

面向光储电站运行收益提升的光伏功率价值导向预测方法

许多^{1,2}, 徐潇源^{1,2}, 秦放³, 王梦圆^{1,2}, 严正^{1,2}, 陆建宇⁴, 姚虹春³

(1. 电力传输与功率变换控制教育部重点实验室(上海交通大学), 上海市 200240;

2. 上海非碳基能源转换与利用研究院, 上海市 200240; 3. 中国电力科学研究院有限公司(南京), 江苏省南京市 210003;

4. 国家电网有限公司华东分部, 上海市 200120)

摘要: 光储电站运行包含光伏功率预测与资源优化调度两部分,通常首先以预测精度最高为目标进行光伏功率预测,再基于预测曲线进行光储电站优化调度。然而,优化调度问题的目标函数值与光伏功率预测误差具有非线性、非对称关系,在相同的预测误差水平下,以精度最高为目标的光伏功率预测结果并不一定使得光储电站运行收益最大。对此,提出了面向光储电站运行收益提升的光伏功率价值导向预测方法。首先,构建包含光伏功率预测与电站运行的双层优化问题,上层为光伏功率日前预测模型训练问题,下层为给定光伏功率预测模型下的光储电站日前投标与日内运行两阶段优化调度问题。然后,将上层预测问题转换为组合预测形式,预测模型参数设置为权重系数,设计了基于迭代优化的预测模型参数求解方法。最后,采用实际光伏电站数据以及电价数据进行算例分析,并与以预测精度最高为目标的光伏功率预测方法进行对比,验证所提出方法在提升电站运行收益方面的有效性。

关键词: 光储电站; 价值导向预测; 光伏功率预测; 优化调整; 组合预测; 双层优化; 自组织映射

0 引言

随着光伏发电在电力系统中的渗透率逐步提高,其输出功率的随机性与波动性在可再生能源消纳^[1]、电力系统安全稳定运行^[2]等方面会产生不利影响。进行光伏功率预测可辅助光伏电站制定发电计划、优化调度方案、参与能源市场^[3],从而提升可再生能源利用率与经济性。

光储电站运行需解决光伏功率预测与优化运行两方面问题。光伏短期预测^[4]通常采用统计学方法,结合数值天气预报(numerical weather prediction, NWP)数据与光伏历史数据,建立历史数据与光伏输出功率的映射关系^[5-10],拟合得到光伏功率预测值。

光储电站的传统运行方式为先预测再调度。由于光储电站运行收益与光伏功率预测误差呈现非对称性、非线性关系,在总体误差水平相同的情况下,精度最高的光伏功率预测结果不一定使得光储电站运行收益最大^[11]。为解决该问题,有研究提出了价值导向的预测技术,以下游的运行问题成本最小为目标进行预测模型训练,可分为神经网络优化层构

建法、决策误差法与预测模型线性回归法3种。

价值导向预测(value-oriented forecasting, VOF)起源于神经网络中的端对端概念,表示使用原始输入数据进行末端目标学习。神经网络优化层构建法沿循网络概念,将运行问题编码为网络层直接嵌入预测模型。文献[12]采用灵敏度分析、隐式微分与双层优化技术,将二次规划问题构建为优化层;文献[13]通过交替微分方法提高隐式微分的计算速度,在精度误差允许范围内提升端对端网络训练效率;文献[14]提出针对一般的凸优化问题的优化层构建方法,并通过残差映射法提高计算效率;对于虚拟电厂两阶段线性规划问题,文献[15]证明预测误差与虚拟电厂运行成本呈分段线性关系,显著降低模型训练难度,文献[16]将该方法推广至两阶段随机优化领域。神经网络优化层构建法的计算成本较高,为避免决策的非唯一性,仅适用于凸优化问题。

仿照精度误差概念,决策误差指分别根据预测值与实际值进行决策的运行函数差值^[17]。通过转化模型目标函数,决策误差法可有效解决下游决策非唯一性问题。文献[18]提出智能先预测再优化(smart “predict, then optimize”, SPO)构架,以决策误差最小为目标函数训练预测模型,并提出运行问

收稿日期: 2024-05-29; 修回日期: 2024-09-27。

上网日期: 2024-11-22。

国家电网有限公司科技项目(4000-202355095A-1-1-ZN)。

题非凸情况下的代理决策误差函数;为克服传统决策误差法需频繁求解下游运行问题的缺陷,文献[19]提出基于可行空间内逼近的运行策略搜索方法;针对电压调节问题,文献[20]建立对应二阶锥优化模型,以功率损失与越限电压的加权和最小为目标函数,链式求导决策误差以进行模型训练;文献[21]采用决策误差作为损失函数训练回归树,利用回归树结构降低模型复杂度。决策误差通常为非凸函数,且不具备连续性,直接计算难度较大,故须合理松弛并建立恰当的代理决策误差。

采用线性形式的预测模型可有效降低VOF问题求解难度,文献[22-23]选取原始特征变量对新能源发电功率进行线性回归预测;文献[24-25]采用线性仿射方式对初始预测结果进行二次拟合,其中,文献[25]构建基于双层整数线性规划的VOF模型,并采用列与约束生成(column-and-constraint generation, C&CG)算法求解;文献[26]选取原始特征变量对新能源发电功率进行线性回归预测,并构建条件风险价值(conditional value-at-risk, CVaR)模型,进行不同风险厌恶程度下的新能源预测。

线性预测模型可应用于复杂场景,但存在参数寻优空间大、拟合程度较为有限的缺陷。为解决该问题,本文提出了一种基于VOF的光储电站预测-调度问题求解方法:首先,构建包含光伏功率日前预测与光储电站日前-日内运行的双层优化问题;然后,将上层预测问题变形为组合预测形式,将预测模型参数作为权重系数,以缩小参数寻优范围,便于使用启发式方法进行参数迭代求解;最后,通过实际光伏数据集与对应NWP数据集进行算例分析,验证本文提出方法的有效性。

1 光储电站预测-调度联合优化问题

1.1 预测-调度双层问题

为提升光伏的消纳率、减轻光伏出力波动性对电力系统的影响,光伏电站通常配备占比为10%~15%的储能设备^[27]。本文考虑的光储电站包含光伏阵列与储能设备,通过优化市场投标策略、协调管理储能取得收益。光伏功率预测训练集为 $\{x_s, p_s^{PV}\}$,其中, $s=1, 2, \dots, S$ (S 为样本总数)。对于第 s 个样本,其特征量为 x_s ,光伏功率为 p_s^{PV} 。在光伏功率预测的训练阶段,建立 x_s 与光伏功率预测值 \hat{p}_s^{PV} 的映射关系为:

$$\hat{p}_s^{PV} = f(x_s; \Theta) \quad (1)$$

式中: Θ 为预测模型参数。

在此基础上,本文建立考虑光储电站收益最大

化的光伏功率预测问题,即

$$\begin{cases} \max_{\Theta} \frac{1}{S} \sum_{s=1}^S (C_s^{DA}(\hat{p}_s^{PV}) + C_s^{RT}(\hat{p}_s^{PV}, p_s^{PV})) \\ \text{s.t. } \hat{p}_s^{PV} = f(x_s; \Theta) \\ C_s^{DA}(\hat{p}_s^{PV}) = \max_{d_s} g_{DA}(d_s) \\ C_s^{RT}(\hat{p}_s^{PV}, p_s^{PV}) = \max_{r_s} g_{RT}(r_s) \end{cases} \quad (2)$$

式中: C_s^{DA} 为第 s 个样本的日前市场收益; d_s 为第 s 个样本日前投标阶段可调度资源决策量,包括光储电站日前市场投标电量与储能日前计划充放电量; g_{DA} 表示日前决策量与日前投标市场运行收益的函数关系; C_s^{RT} 为第 s 个样本的日内市场收益; r_s 为第 s 个样本在日内调度阶段的可调度资源决策量,即储能日内再调度充放电量; g_{RT} 表示日内决策量与日内市场运行收益的函数关系。

日前投标、日内调度均需满足系统运行的约束条件。式(2)为双层优化问题,光伏功率预测模型 $\hat{p}_s^{PV} = f(x_s; \Theta)$ 为上层问题,光储电站的日前-日内两阶段运行下层问题。

本文采用的电力市场主要包含日前投标市场与日内平衡市场两部分,本文设定日前市场投标需在投标日10:00前完成,日前与实时调度时间间隔均为1h。不考虑光伏功率对市场出清价格的影响,同时,为促进新能源的全额优先消纳^[28],光储电站为市场价格接受者。在日前阶段,光储电站需提前确定日内逐时刻的电力申报数量,即采用“投量不投价”的投标方式。日内阶段仅考虑不平衡市场,调度部门对电站实际发电量与发电计划的偏差量进行价格处罚,惩罚价格根据日内实时市场价格设置,同时按实际日前市场出清价格与发电厂商的日前申报电量进行结算。

