

基于最优决策树的多能系统快速鲁棒优化调度

彭浩晋¹, 邱高¹, 税月²

(1. 四川大学电气工程学院, 四川 成都 610065; 2. 国网四川省电力公司技能培训中心, 四川 成都 611133)

摘要: 新能源渗透率的持续增长造成了多能系统快速协调调度的巨大挑战, 包括调度结果过于保守以及日内调度低效等问题。为此, 提出了一种基于最优决策树分布式鲁棒优化的多能系统协调快速调度方法, 所构建模型考虑电网日内经济调度, 引入基于范数约束的概率分布置信集精准描述新能源的不确定性, 防止调度结果过于保守。同时, 根据新能源日内运行数据, 分别通过可解释的最优分类树和最优回归树算法, 优化日内机组启停状态和出力水平的初始决策量, 解决日内鲁棒调度的低效问题。在四川某地区电网的验证结果表明, 该模型可在兼顾调度成本和鲁棒性的同时, 实现水风光多能系统的日内快速协调调度。

关键词: 分布鲁棒优化; 多能互补调度; 数据驱动技术; 最优决策树

中图分类号: TM 732 **文献标志码:** A **文章编号:** 1003-6954(2023)06-0021-07

DOI: 10.16527/j.issn.1003-6954.20230604

Fast Robust Optimal Dispatch of Multi-energy System Based on Optimal Decision Tree

PENG Haojin¹, QIU Gao¹, SHUI Yue²

(1. College of Electrical Engineering, Sichuan University, Chengdu 610065, Sichuan, China; 2. State Grid Sichuan Technical Training Center, Chengdu 611133, Sichuan, China)

Abstract: The increasing penetration of new energy has caused challenges to the fast coordinated dispatch of multi-energy systems, including overly conservative operation and low-efficient intraday dispatch. For this purpose, a fast and coordinated dispatch method for multi-energy systems based on optimal decision tree-based distributed robust optimization (ODT-DRO) is proposed. Considering the intraday economic dispatch of power grid, and in order to prevent the result from being too conservative, the proposed model introduces probability distribution confidence set based on norm constraint, which precisely describes the uncertainties of new energy. At the same time, according to the intraday operation data of new energy, the interpretable optimal classification tree and optimal regression tree algorithms are used to optimize the initial intraday decisions of the status and output level of the units, thus solving the inefficiency problem in intraday robust dispatch. Testing results of a power grid in Sichuan show that the proposed method can balance the operational costs and the robustness, and meanwhile achieve the fast coordinated intraday dispatch for multi-energy system.

Key words: distributionally robust optimization; multi-energy coordinated dispatch; data-driven technology; optimal decision tree

0 引言

对于包括风能、太阳能、水力资源和其他可再生能源的具有多维不确定性的互补发电系统的协调调度^[1-3], 通常采用随机优化^[4]和鲁棒优化^[5]方法进行建模和处理。

随机优化可以用于具有多不确定性的可再生能源发电调度过程的定量分析, 但由于对混合可再生电力系统中不确定性概率分布规律进行精确描述十分困难^[6], 随机优化需要预先设置概率分布类型^[7], 这在一定程度上降低了其可靠性。除此之外, 随机优化基于大量离散场景, 将使计算规模过大, 从而导致更长的消耗时间和较低的计算效

率^[8]。尽管离散场景的场景约简技术^[9]和 Benders 分解加速方法^[10]可以减少计算规模,但这些方法不能覆盖所有实际场景,并且所获得场景的代表性和典型性值得怀疑,那么解的准确性也会降低。

相较而言,鲁棒优化不需要预先设置随机变量的概率分布^[11-13],它通过不确定变量的边界参数来描述随机变化特征^[14],只要变量值在边界内,就可以从鲁棒优化模型中获得可行的解。与随机优化相比,鲁棒优化可以为边界内任意取值的不确定变量获得可行解^[15],并能严格保证决策的可靠性,同时计算规模大大缩小,数据需求也减少。但由于鲁棒优化是基于最坏的情况来搜索最优值^[16-17],因此鲁棒优化存在优化结果过分保守的缺点,这将导致在水风光多能互补调度中不能充分利用资源。

针对随机优化、鲁棒优化在处理水电、风能和太阳能等可再生能源的不确定性特征过程中存在的问题,相关研究人员尝试将随机优化和鲁棒优化结合起来,使其优势互补并避免两种方法的缺点。此外,随着测量技术的不断改进,电力系统产生了大量的多类型生产数据。在此背景下,数据驱动的分布式鲁棒优化(distributionally robust optimization, DRO)应运而生,这为解决随机优化模型的低精度和鲁棒优化模型的保守性提供了新的途径^[18]。目前,DRO 技术已初步应用于电力系统的机组组合^[19]、多能互补调度^[20]等,也有相关研究简化了 DRO 的复杂计算过程^[14]。与随机优化和鲁棒优化相比,DRO 不需要获得变量的精确概率分布,只需要构建一个覆盖真实分布的不确定集,并在最坏分布下进行决策,从而避免了变量的复杂概率分布难以获得的难题。此外,通过采用线性决策规则、拉格朗日对偶处理^[21]等技术,可以将 DRO 问题转化为确定性优化问题,以避免随机优化方法的大采样规模和低计算效率问题。DRO 的显著优点是它覆盖了不确定参数的概率统计信息,并可以提高决策的保守性。DRO 不仅结合了随机优化的概率统计特性,还借鉴了鲁棒优化的思想,其决策结果具有抗风险性能,在处理电力系统的不确定性特征方面具有独特的显著优势^[16]。

