

# 基于改进人工蜂鸟算法的微电网优化调度

闫丽梅, 赵奕岚, 赵书琪

(东北石油大学 电气信息工程学院, 黑龙江 大庆 163318)

**摘要:** 微电网作为一种高效灵活的能源分配系统, 能够集成可再生能源与传统发电资源, 优化能源调度, 提高系统的运行效率; 针对微电网调度中的复杂性与动态性问题进行了研究, 对微电网的结构进行了分析, 建立了包括光伏电池、风力发电机、燃气轮机、柴油发电机及蓄电池等多种能源单元的微电网系统模型, 通过改进人工蜂鸟算法进行优化调度, 并结合目标函数(包括运行成本与环境治理成本)进行多目标优化, 确保在满足负荷需求的同时, 最小化运行成本与碳排放; 算法方面采用了混合技术策略对基础人工蜂鸟算法进行了改进: 引入拉丁超立方体采样(LHS)提升初始种群的多样性, 有助于扩大搜索空间并提高全局搜索能力, 引入模拟退火(SA)机制则增强了算法跳出局部最优的能力, 从而提高了整体收敛性能; 实验通过对不同调度策略的比较, 结果表明改进人工蜂鸟算法在迭代初期表现出较快的收敛速度和较高的求解精度, 显著优于传统的人工蜂鸟算法及粒子群算法; 经微电网实际应用, 基于改进人工蜂鸟算法的微电网优化调度实现了能源使用效率的提高、减少了弃风弃光现象, 同时通过合理的分时电价策略降低了电力成本, 优化了电力采购与销售过程, 在应用于较为复杂的微电网环境中也具有较好的表现, 具有较好的工程应用前景。

**关键词:** 微电网; 优化调度; 人工蜂鸟算法; 分时电价; 拉丁超立方体采样; 模拟退火

## Microgrid Optimization Scheduling Based on Improved AHA

YAN Limei, ZHAO Yilan, ZHAO Shuqi

(College of Electrical and Information Engineering, Northeast Petroleum University, Daqing 163318, China)

**Abstract:** As an efficient and flexible energy distribution system, a microgrid can integrate renewable energy and traditional power generation resources, optimize energy scheduling and improve the operation efficiency of the system. This paper makes a study on the complexity and dynamic problems in microgrid scheduling, analyzes the structure of the microgrid, presents a microgrid system model including photovoltaic cells, wind turbines, gas turbines, diesel generators and batteries, optimizes the scheduling by improving the artificial hummingbird algorithm (AHA), and performs multi-objective optimization in combination with the objective function (including operating cost and environmental governance cost), which minimizes the operating cost and carbon emissions while meeting the load demand. This algorithm adopts a hybrid technical strategy to improve the basic artificial hummingbird algorithm. The Latin hypercube sampling (LHS) is introduced to improve the diversity of initial population, which expands the search space and improves the global search ability. The simulated annealing (SA) mechanism is introduced to enhance the ability of the algorithm to jump out of local optimum, thereby improving the overall convergence performance. Through the comparison of different scheduling strategies, experimental results show that the improved artificial hummingbird algorithm has faster convergence speed and higher solution accuracy in the early stage of iteration, which is significantly better than the traditional artificial hummingbird algorithm and particle swarm algorithm. Through microgrid practical application, the microgrid optimized scheduling based on the improved artificial hummingbird algorithm improves energy utilization efficiency and reduces the phenomena of wind and solar power abandonment, while it has reduced electricity costs through reasonable time-of-use electricity price strategies, which optimizes the electricity procurement and sales process. It also has good performance in more complex microgrid environments and good engineering application prospects.

**Keywords:** microgrid; optimization scheduling; AHA; time-of-use pricing; LHS; simulated annealing

收稿日期:2025-03-14; 修回日期:2025-05-13。

基金项目:国家自然科学基金项目(51774088)。

作者简介:闫丽梅(1971-),女,博士,教授。

引用格式:闫丽梅,赵奕岚,赵书琪.基于改进人工蜂鸟算法的微电网优化调度[J].计算机测量与控制,2026,34(3):177-185.

## 0 引言

随着全球能源结构的转型和可持续发展目标的推进,微电网作为一种灵活且高效的能源分配系统,逐渐成为电力领域的研究热点。微电网能够有效地整合可再生能源(如光伏、风力)与传统发电资源(如燃气轮机、柴油发电机)以及储能装置,提升系统的能源利用效率和运行可靠性<sup>[1]</sup>。然而,由于能源来源的不确定性和波动性,如何在满足负荷需求的同时,优化资源的调度与配置,成为微电网运行中的关键问题。优化调度问题不仅涉及各类发电单元的协调,还需要考虑经济性、环境影响以及系统稳定性等多个目标和约束条件。因此,微电网的优化调度不仅是提升电网运行效率的有效途径,也是实现智能电网和绿色低碳目标的重要组成部分。

