

DOI: 10.14042/j.cnki.32.1309.2024.06.004

# 基于深度学习集合预报的水库闸门防洪优化调度

许月萍, 陆豪楠, 于欣廷, 郭玉雪

(浙江大学建筑工程学院, 浙江 杭州 310058)

**摘要:** 为了减轻洪水灾害的损失, 有必要开展水库防洪预报调度的研究。针对目前水库防洪调度研究较少考虑闸门实际运行及调度方案可执行性的问题, 提出以泄放闸门状态与状态持续时长为决策变量的精细化防洪优化调度模型, 并且考虑入库流量预报不确定性的影响, 将集合了 Long Short-Term Memory (LSTM)、Gated Recurrent Unit (GRU) 与 Transformer 深度学习模型的不确定性集合预报作为调度模型输入, 在浙江省椒江流域开展实例研究。结果表明: 集合预报精度较单一模型提高了 4.6%, 其不确定性预报结果可用于水库调度; 精细化防洪优化调度相比常规调度优势明显, 能降低平均最高坝前水位 0.43 m, 降低下游控制断面平均洪峰流量 32.9 m<sup>3</sup>/s, 方案效果受入库流量不确定性的影响更小, 方案可执行性高, 对水库防洪调度决策有重要的参考价值。

**关键词:** 防洪调度; 集合预报模型; 深度学习; 水库闸门; 多目标优化; 不确定性

**中图分类号:** TV877 **文献标志码:** A **文章编号:** 1001-6791(2024)06-0900-14

受全球环境变化与人类活动影响, 中国洪涝灾害问题日益突出, 严重危害了中国的经济生产与人民生命财产安全<sup>[1]</sup>。水库防洪调度是削弱洪水影响的重要非工程措施, 近年来, 基于洪水预报的水库防洪调度研究受到国内外研究者的重视, 该方法以洪水预报为输入信息, 定制有效的防洪调度策略, 对防洪减灾工作有重要的应用价值<sup>[2-4]</sup>。

近年来国内外学者在洪水预报和水库防洪调度领域开展了诸多研究。洪水预报方面, 有研究表明基于数据驱动的深度学习模型与多模型集合预报技术在洪水预报中有良好的适用性, 相比传统物理机制水文模型更具优势<sup>[5-10]</sup>。水库防洪调度方面, 一部分研究集中于调度问题的求解方法, 如以线性规划和动态规划为代表的运筹学方法, 以及以粒子群算法<sup>[11-13]</sup>、遗传算法<sup>[14-16]</sup>等为代表的启发式算法; 另一部分研究集中于预报调度模型的设计, 根据调度模型的决策变量性质可大致分为 2 类。一类以水库调度直接水力要素为决策变量, 如水库每一时段的下泄流量、每一时段的水库水位等, 调度方案直接给出每个调度时段水库相关参数的值<sup>[17-19]</sup>, 此类模型建模简单, 方案直观。另一类基于“模拟-优化”的设计框架, 将水库防洪调度过程简化为一个由参数控制的数学模型, 以数学模型的主要参数为决策变量, 将水库下泄流量视为水库水位、入库流量的分段线性函数, 优化函数斜率与截距<sup>[20-21]</sup>; 也有将水库的下泄规则参数化, 并以此为决策变量进行优化求解<sup>[22-23]</sup>, 此类模型决策变量数相对较少, 适合复杂问题的求解, 如多水库联合调度。

以上水库防洪调度研究在模型设计与求解方法方面贡献显著, 但这些研究较少考虑水库的实际运用情况, 存在时段下泄流量频繁调整、瞬时突变等问题<sup>[24]</sup>, 且下泄流量难以精确控制, 使得求解方案难以直接应用, 尤其对于小时尺度的防洪调度。在实际调度场景中, 水库管理人员依照调度指令操作水库闸门, 具体细化至水库泄放设施闸门的启闭情况, 因此有必要研究符合实际调度操作需求的精细化模型。王靖等<sup>[25]</sup>采

收稿日期: 2024-06-19; 网络出版日期: 2024-11-11

网络出版地址: <https://link.cnki.net/urlid/32.1309.P.20241108.1636.002>

基金项目: 国家重点研发计划资助项目(2021YFD1700802); 浙江省重点研发计划资助项目(2021C03017)

作者简介: 许月萍(1975—), 女, 浙江诸暨人, 教授, 博士, 主要从事水文与水资源研究。E-mail: [yuepingxu@zju.edu.cn](mailto:yuepingxu@zju.edu.cn)

用多步次逐步优化算法计算水库防洪调度的下泄流量, 并使用二分法和二次微调方法在水库各泄水闸门之间分配流量; Kim 等<sup>[26]</sup>构建了基于溢洪道控制的水库防洪优化调度模型, 并使用后处理方法平滑闸门操作过程。以上研究通过二次分配与后处理的方法构建水库的调度方案使其满足水库闸门的实际运用情况, 但目前关于同时优化水库泄放闸门的开启组合和开启时长的模型研究较少。

针对此, 本文拟构建一个基于多种深度学习算法的水库入库流量集合预报模型, 并提出一种符合实际调度工作需求的基于深度学习集合预报的水库精细化防洪优化调度方法, 最后以浙江省椒江流域的里石门水库为研究对象, 开展实例研究。

## 1 研究方法

### 1.1 基于深度学习算法的洪水集合预报

#### 1.1.1 深度学习模型

本文分别构建了基于 Long Short-Term Memory(LSTM)、Gated Recurrent Unit(GRU)、Transformer 的水库入库流量预报模型, 并基于单一模型表现构建集合预报模型。

(1)LSTM 模型。LSTM 网络由 Hochreiter 等<sup>[27]</sup>提出, 该模型是循环神经网络(RNN)的一种改进模型, 改善了 RNN 模型在长时间序列学习任务中出现的梯度消失问题。LSTM 模型在 RNN 模型的基础上设置了遗忘与记忆的机制, 增加了“遗忘门”、“输入门”和“输出门”, 分别负责训练信息的取舍、输入和输出, 从而能更好地利用长时间序列的数据信息。

(2)GRU 模型。GRU 网络对 LSTM 网络进行了改进, 提出“更新门”和“输出门”替换 RNN 结构, 简化了 LSTM 结构, 所需参数更少, 使模型的性能与 LSTM 相近, 但计算效率更高<sup>[28]</sup>。

(3)Transformer 模型。Transformer 模型<sup>[29]</sup>是基于多头注意力机制的编码器与解码器架构网络, 通过自注意力机制获取数据的全局信息, 利用位置编码获取数据序列的顺序信息, 与传统的递归神经网络相比该方法能更好地捕捉数据的全局信息, 上述特性表明该方法也同样适合用于解决时间序列预测问题。Transformer 网络的核心是多头注意力机制, 其中注意力函数将查询向量和一组键值向量映射到输出向量。输出向量为值向量的加权和, 其中每个值的权重由查询向量与相应的键向量的兼容性函数计算得出。每个注意力机制的输出为一个头, 最后将多头注意力机制输出结果加权合并得到最终输出。