鉴于数据驱动 DRO 在不确定经济调度、低碳调度和机组组合领域的独特优势,下面提出了一种基

于最优决策树的 DRO 的梯级水电与风/光新能源电站联合系统协调优化调度方法(two-stage distributed robustness based on optimal decision tree, ODT-DRO)。该方法首先建立了数据驱动的两阶段 DRO 调度模型,第一阶段考虑系统的互补经济调度成本,第二阶段考虑系统实时调整能力,并引入范数约束来限制风电与太阳能的不确定输出的概率分布置信集,以寻求最差分布情况的最优解。同时,通过嵌入基于优化理论的可解释的最优决策树算法^[22-24]实现机组状态和出力水平的日内快速决策,实现模型热启动有效提升日内决策效率。

1 基于数据驱动的两阶段 DRO 水风光互补协调调度模型

1.1 模型目标函数

基于数据驱动的两阶段分布鲁棒优化水风光互补协调调度模型包含两个阶段,第一阶段为机组组合模型,第二阶段为实时调整模型。模型目标函数如式(1)所示。

$$\min \left\{ C^{\text{uc}} + \max \{ p_k \} \left[\sum_{k=1}^K p_k \cdot \min(C^{\text{re}}) \right] \right\} \quad (1)$$

式中: p_k 为第 k 个离散场景的概率; K 为离散场景总数; C^{uc} 与 C^{re} 分别为机组运行成本和实时调整成本。

可以看出,式(1)是一个 min-max-min 三层的两阶段鲁棒优化问题,与仅针对最坏情况进行优化的传统两阶段鲁棒优化相比,该模型的内部 max、min 函数通过优化决策变量来计算 K 个离散情况的最坏概率分布,并获得最大期望成本值。 C^{uc} 与 C^{re} 分别由式(2)和式(3)计算得到。

$$C^{\text{uc}} = \sum_{t=1}^T (C_t^{\text{buy}} + C_t^{\text{H}} + C_t^{\text{HG}}) \quad (2)$$

式中, C_t^{buy} 、 C_t^{H} 和 C_t^{HG} 分别为 t 时段购电成本、梯级水电系统和风/光发电站的运行成本。

$$C^{\text{re}} = \sum_{t=1}^T (C_t^{\text{buy-re}} + C_t^{\text{H-re}} + C_t^{\text{HG-re}}) \quad (3)$$

式中, $C_t^{\text{buy-re}}$ 、 $C_t^{\text{H-re}}$ 和 $C_t^{\text{HG-re}}$ 分别为 t 时段购电调整成本、梯级水电站和风/光电站运行调整成本。

1.2 考虑经济调度和综合范数的约束条件

模型的约束主要分为 3 种类型:常规运行约束、

实时经济调整约束和数据驱动的综合范数约束。基于梯级水电系统和风/光系统的预测信息形成的运行约束主要包括功率平衡约束、水量平衡约束、机组运行约束、电网约束^[25]和备用约束等。由于实时阶段的不确定性,需要调整梯级水电的输出,以平衡风光出力的随机波动。因此引入实时调整约束,如式(4)~式(12)所示,分别表示实时调整阶段的源-荷平衡约束、水库蓄水量变化约束、梯级水电有功输出约束、排放流量约束、水量平衡约束、级间液压连接约束、水轮机爬坡率约束、风力/光伏电站的有功约束以及网络约束。

$$\sum_{n=1}^{N^{\text{buy}}} (P_{n,t} + \Delta P_{n,t,k}) + \sum_{i=1}^{N^{\text{H}}} (P_{i,t}^{\text{H}} + \Delta P_{i,t,k}^{\text{H}}) + \sum_{j=1}^{N^{\text{HG}}} (P_{j,t}^{\text{HG}} + \Delta P_{j,t,k}^{\text{HG}}) = \sum_{m=1}^{N^{\text{L}}} P_{m,t}^{\text{L}} \quad (4)$$

$$V_i^{\text{min}} \leq (V_{i,t} + \Delta V_{i,t,k}) \leq V_i^{\text{max}} \quad (5)$$

$$P_i^{\text{Hmin}} \leq (P_{i,t}^{\text{H}} + \Delta P_{i,t,k}^{\text{H}}) \leq P_{i,t}^{\text{H0}} \quad (6)$$

$$Q_i^{\text{Hmin}} \leq (Q_{i,t}^{\text{H}} + \Delta Q_{i,t,k}^{\text{H}}) \leq Q_i^{\text{Hmax}} \quad (7)$$

$$\begin{aligned} V_{i,t+1} + \Delta V_{i,t+1,k} &= \\ V_{i,t} + \Delta V_{i,t,k} + (I_{i,t} + \Delta I_{i,t,k} - Q_{i,t}^{\text{H}} - \Delta Q_{i,t,k}^{\text{H}}) \Delta t &= \\ V_{i,t} + \Delta V_{i,t,k} + (I_{i,t} + \Delta I_{i,t,k} - Q_{i,t}^{\text{G}} - \Delta Q_{i,t,k}^{\text{G}} - \\ Q_{i,t}^{\text{C}} - \Delta Q_{i,t,k}^{\text{C}}) \Delta t & \quad (8) \end{aligned}$$

