去隐含层输出值的权重, 从而获得最终的隐含层输出值。本文所使用的 TPA-LSTM 模型结构中的网络输入为前 $w-1$ 个时刻 ($t-w+1$ 到 $t-1$) 的时间序列, 网络输出为当前 t 时刻的预测值^[14-15]。

TPA-LSTM 模型通过前向和后向传播进行训练, 其优化算法为 Adam (Adaptive Moment Estimation)。Adam 算法利用前一时刻不同参数的梯度的一阶和二阶矩估算当前时刻的值, 结合了 AdaGrad 和 RMSProp 优化算法的优势^[16-17]。在神经网络的训练中, 目标函数通常为网络的输出, 即 $f(\theta)$, 其中 θ 为多参数集合, 参数寻优的目的是找到合适的参数 θ 使得函数 $E[f(\theta)]$ 取得最优 (最大或最小) 值^[18]。

在神经网络训练中, 通常以损失函数 (f_{loss} 函数) 代指 $E[f(\theta)]$, 故定义真实与预测值的绝对误差为损失函数, 即:

$$f_{\text{loss}} = |f(\theta) - f(\bar{\theta})| \quad (6)$$

式中: f_{loss} 为损失函数; $f(\theta)$ 为网络输出, 其中 θ 为多参数集合。

3 泵站主机组劣化趋势预测

文中提出基于 MDN 和 VMD-TPA-LSTM 的泵

站主机组劣化趋势预测主要分为3个步骤,一是建立泵站主机组健康状态模型,二是构建机组劣化趋势序列并绘制劣化曲线,三是通过网络预测机组劣化趋势。

为了泵站机组的安全稳定运行,准确预测其未来发展趋势,提出一种基于MDN、VMD与TPA-LSTM的泵站主机组劣化趋势预测模型,其整体框架见图1。

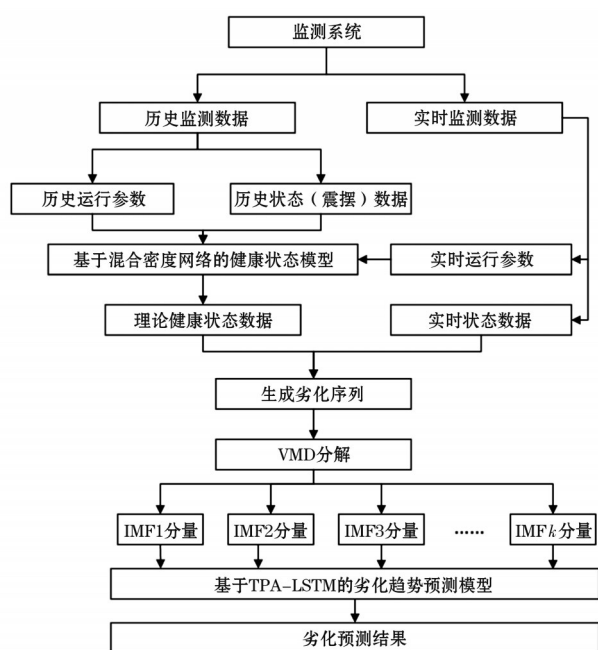


图1 劣化预测模型框架

3.1 基于混合密度网络的泵站主机组健康状态模型

混合密度网络(MDN)的泵站主机组健康状态预测模型,本研究深入分析了设备在多种操作环境下的关键性能数据,包括工作温度、有功和无功功率、电流强度以及电压等级,分析流程可概括为以下2个主要阶段。

第一阶段:确立基准健康状态模型。本阶段的目标是识别对泵站主机组运行至关重要的变量,例如温度、有功和无功功率、电流和电压,并将这些变量作为MDN模型的基础输入参数。进一步借助丰富的历史监测数据建立基准模型,该模型以泵站主机组历史横摆数据为输出,以此确立了设备运行参数与监测数据之间的相关性。

第二阶段:定义健康性能的评价标准。考虑到设备性能随着运行时间的延长而自然下降,引入了实时监测数据至模型中,该模型基于设备初始运行阶段的数据建立。该步骤旨在评估设备在实际运

行期间的健康水平,对模型输入运行参数,并预测在特定工况下的理论振摆值,以此作为健康性能的基准。

模型指标计算式为

$$I_{HP} = \max\left(\frac{F(t) - V(t)}{F(t)}, 0\right) \quad (7)$$

式中: I_{HP} 为定量评估设备的健康性能指标; $V(t)$ 为实际监测到的振摆数据; $F(t)$ 为特定工况下的理论振摆值; t 为机组运行时间;其余符号含义同上,性能指标取大于0部分。

