

张午. 基于多模块耦合预测框架的水源水库水位快速预测方法[J]. 净水技术, 2026, 45(3): 38-51.

Zhang W. A rapid water level forecasting method for reservoir of water source based on multi-module coupling prediction framework [J]. Water Purification Technology, 2026, 45(3): 38-51.

基于多模块耦合预测框架的水源水库水位快速预测方法

张 午*

(上海城市水资源开发利用国家工程中心有限公司, 上海 200082)

摘 要 【目的】针对人工调控主导的水库型水源地水位变化规律复杂、传统预测方法精度不足的难题, 本文旨在构建并验证一种物理信息融合的多模块机器学习耦合预测框架, 以实现对此类水库水位的合理且兼具高时效性的预测, 为水库的精细化调度提供决策支持。【方法】本文将该预测框架应用于 JZ 水库, 对水库内运行机理不同的调控单元进行定制化建模: (1) 对引水闸门流量预测采用双层级联模式, 基于先知模型(Prophet)的闸门开度时序预测与基于极端梯度提升(XGBoost)的流量系数(C_d)动态估计, 通过闸门流量计算公式获得预测结果; (2) 对取水泵流量预测采用二阶段策略, 利用随机森林(RF)和 XGBoost 分离了泵启停状态预测与流量大小预测; (3) 对具有强周期性特征的输水泵流量, 直接采用轻量级梯度提升机(LightGBM)模型进行流量预测。最终, 各模块预测结果在水量平衡方程的物理约束下进行耦合, 计算未来 24 h 水位变化。【结果】将本文提出的预测框架与传统机理模型在测试集上的预测结果进行对比分析, 结果表明: 本方法各指标表现均优于传统机理模型, 纳什效率系数(NSE)由 0.03 显著提升至 0.56, 平均绝对误差(MAE)由 0.20 m 减小为 0.19 m, 平均绝对百分比误差(MAPE)由 9.03% 减小为 8.06%, 同时本方法计算效率较传统模型显著提升。【结论】本文提出的多模块耦合预测框架, 通过将复杂系统拆解并深度融合数据驱动与物理机理后再进行耦合预测, 为解决人工调控主导型水库水位预测问题提供了兼具精度与效率的参考方法, 为水源地智能化管理提供新思路和技术支持。

关键词 水位预测 多模块耦合预测框架 水源水库 双层级联模式 二阶段策略 物理信息融合

中图分类号: X524 **文献标志码:** A **文章编号:** 1009-0177(2026)03-0038-14

DOI: 10.15890/j.cnki.jsjs.2026.03.004

A Rapid Water Level Forecasting Method for Reservoir of Water Source Based on Multi-Module Coupling Prediction Framework

Zhang Wu*

(Shanghai National Engineering Research Center of Urban Water Resource Co., Ltd., Shanghai 200082, China)

Abstract [Objective] In response to the complex water level variation patterns of reservoir drinking water source area that are mainly regulated by humans, as well as the insufficient accuracy of traditional prediction method, this paper aims to develop and validate a physics-informed multi-module machine-learning coupled prediction framework to achieve reasonable and timely water level predictions for such reservoirs, thereby providing decision support for refined reservoir scheduling. [Methods] This paper applied this prediction framework to the JZ reservoir and conducted customized modeling for different control units with different operating mechanisms within the reservoir: (1) For the flow prediction of the water diversion gate, a two-level cascading model was adopted, combining the time series prediction of the gate opening degree based on Prophet model and the dynamic estimation of the coefficient of discharge (C_d) based on extreme gradient boosting (XGBoost), and obtaining the prediction result through the gate flow calculation formula; (2) For the prediction of intake pump flow, a two-stage strategy was adopted, which used random forest (RF) for pump on/off state prediction and XGBoost for flow rate prediction; (3) For transfer pumps exhibiting strong periodicity, light gradient boosting machine (LightGBM) was used for direct flow rate forecasting. Finally, the prediction results of each module were coupled under the physical constraints of the water balance equation, and the water level changes over the next 24 hours were calculated. [Results] The

[收稿日期] 2025-08-12

[基金项目] 国家重点研发计划(2021YFC3201303); 上海市科委“科技创新行动计划”(23DZ1203002)

[通信作者] 张午(1990—), 男, 工程师, 主要从事水动力水环境数值模拟等工作, E-mail: 490732746@qq.com。

prediction framework proposed in this paper was compared with the prediction result of the traditional mechanism model on the test set. The result showed that the performance of each indicator of this method was superior to that of the traditional mechanism model. The Nash-Sutcliffe efficiency (NSE) coefficient significantly increased from 0.03 to 0.56, the mean absolute error (MAE) decreased from 0.20 m to 0.19 m, the mean absolute percentage error (MAPE) decreased from 9.03% to 8.06%, and the calculation efficiency of this method was significantly higher than that of the traditional model. [Conclusion] The multi-module coupled prediction framework proposed in this paper, by decomposing complex systems and deeply integrating data-driven and physical mechanism approaches before conducting coupled predictions, provides a reference method with both accuracy and efficiency for solving the problem of water level prediction in human-controlled reservoirs, and offers new ideas and technical support for intelligent management of water sources.

Keywords water level prediction multi-module coupling prediction framework reservoir of water source two-level cascaded mode two-stage strategy physical information fusion

饮用水水源地是居民饮用水安全的重要保障^[1],而水库型水源地是饮用水水源地的一种,也是城市供水系统的核心基础设施,其水位管理不仅直接关系到城市供水安全,还影响水质稳定性和供水系统运行效率^[2]。因此,提升水位预测精度对于指导水库科学调度、优化水资源配置及降低运行成本具有重要的现实意义。一般而言,水库水位波动受到自然来水(如地表径流、降雨)与人工调度(如取水、输水)的共同影响。而在部分以供水为主要任务的水库型水源地,特别是位于平原河网地区的水库,其水位变化更多地表现为以取输水设施运行等人工调控行为为主导,地表径流等自然因素的影响相对较小。这种以人工调控为主导的运行模式导致水位变化规律复杂,呈现出高频、非线性的动态特征,使得侧重于模拟自然水文过程的传统预测模型面临较大挑战,难以满足智慧化调度对高精度、高时效性的要求。

当前,水位的预测方式大致可分为机理模型和数据驱动模型两大类。机理模型以现实的水文循环或物理规律为基础,利用地质学及数学公式推演水位^[3]。这类模型在描述自然水文演进规律方面理论基础扎实,但应用于以人工调控为主导的水库型水源地时,往往难以精确刻画闸门开度、水泵启停等高频、非线性的动态边界条件,导致模型构建复杂且精度受限。随着监测数据日益丰富与机器学习技术的进步,从历史数据中自主学习复杂映射关系的数据驱动模型获得了广泛应用。Gharehbaghi等^[4]使用门控循环单元(GRU)模型预测地下水位;纪国良等^[5]使用循环神经网络(RNN)也能较为准确地预测水库水位;杨婷婷等^[6]提出基于嵌入式-门控循环单元(Embedding-GRU)的水库水位预测模型,其

