

# 基于改进闭环预测-优化互嵌技术的 含水风光电力系统两阶段调度方法

刘继春<sup>1</sup>, 肖煜瑾<sup>1</sup>, 邱高<sup>1</sup>, 唐伦<sup>2,3</sup>, 孙毅<sup>3</sup>, 李凌昊<sup>4</sup>

(1. 四川大学电气工程学院, 成都市 610065; 2. 西安交通大学电气工程学院, 西安市 710049;  
3. 国网四川省电力公司, 成都市 610041; 4. 中国电力科学研究院有限公司, 北京市 100192)

**摘要:**【目的】水风光资源的强随机性加剧了常用开环预测后优化(open-looped predict-then-optimize, OPO)调度方法在计算复杂度和运行经济性方面的矛盾。为此,提出含水风光电力系统基于改进闭环预测-优化互嵌技术(closed-loop predict-and-optimize intertwined framework, CPO)的两阶段调度方法。【方法】首先,构建了考虑串、并、混联多类水电群的含水风光电力系统两阶段调度模型;然后,以水风光实际和预测曲线在两阶段调度模型下计算所得系统成本的绝对偏差作为损失函数,训练以经济性为导向的水风光预测模型;最终,结合方差、布林带和自相关函数量化新能源出力及水电站入库流量的波动强度,以构建融入弹性网络回归的混合正则化策略,在优化CPO训练复杂度的同时,保证其在多重不确定性下的性能。【结果】Matlab仿真结果表明:在丰、枯、平水期典型月内,采用改进CPO方法得到的月平均实际系统成本相较传统OPO方法分别降低了0.74%、0.57%、0.66%,验证了该方法在提升电力调度经济性方面的有效性。【结论】所提的改进CPO方法在水风光总体预测精度下降不大且部分时段精度提升的情况下显著降低了实际系统成本,优化了调度经济性,且在不确定性程度更高的场景中,该方法提升经济性的效果更为显著。

**关键词:**水电站群; 入库流量预测; 机组组合; 闭环预测-优化互嵌技术; 弹性网络

中图分类号: TM73

文献标志码: A

文章编号: 1000-7229(2025)12-0143-16

DOI: 10.12204/j.issn.1000-7229.2025.12.013

## Improved Closed-Loop Predict-and-Optimize Intertwined Framework- Based Two-Stage Dispatch for Hydro-Wind- Photovoltaic-Involved Power Systems

LIU Jichun<sup>1</sup>, XIAO Yujin<sup>1</sup>, QIU Gao<sup>1</sup>, TANG Lun<sup>2,3</sup>, SUN Yi<sup>3</sup>, LI Linghao<sup>4</sup>

(1. College of Electrical Engineering, Sichuan University, Chengdu 610065, China; 2. School of Electrical Engineering, Xi'an Jiao Tong University, Xi'an 710049, China; 3. State Grid Sichuan Electric Power Company, Chengdu 610041, China; 4. China Electric Power Research Institute, Beijing 100192, China)

**ABSTRACT:** [Objective] The high randomness of hydro, wind, and photovoltaic powers exacerbates the problem of achieving a trade-off between the computational complexity and operational economy of the traditional open-loop predict-then-optimize (OPO) dispatch. [Methods] This limitation is addressed by proposing a two-stage dispatch method based on an improved closed-loop predict-and-optimize intertwined framework (CPO) for hydro-wind-photovoltaic-involved power systems. First, a two-stage dispatch model for hydro-wind-photovoltaic power systems involving series, parallel, and hybrid-connected hydropower groups is constructed. Next, to train an economy-oriented prediction model for inflow and renewable energy generation, a loss function is established by considering the absolute deviation between the system cost calculated from the ground truths and the predictions of inflow and renewable energies. Finally, the variance, Bollinger bands, and autocorrelation function are combined to quantify the fluctuation intensities of renewable energy generation and hydropower inflow such that a hybrid regularization strategy involving elastic net regression is constructed to balance the training complexity and performance of the CPO under multiple uncertainties. [Results] MATLAB simulation results show that during the typical wet, dry, and normal months, the monthly average actual system cost obtained using the improved CPO method is

reduced by 0.74%, 0.57%, and 0.66%, respectively, compared with that obtained using the traditional OPO method; this verifies the effectiveness of the proposed method for improving the economic efficiency of power dispatch. [Conclusions] The improved CPO method proposed in this study significantly reduces the actual system cost and optimizes the economic efficiency of dispatch when the overall prediction accuracy of hydropower inflow, wind power, and photovoltaic power decreases slightly and the accuracy increases in certain periods. Moreover, in scenarios with high degrees of uncertainty, the effect of this method on improving economic efficiency is even more prominent.

This work is supported by State Grid Corporation of China Research Program (No. 5108-202326039A-1-1-ZN).

**KEYWORDS:** hydropower plant group; inflow prediction; unit commitment; closed-loop predict-and-optimize intertwined framework; elastic net regression

## 0 引言

在“双碳”目标的驱动下,以水风光为代表的清洁能源发电比例不断提升<sup>[1-2]</sup>。水电站来水流量及风、光出力的波动性和随机性使得在大规模清洁能源接入电网时,需要频繁更改机组启停和负荷分配计划,给电力系统运行的经济性和稳定性带来了新的挑战<sup>[3-4]</sup>。因此,调度计划的制定应充分考虑清洁能源的波动性<sup>[5-6]</sup>,以保障系统的经济稳定运行。

电力系统机组组合问题作为制定日前调度计划的关键环节,通常采用开环的预测后优化(open-looped predict-then-optimize, OPO)框架,水风光预测与决策优化往往作为两个独立的环节先后进行,依据水风光的预测结果安排机组启停和出力计划。在基于开环框架的机组组合问题中,常采用随机优化法<sup>[7]</sup>和鲁棒优化法<sup>[8]</sup>处理水风光的不确定性。随机优化方法通过概率分布模型刻画预测值或预测误差的不确定性,具有良好的经济性。然而,该方法通常依赖大量随机场景采样<sup>[9-10]</sup>,导致变量与约束规模随场景数线性增长,当应用于实际大规模电力系统时计算复杂度显著提升。鲁棒优化使用不确定集刻画不确定性,仅考虑最恶劣的场景,虽避免了场景采样,但获得的结果往往过于保守且经济性较差<sup>[11-12]</sup>。因此,亟需折中方案平衡机组组合的复杂度与经济性。

针对上述问题,常见的思路是基于OPO框架,提升预测精度以获得更具经济性的决策方案。风电预测方面,文献[13]基于聚类经验模态分解结果,利用样本熵重组分量并构建优化极限学习机的区间预测模型,显著提高了预测的可靠性。光伏预测方面,文献[14]采用粒子群算法优化边界估值理论,实现了高质量的超短期光伏出力的区间预测。来水预测方面,文献[15]使用最小绝对收缩和选择算子(least absolute shrinkage and selection operator, LASSO)回归进行特征选择,建立基于分位数回归长短期记忆神经网络的来水流量预测模型,应用核密度估计拟合

概率密度函数,获得了高精度的来水流量预测结果。

尽管现有研究有效提升了水风光的预测精度,但因其天然的随机和波动特性,预测误差是无法避免的<sup>[16]</sup>。由于预测误差对调度经济性的影响具有非对称的、非单调和非线性特点<sup>[17]</sup>,统计上更精确的预测不一定都能带来更经济的决策方案<sup>[18]</sup>。在某些情况下,有偏差的预测反而有助于降低系统成本。文献[19]建立了一种中长期来水量组合预测模型,证明了适度偏差的预测有助于提升决策经济性。文献[20-21]发现,由于水电存在一定的误差容忍和补偿机制,来水预测精度与水电效益并非严格正相关,低精度预测在一定阈值内反而可能提高发电效益。基于此,一种新兴的思路聚焦于预测误差对决策成本的引导作用,而非单纯追求预测精度,通过直接最小化下游决策成本训练预测模型,实现成本导向的预测<sup>[22]</sup>。在此基础上,文献[23]提出了智能预测优化(smart predict-then-optimize, SPO)框架,其核心是SPO损失函数,用以衡量预测误差对决策的影响,显著提升了优化性能。

进一步地,文献[24]提出闭环预测-优化互嵌技术(closed-loop predict-and-optimize intertwined framework, CPO),将决策成本信息通过损失函数反馈到预测过程中,实现了预测与优化的闭环协同,而非传统的预测后优化。如下给出了传统预测后优化及闭环预测-优化互嵌的定义:

定义1(传统开环预测后优化技术):首先以真实值与预测值偏差最小为目标构建预测模型,然后基于预测模型提供的基线进行日前或滚动调度优化。预测模型与优化模型完全独立,目标不一致。

定义2(智能闭环预测-优化互嵌技术):首先以真实时序数据和预测时序数据下的系统运行成本差异最小为目标构建预测模型,然后基于预测模型提供的基线进行日前或滚动调度优化。预测模型中嵌入调度优化模型,目标一致,均以成本最优为导向。

文献[25-26]分别将预测-优化互嵌思想应用于

风电出力区间预测和点预测中,提升了预测的经济性,但未考虑多源不确定性综合影响。文献[27]将可再生能源预测与交易决策一体化,通过直接最小化成本损失函数训练决策树集成模型,并采用加权样本平均近似法获得决策,显著提升了预测和决策效果,但计算复杂度较高。文献[28]首次将CPO应用于机组组合,结合机组组合模型结构、成本信息及相关特征数据训练成本导向的风光预测模型,验证了CPO在提升机组组合经济性上的有效性,但模型泛化能力有待提升。综上可知,现有研究成果在协调计算复杂度与泛化能力上,仍存在一定的提升空间,亟待进一步探索与优化。

总体而言,当前电力系统优化问题中对成本导向预测的研究大多侧重于新能源出力、水电来水或负荷的单独优化,而本文创新性地考虑了水风光综合作用下电力系统成本预期值与实际值之间的误差,提出了一种基于改进CPO的含水风光电力系统两阶段调度方法。首先,考虑串、并、混联多类小水电群,建立了含水风光系统的两阶段调度模型;其次,在该模型基础上构建改进CPO框架,将以水风光实际曲线计算所得系统成本为基线的绝对成本偏差损失函数引入两阶段调度模型,以训练经济导向的水风光预测模型;最后,结合方差、布林带和自相关函数量化的新能源出力及水电站入库流量波动强度,制定融入弹性网络回归的混合正则化策略。在改进的IEEE RTS 24节点系统对上述CPO框架及传统OPO框架进行对比仿真,分别在丰、枯、平水期中选取一个典型月作为场景,分析两种方法下的系统总运行成本及预测误差,结果验证了本文所提方法的有效性与经济性。

## 1 含水风光系统的两阶段调度模型

### 1.1 基于水风光预测的机组组合模型

#### 1.1.1 目标函数

以系统总运行成本最小为优化目标:

$$\min \sum_{t=1}^T \left\{ \sum_{i \in I} [c_{i,t}^U x_{i,t}^U + c_{i,t}^D x_{i,t}^D + c_i(P_{i,t}^{\text{th}})u_{i,t}] + \sum_{j \in J} c^{\text{res}} E_{j,t}^{\text{res}} + \sum_{n \in N} c^{\text{hyd}} E_{n,t}^{\text{hyd}} \right\} \quad (1)$$

式中: $c_{i,t}^U$ 、 $c_{i,t}^D$ 分别表示机组*i*在*t*时段的启、停成本; $x_{i,t}^U$ 、 $x_{i,t}^D$ 分别表示机组*i*在*t*时段启、停状态的0-1变量; $c^{\text{res}}$ 、 $c^{\text{hyd}}$ 分别为弃新能源、弃水惩罚成本; $E_{j,t}^{\text{res}}$ 、 $E_{n,t}^{\text{hyd}}$ 分别为弃新能源、弃水电量; $u_{i,t}$ 为机组*i*在*t*时段运行状态的0-1变量; $I$ 、 $J$ 和 $N$ 分别表示火电、新能源和水电机组集合; $T$ 为调度时段数; $P_{i,t}^{\text{th}}$ 为火电机组*i*在时段*t*的

