

基于多策略改进 MRFO 算法的家庭能源调度优化

邹雨蒙, 吴冬梅*

南京邮电大学自动化学院 江苏南京

【摘要】针对蝠鲼觅食优化 (Manta Ray Foraging Optimization, MRFO) 算法在求解高维复杂离散家庭能源调度问题时, 存在种群多样性缺失、易陷入局部最优及多目标优化不平衡等问题, 本研究提出一种离散长时记忆蝠鲼觅食优化 (Discrete Long-term Memory Manta Ray Foraging Optimization, DLMMRFO) 算法, 该算法在 MRFO 框架中系统融合了五种改进策略, 离散位置更新策略将连续搜索空间映射为可行调度方案, 解决原始算法在处理离散变量时的失配问题; 动态权重机制在迭代过程中自适应调整成本与峰均比 (Peak-to-Average Ratio, PAR) 的优化权重, 平衡多目标优化进程; 长时记忆机制通过保留历史优质解增强全局探索能力, 防止早熟收敛; 变异操作引入随机扰动以维持种群多样性; PAR 专项优化策略则在迭代后期针对性地降低负荷峰均比。仿真实验通过增加家电数量来增加复杂度, 设置简单与复杂两类场景, 结果表明, 相较于 MRFO 算法和未调度场景, DLMMRFO 算法在简单场景中使成本降低 7.89% 和 45.30%, PAR 降低 9.55% 和 33.91%; 在复杂场景中, 成本降幅达 5.89% 和 53.29%, PAR 降幅为 16.82% 和 43.67%。为家庭能源管理提供了有效解决方案, 有助于实现能源资源的高效配置与利用。

【关键词】家庭能源管理; 蝠鲼觅食优化; 需求响应; 离散优化; 峰值平均比

【收稿日期】2025 年 10 月 24 日 **【出刊日期】**2025 年 11 月 24 日 **【DOI】**10.12208/j.jeea.20250210

Home energy scheduling optimization based on a multi-strategy improved manta ray foraging optimization algorithm

Yumeng Zou, Dongmei Wu*

School of Automation, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu

【Abstract】 To address the issues of population diversity loss, susceptibility to local optima, and unbalanced multi-objective optimization when the Manta Ray Foraging Optimization (MRFO) algorithm is applied to high-dimensional complex discrete home energy scheduling problems, this study proposes a Discrete Long-term Memory Manta Ray Foraging Optimization (DLMMRFO) algorithm. The DLMMRFO systematically integrates five improvement strategies within the MRFO framework: a discrete position update strategy maps the continuous search space to feasible scheduling solutions, resolving the mismatch problem of the original algorithm in handling discrete variables; a dynamic weight mechanism adaptively adjusts the optimization weights of cost and PAR during iteration to balance the multi-objective optimization process; a long-term memory mechanism enhances global exploration capability by preserving high-quality historical solutions, thereby preventing premature convergence; mutation operations introduce random perturbations to maintain population diversity; and a dedicated PAR optimization strategy specifically targets the reduction of the Peak-to-Average Ratio in the later stages of iteration. Simulation experiments, designed with both simple and complex scenarios by increasing the number of household appliances, demonstrate that compared to the original MRFO algorithm and an unscheduled scenario, the DLMMRFO algorithm reduces the cost by 7.89% and 45.30%, and the PAR by 9.55% and 33.91%, respectively, in the simple scenario. In the complex scenario, it achieves cost reductions of 5.89% and 53.29%, and PAR reductions of 16.82% and 43.67%, respectively. The proposed algorithm provides an effective solution for home energy management, contributing to the efficient allocation and utilization of energy resources.

*通讯作者: 吴冬梅

【Keywords】Home energy management; Manta ray foraging optimization; Demand response; Discrete optimization; Peak-to-Average Ratio (PAR)

引言

随着全球人口增长、气候变化以及碳排放量的持续增加, 电力需求不断攀升, 电力系统的生产、分配及可靠性面临着严峻的挑战^[1]。在此背景下, 住宅能源消耗日益增长^[2]。为应对环境与能源危机带来的挑战, 智能电网通过集成先进的通信、传感与控制技术, 实现了电力流与信息流的双向互动, 为需求侧管理 (Demand Side Management, DSM) 提供了坚实的技术基础^[3]。特别是与居民生活息息相关的家庭能源管理系统 (Home Energy Management System, HEMS), 已成为平衡电网负荷、提升能源利用效率的关键环节。

通过调度各类家用电器的工作时间, HEMS 在保障用户舒适度的前提下, 降低用电成本 (Electricity Cost) 与峰均比 (Peak-to-Average Ratio, PAR), 从而帮助用户侧降低用电成本和减轻电网侧的压力^[4]。且随着屋顶光伏、小型风电等分布式可再生能源在居民区的普及, 用户不再是单纯的消费者, 而是转变为可生产、消费甚至出售电力的产消者^[5]。这使得家庭级的电力交易成为可能, 进一步增加了 HEMS 的复杂性与优化潜力。

目前, 国内外学者围绕 HEMS 的调度问题已开展了广泛的研究。诸多智能优化算法被应用于求解该类问题。例如, 文献[6]采用整数线性规划 (Integer Linear Programming, ILP) 来平衡住宅区的电力供需; 文献[7]利用混合整数线性规划 (Mixed-ILP) 来最小化总用电成本; 文献[8]则将实时电价 (Real-Time Pricing, RTP) 的定价模型与倾斜区块率 (Inclining Block Rate, IBR) 相结合, 在分时电价 (Time-of-Use, TOU) 等机制下运用了遗传算法 (Genetic Algorithm, GA) 来优化用电成本与 PAR, 成功降低了电费和提高了系统的稳定性。文献[9]使用粒子群算法 (Particle Swarm Optimization, PSO) 实现了具有中断载荷的家庭能源调度系统。

近年来, 一些新颖的元启发式算法凭借卓越的寻优能力引人注目, 如文献[10]提出了一种混合细菌觅食-遗传算法, 用来处理多重约束的问题, 显著提高了算法在问题中的搜索效率。文献[11]提出了蝠鲼觅食优化 (Manta Ray Foraging Optimization, MRFO) 算法, 它拥有全局探索能力强、收敛速度快等特点, 在诸多领域得到了成功应用。

但是在算法层面现有研究仍存在一些局限性。如

传统的元启发式算法更适用于连续优化问题, 在解决高维、多约束的离散调度问题时, 存在易陷入局部最优、种群多样性过早丧失等不足等缺陷^[12], 且难以在面对多目标优化的问题时平衡多个目标之间的优化程度。因此其难以满足家庭能源管理场景下的复杂优化需求。

