

DOI: 10.19783/j.cnki.pspc.250768

基于 DGJO-TCN-BiGRU 的微电网集群优化调度

王延峰¹, 赵家学¹, 曹育晗², 孙军伟¹

(1. 郑州轻工业大学电气信息工程学院, 河南 郑州 450002; 2. 新能源电力系统
国家重点实验室(华北电力大学), 北京 102206)

摘要: 针对微电网集群在复杂约束下发电成本偏高和经济效益不足的问题, 提出一种基于双种群金豺优化(dual population golden jackal optimization, DGJO)算法的微电网集群优化调度模型。首先, 以综合成本最小化为目标, 构建涵盖运行、储能、电力交易及环境等多项成本的微电网集群优化调度模型。其次, 提出 DGJO 算法, 利用莱维飞行实现自适应收敛, 以双种群策略平衡探索与开发, 引入哈里斯鹰围攻和缓存猎取算子提升寻优精度。然后, 采用 DGJO 对时间卷积网络(temporal convolutional network, TCN)和双向门控循环单元(bidirectional gated recurrent unit, BiGRU)的超参数进行优化, 提升收敛速度和模型的泛化能力。最后算例结果表明, 所提模型在复杂约束与扰动情景下有较好的鲁棒性, 并有效降低了系统的综合成本。

关键词: 微电网集群; 时间卷积网络; 双向门控递归单元; 优化调度; 金豺优化算法

Optimal scheduling of microgrid clusters based on DGJO-TCN-BiGRU

WANG Yanfeng¹, ZHAO Jiayue¹, CAO Yuhang², SUN Junwei¹

(1. College of Electrical and Information Engineering, Zhengzhou University of Light Industry, Zhengzhou 450002, China;
2. State Key Laboratory of New Energy Power System (North China Electric Power University), Beijing 102206, China)

Abstract: To address the issues of high generation costs and insufficient economic benefits of microgrid clusters under complex constraints, an optimal scheduling model for microgrid clusters based on the dual-population golden jackal optimization (DGJO) algorithm is proposed. First, with the objective of minimizing the total cost, an optimal scheduling model for microgrid clusters is constructed, incorporating operation costs, energy storage costs, electricity trading costs, and environmental costs. Second, the DGJO algorithm is developed, in which Lévy flight is employed to achieve adaptive convergence, a dual-population strategy is adopted to balance exploration and exploitation, and Harris hawks encircling and cache-foraging operators are incorporated to improve optimization accuracy. Then, DGJO is applied to optimize the hyperparameters of the temporal convolutional network (TCN) and the bidirectional gated recurrent unit (BiGRU), thereby improving convergence speed and model generalization capability. Finally, case studies demonstrate that the proposed model exhibits strong robustness under complex constraints and disturbance scenarios and effectively reduces the overall system cost.

This work is supported by the National Natural Science Foundation of China (No. 62272424 and No. 62276239).

Key words: microgrid clusters; temporal convolutional network; bidirectional gated recurrent unit; optimal scheduling; golden jackal optimization algorithm

0 引言

随着全球能源需求持续增长与环保政策愈发严苛, 构建可持续能源系统至关重要^[1], 电力系统高效、可持续运行已成为研究重点。微电网(microgrid,

MG)作为分布式能源集成平台^[2-3], 可优化电力供应链并提高能源利用率^[4-5]。多个微电网互联构成微电网集群系统, 其可支持微电网之间智能协调和能源交互, 有效降低社会成本^[6-8]。然而, 新能源的强烈不确定性, 使得负荷难以预测, 对微电网集群系统的协同运行带来可靠性和安全性的巨大挑战^[9-10]。因此, 研究微电网集群系统协同优化调度策略以提升区

基金项目: 国家自然科学基金项目资助(62272424, 62276239)

域能量供需平衡能力具有重要意义^[11-12]。

目前, 已有学者对微电网集群系统优化调度进行相关研究。文献[13]将微电网低碳经济调度构造多目标问题, 采用自适应鲁棒多目标优化算法进行求解。文献[14]将电、热、氢能协同调度建模为不确定性优化问题, 提出一种带约束哈里斯鹰优化算法。文献[15]提出动态分类麻雀搜索算法, 通过精英初始化和种群动态分类降低碳排放和微电网成本。文献[16]将灰狼优化(grey wolf optimizer, GWO)算法应用于微电网储能系统容量优化。文献[17]将自适应搜索粒子群优化算法优化单个微电网经济调度。文献[18]在非受控环境下将鲸鱼优化算法(whale optimization algorithm, WOA)用于优化微电网分时电价, 有效降低了运行成本, 但未考虑环境成本。文献[19]提出实时经济调度的全分布式近似动态规划算法, 降低了运行成本。现有研究大多聚焦于单个微电网, 探索更高效算法和改进策略以适应微电网集群经济调度是未来重要的研究方向。

因此, 本文提出基于双种群金豺优化算法优化时间卷积网络和双向门控循环单元网络(dual population golden jackal optimization-temporal convolutional network-bidirectional gated recurrent unit, DGJO-TCN-BiGRU)的微电网集群调度模型, 主要贡献:

- 1) 在满足安全且可靠运行基础上, 以综合成本最小为目标, 构建包含光伏(photovoltaic, PV)发电机、风力发电机(wind turbine, WT)、电动汽车(electric vehicle, EV)、微型燃气轮机(micro gas turbine, MT)、储能电池(battery energy storage, BT)及负荷的调度模型;
- 2) 提出 DGJO 算法, 采用莱维飞行实现自适应收敛, 通过双种群划分策略实现探索与开发阶段的动态平衡, 引入哈里斯鹰围攻机制和缓存猎取算子, 提高收敛精度与稳定性;
- 3) 利用 DGJO 优化 TCN-BiGRU 超参数和调度参数, 并将模型扩展到微电网集群的优化调度, 通过不同调度策略的对比, 结果表明本文所提模型显著提高了微电网集群系统的经济性和鲁棒性。

1 微电网集群系统结构

1.1 系统结构

微电网集群由 3 个 MG 组成, 每个 MG 包含光伏发电机、风力发电机、电动汽车、微型燃气轮机、储能电池及负荷。每个 MG 与能量管理中心互联, 可与配电网开展电力交易^[20], 结构如图 1 所示。

1.1.1 光伏发电模型

光伏发电机的输出功率主要由太阳辐照度、光伏组件表面温度所决定, 其计算表达式为

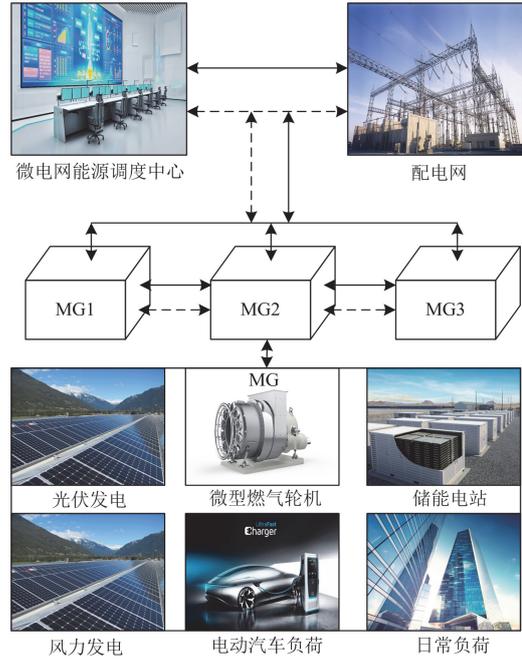


图 1 微电网结构图

Fig. 1 Microgrid cluster diagram

$$P_i^{PV}(t) = P_{\max}^{PV} \frac{G_t}{G_{st}} [1 + \psi(T_{PV} - T_r)] \quad (1)$$