#### 1.1.2 集合预报模型

构建单一预报模型时, 将样本数据分为训练集、验证集和测试集。为保证单一模型的训练性能与泛化性能, 需同时考虑训练集和验证集的模拟效果, 因此构建模型综合评价指标( $P$ )如下:

$$P_i = \omega E_{NS,i,tr} + (1 - \omega) E_{NS,i,va} \quad (1)$$

式中:  $P_i$  为模型  $i$  的综合评价指标;  $E_{NS,i,tr}$  和  $E_{NS,i,va}$  分别为模型  $i$  训练集和验证集的纳什效率系数;  $\omega$  为权重, 本文同等考虑训练集和验证集, 因此  $\omega=0.5$ 。在水文研究中多采用纳什效率系数( $E_{NS}$ )评估模型性能,  $E_{NS}$  越接近 1 则表示误差越小, 模型效果越好。

集合预报模型(EMs)由单一模型加权平均得出。上述 3 个深度学习模型将根据  $P$  选取最优参数, 并计算单一模型权重, 加权平均得到集合模型预测值。模型权重计算如下:

$$W_i = P_i / \sum_{i=1}^m P_i \quad (2)$$

式中： $W_i$ 为模型*i*的权重参数； $m$ 为模型总数。则集合预报值 $Q_a = \sum_{i=1}^m W_i \times Q_{\text{inf},i}$ ， $Q_{\text{inf},i}$ 为模型*i*的预报入库流量。

### 1.1.3 基于模型权重的分段随机模拟与不确定区间计算

结合贝叶斯模型平均方法(BMA)的不确定区间估计<sup>[30]</sup>，本文采用了一种基于模型权重的分段不确定区间估计方法，具体步骤如下：

步骤一：根据流量大小将模型*i*训练验证集流量数据排序分为*a*段，计算各流量段预报误差的均值( $\mu_j$ )与均方根( $\sigma_j$ )， $j=1,2,\dots,a$ ，并构成模型*i*流量预报误差的均值( $\mu_i$ )与均方根( $\sigma_i$ )。

步骤二：根据各预报模型的权重 [ $W_1, W_2, \dots, W_m$ ] 计算分段累积概率， $W'_0 = 0$ ， $W'_i = W'_{i-1} + W_i$ ；随机产生一个数  $n \in [0,1]$ ，若  $W'_{k-1} < n \leq W'_k$ ，则表示选择第*k*个模型。

步骤三：生成第*k*个模型在*t*时刻误差( $\varepsilon_t$ )的概率分布  $g(\varepsilon_t | \mu_k, \sigma_k)$ ，并随机产生一个流量值  $Q'_t = Q_{k,t} + \varepsilon_t$ ，其中， $Q_{k,t}$ 为模型*k*在*t*时刻的预报值， $g(\varepsilon_t | \mu_k, \sigma_k)$ 表示均值为 $\mu_k$ 、标准差为 $\sigma_k$ 的正态分布。

步骤四：重复步骤以上步骤*M*次，即随机模拟*M*次。

以*M*次随机模拟各时刻的最大值与最小值为不确定区间的上下边界。

## 1.2 水库精细化防洪优化调度模型

本文以水库泄放闸门的状态参数值与状态持续时长为调度模型的决策变量，以入库流量集合预报为输入，构建了一个考虑实际调度需求和预报不确定性的精细化防洪优化调度模型。

### 1.2.1 目标函数

本研究从水库自身与下游控制断面角度出发，设置了以下4个优化目标。

(1)最高坝前水位最低。水库坝前水位是反映水库安全状态的重要指标，考虑到入库流量的不确定性，以平均最高坝前水位最低作为防洪调度的目标函数之一。

$$\begin{cases} F_1 = \sum_{i=1}^N Z_{i,\max} / N \\ Z_{i,\max} = \max\{Z_{i,t}\}, \quad t = 1, 2, \dots, T \end{cases} \quad (3)$$

式中： $Z_{i,t}$ 和 $Z_{i,\max}$ 分别为入库流量序列*i*作为调度输入情况下，水库*t*时间段的坝前水位和调度过程中的最高坝前水位；*T*为时间步长总数；*N*为不确定预报入库流量序列个数。

(2)控制断面洪峰流量最小。水库防洪调度直接目的是拦蓄洪水减轻下游河段的防洪压力，调度时采用河段重要控制断面的流量过程表征河段的行洪状态，根据马斯京根河道演进计算可求得控制断面的洪水过程。考虑到入库流量的不确定性，以平均控制断面洪峰流量最小作为防洪调度的目标函数之一。

$$\begin{cases} F_2 = \sum_{i=1}^N Q_{s,i,\max} / N \\ Q_{s,i,\max} = \max\{Q_{s,i,t}\}, \quad t = 1, 2, \dots, T \end{cases} \quad (4)$$

式中： $Q_{s,i,t}$ 和 $Q_{s,i,\max}$ 分别为入库流量序列*i*作为调度输入情况下，控制断面*t*时间段的流量和控制断面洪峰流量。

(3)水库防洪风险最低。入库流量预报的不确定性会增加水库的防洪风险，以水库最高水位超过安全水位次数占不确定性入库流量计算次数的比例为水库防洪风险，并以此为防洪调度的目标函数之一。

$$\begin{cases} F_3 = \text{count}(Z_{i,\max} > Z_{\text{safe}}) / N \times 100\% \\ Z_{i,\max} = \max\{Z_{i,t}\}, \quad t = 1, 2, \dots, T \end{cases} \quad (5)$$

式中:  $Z_{\text{safe}}$  为水库安全水位;  $\text{count}(\cdot)$  为计数函数。

(4) 下游控制断面防洪风险最低。入库流量预报的不确定性会增加控制断面的防洪风险, 以控制断面洪峰流量超过安全流量次数占不确定性入库流量计算次数的比例为下游控制断面防洪风险, 并以此为防洪调度的目标函数之一。

$$\begin{cases} F_4 = \text{count}(Q_{s,i,\max} > Q_{s,\text{safe}})/N \times 100\% \\ Q_{s,i,\max} = \max\{Q_{s,i,t}\}, \quad t = 1, 2, \dots, T \end{cases} \quad (6)$$

式中:  $Q_{s,\text{safe}}$  为控制断面安全流量。

### 1.2.2 约束条件

#### (1) 水库水量平衡约束

$$V_{t+1} - V_t = (I_t - O_t)\Delta t \quad (7)$$

式中:  $V_t$  和  $V_{t+1}$  分别为  $t$  时段和  $t+1$  时段水库库容;  $I_t$  和  $O_t$  分别为  $t$  时段入库和出库流量;  $\Delta t$  为单位时间步长间隔时间, 即每间隔  $\Delta t$  更新一次水库及下游控制断面的状态参数。

#### (2) 水库运行水位约束

$$Z_{\min} \leq Z_{t,\text{mean}} \leq Z_{\max} \quad (8)$$

式中:  $Z_{t,\text{mean}}$  为水库  $t$  时段的平均坝前水位;  $Z_{\min}$ 、 $Z_{\max}$  分别为水库调度期内允许的最低水位与最高水位, 最高水位可根据洪水等级取不同的特征水位如汛限水位、防洪高水位、校核洪水位等, 最低水位可取死水位, 或规定允许的最低运行水位等。

#### (3) 泄放闸门泄流能力约束

$$Q_{i,\min} \leq Q_{i,t} \leq Q_{i,\max} \quad (9)$$

式中:  $Q_{i,t}$  为泄放闸门  $i$  在时段  $t$  的下泄流量;  $Q_{i,\min}$  和  $Q_{i,\max}$  分别为泄放闸门  $i$  的最小和最大下泄流量。

