

# 控制与决策

Control and Decision

## 基于交叉-变异人工蜂群算法的微网优化调度

曹知奥, 汪晋宽, 韩英华, 赵强

引用本文:

曹知奥, 汪晋宽, 韩英华, 等. 基于交叉-变异人工蜂群算法的微网优化调度[J]. *控制与决策*, 2020, 35(9): 2059–2069.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.0506>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 基于改进邻域搜索策略的人工蜂群算法

Artificial bee colony algorithm based on improved neighborhood search strategy

*控制与决策*. 2019, 34(5): 965–972 <https://doi.org/10.13195/j.kzyjc.2017.1506>

### 改进人工蜂群算法求解分布式柔性作业车间调度问题

Improved artificial bee colony algorithm for distributed and flexible job-shop scheduling problem

*控制与决策*. 2019, 34(12): 2527–2536 <https://doi.org/10.13195/j.kzyjc.2018.0336>

### 多可再生能源冷热电联供微网系统环境经济优化调度

Optimal environmental economic scheduling of combined cooling heating and power microgrid system with multi-renewable energy

*控制与决策*. 2016, 31(5): 913–918 <https://doi.org/10.13195/j.kzyjc.2015.0393>

### 分布式人工蜂群免疫算法求解函数优化问题

Distributed artificial bee colony immune algorithm for the problems of function optimization

*控制与决策*. 2015(7): 1181–1188 <https://doi.org/10.13195/j.kzyjc.2014.0547>

### 基于信息熵的改进人工蜂群算法

Improved artificial bee colony algorithm based on information entropy

*控制与决策*. 2015(6): 1121–1125 <https://doi.org/10.13195/j.kzyjc.2014.0377>

# 基于交叉-变异人工蜂群算法的微网优化调度

曹知奥<sup>1</sup>, 汪晋宽<sup>1,2†</sup>, 韩英华<sup>2</sup>, 赵 强<sup>2</sup>

(1. 东北大学 信息科学与工程学院, 沈阳 110004; 2. 东北大学 秦皇岛分校, 河北 秦皇岛 066004)

**摘要:** 随着大规模可再生能源接入微网,其不确定性直接影响微网的优化调度. 鉴于此,以微网的产能利润最大化为目标,构建微网日前产能调度的优化模型,其中对储能单元和需求响应负荷进行调度,对可再生能源产能预测的误差进行处理. 考虑优化模型中包含的非线性特征,提出一种基于交叉和变异的人工蜂群算法以求解微网最优调度策略. 所提出算法在雇佣蜂和观察蜂阶段,引入遗传算法中的交叉和变异操作对邻域搜索策略进行更新,以确保子代种群的多样性;在侦查蜂阶段,构建基于全局搜索的初始化机制,以提高算法搜索全局最优解的能力. 仿真结果验证了所构建模型的有效性和算法的优越性.

**关键词:** 可再生能源; 需求响应; 不确定性; 微网日前产能优化调度; 交叉与变异; 人工蜂群算法

中图分类号: TP273 文献标志码: A

DOI: 10.13195/j.kzyjc.2019.0506

引用格式: 曹知奥,汪晋宽,韩英华,等. 基于交叉-变异人工蜂群算法的微网优化调度[J]. 控制与决策, 2020, 35(9): 2059-2069.

## Crossover-mutation based artificial bee colony algorithm for optimal scheduling of microgrid

CAO Zhi-ao<sup>1</sup>, WANG Jin-kuan<sup>1,2†</sup>, HAN Ying-hua<sup>2</sup>, ZHAO Qiang<sup>2</sup>

(1. College of Information Science and Engineering, Northeastern University, Shenyang 110004, China; 2. Northeastern University at Qinhuangdao, Northeastern University, Qinhuangdao 066004, China)

**Abstract:** With the access of large-scale renewable energy to the microgrid, its uncertainty directly affects the optimal scheduling of the microgrid. In this paper, aiming at maximizing the generation profits of microgrid, an optimization model of day-ahead generation schedule for the microgrid is constructed, with consideration of the energy storage, demand response and error handling of renewable generation prediction. Then an improved artificial bee colony algorithm based on crossover and mutation operations is proposed to solve this problem. In the employed bee phase and onlooker bee phase, crossover and mutation processing is introduced to improve the neighborhood search strategy, in order to ensure the diversity of offspring population. In the scout bee phase, an initialization mechanism based on global search is constructed to improve the ability of searching global optimal solution. Finally, the simulation results demonstrate the effectiveness of the model and the superiority of the algorithm.

**Keywords:** renewable energy; demand response; uncertainty; microgrid optimal day-ahead generation schedule; crossover and mutation; artificial bee colony algorithm

## 0 引言

近年来,电力系统灵活性需求逐渐提高且大规模可再生能源广泛接入,极大地促进了智能微电网(MG)的建立与发展<sup>[1]</sup>. MG可视为一个小规模的区域电力系统,其中包括分布式发电单元、可再生能源、能量存储设备和用电负荷等<sup>[2]</sup>. 利用合理的产能耗能控制和优化的能量调度方案, MG不仅能够为用户提

供更高质量的电力供应,而且可以降低系统产能和运营成本<sup>[3-6]</sup>. 然而,可再生能源本身所具有的不确定性给MG的优化运营带来了巨大困难,因此如何有效降低可再生能源不确定性对MG控制和运营的影响,优化MG的能量调度,成为人们广泛关注的问题<sup>[7-9]</sup>.

在能源危机和环境恶化日益严重的情况下,可再生能源,尤其是风力发电和光伏发电,其应用逐渐

收稿日期: 2019-04-22; 修回日期: 2019-11-05.

基金项目: 国家重点研发计划项目(2016YFB0901900); 河北省自然科学基金项目(F2017501107); 中央高校基本科研业务费专项基金项目(N182303037); 东北大学轧制技术及连轧自动化国家重点实验室开放课题基金项目(2017RALKFKT003).

责任编辑: 刘德荣.

†通讯作者. E-mail: wjk@neuq.edu.cn.

受到重视.然而,可再生能源的产能会随天气情况的变化发生波动<sup>[10]</sup>,具有间歇性和随机性的特点,使得MG运营商难以准确预测可再生能源的产能情况,导致能量调度过程中可能出现供需失衡.为了解决这一问题,电池储能系统(BESS)的设计成为了MG运营中至关重要的一环<sup>[11]</sup>.文献[12]基于BESS的不同运行模式,对多能互补微电网的日前调度总成本进行优化,以获得最低的调度成本.Lee等<sup>[13]</sup>将多个BESS集合为一个整体后接入MG,并利用分布式控制算法协调各个BESS,以实现MG优化调度.Zhao等<sup>[14]</sup>基于分时电价(ToU)机制提出一种微网的动态经济调度方法,根据负荷预测和可再生能源产能数据,利用BESS优化微网的经济调度策略.文献[15]研究了接入MG中的BESS的能量效率与电池SoC及充放电速率之间的关系,有效降低了BESS能量效率波动对MG优化调度的影响.虽然很多文献研究了BESS在MG中的优化调度问题,但大部分文献并未考虑BESS在接入MG运营时所需的投资成本和运营维护成本.实际上,MG在利用BESS进行能量优化调度时,需要支付高昂的投资和运营维护费用,这些成本在计算最终的MG产能收益时必须考虑在内.

另一种降低可再生能源产能波动对MG优化调度影响的方法是需求响应规划(DRP)<sup>[16]</sup>.DRP是指在电力系统出现紧急情况时,针对用电用户所执行的一系列调度策略,以降低用户的用电负荷.文献[17]提出一种基于DRP的方法提升微网的灵活性,将用户负荷划分为关键负荷与非关键负荷两部分,微网运营商通过优化调度决定是否将能量供给非关键负荷或存储于储能单元.文献[18]提出一种新颖的随机优化框架,用于一个独立微网的日前能量管理,利用基于激励的DRP保证微网的供需平衡.文献[19]为提高可再生能源利用率,提出微网层和DRP层协同的双层微网优化调度模型,利用DRP对负荷曲线进行优化,并基于实时电价最小化微网运营成本.Ghasemi等<sup>[20]</sup>利用一个新颖的储能系统和DRP的优化框架降低微网的调度运营成本.大量文献和研究表明,利用DRP进行MG的优化调度,可以有效弥补可再生能源不确定性导致的能量供需失衡,并且能够实现MG运营过程中用电负荷的削峰填谷<sup>[21-22]</sup>.