微电网优化调度的算法研究已经成为近年来的热点问题,尤其是随着智能电网和可再生能源比例的提升,调度问题变得愈加复杂和动态。为了应对这一挑战,学者们提出了多种优化算法,包括经典的启发式算法和现代智能算法。传统方法如线性规划(LP, linear programming)和动态规划(DP, dynamic programming)已广泛应用于微电网的调度问题,但随着问题规模和复杂性的增加,许多研究开始探索更高效且能应对大规模、非线性问题的优化算法。遗传算法(GA, genetic algorithm)和粒子群优化(PSO, particle swarm optimization)作为经典的启发式优化方法,在微电网调度中得到了广泛应用。遗传算法通过模拟生物进化过程,能够有效处理多个优化目标和约束条件,且具有较强的全局搜索能力。文献[2]采用遗传算法优化了微电网中多种发电单元的调度,取得了较好的调度结果。PSO则通过模拟鸟群觅食行为来进行全局优化,其高效性和易于实现的特点使其成为调度问题中的常用算法。文献[3]将PSO与其他优化方法相结合,提出了一种改进的混合算法,提升了微电网调度系统的求解精度和效率。近年来,深度强化学习(DRL, reinforcement learning)逐渐成为解决微电网调度问题的新兴方法。DRL通过与环境的交互学习最优策略,能够在复杂的、动态变化的环境中实现实时调度。文献[4]将DRL应用于微电网的优化调度,提出了一种基于深度Q网络(DQN, deep Q-Network)的调度策略,显著提高了系统的灵活性与自适应能力。这些研究表明,智能优化算法,特别是结合传统与现代方法的混合算法,具有较强的潜力,为微电网的调度提供了新的解决方案。

人工蜂鸟算法(AHA, artificial hummingbird algorithm)相比于其他智能优化算法具有较强的全局搜索能力、更高的搜索灵活性以及更强的跳出局部最优的能

力,能够在复杂、多峰、高维的问题中保持较好的搜索平衡性与适应性;以灰狼算法(GWO, grey wolf optimization)为例,蜂鸟算法通过模拟多蜂鸟协同觅食行为,避免了灰狼算法中因“领头狼”引导机制可能导致的早熟收敛问题<sup>[5]</sup>;再以蚁群算法(ACO, ant colony optimization)为例,蜂鸟算法无需依赖信息素的积累与更新,从而减少了陷入局部最优的风险,且其更强的随机性和并行性使其在动态环境下表现更加稳定高效<sup>[6]</sup>。但人工蜂鸟算法在初始化阶段可能存在分布不均、搜索过程中出现收敛不稳定的情况,当引入拉丁超立方体采样(LHS, latin hypercube sampling)等初始化方法用于初始化种群时,可显著提升解空间的均匀覆盖性,从而增强算法早期探索能力;结合其他方法例如模拟退火机制(SA, simulated annealing)则进一步优化了搜索过程中的收敛稳定性,使得改进后的人工蜂鸟算法在解决高维复杂优化问题时展现出更优的收敛速度与精度;

## 1 微电网系统模型

微电网的模型主要包括光伏电池(PV, photovoltaic)、风力发电机(WT, wind turbine)、微型燃气轮机(MT, micro gas turbine)、柴油发电机(DG, diesel generator)和蓄电池(ES, energy storage)等关键组件。光伏电池利用太阳能转化为电能,其输出功率受光照强度和温度等因素的影响,通常在白天或阳光充足时提供较为稳定的电力。风力发电机则利用风能转化为电能,其功率输出受风速和风机效率等因素的影响,具有较强的波动性和不确定性。微型燃气轮机作为传统发电设备,具有较高的能效和稳定性,通常用于提供基荷电力或在可再生能源不足时补充电力。柴油发电机则作为应急备用电源,能在电力需求高峰或其他发电单元故障时提供稳定的电力供应。蓄电池系统用于存储多余电力,并在需要时提供电力支持,尤其是在光伏和风力发电不足的时段,或者电网电价较高时,从电池中放电以满足需求。微电网的这些组成部分通过智能调度与优化协作,实现能源的高效利用,确保系统在稳定性、经济性和环境效益等方面的平衡。本文研究的微电网系统由以下单元构成:光伏电池、风力发电机、微型燃气轮机、柴油发电机及蓄电池。各单元模型如下:

### 1.1 光伏电池

光伏电池的输出功率通常受光照强度、温度等因素影响,可以使用如下的数字模型<sup>[7]</sup>:

$$P_{PV}(t) = \eta_{PV} \cdot G(t) \cdot A_{PV} \cdot \frac{V_{oc}(t) \cdot I_{sc}(t)}{V_{mp}(t) \cdot I_{mp}(t)} \quad (1)$$

式中,  $\eta_{PV}$  为光伏电池效率;  $G(t)$  为光照强度;  $A_{PV}$  为光伏阵列的有效面积;  $V_{oc}(t)$  为开路电压;  $I_{sc}(t)$  为短路电流;  $V_{mp}(t)$ ,  $I_{mp}(t)$  为最大功率点电压和电流。

## 1.2 风力发电机

$$P_{WTG}(t) = \frac{1}{2} \cdot \rho \cdot A_{WTG} \cdot C_p(v(t)) \cdot v^3(t) \quad (2)$$

式中,  $\rho$  为空气密度 (约  $1.225 \text{ kg/m}^3$ );  $A_{WTG}$  为风力机的有效捕风面积;  $C_p(v(t))$  为风力机功率系数, 是风速  $v(t)$  的函数, 通常可以用 S 叶片的功率曲线近似;  $v(t)$  为时间  $t$  的风速<sup>[8]</sup>。

## 1.3 微型燃气轮机

微型燃气轮机的输出功率可表示为<sup>[9]</sup>:

$$P_{GT}(t) = \eta_{GT} \cdot P_{GT,max} \cdot f(t) \quad (3)$$

式中,  $\eta_{GT}$  为燃气轮机的效率;  $P_{GT,max}$  为燃气轮机最大输出功率;  $f(t)$  为燃气轮机的负载因子, 通常受燃气供应、运行条件等影响, 且在 0 到 1 之间变化。

## 1.4 柴油发电机

柴油发电机的功率输出通常受油料供应、负载情况及效率影响。可以用下列模型表示<sup>[10]</sup>:

$$P_{DG}(t) = P_{DG,max} \cdot \gamma(t) \cdot \eta_{DG} \quad (4)$$

式中,  $P_{DG,max}$  为柴油发电机的最大功率;  $\gamma(t)$  为柴油发电机的负载因子, 通常由调度策略确定, 且在 0 到 1 之间变化;  $\eta_{DG}$  为柴油发电机的效率, 可能随负载变化而变化。