式中: $P_i^{PV}(t)$ 为 t 时刻第 i 个 MG 中 PV 的输出功率; P_{\max}^{PV} 为 PV 最大额定容量; G_t 为 t 时刻实际太阳辐照度; G_{st} 为标准测试条件下太阳辐照度, 取 1000 W/m^2 ; ψ 为温度系数, 取 $-0.005 \text{ }^\circ\text{C}$; T_{PV} 为 PV 实际温度; T_r 为标准测试条件下温度, 取 $25 \text{ }^\circ\text{C}$ 。

1.1.2 风力发电模型

风力发电机出力与当地风速的关系为

$$P_i^{WT}(t) = \begin{cases} 0 & v_t < v_{in} \text{ 或 } v_t \geq v_{out} \\ P_{\max}^{WT} \left(\frac{v_t^3 - v_{in}^3}{v_{rat}^3 - v_{in}^3} \right) & v_{in} \leq v_t < v_{rat} \\ P_{\max}^{WT} & v_{rat} \leq v_t < v_{out} \end{cases} \quad (2)$$

式中: $P_i^{WT}(t)$ 为 t 时刻第 i 个 MG 中 WT 的输出功率; P_{\max}^{WT} 为 WT 最大额定功率; v_t 为 t 时刻风速; v_{in} 为切入风速, 取 3 m/s ; v_{rat} 为额定风速, 取 12 m/s ; v_{out} 为切出风速, 取 25 m/s 。

1.1.3 微型燃气轮机模型

微型燃气轮机的输出功率为

$$P_i^{MT}(t) = \kappa_{MT} Q_{MT} V \quad (3)$$

式中: $P_i^{MT}(t)$ 为 t 时刻第 i 个 MG 中 MT 的输出功率; κ_{MT} 为 MT 等效效率, 取 0.3 ; Q_{MT} 为燃气流量,

取 $55 \text{ m}^3/\text{h}$; V 为燃气低位热值, 取 $35\,800 \text{ kJ/m}^3$ 。

1.1.4 储能电池模型

储能电池状态计算表达式为

$$\delta_{\text{SOC}}^{t+1} = \delta_{\text{SOC}}^t + \frac{\eta_{\text{ch}} P_i^{\text{ch}}(t) \Delta t}{C_{\text{bat}}} - \frac{P_i^{\text{dis}}(t) \Delta t}{\eta_{\text{dis}} C_{\text{bat}}} \quad (4)$$

式中: $\delta_{\text{SOC}}^{t+1}$ 为 $t+1$ 时刻电池的荷电状态; C_{bat} 为 BT 的额定容量; η_{ch} 、 η_{dis} 分别为充、放电效率; $P_i^{\text{ch}}(t)$ 、 $P_i^{\text{dis}}(t)$ 分别为 t 时刻第 i 个 MG 中 BT 的充、放电功率; Δt 为调度时间步长, 取 1 h 。

1.2 目标函数

在满足系统需求的基础上, 综合最小化发电运行维护成本、储能成本、电力交易成本及 CO_2 、 SO_2 、 NO_x 等污染物的环境成本。目标函数为

$$\min f = C_1 + C_2 \quad (5)$$

式中: C_1 为设备运行维护成本; C_2 为环境成本。

$$C_1 = \sum_{i=1}^3 \sum_{t=1}^{24} [C_i^{\text{MT}}(t) + C_i^{\text{PV}}(t) + C_i^{\text{WT}}(t) + C_i^{\text{BT}}(t) + C_i^{\text{ET}}(t) + C_i^{\text{EM}}(t)] \quad (6)$$

式中: $C_i^{\text{MT}}(t)$ 为 t 时刻第 i 个 MG 中 MT 发电成本; $C_i^{\text{PV}}(t)$ 为第 i 个 MG 中 PV 发电成本; $C_i^{\text{WT}}(t)$ 为第 i 个 MG 中 WT 发电成本; C_i^{BT} 为第 i 个 MG 中 BT 储能成本; C_i^{ET} 为第 i 个 MG 的电力交易成本; C_i^{EM} 为第 i 个 MG 的维护成本。

$$\begin{cases} C_i^{\text{MT}}(t) = \frac{C_{\text{nl}}}{L} \times \frac{P_i^{\text{MT}}(t)}{\eta_i^{\text{MT}}(t)} \\ C_i^{\text{PV}}(t) = c_i^{\text{PV}} P_i^{\text{PV}}(t) \\ C_i^{\text{WT}}(t) = c_i^{\text{WT}} P_i^{\text{WT}}(t) \\ C_i^{\text{BT}}(t) = \frac{C_i^{\text{cost}}}{P_i^{\text{R}}} \times \frac{d_i(1+d_i)^{l_i}}{(1+d_i)^{l_i} - 1} P_i^{\text{BT}}(t) \\ C_i^{\text{ET}}(t) = P_i^{\text{MG}}(t) \delta_i^{\text{MG}}(t) + P_i^{\text{grid}}(t) \delta_i^{\text{grid}}(t) \\ C_i^{\text{EM}}(t) = k_i^{\text{WT}} P_i^{\text{WT}}(t) + k_i^{\text{PV}} P_i^{\text{PV}}(t) + k_i^{\text{MT}} P_i^{\text{MT}}(t) \end{cases} \quad (7)$$

式中: C_{nl} 为燃气价格, 取 2.5 元/m^3 ; L 为燃气低位热值, 取 9.7 kWh/m^3 ; $\eta_i^{\text{MT}}(t)$ 为发电效率, 取 0.8 ; c_i^{PV} 为 PV 单位运行成本, 取 0.08 元/kWh ; c_i^{WT} 为 WT 单位成本, 取 0.08 元/kWh ; C_i^{cost} 为 BT 投资成本, 取 2000 元/kWh ; P_i^{R} 为 BT 的额定功率; d_i 为折损率; l_i 为使用寿命; $P_i^{\text{BT}}(t)$ 为 t 时刻 BT 的输出功率; $P_i^{\text{MG}}(t)$ 为 t 时刻 MG 之间交易的电量; $P_i^{\text{grid}}(t)$ 为 MG 与配电网交易的电量; $\delta_i^{\text{MG}}(t)$ 、 $\delta_i^{\text{grid}}(t)$ 分别为 t 时刻 MG 和配电网的实时电价; k_i^{WT} 、 k_i^{PV} 、 k_i^{MT} 分别为第 i 个 MG 中 WT、PV、MT 维护系数。

$$C_2 = \sum_{i=1}^3 \sum_{t=1}^{24} \sum_{k=1}^3 [e_k \lambda_k^{\text{MT}} P_i^{\text{MT}}(t) + C_k \lambda_k^{\text{grid}} P_i^{\text{buy}}(t)] \quad (8)$$

式中: e_k 为第 k 种污染物治理成本; λ_k^{MT} 、 λ_k^{grid} 分别为 MT、配电网中污染物的排放因子; $P_i^{\text{buy}}(t)$ 为 t 时刻配电网的购电成本。