针对上述问题, 本文在不考虑可再生能源 (Renewable Energy Sources, RES) 和储能设备 (Energy Storage System, ESS) 的家庭能源调度场景下, 以降低用户侧用电总成本和电网侧 PAR 为目标, 提出了 HEMS 模型, 该模型通过将电价高峰期时的负载在满足约束条件的情况下转移至电价低谷期, 来实现削峰填谷, 通过 DLMMRFO 获取其最优调度方案。以单户家庭的能源调度为例, 研究对比了在简单和复杂场景下的调度结果。

1 HEMS 建模

本文构建的 HEMS 包含用电设备、电网供电系统、以及能源管理控制器 (Energy Management Controller, EMC) 三个核心组成部分, 系统结构如图 1 所示^[13]。用电设备包括多种类型的家用电器, 所有设备均通过家庭内部网络与 EMC 连接。各类设备的运行状态由二进制变量表示:

$$\alpha_i(t) = \begin{cases} 1, & \text{设备 } i \text{ 在时刻 } t \text{ 处于运行状态} \\ 0, & \text{设备 } i \text{ 在时刻 } t \text{ 处于关闭状态} \end{cases} \quad (1)$$

电网供电系统采用 RTP 机制向家庭供电。RTP 信号为一天 24 小时中每个小时设定不同的电价, 旨在引导用户在电价高的峰值时段减少用电, 在电价低的谷值时段增加用电, 从而实现削峰填谷^[14]。其数学表达式如式 (2) 所示。

$$\rho(t) = RTP(t), \quad t = 1, 2, \dots, 24 \quad (2)$$

EMC 是系统的决策核心, 它接收电网发布的 RTP 信号, 通过优化算法来寻找最优调度方案, 最后将具体的启停指令传输给各类家用电器。本文用加权方式将多目标优化问题转化为单目标优化问题, 其优化目标函数如式 (3) 所示。

$$f = \omega_1 \cdot C^{total} + \omega_2 \cdot PAR \quad (3)$$

式中, ω_1 和 ω_2 为加权系数, C^{total} 表示总成本的大小, 而 PAR 表示峰均比的大小。

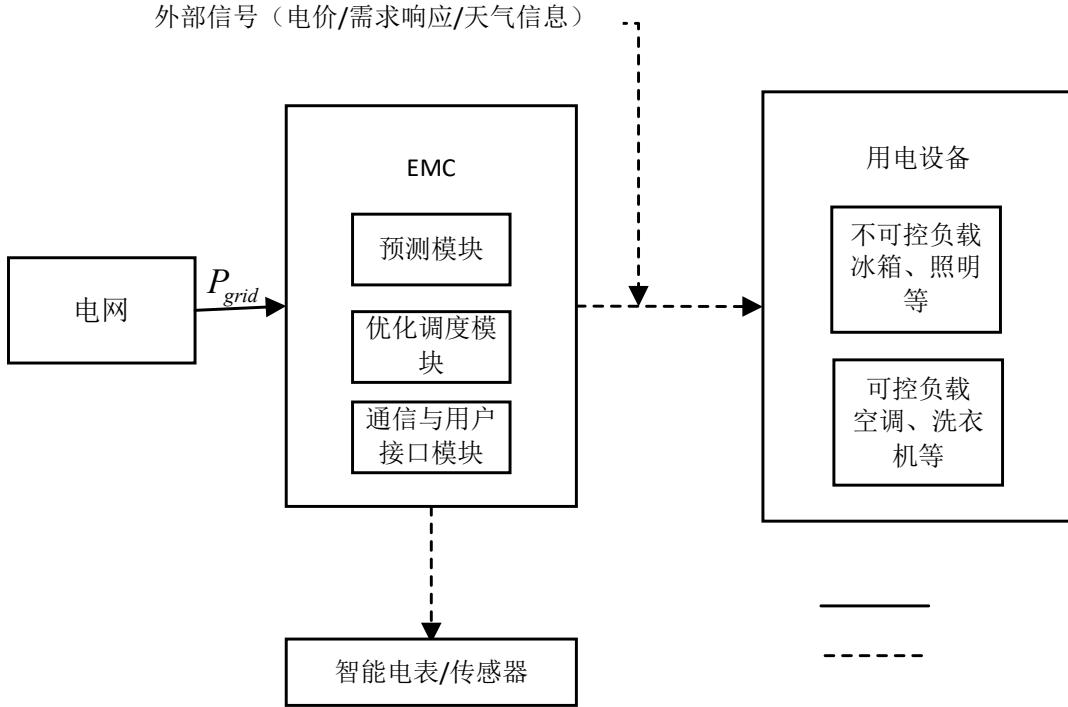


图 1 HEMS 结构图

1.1 家庭用电设备类型

家庭中的用电设备在运行特性上存在较大的差异,本文将其分为基础设备、不可中断设备、可转移设备和可中断设备四类进行建模。

基础设备是指那些通常需要持续地运行,既不可被中断也不可被转移的设备。例如照明设备、冰箱等。其运行时间由用户习惯硬性规定,EMC 不对其进行调度优化。其数学模型如下:

$$S^i = \alpha^i \quad (4)$$

$$P^i(t) = \lambda^i \cdot \alpha_i(t), i \in [1, n_1], \alpha_i(t) = 1 \forall t \in [\alpha^i, \beta^i] \quad (5)$$

式中, S^i 为第 i 个该类设备的启动时间, α^i 为该设备的最早启动时间, $P^i(t)$ 为第 i 个该类设备的功率, n_1 为该类设备总数, β^i 为该设备的最晚结束时间, λ^i 为其额定功率的大小, $\alpha_i(t)$ 为 t 时刻该设备的开关状态。

不可中断设备是指那些一旦开始运行便不可被中断,需要持续运行直至其工作结束的设备,但可以在一个时间窗内灵活调整其启动时间。例如洗衣机和洗碗机。其数学模型如下:

$$\alpha^i \leq S^i \leq \beta^i - \eta^i + 1 \quad (6)$$

$$\sum_{t=S^i}^{S^i+\eta^i-1} \alpha_i(t) = \eta^i, \alpha_i(t) = 1 \forall t \in [S_i, S_i + \eta_i - 1] \quad (7)$$

$$P^i(t) = \lambda^i \cdot \alpha_i(t), i \in [1, n_2] \quad (8)$$

式中, α^i 为第 i 个该类设备的最早启动时间, β^i 为最晚完成时间, η^i 为所需运行时长, $\alpha_i(t)$ 为 t 时刻该设备的开关状态, n_2 为该类设备总数。

