

物理机制耦合机器学习的水库防洪集合调度规则提取

郭玉雪,黄一凡,赵振杰,许月萍,顾海挺

(浙江大学建筑工程学院)

摘要:以轻量级梯度提升机(LightGBM)、极端梯度提升机(XGBoost)和长短期记忆网络(LSTM)3种机器学习算法为基准模型,在损失函数中引入水量平衡、水库水位及下泄流量约束,并结合卡尔曼滤波进行实时修正,构建了 KP-LightGBM、KP-LSTM、KP-XGBoost 模型,进而提出了物理机制耦合机器学习的水库防洪集合调度规则提取方法,并基于最好最差法、熵权法的组合赋权与 TOPSIS 排序方法,筛选出不同水库调度方案。在始丰溪流域的应用结果表明:筛选出均衡防洪、偏上游防洪、偏下游防洪 3 种调度情景;与 LightGBM、XGBoost 模型相比,LSTM 模型的模拟精度最高,模拟结果的纳什效率系数(NSE)均在 0.94 以上;引入物理约束和卡尔曼滤波实时修正,提升了防洪调度规则的可解释性和结构合理性,其中偏上游防洪情景下,KP-LSTM 模型水量平衡指数偏差降低约为 0.17,KP-XGBoost 模型的负值流量百分比降低了 0.05%,有效减少了水量失衡与流量负值现象;集合模型的综合表现优于单一模型,在不同防洪情景下 NSE 均超过 0.97,且其 90%置信区间覆盖率高、宽度合理。

关键词:水库防洪集合调度规则;卡尔曼滤波;机器学习模型;集成学习;始丰溪流域

中图分类号:TV697.1 **文献标志码:**A **文章编号:**1004-6933(2026)05-0050-12

Extraction of ensemble flood control dispatching rules for reservoirs by coupling physical mechanisms with machine learning//Guo Yuxue, Huang Yifan, Zhao Zhenjie, Xu Yueping, Gu Haiting(*College of Civil Engineering and Architecture, Zhejiang University*)

Abstract: Three machine learning algorithms, namely LightGBM, XGBoost, and LSTM, were used as benchmark models. Water balance, reservoir water level, and discharge flow constraints were introduced into the loss function, and Kalman filtering was used for real-time correction. KP-LightGBM, KP-LSTM, and KP-XGBoost models were constructed, and a physical mechanism coupled machine learning method for extracting reservoir flood control ensemble dispatching rules was proposed. Based on the combined weighting of best and worst method, entropy weight method, and TOPSIS ranking method, different reservoir scheduling schemes are screened. The application results in the Shifengxi River Basin show that three scheduling scenarios have been selected, including balanced flood control, upstream-oriented flood control, and downstream-oriented flood control. Compared with LightGBM and XGBoost models, the LSTM model has the highest simulation accuracy, and the Nash efficiency coefficient (NSE) of the simulation result is above 0.94. The introduction of physical constraints and Kalman filtering for real-time correction has improved the interpretability and structural rationality of flood control dispatch rules. In the upstream-oriented flood control scenario, the deviation of the KP-LSTM model's water balance index decreased by about 0.17, and the negative flow percentage of the KP-XGBoost model decreased by 0.05%, effectively reducing the phenomenon of water imbalance and negative flow. The comprehensive performance of the ensemble model is better than that of the single model. Under different flood control scenarios, the NSE exceeds 0.97, and its 90% confidence interval has high coverage and reasonable width.

Key words: reservoir flood control ensemble dispatching rules; Kalman filtering; machine learning model; ensemble learning; the Shifengxi River Basin

在全球气候变化与人类活动的影响下,极端水文事件频发,洪涝灾害风险持续加剧^[1-3]。作为流域防洪体系中的关键工程措施,水库通过拦洪削峰、错

峰泄洪,在降低洪水风险、保障防洪安全方面发挥着不可替代的作用^[4-10]。然而,洪水过程具有不确定性和突发性^[11],使得水库防洪调度决策面临较高复

基金项目:浙江科技计划项目(2025C02049);国家自然科学基金项目(52579023)

作者简介:郭玉雪(1990—),女,研究员,博士,主要从事水文预报与水库调度研究。E-mail:yuxueguo@zju.edu.cn

通信作者:许月萍(1975—),女,教授,博士,主要从事极端水文事件模拟、预报与调控研究。E-mail:yuepingxu@zju.edu.cn

杂性,实际运行中往往高度依赖调度人员的经验判断与历史运行规律。随着水库长期运行的推进,大量水文与调度数据被积累,在复杂多变的防洪情景下挖掘蕴含的规律,提炼稳定、可靠的水库防洪调度规则,有助于为水库防洪运行提供更加稳健的决策支持。

调度规则作为指导水库运行的核心工具,其形式随研究方法的发展不断演进。传统调度图虽直观但较为静态和粗放,而调度函数能够更直接地刻画决策因子与决策变量之间的映射关系,早期研究多采用线性回归方法构建调度函数,从二元线性回归逐步发展为多元线性回归,然而此类方法难以有效捕捉变量间复杂的非线性关系^[12-16]。随着计算机技术的进步,支持向量机(SVM)、梯度提升机、决策树、深度学习等机器学习方法在水库调度领域展现出显著优势,并被广泛应用于调度规则挖掘。例如:刘亚新等^[17]结合极端梯度提升机(XGBoost)与自回归差分移动平均(ARIMA)模型,对葛洲坝水电站的入库流量与日均出力进行了预测;钟加星等^[15]利用随机森林(RF)与轻量级梯度提升机(LightGBM)提取黄河上游梯级库群的多目标调度规则,结果表明LightGBM在协调发电、供水与生态需求方面表现更优;周婷等^[18]采用SVM提取了金沙江—长江中游水电站群的中长期调度规则,为梯级水电站优化运行提供了关键技术支撑;张彪等^[19]使用RF-长短期记忆网络(RF-LSTM)模型,较好地提取了三峡水库汛期调度规则,模拟精度较高且运行稳定;Wei等^[20]通过混合决策树模型优化了石门水库的配水效果。