1.3 约束条件

1) 功率平衡约束

$$P_i^{\text{load}}(t) + P_i^{\text{grid}}(t) = P_i^{\text{WT}}(t) + P_i^{\text{PV}}(t) + P_i^{\text{MT}}(t) + P_i^{\text{BT}}(t) \quad (9)$$

式中: $P_i^{\text{load}}(t)$ 为 t 时刻第 i 个 MG 的负荷需求;

$P_i^{\text{grid}}(t)$ 为 t 时刻第 i 个 MG 的交易电量。

2) 光伏功率约束

$$P_{\text{min}}^{\text{PV}} \leq P_i^{\text{PV}} \leq P_{\text{max}}^{\text{PV}} \quad (10)$$

式中: $P_{\text{max}}^{\text{PV}}$ 、 $P_{\text{min}}^{\text{PV}}$ 分别为光伏功率的上、下限。

3) 风力功率约束

$$P_{\text{min}}^{\text{WT}} \leq P_i^{\text{WT}} \leq P_{\text{max}}^{\text{WT}} \quad (11)$$

式中: $P_{\text{max}}^{\text{WT}}$ 、 $P_{\text{min}}^{\text{WT}}$ 分别为风力功率的上、下限。

4) 微型燃气轮机功率约束

$$R_{i,\text{down}}^{\text{MT}} \Delta t \leq P_i^{\text{MT}}(t) - P_i^{\text{MT}}(t-1) \leq R_{i,\text{up}}^{\text{MT}} \Delta t \quad (12)$$

式中: $R_{i,\text{up}}^{\text{MT}}$ 、 $R_{i,\text{down}}^{\text{MT}}$ 分别为第 i 个 MG 中 MT 的上、下坡功率。

5) 储能电池约束

$$\delta_{\text{SOC}}^{\text{min}} \leq \delta_{\text{SOC}}^t \leq \delta_{\text{SOC}}^{\text{max}} \quad (13)$$

式中: $\delta_{\text{SOC}}^{\text{max}}$ 、 $\delta_{\text{SOC}}^{\text{min}}$ 分别为电池状态的最大、最小值。

$$\begin{cases} P_i^{\text{min}} \leq P_i^{\text{ch}}(t) \leq P_i^{\text{max}} \\ P_i^{\text{min}} \leq P_i^{\text{dis}}(t) \leq P_i^{\text{max}} \\ P_i^{\text{ch}}(t) \times P_i^{\text{dis}}(t) = 0 \end{cases} \quad (14)$$

式中: P_i^{max} 、 P_i^{min} 分别为充放电功率的上、下限。

6) 避免购电与售电同时进行的交互功率约束

$$\begin{cases} P_{\text{min}}^{\text{MG}} \leq P_i^{\text{MG}}(t) \leq P_{\text{max}}^{\text{MG}} \\ P_{\text{min}}^{\text{grid}} \leq P_i^{\text{grid}}(t) \leq P_{\text{max}}^{\text{grid}} \\ P_i^{\text{MG}}(t) \times P_i^{\text{grid}}(t) = 0 \end{cases} \quad (15)$$

式中: $P_{\text{max}}^{\text{MG}}$ 、 $P_{\text{min}}^{\text{MG}}$ 分别为 MG 之间的最大、最小交互功率; $P_{\text{max}}^{\text{grid}}$ 、 $P_{\text{min}}^{\text{grid}}$ 分别为 MG 与配电网的最大、最小交互功率。

2 多策略改进双种群金豺优化算法

2.1 金豺优化算法

金豺优化(golden jackal optimization, GJO)算法是一种元启发式算法, 模仿了金豺合作狩猎的行为模式^[21]。在 GJO 中, 种群由 n 个豺狼组成, 每个金

豺为 N 维向量, 构成 $M \times N$ 阶矩阵, 如式(16)所示。

$$\mathbf{D} = \begin{bmatrix} Y_{1,1} & Y_{1,2} & \cdots & Y_{1,N} \\ Y_{2,1} & Y_{2,2} & \cdots & Y_{2,N} \\ \vdots & \vdots & & \vdots \\ Y_{M,1} & Y_{M,2} & \cdots & Y_{M,N} \end{bmatrix} \quad (16)$$

式中: \mathbf{D} 为猎物矩阵; $Y_{M,N}$ 为第 M 个猎物在猎物矩阵中第 N 维度的位置。

2.2 双种群划分策略

在种群初始化阶段, 按照适应度矩阵对初始个体进行评估与排序, 并等量划分为精英种群和普通种群。精英种群承担全局搜索任务, 避免种群过早收敛并保持解的丰富性, 普通种群则围绕精英指引区域强化开发, 由此实现探索开发的分工协同。

普通种群由位置向量 $\mathbf{X}_A (A=1,2,3,\dots,\frac{n}{2})$ 构成, 表示一组待优化的候选解, 精英种群由位置向量 $\mathbf{W}_B (B=1,2,3,\dots,\frac{n}{2})$ 构成, 表示当前最优解邻域的变量。

2.3 全局搜索策略

尽管双种群划分平衡了开发与探索, 但仍易陷入局部最优。引入莱维飞行步长, 利用飞行步长进行全局扰动, 实现自适应收敛。位置更新公式为

$$\begin{cases} \mathbf{X}(T+1) = \mathbf{X}(T) - E \cdot |\mathbf{X}(T) - \mathbf{L}(N) \cdot \mathbf{D}(T)| \\ \mathbf{W}(T+1) = \mathbf{W}(T) - E \cdot |\mathbf{W}(T) - \mathbf{L}(N) \cdot \mathbf{D}(T)| \end{cases} \quad (17)$$

式中: $\mathbf{X}(T+1)$ 、 $\mathbf{W}(T+1)$ 分别为第 $T+1$ 次迭代精英和普通金豺的位置向量; $\mathbf{X}(T)$ 、 $\mathbf{W}(T)$ 分别为第 T 次迭代位置向量; E 为 $(0,1)$ 随机权重; $\mathbf{D}(T)$ 为第 T 次迭代猎物的位置向量; $\mathbf{L}(N)$ 为莱维飞行步长 (N 维向量), 表达式为

$$\mathbf{L}(N) = 0.01 \times \frac{\boldsymbol{\mu} \boldsymbol{\sigma}}{|\mathbf{v}|^{\frac{1}{\beta}}} \quad (18)$$

式中: $\boldsymbol{\mu}$ 为服从零均值高斯分布的 N 维随机向量; β 为重尾度, 取 1.5; $\boldsymbol{\sigma}$ 为标准差, 取 0.7; \mathbf{v} 为 N 维随机向量。

2.4 哈里斯鹰围攻机制

GJO 中金豺随机搜索和信息交流有限, 易陷入局部最优。精英金豺引入哈里斯鹰围攻机制, 增强局部开发与信息交流, 位置更新表达式为

$$\mathbf{Y} = \mathbf{X}^*(T) - 2V |R_1 \cdot \mathbf{X}^*(T) - \mathbf{X}(T)| \quad (19)$$

$$\mathbf{Z} = \mathbf{Y} + \mathbf{s} \cdot \mathbf{L}(N) \quad (20)$$

$$V = 2\boldsymbol{\omega} \cdot R_1 - \boldsymbol{\omega} \quad (21)$$

式中: \mathbf{Y} 为第 T 次迭代精英金豺的位置向量; \mathbf{Z} 为

莱维飞行后的位置向量; $\mathbf{X}^*(T)$ 为最优解; V 为收敛因子; R_1 为 $(0,1)$ 内的随机值; \mathbf{s} 为 $(1,N)$ 均匀分布的 N 维随机向量; $\boldsymbol{\omega}$ 为随迭代线性递减 $(0,2)$ 内的随机数。