#### (4) 下游控制断面安全流量约束

$$Q_{s,t,\text{mean}} \leq Q_{s,\max} \quad (10)$$

式中:  $Q_{s,t,\text{mean}}$  为控制断面时段  $t$  的平均流量;  $Q_{s,\max}$  为控制断面允许最大流量。

(5) 泄洪闸门运行约束。泄洪闸门运行时的约束, 如对称开启、汛期发电闸门常开、溢洪道闸门最低开启水位等。

#### (6) 非负性约束。模型中各物理量为非负实数。

### 1.2.3 决策变量

在水库的实际防洪调度过程中, 水库泄放流量由闸门的开启个数、开度与开启时长控制, 因此本文提出以水库泄放闸门的状态  $\mathbf{X}_1$  与状态时长  $\mathbf{X}_2$  作为调度模型的决策变量, 有利于调度方案实际运用。决策变量设置如下:

$$G_{\text{gate},\min} \leq \mathbf{X}_1 \leq G_{\text{gate},\max} \quad (11)$$

$$T_{\text{gate},\min} \leq \mathbf{X}_2 \leq T_{\text{gate},\max} \quad (12)$$

式中:  $G_{\text{gate},\min}$  和  $G_{\text{gate},\max}$  分别为状态值的下限和上限;  $T_{\text{gate},\min}$  和  $T_{\text{gate},\max}$  分别为状态持续时长下限和上限;  $\mathbf{X}_1$  与  $\mathbf{X}_2$  的个数与时间步长数  $T$  一致。不同泄放闸门状态对应的泄放流量由水库泄放闸门的泄放流量函数计算得出。

### 1.2.4 模型求解方法

本研究采用 NSGA-III 求解上述构建的防洪调度模型, NSGA-III 在 NSGA-II 的结构框架基础上, 采用参考平面法代替拥挤度法, 提高了多目标, 尤其是 3 个以上目标问题的求解效果<sup>[31]</sup>, 并在算法执行步骤中嵌入决

策变量修正与约束超限修正模块。具体求解步骤如下:

步骤一: 设置模型决策变量数据类型与取值范围, 构建目标函数, 设置优化算法基本参数包括种群规模、迭代次数, 随机生成初始父代种群。

步骤二: 执行  $X_2$  对  $X_1$  的修正程序, 计算种群的约束违反情况, 修正违反约束的个体, 用修正后的  $X_1'$  计算种群的目标函数值。

步骤三: 继续执行优化算法中的剩余步骤直至当前迭代程序完成。

步骤四: 重复上述二、三步骤直至迭代次数达到最大迭代次数, 获取 Pareto 解集。

步骤五: 根据不同偏好选择相应决策方案。

步骤二中  $X_2$  对  $X_1$  的修正程序具体过程如图 1 所示, 其中  $X_1=[x_{1,1}, x_{1,2}, \dots, x_{1,T}]$ ,  $X_2=[x_{2,1}, x_{2,2}, \dots, x_{2,T}]$ , 均为长度为  $T$  的向量。若  $x_{1,1}=m$  且  $x_{2,1}=a$ , 则  $x_{1,1}$  至  $x_{1,a}$  修正为  $m$ ,  $x_{1,1+a}=v$  且  $x_{2,2}=b$ , 则  $x_{1,a+1}$  至  $x_{1,a+b}$  修正为  $v$ , 以此类推直到  $X_1$  修正完成记为  $X_1'$ 。该过程将  $X_2$  中的闸门状态持续时长嵌入至  $X_1'$  中, 使  $X_1'$  既能表征泄放闸门的状态也能表征相应状态的持续时长。




图 1  $X_2$  对  $X_1$  的修正过程

Fig. 1 Correction process of  $X_2$  to  $X_1$

需要注意的是, 为了保证模型的泛化性在模型设置中  $X_1$  与  $X_2$  个数相同, 而修正过程中,  $X_2$  实际使用个数由具体决策变量设置决定, 多余的  $X_2$  将会被模型自动忽略。

## 2 研究案例

### 2.1 研究区域与数据

里石门水库位于浙江省椒江流域上游始丰溪, 所在位置如图 2 所示。里石门水库作为始丰溪上最大的水库, 发挥着重要的防洪作用, 防洪控制断面位于水库坝址河道下游 28.2 km 处前山大桥(下文称前山断面)。水库集雨面积为 296 km<sup>2</sup>, 水库总库容为 1.793 亿 m<sup>3</sup>, 防洪库容为 0.357 亿 m<sup>3</sup>。可为防洪调度使用的泄放闸门包括溢洪道闸门(由 8 扇 10 m×5.3 m 弧形闸门控制)、泄洪洞闸门(3 m×3 m 方圆形断面)和发电尾水闸门。里石门水库其他特征参数见表 1。在常规调度中, 水库管理方遵循防洪调度规则, 根据水库当前的库容使用情况、下游控制断面流量和未来预报入库流量, 调节泄放闸门的开闭组合, 实现对入库洪水的有效削峰, 保护下游控制断面, 例如“当水位超过 179.04 m 时允许对称开启 ≤4 孔泄洪; 水位超过 180.04 m 允许对称开启 2 孔泄洪”。

本研究搜集了下田、柘溪、四协、方前、寺家、里石门 6 个雨量站 1987—2020 年的洪水场次降雨实测数据和里石门水库的实际入库流量数据, 共计 22 场, 其中 1987—2016 年 18 场洪水场次数据为训练和验证数据, 最大洪峰为 2 700 m<sup>3</sup>/s, 平均流量为 151 m<sup>3</sup>/s, 流量标准差为 256 m<sup>3</sup>/s, 按照 7:3 随机划分为训练集与验

证集; 2017—2020年4场洪水场次数据作为测试集, 最大洪峰为1 860 m<sup>3</sup>/s, 平均流量为137m<sup>3</sup>/s, 流量标准差为291 m<sup>3</sup>/s。