可进行更可靠的预测,适用水库范围更广。然而,现有研究多倾向于采用单一模型直接进行水位预测,这可能会面临2个问题:其一,模型设计缺乏物理信息的融合,导致结果可靠性不强;其二,对于包含多个调控单元的复杂系统,单一模型难以精细化地捕捉每个调控单元独特的运行模式和内在规律。

而从水源地管理层面出发,提升水位预测的精度与时效性具有多重现实价值。(1)安全保障与应急韧性:24 h滚动预测可提前识别低水位或高水位波动风险,减少停泵、溢流等事件发生概率,提升突发事件下的应对能力;(2)水质稳定运行:有助于维持取水口水力条件与库内水力停留时间的稳定,保证原水水质稳定;(3)能耗与成本:在合理预测水位的基础上可结合负荷评估,优化泵站启停与闸门开关,实现节能降耗。

综上所述,现有研究在以人工调控为主的水库型水源地水位预测领域仍存在不足,因此,本研究以华东地区典型的水库型水源地——JZ水库为研究对象,提出了一种物理信息融合的多模块耦合预测框架,旨在通过对不同调控单元的定制化建模,并在水量平衡等物理约束下进行耦合,实现对未来24 h水位的高精度、快速预测。该框架在保证物理一致性的同时兼顾计算效率,具备一定的可部署性与推广性,可为水库安全稳定运行、精细化调度、水质保障与能耗优化提供决策支撑。

1 材料与方法

1.1 研究区域概况

JZ水库为华东地区某市重要供水水源地,水库占地面积为2.7 km²,其中水域面积为1.9 km²,水库库容为910万m³,设计日供水规模达351万m³,最高蓄水位为3.30 m,常水位为2.40~2.50 m^[7]。

1.2 水量平衡复杂性分析

JZ 水库的水量平衡由引水闸门、取水泵站和输水泵站 3 个核心单元共同调控,而降雨、蒸发、地表径流等因素对库内水位影响有限,且水库底部及周边也已进行过有效的防渗处理,使得地表水与地下水的交换水量相较于人工调控的水量可以忽略不计。因此,这一简化对于以人工调度为主导的 JZ 水库水位预测是合理且可接受的。JZ 水库水量平衡系统构成如图 1 所示。

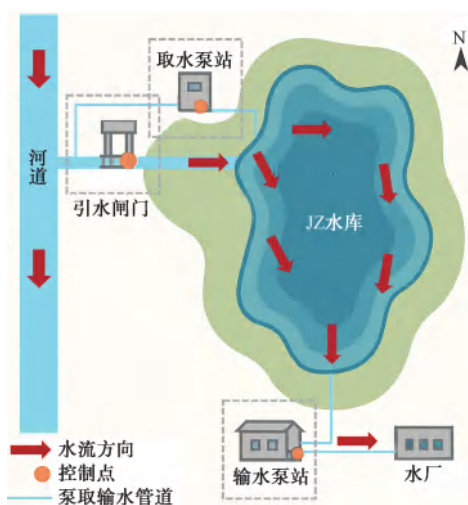


图 1 JZ 水库水量平衡系统构成

Fig. 1 Composition of Water Balance System of JZ Reservoir

作为一个以人工调度为主导的水库型水源地,其水位预测的复杂性主要体现在 3 个方面。

(1) 调控单元的动态耦合与运行模式差异:引水闸门(自流)、取水泵站(强抽)和输水泵站(外送)三者功能各异,运行逻辑迥然不同。闸门引水受上游潮位和库内水位差的物理约束;取水泵的启停则与闸门形成互补或交替关系,以应对不同工况;输水泵则需满足下游水厂波动的供水需求。三者之间相互影响、动态耦合,其组合运行模式并非简单的线性叠加,给水位预测带来了挑战。

(2) 人工调度的非线性与不确定性:水库的实际调度并非遵循固定规则,而是由调度人员根据供水需求、上游来水水质、设备检修计划及突发状况等多重因素综合决策。这种依赖专家经验的调度行为具有显著的非线性和一定的随机不可测性,使得预测模型难以仅凭水位历史数据捕捉其内在规律。

(3) 关键物理参数无法准确获取:尽管水量平

衡是基本原理,但其关键参数在实际中难以精确获知。以闸门流量为例,其计算依赖于流量系数(C_d),而 C_d 值会随闸前后水位、闸门开度、水流形态等因素动态变化,无法实时精确测量,而固定 C_d 值则可能会引入更多误差。

因此,JZ 水库水位预测的核心难点在于如何准确模拟多调控单元耦合运行的复杂系统,这也是本研究重点解决的问题。

1.3 数据采集与预处理

JZ 水库已建立非常完善的水质、水量、气象以及设备运行状态等监测与数据采集系统。本研究采集了库内水位(最终预测目标)、闸门开度、取水泵流量、输水泵流量、降雨量、风速风向、气温等数据,采集频率为每小时 1 次,采集时间段为 2023 年 9 月 1 日—2024 年 8 月 31 日,共 8 784 条记录。

原始监测数据可能会出现规模庞大且质量参差不齐的问题,这会制约模型的学习效率和泛化能力。因此,需要实施系统化的数据预处理以构建高质量的基础数据集,为后续模型训练与测试提供可靠的数据基础^[8]。本研究系统构建了数据预处理框架:采用标准分数(Z-score)算法、K 近邻插补技术和滑动平均法对监测数据进行异常值识别与修正、缺失值填补和降噪处理。同时为构建和验证模型的泛化能力,本研究采用时间序列划分法,将预处理后的数据集按时间顺序以 70%、15% 和 15% 的比例,分割为训练集(training set)、验证集(validation set)和测试集(test set)。在此基础上,应用标准化方法对特征空间进行无量纲化处理,以提升数值计算稳定性并加速模型收敛。