考虑储能单元调度的优化模型中往往具有一定的非线性,而传统的线性规划方法无法高效求解此类包含非线性部分的模型.为了解决这一问题,必须寻求高效的优化算法以获得MG优化调度的最优解.确定性算法是一种高度依赖于系统和建模的优化算法,但对于复杂问题而言,其模型中的不确定性往往使得

算法求解效果不佳,在求解具有高维搜索空间的优化问题时(例如机组组合(UC)问题和经济调度(ED)问题),确定性优化算法难以提供合适的可行解<sup>[23]</sup>.针对此类问题,启发式优化算法可以获得较好的优化结果,如遗传算法<sup>[24]</sup>、粒子群优化算法<sup>[25]</sup>、蚁群优化算法<sup>[26]</sup>和蜂群优化算法<sup>[27]</sup>等.

本文在进行MG优化调度时将BESS的投资成本和运营维护费用考虑在内,其中投资成本模型具有非线性特性,因此优化目标函数成为一个复杂的、非线性的混合整数规划问题.鉴于此,结合MG优化调度目标函数的特征,考虑人工蜂群算法(ABC)的搜索能力强、执行方法简易及收敛速度快的特点<sup>[28-32]</sup>,采用基于交叉与变异的人工蜂群算法.通过选取多维度的初始种群,将不同类型的变量参数置于同一种群,同时在优化过程中引入遗传算法中的交叉和变异操作,以获得MG运营中的最优产能调度策略.

## 1 问题描述与数学模型

### 1.1 问题描述

本文所研究的优化问题是基于一个小规模的居民区MG,具体结构如图1所示,其中包含风力发电(WT)、光伏发电(PV)、BESS和用户负荷.由于WT和PV的产能具有间歇性和随机性,需要利用BESS和可再生能源进行联合运营,以减小可再生能源不确定性对MG优化调度与运营所产生的影响.同时,优化目标函数中加入了BESS的投资成本和运营维护费用,并采用基于交叉和变异的人工蜂群算法对所构建的MG优化调度模型进行求解,以获得MG的最优日前产能规划和最大化的产能利润.

### 1.2 数学模型

本文根据图1的MG结构,针对其中的产能单元、储能单元和用户负荷分别进行数学建模并构建MG优化调度的目标函数.各部分模型建立如下:

#### 1) 风力发电(WT).

风力发电的产能根据风速-功率的关系,利用预测风速获得,其表达式如下:

$$P^W(t) = \begin{cases} 0, & V(t) \leq V_{\text{cut-in}}; \\ \frac{1}{2} \rho \pi R^2 C_p (V(t))^3, & V_{\text{cut-in}} < V(t) \leq V_r; \\ P^{\text{rate}}, & V_r < V(t) \leq V_{\text{cut-out}}; \\ 0, & V(t) > V_{\text{cut-out}}. \end{cases} \quad (1)$$

其中: $P^W(t)$ 为风力发电的产能, $V(t)$ 为平均风速, $V_{\text{cut-in}}$ 、 $V_r$ 、 $V_{\text{cut-out}}$ 分别为风机的切入风速、额定风速和切出风速, $\rho$ 为风机叶片高度处的空气密度, $R$ 为叶片半径, $C_p$ 为风机产能效率.

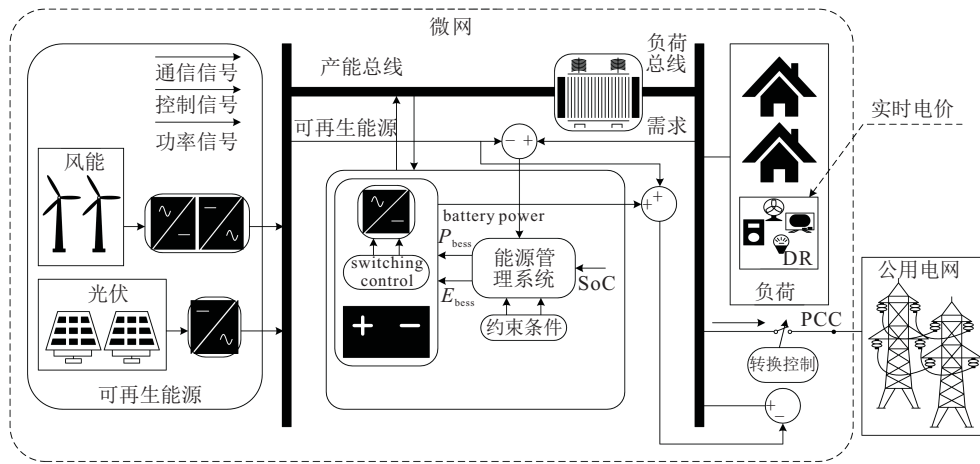


图1 微网系统结构

由于风速的日前预测存在误差,本文在风速预测中加入误差处理. 通过在初步预测得到的风速数据上加上预测误差,可得预测风速的上下界,真实的风速则介于上下界之间,具体表达式如下:

$$V_f^{up}(t) = (1 + \delta)V(t), \quad (2)$$

$$V_f^{low}(t) = (1 - \delta)V(t). \quad (3)$$

其中:  $V(t)$  为误差处理前的预测风速,  $V_f^{up}(t)$ 、 $V_f^{low}(t)$  为误差处理后获得的上、下界,  $\delta$  为预测时段的预测误差. 由文献[33-34]可知,风速日前预测的误差大约在 10%~25% 之间.

将  $V_f^{up}(t)$ 、 $V_f^{low}(t)$  代入式(1),可得到风能预测的上下界,真实的风能产能介于上下界之间. 对获得的风能预测产能上下界进行时序交叉选择,假设当前  $t$  时段内的风能产能取值为上界  $P_f^W(t) = P_f^{up}$ ,则  $t+1$  时段内的产能值取下界  $P_f^W(t+1) = P_f^{low}$ ,依次交叉得到误差处理后的风能预测产能  $P_f^W$ .

### 2) 光伏发电 (PV).

光伏发电的能量输出主要由光伏模块的规模、太阳照度、大气温度和光伏模块能量转换效率决定,具体的能量输出计算公式<sup>[35]</sup>可表示为

$$P^{PV}(t) = \eta_{pv} A_{pv} I_{solar}(t)(1 - 0.005(\text{tem} - 25)). \quad (4)$$

其中:  $\eta_{pv}$  为光伏阵列的能量转换效率,  $A_{pv}$  为光伏太阳能板的覆盖面积,  $\text{tem}$  和  $I_{solar}(t)$  分别为大气温度和太阳照度.

由于光伏发电同样存在波动性,且误差主要与太阳照度  $I_{solar}(t)$  相关,本文利用风能发电相同的方法对光伏日前预测产能进行误差处理,其中太阳照度的误差  $\epsilon$  大约为 30%<sup>[36-37]</sup>,具体计算公式如下:

$$I_{pv}^{up}(t) = (1 + \epsilon)I_{solar}(t), \quad (5)$$

$$I_{pv}^{low}(t) = (1 - \epsilon)I_{solar}(t), \quad (6)$$

$$P_{pv}^{up}(t) = \eta_{pv} A_{pv} I_{pv}^{up}(t)(1 - 0.005(\text{tem} - 25)), \quad (7)$$

$$P_{pv}^{low}(t) = \eta_{pv} A_{pv} I_{pv}^{low}(t)(1 - 0.005(\text{tem} - 25)). \quad (8)$$

同样对得到的光伏预测产能上下界进行时序交叉选择,得到误差处理后的光伏预测产能  $P_f^{PV}$ .