$$I_{i+1,t+\tau} + \Delta I_{i+1,t+\tau,k} = Q_{i,t}^{\text{H}} + \Delta Q_{i,t,k}^{\text{H}} + L_{i,t} + \Delta L_{i,t,k} \quad (9)$$

$$\delta^{\text{L}} \Delta t \leq (P_{i,t+1}^{\text{H}} + \Delta P_{i,t+1,k}^{\text{H}} - P_{i,t}^{\text{H}} - \Delta P_{i,t,k}^{\text{H}}) \leq \delta^{\text{U}} \Delta t \quad (10)$$

$$0 \leq (P_{j,t}^{\text{HG}} + \Delta P_{j,t,k}^{\text{HG}}) \leq P_{j,t}^{\text{HG0}} \quad (11)$$

$$\begin{cases} P_{\text{line}} = \mathbf{B}_{\text{diag}} \mathbf{L} \mathbf{B}^{-1} [(P_t + \Delta P_{t,k}) + (P_t^{\text{H}} + \Delta P_{t,k}^{\text{H}}) + P_{t,k}^{\text{HG}}] \\ -\bar{P}_{\text{line}} \leq P_{\text{line}} \leq \bar{P}_{\text{line}} \\ \mathbf{B}_{\text{diag}} = \text{diag} \left(\frac{1}{x_1}, \frac{1}{x_2}, \dots, \frac{1}{x_N} \right) \end{cases} \quad (12)$$

式中: N^{buy} 、 N^{H} 、 N^{HG} 、 N^{L} 分别为购电时期总期数、梯级水电机组总数、新能源机组总数和负荷总数; $P_{n,t}$ 、 $\Delta P_{n,t,k}$ 分别为 n 购电期 t 时段的购电功率和场景 k 中实时购电调整功率; $P_{i,t}^{\text{H}}$ 、 $\Delta P_{i,t,k}^{\text{H}}$ 分别为 i 水电机组 t 时段有功出力和场景 k 中实时调整功率; $P_{j,t}^{\text{HG}}$ 、 $\Delta P_{j,t,k}^{\text{HG}}$ 分别为 j 新能源机组 t 时段有功功率和场景 k 中实时调整功率; $P_{m,t}^{\text{L}}$ 为系统 m 负荷 t 时段有功需

求; $V_{i,t}$ 、 $\Delta V_{i,t,k}$ 分别为 i 水电机组 t 时段水库水量和场景 k 中水库水量的实时调整量; V_i^{min} 、 V_i^{max} 分别为 i 水电机组水库水量的最小值和最大值; P_i^{Hmin} 、 $P_{i,t}^{\text{H0}}$ 分别为 i 水电机组 t 时段最小允许出力和当前最大出力能力; $Q_{i,t}^{\text{H}}$ 、 $\Delta Q_{i,t,k}^{\text{H}}$ 分别为 i 水电机组 t 时段水库的排水量和场景 k 中实施调整的排水量; Q_i^{Hmin} 、 Q_i^{Hmax} 分别为 i 水电机组水库最小和最大排水量。 $I_{i,t}$ 、 $Q_{i,t}^{\text{C}}$ 、 $Q_{i,t}^{\text{G}}$ 分别为 i 水电机组水库的流入量、发电流量和排放量; $\Delta I_{i,t,k}$ 、 $\Delta Q_{i,t,k}^{\text{G}}$ 、 $\Delta Q_{i,t,k}^{\text{C}}$ 分别为 i 水电机组 t 时段场景 k 流入量、发电流量和排放量的实时调整量; $I_{i+1,t+\tau}$ 、 $\Delta I_{i+1,t+\tau,k}$ 分别为 i 水电机组下级水库 $t+\tau$ 期间流入量和场景 k 流入调整量; $L_{i,t}$ 、 $\Delta L_{i,t,k}$ 分别为 i 水电机组 t 时段流量延迟量和场景 k 延迟调整量; δ^{L} 、 δ^{U} 分别为梯级水电机组爬坡能力上、下限; $P_{j,t}^{\text{HG0}}$ 为 j 新能源机组 t 时段的出力预测值; \mathbf{B} 、 \mathbf{L} 分别为导纳矩阵和节点连接矩阵; P_{line} 、 \bar{P}_{line} 分别为支路 t 时段的直流功率和最大支路功率; x_l 为第 l 个支路的支路阻抗。

由于传统的求解方法对于求解上述 DRO 优化调度模型来说过于复杂,引入了一种基于 1-范数和 ∞ -范数的数据驱动的 DRO 算法来求解模型。首先,该算法以水力径流和风力/光伏强度等不确定参数的历史数据为参考,通过提取有限典型日的水力和风力/光伏历史数据,筛选 K 个离散场景的水力和风/光发电量以及每个场景的初始概率;然后,以每个初始概率分布为中心,引入综合范数约束来计算该联合优化问题,从而获得每个离散场景的最坏概率分布,并获得该场景下的最大期望目标值。因此,在数据驱动的两阶段 DRO 协调调度模型中,除了常规运行调度约束和实时调度约束外,还需要考虑综合范数约束。