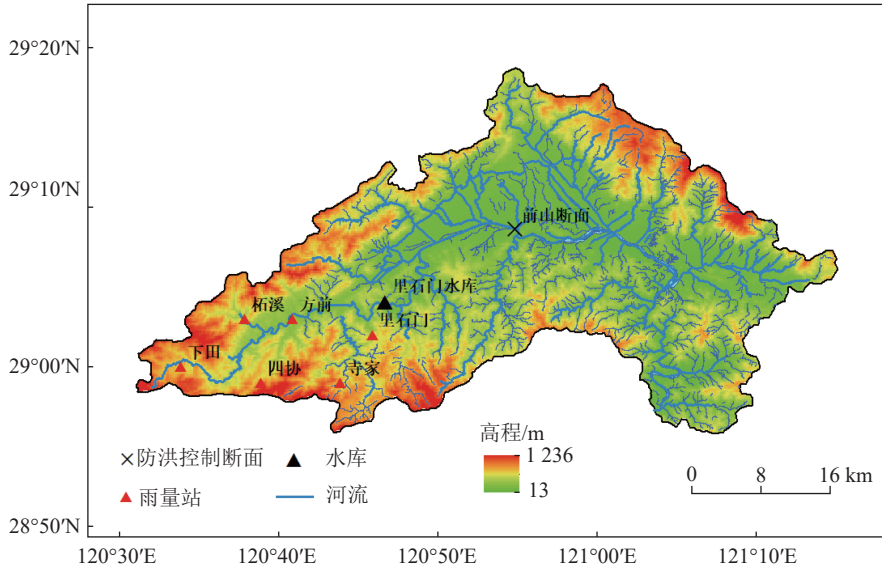


图2 研究区域概况

Fig. 2 Overview of study area

表1 里石门水库特征参数

Table 1 Characteristic parameters of Lishimen Reservoir

序号	特征参数	取值	序号	特征参数	取值
1	最低运行水位/m	160.04	6	校核洪水位/m	184.06
2	汛限水位/m	176.04	7	防洪库容/万m <sup>3</sup>	3 570
3	防洪高水位/m	180.69	8	控制断面安全流量/(m <sup>3</sup> /s)	1 479
4	设计洪水位/m	181.34	9	发电流量/(m <sup>3</sup> /s)	20.4
5	泄洪洞流量/(m <sup>3</sup> /s)	$Q_{XHD} = -4.947 \times 10^{-15} I^2 + 1.719 \times 10^{-6} I + 55.8$	10	溢洪道流量/(m <sup>3</sup> /s)	$Q_{YHD} = 173.7(Z - 176)^{1.5}$

## 2.2 研究试验设置

### 2.2.1 洪水预报模型试验设置

本文分别建立了上述3种深度学习算法的水库入库流量预报模型, 各模型的输入与输出数据结构均保持一致, 并根据模型的性能赋予相应的权重, 构成集合预报模型。为了确定合适的输入数据序列长度, 分析了降雨数据与水库入库流量数据之间的互相关性, 确定输入节点为6个雨量站*t*时刻及以往共20h的每小时降水量, 输出节点为*t*时刻的水库入库流量。如此设置构建了降水量数据与水库入库流量间的映射关系, 通过滚动计算提供水库防洪调度长序列预报入库流量数据, 由于输入数据中不包含水库以往的入库流量, 滚动计算不会导致入库流量预报误差的累计, 实际运用时将在实测降雨数据后接入预报降雨数据, 与前期实测降雨数据共同作为洪水预报模型的输入数据。

对深度学习模型进行参数敏感性分析以确定模型最优参数。将LSTM网络与GRU网络隐藏层层数设为3层, 分析每层神经元个数与层间随机失活率对模型表现的影响。对于Transformer网络则分析编码层、解码层层数与层间随机失活率对模型表现的影响。3个模型迭代次数均为1 000, 损失函数为均方误差( $E_{MS}$ ), 评

价指标为  $E_{NS}$ 、均方根误差( $E_{RMS}$ )、平均绝对误差( $E_{MA}$ )和峰现时间误差( $E_{PE}$ )。

根据式(1)计算模型综合评价指标,为每个单一模型选择综合表现最好的参数配置,并根据式(2)计算模型权重构成集合预报模型。计算不确定区间时,流量序列降序排列等分4段,随机模拟次数设置为500。

### 2.2.2 水库精细化防洪优化调度模型试验设置

调度模型以2019年8月9日场次洪水的入库流量集合预报值随机生成的100组入库流量为输入数据,依据入库流量序列长度,将调度时长设置为25 h,决策变量  $X_1$  与  $X_2$  个数均为25。为发挥水库的防洪能力,将调度最低水位设为最低运行水位160.04 m,最高水位设为防洪高水位(5%)180.69 m。研究案例里石门水库由于未安装闸门开度仪,无法精确控制闸门的开度,实际调度中闸门采用全开或全关,洪水期间发电闸门常开,该水库  $X_1$  取值对应的泄放闸门状态如表2所示。 $T_{gate,min}$  在本文中取3 h,  $T_{gate,max}$  在本文中取调度总时长25 h。NSGA-III算法采用默认参数,编码方式为实整数编码(RI),种群规模为200,迭代次数为500。

表 2 泄放闸门状态取值  
Table 2 Values of discharge gate status

$X_1$	0	1	2	3	4	5	6
泄放闸门状态	所有泄放闸门关闭	发电闸门开启	发电闸门开启+泄洪洞全开	发电闸门开启+2孔溢洪道全开	发电闸门开启+4孔溢洪道全开	发电闸门开启+6孔溢洪道全开	发电闸门开启+8孔溢洪道全开

## 3 结果与分析

### 3.1 深度学习模型及集合模型预报效果分析

根据式(1)计算不同参数配置的综合评价价值,按综合评价价值最高选取各个模型的最优参数配置,根据式(2)计算得GRU、LSTM、Transformer的权重分别为0.339、0.339、0.322。表3展示了不同模型训练集、验证集和测试集的指标性能,以及不同模型测试集洪水场次的指标性能,图3展示了不同模型训练、验证及测试

表 3 模型效果对比  
Table 3 Model performance comparison

预报模型	训练集			验证集			测试集		
	$E_{RMS}/(m^3/s)$	$E_{MA}/(m^3/s)$	$E_{NS}$	$E_{RMS}/(m^3/s)$	$E_{MA}/(m^3/s)$	$E_{NS}$	$E_{RMS}/(m^3/s)$	$E_{MA}/(m^3/s)$	$E_{NS}$
GRU	21.4	17.2	0.993	57.5	28.2	0.968	111	61.6	0.881
LSTM	20.9	14.0	0.993	60.7	27.9	0.965	107	56.9	0.890
Transformer	32.8	23.9	0.983	113	63.8	0.877	105	53.3	0.894
EMs	16.1	11.6	0.996	63.6	31.8	0.961	95.1	49.4	0.913

预报模型	20170624场次洪水预报			20190809场次洪水预报			20200803场次洪水预报		
	$E_{MA}/(m^3/s)$	$E_{PE}/h$	$E_{NS}$	$E_{MA}/(m^3/s)$	$E_{PE}/h$	$E_{NS}$	$E_{MA}/(m^3/s)$	$E_{PE}/h$	$E_{NS}$
GRU	28.9	+1	0.490	170	+2	0.794	110	+2	0.792
LSTM	17.5	+1	0.782	169	+1	0.809	107	0	0.797
Transformer	18.6	0	0.874	158	0	0.807	98.2	+1	0.811
EMs	13.3	0	0.853	148	+1	0.853	101	+2	0.829