可转移设备是指在运行过程中既可以被中断也可以转移的设备。例如笔记本电脑、真空吸尘器和电动汽车充电,可以在一天中的任意可用的时间段内分段完成其工作。其数学模型如下:

$$\alpha^i \leq S^i \leq \beta^i - \eta^i + 1 \quad (9)$$

$$\sum_{t=\alpha^i}^{\beta^i} \alpha_i(t) = \eta^i \quad (10)$$

$$P^i(t) = \lambda^i \cdot \alpha_i(t), i \in [1, n_3] \quad (11)$$

式中, η^i 为总运行时长, λ^i 为设备每小时消耗的功率, n_3 为该类设备总数。

可中断设备是可转移设备的一个子类,为体现复杂性而单独定义。其特性与可转移设备相同, n_4 为该类设备总数。

各类家用电器设备的具体参数如表 1 所示^[15]。

表 1 家用电器设备参数

设备类别	设备名称	功率/kW	最早开始时间	最晚结束时间	运行时长/h	设备类型
基本负载	室内照明	0.84	16	24	6	1
基本负载	冰箱	0.3	1	24	24	1
不可中断	洗碗机	1.5	9	17	2	2
不可中断	洗衣机	1.5	7	15	2	2
不可中断	烘干机	2.5	13	18	1	2
可转移	电饭煲	3	6	10	1	3
可转移	电烤箱	5	15	20	1	3
可转移	微波炉	1.7	6	10	1	3
可转移	笔记本电脑	0.1	18	24	2	3
可转移	台式电脑	0.3	18	24	3	3
可转移	吸尘器	1.2	9	17	1	3
可转移	电动汽车	3.5	18	32	3	3
可转移	热水器	4.5	7	22	2	3
可转移	空调	2.8	8	20	3	3
可转移	电饭锅	1.5	10	18	2	3
可转移	电水壶	1	9	21	1	3
可转移	水族设备	0.4	6	24	4	3
可转移	家庭服务器	0.6	8	23	5	3
可中断	电暖气	2.2	14	22	3	4
可中断	除湿器	1.8	10	20	4	4

1.2 目标函数与约束条件

家庭能源调度问题是一个高维、离散、带约束的组合优化问题。本文同时考虑了总成本和 PAR 两个优化目标。

总成本是用户所有设备在 24 小时内产生的总电费，由每小时耗电量与对应时段电价的乘积之和计算得到，如式 (12) 所示。

$$C^{total} = \sum_{t=1}^{24} [(\sum_{i=1}^n P^i(t)\rho(t))] \quad (12)$$

$$n = n_1 + n_2 + n_3 + n_4 \quad (13)$$

式中, $P^i(t)$ 为设备 i 在 t 时刻的功耗, $\rho(t)$ 为 t 时刻的电价, n 为设备总数。

PAR 是衡量负荷曲线平坦程度的关键指标, 其定义为最大负荷与平均负荷的比值, 其计算如式 (14) 所示。

$$PAR = \left[\max_{t \in [1, 24]} (L(t)) \right] / \left[(1/24) \sum_{t=1}^{24} L(t) \right] \quad (14)$$

$$L(t) = \sum_{i=1}^n P^i(t) \quad (15)$$

式中, $L(t)$ 表示 t 时刻的总负荷。

为了同时优化上述两个目标, 本文采用加权和法将其转换为单目标优化问题并进行归一化。目标函数

定义如下:

$$F = \omega_1 \cdot (C^{total}/C^{max}) + \omega_2 \cdot (PAR/PAR^{base}) \quad (16)$$

$$\omega_1 + \omega_2 = 1 \quad (17)$$

式中, ω_1 和 ω_2 为不小于 0 的权重系数, C^{max} 为一个足够大的成本上界, 本文取为未调度成本的 1.5 倍, PAR^{base} 为未调度场景下的 PAR 值。权重系数可根据优化阶段动态调整, 如前期侧重成本, 后期侧重 PAR。

约束条件由设备运行时间窗约束、设备运行时长约束、设备功率约束和依赖关系约束组成。对于每个可调度设备 i , 其启动时间 S^i 必须满足式 (18)。每个设备必须完成其预设的总运行时长 η^i , 如式 (19) 所示。设备的功率约束如式 (20) 所示。依赖关系约束指的是如烘干机的运行必须在洗衣机运行之后等, 如式 (21) 所示。

$$\alpha^i \leq S^i \leq \beta^i - \eta^i + 1, \forall i \in \{\text{可调度设备}\} \quad (18)$$

$$\sum_{t=\alpha^i}^{\beta^i} \alpha_i(t) = \eta^i, \forall i \in \{\text{可调度设备}\} \quad (19)$$

$$P^i(t) = \lambda^i \cdot \alpha_i(t) \leq P_i^{max}, \forall i, \forall t \quad (20)$$

$$S^{dryer} \geq S^{washer} + \eta^{washer} \quad (21)$$

1.3 复杂度分析

对于包含 M 个可调度设备的场景, 平均每个设备有 K 个可行的启动时间, 解空间规模为 $O(K^M)$, 在 20 设备复杂场景下, 即使 $K=10$, 解空间规模也达到了 10^{20} 量级, 属于 NP 难问题, 传统的精确算法难以在多项式时间内求解, 因此需要采用元启发式算法寻求高质量的近似解。

2 DLMMRFO 算法设计

2.1 MRFO 算法

MRFO 算法是一种模拟蝠鲼群体智能觅食行为

$$X_i(t+1) = \begin{cases} X_i(t) + r \cdot (X_{best}(t) - X_i(t)) + \alpha \cdot (X_{best}(t) - X_i(t)), & i = 1 \\ X_i(t) + r \cdot (X_{i-1}(t) - X_i(t)) + \alpha \cdot (X_{best}(t) - X_i(t)), & i = 2, \dots, n \end{cases} \quad (22)$$

式中, $X_i(t+1)$ 代表在 $t+1$ 时刻个体 i 的位置, r 是一个数值大小在 0 到 1 的随机向量, $X_{best}(t)$ 是 t 时刻最优解的位置, α 为权重系数, 其计算如式 (23) 所示。

$$\alpha = 2 \cdot r \sqrt{|\log(r)|} \quad (23)$$

在螺旋觅食的过程中, 每当蝠鲼在深水中发现一小块浮游生物时, 会以螺旋状的轨迹向猎物移动, 个体的位置更新如式 (24) 所示。

$$X_i(t+1) = \begin{cases} X_{best}(t) + r \cdot (X_{best}(t) - X_i(t)) + \beta \cdot (X_{best}(t) - X_i(t)), & i = 1 \\ X_{best}(t) + r \cdot (X_{i-1}(t) - X_i(t)) + \beta \cdot (X_{best}(t) - X_i(t)), & i = 2, \dots, n \end{cases} \quad (24)$$

$$\beta = \cos(2\pi\omega) \text{ or } \beta = \sin(2\pi\omega) \quad (25)$$

式中, ω 和 r 是 0 到 1 的随机数, β 为权重系数, 在进行以上更新后, 所有最优解的位置都被充分利用。为了加强算法的探索能力, 需要再指定一个随机位置来进行更新, 如式 (26) 所示。

$$X_i(t+1) = \begin{cases} X_{rand}(t) + r \cdot (X_{rand}(t) - X_i(t)) + \beta \cdot (X_{rand}(t) - X_i(t)), & i = 1 \\ X_{rand}(t) + r \cdot (X_{i-1}(t) - X_i(t)) + \beta \cdot (X_{rand}(t) - X_i(t)), & i = 2, \dots, n \end{cases} \quad (26)$$

$$X_{rand} = Lb + r \cdot (Ub - Lb) \quad (27)$$

式中, X_{rand} 是在搜索空间中生成的随机解, Ub 和 Lb 分别是搜索空间的上界和下界。

在翻滚觅食的过程中, 蝠鲼将食物位置当作支点, 每个个体围绕着它来回游动, 以当前的最优解来更新自己的位置, 个体位置的更新如式 (28) 所示。

$$X_i(t+1) = X_i(t) + S \cdot (r_2 \cdot X_{best}(t) - r_3 \cdot X_i(t)) \quad (28)$$

