

DOI: 10.20040/j.cnki.1000-7709.2025.20241784

# 回水顶托效应下巨型水电站下游水位预测研究

彭 旺<sup>1,2</sup>, 姚华明<sup>2</sup>, 蒋志强<sup>1</sup>, 曹 辉<sup>2</sup>

(1. 华中科技大学土木与水利工程学院, 湖北 武汉 470074; 2. 中国长江电力股份有限公司, 湖北 宜昌 443002)

**摘要:** 水电站的尾水水位是计算机组出力的重要参数, 当存在下游水库顶托影响时, 电站尾水的设计曲线与实际观测值往往存在较大误差, 增加了机组出力—流量的计算误差。为此, 根据最新历史观测数据, 分析了BHT水电站尾水水位与其出库流量及下游水库XLD顶托水位的关系, 建立了基于多情景划分的贝叶斯优化—长短期记忆网络(BO-LSTM)预测模型, 并分析了调峰和泄洪工况下模型的应用效果。结果表明, XLD水位高于585 m后对BHT电站的尾水水位有显著的顶托影响。相比于水位—流量曲线和非线性曲线拟合方法, 基于多情景划分的BO-LSTM模型在精度上有显著提升, 平均绝对误差( $M_{MAE}$ )降低了68.1%。BO-LSTM模型在多种工况下均能更准确地捕捉水位的起伏变化过程。研究结果对水电站精细化调度具有重要意义。

**关键词:** 水位—流量关系; 顶托影响; 长短期记忆神经网络; 预测

**中图分类号:** TV741; TV122

**文献标志码:** A

**文章编号:** 1000-7709(2025)09-0203-05

## 1 引言

水电站下游水位是水电出力计算的重要参数<sup>[1]</sup>, 它不仅决定机组的水头高度, 还对水电站的发电效率具有显著影响<sup>[2]</sup>。尾水水位估算不准确会导致出力、流量估算的误差, 使得运行时发电计划需要频繁调整, 精细化管理水平难以提高。水电站的尾水主要受下泄流量的控制。但当存在下游梯级水库水位或下游支流汇入水位顶托时, 水电站的尾水水位受出库流量和下游顶托水位的控制, 呈现非稳态和非线性的特点<sup>[3]</sup>。为保障水电站的综合效益最大化, 水库调度过程和短期发电计划制作时需充分考虑回水顶托效应。何中政等<sup>[4]</sup>基于逐步回归分析预测方法的研究表明, 峡江水库建设对吉安河段水位顶托效果显著, 与峡江水库实测水位高度呈正相关, 而与吉安水位涨水过程、流量等因素具有中等至微弱相关性, 模型拟合度高, 能够有效预测水位变化; HUANG J W等<sup>[5]</sup>研究了金沙江向家坝水库下游水位对流量和水力条件变化的敏感性, 提出了一种基于随机森

林算法的2 h尺度下游水位预测方法, 显著提高了预测准确性并有效控制了调峰期的波动误差。水电站尾水的水位计算方法包括水动力学数值模拟<sup>[6]</sup>、曲线拟合<sup>[7]</sup>和数据挖掘<sup>[8]</sup>。刘晓阳等<sup>[9]</sup>利用人工神经网络、支持向量机和随机森林3种机器学习方法构建三峡和葛洲坝水库坝前与下游水位预测模型, 结果表明随机森林和支持向量机模型在预测精度和稳定性上表现最佳<sup>[10]</sup>, 为水库短期发电调度提供了有效的技术支持。上述研究展示了水电站尾水水位预测方法在不同场景下的应用, 包括回水顶托效应对尾水位的影响以及利用先进的机器学习算法提升预测精度。然而, 现有研究多集中于单一水库或局部区域的水位预测, 且对不同蓄水周期和实际运行工况下尾水位的非稳态特性关注不足, 特别是在水力联系紧密的大型梯级水库联合调度过程中。为此, 本文以XLD水电站回水顶托影响下BHT尾水水位精准预测为核心问题, 利用历史运行数据详细分析XLD水电站回水顶托影响的起止时段和水位, 进而构建基于多情景划分的贝叶斯优化—长短期记忆网络(BO-LSTM)预测模型。在此基础上, 进一步分