### 3) 需求响应规划 (DRP).

本文设定用户负荷分为两部分:固定负荷 ( $\text{Load}_{con}$ ) 和 3 部分柔性负荷 ( $\text{Load}_{var,1}$ 、 $\text{Load}_{var,2}$ 、 $\text{Load}_{var,3}$ ). 其中柔性负荷即为用户参与 DRP 的可调度负荷,固定负荷和柔性负荷均为恒定的常数值,优化过程中 DRP 可调度的能量计算如下:

$$P^{DRP}(t) = \sum_{n=1}^{N_{\text{Load}_{var}}} \text{Load}_{var,n} \Phi_n(t) \Delta t. \quad (9)$$

其中:  $P^{DRP}(t)$  为 DRP 参与调度的能量;  $n$  为柔性负荷的编号;  $\text{Load}_{var,n}$  为每部分柔性负荷参与调度的能量;  $\Phi_n(t)$  为二进制变量,  $\Phi_n(t) = 1$  表示该柔性负荷参与需求响应调度,  $\Phi_n(t) = 0$  表示负荷不执行需求响应调度.

### 4) 电池储能电源 (BESS).

本文利用 BESS 的充放电规划参与 MG 的优化调度,其可调度能量的计算方式如下:

$$P^{BESS}(t) = \zeta p_b(t). \quad (10)$$

其中:  $P^{BESS}(t)$  为 BESS 所需要进行充放电的功率,  $\zeta$  为电池的充放电效率,  $p_b(t)$  为此时间间隔内电池所需要充电或者放电的功率. 此外,在构建优化模型时考虑 BESS 的投资成本和运营维护成本,有

$$C^{om}(t) = r_{BESS}^{om} N_{om}(t), \quad (11)$$

$$C^{in} = \frac{1}{365} r_{BESS}^{in} \left[ \frac{a(1+a)^{\text{year}}}{(1+a)^{\text{year}} - 1} \right] S_{BESS}. \quad (12)$$

其中:  $r_{BESS}^{om}$  为 BESS 每次充放电的运营成本,  $N_{om}(t)$  为到第  $t$  个优化时间段为止累计的充放电次数,

$r_{\text{BESS}}^{\text{in}}$  为 BESS 的投资成本,  $a$  为电池的折扣率,  $S_{\text{BESS}}$  为电池的总容量.

5) 优化目标函数.

假定 MG 的所有产能可以根据当前电价完全转换为所获得的产能利润, 此构建旨在最大化微网所获得的产能利润的目标函数, 从而优化微网中的能量调度. 具体优化模型表示如下:

$$F = \max \sum_{t=1}^T [r(t)(P_f^W(t) + P_f^{\text{PV}}(t) + P^{\text{BESS}}(t) + P^{\text{DRP}}(t))\Delta t - C^{\text{om}}(t) - \gamma^+ r(t)\Delta p^+(t)\Delta t - \gamma^- r(t)\Delta p^-(t)\Delta t] - C^{\text{in}}. \quad (13)$$

其中:  $F$  为优化调度所获得的微网产能利润,  $r(t)$  为电价;  $P_f^W(t)$ 、 $P_f^{\text{PV}}(t)$ 、 $P^{\text{BESS}}(t)$  和  $P^{\text{DRP}}(t)$  分别为误差处理后的预测风能、误差处理后的预测光伏、BESS 的可调度能量和 DRP 的可调度能量;  $C^{\text{om}}(t)$ 、 $C^{\text{in}}$  分别为 BESS 的运营维护成本和投资成本;  $\Delta p^+(t)$ 、 $\Delta p^-(t)$  分别为微网的预测产能与所需提交的日前产能规划之间的正负偏差, 与相对应的正负惩罚因子  $\gamma^+$ 、 $\gamma^-$  一同组成惩罚项, 以保证优化得到的日前产能规划尽可能与微网的预测产能一致, 具体为

$$\Delta p^+(t) = \max(0, P^{\text{da}}(t) - (P_f^W(t) + P_f^{\text{PV}}(t) + P^{\text{BESS}}(t) + P^{\text{DRP}}(t))), \quad (14)$$

$$\Delta p^-(t) = -\min(0, P^{\text{da}}(t) - (P_f^W(t) + P_f^{\text{PV}}(t) + P^{\text{BESS}}(t) + P^{\text{DRP}}(t))). \quad (15)$$

针对上述目标函数, 优化过程中需考虑的约束条件主要是可再生能源的产能限制和 BESS 的充放电状态要求, 数学模型如下:

$$0 \leq P_f^W(t) \leq P^{\text{Wmax}}, \quad (16)$$

$$0 \leq P_f^{\text{PV}}(t) \leq P^{\text{PVmax}}, \quad (17)$$

$$\text{SOC}(t+1) = \text{SOC}(t) + \zeta p_b(t), \quad (18)$$

$$\text{SOC}^{\text{min}} \leq \text{SOC}(t) \leq \text{SOC}^{\text{max}}. \quad (19)$$

其中:  $P^{\text{Wmax}}$ 、 $P^{\text{PVmax}}$  为单位时段内风能和光伏的最大产能,  $\text{SOC}(t)$  为当前时段的 BESS 的充电量状态,  $\text{SOC}^{\text{min}}$ 、 $\text{SOC}^{\text{max}}$  分别为 BESS 最低容量界限和最高容量界限.

## 2 基于交叉与变异的人工蜂群(CM-ABC)算法

人工蜂群(ABC)算法是一种基于群体智能的启发式优化算法, 由 Karaboga<sup>[38]</sup> 首次提出. 传统 ABC 算法中雇佣蜂和观察蜂在单一邻域内“探索”(exploration)食物源, 侦查蜂则于整个可行解空间中

随机“开发”(exploitation)新的食物源, 导致算法搜索全局最优的效率较低, 容易出现早熟收敛的问题. 为了解决上述问题, 本文提出一种基于交叉与变异的 ABC 算法(CM-ABC). 首先, 以最大化 MG 所获得的产能利润为优化目标, 生成多类型多维度参数的初始种群, 根据参数的不同类型采取不同的搜索变化; 然后, 针对传统 ABC 算法“开发”能力较弱的问题, 引入遗传算法中的交叉和变异机制, 使得子代种群保持较高的多样性, 避免算法陷入局部最优的情况; 最后, 对传统 ABC 算法中侦查蜂阶段新食物源初始化方式进行优化, 充分利用全局最优解中的优质信息, 使得算法具有更高的全局搜索效率.

### 2.1 初始化阶段

初始化阶段主要包括算法控制参数初始化和食物源初始化. 其中雇佣蜂与观察蜂的数量相同, 均为 SN, maxLimit 控制可行解更新的过程中观察蜂向侦查蜂转变的条件, 而 maxCycle 则用以限制算法的迭代终止次数. 食物源初始化中, 每个食物源对应一个可行解, 本文针对 MG 的产能优化问题, 将不同类型的参数变量, 构建为一个高维矩阵进行求解, 具体参数主要有 BESS 的充放电电量  $P^{\text{BESS}}(t)$ 、参与 DRP 的柔性负荷的状态变量  $\Phi_n(t)$ 、MG 的日前产能策略  $P^{\text{da}}(t)$ . 构建的参数矩阵表达式如下(以每小时为优化时间间隔):

$$X = \begin{bmatrix} P^{\text{BESS}}(1) & P^{\text{BESS}}(2) & \dots & P^{\text{BESS}}(24) \\ \Phi_1(1) & \Phi_1(2) & \dots & \Phi_1(24) \\ \Phi_2(1) & \Phi_2(2) & \dots & \Phi_2(24) \\ \Phi_3(1) & \Phi_3(2) & \dots & \Phi_3(24) \\ P^{\text{da}}(1) & P^{\text{da}}(2) & \dots & P^{\text{da}}(24) \end{bmatrix}. \quad (20)$$

### 2.2 雇佣蜂阶段

种群初始化后, 雇佣蜂对当前食物源进行邻域搜索, 采用贪婪选择策略获取质量更好的食物源, 记录其位置与适应度值, 并将信息传递至观察蜂, 引导观察蜂对食物源进一步探索. 在传统 ABC 算法中, 邻域搜索策略单一, 搜索空间小且效率低. 本文根据参数特征, 对不同类型参数采用分类邻域搜索策略, 若当前迭代随机选择的变化参数为柔性负荷参与 DRP 的响应状态量, 相应的邻域搜索策略则直接将当前状态值改变为对应状态取值集合中的其余状态值; 若选择的变化参数为 BESS 的充放电电量或者 MG 的日前产能规划, 则采用下述邻域搜索策略进行变化:

$$v_{ij} = x_{ij} + \alpha_{ij}(x_{ij} - x'_{ij}). \quad (21)$$

其中:  $v_{ij}$  为邻域搜索后的参数值,  $x_{ij}$  为参数当前值,  $x'_{ij}$  为另一个随机可行解中相同位置的参数值,

$\alpha_{ij}$  为  $(-1, 1)$  的随机数。

为了进一步提高算法的“搜索”和“开发”能力, 引入交叉和变异操作, 对每次迭代过程中随机选择的参数进行交叉和变异变化, 生成子代与原可行解进行对比, 选取适应度值高的构成新种群以进行下一次迭