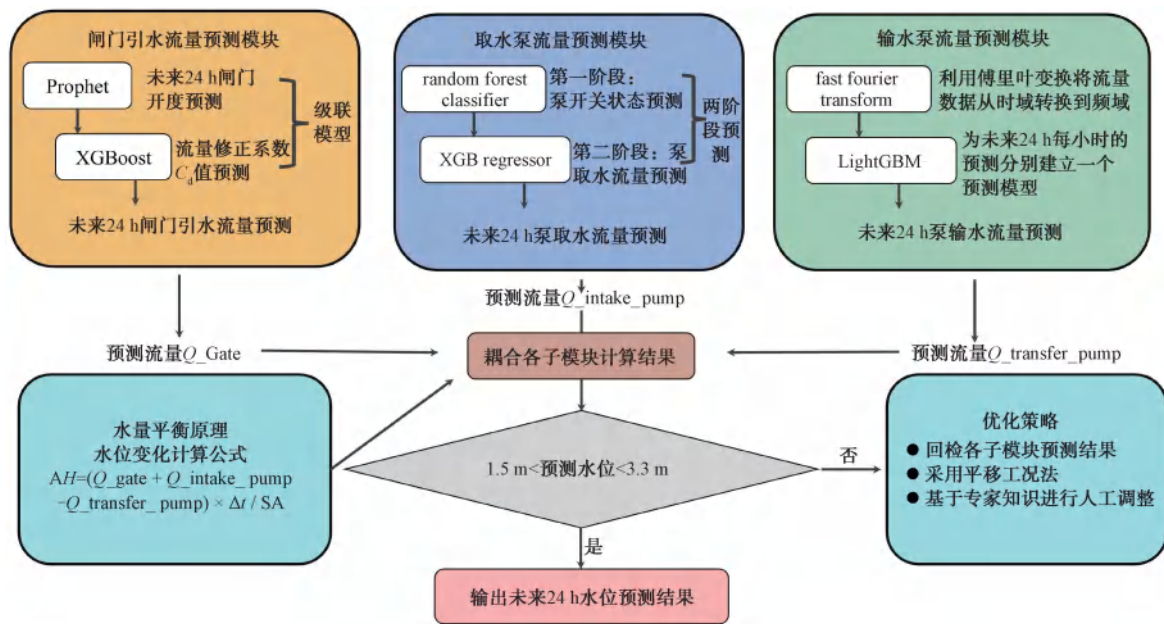
1.4 水位预测模型构建

1.4.1 总体预测框架

本研究构建了一套物理信息融合的多模块机器学习耦合预测框架,如图 2 所示。该框架包含 4 个核心模块,分别为闸门引水流量预测模块、取水泵流量预测模块、输水泵流量预测模块和水位综合预测模块。各模块间逻辑关系清晰,形成了从单元预测到综合决策的完整技术路线。

1.4.2 闸门引水流量预测模块

JZ 水库配置 1#、3# 闸门(宽度为 7 m)和 2# 闸门(宽度为 14 m)进行引水。针对 JZ 水库闸门引水流量的复杂性,本研究构建了一种双层级联预测模型,实现了对闸门引水流量的预测,具体框架如下。



注: Prophet—先知模型; XGBoost—极端梯度提升; Δt —单位时间, h; random forest classifier—随机森林分类器; XGB regressor—极端梯度提升回归器; LightGBM—轻量级梯度提升机; fast fourier transform—快速傅里叶变换; Q_{gate} —闸门引水流量, m^3/s ; Q_{intake_pump} —取水泵流量, m^3/s ; $Q_{transfer_pump}$ —输水泵流量, m^3/s ; ΔH —水位变化, m; SA—水库面积, m^2 。

图2 水位预测框架

Fig. 2 Water Level Forecasting Framework

(1) 基于 Prophet 的闸门开度预测

第一层采用 Prophet 模型对各闸门的开度进行时间序列预测。Prophet 作为一种分解式预测工具, 尤为擅长处理多重季节性问题上^[9]。模型以历史开度数据为基础, 并引入外生回归变量以强化预测的稳定性和可解释性, 主要包括库内外水位差以及由气象预报获取的降雨量等。为精确刻画运行规律, 模型集成了日、周、月等多尺度季节性特征, 并采用乘法季节性模式以适应开度随水力条件变化的动态影响。该层最终输出未来 24 h 的闸门开度预测值。

(2) 基于 XGBoost 的综合流量修正系数动态预测

第二层采用 XGBoost 模型预测 C_d 。XGBoost 是一种基于梯度提升决策树的集成学习模型, 在处理非线性关系和特征交互方面表现优异^[10]。

C_d 反映了实际流量与理论流量的比值, 受闸门开度、水位条件、季节变化等因素影响^[11]。模型输入特征包括由第一层模型输出的开度预测值、库内外水位差以及时间戳衍生的周期性特征。XGBoost 通过其深度树结构, 能够自动学习输入特征与 C_d 之间的复杂非线性关系。利用历史实测流量数据反算

得到 C_d 历史序列作为训练标签。为防止数据泄露, 训练时采用预测开度作为输入特征。

(3) 级联预测与流量计算

最终, 通过级联方式整合 2 层预测结果, 并嵌入修正后的水力学闸孔出流公式进行流量计算, 如式(1)。

$$Q_{gate}(t) = C_d(t) \times b \times a(t) \times \sqrt{2gh(t)} \quad (1)$$

其中: $Q_{gate}(t)$ ——预测的闸门引水流量, m^3/s ;
 $C_d(t)$ ——由 XGBoost 预测的综合流量修正系数;
 b ——闸门宽度, m;
 $a(t)$ ——由 Prophet 预测的闸门开度, m;
 g ——重力加速度, 取值为 $9.81 m/s^2$, m/s^2 ;
 $h(t)$ ——动态计算得到的库内外水位差, m。

未来库外感潮河道的水位采用平移法, 未来库内水位由水量平衡方程滚动更新, 具体可参考式(2)。

1.4.3 取水泵流量预测模块

JZ 水库于 2021 年新建成额定流量为 $60 m^3/s$ 的取水泵站, 形成了“泵站主动取水+闸门自流引

水”的双模式运行体系。针对泵站与闸门交替运行的间歇性特征,本研究构建了一种嵌入物理约束的二阶段预测模型,将复杂的预测任务拆解为状态识别与流量预测 2 个核心环节^[12]。

(1) 第一阶段:基于随机森林分类器(RFC)的启停状态识别

本阶段采用 RFC 判别泵站未来 24 h 的逐时启停状态。针对泵站启停样本不均衡问题(“开启”样本明显少于“关闭”样本),采用合成少数类过采样技术(SMOTE)算法平衡训练集,并以 F-beta 评分($\beta=4.0$, β 为召回率相对于精确率的重要性倍数)为优化目标,同时对 RFC 输出的概率进行阈值寻优,以重点提升对“开启”状态的召回率,降低关键时段的漏报风险^[13]。

(2) 第二阶段:基于 XGBoost 的开启状态流量预测

针对第一阶段预测为“开启”的时段,采用 XGBoost 回归器预测具体的取水流量。为确保模型的泛化能力,本阶段在训练时,使用了第一阶段产生的状态预测作为输入特征,而非真实的标签,以模拟真实的预测流程。模型的输入特征体系还涵盖了水位差、降雨量等环境变量,以及历史状态和流量的滞后项与滚动统计量。

1.4.4 输水泵流量预测模块

输水泵承担着向水厂连续供水的任务,其流量序列呈现出强烈的周期性,但不存在间歇性启停。针对这一特性,本研究采用 LightGBM 算法构建了一个直接多步预测模型。该策略为未来 1~24 h 的每一个预测步长独立训练一个专门的预测模型。为驱动模型学习,本研究构建了一个融合物理先验的多尺度特征体系,主要包括 3 个层面。

(1) 物理驱动特征:基于泵-管系统水力学的基本原理,构建了能够反映系统驱动力的核心变量,如库内外水位差及其平方根。这些特征将物理规律作为先验知识嵌入模型,提升了模型的可解释性。

(2) 多尺度时序特征:为全面捕捉流量的动态依赖性,提取了覆盖 1~3 h(短期)、6~12 h(中期)和 24 h(长期)的历史流量滞后项、滚动统计量(均值、方差)及一阶差分。