式中, S 是决定翻腾范围的翻腾因子, r_2 和 r_3 是介于 0 和 1 之间的随机值。

2.2 DLMMRFO 算法

HEMS 负载调度问题属于复杂的高维离散调度问题, 原有的 MRFO 算法存在易陷入局部最优和收敛精度不足等问题。为提高 MRFO 算法的性能, DLMRFO 算法通过引入离散位置更新策略、动态权重机制、长时记忆机制、遗传算法中的变异操作和 PAR 专项优化策略来更好地解决此类问题。

2.2.1 离散位置更新策略

针对调度问题的离散性质, DLMMRFO 通过引入离散位置更新策略, 有效地增强算法在离散解空间中的探索能力。该策略主要由动态转移和分级转移机制

的元启发式优化算法。蝠鲼群体通过链式觅食、螺旋觅食、和翻滚觅食这三种独特的觅食策略来在海洋中高效地搜寻猎物。该算法通过模拟这些觅食行为, 在解空间中进行高效的全局探索和局部开发, 以寻找最优解。

首先, 在链式觅食的过程中, 蝠鲼可以看到浮游生物的位置, 并朝浮游生物浓度最高的位置游去, 且种群中每一个个体都会根据这个最优位置进行迭代更新, 个体的位置更新如式 (22) 所示。

$$X_i(t+1) = \begin{cases} X_i(t) + r \cdot (X_{best}(t) - X_i(t)) + \alpha \cdot (X_{best}(t) - X_i(t)), & i = 1 \\ X_i(t) + r \cdot (X_{i-1}(t) - X_i(t)) + \alpha \cdot (X_{best}(t) - X_i(t)), & i = 2, \dots, n \end{cases} \quad (22)$$

式中, $X_i(t+1)$ 代表在 $t+1$ 时刻个体 i 的位置, r 是一个数值大小在 0 到 1 的随机向量, $X_{best}(t)$ 是 t 时刻最优解的位置, α 为权重系数, 其计算如式 (23) 所示。

$$\alpha = 2 \cdot r \sqrt{|\log(r)|} \quad (23)$$

在螺旋觅食的过程中, 每当蝠鲼在深水中发现一小块浮游生物时, 会以螺旋状的轨迹向猎物移动, 个体的位置更新如式 (24) 所示。

$$X_i(t+1) = \begin{cases} X_{best}(t) + r \cdot (X_{best}(t) - X_i(t)) + \beta \cdot (X_{best}(t) - X_i(t)), & i = 1 \\ X_{best}(t) + r \cdot (X_{i-1}(t) - X_i(t)) + \beta \cdot (X_{best}(t) - X_i(t)), & i = 2, \dots, n \end{cases} \quad (24)$$

$$\beta = \cos(2\pi\omega) \text{ or } \beta = \sin(2\pi\omega) \quad (25)$$

式中, ω 和 r 是 0 到 1 的随机数, β 为权重系数, 在进行以上更新后, 所有最优解的位置都被充分利用。为了加强算法的探索能力, 需要再指定一个随机位置来进行更新, 如式 (26) 所示。

$$X_i(t+1) = \begin{cases} X_{rand}(t) + r \cdot (X_{rand}(t) - X_i(t)) + \beta \cdot (X_{rand}(t) - X_i(t)), & i = 1 \\ X_{rand}(t) + r \cdot (X_{i-1}(t) - X_i(t)) + \beta \cdot (X_{rand}(t) - X_i(t)), & i = 2, \dots, n \end{cases} \quad (26)$$

$$X_{rand} = Lb + r \cdot (Ub - Lb) \quad (27)$$

式中, X_{rand} 是在搜索空间中生成的随机解, Ub 和 Lb 分别是搜索空间的上界和下界。

在翻滚觅食的过程中, 蝠鲼将食物位置当作支点, 每个个体围绕着它来回游动, 以当前的最优解来更新自己的位置, 个体位置的更新如式 (28) 所示。

$$X_i(t+1) = X_i(t) + S \cdot (r_2 \cdot X_{best}(t) - r_3 \cdot X_i(t)) \quad (28)$$

式中, S 是决定翻腾范围的翻腾因子, r_2 和 r_3 是介于 0 和 1 之间的随机值。

组成, 动态转移机制的触发条件如式 (29) 所示。

$$Tf_{i,j} = \begin{cases} 1, & P_j > (\theta - \beta + \gamma) \cdot P_{avg} \\ 1, & (P_j > P_{avg}) \cap (h_j \in H_{peak}) \\ 0, & \text{otherwise} \end{cases} \quad (29)$$

式中, $\beta=0.1$ 为电价高峰时段的奖励因子, γ 为算法陷入停滞时的临时增强因子。 θ 为动态阈值, P_{avg} 为平均电价, H_{peak} 为电价高峰时段集合, θ 的更新公式如式 (30) 所示。

$$\theta = 0.5 + 0.2 \cdot (1 - L/L_{max}) \quad (30)$$

式中, L 为当前迭代次数, L_{max} 为最大迭代次数。

分级转移机制按候选时段将电价水平分为 6 个等级, 其对应的转移概率从 0.98 到 0.30, 该机制实现了精细化搜索控制且使算法能够优先处理功率高以及运行时间长的设备, 提升了算法的搜索效率。设备重要性的加权公式如式 (31) 所示。

$$\omega_i = P_i \cdot T_i \quad (31)$$

式中, P_i 为设备 i 的功率, T_i 为其运行时长。

2.2.2 动态权重机制

DLMMRFO 通过引入动态权重机制, 来平衡迭代过程中成本和 PAR 两个目标的优化优先级, 成本和 PAR 权重的更新公式如式 (32) 所示。

$$\begin{cases} \omega_1 = 0.7 - 0.2 \frac{iter}{maxIter} \\ \omega_2 = 1 - \omega_1 \end{cases} \quad (32)$$