的对比情况, 图4展示了不同模型测试集洪水场次的预报效果。

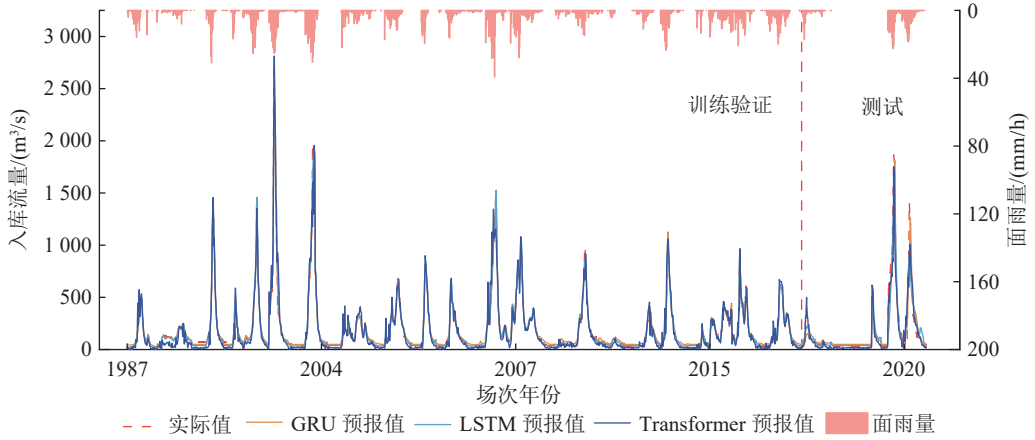


图3 不同深度学习模型效果对比

Fig. 3 Comparison among effects of different deep learning models

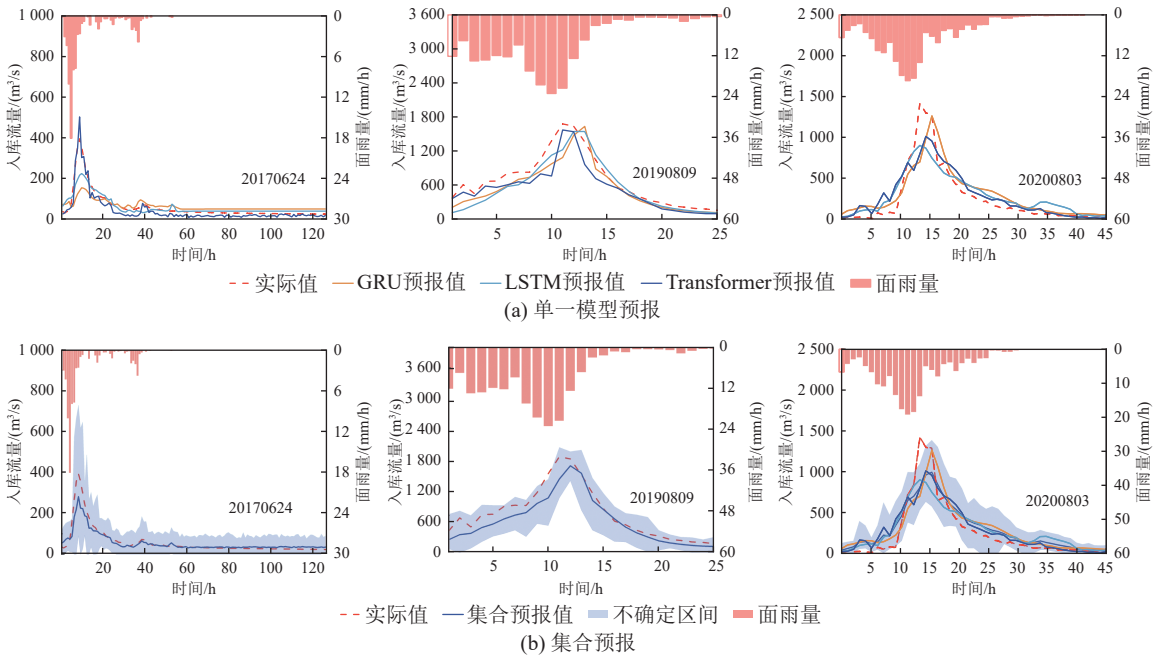


图4 集合预报模型测试集效果

Fig. 4 Performance of ensemble forecasting model on test set

由表3可知GRU模型、LSTM模型与Transformer模型训练集与测试集总体上表现相近, 说明3个深度学习模型总体表现均衡, 且 $E_{NS}$ 均大于0.88, 说明模型对数据关系挖掘彻底, 预报效果较好。基于3个深度学习模型构建集合预报模型, 并计算不确定性区间。由表3可知集合预报模型测试集的指标效果均好于单一模型, 其中 $E_{NS}$ 达到0.91, 相较单一模型预报提高了4.6%。

现分析场次洪水预报效果, 20170624场次洪水中, Transformer模型对洪峰存在高估, 而LSTM模型与GRU模型则存在低估; 20190809场次洪水中, LSTM与GRU模型预报洪峰时间略有滞后, 但整体洪水过程与实际接近, Transformer模型预报洪峰时间准确, 但整体洪水过程线较实际存在低估; 20200803场次洪水

中, GRU 模型与 Transformer 模型预报洪峰均有滞后, 且 3 个模型均存在一定程度的低估。不同模型对同一洪水的预报表现出不同的偏差特性, 集合预报融合了单一模型的特性, 使其预报精度更佳。如表 3 所示, 集合预报模型指标效果基本上好于单一模型, 仅 20170624 的场次洪水略差于 Transformer 模型, 且集合预报模型对不同大小洪水的预报效果稳定,  $E_{NS}$  均大于 0.82, 说明集合预报相比单一模型预报有更好的准确性和稳定性。

由于训练数据中中小流量占比较大, 单一模型预报与集合预报均存在一定程度的洪峰低估, 可导致水库防洪调度风险增加, 集合不确定性预报可有效减轻该风险。如图 4 所示, 经分段随机模拟计算获得的集合预报不确定性区间基本覆盖实际洪水过程线, 为水库调度提供了入库流量不确定预报, 有利于减少预报误差导致的调度风险。

### 3.2 优化调度结果分析

以上述集合预报模型不确定预报结果为输入, 求解水库精细化防洪优化调度模型, 并根据该水库防洪调度规则中对于闸门的调度规定, 得到 2 个常规调度方案: RO-1, 水库平均最高水位最低的方案; RO-2, 控制断面平均洪峰流量最低的方案。优化模型经过 500 次迭代基本收敛, 选择了 4 个优化调度方案(OO-1 至 OO-4)与常规调度对比分析并汇总于表 4。

表 4 调度方案目标对比  
Table 4 Objectives comparison of operation solutions

调度方案	$F_1/m$	$F_2/(m^3/s)$	$F_3/\%$	$F_4/\%$
RO-1	179.81	1 416.46	0	4
RO-2	180.95	1 205.72	100	0
OO-1	179.38	1 440.01	0	19
OO-2	179.58	1 389.89	0	0
OO-3	180.31	1 198.92	0	0
OO-4	180.65	1 172.80	44	0

图 5 展示了常规调度与优化调度的目标分布情况, 由图 5 可知, 优化调度结果完全支配常规调度结果, 优化调度所得方案中水库平均最高坝前水位最低可达到 179.38 m, 而常规调度为 179.81 m, 削减水位 0.43 m; 平均前山断面洪峰流量最低为 1 170  $m^3/s$ , 而常规调度为 1 210  $m^3/s$ , 削减洪峰 32.9  $m^3/s$ , 说明在降低水库水位与削减下游洪峰方面, 优化调度具有明显优势。此外如图 5 所示, 优化调度能产生无风险方案且完全支配常规调度解, 而常规调度产生的方案均有风险, 因此在风险控制方面优化调度也具有明显优势。

图 6 进一步对比了 RO-1 与 OO-2 及 RO-2 与 OO-3 的方案效果, 从图 5 所示的这 4 个方案的目标分布可知, RO-1 与 OO-2 是侧重保护水库的方案, 而 RO-2 与 OO-3 是侧重保护控制断面的方案。从图 6 可知, 2 类方案在风险控制、水库保护和控制断面保护方面, 优化调度方案均优于常规调度, 具体表现为其优化调度方案的目标值均小于常规调度方案。此外, 优化调度方案的调度效果受入库流量不确定性的影响更小, 方案实施的稳定性更好, 具体表现为图 6 中优化调度方案的箱体范围小于常规调度, 箱体的范围越大说明调度方案的效果变化范围越大, 则效果的不确定性更大, 甚至会出现超过安全值的情况, 箱体越小则说明方案

