

DOI: 10.19783/j.cnki.pspc.241766

一种新型的微电网三层优化调度模型研究

张丽^{1,2}, 贾晨豪¹, 马泽原¹, 张涛^{1,3}, 张宏伟⁴

(1. 河南理工大学电气工程与自动化学院, 河南 焦作 454003; 2. 河南省煤矿装备智能检测与控制重点实验室, 河南 焦作 454003; 3. 河南省智能装备直驱技术与控制国际联合实验室, 河南 焦作 454003; 4. 山西省电力公司临汾供电公司, 山西 临汾 041000)

摘要: 为了解决间歇性能源的不确定性问题, 提高微电网的经济性和运行效率, 基于模型预测控制思想提出了一种新型的三层耦合微电网调度模型, 并用改进的蜣螂算法对模型进行优化和求解。首先, 通过综合考虑分时电价和污染治理成本, 优化并降低日前不确定因素的影响, 在线修正最优控制量, 从而构建一种新型的三层调度模型。其次, 对传统蜣螂算法的种群初始化、滚动行为、觅食行为等改进后, 通过仿真验证了算法的可行性, 结果表明改进后的算法在精确度和收敛速度方面均有所提升。然后, 采用改进的蜣螂算法优化调度层的经济性, 求解滚动控制中的最优控制。最后, 通过经济性对比、滚动调度分析和控制效果对比实验, 证明了所提模型及算法能够改善微电网的环保经济性, 提高系统的可控性和稳定性。

关键词: 微电网; 分层调度模型; 优化经济调度; 模型预测控制; 改进蜣螂算法

A novel three-layer optimal dispatch model for microgrids

ZHANG Li^{1,2}, JIA Chenhao¹, MA Zeyuan¹, ZHANG Tao^{1,3}, ZHANG Hongwei⁴

(1. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China; 2. Henan Key Laboratory of Intelligent Detection and Control of Coal Mine Equipment, Jiaozuo 454003, China; 3. Henan International Joint Laboratory of Direct Drive and Control of Intelligent Equipment, Jiaozuo 454003, China; 4. Linfen Power Supply Company, Shanxi Electric Power Company, Linfen 041000, China)

Abstract: To address the uncertainty of intermittent energy sources and improve the economic efficiency and operation performance of microgrids, a novel three-layer coupled microgrid dispatch model is proposed based on model predictive control. The model is optimized and solved using an improved dung beetle algorithm. First, by comprehensively considering time-sharing tariffs and pollution control costs, the model mitigates the impact of day-ahead uncertainties and performs online correction of the optimal control variables, thereby forming a new three-layer scheduling structure. Second, improvements are made to the traditional dung beetle algorithm in aspects such as population initialization, rolling behavior, and foraging behavior. The feasibility of the algorithm is verified by simulation, showing improved accuracy and convergence speed. Subsequently, the improved dung beetle algorithm is used to optimize the economic performance of the scheduling layer and determine the optimal control actions in rolling control. Finally, comparative analyses in terms of economic performance, rolling scheduling, and control effect demonstrate that the proposed model and algorithm can effectively enhance the environmental and economic performance of microgrids while improving system controllability and stability.

This work is supported by the National Natural Science Foundation of China (No. 52177039).

Key words: microgrids; hierarchical dispatch model; optimizing economic dispatch; model predictive control; improved dung beetle optimization algorithm

0 引言

微电网是由多种组件构成的小型发配电系统,

基金项目: 国家自然科学基金项目资助(52177039); 河南省科技攻关项目资助(242102241027; 242102210185); 河南省高等学校重点科研项目资助(24A470006)

不仅有助于实现可再生能源的高效利用, 还能提高电力系统的灵活性和可靠性, 推动能源结构的优化和可持续发展。但间歇性分布式能源和负荷需求的不确定性, 使微电网日前预测误差大, 机组出力不断变化, 调节速度难以跟上其变化。因此, 如何应对间歇性分布式能源和负荷需求的不确定性是微电网优化调度中亟待解决的问题^[1-4]。

基于滚动优化与反馈修正思想的模型预测控制(model predictive control, MPC), 可有效处理不确定性因素, 灵活处理多种约束条件, 追踪多个优化目标。因此, 在微电网优化调度中, MPC 在可再生能源和负荷需求的不确定性以及市场电价的波动性等方面得到了广泛的应用^[5-8]。

尽管 MPC 为微电网不确定性调度提供了可行框架, 但其在复杂场景下的实际应用仍面临多重瓶颈。文献[9]为了应对可再生能源和负荷预测的不确定性, 制定了一种考虑预测误差的微电网日内经济调度策略。然而, 传统的集中式模型预测控制在应对复杂的微电网调度时存在在线计算量大和扩展性差等问题, 使得传统 MPC 难以适用于包含众多分布式单元的综合能源系统, 尤其是实时性和灵活性要求较高的场景。因此, 越来越多的研究倾向于采用分层架构来解决微电网调度中的问题^[10]。文献[11-12]提出了日前-日内架构。在日前阶段, 构建最优成本调度模型; 在日内阶段, 基于 MPC 进行校正控制, 以应对可再生能源发电和负荷预测中的不确定性。这种架构能够通过分阶段优化, 提高系统的稳定性和经济性, 文献[13]采用神经网络智能算法对分段优化模型进行改进, 提高了系统的响应速度。但不确定变量的预测精度和预测时间成反比^[14], 且随着预测时间的延长, 预测的误差会逐渐增大, 特别是在预测后期, 预测的误差进一步增大^[15], 从而影响到调度方案的执行效果。因此, 为了降低预测的误差, 需对微网日内的调度策略进行优化。文献[16]提出了一个结合“优化-分层”及递阶控制思想的日内分层模式预测方案, 但该研究重点聚焦于光伏集群体系, 而并未充分考虑对多源供电及储能体系的影响。文献[17]提出了多源供电的三层架构, 实现了更加可控和高效的优化调度。但是优化调度和滚动求解未采用智能算法, 并且成本最小化的优化调度在日内层滚动优化的计算量过大, 难以满足更精细的实时调控。

综上所述, 目前三层的调度模型在国内外研究中较少, 现有的一些研究未充分考虑环保经济性和智能算法优化及求解对微电网运行的影响。基于此, 本文提出一种基于改进蜣螂算法的三层优化调度策略。该策略的第一层综合考虑分时电价和环境污染成本, 以微电网的经济运行为目标, 用改进智能算法进行优化; 第二层考虑机组的运行效率, 将优化调度提前至日前阶段, 用改进智能算法滚动优化降低日前可再生能源和负荷预测的不确定性; 第三层利用实际输出值对第二层反馈修正, 考虑机组的运行速度, 采用改进的智能算法实现在线运行。通过

日前调度经济性算法和联络线跟踪效果对比分析, 验证了所提策略和算法的可行性和优越性, 对改善微电网运行效率、稳定性和运行成本的经济性有重要意义。

1 三层优化调度模型的构建

1.1 微电网结构模型

本文所研究的微电网模型是以山西某微电网为原型, 结构如图 1 所示。该并网微电网模型假设主电网为电压和频率恒定的无限大电网, 并网模式下微电网无须主动调频调压; 燃气轮机和柴油发电机作为可控电源, 其动态响应时间被简化为稳态模型, 仅考虑功率输出上限及燃料成本与功率的线性关系; 光伏、风机的出力和负荷需求的前日预测值为已知量, 以正态分布来模拟实时波动; 储能系统的充放电效率 η 设为固定值($\eta = 0.9$); 优化调度管理实时调度各单元功率, 以经济性为目标优化储能充放电、可控电源出力及并网购电策略。

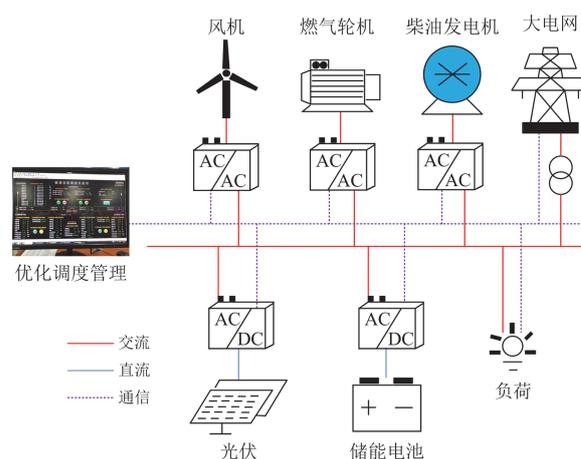


图 1 微电网模型结构

Fig. 1 Microgrid model structure

1.2 三层优化调度框架

为了有效消纳微电网中的间歇性分布式能源, 根据可再生能源和负荷预测误差随着预测时间缩短而逐步减小的特性, 本文在多时间尺度内, 构建了一个三层优化调度模型, 分别是调度层、优化层、和修正层, 如图 2 所示。具体优化调度思路如下。