式中, ω_1 为成本权重, ω_2 为 PAR 权重, $iter$ 为当前迭代次数, $maxIter$ 为最大迭代次数。

2.2.3 长时记忆机制

DLMMRFO 通过引入长时记忆机制来提高算法的全局探索能力, 防止陷入局部最优^[16], 长时记忆机制采用轮盘赌选择机制从记忆库中选择领导者, 选择概

率的计算如式 (33) 所示。

$$P_i = \frac{S_j}{\sum_{j=1}^M S_j} \quad (33)$$

式中, S_j 为第 j 个个体的综合评分。 M 为当前记忆库的容量。

2.2.4 遗传算法中的变异操作

DLMMRFO 通过在离散搜索空间中对设备的启动时间引入单点变异来有效维持种群多样性。设备变异后的开始时间计算公式如式 (34) 所示。

$$x_j^{new} = U(a_j, b_j) \quad (34)$$

式中, $U(a_j, b_j)$ 为在区间 $[a_j, b_j]$ 上的均匀分布, a_j 为设备 j 的最早开始时间, b_j 为设备 j 的最晚结束时间。

2.2.5 PAR 专项优化策略

DLMMRFO 通过引入 PAR 专项优化策略, 有效地平衡了成本和 PAR 两个目标之间的优化。PAR 专项优化根据一定条件触发, 该触发条件如式 (35) 所示。

$$PAR_{Trigger} = (iter > [maxIter \times 0.5]) \wedge (mod(iter, 7) = 0) \quad (35)$$

式中, $iter$ 为当前迭代数, $maxIter$ 为大迭代数。

综上所述, DLMMRFO 算法的流程如图 2 所示, 伪代码如下所示:

算法 1 DLMRFO 算法

```

1   初始化: 种群大小  $P$ , 最大迭代次数  $T_{max}$ , 问题维度  $d$ , 负载转移算子  $p^{par}$ ,  $p^{par2}$ , 全局最优解  $G^{best}$  和长时记忆记忆库  $M$ ,
2   生成满足约束的离散初始种群  $P$ 。
3   评估种群中每个个体的适应度值  $F$ 
4   for  $t = 1$  to  $T_{max}$  do
5       for 每个体  $X^i$  in 种群  $P$ 
6           动态计算当前权重  $\omega_1, \omega_2$ 
7           从  $M$  中基于轮盘赌选择领导者  $L$ 
8           if  $rand < 0.5$  then
9               if  $t/T_{max} < rand$  then
10                  按式(26)随机选择参考位置  $X_{rand}$  进行螺旋觅食
11             else 按式(24)围绕随机解进行螺旋觅食
12                 应用离散位置更新策略
13             end if
14           else 按式(22)进行链式觅食
15             应用离散位置更新策略
16           end if
17       end for
18       for 每个体  $X_i$  按式(28)执行翻滚觅食
19         应用离散位置更新策略
20     end for
21     以概率  $p^{par2}$  触发 PAR 专项优化算子并确保新解满足所有硬约束
22     评估新解的适应度值  $F^{new}$ 
23     If  $F^{new} < F^i$  then
24         更新  $X^i$  和  $F^i$ 
25     end if
26     更新全局最优解  $G^{best}$  和长时记忆记忆库  $M$ 。
27   end for
28   return  $G^{best}$ 

```

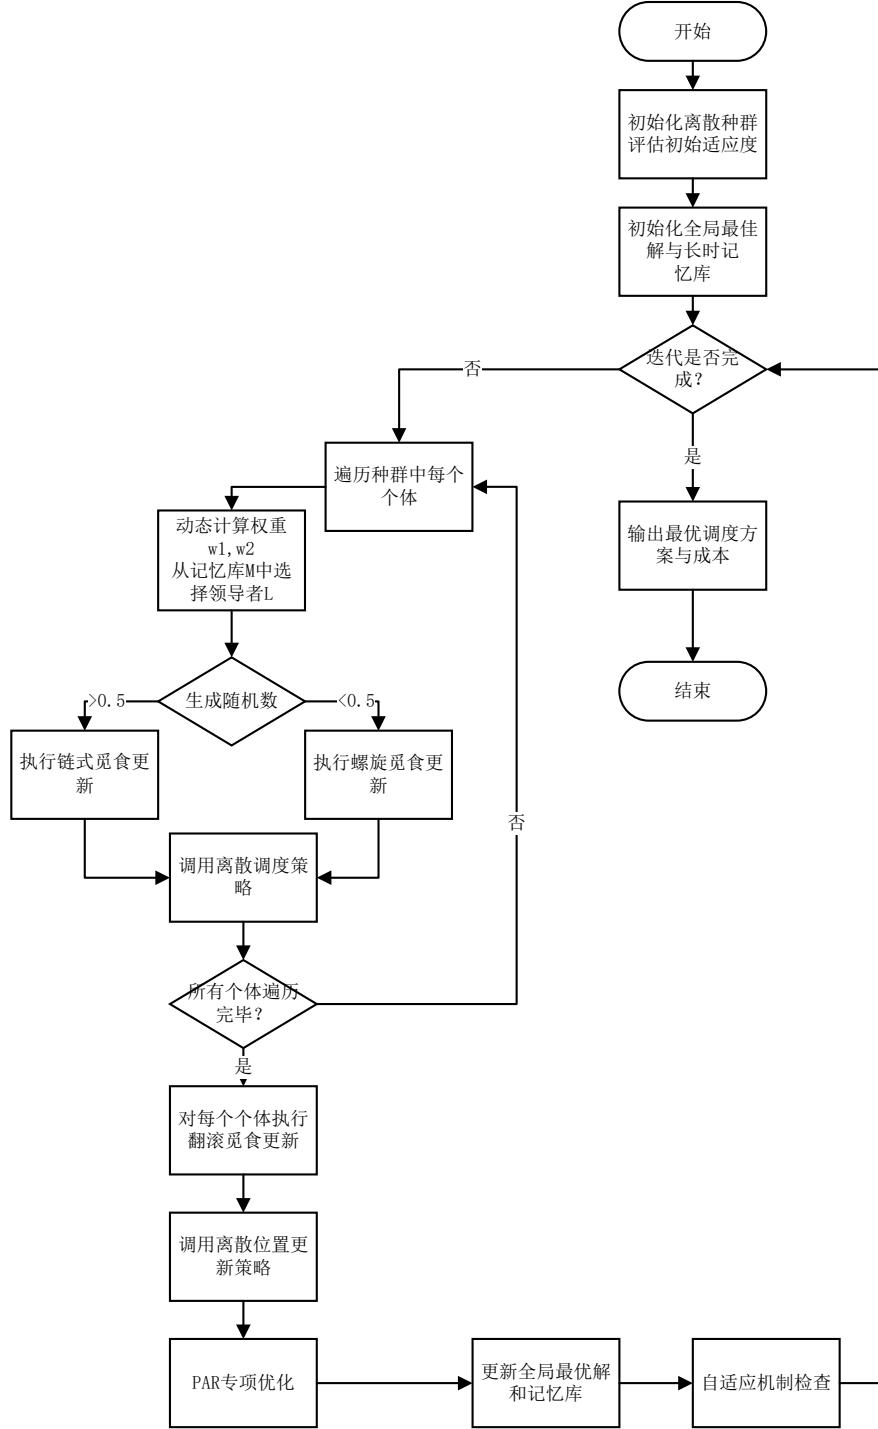


图 2 DLMMRFO 算法流程图

3 实验与结果分析

3.1 实验与参数设置

为验证 DLMMRFO 算法的性能, 设计了两组仿真实验场景, 并与 MRFO、GA、PSO 算法进行对比分析。简单场景包含 12 个家用电器, 用于验证算法在基准情况下的正确性与有效性。复杂场景在简单场景基础上