1.2 日前预测与投标模型

日前市场收益包含日前市场投标收益与储能设备运行成本两部分,可调度资源为储能设备,函数关系可表示为:

$$\begin{cases} C_t^{DA} = C_t^{e, DA} - C_t^{ess, DA} \\ C_t^{e, DA} = u_t p_t^{bidp} - v_t p_t^{bidn} \\ C_t^{ess, DA} = c_{ess} (p_t^{dis, DA} + p_t^{cha, DA}) \end{cases} \quad (3)$$

式中: C_t^{DA} 为 t 时刻日前市场收益; $C_t^{e, DA}$ 为 t 时刻日前市场的投标收益; $C_t^{ess, DA}$ 为 t 时刻日前阶段调用储能设备的折旧成本; p_t^{bidp} 、 p_t^{bidn} 分别为 t 时刻日前市场的售电量与购电量; v_t 、 u_t 分别为 t 时刻日前市场的购、售电价格; $p_t^{cha, DA}$ 、 $p_t^{dis, DA}$ 分别为 t 时刻日前阶段调用的储能设备充、放电量; c_{ess} 为储能设备折旧成本。

采用日前市场实际出清价格进行结算,由于出

清价格未知,光储电站需根据光伏功率预测值与日前市场预测价格进行决策,优化问题的目标函数为:

$$\max \hat{C}^{\text{DA}} = \sum_{t=1}^T (\hat{C}_t^{\text{e,DA}} - C_t^{\text{ess,DA}}) \quad (4)$$

式中: \hat{C}^{DA} 为日前市场预计收益; T 为总时长; $\hat{C}_t^{\text{e,DA}}$ 为 t 时刻日前市场预计投标收益,计算方法见式(5)。

$$\hat{C}_t^{\text{e,DA}} = \hat{u}_t p_t^{\text{bidp}} - \hat{v}_t p_t^{\text{bidn}} \quad (5)$$

式中: \hat{v}_t 和 \hat{u}_t 分别为 t 时刻日前市场的购、售电预测价格。

日前投标优化问题的约束条件包含功率平衡约束与储能设备运行约束两部分。系统功率平衡约束为:

$$p_t^{\text{bidp}} - p_t^{\text{bidn}} = \hat{p}_t^{\text{PV}} + p_t^{\text{dis,DA}} - p_t^{\text{cha,DA}} \quad (6)$$

式中: \hat{p}_t^{PV} 为 t 时刻光伏功率预测值。

储能设备运行需满足充放电功率约束,即

$$\begin{cases} 0 \leq p_t^{\text{cha,DA}} \leq u_t^{\text{cha,DA}} p_{\text{max}}^{\text{cha}} \\ 0 \leq p_t^{\text{dis,DA}} \leq u_t^{\text{dis,DA}} p_{\text{max}}^{\text{dis}} \end{cases} \quad (7)$$

式中: $u_t^{\text{cha,DA}}$ 和 $u_t^{\text{dis,DA}}$ 分别为表示 t 时刻储能设备充、放电状态的0-1变量,若 $u_t^{\text{cha,DA}}=1$,储能处于充电状态,同时需满足 $u_t^{\text{cha,DA}}+u_t^{\text{dis,DA}} \leq 1$,即储能设备不能同时处于充电与放电状态; $p_{\text{max}}^{\text{cha}}$ 、 $p_{\text{max}}^{\text{dis}}$ 分别为储能最大充、放电功率。

电池功率平衡约束为:

$$E_{t+1}^{\text{DA}} = E_t^{\text{DA}} + p_t^{\text{cha,DA}} \eta_{\text{cha}} - \frac{p_t^{\text{dis,DA}}}{\eta_{\text{dis}}} \quad (8)$$

式中: E_t^{DA} 、 E_{t+1}^{DA} 分别为日前调度计划中 t 时刻和 $t+1$ 时刻末储能设备的电池电量; η_{cha} 、 η_{dis} 分别为电池充、放电效率。

为保证储能系统的连续性,需使电池在开始运行与结束运行时的电量相等,即

$$E_0^{\text{DA}} = E_{24}^{\text{DA}} \quad (9)$$

综上所述,光储电站通过求解如下优化问题获得决策量 p_t^{bidp} 、 p_t^{bidn} 、 $p_t^{\text{cha,DA}}$ 与 $p_t^{\text{dis,DA}}$:

$$\begin{cases} \max \hat{C}^{\text{DA}} = \sum_{t=1}^T (\hat{C}_t^{\text{e,DA}} - C_t^{\text{ess,DA}}) \\ \text{s.t. } p_t^{\text{bidp}} - p_t^{\text{bidn}} = \hat{p}_t^{\text{PV}} + p_t^{\text{dis,DA}} - p_t^{\text{cha,DA}} \\ 0 \leq p_t^{\text{cha,DA}} \leq u_t^{\text{cha,DA}} p_{\text{max}}^{\text{cha}} \\ 0 \leq p_t^{\text{dis,DA}} \leq u_t^{\text{dis,DA}} p_{\text{max}}^{\text{dis}} \\ E_{t+1}^{\text{DA}} = E_t^{\text{DA}} + p_t^{\text{cha,DA}} \eta_{\text{cha}} - \frac{p_t^{\text{dis,DA}}}{\eta_{\text{dis}}} \\ E_0^{\text{DA}} = E_{24}^{\text{DA}} \end{cases} \quad (10)$$

1.3 日内调度模型

由于光伏出力的随机性,光储电站的预测出力与实际出力存在偏差,为减少调度部门对不平衡电

量的惩罚,在日内阶段,光储电站可灵活应用储能设备进行功率平抑。在日内调度阶段,日前投标市场采用日前市场投标量与实际日前市场出清价格进行结算。

光储电站实时调度采用滚动优化,调度时间窗口为 T^{usp} ,可对日前储能设备运行计划做出调整。日内市场成本包含不平衡电量惩罚成本与储能设备运行成本两部分,可调度资源为储能设备,函数关系可表示为:

$$\begin{cases} C_t^{\text{RT}} = -(C_t^{\text{im}} + C_t^{\text{ess,RT}}) \\ C_t^{\text{im}} = u_t^{\text{im}} p_t^{\text{imp}} + v_t^{\text{im}} p_t^{\text{imn}} \\ C_t^{\text{ess,RT}} = c_{\text{ess}} (p_t^{\text{cha,RT}} + p_t^{\text{dis,RT}} - p_t^{\text{cha,DA}} - p_t^{\text{dis,DA}}) \end{cases} \quad (11)$$

式中: C_t^{RT} 为 t 时刻日内调度的总收益; C_t^{im} 为 t 时刻不平衡惩罚成本; $C_t^{\text{ess,RT}}$ 为 t 时刻日内调度的储能成本; u_t^{im} 、 v_t^{im} 分别为 t 时刻正、负不平衡惩罚电价; $p_t^{\text{cha,RT}}$ 、 $p_t^{\text{dis,RT}}$ 分别为 t 时刻储能设备的实际充、放电量; p_t^{imp} 、 p_t^{imn} 分别为 t 时刻的正、负不平衡电量,其定义如式(12)所示。

$$\begin{cases} p_t^{\text{imp}} = \max(0, p_t^{\text{PV}} + p_t^{\text{dis,RT}} - p_t^{\text{cha,RT}} - p_t^{\text{bidp}} + p_t^{\text{bidn}}) \\ p_t^{\text{imn}} = -\min(0, p_t^{\text{PV}} + p_t^{\text{dis,RT}} - p_t^{\text{cha,RT}} - p_t^{\text{bidp}} + p_t^{\text{bidn}}) \end{cases} \quad (12)$$

式中: p_t^{PV} 为 t 时刻光伏实际功率。

为了减少预测误差对光储电站运行的影响,日内运行采用滚动优化模式实时调整运行策略。日内决策量通过滚动求解以下优化问题获得:

$$\begin{cases} \max C_{t_{\text{st}}}^{\text{RT}} = - \sum_{t=t_{\text{st}}}^{t_{\text{st}}+T^{\text{usp}}} (C_t^{\text{ess,RT}} + C_t^{\text{im}}) \\ \text{s.t. } p_t^{\text{bidp}} - p_t^{\text{bidn}} + p_t^{\text{imp}} - p_t^{\text{imn}} = p_t^{\text{PV}} + p_t^{\text{dis,RT}} - p_t^{\text{cha,RT}} \\ 0 \leq p_t^{\text{cha,RT}} \leq u_t^{\text{cha,RT}} p_{\text{max}}^{\text{cha}} \\ 0 \leq p_t^{\text{dis,RT}} \leq u_t^{\text{dis,RT}} p_{\text{max}}^{\text{dis}} \\ E_{t+1}^{\text{RT}} = E_t^{\text{RT}} + p_t^{\text{cha,RT}} \eta_{\text{cha}} - \frac{p_t^{\text{dis,RT}}}{\eta_{\text{dis}}} \\ E_0^{\text{RT}} = E_{24}^{\text{RT}} \end{cases} \quad (13)$$

