

陈鹿尧, 闻昕, 谭乔凤, 等. 基于 DQN 的梯级水电站实时负荷优化分配研究[J]. 水利水电技术(中英文), 2025, 56(7): 26-40. DOI: 10.13928/j.cnki.wrahe.2025.07.003

CHEN Luyao, WEN Xin, TAN Qiaofeng, et al. DQN-based real-time optimized load distribution of cascade hydropower stations[J]. Water Resources and Hydropower Engineering, 2025, 56(7): 26-40. DOI: 10.13928/j.cnki.wrahe.2025.07.003

# 基于 DQN 的梯级水电站实时负荷优化分配研究

陈鹿尧<sup>1</sup>, 闻昕<sup>1</sup>, 谭乔凤<sup>1</sup>, 曾宇轩<sup>1,2</sup>, 田宗勇<sup>1,3</sup>

(1. 河海大学 水利水电学院, 江苏 南京 210098; 2. 雅砻江流域水电开发有限公司, 四川 成都 610051; 3. 贵州水投能源开发有限责任公司, 贵州 贵阳 550014)

**摘要:**【目的】流域梯级水电系统规模持续扩大与运行环境日趋复杂, 传统优化调度方法难以适应流域复杂多样的调控要求, 且其决策精度与求解效率均有限。【方法】以耗水量最小为主要目标, 构建了兼顾电调-水调的梯级水电优化调度模型, 并研发了基于深度强化学习(DQN)的高效求解方法。以大渡河中游梯级水电系统为研究实例, 分别设置中等负荷, 低负荷和高负荷三种工况, 输入实际运行数据对模型进行训练, 并结合耗水量、水位过程等角度对模型优化效果进行评估。【结果】结果显示: DQN 算法可显著减少计算耗时, 将计算效率提升约 41.37 倍; 同时, DQN 算法可以很好地平衡水位和流量等水调需求之间的冲突, 相较于优化前, DQN 可在将水位波动指数平均降低约 0.058 m/min 的同时将平均总耗水量减少 1 158 万 m<sup>3</sup>; 除此之外, 提出的模型适用于多种工况, 具有良好的稳定性。【结论】结果表明: 基于 DQN 的负荷分配方法可有效增强系统运行稳定性与安全性, 实现调度科学性与计算效率的双重突破; 智能决策框架通过实时优化电站出力分配, 显著降低水位波动与发电耗水, 验证了电调-水调协同优化的可行性。该方法为梯级水电系统智能化调度与新时期复杂场景下的优化调控提供了新的技术路径。

**关键词:** 负荷分配; 梯级水电; 深度强化学习; 实时调度; 动态规划; 影响因素

DOI: 10.13928/j.cnki.wrahe.2025.07.003

开放科学(资源服务)标志码(OSID):

中图分类号: TV213.9

文献标志码: A

文章编号: 1000-0860(2025)07-0026-15



## DQN-based real-time optimized load distribution of cascade hydropower stations

CHEN Luyao<sup>1</sup>, WEN Xin<sup>1</sup>, TAN Qiaofeng<sup>1</sup>, ZENG Yuxuan<sup>1,2</sup>, TIAN Zongyong<sup>1,3</sup>

(1. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, Jiangsu, China;

2. Yalong River Hydropower Development Co., Ltd., Chengdu 610051, Sichuan, China; 3. Guizhou Water

Resources Investment Energy Development Co., Ltd., Guiyang 550014, Guizhou, China)

**Abstract:** [Objective] With the continuous expansion of cascade hydropower systems and increasingly complex operational environments, traditional optimized scheduling method struggle to meet the complex and diverse regulation requirements of river basins, while their decision-making accuracy and computational efficiency remain limited. [Methods] To address these

收稿日期: 2025-03-12; 修回日期: 2025-05-17; 录用日期: 2025-05-19; 网络出版日期: 2025-05-21

基金项目: 国家自然科学基金项目(52479013)

作者简介: 陈鹿尧(2000—), 女, 硕士研究生, 主要从事水利水电工程调度研究。E-mail: chenluyao0814@163.com

通信作者: 闻昕(1987—), 男, 教授, 河海大学研究生院副院长, 博士, 主要从事水利水电工程调度研究。E-mail: njwenxin@163.com

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

limitations, an optimized scheduling model was established for cascade hydropower systems that considered power generation scheduling and water resource regulation, with minimum water consumption as the primary objective. Additionally, an efficient solution method based on deep reinforcement learning (Deep Q-Network, DQN) was developed. Using the cascade hydropower system in the middle reaches of the Dadu River as a case study, three operating conditions (medium, low, and high load) were established. The model was trained using actual operational data and evaluated through water consumption and water level processes. [Results] The result showed that the DQN algorithm reduced computational time by approximately 41.37 times compared to conventional method. Furthermore, DQN effectively balanced conflicting water regulation demands (e.g., water level stability and flow control), achieving an average reduction of 0.058 m/min in the water level fluctuation index and a total water consumption decrease of 11.58 million  $\text{m}^3$  compared to pre-optimization. Notably, the proposed model exhibited good stability across diverse operating conditions. [Conclusion] The findings indicate that the DQN-based load distribution method enhances system operational stability and safety while achieving breakthroughs in both scientific scheduling and computational efficiency. By dynamically optimizing real-time power output distribution among stations, the intelligent decision-making framework significantly mitigates water level fluctuations and reduces water consumption in power generation, thereby validating the feasibility of coordinated power-water optimization. This method provides a novel technical approach for intelligent scheduling of cascade hydropower systems and their optimized regulation under complex operational scenarios in the new era.

**Keywords:** load distribution; cascade hydropower; deep reinforcement learning; real-time scheduling; dynamic programming; influencing factors

## 0 引言

水电是技术成熟、运行灵活的清洁低碳可再生能源。经过几十年高速发展,我国水电总装机规模已达 42 154 万 kW,形成澜沧江、金沙江、黄河等十四大水电基地<sup>[1]</sup>。如何调度运行如此复杂的水电系统,对充分发挥工程效益、实现水资源高效利用、推动能源结构转型具有重要意义<sup>[2-4]</sup>。站间实时负荷分配需在满足电网需求、库容约束、出力限制等条件下,依据水文条件与电站运行状态,通过优化各电站出力,以提升系统发电效益与水能利用效率<sup>[5]</sup>。该问题具备高维度、非线性、多约束、多阶段等特征<sup>[6-8]</sup>,决策科学性与求解效率是关键难点<sup>[9]</sup>。

传统方法的负荷分配方法包括线性规划(LP)、动态规划(DP)及启发式算法等<sup>[10-12]</sup>。其中,LP适用于防洪调度等线性目标优化,其寻优过程无需初始决策,但最终能够收敛至全局最优解,具有理论成熟、求解迅速的优势,但模型线性化易导致精度损失<sup>[13]</sup>;DP是最常用于求解负荷分配问题的方法,其通过将复杂问题划分为若干阶段并逐段求解的方式获得全局最优解,具有动态适应性强的特点,但随电站数量增加面临维度灾难<sup>[14]</sup>;启发式算法基于经验规则获取近似解,虽具有全局优化性能、稳健性强、通用性强且适于并行计算等优点,但存在规则依赖性强、局部最优陷阱等问题<sup>[15-17]</sup>。

随着“双碳”目标的落地实施,新能源高比例并网带来的随机性与波动性显著加剧电网运行风

险<sup>[18]</sup>,梯级水电作为电网主要灵活性调节电源,其调度运行面临诸多新的挑战<sup>[19]</sup>:一方面,传统以发电量最大为核心的调度模型难以适应精细化水位控制与复杂水力-电力耦合需求<sup>[20]</sup>,且中小型电站受调节库容限制,易出现水位流量变化剧烈等问题,严重影响水库运行的安全性与稳定性;另一方面,新能源并网引发的短时功率波动要求梯级水电具备更强的调峰调频响应能力,而传统算法在求解速度与计算精度上存在显著局限性,亟需发掘新的算法以适应新形势下梯级水电实时运行决策需求。因此,如何合理地分配梯级水电系统中各电站承担的负荷,使梯级水电系统同时满足发电调度需求和水量调度需求,并实现求解效率与决策精度的协同优化,是当前清洁能源转型背景下水电系统优化调度的核心难题。

计算机技术的高速发展,特别是强化学习(Reinforcement Learning, RL)算法凭借其环境适应性强、决策速度快等优势,在水库调度领域展现了良好的应用潜力<sup>[21]</sup>。例如,运用 Q-Learning 算法解决梯级水电优化调度问题<sup>[22]</sup>;采用 SARSA 算法进行多能互补系统联合调度决策优化问题<sup>[23]</sup>等。然而,早期强化学习算法因探索与利用平衡难、奖励稀疏、状态空间高维、环境非静态、策略评估复杂、局部最优、泛化能力差等问题,存在训练效率低、学习效果不稳定等不足<sup>[24-25]</sup>。DQN(Deep Q-Network)是一种结合深度学习和 Q-Learning 的深度强化学习算法,其通过智能体与梯级水电系统动态环境的持续交互,模拟实际的多阶段决策过程,且通过合理的环境状态及奖励函

数设置,能够有效融合水力-电力耦合约束、调峰调频需求、生态流量限制等多维复杂因素对策略生成的影响<sup>[26]</sup>。该算法采用深度神经网络代替表格形式逼近动作-价值函数,同时引入经验回放机制,显著提高了模型的学习效率<sup>[27]</sup>。除此之外, DQN 算法具有自适应能力,能够有效调整策略以适应不同负荷需求与约束<sup>[28-29]</sup>。因此,基于 DQN 的智能决策模型为新型电力系统下梯级水电站间负荷分配的实时优化提供了理论创新与技术突破,对推动清洁能源高效利用具有重要实践价值。

为此,本文提出基于 DQN 算法的梯级水电站间负荷分配模型,以适应新形势下复杂的水力-电力耦合需求和更精细的水位流量约束,提升梯级水电站的整体运行效率和经济效益。首先,针对梯级水电站运行的经济性和安全性要求,建立兼顾电调-水调需求的站间负荷分配模型。其次,采用强化学习中的 DQN 算法进行求解,以保证梯级水电负荷实时分配的高效性。并以大渡河流域“瀑-深-枕”梯级水电系统为研究实例,验证方法的有效性,为梯级水电的安全稳定运行提供了参考。

