



DOI:10.12404/j.issn.1671-1815.2404753

引用格式: 吴艳敏, 安艳军, 王璐, 等. 改进星鸦优化算法用于配电网多目标动态重构[J]. 科学技术与工程, 2025, 25(14): 5886-5896.

Wu Yanmin, An Yanjun, Wang Lu, et al. Improved nutcracker optimization algorithm for multi-objective dynamic reconfiguration of distribution network[J]. Science Technology and Engineering, 2025, 25(14): 5886-5896.

改进星鸦优化算法用于配电网多目标动态重构

吴艳敏^{1,2}, 安艳军^{1*}, 王璐¹, 刘家旗¹, 张晓锋²

(1. 郑州轻工业大学建筑环境工程学院, 郑州 450000; 2. 海军工程大学电气工程学院, 武汉 430030)

摘要 针对风光荷时变的配电网动态重构问题,提出了一种 Kmeans++ 融合 PAM(Kmeans++-partitioning around medoid) 聚类方法,按时间顺序划分日等值负荷曲线。以综合成本、电压偏移和负荷均衡度为优化目标构建配电网多目标动态重构模型。提出了一种改进星鸦优化算法(improved Nutcracker optimization algorithm, INOA) 提升模型求解效率,利用 Tent 映射+准反射学习提供优质初始种群,引入动态适应度-距离平衡选择方法和切线飞行策略提高全局搜索能力,加入柯西-高斯变异扰动克服局部最优。基于 IEEE33 节点系统进行对比分析,结果表明所提方法能够实现负荷最优划分并对重构模型进行高效求解。

关键词 动态重构; 分布式电源; 负荷聚类; 星鸦优化算法

中图分类号 TM734; **文献标志码** A

Improved Nutcracker Optimization Algorithm for Multi-objective Dynamic Reconfiguration of Distribution Network

WU Yan-min^{1,2}, AN Yan-jun^{1*}, WANG Lu¹, LIU Jia-qi¹, ZHANG Xiao-feng²

(1. College of Building Environment Engineering, Zhengzhou University of Light Industry, Zhengzhou 450000, China;

2. College of Electrical Engineering, Naval University of Engineering, Wuhan 430030, China)

[Abstract] A novel clustering approach combining Kmeans++ and PAM was introduced to segment the daily load curve chronologically for the dynamic reconfiguration of distribution networks incorporating time-varying wind solar power and loads. Multi-objective dynamic reconfiguration model of distribution network based on the optimal objectives of comprehensive cost, voltage offset and load balance. To enhance the computational efficiency of the model, an INOA (improved Nutcracker optimization algorithm) was proposed, which used Tent mapping + quasi-reflection learning to provide high-quality initial population. Dynamic fitness-distance balance selection method and tangential flight strategy were introduced to enhance the global search capability. The Cauchy-Gaussian variation perturbation was incorporated to augment the algorithm's capability to escape from local optima. Using the IEEE 33-node system as a basis, the outcomes indicate that the suggested approach effectively achieves optimal load distribution and efficiently addresses the restructured model.

[Keywords] dynamic reconstruction; distributed generation; load clustering; Nutcracker optimization algorithm

为达成“双碳”目标,中国新型电力系统建设不断深化,分布式发电(distributed generation, DG)迅速扩张,其大规模接入对电网的可靠性、稳定性和经济效益提出了新的考验^[1-2]。配电网重构是提升电网效率的关键策略,通过调整开关配置优化网络结构,旨在增强系统的可靠性和经济效益^[3]。配电网动态重构问题可以划分为多个时间段的静态重构问题来解决,其结果反映了负荷和 DG 的动态变化,更切合实际^[4-5]。

配电网静态重构技术已经发展非常完善,但基于时段划分的动态重构研究较少^[6]。文献[7]运用递归方法遍历每种时段划分方案,找到各分时段数下的最佳方案;计算损失函数随分时段数变化的速率,选择变化速率最大时对应的分时段数作为最优分段数,该方法能够保证时段最优划分,但数学推导过程复杂,计算量较大。文献[8]以基于马氏距离的动态时间归整(dynamic time warping, DTW)值为相似度量,提出分段指标为目标值,进行时段划分