上述研究验证了机器学习在水库调度规则提取中的可行性与有效性。然而现有机器学习模型大多依赖纯数据驱动,虽在模拟精度上有所提升,却因忽略水库调度中的物理机制而面临可解释性不足的问题,影响了调度规则的可靠性与实用性^[21-24]。针对这一问题,已有研究尝试将物理机制引入机器学习模型中,例如:Zheng等^[25]在LSTM中嵌入水量平衡等约束,有效减少了负流量的出现,降低了水量平衡指数的偏差;罗赞等^[26]将龙头水库蓄丰补枯的物理机制嵌入卷积神经网络-长短期记忆网络(CNN-LSTM)模型,有效提升了龙羊峡水库在水量统一调度中所控制河段的模拟精度;钟鸣等^[27]将物理机制融入循环神经网络(RNN)模型中,提高了径流预测和洪水预测的准确性。但是现有研究大多使用单一机器学习模型,而单一模型在面对复杂多变的调度情景时,往往存在泛化能力有限、模拟结果波动、易受随机误差影响等局限,所以引入一种能结合不同机器学习模型特点的集合模型尤为重要。

针对上述问题,本文针对水库管理中调度目标多样、方案选择困难的问题,采用组合赋权与排序方法筛选出不同偏好情景,选取多种机器学习模型,通过引入物理约束损失函数,并利用卡尔曼滤波(Kalman filter, KF)进行实时动态修正,构建物理引导模型,进而采用Stacking策略进行集成,构建集合调度规则模型,并生成决策预测区间。在浙江省始丰溪流域进行应用并对比,检验提出的方法在物理合理性、预测精度与跨情景稳定性方面的效能,期为水库智慧调度提供方法参考。

1 研究方法

1.1 优化调度方案的筛选

水库多目标优化调度得到的Pareto非劣解集能够刻画各目标之间的权衡关系,本文以该Pareto非劣解集为候选集合开展方案筛选,并构建评价指标体系对候选方案进行综合排序,利用主观、客观两种赋权法确定指标权重。主观赋权法主要依赖专家经验,如最好最差法(BWM)^[28]层次分析法(AHP)^[29-30]等;客观赋权法则依据数据自身的统计特性确定权重,如熵权法^[31]、CRITIC法^[32]、主成分分析法^[33]等。其中,BWM能够有效融入专家对防洪调度中各指标相对重要性的专业判断,且相较于AHP具有更高的一致性和计算效率;熵权法则依据各指标值在方案间的离散程度自动确定权重,可避免主观偏差,更好地反映数据内在信息量。因此,本文采用熵权法与BWM相结合的组合赋权策略。

为比较不同调度方案在防洪运行中的表现,从上游、下游防洪安全两个方面构建调度方案评价指标体系,用以刻画各方案在削减洪峰流量与控制运行水位方面的效果。

a. 下游防洪评价指标。在汛期运行过程中,下游防洪安全是调度方案评价的重要内容。为反映不同调度方案对下游洪水过程的削减能力,选取调度期内水库的下泄流量平方和 F_1 作为评价指标。该指标值越小,调度方案对洪峰的削减效果越显著,下游防洪压力越小,表达式为:

$$F_1 = \sum_{i=1}^T Q_i^2 \tag{1}$$

式中: Q_i 为 t 时刻水库的下泄流量; T 为总运行时间。

b. 上游防洪评价指标。除下游地区的防洪需求外,上游的调度安全同样至关重要。若运行水位过高,极易造成漫坝或对大坝结构安全造成威胁。因此选取调度期内水库运行水位的最大值 F_2 作为上游防洪评价指标。该指标值越小,水库运行过程

中对高水位的控制效果越好,表达式为:

$$F_2 = \max \{ Z_t \} \quad (2)$$

式中: Z_t 为 t 时刻水库的水位。

具体方案筛选过程如下:

步骤 1 候选方案整理。汇总 Pareto 非劣解集中的候选调度方案,计算各方案对应的评价指标,构建判断矩阵并完成标准化处理。

步骤 2 客观综合赋权。在标准化判断矩阵基础上开展综合赋权。采用熵权法挖掘指标数据的离散性与信息量,确定客观权重;采用 BWM 判断决策偏好与指标重要性差异,获得主观权重。

步骤 3 方案排序与优选。将不同偏好情景下的权重组合分别输入优劣解距离 (TOPSIS) 模型,计算各方案相对理想解的贴近度,并按贴近度最大原则进行优选,形成 3 类调度偏好情景:均衡防洪情景基于客观熵权的贴近度最大的方案,兼顾上下游防洪安全;偏下游防洪情景在 F_1 指标高权重偏好下的最优方案,侧重控制下泄流量;偏上游防洪情景在 F_2 指标高权重偏好下的最优方案,侧重控制库区水位。

1.2 耦合物理机制的机器学习模型

XGBoost 和 LightGBM 作为梯度提升机模型的代表,具有较强的非线性拟合能力与良好的结构化数据建模优势,适用于刻画调度影响因子之间的复杂映射关系^[34-35];LSTM 则通过门控机制有效表征长序列依赖,能够捕捉水库调度过程中的时序动态特征^[36-37]。选取 XGBoost、LightGBM、LSTM 作为基准模型,建立提取水库调度规则的方法。

1.2.1 引入物理机制的损失函数

在传统的机器学习模型中,损失函数通常以提升模拟结果的拟合程度为核心目标。然而,依据该目标函数得到的水库下泄流量往往存在高值模拟较差、出现负值流量的问题,不能满足调度期入库流量与下泄流量之间的水量平衡的需求^[38]。为解决上述问题,本文在损失函数中引入水库运行过程中的物理机制,通过增加惩罚项来约束模型解的可行域范围,引入物理机制的模型分别记为 PHY-XGBoost、PHY-LightGBM、PHY-LSTM (统称 PHY 模型)。具体来说,考虑水量平衡原则、水位范围的上下限约束以及下泄流量范围的上下限约束,用以引导机器学习模型得出更符合真实调度的解^[39],表达式为:

$$L = \lambda_1 L_1 + \lambda_2 L_2 + \lambda_3 L_3 + \lambda_4 L_4 \quad (3)$$

式中: L 为基于物理机制引导的损失函数; L_1 为模拟结果的均方根误差; L_2 为模拟值违反水库水量平衡原则的惩罚项; L_3 为模拟值违反水库水位范围约束的惩罚项; L_4 为模拟值违反下泄流量范围约束的惩