## 1 研究区域概况

大渡河是岷江的最大支流,发源于青海省境内的果洛山南麓,是我国第五大水电基地<sup>[30-31]</sup>。瀑布沟、深溪沟和枕头坝水电站位于大渡河流域的中下游,形成以发电为主,兼顾防洪、生态等综合效益的梯级水电系统<sup>[32]</sup>。其中,瀑布沟水电站装机容量 3 600 MW,具备不完全年调节能力,需根据年内径流规律进行年调节。同时,为提高发电效益,年末应尽量维持在较高水位运行。深溪沟和枕头坝一级电站的装机容量分别为 660 MW 和 720 MW,均为瀑布沟电站的反调节电站,水库库容较小,基本不具备调节能力,在配合瀑布沟电站完成电网负荷要求的前提下,应尽量保持与瀑布沟电站同步运行并优化梯级水位过程。此外,各电站均需满足生态下泄要求。

随着大规模风光并网,来自电力和水力的两方要求加剧了大渡河中下游梯级水电的调度复杂性,造成日调节电站水位波动失稳等问题<sup>[33]</sup>。据 2016—2019 年实际运行数据,深溪沟和枕头坝电站的水位波动指数最高可达 0.27 m/min 和 0.14 m/min,快速水位波动不仅降低水能利用效率,更可能引发机组启闭频繁、振动加剧等安全隐患,直接影响梯级系统的经济运行与设备寿命周期。

表 1 “瀑-深-枕”梯级各电站参数

Table 1 Parameters of “Pu-Shen-Zhen” cascade hydropower stations

参数名称	瀑布沟	深溪沟	枕头坝一级
调节性能	不完全年调节	日调节	日调节
正常蓄水位/m	850	660	624
死水位/m	790	655	618
调节库容/10 <sup>8</sup> m <sup>3</sup>	38.26	0.085	0.123
装机容量/MW	3 600	660	720
最大发电流量/m <sup>3</sup> ·s <sup>-1</sup>	2 679	1 808	2 428
生态流量/m <sup>3</sup> ·s <sup>-1</sup>	327	327	327

水库水位过程及耗水量主要受水库入库流量、电站负荷及闸门调度策略影响。其中,闸门调控行为主要集中于汛期,该时段电站通常处于满负荷发电工况或泄洪弃水模式,不存在站间负荷分配的问题。而枯期径流量普遍较低,且电站多处于非满发工况,存在良好的站间负荷分配优化潜力。故而在枯期设置中等负荷、低负荷和高负荷三种工况,以验证模型稳定性。为此,本文收集“瀑-深-枕”梯级水电 2016—2019 年的 5 min 尺度运行数据,分析表明,在刚进入枯期的 11 月负荷普遍较高,出力均值高达 2 180.57 MW,即将进入汛期的 4 月负荷普遍较低,出力均值低至 1 090.66 MW(见图 1 和表 2)。因此,分别选取 2019 年 1 月 29 日至 31 日、2019 年 4 月 5 日至 7 日和 2019 年 11 月 2 日至 4 日作为中等负荷、低负荷和高负荷工况的代表时段,研究“瀑-深-枕”梯级水电的实时站间负荷分配。实际运行数据包含入库流量信息、实际运行水位信息、负荷指令信息等,训练后的模型用于指导梯级水电 5 min 尺度站间负荷分配。




图 1 “瀑-深-枕”梯级水电系统枯期负荷分布

Fig. 1 Load distribution of “Pu-Shen-Zhen” cascade hydropower system during dry season

表 2 “瀑-深-枕”梯级水电系统枯期负荷分布  
Table 2 Load distribution of “Pu-Shen-Zhen” cascade hydropower system during dry season

月 份	均值/MW	最大值/MW	最小值/MW
11 月	2 180.57	4 337.46	232.85
12 月	1 851.60	4 085.85	229.82
1 月	1 571.82	4 017.51	242.26
2 月	1 371.01	3 725.12	235.68
3 月	1 587.34	3 447.65	137.58
4 月	1 090.66	3 187.62	178.08

## 2 基于 DQN 算法的实时站间负荷分配模型

电站的水位过程主要与电站承担的总负荷及入库流量有关,而站内各机组不同的出力组合方式并不会显著影响电站水位和耗水量。故而本文聚焦电站层级,主要研究如何在满足电网负荷指令的同时,提高梯级水电系统的水能利用效率,并减少水位波动情况,实现求解效率与准确性的协同优化,从而保障梯级水电的安全稳定运行。

基于 DQN 算法的实时站间负荷优化分配模型主要由两部分构成:一是兼顾梯级水电经济性与安全性要求的目标函数及约束条件集合,二是包含环境和智能体的 DQN 智能算法框架。将数学模型中的目标函数和约束条件嵌入强化学习框架的环境模型中,不仅能够解决传统负荷分配无法满足精细水位控制需求的问题,还能提升模型求解效率,从而满足梯级水电实时站间负荷分配的高效性要求。

### 2.1 梯级水电概化模型

流域梯级水电站是由河道连接而成的整体,上下游之间存在密切的水力联系,下级水库的入库流量由上级水库的下泄流量和两级水库之间的区间径流汇集而成<sup>[34]</sup>。由此,梯级水电可概化为图 2 所示的数学模型。

图 2 中,  $Q_{A,t}$  为水库 A 在第  $t$  时段的入库径流;  $q_{A,t}$  和  $q_{B,t}$  分别为水库 A 和水库 B 在第  $t$  时段的下泄流量;  $L_{AB,t}$  为第  $t$  时段水库 A 和 B 之间的区间径流;  $L_{BC,t}$  为第  $t$  时段下游水库 B 和 C 之间的区间径流。其




图 2 梯级系统概化

Fig. 2 Generalized model of cascade hydropower system

中,  $q_{A,t}$  和  $L_{AB,t}$  共同构成第  $t$  时段水库 B 的入库流量;  $q_{B,t}$  和  $L_{BC,t}$  共同构成第  $t$  时段水库 C 的入库流量。

### 2.2 负荷分配模型

梯级水电系统调度涵盖电力调度和水量调度:电力调度是指在满足水电站基本运行约束的前提下,实时响应并执行电网负荷指令;水量调度则面向梯级水库群的水位和流量等控制需求,通过调整各电站下泄流量,确保梯级水电系统安全稳定运行并提升水资源综合利用效益。因此,兼顾电调-水调需求的调度决策过程可以视为梯级水电在响应电网负荷指令的前提下“以电定水”的负荷分配过程<sup>[35]</sup>。针对枯期梯级水电系统响应电网负荷指令的电调需求及“节水增发”、生态基流保障、水位平稳控制等多维度水调需求<sup>[36]</sup>,本文以耗水量最小为主要目标,设置水位波动、生态基流、电站出力限制等约束条件,构建了兼顾电调-水调目标的梯级水电站间负荷分配模型。具体目标函数为

$$f = \min \sum_i \sum_t q_{i,t}^e \times \Delta t \quad (1)$$

式中,  $f$  为梯级水电站间负荷分配模型的目标函数;  $T$  为总调度时段数;  $q_{i,t}^e$  为  $i$  电站在第  $t$  时段的平均发电流量 ( $\text{m}^3/\text{s}$ );  $\Delta t$  为计算时段长度 ( $\text{s}$ )。

梯级水电站间负荷分配模型需要满足以下约束条件。

#### (1) 水量平衡约束

$$V_{i,t+1} = V_{i,t} + (Q_{i,t} - q_{i,t}) \Delta t \quad (2)$$

式中,  $V_{i,t+1}$  为  $i$  水库在第  $t+1$  时段的时段初库容 ( $\text{m}^3$ );  $V_{i,t}$  为  $i$  水库在第  $t$  时段的时段初库容 ( $\text{m}^3$ );  $Q_{i,t}$  为  $i$  水库在第  $t$  时段的平均入库流量 ( $\text{m}^3/\text{s}$ );  $q_{i,t}$  为  $i$  水库在第  $t$  时段的平均出库流量 ( $\text{m}^3/\text{s}$ )。

#### (2) 出力平衡约束

$$N_{all,t}^{\text{target}} = \sum_{i=1}^I N_{i,t}^{\text{target}} \quad (3)$$

式中,  $N_{all,t}^{\text{target}}$  为第  $t$  时段电网下达给梯级电站群系统的总发电负荷指令 ( $\text{MW}$ );  $N_{i,t}^{\text{target}}$  为第  $t$  时段梯级分配给  $i$  电站的发电负荷 ( $\text{MW}$ );  $I$  为参与负荷分配梯级电站

的总个数。

### (3) 流量平衡约束

$$q_{i,t} = q_{i,t}^e + q_{i,t}^l \quad (4)$$

式中,  $q_{i,t}$  为  $i$  电站在第  $t$  时段的平均下泄流量 ( $\text{m}^3/\text{s}$ );  $q_{i,t}^e$  为  $i$  电站在第  $t$  时段的平均发电流量 ( $\text{m}^3/\text{s}$ );  $q_{i,t}^l$  为  $i$  电站在第  $t$  时段的平均弃水流量 ( $\text{m}^3/\text{s}$ )。

### (4) 发电流量约束

$$0 \leq q_{i,t}^e \leq q_{i,\max}^e \quad (5)$$

式中,  $q_{i,t}^e$  为  $i$  电站在第  $t$  时段的发电流量 ( $\text{m}^3/\text{s}$ );  $q_{i,\max}^e$  为  $i$  电站的最大发电流量 ( $\text{m}^3/\text{s}$ )。

### (5) 下泄流量约束

$$q_{i,\min} \leq q_{i,t} \leq q_{i,\max} \quad (6)$$

式中,  $q_{i,\min}$  为  $i$  水库的最小下泄流量 ( $\text{m}^3/\text{s}$ );  $q_{i,t}$  为  $i$  水库在第  $t$  时段的下泄流量 ( $\text{m}^3/\text{s}$ );  $q_{i,\max}$  为  $i$  水库的最大下泄流量 ( $\text{m}^3/\text{s}$ )。