新增了 8 个高功率、长运行时间的可中断/可转移设备, 旨在模拟现代智能家庭中设备数量增多与用电行为复杂化所带来的挑战。DLMMRFO 参数设置如表 2 所示^[16]。仿真结果以日总成本和 PAR 作为评估指标。所有实验在 MATLABR2018b 环境中完成, 硬件平台设置为 IntelCorei7-10750KCPU@2.60GHz, 8GBRAM。

表 2 DLMMRFO 参数设置

参数	取值
种群大小	100
最大迭代次数	100
记忆库长度	20
翻滚因子	2.5
精英比率	0.15
初始权重	[0.6, 0.4]

3.2 简单场景结果与分析

RTP 电价曲线以及模拟电价曲线随机生成的未调度负载如图 3 所示。在简单场景下, 利用 DLMMRFO、MRFO、GA、PSO 四种算法得到的最优调度曲线以及对应的每日成本和 PAR 对比结果分别如图 4 和图 5 所示。上述四种算法在复杂场景下的最优调度曲线, 以及对应的每日成本和 PAR 对比结果分别如图 6 和图 7 所示。

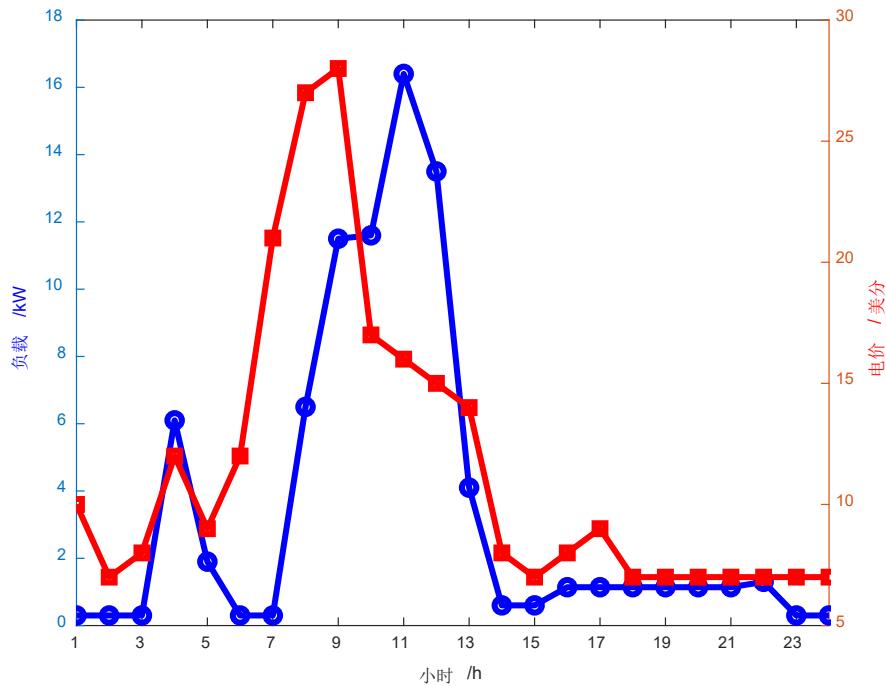


图 3 电价-负载曲线

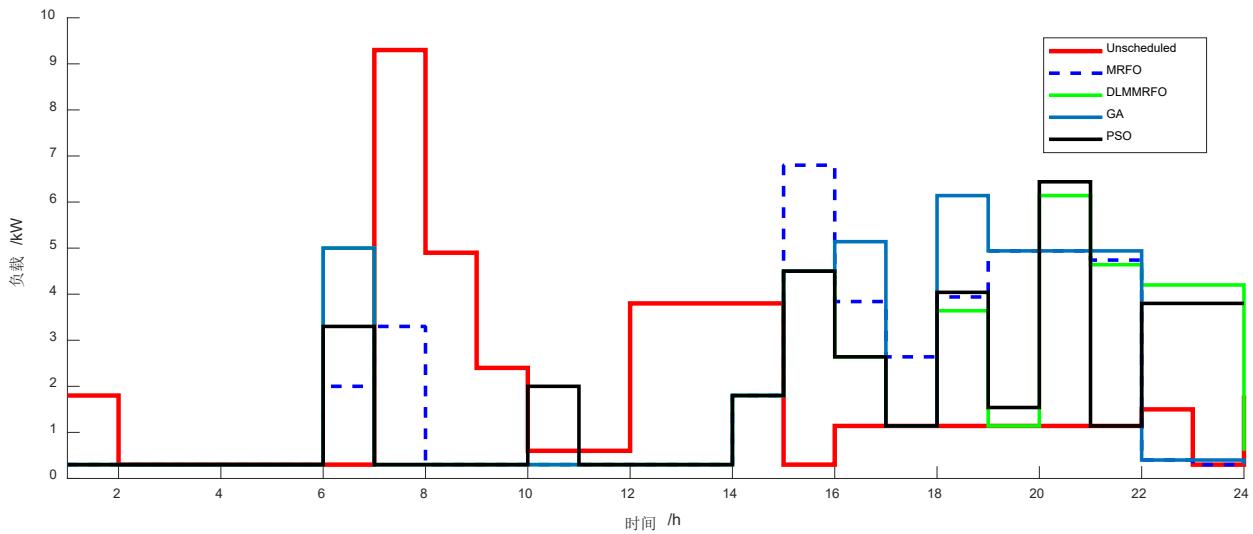


图 4 简单场景下最优调度曲线的对比

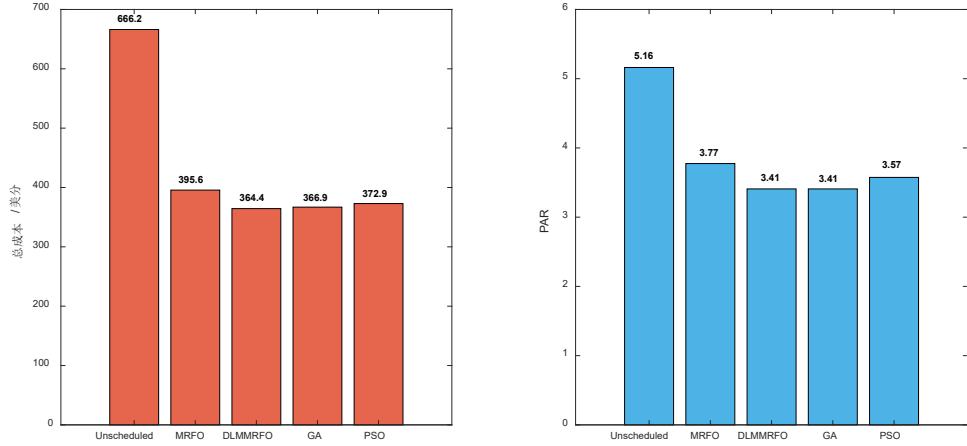


图 5 简单场景下每日成本和 PAR 的对比

