

DOI: 10.19783/j.cnki.pspc.211406

计及源荷不确定性及需求响应的离网型微电网 两阶段日前经济调度

侯慧^{1,2}, 王晴^{1,2}, 薛梦雅³, 吴细秀^{1,2}, 谢长君^{1,2}, 张清勇^{1,2}

(1. 武汉理工大学自动化学院, 湖北 武汉 430070; 2. 武汉理工大学深圳研究院, 广东 深圳 518000;
3. 国网安徽省电力有限公司蚌埠供电公司, 安徽 蚌埠 233000)

摘要: 离网型微电网在远洋海岛、偏远地区等有举足轻重的作用, 但源荷不确定性对其稳定运行具有一定负面影响。为减轻日内调度压力, 提出了一种适用于离网型微电网的两阶段日前调度模型。利用混沌相空间重构、多目标粒子群、数据驱动及线性规划等方法, 通过灵活资源调控降低源荷不确定性所带来的弃风和失负荷等负面影响, 可在降低调度成本的基础上, 兼顾系统高效性及可靠性。第一阶段以微电网综合运行成本最低, 可再生能源就地利用率最高及系统失负荷率最小为目标, 建立了计及需求响应的离网型微电网多目标经济调度模型。第二阶段针对第一阶段调度后产生的弃风与失负荷, 采用极限学习机(Extreme Learning Machine, ELM)及XGBoost构建了蓄电池消纳弃风模型和调频电源调度模型。最后通过仿真算例的对比表明, 需求响应对于系统高效性的增强是以增加调度成本和降低负荷可靠性为代价的, 相比之下, 所提两阶段日前调度方法可在降低调度成本的基础上, 同时兼顾系统高效性及可靠性, 为偏远地区 and 海岛等地区的离网型微电网运行提供参考。

关键词: 多目标经济调度; 需求响应; 源荷不确定性; Pareto Front; XGBoost

Two-stage economic day-ahead dispatch of an islanded microgrid considering uncertainty and demand response

HOU Hui^{1,2}, WANG Qing^{1,2}, XUE Mengya³, WU Xixiu^{1,2}, XIE Changjun^{1,2}, ZHANG Qingyong^{1,2}

(1. School of Automation, Wuhan University of Technology, Wuhan 430070, China; 2. Shenzhen Research Institute, Wuhan University of Technology, Shenzhen 518000, China; 3. Bengbu Power Supply Company, State Grid Anhui Electric Power Co., Ltd., Bengbu 233000, China)

Abstract: An islanded microgrid has a great effect on ocean islands and remote areas, but the uncertainty of source and load has a negative impact on the stable operation of an islanded microgrid. To reduce the pressure of intra-day dispatch, a two-stage day-ahead dispatch model of an islanded microgrid is constructed. By applying chaotic phase space reconstruction, multi-objective particle swarm, data-driven and linear programming methods, the negative effects of wind curtailment and loss load caused by uncertainties can be reduced through flexible resource regulation. This can reduce the operational cost while giving consideration to the efficiency and reliability of the system. The first stage takes the lowest integrated operation cost of microgrid, the highest utilization rate of renewable energy and the smallest load loss rate of system as objectives, and establishes a multi-objective microgrid economic dispatch model taking into account demand response resources. In the second stage, considering wind curtailment and load loss occurring after the first stage, the dispatch model of consuming wind curtailment and the frequency modulation power dispatch model are constructed by applying an extreme learning machine and XGBoost. Finally, through the comparison of simulation cases, the results show that the enhancement of demand response to system efficiency is at the cost of increasing dispatch cost and reducing load reliability. In contrast, the proposed two-stage dispatch method not only reduces dispatch cost, but also gives consideration to system efficiency and load reliability. This provides a reference for an islanded microgrid for rural areas, islands, etc.

This work is supported by the National Natural Science Foundation of China (No. 52177110).

Key words: multi-objective economic dispatch; demand response; uncertainty of source and load; Pareto Front; XGBoost

0 引言

离网型微电网对解决可再生能源的就地接入与消纳、偏远地区和远离内陆的海岛地区的用电问题有着举足轻重的作用^[1]。而可再生能源发电量受环境条件的影响，对离网型微电网运行产生极大不确定性，另外，负荷的波动同样具有不确定性。如何缓解源荷不确定性所带来的负面影响，对离网型微电网的稳定运行至关重要^[2]。

解决由源荷不确定性所导致的发电侧与用户侧之间的功率失衡，方法之一为引入需求响应(Demand Response, DR)，通过实时调节负荷需求实现功率平衡。如文献[3]以常见的空调负荷和插电式混合动力汽车负荷模型作为主要的 DR 模型，但其优化目标主要针对运行成本和负荷满意度。文献[4-5]同时考虑电价型 DR 和激励性 DR，探索 DR 聚合商和顾客之间的最优交易模式。与文献[3]类似，文献[4-5]的优化目标也局限于成本及用户两方面。文献[6]建立了风光储联合发电系统模型，且将可转移负荷、可中断负荷和电动汽车等可调控负荷作为信息申报方参与调度。其优化目标为系统收益最大和用户收益最大。综上所述，上述文献对于计及 DR 的系统优化主要聚焦在经济性和可靠性上，考虑的因素不够全面。可再生能源对于系统负荷波动同样具有平抑作用，可再生能源利用率反映了系统的高效性，也应被作为优化目标考虑在内。

除 DR 外，另一种解决源荷不确定性的方法为：通过调整储能及化石能源分布式发电的输出，寻找最优负荷配电方案，实现系统经济调度。计及不确定性因素的能量优化研究可分为两类^[7]。一类采用随机优化技术与概率统计方法，主要包括随机优化、模糊优化和鲁棒优化。随机优化如文献[8-9]建立了分布式可再生能源优化配置的机会约束规划模型。模糊优化如文献[10]利用模糊随机理论对预测误差的模糊随机性进行建模。鲁棒优化如文献[11]建立了 min-max-min 结构的两阶段鲁棒优化模型，得到最恶劣场景下运行成本最低的调度方案。然而上述文献对于源荷不确定性的描述多是假定其预测值或其预测误差满足某种概率分布或是某一不确定集，而在实际生产中，可再生能源和负荷的随机性较大，且对于地区和季节等因素较为敏感，未必符合所设定的不确定性约束。另一类计及不确定性因素的能量优化研究方法是通过对备用资源调控不确定因素。如文献[12]采用蓄电池作为备用电源，利用前馈神经网络构建调频策略，结果表明备用资源的调控降低了日平均发电成本；文献[13]针对风电消纳受阻

情况，选取高载能负荷参与调度，显著缓解了大规模风电接入电网的调峰瓶颈问题。上述文献均采用两阶段调度方法，对于不同场景具有普适性。不足之处在于对于源荷不确定性所产生的影响考虑不全面：只考虑弃风时如何调度或只考虑失负荷时如何调度。而在日前调度中，失负荷和弃风往往发生在一天不同的时刻，因而需要对其同时考虑。

综上，针对当前日前调度研究中较少同时考虑由源荷不确定性所引起的弃风和失负荷问题，本文采用两阶段调度方法，通过备用资源调控降低源荷不确定性所带来的弃风和失负荷影响。首先在第一阶段调度中建立了 DR 参与的离网型微电网多目标经济调度模型，对所选择的多个连续样本日进行第一阶段日前调度，不仅考虑离网型运行状态下微电网系统的成本经济性，同时兼顾其运行高效性和系统负荷可靠性。其次，根据第一阶段的调度结果计算每日的理想弃风量和失负荷量。利用极限学习机(Extreme Learning Machine, ELM)和 XGBoost 构建了第二阶段的调度策略，通过对多个连续样本日的学习训练构建了自主学习的模型，从而对调度日进行第二阶段日前调度。最后，利用算例对所提方法的有效性进行了验证。

1 离网型微电网结构

本文研究的离网型微电网系统如图 1 所示，主要由传统能源发电模块、源荷不确定性模块及 DR 等组成。传统能源发电模块包括柴油机组和储能等；源荷不确定性模块包括风电、光伏和不可调控负荷等；DR 模块包括可中断负荷(Interruptible Load, IL)、电动汽车(Electric Vehicle, EV)和可转移负荷(Transferable Load, TL)等。