### (6) 水位约束

$$Z_{i,\min}^{up} \leq Z_{i,t}^{up} \leq Z_{i,\max}^{up} \quad (7)$$

式中,  $Z_{i,\min}^{up}$  为  $i$  水库的死水位 ( $\text{m}$ );  $Z_{i,t}^{up}$  为  $i$  水库在第  $t$  时段的时段初水位 ( $\text{m}$ );  $Z_{i,\max}^{up}$  为  $i$  水库的最大允许水位, 在防洪限制期内为防洪限制水位, 其他时期为正常蓄水位 ( $\text{m}$ )。

### (7) 水位波动约束

$$|Z_{i,t}^{up} - Z_{i,t-1}^{up}| \leq \Delta Z_{i,\max}^{up} \quad (8)$$

式中,  $\Delta Z_{i,\max}^{up}$  为  $i$  电站允许的最大相邻时段水位差 ( $\text{m}$ )。鉴于年调节电站的调节库容较大, 对复杂环境的适应能力较强, 因此该约束的核心是控制梯级水电系统中调节能力较差的日调节电站的水位波动情况, 实现水位异常预警, 保障梯级水电整体的运行经济性与安全性。

### (8) 电站出力约束

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

式中,  $N_{i,\min}$  为  $i$  电站的最小出力限制 ( $\text{MW}$ );  $N_{i,t}$  为  $i$  电站在第  $t$  时段的出力 ( $\text{MW}$ );  $N_{i,\max}$  为  $i$  电站的最大出力限制, 通常为装机容量 ( $\text{MW}$ )。

### (9) 电站出力变幅约束

$$|N_{i,t}^{\text{target}} - N_{i,t}| \leq \Delta N_i \quad (10)$$

式中,  $\Delta N_i$  为  $i$  电站允许的最大出力变幅 ( $\text{MW}$ )。该约束条件用以防止电站的分配负荷相对于当前实发出力变化过大而不被电站接受, 由电站的系统特性决定。

## 2.3 深度强化学习模型

深度强化学习模型主要由智能体 (Agent) 和环境 (Environment) 两部分组成<sup>[37]</sup>。其中, 智能体负责学

习和决策, 而环境则提供可观察的状态信息及反馈 (如奖励)<sup>[38]</sup>。本文在强化学习框架下, 将梯级水电站间实时负荷分配问题建模为离散的马尔可夫决策过程 (MDP), 并以 5 min 为离散时间步长。在每个离散时段  $t$ , 智能体基于马尔可夫决策过程以离散的时间步与环境交互获取知识, 并以价值估值最大化为目标进行智能体训练即价值估值更新, 最终获取最优动作策略。DQN 算法有效体现了梯级水电站间负荷分配问题的非线性特征, 实现高效的自动化决策, 满足实时站间负荷分配问题的高效性要求。本文模型的具体设置如下。

(1) 状态  $s_t$ : 状态是智能体在特定时段对其所处环境的描述, 是智能体与环境交互后得到的观测值。在梯级水电负荷分配问题中, 状态转移过程涉及各电站的实际运行状态, 因此需要运用大量数据以全面表征环境状态。为综合考虑入库流量、负荷分配等多重因素对水位波动的影响, 仿真模拟水库的调度运行过程, 本文采用各水库上时段的  $N_{i,t-1}$ 、 $Z_{i,t-1}^{up}$ 、 $Q_{i,t-1}$ 、 $q_{i,t-1}$ , 本时段的  $N_{i,t}$ 、 $Z_{i,t}^{up}$ 、 $Q_{i,t}$ 、 $q_{i,t}$ , 下时段的  $Z_{i,t+1}^{up}$ 、 $Q_{i,t+1}$  构成一个多维向量作为  $t$  时段的状态变量  $s_t$ 。其中, 本时段的下泄流量  $q_{i,t}$  及下时段初的水位  $Z_{i,t+1}^{up}$  通过试算获得, 以表示智能体采取行动后造成的环境变化。

(2) 动作  $a_t$ : 动作表示智能体可以执行的行为, 用于与环境交互并影响环境的状态。在梯级水电负荷分配问题中, 若直接采用各电站承担的负荷值构建动作空间, 将导致动作空间过大, 影响神经网络拟合效果差和模型收敛性。对于梯级水电系统, 当下游电站的负荷分配情况确认后, 可通过总负荷指令反推剩余电站的负荷值。同时, 对于每个决策阶段, 前一阶段的负荷分配已确定, RL 模型仅需在前一阶段的基础上进行负荷调整。因此, 为增强神经网络的拟合效果, 提高寻优效率, 可基于下游电站两决策阶段间的出力变化区间  $\Delta N$  构造动作空间, 以减少动作数量, 缩小动作空间, 减少每个动作空间内对应的迭代次数。

(3) 奖励  $r_t(s_t, a_t)$ : 奖励是表示智能体在完成一次动作后环境给予的即时回报。针对梯级电站安全经济调度要求, 本文以耗水量最小为核心, 设置由基础奖励和惩罚项构成的奖励函数。其中基础奖励值由梯级各电站的最大发电流量与当前时段发电流量的差值表示, 惩罚项则与水位控制等实际运行过程中应该避免和禁止的情况相关。根据式 (1) 定义的目标函数计算公式, 本文奖励函数设置为

$$r_t(s_t, a_t) = R_t + P_t \quad (11)$$

$$R_t = \sum_i^I (q_{i, \max}^e - q_{i, t}^e) \quad (12)$$

$$P_t = P_1 + P_2 \quad (13)$$

$$P_1 = \begin{cases} 0, & N_{i, \min} \leq N_{i, t} \leq N_{i, \max}, 0 \leq q_{i, t}^e \leq q_{i, \max}^e, \\ & q_{i, \min} \leq q_{i, t} \leq q_{i, \max} \\ -1000, & \text{else} \end{cases} \quad (14)$$

$$P_2 = \begin{cases} 0, & \Delta Z_{i, t \sim t+1}^{up} \leq \Delta Z_{i, \max}^{up} \\ |\Delta Z_{i, t \sim t+1}^{up}| \times C, & \Delta Z_{i, t \sim t+1}^{up} > \Delta Z_{i, \max}^{up} \end{cases} \quad (15)$$

式中,  $R_t$  为第  $t$  时段的基础奖励值;  $P_t$  为第  $t$  时段的惩罚值;  $\Delta Z_{i, t \sim t+1}^{up}$  为电站  $i$  的相邻时段水位差;  $C$  为惩罚参数, 此处取  $-1000$ 。

(4) 动作值函数  $Q_\pi(s, a)$ : 动作值函数是指在特定状态下选择特定动作后的预期收益, 包含当前奖励和未来预期奖励。这意味着智能体在做出动作决策时需要综合考虑当前决策对后续收益的影响, 具体定义为

$$Q_\pi(s, a) = r(s, a) + \gamma \max Q(s', a') \quad (16)$$

式中,  $\pi$  为动作选择策略;  $\gamma$  为衰减系数;  $Q(s', a')$  为选择动作  $a'$  并使得状态转变为  $s'$  对应的价值  $Q$ 。

(5) 策略  $\pi(s, a)$ : 策略是指智能体在特定状态下选择动作的规则或方法。在深度 RL 模型中, 智能体必须具备两种关键能力: (1) 需要能够记忆并执行最优动作, 即在给定状态下选择能够带来最大预期回报的动作; (2) 需要在面对未知或不确定的情况下进行探索, 以便发现可能存在的更优策略。因此, 本文采用  $\epsilon$ -greedy 方法作为智能体动作选择的策略, 在该方法中, 智能体以  $\epsilon$  的概率在动作空间内随机抽样选

择动作, 以  $1-\epsilon$  的概率选择当前状态下价值函数估计的具有最高价值的动作。为进一步提高模型训练速度, 设定当达到一定训练轮次后,  $\epsilon$  随学习轮次的增加而减小, 从而降低采样重复率, 实现探索与利用的平衡。具体公式为

$$\pi(a|s) = \begin{cases} \frac{\epsilon}{|A|} + 1 - \epsilon, & a^* = \operatorname{argmax} Q(s, a) \\ \frac{\epsilon}{|A|}, & \text{else} \end{cases} \quad (17)$$

式中,  $|A|$  为动作空间中可选择动作的数量;  $\epsilon$  为探索率。

### 2.4 DQN 算法

DQN 算法是一种结合深度学习与强化学习的先进技术, 相比于早期的强化学习算法, 其在处理复杂问题时展现出显著优势。传统的强化学习方法通常依赖简单的  $Q$  表, 因此在面对高维状态空间时效率较低。DQN 则通过深度神经网络来近似动作价值函数, 从而能够有效应对复杂环境。此外, DQN 模型采用了主网络和目标网络的双重神经网络设计, 其中主网络负责与环境进行交互并更新参数, 而目标网络则稳定地估计  $Q$  值, 其参数定期从主网络复制更新。此设计显著提高了训练的稳定性和收敛速度。针对梯级水电站的负荷分配问题, DQN 算法能够捕捉复杂的动态关系, 并实时调整决策策略, 以适应不断变化的负荷需求, 因此为该问题提供了一种高效且可靠的解决方案。模型参数更新过程如图 3 所示。

### 2.5 模型求解

梯级水电站间实时负荷优化分配模型求解可分为

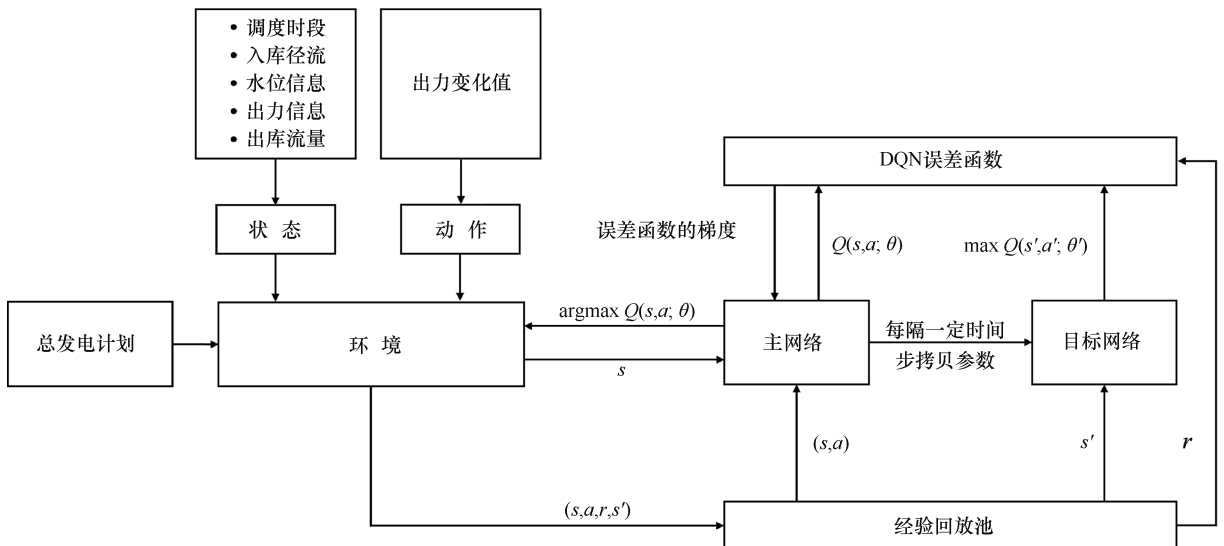


图 3 DQN 模型参数更新过程

Fig. 3 Parameter update process of DQN model

两部分: 第一部分, 根据各电站的出力约束条件和梯级总出力计划, 筛选输出所有可选择的负荷分配方案; 第二部分, 在第一部分输出的可行方案基础上, 综合考虑梯级水电的水位控制目标和水能利用效率, 以梯级总耗水量最小为判断标准, 采用 DQN 算法输出最优的负荷分配方案, 具体的模型求解步骤如下。