出力;火电机组*i*在时段*t*的成本 $c_i(P_{i,t}^{\text{th}})$ 为二次函数,经分段线性化处理后可由下式计算<sup>[29]</sup>:

$$c_i(P_{i,t}^{\text{th}}) = \sum_{k=1}^K c_{i,k} P_{i,t,k}^{\text{th}} + c_i^0 u_{i,t} \quad (2)$$

式中: $K$ 为分段总数; $c_{i,k}$ 表示火电机组*i*在第*k*段出力时的成本; $c_i^0$ 表示机组*i*的空载成本; $P_{i,t,k}^{\text{th}}$ 表示火电机组*i*在*t*时段的第*k*段出力值,且需满足以下约束:

$$P_{i,t}^{\text{th}} = \sum_{k=1}^K P_{i,t,k}^{\text{th}} \quad (3)$$

$$0 \leq P_{i,t,k}^{\text{th}} \leq P_{i,k,\text{max}}^{\text{th}} u_{i,t} \quad (4)$$

式中: $P_{i,k,\text{max}}^{\text{th}}$ 表示火电机组*i*的第*k*段出力上限。

#### 1.1.2 约束条件

1)火电机组约束。

出力上下限约束:

$$u_{i,t} P_{i,\text{min}}^{\text{th}} \leq P_{i,t}^{\text{th}} \leq u_{i,t} P_{i,\text{max}}^{\text{th}} \quad (5)$$

式中: $P_{i,\text{min}}^{\text{th}}$ 、 $P_{i,\text{max}}^{\text{th}}$ 分别是机组*i*的最小、最大出力。

爬坡约束:

$$P_{i,t}^{\text{th}} - P_{i,t-1}^{\text{th}} \leq R_{i,t}^{\text{up}} u_{i,t-1} + P_{i,\text{max}}^{\text{th}} (1 - u_{i,t}) + P_{i,\text{min}}^{\text{th}} (u_{i,t} - u_{i,t-1}) \quad (6)$$

$$P_{i,t-1}^{\text{th}} - P_{i,t}^{\text{th}} \leq R_{i,t}^{\text{down}} u_{i,t} + P_{i,\text{max}}^{\text{th}} (1 - u_{i,t-1}) - P_{i,\text{min}}^{\text{th}} (u_{i,t} - u_{i,t-1}) \quad (7)$$

式中: $R_{i,t}^{\text{up}}$ 、 $R_{i,t}^{\text{down}}$ 分别是机组*i*向上、向下爬坡的最大能力。

最小启停时间约束:

$$\sum_{t'=t-T_i^{\text{U}}}^{t-1} u_{i,t'} \geq (u_{i,t-1} - u_{i,t}) T_i^{\text{U}} \quad (8)$$

$$\sum_{t'=t-T_i^{\text{D}}}^{t-1} (1 - u_{i,t'}) \geq (u_{i,t} - u_{i,t-1}) T_i^{\text{D}} \quad (9)$$

式中: $T_i^{\text{U}}$ 和 $T_i^{\text{D}}$ 分别为机组*i*的最小连续开、停机时间。

2)新能源机组约束。

风光出力 $P_{j,t}^{\text{res}}$ 上下限约束:

$$0 \leq P_{j,t}^{\text{res}} \leq \hat{P}_{j,t}^{\text{res}} \quad (10)$$

式中: $\hat{P}_{j,t}^{\text{res}}$ 为机组*j*在*t*时段的预测出力。

弃风弃光电量 $E_{j,t}^{\text{res}}$ 约束:

$$0 \leq E_{j,t}^{\text{res}} \leq E_{\text{max},j,t}^{\text{res}} \quad (11)$$

式中: $E_{\text{max},j,t}^{\text{res}}$ 为机组*j*在*t*时段弃风弃光电量上限。

3)水电约束。

库容 $V_{n,t}$ 上下限约束:

$$V_{n,\text{min}} \leq V_{n,t} \leq V_{n,\text{max}} \quad (12)$$

式中: $V_{n,\text{max}}$ 和 $V_{n,\text{min}}$ 为水电*n*的库容上下限。

水电引用流量 $Q_{n,t}$ 约束:

$$Q_{n,\text{min}} \leq Q_{n,t} \leq Q_{n,\text{max}} \quad (13)$$

式中: $Q_{n,\text{min}}$ 和 $Q_{n,\text{max}}$ 为水电*n*的最小、最大发电引用流量。

水量平衡约束:

$$V_{n,t} = V_{n,t-1} + (\hat{I}_{n,t} - Q_{n,t} - w_{n,t})\Delta t \quad (14)$$

式中:  $\hat{I}_{n,t}$  为水电  $n$  在  $t$  时段的预测入库流量;  $w_{n,t}$  为水电  $n$  在  $t$  时段的弃水流量。

弃水流量  $w_{n,t}$  约束:

$$0 \leq w_{n,t} \leq w_{n,\max} \quad (15)$$

式中:  $w_{n,\max}$  为水电  $n$  的弃水流量上限。

若水电  $n$ 、 $n+1$  在一条流域上, 则二者间存在水量联系关系如下:

$$\hat{I}_{n+1,t} = R_{n+1,t} + Q_{n,t} + w_{n,t} \quad (16)$$

式中:  $R_{n+1,t}$  为水电  $n+1$  在  $t$  时段的天然来水量。

水电出力上下限约束:

$$P_{n,\min}^{\text{hyd}} \leq P_{n,t}^{\text{hyd}} \leq P_{n,\max}^{\text{hyd}} \quad (17)$$

式中:  $P_{n,\min}^{\text{hyd}}$ 、 $P_{n,\max}^{\text{hyd}}$  分别为水电站  $i$  的最小、最大出力;  $P_{n,t}^{\text{hyd}}$  为水电  $t$  在  $n$  时段的出力, 可由流量-功率转换系数  $\varphi_n$  近似计算<sup>[30]</sup>:

$$P_{n,t}^{\text{hyd}} = \varphi_n Q_{n,t} \quad (18)$$

若所有水电都在同一条流域, 则构成串联小水电群, 其约束可由式(12)~(18)表示。若各水电间无水力联系, 则构成并联小水电群, 无须考虑式(16)。若小水电群中既存在串联关系, 又存在并联关系, 则构成混联小水电群。

4) 系统级约束。

系统功率平衡约束:

$$\sum_{i \in \mathcal{I}} P_{i,t}^{\text{th}} + \sum_{j \in \mathcal{J}} P_{j,t}^{\text{res}} + \sum_{n \in \mathcal{N}} P_{n,t}^{\text{hyd}} = \sum_{m=1}^M L_{m,t} \quad (19)$$

式中:  $L_{m,t}$  为负荷节点  $m$  在  $t$  时段的负荷。

备用约束:

$$\sum_{i \in \mathcal{I}} (P_{i,\max}^{\text{th}} u_{i,t} - P_{i,t}^{\text{th}}) \geq \rho L_t \quad (20)$$

式中:  $\rho$  为系统备用容量系数;  $L_t$  表示系统在  $t$  时刻的总负荷。

线路潮流约束:

$$-P_{l,\max} \leq \sum_{i \in \mathcal{I}} \tau_{l,i} P_{i,t}^{\text{th}} + \sum_{j \in \mathcal{J}} \tau_{l,j} P_{j,t}^{\text{res}} + \sum_{n \in \mathcal{N}} \tau_{l,n} P_{n,t}^{\text{hyd}} - \sum_{m=1}^M \tau_{l,m} L_{m,t} \leq P_{l,\max} \quad (21)$$

式中:  $P_{l,\max}$  为线路  $l$  的潮流传输极限;  $\tau_{l,i}$ 、 $\tau_{l,j}$ 、 $\tau_{l,n}$  分别为火电机组  $i$ 、新能源机组  $j$  和水电  $n$  所在节点对线路  $l$  的功率转移因子;  $\tau_{l,m}$  为负荷节点  $m$  对线路  $l$  的功率转移因子。

## 1.2 经济调度模型

日内经济调度模型的目标函数如下:

$$\begin{cases} z^{\text{ED}}(\hat{P}^{\text{res}}, \hat{I}) = \min \sum_{t=1}^T [\sum_{i \in \mathcal{I}} c_i(P_{i,t}^{\text{th,ED}}) u_{i,t}^{\text{ED}} + \\ C_t^{\text{co}} + \sum_{j \in \mathcal{J}} c_j^{\text{res}} E_{j,t}^{\text{res,ED}} + \sum_{n \in \mathcal{N}} c_n^{\text{hyd}} E_{n,t}^{\text{hyd,ED}}] \\ C_t^{\text{co}} = \sum_{i \in \mathcal{O}} (c_{i,t}^{\text{U}} x_{i,t}^{\text{U,ED}} + c_{i,t}^{\text{D}} x_{i,t}^{\text{D,ED}}) \end{cases} \quad (22)$$

式中:  $z^{\text{ED}}(\hat{P}^{\text{res}}, \hat{I})$  为实际系统总运行成本;  $\sum_{i \in \mathcal{I}} c_i(P_{i,t}^{\text{th,ED}}) u_{i,t}^{\text{ED}}$  为经济调度阶段的总发电成本;  $C_t^{\text{co}}$  为冷备用成本;  $x_{i,t}^{\text{U,ED}}$ 、 $x_{i,t}^{\text{D,ED}}$  分别为冷备用机组的启停状态变量;  $\sum_{j \in \mathcal{J}} c_j^{\text{res}} E_{j,t}^{\text{res,ED}}$ 、 $\sum_{n \in \mathcal{N}} c_n^{\text{hyd}} E_{n,t}^{\text{hyd,ED}}$  分别为弃新能源、弃水惩罚;  $(\hat{P}^{\text{res}}, \hat{I})$  为新能源出力和来水的超短期预测向量;  $u_{i,t}^{\text{ED}}$ 、 $P_{i,t}^{\text{th,ED}}$  分别为经济调度阶段调整后的火电机组运行状态变量及出力;  $\mathcal{O}$  表示具有日内启停能力的冷备用机组集合。

日内经济调度模型的约束条件如下:

$$\begin{cases} \text{式(12); 式(13); 式(15); } \mathcal{G} \cup \mathcal{O} = \mathcal{I} \\ u_{i,t}^{\text{ED}} = u_{i,t}^* ; u_{i,t}^{\text{ED}} P_{i,\min}^{\text{th}} \leq P_{i,t}^{\text{th,ED}} \leq u_{i,t}^{\text{ED}} P_{i,\max}^{\text{th}} \quad \forall i \in \mathcal{G} \\ u_{i,t}^{\text{ED}} \in \{0, 1\} ; u_{i,t}^{\text{ED}} P_{i,\min}^{\text{th}} \leq P_{i,t}^{\text{th,ED}} \leq u_{i,t}^{\text{ED}} P_{i,\max}^{\text{th}} \quad \forall i \in \mathcal{O} \\ \sum_{t'=t-\tau_i^{\text{U}}}^{t-1} u_{i,t'}^{\text{ED}} \geq (u_{i,t}^{\text{ED}} - u_{i,t-1}^{\text{ED}}) \tau_i^{\text{U}} ; \\ \sum_{t'=t-\tau_i^{\text{D}}}^{t-1} (1 - u_{i,t'})^{\text{ED}} \geq (u_{i,t}^{\text{ED}} - u_{i,t-1}^{\text{ED}}) \tau_i^{\text{D}} \quad \forall i \in \mathcal{O} \\ P_{i,t}^{\text{th,ED}} - P_{i,t-1}^{\text{th,ED}} \leq P_{i,\max}^{\text{th}} (1 - u_{i,t}^{\text{ED}}) + \\ P_{i,\min}^{\text{th}} (u_{i,t}^{\text{ED}} - u_{i,t-1}^{\text{ED}}) + R_{i,t}^{\text{up}} u_{i,t-1}^{\text{ED}} ; \\ P_{i,t-1}^{\text{th,ED}} - P_{i,t}^{\text{th,ED}} \leq P_{i,\max}^{\text{th}} (1 - u_{i,t-1}^{\text{ED}}) - \\ P_{i,\min}^{\text{th}} (u_{i,t}^{\text{ED}} - u_{i,t-1}^{\text{ED}}) + R_{i,t}^{\text{down}} u_{i,t-1}^{\text{ED}} \quad \forall i \in \mathcal{I} \\ 0 \leq P_{j,t}^{\text{res,ED}} \leq P_{j,t}^{\text{res}} ; P_{n,\min}^{\text{hyd}} \leq P_{n,t}^{\text{hyd,ED}} \leq P_{n,\max}^{\text{hyd}} \\ V_{n,t} = V_{n,t-1} + (I_{n,t} - Q_{n,t} - w_{n,t})\Delta t \\ I_{n+1,t} = R_{n+1,t} + Q_{n,t} + w_{n,t} \\ \sum_{i \in \mathcal{I}} P_{i,t}^{\text{th,ED}} + \sum_{j \in \mathcal{J}} P_{j,t}^{\text{res,ED}} + \sum_{n \in \mathcal{N}} P_{n,t}^{\text{hyd,ED}} = \sum_{m=1}^M L_{m,t} - \\ P_{l,\max} \leq \sum_{i \in \mathcal{I}} \tau_{l,i} P_{i,t}^{\text{th,ED}} + \sum_{j \in \mathcal{J}} \tau_{l,j} P_{j,t}^{\text{res,ED}} + \\ \sum_{n \in \mathcal{N}} \tau_{l,n} P_{n,t}^{\text{hyd,ED}} - \sum_{m=1}^M \tau_{l,m} L_{m,t} \leq P_{l,\max} \end{cases} \quad (23)$$