1) 调度层。本层以“日前”为时间尺度, 基于对可再生能源和负荷需求的预测, 综合考虑分时电价和环境治理成本, 以最小化系统经济成本为目标。通过优化微源的功率、调整充放电和联络线出力占比等控制变量, 制定了次日每小时的发电计划。

2) 优化层。本层以“日内”为时间尺度, 按照日前发电计划对各机组进行管理, 每隔 15 min 进行

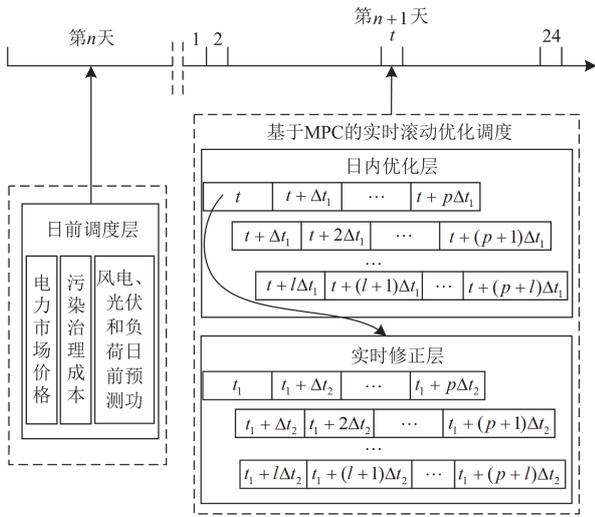


图2 三层优化调度框架

Fig. 2 Three-layer optimal scheduling framework

一次滚动优化，同时每次优化都会考虑当前时间段及未来一段时间窗口内的可再生能源和负荷的短期预测功率。以微电网的联络线功率和储能荷电状态 (state of charge, SOC) 日前计划跟踪误差最小为目标，求解各机组的最优控制序列，以此序列得到的各机组及储能和联络线的功率状态值作为优化层下一个时间断面的初始值。

3) 修正层。本层以“实时”为时间尺度，以优化层得到的调度计划值为参考，对各机组进行实时管理，将优化层的一个周期细化为3个周期，即以5 min为周期进行滚动修正，以微电网联络线功率实时输出值与计划参考值和储能SOC跟踪误差最小为目标，求解各机组的最优控制序列并取首项得到机组最终出力。

调度层是优化层的前提，为优化层提供了每小时的发电计划。优化层是对调度层的补充完善，显著降低了调度层日前不确定因素的影响。修正层是优化层的目的，通过对优化后的参考值进行反馈校正，实现在线实时调控。

1.3 调度层的构建

调度层以1 h为采样时间，生成未来24 h的日前调度计划^[18]。日前优化调度综合考虑分时电价和污染治理成本，通过合理规划可控型微电源的运行功率，优化储能充放电和微电网的购售电功率分配，以实现系统总成本的最小化。其目标函数为

$$\min J_{\text{ex-d}} = \sum_{t=1}^T \sum_{i=1}^N ((C_{\text{Gi-f}} + C_{\text{Gi-ma}} + C_{\text{Gi-pd}}) \times P_{\text{Gi}}(t)) + \sum_{t=1}^T (C_b \times P_b(t) + C_g \times P_g(t)) \quad (1)$$

式中： $J_{\text{ex-d}}$ 为优化调度的总经济成本； T 为总时段； N 为分布式电源的个数； $C_{\text{Gi-f}}$ 、 $C_{\text{Gi-ma}}$ 、 $C_{\text{Gi-pd}}$ 分别为第*i*台机组的燃料成本、维护成本和污染碳排放成本^[19]； C_b 为储能的维护成本； C_g 为微电网向大电网购电或售电的价格； $P_{\text{Gi}}(t)$ 表示在*t*时段各分布式电源的功率； $P_b(t)$ 表示在*t*时段储能的充放电功率； $P_g(t)$ 表示微电网向配电网购电或售电的功率。

日前优化调度需要满足以下约束条件。

1) 功率平衡约束

$$\sum_{i=1}^N (P_{\text{Gi}}(t) + P_b(t) + P_g(t)) = P_{\text{Load}}(t) \quad (2)$$

式中： $P_{\text{Load}}(t)$ 为*t*时段的负荷需求功率。

2) 分布式电源功率约束

$$P_{\text{Gi-min}} \leq P_{\text{Gi}}(t) \leq P_{\text{Gi-max}} \quad (3)$$

式中： $P_{\text{Gi-max}}$ 和 $P_{\text{Gi-min}}$ 分别为第*i*台分布式电源输出功率的上、下限。

3) 分布式电源功率爬坡约束

$$\Delta P_{\text{Gi-min}} \leq P_{\text{Gi}}(t) - P_{\text{Gi}}(t-1) \leq \Delta P_{\text{Gi-max}} \quad (4)$$

式中： $\Delta P_{\text{Gi-max}}$ 和 $\Delta P_{\text{Gi-min}}$ 分别为第*i*台分布式电源爬坡功率的上、下限。

4) 联络线传输功率约束

$$P_{\text{g-min}} \leq P_g(t) \leq P_{\text{g-max}} \quad (5)$$

式中： $P_{\text{g-min}}$ 和 $P_{\text{g-max}}$ 分别为联络线允许传输的最小功率和最大功率。

5) 储能单元容量约束

储能状态的计算公式为

$$S_{\text{OC}}(t) = \begin{cases} S_{\text{OC}}(t-1) - \eta \frac{P_b(t) \times \Delta t}{E_b}, & P_b(t) \leq 0 \\ S_{\text{OC}}(t-1) - \frac{1}{\eta} \frac{P_b(t) \times \Delta t}{E_b}, & P_b(t) > 0 \end{cases} \quad (6)$$

式中： $S_{\text{OC}}(t)$ 为*t*时段的储能状态； E_b 为电池容量； Δt 为时间变化量。

储能状态的约束为

$$S_{\text{OC-min}} \leq S_{\text{OC}}(t) \leq S_{\text{OC-max}} \quad (7)$$

式中： $S_{\text{OC-max}}$ 和 $S_{\text{OC-min}}$ 分别为储能容量的上、下限。

6) 储能充放电功率约束

$$-P_{\text{dis-max}} \leq P_b(t) \leq P_{\text{ch-max}} \quad (8)$$

式中： $P_{\text{dis-max}}$ 和 $P_{\text{ch-max}}$ 分别为储能放电和充电的最大功率。

1.4 优化层和修正层的构建

修正层是以优化层作为基础进行实时修正的，故将其两层一起搭建，其调度过程如图3所示。

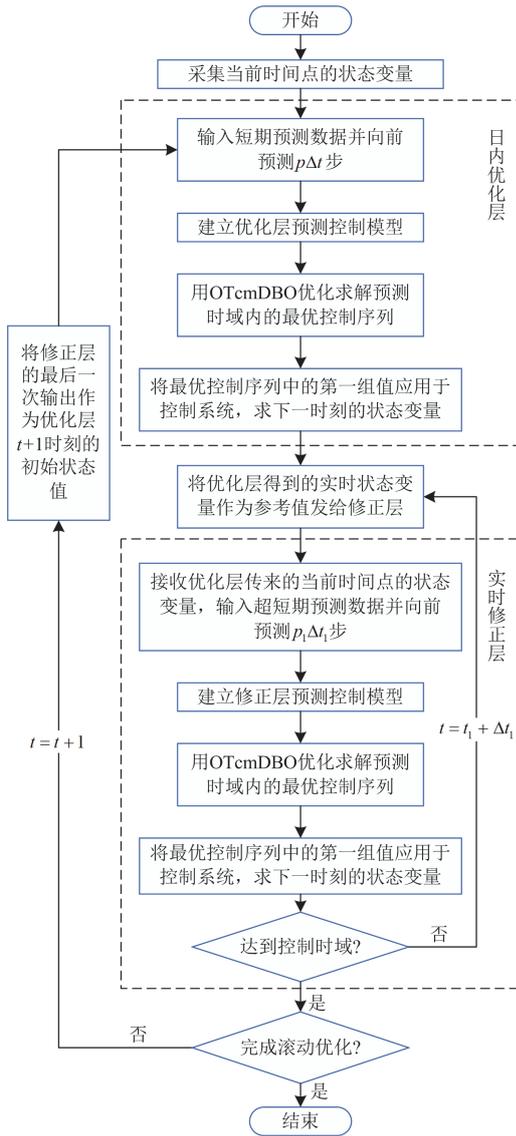


图3 日内-实时调度流程

Fig. 3 Intraday-realtime scheduling process

优化层以 15 min 为周期, 生成未来 1 h 的调度计划; 修正层以 5 min 为周期, 生成未来 15 min 的调度计划。但每次仅执行控制序列中的首个值, 确保在每个调度周期内只执行一次控制操作, 保证系统稳定性。优化层主要负责形成长期计划的调度方案, 并将其下发给修正层作为参考值。修正层通过来自优化层的参考值和实时状态信息, 修正控制量以应对不确定性因素的影响。修正层和优化层以及实时状态之间进行信息反馈, 以更新时刻的初始状态值。