Step1: 读取各水库的基本调度信息, 输入初始时段梯级水电系统各电站的水位信息  $[Z_{1,str}, Z_{2,str}, Z_{3,str}, \dots, Z_{l,str}]$ 、入库径流  $[Q_{1,str}, Q_{2,str}, Q_{3,str}, \dots, Q_{l,str}]$ 、电网负荷指令  $N^{target}$  等基本信息, 确定计算时段总数  $T$ , 迭代轮次  $M$ , 令  $t=0, m=1$ 。

Step2: 根据当前状态信息及各电站出力约束, 筛选可以选择的动作范围并进行动作选择, 确定下游各级电站的出力区间,  $t = t + 1$ 。

Step3: 将出力区间以 0.5 MW 精度离散并进行迭代计算。初次计算时, 梯级水电下游日调节电站均取对应出力区间的上限值, 根据当前时段出力计划, 反算得出相应的龙头电站的出力, 并记录当前各电站的出力计算结果  $[N_{1,t}, N_{2,t}, N_{3,t}, \dots, N_{l,t}]$ 。

Step4: 根据当前时段各水库的上游水位  $[Z_{1,t}^{up}, Z_{2,t}^{up}, Z_{3,t}^{up}, \dots, Z_{l,t}^{up}]$ 、入库流量  $[Q_{1,t}, Q_{2,t}, Q_{3,t}, \dots, Q_{l,t}]$ 、负荷分配  $[N_{1,t}, N_{2,t}, N_{3,t}, \dots, N_{l,t}]$  等信息, 由水电站水能计算公式反推各电站当前时段的出库流量  $[q_{1,t}, q_{2,t}, q_{3,t}, \dots, q_{l,t}]$  和下一时段初的水库水位  $[Z_{1,t+1}^{up}, Z_{2,t+1}^{up}, Z_{3,t+1}^{up}, \dots, Z_{l,t+1}^{up}]$ 。

Step5: 根据当前负荷分配情况, 计算当前状态对应奖励值  $r_t$ 。判断  $r_t$  是否为当前出力区间内的最优值, 若是, 则记录当前  $r_t$  值及各对应电站的运行状态, 否则, 调整下游日调节电站出力组合, 返回 Step3, 直至遍历出力区间。

Step6: 将原始状态输入深度神经网络, 得到该状态的价值  $Q_{t-1}$ , 结合 Step5 中的计算结果进行状态更新, 计算本轮累计奖励值  $r_{sum} = r_{sum} + r_t$ , 并将更新后的状态输入神经网络, 可得到执行动作后对应的状态的价值  $Q_t$ 。结合  $Q_{t-1}$ 、 $Q_t$  和  $r_t$  计算损失函数, 并采用梯度下降法对主神经网络参数进行更新, 并每隔一定时间步将参数赋值给目标神经网络, 实现智能体的“自主学习”。

Step7: 判断是否达到轮次终止条件  $t = T$ , 若满足, 则转入 Step8; 否则返回 Step2。

Step8: 判断是否达到学习终止条件  $m = M$ , 若满足, 则转入 Step9; 否则返回 Step1, 迭代轮次  $m = m + 1$ 。

Step9: 输出每轮学习的奖励总和  $r_{sum}$ , 若  $r_{sum}$  趋于收敛, 则模型完成学习过程, 输出当前调度方案, 否则增加迭代轮数继续学习。

### 3 研究实例结果与分析

#### 3.1 方案设置

为系统评估深度强化学习模型的优化性能, 本研究采用实际运行数据与传统动态规划方法<sup>[39-40]</sup>作为 DQN 模型的对比方法。基于优化需求的复杂度差异, 分别设置仅以耗水量最小为目标的优化模型和兼顾耗水量及水位控制需求的优化模型, 具体对比方案设置如表 3 所列。

表 3 对比方案设置

Table 3 Settings for comparative schemes

方案名称	求解算法	优化目标	
		电调	水调
实际运行	—	—	—
方案 1	DP	满足电网负荷指令	耗水量最小
方案 2	DP	满足电网负荷指令	耗水量最小+水位控制
方案 3	DQN	满足电网负荷指令	耗水量最小+水位控制

#### 3.2 DQN 参数优选

超参数直接影响智能体的学习效率和决策质量, 进而决定强化学习模型的收敛速度和最终性能。在 DQN 模型框架中, 主要超参数包括学习率 ( $\alpha$ )、折扣因子 ( $\gamma$ ) 和最小探索率 ( $\epsilon$ )。学习率控制模型每一步学习的更新幅度; 折扣因子影响模型对未来奖励的重视程度; 探索率则决定模型选择随机动作的概率。为加快模型学习速度, 增强其泛化能力, 本文选取 2019 年 1 月的实际运行数据作为试验素材, 进行 100 轮次迭代。经过初步试验, 确定上述三种超参数的选择范围, 并通过排列组合的方式设置计算方案, 最终选取使模型最快达到最大奖励值的方案作为最优参数组合, 试验所得结果如图 3 所示。分析表明, 总奖励值的变化趋势相似, 初期快速提升, 后期逐渐趋于稳定。图 3(a) 中, 各方案收敛时间和总奖励值较为接近, 因此选取总奖励值收敛效果最优且振动幅度最小的方案。图 3(b) 与图 3(c) 中显示某种方案总奖励值高于其他方案, 因此以总奖励值最大为判断标准, 选取对应的超参数。最终超参数具体数值如表 4 所列。

表 4 超参数设置

Table 4 Hyperparameter settings

参数类型	参数名称	参数取值
学习效率参数	学习率 $\alpha$	0.000 5
	折扣因子 $\gamma$	0.8
	最小贪婪率 $\epsilon$	0.05

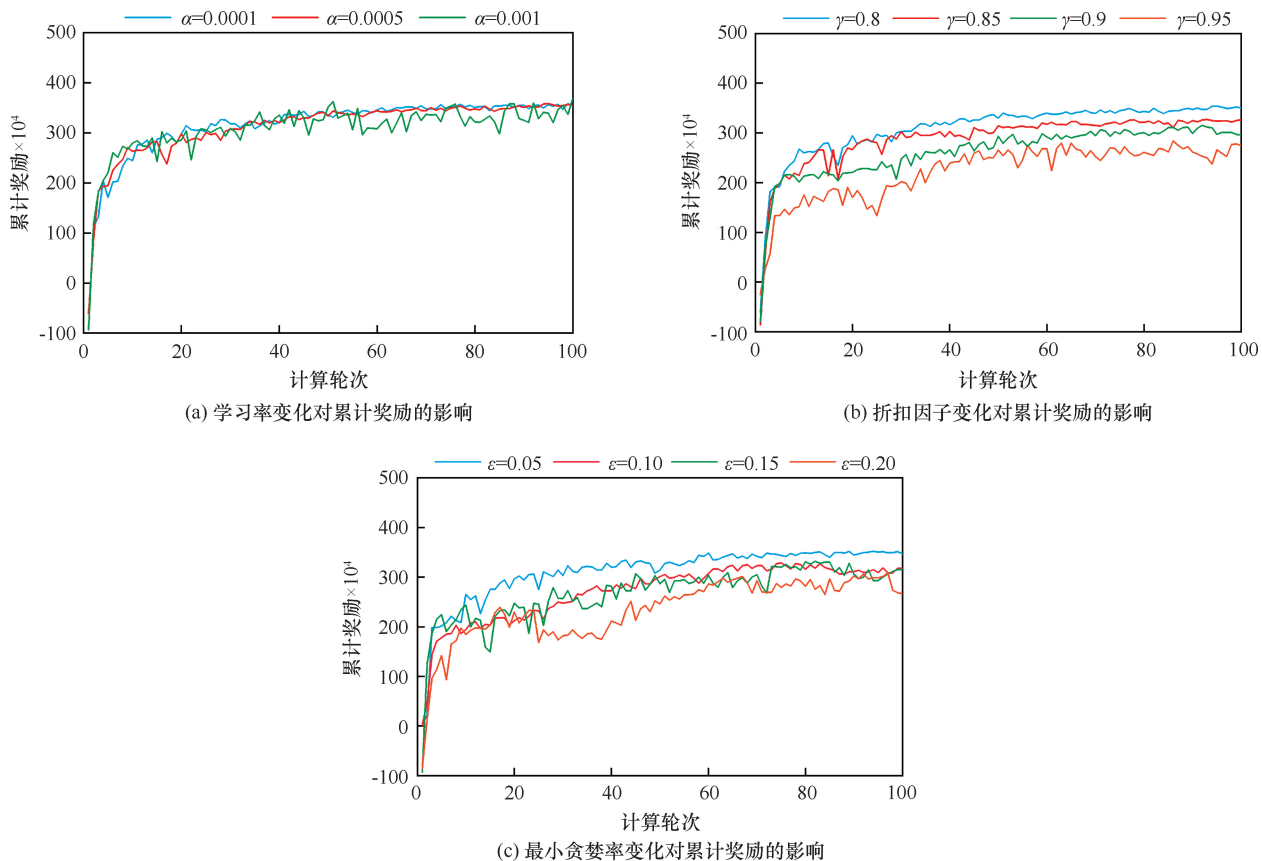


图 4 不同超参数组合下计算轮次与累计奖励变化曲线

Fig. 4 Variation curves of computation iterations and cumulative rewards under different hyperparameter combinations