**收稿日期:** 2024-09-19, **修回日期:** 2024-11-20

**基金项目:** 国家自然科学基金项目(52479017, 52179016); 中国长江电力股份有限公司资助(Z242302051)

**作者简介:** 彭旺(1997-), 男, 博士研究生, 研究方向为水资源与水电能源优化调度, E-mail: hz09161997@outlook.com

**通讯作者:** 蒋志强(1986-), 男, 博士、副教授、博导, 研究方向为水库群联合调度与水文预报, E-mail: zqjzq@hust.edu.cn


析了调峰和泄洪工况下模型的应用效果,并与水位—流量曲线和拟合曲线的计算结果进行了验证与对比评估,以期为大型水库回水顶托影响下的尾水位精准预测任务提供技术支撑。

## 2 研究数据与方法

### 2.1 概况与数据

BHT 水电站位于金沙江下游河段的四川省凉山彝族自治州宁南县,总库容  $206.27 \times 10^8 \text{ m}^3$ ,装机规模  $1\,600 \times 10^4 \text{ kW}$ ,位列世界第 2。XLD 水电站是 BHT 水电站的下游电站,相距约 200 km。以发电为主,兼有防洪、拦沙和改善下游航运条件等综合效益,水库库容  $115.7 \times 10^8 \text{ m}^3$ ,具有不完全年调节性能。电站总装机  $1\,386 \times 10^8 \text{ kW}$ ,位列世界第 3。当 XLD 水库处于较高水位运行时,对 BHT 尾水具有顶托作用,会增加 BHT 的尾水水位。本文选取 2022 年 7 月~2024 年 1 月的实际运行数据,对 BHT 的尾水关系进行分析,试图建立更准确的尾水预测曲线,更新原有设计曲线。历史数据包括同时段的 XLD 水电站上游水位、BHT 水电站出库流量和 BHT 水电站下游水位,时间分辨率为每 2 h。

图 1 为不同 XLD 水电站水位下 BHT 出库流量与尾水水位的关系,图 1 中曲线为实测数据拟合曲线。由图 1 可看出,当 XLD 水位处于 500~570 m 时,BHT 下游水位和出库流量比较集中分布在  $45^\circ$  拟合线附近,当 XLD 水位处于 500~560、560~565、565~570 m 时,决定系数  $R^2$  分别为 0.98、0.97、0.98,说明 XLD 上游水位低于 570 m 时,BHT 尾水水位不受顶托影响。随着 XLD 上游水位从 570 m 逐步抬升至 600 m,出库流量和下游水位的决定系数  $R^2$  从 0.89 迅速下降至 0.65,二者的散点分布开始逐渐向图像的左上方偏移,实际表现为相同 BHT 出库流量



(a) XLD 水电站水位(500~570 m) (b) XLD 水电站水位(570~600 m)

图 1 不同 XLD 水位下 BHT 出库流量与下游水位关系

Fig. 1 Relationship between discharge and downstream water level of BHT Hydropower Station under different water levels of XLD Hydropower Station

情况下,下游水位会更高;说明 XLD 的回水开始对 BHT 尾水水位产生顶托作用。当 XLD 上游水位达到 585 m 及以上时,BHT 下游水位和出库流量关系的散点分布呈显著的系统性抬升趋势。综上可知,在计算 BHT 下游水位时,必须要考虑 XLD 上游水位的顶托作用,尤其是当 XLD 上游水位达到 585 m 及以上时。

### 2.2 非线性曲线拟合方法

非线性曲线拟合方法利用当前时刻 XLD 上游水位和 BHT 出库流量为自变量,BHT 下游水位作为因变量,利用最小化残差平方和或最大似然估计等优化方法对模型参数进行估计和调整,以使拟合曲线与实测数据最为吻合。本文采取三次混合交叉多项式进行拟合,函数为:

$$Z_{\text{bht}} = ax + bx^2 + cx^3 + dy + ey^2 + fy^3 + gxy + \epsilon \quad (1)$$

式中, $Z_{\text{bht}}$  为 BHT 尾水水位; $a、b、c、d、e、f、g$  均为拟合系数; $x$  为 XLD 上游代表水位; $y$  为 BHT 出库流量; $\epsilon$  为不确定误差。