具体到建立 MPC 滚动优化调度模型, 优化层跟修正层原理相同, 下面以优化层为例说明, 修正层不再赘述。根据微电网的动态特性, 基于功率平衡方程和储能状态的迭代方程, 取向量 $\mathbf{x}(t) =$

$[P_{MT}(t), P_{DE}(t), P_b(t), S_{OC}(t), P_g(t)]^T$ 为状态输入变量, $\mathbf{u}(t) = [\Delta P_{MT}(t), \Delta P_{DE}(t), \Delta P_b(t)]^T$ 为控制变量, $\mathbf{r}(t) = [\Delta P_{WT}(t), \Delta P_{PV}(t), \Delta P_{Load}(t)]^T$ 为扰动输入变量, $\mathbf{y}(t) = [P_g(t), S_{OC}(t)]^T$ 为输出变量。其中: $P_{MT}(t)$ 为微型燃气轮机的输出功率; $P_{DE}(t)$ 为柴油发电机的输出功率; $\Delta P_{MT}(t)$ 、 $\Delta P_{DE}(t)$ 、 $\Delta P_b(t)$ 分别为其对应微源的增量; $\Delta P_{WT}(t)$ 、 $\Delta P_{PV}(t)$ 、 $\Delta P_{Load}(t)$ 分别为风电、光伏和负荷的预测功率增量。

根据上述所取向量, 可以建立如式(9)所示的多输入多输出状态空间模型。

$$\mathbf{x}(t + \Delta t) = \mathbf{A} \cdot \mathbf{x}(t) + \mathbf{B} \cdot \mathbf{u}(t) + \mathbf{C} \cdot \mathbf{r}(t) \quad (9)$$

式中: \mathbf{A} 、 \mathbf{B} 、 \mathbf{C} 表示满足功率平衡方程和储能 SOC 迭代方程的系数矩阵。

通过可再生能源和负荷需求的短期预测数据, 对状态方程进行迭代, 得到某一时刻向前 p 步的预测状态空间模型, 如式(10)所示。

$$\mathbf{X}(t) = \begin{bmatrix} \mathbf{x}(t|t) \\ \mathbf{x}(t + \Delta t|t) \\ \mathbf{x}(t + 2\Delta t|t) \\ \vdots \\ \mathbf{x}(t + p\Delta t|t) \end{bmatrix} = \mathbf{E} \mathbf{x}(t|t) + \mathbf{F} \begin{bmatrix} \mathbf{u}(t|t) \\ \mathbf{u}(t + \Delta t|t) \\ \mathbf{u}(t + 2\Delta t|t) \\ \vdots \\ \mathbf{u}(t + p\Delta t|t) \end{bmatrix} + \mathbf{G} \begin{bmatrix} \mathbf{r}(t|t) \\ \mathbf{r}(t + \Delta t|t) \\ \mathbf{r}(t + 2\Delta t|t) \\ \vdots \\ \mathbf{r}(t + p\Delta t|t) \end{bmatrix} \quad (10)$$

式中: \mathbf{E} 、 \mathbf{F} 、 \mathbf{G} 为关于 \mathbf{A} 、 \mathbf{B} 、 \mathbf{C} 的矩阵。

输出变量 $\mathbf{y}(t)$ 如式(11)所示。

$$\mathbf{y}(t) = \begin{bmatrix} P_g(t) \\ S_{OC}(t) \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 & 0 \end{bmatrix} \times \quad (11)$$

$$[P_{MT}(t) \ P_{DE}(t) \ P_b(t) \ S_{OC}(t) \ P_g(t)]^T = \mathbf{D} \times \mathbf{x}(t)$$

式中: \mathbf{D} 为常数矩阵。

$\mathbf{y}(t)$ 在向前预测 $p\Delta t$ 时段内的输出值构成的向量 \mathbf{Y} 如式(12)所示。

$$\mathbf{Y} = [P_g(t + \Delta t), S_{OC}(t + \Delta t), \dots, P_g(t + p\Delta t), S_{OC}(t + p\Delta t)]^T \quad (12)$$

为了降低日前预测中可再生能源和负荷等不确定性因素的影响, 取 t 时刻向前 $p\Delta t$ 时段日前计划的联络线功率和储能 SOC 构成的向量 \mathbf{R}_d 为跟踪目标。

$$\mathbf{R}_d = [P_g^{\text{ref}}(t + \Delta t), S_{OC}^{\text{ref}}(t + \Delta t), \dots, P_g^{\text{ref}}(t + p\Delta t), S_{OC}^{\text{ref}}(t + p\Delta t)]^T \quad (13)$$

式中: $P_g^{\text{ref}}(t)$ 和 $S_{\text{OC}}^{\text{ref}}(t)$ 分别为 t 时刻的联络线功率和储能 SOC 的日前计划参考值。

在跟踪日前计划联络线功率和 SOC 的同时, 尽可能减小各可控机组的出力增量, 建立目标函数及约束条件如式(14)所示。

$$\begin{cases} \min J_{\text{in-d}} = (\mathbf{R}_d - \mathbf{Y})^T \mathbf{Q}_{\text{err}} (\mathbf{R}_d - \mathbf{Y}) + \mathbf{U}^T \mathbf{Q}_u \mathbf{U} \\ \text{s. t. } \Delta P_{G_i-\min} \leq P_{G_i}(t) \leq \Delta P_{G_i-\max} \\ P_{G_i-\min} \leq P_{G_i}(t) \leq P_{G_i-\max} \\ S_{\text{OC}-\min} \leq S_{\text{OC}}(t) \leq S_{\text{OC}-\max} \end{cases} \quad (14)$$

式中: $J_{\text{in-d}}$ 为目标值, 代表跟踪误差和机组出力增量的适应度值, 此值较小代表机组以最小的出力变化达到最佳的跟踪效果; \mathbf{Q}_{err} 和 \mathbf{Q}_u 分别为跟踪误差和机组出力增量的权重系数矩阵; \mathbf{U} 为控制向量, 表示各可控机组的出力增量。

即使经过优化层的优化控制, 实际输出功率与预测控制值之间仍会存在差异, 这种差异会影响电网的调度, 增加系统不稳定性的风险。因此须在修正层引入反馈校正环节, 通过实时监测和动态调整, 在一定程度上弥补预测误差, 提高功率预测的精度。反馈校正机制的核心在于以日前实际功率为起点, 进行新一轮的滚动优化, 形成一个闭环控制系统。其优势在于它能够不断地校正预测值来提高功率预测的准确性, 使其更贴近实际情况。

$$P_0(t + \Delta t) = P_{\text{real}}(t + \Delta t) \quad (15)$$

式中: $P_0(t + \Delta t)$ 为 $t + \Delta t$ 时刻有功出力初始值; $P_{\text{real}}(t + \Delta t)$ 为在 t 时刻下发了有功预测输出值后, 通过实际测量获得的 $t + \Delta t$ 时刻的实际有功输出值。