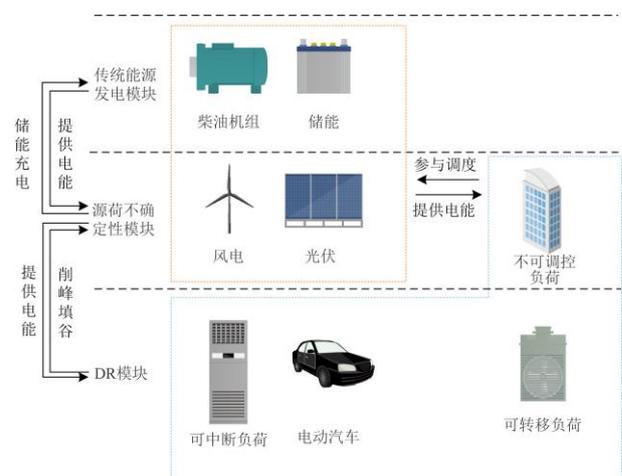


图 1 离网型微电网系统

Fig. 1 Islanded microgrid system

2 离网型微电网日前优化调度模型

2.1 柴油机组成本模型

柴油机组属于传统电源, 其在经济调度过程中将产生燃料成本 $C_{de, fuel}$ 、运行维护成本 $C_{de, om}$ 、环境污染治理成本 $C_{de, en}$ 以及启动成本 $C_{de, start}$ 。其中, 柴油机组的燃料成本与传统火力发电机组的消耗特性函数类似^[14]。

$$C_{de, fuel} = \sum_{t=1}^T a + bP_{de}(t) + cP_{de}(t)^2 \quad (1)$$

$$C_{de, om} = \sum_{t=1}^T K_{om, de} \cdot P_{de}(t) \quad (2)$$

$$C_{de, en} = \sum_{t=1}^T \sum_{k=1}^K (C_k \gamma_{de, k}) \cdot P_{de}(t) \quad (3)$$

$$C_{de, start} = \lambda \cdot n_{de} \quad (4)$$

式中: $P_{de}(t)$ 为 t 时刻柴油机组的输出功率, a, b, c 为燃料成本函数系数; $K_{om, de}$ 为柴油机组的运行维护系数; $\gamma_{de, k}$ 为柴油机组运行产生的第 k 类污染物排放量; C_k 为处理第 k 类污染物的费用; λ 和 n_{de} 分别为柴油机组每次开启所需费用和柴油机组在一个调度周期启动次数。

2.2 储能成本模型

本文储能模型采用蓄电池储能。蓄电池储能系统一般由荷电状态(State of Charge, SOC)来衡量其存储电量, SOC 值为储能剩余电量除以额定容量的比值。蓄电池在 t 时刻的剩余电量由上一时刻的剩余电量以及 $[t-1, t]$ 时段蓄电池的充电或放电量决定^[15], 如式(5)、式(6)所示。

$$SOC(t) = SOC(t-1) + P_{ES}(t)\Delta t \eta_c / E_{es} \quad (5)$$

$$SOC(t) = SOC(t-1) + P_{ES}(t)\Delta t / (E_{es}\eta_d) \quad (6)$$

式中: $SOC(t)$ 和 $SOC(t-1)$ 分别为蓄电池组在 t 和 $t-1$ 时刻的荷电状态; $P_{ES}(t)$ 为蓄电池组在 t 时刻的输出功率; η_c 和 η_d 分别为蓄电池充、放电效率; E_{es} 为蓄电池的额定容量。

储能单元在经济调度过程中所产生的费用包括储能单元的运行维护成本 $C_{ES, om}$ 和充放电转换造成的损耗成本 $C_{ES, loss}$ 。

$$C_{ES, om} = |P_{ES}(t)| \cdot K_{om, ES} \quad (7)$$

$$C_{ES, loss} = n_B \cdot (C_{cost, change} / n_{BN}) \quad (8)$$

式中: $K_{om, ES}$ 及 $C_{cost, change}$ 分别为储能单元的运行成本系数和更换成本; n_B 和 n_{BN} 分别为储能单元一个周期内充放电的次数和寿命周期内额定充放电次数。

2.3 源荷不确定性模块模型

微电网中的源荷不确定性由风电、光伏及不可调控负荷的随机性和波动性引起, 使用某种概率分布或数学公式来描述这种不确定性均具有一定的局限性, 这种局限性表现在对于不同时空场景不具备普适性, 而数据驱动算法不限制数据所服从的概率分布, 自主学习数据规律, 应用范围更广, 因而本文采用数据预测的方式构建源荷不确定性模型。不论是风电、光伏还是不可调控负荷, 影响其变化的因素均十分繁杂, 包含天气信息、地理信息等等, 通常难以获得完备且准确的影响因素数据, 一般情况下仅可获得历史风电/光伏/负荷数据。文献[16-18]表明风电/光伏/电力负荷具有混沌特性, 采用相空间重构技术对历史数据处理, 可不考虑除历史数据以外的影响因素。因此, 本文采用相空间重构^[19]和数据驱动^[20]结合的方式进行预测。

2.4 EV 充放电模型

假设 EV 受到用户行驶习惯的限制, 一般早上驶离微电网系统, 傍晚结束行程返回微电网系统^[21]。

假设微电网原始负荷早高峰起始时刻为 $T_{start, m}$, 晚高峰起始时刻为 $T_{start, n}$, 第 i 辆 EV 返程时刻为 $t_0(i)$, 充电起始时刻为 $T_{start, char}(i)$, 放电起始时刻为 $T_{start, dischar}(i)$ 。本文通过对比 EV 用户返程时刻与微电网负荷的早晚负荷高峰的起始时刻来确定 EV 的充放电起始时刻, 即:

$$\text{当 } t_0(i) < T_{start, m} \text{ 时, 则 } T_{start, char}(i) = t_0(i);$$

$$\text{当 } T_{start, m} \leq t_0(i) \leq T_{start, n} \text{ 时, 则 } T_{start, dischar}(i) = T_{start, n};$$

$$\text{当 } t_0(i) > T_{start, n} \text{ 时, 则 } T_{start, dischar}(i) = t_0(i)。$$

EV 最大放电电量既要保证剩余电量满足用户日常行驶需求, 又不能超过其所设置的 EV 最大放电深度, 即 EV 最大放电量取两者之间的最小值, 如式(9)所示。

$$C_{dischar}(i) = \min \left(\begin{array}{l} (SOC_{max} - SOC_{min}) \cdot C_{ev} - s(i) \cdot w \\ f_r \cdot C_{ev} \end{array} \right) \quad (9)$$

式中: SOC_{max} , SOC_{min} 及 C_{ev} 分别为 EV 荷电状态上下限以及电池电量; w 和 f_r 分别为每公里耗电量及最大放电深度。

利用 EV 充放电起始时间以及最大放电量确定第 i 辆 EV 的充电时长 $T_{char}(i)$ 、放电时长 $T_{dischar}(i)$ 以及 EV 有序充放电负荷 $P_{EV}(t)$ 。

$$T_{dischar}(i) = C_{dischar}(i) / P_d \quad (10)$$

$$T_{char}(i) = (C_{dischar}(i) + s(i) \cdot w) / P_c \quad (11)$$

$$P_{EV}(t) = \sum_{i=1}^N (P_c \cdot a(i,t) + P_d \cdot b(i,t)) \quad (12)$$

当 $t \in [T_{start, char}(i), T_{start, char}(i) + T_{char}(i) - 1]$ 时, $a(i,t) = 1$; 否则, $a(i,t) = 0$;

当 $t \in [T_{start, dischar}(i), T_{start, dischar}(i) + T_{dischar}(i) - 1]$ 时, $b(i,t) = 1$; 否则, $b(i,t) = 0$ 。

式中: N 为 EV 的数量; P_c 和 P_d 分别为充放电功率且 $P_c > 0, P_d < 0$; $s(i)$ 为第 i 辆 EV 的行驶里程; $a(i,t)$ 和 $b(i,t)$ 分别为第 i 辆 EV 在 t 时段的充电状态和放电状态, 当 EV 充电时, $a(i,t)$ 值为 1, 当 EV 放电时, $b(i,t)$ 值为 1。

2.5 TL 模型

TL 模型: 负荷转入转出模型^[22]如式(13)所示。

$$P_{in}(t) = \sum_{k=1}^{N_{TL}} x_k(t) P_{l,k} + \sum_{h=1}^{h_{max}-1} \sum_{k=1}^{N_{TL}} x_k(t-h) P_{(h+1),k} \quad (13)$$

$$P_{out}(t) = \sum_{k=1}^{N_{TL}} y_k(t) P_{l,k} + \sum_{h=1}^{h_{max}-1} \sum_{k=1}^{N_{TL}} y_k(t-h) P_{(h+1),k}$$