效果的不确定性越小。如图5中RO-1方案, 其最高坝前水位的均值为179.81 m, 但最大值接近安全水位180.69 m; 前山洪峰流量的均值为1420 m<sup>3</sup>/s, 但最大值超过安全流量1480 m<sup>3</sup>/s。

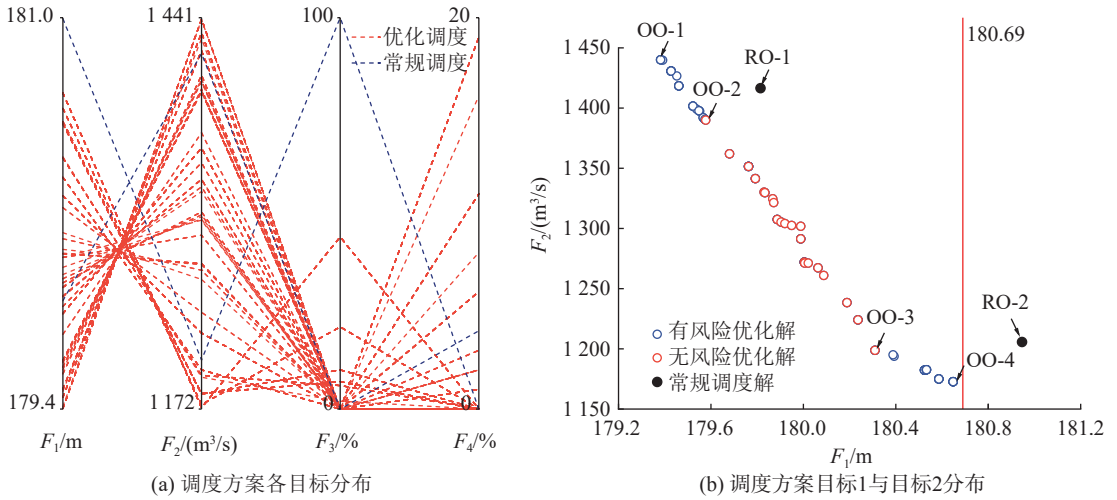


图5 调度方案解集

Fig. 5 Set of operation solutions

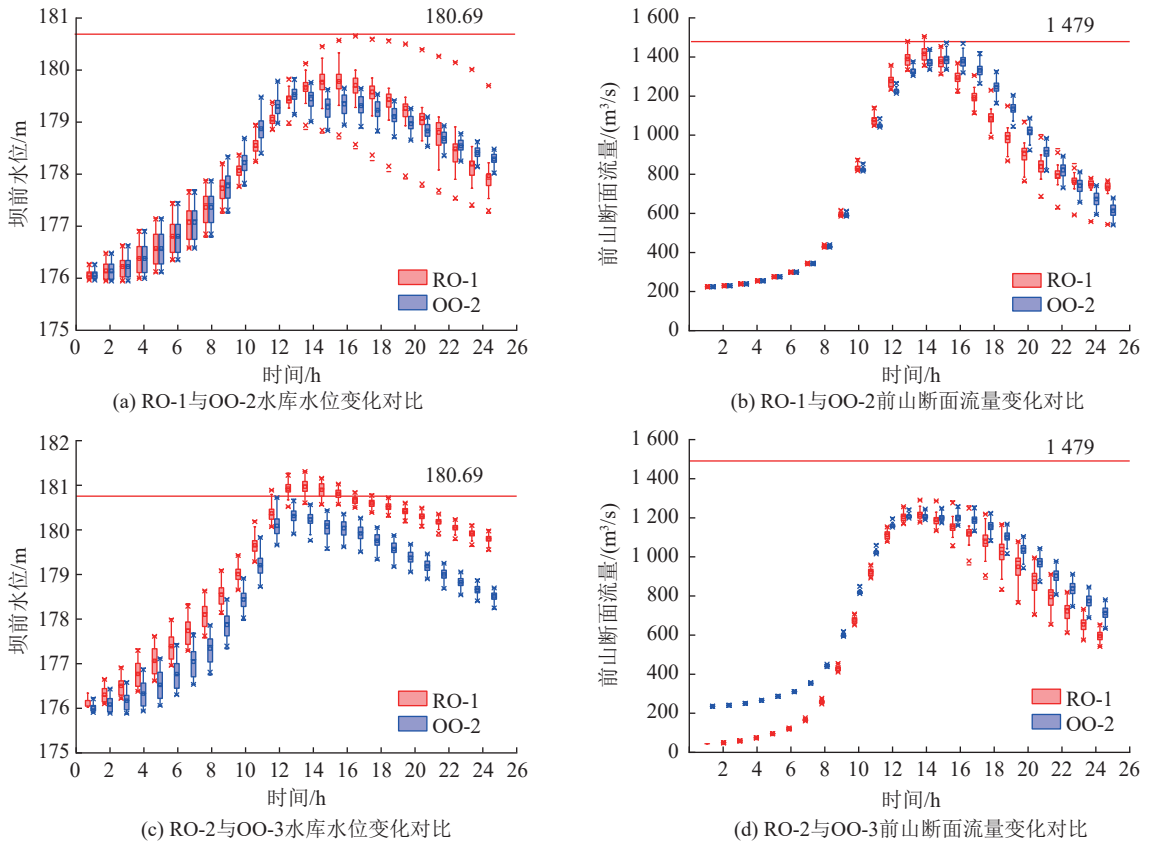


图6 调度方案效果对比

Fig. 6 Effect comparison of operation solutions

### 3.3 优化调度方案可执行性分析

优化调度除了方案效果与效果稳定性优于常规调度,其方案可执行性也好于常规调度。如图7所示,优化调度方案的执行受入库流量不确定性的影响较小,优化调度方案闸门状态的变化过程在不同入库流量下的差异较小,闸门调整较少,方案的可执行性更佳;而常规调度的差异较大,尤其是调度的中后期。这是因为常规调度是根据不同水库坝前水位高度而采用不同的泄放方式,坝前水位的波动会让水库在不同的泄放方式间频繁切换,不同的入库流量导致不同的水库坝前水位变化过程,使常规调度方案受到预报流量的不确定性影响更大,导致方案可执行性不佳。而优化调度仅需在原泄放方式超出实际约束时进行调整,因此不同入库流量的水库泄放过程差异较小,调度方案执行的稳定性高,鲁棒性更强。