统一采用 Levenberg-Marquardt 算法进行求解,Levenberg-Marquardt 算法是一种用于解决非线性最小二乘问题的迭代优化算法,该算法结合了梯度下降方法和高斯—牛顿方法的优点,对于非线性最小二乘问题具有较好的收敛性和稳定性,即通过在每一步中动态调整梯度下降和高斯—牛顿方法之间的比例来平衡两者的优势,从而更有效地搜索最小二乘解曲线。

### 2.3 基于多情景划分的 BO-LSTM 的下游水位预测方法

长短期记忆神经网络(LSTM)是一种深度学习递归神经网络(RNN)的变体,专门设计用于处理序列数据。LSTM 的核心结构包括输入门、遗忘门和输出门,这些组件允许网络选择性地存储、遗忘和输出信息。在水位—流量关系建模预测中,LSTM 的优势尤为明显。这是因为其设计的记忆单元能够有效捕捉和利用过去的水文数据,预测未来的水位和流量。LSTM 对时间序列数据的长期依赖性处理能力,使得它在面对不规则时间间隔和复杂环境影响时,展现出极好的适应性和准确性。

贝叶斯优化(BO)是一种全局优化算法,可有效地优化 LSTM 模型中的隐藏层层数、神经元数量和初始学习率等超参数,提高模型的泛化能力和稳定性。贝叶斯优化算法的核心优势在于其能够通过贝叶斯定理充分利用每一次函数评估(即 LSTM 模型在特定超参数组合下的训练与验证)

所获得的信息,不断细化对目标函数形状的理解。通过迭代选择并评估最有可能改善模型性能的超参数组合,算法逐步缩小搜索空间,最终逼近全局最优解。贝叶斯优化 LSTM 时,首先需要初始化超参数搜索空间,然后使用概率代理模型(如高斯过程)来近似真实目标函数,利用采集函数对每个超参数组合下的 LSTM 模型进行预测和评估,从而计算目标函数值超过当前最优值的概率,以此作为调整超参数的参考依据。本文采用高斯过程作为概率代理模型,用于估计目标函数的均值  $\mu(x)$  和方差  $\sigma^2(x)$ ,高斯过程的具体形式为:

$$f(x) \approx N(\mu(x), \sigma^2(x)) \quad (2)$$

式中,  $N$  为高斯分布。

采集函数采用概率改进( $P_1$ ),其定义为:

$$\begin{cases} P_1(x) = P(f(x) \geq f(x^+) + \alpha) = \\ \Phi\left(\frac{\mu(x) - f(x^+) - \alpha}{\sigma(x)}\right) \\ x_{\text{next}} = \underset{x \in X}{\operatorname{argmin}} P_1(x) \end{cases} \quad (3)$$

式中,  $P_1(x)$  为采集函数;  $\alpha$  为超参数,当  $\alpha$  趋近于 0 时  $P_1(x)$  的值收敛于  $f(x^+)$ ,避免了局部最优;  $\Phi(\cdot)$  为正态累积分布函数。

BO 在评价目标函数  $f(x)$  时不断重复高斯过程回归和采集函数,直到达到最大迭代次数。

考虑回水顶托影响下 BHT 水电站下游水位的复杂工况,因此在采取数据驱动方法预测 BHT 水电站下游水位时,有必要根据蓄水时段和 XLD 水电站水位划分为多个情景进行讨论。具体而言,首先按时段划分为蓄水期(当年 9 月初~次年 2 月底)和非蓄水期(3 月初~8 月底),然后计算 XLD 水电站的日平均水位,按照 570 m 为间隔划分为 4 种情景,再分别进行建模,最后进行聚合得到整体的预测结果。整个流程见图 2。

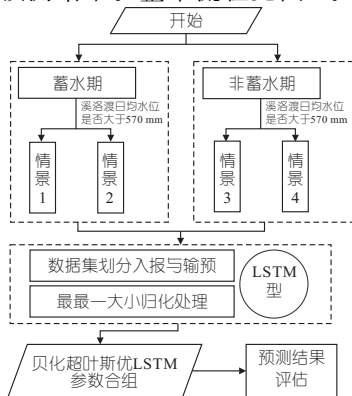


图 2 基于多情景划分和 BO-LSTM BHT 水电站下游水位预测流程

Fig. 2 Based on multi-scenario division and BO-LSTM BHT Hydropower Station downstream water level prediction process