3.2 基于VMD-TPA-LSTM的泵站主机组劣化预测模型

针对HPI序列表现出的非线性特性和时变行为,传统预测技术往往难以捕捉其内在的复杂性。为了增强预测模型在处理此类序列时的精确度,本研究设计了综合模型,该模型融合了变分模态分解(VMD)用于信号解构、时序模式注意力长短期记忆网络(TPA-LSTM)用于趋势预测,以及注意力机制在关键特征识别方面的能力,有效解决了高维非线性预测问题。

模型构建过程中,初始阶段采用VMD技术对原始数据序列进行分解,得到若干独立的模态成分。随后,每个独立成分被分别送入定制的TPA-LSTM模型中进行分析预测,其预测输出随后被整合,最终形成对整个序列的全面预测。该模型特别擅长于辨识并适应复杂的劣化模式,即便在多变的外部环境因素影响下,也能提供高准确度的预测结果。

3.3 评价指标

在评价预测模型性能方面,本研究选取了4个关键的评价指标:均方根误差(RMSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)以及判定系数(R^2)。这些指标共同作用,全面评估预测模型的准确性和可靠性。 $RMSE$ 用于衡量预测值与观测值之间的标准偏差, MAE 则提供了预测误差的平均大小, $MAPE$ 从相对误差的角度进行评估,而 R^2 则反映了模型对数据变异性的解释程度。各指标计算式为

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y - \hat{Y})^2} \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y - \hat{Y}| \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y - \hat{Y})^2}{\sum_{i=1}^n (Y - \bar{Y})^2} \quad (10)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n (Y - \hat{Y} - \mu) \quad (11)$$

式中: μ 为预测序列误差序列的样本均值; n 为序列样本数;其余符号含义同上。

4 实例验证

4.1 相关数据获取

在工程实践中,设备的振动信号是评估其运行状况的关键信息源,准确的劣化分析对于设备的长期稳定运行至关重要。本研究以某水利工程的3号泵站机组为例,通过仿真手段,采用上导X向摆度数据评估机组的劣化程度。为了能够模拟出劣化的数据,本文将机组大修前后工况作为机组的健康态和劣化态。根据泵站运行报告,2019年10月20日至2020年2月10日为大修后运行状态良好,以此阶段数据来训练和验证健康模型;2019年4月5日至2019年10月1日期间为大修前的数据,因此作为劣化数据,训练并测试机组劣化趋势预测模型。

4.2 健康状态模型

为确定机组健康状态模型的准确性,本研究基于混合密度网络(MDN)构建了机组健康模型,该模型能够精确地描述机组运行参数与上导X向摆度的关联。模型的训练和测试使用了2020年4月1日至2020年9月1日收集的数据,为了评估MDN模型性能,将其与其他2种方法(K近邻算法和线性回归)进行比较。对比结果显示,MDN模型在均方根误差(RMSE)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)和决定系数(R^2)等评价指标上均表现优异。具体来说,MDN模型的RMSE值为1.443,MAE值为1.0438,MAPE值为17.921, R^2 达到了0.989。图2直观地展示了模型的拟合效果,详细计算结果列于表1中。




图2 基于混合密度网络的健康模型拟合结果

4.3 劣化趋势序列

在本项研究中,收集分析了2020年4月1日至

表1 各模型评价指标

回归模型	均方根误差/ μm	平均绝对误差/ μm	平均绝对百分比误差/%	决定系数
K邻值	1.757	1.6270	18.957	0.935
线性回归	2.033	1.7310	22.750	0.955
混合密度网络	1.443	1.0438	17.921	0.989

2020年9月1日的机组性能数据,将其作为构建健康状态模型的基础输入参数。该模型旨在预测理想状态下的摆度表现,通过对比实际摆度测量值与模型预测的理论值,能够评估设备的劣化程度,从而进一步利用上述数据及公式,推导出上导X向振摆的劣化趋势序列。通过分析泵站3号机组上导X向摆度劣化趋势序列(图3)可知,随着设备运行时间的延长,劣化程度呈现逐步上升的趋势,从而验证了混合密度网络模型在生成劣化趋势序列方面的有效性。




图3 泵站3号机组上导X向摆度劣化趋势序列

4.4 劣化趋势预测

为了对机组的劣化趋势做出精确的预测,本研究首先采用中值滤波技术对劣化数据序列进行平滑处理,随后应用VMD-TPA-LSTM这一先进的预测模型。在模型的训练阶段,使用了数据集中80%的劣化序列,而剩余的20%则用于模型的测试阶段,以此来评估模型的预测效能。

为了进一步证明所提出模型的优越性,本研究构建了多种不同的模型,包括RNN、LSTM、BiLSTM、VMD-LSTM、TPA-LSTM、VMD-RNN以及VMD-TPA-LSTM,并进行预测准确度的对比分析,详见图4和表2。可以看出,本研究所提出的VMD-TPA-LSTM模型在各项评价指标上均展现出了一定优势。