罚项; $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ 为权重系数。

1.2.2 KF 实时修正方法

KF 是一种基于状态空间模型的递归滤波算法,广泛应用于动态系统的估计与预测^[40]。KF 的核心原理是通过融合当前时刻的观测数据与系统的预测模型,用递归的方式对系统状态进行估计,从而实现动态系统状态的最优估计^[41]。为提高物理机制引导的机器学习模型对实时观测信息的适应能力,本文在 PHY-XGBoost、PHY-LightGBM、PHY-LSTM 的预测结果基础上引入 KF 进行逐时段修正,修正后的模型分别记为 KP-XGBoost、KP-LightGBM、KP-LSTM (统称 KP 模型)。具体实施时,先将模型输出反归一化至实际下泄流量空间,再以各模型在当前时段的下泄流量预测值作为先验估计,同期可获得的实际下泄流量作为观测信息,对调度过程逐时递推更新;首时段以模型预测值作为初始值,后续时段在观测数据到达后依次完成修正。

1.3 水库防洪集合调度规则提取

1.3.1 集合模型构建

集成学习通过组合多个基学习器提升预测精度与泛化能力,常见策略包括 Bagging、Boosting、Stacking 等^[42-44]。其中,Stacking 采用分层融合框架,将多个 (可异构) 基学习器的输出作为元特征,并由第二层元学习器学习其最优组合关系,从而在保留各模型优势的同时实现数据驱动的自适应集成,尤其适用于结构差异较大的模型互补融合^[44]。本文基学习器包含两类树模型与时序神经网络:前者擅长刻画结构化非线性映射,后者更善于捕捉时序依赖与动态演化特征,属于典型的异构组合。因此,本文采用 Stacking 构建集合模型,以充分发挥不同模型的互补优势并提高模型模拟稳健性^[45]。Stacking 元学习器可选用线性、核或树模型。本文选用 RF 模型,主要因其具备较强的非线性与特征交互学习能力,对元特征尺度差异适应性较好,且稳健性较强、对噪声与异常值不敏感,有助于缓解过拟合并提升多情景泛化能力^[46]。集合模型构建的主要步骤如下:

步骤 1 基学习器选取。选取 KP 模型作为第一层基学习器。

步骤 2 元特征构建。为避免数据泄露并确保元学习器具备良好的泛化能力,使用各基学习器在整个验证集上产生的模拟结果作为元特征 (本文使用验证集作为元特征已获得良好效果,故不再进行 K 折交叉验证来生成新数据)。即将验证集的输入数据分别输入 3 个已训练好的基学习器,得到 3 列模拟值,这些模拟值共同构成第二层训练集的输入特征。

步骤3 元学习器训练。采用 RF 模型作为第二层元学习器。将步骤2中得到的3列元特征作为输入特征,以验证集对应的实际下泄流量值作为输出目标,训练 RF 模型。

步骤4 集合模型测试。对于最终的测试集,先利用3个基学习器生成初级模拟,然后将这些模拟值作为特征,输入已训练好的 RF 元学习器,动态分配权重,得到最终的模拟值。

1.3.2 区间生成

为量化调度中的不确定性,并为实时调度决策提供风险参考,本文在集成点模拟的基础上,采用蒙特卡洛模拟方法^[47]生成概率模拟区间,具体步骤如下:

步骤1 残差分布估计。在验证集上,分别计算3个基学习器(KP 模型)的残差,这些残差序列表征了各模型模拟误差的经验分布。

步骤2 蒙特卡罗模拟生成扰动。进行1000次蒙特卡罗模拟,在每次模拟中,从3个残差分布中有放回地随机抽取与测试集样本数相同的残差样本,将抽取的残差叠加到测试集基学习器模拟值上,生成扰动后的模拟值,将其输入元学习器,得到该次模拟值。

步骤3 区间计算。对于测试集的每个样本点,收集其所有1000次模拟的结果。计算该样本点模拟值的第5、第95百分位数,分别作为90%置信区间的下限和上限。

1.4 模型评价

1.4.1 确定性评价

确定性指标包括数学指标和物理指标两种,采取纳什效率系数(NSE)^[48]、均方根误差(RMSE)^[49]和相关系数(r)^[50]对数学指标进行评价;采用水量平衡指数(I_{WB})和负值流量占比(P_{NQ})对物理指标进行评价,计算公式见式(4)、式(5)。 I_{WB} 越偏离1,表示模拟值的水量损失或增益越大; P_{NQ} 越趋近1,表示流量出现负值情况越多,越违背水量守恒的基本要求。

$$I_{WB} = \frac{\sum_{t=1}^T q_t}{\sum_{t=1}^T Q_t} \tag{4}$$

$$P_{NQ} = \frac{1}{T} \sum_{t=1}^T N_t \times 100\% \tag{5}$$

其中
$$N_t = \begin{cases} 1 & q_t < 0 \\ 0 & q_t \geq 0 \end{cases}$$

式中: q_t 为下泄流量模拟值。

1.4.2 不确定性评价

采用覆盖率(C)和平均区间宽度(M)对不确定

性指标进行评价,覆盖率反映真实值落在区间内的比例,平均区间宽度衡量区间的精确程度,计算公式为:

$$C = \frac{1}{N_1} \sum_{i=1}^{N_1} n_i \tag{6}$$

$$M = \frac{1}{N_1} \sum_{i=1}^{N_1} (U_i - L_i) \tag{7}$$

其中
$$n_i = \begin{cases} 1 & L_i \leq Q_t \leq U_i \\ 0 & Q_t < L_i \text{ 或 } Q_t > U_i \end{cases}$$

式中: N_1 为样本数量; L_i 、 U_i 分别为第*i*个样本区间的下、上限。

2 实例应用

2.1 研究区概况

始丰溪流域地处浙江省中北部,地理范围为28°50'N~29°20'N、120°30'E~121°10'E(图1),流域地势总体由西向东逐渐趋于平缓,上游以山地和丘陵为主,地形起伏较大,水资源较为丰富,年平均流入量为3.08亿m³。流域大部分地区属于亚热带季风气候,降水充沛,年平均降水量为1673.9mm,但年内分配不均,主要集中在汛期(6—9月),汛期强降雨容易引起入库流量大幅波动,进而形成洪峰。特别是在8月台风活动较为频繁的时期,局部地区常出现短历时集中暴雨,导致河道及水库来水量迅速增加,给流域防洪、排涝和水库泄洪调度带来较大压力。