式中:  $u_{i,t}^*$  为日前机组组合优化后得到的火电机组运行状态变量; 对于所有时段  $t$ ,  $\mathcal{G}$  为非冷备用机组集合;  $\hat{P}_{j,t}^{\text{res}}$ 、 $\hat{I}_{n,t}$  分别表示新能源出力和来水超短期预测值;  $P_{j,t}^{\text{res,ED}}$ 、 $P_{n,t}^{\text{hyd,ED}}$  分别为经济调度阶段调整后的新能源出力和水电出力。

## 2 基于改进混合正则化的闭环预测-优化互嵌框架

### 2.1 问题概述

上述模型是同时考虑负荷、新能源和水电的复杂运筹问题, 包括随机优化和鲁棒优化在内的传统求解方法存在经济性和复杂度难以兼顾的根本矛

盾。CPO框架通过引导随机变量预测值的误差以提升调度经济性,避免向模型引入刻画随机场景的中间变量,亦保证了合理的计算复杂度,是解决上述问题的一种有力潜在方案。具体而言,CPO框架考虑了发生欠预测和过预测时预测误差对决策经济性的非对称影响,通过最小化预期系统总成本与最优系统总成本之间的绝对偏差来训练预测模型,所得预测结果倾向于使得日前机组组合阶段的预期系统成本更接近最优系统总成本,实现了以“系统总成本最优”为导向的预测模型训练,而非单纯追求预测精度最优。

为便于进行更清晰地表述,将上述机组组合模型用紧凑形式表示如下:

$$\begin{cases} z(\hat{P}^{\text{res}}, \hat{I}) = \min_{x,y} [\mathbf{a}^T \mathbf{x} + \mathbf{b}^T \mathbf{y}] \\ \text{s.t. } \mathbf{C}\mathbf{x} + \mathbf{D}\mathbf{y} + \mathbf{G}\hat{I} \leq \mathbf{s} \\ \mathbf{L}\mathbf{y} \leq \hat{P}^{\text{res}} \\ \mathbf{x} = [x_1, \dots, x_E] \in \{0, 1\} \end{cases} \quad (24)$$

式中: $z(\hat{P}^{\text{res}}, \hat{I})$ 表示基于新能源出力和水电站来水量预测曲线调控的系统总运行成本; $\mathbf{x}$ 是表示机组组合问题中0-1变量的 $E$ 维向量; $\mathbf{y}$ 表示连续变量的向量; $\mathbf{a}$ 和 $\mathbf{b}$ 表示成本向量; $\mathbf{C}$ 、 $\mathbf{D}$ 、 $\mathbf{G}$ 和 $\mathbf{L}$ 是常数矩阵; $\mathbf{s}$ 是除新能源出力约束外的所有约束的右端向量; $\mathbf{L}\mathbf{y} \leq \hat{P}^{\text{res}}$ 表示新能源出力上限约束; $\hat{P}^{\text{res}}$ 为新能源出力预测向量; $\hat{I}$ 表示水电站入库流量预测向量。

## 2.2 水风光预测模型架构

在进行来水量及新能源出力预测时,为平衡预测模型的预测效果及计算量,以7天为一个调度周期重新训练预测模型。选取上个调度周期中7个样本日的24 h实际来水、出力数据,精度为导向的OPO方法得到的日前预测来水、出力数据及气候数据等作为输入数据,则可以分别构建新能源和水电的线性回归模型,如式(25)和式(26):

$$\begin{cases} \tilde{P}_{j,t}^{\text{res},1} = \beta_{j,t,0}^{\text{res}} + \beta_{j,t,1}^{\text{res}} f_{t,1}^{\text{res},1} + \dots + \beta_{j,t,F^{\text{res}}}^{\text{res}} f_{t,F^{\text{res}}}^{\text{res},1} \\ \vdots \\ \tilde{P}_{j,t}^{\text{res},7} = \beta_{j,t,0}^{\text{res}} + \beta_{j,t,1}^{\text{res}} f_{t,1}^{\text{res},7} + \dots + \beta_{j,t,F^{\text{res}}}^{\text{res}} f_{t,F^{\text{res}}}^{\text{res},7} \end{cases} \quad (25)$$

$$\begin{cases} \tilde{I}_{n,t}^1 = \beta_{n,t,0}^{\text{hyd}} + \beta_{n,t,1}^{\text{hyd}} f_{t,1}^{\text{hyd},1} + \dots + \beta_{n,t,F^{\text{hyd}}}^{\text{hyd}} f_{t,F^{\text{hyd}}}^{\text{hyd},1} \\ \vdots \\ \tilde{I}_{n,t}^7 = \beta_{n,t,0}^{\text{hyd}} + \beta_{n,t,1}^{\text{hyd}} f_{t,1}^{\text{hyd},7} + \dots + \beta_{n,t,F^{\text{hyd}}}^{\text{hyd}} f_{t,F^{\text{hyd}}}^{\text{hyd},7} \end{cases} \quad (26)$$

式中: $\tilde{P}_{j,t}^{\text{res},1}$ 为新能源机组 $j$ 在第1个样本日 $t$ 时刻的实际出力值; $f_{t,1}^{\text{res},1}$ — $f_{t,F^{\text{res}}}^{\text{res},1}$ 为新能源机组对应第1个样本日 $t$ 时刻的 $F^{\text{res}}$ 个特征类型的特征值; $\tilde{I}_{n,t}^1$ 为水电站 $n$ 在第1个样本日 $t$ 时刻的实际来水量; $f_{t,1}^{\text{hyd},1}$ — $f_{t,F^{\text{hyd}}}^{\text{hyd},1}$ 为来水预测对应第1个样本日 $t$ 时刻的 $F^{\text{hyd}}$ 个特征类型

的特征值; $\beta_{j,t,0}^{\text{res}}$ — $\beta_{j,t,F^{\text{res}}}^{\text{res}}$ 和 $\beta_{n,t,0}^{\text{hyd}}$ — $\beta_{n,t,F^{\text{hyd}}}^{\text{hyd}}$ 是新能源预测和来水量预测的回归系数。对每个新能源机组 $j$ 及水电站 $n$ ,求得的24组 $\beta_{j,t}^{\text{res}}$ 和 $\beta_{n,t}^{\text{hyd}}$ 值分别对应于24个预测时段的线性回归方程。

系统新能源预测模型 $\mathbf{W}^{\text{res}}$ 和来水预测模型 $\mathbf{W}^{\text{hyd}}$ 可以表示为:

$$\mathbf{W}^{\text{res}} = \text{diag} \{ \beta_{1,t}^{\text{res}}, \dots, \beta_{24,t}^{\text{res}} \} \quad (27)$$

$$\mathbf{W}^{\text{hyd}} = \text{diag} \{ \beta_{1,t}^{\text{hyd}}, \dots, \beta_{24,t}^{\text{hyd}} \} \quad (28)$$

式中:对时段 $t$ , $\beta_{t,t}^{\text{res}} = [\beta_{1,t}^{\text{res}}, \dots, \beta_{24,t}^{\text{res}}]^T$ ;对每个新能源机组 $j$ , $\beta_{j,t}^{\text{res}} = [\beta_{j,t,0}^{\text{res}}, \dots, \beta_{j,t,F^{\text{res}}}^{\text{res}}]$ ;  $\mathbf{W}^{\text{hyd}}$ 的构成方式类似。

则未来新能源出力和来水流量可以由下式进行预测:

$$\hat{P}^{\text{res}} = \mathbf{W}^{\text{res}} \mathbf{f}^{\text{res}} \quad (29)$$

$$\hat{I} = \mathbf{W}^{\text{hyd}} \mathbf{f}^{\text{hyd}} \quad (30)$$

式中:特征向量 $\mathbf{f}^{\text{res}} = [f_{1,t}^{\text{res}}, \dots, f_{24,t}^{\text{res}}]^T$ ,且对每个时段, $\mathbf{f}_{t,t}^{\text{res}} = [1, f_{t,1}^{\text{res}}, \dots, f_{t,F^{\text{res}}}^{\text{res}}]^T$ ;  $\mathbf{f}^{\text{hyd}}$ 的结构类似。

## 2.3 面向经济性优化的弹性网络损失函数构建

### 2.3.1 经济导向的损失函数构建

常用的精度导向的损失函数如均方误差损失函数虽能量化预测偏差,但往往仅关注预测值与真实值的数值逼近,无法反映预测误差对后续决策经济性的影响。基于此,文献[23]提出了SPO损失函数,以决策误差最小为目标训练预测模型。

为衡量由预测导致的系统总运行成本偏差,本文采用上述“SPO损失”概念对样本构建绝对成本偏差损失函数 $f_{\text{loss}}^{\text{SPO}}(\cdot)$ 如下:

$$f_{\text{loss}}^{\text{SPO}}(\hat{P}_h^{\text{res}}, \tilde{P}_h^{\text{res}}, \hat{I}_h, \tilde{I}_h) = |z^*(\hat{P}_h^{\text{res}}, \hat{I}_h) - z^*(\tilde{P}_h^{\text{res}}, \tilde{I}_h)| \quad (31)$$

式中: $z^*(\hat{P}_h^{\text{res}}, \hat{I}_h)$ 和 $z^*(\tilde{P}_h^{\text{res}}, \tilde{I}_h)$ 分别是用预测值和实际值求解式(24)得到的最优决策下的系统成本。

该损失函数直接反映了由预测误差导致的系统成本损失,将下游优化阶段的信息反馈到了上游预测阶段中,可以以决策经济性为导向训练预测模型 $\mathbf{W}^{\text{res}}$ 和 $\mathbf{W}^{\text{hyd}}$ 。

### 2.3.2 考虑水风光波动特性的混合正则化策略

为防止模型过拟合,应采取合适的正则化策略。常用的正则化策略有 $L_1$ 正则化和 $L_2$ 正则化及将两者结合的弹性网络正则化。 $L_1$ 正则化可以实现特征选择并使模型稀疏化,适用于非线性程度高的模型,但计算效率低。 $L_2$ 正则化具有更高的计算效率且可以控制权重均匀减小,对于接近线性关系的数据,可以防止模型过度拟合数据中的微小波动,但不能执行特征选择。为保证模型的训练效率和效果,应根据数据波动程度及非线性强度选择合适的正则化策

略。以某地区 1 月、5 月和 10 月的新能源出力数据(图 1)及水电站来水流量数据(图 2)为例,采用方差、布林带、自相关系数(autocorrelation function, ACF)及偏自相关系数(partial autocorrelation function, PACF)作为非线性程度指标对新能源出力及来水流量的随机性、波动性进行评估。