2 蜣螂优化算法的改进

2.1 传统蜣螂优化算法的问题

蜣螂优化算法(dung beetle optimizer, DBO)中, 不同的子种群执行不同的搜索方法, 能够实现对解空间的高效探索和开发, 与大多数优化算法相比, 其具有更高的计算精度、更快的收敛速度和更强的稳定性等优点^[20]。但该算法还有以下不足: 1) 由于个体之间没有信息交流, 易陷入局部最优; 2) 个体位置更新时没有考虑步长的自适应变化, 导致全局探索和局部开发能力不平衡; 3) 种群初始化时在解空间的分布过于随机, 导致搜索范围小; 4) 面对复杂问题时求解精度低, 收敛速度慢。

基于上述问题, 本文融合了鱼鹰优化算法^[21], 并引入自适应 t 分布扰动策略, 采用混沌映射方法对群体进行初始化, 并加入自适应混合变异扰动, 提出了融合鱼鹰自适应扰动的蜣螂优化算法(osprey T-adaption chaotic mutation DBO, OTcmDBO), 下面

对算法的改进过程进行说明。

2.2 改进过程

2.2.1 种群初始化的改进

混沌映射是一种结合了确定性和不可预测性的复杂动态系统^[22-23]。利用混沌映射的特性, 可以提高智能算法的搜索性能, 避免局部最优陷阱, 找到更优的解决方案。

Bernoulli 映射作为一种典型的混沌映射方法, 可用于初始化蜣螂个体位置。首先生成混沌序列, 然后根据这些混沌序列对个体位置进行初始化, 确保初始种群具有较好的覆盖性和多样性。Bernoulli 映射表达式为

$$X_{i+1} = \begin{cases} \frac{X_i}{1-\alpha}, & 0 \leq X_i \leq 1-\alpha \\ \frac{X_i - (1-\alpha)}{\alpha}, & 1-\alpha \leq X_i \leq 1 \end{cases} \quad (16)$$

式中: X_i 是第 i 只蜣螂个体的初始位置; α 是控制参数, $\alpha \in (0, 1)$ 。为取得较好的映射种群, 在本文中取 $\alpha = 0.518$, $X_0 = 0.326$ 。

2.2.2 滚球行为的改进

由于蜣螂优化算法在滚球行为中只依赖最差值, 无法及时与其他蜣螂进行交流, 且参数较多, 而采用鱼鹰优化算法的全局勘探策略, 每次迭代都与粪球组进行信息交流(粪球组对应鱼鹰的鱼组, 是比当前蜣螂位置适应度好的所有滚球蜣螂的位置集合), 随机检测其中一个粪球的位置进行迭代, 提升了全局探索能力。因此, 可以用鱼鹰优化算法改进蜣螂的滚球行为。位置更新公式为

$$X_i(n+1) = X_i(n) + r_1 \cdot [S_{F_i}(n) - I \cdot X_i(n)] \quad (17)$$

式中: n 为当前迭代次数; $X_i(n)$ 为第 n 次迭代时第 i 只蜣螂的位置信息; $S_{F_i}(n)$ 为第 n 次迭代时第 i 只蜣螂选中的粪球; r_1 为 $[0, 1]$ 之间的随机数; $I \in \{1, 2\}$ 。

融合鱼鹰优化算法的全局勘探策略后, 每个个体都会与粪球组进行信息交流, 给蜣螂的移动引入了指引机制, 弥补了蜣螂在滚球阶段过于随机的不足。

2.2.3 觅食行为的改进

算法收敛性和多样性在一定程度上会相互矛盾^[24], 算法收敛性与多样性的平衡被蜣螂的觅食阶段一定程度上控制着。在算法迭代的初期, 需要提高算法的多样性, 增加算法的全局搜索能力, 充分探索解空间; 而到算法迭代的中后期, 权重会慢慢偏向收敛性, 加快算法的收敛速度。为此, 本文采用一种自适应 t 分布扰动策略。位置更新表达式为

$$X_i(n+1) = X_i(n) + T(n) \cdot X_i(n) \quad (18)$$

式中: $T(n)$ 为以种群迭代次数为自由度参数的自适

应 t 分布函数。

采用上述自适应 t 分布变异算子, 可以显著提升算法的优化性能。然而, 如果盲目应用于每次迭代中的所有个体, 不仅会增加算法计算时间, 还会削弱其原有特点。为了应对这一问题, 可以通过自适应选择概率 q 调整自适应 t 分布变异算子的使用, 以减轻这种策略对算法优化能力的影响。具体的自适应选择概率公式为

$$q = \omega_1 - \omega_2 \times (T_{\max} - n) / T_{\max} \quad (19)$$

式中: T_{\max} 为最大迭代次数; ω_1 为选择概率的上限; ω_2 为选择变化的幅度。本文中取 $\omega_1 = 0.5$, $\omega_2 = 0.1$, 以达到调节作用最优^[25]。

2.2.4 对最优解的变异扰动

变异算子在智能优化算法中起到增强种群多样性、避免陷入局部极小值的作用。常见的变异算子包括柯西变异和高斯变异, 柯西变异具有搜索范围广但容易跳离最优值的特点, 而高斯变异在小范围内搜索能力较好, 但全局搜索能力较弱, 各自具有一定的优缺点^[26]。为弥补柯西变异与高斯变异的不足, 本文提出了一种基于高斯-柯西的自适应混合变异扰动策略。通过对最优个体的变异扰动, 智能优化算法能够在平衡搜索范围和搜索精度的同时, 提高全局搜索能力。具体公式为

$$\mathbf{H}(n) = \mathbf{X}_b(n) \cdot (1 + \lambda_1 \times G_{\text{auss}} + \lambda_2 \times C_{\text{auchy}}) \quad (20)$$

式中: $\mathbf{H}(n)$ 为扰动后的位置; $\mathbf{X}_b(n)$ 为种群 \mathbf{X} 在第 n 次迭代时的最优位置; λ_1 和 λ_2 为变异算子权重, $\lambda_1 = n / T_{\max}$, $\lambda_2 = 1 - n / T_{\max}$, λ_1 和 λ_2 随迭代次数的变化线性变化, 具有自适应性; G_{auss} 为高斯变异算子; C_{auchy} 为柯西变异算子, 其值为 $-1 / \tan(k\pi)$, k 为随机数, $k \in [0, 1]$ 。

2.3 OTcmDBO 性能测试

为了评估算法改进后的性能, 将 OTcmDBO 算法与 GWO、PSO、SSA 和 DBO 算法进行比较, 表 1 给出了 CEC2021 测试集部分函数的范围和最小值, F_1 和 F_2 是单峰函数, F_3 和 F_4 是多峰函数, F_5 和 F_6 是混合函数, 测试函数的表达式如式(21)所示。

表 1 测试函数

Table 1 Test function

函数	范围	最小值
F_1	[-10, 10]	0
F_2	[-100, 100]	0
F_3	[-5.12, 5.12]	0
F_4	[-32, 32]	0
F_5	[-65, 65]	1
F_6	[-2, 2]	3

$$\left\{ \begin{aligned} F_1 &= \sum_{i=1}^n |x_i| + \prod_{i=1}^n |x_i| \\ F_2 &= \max \{ |x_i|, 1 \leq i \leq n \} \\ F_3 &= \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10] \\ F_4 &= -20 \exp \left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right) - \\ &\quad \exp \left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i) \right) + 20 + e \\ F_5 &= \left(\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6} \right)^{-1} \\ F_6 &= [1 + (x_1 + x_2 + 1)^2 (19 - 14x_1 + 3x_1^2 - 14x_2 + \\ &\quad 6x_1x_2 + 3x_2^2)] \times [30 + (2x_1 - 3x_2)^2 \times \\ &\quad (18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)] \end{aligned} \right. \quad (21)$$

评价指标为 30 次独立重复实验的平均最优适应度值 M 和标准差 S_{id} , 分别用于评估算法的搜索精度和稳定性, 其计算公式为

$$\left\{ \begin{aligned} M &= \frac{1}{N'} \sum_{i=1}^{N'} f_i \\ S_{\text{id}} &= \sqrt{\frac{1}{N'-1} \sum_{i=1}^{N'} (f_i - M)^2} \end{aligned} \right. \quad (22)$$

式中: N' 为实验重复次数; f_i 为第 i 次独立运行的最优适应度值。评价指标对比如表 2 所示, 收敛曲线如图 4 所示。

从表 2 和图 4 可以看出, 对于单峰函数 F_1 和 F_2 , 相较于其他优化算法, OTcmDBO 未陷入局部最优, 平均最优适应度值和标准差都是最小。对于多峰函数 F_3 和 F_4 , OTcmDBO 和 SSA 优化算法都能达到最优解, 但 OTcmDBO 的收敛速度大大加快。对于混合函数 F_5 和 F_6 , F_5 中 OTcmDBO 收敛效果最好, F_6 中 OTcmDBO 收敛速度最快。