代, 具体实现过程如下所示。

1) 选取任意两个可行解  $X_1$ 、 $X_2$  对随机选取的某一位置的参数变量进行邻域搜索, 得到新的可行解  $V_1$ 、 $V_2$ , 有

$$\begin{array}{ccc}
 X_1 & & X_2 \\
 \left[ \begin{array}{cccccc} x_1(1,1) & x_1(1,2) & \dots & x_1(1,j) & \dots & x_1(1,24) \\ x_1(2,1) & x_1(2,2) & \dots & x_1(2,j) & \dots & x_1(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_1(5,1) & x_1(5,2) & \dots & x_1(5,j) & \dots & x_1(5,24) \end{array} \right] & & \left[ \begin{array}{cccccc} x_2(1,1) & x_2(1,2) & \dots & x_2(1,j) & \dots & x_2(1,24) \\ x_2(2,1) & x_2(2,2) & \dots & x_2(2,j) & \dots & x_2(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_2(5,1) & x_2(5,2) & \dots & x_2(5,j) & \dots & x_2(5,24) \end{array} \right] \\
 \Downarrow \text{初始变化} & & \\
 V_1 & & V_2 \\
 \left[ \begin{array}{cccccc} x_1(1,1) & x_1(1,2) & \dots & x_1(1,j) & \dots & x_1(1,24) \\ x_1(2,1) & x_1(2,2) & \dots & v_1(2,j) & \dots & x_1(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_1(5,1) & x_1(5,2) & \dots & x_1(5,j) & \dots & x_1(5,24) \end{array} \right] & & \left[ \begin{array}{cccccc} x_2(1,1) & x_2(1,2) & \dots & x_2(1,j) & \dots & x_2(1,24) \\ x_2(2,1) & x_2(2,2) & \dots & v_2(2,j) & \dots & x_2(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_2(5,1) & x_2(5,2) & \dots & x_2(5,j) & \dots & x_2(5,24) \end{array} \right]
 \end{array}$$

2) 在得到解  $V_1$ 、 $V_2$  后对其进行交叉操作, 由于解  $V_1$ 、 $V_2$  中选择的参数位于第 2 行, 将两解第 2

行中的所有参数进行互换, 得到交叉操作后的变化解  $C_1$ 、 $C_2$ , 有

$$\begin{array}{ccc}
 V_1 & & V_2 \\
 \left[ \begin{array}{cccccc} x_1(1,1) & x_1(1,2) & \dots & x_1(1,j) & \dots & x_1(1,24) \\ x_1(2,1) & x_1(2,2) & \dots & v_1(2,j) & \dots & x_1(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_1(5,1) & x_1(5,2) & \dots & x_1(5,j) & \dots & x_1(5,24) \end{array} \right] & \xleftrightarrow{\text{交叉操作}} & \left[ \begin{array}{cccccc} x_2(1,1) & x_2(1,2) & \dots & x_2(1,j) & \dots & x_2(1,24) \\ x_2(2,1) & x_2(2,2) & \dots & v_2(2,j) & \dots & x_2(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_2(5,1) & x_2(5,2) & \dots & x_2(5,j) & \dots & x_2(5,24) \end{array} \right] \\
 \Downarrow & & \\
 C_1 & & C_2 \\
 \left[ \begin{array}{cccccc} x_1(1,1) & x_1(1,2) & \dots & x_1(1,j) & \dots & x_1(1,24) \\ x_2(2,1) & x_2(2,2) & \dots & v_2(2,j) & \dots & x_2(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_1(5,1) & x_1(5,2) & \dots & x_1(5,j) & \dots & x_1(5,24) \end{array} \right] & & \left[ \begin{array}{cccccc} x_2(1,1) & x_2(1,2) & \dots & x_2(1,j) & \dots & x_2(1,24) \\ x_1(2,1) & x_1(2,2) & \dots & v_1(2,j) & \dots & x_1(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x_2(5,1) & x_2(5,2) & \dots & x_2(5,j) & \dots & x_2(5,24) \end{array} \right]
 \end{array}$$

利用适应度函数 (本文为微网产能所获得的利润) 分别计算  $V_1$ 、 $V_2$ 、 $C_1$ 、 $C_2$  的适应度函数值, 并与初始可行解  $X_1$ 、 $X_2$  进行对比, 选择适应度函数值最高的两个可行解作为进行变异操作的对象, 即  $X'_1$ 、 $X'_2$ , 同时记录适应度值最高的可行解作为当前最优解。

变。变异时对每个可行解中的第  $j$  列充放电进行一次邻域搜索, 得到变异后的可行解  $MX'_1$ 、 $MX'_2$ , 分别计算  $X'_1$ 、 $X'_2$ 、 $MX'_1$ 、 $MX'_2$  的适应度值, 选择适应度值最高的两个可行解作为传递至观察蜂的最优信息, 同时将适应度值最高的可行解与当前最优解对比, 更新当前最优解, 有

3) 对  $X'_1$ 、 $X'_2$  进行变异操作, 本文引入的变异操作仅针对实数范围内变化的电池充放电值进行改

$$\begin{array}{ccc}
 X'_1 & & X'_2 \\
 \left[ \begin{array}{cccccc} x'_1(1,1) & x'_1(1,2) & \dots & x'_1(1,j) & \dots & x'_1(1,24) \\ x'_1(2,1) & x'_1(2,2) & \dots & x'_1(2,j) & \dots & x'_1(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x'_1(5,1) & x'_1(5,2) & \dots & x'_1(5,j) & \dots & x'_1(5,24) \end{array} \right] & & \left[ \begin{array}{cccccc} x'_2(1,1) & x'_2(1,2) & \dots & x'_2(1,j) & \dots & x'_2(1,24) \\ x'_2(2,1) & x'_2(2,2) & \dots & x'_2(2,j) & \dots & x'_2(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x'_2(5,1) & x'_2(5,2) & \dots & x'_2(5,j) & \dots & x'_2(5,24) \end{array} \right] \\
 \Downarrow \text{变异操作} & & \\
 MX'_1 & & MX'_2 \\
 \left[ \begin{array}{cccccc} x'_1(1,1) & x'_1(1,2) & \dots & mx'_1(1,j) & \dots & x'_1(1,24) \\ x'_1(2,1) & x'_1(2,2) & \dots & x'_1(2,j) & \dots & x'_1(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x'_1(5,1) & x'_1(5,2) & \dots & x'_1(5,j) & \dots & x'_1(5,24) \end{array} \right] & & \left[ \begin{array}{cccccc} x'_2(1,1) & x'_2(1,2) & \dots & mx'_2(1,j) & \dots & x'_2(1,24) \\ x'_2(2,1) & x'_2(2,2) & \dots & x'_2(2,j) & \dots & x'_2(2,24) \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ x'_2(5,1) & x'_2(5,2) & \dots & x'_2(5,j) & \dots & x'_2(5,24) \end{array} \right]
 \end{array}$$



### 2.3 观察蜂阶段

观察蜂接收到食物源信息后,利用适应度值计算可行解被观察蜂选择的概率,利用轮盘赌的方式选择可行解进行观察蜂阶段的优化. 概率计算为

$$P_i = f_i / \sum_{i=1}^{SN} f_i, \quad (22)$$

其中  $f_i$  为可行解对应的适应度值. 可行解适应度值越高,代表食物源质量越好,被观察蜂选中的概率也越大.

观察蜂选择可行解后,按照第2.2节描述的交叉变异过程进行进一步探索,通过这种方式在当前最优解的邻域附近进一步搜索适应度高的可行解.