图 1 某地区 1、5、10 月新能源出力曲线

Fig. 1 Renewable energy source (RES) power in January, May and October




图 2 某流域 1、5、10 月来水流量曲线

Fig. 2 Waterflow in January, May and October

由图 1 和图 2 可知,来水流量曲线变化趋势具有一定的线性特征,且来水流量数据的方差和布林带宽度都远小于新能源出力数据,说明来水流量的变化相对平稳,而新能源出力具有更强的波动性。

该地区 1 月、5 月和 10 月的新能源出力、来水流量的 ACF 和 PACF 分别如图 3 和图 4 所示。由图 3 和图 4 可知,新能源出力 ACF 相对来水流量 ACF 具有更强的衰减趋势,说明随着时间间隔的增加,新能源出力数据的相关性显著下降。新能源数据的 PACF 在更短的时间间隔内下降到了显著性水平线以下,且在大部分时间间隔下都比来水流量的 PACF 更接近于 0,因此,新能源出力数据更接近随机状态。

综上,由于来水流量的随机性、波动性较弱,为降低计算成本,在进行来水流量预测模型训练时仅

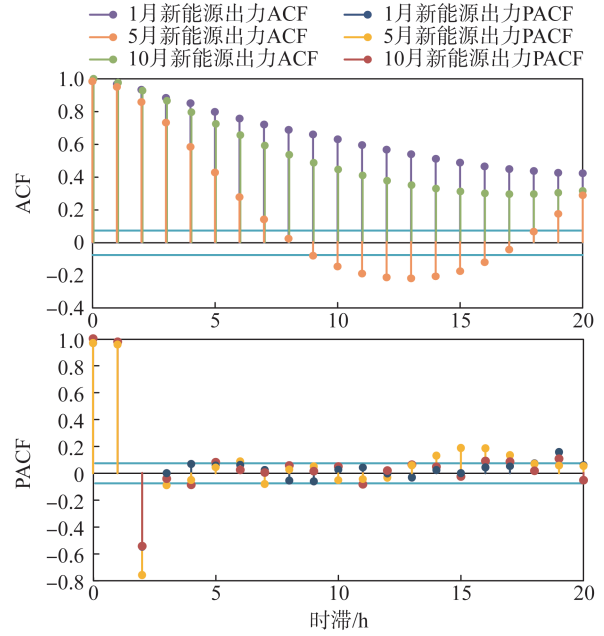


图 3 新能源出力 ACF 和 PACF

Fig. 3 ACF and PACF of renewable energy source

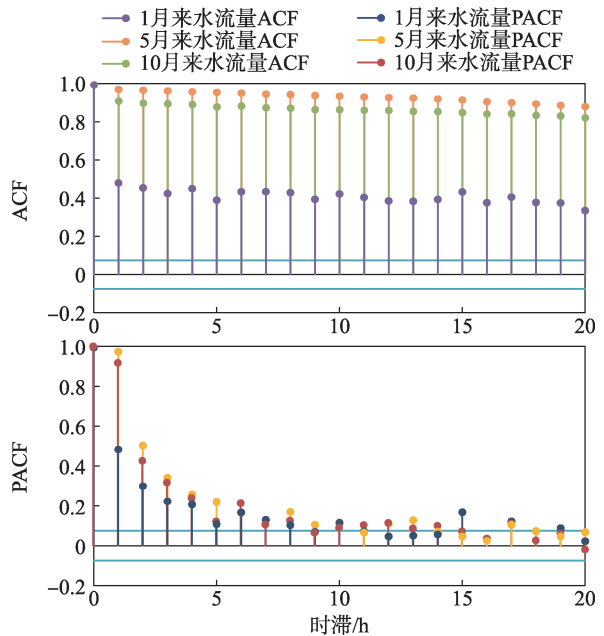


图 4 来水流量 ACF 和 PACF

Fig4 ACF and PACF of waterflows

采用  $L_2$  正则化进行处理;对于随机性、波动性较强的新能源出力,在训练预测模型时使用弹性网络正则化策略,在  $L_2$  正则化基础上增加  $L_1$  正则化项,增强模型的拟合性能。

图中各项指标计算方法如下:

1)方差。对于  $T$  个时段的数据  $\chi_1, \dots, \chi_i, \dots, \chi_T$ ,方差越大,数据的波动越大;反之,数据的波动越小。方差的计算公式如下:

$$\sigma^2 = \frac{1}{T} \sum_{i=1}^T (\chi_i - \mu)^2 \quad (32)$$

式中: $\mu$ 表示平均值。

2)布林带。布林带是一种基于标准差的波动性指标,其轨间宽度越大,表示数据的波动性越大。中轨线、标准差和上下轨线的计算方法分别为式(33)–(35)。

$$\mu = \frac{1}{T} \sum_{t=1}^T \chi_t \quad (33)$$

$$\sigma = \sqrt{\frac{1}{T} \sum_{t=1}^T (\chi_t - \mu)^2} \quad (34)$$

$$\bar{\mu} = \mu + \theta\sigma; \underline{\mu} = \mu - \theta\sigma \quad (35)$$

式中: $\theta$ 表示标准差的倍数,本文取为2; $\bar{\mu}$ 为上轨线; $\underline{\mu}$ 为下轨线。

3)ACF和PACF。对于时间序列数据,ACF和PACF是分析其相关性和随机性的有效方法。ACF及PACF的计算公式如下:

$$F_{AC}(\tau) = \frac{\sum_{t=1}^T (\chi_t - \mu)(\chi_{t+\tau} - \mu)}{\sum_{t=1}^T (\chi_t - \mu)^2} \quad (36)$$

$$F_{PAC}(\tau) = \frac{\text{cov}[(\chi_t - \hat{\chi}_t), (\chi_{t-\tau} - \hat{\chi}_{t-\tau})]}{\sqrt{\text{var}(\chi_t - \hat{\chi}_t)} \sqrt{\text{var}(\chi_{t-\tau} - \hat{\chi}_{t-\tau})}} \quad (37)$$

式中: $F_{AC}(\tau)$ 为自相关系数; $F_{PAC}(\tau)$ 为偏自相关系数; $\text{cov}$ 表示协方差运算; $\text{var}$ 表示方差运算; $\hat{\chi}_t$ 表示参数估计值。

## 2.4 闭环预测模型训练及实施流程

本文所提基于改进混合正则化的CPO框架包括三个步骤:1)基于历史数据,构建并求解基于SPO损失函数和弹性网络回归的经验风险最小化(empirical risk minimization, ERM)问题以训练成本导向的预测模型;2)基于训练后的预测模型,构建并求解预测-优化一体化的机组组合模型;3)结合机组组合优化结果及日内超短期来水、新能源预测出力求解经济调度模型,得到系统实际运行成本。下文将对该框架下预测模型的训练及两阶段调度实施流程展开介绍。

### 2.4.1 预测模型的训练

为了保证预测模型性能,应当保证用于训练的历史样本的预测曲线和真实曲线偏差处于平均水平,剔除历史运行数据中预测值和真实值偏差过大或过小的极端坏/好场景。对此,采用文献[28]提供的基于Wasserstein距离的样本集选取方法对历史样本进行二次筛选,具体不再赘述。

利用2.2节所提SPO损失函数(式(31))和正则化策略,在机组组合模型式(24)基础上构建ERM模型如下:

$$\begin{cases} \min_{\mathbf{W}^{\text{res}}, \mathbf{W}^{\text{hyd}}, \mathbf{x}_1, \dots, \mathbf{x}_{|H|}, \mathbf{y}_1, \dots, \mathbf{y}_{|H|}} \frac{1}{|H|} \sum_{h \in H} [f_{\text{loss}}^{\text{SPO}}(\hat{\mathbf{P}}_h^{\text{res}}, \tilde{\mathbf{P}}_h^{\text{res}}, \hat{\mathbf{I}}_h, \tilde{\mathbf{I}}_h)] + \\ \lambda_1^{\text{res}} \|\mathbf{W}^{\text{res}}\|_1 + \lambda_2^{\text{res}} \|\mathbf{W}^{\text{res}}\|_2^2 + \lambda^{\text{hyd}} \|\mathbf{W}^{\text{hyd}}\|_2^2 = \\ \min_{\mathbf{W}^{\text{res}}, \mathbf{W}^{\text{hyd}}, \mathbf{x}_1, \dots, \mathbf{x}_{|H|}, \mathbf{y}_1, \dots, \mathbf{y}_{|H|}} \frac{1}{|H|} \sum_{h \in H} \{ |(\mathbf{a}^T \mathbf{x}_h + \mathbf{b}^T \mathbf{y}_h) - z^*(\tilde{\mathbf{P}}_h^{\text{res}}, \tilde{\mathbf{I}}_h) | \} + \\ \lambda_1^{\text{res}} \|\mathbf{W}^{\text{res}}\|_1 + \lambda_2^{\text{res}} \|\mathbf{W}^{\text{res}}\|_2^2 + \lambda^{\text{hyd}} \|\mathbf{W}^{\text{hyd}}\|_2^2 \quad (38) \\ \text{s.t. } \mathbf{C}\mathbf{x}_h + \mathbf{D}\mathbf{y}_h + \mathbf{G}\mathbf{W}^{\text{hyd}} \mathbf{f}_h^{\text{hyd}} \leq \mathbf{s} \\ \mathbf{L}\mathbf{y}_h \leq \mathbf{W}^{\text{res}} \mathbf{f}_h^{\text{res}} \\ \mathbf{x}_h = [x_{h,1}, \dots, x_{h,E}] \in \{0, 1\} \end{cases}$$

式中: $H$ 为选取的训练样本集合; $\lambda^{\text{hyd}} \|\mathbf{W}^{\text{hyd}}\|_2^2$ 为 $\mathbf{W}^{\text{hyd}}$ 的 $L_2$ 正则化项; $\lambda_1^{\text{res}} \|\mathbf{W}^{\text{res}}\|_1 + \lambda_2^{\text{res}} \|\mathbf{W}^{\text{res}}\|_2^2$ 为 $\mathbf{W}^{\text{res}}$ 的弹性网络正则化项。2.2.1节中已提到, $z^*(\tilde{\mathbf{P}}_h^{\text{res}}, \tilde{\mathbf{I}}_h)$ 是用实际出力/来水数据求解式(24)得到的最优决策下的系统成本,因此,在式(38)中该项为已知常数项,为预测模型的训练提供目标基准值。

$L_1$ 正则化项 $\lambda_1^{\text{res}} \|\mathbf{W}^{\text{res}}\|_1$ 的计算方法如下:

$$\lambda_1^{\text{res}} \|\mathbf{W}^{\text{res}}\|_1 = \max_{c \in \{1, \dots, C^{\text{res}}\}} \sum_{r=1}^{R^{\text{res}}} \lambda_1^{\text{res}} |W_{r,c}^{\text{res}}| \quad (39)$$

式中: $R^{\text{res}}$ 和 $C^{\text{res}}$ 分别表示 $\mathbf{W}^{\text{res}}$ 的行数和列数; $W_{r,c}^{\text{res}}$ 表示 $\mathbf{W}^{\text{res}}$ 中第 $r$ 行第 $c$ 列元素。

引入辅助变量 $W'_{r,c}$ ,令 $W'_{r,c}$ 满足以下约束:

$$\begin{cases} W'_{r,c} \geq \lambda_1^{\text{res}} W_{r,c}^{\text{res}}; W'_{r,c} \geq -\lambda_1^{\text{res}} W_{r,c}^{\text{res}}; W'_{r,c} \geq 0 \\ \forall c \in \{1, \dots, C^{\text{res}}\}, r \in \{1, \dots, R^{\text{res}}\} \end{cases} \quad (40)$$

式(39)可以转换成如下形式:

$$\lambda_1^{\text{res}} \|\mathbf{W}^{\text{res}}\|_1 = \max_{c \in \{1, \dots, C^{\text{res}}\}} \sum_{r=1}^{R^{\text{res}}} W'_{r,c} \quad (41)$$

引入辅助变量 $W''_1$ ,令其满足:

$$W''_1 \geq \sum_{r=1}^{R^{\text{res}}} W'_{r,c} \quad \forall c \in \{1, \dots, C^{\text{res}}\} \quad (42)$$