式中: $P_{in}(t)$ 和 $P_{out}(t)$ 分别为 t 时段转入和转出的负荷值; N_{TL} 为 TL 种类总数; N'_{TL} 为运行持续时间大于一个调度时段的 TL 种类数; h_{max} 为 TL 单元供电持续时间最大值; $x_k(t)$ 为 t 时段开始运行的第 k 类负荷转入单元数; $y_k(t)$ 为 t 时段开始运行的第 k 类负荷转出单元数; $P_{l,k}$ 为第 k 类 TL 在第 l 个工作时段的功率, 其中 $0 \leq k \leq N_{TL}$ 。

$$\begin{cases} x_{TL}(t) \leq X_{TL}(t) \\ \sum_{t=1}^T P_{in}(t) = \sum_{t=1}^T P_{out}(t) \end{cases} \quad (14)$$

式中: $x_{TL}(t)$ 为 t 时刻实际负荷转移量; $X_{TL}(t)$ 为 t 时刻 TL 容量。

微电网系统对 TL 的补贴成本为

$$C_{TL, cost} = \sum_{t=1}^T P_{in}(t) \cdot c_{TL}(t) \quad (15)$$

式中: $C_{TL, cost}$ 为微电网对 TL 的补贴成本; c_{TL} 为微电网对 TL 的统一补贴单价。

2.6 IL 模型

IL 模型: 采用 IL^[23]控制后的负荷时序表达式为

$$P'(t) = P(t) - \sum_{y=1}^Y [U(y,t) \cdot S(y,t)] \quad (16)$$

式中: $P'(t)$ 为 t 时段采用 IL 后的负荷需求; $P(t)$ 为 t 时段原始预测负荷需求; y 为能够提供 IL 的用户编号, 共有 Y 个用户; $U(y,t)$ 是 0-1 变量, 表示第 y 个用户在 t 时段是否被选中的状态; $S(y,t)$ 为第 y

个用户 t 时段的中断容量。

微电网系统对 IL 的补贴成本为

$$C_{IL, cost} = \sum_{t=1}^T P_{IL}(t) \cdot c_{IL}(t) \quad (17)$$

$$P_{IL}(t) = \sum_{y=1}^Y [U(y,t) \cdot S(y,t)] \quad (18)$$

式中: $C_{IL, cost}$ 为微电网对 IL 的补贴成本; c_{IL} 为微电网对 TL 的统一补贴单价; $P_{IL}(t)$ 为 t 时段采用 IL 后的负荷需求。

3 离网型微电网两阶段调度模型及策略

本文提出了一种计及源荷不确定性和 DR 的离网型微电网两阶段日前经济调度策略, 其总体框图如图 2 所示。

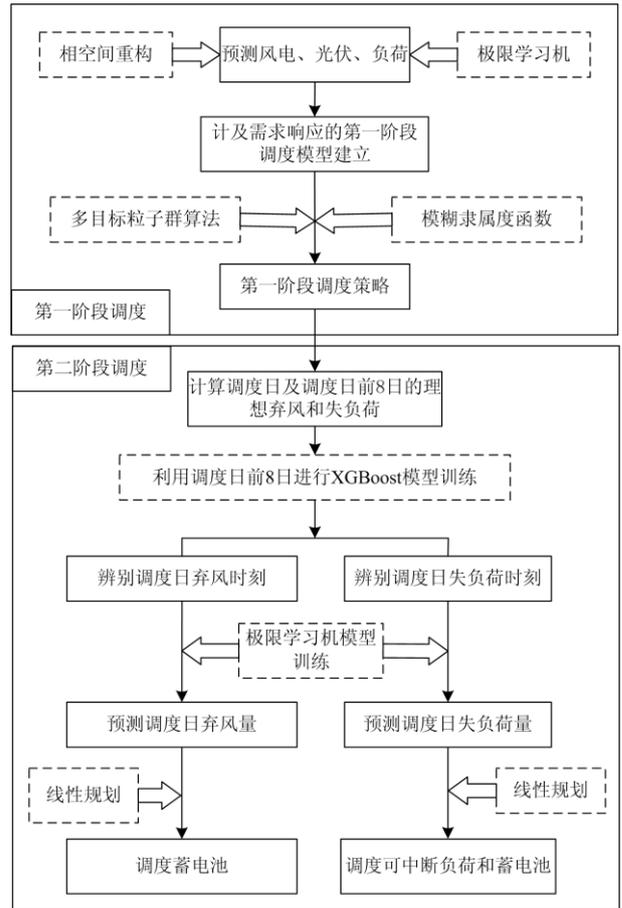


图 2 两阶段日前调度框图

Fig. 2 Diagram of two-stage day-ahead dispatch

第一阶段采用多目标粒子群算法求解包含需求响应模型在内的日前调度模型, 得到非劣解集。其中, 需求响应模型包含电动汽车充放电模型、可转移负荷模型和可中断负荷模型。然后利用模糊隶属度函数对非劣解集进行排序, 选出综合满意度最大

的解作为第一阶段调度方案。

从图2中可以看出, 第一阶段根据可再生能源及负荷的预测值对离网型微电网进行了预调度。由于可再生能源及负荷的预测值和实际值之间具有偏差, 该偏差可能引起系统弃风或失负荷现象, 因此第二阶段首先采用数据驱动算法预测实施第一阶段调度后系统可能出现的弃风和失负荷时刻及弃风和失负荷量。其次, 根据预测结果, 采用线性规划分别调度调频电源及蓄电池, 以保持系统有功功率平衡, 从而完成两阶段调度。需要注意的是, 本文所提理想弃风或理想失负荷并非实际运行中的真实值, 而是日内调度决策者面临的源与荷之间的偏差值。

3.1 第一阶段调度

1) 第一阶段调度模型

本文所建立的第一阶段微电网多目标经济调度模型主要考虑 DR。模型优化指标包括: 高效性指标 f_1 , 即可再生能源的就地利用率最高(模型中用微电网净负荷均值最小来表示); 经济性指标 f_2 , 即微电网系统综合运行成本最小; 负荷可靠性指标 f_3 , 即微电网失负荷率最小。

$$f_1 = \min\left[\left(\sum_{t=1}^T |P'_{\text{load-pre}}(t)|\right)/T\right] \quad (19)$$

$$f_2 = \min[C_{\text{ES, cost}} + C_{\text{EV, cost}} + C_{\text{de, cost}} + C_{\text{TL, cost}} + C_{\text{IL, cost}}] \quad (20)$$

$$f_3 = \min\left[\sum_{t=1}^T P_{\text{IL}}(t) / \sum_{t=1}^T P_{\text{load-pre}}\right] \quad (21)$$

$$C_{\text{ES, cost}} = C_{\text{ES, om}} + C_{\text{ES, loss}} \quad (22)$$

$$C_{\text{de, cost}} = C_{\text{de, fuel}} + C_{\text{de, om}} + C_{\text{de, EN}} + C_{\text{de, start}} \quad (23)$$

$$C_{\text{EV, cost}} = \left| \sum_{t=1}^T P_{\text{EV}}(t) \cdot c_{\text{EV}} \right| \quad (24)$$

$$(\text{s.t. } P_{\text{EV}}(t) \leq 0)$$

$$P'_{\text{load-pre}}(t) = -P_{\text{pv-pre}}(t) - P_{\text{wind-pre}}(t) + P_{\text{EV}}(t) + P_{\text{TL}}(t) + P_{\text{IL}}(t) + P_{\text{load-pre}}(t) \quad (25)$$

式中: $P'_{\text{load-pre}}(t)$ 为使用预测风光荷进行一阶段调度后 t 时刻的微电网净负荷; $C_{\text{ES, cost}}$ 为储能的综合运行成本; $C_{\text{EV, cost}}$ 为微电网系统对 EV 的放电补贴成本; $C_{\text{de, cost}}$ 为柴油机组运行产生的综合运行成本; $C_{\text{TL, cost}}$ 为微电网对 TL 的补贴成本; $P_{\text{load-pre}}(t)$ 为 t 时刻的微电网预测不可调控负荷; c_{EV} 为微电网系统对 EV 放电的统一补贴单价。

模型中各单元需要满足的约束条件如下。

(1) 储能单元的荷电状态和出力约束

$$SOC_{\min} \leq SOC(t) \leq SOC_{\max} \quad (26)$$

$$P_{\text{ES}}^{\min} \leq P_{\text{ES}}(t) \leq P_{\text{ES}}^{\max} \quad (27)$$