2.5 缓存猎取算子

为提升全局搜索的稳定性, 普通金豺种群的位置更新引入最优解记忆和多角度协同的缓存猎取机制, 非线性观察半径 r 的表达式为

$$r = \begin{cases} a \frac{\sin(\phi_n)}{\phi_n}, & \phi_n \neq 0 \\ \theta, & \phi_n = 0 \end{cases} \quad (22)$$

式中: a 为普通金豺与猎物的缩放系数, 为 $(0,0.2)$ 的随机数; ϕ_n 为第 n 只普通金豺的观察角度, 取值为 $[0,2\pi]$ 的随机数; θ 为 $(0,1)$ 的随机数。

$$\mathbf{W}_n = ar \cdot \sum_1^n \sin(\phi_{n-1}) + ar \cdot \sin(\phi_n) + \mathbf{W}_n^{\text{actual}} \quad (23)$$

式中: \mathbf{W}_n 为多角度扰动后第 n 只普通金豺的位置向量; $\mathbf{W}_n^{\text{actual}}$ 为第 n 只普通金豺当前的位置向量。

在候选解集中根据适应度值进行排序, 选取排名前 3 的最佳个体 $\mathbf{W}_1(T)$ 、 $\mathbf{W}_2(T)$ 和 $\mathbf{W}_3(T)$, 则最终普通金豺的位置更新公式为

$$\mathbf{Y}(T+1) = \frac{\mathbf{X}_1(T) + \frac{\mathbf{W}_1(T) + \mathbf{W}_2(T) + \mathbf{W}_3(T)}{3}}{2} \quad (24)$$

DGJO 算法的流程如图 2 所示。

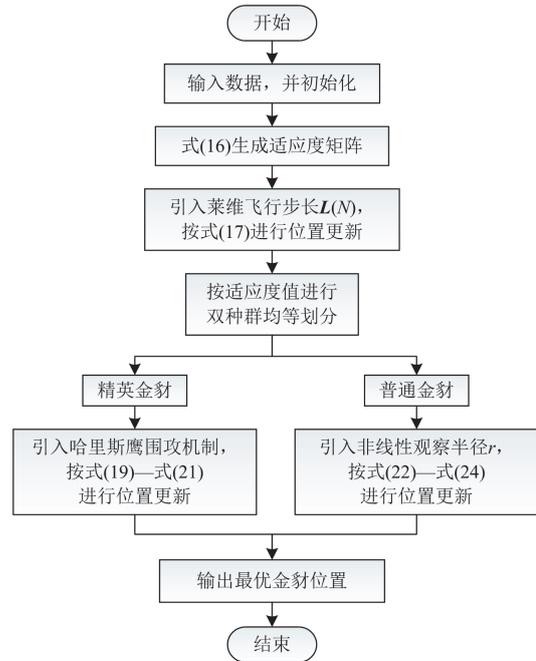


图 2 DGJO 算法流程图

Fig. 2 Flowchart of DGJO algorithm

3 TCN-BiGRU 模型

3.1 TCN 模型

TCN 是一种基于卷积的时序模型,通过扩张因果卷积与残差连接,实现对多尺度时序动态特征的建模。将 TCN 引入微电网集群经济调度中,实现多源电力负荷的动态演化^[22]。TCN 扩张因果卷积结构如图 3 所示,其中为 D 为膨胀因子。

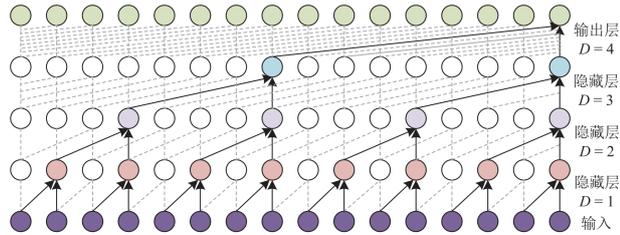


图 3 TCN 扩张因果卷积结构

Fig. 3 Structure of TCN dilated causal convolutions

深层网络易出现梯度消失,TCN 通过残差连接将上层误差直接传递到下层,从而稳定梯度,提升特征提取效果。TCN 残差连接结构如图 4 所示。

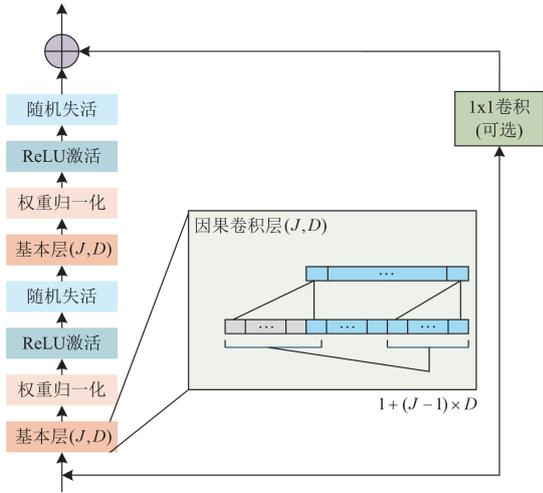


图 4 TCN 残差连接结构

Fig. 4 TCN residual connected structure

$$\mathbf{X} = \begin{bmatrix} P_{\text{sort},1}^1 & P_{\text{sort},2}^1 & \cdots & P_{\text{sort},A}^1 \\ P_{\text{sort},1}^2 & P_{\text{sort},2}^2 & \cdots & P_{\text{sort},A}^2 \\ \vdots & \vdots & \ddots & \vdots \\ P_{\text{sort},1}^K & P_{\text{sort},2}^K & \cdots & P_{\text{sort},A}^K \end{bmatrix} \quad (25)$$

$$\mathbf{X}_1 = \delta(\mathbf{G}(\mathbf{X}) + \mathbf{X}) \quad (26)$$

$$\mathbf{X}_2 = \delta(\mathbf{G}(\mathbf{X}_1) + \mathbf{X}_1) = \begin{bmatrix} P_{\text{sort},1}^1 & P_{\text{sort},2}^1 & \cdots & P_{\text{sort},A}^1 \\ P_{\text{sort},1}^2 & P_{\text{sort},2}^2 & \cdots & P_{\text{sort},A}^2 \\ \vdots & \vdots & \ddots & \vdots \\ P_{\text{sort},1}^K & P_{\text{sort},2}^K & \cdots & P_{\text{sort},A}^K \end{bmatrix} \in \mathbf{R}^{m \times A} \quad (27)$$

式中: \mathbf{X} 为由负荷数据与时间序列组成的 $m \times A$ 阶矩阵,其中 m 为样本数, A 为时间节点数,本文 $A=4$; $\mathbf{x}_K = [P_{\text{sort},1}^K, P_{\text{sort},2}^K, \dots, P_{\text{sort},A}^K]$ ($1 \leq K \leq m$) 为 t 时刻第 K 个样本的时间序列, $t \in [1, A]$; \mathbf{X}_1 为第一残差层的输出; $\mathbf{G}(\mathbf{X})$ 为残差函数; \mathbf{X}_2 为 TCN 的最终输出; $\delta(x)$ 为激活函数; $P_{\text{sort},A}^K$ 为 t 时刻第 K 个样本的输出。