(3) 自适应周期特征:通过对训练集进行傅里叶变换识别出流量序列中能量最强的主导周期(如 24、12 h),并以此为基础构建了相应的正弦、余弦周

期特征,使模型能够自适应地学习其周期性规律。

LightGBM 作为一种高效的梯度提升框架,在处理本研究所构建的高维、异构特征集方面表现优异^[14]。在预测阶段,模型输出的原始预测值会通过物理投影被裁剪至设备允许的流量范围内,确保结果的合理性。

1.4.5 水位综合预测模块

本模块将前述 3 个子模块的流量预测结果进行耦合,通过水量平衡原理对库内水位进行滚动预测,同时引入反馈调整机制以增强预测的鲁棒性。

(1) 基于水量平衡的水位滚动预测

在获得未来 24 h 逐时的闸门引水流量、取水泵流量和输水泵流量后,依据离散化的水量平衡方程对库内水位进行递推。考虑到 JZ 水库在常规工况下水位波动幅度有限,采用固定等效水域面积进行线性化近似是可接受的,如式(2)。

$$L_{t+1} = L_t + \frac{[Q_{\text{gate}}(t) + Q_{\text{intake}}(t) - Q_{\text{transfer}}(t)] \times \Delta t}{S_{\text{Area}}} \quad (2)$$

其中: L_{t+1} —— $t+1$ 时刻库内水位,m;

L_t —— t 时刻库内水位,m;

$Q_{\text{gate}}(t)$ ——预测闸门引水流量, m^3/s ;

$Q_{\text{intake}}(t)$ ——预测取水泵流量, m^3/s ;

$Q_{\text{transfer}}(t)$ ——预测输水泵流量, m^3/s ;

Δt ——单位时间,取值为 3 600 s,s;

S_{Area} ——等效水域面积,取值为 1 920 000 m^2 , m^2 。

(2) 基于安全水位的反馈调整机制

考虑水库运行安全和水质保障需求,JZ 水库运行水位根据经验需控制在一定范围内,本研究基于历史数据分析设置为[1.5 m, 3.3 m]。另外,为提高预测结果的合理性,本文嵌入了反馈调整机制。

1) 若初步预测的 24 h 水位序列均为[1.5 m, 3.3 m],则直接输出该序列。

2) 若预测水位超出控制区间,表明预测可能偏离实际调度决策。此时启动反馈机制即以前一日实际运行工况(包括引水闸门、取水泵和输水泵的运行参数)为输入,重新预测各控制因素并计算水位序列。如果依然存在异常,则需要依赖专家经验进行人工调整或者确定。

1.5 模型评估指标

为了全面评估所构建模型的性能,本研究针对

不同任务采用多项评估指标,,具体如表 1 所示。评估指标的计算如式(3)~式(10)。

表 1 模型性能评估指标
Tab. 1 Model Performance Evaluation Indices

任务类型	指标名称	计算公式	说明
状态分类	准确率	式(3)	正确预测的样本占总样本的比例
	精确率	式(4)	预测为正的样本中实际为正的样本比例
	召回率	式(5)	实际为正的样本中被成功预测的比例
	F1 分数	式(6)	精确率和召回率的调和平均值
流量/水位预测	均方根误差	式(7)	衡量预测值与真实值离散程度
	平均绝对误差	式(8)	衡量模型预测值与真实值之间偏差的平均绝对程度
	平均绝对百分比误差	式(9)	衡量模型预测值与真实值之间偏差的平均相对程度
	纳什效率系数	式(10)	水文模型模拟优度的常用指标,衡量模型预测值与实测值吻合程度

$$A_{cc} = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \quad (3)$$

其中: A_{cc} ——准确率;

T_P ——真正例,预测为正,实际也为正;

T_N ——真负例,预测为负,实际也为负;

F_P ——假正例,预测为正,实际为负;

F_N ——假负例,预测为负,实际为正。

$$P = \frac{T_P}{T_P + F_P} \quad (4)$$

其中: P ——精确率。

$$R = \frac{T_P}{T_P + F_N} \quad (5)$$

其中: R ——召回率。

$$F_1 = 2 \times \frac{P \times R}{P + R} \quad (6)$$

其中: F_1 ——F1 分数。

$$R_{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

其中: R_{MSE} ——均方根误差;

y_i ——第 i 个样本的真实值;

n ——样本总数;

\hat{y}_i ——第 i 个样本的预测值。

$$M_{AE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

其中: M_{AE} ——平均绝对误差。

$$M_{APE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (9)$$

其中: M_{APE} ——平均绝对百分比误差。

$$N_{SE} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

其中: N_{SE} ——纳什效率系数;

\bar{y} ——所有样本真实值的平均值。

2 结果与分析

2.1 闸门引水流量模型结果分析

2.1.1 闸门运行模式分析与物理约束提取

对研究时段三道闸门的运行数据进行分析,结果如图 3 所示。从流量贡献可知[图 3(a)],水库引水任务主要由 1#和 3#闸门承担,二者流量贡献约占总量的 98%。进一步分析闸门开度与流量的关系发现[图 3(b)],2#闸门理论过流能力最强,但绝大多数时间处于关闭状态(开度为 0),仅在特定工况下短时开启,此外,所有闸门的运行开度均大于 0.3 m,不存在小开度运行工况。上述发现为后续模型构建提供了关键的物理先验知识与约束条件:(1)1#和 3#闸门是主要预测对象,其开启频率和幅度远高于 2#闸门;(2)可将模型预测出的低于 0.3 m 的开度值修正为 0,以符合物理实际,避免不合理的预测输出。

2.1.2 闸门开度预测模块性能评估

本模块的主要任务是准确预测连续的闸门开度值。图 4 展示了第一层 Prophet 模型在测试集上的




图 3 闸门流量贡献比及开度与流量的关系

Fig. 3 Gate Flow Contribution Ratio and Relationship between Gate Opening Degree and Flow Rate

时序预测结果。整体来看,模型对 3 座闸门的预测精度存在一定差异:1#闸门的 RMSE、MAE 和 NSE 分别为 0.184 8、0.090 3 m 和 0.942 3;3#闸门的 RMSE、MAE 和 NSE 分别为 0.191 0、0.091 8 m 和 0.939 3。两者预测曲线与实测值整体吻合,其 NSE 均超过 0.90,且 MAE 小于 0.1 m,表明模型能够较好地捕捉其运行过程中的周期性和趋势性。相比之下,2#闸门的预测精度相对较低,其 RMSE、MAE 和 NSE 分别为 0.132 8、0.025 2 m 和 0.646 6,这主要由于其历史样本稀疏,难以形成稳定的时间序列模式。

为进一步评估模型对闸门启停行为的判别能力,本研究将预测开度值进行二值化处理(开度>0

为“开启”,否则为“关闭”),并计算其分类评价指标,如表 2 所示。结果显示,1#和 3#闸门的状态识别 F1 分数分别达到了 89.87%和 90.42%,表现稳健。值得注意的是,2#闸门因其关闭状态样本占绝对主导(占比约为 98%),导致其分类准确率高达 99.28%,但这是一种由严重样本不平衡引发的假象。在此场景下,F1 分数能更公允地衡量模型对少数类(开启状态)的识别效能,其结果表明模型对 2#闸门开启状态的预测仍然有提升空间。