则可以用 $W''_1$ 替代目标函数中的 $\lambda_1^{\text{res}} \|\mathbf{W}^{\text{res}}\|_1$ 以实现 $L_1$ 正则化项的线性化,同时将式(40)和式(42)加入至约束条件中。

$L_2$ 正则化项 $\lambda_2^{\text{res}} \|\mathbf{W}^{\text{res}}\|_2^2$ 和 $\lambda^{\text{hyd}} \|\mathbf{W}^{\text{hyd}}\|_2^2$ 可以由式(43)和式(44)表示:

$$\lambda_2^{\text{res}} \|\mathbf{W}^{\text{res}}\|_2^2 = \sum_{r=1}^{R^{\text{res}}} \sum_{c=1}^{C^{\text{res}}} \lambda_2^{\text{res}} W_{r,c}^{\text{res}2} \quad (43)$$

$$\lambda^{\text{hyd}} \|\mathbf{W}^{\text{hyd}}\|_2^2 = \sum_{r=1}^{R^{\text{hyd}}} \sum_{c=1}^{C^{\text{hyd}}} \lambda^{\text{hyd}} W_{r,c}^{\text{hyd}2} \quad (44)$$

可见,经过上述变换,原ERM模型变为为了一个混合整数二次规划(mixed integer quadratic programming, MIQP)问题,可以调用Gurobi求解器进行求解。该ERM模型的目标函数为最小化系统总成

本误差,求解的同时可以训练出以成本为导向的预测模型  $W^{res*}$ 、 $W^{hyd*}$ 。

综上,损失函数在模型训练过程中的具体计算步骤可以总结为:

1) 选取合适的训练样本集合  $H$ , 每个样本中包含新能源出力及来水流量的实际值  $\tilde{P}_h^{res}$  和  $\tilde{I}_h$ 、新能源和来水的特征数据  $f_h^{res}$  和  $f_h^{hyd}$ 。

2) 将样本数据中的  $\tilde{P}_h^{res}$  和  $\tilde{I}_h$  代入机组组合模型式(24)中,求解得假定预测值等于实际值时的最优系统总运行成本  $z^*(\tilde{P}_h^{res}, \tilde{I}_h)$ 。

3) 利用  $|H|$  组求得的最优系统总运行成本  $z^*(\tilde{P}_h^{res}, \tilde{I}_h)$  和特征数据  $f_h^{res}$  和  $f_h^{hyd}$  构建基于 SPO 损失函数的 ERM 模型(式(38)),并对  $L_1$  正则化项进行线性化处理。

4) 调用 Gurobi 求解器对 ERM 模型进行求解,实现能源出力预测模型  $W^{res*}$  和来水预测模型  $W^{hyd*}$  的训练。

#### 2.4.2 基于 CPO 框架的两阶段调度实施流程

将 2.3.1 节中训练得到的预测模型  $W^{res*}$ 、 $W^{hyd*}$  嵌入机组组合模型式(24)中,可以形成集预测、优化为一体的机组组合模型:

$$\begin{cases} z(f^{res}, f^{hyd}) = \min_{x, y} [a^T x + b^T y] \\ \text{s.t.} & Cx + Dy + GW^{hyd*} f^{hyd} \leq s \\ & Ly \leq W^{res*} f^{res} \\ & x = [x_1, \dots, x_E] \in \{0, 1\} \end{cases} \quad (45)$$

式中:  $z(f^{res}, f^{hyd})$  表示机组组合阶段的预期系统成本;  $f^{hyd}$  和  $f^{res}$  表示在日前阶段可获得的调度日的特征数据。由于式(24)中的新能源出力及来水预测由基于成本导向预测模型的预测结果替代,因此求解式(45)可以获得更具经济性的机组组合结果。

基于上述机组组合优化结果及日内超短期预测情况求解 1.2 节构建的经济调度模型,可以得到实际的系统总成本。

完整的 CPO 框架下的两阶段调度时序滚动实施方法如图 5 所示。

在图 5 中,滚动优化流程以 7 天为 1 个调度周期,每个调度周期结束后重新训练一次预测模型。当前调度周期第 1 天的前 7 天为用于训练预测模型的历史周期,为预测模型的训练提供输入数据。首先,在历史周期一中选取合适的历史场景作为第 1 次训练的数据集,建立 ERM 模型式(38)并求解,可得调度周期一的预测模型  $W_{1st}^{res}$  和  $W_{1st}^{hyd}$ 。在调度周期一中每一天的日前,将可获得的相关特征数据  $f^{res}$  和  $f^{hyd}$  输入机组组合模型式(45)中,可以获得每天的 24 h 日前机

组调度计划及预期系统成本  $z^*(f^{res}, f^{hyd})$ 。根据日内新能源出力及来水流量的超短期预测值求解经济调度模型,可得日内调度计划及实际系统总成本  $z^{ED*}(\hat{P}_h^{res}, \hat{I}_h)$ 。当调度周期一结束后,调度周期一的相关数据将作为历史周期二的数据,为调度周期二的预测模型的训练提供样本数据,通过训练可获得更新后的预测模型  $W_{2st}^{res}$  和  $W_{2st}^{hyd}$ 。

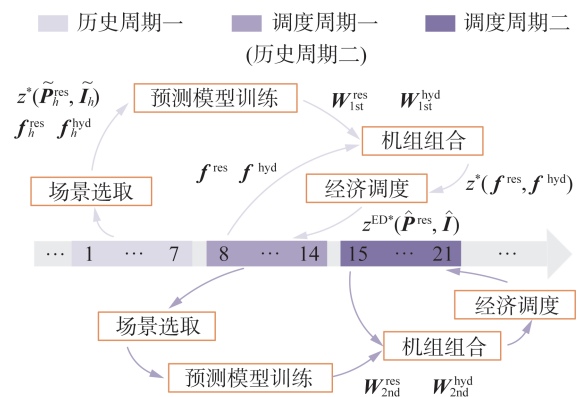


图 5 基于 CPO 的两阶段调度滚动实施时序示意图

Fig. 5 Rolling implementation sequence diagram of the two-stage scheduling based on CPO

整体算法流程图如附录 A 图 A1 所示。图 5 中历史周期一(第 1—7 天)的数据即为图 A1 中步骤①的输入数据。输入样本数据后,由步骤②至④完成基于 SPO 损失函数的 ERM 模型构建,其中步骤③得到的  $z^*(\tilde{P}_h^{res}, \tilde{I}_h)$  将作为常数代入步骤④中,调用 Gurobi 求解步骤④中的 ERM 模型可以实现预测模型的训练。通过步骤⑤得到式(45)后,对图 5 中调度周期一(第 8—14 天)内的每一天实施图 A1 中“周期内第  $d$  天前”和“第  $d$  天内”两个阶段的相关步骤(步骤⑥至⑧)。在调度周期一结束后输出周期内的相关数据,作为调度周期二(第 15—21 天)步骤①的输入数据。

### 3 算例分析

#### 3.1 算例介绍

本文算例在改进的 IEEE RTS 24 节点系统上进行,如图 6 所示,三个风电场由 1 节点、15 节点、18 节点接入系统,两个光伏电站由 10 节点、21 节点接入系统,含 6 个小水电的混联小水电群由 22 节点接入系统。算例中负荷、新能源出力数据由某地区实际数据经缩放得到,水电站来水数据由 6 个水电站的历史来水量经过一定比例的缩放得到。系统中各类机组装机容量及水电站基本参数如表 1 和表 2 所示。由表 1 可知,该系统是高清洁能源占比的电力系统,小水电群作为辅助手段同火电机组一起为风光提供互

补灵活性资源。本文将弃风弃光惩罚设为 390 元/MWh,弃水电量惩罚设为 200 元/MWh。仿真算例在 MATLAB R2018a 平台上采用 yalmip 工具箱编程,并调用 Gurobi 10.0.1 求解。硬件平台为 Win 11 系统, Intel Core i7-11370H 处理器,3.30 GHz 主频,16 GB 内存的计算机。

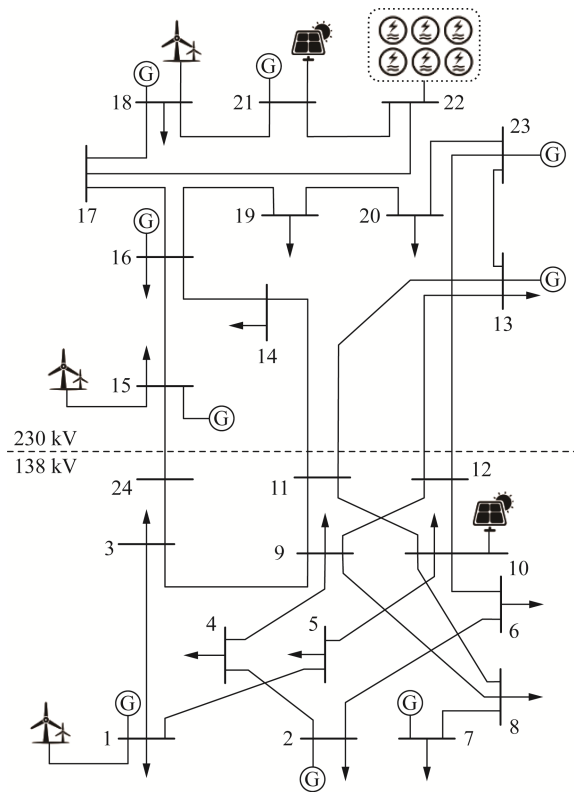


图 6 改进的 IEEE RTS 24 节点系统图

Fig. 6 The modified IEEE RTS 24-bus system

表 1 改进 IEEE RTS 24 节点系统机组装机容量

Table 1 Modified IEEE 24-bus system generator capacity

机组类型	总装机容量/MW	接入节点	占比/%
火电机组	3105	1,2,7,13,15,16,18,21,23	49
风电	1536	1,15,18	24
光伏	1397	10,21	22
水电	300	22	5

表 2 水电站基本参数

Table 2 Characteristics of hydropower plants

水电站编号	调节库容/万 m <sup>3</sup>	装机容量/MW	$\varphi_n$
1	977	60	0.178 3
2	390	50	0.244 7
3	597	50	0.345 7
4	420	50	0.747 5
5	500	50	0.316 0
6	308	40	0.562 7

### 3.2 仿真结果分析

#### 3.2.1 实验场景与参数设置

分别使用本文所提改进 CPO 框架的两阶段调度方法和传统 OPO 方法对该系统 1 月、5 月和 10 月的电力调度问题进行滚动优化。该系统 1 月处于枯水期,5 月处于丰水期,10 月处于平水期,且 1 月、5 月和 10 月的清洁能源平均出力占比约为 36%、54% 和 46%。

ERM 模型(式(38))中新能源预测模型  $W^{res}$  的弹性网络正则化参数  $\lambda_1^{res}$  和  $\lambda_2^{res}$  满足如下关系:

$$\lambda_1^{res} = \alpha\lambda; \lambda_2^{res} = (1 - \alpha)\lambda \quad (46)$$

式中: $\alpha$  为混合参数且  $\alpha \in [0, 1]$ ,控制  $L_1$  和  $L_2$  正则化的比例; $\lambda$  为总体正则化强度,控制弹性网络正则化项的整体大小。采用网格搜索<sup>[31]</sup>对  $\alpha$ 、 $\lambda$  及来水预测模型  $W^{hyd}$  的正则化项  $\lambda^{hyd}$  进行参数优选,过程如下:

1) 根据实验设定  $\lambda$  和  $\lambda^{hyd}$  的搜索范围分别为  $\{10^4, 10^5, 10^6\}$ 、 $\{10^3, 10^4, 10^5\}$ 。以  $L_1$  正则化为主导以保证  $W^{res}$  的稀疏性,设定  $\alpha$  的搜索范围为  $\{0.7, 0.8, 0.9\}$ 。

2) 对各参数组合下系统 1、5、10 月各天的两阶段调度模型进行求解,得到的平均实际系统总运行成本结果见附录 B 表 B1。

3) 选取成本最低的参数组合为最优参数组合。由附录 B 表 B1 可知,当  $\alpha = 0.8$ 、 $\lambda = 10^5$ 、 $\lambda^{hyd} = 10^4$  时成本最低,因此本文算例均采用该参数组合进行仿真。