## 1.5 蓄电池

蓄电池的电池储能与充放电效率、深度放电限制等因素有关。蓄电池的储能和功率输出通常)以下模型来描述<sup>[11]</sup>:

蓄电池充电功率:

$$P_{charge}(t) = \eta_{charge} \cdot P_{charge,max}(t) \quad (5)$$

蓄电池放电功率:

$$P_{discharge}(t) = \eta_{discharge} \cdot P_{discharge,max}(t) \quad (6)$$

蓄电池电量:

$$E_{ES}(t) = E_{ES}(t-1) + (P_{charge}(t) - P_{discharge}(t)) \cdot \Delta t \quad (7)$$

式中,  $E_{ES}(t)$  为当前时刻电池的剩余电量;  $\eta_{charge}$ ,  $\eta_{discharge}$  为电池充电和放电效率;  $P_{charge,max}(t)$ ,  $P_{discharge,max}(t)$  为电池的充电和放电功率上限;  $\Delta t$  为时间步长。

# 2 微电网优化运行模型

## 2.1 目标函数

### 2.1.1 微电网运行成本

系统运行成本主要包括传统发电单元 (如柴油发电机和微型燃气轮机) 的燃料成本, 储能设备的充放电成本等<sup>[12]</sup>。假设系统运行总成本  $C_{total}$  包括发电单元和储能单元的运行成本:

$$C_{total} = \sum_{t=1}^T [C_{DG}(t) + C_{MT}(t) - C_{PV}(t) - C_{WT}(t) + C_{ES}(t)] \quad (8)$$

式中,  $C_{DG}(t) = P_{DG}(t) \cdot C_{fuel}$  为柴油发电机的燃料成本,  $C_{fuel}$  是单位功率的燃料成本;  $C_{MT}(t) = P_{MT}(t) \cdot C_{fuel}$  为微型燃气轮机的燃料成本;  $C_{PV}(t)$  和  $C_{WT}(t)$  为光伏和风力发电的成本, 通常为负值, 因为这类能源一般不消耗燃料;  $C_{ES}(t)$  为储能设备的充放电成本, 分别考虑充电和放电过程中的单位成本。

### 2.1.2 环境治理成本

环境治理成本主要与系统排放的  $\text{CO}_2$ 、 $\text{SO}_2$ 、 $\text{NO}_x$  有关, 图 1 为主要排放物与健康影响趋势。化石能源发电单元的燃料消耗率通常与输出功率呈近似线性或分段线性关系, 所以假设每种发电单元都有一个与其输出功率相关的排放因子, 具体计算方式为<sup>[13]</sup>:

$$C_{env} = \sum_{t=1}^T [\lambda_{DG} \cdot P_{DG}(t) + \lambda_{GT} \cdot P_{MT}(t)] \quad (9)$$

式中,  $\lambda_{DG}$  和  $\lambda_{MT}$  分别为柴油发电机和燃气轮机的污染物排放系数 (单位:  $\text{kg/kWh}$ );  $P_{DG}(t)$  和  $P_{MT}(t)$  分别是柴油发电机和燃气轮机在时间  $t$  的输出功率。

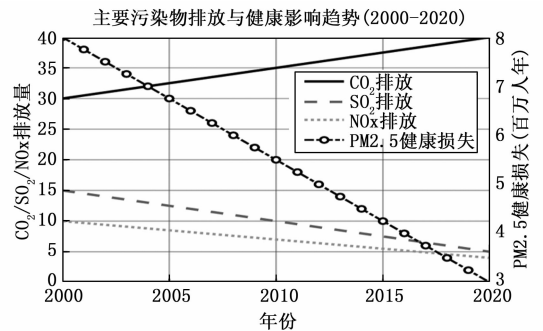


图1 主要排放物与健康影响趋势

### 2.1.3 总目标函数

最终的目标函数可以合并运行成本和环境治理成本, 形成如下的多目标优化模型:

$$\min C_{total} + \alpha \cdot C_{env} \quad (10)$$

式中,  $\alpha$  是环境治理成本的权重系数, 用于平衡经济性和环保目标。若  $\alpha$  较大, 则环境治理的影响较大; 反之, 运行成本的影响占主导。

## 2.2 约束条件

### 2.2.1 电力平衡约束

微电网的发电总功率必须等于负荷需求加上储能的充放电功率<sup>[14]</sup>:

$$\sum_{i \in (PV, WT, DG, MT)} P_i(t) + P_{ES, discharge}(t) = P_{load}(t) + P_{ES, charge}(t) \quad (11)$$

式中,  $P_{load}(t)$  是时间  $t$  的负荷需求。

### 2.2.2 发电设备容量约束

每个发电单元的输出功率不能超过其最大输出功率<sup>[15]</sup>:

$$\begin{cases} P_{PV}(t) \leq P_{PV,max} \\ P_{WT}(t) \leq P_{WT,max} \\ P_{DG}(t) \leq P_{DG,max} \\ P_{MT}(t) \leq P_{MT,max} \end{cases} \quad (12)$$

### 2.2.3 储能设备的充放电约束

储能设备的充放电功率应满足其最大功率限制，并且储能电池的电量应在其允许的范围<sup>[16]</sup>：

$$\begin{cases} P_{ES,charge}(t) \leq P_{ES,charge,max} \\ P_{ES,discharge}(t) \leq P_{ES,discharge,max} \end{cases} \quad (13)$$

$$E_{ES}(t) = E_{ES}(t-1) + (P_{ES,charge}(t) - P_{ES,discharge}(t)) \cdot \Delta t \quad (14)$$