式中, SOC_{\max} 、 SOC_{\min} 和 P_{ES}^{\max} 、 P_{ES}^{\min} 分别为储能单元的荷电状态和出力最大、最小值。

(2) 柴油机组的出力上下限和爬坡速率约束

$$P_{\text{de}}^{\min} \leq P_{\text{de}}(t) \leq P_{\text{de}}^{\max} \quad (28)$$

$$P_{\text{de}}^{\text{down}} \leq |P_{\text{de}}(t) - P_{\text{de}}(t-1)| \leq P_{\text{de}}^{\text{up}} \quad (29)$$

式中: P_{de}^{\max} 、 P_{de}^{\min} 分别为柴油机组出力最大、最小值; $P_{\text{de}}^{\text{up}}$ 、 $P_{\text{de}}^{\text{down}}$ 分别为柴油机组爬坡速率上下限。

(3) 功率平衡等式

$$P_{\text{ES}}(t) + \sum_{d=1}^D P_{\text{de}}(t) = P'_{\text{load-pre}}(t) \quad (30)$$

2) 第一阶段调度策略及调度模型求解

从经济性及高效性的角度出发, 第一阶段调度策略首先考虑调度可再生能源, 其次调度 DR。若净负荷大于 0, 表明可再生能源和 DR 无法满足负荷需求, 则依次调度储能和柴油机组; 若净负荷等于 0, 表明可再生能源和 DR 刚好可以满足负荷需求, 储能和柴油机组无需出力; 若净负荷小于 0, 表明可再生能源出力有余, 则储能进行充电以吸收多余电量。

本文在求解计及 DR 的微电网多目标经济调度模型时采用多目标粒子算法(Multi-objective Particle Swarm Optimization, MPSO)^[24], 其算法步骤及流程见附录 B。利用 MPSO 算法可以获得一系列的非劣解, 这些非劣解组成的集合称为非劣解集, 也称 Pareto Front(帕累托前沿)^[25]。

在获得非劣解集之后, 本文采用模糊隶属度函数^[26]选取适当的最终解决方案。考虑 Pareto Front 其中一个非劣解 x_k , 其对于第 i 个子目标函数的满意程度 μ_i^k 可以用式(31)表示。

$$\mu_i^k = \frac{f_i^{\max} - f_i(x_k)}{f_i^{\max} - f_i^{\min}} \quad (31)$$

式中, f_i^{\max} 、 f_i^{\min} 分别为第 i 个子目标最大最小函数值, 因此, μ_i^k 取值范围为(0,1)。

对 x_k 来说, 所有子目标的综合满意度可用式(32)表示。

$$\mu^k = \frac{\sum_{i=1}^N \mu_i^k}{\sum_{k=1}^M \sum_{i=1}^N \mu_i^k} \quad (32)$$

式中: M 、 N 分别为非劣解和子目标的个数; μ^k 的值越大, 表明此非劣解对应的综合满意度越高。

3.2 第二阶段调度

1) 第二阶段调度模型

第一阶段调度中所使用的风电出力、光伏出力及不可调控负荷均为预测值，实际值一般在预测值附近随机波动，预测值与实际值之间的偏差可能会导致弃风或失负荷。第二阶段主要针对第一阶段调度后可能出现的弃风和失负荷现象进行调度。采用蓄电池消纳弃风。将蓄电池与第一阶段调度中未中断的 IL 作为调频电源。

弃风和失负荷的计算公式为

$$P_{\text{windcut}}(t) = \begin{cases} -P'_{\text{load-act}}(t) & P'_{\text{load-act}}(t) < 0 \\ P'_{\text{load-act}}(t) - P'_{\text{load-pre}}(t) & 0 < P'_{\text{load-act}}(t) < P'_{\text{load-pre}}(t) \\ 0 & \text{其他} \end{cases} \quad (33)$$

$$P_{\text{loadcut}}(t) = \begin{cases} P'_{\text{load-act}}(t) & P'_{\text{load-act}}(t) > 0 \text{ 且 } P'_{\text{load-pre}}(t) < 0 \\ P'_{\text{load-act}}(t) - P'_{\text{load-pre}}(t) & 0 < P'_{\text{load-pre}}(t) < P'_{\text{load-act}}(t) \\ 0 & \text{其他} \end{cases} \quad (34)$$

式中， $P'_{\text{load-act}}$ 为实际净负荷，其计算公式为

$$P'_{\text{load-act}} = P'_{\text{load-pre}} + (P_{\text{load-act}} - P_{\text{load-pre}}) - ((P_{\text{pv-act}} + P_{\text{wind-act}}) - (P_{\text{pv-pre}} + P_{\text{wind-pre}})) \quad (35)$$

式中， $P_{\text{pv-act}}$ 和 $P_{\text{wind-act}}$ 分别为光伏和风电的实际最大发电量。

由于弃风与失负荷不同时存在，因此分别考虑弃风时蓄电池消纳模型和失负荷时调频电源的调度模型。蓄电池消纳弃风模型仍遵循储能成本模型。

调频电源调度模型的目标是调频成本最小。如式(36)所示。

$$C_f = C_{\text{IES},\text{cost}} + C_{\text{IL},\text{cost}} \quad (36)$$

式中， $C_{\text{IES},\text{cost}}$ 和 $C_{\text{IL},\text{cost}}$ 分别为调频蓄电池和 IL 的调频成本。

调频电源需要满足的约束条件有：储能单元的荷电状态和出力约束如式(26)和式(27)；功率平衡等式如式(37)。

$$P_{\text{load-cut}} = P_{\text{IES}} + P_{\text{IL}} \quad (37)$$

式中， P_{IES} 和 P_{IL} 分别为第二阶段调度的蓄电池出力和可中断负荷功率。

两阶段调度后，调度指标需要重新计算。式(38)一式(40)为两阶段调度指标计算公式。

$$f_{2-1} = \left(\sum_{t=1}^T |P'_{\text{load-act}}(t) - P_{\text{IES}} - P_{\text{IL}}| \right) / T \quad (38)$$

$$f_{2-2} = f_2 + \sum_{t=1}^T k_{\text{wp}} P_{\text{wcut}}(t) + \sum_{t=1}^T k_{\text{lp}} P_{\text{lcut}}(t) - C'_w + C_f \quad (39)$$

$$f_{2-3} = \sum_{t=1}^T (P_{\text{IL}}(t) + P_{\text{IL}}(t) + P_{\text{lcut}}(t)) / \sum_{t=1}^T P_{\text{load-pre}} \quad (40)$$

式中： f_{2-1} 、 f_{2-2} 和 f_{2-3} 分别表示经过两阶段调度后

的高效性指标、经济性指标和负荷可靠性指标，其含义与 f_1 、 f_2 和 f_3 一一对应； k_{wp} 为弃风惩罚系数； P_{wcut} 为理想弃风； k_{lp} 为切负荷惩罚系数； P_{lcut} 为理想切负荷； C'_w 为风电消纳收益。

2) 第二阶段调度策略及调度模型求解

由于风电、光伏和负荷的实际值无法提前得知，因而实际净负荷未知，也就无法根据式(33)和式(34)计算当天的理想弃风和失负荷。因此，需要在日前安排调度时，构建能够自主学习的模型，使其依据当日风光荷预测值及历史理想弃风与理想失负荷学习得到调度日的预测弃风和失负荷。由于弃风与失负荷发生在不同时段，可预见弃风量序列与失负荷量序列均不是连续序列。若使用回归算法预测不连续序列，预测误差则较大。因此，为提高预测精度，本文先使用分类算法辨别失负荷时刻和弃风时刻，然后利用回归算法针对失负荷时刻的失负荷量及弃风时刻的弃风量进行回归预测。由于不可调控负荷的预测值和实际值与前一周期不可调控负荷相关性较大^[27]，因此选取调度日前一周数据作为训练数据。第二阶段调度策略如下。

Step1: 采用多目标粒子群算法及模糊隶属度函数求解第一阶段调度模型，得到第一阶段的调度方案；

Step2: 对调度日及调度日前一周实施 Step1；

Step3: 根据式(33)和式(34)计算包括调度日在内的 8 日的理想弃风量和理想失负荷量；

Step4: 将包括调度日在内的 8 日的预测风电、预测光伏、预测不可调控负荷及预测净负荷作为输入，对于每日的理想弃风序列，有弃风时刻记为 1，无弃风时刻记为 0，构建 0-1 序列作为输出，构建 XGBoost 模型，预测得到调度日有弃风时刻；