图1 研究区概况

Fig. 1 Overview of study area

里石门水库是始丰溪流域的重要水利工程,位于流域西南部、始丰溪干流中游附近,地理位置为29°00'N、120°40'E。里石门水库具有较强的洪水调蓄能力和较好的综合调节作用,是始丰溪流域防洪调度体系的重要组成部分。里石门水库初始水位和防洪汛限水位均为176.04m,初始库容为

1.218 亿 m^3 ; 水库最低下限水位为 160.97 m, 防洪高水位为 180.69 m, 防洪库容为 3140 万 m^3 , 总库容为 1.793 亿 m^3 ; 水库最小下泄流量为 0, 安全下泄流量为 1000 m^3/s 。依托其调蓄库容和泄流能力, 里石门水库能够在洪水过程中发挥拦蓄洪水、削减洪峰和减轻下游防洪压力等作用。

2.2 数据资料

本文采用的数据来源于课题组前期研究成果^[4]。该论文开展了考虑径流不确定性的里石门和龙溪水库群对冲-鲁棒联合调度研究, 研究时间为 1987—2016 年的台汛期(8 月), 时间尺度为日。鉴于历史观测样本有限, 为构建能够充分表征汛期入流不确定性及多站点时空依赖特征的训练样本, 课题组采用 RDVine-Copula 函数随机生成了 294 组径流情景, 每组情景对应一条覆盖 8 月 1—31 日的逐日径流序列, 该方法在遵循历史径流统计规律的基础上, 可较好保持多站点间的相关结构。在此基础上, 本文选取里石门水库的 294 组入库径流数据作为模型输入, 以对应的调度方案作为输出, 进行集合调度规则提取。所有样本整合为 9114 天(294×31)的日尺度序列, 并按 6:2:2 的比例统一划分为训练集、验证集、测试集, 以提升模型对不同入流模式的泛化能力。

2.3 模型设置

水库调度中常见的输入变量包括水库的蓄水量、水位和其他水量因素, 决策变量常选择水位或下泄流量等^[15,51]。本文选用水库调度期内的入库流量 $Q_{in,t}$ 、水位 Z_t 作为输入变量, 输出变量为下泄流量 $Q_{ou,t}$ 和水位 Z'_t , 以损失函数最小为目标构建模型。对于 LightGBM 与 XGBoost 模型, 采用网格搜索对关键超参数进行调优; 对于 LSTM 模型, 采用 PyTorch 框架的 Optuna 库进行自动超参数优化, 其通过高效的采样与剪枝算法在范围内搜索最优组合; 对于集合调度规则模型的元学习器 RF 模型, 采用网格搜索进行超参数优化。权重系数作为模型损失函数的一部分, 参与各模型超参数的联合调优, 本文 λ_1 、 λ_2 、 λ_3 、 λ_4 的搜索范围均设为 0.01~1。LightGBM 模型的超参数调优范围: 树的数量为 100~800, 最大深度为 4~12, 学习率为 0.0001~0.1, 子样本比例为 0.5~1.0, 特征采样比例为 0.5~1.0, 叶子数量为 31~127, 叶节点最小样本数为 5~30; XGBoost 模型的超参数调优范围: 树的数量为 100~800, 最大深度为 4~12, 学习率为 0.0001~0.1, 子样本比例为 0.5~1.0, 特征采样比例为 0.5~1.0, 最小叶子权重为 1~15, Gamma 参数为 0.0~0.3; LSTM 模型的超参数调优范围: 隐藏单元数为

32~256, 层数为 1~3, 训练轮次为 10~300, 学习率为 0.001~0.1, 丢弃率为 0.1~0.2; RF 元学习器的超参数调优范围: 树的数量为 50~400, 最大深度为 3~20, 节点分裂最小样本数为 2~15, 叶节点最小样本数为 1~6, 最大特征比例为 0.5~1.0, 自助采样参数设置为 True 或 False, 最小不纯度减少量为 0.0~0.1。

2.4 结果与分析

2.4.1 优化调度方案筛选

图 2 为各调度方案目标函数值基于上、下游防洪目标的分布情况。由图 2 可见, 大部分方案集中在中段区域, 少数在某一目标上表现突出或较差。方案筛选过程中, 基于熵权法得到 F_1 的客观权重为 43.35%, F_2 的客观权重为 56.65%, 以此为基础通过 TOPSIS 计算各方案的相对接近度, 选取相对接近度最大的方案作为均衡防洪方案; 结合 BWM 进行组合赋权, 侧重下游防洪时, F_1 的综合权重设为 75%、 F_2 的综合权重设为 25%, 此时相对接近度最大的方案即为偏下游防洪方案; 侧重上游防洪时, F_1 的综合权重设为 25%、 F_2 的综合权重设为 75%, 此时相对接近度最大的方案即为偏上游防洪方案。




图 2 调度方案目标函数值分布

Fig. 2 Distribution of objective function values of scheduling schemes

均衡防洪方案、偏上游防洪方案、偏下游防洪方案的 F_1 分别为 3171.5、3221.5、3139.2 m^6/s^2 , F_2 分别为 176.469、176.464、176.478 m。均衡防洪方案统筹了下泄流量与运行水位两个目标, 适用于防洪压力相对均衡、需稳健调度的情景; 偏上游防洪方案适用于上游库区安全风险较高、需严格控制水位的调度场景; 偏下游防洪方案能有效控制下泄流量, 更适用于下游防洪压力大、需显著削减洪峰的运行场景。3 种方案为机器学习提供了差异化调度情景, 即均衡防洪情景、偏上游防洪情景、偏下游防洪情景, 为基于不同调控目标的调度规则提取奠定了多样化的数据基础。