式中: t_{st} 为当前时刻; $C_{t_{\text{st}}}^{\text{RT}}$ 为日内调度在 t_{st} 时刻时间窗口内的总收益; E_t^{RT} 为 t 时刻末储能设备的电池电量; $u_t^{\text{cha,RT}}$ 、 $u_t^{\text{dis,RT}}$ 分别为 t 时刻表示日内调度储能设备充、放电状态的0-1变量。式(11)至式(13)为日内市场收益 C^{RT} 和日内可调度资源的映射关系 g_{RT} 。

日前-日内两阶段优化调度的简要模型见图1。在日前投标阶段,光伏功率预测、日前调度计划制定、日前市场投标需在投标日的 t_b 时刻前完成, t_b 距日内调度开始的时长为 T_p ;日内调度阶段实行滚动优化,在 $[t_{\text{st}}, t_{\text{st}} + T^{\text{usp}}]$ 的时间窗内,光储电站实时调

整储能设备动作,储能设备在 t_{st} 时刻的实际动作 $z_{t_{st}} = d_{t_{st}} + r_{t_{st}}$,其中, $d_{t_{st}}$ 和 $r_{t_{st}}$ 分别为日前与日内阶段的调度策略。




图1 两阶段优化模型时间轴
Fig. 1 Timeline of two-stage optimization model

2 光伏功率预测模型参数训练方法

2.1 基于组合预测的VOF模型

式(2)所示的双层优化问题中,上层光伏功率预测模型为非凸函数,并且形式复杂,难以使用代数方程表示;下层调度模型包括日前投标与日内调度两阶段,含有光伏实际功率、日前市场出清电价等不确定变量以及整数决策变量,故光储电站的预测-优化问题难以直接求解。

采用组合预测作为上层预测模型,寻优参数设置为权重系数,具有形式简单、参数寻优范围小、模型稳定性强等优点,可有效降低模型训练难度。组合预测指通过权重系数将两种及两种以上的基础预测模型组合,以加权求和的方式获得预测结果,即

$$\hat{Y} = \sum_{i=1}^n \omega_i \hat{y}_i \quad (14)$$

式中: \hat{Y} 为组合预测的预测结果; n 为基础预测模型的个数; ω_i 和 \hat{y}_i 分别为第 i 个预测模型的权重系数与预测结果,其中, ω_i 需满足

$$\sum_{i=1}^n \omega_i = 1 \quad 0 \leq \omega_i \leq 1 \quad (15)$$

将预测模型 $\hat{p}_s^{PV} = f(x_s; \Theta)$ 转化为组合预测形式,即

$$\hat{p}_s^{PV} = \sum_{i=1}^n \omega_i \hat{p}_{s,i}^{PV} \quad (16)$$

式中: $\hat{p}_{s,i}^{PV}$ 为第 s 个样本中第 i 个预测模型的光伏功率预测值。

将组合预测模型代入双层问题(式(2))中得:

$$\left\{ \begin{array}{l} \max_{\Theta} \frac{1}{S} \sum_{s=1}^S (C_s^{DA}(\hat{p}_s^{PV}) + C_s^{RT}(\hat{p}_s^{PV}, p_s^{PV})) \\ \text{s.t. } \hat{p}_s^{PV} = \sum_{i=1}^n \omega_i \hat{p}_{s,i}^{PV} \\ C_s^{DA}(\hat{p}_s^{PV}) = \max_{d_s} g_{DA}(d_s) \\ C_s^{RT}(\hat{p}_s^{PV}, p_s^{PV}) = \max_{r_s} g_{RT}(r_s) \end{array} \right. \quad (17)$$

式(17)将式(2)的上层预测模型变换为组合预

测形式,寻优参数为组合预测的权重系数,可有效减小预测模型的参数规模与寻优范围,将复杂的功率预测模型转化为线性函数形式,降低双层问题的求解难度。

2.2 组合预测参数寻优方法

本文将上下层问题分离,分别对上层预测模型与下层优化模型进行参数寻优,过程如图2所示,具体步骤如下。




图2 双层模型求解过程
Fig. 2 Solving process of bi-level model

1)固定预测模型:采用固定权重系数进行光伏日前功率组合预测;

2)求解调度问题:根据光伏组合预测结果求解下层光储电站两阶段运行问题,计算训练集总的日运行收益;

3)迭代优化权重系数:以训练集样本总运行收益最大为目标函数,使用启发式算法迭代求解最优权重系数。

2.2.1 组合预测基础模型构建

本文采用支持向量机回归^[29](support vector regression, SVR)、梯度提升决策树^[30](gradient boosting decision tree, GBDT)、随机森林^[31](random forest, RF)、多层感知机^[32](multilayer perceptron, MLP)、 k 近邻^[33](k -nearest neighbor, KNN)回归这5种预测方法作为基础预测模型。

2.2.2 基于自组织映射的光伏与电价数据聚类方法

组合预测可分为固定权重组合预测与变动权重组合预测。变动权重组合预测可利用外部环境特征、子模型预测性能对权重系数进行调整,从而更好地发挥各基础模型优点。本文利用聚类原理,将光伏功率特征、电价变化特征相似的样本进行集群,并分别计算各集群的最优权重,从而实现权重调整。

聚类算法采用自组织映射^[34](self-organizing map, SOM)算法。SOM算法属于无监督的神经网络算法,由输入层与竞争层组成,以竞争获胜的神经元为中心确定其邻域并计算邻域内神经元权重,通过更新网络实现数据的稳定分类。SOM算法对初始中心不敏感且高度可视化,其具体训练步骤如下:

1)数据预处理:清洗并筛选特征变量,对输入特征 $x \in \mathbf{R}^N$ (N 为输入特征维度)进行归一化。

2)网络初始化:设置迭代次数最大值为 K ,参数学习率 $\alpha^{(k)}$ 与神经元邻域 $\sigma^{(k)}$ 均随着迭代次数 k 的增大而减小,竞争层神经元为 M ,对其权重 $\omega \in \mathbf{R}^{M \times N}$ 赋随机初始值。

3)神经元竞争:计算输入特征向量与竞争层各神经元权重向量 ω_i 的距离,其中,距离最小者为获胜神经元 c ,其对应的权重向量为 ω_c ,采用欧氏距离作为距离度量指标。

$$\omega_c = \arg \min \|x - \omega_i\|_2 \quad (18)$$

4)网络权重与输入变量更新:更新获胜神经元邻域中的神经元权重。

$$\omega_i^{(k+1)} = \omega_i^{(k)} + h_{ci}^{(k)}(x^{(k)} - \omega_i^{(k)}) \quad (19)$$

权函数 h_{ci} 定义如下:

$$h_{ci}^{(k)} = \alpha^{(k)} e^{-\frac{\|\omega_c - \omega_i\|_2^2}{2(\sigma^{(k)})^2}} \quad (20)$$

选择下一个训练样本作为网络输入变量,返回步骤3),直至遍历样本训练集。

5)判断收敛:判断是否达到最大迭代次数 K 或两次迭代误差小于设定值,若未达到则返回步骤3)。

聚类算法属于数据预处理部分。SOM分类的输入特征为光伏功率预测值与电价预测值,分类后对每个聚类分别进行组合预测模型参数训练。

$$G_{\text{cluster}} = \text{classify}(x) \quad (21)$$

式中: $G_{\text{cluster}} \in \{\text{类别1, 类别2, } \dots\}$ 为该样本所属类别; $\text{classify}(\bullet)$ 为分类SOM网络; x 为输入变量,本文采用光伏功率预测值与电价预测值作为特征值。基于SOM算法的预测框架训练过程见附录A图A1。

2.2.3 基于饥饿游戏搜索的参数寻优方法

引入组合预测模型后,上层预测模型中的参数求解问题转化为组合预测的权重系数确定问题。

本文提出的上下层模型包括上层预测模型与下层调度模型,预测与调度为上下层关系,光储电站进行优化调度时采用固定参数的光伏功率预测模型。同时,光储电站调度为日前-日内两阶段优化问题,具体类型为混合整数线性规划,即下层模型为混合整数线性规划。