3.2 BiGRU 模型

BiGRU 由正、反向两条通道组成,同时利用历史和未来信息更新隐藏状态^[23]。BiGRU 结构如图 5 所示。

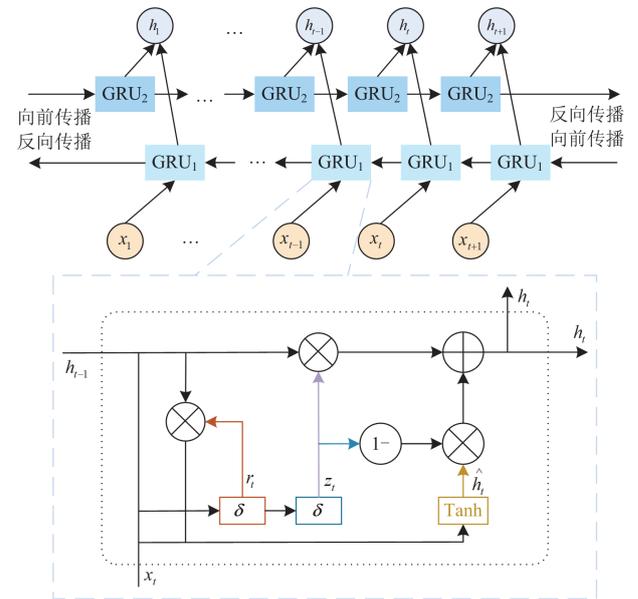


图 5 BiGRU 结构

Fig. 5 BiGRU structure

以 \mathbf{X}_2 作为 BiGRU 的输入,得到矩阵 \mathbf{X}_3 , 如式(28)所示。

$$\mathbf{X}_3 = \begin{bmatrix} P_{\text{sort},1}^1 & P_{\text{sort},2}^1 & \cdots & P_{\text{sort},A}^1 \\ P_{\text{sort},1}^2 & P_{\text{sort},2}^2 & \cdots & P_{\text{sort},A}^2 \\ \vdots & \vdots & \ddots & \vdots \\ P_{\text{sort},1}^K & P_{\text{sort},2}^K & \cdots & P_{\text{sort},A}^K \end{bmatrix} \quad (28)$$

式中: $\mathbf{P}_K^m = [P_{\text{sort},1}^K, P_{\text{sort},2}^K, \dots, P_{\text{sort},A}^K]$ ($1 \leq K \leq m$) 为第 K 个样本在第 A 个时间步长输出的特征向量。

3.3 DGJO-TCN-BiGRU 优化调度模型

DGJO-TCN-BiGRU 微电网集群经济调度模型的具体步骤如下所示。

Step1: 将电力负荷及时序变量构成输入矩阵 \mathbf{X} , 经 TCN 提取得到特征矩阵 \mathbf{X}_2 , 由 BiGRU 进行双向时序编码得到状态表征矩阵 \mathbf{X}_3 。

Step2: 构建满足运行约束、最小化综合成本的微电网集群经济调度模型。

Step3: 采用 DGJO 对 TCN-BiGRU 的超参数和调度决策变量进行两层联合寻优。

Step4: 输出在各个时段中, 每个 MG 的机组出力、储能充放电及购售电交易的最优调度方案。

4 实验验证

4.1 DGJO 性能测试

4.1.1 函数性能测试

为评估改进机制的有效性, 对比算法参数均按照原文献设置, 种群数量为 30, 迭代次数为 500, 在 CEC2017 测试集中选择 F_1 和 F_5 函数进行消融实验, 函数表达式如式(29)所示。

$$\begin{cases} F_1(\mathbf{x}) = x_1^2 + 10^6 \sum_{o=2}^O x_o^2 \\ F_5(\mathbf{x}) = \sum_{o=1}^O (x_o^2 - 10 \cos(2\pi o) + 10) \end{cases}, o = 1, 2, \dots, O \quad (29)$$

式中: $\mathbf{x} = [x_1, x_2, \dots, x_O]^T$ 为决策向量; O 为决策向量 \mathbf{x} 的维度。

将 DGJO 与去双种群(without dual population, NoDP)、去全局搜索(without Lévy flight based global search, NoLF)、去哈里斯鹰围攻(without Harris Hawks strategy, NoHHO)、去缓存猎取(without Cache Hunting strategy, NoCache)和 GJO 进行对比, 函数 F_1 和 F_5 的收敛曲线分别如图 6 和图 7 所示。由图 6 和图 7 可以看出, DGJO 均最早收敛且波动最小, 且在 F_5 后期呈快速收敛。

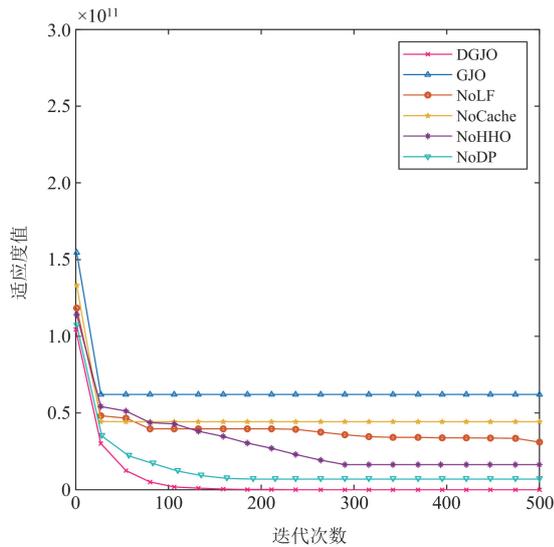


图 6 函数 F_1 适应度曲线

Fig. 6 Unimodal function fitness curve

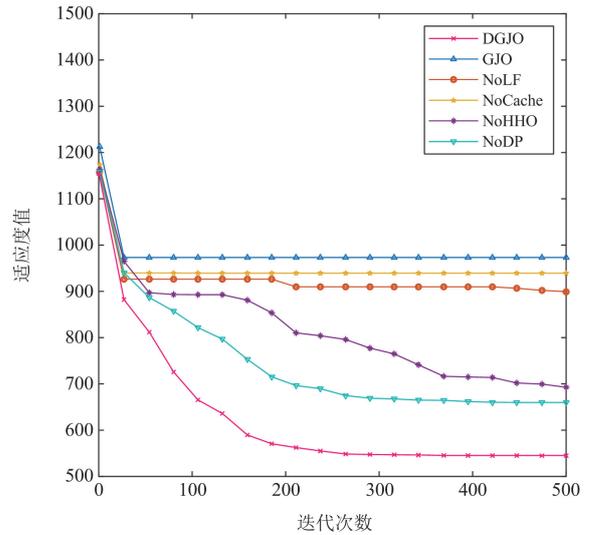


图 7 函数 F_5 适应度曲线

Fig. 7 Fitness curve of function F_5

4.1.2 神经网络参数优化

为保持时序一致性, 数据集按时间顺序划分为比例为 4:1 的训练集和测试集。在训练集上采用 DGJO 对 TCN-BiGRU 的超参数进行优化, 包含 BiGRU 隐藏单元数、TCN 卷积核大小、丢弃率、学习率、批量大小与迭代次数, 膨胀因子 D 设为 $D = \{1, 2, 4\}$ 。据此构建 DGJO-TCN-BiGRU 调度模型并在测试集上展开评估。DGJO-TCN-BiGRU 超参数寻优结果如表 1 所示。