综合分析,尽管模型对 2#闸门的预测存在一定偏差,但考虑到该闸门的实际流量贡献极小(<3%),其误差对最终总流量计算的影响可控。因

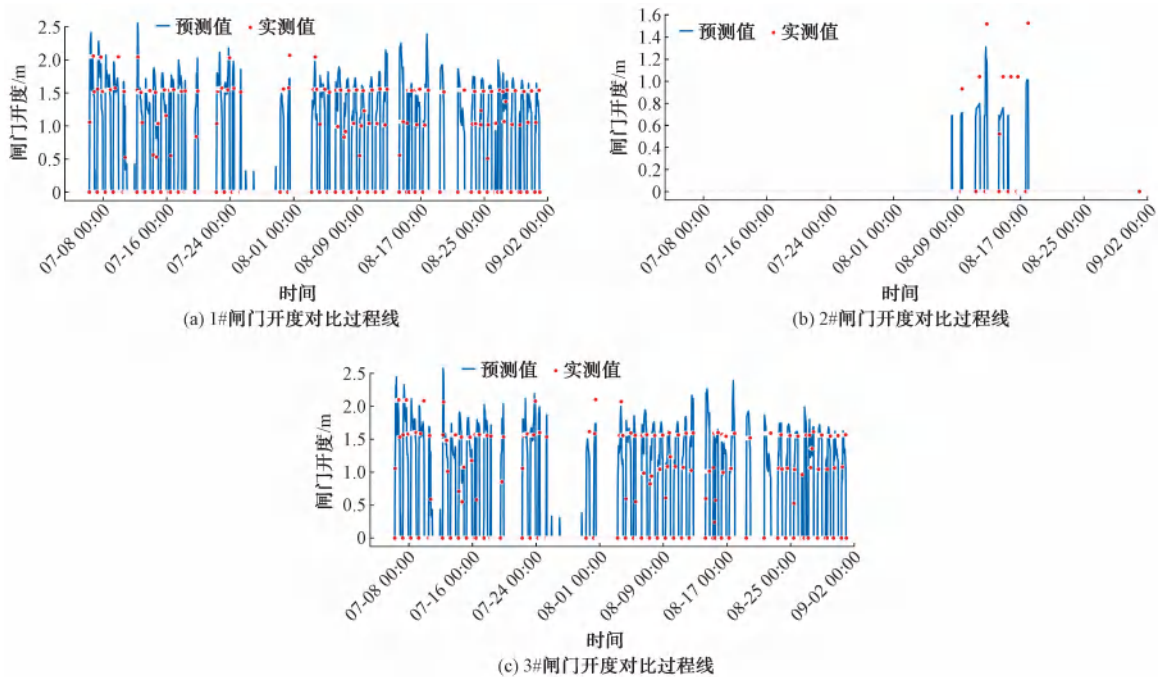


图 4 测试集闸门开度预测结果

Fig. 4 Forecasting Results of Gate Opening Degree in the Test Set

表 2 闸门状态评估结果

Tab. 2 Results of Gate Status Assessment

评估指标	1#闸门	2#闸门	3#闸门
准确率	90.11%	99.28%	90.62%
精确率	81.31%	71.11%	81.98%
召回率	98.43%	72.73%	98.86%
F1 分数	89.87%	71.92%	90.42%

此,该开度预测模型的总体性能较好,并为后续流量系数估计提供了可靠的输入。

2.1.3 C_d 动态预测模块性能评估

准确预测 C_d 是提升流量计算精度的关键。为




图 5 XGBoost 模型特征重要性分析

Fig. 5 Importance Analysis of XGBoost Model Feature

图 6 展示了 C_d 动态预测模型的性能。在训练集和测试集上,模型的 NSE 分别达到了 0.89 和 0.85 [图 6(a)],表明模型对 C_d 值的变化具有良好的解释能力和泛化性能。散点基本沿对角线分布,说明预测值与真实值整体吻合度高。从预测

克服传统固定 C_d 值无法适应复杂工况的缺陷,本研究构建了基于 XGBoost 的 C_d 动态预测模型,将第一层 Prophet 模型预测的闸门开度作为输入条件参与第二层 XGBoost 模型的训练和预测。

为验证模型的物理可解释性,分析了模型输入特征的重要性,如图 5 所示。“水位差平方根”和“开度×水位差”交互项等物理相关特征占据主导地位,证明模型成功学习到了关键的水力学驱动机制。此外,不同闸门的预测开度也成为重要特征,说明模型有效区分了各闸门在不同工况下的差异性。

性能评估[图 6(b)]可知,预测模型误差集中在 C_d 模拟值为 0.5~0.8,误差主要分布在 ± 0.05 以内,可以认为预测模型偏差小且集中。总体而言,该模型有效捕捉了 C_d 值随水力条件变化的内在规律。




图 6 C_d 预测值与真实值对比

Fig. 6 Comparison of C_d Prediction and Actual Values

2.1.4 综合流量预测精度对比分析

为最终验证本文方法的有效性,将采用 C_d 动态预测模型计算的流量与采用 3 种不同固定 C_d 值 (0.6, 0.7, 0.8, 为经验常用值) 计算的流量进行精

度对比,结果如表 3 所示。结果表明,基于动态预测 C_d 的方法展现出最优性能,其 NSE 达到 0.90,显著高于所有固定 C_d 方案。在误差指标上,其 MAE (11 270 m^3/h) 和 RMSE (23 669 m^3/h) 也远低于其

他方案。这充分证明,通过数据驱动方法动态估计 C_d ,能更准确地反映真实水力过程,也说明本文提出的双层级联模型具有可行性。

表 3 测试集动态预测 C_d 与固定 C_d 计算流量精度评估

Tab. 3 Accuracy Evaluation of Flow Rate Calculation for Adaptive C_d and Fixed C_d Values in the Test Set

评估指标	动态预测 C_d	固定 $C_d(0.6)$	固定 $C_d(0.7)$	固定 $C_d(0.8)$
NSE	0.90	0.80	0.74	0.59
RMSE	23 669	33 568	38 036	47 685
MAE	11 270	18 991	19 631	26 194

2.2 取水泵流量预测模型结果分析

2.2.1 多周期滚动预测总体性能评估

取水泵流量预测模型采用“状态预测+流量预测”的二阶段策略。为验证模型性能,在测试集上进行了多个周期的滚动预测(每次预测未来 24 h)。图 7(a)~图 7(b)直观展示了模型的预测结果。在大部分时间段内,模型能够准确预测泵的开关状态及相应的流量变化趋势。图 7(c)~图 7(e)对多个周期的预测性能进行了定量统计。结果显示,模型性能虽存在一定的周期性波动,这可能与不同周期内水文工况、调度策略的变化有关,但总体而言,模型在状态预测方面表现稳健,多周期状态预测准确率达到 80.73%,多周期 F1 分数达到 83.26%;在流量预测方面,评估泵实际开启状态下的平均 RMSE 为 16.0 m³/s,表明在泵开启时,流量大小的预测较为准确。