双层优化的一种常见解法为:若下层问题为凸优化问题,则利用KKT(Karush-Kuhn-Tucker)条件将双层优化转换为单层优化问题。由于本文的下层优化问题为混合整数线性规划,难以将双层问题直接转化为单层优化问题,故采用先固定上层组合预测模型中权重系数求解下层问题,再迭代更新预测模型参数的方式求解双层问题。

启发式参数寻优算法存在性能不稳定的缺陷,

故较少应用于VOF领域。组合预测的权重系数范围为 $[0, 1]$,预测模型稳定性强,故可以通过启发式算法进行权重系数寻优。

饥饿游戏搜索^[35](hunger games search, HGS)算法是一种模拟饥饿生物进行食物搜索的群体智能算法,具有结构简单、易收敛、稳定性高的优点,广泛应用于工程实践。HGS算法模拟生物群体协作捕食,可表示为:

$$X^{(k+1)} = \begin{cases} X^{(k)}(1+r(1)) & r_1 < l \\ W_1 X_b + RW_2 |X_b - X^{(k)}| & r_1 \geq l, r_2 \geq E \\ W_1 X_b - RW_2 |X_b - X^{(k)}| & r_1 \geq l, r_2 < E \end{cases} \quad (22)$$

式中: r_1, r_2 为区间 $[0, 1]$ 中服从均匀分布的随机数; $r(1)$ 为服从标准正态分布的随机数; X_b 为个体最优位置,即需搜索的最优权重系数; $X^{(k)}$ 为第 k 次迭代中的个体位置,即本次迭代采用的组合预测权重; l 为超参数; E 为搜索位置控制变量,使用双曲正割函数计算当前搜索权重与最优权重距离,如式(23)所示; R 为生物搜索范围,取值为 $[-1, 1]$,随迭代次数的增加逐渐缩减至0; W_1 和 W_2 为饥饿权重,计算公式分别见式(24)、式(25)。

$$E = \frac{2}{e^{|F(i)-B_F|} + e^{-|F(i)-B_F|}} \quad (23)$$

$$R = 2 \left[2 \left(1 - \frac{t}{T} \right) \right] r' - 2 \left(1 - \frac{t}{T} \right) \quad (24)$$

$$W_1 = \begin{cases} r_4 h_{\text{ungry}}(i) \frac{N'}{\sum_i h_{\text{ungry}}(i)} & r_3 < l \\ 1 & r_3 \geq l \end{cases} \quad (25)$$

$$W_2 = 2r_5 \left(1 - e^{-|h_{\text{ungry}}(i) - \sum_i h_{\text{ungry}}(i)|} \right) \quad (26)$$

式中: $F(i)$ 为第 i 个生物的适应度; B_F 为最佳适应度,即式(17)的目标函数值; r_3, r_4, r_5, r' 为区间 $[0, 1]$ 中服从均匀分布的随机数; N' 为设定的种群大小; $h_{\text{ungry}}(i)$ 的计算公式如式(27)一式(29)所示。

$$h_{\text{ungry}}(i) = \begin{cases} 0 & F(i) = B_F \\ h_{\text{ungry}}(i) + H & F(i) \neq B_F \end{cases} \quad (27)$$

$$H = \begin{cases} L_H(1+r_6) & T_H < L_H \\ T_H & T_H \geq L_H \end{cases} \quad (28)$$

$$T_H = 2r_7 \frac{F(i) - B_F}{W_F - B_F} (U_B - L_B) \quad (29)$$

式中: T_H, L_H 为超参数,分别表示饥饿值的上、下限; U_B, L_B 分别为搜索空间上、下限,即权重系数寻优范

围,本文设定为 $[0, 1]$; r_6, r_7 为区间 $[0, 1]$ 中服从均匀分布的随机数; W_F 为最劣适应度。

组合预测参数优化过程如图3所示,具体步骤如下:

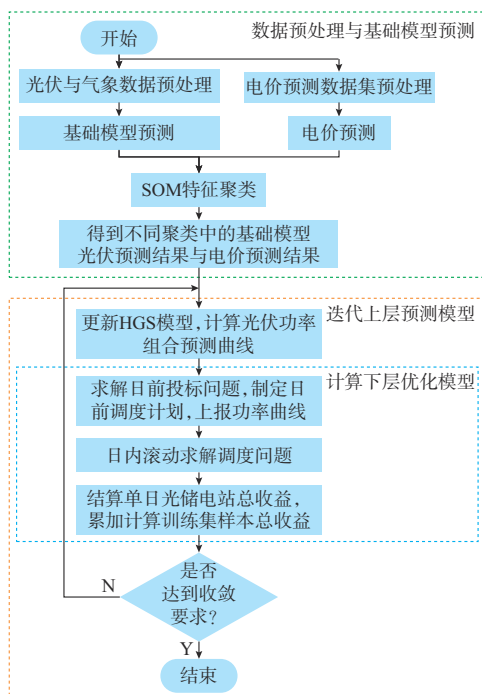


图3 双层问题求解流程图
Fig. 3 Flow chart of solving bi-level problem

1)数据预处理:对光伏功率预测数据集与日前市场电价预测数据集进行异常值修正与数据归一化。

2)光伏基础预测模型训练与电价预测:使用多种基础模型对光伏功率进行预测;训练日前市场出清电价预测模型;以光伏基础模型预测值与日前电价预测值为特征变量,使用SOM算法进行聚类。

3)权重参数优化:使用HGS算法对不同聚类分别进行权重系数寻优,根据基础预测模型与HGS算法寻优结果组合预测光伏功率,按预测结果进行日前市场投标与日内滚动优化,目标函数为单个聚类中所有样本日的总体收益最大,直至HGS算法收敛。

4)效果测试:根据实际光伏功率预测曲线与电价预测曲线构建输入特征 x ,并将该特征量作为SOM算法输入变量,输出量为该样本所属聚类;随后,采用聚类中组合预测权重系数进行光伏功率预测,根据光伏功率预测曲线进行日前投标与日内调度,计算测试集总体收益指标。

SOM网络竞争层中,同一邻域中神经元不断进行竞争与权重更新,进而可将特征相似的输入样本映射至相邻输出节点完成聚类。文中光储电站调度

问题与光伏功率、出清电价相关,故将光伏功率预测曲线与日前市场预测出清电价曲线作为输入特征,采用SOM算法聚类,针对不同类别分别训练VOF模型,得出对应最优权重系数,更好地适应不同光伏功率、电价波动场景,提升模型的灵活性。

3 算例分析

3.1 数据集介绍

本文采用美国俄勒冈州本德(Bend)一处光伏电站的历史数据^[36]。该电站纬度为 44.06° ,经度为 -121.31° ,装机容量为3.6 kW,使用2018年8月2日至2023年10月31日的整点时刻光伏功率数据。高分辨率快速刷新^[37](high-resolution rapid refresh, HRRR)是由美国国家环境预测中心建立的分辨率为3 km的大气模型,其覆盖范围为美国及毗邻区域,可提供48 h内的气象预测数据,时间分辨率为1 h。选取其中数据较为完整的126个预测气象特征量,与对应时间的光伏功率数据构成光伏功率预测数据集。光伏功率预测模型输入特征为3个时间戳特征量(月、日、小时)与HRRR模型提供的126个气象特征预测量,包括水平面2 m气温、地表温度等共计129个输入特征量。去除空白数据后共有1 893个完整样本日,选取前75%作为训练集(1 420个样本日),后25%作为测试集(473个样本日)。在进行基础光伏功率预测模型训练时,由于光伏出力的间歇性,仅采用当地时间06:00—19:00的功率数据,即每个样本日包含14个数据点,输入特征选用预测气象特征与时间戳,对输入特征与光伏输出均采用归一化处理,使用10折交叉验证。

不考虑光储电站光伏功率对电力市场的影响,故选用的电价数据不与光伏数据对应。本文采用PJM电力市场COMED节点的市场出清价格,日前市场出清电价预测使用双层深度神经网络(deep neural network, DNN)进行预测,辅助预测特征量为2个负荷预测值。该模型输出变量为一天内每小时电价预测值,共24个输出特征量;输入变量为该样本对应前1日、2日、3日、7日的历史电价(96个特征量),前1日、7日的历史负荷值(96个特征量)、负荷预测值(48个特征量)、时间戳(7个特征量),共计247个输入特征量。利用文献[38]中模型对PJM日前市场出清价格进行预测,时间为2013年10月10日至2018年12月24日,并将出清价格作为日前市场购电价格 v ,日前市场售电价格 $u = 0.9v$ 。