表 1 DGJO-TCN-BiGRU 超参数寻优结果

Table 1 TCN-BiGRU hyperparameters optimized by DGJO

参数	范围	优化结果
BiGRU 隐藏单元数	[1,50]	32
TCN 卷积核大小	[3,5]	4
丢弃率	[0,0.5]	0.1
学习率	[0.001,0.01]	0.001
批量大小	[16,32]	16
迭代次数	[100,200]	108

4.2 案例研究

对本文所提的微电网集群系统进行验证, 采用电能互补策略, 电能饱和的微电网向亏电的微电网出售电能, 提升系统整体经济性^[24]。本文选用 2021 年中国某地区的电力负荷数据及环境变量, 采样周期 15 min, 单位为 kW。据国家电网公开信息, 该地区 2021—2025 年负荷总体呈稳定增长且结构变化较小, 保证了仿真结果的代表性与适用性。

4.2.1 参数设置

模型的污染物排放因子与成本、分时电价、发电机组参数和储能单元参数分别如表 2—表 5 所示。

表 2 污染排放因子与成本

Table 2 Pollution discharge factor and cost

类型	治理成本/ (元/kg)	污染物排放因子/(g/kWh)	
		电网	MT
CO ₂	0.21	890	750
SO ₂	14.85	1.92	0.041
NO _x	62.53	1.65	0.26

表 3 分时电价

Table 3 Hourly electricity price

类型	时间	电网	MG1	MG2	MG3
售电/(元/ kWh)	高峰 时段 09:00—12:00	1.52	0.51	0.62	0.58
	18:00—23:00				
正常 时段 07:00—09:00	12:00—16:00	1.21	0.46	0.56	0.52
低谷 时段 00:00—07:00	23:00—24:00	0.65	0.41	0.51	0.43
购电/(元/ kWh)	全天 00:00—24:00	0.40	0	0	0

表 4 发电机组参数

Table 4 Parameters of generator unit

类型	最大功率/ kW	最小功率/ kW	爬坡率/ (kW/h)	维护系数/ (元/kWh)
PV1	160	0	0	0.030
PV2	200	0	0	0.060
PV3	240	0	0	0.080
WT1	180	0	0	0.040
WT2	230	0	0	0.080
WT3	260	0	0	0.100
MT1	120	0	15	0.083
MT2	100	0	15	0.075
MT3	80	0	10	0.065

表 5 储能单元参数

Table 5 Parameters of energy storage unit

参数	数值
额定容量/kWh	150
初始容量/kWh	75
充放电最大功率/kW	50
充放电效率	0.9
折损率/(元/kW)	12
安装成本/(元/kW)	12
最大充电容量/kWh	130
最小充电容量/kWh	30
使用寿命/年	10

4.2.2 评价指标

为评估调度方案在不确定条件下的经济性与可靠性，引入扰动进行测试^[25-26]。本文在验证集上利用 TCN-BiGRU 的历史残差分布构造多维扰动场景，包含负荷、光电等不确定因素作为扰动输入，

在每个场景下，计算评价指标^[27]为

$$J(U_i; \xi_i^{(s)}) = C_1(U_i; \xi_i^{(s)}) + C_2(U_i; \xi_i^{(s)}) \quad (30)$$

$$\xi_i^{(s)}(t) = (1 + \mathcal{G}_i^{(s)})U_i \quad (31)$$

式中： $J(U_i; \xi_i^{(s)})$ 为在场景 s 下第 i 个 MG 采用调度决策 U_i 时的总成本； $C_1(U_i; \xi_i^{(s)})$ 为场景 s 下第 i 个 MG 的经济运行成本； $C_2(U_i; \xi_i^{(s)})$ 为场景 s 下第 i 个 MG 的环境成本； U_i 为场景 s 下第 i 个 MG 的调度决策向量； $\xi_i^{(s)}$ 为场景 s 下第 i 个 MG 的扰动系数； $\mathcal{G}_i^{(s)}$ 为场景 s 下第 i 个 MG 的百分比扰动项。

尾部风险是在扰动场景下经济成本超过分位点 τ 的平均值，越小则尾部成本越低，稳健性越好^[28]。

$$C_\tau = \min \left\{ z + \frac{1}{(1-\tau)S} \sum_{s=1}^S [J(U_i; \xi_i^{(s)}) - z]_+ \right\} \quad (32)$$

式中： C_τ 为置信水平 τ 下的尾部风险指标； τ 为置信水平，取 0.95； z 为 C_τ 辅助变量； $[x]_+ = \max(x, 0)$ 为正部算子； S 为扰动场景总数，且 $1 \leq s \leq S$ 。

约束违约率是指在扰动场景下，所有微电网和整个调度时域内，约束条件被触发的比例。

$$\hat{u} = \frac{1}{3SH} \sum_{s=1}^S \sum_{i=1}^3 \sum_{t=1}^H 1(\max(g_i^{(s)}(t)) > 0) \quad (33)$$

式中： \hat{u} 为约束违约率； H 为调度时段，取 24 h； $\max(\cdot)$ 为 t 时刻第 i 个 MG 在场景 s 下不等式约束条件的最大值； $1(\cdot)$ 为违规提示，若约束越界为 1，否则为 0； $g_i^{(s)}(t)$ 为 t 时刻第 i 个 MG 在场景 s 下的约束违约率。

供电可靠性表示在扰动场景下系统发生供电不足的平均持续时间，其值越小，模型的可靠性越高。

$$\hat{N} = \frac{1}{S} \sum_{s=1}^S \sum_{i=1}^3 \sum_{t=1}^H P_i^{(s)}(t) \Delta t \quad (34)$$

$$P_i^{(s)}(t) = P_i^{\text{WT}}(t) + P_i^{\text{PV}}(t) + P_i^{\text{MT}}(t) + P_i^{\text{BT}}(t) - P_i^{\text{load}}(t) - P_i^{\text{grid}}(t) \quad (35)$$

式中： \hat{N} 为供电可靠性； $P_i^{(s)}(t)$ 为 t 时刻第 i 个 MG 在场景 s 下的平衡功率。

4.2.3 对比分析

3 个微电网的设备输出曲线分别如图 8—图 10 所示。可以看出，MG1、MG2 夜间 00:00—06:00 时段以 WT 和 BT 协同供电，并在 05:00 时段从外购供电；日间 06:00—19:00 时段 PV 和 WT 充裕，满足自身负荷并为 BT 充电，余电对外出售；晚间 19:00—24:00 由 BT 放电，购电补缺。MG3 具有枢纽作用，在 01:00—05:00、07:00—19:00 时段向需求较高的微电网售电，余电售给配电网；在

16:00—17:00 时段定向售予 MG2; 在 00:00—01:00、05:00—07:00、19:00—24:00 时段由 BT 放电并从外部购电。3 个微电网通过蓄电池管理和电力交易策略, 跨网协调降低电能浪费, 同时提升了经济与环保效益。