由 1-范数和 ∞ -范数对水风光随机输出的离散场景施加了约束, Ω 为综合范数的可行域,可用式(13)表示。

$$\Omega = \{p_k\} \begin{cases} p_k \geq 0, k = 1, 2, \dots, K \\ \sum_{k=1}^K p_k = 1 \\ \sum_{k=1}^K |p_k - p_k^0| \leq \theta_1 \\ \max_{1 \leq k \leq K} |p_k - p_k^0| \leq \theta_\infty \end{cases} \quad (13)$$

式中: p_k 为优化过程中第 k 个离散场景的概率; p_k^0 为离散场景 k 的初始概率值; $\sum_{k=1}^K |p_k - p_k^0| \leq \theta_1$ 和 $\max_{1 \leq k \leq K} |p_k - p_k^0| \leq \theta_\infty$ 分别为 1-范数约束和 ∞ -范数约束, θ_1 、 θ_∞ 分别为对应约束下离散情景概率的允许偏差极限。其中置信系数 $\{\alpha_k\}$ 根据文献[26-27]可以描述为:

$$\begin{cases} \Pr\left\{\sum_{k=1}^K |p_k - p_k^0| \leq \theta_1\right\} \geq \alpha_1 \\ \Pr\left\{\max_{1 \leq k \leq K} |p_k - p_k^0| \leq \theta_\infty\right\} \geq \alpha_\infty \end{cases} \quad (14)$$

$$\begin{cases} \alpha_1 = 1 - 2Ke^{-\frac{2M\theta_1}{K}} \\ \alpha_\infty = 1 - 2Ke^{-2M\theta_\infty} \end{cases} \quad (15)$$

式中: α_1 和 α_∞ 分别为 1-范数和 ∞ -范数约束下离散场景集的概率分布置信系数; M 为选定的有限典型水风光发电场景日数。根据式(13)和式(14), 约束水风光不确定性输出的允许偏差限值 θ_1 和 θ_∞ 是可以获得的, 如式(16)所示。

$$\begin{cases} \theta_1 = \frac{K}{2M} \ln \frac{2K}{1 - \alpha_1} \\ \theta_\infty = \frac{1}{2M} \ln \frac{2K}{1 - \alpha_\infty} \end{cases} \quad (16)$$

2 最优决策树模型

鲁棒优化受初值影响较大。若可将初值设置在最优解附近, 则鲁棒优化的搜索范围将极大减小, 从而可有效提升多能系统的调度效率。下面通过引入可解释性较强的最优树方法, 建立以风、光、荷等实时量测值为输入、机组出力和机组组合为输出的决策树映射, 实现对鲁棒调度决策变量的实时“热启动”优化初始化。

决策树模型基于树结构对特征进行拆分, 能够实现数据的分类与回归任务, 具有可解释性强的优点^[28-31]。这里使用混合整数规划 (mixed integer programming, MIP) 搭建最优决策树模型, 相较于经典的决策树算法 (classification and regression tree, CART), 最优决策树模型在树的顶部做出的决策也会影响全局最优解, 而不是简单地做出一系列局部最优决策, 避免了对决策树采取修剪和杂质措施。并且模型为混合整数规划问题, 可以通过 MIP 解算

器, 如 Gurobi 和 CPLEX 进行求解。

搭建 MIP 的最优决策树可概述为建立分支结点与叶结点的精细参数化决策规则以及约束条件, 并明确最终优化函数目标, 最后通过 MIP 解算器求解。搭建的最优决策树结构如图 1 所示。

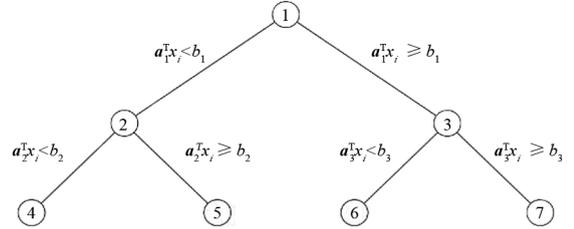


图 1 最优决策树结构

图中, \mathbf{a} 为分支选择状态变量, 且 $\mathbf{a} \in \{0, 1\}$; b 为分支判别变量。分支结点的拆分遵守 $\mathbf{a}^T \mathbf{x} < b$, 即在分支结点拆分时满足此约束的样本进入左分支, 不符合的进入右分支, 其中 x 是样本的某一特征属性进行归一化处理后的值, 即 $x \in [0, 1]$ 。而对于此拆分引入以下变量:

$$d_s \leq d_{p(s)}, \quad \forall s \in T_B \quad (17)$$

$$\sum_{r=1}^p a_{rs} = d_s, \quad \forall s \in T_B \quad (18)$$

$$0 \leq b_s \leq d_s, \quad \forall s \in T_B \quad (19)$$

$$a_{rs} \in \{0, 1\}, \quad r = 1, \dots, p, \quad \forall t \in T_B \quad (20)$$

式中: d_s 为结点 s 的分支指示变量, 其取值只有 0 和 1, 表示不可拆分或可拆分; $p(s)$ 为结点 s 父结点; T_B 为决策树的分支结点集合; p 为样本包含的特征总数; r 为特征序号; a_{rs} 为二进制变量, 用以确保每个结点只允许对一个变量 (即样本属性) 进行拆分; b_s 为在分支结点 s 上进行拆分的判断阈值条件, 作为连续变量, 因为样本特征属性是归一化的结果, 所以 b_s 取值也在 0 和 1 之间。式(17)表示当分支结点的父结点不可拆分, 那么分支结点也必定不能拆分; 式(18)表示在分支结点上一次只能针对一个属性进行拆分。