2.4.2 模型性能评价

为比较不同模型在 3 种防洪调度情景下的综合表现, 基于 NSE、RMSE、 r 、 I_{WB} 、 P_{NQ} 5 项评价指标, 分

别统计训练集、验证集、测试集结果,绘制模型性能雷达图,如图 3~5 所示。由图 3~5 可见,在基准模型、PHY 模型、KP 模型 3 种情况下,3 类机器学习模型的整体性能由高到低依次为: LSTM、LightGBM、XGBoost,这一排序反映了机器学习模型在时序依赖性较强的水库调度规则提取中,从数据拟合到泛化能力的综合差异。从不同防洪调度情景来看,LSTM 模型在训练集、验证集、测试集上均表现出优异的时序建模能力和稳健的泛化性能。在均衡防洪情景下,LSTM 模型在训练集、验证集、测试集上的 NSE 分别为 0.96、0.95、0.96,性能衰减极小,说明其能够有效捕捉调度过程中的动态依赖关系,且具备较强的外推能力。相比之下,XGBoost、LightGBM 模型在训练集上虽能实现良好拟合,但在验证集和测试集上均出现了一定的性能衰减,说明其在泛化与时序外推方面具有一定局限性。具体而言,XGBoost 模型的泛化能力最弱,在均衡防洪情景下测试集 NSE 较训练集下降约 0.16,且在部分情景中出现了

水量平衡偏差与负值流量问题;LightGBM 模型在训练效率与拟合速度上具有优势,是一种兼顾效率与性能的平衡选择,但其时序外推能力不及 LSTM 模型,在测试集上会出现一定程度的精度损失。

进一步分析图 3~5,发现物理约束可以提升模型的模拟精度与结构合理性。训练集中,引入物理约束可以改善模型的拟合效果与物理指标。例如:均衡防洪情景下,PHY-XGBoost 模型的训练集 NSE 从 0.84 提升至 0.99, I_{WB} 趋近于 1;偏上游防洪情景下,PHY-LSTM 模型的 I_{WB} 从 1.18 修正至 0.99,水量平衡得到明显改善。在验证集与测试集上,物理约束继续发挥积极作用,偏上游防洪情景下 PHY-LSTM 模型的 I_{WB} 同样得到明显修正。3 种防洪情景下各模型的 P_{NQ} 普遍下降,部分模型降至 0,且 NSE 仍保持较高水平,说明物理约束在不损失精度的前提下,提高了输出的合理性。此外,各模型在验证集与测试集上的性能衰减得到缓解,表明物理机制有助于提升模型对未知数据的泛化能力。另外,




图 3 均衡防洪情景下模型性能雷达图

Fig. 3 Radar chart of model performance under balanced flood control scenario




图4 偏上游防洪情景下模型性能雷达图

Fig. 4 Radar chart of model performance under upstream-oriented flood control scenario

KF 进一步提高了模型精度并增强了稳定性。例如：在偏上游防洪情景测试集中，KP-XGBoost 模型的 NSE 达到 0.87，较 PHY-XGBoost 模型(0.76)有显著提升；均衡防洪情景下，KP-LSTM 模型的 NSE 进一步增至 0.99。KF 还收窄了模型在不同情景下的性能波动，以 XGBoost 模型为例，其在 3 种防洪情景下的 NSE 波动范围为 0.68~0.74，经物理约束后 (PHY-XGBoost) 波动范围收窄至 0.76~0.79，而经 KF 修正后 (KP-XGBoost) 波动范围进一步缩小至 0.87~0.88，体现出良好的泛化适应能力。

进一步地，为更直观展示不同防洪情景下模型对调度过程的刻画能力，绘制了 KP 模型模拟与实际调度过程的对比图以及模拟-实际散点图，如图 6、图 7 所示。由图 6 可见，3 类机器学习模型的差异主要在于对调度时序信息的利用方式。防洪下泄流量并非静态回归，而是受入流、水位及其变化趋势共同影响。其中，LSTM 模型通过门控与隐状态记忆显式引入历史信息，能学习“状态-决策”的动态关系，因此从训练集到验证集、测试集的性能衰减较

小。相比之下，XGBoost、LightGBM 模型以特征分裂与分段拟合为主，时序依赖大多通过滞后项间接表征，且逐轮拟合残差对噪声与分布差异更敏感，泛化下降更明显。两者中，LightGBM 模型通常更易捕捉局部复杂非线性结构，因此整体效果往往优于 XGBoost 模型。由图 7 可见，在 3 种防洪情景下，KP 模型模拟值与实际值拟合较好且下泄过程再现效果好，再一次说明物理机制及 KF 的耦合有效增强了模型的模拟效果、结构合理性及跨情景稳健性。

2.4.3 集合模型区间生成与调度规则提取效果

本文基于 Stacking 策略构建集合模型，对 KP-LightGBM、KP-XGBoost、KP-LSTM 进行融合。表 1 为集合模型在不同防洪情景下的评价指标。由表 1 可见，在训练集、验证集、测试集中，集合模型在不同防洪情景下均表现出较高的模拟精度和良好的稳健性。其中，NSE 均高于 0.97， r 接近 0.99，RMSE 稳定在 0.1~1.5 m³/s 范围内， I_{yb} 接近 1， P_{NQ} 始终为 0，训练集、验证集、测试集的性能衰减均很小，说明集合模型在保持高精度的同时，能够有效避免负




图 5 偏下游防洪情景下模型性能雷达图

Fig. 5 Radar chart of model performance under downstream-oriented flood control scenario




图 6 不同防洪情景下 KP 模型模拟与实际调度过程对比

Fig. 6 Comparison between actual scheduling process and process simulated by KP models under different flood control scenarios




图 7 不同防洪情景下 KP 模型模拟-实际散点图

Fig. 7 Scatter plot of observed values and values simulated by KP models under different flood control scenarios

表 1 不同防洪情景下集合模型的评价指标

Table 1 Evaluation indexes of ensemble model under different flood control scenarios

数据集	防洪情景	NSE	RMSE/(m^3/s)	r	I_{WB}	$P_{\text{NQ}}/\%$	$C/\%$	$M/(\text{m}^3/\text{s})$
训练集	均衡防洪情景	0.99	0.64	0.99	0.97	0	94.72	2.02
	偏上游防洪情景	0.99	0.61	0.99	0.99	0	95.01	1.84
	偏下游防洪情景	0.99	0.96	0.99	0.97	0	93.99	2.68
验证集	均衡防洪情景	0.99	0.50	0.99	0.97	0	94.81	2.01
	偏上游防洪情景	0.99	0.18	0.99	1.00	0	95.24	1.84
	偏下游防洪情景	0.99	0.92	0.99	0.97	0	94.70	2.68
测试集	均衡防洪情景	0.98	1.11	0.99	0.97	0	90.45	2.01
	偏上游防洪情景	0.97	1.40	0.99	0.98	0	92.02	1.91
	偏下游防洪情景	0.98	1.08	0.99	0.97	0	92.95	2.69