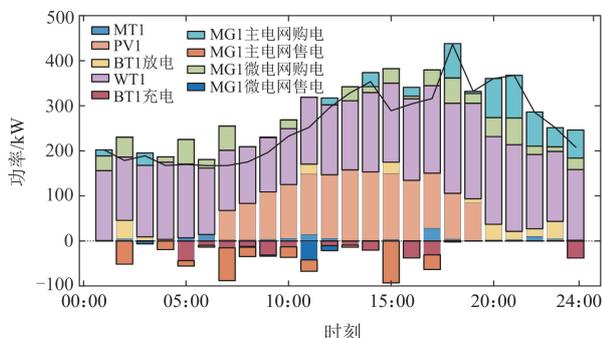


图 8 微电网 1 设备输出曲线

Fig. 8 Equipment output curves of microgrid 1

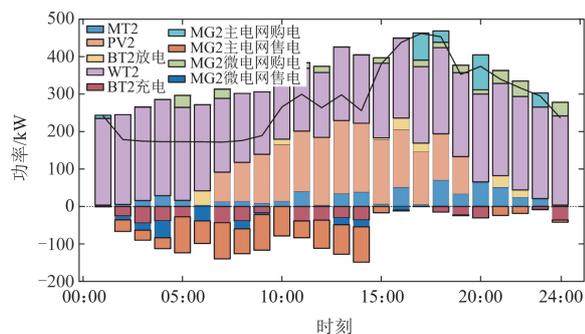


图 9 微电网 2 设备输出曲线

Fig. 9 Equipment output curves of microgrid 2

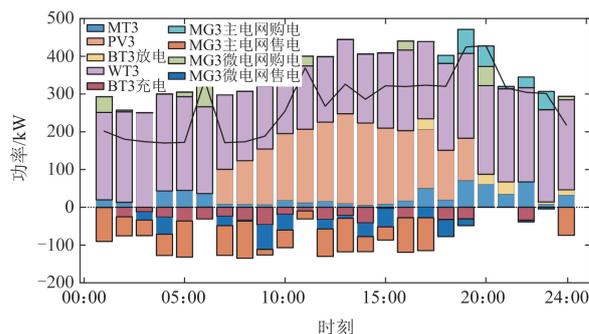


图 10 微电网 3 设备输出曲线

Fig. 10 Equipment output curves of microgrid 3

为了更直观表现 DGJO 算法的整体性能, 将 DGJO 算法与其他寻优效果较好的原始算法进行比较, 如麻雀搜索算法 (sparrow search algorithm, SSA), WOA 算法和 GWO 算法, 不同算法的成本比较如表 6 所示。

由表 6 可以看出, DGJO 在成本优化方面表现出显著优势。DGJO 优化后总成本为 2260.75 元, 相较 GJO 总成本降低约 21.41%, 各项成本降低幅度均在 15%~21%之间; 相比 SSA 总成本降低约 37.55%, 各项成本降幅均超过 36%; 相比 WOA 总成本降低 26.22%; 相比 GWO 总成本降低 31.03%。实验结果充分体现了 DGJO 在多维成本优化上的显著优势。

在相同预算下, 为测试模型的鲁棒性, 构建 600 个扰动压力场景总数。扰动比例取 10%和 20%两种水平, 分别生成 300 个压力场景。对比结果如表 7 所示。可以看出, 在 10%扰动下, DGJO 表现最优,

表 6 不同算法的成本比较

Table 6 Cost comparison of different algorithms

算法	MT 运行成本	BT 运行成本	分布式电源维护成本	交易成本	环境成本	总成本
DGJO	385.81	135.07	1026.94	395.49	317.44	2260.75
GJO	483.24	169.71	1262.45	467.12	403.78	2876.30
SSA	617.97	219.95	1624.21	639.36	520.15	3621.64
WOA	531.37	180.18	1382.08	537.42	433.14	3064.18
GWO	578.80	185.64	1497.39	574.82	439.77	3276.41

元

表 7 鲁棒性评估

Table 7 Robustness analysis

算法	总成本/元	尾部风险 (10%)/元	违约率 (10)%/%	供电可靠性 (10%)/kWh	尾部风险 (20%)/元	违约率 (20)%/%	供电可靠性 (20%)/kWh
DGJO	2260.75	2503.79	1.80	0.050	2727.93	4.60	0.105
GJO	2876.30	3322.44	6.20	0.314	3746.34	11.70	0.936
WOA	3064.18	3511.75	6.70	0.401	3961.09	14.50	1.102
GWO	3276.41	3801.05	7.00	0.443	4325.85	15.50	1.243
SSA	3621.64	4264.15	10.10	0.719	4902.53	18.10	1.846

其尾部风险成本相比 GJO 降低约 24.6%，违约率和供电可靠性均为最低。在 20%扰动下，DGJO 尾部风险成本相比 WOA 下降约 31.1%，违约率和供电可靠性也均为最低。综上所述，DGJO-TCN-BiGRU 模型在总成本、尾部风险、违约率与供电可靠性等方面均显著优于其他模型，且随扰动增加仍能保持稳定的调度性能，体现出较强的鲁棒性。

5 结论

针对微电网集群经济调度优化问题，提出基于 DGJO-TCN-BiGRU 调度优化模型，主要贡献如下。

1) 提出 DGJO 算法，引入莱维飞行实现自适应收敛；采用双种群划分策略，实现开发探索的协同，结合哈里斯鹰围攻和缓存猎取机制，提升算法的收敛精度和全局优化能力。

2) 构建 DGJO-TCN-BiGRU 模型，利用 DGJO 优化神经网络超参数，结合 TCN 和 BiGRU 深度挖掘特征关联，进一步增强模型的鲁棒性。

3) 构建微电网集群互联系统，涵盖分布式能源运行、储能、电力交易及环境等成本，并在扰动场景下验证模型的鲁棒性，结果表明该模型通过电能调度，显著提高了系统经济性和鲁棒性。

综上所述，本文将深度学习与群智能算法相结合，为复杂微电网的经济调度提供了可行路径。未来将进一步考虑可再生能源的高度不确定性、电网潮流约束以及负荷需求的随机性等关键因素，从而提升调度策略的鲁棒性、可行性与经济性。