通过上述规则和引入的变量可以能够实现 MIP 的树结构建模, 同时还需要建立叶结点的分配规则, 将叶结点与样本类别相匹配。通过引入二进制变量 $z_{ms} = 1$ 来标志有样本 m 落入叶结点中, 样本总数为 n , 并引入二进制变量 $l_s = 1$ 表示叶结点满足最小落入样本数, 最小样本数为 N_{\min} , 并且需要强制每个样

本点只能分配给一个叶结点,因此有如下约束:

$$z_{ms} \leq l_s, \quad s \in T_L \quad (21)$$

$$\sum_{m=1}^n z_{ms} \geq N_{\min} l_s, \quad s \in T_L \quad (22)$$

$$\sum_{s \in T_L} z_{ms} = 1, \quad m = 1, \dots, n \quad (23)$$

式中: z_{ms} 为叶结点样本指示变量, $z_{ms} = 1$ 表示样本 x_m 落在结点 s ,以此来跟踪分配给每个叶结点的样本; l_s 为叶结点最小样本数限制指示变量,与叶结点最小样本数 N_{\min} 构建最小样本数限制; T_L 为叶结点集合。

最后在将样本分配给叶结点时需要用强制约束进行拆分:

$$\mathbf{a}_v^T (x_m + \delta) \leq b_s + M_1(1 - z_{ms}), \quad m = 1, \dots, n, \quad \forall s \in T_B, \quad \forall v \in A_L(s) \quad (24)$$

$$\mathbf{a}_v^T x_m \geq b_s - M_2(1 - z_{ms}),$$

$$m = 1, \dots, n, \quad \forall s \in T_B, \quad \forall v \in A_R(s) \quad (25)$$

式中: M_1 与 M_2 都为任意大的常数; $A_L(s)$ 为叶结点的拆分路径上的左分支结点集; $A_R(s)$ 为叶结点的拆分路径上的右分支集; v 为左分支结点或右分支结点的索引; δ 为引入的小常数,满足MIP解算器的不等式要求。

通过上述模型,需要最小化每个叶结点中误分类样本的个数 L_s ,线性化表达为:

$$L_s \geq N_s - N_{us} - M(1 - c_{us}), \quad u = 1, \dots, U, \quad \forall s \in T_L \quad (26)$$

$$L_s \leq N_s - N_{us} + M c_{us}, \quad u = 1, \dots, U, \quad \forall s \in T_L \quad (27)$$

$$L_s \geq 0, \quad \forall s \in T_L \quad (28)$$

式中: L_s 为误分类损失,其值为叶结点样本总数减去比例最多标签样本数; N_s 为叶结点上总的样本个数; N_{us} 为叶结点上第 u 类样本的个数;通过找到叶结点中样本数最多的类,确定该类为叶结点所对应的类别,最小化错误分类样本个数,引入 $c_{us} = 1$ 表示叶结点 s 对应类别为 u ; M 为任意大常数,结合 c_{us} 的取值使约束无效。

根据基线精度标准化错误分类,得到模型的优化目标为

$$\min \frac{1}{L} \sum_{s \in T_L} L_s + \alpha \sum_{s \in T_B} d_s \quad (29)$$

式中, α 为复杂性参数,控制树的精度与复杂性。

构建的最优决策树模型为混合整数规划问题,能够有效嵌入数据驱动的水风光两阶段分布鲁棒模型中。根据新能源实测数据进行运行方式快速决策,提供给模型进一步优化,解释性强,可通过Gurobi和CPLEX等求解器进行求解。

3 ODT-DRO 联合优化调度方法

使用ODT-DRO实现水风光多能系统协调调度。首先,需要通过大量历史新能源出力水平、负荷水平、发电机出力水平、机组启停状态等数据作为最优决策树训练数据输入特征,分别得到最优分类决策树与最优回归决策树;最优分类决策树与最优回归决策树根据新能源机组出力能力实测数据分别输出同步发电机组启停状态与出力水平,将同步发电机启停状态与出力水平传递给两阶段DRO水风光协调调度模型,进一步优化得到日内发电策略,具体流程如图2所示。

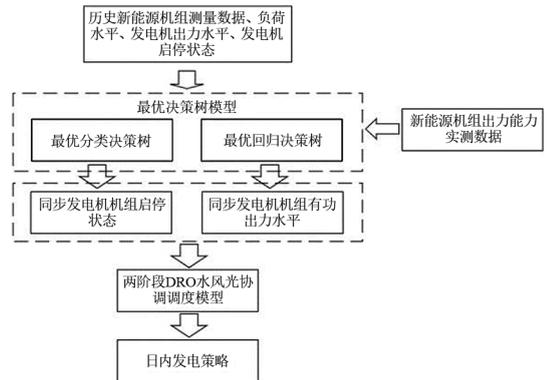


图2 联合优化方法流程

由于最优决策树模型通过离线训练得到,对新能源实测数据能够快速给出发电机出力和状态的决策结果,实现对两阶段DRO水风光协调调度的加速,避免由于新能源预测误差对调度结果的不利影响,实现多能互补系统的日内发电策略快速决策。