由于电力系统的正负备用成本不同,同时为促进新能源消纳、减少弃光,正不平衡惩罚系数设置高于负不平衡惩罚系数。选用对应时段PJM实时市

场出清价格 p_n 作为日内不平衡市场的惩罚电价标准^[39], 不平衡惩罚电价 $u^{im} = 1.8p_n, v^{im} = 1.5p_n$, 即对应惩罚系数分别为 1.8 和 1.5, 正惩罚系数为负惩罚系数的 1.2 倍。为避免实时电价较低导致惩罚价格小于投标价格, 设置负惩罚电价最小值为日前市场实际结算价格, 正惩罚电价保持与负惩罚电价的系数关系, 即

$$\begin{cases} v^{im} = \max(v, 1.5p_n) \\ u^{im} = 1.2\max(v, 1.5p_n) = \max(1.2v, 1.8p_n) \end{cases} \quad (30)$$

日前市场电价预测模型暂未通过组合预测进行优化, 日内滚动优化时间窗口为 4 h, 不进行日内实时市场电价预测。

本文提出的光储电站模型的光伏装机容量为 36 MW, 即采用 10 000 组光伏^[36]并联, 配备储能容量为 3.6 MW, 其具体参数如附录 B 表 B1 所示。使用 Python 3.11 实现编程, 日前投标与日内调度模型采用 Gurobi solver 10 求解, 运行环境为 Intel core i7-11390H、160 GB 内存。

3.2 基础预测模型性能

本文使用 Python scikit-learn 中的回归模块, 包含 SVR 模块、直方图梯度提升回归模块 (Hist Gradient Boosting Regressor)、随机森林回归模块 (Random Forest Regressor)、多层感知机回归模块 (MLP Regressor) 与 k 近邻回归模块 (K Neighbors Regressor), 进行光伏功率基础模型预测。基础预测模型以预测精度最高为拟合目标。本文精度指标为均方根误差 (root mean square error, RMSE), 并以此判断测试集预测效果, 定义如下:

$$I_{RMSE} = \sqrt{\frac{1}{n'} \sum_{h=1}^{n'} (y_h - \hat{y}_h)^2} \quad (31)$$

式中: y_h, \hat{y}_h 分别为第 h 个样本的真实值、预测值; n' 为样本总数。RMSE 计算采用归一化光伏数据。

由于数据集中输入特征较多, 将输入数据通过互信息进行筛选。模型具体超参数设置见附录 B 表 B2, 模型预测特征见表 B3。SVR1 (采用径向基核函数的支持向量机)、SVR2 (采用多项式核函数的支持向量机)、GBDT、RF、MLP 模型的预测误差相近, KNN 模型的预测误差较大; 但各模型的基础统计数据均值与方差存在差异, 该特征也表现了不同模型的预测特性不同: GBDT、RF、MLP、KNN 预测光伏功率偏大; GBDT、KNN 模型预测曲线较为平稳。通过组合不同特性的模型, 可获得更优的预测效果。

3.3 VOF 性能实验

本文经济指标为日平均收益 (average monetary

score, AMS), 即

$$I_{AMS} = \frac{1}{S} \sum_{s=1}^S (C_s^{DA}(\hat{p}_s^{PV}) + C_s^{RT}(\hat{p}_s^{PV}, p_s^{PV})) \quad (32)$$

本文选择基础预测模型 MLP、传统精度导向预测 (accuracy-oriented forecasting, AOF) 模型、线性回归 (linear-regression, LR) 模型^[24]、本文所提出的 VOF 模型进行对比分析。AOF 模型采取组合预测方式, 根据基础模型预测结果, 以训练集样本预测精度最高为目标计算组合预测权重系数; LR 模型选用基础预测模型中训练集预测精度最高的 SVR2 模型为原始预测模型, 进行线性拟合, AOF 与 LR 模型具体计算过程如附录 C 所示。模型冗余性与模型鲁棒性实验如附录 D 所示。

组合预测中子模型权重受自身模型准确度、与其他模型的互信息等多种因素影响。AOF 与 VOF 模型中子模型的权重系数见表 1。由表 1 可知, 在组合模型 AOF 中, 基础模型 SVR1 与 KNN 模型比重较小, 其中, KNN 预测精度相对较低。

表 1 各模型权重系数
Table 1 Weight coefficient of each model

模型名称	子模型的权重系数					
	SVR1	SVR2	GBDT	RF	MLP	KNN
AOF	6.390×10^{-13}	3.373×10^{-1}	2.824×10^{-1}	2.045×10^{-1}	1.758×10^{-1}	3.020×10^{-1}
VOF	1.410×10^{-7}	1.501×10^{-1}	1.410×10^{-7}	6.069×10^{-1}	2.429×10^{-1}	1.410×10^{-7}
RMSE/p.u.	0.126 7	0.127 4	0.125 6	0.127 0	0.126 7	0.138 1

表 2 展示了 4 种预测模型的精度指标与经济指标。与基础模型 MLP 比较, AOF 模型精度指标提升 5.37%, VOF 模型精度指标提升 4.42%。该结果表明: 组合预测模型可提升预测精度; 运行收益导向的 VOF 模型预测精度逊于 AOF 模型, 但高于基础模型, VOF 模型可有效保障预测准确性; 在经济指标方面, VOF 模型取得最高 AMS, 相较于 AOF 模型, VOF 收益提升 13.98%, 在提升光储电站运行收益方面效果显著。

表 2 各模型预测效果对比
Table 2 Comparison of forecasting effects of various models

模型	RMSE/p.u.	AMS/美元
MLP	0.126 7	1 632.95
AOF	0.119 9	1 705.76
VOF	0.121 1	1 944.15
LR	0.130 0	1 860.28

在测试集的473个样本日中,AOF模型的平均光伏投标收益为4 089.95美元,平均惩罚费用为2 373.60美元,AMS为1 705.76美元;VOF模型的平均光伏投标收益为4 224.85美元,平均惩罚费用为2 270.35美元,AMS为1 944.15美元,VOF模型的AMS指标相比AOF模型提升13.98%;测试集共有333个样本(即70.40%的测试样本),VOF模型平均收益超过AOF模型。VOF模型在提升光伏投标收入与降低惩罚费用方面均有优势。

选取测试集样本中VOF模型效能较优的样本日1(2022年9月2日)与效能较差的样本日2(2022年8月7日),图4所示为AOF模型、VOF模型、LR模型预测曲线与光伏实际功率曲线,图5所示为AOF模型、VOF模型、LR模型对应运行结果。

样本日1中,VOF模型和AOF模型的日运行收益分别为3 712.36和3 509.32美元。AOF模型中,负惩罚电量为10.21 MW·h,对应负惩罚成本为376.14美元;正惩罚电量为17.25 MW·h,对应正惩罚成本为717.43美元;总投标量为166.08 MW·h,投标收益为4 616.94美元。VOF模型中,负惩罚电量为12.56 MW·h,对应负惩罚成本为464.17美元;正惩罚电量为13.81 MW·h,对应正惩罚成本为581.79美元;总投标量为171.87 MW·h,投标收益为4 772.14美元。由图4(a)可知,VOF模型的预测误差高于AOF模型。观察图5(a)、(c)可知,VOF模型的前日市场投标量与负惩罚电量较高,正惩罚电量较低,利用模型正负惩罚的差异,VOF模型的实际惩罚成本较低,并且VOF模型的前日市场投标电

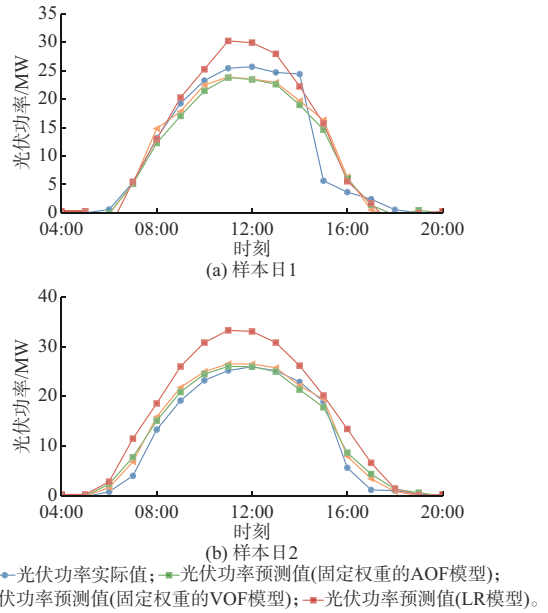


图4 各模型预测结果对比
Fig. 4 Comparison of forecasting results of various models

量高于AOF模型。因此,VOF模型在预测精度较低的情况下光储电站仍能够取得更高收益。

样本日2中,VOF模型日总收益为7 821.26美元,AOF模型日总收益为8 072.16美元。该样本日中,VOF模型预测平均误差为0.83 MW,利用储能设备的调节作用,平均惩罚电量降低至0.76 MW;AOF模型预测平均误差为0.88 MW,但是平均惩罚电量仅为0.68 MW,进而使得光储电站效益提升。通过分析以上具体案例可得出结论:不同样本日中