### 3 模型评估

#### 3.1 模型输入与参数设置

LSTM 模型结构由 2 个隐藏层和 1 个全连接层组成,激活函数设置为 ReLU,使用 Adam 梯度下降优化技术来优化内部权重和偏置,损失函数为 MSE,迭代次数为 100 次。训练过程中,每个情景下时间序列数据的前 70% 确定为训练数据,后 30% 的确定为测试数据,同时对输入的预报因子进行最大最小归一化。预报因子为当前时刻 BHT 出库流量与 XLD 上游水位及前一个时刻的 BHT 尾水水位与 XLD 上游水位,输出因子均为当前时刻 BHT 尾水水位。

在使用贝叶斯优化算法进行 LSTM 的超参数优化时,超参数组合包括隐藏层神经元个数(范围:32~256,步长为 8)、学习率(范围: $10^{-1} \sim 10^{-5}$ ,个数为 5)和 Dropout 率(范围:0.1~0.8,步长为 0.1)。采取原始水位—流量关系曲线的计算结果与本文采用的两种方法进行对比,原始水位—流量关系曲线形式为:

$$Z_{\text{bht}} = f(Q_{\text{out}}) = \begin{cases} f_1(Q_{\text{out}}) & Z_{\text{xld}} \leq 560 \\ f_2(Q_{\text{out}}) & 560 < Z_{\text{xld}} \leq 565 \\ \vdots & \vdots \\ f_8(Q_{\text{out}}) & 595 < Z_{\text{xld}} \leq 600 \\ f_9(Q_{\text{out}}) & Z_{\text{xld}} \geq 600 \end{cases} \quad (4)$$

使用决定系数( $R^2$ )、均方根误差( $R_{\text{RMSE}}$ )、平均绝对误差( $M_{\text{MAE}}$ )和标准偏差( $\sigma$ )来评估模型预测结果。

#### 3.2 结果评估

表 1 为不同水位预测方法的评价结果。由表 1 可看出,BO-LSTM 的预测精度显著优于原始水位—流量关系曲线,均方根误差  $R_{\text{RMSE}}$ 、平均绝对误差  $M_{\text{MAE}}$ 、标准偏差  $\sigma$  分别降低了 56.8%、68.1%、45.9%。而非线性曲线的预测精度显著优于原始水位—流量关系曲线,平均绝对误差  $M_{\text{MAE}}$ 、均方根误差  $R_{\text{RMSE}}$  分别降低了 38.7%、

表 1 BHT 水电站下游水位预测结果

Tab. 1 Prediction result of water level in the lower reaches of BHT Hydropower Station

评价指标	水位—流量 关系曲线	非线性 曲线	BO-LSTM	
			训练数据	测试数据
决定系数( $R^2$ )	0.966	0.987	0.998	0.997
均方根误差 $R_{\text{RMSE}}$	1.550	0.950	0.410	0.420
平均绝对误差 $M_{\text{MAE}}$	1.330	0.720	0.220	0.240
标准偏差 $\sigma$	0.790	0.610	0.330	0.330

45.8%。整体来看,BO-LSTM 方法的预测结果最优,标准偏差  $\sigma$  仅为 0.330,决定系数  $R^2$  达到了 0.997。说明基于深度学习的水位预测模型在复杂回水顶托因素影响下的预测精度要优于传统方法。

图 3 为不同预测模型的误差序列和散点分布。由图 3 可看出,水位—流量关系曲线的预测误差明显高于非线性曲线和 BO-LSTM,最高绝对误差超过了 4 m,同时二者的散点分布较为零散,说明水位—流量关系曲线的预测结果具有更高的不确定性。基于 BO-LSTM 的预测结果曲线序列可很好地与真实水位曲线序列相吻合,BO-LSTM 超过 99% 时刻的绝对误差在 0.5 m 以内,平均为 0.16 m。