3 基于 OTcmDBO 的三层优化调度模型的优化与求解

OTcmDBO 算法对模型的优化体现在调度层的经济性优化, 以最优经济成本为目标函数进行优化; 对模型的求解体现在优化层和修正层的滚动优化, 以跟踪联络线功率和储能 SOC 为目标函数, 求解可控机组的最优控制序列。将本文算法应用到模型的优化与求解中, 流程如图 5 所示。

表 2 评价指标对比
Table 2 Evaluation index comparison

测试函数	OTcmDBO		GWO		PSO		SSA		DBO	
	M	S_{id}	M	S_{id}	M	S_{id}	M	S_{id}	M	S_{id}
F_1	0	0	0.02	0.01	24.28	6.88	2.48×10^{-21}	1.06×10^{-20}	7.49×10^{-10}	3.65×10^{-9}
F_2	0	0	1.31	0.55	8.31	1.98	2.49×10^{-20}	1.11×10^{-19}	4.58×10^{-8}	1.71×10^{-7}
F_3	0	0	32.75	9.51	146.55	47.33	0	0	0.95	3.81
F_4	4.44×10^{-16}	0	0.02	0.01	5.81	0.58	3.81×10^{-16}	4.01×10^{-16}	3.89×10^{-10}	1.73×10^{-9}
F_5	1.16	0.53	5.72	4.93	2.74	1.86	7.56	5.48	2.54	2.26
F_6	3	2.9×10^{-15}	3	9.08×10^{-4}	3.02	0.02	4.8	6.85	3	6.73×10^{-15}

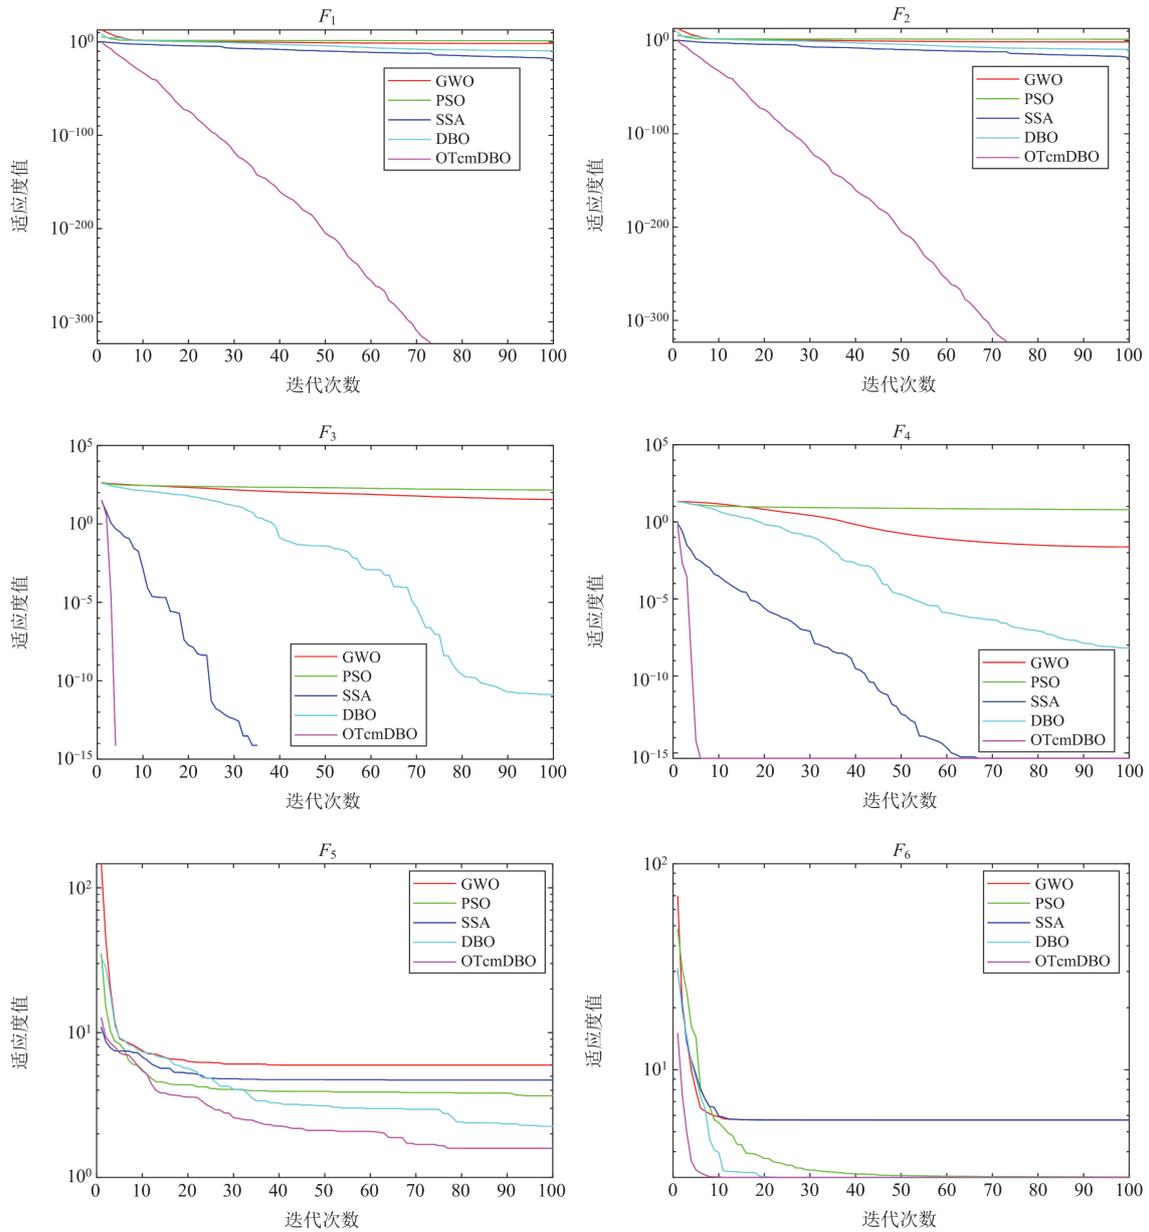


图 4 测试函数的收敛曲线
Fig. 4 Convergence curve of test function

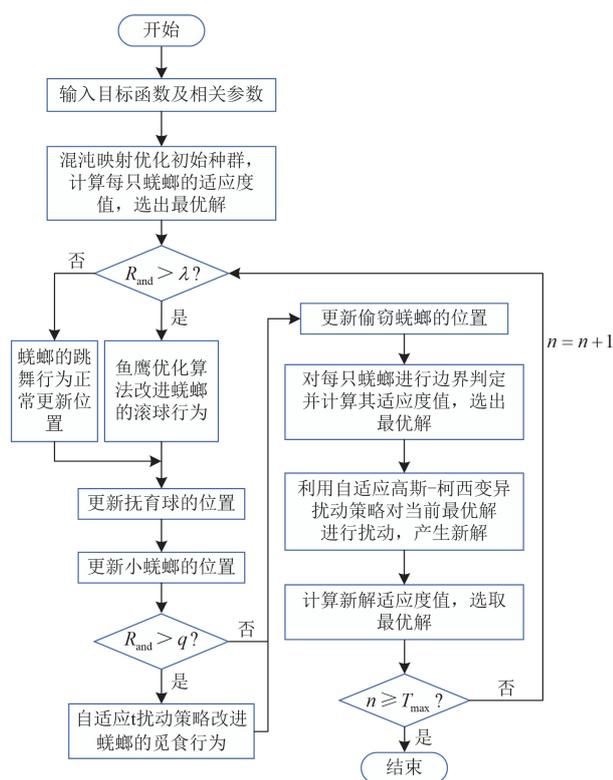


图5 OTcmDBO 算法的流程图

Fig. 5 Flow chart of OTcmDBO algorithm

具体优化步骤如下。

1) 输入目标函数及相关约束条件, 用式(16)初始化螻蛄种群, 计算每个个体的适应度值并选出最优个体。

2) 根据随机数 R_{and} 来判断是螻蛄的跳舞行为还是改进的滚球行为来更新位置, $R_{\text{and}} \in [0,1]$, 由原始算法取选择行为的概率 $\lambda = 0.9$ 。