### 2.4 侦查蜂阶段

若可行解的更新次数超过阈值 ( $\maxLimit$ ) 仍未获得改进,则将该可行解舍弃,对应的观察蜂转变为侦查蜂,开发新的可行解代替未获提升的解. 传统 ABC 算法中,侦查蜂在整个可行解空间随机生成新的可行解进行探索评估,新解的确立方式具有盲目性,并未利用到算法优化过程中得到的最优解中的优质信息.

针对上述问题,根据优化参数的变化特征优化侦查蜂可行解确立的初始化策略. 选用当前记录的全局最优解,保留其中 DRP 响应状态量,仅将 BESS 充放电量和日前产能规划  $P^{da}(t)$  初始化,以此作为侦查蜂确立的新解. 优化后的侦查蜂初始化策略,保留了当前最优解中的部分优质信息,从而更有可能向算法的全局最优解靠拢,提高了算法的搜索效率.

### 2.5 CM-ABC 算法流程

CM-ABC 算法的流程如图2所示,具体过程如下.

step 1: 初始化算法控制参数.

step 2: 构建初始种群  $X_i (i = 1, 2, \dots, SN)$ , 其中  $X_i$  代表目标函数的一个可行解,计算所有可行解的适应度值,并记录当前适应度值最高的为全局最优可行解  $X_{best}$ .

step 3: 雇佣蜂搜索阶段,每只雇佣蜂均执行以下子步骤.

step 3.1: 对初始种群  $X_i (i = 1, 2, \dots, SN)$  中的可行解进行邻域搜索、交叉操作和变异操作,获得新的种群  $X'_i (i = 1, 2, \dots, SN)$ ;

step 3.2: 计算新种群中每个可行解的适应度值  $f(X'_i)$ ;

step 3.3: 选择适应度值高的可行解代替旧的可行解,从而对种群进行更新,参数  $Limit$  表示每个可行解未获得提升的次数,若  $X'_i$  的适应度值高于  $X_i$ , 则

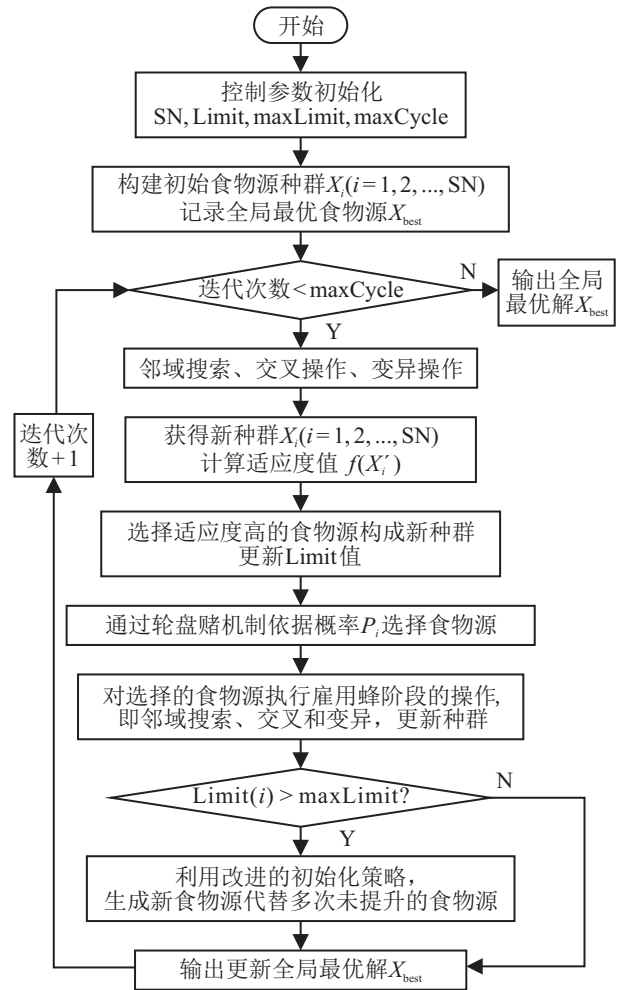


图2 CM-ABC 算法流程

$X_i = X'_i$ , 可行解获得提升,  $Limit = 0$ , 否则可行解未获得提升,  $Limit = Limit + 1$ .

step 4: 观察蜂阶段,利用式(23)计算每个可行解被选择的概率,利用轮盘赌的方式选择可行解进行探索,每个观察蜂选中可行解后,对其执行 step 3 的整个搜索过程.

step 5: 侦查蜂阶段,将超过  $\maxLimit$  的可行解舍弃,利用第2.4节描述的初始化策略确立新的可行解以继续执行算法的寻优过程.

step 6: 经过雇佣蜂、观察蜂和侦查蜂的寻优过程后,对所获得的新种群中的所有可行解进行适应度值的计算,将适应度值最高的可行解与之前记录的全局最优可行解进行对比,更新  $X_{best}$ .

step 7: 判断算法循环次数是否达到终止迭代次数  $\maxCycle$ , 若达到,则输出全局最优可行解  $X_{best}$ ; 否则转至 step 3 继续执行寻优搜索过程.

## 3 实验结果与分析

### 3.1 仿真参数

本文研究 MG 的产能优化调度,其中接入风能和光伏作为可再生能源,采用澳大利亚能源市场运营

商(AEMO)的数据,利用人工神经网络(ANN)进行预测,获得夏季某一晴天的风光产能预测数据<sup>[36]</sup>.考虑可再生能源的随机性和波动性,按照第1.2节描述的方法对预测数据进行误差处理,其中预测时域为00:00~04:00时,风能预测误差为10%;04:00~24:00时,误差为20%.光伏产能的预测误差为30%.未考虑预测误差时,风能和光伏产能情况及其上下界如图3所示.

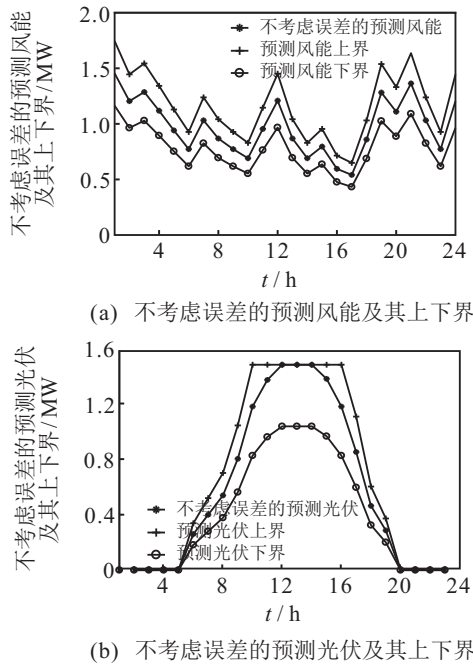


图3 未考虑误差的预测产能及其上下界

由图3得到的可再生能源产能的上下界,按照时序交替选择风能与光伏的上下界值,以此作为考虑预测误差后得到的可再生能源产能,如图4所示.

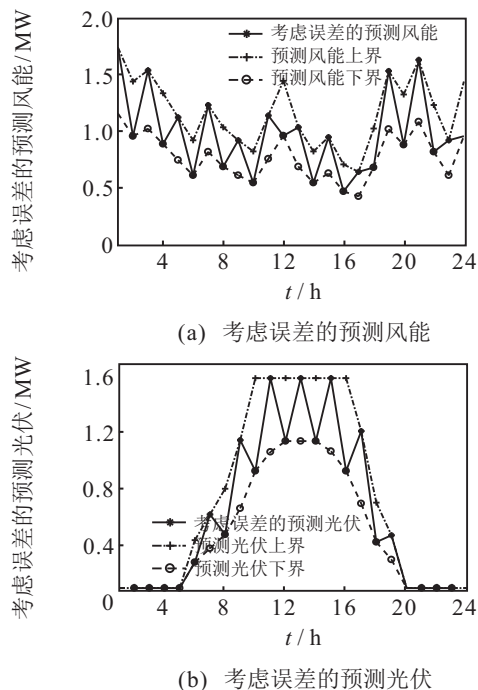


图4 考虑误差的预测风能及光伏

用户负荷分为固定负荷与柔性负荷,固定负荷设为2MW,柔性负荷部分(可参与DRP响应的用户负荷)分别为0.4MW、0.5MW和0.7MW.储能单元方面,假设BESS的充放电效率 $\zeta$ 为95%且单位时间内可调度的充电量不超过0.3MW. BESS和DRP的可调度能量均可通过对应的每个时段的价值进行优化.