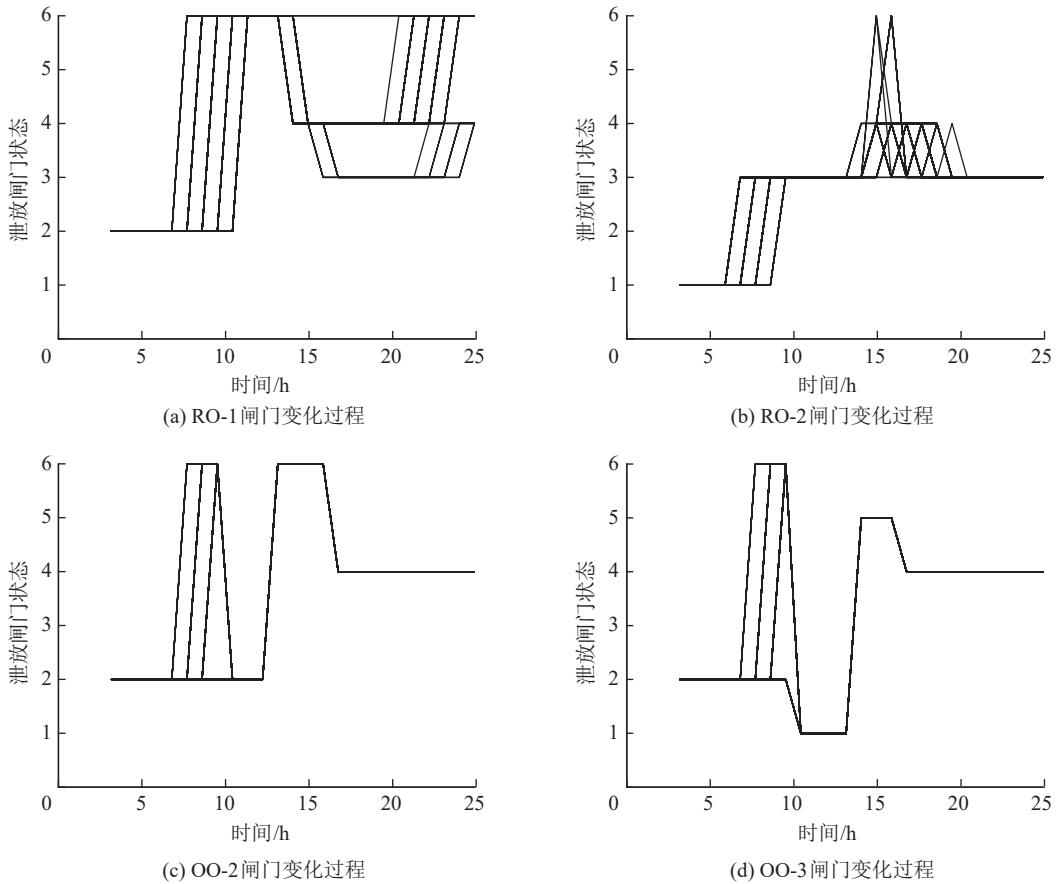


图7 调度方案闸门状态变化过程

Fig. 7 Change process of gate status

## 4 结 论

本文构建了基于多种深度学习算法的洪水集合预报模型和考虑闸门实际运行及调度方案可执行性的水库精细化防洪优化调度模型,以集合预报模型产生的不确定性预报作为调度模型的输入,采用NSGA-III算法求解模型,并与常规调度结果进行比较,验证了优化模型的优势。主要结论如下:

(1)本研究构建的各深度学习洪水预报模型均有良好的预报性能,适合小时尺度洪水预报,但受限于训

练数据的质量与数量和模型的性能,单一的深度学习洪水预报模型也存在局限性,如洪峰低估、峰现时间偏差等,可在未来进一步探究改进。

(2)本研究构建的集合预报模型纳什效率系数较单一模型提高了4.6%,预报不确定性区间基本覆盖实际洪水过程线。

(3)本研究构建的精细化防洪优化调度模型以泄放闸门状态和状态持续时长为决策变量,符合实际调度的操作场景,调度效果受入库流量预报不确定性影响小,相较于常规调度,削减水库水位0.43m,削减控制断面洪峰 $32.9\text{ m}^3/\text{s}$ ,显著降低水库防洪风险与控制断面防洪风险,可为水库防洪调度提供决策支持。

## 参考文献:

- [1] 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 Z X, CHEN H, REN M F, 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))
- [2] 周研来,郭生练,王俊,等.金沙江下游梯级水库汛期运行水位协同浮动调度研究[J].水利学报,2023,54(6):633-643.(ZHOU Y L, GUO S L, WANG J, et al. Study on synergetic control of flood operating water levels of cascade reservoirs in the downstream reach of the Jinsha River basin[J]. Journal of Hydraulic Engineering, 2023, 54(6): 633-643. (in Chinese))
- [3] YU X T, XU Y P, GU H T, et al. Multi-objective robust optimization of reservoir operation for real-time flood control under forecasting uncertainty[J]. *Journal of Hydrology*, 2023, 620: 129421.
- [4] DEVI D, KUMAR SARMA A. Optimal advanced release scheme based on effective forecast horizon to minimize flood at downstream of a hydroelectric project[J]. *Journal of Hydrology*, 2024, 631: 130822.
- [5] 赵泽谦,黄强,明波,等.基于多模型随机组合的水文集合预报方法研究[J].水力发电学报,2021,40(1):76-87.(ZHAO Z Q, HUANG Q, MING B, et al. Hydrological ensemble forecasting method based on stochastic combination of multiple models[J]. *Journal of Hydroelectric Engineering*, 2021, 40(1): 76-87. (in Chinese))
- [6] MADDU R, PRADHAN I, AHMADISHARAF E, et al. Short-range reservoir inflow forecasting using hydrological and large-scale atmospheric circulation information[J]. *Journal of Hydrology*, 2022, 612: 128153.
- [7] CASTANGIA M, GRAJALES L M M, ALIBERTI A, et al. Transformer neural networks for interpretable flood forecasting[J]. *Environmental Modelling & Software*, 2023, 160: 105581.
- [8] 李建柱,李磊菁,冯平,等.基于深度学习的雷达降雨临近预报及洪水预报[J].水科学进展,2023,34(5):673-684.(LI J Z, LI L J, FENG P, et al. Radar rainfall nowcasting and flood forecasting based on deep learning[J]. Advances in Water Science, 2023, 34(5): 673-684. (in Chinese))
- [9] 刘成帅,孙悦,胡彩虹,等.考虑产流模式空间分布的流域-城市复合系统洪水预报模型[J].水科学进展,2023,34(4):530-540.(LIU C S, SUN Y, HU C H, et al. Study on flood forecasting model of watershed-urban complex system considering the spatial distribution of runoff generation pattern[J]. Advances in Water Science, 2023, 34(4): 530-540. (in Chinese))
- [10] 刘成帅,解添宁,李文忠,等.考虑径流过程矢量化的机器学习洪水预报模型[J].水科学进展,2024,35(3):420-429.(LIU C S, XIE T N, LI W Z, et al. Machine learning-based flood forecasting models considering runoff process vectorization[J]. Advances in Water Science, 2024, 35(3): 420-429. (in Chinese))
- [11] 邹强,王学敏,李安强,等.基于并行混沌量子粒子群算法的梯级水库群防洪优化调度研究[J].水利学报,2016,47(8):967-976.(ZOU Q, WANG X M, LI A Q, et al. Optimal operation of flood control for cascade reservoirs based on parallel chaotic quantum particle swarm optimization[J]. Journal of Hydraulic Engineering, 2016, 47(8): 967-976. (in Chinese))
- [12] 唐金杰.基于离散粒子群算法的水库防洪调度优化研究[J].水利技术监督,2022,30(9):190-194.(TANG J J. Optimization of reservoir flood control operation based on discrete particle swarm optimization[J]. *Technical Supervision in Water Resources*, 2022, 30(9): 190-194. (in Chinese))
- [13] 黄显峰,吴志远,李昌平,等.基于改进粒子群-逐次逼近法的水库调度图多目标优化[J].水利水电科技进展,2021,41(2):1-7.(HUANG X F, WU Z Y, LI C P, et al. Multi-objective optimization of reservoir operation chart based on IPSO-DPSA[J]. Advances in Science and Technology of Water Resources, 2021, 41(2): 1-7. (in Chinese))
- [14] 陈立华,梅亚东,董雅洁,等.改进遗传算法及其在水库群优化调度中的应用[J].水利学报,2008,39(5):550-556.(CHEN L H, MEI Y D, DONG Y J, et al. Improved genetic algorithm and its application in optimal dispatch of cascade reservoirs[J]. *Journal of*