4 算例分析

将所提ODT-DRO模型在四川ZD地区电网的试验应用,验证所提方法多能互补协调调度可行性。ZD地区等值系统如图3所示,根据拓扑结构与基础数据将该系统简化为29个母线节点的系统,包含BT、SWL、KJW、YFG与KL等发电厂。参考攀西新能源大发运行方式作为基准运行方式,该运行方式

下 GN 并网 1700 MW, ZD 地区汇集站光伏并网 600 MW, 金上直流外送功率为 5000 MW。

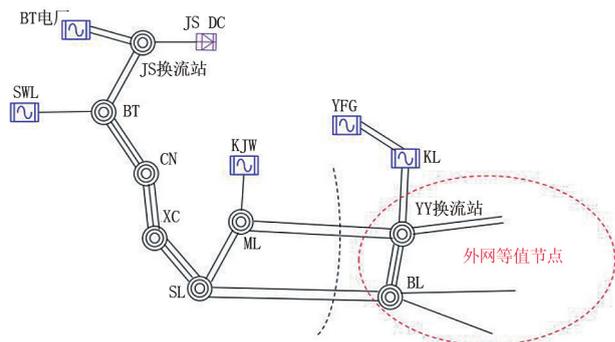


图 3 ZD 地区等值系统

4.1 最优决策树算法分类与回归效果分析

引入最优分类决策树,根据新能源实测数据、负荷水平以及水电机组实际运行条件对同步机组启停状态进行决策。最优决策树树结构最大深度为 5,最优分类决策树进行分支的最小样本数为 10,最优回归决策树采用均方差来进行评估。最优决策树算法在分类准确率达到 99.52%且训练样本数据量充足的情况下,能精确地决策机组启停状态。相比于经典的 CART 算法,其准确率提升了 5.18%,如表 1 所示。

表 1 CART 决策树与最优决策树分类准确率

算法	CART 决策树	最优决策树
准确率/%	94.34	99.52

通过最优回归决策树拟合不同运行环境下同步机组有功出力,并与 CART 决策树拟合结果进行对比,如图 4 所示。由图 4 可以看到:CART 算法拟合后得到的发电机出力曲线与实际曲线存在较大误差;使用最优决策树进行拟合后得到的发电机出力曲线与实际曲线贴合度较高,误差较小,拟合效果更好。

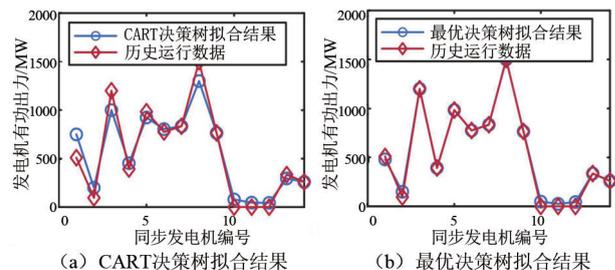


图 4 两种决策树算法拟合效果

4.2 模型求解时间

通过最优分类决策树与最优回归决策树得到同步发电机组启停状态和出力结果。将该结果传递给两阶段 DRO 水风光协调调度模型作为初始解,实

现热启动,加速模型优化求解速度。相较于没有嵌入最优决策树的模型,所建模型求解时间节省了 231.752 3 s,如表 2 所示。

表 2 模型求解时间对比

模型	求解时间/s
DRO 调度模型	755.093 8
ODT-DRO 模型	523.341 5

4.3 新能源机组调度出力偏差分析

在不考虑新能源消纳受阻情况下,以 ZD 地区风机出力能力为例,对比日前调度与所提 ODT-DRO 模型对新能源机组优化出力与实测数据的偏差,如图 5 所示。从图 5 可以看到:日前调度通常根据未来一天新能源预测曲线对未来一天的发电计划进行优化计算,因此新能源预测误差较大,与实际测得的新能源出力水平曲线有较大偏差;所提 ODT-DRO 调度方法根据当前时刻新能源机组出力水平的实测数据进行决策,时间尺度短,预测误差与调度误差较小。

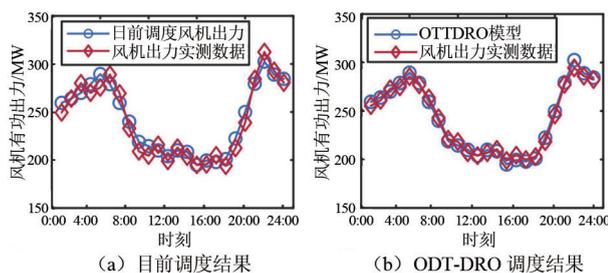


图 5 两种模型调度误差与预测误差分析

4.4 ODT-DRO 优化调度结果分析

ODT-DRO 水风光协调调度结果如图 6 所示。可以看到所提模型能够在四川电网 ZD 地区完成水风光多能协调互补调度,并且在新能源机组出力水平较高的时间段(10:00—16:00),降低同步发电机组出力甚至关停部分机组,为新能源机组让出更多空间,防止出现新能源消纳受阻的情况,验证了所提模型在多能互补系统中调度的合理性和可行性。表 3 是部分调度结果展示。