Step5: 将 8 日中有弃风时刻的预测风电、预测光伏、预测不可调控负荷及预测净负荷作为输入，有弃风时刻的理想弃风量作为输出，前 7 日作为训练集，第 8 日为测试集，构建 ELM 模型，得到调度日的预测弃风量；

Step6: 将包括调度日在内的 8 日的预测风电、预测光伏、预测不可调控负荷及预测净负荷作为输入，对于每日的理想失负荷情况，有失负荷时刻记为 1，无失负荷时刻记为 0，构建 0-1 序列作为输出，构建 XGBoost 模型，得到调度日有失负荷时刻；

Step7: 将 8 日中有失负荷时刻的预测风电、预测光伏、预测不可调控负荷及预测净负荷作为输入，有失负荷时刻的理想失负荷量作为输出，前 7 日作为训练集，第 8 日为测试集，构建 ELM 模型，得到调度日的预测失负荷量；

Step8: 根据预测弃风量, 调度蓄电池消纳弃风;

Step9: 求解调频电源调度模型得到调频电源的功率分配。为减少出现无失负荷时刻蓄电池出力的情况, 优先调度 IL, 其次调度蓄电池, 当蓄电池与 IL 无法满足负荷需求时做切负荷处理。

4 算例分析

4.1 设计方案

为了对比和分析计及源荷不确定性和 DR 对微电网系统经济运行的影响, 设置了 4 种不同的对比方案如表 1 所示。

表 1 对比方案设计

Table 1 Contrastive scheme design

	DR	一阶段调度	两阶段调度	
			使用预测弃风/预测失负荷	使用实际弃风/实际失负荷
方案 1	✓		✓	
方案 2	✓	✓		
方案 3			✓	
方案 4	✓			✓

方案 1 为本文所提方案, 方案 2 为研究第二阶段调度影响的对比方案, 方案 3 为研究 DR 影响的对比方案, 方案 4 为在第二阶段调度中使用理想弃风和理想失负荷的理想方案, 方案 4 与方案 1 对比即可看出第二阶段中弃风与失负荷量的预测精度高低, 预测精度越高, 则方案 1 与方案 4 的调度指标越接近。

4.2 算例参数

本文以一个含有多种微源的微电网为例, 算例仿真设置参数如下: 系统内含有 50 辆电池容量为 24 kWh 的 EV, 1 台容量为 0.6 MW 和 1 台容量为 1 MW(备用机组)的柴油机组, 两组容量同为 1.5 MW 的铅酸蓄电池作为储能单元。系统将风电与光伏视作清洁能源, 且使用过程中不会产生额外附加费用。

在选择风电/光伏/不可调控负荷的预测方法时, 本文对比了多种数据驱动方法, BP 神经网络(Back Propagation Neural Network, BPNN)、小波神经网络(Wavelet Neural Network, WNN)、ELM、长短期记忆网络(Long Short Term Memory, LSTM)、支持向量回归(Support Vector Regression, SVR)、极端梯度提升(eXtreme Gradient Boosting, XGBoost)及随机森林(Random Forest, RF)等, 采用平均绝对百分比误差指标(Mean Absolute Percentage Error, MAPE)和均方根误差(Root Mean Square Error, RMSE)指标

评价预测精度, 结果显示 ELM 算法的预测精度较高, 表明在本文所采取的相空间重构技术下, ELM 的学习能力较强, 如表 2 所示。因此, 选择 ELM 预测风电/光伏/不可调控负荷。

表 2 不同数据驱动模型预测结果对比

Table 2 Comparative results of several data-driven models

模型名称	MAPE/%	RMSE/kW
BPNN	7.93	295.38
WNN	5.79	215.37
ELM	0.03	9.63
LSTM	3.31	173.92
SVR	2.12	136.00
XGBoost	1.91	126.08
RF	1.92	129.23

从原理上来看, ELM 预测精度高于其他模型, 可从以下两方面分析原因: 一方面, 以上模型均使用默认参数, 在默认参数设置下, ELM 通过固有计算公式得到超参数, 与样本契合度高, 而其他模型大多通过损失函数反馈误差来调整超参数, 在不调整时, 默认损失函数下较难得到最优超参数。另一方面, ELM 和相空间重构具有相似点, 核心均是计算公式的推算。相空间重构而成的高维序列是原一维序列通过矩阵变换后得到的, ELM 学习输入输出之间的关系通过计算公式求解各个神经元的系数矩阵得到, 无迭代过程, 而其他模型求解超参数通过训练样本反馈损失函数迭代得到。因此, 相比之下, ELM 更容易学习到相空间重构的变换规则, 相应也就更容易学习到输入输出之间的关系, 从而获得更高的预测精度。

本文对微电网系统采取日前经济调度, 所设时间间隔为 1 h。EV、蓄电池及柴油机组运行参数, 运行产生污染物种类及治理污染物费用参数^[28], TL、IL 参数分别如附表 1、附表 2、附表 3、附表 4 所示。风电、光伏及不可控负荷功率预测值如附图 1 所示, 预测步骤及流程见附录 B。多目标粒子群算法程序中的相关参数设置为: 最大迭代次数 $M_{\max iter} = 80$; 种群数量 $S_{\text{sizepop}} = 150$; 学习因子 $c_1 = c_2 = 1.4995$; 初始权重 $w = 0.5$; 非支配解种群数量 $r = 80$; 权重衰减因子 $w_{\text{damp}} = 0.99$; 非支配解集的扩展因子 $\alpha = 0.1$; 非支配解的选择因子 $\beta = 2$; 非支配解的淘汰因子 $\gamma = 2$ 。

4.3 第一阶段调度结果

图 3 为 DR 参与调度情况下, 利用多目标粒子群算法求得的多目标 Pareto Front, 图 3 中的每一个红点都代表一个可行解。图 3 中的数据标签是通过模糊隶属度函数综合计算出的折衷最优解, 标签中

的(X 轴, Y 轴, Z 轴)对应经济调度模型中的目标函数(f_1, f_2, f_3), 即净负荷均值、综合运行成本以及负荷损失率。可以看出, 在 DR 参与调度情况下, 求得的综合最优解为: 微电网系统的日净负荷均值为 491.2 kW, 日综合运行成本(f_2)为 1.062 万元, 日负荷损失率(f_3)为 0.4781%。

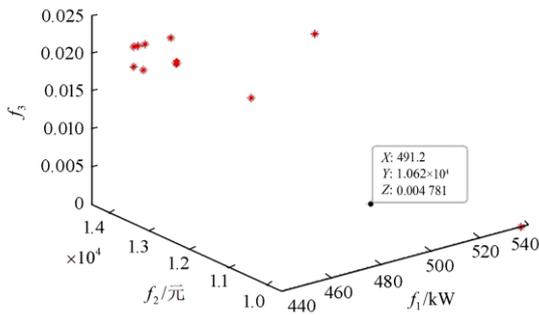


图 3 一阶段调度的多目标 Pareto Front 图

Fig. 3 Multi-objective Pareto Front diagram of first-stage dispatch

附表 5 为一阶段调度求得的非劣解集及利用模糊隶属度函数对其进行归一化处理得到的结果, 附表 5 中的数据都与图 3 中的点一一对应, 可以看出利用多目标粒子群算法求解模型得到了 14 个非劣解。利用模糊隶属度函数可以求得这 14 个非劣解对应的目标函数满意度值。附表 5 中 f_1^k 、 f_2^k 、 f_3^k 分别表示第 k 个非劣解对应目标函数 f_1 、 f_2 和 f_3 的值, μ_1^k 、 μ_2^k 、 μ_3^k 分别表示第 k 个非劣解对目标函数 f_1 、 f_2 和 f_3 的满意程度, μ_k 表示第 k 个非劣解对所有目标函数的满意度, 即综合满意度值。取对应综合满意度值最大的非劣解作为综合最优解, 由附表 5 中数据可得第 1 个非劣解所对应的综合满意度值最大, $\mu^k = 0.118$, 因此选取第 1 个非劣解作为综合最优解, 即对应图 3 标签所示值为(491.2 kW, 1.062 万元, 0.4781%)。