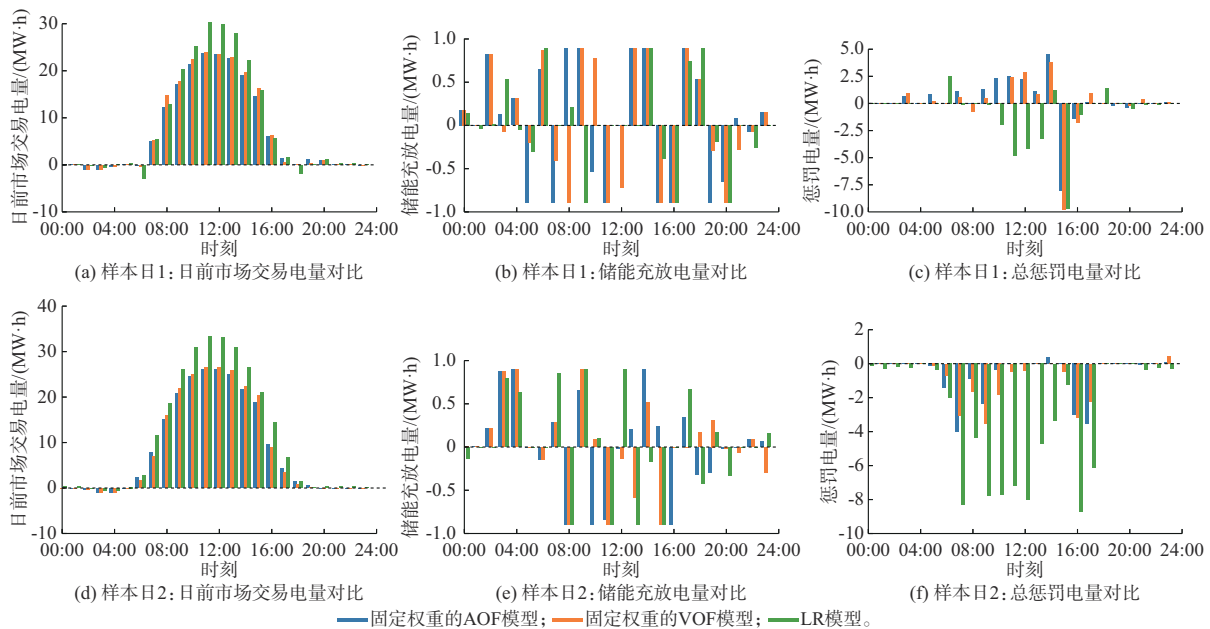


图5 各模型运行结果对比
Fig. 5 Comparison of operation results of various models

预测模型效能受具体实际光伏功率与电价影响。

VOF模型经济效益提升包含两方面物理成因:1)组合预测本质是基础预测结果的二次训练,不同基础模型预测结果包含不同信息,达到信息互补的作用;本文采用最优权重法确定最优权重系数,使得各模型达到最优的信息组合效果。2)光储电站运行收益与光伏功率预测误差具有非对称性、非线性关系。在保持总体误差水平相近的条件下,本文通过二次调整初始预测结果,提升光储电站运行收益。首先,调度部门对正负不平衡电量的惩罚力度不同;其次,光储电站配置储能设备进行电量调节。本文设置正、负惩罚系数分别为1.8和1.5,即正惩罚系数为1.2倍负惩罚系数;若合理提高光伏日前市场投标量,光储电站在增加投标收益的同时,利用不同惩罚价格可以减小惩罚成本。

表3 AOF与VOF模型的预测结果对比
Table 3 Comparison of forecasting results between AOF and VOF models

模型	投标收益/美元	正惩罚电量/(MW·h)	正惩罚成本/美元	负惩罚电量/(MW·h)	负惩罚成本/美元
AOF	4 089.95	23.896 9	1 340.57	20.990 3	1 032.91
VOF	4 224.85	21.028 7	1 160.63	22.474 9	1 109.47

LR模型平均投标收益为4 525.51美元,惩罚费用为2 655.30美元,AMS为1 860.28美元,由投标收益与图5中日前市场交易电量可知,LR模型的正投标电量高于AOF与VOF模型,投标收益与惩罚成本均提高。由于惩罚成本增加量小于投标收益增加量,LR模型可以有效提高光储电站收益,该现象也表现了预测误差与电站收益的非对称关系。LR模型的主要缺陷为:1)模型预测准确性低,光储电站申报电量不能准确反映光储电站功率水平,若大量光储电站采用该投标模式,调度部门无法提前获知可再生能源真实功率情况,进而对电力调度造成影响;2)LR模型的经济效益浮动较大,模型效能稳定性差。在光伏功率预测值明显偏大,即突发阴雨天气情况下,LR模型预测效能显著降低。

LR模型在样本日1中的总收益为4 145.50美元,其中,投标收益为5 327.58美元,惩罚成本为1 173.80美元,相较于AOF模型,投标收益增加710.64美元,而惩罚成本仅增加80.23美元。LR模型充分利用正负惩罚电价差异,在预测精度远低于AOF与VOF模型的情况下,有效增加光储电站收益。在样本日2中,由图4(b)可知,光伏功率小于预测值,且下午时段实时电价突升、惩罚电价上升,LR模型当日收益仅为-580.15美元,远低于AOF与VOF模型收益。

以上算例均使用正、负不平衡惩罚系数1.8和

AOF与VOF模型的效果对比见表3,表中数据均表示测试集的日平均指标。根据表3数据可得出以下结论:1)VOF模型可有效利用储能设备,在预测精度低于AOF模型预测精度的情况下,可降低总惩罚电量,VOF模型预测精度较低,但其日均惩罚电量为43.50 MW·h,低于AOF模型日均惩罚电量(44.89 MW·h);2)VOF模型可以通过调整预测值来减小惩罚成本,VOF模型正惩罚电量低于AOF模型,负惩罚电量高于AOF模型,利用了正惩罚系数大于负惩罚系数的模型特点,降低了惩罚成本,总惩罚成本由2 373.47美元减少至2 270.10美元;3)VOF模型可提升光储电站的投标收益,通过改变投标策略,VOF模型投标收益为4 224.85美元,高于AOF模型的收益(4 089.95美元)。

1.5,为验证所提方法的适应性,对不同惩罚系数进行测试,结果见表4。由表4可知,在负惩罚系数保持不变,正惩罚系数提高的情况下,两种预测模型的收益均有所下降,但VOF模型的AMS均高于AOF模型,且提升幅度逐渐增大。由于增加日前市场投标量在减少惩罚成本的同时可提高投标收益,故在惩罚系数相同时,VOF模型仍获得更高的经济效益。

表4 惩罚系数对模型效果的影响
Table 4 Impact of penalty coefficient on model performance

正惩罚系数	负惩罚系数	AMS/美元		提升效果/%
		AOF模型	VOF模型	
1.20	1.50	2 152.65	2 317.00	7.634 5
1.50	1.50	1 929.21	2 163.50	12.144 2
1.80	1.50	1 705.76	1 944.15	13.975 6
2.25	1.50	1 370.58	1 710.60	24.807 9
2.70	1.50	1 035.38	1 387.43	34.001 0

3.4 启发式算法性能比较实验

为了验证本文采用启发式算法的优越性,对本文采用的HGS算法、粒子群优化(particle swarm optimization, PSO)算法与遗传算法(genetic algorithm, GA),迭代次数均为500。附录B表B4所示为启发式算法采用的参数,各启发式算法训练集的寻优结果见表5。

表 5 启发式算法的寻优结果
Table 5 Optimization results of heuristic algorithms

算法	日平均收益/美元	基础模型权重					
		SVR1	SVR2	GBDT	RF	MLP	KNN
HGS	1 874.19	1.41×10^{-7}	0.150 1	1.41×10^{-7}	0.606 9	0.242 9	1.41×10^{-7}
PSO	1 870.24	5.81×10^{-2}	0.168 5	6.46×10^{-9}	0.614 5	0.158 9	6.46×10^{-9}
GA	1 868.40	2.05×10^{-2}	0.214 3	4.50×10^{-3}	0.551 8	0.194 0	1.49×10^{-2}