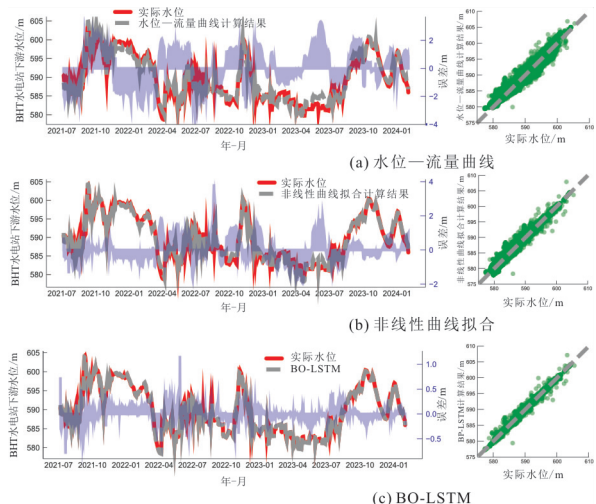


图 3 不同预测模型的误差序列和散点分布  
Fig. 3 Error sequence and scatter distribution of different prediction models

图 4 为 BHT 水电站处于泄洪和调峰工况下的预测结果。由图 4 可看出,2021 年某日,BHT 水电站启动试验性泄洪,最高下泄流量超过 7 000  $m^3/s$ ,造成下游水位骤涨 2.1 m。对比发现 BO-LSTM 能更好地捕捉水位的起幅和消落过程,此过程 BO-LSTM 的平均绝对误差为 0.05 m,最高为 0.4 m,而水位—流量关系和非线性曲线的平均绝对误差分别为 1.74、0.68 m。2023 年某日,为缓解高温带来的电力紧张问题,BHT 水电站启动调峰工作,最高调峰量超过  $300 \times 10^4 kW$ 。发现 3 种预测方法均能较好地反映出下游水位的骤升骤降,但 BO-LSTM 的预测误差更低,平均绝对误差为 0.48 m,而水位—流量关系和非线性曲线拟合的平均绝对误差分别为 0.91、1.68 m。在电站频繁调峰情景下,出库流量的剧烈波动显著增加了下游水位预测的复杂性。

图 5 为基于水位—流量曲线、非线性曲线拟




图 4 BHT 水电站泄洪和调峰工况下的预测结果

Fig. 4 The forecast results of BHT Hydropower Station under the conditions of flood discharge and peak regulation

合和 BO-LSTM 方法对 BHT 下游水位预测结果。由图 5 可看出,水位—流量曲线的平均绝对误差在不同月份具有较大的差异,标准差为 0.54 m,其中最高的平均绝对误差为 2.2 m(6 月),最低的平均绝对误差为 0.5 m。BO-LSTM 和非线性拟合曲线在不同月份之间的平均绝对误差分布比较均匀,标准差分别为 0.28、0.09 m。BO-LSTM 在所有月份的预测误差均低于水位—流量曲线和非线性曲线拟合方法。




图 5 不同月份下的平均绝对误差

Fig. 5 The average absolute error under different months

## 4 结论

a. 本文建立了基于多情景划分的 BO-LSTM 预测模型,通过基于蓄水周期与日均水位的多情景划分,并引入贝叶斯优化算法对 LSTM 模型进行调优,有效提升了模型在不同工况下的预测精度和鲁棒性。

b. 当 XLD 水电站水位高于 585 m 后,开始对 BHT 水电站尾水水位产生明显顶托作用,决定系数  $R^2$  从 0.89 迅速下降至 0.65,此时 BHT 水电站尾水水位与出库流量之间的散点关系明显偏离。

c. 基于多情景划分的 BO-LSTM 预测精度显著优于非线性曲线拟合方法,平均绝对误差相对降低了 68.1%,决定系数  $R^2$  达到 0.997,标准偏差  $\sigma$  为 0.330。同时非线性曲线的预测精度显著优于原始水位—流量关系曲线,平均绝对误差降低了 38.7%。在 BHT 水电站频繁调峰和泄洪