收稿日期: 2024-06-25; 修订日期: 2025-02-26

基金项目: 河南省科技攻关项目(232102211050, 222102320298)

第一作者: 吴艳敏(1981—),女,汉族,河南郑州人,博士,副教授。研究方向:配电网自愈控制与智能优化。E-mail:yanmin1020@126.com。

* 通信作者: 安艳军(1998—),男,汉族,山西忻州人,硕士研究生。研究方向:配电网智能优化与控制。E-mail:2503202633@qq.com。

同时根据分段指标最大找出最优分段数。文献[9]提出了欧式距离和余弦距离组成的综合距离作为相似度量,围绕中心点划分(partitioning around medoid, PAM)中引入模拟退火提高时段划分准确度,最后“拐点法”确定最优方案。文献[10]考虑到了负荷曲线形态上的相似性,提出了外层皮尔逊内层欧氏距离为相似度量的双层聚类,提高了时段划分的准确性。以上方法虽然能有效划分时段,但未充分考虑负荷的时序性,等值负荷归类后还需根据时间轴进行二次划分。基于此,提出一种改进 PAM 聚类方法,使得输出结果具有严格的时序特性。

配电网重构是多项式复杂程度的非确定性(non-deterministic polynomial, NP)问题,利用智能算法求解相比传统数学优化方法具有一定的优越性。文献[11]以系统损耗和电压偏移为优化目标,采用改进灰狼优化算法求解,提升了系统运行水平。文献[12]以系统运行成本和电压偏移为目标函数,应用改进哈里斯鹰算法求解重构模型,提高了系统运行经济性与稳定性。文献[13]同样以系统运行成本和电压偏移为目标函数,应用 NSGA-II 改进算法求得帕累托前沿解集,通过模糊决策确定最终方案,全方位提升了系统运行水平。文献[14]以网损、平均和最小安全系数为目标函数,以约束指导目标求解过程,通过改进鼠群算法求解模型,有效提升系统运行稳定性。但同时考虑负荷与 DG 时变性,并针对系统综合成本及负荷均衡度等多目标开展配电网动态重构的研究还相对较少。

现利用改进 Kmeans++-PAM 对等值负荷预测曲线进行时段划分。考虑到配电网最基本的运行稳定性以及经济性要求,以综合成本、电压偏移和负荷均衡度为目标,构建多目标函数,并将改进星鸦优化算法应用于含 DG 的配电网动态重构中,求得各时段最优开关组合。

1 基于 Kmeans++-PAM 聚类的时段划分策略

聚类可以挖掘数据内在规律,通过聚类整合相似数据,进而简化复杂问题^[15]。现有的聚类方法很多,像 Kmeans 和 PAM 都是基于中心点的聚类算法,相比 Kmeans, PAM 的中心点是数据中真实存在的点,很大程度避免噪声点的干扰,聚类效果更佳。

1.1 改进 PAM 聚类算法

PAM 聚类具体流程如下。

(1)数据集 X 包含 n 个样本点,分为 k 类,随机选取 k 个样本点作为初始聚类中心。

(2)计算剩余 $n - k$ 个点到 k 个聚类中心的距

离,并将这些点逐一分配至最近的聚类中心,从而形成 k 个簇。

(3)每个簇重复以下步骤:选取簇内一点作为临时中心,计算簇内其他点到该点的总距离,遍历簇内所有点,找出使得总距离最小的点,并将其设为该簇的新聚类中心。

(4)若达到最大迭代次数,则输出结果;否则重复执行步骤(2)和步骤(3)。

其中 k 个初始对象的选取对 PAM 聚类效果影响较大,特别是当 k 值较小时,初始聚类中心之间的距离不够大,直接导致聚类效果下降。Kmeans++ 的初始化可以使初始聚类中心之间的距离尽可能远,有效防止局部早熟收敛,因此引入该策略提升 PAM 性能。