图 4 为对应综合最优解的微电网系统内各负荷出力曲线。从图 4 可以看出, EV 进行有序充放电时基本遵循用户的出行习惯, 即凌晨至早上负荷低谷时段, 如 04:00—07:00 进行有序充电, 夜间负荷晚高峰时期, 如 18:00—20:00 进行有序放电, 上午至傍晚时段如 09:00—20:00 既不充电也不放电, 此时段为用户往返工作地点的出行时段或者用户已到达工作地点 EV 处于停驻时段。DR 方面, TL 从风电出力小于微电网原始负荷时段转移至风电出力富余时段, 如从 13:00—16:00 及 19:00—21:00 时段转移至 07:00—10:00 时段, 进一步提高可再生能源的就地利用率, 减小风电的弃用率; IL 选择在 15:00 中断负荷, 对微电网总负荷起到平

抑作用。因此 DR 既可以起到“削峰填谷”平抑微电网负荷波动的作用, 又可以起到提高可再生能源利用率的作用。

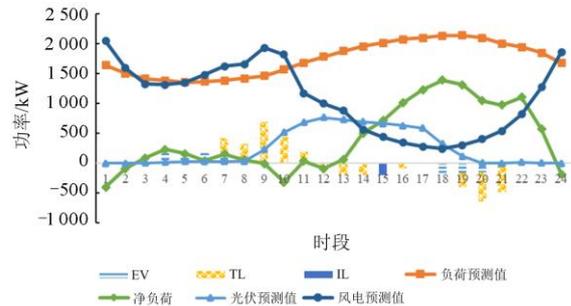


图 4 一阶段调度中各负荷出力曲线图

Fig. 4 Output curve of each load in first-stage dispatch

图 5 为对应综合最优解的各分布式电源出力曲线图。由图 5 中可得, 风光出力及需求响应不足以支持微电网负荷用电时, 净负荷值为正, 如 14:00—23:00 时段。其中, 16:00—22:00 时段柴油机组 1 几乎都以最大输出功率发电, 柴油机组 2 补充微电网剩余负荷所需电量; 在净负荷值为负时, 即风光出力大于微电网所需电量时, 如 10:00 时段, 储能单元充电以吸收多余的光伏出力, 而在 1:00—2:00 时段由于储能单元初始电量为最大荷电状态, 因而无法充电。从图 5 中可以看出, 储能单元由于荷电状态及工作功率的限制无法完全吸收所有富余风光出力, 因此未被吸收利用的风光能量将被丢弃。



图 5 一阶段调度中各运行单元出力曲线图

Fig. 5 Output curve of each operating unit in first-stage dispatch

4.4 第二阶段调度结果

采用 XGBoost 分别预测弃风时刻和失负荷时刻, 超参数设置如附表 6 所示。弃风时刻和失负荷时刻的预测准确率均为 80%, 预测结果如附表 7 所示, 其中, “1”表示有弃风时刻或失负荷时刻, “0”表示无弃风时刻或失负荷时刻。去除训练集和测试集中无弃风或无失负荷时刻, 采用 ELM 针对有弃风或有失负荷时刻预测弃风量或失负荷量, 超参数

设置如附表 8 所示。根据预测弃风量及失负荷量调度蓄电池及调频电源。在第二阶段中使用三组蓄电池, 其中两组用作消纳弃风, 一组用作调频电源。

图 6 为蓄电池调度结果图。

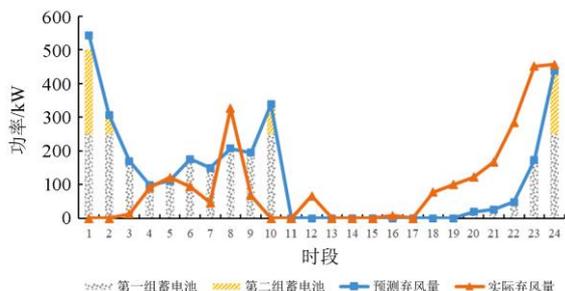


图 6 蓄电池调度弃风结果图

Fig. 6 Dispatch of battery to wind curtailment

图 7 为调频电源调度结果图。由图 7 可以看出, IL 与蓄电池足以支持预测失负荷量, 但由于预测失负荷量与理想失负荷量之间存在偏差, 因此在理想失负荷量大于预测失负荷量的时刻仍然需要切负荷。

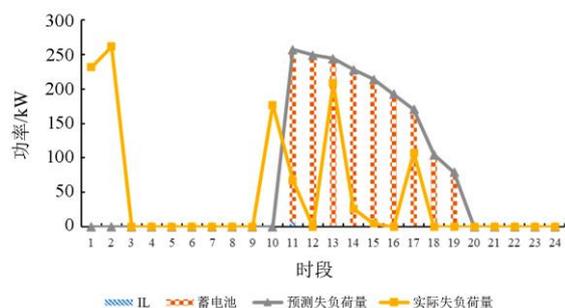


图 7 调频电源调度结果

Fig. 7 Dispatch of frequency modulation power

4.5 对比方案分析

图 8 为对比方案的调度指标结果。

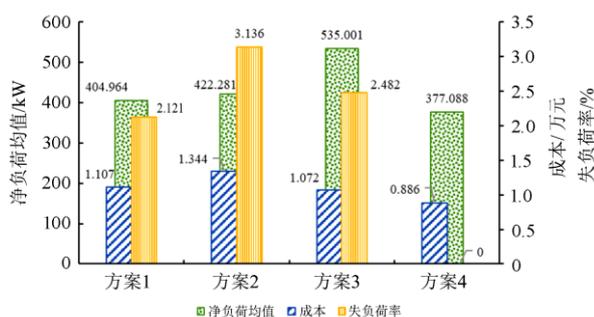


图 8 对比方案调度指标

Fig. 8 Indexes comparison of dispatch cases

首先将 4 种方案的不同指标最优解进行对比, 分析系统的调度成本, 方案 4 作为理想方案无疑具

有最低成本, 方案 3 次之, 方案 1 和方案 2 成本依次增大。分析数据表明: 方案 3 成本之所以低于方案 1 是因为在不考虑 DR 的情况下, 方案 3 具有更多弃风量, 蓄电池消纳弃风带来的收益大幅降低成本; 分析系统的净负荷均值, 除理想方案外, 方案 1 具有最低净负荷均值, 方案 3 由于不计及 DR, 缺少“削峰填谷”, 其净负荷均值最大; 分析系统的失负荷率, 除理想方案外, 方案 1 具有最低失负荷率, 方案 3 次之。表明两阶段调度提升了系统负荷可靠性。

其次进行对比方案分析, 对比方案 1 与方案 2 可知: 两阶段调度由于获得风电消纳收益和调频收益而使得成本降低了 17.63%, 同时风电消纳和调频使负荷波动降低, 表现在方案 1 的净负荷均值和失负荷率均小于方案 2, 分别降低了 4.1% 和 32.37%, 显示了第二阶段调度的重要性; 对比方案 1 和方案 3 可知, DR 的参与一定程度上降低了净负荷均值, 但会带来调度成本的增长。由此可见, DR 所带来的负荷波动降低是以调度成本增加为代价; 方案 4 为理想状态下的调度方案, 对比方案 1 与方案 4 可知, 按预测弃风和预测失负荷进行第二阶段调度后的调度成本略高于理想状态下的调度方案, 约高 19.96%, 表明第二阶段算法求解精度较高。总体来说, 方案 1 具有较为良好的综合效益, 结果较为理想。

5 结论

本文提出一种离网状态下计及源荷不确定性及 DR 参与的微电网两阶段日前经济调度模型, 该模型考虑了系统的成本经济性、运行的高效性以及系统的负荷损失率。利用多目标粒子群算法求得第一阶段调度的非劣解集, 同时通过模糊隶属度函数方法获得其相应的综合最优解, 并采用 ELM 和 XGBoost 构建了第二阶段的调度策略。通过算例仿真得出以下结论:

1) 需求响应的参与使得系统净负荷均值降低了 24.31%, 但同时成本和失负荷率均有所增长。说明在需求响应参与的方案下, 系统的高效性与系统的经济性之间存在互相制约的关系。

2) 所提两阶段调度方法相比一阶段调度方法成本降低了 17.63%, 净负荷均值和失负荷率分别降低了 4.1% 和 32.37%, 说明了本文所提方法既能在源荷不确定时降低调度成本, 又能同时兼顾系统高效性和负荷可靠性。

本文针对特定的离网型微电网开展计及源荷不确定性的研究。除离网型微电网以外, 并网型微电网等应用场景, 还需要进一步探索和分析。

附录 A

附表 1 运行参数
Attached Table 1 Operating parameters

运行参数	类型				
	电动汽车	蓄电池 1 (第一阶段储能)	蓄电池 2 (第二阶段调频/消纳弃风)	柴油机组 1	柴油机组 2
出力上限/kW	4	250	250	0	0
出力下限/kW	-4	-250	-250	600	1 000
爬坡上限/kW	—	—	—	100	150
爬坡下限/kW	—	—	—	-100	-150
充电效率	0.9	0.9	0.9	—	—
放电效率	0.9	0.9	0.9	—	—
荷电状态最大值	0.9	0.9	0.9	—	—
荷电状态最小值	0.3	0.2	0.2	—	—
运行维护系数/(元/kW)	—	0.104 0	0.104 0	0.236	0.236