算法各控制参数如下:初始可行解数量(SN)为20,可行解未提升次数阈值(maxLimit)为50,算法最大循环次数(maxCycle)为10000.算法在Matlab平台实现,并在Core I7-6700, 3.40 GHz, 16 G内存的计算机运行.

### 3.2 结果分析

本文采用传统人工蜂群(ABC)算法、交叉人工蜂群(CABC)算法、变异人工蜂群(MABC)算法、粒子群优化(PSO)算法以及标准蝙蝠(BA)算法<sup>[39-41]</sup>与CM-ABC算法进行对比,对文中的MG日前产能规划问题进行求解,6种算法运行后的收敛结果对比如图5所示.




图5 算法收敛结果对比

由图5可见,在相同的算法迭代次数和控制参数条件下,本文提出的CM-ABC算法较其他5种启发式算法,拥有最好的优化结果.对图5所示的收敛结果进行分析,可以得出以下几点结论:

1) PSO算法较传统ABC算法和3种基于传统ABC算法进行优化后的启发式算法而言,收敛结果具有明显差距. PSO算法将每个可行解视为一个粒子,通过更新粒子的位置和速度,在可行解空间中搜索目标函数的最优解.然而,该算法中每个粒子速度的初始化方式和速度更新策略中两个控制参数(惯性权重和学习因子)的设定,会对算法优化过程中当前迭代最优解和全局最优解中优质信息的利用率产生很大影响.传统PSO算法中,并未对这些控制参数进行优化,使得算法运行时难以充分利用最优解的信息,从而容易陷入局部最优.

2) 传统ABC算法虽然优化结果比PSO算法好,但通过与其他优化ABC算法对比可知,传统ABC算法也出现了早熟收敛的情况.虽然ABC算法中雇佣



蜂、观察蜂和侦查蜂的信息传递机制能够较好地利用获得的最优解中的信息,算法具有相对较好的搜索能力,但算法的开发能力不足,在可行域范围内搜索全局最优解的能力较弱,导致算法在优化过程中容易出现早熟收敛。

3) BA算法获得的优化结果比PSO算法好,与传统ABC算法相近,但是,优化效果仍不及CM-ABC算法。由图5可知,BA算法也出现了陷入局部极值的情况,这主要是因为BA算法参数的初始化较为随机且参数更新方式固定不变,使得算法缺少在局部最优解附近进一步搜索的方式,无法有效利用最优解信息进行深度的探索与开采,导致种群的多样性降低,算法寻优过程容易陷入局部极值。

4) 在传统ABC算法中引入遗传算法中的交叉操作,构成CABC算法。由图5可见,CABC算法的优化结果明显优于PSO算法和传统ABC算法,但收敛速度较慢。对比结果表明,交叉操作提升了传统ABC算法的优化效果,但仍不及MABC算法和CM-ABC算法获得的结果。这是因为CABC算法并未对算法的开发能力进行改进,算法难以收敛到全局最优值。此外,仅对可行解进行交叉操作,对交叉后获得的解未进行进一步优化,处理过程随机性较高,可能存在多次交叉操作后获得可行解的质量并未提升的情况,从而使得算法需要较多的迭代次数才能达到收敛。

5) 如同CABC算法,在传统ABC算法中引入遗传算法中的变异操作,构成MABC算法,MABC算法的收敛结果仅次于本文提出的CM-ABC算法。变异操作主要基于传统ABC算法较好的搜索能力,加强了算法的开发能力,通过对可行解进行变异的方式增加每次变化后可行解子代的多样性,从而提升算法在可行域中搜索全局最优解的能力。

6) 本文提出的CM-ABC算法利用遗传算法中的核心操作交叉和变异,同时对传统ABC算法中的可行解搜索过程进行优化。通过交叉和变异,既进一步提升了传统ABC算法的搜索能力,又增强了算法的开发能力,同时结合ABC算法中独特的雇佣蜂、观察蜂和侦查蜂3个阶段的信息传递机制,使得算法充分利用最优解中的信息,更快地在可行域范围内搜索到全局最优解。由图5结果可见,CM-ABC算法在第4560次迭代时达到收敛,收敛结果为36644.4RMB,明显优于其他4种启发式算法。通过与CABC算法对比可知,利用变异操作对交叉后获得的可行解进一步优化,提升了算法搜索全局最优解的能力,且降低了子代中可行解的随机性,提升了算法的收敛速

度;与MABC的对比可以看出,交叉操作的引入进一步增强了算法的搜索能力,结合变异操作对可行解多样性的提升,使得算法具有更好的在全局范围内搜索最优解的能力。

结合每种算法进行单次迭代所需要的时间,可得各算法收敛结果与运行时间如表1所示。

表1 算法收敛结果与运行时间

算法	收敛迭代次数	收敛结果/RMB	单次迭代时间/s
PSO	4014	28503.4	0.044
ABC	2061	31921.4	0.130
BA	6024	32397.1	0.084
CABC	6868	35414.4	0.172
MABC	2258	35869.6	0.159
CM-ABC	4560	36644.4	0.197

由表1可见,虽然PSO算法、ABC算法和BA算法迭代速度较快,但收敛结果易陷入局部最优。CABC算法和MABC算法的优化结果均不如CM-ABC算法,且CM-ABC算法具有相对较快的收敛速度。另一方面,优化效果最好的CM-ABC算法单次迭代所需要的运行时间最长,这主要是由于算法运行过程中交叉和变异操作增加了算法的执行步骤,从而一定程度上延长了算法的运行时间。即便如此,CM-ABC算法平均一次完整的迭代过程只需要0.197s,运行时间完全满足日前优化调度的需求。

算法收敛到全局最优时获得的可行解即为全局最优解,其中BESS充放电策略、DR响应策略和日前产能规划即为使得MG产能利润最高的最优策略,图6为获得的MG日前产能规划的最优策略。




图6 MG日前产能规划

由图6可见,优化得到的日前产能规划变化趋势与风能及光伏产能总和的变化趋势相同,表明MG尽可能地可将可再生能源的产能完全消纳,以最大化获得产能利润。对图6进一步分析可知,在01:00~05:00和20:00~24:00时间段,由于没有光伏产能,可再生能源仅包括风能产能一项,此时为了满足微网的产能需求,并尽可能减少MG向主电网购电的成本,优化调度策略中利用DR响应提供可调度的能量,以弥补光伏产能的缺失;在05:00~20:00时间段,风能和光

伏共同出力, MG 尽可能完全消纳可再生能源, 因此 DR 参与调度量相对减少. 另一方面, 由于市场中的分时电价作为激励, 参与了 MG 中电池的充放电调度和 DR 响应调度, 在 09:00~23:00 为高电价, 其余时间段为低电价的情形下, 电池的充电行为基本均处于 01:00~08:00 和 24:00 的低电价时间段, 以此降低电池充电所造成的成本. 在 17:00~23:00 时间段内, 存在连续的高比例 DR 响应参与调度, 且电池均处于放电状态, 这也表明了较高的市场电价激励 MG 进行电池放电和 DR 响应的调度, 以增加所获得的产能利润.

为了更好地表明本文所提出模型的有效性, 进一步采用基于蒙特卡洛仿真生成的场景法模拟风能光伏不确定性. 基于蒙特卡洛仿真的场景法是研究随机变量不确定性最常用的方法之一. 根据风速和光照预测误差在预测值附近呈现正态分布的特性, 利用蒙特卡洛仿真生成风速和光伏照度场景, 并根据风速-风能、光伏照度-光伏能量转换关系获得对应的风能和光伏场景各 1000 个, 然后利用场景削减方法对原始场景进行削减以降低计算负担. 最终, 选取 5 个遵循原始场景分布特征的近似子场景用于模拟风能光伏产能的不确定性. 风能和光伏产能的预测值和子场景集如图 7 所示.