表 3 部分调度结果展示 单位:MW

节点	9:00	12:00	13:00	14:00	15:00	16:00	17:00
9	834	834	834	834	834	795	834
10	1500	1500	1114	819	1035	1500	1500
11	765	765	765	765	765	765	765
17	100	40	0	0	0	0	80
19	40	15	0	0	0	0	30

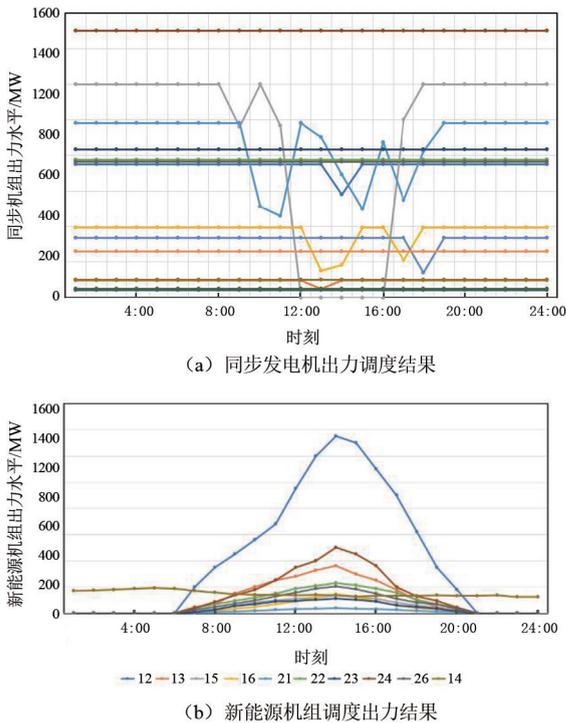


图6 模型优化调度结果

4.5 模型成本分析

表4比较了所提ODT-DRO算法、随机优化算法以及传统鲁棒优化算法的调度成本。ODT-DRO单位调度成本为148.7216元/MWh,远低于传统鲁棒优化算法单位平均调度成本,也略低于随机优化算法的单位平均调度成本。因此,所提出的ODT-DRO协调调度方法更具经济性。

表4 模型调度成本对比

模型	单位平均调度成本/(元·MWh ⁻¹)
ODT-DRO	148.7216
随机优化	152.4765
传统鲁棒优化	185.5362

5 结论

为了在包含多清洁能源的系统中实现水风光多能互补调度,并且在防止调度结果过度保守的同时实现以新能源优先消纳为目标的日内发电策略快速决策,提出了基于最优决策树的两阶段DRO水风光协调调度模型。该模型考虑实时调整能力以及范数约束,避免了调度结果的过分保守。同时,嵌入的最优决策树模型根据新能源实测数据、负荷数据以及实际运行情况,为两阶段DRO提供了同步发电机启停状态与出力决策,加速两阶段DRO求解,实现日内发

电策略快速决策。通过在四川某地区电网的试验验证了所提模型的有效性,该模型在求解速度、决策精度、调度成本、安全稳定性以及鲁棒性上都有较好的表现,能够快速给出可靠的日内调度辅助决策信息。

参考文献

- [1] 王开艳,罗先觉,贾嵘,等.充分发挥多能互补作用的风蓄水火协调短期优化调度方法[J].电网技术,2020,44(10):3631-3641.
- [2] 周晓倩,艾芊,林琳,等.多能互补微电网集群分布式优化调度[J].电网技术,2019,43(10):3678-3686.
- [3] 施焯,金浩,郝飞,等.一种多能互补系统优化调度通用化建模方法[J].电网技术,2022,46(12):4924-4943.
- [4] 印月,刘天琪,何川,等.风-光-水-火多能互补系统随机优化调度[J].电测与仪表,2020,57(16):51-58.
- [5] 张增强,高明,吕盼,等.基于鲁棒优化理论的输电网随机优化方法研究[J].电工技术,2019(14):106-110.
- [6] NING C, YOU F Q. Data-driven stochastic robust optimization: General computational framework and algorithm leveraging machine learning for optimization under uncertainty in the big data era[J]. Computers & Chemical Engineering, 2018, 111: 115-133.
- [7] 张沈习,袁加妍,程浩忠,等.主动配电网中考虑需求侧管理和网络重构的分布式电源规划方法[J].中国电机工程学报,2016,36(S1):1-9.
- [8] 欧阳金鑫,于莉,蒋航,等.基于多层随机优化的电网安全稳定控制装置机会检修决策方法[J].电力自动化设备,2023,43(6):144-151.
- [9] GROWE-KUSKA N, HEITSCH H, ROMISCH W. Scenario reduction and scenario tree construction for power management problems[C]//2003 IEEE Bologna Power Tech Conference Proceedings, IEEE, 2003:1-7.
- [10] 晏鸣宇,张伊宁,艾小猛,等.采用Benders分解含机组禁止运行区间的安全约束最优潮流[J].电力系统自动化,2018,42(6):60-65.
- [11] ZHONG Z M, FAN N, WU L. Robust optimization for the day-ahead scheduling of cascaded hydroelectric systems[C]//2022 IEEE Power & Energy Society General Meeting (PESGM), IEEE, 2022:1-8.
- [12] CHEN Y B, ZHANG Z, CHEN H, et al. Robust UC model based on multi-band uncertainty set considering the temporal correlation of wind/load prediction errors[J]. IET Generation, Transmission & Distribution, 2020, 14(2):180-190.

deep reinforcement learning approach [J]. Renewable Energy, 2022, 201: 792–801.