式中， $E_{ES}(t)$  是时间  $t$  时刻电池的剩余电量，且  $E_{ES}(t)$  需要满足处于  $E_{ES}(t)$  的最大最小值区间内。

### 2.2.4 可再生能源的输出功率约束

由于可再生能源（如光伏和风力发电）的输出受天气、环境等因素的影响，具有较强的波动性和不确定性。因此，需要根据实际的气象数据来限制光伏和风力发电的输出功率。假设光伏和风力发电的输出功率分别由其辐照度  $G(t)$  和风速  $v(t)$  决定，约束条件可以表示为<sup>[17]</sup>：

$$\begin{cases} P_{PV}(t) \leq P_{PV,max} \cdot G(t) \\ P_{WT}(t) \leq P_{WT,max} \cdot v(t) \end{cases} \quad (15)$$

式中， $P_{PV}(t)$  和  $P_{WT}(t)$  分别是光伏和风力发电在时间  $t$  的输出功率； $G(t)$  是时间  $t$  的光照强度， $v(t)$  是风速； $P_{PV,max}$  和  $P_{WT,max}$  分别是光伏和风力发电单元的最大输出功率。

### 2.2.5 发电设备启停约束

对于某些发电单元（如柴油发电机和微型燃气轮机），其启停操作通常存在一定的时间延迟和限制。例如，启动或关闭发电机需要一定的时间，并且在一定时间内不能频繁启停。为此，可以引入启停约束，表示设备的启停状态及其约束。假设每个设备有一个启停状态变量  $u_{DG}(t)$  和  $u_{GT}(t)$ ，其中  $u_{DG}(t)$  和  $u_{MT}(t)$  为 0 或 1，表示设备是否运行<sup>[18]</sup>。

启停约束可以如下表示：

$$\begin{cases} P_{DG}(t) \leq u_{DG}(t) \cdot P_{DG,max} \\ P_{MT}(t) \leq u_{MT}(t) \cdot P_{MT,max} \end{cases} \quad (16)$$

同时，为了确保设备的启停不频繁，通常还会引入启停时间约束，要求设备的启停间隔大于一定的时间：

$$\begin{cases} u_{DG}(t) - u_{DG}(t-1) \leq \Delta u_{DG} \\ u_{MT}(t) - u_{MT}(t-1) \leq \Delta u_{MT} \end{cases} \quad (17)$$

式中， $\Delta u_{DG}$  和  $\Delta u_{MT}$  分别是柴油发电机和微型燃气轮机的最小启停间隔，表示设备在启停后需要等待的最小时间段。

## 3 人工蜂鸟算法

### 3.1 基础算法

人工蜂鸟算法（AHA, artificial hummingbird algorithm）模拟了蜂鸟的觅食行为，主要包括三种不同的觅食策略：领导觅食、迁徙觅食和领土觅食。这些策略通过不同的方式调整蜂鸟的位置，寻找全局最优解<sup>[19]</sup>。

#### 3.1.1 领导觅食

在领导觅食阶段，蜂鸟根据全局最优解的指导信息来调整自己的飞行路径。领导蜂鸟提供方向指引，其他蜂鸟根据这个指引更新自己的位置。

领导蜂鸟通过最优路径（即全局最优解）对其他蜂鸟的行为产生影响。每只蜂鸟根据当前最优解更新自己的位置，公式如下：

$$\mathbf{X}_i^{new} = \mathbf{X}_i + \beta \cdot (\mathbf{X}_{best} - \mathbf{X}_i) \quad (18)$$

式中， $\mathbf{X}_i^{new}$  是第  $i$  只蜂鸟的新位置； $\mathbf{X}_i$  是第  $i$  只蜂鸟当前的位置； $\mathbf{X}_{best}$  是当前全局最优解的位置； $\beta$  是一个控制步长的系数，调节蜂鸟在更新过程中的移动速度。

这一阶段通过领导觅食策略，蜂鸟能够快速接近全局最优解，但仍然保留一定的探索性。该策略利用全局信息来加速收敛。

#### 3.1.2 迁徙觅食

迁徙觅食模拟蜂鸟在寻找食物时根据环境变化调整飞行方向。在该阶段，蜂鸟在搜索空间内进行较大范围的迁徙，探索新的位置。

蜂鸟在迁徙觅食阶段执行较大步长的更新，公式如下：

$$\mathbf{X}_i^{new} = \mathbf{X}_i + \gamma \cdot (\mathbf{X}_{global}^{best} - \mathbf{X}_i) + \delta \cdot \epsilon(t) \quad (19)$$

式中， $\mathbf{X}_{global}^{best}$  是全局最优化解； $\gamma$  是控制迁徙方向的系数，调节蜂鸟在全局最优解方向上的迁移步长； $\delta$  是控制环境扰动强度的系数。

这一阶段有助于避免陷入局部最优，通过扰动引入多样性，探索更多潜在的解空间。这个策略确保了算法能在广泛的搜索空间内进行探索，增加全局搜索的概率。

#### 3.1.3 领土觅食

领土觅食模拟蜂鸟在其领土内寻找花蜜的行为。在这个阶段，蜂鸟会在局部区域内进行更加精细的搜索，根据本地信息来调整自己的位置。

在领土觅食阶段，蜂鸟在其当前邻域内进行局部搜索，根据当前最优解和历史最优解之间的距离来调整位置。更新公式如下：

$$\mathbf{X}_i^{new} = \mathbf{X}_i + \theta \cdot (\mathbf{X}_i^{best} - \mathbf{X}_i) \quad (20)$$