参考文献

- [1] 张静, 毕天姝, 刘灏. 电力系统状态估计精度综合评价与分析体系[J]. 电力系统保护与控制, 2024, 52(20): 12-24.
ZHANG Jing, BI Tianshu, LIU Hao. A comprehensive evaluation and analysis system for accuracy of power system state estimation[J]. Power System Protection and Control, 2024, 52(20): 12-24.
- [2] 刘宿城, 栾李, 李龙, 等. 基于人工智能的直流微电网大信号稳定性评估方法研究[J]. 发电技术, 2025, 46(3): 496-507.
LIU Sucheng, LUAN Li, LI Long, et al. Research on large-signal stability assessment methods of DC microgrids based on artificial intelligence[J]. Power Generation Technology, 2025, 46(3): 496-507.
- [3] 姜延卓, 高冲, 刘艳云, 等. 考虑能量转换装置可变效率的综合能源系统多目标优化调度[J]. 电力系统保护与控制, 2025, 53(1):71-83.
JIANG Yanzhuo, GAO Chong, LIU Yanyun, et al. Multi-objective scheduling optimization of an integrated energy system considering variable efficiency of energy conversion devices[J]. Power System Protection and Control, 2025, 53(1): 71-83.
- [4] SHI J, TEH J. Load forecasting for regional integrated energy system based on complementary ensemble empirical mode decomposition and multi-model fusion[J]. Applied Energy, 2024, 353.
- [5] 李嘉伟, 巨云涛, 张璐, 等. 基于分布鲁棒模型预测控制的微电网多时间尺度优化调度[J]. 电力工程技术, 2024, 43(4): 45-55.
LI Jiawei, JU Yuntao, ZHANG Lu, et al. Multi-time scale distributed robust optimal scheduling of microgrid based on model predictive control[J]. Electric Power Engineering Technology, 2024, 43(4): 45-55.
- [6] 张儒峰, 张玉岳, 姜涛, 等. 基于等效投影的多微电网柔性配电系统协同优化运行方法[J]. 电力系统自动化, 2025, 49(12): 121-130.
ZHANG Rufeng, ZHANG Yuyue, JIANG Tao, et al. Equivalent projection-based cooperative optimal operation method for multi-microgrid flexible distribution systems[J]. Automation of Electric Power Systems, 2025, 49(12): 121-130.
- [7] 马立红, 梁亚峰, 程西, 等. 计及构网型储能稳定拓展的微电网群优化运行[J]. 电力工程技术, 2024, 43(6): 214-222.
MA Lihong, LIANG Yafeng, CHENG Xi, et al. Optimal operation of microgrids considering stabilized expansion of grid-forming energy storage[J]. Electric Power Engineering Technology, 2024, 43(6): 214-222.
- [8] 房超运, 杨昆, 柴瑞环. 分时电价下含电动汽车的微电网群双层多目标优化调度[J]. 电力科学与技术学报, 2024, 39(1): 124-133.
FANG Chaoyun, YANG Kun, CHAI Ruihuan. Two-layer multi-objective optimal dispatching of microgrid group with electric vehicles under time-of-use electricity prices[J]. Journal of Electric Power Science and Technology, 2024, 39(1): 124-133.
- [9] 王延峰, 廖荣航, 梁恩豪, 等. 基于围攻机制的改进鲸鱼优化算法[J]. 控制与决策, 2023, 38(10): 2773-2782.
WANG Yanfeng, LIAO Ronghang, LIANG Enhao, et al. Improved whale optimization algorithm based on siege mechanism[J]. Control and Decision, 2023, 38(10): 2773-2782.
- [10] 李虹, 韩雨萌. 计及新能源不确定性的配电网-多微电网协同优化调度[J]. 电工技术学报, 2025, 40(17): 5571-5588.
LI Hong, HAN Yumeng. Coordinated optimal scheduling of distribution networks and multiple microgrids considering

- renewable energy uncertainty[J]. Transactions of China Electrotechnical Society, 2025, 40(17): 5571-5588.
- [11] 郑涛, 曲荣洪, 陈云飞, 等. 基于牛顿法和拟牛顿法自适应结合的高比例新能源接入电网故障计算方法[J]. 电力系统保护与控制, 2025, 53(10): 57-65.
ZHENG Tao, QU Rongqi, CHEN Yunfei, et al. Fault calculation method for a power grid with high penetration of renewable energy based on adaptive combination of Newton and quasi-Newton methods[J]. Power System Protection and Control, 2025, 53(10): 57-65.
- [12] 朱晓荣, 杜雯菲. 基于能量管理的直流微电网集群协同控制策略[J]. 电力自动化设备, 2025, 45(1): 123-130.
ZHU Xiaorong, DU Wenfei. Coordinated control strategy of DC microgrid cluster based on energy management[J]. Electric Power Automation Equipment, 2025, 45(1): 123-130.
- [13] FENG X, CUI L, REN D, et al. A new adaptive robust multi-objective optimization algorithm for dispatching of microgrids design[J]. Engineering Applications of Artificial Intelligence, 2025, 159.
- [14] XU C, ABDALLA A N. Coordinated dispatch of electric, thermal, and hydrogen vectors in renewable-enriched microgrids using constrained Harris Hawks optimization under uncertainty[J]. Renewable Energy, 2026, 256.
- [15] XIE G, ZHANG M, WANG D, et al. Economic-environmental dispatch of isolated microgrids based on dynamic classification sparrow search algorithm[J]. Expert Systems with Applications, 2025, 271.
- [16] 苏向敬, 朱敏轩, 宇海波, 等. 基于频谱注意力和无交叉联合分位数回归的海上风电功率超短期概率预测[J]. 电力系统保护与控制, 2024, 52(21): 103-116.
SU Xiangjing, ZHU Minxuan, YU Haibo, et al. Ultra-short-term probabilistic forecasting of offshore wind power based on spectral attention and non-crossing joint quantile regression[J]. Power System Protection and Control, 2024, 52(21): 103-116.
- [17] KOH J S, TAN R H G, LIM W H, et al. A modified particle swarm optimization for efficient maximum power point tracking under partial shading condition[J]. IEEE Transactions on Sustainable Energy, 2023, 14(3): 1822-1834.
- [18] DENG H, LIU L, FANG J, et al. A novel improved whale optimization algorithm for optimization problems with multi-strategy and hybrid algorithm[J]. Mathematics and Computers in Simulation, 2023, 205: 794-817.
- [19] XUE Xizhen, FANG Jiakun, AI Xiaomeng, et al. A fully distributed ADP algorithm for real-time economic dispatch of microgrid[J]. IEEE Transactions on Smart Grid, 2024, 15(1): 513-528.
- [20] CEJA-ESPINOSA C, PIRNIA M, CAÑIZARES C A. An affine arithmetic-based energy management system for cooperative multi-microgrid networks[J]. IEEE Transactions on Smart Grid, 2024, 15(2): 1317-1329.
- [21] CHOPRA N, ANSARI M M. Golden jackal optimization: a novel nature-inspired optimizer for engineering applications[J]. Expert Systems with Applications, 2022, 198.
- [22] SHE B, LI F, CUI H, et al. Virtual inertia scheduling (VIS) for real-time economic dispatch in power systems with IBR penetration[J]. IEEE Transactions on Sustainable Energy, 2024, 15(2): 938-951.
- [23] WANG J. BGcsSENet: bidirectional GRU with spatial and channel squeeze-excitation network for bundle branch block detection[J]. IEEE Transactions on Human-Machine Systems, 2023, 53(2): 449-457.
- [24] LIU Z, ZHANG Y, ZHANG Y, et al. Distributed economic dispatch algorithms of microgrids integrating grid-connected and isolated modes[J]. IEEE/CAA Journal of Automatica Sinica, 2025, 12(1): 86-98.
- [25] VAHEDIPOUR-DAHRAIE M, R ASHIDIZADEH-KERMANI H, ANVARI-MOGHADDAM A. Risk-based stochastic scheduling of resilient microgrids considering demand response programs[J]. IEEE Systems Journal, 2020, 15(1): 971-980.
- [26] ZHANG C, LIANG H, YANG L. A distributionally robust approximate framework consider CVaR constraints for energy management of microgrid[J]. Sustainable Energy, Grids and Networks, 2023, 36.
- [27] ZHOU J, WENG Z, LI J, et al. Reliability evaluation, planning, and economic analysis of microgrid with access to renewable energy and electric vehicles[J]. Electric Power Systems Research, 2024, 230.
- [28] ZHU J, LI G, GUO Y, et al. Real-time risk-averse dispatch of an integrated electricity and natural gas system via conditional value-at-risk-based lookup-table approximate dynamic programming[J]. Protection and Control of Modern Power Systems, 2024, 9(2): 47-60.

收稿日期: 2025-07-15; 修回日期: 2025-11-18

作者简介:

王延峰(1973—), 男, 博士, 教授, 研究方向为仿生计算和数据处理; E-mail: yanfengwang@yeah.net

赵家学(2002—), 男, 硕士研究生, 研究方向为大数据和群智能算法; E-mail: jiaxuezhao@yeah.net

孙军伟(1984—), 男, 通信作者, 博士, 教授, 研究方向为智能算法及数据处理。E-mail: junweisun@yeah.net

(编辑 张颖)