3种启发式算法的寻优效果对比见图6,由于启发式算法每次的迭代结果存在随机性,为使得曲线趋势更为清晰,选用每5次迭代中的最优寻优效果数据,并绘制曲线。由表5可知,3种启发式算法中,HGS算法取得最高的训练集收益,但3种算法的效果差异不明显,模型权重具有相似性。观察图6可知,HGS模型的收敛速度最快,在第200次迭代左右已达到较好的寻优效果。




图 6 启发式算法的寻优效果
Fig. 6 Optimization effect of heuristic algorithms

3.5 SOM算法聚类性能实验

SOM算法聚类实验包括SOM算法聚类下的AOF模型(下文简称SOM-AOF模型)与SOM算法聚类下的VOF模型(下文简称SOM-VOF模型)。SOM-AOF模型的聚类特征量为组合预测基础子模型各时刻的光伏功率预测向量,即SOM输入层个数为6。为保证光伏功率预测向量获得充分分类且每个聚类中包含的样本数充足,SOM网络中竞争层神经元个数设置为5。附录A图A2所示为SOM算法聚类效果,由图A2可知,SOM算法可以有效聚类相似特征的光伏数据。图A3所示为2023年5月12日光伏功率预测结果,固定权重的AOF模型的日预测误差RMSE为0.0407,SOM-AOF模型的RMSE为0.0308,精度提升24.47%。使用SOM算法聚类后,测试集的总体预测RMSE从0.1199降至0.1190,与聚类前比较减小0.724%。由实验结果可知,SOM-AOF模型可提升光伏日前功率预测的准确度。

由于光伏功率与市场价格均会对光储电站运行

利润产生影响,SOM-VOF模型选用光伏与电价日预测曲线作为聚类特征。SOM网络的输入层包含168个神经元,竞争层包含 $M=3 \times 2$ 个神经元。附录A图A4所示为SOM聚类效果,由图A4可知,SOM算法可聚类具有相同光伏功率、电价波动特征的样本日。

图7所示为2022年8月24日的光伏功率预测曲线与光伏实际功率曲线,图8所示为对应的光储电站调度结果,包括日前市场投标、储能调度与不平衡市场惩罚3个部分。通过SOM算法聚类优化后,该样本日总收益从4 218.94美元增长至4 608.60美元,SOM-VOF模型通过增加日前投标量,提高日前市场投标收益,同时使正惩罚电量下降。




图 7 预测结果对比(2022-08-24)
Fig. 7 Comparison of forecasting results (2022-08-24)

在测试集样本中,与固定权重的VOF模型相比,SOM-VOF模型的日平均收益由1 944.15美元增长至1 950.89美元,提升0.35%。实验效果显示,通过聚类方式实现权重调整可有效提升光储电站收益,但受日内惩罚电价波动影响,提升效果并不明显。

4 结语

本文提出了面向光储电站运行收益提升的光伏功率价值导向预测方法。首先,搭建光储电站光伏日前功率预测与电站日前投标-日内运行的双层优化问题;然后,使用组合预测作为上层预测模型,通过SOM算法进行特征聚类,采用HGS算法求解组合预测模型的权重系数,得出以下结论:

1)以运行收益为导向的价值导向预测方法可提

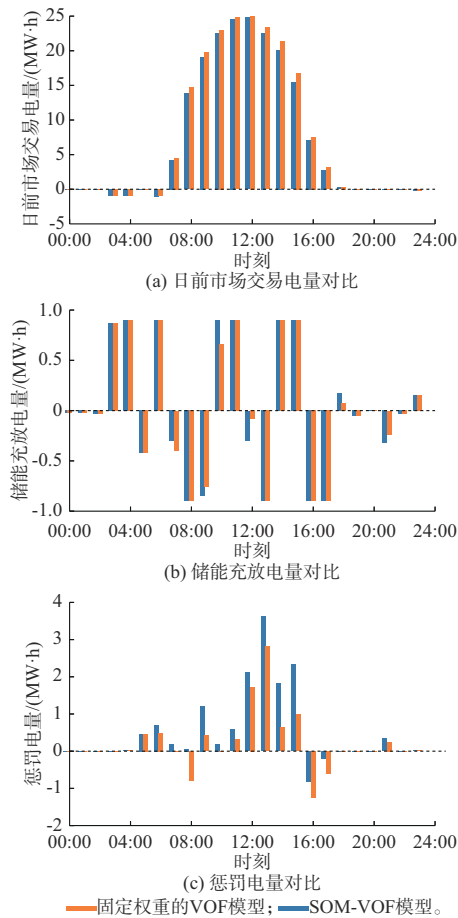


图8 调度结果对比
Fig. 8 Comparison of dispatching results

升光储电站参与两阶段电力市场的经济效益。

2)使用组合预测作为上层预测模型可以简化预测模型形式、减小寻优参数范围,并有效保障预测模型的准确性,组合预测的仿射性质使得预测模型更易嵌入价值导向优化问题。

下一步工作将考虑从风险角度构建预测模型,具体评估光储电站参与电力市场的运行风险,并制定对应运行策略。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

参考文献

- [1] 朱敏.我国新能源消纳困难原因及其对策[J].中国发展观察,2018(21):35-37.
ZHU Min. Causes and countermeasures of difficulties in the consumption of new energy in China [J]. China Development Observation, 2018(21): 35-37.
- [2] 王强强,姚良忠,盛万兴,等.基于机会约束规划的配电网分布式光伏承载力提升方法[J].电力系统自动化,2023,47(18):

132-141.

WANG Qiangqiang, YAO Liangzhong, SHENG Wanxing, et al. Enhancement method for distributed photovoltaic hosting capacity of distribution network based on chance-constrained programmings [J]. Automation of Electric Power Systems, 2023, 47(18): 132-141.

- [3] 武昭原,刘婧宇,周明,等.分散决策下分布式光伏储能系统外部性价值量化评估[J].电力系统自动化,2024,48(5):38-47.
WU Zhaoyuan, LIU Jingyu, ZHOU Ming, et al. Quantitative evaluation of externality value for distributed photovoltaic energy storage system under decentralized decision-making [J]. Automation of Electric Power Systems, 2024, 48(5): 38-47.
- [4] 龚莺飞,鲁宗相,乔颖,等.光伏功率预测技术[J].电力系统自动化,2016,40(4):140-151.
GONG Yingfei, LU Zongxiang, QIAO Ying, et al. An overview of photovoltaic energy system output forecasting technology [J]. Automation of Electric Power Systems, 2016, 40(4): 140-151.
- [5] LIU Y Q, SUN Y, INFELD D, et al. A hybrid forecasting method for wind power ramp based on orthogonal test and support vector machine (OT-SVM) [J]. IEEE Transactions on Sustainable Energy, 2017, 8(2): 451-457.
- [6] 吴春华,董阿龙,李智华,等.基于图相似日和 PSO-XGBoost 的光伏功率预测[J].高电压技术,2022,48(8):3250-3259.
WU Chunhua, DONG Along, LI Zhihua, et al. Photovoltaic power prediction based on graph similarity day and PSO-XGBoost [J]. High Voltage Engineering, 2022, 48(8): 3250-3259.
- [7] 魏联滨,王彬,王莹,等.基于气象相似日选取与提升回归树的光伏发电短期功率预测[J].电子器件,2022,45(1):183-188.
WEI Lianbin, WANG Bin, WANG Ying, et al. Short-term power forecast of photovoltaic power generation based on weather similarity day and boosting regression tree [J]. Chinese Journal of Electron Devices, 2022, 45(1): 183-188.
- [8] LIU D, SUN K. Random forest solar power forecast based on classification optimization [J]. Energy, 2019, 187: 115940.
- [9] 王育飞,付玉超,薛花.计及太阳辐射和混沌特征提取的光伏发电功率 DMCS-WNN 预测法[J].中国电机工程学报,2019,39(增刊1):63-71.
WANG Yufei, FU Yuchao, XUE Hua. DMCS-WNN prediction method of photovoltaic power generation by considering solar radiation and chaotic feature extraction [J]. Proceedings of the CSEE, 2019, 39(S1): 63-71.
- [10] KIM H, PARK S, PARK H J, et al. Solar radiation forecasting based on the hybrid CNN-CatBoost model [J]. IEEE Access, 2023, 11: 13492-13500.
- [11] ZHANG Y, WEN H, WU Q. A contextual bandit approach for value-oriented forecasting interval forecasting [J]. IEEE Transactions on Smart Grid, 2024, 15(2): 2271-2281.
- [12] AMOS B, KOLTER J Z. OptNet: differentiable optimization as a layer in neural networks [EB/OL]. [2024-09-10]. <https://arxiv.org/abs/1703.00443v5>.
- [13] SUN H X, SHI Y, WANG J Y, et al. Alternating differentiation for optimization layers [EB/OL]. [2024-09-10]. <https://arxiv.org/abs/2210.01802v2>.