式中， $\mathbf{X}_i^{best}$  是第  $i$  只蜂鸟的历史最优位置； $\theta$  是控制步长的系数，调节蜂鸟局部搜索的精细程度。

领土觅食策略使蜂鸟专注于其局部环境的探索，通

过调整历史最优位置来细化搜索,避免过早收敛。这个策略是局部搜索的一部分,帮助算法跳出局部最优。

### 3.2 改进人工蜂鸟算法

针对人工蜂鸟算法中存在的寻找全局最优解能力不足,容易陷入局部最优的缺点,本文提出以下的改进措施。

#### 3.2.1 拉丁超立方体采样

LHS是一种常用于多维空间的随机采样方法,尤其在计算机模拟、优化和实验设计中应用广泛<sup>[20]</sup>。LHS通过确保样本点在每个维度上均匀分布,减少了采样点之间的相关性,从而提高了采样效率和结果的代表性。与传统的蒙特卡洛方法相比,LHS通常需要更少的样本点就能有效地覆盖整个输入空间,因此它在高维问题中表现得尤为出色。LHS的原理如下:设目标空间为 $D$ 维,每个维度被划分为 $N$ 个等距区间,形成一个 $N \times D$ 的网格。首先,在每一维上,从每个区间中随机抽取一个样本点,确保每个区间中仅有一个样本被选中;然后,在所有维度中将这 $N$ 个样本点按照随机排列的方式组合,使得最终形成 $N$ 个互不重复且在每一维上均匀分布的多维样本点,这个过程如图2所示。




图2 LHS工作图

假设我们在 $d$ 维空间中进行采样,采样点数为 $N$ ,每个维度的区间为 $[a_i, b_i]$ 。在每个维度 $i$ 中,从 $N$ 个等分区间内随机选择一个样本点 $x_{i,j}$ ,其计算公式为:

$$x_{i,j} = a_i + \left(j + \frac{\xi_{i,j}}{N}\right) \Delta x_i, \xi_{i,j} \in [0,1) \quad (21)$$

式中, $x_{i,j}$ 是第 $i$ 维度中第 $j$ 个采样点; $\xi_{i,j}$ 是第 $i$ 维度中第 $j$ 个采样点的随机扰动项,它是一个介于0到1之间的随机数,确保了采样的随机性; $\Delta x_i = \frac{b_i - a_i}{N}$ 是第 $i$ 维度的区间长度; $a_i$ 和 $b_i$ 是第 $i$ 维度的最小值和最大值; $N$ 是采样点的数量。

#### 3.2.2 模拟退火

SA是一种用于全局优化的随机搜索算法,其灵感来源于物理中的退火过程<sup>[21]</sup>。在金属材料的热处理过程中,材料首先被加热到高温,然后缓慢冷却,以便其内部结构达到最低能量状态(即稳定晶体结构)。模拟退火算法借鉴了这一过程,并将其应用于优化问题。SA通过在初始阶段允许接受较差解(即接受局部最优解之外的解),然后随着时间的推移逐渐减少这种接受

概率,使搜索过程从全局探索逐步收敛到局部优化。

#### 1) 适应度差:

首先,计算当前解和新解的适应度差:

$$\Delta C = C_{\text{new}} - C_{\text{current}} \quad (22)$$

式中, $C_{\text{new}}$ 是新解的适应度(成本); $C_{\text{current}}$ 是当前解的适应度(成本)。

#### 2) 接受新解的条件:

如果新解的适应度比当前解更好(即 $\Delta C < 0$ ),则直接接受新解:

$$\Delta C < 0 \Rightarrow \text{accept} \quad (23)$$

如果新解的适应度比当前解差(即 $\Delta C > 0$ ),则通过模拟退火的概率来决定是否接受较差的解,如果一个随机数 $r$ 比这个概率小则接受新解,否则保留当前解。这个概率 $P_{\text{accept}}$ 是根据适应度差来计算的,并且随着迭代次数 $It$ 的增加而逐渐减小,表示“温度”逐渐降低。接收较差解的概率计算为:

$$P_{\text{accept}} = \exp\left(-\frac{\Delta C}{1 + It}\right) \quad (24)$$

式中, $\Delta C = \Delta C_{\text{new}} - \Delta C_{\text{current}}$ 是新解和当前解之间的适应度差(当 $\Delta C > 0$ 时表示新解较差); $It$ 是当前的迭代次数,它影响接受概率的衰减; $1 + It$ 是一个递增的温度控制因子,使得随着迭代次数的增加,接受较差解的概率逐渐降低。

### 3.3 算法流程

#### 3.3.1 初始化

首先,采用拉丁超立方体采样初始化 $N$ 个 $D$ 维个体构成初始种群,并对每个个体进行适应度评估;随后,从种群中提取非支配解,构建初始归档以用于后续的多目标优化搜索。

#### 3.3.2 循环迭代

在每一代迭代中,首先对当前种群进行非支配排序,并将新获得的非支配解更新至归档中;随后,针对种群中每个个体,更新其方向向量,其中以概率 $p_1$ 执行对角飞行以更新部分维度,以概率 $p_2$ 执行全向飞行以更新所有维度,否则执行轴向飞行,仅更新一个随机维度;个体随后依据引导觅食或领地觅食策略进行位置更新,生成新位置 $X'_i$ ,计算其适应度,并根据其是否支配原位置或通过模拟退火概率判断是否接受该解;在个体更新之后,还将执行迁徙觅食操作,通过扰动部分个体增强种群多样性;最后,将新产生的非支配解加入归档,若归档数量超出设定容量,则依据拥挤距离进行精简,以维持解集的多样性与代表性。