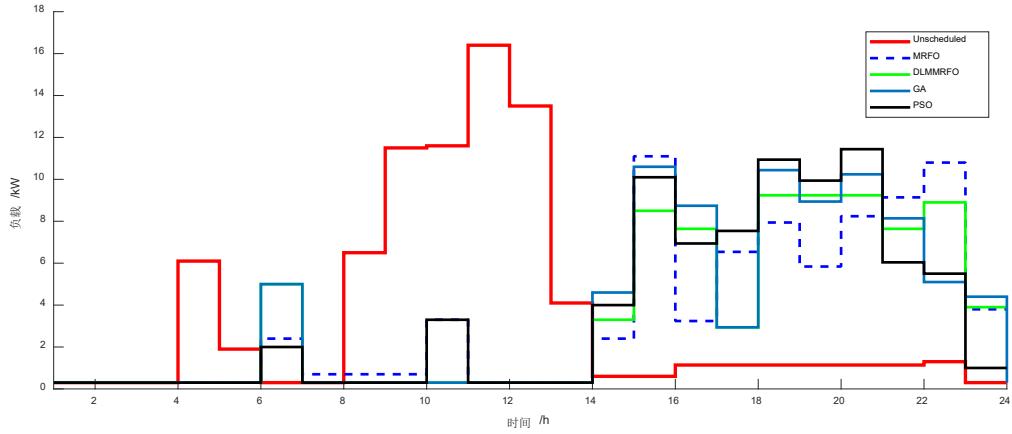


图 6 复杂场景下最优调度曲线的对比

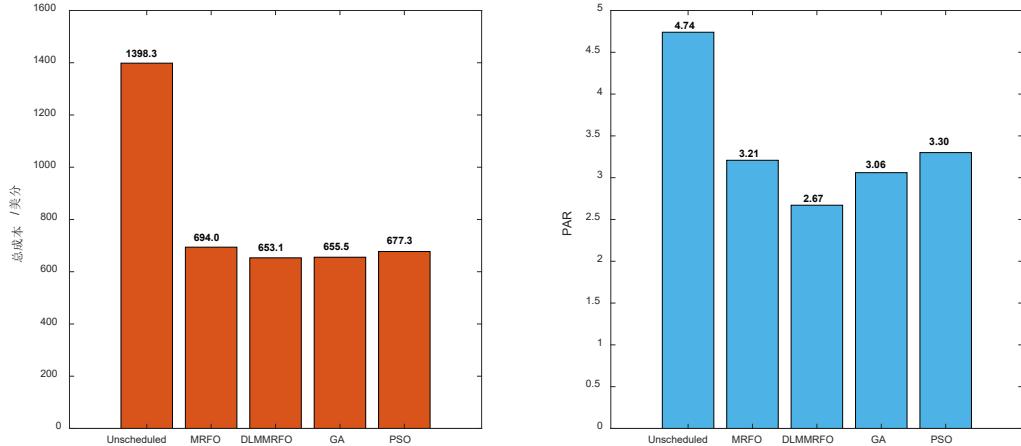


图 7 复杂场景下每日成本和 PAR 的对比

对不同算法的调度结果进行对比分析发现, DLMMRFO 算法在负荷曲线平坦度、总成本及 PAR 方面均表现最佳。相较于早期经典算法如 GA 和 PSO 算法, DLMMRFO 算法展现出了更强的全局搜索和避免早熟收敛的能力。相较于原始 MRFO 算法, DLMMRFO

算法在简单与复杂场景下分别将成本降低了 7.89% 与 5.89%, 将 PAR 降低了 9.55% 与 16.82%。若与未调度基准相比, 其成本降幅更高达 45.30% 与 53.29%。这一结果充分证明了本文所提多策略改进有效提升了 MRFO 算法处理高维离散调度问题的性能。

3.3 收敛性分析

以复杂场景为例, 四种算法的成本收敛曲线如图 8 所示。其中, DLMMRFO 算法展现出了更快的收敛速度和更强的全局勘探能力。与 GA 和 PSO 算法相比, DLMMRFO 算法在迭代初期便能迅速下降至更低的成

本区间, 体现了其优异的初始搜索能力。更重要的是, 在迭代中后期, 当 GA 和 PSO 算法已明显陷入停滞时, DLMMRFO 算法凭借其长时记忆和变异机制, 仍能发现更优解, 这证明了其改进策略在维持种群多样性和避免早熟收敛方面的有效性。