附表 2 污染物排放系数及处理成本
Attached Table 2 Pollutant emission factor and disposing cost

污染物类型	CO ₂	SO ₂	NO _x
处理费用/(元/kg)	0.210	14.824	62.964
污染物排放系数/(g/kWh)	光伏	0	0
	风机	0	0
	柴油机组 1/柴油机组 2	649	0.206

附表 3 TL 运行参数
Attached Table 3 Parameters of transferable load

	负荷类型 1	负荷类型 2	负荷类型 3	负荷类型 4
转出前起始运行时间	2:00	20:00	6:00	4:00
运行时长/h	3	2	1	3
运行功率/kW	0.75	2	0.5	1.5
转移负荷容量/kW	350	250	300	300

附表 4 IL 运行参数
Attached Table 4 Parameters of interruptible load

	负荷类型 1	负荷类型 2	负荷类型 3	负荷类型 4
最大中断时长/h	1	2	1	2
中断容量/kW	200	150	150	200

附表 5 第一阶段调度模型求解的非劣解集及归一化处理
Attached Table 5 Noninferior solution set and normalized treatment of case 1

序号 k	f_1^k	f_2^k	f_3^k	μ_1^k	μ_2^k	μ_3^k	μ^k
1	491.240	10 619.203	0.005	0.513	0.804	0.800	0.118
2	490.892	12 009.218	0.024	0.517	0.514	0.000	0.057
3	536.793	9 676.189	0.000	0.000	1.000	1.000	0.111
4	484.576	13 232.189	0.013	0.588	0.260	0.450	0.072
5	457.149	14 481.443	0.017	0.898	0.000	0.300	0.067
6	451.835	13 877.036	0.022	0.958	0.126	0.100	0.066
7	449.136	13 883.271	0.022	0.988	0.124	0.100	0.067
8	448.068	13 907.734	0.022	1.000	0.119	0.100	0.068
9	469.981	14 204.986	0.017	0.753	0.057	0.300	0.062
10	469.911	14 219.297	0.017	0.754	0.054	0.300	0.062
11	470.038	14 194.630	0.017	0.752	0.060	0.300	0.062
12	470.059	14 194.546	0.017	0.752	0.060	0.300	0.062
13	457.430	14 265.468	0.017	0.894	0.045	0.300	0.069
14	462.032	13 854.114	0.022	0.843	0.131	0.100	0.060

附表 6 XGBoost 超参数设置

Attached Table 6 Setting of XGBoost's Hyperparameters

模型名称	超参数设置
蓄电池消纳弃风调度模型	colsample_bytree=0.1, gamma=0.568, importance_type='gain', learning_rate=0.0087, max_depth=9, min_child_weight=8, n_estimators=1600, objective='binary:logistic', scale_pos_weight=0.8, subsample=0.9
调频电源调度模型	colsample_bytree=0.7, gamma=0.010, importance_type='gain', learning_rate=0.0342, max_depth=16, min_child_weight=4, n_estimators=1900, objective='binary:logistic', scale_pos_weight=0.7, subsample=0.4

附表 7 XGBoost 预测弃风时刻和失负荷时刻结果

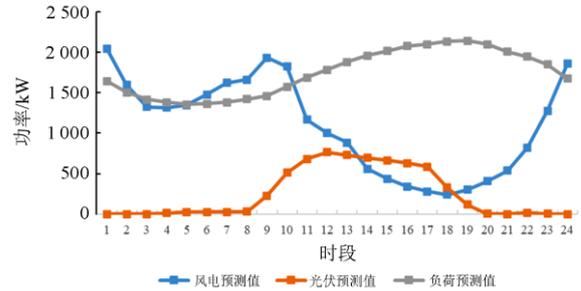
Attached Table 7 Moments prediction of wind curtailment and load loss by XGBoost

弃风时刻		失负荷时刻	
预测值	实际值	预测值	实际值
1	0	0	1
1	0	0	1
1	1	0	0
1	1	0	0
1	1	0	0
1	1	0	0
1	1	0	0
1	1	0	0
1	1	0	0
1	0	0	1
0	0	1	1
0	1	1	0
0	0	1	1
0	0	1	1
0	1	1	0
0	0	1	1
0	1	1	0
0	1	1	0
1	1	0	0
1	1	0	0
1	1	0	0
1	1	0	0
1	1	0	0

附表 8 ELM 超参数设置

Attached Table 8 Setting of extreme learning machine's hyperparameters

模型名称	超参数设置
蓄电池消纳弃风调度模型	N=26, TF='sin', TYPE=0.
调频电源调度模型	N=26, TF='sin', TYPE=0.



附图 1 风电、光伏及负荷功率预测值

Attached Fig. 1 Prediction of wind power, PV and load

附录 B

MPSO 优化的算法流程与标准粒子群算法的流程大体上是一样的,通常 MPSO 优化算法步骤如下。

1) 初始化粒子群,种群大小为 N ,粒子维数为 D ,随机初始化每个粒子的位置 x_{id} 和速度 v_{id} (其中 $i=1,2,\dots,N$, $d=1,2,\dots,D$)。

2) 计算粒子的适应值。

3) 计算粒子个体和全局历史最佳 P_i 和 P_g 。

4) 采用充分大(小)适应度函数值进行比较,选择新的最佳适应度函数值。

5) 按下述公式更新粒子速度和位置,若粒子的某一维超过边界,则重新初始化此维数据。

$$v_{id} = w \cdot v_{id}^k + c_1 \cdot r_1 (P_{id}^k - x_{id}^k) + c_2 \cdot r_2 (P_{gd}^k - x_{id}^k) \quad (1)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (2)$$

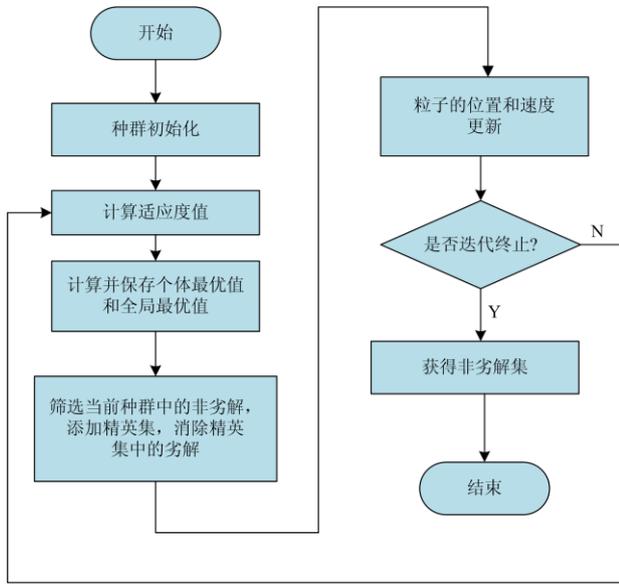
式中: w 为惯性权重; k 为当前迭代次数; v_{id} 为粒子的速度; c_1 和 c_2 是非负的常数,称为加速度因子; r_1 和 r_2 是分布于 $[0,1]$ 区间的随机数。

6) 筛选当前粒子群中的非劣解,并加入精英集中,并剔除精英集合中的劣解。

7) 是否满足终止条件,满足则结束循环,否则返回步骤 2)。

最终获得的精英集即为 MPSO 算法所得非劣解集,也即所需要达到的目标。

MPSO 算法的流程图如附图 2 所示。



附图 2 MOPSO 算法的流程图

Attached Fig. 2 Flow chart of MOPSO

参考文献

[1] 郝飞, 袁贞, 袁志彬, 等. 离网型微电网稳态功率控制策略研究与实践[J]. 电力系统保护与控制, 2020, 48(22): 173-179.
HAO Fei, YUAN Zhen, YUAN Zhibin, et al. Research and practice on off-grid microgrid steady power control strategy[J]. Power System Protection and Control, 2020, 48(22): 173-179.