#### 3.3.3 输出

最终输出包括当前归档中的非支配解集,以及从该归档中选取的最优解,作为多目标优化问题的解集和代表性最优解。

### 3.3.4 算法伪代码

改进后的人工蜂鸟算法伪代码如图 3 所示。

```

Algorithm 1: Multi-objective Optimization via Foraging-based Strategy
Input: Initial parameters: population size  $N$ , maximum generations  $MaxGen$ , archive size  $N_{archive}$ , etc.
Output: Final non-dominated solution set  $A$ , best solution's fitness and position
1 Special treatment: Initialize population;
2 Generate  $Pop(0)$  using Latin Hypercube Sampling;
3 Evaluate fitness  $f(x)$  for each individual in  $Pop(0)$ ;
4 Special treatment: Initialize archive;
5 Perform non-dominated sorting on  $Pop(0)$ ;
6 Initialize archive  $A$  with non-dominated solutions;
7 for  $t \leftarrow 1$  to  $MaxGen$  do
8   Perform non-dominated sorting on  $Pop(t)$ ;
9   Update archive  $A$  with new non-dominated solutions;
10  for each individual  $x_i \in Pop(t)$  do
11    Update direction vector and select flight strategy;
12    if  $rand() < 1/3$  then
13      | Diagonal Flight: update part of dimensions;
14    else if  $rand() > 2/3$  then
15      | Omidirectional Flight: update all dimensions;
16    else
17      | Axial Flight: update one random dimension;
18    Select foraging strategy;
19    if guided foraging then
20      | Select a guide solution from  $A$ ;
21      | Move  $x_i$  toward the guide solution;
22    else if territorial foraging then
23      | Move  $x_i$  based on the best solution in  $Pop(t)$  or  $A$ ;
24    Evaluate new fitness  $f'(x_i)$  and check dominance;
25    if  $f'_i$  dominates  $x_i$  then
26      | Replace  $x_i$  with  $x'_i$ ;
27    else
28      | Apply simulated annealing;
29      | if  $accept(x'_i, x_i, T)$  then
30      |   Replace with  $x'_i$ ;
31  Perform migration foraging to update part of individuals;
32  Update archive  $A$ ;
33  if  $|A| > N_{archive}$  then
34    | Apply dynamic elimination based on crowding distance;
35  return Archive  $A$ , best fitness value and corresponding position;
    
```

图 3 改进人工蜂鸟算法伪代码

### 3.4 算法时间复杂度和空间复杂度

为评估改进后人工蜂鸟算法的可扩展性，有必要对其时间复杂度与空间复杂度进行理论分析。设问题维度为  $D$ ，种群规模为  $N$ ，最大迭代次数为  $T$ ，原始人工蜂鸟算法在每次迭代中需对每个个体进行位置更新与目标函数评估，其时间复杂度为  $O(NDT)$ 。

在引入 LHS 后，种群初始化阶段需在每个维度上对  $N$  个区间进行采样并进行随机重组，时间复杂度为  $O(ND)$ ，该部分仅在初始阶段执行一次，对整体复杂度影响可忽略。引入 SA 后，为每个个体增加了基于温度更新和接受概率的局部搜索策略，假设每次迭代均执行该机制，则增加时间复杂度为  $O(NT)$ ，仍为线性增长，未改变主导复杂度阶数。因此，综合考虑后，改进算法的整体时间复杂度维持在  $O(NDT)$  级别，具备良好的时间可扩展性。

在空间复杂度方面，原算法需存储每个个体在  $D$  维空间中的位置和适应度信息，空间复杂度为  $O(ND)$ 。

LHS 所产生的样本点可复用为种群初始化，不引入额外空间；模拟退火机制仅需为每个个体额外维护温度参数及局部状态，额外空间复杂度为  $O(N)$ ，在高维优化问题中可视为常量开销。因而，改进后算法的总体空间复杂度仍为  $O(ND)$ ，维持与原始算法相同的空间增长特性。

综上所述，引入 LHS 与 SA 虽在初始化与搜索阶段增加了轻微的计算与存储负担，但不影响算法整体的复杂度级别，改进后的人工蜂鸟算法在面对高维、大规模优化问题时仍具备良好的计算效率与资源可控性。

## 4 实验结果与分析

为了验证本文所提出的微电网模型，设计一种含 PV、WT、MT、DE 及 ES 的微电网系统。

### 4.1 微电网参数

微电网结构如图 4 所示，微电网中各机组参数如表 1 所示<sup>[22]</sup>，温室气体排放成本如表 2 所示<sup>[23]</sup>，典型日风光、负荷如图 5 所示<sup>[24]</sup>，阶梯电价分布如图 6 所示<sup>[25]</sup>。

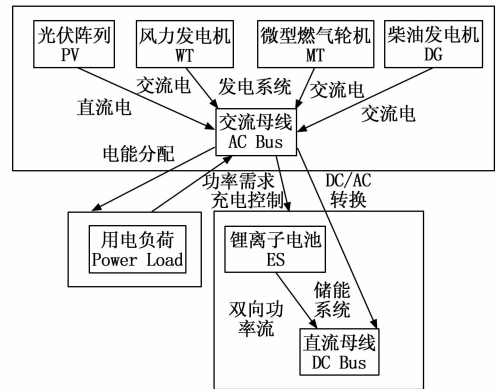


图 4 微电网结构图

表 1 各类型分布式能源参数

类型	出力范围/kW	管理费用/(元/kW·h)	爬坡约束/(kW/min)
光伏	0~75	0	0
风机	0~150	0	0
柴油发电机	9~45	0.192	2.25
燃气轮机	4.5~45	0.043 95	2.25
主网交互	-45~45	0	0