工况下,BO-LSTM 均能更准确地捕捉水位的起幅和消落过程,平均绝对误差分别为 0.48、0.05 m。频繁调峰情景下出库流量的剧烈波动显著增加了下游水位预测复杂性。BO-LSTM 方法在不同月份中具有比水位—流量曲线和非线性拟合方法更均匀的预测误差,显示出良好的稳定性和适用性。

d. 尽管基于多情景划分的 BO-LSTM 模型在尾水位预测中具有较高的精度,但在极端工况下(如电站频繁调峰导致出库流量剧烈波动)仍显局限。结合河道水动力模型的精细化模拟,揭示出库流量对下游水位的具体影响,并对模型预测结果实时修正以提高预测精确度和可靠性,将是未来进一步研究的重点。

#### 参考文献:

- [1] 张勇传. 水电站经济运行原理[M]. 2 版. 北京: 中国水利水电出版社, 1998.
- [2] 贾本军, 周建中, 陈潇, 等. 水电站尾水位特性解析与建模[J]. 水力发电学报, 2021, 40(10): 45-59.
- [3] 曹辉, 张继顺, 董先勇, 等. 白鹤滩水电站受溪洛渡水电站回水顶托影响的分析[J]. 水力发电, 2017, 43(12): 65-67, 75.
- [4] 何中政, 钱伟, 傅春, 等. 基于逐步回归分析的峡江水库对吉安水位顶托作用量化分析[J]. 中国农村水利水电, 2024(7): 53-59.
- [5] HUANG J W, QIN H, ZHANG Y C, et al. Short-term prediction method of reservoir downstream water level under complicated hydraulic influence [J]. Water resources management, 2023, 37(11): 4475-4490.
- [6] SHAO Q X, DUTTA D, KARIM F, et al. A method for extending stage-discharge relationships using a hydrodynamic model and quantifying the associated uncertainty [J]. Journal of hydrology, 2018, 556: 154-172.
- [7] 柳俊, 李匡, 黄存宇, 等. 有尾水位顶托的上下游水电站的水位影响分析与控制方法[J]. 水电与新能源, 2021, 35(8): 31-35.
- [8] 李俊聪, 张勇传, 覃晖, 等. 锦东—官地梯级水电站短期调度中的电站间流量响应关系研究[J]. 水电能源科学, 2023, 41(7): 75-79.
- [9] 刘晓阳, 郭乐. 基于机器学习方法的葛洲坝水电站下游水位预测研究[J]. 水利水电快报, 2022, 43(10): 19-22, 36.
- [10] 刘晓阳, 姚华明, 张海荣, 等. 基于机器学习的三峡水库小时尺度坝前水位预测[J]. 人民长江, 2023, 54(2): 147-151.

## Research on Water Level Prediction of Downstream Giant Hydropower Plant Under Backwater Effect

PENG Wang<sup>1,2</sup>, YAO Hua-ming<sup>2</sup>, JIANG Zhi-qiang<sup>1</sup>, CAO Hui<sup>2</sup>

(1. School of Civil and Hydraulic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China; 2. China Yangtze Power Co., Ltd., Yichang 443002, China)

**Abstract:** The tailwater level of hydropower station is a critical parameter for calculating the unit's output. When influenced by the downstream reservoir's backwater effect, discrepancies often arise between the designed tailwater curve and the actual observed values, leading to increased errors in the output-flow calculations. Utilizing the latest historical observation data, this study explores the relationship between the tailwater level of BHT Hydropower Station, its discharge, and the water level of the downstream XLD Reservoir. A Bayesian optimized long short-term memory (BO-LSTM) prediction model is developed based on multi-scenario analysis. The applied effect is analyzed under conditions of peak load and flood discharge. The results indicate that when the water level of XLD exceeds 585 meters, the tailwater level of BHT Hydropower Station is significantly influenced. Compared to the nonlinear curve fitting method, the BO-LSTM model based multi-scenario analysis demonstrates a substantial improvement in accuracy, with an average absolute error ( $M_{MAE}$ ) reduced by 68.1%. The BO-LSTM model more accurately captures the fluctuations and changes in water levels under various operating conditions. The research results have important significant for refined operation of hydropower stations.

**Key words:** water-level discharge relationship; backwater effect; long short-term memory neural networks; prediction