### 3.3 结果与分析

对本文选取“瀑-深-枕”梯级三种典型工况进行研究,采用 5 min 时间步长进行模拟分配,计算结果如下。

(1) 计算效率方面,各方案的计算耗时如表 5 所列。采用 DP 算法的方案 1 和方案 2 平均计算耗时约为 7.64 h 和 7.86 h,而采用 DQN 算法的方案 3 平均计算耗时约为 0.19 h,仅为方案 1 和方案 2 的 2.49% 和 2.42%,计算效率提升了 40.21 倍和 41.37 倍。这是因为 DP 算法需对每一个可能的状态和动作进行计算和储存,并最终在所有可行决策中搜寻最优解,因此其计算耗时较长。而 DQN 算法通过前期智能体训练,有效搜寻学习到相对稳定的最优策略,因此在后续决策过程中,可大幅缩短决策用时。因此, DQN 算法可显著提升模型求解效率,降低计算耗时,满足梯级水电站间负荷分配的高效性要求。

(2) 水位控制方面,结合表 6 与图 5—图 7 分析,各方案瀑布沟电站的水位计算结果均呈现平稳下降趋势,满足其枯期水位均匀消落要求。方案 2 采用 DP 算法并考虑水位平稳控制需求,其深溪沟和枕头坝电站的平均水位波动指数分别为 0.019 m/min

表 5 高、中、低负荷工况下各方案计算耗时

Table 5 Computational time of different schemes under high, medium, and low load conditions

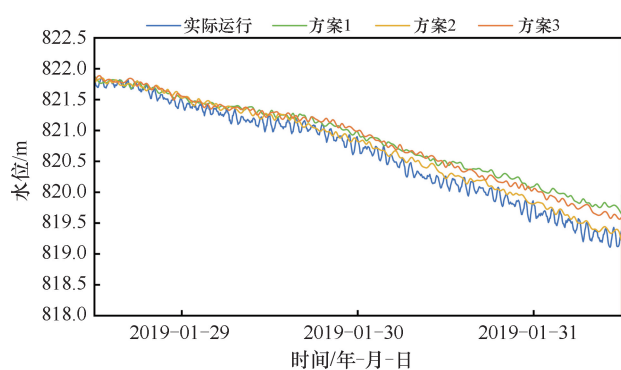
研究工况	方案编号	计算耗时/s	单次决策耗时/s
中等负荷工况 (1月)	实际运行	—	—
	方案 1	27 654	32.01
	方案 2	28 153	32.58
	方案 3	683	0.79
低负荷工况 (4月)	实际运行	—	—
	方案 1	27 581	31.92
	方案 2	28 267	32.72
	方案 3	697	0.81
高负荷工况 (11月)	实际运行	—	—
	方案 1	27 234	31.52
	方案 2	28 457	32.94
	方案 3	706	0.82

和 0.016 m/min,相较于不考虑水位控制需求的方案 1 降低了 0.049 m/min 和 0.005 m/min。方案 3 采用 DQN 算法并考虑水位平稳控制需求,其深溪沟和枕头坝电站的平均水位波动指数分别为 0.024 m/min 和 0.017 m/min,相较于方案 1 降低了 0.044 m/min 和 0.004 m/min,水位波动情况明显改善。结合图 4 可知,在同样考虑水位控制需求的条件下, DP 算法计


表 6 高、中、低负荷工况下各方案深溪沟与枕头坝水位结果

Table 6 Water level results of Shenxigou and Zhentouba dams under high, medium, and low load conditions


研究工况	方案编号	水位最大值/m		水位最小值/m		水位波动指数/ $m \cdot \min^{-1}$	
		深溪沟	枕头坝	深溪沟	枕头坝	深溪沟	枕头坝
中等负荷工况 (1月)	实际运行	658.67	622.83	656.19	621.46	0.033	0.032
	方案1	659.06	623.57	657.20	622.63	0.146	0.010
	方案2	658.07	623.36	656.38	622.36	0.014	0.006
	方案3	658.34	623.57	656.97	622.64	0.022	0.007
低负荷工况 (4月)	实际运行	658.62	622.51	656.88	621.66	0.026	0.030
	方案1	658.51	622.37	657.15	621.80	0.014	0.007
	方案2	658.55	622.45	657.23	621.90	0.011	0.006
	方案3	658.43	622.40	657.02	621.82	0.013	0.006
高负荷工况 (11月)	实际运行	658.97	623.45	654.65	619.05	0.068	0.052
	方案1	658.67	622.69	655.00	619.36	0.043	0.046
	方案2	658.96	623.36	655.43	620.07	0.031	0.036
	方案3	658.73	623.02	655.09	619.71	0.037	0.040




(a) 瀑布沟电站模拟水位过程



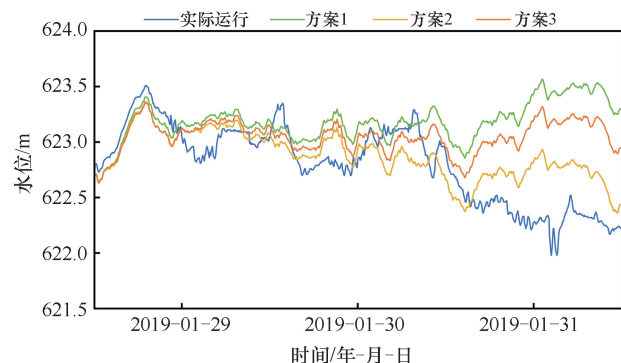
(b) 瀑布沟电站模拟出力过程




(c) 深溪沟电站模拟水位过程



(d) 深溪沟电站模拟出力过程



(e) 枕头坝电站模拟水位过程



(f) 枕头坝电站模拟出力过程

图 5 “瀑-深-枕” 梯级水电中等负荷工况(1月)计算结果

Fig. 5 Computational results of “Pu-Shen-Zhen” cascade hydropower system under medium load conditions (January)

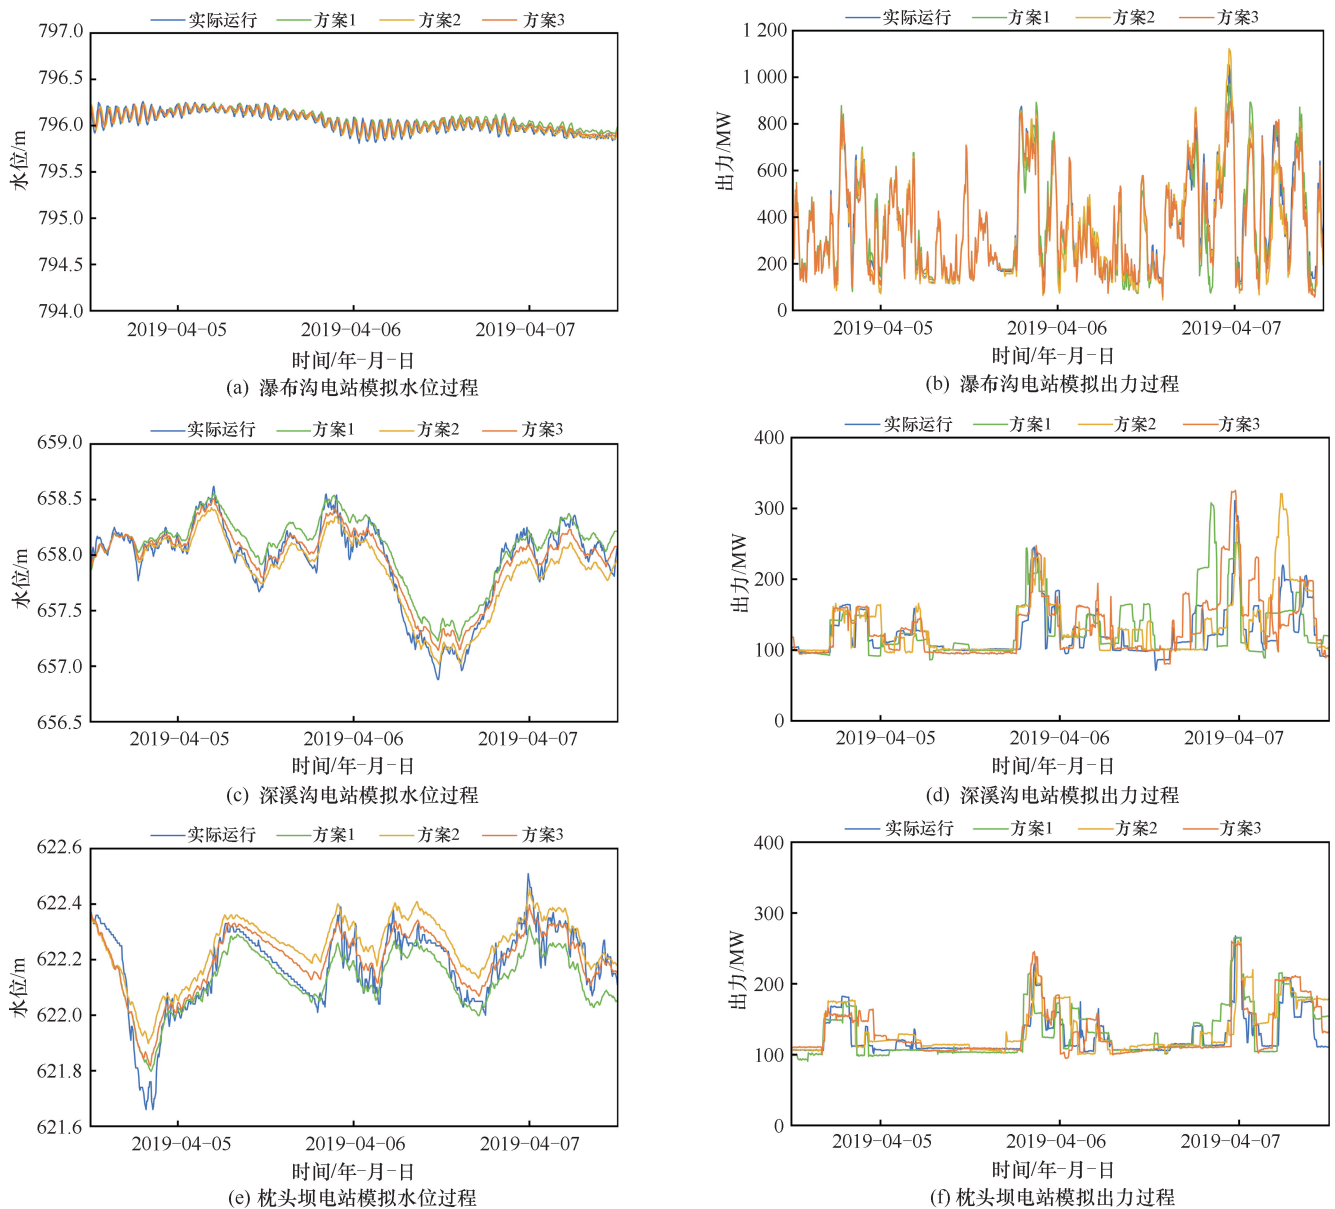


图6 “瀑-深-枕”梯级水电低负荷工况(4月)计算结果

Fig. 6 Computational results of “Pu-Shen-Zhen” cascade hydropower system under low load conditions (April)