此外,还可以使用自动机器学习(automated machine learning, AutoML)技术<sup>[32]</sup>实现上述参数的自动调优。

#### 3.2.2 系统月平均运行成本分析

该系统 1 月的平均成本信息如表 3 所示,表中成本数据均由月总成本除以该月天数得到。该系统 5 月的平均成本信息如表 4 所示。该系统 10 月的平均成本信息如表 5 所示。

表 3 系统 1 月平均成本

Table 3 Average costs over January 万元

方法	机组组合		经济调度		弃水风光成本	月平均实际系统成本
	启停成本	预期系统成本	冷备用成本	发电成本		
CPO	17.87	332.19	13.10	325.82	0.12	356.91
OPO	17.71	309.85	24.35	316.76	0.11	358.93

表 3 对使用本文基于改进 CPO 框架的两阶段调度方法与传统 OPO 方法在 1 月的系统平均成本进行了比较。数据显示,CPO 方法在机组组合阶段的启停成本为 17.87 万元,预期系统成本为 332.19 万元,均

表 4 系统 5 月平均成本

Table 4 Average costs over May 万元

方法	机组组合		经济调度		弃水风光成本	月平均实际系统成本
	启停成本	预期系统成本	冷备用成本	发电成本		
CPO	14.26	149.31	10.71	142.85	11.43	179.25
OPO	14.11	146.32	15.70	141.29	9.49	180.59

表 5 系统 10 月平均成本

Table 5 Average costs over October 万元

方法	机组组合		经济调度		弃水风光成本	月平均实际系统成本
	启停成本	预期系统成本	冷备用成本	发电成本		
CPO	16.28	221.14	15.49	209.56	5.93	247.26
OPO	16.14	200.45	23.35	204.74	4.68	248.91

高于 OPO 方法。可见 CPO 方法在日前会启用更多发电机组来应对日内水风光及负荷的波动。由于 CPO 方法中多启用的部分机组未得到充分利用,在经济调度阶段, CPO 方法发电成本为 325.82 万元,高于 OPO 方法的 316.76 万元。然而, CPO 方法的冷备用成本比 OPO 方法低 11.25 万元,导致其月平均实际系统成本比 OPO 方法低 2.02 万元。因此, CPO 方法在应对水风光的波动时能更灵活地调整出力计划,可以减少冷备用资源的利用。

表 4、表 5 中 5 月和 10 月的优化结果同样表明,采用 CPO 方法得到的月平均实际系统成本要低于 OPO 方法。其中, 5 月 CPO 方法的月平均实际系统成本比 OPO 方法低 1.34 万元, 10 月 CPO 方法的月平均实际系统成本比 OPO 方法低 1.65 万元。

为进一步从源荷协调角度说明方法原理,图 7 给出了三个测试月份的负荷曲线。结合图 1、图 2 和图 7 可知,系统成本与负荷水平和水风光资源量息息相关,负荷水平越低、水风光资源越丰富,则系统运行成本越低。此外,系统 1 月、5 月及 10 月采用 CPO 方法的月平均弃水风光成本都要略高于 OPO 方法,这是因为 CPO 方案的预测结果更加保守,系统启用了更多的火电机组保障出力,为避免昂贵的停机成本,导致部分水风光资源无法消纳,出现弃水风光电量。

由表 3 至表 5 中的月平均实际系统成本数据可知, 1 月、5 月和 10 月 CPO 方法较 OPO 方法的月平均实际系统成本分别下降了 0.57%、0.74% 和 0.66%。为进一步分析新能源出力及来水流量波动强度对上述系统成本结果的影响,结合 1 月(枯水期)、5 月(丰水期)和 10 月(平水期)新能源出力及来水流量数据的波动强度验证 CPO 方法在不确定性场景下的适应性。




图 7 系统 1 月、5 月、10 月负荷曲线

Fig. 7 System load in January, May and October

表 6 记录了 1 月、5 月和 10 月实际新能源出力和水电来水曲线的波动特性(包括方差和布林带宽度),以及 CPO 方法较 OPO 方法的系统成本下降百分比。具体而言,新能源出力数据 1 月、5 月和 10 月的方差分别为 161 628 MW<sup>2</sup>、226 500 MW<sup>2</sup>和 183 870 MW<sup>2</sup>,布林带宽度分别为 1608 MW、1903 MW 和 1715 MW;来水流量数据 1 月、5 月和 10 月的方差分别为 69 (m<sup>3</sup>/s)<sup>2</sup>、9241 (m<sup>3</sup>/s)<sup>2</sup>和 1016 (m<sup>3</sup>/s)<sup>2</sup>,布林带宽度分别为 33 m<sup>3</sup>/s、384 m<sup>3</sup>/s 和 127 m<sup>3</sup>/s。

表 6 新能源及来水波动强度对决策结果的影响

Table 6 Impact of fluctuation intensities of renewable energy source and waterflow on results

月份	方差(新能源出力)/MW <sup>2</sup>	方差(来水流量)/(m <sup>3</sup> /s) <sup>2</sup>	布林带宽度(新能源出力)/MW	布林带宽度(来水流量)/(m <sup>3</sup> /s)	CPO 较 OPO 成本下降/%
1	161 628	69	1608	33	0.57
5	226 500	9241	1903	384	0.74
10	183 870	1016	1715	127	0.66

可见, 5 月新能源出力及来水流量的波动强度显著高于 1 月和 10 月,且 CPO 方法在波动更强的 5 月成本下降幅度更大。因此,本文所提 CPO 方法在不确定性程度更高的场景下提升经济性的效果更为显著。

### 3.2.3 预测准确性分析

表 7 和表 8 分别比较了 CPO 方法和 OPO 方法下新能源出力预测和来水流量预测的误差。其中,平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE)用于评估预测结果的准确性,MAE 和 RMSE 数值越小,说明预测结果的准确度越高;平均过预测百分比误差(mean over prediction error, MOPE)和平均欠预测百分比误差(mean under prediction error, MUPE)<sup>[28]</sup>分别体现预测结果偏高和偏低时与实际值的偏离程度。以新能源出力预测为例,其 MAE、RMSE、MOPE 和 MUPE 分别用式(47)~(50)计算:

$$E_{MA} = \frac{1}{T} \sum_{t=1}^T |\hat{P}_t^{\text{res}} - \hat{P}_t^{\text{res}}| \quad (47)$$

$$E_{RMS} = \sqrt{\frac{1}{T} \sum_{t=1}^T (\tilde{P}_t^{res} - \hat{P}_t^{res})^2} \quad (48)$$

$$E_{MO} = \frac{1}{T} \sum_{t=1}^T \max \{0, \tilde{P}_t^{res} - \hat{P}_t^{res}\} \times 100\% \quad (49)$$

$$E_{MU} = \frac{1}{T} \sum_{t=1}^T \max \{0, \hat{P}_t^{res} - \tilde{P}_t^{res}\} \times 100\% \quad (50)$$

式中: $E_{MA}$ 为平均绝对误差; $E_{RMS}$ 为均方根误差; $E_{MO}$ 为平均过预测百分比误差; $E_{MU}$ 为平均欠预测百分比误差。

表 7 新能源预测误差

Table 7 Renewable energy source prediction errors

月份	方法	MAE/ MW	RMSE/ MW	MOPE/%	MUPE/%
1月	CPO	25.4	46.5	22.2	26.2
	OPO	21.2	42.4	28.8	16.9
5月	CPO	24.7	48.0	21.4	22.9
	OPO	22.5	44.2	28.1	15.8
10月	CPO	28.0	52.0	21.2	19.5
	OPO	24.0	45.6	27.8	14.2

由表 7 和表 8 可知,1月、5月、10月 CPO 方法下新能源出力和来水预测结果的 MOPE 都低于 OPO 方法,且 MUPE 都高于 OPO 方法。因此,CPO 方法更倾向于引导预测误差向欠预测方向偏移,从而在日前调度计划中增加火电机组的启用,以降低系统在日内阶段因新能源和来水不确定性所导致的调

表 8 来水流量预测误差

Table 8 Waterflow prediction errors

月份	方法	MAE/ (m <sup>3</sup> /s)	RMSE/ (m <sup>3</sup> /s)	MOPE/%	MUPE/%
1月	CPO	6.9	9.3	2.7	7.0
	OPO	4.8	6.1	4.8	2.0
5月	CPO	44.0	55.7	3.1	6.7
	OPO	9.8	13.1	23.8	2.6
10月	CPO	54.0	70.5	4.0	9.8
	OPO	10.5	13.5	11.3	4.5

整成本。尽管 CPO 方法的整体预测精度较 OPO 方法有所下降,但 3.2.1 节的成本分析结果表明,这种精度损失并未影响优化效果,反而提升了调度经济性。

### 3.2.4 典型日结果分析

为分析两种预测优化方法在枯水期、丰水期与平水期的表现,选取 1 月 19 日、5 月 2 日、10 月 23 日分别作为枯水期、丰水期、平水期的典型日,对这三天的 CPO、OPO 结果进行对比分析。表 9 比较了这三天的系统成本数据及 CPO 与 OPO 方法预测结果的 MAE。就 1 月 19 日的数据而言,CPO 方法的实际系统成本低于 OPO 方法,新能源出力预测的精度高于 OPO 方法,但在来水量预测精度方面略逊于 OPO 方法;而在 5 月 2 日和 10 月 23 日,CPO 方法在实际系统成本、新能源出力预测精度、来水量预测精度方面的结果都优于 OPO 方法。

表 9 1月19日、5月2日和10月23日结果比较

Table 9 Comparisons of 01-19, 05-02 and 10-23

日期	方法	成本/万元				MAE		
		启停成本	冷备用成本	发电成本	惩罚成本	典型日实际系统成本	新能源出力/ MW	来水流量/ (m <sup>3</sup> /s)
01-19	CPO	17.33	21.79	237.66	0.04	276.82	19.1	7.4
	OPO	17.33	31.76	237.87	0.03	286.99	24.0	7.2
05-02	CPO	15.23	15.75	102.33	1.30	134.61	34.8	30.0
	OPO	11.81	26.51	104.03	1.21	143.56	36.2	42.0
10-23	CPO	19.22	22.31	270.91	0.03	312.47	55.6	19.9
	OPO	19.76	35.15	276.86	0.01	331.78	163.9	32.8

图 8 描述了系统 1 月 19 日日前优化调度结果。图 9 和图 10 分别描述了两种方法相较实际值的预测效果及在经济调度中冷热备用的利用情况。

由图 8 可知,在日前机组组合阶段初步制定的调度计划中,CPO 方法在 24 个时段都较 OPO 方法部署了更多的火电机组容量。结合图 9 可知,这主要由于所有时段 CPO 方法的新能源出力与来水流量预测结

果均低于 OPO 方法。除此之外,CPO 方法在图 9 中紫色阴影覆盖的 20 个时段内,新能源出力预测精度更高,在橙色阴影的 9 个时段内,来水流量预测精度亦优于 OPO 方法。表 9 显示,在机组组合阶段,两种方法启停成本相同(17.33 万元),但 CPO 方法的实际系统成本较 OPO 低 10.17 万元。结合图 10 可知,这是因为 OPO 方法在 23 个时段内都使用了更多的冷备

用,导致其冷备用成本显著上升。综上,尽管该日CPO方法在部分时段来水预测精度略低,但整体经济性更优,且新能源预测精度甚至优于OPO方法。




图8 系统1月19日日前优化调度结果

Fig. 8 Day-ahead optimized scheduling results of the system on January 19th




图9 系统1月19日新能源出力及来水量实际值与预测值

Fig. 9 Predictions and actual realization of RES power and waterflow on January 19th