3) 由繁殖行为和觅食行为更新抚育球和小螻蛄位置后, 将新随机数 R_{and} 与式(19)中的自适应选择概率 q 进行比较, 若符合判据则用式(18)更新小螻蛄的位置, 最后更新偷窃螻蛄的位置, 增加多样性。

4) 计算适应度值, 选出最优解, 用式(20)对最优解进行变异扰动并计算其适应度值, 选取最优解。

5) 判断算法是否达到最大迭代次数, 若未达到最大迭代次数, 则重新执行步骤 2)~步骤 4); 若达到最大迭代次数, 则结束循环, 最优解即是各机组最优出力或最优控制序列。

4 算例分析与验证

4.1 算例参数

本文数据取自于山西省某微网一天的实际日前预测值, 其趋势既符合普遍发用电情况, 又具有

相当的波动性, 可以在一定程度上体现所提模型与算法的普遍性。采用有微型燃气轮机(MT)、柴油发电机(DE)、风电机组(WT)、光伏机组(PV)、储能装置(BESS)和配电网(Grid)的多源微电网三层优化调度模型来进行算例分析, 表 3 列出了各机组参数, 表 4 列出了污染物排放系数及成本, 表 5 列出了储能装置的参数。实时电价参考文献[27]。

表 3 机组参数

Table 3 Unit parameters

参数名称	MT	DE	WT	PV	Grid
功率上限/kW	30	40	100	50	30
功率下限/kW	3	6	0	0	-30
爬坡速率上限/(kW/s)	1.5	1.5	0	0	0
运维单价/(元/kWh)	0.0293	0.128	0	0	0

表 4 污染物排放系数及成本

Table 4 Discharge coefficient and cost of pollutants

污染物类型	治理费用/(元/kg)	污染物排放系数/(g/kWh)				
		MT	DE	WT	PV	Grid
CO ₂	0.023	724	680	0	0	889
SO ₂	6	0.0036	0.306	0	0	1.8
NO _x	8	0.2	10.09	0	0	1.6

表 5 储能装置参数

Table 5 Energy storage parameters

类型	参数	数值
蓄电池	最大容量/kWh	150
	最小容量/kWh	5
	最大输入功率/kW	30
	初始储能容量/kWh	80
	最大输出功率/kW	30
	充放电效率	0.9

微电网的风电、光伏和负荷的日前预测数据如图 6 所示。

4.2 结果分析

4.2.1 日前调度经济性对比分析

分别采用 OTcmDBO 算法、DBO 算法和 SSA 算法对日前调度的经济性进行优化。3 种算法的参数相同: 种群的个数为 100, 迭代 300 次, 各独立运行 30 次。3 种算法的平均最优收敛曲线对比如图 7 所示, 最优经济成本下各机组出力情况如图 8 所示。

从图 7 可以看出, SSA 算法收敛速度较慢, DBO 算法容易陷入局部最优值, 而 OTcmDBO 算法不仅具有更好的全局探索能力, 而且收敛速度也更快, 经济性也比 DBO 算法优化后提升了 4.3%, 证明了 OTcmDBO 算法在微电网经济调度优化中的有效性和快速性。

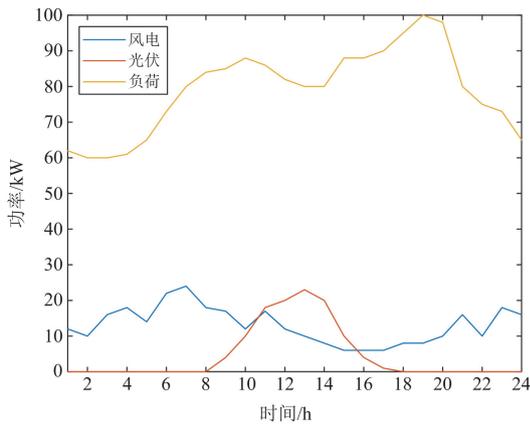


图 6 风电、光伏和负荷功率预测值

Fig. 6 Wind power, PV and load power forecast

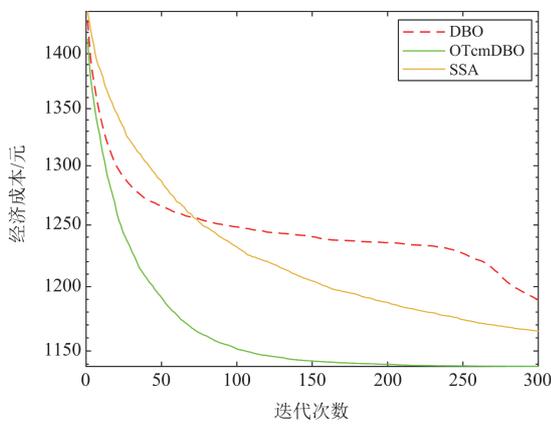


图 7 3 种算法的经济性收敛曲线

Fig. 7 Economic convergence curves of three algorithms

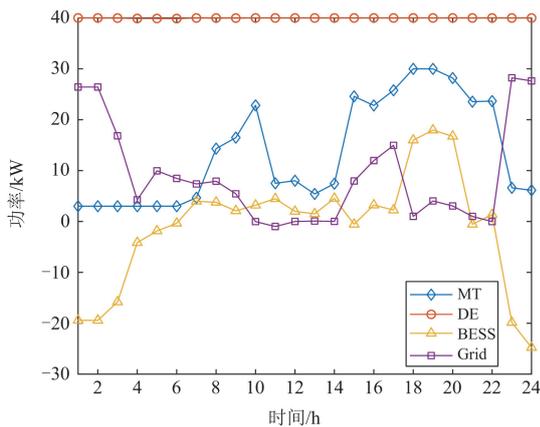


图 8 最优经济成本下各机组出力

Fig. 8 Output of each unit at optimal economic cost

从图 8 可以看出，为满足负荷需求，微电网首先用柴油发电机发电，这是因为考虑到发电成本、运维成本以及环境保护成本的综合影响，燃气轮机

的成本和峰时电价均高于柴油发电机(单论环境保护成本，由表 4 可知 MT 的成本低于 DE)。此外，为了优化运行的经济性，在 0~6 h 电价谷时段内，除了满足负荷需求外，风电机组、光伏以及电网还会适当地向储能系统充电，以备后续合适时机的放电。而在图中的 17~21 h 时段，负荷用电量，属于电价峰时段，因此在这段时间内，主要依赖燃气轮机和柴油发电机供电，同时储能系统也相应地进行放电。

4.2.2 日内滚动优化调度分析

为增强普适性，本文假定对风能、光伏系统和负荷的长短期预测功率模拟，是通过在日前预测输出功率上叠加正态分布来完成的(可通过双向长短期记忆网络法、人工智能等方法进行预测^[28-29])。优化层每 15 min 启动一次，预测时长为 1 h，共滚动优化 96 次；修正层每 5 min 启动一次，预测时长为 15 min，共滚动优化 288 次。

滚动优化调整后得到的各机组出力如图 9 所示。文中以微电网的联络线功率和储能 SOC 计划跟踪误差最小为目标，求解各机组的最优控制序列。为了解决风电、光伏和负荷在日前调度阶段产生的干扰，优化层调整了日前调度计划，取得了显著的改善；修正层又实时跟踪优化层的联络线功率，对优化层的调度计划进行了修正，解决了实际产生的各种微小干扰。

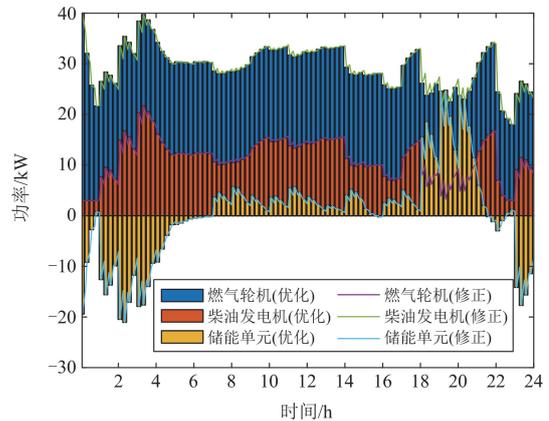


图 9 优化修正各机组出力

Fig. 9 Output of each unit after optimization and correction

4.2.3 控制效果对比分析

为了验证所提模型能够改善微电网的调度性能，参考日前计划值，将优化层对计划值、修正层对优化层的联络线功率跟踪和不优化进行对比，将优化层对计划值、修正层对优化层的储能 SOC 功率的跟踪情况进行对比，将本文模型和现有调度模型