算结果会比 DQN 算法更加平稳, 因为 DP 算法是确定性算法, 在状态转移的过程中可通过 Bellman 方程直接得出最优策略, 其计算结果是相应计算精度下的全局最优解。而 DQN 算法是不确定性算法, 需要在探索和利用中做出平衡, 在面对奖励较低的情况时, DQN 算法通过给予负面反馈的方式来引导行为, 而不能直接排除不理想的选项, 这一结果也符合两种算法各自的特性。但相比于优化前, 经 DQN 模型优化后的深溪沟和枕头坝电站相邻最大水位差分别降低 42.86% 和 55.26%, 这表明考虑水位控制约束的 DQN 模型可以有效减少水位大幅波动情况, 实现水位平稳控制。

(3) 出力过程方面, 不同工况下各方案的模拟出力过程如图 5—图 7 所示, 结合表 7—表 9 分析可知, 由于各方案采用的负荷分配方法不同, 因此其对应出力过程表现出明显差异。在中等负荷、低负荷和高负荷工况下, 梯级水电系统的主要负荷均由瀑布沟电站承担。在中等负荷工况下, 瀑布沟电站出力均值约为 1 472.25 MW, 在梯级水电系统平均总出力中占比约 75.82%; 在低负荷工况下, 瀑布沟电站出力均值约为 361.12 MW, 在梯级水电系统平均总出力中占比约 58.03%; 在高负荷工况下, 瀑布沟电站出力均值约为 2 653.99 MW, 在梯级水电系统平均总出力中占比约 73.94%。当处于高负荷工况时, 梯级水电系统内

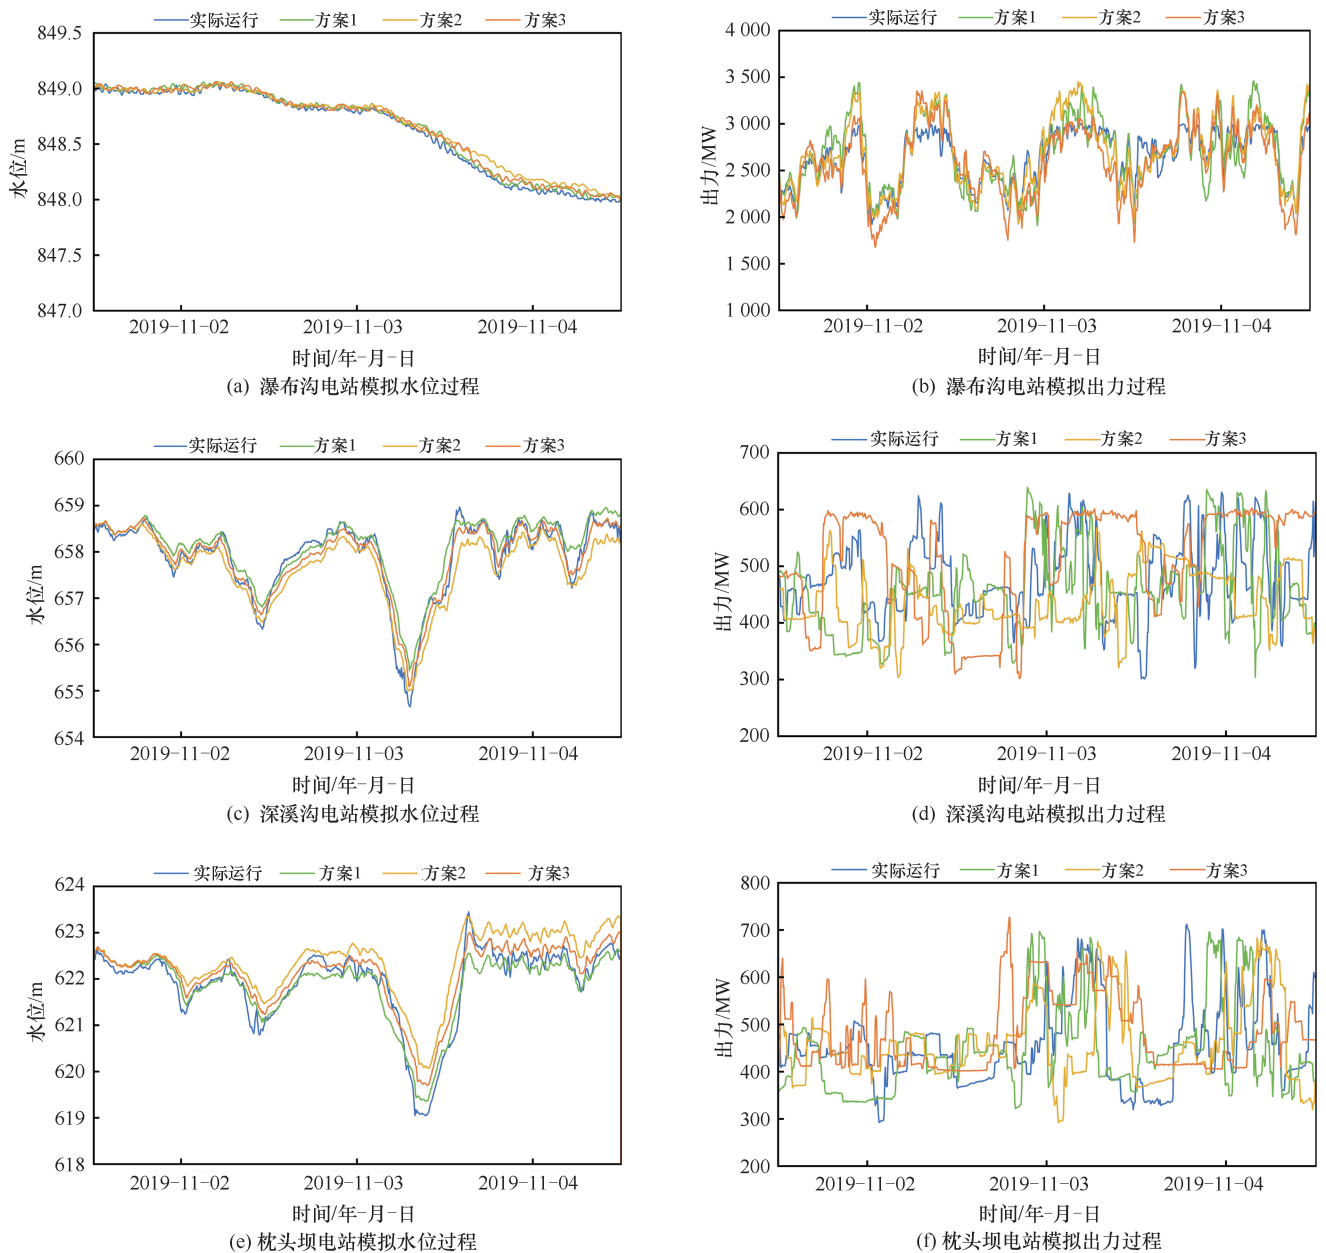


图7 “瀑-深-枕”梯级水电高负荷工况(11月)计算结果

Fig. 7 Computational results of “Pu-Shen-Zhen” cascade hydropower system under high load conditions (November)

各电站的出力波动指数普遍较高, 而出力过程则相对均衡; 当处于中等负荷和低负荷工况时, 梯级水电系统内各电站的出力波动指数则相对降低, 而出力不均衡指数则相对增加。在高负荷工况下, 瀑布沟出力波动指数高达约 269.72 MW/min, 出力不均衡系数约为 0.13; 深溪沟出力波动指数高达约 119.88 MW/min, 出力不均衡系数约为 0.15; 枕头坝出力波动指数高达约 132.55 MW/min, 出力不均衡系数约为 0.18。经本文提出的方案优化后, 各电站的出力不均衡系数和出力波动指数均普遍增加。其中, 瀑布沟电站由于调节能力较强, 再多重约束

条件下仍可通过库容缓冲有效均衡出力过程, 因此其处理不均衡系数及水位波动指数的增幅相对较小。而深溪沟和枕头坝电站由于调节性能较差, 且耗水量最小与水位平稳目标存在本质冲突, 下游电站需频繁调整出力以满足约束, 因此导致不均衡系数增幅相对较大。

(4)运行效益方面, 结合表 10 可知, 梯级系统负荷越大, 对应总耗水量越高。方案 1 在三种工况下的梯级总耗水量相较优化前共减少 1770 万  $m^3$ ; 方案 2 的梯级总耗水量较优化前共减少 656 万  $m^3$ ; 方案 3 的梯级总耗水量较优化前共减少 1158 万  $m^3$ 。这是因

表 7 中等负荷工况各方案出力计算分析

Table 7 Computational analysis of output for different schemes under medium load conditions