2.2.2 模型误差来源的定量归因与物理可解释性分析

预测误差主要包含 2 个部分,分别为状态切换导致的状态预报误差以及流量变化产生的流量预报误差。首先,为深度剖析模型的误差构成,本研究设计了 2 种口径的 RMSE 指标进行对比[图 7(d)~图 7(e)]。

(1)流量预测 RMSE:统计状态预测正确的开启样本,用于衡量流量预测模块的固有精度。

(2)端到端 RMSE:统计所有样本,其误差包含了流量预测模块的固有误差,以及因状态预测错误(如将“开启”误判为“关闭”)而引入的惩罚性误差。

结果显示,多周期平均的流量预测 RMSE 为 16.0 m³/s,而端到端 RMSE 为 17.6 m³/s,二者非常接近,表明由状态预测错误额外引入的误差增量非

常小。这一关键发现有力地证明了第一阶段的状态预测模型 RFC 是高效且可靠的,其预测误差对总体误差的贡献十分有限。因此,可以明确该二阶段模型的主要预测误差来源为第二阶段的流量预测模型。为进一步诊断流量预测模块的误差特性,本文对其在不同工况下的表现进行了分析。结果发现,模型的预测误差主要集中在泵组刚刚开启的初始阶段以及流量处于峰值的短暂时段,而在长时间稳定运行的中等流量区间,其预测精度较好。这种误差分布特性表明,模型对稳态运行模式的捕捉已较为成熟,但对动态转换过程的瞬时响应仍有提升空间。然而,从应用角度分析,这种误差特性是可以接受的,因为它保证了对系统常态运行模式的准确识别。

其次,对模型的物理可解释性进行探究。特征重要性分析表明,“泵开启持续时间_平方”和“泵开启持续时间”是影响预测的最关键特征,两者合计贡献度超过 60%。这与水泵运行的物理特性和管理规律较为一致:水泵的运行状态具有惯性,一旦开启或关闭,通常会持续一段时间,而非频繁切换。此外,时间周期特征“hour_cos”和流量时滞特征“取水泵流量_lag”也具有一定重要性,说明模型兼顾了运行的周期性和连续性。

总体而言,本研究采用二阶段模型的设计是合理的,通过将复杂的预测任务拆解为“状态识别”和“流量预测”2 个子问题,状态预测模型的突出性能保证了预测的可靠性,而流量预测模型虽为主要误差来源,但其结果仍然具有较好的可信度。

2.3 输水泵流量预测模型结果分析

输水泵流量是具有多种尺度周期性规律的复杂时间序列,这一特性对预测模型捕捉和利用多维特征的能力提出了很高要求,而 LightGBM 具有极强的多维特征处理能力,同时也能通过构造滞后特征、周期特征等方式提升对时间序列的建模能力,且具有计算高效、精度较高的特点。因此,本文选择 LightGBM 作为主要预测模型。图 8 展示了所构建的 LightGBM 模型在测试集上的预测性能。由时序对比图[图 8(a)]可知,模型预测值(红色曲线)在整体趋势及峰值捕捉方面与实测值(黑色曲线)具有良好的一致性,能够较准确地反映流量随时间变化的特征。误差分析图[图 8(b)]进一步表明,大多数样本点的预测误差波动范围介于 ± 2 m³/s,模型稳定性较强。




图7 测试集多周期泵状态流量预测结果及性能分析(每次预测24h)

Fig. 7 Flow Rate Forecasting Results of Multi-Cycle Pump Status and Performance Analysis in the Test Set (Each Forecasting Covers a 24-Hour Period)

同时为进一步验证所提模型的先进性,本研究还选取了2种在时间序列预测领域具有代表性的基

准模型进行对比。其一是自回归积分滑动平均模型 (ARIMA),作为经典的时间序列统计分析模型,它




图 8 LightGBM 模型测试集结果

Fig. 8 Results of LightGBM Model Test Set

通过捕捉序列自身的滞后项、差分阶数和预测误差来实现预测^[15]; 其二是 Prophet 模型, 是一种基于加法模型的分解式时序预测工具, 尤为擅长处理具有强季节性和节假日效应的时间序列数据^[9]。将本文的 LightGBM 模型与这 2 种基准模型进行性能对比, 以评估不同建模策略在输水流量预测中的适用性和性能差异, 结果如图 9 和表 4 所示。从测试集预测结果来看, LightGBM 模型在各项评价指标上均表现出更优的预测性能。其中, LightGBM 模型的 RMSE 为 1.280 0 m³/s, MAPE 为 3.94%, NSE 达到 0.821 1; 相比之下, Prophet 模型的 RMSE 为 1.450 8 m³/s, MAPE 为 4.35%, NSE 为 0.770 1; ARIMA 模型的 RMSE 为 1.575 2 m³/s, MAPE 为 4.86%, NSE 为 0.729 0。总体而言, LightGBM 模型在误差控制




图 9 LightGBM、Prophet 和 Arima 模型测试集结果

Fig. 9 Results of LightGBM, Prophet, and ARIMA Models Test Set

表 4 LightGBM、Prophet 和 Arima 模型测试集关键评价指标对比

Tab. 4 Comparison of Key Evaluation Indices for LightGBM, Prophet, and ARIMA Models in the Test Set

评估指标	LightGBM	Prophet	Arima
NSE	0.82	0.77	0.73
MAPE	3.94%	4.35%	4.86%
RMSE	1.28 m ³ /s	1.45 m ³ /s	1.58 m ³ /s

能力和拟合精度方面均明显优于 Prophet 与 ARIMA 模型, 表明其在刻画输水流量序列的非线性特征和复杂变化规律方面具有更强的优势, 从而能够获得更高精度且稳定的预测结果。

2.4 水位综合预测模型结果分析

本节将对所构建的多模块机器学习耦合预测框架的最终水位预测性能进行综合评估, 并与作为基准的传统机理模型进行对比。为保证对比合理性, 2 种方法使用相同的起算时刻与 24 h 预报长度, 并在

每日预测开始时同步更新初始水位以控制误差累积。测试集时间跨度为 57 d, 时间步长为 1 h, 共 1 368 个时段。基准方法基于 MIKE21 水力模块构建, 采用“工况平移”边界条件(即次日入/出库按前一日外推), 网格与时间步长经校核; 本研究框架也已经校核, 预测阶段仅使用与基准相同的信息集合, 避免信息不对称。为全面评估模型性能, 本研究首先展示了 2 种模型预测结果与实测水位的时序对比(图 10), 由图 10 可知, 多模块机器学习耦合框架预测水位(蓝色)与实测水位(黑线)变化趋势较为一致, 尤其是在峰值和谷值的捕捉上更为精准, 相比之下, 传统机理模型(红色)的预测水位则表现出偏差较大和相位滞后的不足。然后对预测数据进行量化分析, 计算了 2 种模型在测试集上的多项评价指标, 结果汇总于表 5。由表 5 可知, 本研究提出的预测框架 NSE 为 0.566 1, 相较传统机理模型 0.030 6 显著提升 0.535 5; MAE 由 0.20 m 降至 0.19 m (降