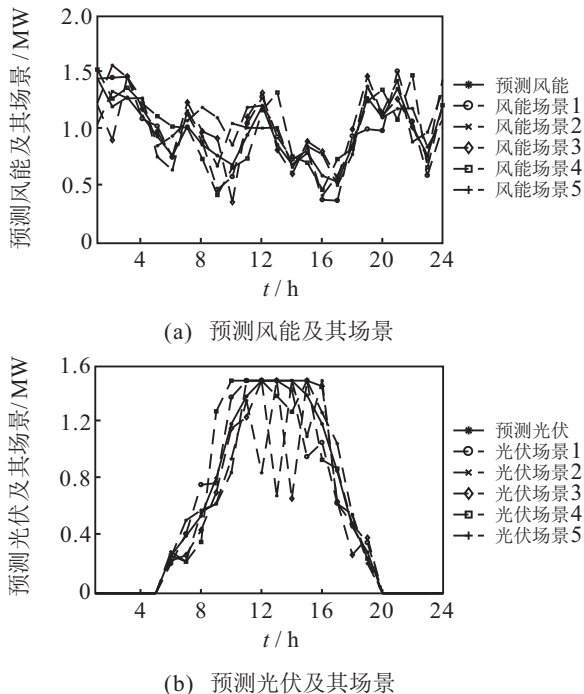


图 7 预测风能与光伏及其场景

利用所生成的场景集模拟风能和光伏产能的不确定性, 对本文的微网最优产能调度问题进行求解, 以验证本文所提出模型的优势. 求解所得的微网产能利润对比如表 2 所示. 由表 2 可知, 基于场景法求解的微网优化调度模型收敛时获得的算法迭代次数与

本文所使用的模型相近, 但最优产能利润明显少于本文模型, 表明针对本文所提出的问题, 基于 CM-ABC 算法且进行预测误差处理所获得的优化调度效果更好.

表 2 两种优化调度模型的结果对比

优化模型	收敛迭代次数	最优产能利润/RMB
基于预测误差处理的优化调度模型(本文提出)	4 560	36 644.4
基于场景法的优化调度模型	4 385	3 5360.1

总结上述结果可知, 本文所提出的 CM-ABC 算法能够利用市场电价的激励作用对 MG 中的 BESS 和 DR 响应进行最优调度, 有效地降低了可再生能源产能不确定性对 MG 优化运营的影响, 在充分消纳可再生能源出力的前提下, 提高 MG 所获得的最大产能利润.

### 4 结论

本文在大规模可再生能源接入 MG 运营的趋势下, 对由可再生能源的随机性和波动性导致的 MG 优化调度问题进行研究, 以 MG 的产能利润最大化为目标, 建立了 MG 日前产能规划的优化模型. 在考虑电池储能单元的投资成本和运维费用的基础上, 对 MG 中参与需求响应的负荷以及电池储能单元进行优化调度. 此外, 针对可再生能源产能预测过程中存在的预测误差进行误差处理, 进一步降低了可再生能源不确定性的影响. 为了求解所建立的优化模型, 提出了一种基于交叉和变异的人工蜂群 (CM-ABC) 算法, 通过所获得的最大产能利润和最优日前产能规划可知, MG 运营过程中, 在最大化消纳可再生能源的前提下, 算法提升了所获得的产能利润, 表明了本文所采用的优化模型的合理性和有效性. 同时, 选用其他 4 种启发式算法与 CM-ABC 算法进行对比, 仿真结果表明 CM-ABC 算法求解性能明显优于传统 ABC 算法、交叉 ABC 算法、变异 ABC 算法、PSO 算法和 BA 算法, 验证了本文所提出的 CM-ABC 算法的可行性及优越性.

### 参考文献(References)

[1] 陈科彬, 邱晓燕, 史光耀, 等. 含可再生能源的微电网分时间尺度储能方案[J]. 电测与仪表, 2018, 55(6): 30-34.  
(Chen K B, Qiu X Y, Shi G Y, et al. Time-scale decomposition of energy storage in micro-grid with renewable energy[J]. Electrical Measurement & Instrumentation, 2018, 55(6): 30-34.)

[2] Lasseter R H, Paigi P. Microgrid: A conceptual

- solution[C]. Power Electronics Specialists Conference. Aachen: IEEE, 2004, 6: 4285-4290.
- [3] González F, Marquez A, Leon J I. Modelling of a microgrid for high integration of renewable sources[C]. 2018 International Young Engineers Forum (YEF-ECE). Costa da Caparica: IEEE, 2018: 73-78.
- [4] 王鲁浩, 李歧强, 王桂荣, 等. 多可再生能源冷热电联供微网系统环境经济优化调度[J]. 控制与决策, 2016, 31(5): 913-918.  
(Wang L H, Li Q Q, Wang G R, et al. Optimal environmental economic scheduling of combined cooling heating and power microgrid system with multi-renewable energy[J]. Control and Decision, 2016, 31(5): 913-918.)
- [5] Rey J M, Martí P, Velasco M, et al. Secondary switched control with no communications for islanded microgrids[J]. IEEE Transactions on Industrial Electronics, 2017, 64(11): 8534-8545.
- [6] 杨文荣, 马晓燕, 边鑫磊. 分时电价机制下采用改进鸟群算法的微电网运行优化[J]. 可再生能源, 2018, 36(7): 1046-1054.  
(Yang W R, Ma X Y, Bian X L. Optimization of micro-grid operation using improved bird swarm algorithm under time-of-use price mechanism[J]. Renewable Energy Resources, 2018, 36(7): 1046-1054.)
- [7] Li Y, Yang Z, Li G, et al. Optimal scheduling of an isolated microgrid with battery storage considering load and renewable generation uncertainties[J]. IEEE Transactions on Industrial Electronics, 2018, 66(2): 1565-1575.
- [8] Zhao T, Ding Z. Cooperative optimal control of battery energy storage system under wind uncertainties in a microgrid[J]. IEEE Transactions on Power Systems, 2018, 33(2): 2292-2300.
- [9] 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 Y X, Guo L, Wang C S. Economic dispatch of microgrid based on two stage robust optimization[J]. Proceedings of CSEE, 2018, 38(14): 4013-4022.)
- [10] 杨健, 唐飞, 廖清芬, 等. 考虑可再生能源随机性的微电网经济性与稳定性协调优化策略[J]. 电力自动化设备, 2017, 37(8): 179-184.  
(Yang J, Tang F, Liao Q F, et al. Microgrid economy and stability coordinated optimization considering randomness of renewable energy resource[J]. Electric Power Automation Equipment, 2017, 37(8): 179-184.)
- [11] Dell R M, Rand D A J. Energy storage—A key technology for global energy sustainability[J]. Journal of Power Sources, 2001, 100(1/2): 2-17.
- [12] 门向阳, 曹军, 王泽森, 等. 能源互联微网型多能互补系统的构建与储能模式分析[J]. 中国电机工程学报, 2018, 38(19): 5727-5737.  
(Men X Y, Cao J, Wang Z S, et al. The constructing of multi-energy complementary system of energy internet microgrid and energy storage model analysis[J]. Proceedings of the CSEE, 2018, 38(19): 5727-5737.)
- [13] Lee S J, Kim J H, Kim C H, et al. Coordinated control algorithm for distributed battery energy storage systems for mitigating voltage and frequency deviations[J]. IEEE Transactions Smart Grid, 2016, 7(3): 1713-1722.
- [14] Zhao F, Yuan J, Wang N. Dynamic economic dispatch model of microgrid containing energy storage components based on a variant of NSGA-II algorithm[J]. Energies, 2019, 12(5): 871-885.
- [15] 李保恩, 李献伟, 毋炳鑫. 基于储能SOC状态的微电网能量优化调度策略研究[J]. 电力系统保护与控制, 2017, 45(11): 108-114.  
(Li B E, Li X W, Wu B X. Research on energy optimal dispatching strategy for microgrid based on battery SOC[J]. Power System Protection and Control, 2017, 45(11): 108-114.)
- [16] 赵波, 汪湘晋, 张雪松, 等. 考虑需求侧响应及不确定性的微电网双层优化配置方法[J]. 电工技术学报, 2018, 33(14): 3284-3295.  
(Zhao B, Wang X J, Zhang X S, et al. Two-layer method of microgrid optimal sizing considering demand-side response and uncertainties[J]. Transactions of China Electrotechnical Society, 2018, 33(14): 3284-3295.)
- [17] Balasubramaniam K, Saraf P, Hadidi R, et al. Energy management system for enhanced resiliency of microgrids during islanded operation[J]. Electric Power Systems Research, 2016, 137: 133-141.
- [18] Ghasemi A, Enayatzare M. Optimal energy management of a renewable-based isolated microgrid with pumped-storage unit and demand response[J]. Renewable Energy, 2018, 28(10): 460-474.
- [19] 米阳, 李战强, 吴彦伟, 等. 基于两级需求响应的并网微电网双层优化调度[J]. 电网技术, 2018, 42(6): 1899-1906.  
(Mi Y, Li Z Q, Wu Y W, et al. Bi-layer optimal dispatch of grid-connected microgrid based on two-stage demand response[J]. Power System Technology, 2018, 42(6): 1899-1906.)
- [20] Ghasemi A, Mortazavi S S, Mashhour E. Hourly demand response and battery energy storage for imbalance reduction of smart distribution company embedded with electric vehicles and wind farms[J]. Renewable Energy, 2016, 26(1): 124-136.
- [21] 肖安南, 张蔚翔, 张超, 等. 需求侧响应下的微电网-网-荷互动优化运行[J]. 电工电能新技术, 2017, 36(9): 71-79.  
(Xiao A N, Zhang W X, Zhang C, et al. Optimal interactive operation of microgrid under demand response[J]. Advanced Technology of Electrical Engineering and Energy, 2017, 36(9): 71-79.)
- [22] 王海燕, 同向前, 路峤, 等. 基于需求侧响应和储能电量预估的微网运行调度策略[J]. 电力系统保护与控制, 2017, 45(19): 86-93.  
(Wang H Y, Tong X Q, Lu Q, et al. Dispatching strategy of microgrid based on demand side response and energy