- [14] AGRAWAL A, BARRATT S, BOYD S, et al. Differentiating through a cone program [EB/OL]. [2024-09-10]. <https://arxiv.org/abs/1904.09043v4>.
- [15] ZHANG Y F, WEN H L, BIAN Y X, et al. Deriving loss function for value-oriented renewable energy forecasting [EB/OL]. [2024-09-10]. <https://arxiv.org/abs/2310.00571v1>.
- [16] ZHANG Y F, JIA M S, WEN H L, et al. Toward value-oriented renewable energy forecasting: an iterative learning approach [EB/OL]. [2024-09-10]. <https://arxiv.org/abs/2309.00803v2>.
- [17] MANDI J, KOTARY J, BERDEN S, et al. Decision-focused learning: foundations, state of the art, benchmark and future opportunities [EB/OL]. [2024-09-10]. <https://arxiv.org/abs/2307.13565v4>.
- [18] ELMACHTOUB A N, GRIGAS P. Smart “predict, then optimize” [J]. *Management Science*, 2022, 68(1): 9-26.
- [19] MULAMBA M, MANDI J, DILIGENTI M, et al. Contrastive losses and solution caching for predict-and-optimize [EB/OL]. [2024-09-10]. <https://arxiv.org/abs/2011.05354v2>.
- [20] SANG L W, XU Y L, LONG H, et al. Safety-aware semi-end-to-end coordinated decision model for voltage regulation in active distribution network [J]. *IEEE Transactions on Smart Grid*, 2023, 14(3): 1814-1826.
- [21] ELMACHTOUB A N, LIANG J C N, MCNELLIS R. Decision trees for decision-making under the predict-then-optimize framework [C]// *International Conference on Machine Learning*, July 12-18, 2020.
- [22] MUÑOZ M A, MORALES J M, PINEDA S. Feature-driven improvement of renewable energy forecasting and trading [J]. *IEEE Transactions on Power Systems*, 2020, 35(5): 3753-3763.
- [23] 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.
- [24] KHABIBRAKHMANOV I, LU S, HAMANN H F, et al. On the usefulness of solar energy forecasting in the presence of asymmetric costs of errors [J]. *IBM Journal of Research and Development*, 2016, 60(1): 1-7.
- [25] CHEN X B, LIU Y K, WU L. Towards improving unit commitment economics: an add-on tailor for renewable energy and reserve predictions [J]. *IEEE Transactions on Sustainable Energy*, 2024, 15(4): 2547-2566.
- [26] ZHANG H P, LI R, CHEN Y, et al. Risk-aware objective-based forecasting in inertia management [J]. *IEEE Transactions on Power Systems*, 2024, 39(2): 4612-4623.
- [27] 李瑞月. 风光联合系统储能容量优化配置技术研究 [D]. 北京: 华北电力大学, 2022.
LI Ruiyue. Research on optimal configuration technology of energy storage capacity of wind-solar combined system [D]. Beijing: North China Electric Power University, 2022.
- [28] 杨波, 汤文成, 吴福保, 等. 考虑 CVaR 的“新能源+储能”电厂日前市场投标策略 [J]. *电力系统保护与控制*, 2022, 50(9): 93-100.
YANG Bo, TANG Wencheng, WU Fubao, et al. Day-ahead market bidding strategy for “renewable energy+energy storage” power plants considering conditional value-at-risk [J]. *Power System Protection and Control*, 2022, 50(9): 93-100.
- [29] CRISTIANINI N, TAYLOR J S. An introduction to support vector machines and other kernel-based learning methods [M]. Cambridge, UK: Cambridge University Press, 2000.
- [30] JEROME H F. Greedy function approximation: a gradient boosting machine [J]. *Annals of Statistics*, 2001, 29(5): 1189-1232.
- [31] BREIMAN L. Random forests [J]. *Machine learning*, 2001, 45: 5-32.
- [32] PAL S K, MITRA S. Multilayer perceptron, fuzzy sets, and classification [J]. *IEEE Transactions on Neural Networks*, 1992, 3(5): 683-697.
- [33] KRAMER O. Dimensionality reduction by unsupervised k-nearest neighbor regression [C]// *2011 10th International Conference on Machine Learning and Applications and Workshops*, December 18-21, 2011, Honolulu, USA.
- [34] KOHONEN T. The self-organizing map [J]. *Neurocomputing*, 1990, 21: 1-6.
- [35] YANG Y T, CHEN H L, HEIDARI A A, et al. Hunger games search: visions, conception, implementation, deep analysis, perspectives, and towards performance shifts [J]. *Expert Systems with Applications*, 2021, 177: 114864.
- [36] The University of Oregon Solar Radiation Monitoring Lab (SRML) [EB/OL]. [2024-09-10]. <http://is-solardata01.uoregon.edu/index.html>.
- [37] DOWELL D C, ALEXANDER C R, JAMES E P, et al. The high-resolution rapid refresh (HRRR): an hourly updating convection-allowing forecast model: part I motivation and system description [J]. *Weather and Forecasting*, 2022, 37(8): 1371-1395.
- [38] LAGO J, MARCJASZ G, DE SCHUTTER B, et al. Forecasting day-ahead electricity prices: a review of state-of-the-art algorithms, best practices and an open-access benchmark [J]. *Applied Energy*, 2021, 293: 116983.
- [39] WANG Y, DONG W, YANG Q. Multi-stage optimal energy management of multi-energy microgrid in deregulated electricity markets [J]. *Applied Energy*, 2022, 310: 118528.

许多(2000—),女,硕士研究生,主要研究方向:光伏功率预测。E-mail:xdd0816@sjtu.edu.cn

徐潇源(1989—),男,通信作者,副教授,主要研究方向:电力系统不确定性分析、电力系统优化运行。E-mail:xuxiaoyuan@sjtu.edu.cn

秦放(1991—),女,博士,主要研究方向:新能源资源评估及卫星遥感应用。E-mail:qinfang@epri.sgcc.com.cn

(编辑 鲁尔姣)

Value-oriented Photovoltaic Power Forecasting Method for Operation Revenue Improvement of Photovoltaic-Energy Storage Plants

XU Duo^{1,2}, XU Xiaoyuan^{1,2}, QIN Fang³, WANG Mengyuan^{1,2}, YAN Zheng^{1,2}, LU Jianyu⁴, YAO Hongchun³

- (1. Key Laboratory of Control of Power Transmission and Conversion, Ministry of Education (Shanghai Jiao Tong University), Shanghai 200240, China; 2. Shanghai Non-carbon Energy Conversion and Utilization Institute, Shanghai 200240, China; 3. China Electric Power Research Institute (Nanjing), Nanjing 210003, China; 4. East China Branch of State Grid Corporation of China, Shanghai 200120, China)

Abstract: The operation of photovoltaic-energy storage plants includes two parts: photovoltaic power forecasting and resource optimal scheduling. The photovoltaic power forecasting is usually carried out first with the goal of the highest forecasting accuracy, and then the optimal scheduling of the photovoltaic-energy storage plant is carried out based on the forecasting curve. However, there is a nonlinear and asymmetric relationship between the objective function value of optimal scheduling problem and the photovoltaic power forecasting error. At the approximate forecasting error level, the photovoltaic power forecasting result aiming at the highest accuracy does not necessarily lead to the maximum operation revenue of the photovoltaic-energy storage plant. In this regard, a value-oriented photovoltaic power forecasting method for improving the operation revenue of photovoltaic-energy storage plants is proposed. Firstly, a bi-level optimization problem is constructed, which includes photovoltaic power forecasting and power plant operation. The upper layer is the training problem of the day-ahead photovoltaic power forecasting model, and the lower layer is the two-stage optimal scheduling problem of day-ahead bidding and intra-day operation for the photovoltaic-energy storage plant under the conditions of given photovoltaic power forecasting model. Then, the upper forecasting problem is transformed into a combined forecasting form, and the forecasting model parameters are set as weight coefficients. A parameter solving method for the forecasting model based on iterative optimization is designed. Finally, using actual photovoltaic power plant data and electricity price data for case analysis, and compared with the photovoltaic power forecasting method that aims to achieve the highest forecasting accuracy, the effectiveness of the proposed method in improving the operation income of power plants is verified.

This work is supported by State Grid Corporation of China (No. 4000-202355095A-1-1-ZN).

Key words: photovoltaic-energy storage plant; value-oriented forecasting; photovoltaic power forecasting; optimal scheduling; combined forecasting; bi-level optimization; self-organizing map