低 0.01 m, 约 5.0%); MAPE 由 9.03% 降至 8.06%。同时进一步评估 2 种模型预测性能的差异, 本研究采用了 DM 检验。该检验专门用于比较时间序列预测模型的性能, 考虑了预测误差的序列相关性, 在水文预测领域有广泛应用。检验结果表明, 基于平方损失函数, 本研究提出的预测框架的预测性能显著优于传统机理模型 (DM 统计量 = 2.73, $p < 0.01$)。损失差异的均值为 0.075, 表明本研究提出的预测框架的平均平方误差较传统机理模型降低了 0.075。效应量达到中等水平, 证明这种改进不仅在统计上显著, 在实际应用中也具有重要意义。另外, 还对比了水位峰值误差的平均值和出现峰值时刻误差的平均值, 从峰值大小和峰值时刻 2 个维度进行更全面的评估, 结果可知本研究提出的预测框架在水位峰值误差的平均值较传统机理模型减小了 0.02 m, 出现峰值时刻误差的平均值较传统机理模型缩短了 2.4 h, 这也从数据角度支撑了本预测框架较传统机理模型从水位预测峰值和相位上都进行了优化。




图 10 多模块融合的机器学习预测框架与传统机理模型预测水位结果对比

Fig. 10 Comparison of Multi-Module Fusion Machine Learning Forecasting Framework and Traditional Mechanistic Models in Water Level Forecasting

表 5 综合水位预测模型与传统机理模型性能对比

Tab. 5 Performance Comparison between Integrated Water Level Forecasting Model and Traditional Mechanism-based Model

模型	MAE/m	MAPE	NSE
综合水位预测模型	0.19	8.06%	0.566 1
传统机理模型	0.20	9.03%	0.030 6

本研究还发现在测试集样本编号为 900~1 300, 本预测框架性能更加显著, 而传统机理模型在该阶段表现较差。通过数据分析发现, 该时段处于夏季高温时段, 水库取水泵闸切换频率显著上升,

因此采用“工况平移”法会导致传统机理模型误差明显上升, 而本预测框架对每个调控单元分别进行建模, 较为准确地刻画了每个单元的独特行为模式, 使其能更准确地捕捉真实水力工况变化, 而通过顶层物理约束, 也使水位预测更加谨慎, 保证预测水位处于合理区间, 不会大幅度高频率波动。

为客观评估本研究成果在相关领域中所处的水平, 本文将从水文学通用评价标准和与同类研究对比 2 个维度进行横向评估。首先, 依据水文学领域的通用评价标准进行检验。在水文模型评估中, NSE 是衡量模型优劣的关键指标。通常认为, 当 NSE 大于 0.5 时, 模型结果即被认为是“良好”且可接受的。本研究最终的综合水位预测 NSE 达到了 0.56, 表明所构建的框架已能可靠地复现由复杂人工调控驱动的水库水位动态过程。同时, 模型的 MAE 为 0.19 m, 也满足了水库调度应用中通常要求误差小于 0.2 m 的经验准则。这从根本上验证了本研究方法的有效性。其次, 与国内外相关水位预测研究进行对比。必须指出, 针对本文研究对象——以人工调控为主导的平原河网水库型水源地, 其水位变化主要由高频、非线性的泵闸调度决定, 而地表径流或地下水补充影响有限, 类似的研究案例较少, 而普遍的研究案例如山区型水库 (如三峡水库等), 主要由相对平缓、可预测性更强的入库径流过程主导。因此, 直接的性能对比存在一定的基准差异。尽管如此, 将本研究结果与这些采用先进机器学习模型的水库水位预测研究进行参照, 仍能提供有价值的参考 (表 6)。

表 6 本文与同类水位预测研究的 MAE 指标对比

Tab. 6 Comparison of MAE Indices between this Paper and Existing Water Level Prediction

研究对象	核心模型	MAE/m	文献来源
JZ 水库	多模块预测框架	0.19	本文
三峡水库	长短期记忆 (LSTM) + 图结构	0.5	[3]
三峡水库	RNN	<0.4	[5]
三峡水库	LSTM	<0.2	[16]
石门水库	序列到序列模型 (Seq2Seq)	<0.3	[17]
安加特大坝	U 型深度神经网络 (DNN-U)	0.2	[18]
Mayurakshi 水库	混合贝叶斯	2.5	[19]

由表 6 可知, 尽管面临着预测难度可能更大的、由高频人工调度主导的水位变化, 本研究的预测精度 (MAE=0.19 m) 表现较好, 与大部分案例的预测

精度处于同一水平,甚至在部分案例中优于以径流为主导型水库的研究成果。这进一步从侧面印证了本研究所提出的多模块耦合预测框架,在处理复杂边界条件驱动下的水位预测问题时,具有一定的先进性和有效性。

除计算精度外,本研究建立多模块耦合预测框架较传统机理模型在计算速度上有明显提升。在本研究中,传统机理模型完成一个周期水位的预测(即预测未来 24 h 水位变化)平均需要 30 min,而采用本框架完成一个周期水位的预测平均需要 35 s,计算效率提升约 50 倍。这一性能差异主要由于两种技术路线的内在属性。传统机理模型依赖于对水动力学方程的数值求解,该过程通常需要对时间和空间进行精细的网格剖分,并通过迭代计算来逐步逼近稳定解,其计算复杂度高,对处理器性能和内存要求苛刻。与之相反,本研究构建的多模块耦合预测框架,其计算开销主要集中在一次性的离线训练阶段,一旦训练完成,在预测阶段则极为轻量。因此,本框架不仅在预测精度上实现了优化,更通过将复杂的求解过程转化为高效的推理过程,显著降低了对计算资源的需求,能满足水库实际调度对高时效性的要求。

3 结论与不足

针对水库型水源地水位预测中存在的动态边界复杂、关键参数未知、多设施耦合紧密等难题,本文成功构建并验证了一种物理信息融合的多模块机器学习耦合预测框架,主要结论如下。(1)方法创新:本研究针对复杂问题采用了先分解后耦合的建模思路,通过为运行机理不同的闸门、取水泵、输水泵等调控单元设计定制化的机器学习模型(如级联模型、二阶段策略),然后以水量平衡方程作为物理约束,将各数据驱动子模块的预测结果进行耦合,为解决同类复杂水库型水源地的水位预测问题提供了新思路;(2)性能提升:与传统机理模型相比,本框架在所有评价指标上均表现更好,且与国内外同类案例相比处于相近水平甚至更优,这表明本框架不仅具有较好的预测精度,同时在处理复杂边界条件驱动下的水位预测问题展现出一定的先进性。另外本框架计算效率较传统模型提升了约 50 倍,实现了预测精度与速度的双重优化。