表 2 空气净化处理成本

类型	排放系数/(g·kW <sup>-1</sup> )				处理系数/(元/kg)
	MT	DE	PV	WT	
CO <sub>2</sub>	724	680	0	0	0.023
NO <sub>x</sub>	0.2	10.09	0	0	8
SO <sub>2</sub>	0.003 6	0.306	0	0	6

### 4.2 算例分析

#### 4.2.1 微电网算例分析

采用改进人工蜂鸟算法对微电网进行优化时，优化




图 5 负荷与风电预测值




图 9 风电利用率




图 6 分时电价示意图

运行的时间尺度设为 1 d, 选取典型日 24 h 负荷数据, 设置迭代次数 500 次, 种群大小为 100, 算法运行 50 次选取平均值进行分析, 如图 7~9 所示。




图 7 各分布式能源出力




图 8 光伏利用率

根据微电网优化调度结果图的分析, 可以得出以下结论: 在电力调度过程中, 微电网的各类发电源呈现出明显的时段性变化, 优化调度策略能够有效应对电力需求的峰谷波动。具体而言, 在白天, 光伏和风力发电的功率较为充足, 微电网的优化调度策略应优先利用这些

可再生能源, 以最大化减少电网购电需求, 从而降低电力成本。而在夜间低谷时段, 电网电价通常较低, 此时微电网可考虑从电网购电, 特别是在风力和光伏发电不足的情况下, 进一步优化成本。此外, 微电网还应灵活调整在电力需求高峰时段使用本地发电和购买电网电力的比例, 避免高峰时段的高电价, 同时在电价较高时段将多余电力卖回电网, 优化电力销售收入。通过合理的分时电价策略, 微电网不仅能够提高电力供应的可靠性, 实现了光伏和风力能源的高利用率, 减少了弃风弃光现象, 还能够在保持电力稳定供应的同时, 实现经济性和能源利用的双重优化。

#### 4.2.2 扩大微电网算例分析

为深入分析改进算法在不同规模问题下的适应性, 将原有典型日的风光资源数据替换为南方某城市的实际风光出力数据, 同时引入风光出力的不确定性建模与分析, 以构建更复杂的调度场景, 从而对微电网各类机组的优化调度能力提出更高要求。

风光原始数据分布如图 10、11 所示。




图 10 风电原始出力




图 11 光伏原始出力

采用拉丁超立方抽样与 K-means 聚类对数据进行

处理，得到削减后的风光出力场景，如图 12、13 所示。




图 12 风电削减场景




图 13 光伏削减场景

将风力和光伏不同场景数据交叉选出最具有代表性的一种组合，对应风电的场景 1 与光伏的场景 3。

采用改进人工蜂鸟算法对扩大规模后的微电网进行优化，优化运行的时间尺度设为 1 d，出了风光数据，其余数据设置保持不变，设置迭代次数 500 次，种群大小为 100，算法运行 50 次选取平均值进行分析，结果如图 14 所示。




图 14 分布式能源出力

在面对更高复杂度的微电网优化调度问题时，改进后的人工蜂鸟算法依然展现出良好的适应性，能够有效应对多源耦合和不确定性带来的挑战；在风光资源波动加剧的背景下，该算法通过增强的全局搜索能力与局部跳出机制，实现了对可再生能源出力的高效利用，提高了风光消纳率；同时，在各类机组的协调运行方面，算法能够在满足多重运行约束的前提下，合理分配调度任务，提升了系统整体的经济性与稳定性，充分体现了其在复杂环境下的调度鲁棒性与优化效率。

### 4.3 算法对比

将基于改进人工蜂鸟算法的模型与人工蜂鸟算法

和粒子群算法做对比，以验证人工蜂鸟算法在微电网优化问题上的适用性以及改进算法的有效性，如图 15 所示。




图 15 3 种算法迭代曲线

从图中可以看出，3 种算法在迭代过程中的表现差异。改进人工蜂鸟算法在初期迭代中表现出最快的下降速度，迅速收敛到一个较优解，优化效果最为明显。人工蜂鸟算法则在前期表现出较慢的下降速度，虽然最终也收敛，但其优化效率逊色于改进版。粒子群算法在初期下降较慢，迭代过程中逐渐趋于平稳，收敛速度与人工蜂鸟算法相似。总体而言，改进人工蜂鸟算法在三个算法中表现最佳，能够较快找到最优解，而人工蜂鸟算法和粒子群算法的收敛速度相对较慢。

### 5 结束语

本文基于改进人工蜂鸟算法对微电网优化调度进行了研究，提出了一种多目标优化模型，旨在优化微电网中光伏、风力发电、燃气轮机、柴油发电机和蓄电池等多种能源单元的调度。通过引入拉丁超立方体采样和模拟退火技术，改进了原有的人工蜂鸟算法，提高了全局搜索能力和收敛速度。实验结果表明，改进的人工蜂鸟算法在优化效率、解的精度及收敛速度上优于传统的人工蜂鸟算法和粒子群算法。然而，算法在处理大规模、复杂问题时仍有提升空间，尤其是在动态变化的负荷和可再生能源波动的情况下，如何进一步提高算法的适应性和实时性，以及如何在实际约束条件下进一步优化调度策略，仍是未来的技术挑战。微电网优化调度不仅能提高能源利用效率，还能实现电力系统的稳定性和经济性，随着可再生能源比例的增加，微电网在智能电网和绿色低碳发展中的应用前景广阔，未来结合更加精确的预测模型和高效的优化算法，将进一步提高系统运行效率，聚焦于动态负荷预测耦合改进蜂鸟算法、多微电网协同博弈优化、高比例可再生能源韧性调度及实时电价响应机制，以提升微电网在复杂环境下的自适应性及经济性，并为电力交易、需求响应和电网调度提供灵活、经济的解决方案。