进行对比。图 10 是大电网的交互功率跟踪情况对比, 图 11 是储能 SOC 的跟踪情况对比, 图 12 是不同模型优化结果的对比。

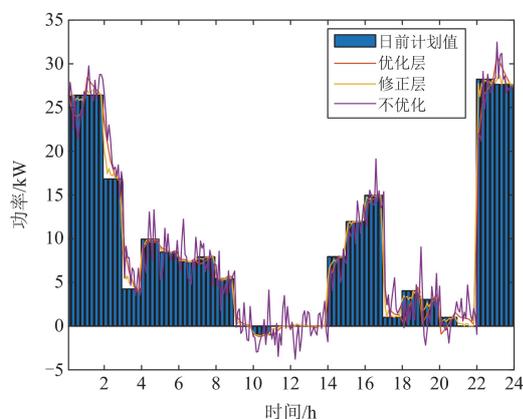


图 10 联络线功率跟踪效果对比

Fig. 10 Effect comparison of contact line power tracking

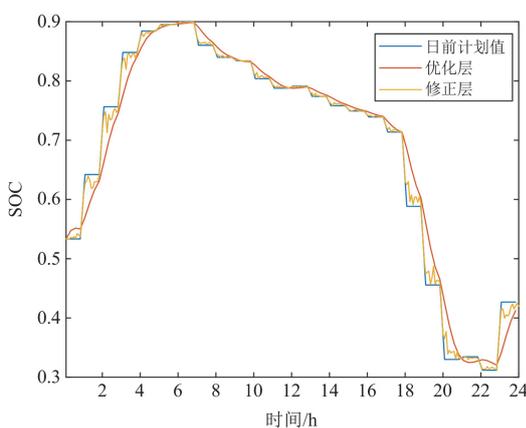
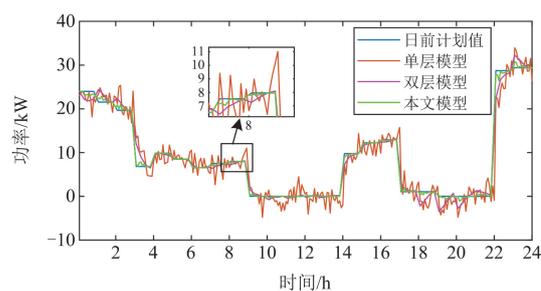


图 11 储能 SOC 跟踪效果对比

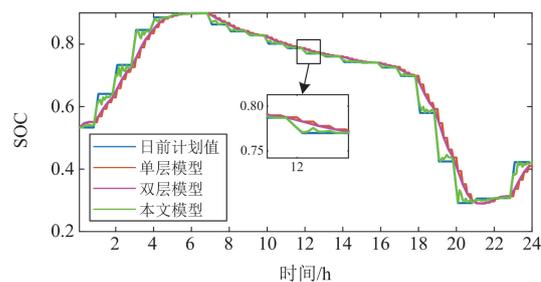
Fig. 11 Effect comparison of energy storage SOC tracking

由图 10 可以看出, 在没有日内分层调度优化的情况下, 由于微电网的联络线功率波动剧烈, 导致电网平衡状态频繁变化, 从而难以实现稳定和可控的调度。但是, 通过引入分层调度优化, 联络线功率的波动得到了有效的平抑, 联络线功率能够与日前计划值基本保持一致。这表明, 分层调度优化能够有效地减少实际功率输出与预测值之间的偏差, 从而提高系统的可控性和稳定性。

由图 11 可以看出, 使用 OTcmDBO 算法进行优化和求解所提出的基于 MPC 的三层调度模型, 无论是优化层还是修正层, SOC 的跟踪曲线都能够较好地跟随目标曲线, 这表明本文提出的三层优化调度模型是有效的, 它实现了微电网接入配电网的平稳和可控调度, 同时保证了计算效率和系统的稳定性。



(a) 联络线的交换功率



(b) 储能系统的 SOC 值

图 12 不同模型优化结果的对比

Fig. 12 Comparison of optimization results of different models

由图 12 可以看出, 本文所提出的三层优化调度模型能够更精细地处理不同时间尺度的调度问题, 有效平抑联络线功率波动, 提高系统的可控性和稳定性, 相比现有的调度模型(通常采用单层或双层结构), 该模型在优化调度效果上表现更优, 提高了调度的灵活性和准确性。

综上所述, 本文所提的三层优化调度模型相较于现有调度模型有较强的优越性。主要体现在: 在日前调度经济性方面, 通过 OTcmDBO 算法优化, 降低了系统的经济成本; 在日内滚动优化方面, 有效降低了可再生能源和负荷预测的不确定性影响, 提高了调度计划的准确性和灵活性; 在控制效果方面, 通过分层调度和实时反馈校正, 提升了系统的可控性和稳定性。本文模型及算法有效解决了微电网中由于低经济性、间歇性、不确定性和实时性差等导致的调度问题, 对未来提高微电网的经济性、稳定性和运行效率提供了技术参考。

5 结论

本文提出了一种新型微电网三层优化调度模型, 通过理论分析和仿真验证, 得到结论如下。

1) 构建了一种“调度-优化-修正”的新型微电网三层优化调度模型, 该模型通过综合考虑分时电价、环境污染成本及可再生能源与负荷的不确定性, 实现了微电网在不同时间尺度下的精细化调度, 有

效提升了微电网的经济性和稳定性。

2) 通过改进传统蜚螂优化算法的种群初始化、滚球行为、觅食行为, 基于自适应混合变异扰动提出一种 OTcmDBO 算法。该算法具有搜索精度高、收敛速度快、全局探索能力强等优点, 为微电网的优化调度提供了高效可靠的求解方案。

3) OTcmDBO 算法与三层模型深度融合, 在调度层, 优化了系统整体的经济成本, 降低了约 4.3% 的日运行费用; 在优化层和修正层, 滚动求解与实时反馈校正有效解决了间歇性能源与负荷的预测偏差。模型与算法的协同作用兼顾了经济调度与动态调控需求, 在降低碳排放、提升可再生能源利用率的同时, 增强了系统的经济性、可控性及稳定性。