电站名称	方案编号	出力最大值/MW	出力最小值/MW	出力均值/MW	出力波动指数/MW · min <sup>-1</sup>	出力不均衡系数
瀑布沟	实际运行	2 753.09	50.02	1 459.94	91.04	0.43
	方案 1	3 047.86	25.54	1 482.55	90.84	0.43
	方案 2	2 756.73	51.01	1 436.50	91.04	0.42
	方案 3	3 031.59	54.52	1 509.99	95.57	0.43
深溪沟	实际运行	539.00	79.00	301.74	120.00	0.34
	方案 1	496.00	76.00	262.92	120.00	0.37
	方案 2	485.00	79.00	290.71	82.00	0.31
	方案 3	441.00	79.00	262.54	87.00	0.31
枕头坝	实际运行	344.00	117.00	185.25	108.00	0.25
	方案 1	334.00	86.00	204.05	127.00	0.31
	方案 2	392.50	117.00	220.52	117.50	0.33
	方案 3	331.00	81.00	178.23	116.50	0.35

表 8 低负荷工况各方案出力计算分析

Table 8 Computational analysis of output for different schemes under low load conditions

电站名称	方案编号	出力最大值/MW	出力最小值/MW	出力均值/MW	出力波动指数/MW · min <sup>-1</sup>	出力不均衡系数
瀑布沟	实际运行	1 053.14	57.12	370.47	255.26	0.55
	方案 1	972.35	47.91	362.92	256.14	0.57
	方案 2	1 123.06	45.24	354.79	282.63	0.58
	方案 3	897.14	58.19	356.28	255.08	0.56
深溪沟	实际运行	311.09	71.45	125.21	61.10	0.28
	方案 1	307.61	86.20	129.83	122.15	0.31
	方案 2	320.11	96.20	132.77	66.44	0.32
	方案 3	325.61	80.70	133.63	105.14	0.33
枕头坝	实际运行	267.68	101.54	126.58	52.30	0.24
	方案 1	265.83	90.70	129.51	70.98	0.27
	方案 2	261.33	100.20	134.70	72.17	0.24
	方案 3	260.83	94.70	132.35	148.84	0.27

表 9 高负荷工况各方案出力计算分析

Table 9 Computational analysis of output for different schemes under high load conditions

电站名称	方案编号	出力最大值/MW	出力最小值/MW	出力均值/MW	出力波动指数/MW · min <sup>-1</sup>	出力不均衡系数
瀑布沟	实际运行	3 001.85	1 923.99	2 641.87	248.51	0.11
	方案 1	3 462.19	1 909.95	2 685.40	278.97	0.14
	方案 2	3 450.50	1 932.11	2 694.63	276.18	0.14
	方案 3	3 353.08	1 678.39	2 594.06	275.21	0.14
深溪沟	实际运行	630.62	301.12	478.62	140.76	0.14
	方案 1	639.30	304.07	456.82	124.21	0.16
	方案 2	567.80	567.57	436.98	84.60	0.12
	方案 3	602.80	302.07	514.31	129.96	0.18
枕头坝	实际运行	711.92	292.43	454.70	127.35	0.19
	方案 1	697.40	321.91	447.07	160.85	0.20
	方案 2	682.90	292.41	457.68	127.35	0.18
	方案 3	727.40	401.41	480.92	114.66	0.16

表 10 高、中、低负荷工况下各方案梯级系统耗水量分析

Table 10 Analysis of water consumption in cascade hydropower system under high, medium, and low load conditions for different schemes

研究工况	方案编号	总耗水量/ $10^6 \text{ m}^3$
中等负荷工况 (1月)	实际运行	528.77
	方案 1	520.81
	方案 2	527.02
	方案 3	523.96
低负荷工况 (4月)	实际运行	314.58
	方案 1	309.62
	方案 2	312.50
	方案 3	311.02
高负荷工况 (11月)	实际运行	1 293.75
	方案 1	1 288.97
	方案 2	1 291.02
	方案 3	1 290.54

为方案 1 为仅以耗水量最小为目标, 未考虑水位控制需求, 故而可选择的优化路径更多, 可以通过水位的动态调整达到减少发电耗水的目的, 因此其运行效益提升最明显。方案 2 则考虑水位控制及发电效益多重需求, 其采用的 DP 算法将水位控制约束处理为硬性条件, 因此运行效益的优化空间受到一定限制。方案 3 虽然也考虑水位控制及发电效益的多重需求, 但其采用的 DQN 算法通过奖励函数权重博弈机制与多步奖励预见性, 可实现在允许的水位波动范围内平衡节水与水位控制目标。此外, DQN 的时序决策特性使其能够权衡短期水位控制惩罚与长期节水收益, 而动态规划算法因缺乏跨时段价值传递机制无法实现此类优化。

## 4 总结

本文构建了兼顾电调-水调需求的梯级水电间实时负荷分配模型, 以耗水量最小化为核心目标, 嵌入水位动态控制约束, 并采用 DQN 算法进行高效求解, 可在满足电网负荷指令的前提下, 实现决策科学性与求解效率的协同优化。以大渡河流域“瀑-深-枕”梯级电站为研究实例, 结果表明如下。

(1) DQN 算法可显著减少计算耗时, 满足高强度调峰调频背景下对负荷分配的分钟级快速响应要求。在同样考虑节水和水位控制需求的情况下, DQN 算法求解平均用时仅为 695.33 s, 相比传统 DP 算法缩减了 97.54%, 计算效率提高了 41.37 倍。

(2) DQN 算法可以很好地平衡水位和流量等水调需求之间的冲突, 实现经济性与安全性的协同优化。相较于优化前, DQN 可在将水位波动指数平均降低约 0.058 m/min 的同时将平均总耗水量减少

1 158 万  $\text{m}^3$ ; 相较于 DP 算法, DQN 算法的水位波动指数平均抬升约 0.003 m/min, 但平均总耗水量减少 502 万  $\text{m}^3$ 。

(3) 本文提出的模型具备良好的稳定性。该模型在中等负荷、低负荷和高负荷多种工况下均适用, 可实现在满足电网负荷指令的同时, 有效改善水位波动情况, 降低发电耗水, 实现电调-水调的协同优化。

## 参考文献 (References):

- [1] 李国英. 进一步全面深化水利改革 为推动水利高质量发展、保障我国水安全作出新的贡献: 在 2025 年全国水利工作会议上的讲话[J]. 水利发展研究, 2025, 25(1): 1-12.  
LI G Y. Further comprehensively deepen water conservancy reform to promote high-quality development of water conservancy and safeguard national water security: A speech at the 2025 national water conservancy work conference [J]. Water Resources Development Research, 2025, 25(1): 1-12.
- [2] 过夏明, 秦毓毅, 魏少岩. 节能发电调度下的水电短期优化调度[J]. 电力系统及其自动化学报, 2010, 22(1): 138-141.  
GUO X M, QIN Y Y, WEI S Y. Short-term hydro power optimal scheduling in energy saving generation dispatch [J]. Proceedings of the Chinese Society of Universities for Electric Power System and Its Automation, 2010, 22(1): 138-141.
- [3] 马宇航, 黄媛, 刘俊勇, 等. 考虑日内来水不确定和电网断面约束的梯级水电日前调度[J]. 电力建设, 2020, 41(9): 39-49.  
MA Y H, HUANG Y, LIU J Y, et al. Day-ahead dispatching of cascade hydropower stations considering daily interval flow uncertainty and the section constraint of power grid [J]. Electric Power Construction, 2020, 41(9): 39-49.
- [4] 李国英. 为以中国式现代化全面推进强国建设、民族复兴伟业提供有力的水安全保障: 在 2024 年全国水利工作会议上的讲话[J]. 水利发展研究, 2024, 24(1): 1-10.  
LI G Y. Improved water security for China's efforts to build itself into a stronger country and rejuvenate the Chinese nation on all fronts by pursuing Chinese modernization: Speech at the 2024 National Water Conservancy Work Conference [J]. Water Resources Development Research, 2024, 24(1): 1-10.
- [5] 郭富强, 郭生练, 刘攀, 等. 清江梯级水电站实时负荷分配模型研究[J]. 水力发电学报, 2011, 30(1): 5-11.  
GUO F Q, GUO S L, LIU P, et al. Real-time load distribution models for the Qingjiang cascade hydropower plants [J]. Journal of Hydroelectric Engineering, 2011, 30(1): 5-11.
- [6] LEI K X, CHANG J X, WANG Y M, et al. Cascade hydropower stations short-term operation for load distribution considering water level synchronous variation [J]. Renewable Energy, 2022, 196: 683-693.
- [7] 葛晓琳, 张粒子, 王春丽. 多目标短期梯级水电优化调度混合整数模型[J]. 电力系统保护与控制, 2013, 41(4): 55-60.  
GE X L, ZHANG L Z, WANG C L. Mixed integer model for multi-objective short-term cascaded hydropower optimal scheduling [J].