尽管本研究取得了良好效果,但仍存在可进一

步深化和拓展的方向。(1)物理约束的精细化:本研究采用了简化的水量平衡模型。未来可引入精确的三维地形或库容曲线数据,构建更精细化的物理约束,以期进一步降低由库区形态简化带来的预测偏差;(2)框架的端到端协同优化:目前各子模块为独立训练,其协同效应尚未达到最优。未来可探索多任务学习或强化学习等先进技术,将各子模块纳入一个统一的框架内进行端到端联合训练,以实现各调控单元策略的全局最优化;(3)多目标与事件驱动的预测:当前模型主要关注水量。未来研究可将水质参数(如浊度、叶绿素 a)作为新的预测目标或决策变量,构建水量-水质联合调度预测模型。此外,针对应急抢修、调度规则变更等突发事件,可研究基于事件驱动的动态模型修正机制,以提升模型在非规范工况下的鲁棒性。

参考文献

- [1] Zhang Y L, Deng J M, Qin B Q, et al. Importance and vulnerability of lakes and reservoirs supporting drinking water in China[J]. *Fundamental Research*, 2023, 3(2): 265-273.
- [2] 李金粟. 水库型水源地保护与防治策略研究[J]. *工程施工技术*, 2024, 2(3): 108-110.
Li J L. Research on protection and prevention strategies for reservoir type water source areas[J]. *Engineering Construction Technology*, 2024, 2(3): 108-110.
- [3] 郭宝椿, 李佐勇, 陈健, 等. 融合长短时记忆与图结构学习的水库水位预测[J]. *福建理工大学学报*, 2024, 22(1): 90-94.
Guo B C, Li Z Y, Chen J, et al. Reservoir level prediction via integrating long short-term memory and graph structure learning [J]. *Journal of Fujian University of Technology*, 2024, 22(1): 90-94.
- [4] Gharehbaghi A, Ghasemloumia R, Ahmadi F, et al. Groundwater level prediction with meteorologically sensitive gated recurrent unit (GRU) neural networks [J]. *Journal of Hydrology*, 2022, 612: 128262. DOI: 10.1016/j.jhydrol.2022.128262.
- [5] 纪国良, 周曼, 刘涛, 等. 基于循环神经网络的水库水位预测方法[J]. *长江科学院院报*, 2022, 39(3): 80-85.
Ji G L, Zhou M, Liu T, et al. Predicting water level for large reservoirs using recurrent neural network[J]. *Journal of Yangtze River Scientific Research Institute*, 2022, 39(3): 80-85.
- [6] 杨婷婷, 虞佳颖, 肖姚, 等. 基于 Embedding-GRU 的水库水位预测模型[J]. *南水北调与水利科技(中英文)*, 2023, 21(5): 940-950.
Yang T T, Yu J Y, Xiao Y, et al. Reservoir level prediction

- based on Embedding-GRU model [J]. *South-to-North Transfers and Water Science & Technology*, 2023, 21(5): 940-950.
- [7] 叶源新. 小型生态供水水库构建探讨与初期运行效果分析——金泽水库案例[J]. *净水技术*, 2018, 37(5): 33-38.
Ye Y X. Exploration of construction for small scale ecological reservoir and effects analysis on the initial operation—Case study on Jinze Reservoir[J]. *Water Purification Technology*, 2018, 37(5): 33-38.
- [8] 薛浩, 袁丹, 李国富, 等. 一种面向智慧水务数据分析与共享的元数据建模方法[J]. *给水排水*, 2024, 50(12): 146-153.
Xue H, Yuan D, Li G F, et al. A metadata modeling method for smart water management data analysis and sharing[J]. *Water & Wastewater Engineering*, 2024, 50(12): 146-153.
- [9] 沈时宇, 陈明. Prophet 时序模型在短期水质溶氧预测中的应用[J]. *渔业现代化*, 2020, 47(3): 29-35.
Shen S Y, Chen M. Application of Prophet time series model in short-term prediction of dissolved oxygen in water[J]. *Fishery Modernization*, 2020, 47(3): 29-35.
- [10] 余镒琦, 陈能汪, 余其彪, 等. 基于 XGBoost 选择迁移条件提升 LSTM 模型河流水质预测能力[J]. *环境工程*, 2024, 42(1): 223-234.
Yu Y Q, Chen N W, Yu Q B, et al. Selecting transfer conditions based on XGBoost to improve water quality prediction capacity of the LSTM model [J]. *Environmental Engineering*, 2024, 42(1): 223-234.
- [11] 曹顶业. 基于随机森林和 Sobol 法的平板闸门泄流预测及敏感性分析[D]. 西安: 西安理工大学, 2024.
Cao D Y. Discharge prediction and sensitivity analysis of sluice gate based on Random Forest and Sobol's method[D]. Xi'an: Xi'an University of Technology, 2024.
- [12] 李克. 基于机器学习的大坝渗流两阶段区间预测研究[D]. 天津: 天津大学, 2022.
Li K. Research on two-stage interval prediction for dam seepage based on machine learning [D]. Tianjin: Tianjin University, 2022.
- [13] 吴钰. 随机森林算法在交通状态预测中的研究与应用[D]. 沈阳: 沈阳师范大学, 2021.
Wu Y. Research and application of random forest algorithm in traffic state prediction [D]. Shenyang: Shenyang Normal University, 2021.
- [14] 耿为民, 颜军, 张典, 等. 基于 LightGBM 的水厂供水压力预测[J]. *计算机应用与软件*, 2024, 41(4): 340-349.
Geng W M, Yan J, Zhang D, et al. Forecasting of water supply pressure based on LightGBM [J]. *Computer Applications and Software*, 2024, 41(4): 340-349.
- [15] 陈帅宇, 赵龔龔, 蒋磊. 基于 ARIMA-CNN-LSTM 模型的黄河开封段水位预测研究[J]. *水利水电快报*, 2023, 44(1): 15-22.
Chen S Y, Zhao Y X, Jiang L. Prediction of water level of Kaifeng section of Yellow River based on ARIMA-CNN-LSTM model[J]. *Express Water Resources & Hydropower Information*, 2023, 44(1): 15-22.
- [16] 徐扬, 刘亚新, 汪涛, 等. 基于 LSTM 的三峡水库短期上游水位预测方法研究[J]. *水利水电快报*, 2022, 43(10): 13-18.
Xu Y, Liu Y X, Wang T, et al. Study on short-term upstream water level prediction method of Three Gorges Reservoir based on LSTM[J]. *Express Water Resources & Hydropower Information*, 2022, 43(10): 13-18.
- [17] Gwo-Fong L. Forecasting of water levels downstream of reservoirs [D]. Taiwan: National Taiwan University, 2023.
- [18] Ibañez S C, Dajac C V G, Liponhay M P, et al. Forecasting reservoir water levels using deep neural networks: A case study of Angat Dam in the Philippines[J]. *Water*, 2022, 14(1): 34-34.
- [19] Das M, Ghosh S K, Chowdary V M, et al. A probabilistic nonlinear model for forecasting daily water level in reservoir[J]. *Water Resources Management*, 2016, 30(9): 3107-3122.