参考文献

- [1] 程杉, 傅桐, 李泮洋, 等. 含高渗透可再生能源的配电网灵活性供需协同规划[J]. 电力系统保护与控制, 2023, 51(22): 1-12.
CHENG Shan, FU Tong, LI Fengyang, et al. Flexible supply demand collaborative planning for distribution networks with high penetration of renewable energy[J]. Power System Protection and Control, 2023, 51(22): 1-12.
- [2] 徐雨舟, 唐忠. 含 CSPP 的区域多能源微网优化调度模型[J]. 智慧电力, 2024, 52(10): 24-31.
XU Yuzhou, TANG Zhong. Optimal scheduling model of regional multi-energy microgrid containing concentrating solar power plant[J]. Smart Power, 2024, 52(10): 24-31.
- [3] DASHTAKI A A, HAKIMI S M, HASANKHANI A, et al. Optimal management algorithm of microgrid connected to the distribution network considering renewable energy system uncertainties[J]. International Journal of Electrical Power & Energy Systems, 2023, 145.
- [4] 金文, 方登洲, 李鸿鹏, 等. 共享自有储能模式下多微电网协同鲁棒调度与效益分配[J]. 智慧电力, 2024, 52(11): 56-63, 97.
JIN Wen, FANG Dengzhou, LI Hongpeng, et al. Cooperative robust scheduling and benefit allocation for multiple microgrid under shared owned energy storage mode[J]. Smart Power, 2024, 52(11): 56-63, 97.
- [5] 邵蓝铨, 万灿, 张晓波, 等. 考虑不确定性与交互功率的城市综合能源系统两阶段调度[J]. 电力系统自动化, 2023, 47(9): 59-69.
SHAO Lanxin, WAN Can, ZHANG Xiaobo, et al. Two-stage dispatching for urban integrated energy system considering uncertainty and interactive power[J]. Automation of Electric Power Systems, 2023, 47(9): 59-69.
- [6] 贾士铎, 康小宁, 黑皓杰, 等. 基于 V2G 负荷反馈修正的电热氢综合能源系统多层协调优化调度[J]. 电力系统自动化, 2023, 47(15): 100-110.
JIA Shiduo, KANG Xiaoning, HEI Haojie, et al. Multi-layer coordinated optimal dispatch of electric-thermal-hydrogen integrated energy system based on V2G load feedback correction[J]. Automation of Electric Power Systems, 2023, 47(15): 100-110.
- [7] 刘晓雄, 蔺红. 基于模型预测控制的源荷储低碳经济调度[J]. 电测与仪表, 2024, 61(7): 153-160.
LIU Xiaoxiong, LIN Hong. Low-carbon economic dispatching of source, charge and storage based on model predictive control[J]. Electrical Measurement & Instrumentation, 2024, 61(7): 153-160.
- [8] GORBACHEV S, GUO J, MANI A, et al. MPC-based LFC for interconnected power systems with PVA and ESS under model uncertainty and communication delay[J]. Protection and Control of Modern Power Systems, 2023, 8(4): 869-885.
- [9] 热依娜·马合苏提, 周玮, 彭飞翔, 等. 考虑端对端交易与预测误差的配电网实时能量平衡策略[J]. 电力系统保护与控制, 2023, 51(23): 1-15.
REYINA·Mahesuti, ZHOU Wei, PENG Feixiang, et al. Real-time energy balancing strategy for distribution networks considering peer-to-peer trading and prediction errors[J]. Power System Protection and Control, 2023, 51(23): 1-15.
- [10] 胡剑, 林耀玮, 阎发友, 等. 考虑光热电站接入的电力系统双层双时间尺度优化调度[J]. 电力系统保护与控制, 2022, 50(13): 23-32.
HU Jian, LIN Yaowei, YAN Fayou, et al. Two-layer double-time scale optimal dispatch for a power system considering concentrating solar power plant penetration[J]. Power System Protection and Control, 2022, 50(13): 23-32.
- [11] 王振浩, 马爽, 李国庆, 等. 考虑复合储能电站接入的电网日前-日内两阶段滚动优化调度[J]. 太阳能学报, 2022, 43(10): 400-408.
WANG Zhenhao, MA Shuang, LI Guoqing, et al. Day-ahead and intra-day two-stage rolling optimal dispatch of power grid considering access of composite energy storage power stations[J]. Acta Energetica Sinica, 2022, 43(10): 400-408.
- [12] 杨明杰, 胡扬宇, 千海霞, 等. 计及碳排放的综合能源配电网日前与日内多时间尺度优化调度[J]. 电力系统保护与控制, 2023, 51(5): 96-106.
YANG Mingjie, HU Yangyu, QIAN Haixia, et al. Optimization of day-ahead and intra-day multi-time scale scheduling for integrated power-gas energy system considering carbon emission[J]. Power System Protection and Control, 2023, 51(5): 96-106.
- [13] HOU J, YU W, XU Z, et al. Multi-time scale optimization scheduling of microgrid considering source and load uncertainty[J]. Electric Power Systems Research, 2023, 216.

- [14] 于越, 葛磊蛟, 金朝阳, 等. 考虑天气特征与多变量相关性的配电网短期负荷预测[J]. 电力系统保护与控制, 2024, 52(6): 131-141.
YU Yue, GE Leijiao, JIN Zhaoyang, et al. Short-term load prediction method of distribution networks considering weather features and multivariate correlations[J]. Power System Protection and Control, 2024, 52(6): 131-141.
- [15] FU S, SUN H, LIU Z, et al. Model predictive control for nonlinear systems with two-time scales[J]. IEEE Transactions on Automation Science and Engineering, 2024, 21(4): 5088-5098.
- [16] 叶林, 程文丁, 李卓, 等. 光伏集群有功功率分层预测控制策略[J]. 电力系统自动化, 2023, 47(2): 42-52.
YE Lin, CHENG Wending, LI Zhuo, et al. Hierarchical prediction control strategy of active power for photovoltaic cluster[J]. Automation of Electric Power Systems, 2023, 47(2): 42-52.
- [17] HU K, WANG B, CAO S, et al. A novel model predictive control strategy for multi-time scale optimal scheduling of integrated energy system[J]. Energy Reports, 2022, 8: 7420-7433.
- [18] QIU Yibin, LI Qi, AI Yuxuan, et al. Two-stage distributionally robust optimization-based coordinated scheduling of integrated energy system with electricity-hydrogen hybrid energy storage[J]. Protection and Control of Modern Power Systems, 2023, 8(2): 542-555.
- [19] DEY B, MISRA S, MARQUEZ F P G. Microgrid system energy management with demand response program for clean and economical operation[J]. Applied Energy, 2023, 334.
- [20] XUE J, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [21] DEGHANI M, TROJOVSKÝ P. Osprey optimization algorithm: a new bio-inspired metaheuristic algorithm for solving engineering optimization problems[J]. Frontiers in Mechanical Engineering, 2023, 8.
- [22] 刘磊, 姜博文, 周恒扬, 等. 融合改进 Sine 混沌映射的新型粒子群优化算法[J]. 西安交通大学学报, 2023, 57(8): 182-193.
LIU Lei, JIANG Bowen, ZHOU Hengyang, et al. A novel particle swarm optimization algorithm incorporating improved sine chaos mapping[J]. Journal of Xi'an Jiaotong University, 2023, 57(8): 182-193.
- [23] 马宽, 何国锋, 董燕飞, 等. 基于多策略改进 PSO 算法的微电网优化调度研究[J]. 智慧电力, 2023, 51(8): 23-29, 45.
MA Kuan, HE Guofeng, DONG Yanfei, et al. Microgrid optimal scheduling based on multi-strategy improved PSO algorithm[J]. Smart Power, 2023, 51(8): 23-29, 45.
- [24] 张丽, 刘雨航, 贾晨豪, 等. 基于多分区自适应改进果蝇算法的风光燃储微电网协调控制策略[J]. 电力系统保护与控制, 2023, 51(22): 13-23.
ZHANG Li, LIU Yuhang, JIA Chenhao, et al. A coordinated control strategy for a wind/photovoltaic/gas turbine/storage microgrid based on a multi-partition adaptive improved fruit fly algorithm[J]. Power System Protection and Control, 2023, 51(22): 13-23.
- [25] 常雨芳, 杨子潇, 潘风, 等. 基于 CEEMDAN-PE-WPD 和多目标优化的超短期风电功率预测方法[J]. 电网技术, 2023, 47(12): 5015-5026.
CHANG Yufang, YANG Zixiao, PAN Feng, et al. Ultra-short-term wind power prediction based on CEEMDAN-PE-WPD and multi-objective optimization[J]. Power System Technology, 2023, 47(12): 5015-5026.
- [26] 付华, 刘昊. 多策略融合的改进麻雀搜索算法及其应用[J]. 控制与决策, 2022, 37(1): 87-96.
FU Hua, LIU Hao. Improved sparrow search algorithm with multi-strategy integration and its application[J]. Control and Decision, 2022, 37(1): 87-96.
- [27] 张婕, 孙伟卿, 刘唯. 考虑需求响应收益的售电商实时电价决策模型[J]. 电网技术, 2022, 46(2): 492-504.
ZHANG Jie, SUN Weiqing, LIU Wei. Real time pricing considering demand response revenue of electricity sellers[J]. Power System Technology, 2022, 46(2): 492-504.
- [28] 张丽, 李世情, 艾恒涛, 等. 基于改进 Q 学习算法和组合模型的超短期电力负荷预测[J]. 电力系统保护与控制, 2024, 52(9): 143-153.
ZHANG Li, LI Shiqing, AI Hengtao, et al. Ultra-short-term power load forecasting based on an improved Q-learning algorithm and combination model[J]. Power System Protection and Control, 2024, 52(9): 143-153.
- [29] ZHU Suxun, MA Hengrui, CHEN Laijun, et al. Short-term load forecasting of an integrated energy system based on STL-CPLE with multitask learning[J]. Protection and Control of Modern Power Systems, 2024, 9(6): 71-92.

收稿日期: 2024-12-31; 修回日期: 2025-04-19

作者简介:

张丽(1982—), 女, 博士, 副教授, 硕士生导师, 主要研究方向为电网需求侧响应、智能用电技术; E-mail: dqzhangli@hpu.edu.cn

贾晨豪(1998—), 男, 通信作者, 硕士研究生, 主要研究方向为综合能源系统优化调度与协调控制。E-mail: 976066423@qq.com

(编辑 周金梅)