值流量的出现,并基本满足水量平衡约束的要求,兼具了准确性与结构合理性。在区间生成方面,不同防洪情景的覆盖率和平均区间宽度均达到了合理水平。从测试集来看,均衡防洪情景的覆盖率最低,偏上游防洪情景的平均区间宽度最小,偏下游防洪情景的覆盖率最高,但平均区间宽度也相应增至最大。总体上,3种防洪情景的覆盖率均超过设定的90%置信水平,表明集合模型构建的区间能够有效覆盖绝大多数真实下泄过程,具有较强的可靠性;同时,所有防洪情景的平均区间宽度均未超过 $2.7\text{ m}^3/\text{s}$,说明集合模型在不确定性刻画方面既不过度保守,也能保持足够的分辨率。与单一模型效果进行对比可知,集合模型在训练集和验证集上的各项评价指标均优于 KP-LSTM;在测试集上,尽管两者在模拟

精度指标上表现接近,但集合模型在水量平衡方面表现更优。上述结果表明,集合模型综合表现优于单一模型,成功融合了各基学习器。

利用集合模型进行水库调度规则提取,图8、图9分别为不同防洪情景下集合模型提取的水库运行水位、下泄流量过程。由图8、图9可见,集合模型提取的水库运行水位、下泄流量与实际过程基本一致,无论是在平稳的小流量阶段,还是在流量突增、突降的剧烈波动阶段,集合模型均能够紧密跟随实际过程变化,较好地再现运行水位和下泄流量的动态变化特征。同时,均衡、偏上游、偏下游防洪情景下,最大运行水位分别为176.68、176.58、176.75 m,单日最大下泄流量分别为15.90、16.85、 $13.29\text{ m}^3/\text{s}$,体现了不同运行方案的差异。偏上游




图 8 不同防洪情景下集合模型提取的水库水位运行过程

Fig. 8 Reservoir water level operation processes extracted by ensemble model under different flood control scenarios




图9 不同防洪情景下集合模型提取的水库下泄流量过程

Fig. 9 Reservoir discharge processes extracted by ensemble model under different flood control scenarios

防洪情景下最大运行水位最低,表明集合模型更注重控制库区水位,以降低上游防洪风险,相应地,该防洪情景下的单日最大下泄流量最高;偏下游防洪情景下最大下泄流量降低至 $13.29 \text{ m}^3/\text{s}$,体现出一定的削峰意图,而运行水位则允许抬升至 176.75 m ,以蓄洪缓泄;均衡防洪情景的各项指标介于两者之间,体现出对上、下游防洪风险的统筹考虑。可见,集合模型在不同防洪情景下均表现出较好的模拟能力,且能区分不同防洪偏好对应的运行方案特征。集合模型通过整合不同基学习器的特征,使其既能够利用树模型在特征空间的局部划分能力,又能够充分发挥 LSTM 在处理时序依赖结构方面的优势,从而在不同流量变化阶段均保持较高的拟合度。

3 结 论

a. 采用 BWM-熵权-TOPSIS 组合赋权与排序方法筛选出不同防洪偏好情景,以 XGBoost、LightGBM、LSTM 为基准模型,引入物理约束损失函数和 KF 实时动态修正,进而采用 Stacking 策略进行集成,构建集合模型进行调度规则提取并生成决策预测区间。

b. 在始丰河流域的实例应用结果表明,物理机制与 KF 耦合有效提升了模型的结构合理性与模拟精度。在偏上游防洪情景下,物理约束显著改善了模型输出的一致性,LSTM 模型在测试集上的水量平衡指数下降 0.19 ,且 XGBoost 模型的负值流量占比降至 0 。

c. 集合模型综合表现优于单一模型,其 NSE 均超过 0.97 ,水量平衡指数接近 1 ,负值流量占比为 0 ,其生成的置信区间覆盖率超过 90% ,平均区间宽度不超过 $2.7 \text{ m}^3/\text{s}$,在提升模拟精度的同时增强了结构合理性。

参考文献:

[1] 严登华,王浩,周梦,等. 全球治水模式思辨与发展展望[J]. 水资源保护, 2020, 36(3): 1-7. (Yan Denghua,

Wang Hao, Zhou Meng, et al. Scientific ideas and development prospects of global water management modes [J]. Water Resources Protection, 2020, 36(3): 1-7. (in Chinese))

[2] 左其享,张志卓,马军霞. 我国现代治水研究进展与展望[J]. 水利水电科技进展, 2025, 45(5): 102-111. (Zuo Qiting, Zhang Zhizhuo, Ma Junxia. Progress and prospects of modern water control research in China [J]. Advances in Science and Technology of Water Resources, 2025, 45(5): 102-111. (in Chinese))

[3] Lehner B, Liermann C R, Revenga C, et al. High-resolution mapping of the world's reservoirs and dams for sustainable river-flow management [J]. Frontiers in Ecology and the Environment, 2011, 9(9): 494-502.

[4] 许月萍,陆豪楠,于欣廷,等. 基于深度学习集合预报的水库闸门防洪优化调度[J]. 水科学进展, 2024, 35(6): 900-913. (Xu Yueping, Lu Haonan, Yu Xinting, et al. Optimization of gate operation for reservoir flood control based on deep learning ensemble forecasting [J]. Advances in Water Science, 2024, 35(6): 900-913. (in Chinese))

[5] 徐宗学,陈浩,任梅芳,等. 中国城市洪涝致灾机理与风险评估研究进展[J]. 水科学进展, 2020, 31(5): 713-724. (Xu Zongxue, Chen Hao, Ren Meifang, et al. Progress on disaster mechanism and risk assessment of urban flood/waterlogging disasters in China [J]. Advances in Water Science, 2020, 31(5): 713-724. (in Chinese))

[6] 徐宗学,卢兴超,施奇妙. 城市暴雨洪涝灾害特征与风险评估研究进展[J]. 水利水电科技进展, 2025, 45(1): 1-9. (Xu Zongxue, Lu Xingchao, Shi Qimiao. Research progress on urban flooding disaster characteristics and risk assessment [J]. Advances in Science and Technology of Water Resources, 2025, 45(1): 1-9. (in Chinese))