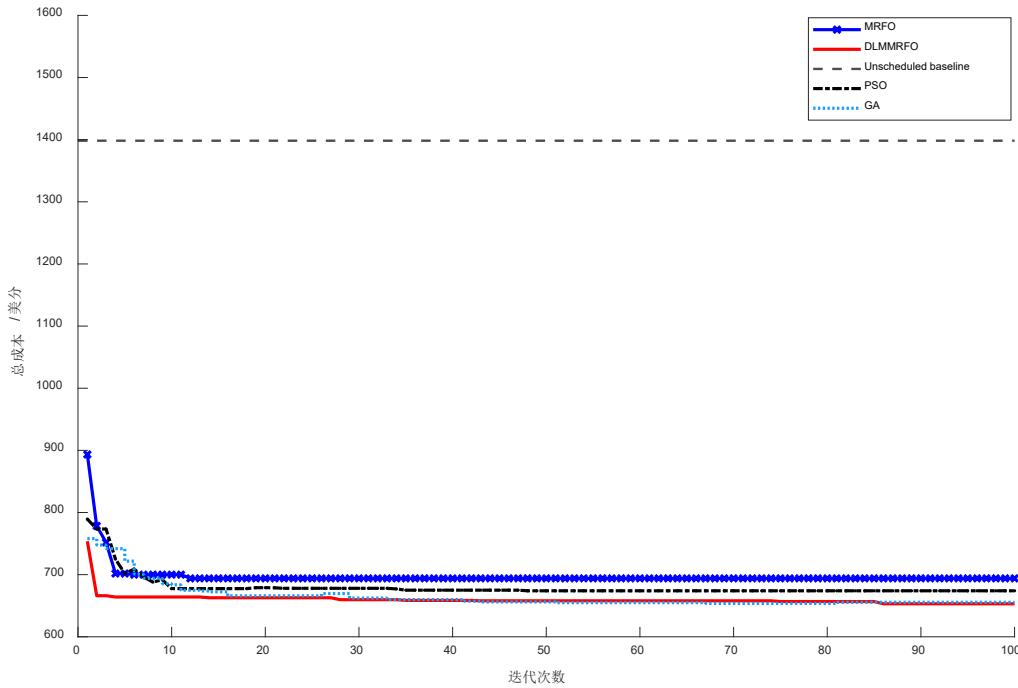


图 8 复杂场景算法收敛曲线对比

4 结论

为了应对 MRFO 算法在 HEMS 调度优化中所面临的种群多样性不足、易陷入局部最优解以及在加权多目标优化中目标间不均衡的问题, 本文提出了一种改进的 DLMMRFO 算法。通过系统的仿真实验与多维度对比分析, 本文在下列方面取得显著成效:

(1) DLMMRFO 算法通过在高维离散解空间中直接进行搜索, 避免了连续-离散映射的失配问题, 从根本上提升了算法的性能和效率。

(2) 通过引入动态权重机制和 PAR 专项优化策略, DLMMRFO 成功解决了复杂场景下成本与 PAR 优化之间的不平衡问题。在 20 台设备的复杂场景下, 算法不仅显著降低了总成本, 同时将 PAR 值降低了 43.67%。

(3) 相比于 MRFO 算法, 改进算法提升了收敛精度, 有更好的跳出局部最优的能力, 以及更丰富的种群多样性, 更好的平衡多目标之间优化的能力, 且在高维离散场景中具有更强的适应力。

本研究提出的 DLMMRFO 算法在解决家庭能源调度问题上展现了优异的性能。然而, 需要指出的是, 本研究构建的模型基于以下关键假设:首先, 模型假设电价与设备功耗为确定性参数, 而未考虑现实环境中电价波动、可再生能源发电的不确定性及用户行为的随机性;其次, 模型仅考虑了从电网购电的单一电能来源, 未纳入住宅光伏、储能系统(ESS)以及家庭向电网售电等双向电能交互;最后, 当前的优化目标集中于经济性与电网侧指标, 未将用户舒适度作为明确的优化目标。上述假设在一定程度上限制了模型在实际复杂场景中的直接应用。

针对上述局限, 未来的研究工作可以从以下几个方向展开:首先, 可引入鲁棒优化或随机规划方法, 构建能够应对电价、可再生能源等不确定性的更复杂的调度模型。其次, 可集成 ESS、电动汽车车联网(Vehicle-to-Grid, V2G)技术以及分布式可再生能源, 以研究家庭与电网之间双向能量流动的优化调度模型。同时, 将用户舒适度量化为第三优化目标, 并构建多目标优化

框架, 以更好地平衡能效与用户体验。最后, 将本研究提出的算法扩展应用于多户家庭或社区级的调度问题, 探索其在区域能源管理和配网优化中的潜力, 从而为实现更广泛的能源管理和系统协同运行做出贡献。

参考文献

- [1] 付建勇, 智能电网中分布式能源接入对系统稳定性的影响研究[J]. 电气工程与自动化, 2024, 3: (2) : 31-34.
- [2] 代业明, 孙锡连, 李陆, 等. 基于多层博弈的智能电网住宅电力实时需求响应机制[J]. 运筹与管理, 2021, 30(10): 11-17.
- [3] de Lima T D, Faria P, Vale Z. Optimizing home energy management systems: A mixed integer linear programming model considering battery cycle degradation[J]. Energy and Buildings, 2025, 329: 115251.
- [4] Abreu C, Soares I, Oliveira L, et al. Application of genetic algorithms and the cross - entropy method in practical home energy management systems[J]. IET Renewable Power Generation, 2019, 13(9): 1474-1483.
- [5] 华聪聪, 冯胜, 李大华, 等. 基于改进量子遗传算法的光伏智能楼宇负荷优化[J]. 计算机应用与软件, 2024, 41(9): 77-82, 105.
- [6] 丁迅, 张忠, 夏兆俊, 等. 基于非侵入式负荷监测的家庭智慧用能管理研究[J]. 现代电力, 2022, 39(4): 496-504.
- [7] Sivarajani R, Rao P M. Smart energy optimization using new genetic algorithms in Smart Grids with the integration of renewable energy sources[M]//Sustainable Networks in Smart Grid. Academic Press, 2022: 121-147.
- [8] 江泽昌, 刘天羽, 江秀臣, 等. 智能电网下多时间尺度家庭能量管理优化策略[J]. 太阳能学报, 2021, 42(1): 460-469.
- [9] Abedin Z U, Shahid U, Mahmood A, et al. Application of PSO for HEMS and ED in Smart Grid[C]//2015 Ninth International Conference on Complex, Intelligent, and Software Intensive Systems. IEEE, 2015: 260-266.
- [10] Khalid A, Javaid N, Guizani M, et al. Towards dynamic coordination among home appliances using multi-objective energy optimization for demand side management in smart buildings[J]. IEEE access, 2018, 6: 19509-19529.
- [11] Zhao W, Zhang Z, Wang L. Manta ray foraging optimization: An effective bio-inspired optimizer for engineering applications[J]. Engineering Applications of Artificial Intelligence, 2020, 87: 103300.
- [12] Houssein E H, Emam M M, Ali A A. Improved manta ray foraging optimization for multi-level thresholding using COVID-19 CT images[J]. Neural Computing and Applications, 2021, 33(24): 16899-16919.
- [13] 陈晨, 郝国凯, 陈高伟, 等. 人类偏好强化学习与演化计算融合的家庭能源系统需求响应优化[J/OL]. 上海交通大学学报, 2025: 1-22 [2025-09-25].
- [14] Economics F, First S. Demand side response in the domestic sector—a literature review of major trials[R]. London: Final Report, 2012.
- [15] Aslam S, Javaid N, Khan F A, et al. Towards efficient energy management and power trading in a residential area via integrating a grid-connected microgrid[J]. Sustainability, 2018, 10(4): 1245.
- [16] Youssef H, Kamel S, Hassan M H. Smart home energy management and power trading optimization using an enhanced manta ray foraging optimization[J]. Scientific Reports, 2023, 13(1): 22163.

版权声明: ©2025 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

<https://creativecommons.org/licenses/by/4.0/>



OPEN ACCESS