- Power System Protection and Control, 2013, 41(4): 55-60.
- [8] 吴丰昌. 我国水体污染控制与治理成效、科技支撑与展望[J]. 水利发展研究, 2023, 23(12): 1-8.  
WU F C. Effectiveness, scientific and technological support, and prospects for water pollution control and management in China[J]. Water Resources Development Research, 2023, 23(12): 1-8.
- [9] 张建云, 刘九夫, 金君良. 关于智慧水利的认识与思考[J]. 水利水运工程学报, 2019(6): 1-7.  
ZHANG J Y, LIU J F, JIN J L. Understanding and thinking of smart water conservancy[J]. Hydro-Science and Engineering, 2019(6): 1-7.
- [10] 牛文静, 冯仲恺, 程春田. 梯级水电站群优化调度多目标量子粒子群算法[J]. 水力发电学报, 2017, 36(5): 47-57.  
NIU W J, FENG Z K, CHENG C T. Multi-objective quantum-behaved particle swarm optimization for operation of cascade hydropower stations[J]. Journal of Hydroelectric Engineering, 2017, 36(5): 47-57.
- [11] 梅亚东, 熊莹, 陈立华. 梯级水库综合利用调度的动态规划方法研究[J]. 水力发电学报, 2007, 26(2): 1-4.  
MEI Y D, XIONG Y, CHEN L H. A dynamic programming method for the multi-purpose operation of cascade reservoirs[J]. Journal of Hydroelectric Engineering, 2007, 26(2): 1-4.
- [12] 董子敖, 闫建生, 刘文彬, 等. 径流时空相关时梯级水库群补偿调节和调度的多目标多层次优化法[J]. 水力发电学报, 1986, 5(2): 1-15.  
DONG Z A, YAN J S, LIU W B, et al. Multiobjective and multilevel method of optimal compensation adjustment and operation of cascade reservoirs taking into account correlations of river flows in time and space[J]. Journal of Hydroelectric Engineering, 1986, 5(2): 1-15.
- [13] NEEDHAM J T, WATKINS D W, LUND J R, et al. Linear programming for flood control in the Iowa and des Moines Rivers[J]. Journal of Water Resources Planning and Management, 2000, 126(3): 118-127.
- [14] 王浩, 王旭, 雷晓辉, 等. 梯级水库群联合调度关键技术发展历程与展望[J]. 水利学报, 2019, 50(1): 25-37.  
WANG H, WANG X, LEI X H, et al. The development and prospect of key techniques in the cascade reservoir operation[J]. Journal of Hydraulic Engineering, 2019, 50(1): 25-37.
- [15] 郭生练, 陈炯宏, 刘攀, 等. 水库群联合优化调度研究进展与展望[J]. 水科学进展, 2010, 21(4): 496-503.  
GUO S L, CHEN J H, LIU P, et al. State-of-the-art review of joint operation for multi-reservoir systems[J]. Advances in Water Science, 2010, 21(4): 496-503.
- [16] 周建中, 李英海, 肖舸, 等. 基于混合粒子群算法的梯级水电站多目标优化调度[J]. 水利学报, 2010, 41(10): 1212-1219.  
ZHOU J Z, LI Y H, XIAO G, et al. Multi-objective optimal dispatch of cascade hydropower stations based on shuffled particle swarm operation algorithm[J]. Journal of Hydraulic Engineering, 2010, 41(10): 1212-1219.
- [17] 舒卫民, 马光文, 黄炜斌, 等. 基于人工神经网络的梯级水电站群调度规则研究[J]. 水力发电学报, 2011, 30(2): 11-14.  
SHU W M, MA G W, HUANG W B, et al. Study on hydropower stations operation rule by an artificial neural network model[J]. Journal of Hydroelectric Engineering, 2011, 30(2): 11-14.
- [18] 李国英. 深入贯彻落实党的二十大精神 扎实推动新阶段水利高质量发展: 在 2023 年全国水利工作会议上的讲话[J]. 水利发展研究, 2023, 23(1): 1-11.  
LI G Y. Thoroughly implement the spirit of the 20<sup>th</sup> National Congress of the Communist Party of China and solidly promote the high-quality development of water conservancy in the new stage: Speech at the National Water Conservancy Work Conference in 2023[J]. Water Resources Development Research, 2023, 23(1): 1-11.
- [19] 谭乔凤, 宋嘉伟, 闻昕, 等. 基于 DQN 算法的水电站内负荷优化分配研究[J]. 水利学报, 2024, 55(11): 1345-1355.  
TAN Q F, SONG J W, WEN X, et al. Research on optimal load allocation in hydropower station based on DQN algorithm[J]. Journal of Hydraulic Engineering, 2024, 55(11): 1345-1355.
- [20] 程春田. 碳中和下的水电角色重塑及其关键问题[J]. 电力系统自动化, 2021, 45(16): 29-36.  
CHENG C T. Function remolding of hydropower systems for carbon neutral and its key problems[J]. Automation of Electric Power Systems, 2021, 45(16): 29-36.
- [21] WANG H N, LIU N, ZHANG Y Y, et al. Deep reinforcement learning: A survey[J]. Frontiers of Information Technology & Electronic Engineering, 2020, 21(12): 1726-1744.
- [22] LEE J, KAO H G, YANG S H. Service innovation and smart analytics for industry 4.0 and big data environment[J]. Procedia CIRP, 2014, 16: 3-8.
- [23] 李文武, 郑凯新, 刘江鹏, 等. 基于 SARSA 算法的风电: 抽蓄联合系统日随机优化研究[J]. 水电能源科学, 2020, 38(11): 72-76.  
LI W W, ZHENG K X, LIU J P, et al. Research on daily stochastic optimization of combined wind PowerPumping system based on SARSA algorithm[J]. Water Resources and Power, 2020, 38(11): 72-76.
- [24] 黄显峰, 冉超越, 周文, 等. 基于深度强化学习算法的水光互补优化调度研究[J]. 水利水电技术(中英文), 2025, 56(4): 235-247.  
HUANG X F, RAN C Y, ZHOU W, et al. Research on water-light complementary optimal scheduling based on deep reinforcement learning algorithm[J]. Water Resources and Hydropower Engineering, 2025, 56(4): 235-247.
- [25] 李成健, 宋姝谊, 粟宇, 等. 深度强化学习求解多目标. 旅行商问题的研究综述[J/OL]. 计算机工程与应用, 2025: 1-18. [2025-03-16]. <https://kns.cnki.net/kcms/detail/11.2127.TP.20250116.1216.004.html>.  
LI C J, SONG S Y, SU Y, et al. Review of multi-objective traveling salesman problem based on deep reinforcement learning[J/OL]. Computer Engineering and Applications, 2025: 1-18. [2025-03-16]. <https://kns.cnki.net/kcms/detail/11.2127.TP.20250116.1216.004.html>.
- [26] 李文武, 周佳妮, 裴本林, 等. 梯级水库深度强化学习长期随机优化调度研究[J]. 水力发电学报, 2023, 42(11): 21-32.  
LI W W, ZHOU J N, PEI B L, et al. Study on long-term stochastic

- optimal operation of cascade reservoirs by deep reinforcement learning [J]. *Journal of Hydroelectric Engineering*, 2023, 42(11): 21-32.
- [27] 杨思明, 单征, 丁煜, 等. 深度强化学习研究综述[J]. *计算机工程*, 2021, 47(12): 19-29.
- YANG S M, SHAN Z, DING Y, et al. Survey of research on deep reinforcement learning[J]. *Computer Engineering*, 2021, 47(12): 19-29.
- [28] 刘全, 翟建伟, 章宗长, 等. 深度强化学习综述[J]. *计算机学报*, 2018, 41(1): 1-27.
- LIU Q, ZHAI J W, ZHANG Zongchang, et al. A survey on deep reinforcement learning[J]. *Chinese Journal of Computers*, 2018, 41(1): 1-27.
- [29] ARULKUMARAN K, DEISENROTH M P, BRUNDAGE M, et al. Deep reinforcement learning: A brief survey [J]. *IEEE Signal Processing Magazine*, 2017, 34(6): 26-38.
- [30] 李佳, 曲田, 朱艳军, 等. 大型梯级水电站枯水期多模式优化调度模型研究[J]. *水资源与水工程学报*, 2024, 35(1): 124-132.
- LI J, QU T, ZHU Y J, et al. Multi-mode scheduling of large-scale cascade hydropower stations in dry season [J]. *Journal of Water Resources and Water Engineering*, 2024, 35(1): 124-132.
- [31] 程海花, 寇宇, 周琳, 等. 面向清洁能源消纳的流域型风光水多能互补基地协同优化调度模式与机制[J]. *电力自动化设备*, 2019, 39(10): 61-70.
- CHENG H H, KOU Y, ZHOU L, et al. Collaborative optimal dispatching mode and mechanism of watershed-type wind-solar-water multi-energy complementary bases for clean energy absorption [J]. *Electric Power Automation Equipment*, 2019, 39(10): 61-70.
- [32] 尤渺. 大渡河流域下游梯级电站发电优化调度研究[D]. 重庆: 重庆大学, 2008.
- YOU M. Study on the United Optimal Dispatching of Cascaded Hydropower Plant in Lower Reaches of Dadu River Basin [D]. Chongqing: Chongqing University, 2008.
- [33] 闻昕, 刘凡骞, 谭乔凤, 等. 复杂水利-电力约束下梯级水电站短期多层次多目标优化调度研究[J]. *水利学报*, 2023, 54(4): 392-404.
- WEN X, LIU F Q, TAN Q F, et al. Research on short-term multi-level and multi-objective optimal scheduling of cascade hydropower stations under complex water resources and power constraints [J]. *Journal of Hydraulic Engineering*, 2023, 54(4): 392-404.
- [34] BARROS M T L, TSAI F T, YANG S-L, et al. Optimization of large-scale hydropower system operations [J]. *Journal of Water Resources Planning and Management*, 2003, 129(3): 178-188.
- [35] 郑明芬, 谭乔凤, 闻昕, 等. 兼顾水调-电调需求的梯级水光互补调度及影响分析研究[J/OL]. *工程科学与技术*, 2024: 1-14. [2025-03-05]. <https://kns.cnki.net/kcms/detail/51.1773.TB.20241105.1408.004.html>.
- ZHENG M F, TAN Q F, WEN X, et al. Cascaded hydro-PV complementary dispatching and its impact analysis considering both water and power demands [J/OL]. *Advanced Engineering Sciences*, 2024: 1-14. [2025-03-05]. <https://kns.cnki.net/kcms/detail/51.1773.TB.20241105.1408.004.html>. *Production*, 2023, 385: 135704.
- [36] 胡瑞. 基于调度知识经验的梯级水库群优化调度方法研究[D]. 武汉: 华中科技大学, 2017.
- HU R. Research on Optimal Operation for Cascaded Hydropower Stations Based on Optimizing Knowledge Experience [D]. Wuhan: Huazhong University of Science and Technology, 2017.
- [37] 舒生茂. 基于深度学习的梯级水电站发电调度及系统设计研究[D]. 武汉: 华中科技大学, 2019.
- SHU S M. Research on Power Generation Dispatching and System Design of Cascade Hydropower Station Based on Deep Learning [D]. Wuhan: Huazhong University of Science and Technology, 2019.
- [38] JIANG W Y, LIU Y Q, FANG G H, et al. Research on short-term optimal scheduling of hydro-wind-solar multi-energy power system based on deep reinforcement learning [J]. *Journal of Cleaner Production*, 2023, 385: 135704.
- [39] FENG Z K, LUO T, NIU W J, et al. A LSTM-based approximate dynamic programming method for hydropower reservoir operation optimization [J]. *Journal of Hydrology*, 2023, 625: 130018.
- [40] SHANG Y Z, LU S B, GONG J G, et al. Improved genetic algorithm for economic load dispatch in hydropower plants and comprehensive performance comparison with dynamic programming method [J]. *Journal of Hydrology*, 2017, 554: 306-316.

(责任编辑 王海锋)