- estimation of energy storages[J]. *Power System Protection and Control*, 2017, 45(19): 86-93.)
- [23] Marzband M, Sumper A, Domínguez-García J L, et al. Experimental validation of a real time energy management system for microgrids in islanded mode using a local day-ahead electricity market and MINLP[J]. *Energy Conversion & Management*, 2013, 76(30): 314-322.
- [24] 王吉权, 程志文, 张攀利, 等. 求解有约束优化问题的实数遗传算法改进研究[J]. *控制与决策*, 2019, 34(5): 937-946.  
(Wang J Q, Cheng Z W, Zhang P L, et al. Research on improvement of real-coded genetic algorithm for solving constrained optimization problems[J]. *Control and Decision*, 2019, 34(5): 937-946.)
- [25] Hong Y Y, Hsiao M C, Chang Y R, et al. Multiscenario underfrequency load shedding in a microgrid consisting of intermittent renewables[J]. *IEEE Transactions on Power Delivery*, 2013, 28(3): 1610-1617.
- [26] Najy W K A, Zeineldin H H, Wei L W. Optimal protection coordination for microgrids with grid-connected and islanded capability[J]. *IEEE Transactions on Industrial Electronics*, 2013, 60(4): 1668-1677.
- [27] Cao Z A, Han Y H, Wang J K, et al. Two-stage energy generation schedule market rolling optimisation of highly wind power penetrated microgrids[J]. *International Journal of Electrical Power & Energy Systems*, 2019, 41(9): 12-27.
- [28] 崔秋丽. 基于人工蜂群算法的微网并网优化运行[J]. *系统仿真学报*, 2018, 30(4): 1551-1559.  
(Cui Q L. Optimal operation of grid-connected microgrid based on ABC algorithm[J]. *Journal of System Simulation*, 2018, 30(4): 1551-1559.)
- [29] 王志刚, 尚旭东, 夏慧明, 等. 多搜索策略协同进化的人工蜂群算法[J]. *控制与决策*, 2018, 33(2): 235-241.  
(Wang Z G, Shang X D, Xia H M, et al. Artificial bee colony algorithm with multi-search strategy cooperative evolutionary[J]. *Control and Decision*, 2018, 33(2): 235-241.)
- [30] Marzband M, Ghazimirsaeid S S, Uppal H, et al. A real-time evaluation of energy management systems for smart hybrid home Microgrids[J]. *Electric Power Systems Research*, 2017, 41(2): 624-633.
- [31] 刘佳, 王书伟. 一种混合人工蜂群算法求解顺序相依拆卸线平衡问题[J]. *控制与决策*, 2018, 33(4): 698-704.  
(Liu J, Wang S W. A hybrid artificial bee colony algorithm for solving sequence-dependent disassembly line balancing problem[J]. *Control and Decision*, 2018, 33(4): 698-704.)
- [32] Marzband M, Azarnejadian F, Savaghebi M, et al. An optimal energy management system for islanded microgrids based on multiperiod artificial bee colony combined with Markov chain[J]. *IEEE Systems Journal*, 2015, 11(3): 1712-1722.
- [33] Sideratos G, Hatziaargyriou N D. An advanced statistical method for wind power forecasting[J]. *IEEE Transactions on Power Systems*, 2007, 22(1): 258-265.
- [34] Lange M. On the uncertainty of wind power predictions — Analysis of the forecast accuracy and statistical distribution of errors[J]. *Journal of Solar Energy Engineering*, 2005, 127(2): 177-184.
- [35] Chen S X, Gooi H B, Wang M Q. Sizing of energy storage for microgrids[J]. *IEEE Transactions on Smart Grid*, 2012, 3(1): 142-151.
- [36] Zhang C, Xu Y, Li Z, et al. Robustly coordinated operation of a multi-energy microgrid with flexible electric and thermal loads[J]. *IEEE Transactions on Smart Grid*, 2018, 10(3): 2765-2775.
- [37] Huang C M, Chen S J, Yang S P, et al. One-day-ahead hourly forecasting for photovoltaic power generation using an intelligent method with weather-based forecasting models[J]. *IET Generation Transmission & Distribution*, 2015, 9(14): 1874-1882.
- [38] Karaboga D. An idea based on honey bee swarm for numerical optimization[R]. Technical report-tr06, Erciyes University, Engineering Faculty, Computer Engineering Department, 2005, 200: 1-10.
- [39] 滕飞, 薛磊, 李修和. 基于KLD的蝙蝠算法优化自适应粒子滤波[J]. *控制与决策*, 2019, 34(3): 561-566.  
(Teng F, Xue L, Li X H. Adaptive particle filter with bat optimization based on KLD sampling[J]. *Control and Decision*, 2019, 34(3): 561-566.)
- [40] 崔志华, 张春妹, 时振涛, 等. 基于蝙蝠算法的观测矩阵优化算法[J]. *控制与决策*, 2018, 33(7): 1341-1344.  
(Cui Z H, Zhang C M, Shi Z T, et al. Measurement matrix optimization algorithm with bat algorithm[J]. *Control and Decision*, 2018, 33(7): 1341-1344.)
- [41] 王坚浩, 张亮, 史超, 等. 基于入侵杂草蝙蝠双子群优化的装备保障编组协同任务规划[J]. *控制与决策*, 2019, 34(7): 1375-1384.  
(Wang J H, Zhang L, Shi C, et al. Cooperative task scheduling for equipment support groups using invasive weed bat dual-subpopulation optimization algorithm[J]. *Control and Decision*, 2019, 34(7): 1375-1384.)

### 作者简介

曹知奥(1991—), 男, 博士生, 从事智能微电网及可再生能源的研究, E-mail: 1510384@stu.neu.edu.cn;

汪晋宽(1957—), 男, 教授, 博士生导师, 从事智能电网、自适应信号处理、无线传感器网络、认知雷达等研究, E-mail: wjk@neuq.edu.cn;

韩英华(1979—), 女, 教授, 博士, 从事能源互联网优化控制的研究, E-mail: yhhan723@126.com;

赵强(1981—), 男, 讲师, 博士, 从事能源互联网优化调度等研究, E-mail: learner\_2003@163.com.

(责任编辑: 郑晓蕾)