综合考虑所有模型的预测误差及其分布情况,




图4 各模型的预测结果

表2 不同预测模型的评价指标

模型	均方根误差/ μm	平均绝对误差/ μm	平均绝对百分比误差/%	决定系数
RNN	0.032	0.025	18.957	0.222
LSTM	0.032	0.024	17.750	0.232
BiLSTM	0.031	0.024	16.921	0.355
TPA-LSTM	0.022	0.022	10.151	0.414
VMD-RNN	0.012	0.008	5.855	0.944
VMD-LSTM	0.008	0.006	2.412	0.965
VMD-TPA-LSTM	0.006	0.004	2.181	0.984

利用本研究所构建的综合性评价体系进行比较分析。结果表明,VMD-TPA-LSTM模型不仅在预测精度上具有显著优势,而且在预测过程中表现出了良好的稳定性,与其他模型相比,VMD-TPA-LSTM模型性能更优,充分证明了本研究所提出模型在准确预测泵站机组设备性能方面的可靠性和有效性。

5 结 论

本研究创新的预测模型融合了混合密度网络(MDN)与变分模态分解和时序模式注意力长短期记忆网络(VMD-TPA-LSTM),专门用于预测机组劣化趋势,这一模型能够有效处理由运行条件引起的劣化趋势的不确定性和动态变化。结果显示,利用MDN构建的健康状态模型能够精确捕捉机组工况参数与振摆之间的相互关系,其高拟合度证实了模型在反映机组组件运行特征方面的可靠性和准确性。相较于传统研究中所使用的回归和时间序列模型,VMD-TPA-LSTM模型在预测精度上展现了显著优势,同时也表明了该模型在泵站机组状态预测领域具有重要的应用潜力和实用价值。

参考文献:

- [1] 韩冬,方红卫,严秉忠,等. 2013年中国水电发展现状[J]. 水力发电学报,2014,33(5):1-5.
- [2] 王淑青,柯洋洋,胡文庆,等. 基于参数自适应SVR和VMD-TCN的水电机组劣化趋势预测[J]. 中国农村水利水电,2024(4):193-198.
- [3] 付波,姜奔,赵熙临,等. 基于RFR和VMD-TCN的抽水蓄能机组劣化趋势预测方法[J]. 中国农村水利水电,2023(3):208-217.
- [4] 方娜,李新新,马森源,等. 基于VMD-BiLSTM-Attention的抽水蓄能机组性能劣化趋势预测[J]. 中国农村水利水电,2023(8):272-278.
- [5] 兰家法,周玉辉,高泽良,等. 基于机器学习的水电机组劣化趋势预测模型[J]. 水力发电学报,2022,41(12):135-144.
- [6] 兰家法,周玉辉,高泽良. 基于机器学习法的水电机组趋势预测[J]. 水力发电学报,2023,42(1):13-17.
- [7] 朱梓彬,孟安波,欧祖宏,等. 基于多元模态分解与多目标算法优化的深度集成学习模型的超短期风电功率预测[J/OL]. 现代电力,1-12[2024-05-24].<https://doi.org/10.19725/j.cnki.1007-2322.2022.0318>.
- [8] 段然. 复杂工况下水电机组状态评估及劣化趋势预测方法研究[D]. 武汉:华中科技大学,2022.
- [9] 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.
- [10] 褚瑞娟. 高速公路交通运行状态判别与预测方法研究[D]. 长春:吉林大学,2021.
- [11] 王博宇,文中,周翔,等. 基于变分非线性调频模态分解及TCN-TPA-LSTM的短期电力负荷组合预测模型[J/OL]. 现代电力,1-10[2024-04-09].<https://doi.org/10.19725/j.cnki.1007-2322.2023.0250>.
- [12] 付波,姜奔,赵熙临,等. 基于RFR和VMD-TCN的抽水蓄能机组劣化趋势预测方法[J]. 中国农村水利水电,2023(3):208-217.
- [13] 吉锶宸. 基于改进鲸鱼算法和时间模式注意力机制的短期电力负荷预测[D]. 北京:北京化工大学,2022.
- [14] 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.
- [15] 王峰. 面向复杂劣化信号的预测健康指数构造方法研究及应用[D]. 北京:北京交通大学,2021.
- [16] 张云超. 旋转机械剩余寿命预测方法研究[D]. 南京:南京航空航天大学,2020.
- [17] 安学利,潘罗平,张飞,等. 水电机组劣化趋势混合预测模型[J]. 水力发电学报,2014,33(3):286-291.
- [18] 侯锐. 基于TPA-LSTM预测模型的高准确度最小熵评估方法[D]. 太原:太原理工大学,2022.