- [Hydraulic Engineering](#), 2008, 39(5): 550-556. (in Chinese))
- [15] 肖刚, 解建仓, 罗军刚. 基于改进 NSGA II 的水库多目标防洪调度算法研究 [J]. 水力发电学报, 2012, 31(5): 77-83. (XIAO G, XIE J C, LUO J G. Improved NSGA II algorithm for flood dispatching of multi-objectives reservoir[J]. [Journal of Hydroelectric Engineering](#), 2012, 31(5): 77-83. (in Chinese))
- [16] 黄显峰, 王宁, 刘志佳, 等. 基于改进 NSGA-II 算法的梯级水库多目标优化调度 [J]. 水利水电科技进展, 2024, 44(4): 51-58. (HUANG X F, WANG N, LIU Z J, et al. Multi-objective optimal operation of cascade reservoirs based on improved NSGA-II algorithm[J]. [Advances in Science and Technology of Water Resources](#), 2024, 44(4): 51-58. (in Chinese))
- [17] CHEN J, ZHONG P G, LIU W F, et al. A multi-objective risk management model for real-time flood control optimal operation of a parallel reservoir system[J]. [Journal of Hydrology](#), 2020, 590: 125264.
- [18] HUANG X, XU B, ZHONG P G, et al. Robust multiobjective reservoir operation and risk decision-making model for real-time flood control coping with forecast uncertainty[J]. [Journal of Hydrology](#), 2022, 605: 127334.
- [19] GUO Y X, XU Y P, YU X T, et al. AI-based ensemble flood forecasts and its implementation in multi-objective robust optimization operation for reservoir flood control[J]. [Water Resources Research](#), 2024, 60(5): e2023WR035693.
- [20] ZHANG J W, LI Z J, WANG X, et al. A novel method for deriving reservoir operating rules based on flood classification-aggregation-decomposition[J]. [Journal of Hydrology](#), 2019, 568: 722-734.
- [21] PAN Z H, CHEN L H, TENG X. Research on joint flood control operation rule of parallel reservoir group based on aggregation-decomposition method[J]. [Journal of Hydrology](#), 2020, 590: 125479.
- [22] ZHU D, CHEN H, ZHOU Y L, et al. Exploring a multi-objective cluster-decomposition framework for optimizing flood control operation rules of cascade reservoirs in a river basin[J]. [Journal of Hydrology](#), 2022, 614: 128602.
- [23] 朱迪, 周研来, 陈华, 等. 考虑分级防洪目标的梯级水库汛控水位调度模型及应用 [J]. 水利学报, 2023, 54(4): 414-425. (ZHU D, ZHOU Y L, CHEN H, et al. An operation model of flood control water levels of cascade reservoirs considering grading flood control objectives and its application[J]. [Journal of Hydraulic Engineering](#), 2023, 54(4): 414-425. (in Chinese))
- [24] 陈森林, 张亚文, 李丹. 水库防洪优化调度的恒定出流模型及应用 [J]. 水科学进展, 2021, 32(5): 683-693. (CHEN S L, ZHANG Y W, LI D. Study on constant outflow model for reservoir flood control operation and its application[J]. [Advances in Water Science](#), 2021, 32(5): 683-693. (in Chinese))
- [25] 王靖, 鄢尚, 陈仕军, 等. 考虑闸门实际运行的雅砻江下游梯级水库联合防洪优化调度 [J]. 四川大学学报(工程科学版), 2014, 46(4): 20-25. (WANG J, YAN S, CHEN S J, et al. Flood control optimal operation on cascade reservoirs of downstream yalong river considering actual running of floodgate[J]. [Journal of Sichuan University \(Engineering Science Edition\)](#), 2014, 46(4): 20-25. (in Chinese))
- [26] KIM Y G, SUN B Q, KIM P, et al. A study on optimal operation of gate-controlled reservoir system for flood control based on PSO algorithm combined with rearrangement method of partial solution groups[J]. [Journal of Hydrology](#), 2021, 593: 125783.
- [27] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. [Neural Computation](#), 1997, 9(8): 1735-1780.
- [28] 郭玉雪, 许月萍, 陈浩, 等. 基于多种递归神经网络的海岛水库径流预报 [J]. 水力发电学报, 2021, 40(9): 14-26. (GUO Y X, XU Y P, CHEN H, et al. Reservoir inflow forecasting for island areas based on multiple recurrent neural networks[J]. [Journal of Hydroelectric Engineering](#), 2021, 40(9): 14-26. (in Chinese))
- [29] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. [Neural Information Processing Systems](#), 2017, 5998:6008.
- [30] 董磊华, 熊立华, 万民. 基于贝叶斯模型加权平均方法的水文模型不确定性分析 [J]. 水利学报, 2011, 42(9): 1065-1074. (DONG L H, XIONG L H, WAN M. Uncertainty analysis of hydrological modeling using the Bayesian Model Averaging Method[J]. [Journal of Hydraulic Engineering](#), 2011, 42(9): 1065-1074. (in Chinese))
- [31] DEB K. An efficient constraint handling method for genetic algorithms[J]. [Computer methods in applied mechanics and engineering](#), 2000, 186(2/3/4): 311-338.

# Optimization of gate operation for reservoir flood control based on deep learning ensemble forecasting\*

XU Yueping , LU Haonan , YU Xinting , GUO Yuxue

(*College of Civil Engineering and Architecture, Zhejiang University, Hangzhou 310058, China*)

**Abstract:** Research is needed for improving reservoir flood forecasting and operation to reduce flood-induced losses. Current reservoir flood control practices lack consideration of actual gate operations and dispatch scheme feasibility. This study proposes a refined flood operation optimization model, which takes into account inflow forecast uncertainties by utilizing ensemble forecasts derived from a combination of Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU) and Transformer deep learning models. Gate discharge states and their durations are taken as decision variables. A case study was conducted in the Jiaojiang River basin, Zhejiang Province. Results indicate that the ensemble forecasts are improved by 4.6% in accuracy compared to single model forecasts, and the forecast uncertainty is reliable for reservoir operation. The refined flood operation optimization model shows significant advantages over conventional methods, reducing the average maximum water level at the dam by 0.43 m and the average flood peak flow at downstream control section by 32.9 m<sup>3</sup>/s. The effectiveness of the optimized solution is less affected by inflow uncertainties. Overall, the proposed refined model is demonstrated to have the potential to provide valuable information to support reservoir flood control decision-making.

**Key words:** reservoir gates; ensemble forecasting model; deep learning; flood control operation; multi-objective optimization; uncertainty

---

\* The study is financially supported by the National Key R&D Program of China (No. 2021YFD1700802) and the Key R&D Program of Zhejiang Province, China (No. 2021C03017).