- [20] LI G Q, ZHANG R F, JIANG T, et al. Optimal dispatch strategy for integrated energy systems with CCHP and wind power[J]. Applied Energy, 2017, 192:408–419.
- [21] 王泽森, 石岩, 唐艳梅, 等. 考虑 LCA 能源链与碳交易机制的综合能源系统低碳经济运行及能效分析[J]. 中国电机工程学报, 2019, 39(6): 1614–1626.

作者简介:

冯文韬(1996), 男, 硕士, 研究方向为新型电力系统;

(上接第 27 页)

- [13] CHEN Y B, ZHANG Z, LIU Z Y, et al. Robust N-k CCUC model considering the fault outage probability of units and transmission lines[J]. IET Generation, Transmission & Distribution, 2019, 13(17): 3782–3791.
- [14] 周任军, 闵雄帮, 童小娇, 等. 电力环保经济调度矩不确定分布鲁棒优化方法[J]. 中国电机工程学报, 2015, 35(13): 3248–3256.
- [15] 季峰, 蔡兴国, 王超柱. 基于弱鲁棒优化的含风电电力系统调度方法[J]. 中国电机工程学报, 2016, 36(17): 4600–4609.
- [16] SHANG C, YOU F Q. Distributionally robust optimization for planning and scheduling under uncertainty [J]. Computers & Chemical Engineering, 2018, 110: 53–68.
- [17] 钱峰, 白津阳, 刘俊磊, 等. 基于弱鲁棒控制的风电降载调度模型[J]. 电气自动化, 2020, 42(4): 11–13.
- [18] 孙泽锋, 李渤, 王磊. 计及风电相关性的电力系统数据驱动分布鲁棒优化调度[J]. 中国测试, 2023, 49(8): 93–103.
- [19] 吉兴全, 郝晴, 张玉敏, 等. 分布不确定性条件下的 N-k 分布鲁棒优化机组组合[J]. 电力系统自动化, 2022, 46(2): 56–64.
- [20] 吴孟雪, 房方. 计及风光不确定性的电-热-氢综合能源系统分布鲁棒优化[J]. 电工技术学报, 2023, 38(13): 3473–3485.
- [21] DELAGE E, YE Y. Distributionally robust optimization under moment uncertainty with application to data-driven problems[J]. Operations Research, 2010, 58(3): 595–612.
- [22] BERTSIMAS D, DUNN J. Optimal classification trees[J]. Machine Learning, 2017, 106(7): 1039–1082.
- [23] SUAREZ A, LUTSKO J F. Globally optimal fuzzy decision trees for classification and regression [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1999, 21(12): 1297–1311.

李龙胜(1976), 男, 硕士, 高级工程师, 研究方向为新型电力系统;

曾 愚(1986), 男, 硕士, 高级工程师, 研究方向为新型电力系统;

潘可佳(1982), 男, 硕士, 高级工程师, 研究方向为新型电力系统;

张子闻(1994), 女, 硕士, 研究方向为电力大数据分析;

景致远(1999), 男, 硕士, 研究方向为电子信息、智能电网。

(收稿日期: 2023–06–27)

- [24] BERTSIMAS D, DUNN J, PASCHALIDIS A. Regression and classification using optimal decision trees [C]// 2017 IEEE MIT Undergraduate Research Technology Conference (URTC), IEEE, 2017: 1–4.
- [25] 高红均, 刘俊勇, 魏震波, 等. 基于极限场景集的风电机组安全调度决策模型[J]. 电网技术, 2013, 37(6): 1590–1595.
- [26] ZHAO C Y, GUAN Y P. Data-driven stochastic unit commitment for integrating wind generation [J]. IEEE Transactions on Power Systems, 2016, 31(4): 2587–2596.
- [27] DING T, YANG Q R, YANG Y H, et al. A data-driven stochastic reactive power optimization considering uncertainties in active distribution networks and decomposition method[J]. IEEE Transactions on Smart Grid, 2018, 9(5): 4994–5004.
- [28] 李兵, 韩睿, 何怡刚, 等. 改进随机森林算法在电机轴承故障诊断中的应用[J]. 中国电机工程学报, 2020, 40(4): 1310–1319.
- [29] 申建建, 张楠男, 程春田, 等. 基于聚类分析和决策树的“一库多级”水电站日调度方法[J]. 中国电机工程学报, 2019, 39(3): 652–663.
- [30] 石访, 张林林, 胡熊伟, 等. 基于多属性决策树的电网暂态稳定规则提取方法[J]. 电工技术学报, 2019, 34(11): 2364–2374.
- [31] 甄永赞, 阮程. 基于代价敏感支持向量机和多变量决策树的分级自适应暂态电压稳定评估[J/OL]. 电网技术: 1–14. [2023–09–13]. DOI: 10.13335/j.1000–3673.pst.2023.0074.

作者简介:

彭浩晋(2000), 男, 硕士研究生, 研究方向为数据驱动的电力系统运行规划;

邱 高(1994), 男, 博士, 副研究员, 研究方向为电力系统人工智能应用。

(收稿日期: 2023–06–11)