[7] 吴祈,郭海湘,辛美仪,等. 城市洪水灾害韧性评估及其影响因素研究:以武汉市为例[J]. 灾害学, 2026, 41(1): 202-211. (Wu Qi, Guo Haixiang, Xin Meiyi, et al. Urban flood disaster resilience assessment and its influencing factors; a case study of Wuhan City [J]. Journal of Catastrophology, 2026, 41(1): 202-211. (in Chinese))

- [8] Field C B,Barros V,Stocker T F,et al. Managing the risks of extreme events and disasters to advance climate change adaptation:special report of working groups I and II of the Intergovernmental panel on climate change [R]. Cambridge:Cambridge University Press,2012.
- [9] Mohanty A, Sahoo B, Kale R V. A coupled optimized hedging rule-based reservoir operation and hydrodynamic model framework for riverine flood risk management[J]. Water Research,2025,279:123443.
- [10] 黄德春,朱宇昂,张修忠,等. 基于多理论视角的我国现代化水库运行管理矩阵建设研究[J]. 水利经济,2025,43(3):84-93. (Huang Dechun, Zhu Yuang, Zhang Xiuzhong,et al. Research on the construction of modern reservoir operation and management matrix in China from multiple theoretical perspectives[J]. Journal of Economics of Water Resources,2025,43(3):84-93. (in Chinese))
- [11] Yu Xinting,Xu Yueping,Gu Haiting,et al. Multi-objective robust optimization of reservoir operation for real-time flood control under forecasting uncertainty[J]. Journal of Hydrology,2023,620:129421.
- [12] 王栋,武新宇,王森,等. 基于可用水量预测的梯级水电站水库调度函数[J]. 水资源研究,2014,3(3):257-266. (Wang Dong, Wu Xinyu, Wang Sen,et al. Cascaded reservoirs operation rules based on predicted available water[J]. Journal of Water Resources Research,2014,3(3):257-266. (in Chinese))
- [13] Bhaskar N R, Whitlatch Jr E E. Derivation of monthly reservoir release policies[J]. Water Resources Research, 1980,16(6):987-993.
- [14] Young Jr G K. Finding reservoir operating rules [J]. Journal of the Hydraulics Division,1967,93(6):297-322.
- [15] 钟加星,董增川,孟金玉,等. 基于机器学习的黄河上游梯级水库群多目标优化调度规则提取[J]. 河海大学学报(自然科学版),2024,52(6):30-37. (Zhong Jiaxing, Dong Zengchuan, Meng Jinyu, et al. Extracting multi-objective optimal operation rules of cascade reservoirs in upper reaches of Yellow River based on machine learning [J]. Journal of Hohai University (Natural Sciences), 2024,52(6):30-37. (in Chinese))
- [16] 赵紫薇,杨哲,张全旺,等. 考虑预报不确定性的梯级水库群联合优化调度[J]. 水利水电科技进展,2025,45(4):67-75. (Zhao Ziwei, Yang Zhe, Zhang Quanwang, et al. Joint optimal operation of cascade reservoirs considering forecast uncertainty[J]. Advances in Science and Technology of Water Resources,2025,45(4):67-75. (in Chinese))
- [17] 刘亚新,徐杨. 基于机器学习的葛洲坝水电站日均出力预测[J]. 人民长江,2022,53(4):201-209. (Liu Yaxin, Xu Yang. Prediction of daily power output of Gezhouba Hydropower Station during non-discarded water period based on machine learning [J]. Yangtze River, 2022, 53 (4): 201-209. (in Chinese))
- [18] 周婷,纪昌明,朱艳霞,等. 基于支持向量机的梯级水电站群中长期调度计划制定及评价[J]. 电力系统自动化,2013,37(2):56-60. (Zhou Ting, Ji Changming, Zhu Yanxia, et al. Establishment and evaluation of medium-long term operating plans for cascade hydropower stations based on support vector machine [J]. Automation of Electric Power Systems, 2013, 37 (2): 56-60. (in Chinese))
- [19] 张彪,彭杨,亓心仪,等. 基于深度学习的三峡水库汛期调度规则提取方法[J]. 中国农村水利水电,2026(2):99-106. (Zhang Biao, Peng Yang, Qi Xinyi, et al. A method for extracting flood season regulation rules of Three Gorges Reservoir based on deep learning[J]. China Rural Water and Hydropower,2026(2):99-106. (in Chinese))
- [20] Wei C C, Hsu N S. Derived operating rules for a reservoir operation system: comparison of decision trees, neural decision trees and fuzzy decision trees [J]. Water Resources Research,2008,44(2):2006WR005792.
- [21] Shen Chaopeng. A transdisciplinary review of deep learning research and its relevance for water resources scientists[J]. Water Resources Research,2018,54(11):8558-8593.
- [22] Willard J, Jia Xiaowei, Xu Shaoming, et al. Integrating scientific knowledge with machine learning for engineering and environmental systems[J]. ACM Computing Surveys, 2023,55(4):1-37.
- [23] 瞿思敏,余裕,方正,等. 机器学习模型与物理机制模型在长诏水库流域实时洪水预报中的比较研究[J]. 水资源保护,2025,41(5):73-78. (Qu Simin, Yu Yu, Fang Zheng, et al. Comparative study of machine learning model and physical mechanism model in flood forecasting of the Changzhao Reservoir Basin [J]. Water Resources Protection,2025,41(5):73-78. (in Chinese))
- [24] 冯钧,邵萍萍,张继茹,等. 物理引导数据驱动方法研究综述及其在水文模型构建中的应用与展望[J]. 河海大学学报(自然科学版),2025,53(5):1-9. (Feng Jun, Shao Pingping, Zhang Jiru, et al. Research review of physics-guided data-driven methods and their application and prospects in hydrological model development [J]. Journal of Hohai University (Natural Sciences), 2025, 53 (5): 1-9. (in Chinese))
- [25] Zheng Yalian, Liu Pan, Cheng Lei, et al. Extracting operation behaviors of cascade reservoirs using physics-guided long-short term memory networks [J]. Journal of Hydrology:Regional Studies,2022,40:101034.
- [26] 罗赞,张翔宇,董增川,等. 基于物理机制耦合深度学习的黄河干流流量演进模拟[J]. 水科学进展,2025,36(2):217-229. (Luo Yun, Zhang Xiangyu, Dong Zengchuan, et al. Simulation of river flow evolution in the Yellow River main stream based on the coupling of physical mechanisms and deep learning [J]. Advances in Water Science,2025,36(2):217-229. (in Chinese))