### 参考文献：

[1] HOSSAIN E, KABALCI E, BAYINDIR R, et al. Mi-

- crogrid testbeds around the world: State of art [J]. *Energy Conversion & Management*, 2014, 86 (oct.): 132 - 153.
- [2] ZHAO L, et al. A mixed integer linear programming model for optimal scheduling of microgrids considering renewable energy uncertainties [J]. *Energy Reports*, 2020, 6: 345 - 356.
- [3] XU H, et al. A hybrid particle swarm optimization algorithm for microgrid energy management [J]. *Renewable Energy*, 2022, 180: 1264 - 1276.
- [4] CHEN Z, et al. Deep reinforcement learning-based microgrid optimal scheduling with uncertainty [J]. *IEEE Transactions on Smart Grid*, 2023, 14 (1): 123 - 134.
- [5] 冯麟皓, 方喜峰, 李俊. 基于灰狼算法的多目标车间调度优化 [J]. *组合机床与自动化加工技术*, 2023 (1): 168 - 172.
- [6] 朱敏, 胡若海, 卞京. 基于改进蚁群算法的移动机器人路径规划 [J]. *现代制造工程*, 2024 (3): 38 - 44.
- [7] 戴锦, 肖文波, 胡芳雨, 等. 光伏发电性能物理预测模型的研究 [J]. *电源技术*, 2018, 42 (2): 262 - 266.
- [8] 李东东, 陈陈. 风力发电机组动态模型研究 [J]. *中国电机工程学报*, 2005 (3): 117 - 121.
- [9] 刘君, 穆世霞, 李岩松, 等. 微电网中微型燃气轮机发电系统整体建模与仿真 [J]. *电力系统自动化*, 2010, 34 (7): 85 - 89.
- [10] 刘畅, 卓建坤, 赵东明, 等. 利用储能系统实现可再生能源微电网灵活安全运行的研究综述 [J]. *中国电机工程学报*, 2020, 40 (1): 1 - 18.
- [11] 张国驹, 唐西胜, 齐智平. 超级电容器与蓄电池混合储能系统在微网中的应用 [J]. *电力系统自动化*, 2010, 34 (12): 85 - 89.
- [12] 鲁宗相, 王彩霞, 闵勇, 等. 微电网研究综述 [J]. *电力系统自动化*, 2007 (19): 100 - 107.
- [13] 张基岳, 任洲洋, 姜云鹏, 等. 微电网定碳排运行域: 理论、构建与观测 [J]. *电工技术学报*, 2024, 39 (8): 2342 - 2359.
- [14] ZHOU Y, CHEN H. Power balance constraints in microgrid optimization [J]. *IEEE Access*, 2020, 8: 123456 - 123465.
- [15] 国家电网公司. 微电网运行技术规范 [S]. 北京: 中国电力出版社, 2018.
- [16] LI X, WANG Z. Energy storage constraints and management in microgrids [J]. *Journal of Energy Storage*, 2019, 25: 100842.
- [17] 孙启星, 张超, 李成仁, 等. “碳达峰、碳中和”目标下的电力系统成本及价格水平预测 [J]. *中国电力*, 2023, 56 (1): 9 - 16.
- [18] GUO F, ZHANG Y. Start-Stop constraints for diesel generators in microgrids [J]. *Energy Systems*, 2021, 12 (3): 567 - 582.
- [19] WANG M, ZHAO Y. Artificial hummingbird algorithm: a novel Bio-Inspired optimizer [J]. *Swarm and Evolutionary Computation*, 2022, 68: 101028.
- [20] 何星月, 张靖, 覃涛, 等. 基于拉丁超立方的改进白骨顶鸡算法 [J]. *计算机工程与设计*, 2024, 45 (4): 1069 - 1078.
- [21] KIRKPATRICK S, GELATT C D, VECCHI M P. Optimization by simulated annealing [J]. *Science*, 1983, 220 (4598): 671 - 680.
- [22] 国家能源局. 微电网设计与运行技术导则 [S]. 北京: 中国标准出版社, 2017.
- [23] 联合国气候变化框架公约 (UNFCCC). 碳排放成本核算手册 [R]. 波恩: UNFCCC, 2015.
- [24] EUROPEAN WIND ENERGY ASSOCIATION. Wind power forecasting in europe [Z]. Brussels: EWEA, 2018.
- [25] 国家发改委. 分时电价政策文件 [Z]. 北京: 国家发改委, 2020.
- [14] ULTRALYTICS. YOLOv8: Real-Time Object Detection [EB/OL]. (2023) [2025-12-28]. <https://github.com/ultralytics/ultralytics>.
- [15] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: optimal speed and accuracy of object detection [Z]. 2020.
- [16] STOLL A, MAIER A, KRAUSS P, et al. Coincidence detection and integration behavior in spiking neural networks [J]. *Cognitive Neurodynamics*, 2023, 18 (4): 1753 - 1765.
- [17] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks [C] // *Proceedings of the 25th International Conference on Neural Information Processing Systems (NIPS)*, Lake Tahoe, NV, 2012.
- [18] LIN T Y, MAIRE M, BELOWNGIE S, et al. Microsoft COCO: common objects in context [J]. Springer International Publishing, 2014.
- [19] GEIGER A, LENZ P, URTASUN R. Are we ready for autonomous driving? the KITTI vision benchmark suite [C] // *IEEE Conference on Computer Vision & Pattern Recognition*. IEEE, 2012.
- [20] LEAL-TAIXÉ L, ARBELÁEZ M, REID I, et al. MOTChallenge 2015: Towards a Benchmark for Multi-Target Tracking [EB/OL]. (2015-04-07) [2025-12-28]. <https://arxiv.org/abs/1504.01942>.

(上接第 176 页)