图10 系统1月19日经济调度中系统备用利用情况

Fig. 10 Reserve deployment in the redispatch problem on January 19th

图11描述了系统5月2日日前优化调度结果。图12和图13分别描述了该日两种方法相较实际值的预测效果及在经济调度中冷热备用的利用情况。

由图11可知,系统在5月2日水风光发电占比较高,因而该日两种方法下的系统成本都远低于月平均水平。图12显示,在新能源曲线紫色阴影时段及来水曲线橙色阴影时段,CPO方法的预测精度都要更高。来水流量预测除05:00—07:00、09:00、12:00、21:00时段外,CPO预测结果均偏向欠预测,促使日前调度阶段启用更多火电机组支撑负荷,导致机组




图11 系统5月2日日前优化调度结果

Fig. 11 Day-ahead optimized scheduling results of the system on May 2nd

组合启停成本高于OPO方法。然而,如图13所示,OPO方法在阴影时段过预测的程度更大,经济调度阶段需调用更多冷备用资源,导致其冷备用成本较CPO方法高10.76万元,最终实际系统成本高出8.95万元。综上,本文方法在该日有效平衡了预测准确性与经济性。




图12 系统5月2日新能源出力及来水量实际值与预测值

Fig. 12 Predictions and actual realization of RES power and waterflow on May 2nd




图13 系统5月2日经济调度中系统备用利用情况

Fig. 13 Reserve deployment in the redispatch problem on May 2nd

图14描述了系统10月23日日前优化调度结果。图15和图16分别描述了10月23日两种方法相较实际值的预测效果及在经济调度中冷热备用的利用情况。

由图14可知,该系统在10月23日主要依靠火电出力来支撑负荷,使得该日两种方法下的系统成本都远高于月平均水平。图15表明,该日OPO方法在所有时段的新能源出力预测及来水预测都出现了较




图 14 系统 10 月 23 日日前优化调度结果

Fig. 14 Day-ahead optimized scheduling results of the system on October 23rd

大程度的过预测,其所有时段的新能源预测及橙色时段的来水预测准确度都低于 CPO 方法。结合图 16 可知,该日 OPO 方法下的日前预测过于乐观,其在 15 个时段都调用了 10% 以上的非旋转备用容量,导致该日 OPO 方法的冷备用成本高达 35.15 万元。综上,CPO 方法因其较为保守的预测策略在一定程度上修正了 OPO 方法的过预测,其预测准确性与经济性都优于 OPO 方法。




图 15 系统 10 月 23 日新能源出力及来水量实际值与预测值

Fig. 15 Predictions and actual realization of RES power and waterflow on October 23rd




图 16 系统 10 月 23 日经济调度中系统备用利用情况

Fig. 16 Reserve deployment in the redispatch problem on October 23rd

### 3.3 计算时间讨论

本文所采用的 CPO 方法基于确定性优化框架,与鲁棒、随机优化相比,其优势在于避免了因引入额外决策变量和约束而导致的计算复杂度显著增加。具体而言,若系统新能源、水电和线路数分别为  $J$ 、 $N$

和  $L$ ,采用鲁棒优化<sup>[33]</sup>并选取  $\gamma$  个鲁棒场景,相较于确定性优化,大约增加  $(4J + 11N + 2L)(\gamma - 1)$  个约束及  $(2J + 4N)(\gamma - 1)$  个变量;若采用随机优化<sup>[34]</sup>并设定场景数为  $\xi$ ,相较于确定性优化,约增加  $(4J + 11N + 2L)(\xi - 1) + 1$  个约束及  $(2J + 4N)(\xi - 1) + \xi$  个变量。为进一步验证 CPO 方法的计算效率,在表 10 中对比了 CPO 方法、OPO 方法、传统鲁棒优化和随机优化在 1 月 19 日、5 月 2 日和 10 月 23 日的计算时间,其中,鲁棒优化选定 16 个场景<sup>[33]</sup>,随机优化场景数为 100。

表 10 不同优化方法计算时间比较  
Table 10 Computation time comparison of optimization methods

日期	计算时间/s			
	CPO	OPO	鲁棒优化	随机优化
01-19	3.49	3.65	18.71	73.89
05-02	5.03	5.29	26.32	107.08
10-23	2.98	3.12	17.89	63.16

由于 CPO 与 OPO 方法均为确定性优化,计算复杂度相近,因此两者计算时间差异较小。但相比鲁棒优化和随机优化,CPO 方法在计算时间上具有明显优势。鲁棒优化和随机优化均需引入额外的决策变量和约束以刻画不确定性,导致计算时间显著增加,计算复杂度远超确定性优化,在实际系统中难以部署。此外,因随机优化需大量场景样本支撑来获得有效的统计信息<sup>[35]</sup>,其计算负担最大<sup>[36]</sup>,求解时间最长。

虽然 CPO 方法和 OPO 方法的计算时间相差不大,但由 3.2 节可知,CPO 方法下的实际系统成本更低。上述结果体现了 CPO 方法在复杂电力系统优化调度中的应用价值。

## 4 结论

本文在考虑水风光资源的波动性、季节性基础上,提出一种基于改进 CPO 框架的含水风光电力系统两阶段调度方法。考虑串、并、混联多类小水电群构建了含水风光电力系统两阶段调度模型;基于 SPO 损失函数,构建 ERM 问题以训练经济导向的水风光预测模型,并结合方差、布林带和自相关函数量化的新能源出力及水电站入库流量波动强度,制定了融入弹性网络回归的混合正则化策略;基于 CPO 框架,介绍了两阶段调度模型的实施流程,并结合算例分析了其效果。

1) 本文所提的改进 CPO 方法在总体预测精度下

降不大且部分时段精度提升的情况下,显著降低了系统实际运行成本。

2)在1月、5月和10月算例场景中,使用本文CPO方法较OPO方法的月平均实际系统成本分别下降了0.57%、0.74%和0.66%,可见在不确定性程度更大的场景下本文CPO方法提升经济性的效果更为显著。

### 致谢

陈贤邦博士在本文模型构建方面提出了指导性意见,谨此深表感谢。

### 利益冲突声明(Conflict of Interests):

所有作者声明不存在利益冲突。

### 作者贡献声明(Authors' Contributions):

刘继春设计研究方案,进行研究方案可行性调查分析;肖煜瑾实施研究过程,进行实验分析,参与论文写作和修订;邱高设计论文的基本框架,参与撰写论文;孙毅、唐伦、李凌昊参与论文写作、修订及审核。所有作者均阅读并同意了论文终稿内容。

## 5 参考文献

- [1] 陈国平,董昱,梁志峰. 能源转型中的中国特色新能源高质量发展分析与思考[J]. 中国电机工程学报, 2020, 40(17): 5493-5506.  
CHEN Guoping, DONG Yu, LIANG Zhifeng. Analysis and reflection on high-quality development of new energy with Chinese characteristics in energy transition [J]. Proceedings of the CSEE, 2020, 40(17): 5493-5506.
- [2] 李建林,丁子洋,游洪灏,等. 构网型储能支撑新型电力系统稳定运行研究[J]. 高压电器, 2023, 59(7): 1-11.  
LI Jianlin, DING Ziyang, YOU Honghao, et al. Research on stable operation of new power system supported by grid-forming energy storage system[J]. High Voltage Apparatus, 2023, 59(7): 1-11.
- [3] 赵毅,陈雨婷,孙文瑶. 多微网配电系统区间调度方法与市场交易策略研究[J]. 电网技术, 2022, 46(1): 47-56.  
ZHAO Yi, CHEN Yuting, SUN Wenyao. Region dispatch method and market trading strategy for multi-microgrid distribution system [J]. Power System Technology, 2022, 46(1): 47-56.
- [4] 李伟,韩瑞迪,孙晨家,等. 基于用电偏好的可平移负荷参与需求响应最优激励合同与激励策略[J]. 中国电机工程学报, 2021, 41(S1): 185-193.  
LI Wei, HAN Ruidi, SUN Chenjia, et al. Optimal incentive contract and incentive strategy of translatable load participating in demand response based on power consumption preference [J]. Proceedings of the CSEE, 2021, 41(S1): 185-193.
- [5] 郭红霞,陈凌轩,张启,等. 电力电量平衡视角下新型电力系统极端场景研究及应对综述[J]. 电网技术, 2024, 48(10): 3975-3994.  
GUO Hongxia, CHEN Lingxuan, ZHANG Qi, et al. Research and response to extreme scenarios in new power system: a review from perspective of electricity and power balance [J]. Power System Technology, 2024, 48(10): 3975-3994.
- [6] 黄河,王建学,肖云鹏,等. 新型电力系统电力电量平衡分析关键技术与研究框架[J]. 电力建设, 2024, 45(9): 1-12.  
HUANG He, WANG Jianxue, XIAO Yunpeng, et al. Key technologies and research framework for the power and energy balance analysis in new-type power systems [J]. Electric Power Construction, 2024, 45(9): 1-12.
- [7] 陈皇森,石立宝. 考虑多风电场出力预测误差分布特征的随机机组组合[J]. 电网技术, 2023, 47(12): 5026-5040.  
CHEN Huangsen, SHI Libao. Stochastic unit commitment considering output forecast error distribution characteristics of multiple wind farms [J]. Power System Technology, 2023, 47(12): 5026-5040.
- [8] VELLOSO A, STREET A, POZO D, et al. Two-stage robust unit commitment for co-optimized electricity markets: an adaptive data-driven approach for scenario-based uncertainty sets [J]. IEEE Transactions on Sustainable Energy, 2020, 11(2): 958-969.
- [9] 朱继忠,董瀚江,李盛林,等. 基于分布式新能源集群的微电网优化调度综述[J]. 中国电机工程学报, 2024, 44(20): 7952-7970.  
ZHU Jizhong, DONG Hanjiang, LI Shenglin, et al. Review of optimal dispatching for the aggregation of micro-energy grids based on distributed new energy [J]. Proceedings of the CSEE, 2024, 44(20): 7952-7970.
- [10] 李嘉森,王进,杨蒙,等. 基于随机优化的虚拟电厂热电联合经济优化调度[J]. 太阳能学报, 2023, 44(9): 57-65.  
LI Jiasen, WANG Jin, YANG Meng, et al. Combined heat and power economic optimal dispatching in virtual power plant based on stochastic optimization [J]. Acta Energetica Sinica, 2023, 44(9): 57-65.
- [11] 王海伦,丁一凡,李杨,等. 计及混合式抽水蓄能改造的清洁微网分布鲁棒容量优化配置[J]. 电工技术学报, 2025, 40(7): 2112-2126.  
WANG Hailun, DING Yifan, LI Yang, et al. Distributionally robust capacity optimization for clean energy microgrid considering pumped-storage retrofitting [J]. Transactions of China Electrotechnical Society, 2025, 40(7): 2112-2126.
- [12] 刘亚鑫,蔺红,马越,等. 考虑分时碳价的虚拟电厂分布鲁棒竞标方法[J]. 电测与仪表, 2024, 61(8): 12-19.  
LIU Yaxin, LIN Hong, MA Yue, et al. Distributionally robust bidding method for virtual power plant considering time-of-use carbon price [J]. Electrical Measurement & Instrumentation, 2024, 61(8): 12-19.
- [13] 张亚超,刘开培,秦亮,等. 基于聚类经验模态分解-样本熵和优化极限学习机的风电功率多步区间预测[J]. 电网技术, 2016, 40(7): 2045-2051.  
ZHANG Yachao, LIU Kaipei, QIN Liang, et al. Wind power multi-step interval prediction based on ensemble empirical mode decomposition-sample entropy and optimized extreme learning machine [J]. Power System Technology, 2016, 40(7): 2045-2051.
- [14] 黎敏,林湘宁,张哲原,等. 超短期光伏出力区间预测算法及其应用[J]. 电力系统自动化, 2019, 43(3): 10-16.  
LI Min, LIN Xiangning, ZHANG Zheyuan, et al. Interval prediction algorithm for ultra-short-term photovoltaic output and its application [J]. Automation of Electric Power Systems, 2019, 43(3): 10-16.
- [15] 何常新,彭旭,方福东,等. 基于LASSO回归和QRLSTM的来