- [27] 钟鸣,张鸿瑞,王一帆,等. 基于物理机制耦合深度学习方法的径流预测研究[J]. 云南电力技术,2023,51(3):2-6. (Zhong Ming, Zhang Hongrui, Wang Yifan, et al. Research on runoff prediction based on physical mechanism coupling deep learning method[J]. Yunnan Electric Power,2023,51(3):2-6. (in Chinese))
- [28] Rezaei J. Best-worst multi-criteria decision-making method[J]. Omega,2015,53:49-57.
- [29] 金菊良,刘东平,周戎星,等. 基于投影寻踪权重优化的水资源承载力评价模型[J]. 水资源保护,2021,37(3):1-6. (Jin Juliang, Liu Dongping, Zhou Rongxing, et al. Evaluation model of water resources carrying capacity based on projection pursuit weight optimization[J]. Water Resources Protection,2021,37(3):1-6. (in Chinese))
- [30] 左其亭,张志卓,吴滨滨. 基于组合权重 TOPSIS 模型的黄河流域九省区水资源承载力评价[J]. 水资源保护,2020,36(2):1-7. (Zuo Qiting, Zhang Zhizhuo, Wu Binbin. Evaluation of water resources carrying capacity of nine provinces in Yellow River Basin based on combined weight TOPSIS model[J]. Water Resources Protection,2020,36(2):1-7. (in Chinese))
- [31] 王子悦,徐慧,黄丹姿,等. 基于熵权物元模型的长三角幸福河层次评价[J]. 水资源保护,2021,37(4):69-74. (Wang Ziyue, Xu Hui, Huang Danzi, et al. Hierarchy evaluation of Happy River in the Yangtze River Delta based on entropy weight and matter element model[J]. Water Resources Protection,2021,37(4):69-74. (in Chinese))
- [32] 白晓燕,赖成光,陈晓宏,等. 基于 Critic-Cloud 模型的东江干流水质评价[J]. 水资源保护,2014,30(5):26-31. (Bai Xiaoyan, Lai Chengguang, Chen Xiaohong, et al. Evaluation of water quality of trunk stream of Dongjiang River based on Critic-Cloud model[J]. Water Resources Protection,2014,30(5):26-31. (in Chinese))
- [33] 杨荣金,王逸卓,李秀红,等. 官厅水库水质评价及时空变化特征[J]. 水资源保护,2021,37(6):135-141. (Yang Rongjin, Wang Yizhuo, Li Xiuhong, et al. Water quality evaluation and spatiotemporal variation characteristics of Guanting Reservoir[J]. Water Resources Protection,2021,37(6):135-141. (in Chinese))
- [34] Bentéjac C, Csörgö A, Martínez-Muñoz G. A comparative analysis of gradient boosting algorithms[J]. Artificial Intelligence Review,2021,54(3):1937-1967.
- [35] Chen Tianqi, Guestrin C. XGBoost: a scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco:ACM,2016:785-794.
- [36] Shwartz-Ziv R, Armon A. Tabular data: deep learning is not all you need[J]. Information Fusion,2022,81:84-90.
- [37] Khorram S, Jehbez N. A hybrid CNN-LSTM approach for monthly reservoir inflow forecasting[J]. Water Resources Management,2023,37(10):4097-4121.
- [38] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation,1997,9(8):1735-1780.
- [39] 张伟,郑雅莲,刘志武,等. 物理机制引导的水库调度深度学习模型研究[J]. 水力发电学报,2023,42(3):13-25. (Zhang Wei, Zheng Yalian, Liu Zhiwu, et al. Deep learning model guided by physical mechanism for reservoir operation[J]. Journal of Hydroelectric Engineering,2023,42(3):13-25. (in Chinese))
- [40] 金桂中,陈国灿,赵兰兰,等. 基于多源预报残差的卡尔曼滤波校正技术[J]. 河海大学学报(自然科学版),2024,52(4):1-4. (Jin Guizhong, Chen Guocan, Zhao Lanlan, et al. Kalman filter correction technique based on multi-source forecast residuals[J]. Journal of Hohai University (Natural Sciences),2024,52(4):1-4. (in Chinese))
- [41] Luo Yuxuan, Zhou Yanlai, Xu Hanbing, et al. Enhancing physically-based flood forecasts through fusion of long short-term memory neural network with unscented Kalman filter[J]. Journal of Hydrology,2024,641:131819.
- [42] Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting[J]. Journal of Computer and System Sciences,1997,55(1):119-139.
- [43] Breiman L. Bagging predictors[J]. Machine Learning,1996,24(2):123-140.
- [44] Wolpert D H. Stacked generalization[J]. Neural Networks,1992,5(2):241-259.
- [45] van der Laan M J, Polley E C, Hubbard A E. Super learner[J]. Statistical Applications in Genetics and Molecular Biology,2007,6(1):1-21.
- [46] Breiman L. Random forests[J]. Machine Learning,2001,45(1):5-32.
- [47] Metropolis N, Ulam S. The Monte Carlo method[J]. Journal of the American Statistical Association,1949,44(247):335-341.
- [48] Nash J E, Sutcliffe J V. River flow forecasting through conceptual models part I: a discussion of principles[J]. Journal of Hydrology,1970,10(3):282-290.
- [49] Chai T, Draxler R R. Root mean square error (RMSE) or mean absolute error (MAE)? : arguments against avoiding RMSE in the literature[J]. Geoscientific Model Development,2014,7(3):1247-1250.
- [50] Pearson K. VII. mathematical contributions to the theory of evolution: III. regression, heredity, and panmixia[J]. Philosophical Transactions of the Royal Society of London. Series A, Containing Papers of a Mathematical or Physical Character,1896(187):253-318.
- [51] Zhang Di, Lin Junqiang, Peng Qidong, et al. Modeling and simulating of reservoir operation using the artificial neural network, support vector regression, deep learning algorithm[J]. Journal of Hydrology,2018,565:720-736.

(收稿日期:2025-12-26 编辑:王芳)