[2] 陈寒, 唐忠, 鲁家阳, 等. 基于 CVaR 量化不确定性的微电网优化调度研究[J]. 电力系统保护与控制, 2021, 49(5): 105-115.
CHEN Han, TANG Zhong, LU Jiayang, et al. Research on optimal dispatch of a microgrid based on CVaR quantitative uncertainty[J]. Power System Protection and Control, 2021, 49(5): 105-115.

[3] 唐程辉, 张凡, 张宁, 等. 考虑可再生能源随机性和需求响应的电力系统日前经济调度[J]. 电力系统自动化, 2019, 43(15): 18-25, 63.
TANG Chenghui, ZHANG Fan, ZHANG Ning, et al. Day-ahead economic dispatch of power system considering renewable power uncertainty and demand response[J]. Automation of Electric Power Systems, 2019, 43(15): 18-25, 63.

[4] NIKZAD M, SAMIMI A. Integration of designing price-based demand response models into a stochastic bi-level scheduling of multiple energy carrier microgrids considering energy storage systems[J]. Applied Energy, 2021, 282.

[5] TALARI S, SHAFIE-KHAH M, MAHMOUDI N, et al. Optimal management of demand response aggregators considering customers' preferences within distribution networks[J]. IET Generation, Transmission & Distribution, 2020, 14(23): 5571-5579.

[6] 侯慧, 徐焘, 肖振锋, 等. 计及可调负荷的发电量一体化综合优化调度[J]. 电网技术, 2020, 44(11): 4294-4304.
HOU Hui, XU Tao, XIAO Zhenfeng, et al. Generation and load integrated optimal scheduling considering adjustable load[J]. Power System Technology, 2020, 44(11): 4294-4304.

[7] 向月, 刘俊勇, 魏震波, 等. 考虑可再生能源出力不确定性的微电网能量优化鲁棒模型[J]. 中国电机工程学报, 2014, 34(19): 3063-3072.
XIANG Yue, LIU Junyong, WEI Zhenbo, et al. Robust model of microgrid energy optimization with uncertain renewable energy sources[J]. Proceedings of the CSEE, 2014, 34(19): 3063-3072.

[8] 夏澍, 顾劲岳, 葛晓琳, 等. 风光联合优化配置的多目标机会约束规划方法[J]. 电力系统保护与控制, 2016, 44(6): 35-40.
XIA Shu, GU Jinyue, GE Xiaolin, et al. Multiobjective chance-constrained programming method for wind generations and photovoltaic allocating[J]. Power System Protection and Control, 2016, 44(6): 35-40.

[9] 赵晶晶, 徐传琳, 吕雪, 等. 微电网一次调频备用容量与储能优化配置方法[J]. 中国电机工程学报, 2017, 37(15): 4324-4332.
ZHAO Jingjing, XU Chuanlin, LÜ Xue, et al. Optimization of micro-grid primary frequency regulation reserve capacity and energy storage system[J]. Proceedings of the CSEE, 2017, 37(15): 4324-4332.

[10] 赵冬梅, 殷加玢. 考虑源荷双侧不确定性的模糊随机机会约束优先目标规划调度模型[J]. 电工技术学报, 2018, 33(5): 1076-1085.
ZHAO Dongmei, YIN Jiafu. Fuzzy random chance constrained preemptive goal programming scheduling model considering source-side and load-side uncertainty[J]. Transactions of China Electrotechnical Society, 2018, 33(5): 1076-1085.

[11] 刘一欣, 郭力, 王成山. 微电网两阶段鲁棒优化经济调度方法[J]. 中国电机工程学报, 2018, 38(14): 4013-4022.
LIU Yixin, GUO Li, WANG Chengshan. Economic dispatch of microgrid based on two stage robust optimization[J]. Proceedings of the CSEE, 2018, 38(14): 4013-4022.

[12] 杨茂, 王金鑫. 考虑可再生能源出力不确定的孤岛型微电网优化调度[J]. 中国电机工程学报, 2021, 41(3): 973-984.

- YANG Mao, WANG Jinxin. Optimal scheduling of islanded microgrid considering uncertain output of renewable energy[J]. Proceedings of the CSEE, 2021, 41(3): 973-984.
- [13] 文晶, 刘文颖, 谢昶, 等. 计及风电消纳效益的电力系统源荷协调二层优化模型[J]. 电工技术学报, 2015, 30(8): 247-256.
- WEN Jing, LIU Wenyong, XIE Chang, et al. Source-load coordination optimal model considering wind power consumptive benefits based on bi-level programming[J]. Transactions of China Electrotechnical Society, 2015, 30(8): 247-256.
- [14] MOHAMED F A, KOIVO H N. Microgrid online management and balancing using multiobjective optimization[C] // 2007 IEEE Lausanne Power Tech, July 1-5, 2007, Lausanne, Switzerland.
- [15] LI J, NIU D, WU M, et al. Research on battery energy storage as backup power in the operation optimization of a regional integrated energy system[J]. Energies, 2018, 11(11).
- [16] 欧阳庭辉, 查晓明, 秦亮, 等. 含核函数切换的风电功率短期预测新方法[J]. 电力自动化设备, 2016, 36(9): 80-86.
- OUYANG Tinghui, ZHA Xiaoming, QIN Liang, et al. Short-term wind power prediction based on kernel function switching[J]. Electric Power Automation Equipment, 2016, 36(9): 80-86.
- [17] 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.
- [18] O'NEILL-CARRILLO E, HEYDT G T, KOSTELICH E J. Chaotic phenomena in power systems: detection and applications[J]. Electric Machines and Power Systems, 1999, 27(1): 79-91.
- [19] FAN G, PENG L, HONG W. Short term load forecasting based on phase space reconstruction algorithm and bi-square kernel regression model[J]. Applied Energy, 2018, 224: 13-33.
- [20] 靳果, 朱清智, 孟阳, 等. 基于多层极限学习机的电能质量扰动多标签分类算法[J]. 电力系统保护与控制, 2020, 48(8): 96-105.
- JIN Guo, ZHU Qingzhi, MENG Yang, et al. Power quality disturbances multi-label classification algorithm based on a multi-layer extreme learning machine[J]. Power System Protection and Control, 2020, 48(8): 96-105.
- [21] HOU H, XUE M Y, XU Y, et al. Multi-objective economic dispatch of a microgrid considering electric vehicle and transferable load[J]. Applied Energy, 2020, 262.
- [22] LOGENTHIRAN T, SRINIVASAN D, SHUN T Z. Demand side management in smart grid using heuristic optimization[J]. IEEE Transactions on Smart Grid, 2012, 3(3): 1244-1252.
- [23] HUANG K Y, CHIN H C, HUANG Y C. A model reference adaptive control strategy for interruptible load management[J]. IEEE Transactions on Power Systems, 2004, 19(1): 683-689.
- [24] 陆立民, 褚国伟, 张涛, 等. 基于改进多目标粒子群算法的微电网储能优化配置[J]. 电力系统保护与控制, 2020, 48(15): 116-124.
- LU Limin, ZHU Guowei, ZHANG Tao, et al. Optimal configuration of energy storage in a microgrid based on improved multi-objective particle swarm optimization[J]. Power System Protection and Control, 2020, 48(15): 116-124.
- [25] HUANG Z, FANG B, DENG J. Multi-objective optimization strategy for distribution network considering V2G enabled electric vehicles in building integrated energy system[J]. Protection and Control of Modern Power Systems, 2020, 5(1): 48-55.
- [26] XU Y, ZHANG R, DONG Z Y, et al. Optimal placement of static compensators for multi-objective voltage stability enhancement of power systems[J]. IET Generation, Transmission & Distribution, 2015, 9(15): 2144-2151.
- [27] 陈纬楠, 胡志坚, 岳菁鹏, 等. 基于长短期记忆网络和 LightGBM 组合模型的短期负荷预测[J]. 电力系统自动化, 2021, 45(4): 91-97.
- CHEN Weinan, HU Zhijian, YUE Jingpeng, et al. Short-term load prediction based on combined model of long-short-term memory network and light gradient boosting machine[J]. Automation of Electric Power Systems, 2021, 45(4): 91-97.
- [28] HOU H, XUE M, XU Y, et al. Multiobjective joint economic dispatching of a microgrid with multiple distributed generation[J]. Energies, 2018, 11(12).

收稿日期: 2021-10-19; 修回日期: 2022-01-05

作者简介:

侯慧(1981—), 女, 博士, 副教授, 研究方向为能源互联网、电动汽车智能充电策略等; E-mail: husthou@126.com

王晴(1998—), 女, 硕士研究生, 研究方向为能源互联网。E-mail: wangqing1342@whut.edu.cn

(编辑 葛艳娜)