- 水预测方法研究[J]. 人民长江, 2024, 55(11): 138-145, 165.
- HE Changxin, PENG Xu, FANG Fudong, et al. Research on river inflow prediction method based on LASSO regression and QRLSTM [J]. Yangtze River, 2024, 55(11): 138-145, 165.
- [16] 黄晟, 潘丽君, 屈尹鹏, 等. 基于改进深度Q网络的无预测风电场日前拓扑优化[J]. 电力系统自动化, 2025, 49(2): 122-132.
- HUANG Sheng, PAN Lijun, QU Yinpeng, et al. Day-ahead topology optimization for wind farm without forecasting based on improved deep Q network [J]. Automation of Electric Power Systems, 2025, 49(2): 122-132.
- [17] BADESA L, TENG F, STRBAC G. Economic value of inertia in low-carbon power systems [C]//2017 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe). IEEE, 2017: 1-6.
- [18] WANG Y M, WU L. Improving economic values of day-ahead load forecasts to real-time power system operations[J]. IET Generation, Transmission & Distribution, 2017, 11(17): 4238-4247.
- [19] GUO Y X, XU Y P, XIE J K, et al. A weights combined model for middle and long-term streamflow forecasts and its value to hydropower maximization [J]. Journal of Hydrology, 2021, 602: 126794.
- [20] LEE D, NG J Y, GALELLI S, et al. Unfolding the relationship between seasonal forecast skill and value in hydropower production: a global analysis[J]. Hydrology and Earth System Sciences, 2022, 26(9): 2431-2448.
- [21] SHU X S, DING W, PENG Y, et al. Value of long-term inflow forecast for hydropower operation: a case study in a low forecast precision region[J]. Energy, 2024, 298: 131218.
- [22] VANDERSCHUEREN T, VERDONCK T, BAESSENS B, et al. Predict-then-optimize or predict-and-optimize? An empirical evaluation of cost-sensitive learning strategies [J]. Information Sciences, 2022, 594: 400-415.
- [23] ELMACHTOUB A N, GRIGAS P. Smart "predict, then optimize" [J]. Management Science, 2022, 68(1): 9-26.
- [24] BERTSIMAS D, VAN PARYS B. Bootstrap robust prescriptive analytics[J]. Mathematical Programming, 2022, 195(1): 39-78.
- [25] 赵长飞. 新能源电力系统概率预测-决策一体化研究[D]. 杭州: 浙江大学, 2022.
- ZHAO Changfei. Research on integration of probability prediction and decision-making in new energy power system [D]. Hangzhou: Zhejiang University, 2022.
- [26] LI G, CHIANG H D. Toward cost-oriented forecasting of wind power generation [J]. IEEE Transactions on Smart Grid, 2018, 9(4): 2508-2517.
- [27] STRATIGAKOS A, CAMAL S, MICHIORRI A, et al. Prescriptive trees for integrated forecasting and optimization applied in trading of renewable energy [J]. IEEE Transactions on Power Systems, 2022, 37(6): 4696-4708.
- [28] CHEN X B, YANG Y F, LIU Y K, et al. Feature-driven economic improvement for network-constrained unit commitment: a closed-loop predict-and-optimize framework [J]. IEEE Transactions on Power Systems, 2022, 37(4): 3104-3118.
- [29] CARRION M, ARROYO J M. A computationally efficient mixed-integer linear formulation for the thermal unit commitment problem [J]. IEEE Transactions on Power Systems, 2006, 21(3): 1371-1378.
- [30] BELTRÁN F, DE OLIVEIRA W, FINARDI E C. Application of scenario tree reduction via quadratic process to medium-term hydrothermal scheduling problem [J]. IEEE Transactions on Power Systems, 2017, 32(6): 4351-4361.
- [31] 加鹤萍, 郭宇辰, 马乾鑫, 等. 基于机器学习方法的现货电价预测研究综述[J]. 电力建设, 2025, 46(2): 160-179.
- JIA Heping, GUO Yuchen, MA Qianxin, et al. Review of spot electricity price prediction studies based on machine learning methods [J]. Electric Power Construction, 2025, 46(2): 160-179.
- [32] MALLIK N, BERGMAN E, HVARFNER C, et al. PriorBand: practical hyperparameter optimization in the age of deep learning [EB/OL]. (2023-11-15) [2025-03-05]. <https://doi.org/10.48550/arXiv.2306.12370>.
- [33] XU Y, YIN M H, DONG Z Y, et al. Robust dispatch of high wind power-penetrated power systems against transient instability [J]. IEEE Transactions on Power Systems, 2018, 33(1): 174-186.
- [34] XU Y J, KORKALI M, MILI L, et al. An iterative response-surface-based approach for chance-constrained AC optimal power flow considering dependent uncertainty [J]. IEEE Transactions on Smart Grid, 2021, 12(3): 2696-2707.
- [35] 侯慧, 甘铭, 吴细秀, 等. 考虑移动氢能存储的港口多能微网两阶段分布鲁棒优化调度[J]. 中国电机工程学报, 2024, 44(8): 3078-3093.
- HOU Hui, GAN Ming, WU Xixiu, et al. Two-stage distributionally robust optimal scheduling for port multi-energy microgrid considering mobile hydrogen energy storage [J]. Proceedings of the CSEE, 2024, 44(8): 3078-3093.
- [36] 杜刚, 赵冬梅, 刘鑫. 计及风电不确定性优化调度研究综述 [J]. 中国电机工程学报, 2023, 43(7): 2608-2627.
- DU Gang, ZHAO Dongmei, LIU Xin. Research review on optimal scheduling considering wind power uncertainty [J]. Proceedings of the CSEE, 2023, 43(7): 2608-2627.

收稿日期: 2024-12-25 修回日期: 2025-03-25

作者简介:

刘继春(1975),男,博士,教授,博士生导师,IEEE高级会员,主要研究方向为新能源与储能、电力市场等;

肖煜瑾(1999),女,硕士,主要研究方向为电力市场, E-mail: 894290692@qq.com;

邱高(1994),男,博士,副教授,通信作者,主要研究方向为电力系统人工智能、电力系统运行优化, E-mail: qiugscu@163.com;

唐伦(1988),男,硕士,工程师,主要研究方向为电力系统运行分析及优化、电力市场等;

孙毅(1978),女,硕士,高级工程师,主要研究方向为电网调度管理、电力市场等;

李凌昊(1994),男,硕士,工程师,主要研究方向为需求响应、新能源消纳等。

(编辑 魏希辉)

### 附录 A

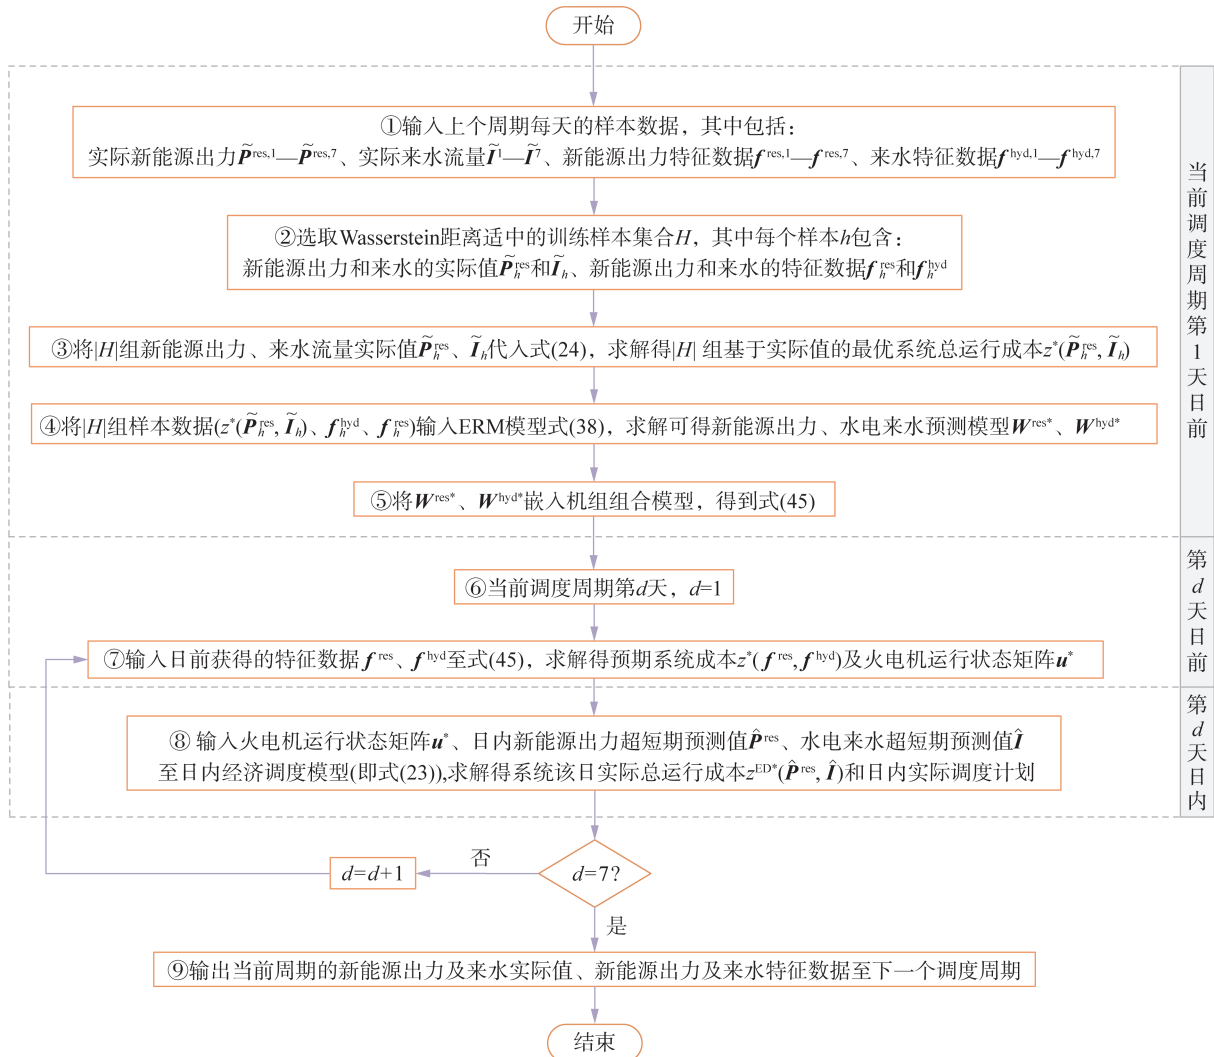


图 A1 算法整体实施流程图

Fig. A1 The entire workflow of algorithm implementation

### 附录 B

表 B1 不同正则化参数组合下的实际系统成本

Table B1 Actual system costs under different regularization parameter combinations

$\alpha$	$\lambda$	$\lambda^{hyd}$	实际系统成本/万元	$\alpha$	$\lambda$	$\lambda^{hyd}$	实际系统成本/万元	$\alpha$	$\lambda$	$\lambda^{hyd}$	实际系统成本/万元
0.7	$10^4$	$10^3$	262.345	0.8	$10^4$	$10^3$	261.923	0.9	$10^4$	$10^3$	262.214
0.7	$10^4$	$10^4$	261.789	0.8	$10^4$	$10^4$	261.578	0.9	$10^4$	$10^4$	261.756
0.7	$10^4$	$10^5$	262.073	0.8	$10^4$	$10^5$	261.897	0.9	$10^4$	$10^5$	262.049
0.7	$10^5$	$10^3$	261.574	0.8	$10^5$	$10^3$	261.389	0.9	$10^5$	$10^3$	261.572
0.7	$10^5$	$10^4$	261.245	0.8	$10^5$	$10^4$	261.142	0.9	$10^5$	$10^4$	261.324
0.7	$10^5$	$10^5$	261.832	0.8	$10^5$	$10^5$	261.583	0.9	$10^5$	$10^5$	261.780
0.7	$10^6$	$10^3$	262.081	0.8	$10^6$	$10^3$	261.729	0.9	$10^6$	$10^3$	262.034
0.7	$10^6$	$10^4$	261.894	0.8	$10^6$	$10^4$	261.520	0.9	$10^6$	$10^4$	261.817
0.7	$10^6$	$10^5$	262.153	0.8	$10^6$	$10^5$	261.965	0.9	$10^6$	$10^5$	262.239