Kmeans++ 初始化具体流程如下。

(1)从数据集 $X = [X_1, X_2, \dots, X_n]$ 中随机选择一个样本点作为第一个聚类中心点。

(2)数据集 X 中除已经被选为聚类中心外的样本点称为待选点,每个待选点 X_i 执行相同操作:计算其与最近聚类中心之间的距离 D_i 。

(3)计算每个待选点 X_i 被选为聚类中心的概率 P_i 。

$$P_i = \frac{D_i^2}{\sum_{i \in A(x)} D_i^2} \quad (1)$$

式(1)中: $A(x)$ 为待选点集。

(4)按照概率选择一个待选点为聚类中心并重复步骤(2)和步骤(3)直到得到 k 个初始化聚类中心。

1.2 基于 Kmeans++-PAM 聚类的时段划分方法

配电网重构时段划分指根据电力系统的负荷特性和运行要求,将一定时间段分为不同的时段,在避免开关频繁动作的基础上尽可能达到降低网损和抬高电压等目标。

Kmeans++-PAM 聚类进行配电网重构时段划分流程如下。

(1)预测一天的负荷曲线及 DG 出力, DG 作为负的负荷加入负荷曲线中形成等值负荷曲线,设系统共有 n 个节点,以 1 h 为步长将一天划分为 m 个时间段,得到一个以时段为行,节点数为列的矩阵数据集 X , X 中的每个元素代表特定时段某一节点的功率值。

$$X = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,n} \\ \vdots & \vdots & & \vdots \\ x_{m,1} & x_{m,2} & \cdots & x_{m,n} \end{bmatrix} \quad (2)$$

(2)利用上述 Kmeans++ 初始化策略得到 k 个

按时序排列的初始化聚类中心 $X_c = [X_{c_1}, X_{c_2}, \dots, X_{c_k}]^T$, 其中 $X_{c_i} = [X_{c_i,1}, X_{c_i,2}, \dots, X_{c_i,n}]$ 为 c_i ($c_i \in [1, m]$) 时段的功率, $X_{c_i,j}$ 为 c_i 时段节点 j 的功率。

(3) 以欧式距离衡量数据间的相似性, 计算每个点到相邻两个聚类中心的相似度 s_j , 并划入相似度小的聚类簇中, 同时得到相似度指标 S_k 。

$$s_j = \min \{ \text{dis}(X_{c_i}, X_j), \text{dis}(X_{c_{i+1}}, X_j) \}, \quad j = 1, 2, \dots, m \quad (3)$$

式(3)中: X_{c_i} 和 $X_{c_{i+1}}$ 分别为 X_j 相邻的两个聚类中心。

$$S_k = \sum_{j=1}^m s_j \quad (4)$$

(4) 将每个簇内与其他点总距离最小的点设为新的聚类中心, 仍用 X_c 表示。

(5) 重复步骤(3)和步骤(4)直到 k 个分段点稳定不变或达到最大迭代次数。

1.3 最优分段

相似度指标 S_k 随分段数 k 的增加而递减^[16], 文中损失函数曲线法, 以分段数 k 为横轴, 纵轴为相似度指标值 S_k , 得到分段数与相似度指标的近似拟合曲线, 寻找曲线“拐点”。如果拐点横坐标值为整数, 即为最佳分段数; 否则计算拐点横坐标相邻两个分段数的斜率变化率, 选择斜率变化率较大的分段数作为最佳分段数。

2 配电网多目标重构模型

2.1 目标函数

(1) 综合成本。

$$\min f_1 = \sum_{t=1}^T \sum_{i=1}^b \left[C_t \frac{P_{i,t}^2 + Q_{i,t}^2}{U_{i,t}^2} R_i + C_s |S_{i,t} - S_{i,t-1}| \right] \quad (5)$$

式(5)中: T 为基本时段数; b 为支路数; C_t 为 t 时段网损单价; $U_{i,t}$ 、 $P_{i,t}$ 和 $Q_{i,t}$ 分别为 t 时段支路 i 的末端电压、有功和无功功率; R_i 为支路 i 的电阻; C_s 为单个开关单次动作成本; $S_{i,t}$ 为 t 时段支路 i 上开关开断状态。

(2) 系统电压偏移。

$$\min f_2 = \sum_{i=1}^n \sum_{j=1}^n \left| \frac{U_{j,t} - U_{j,N}}{U_{j,N}} \right| \quad (6)$$

式(6)中: n 为节点数; $U_{j,N}$ 和 $U_{j,t}$ 分别为 t 时段节点 j 的额定和实际电压。

(3) 负荷均衡度。

$$\min f_3 = \sum_{i=1}^T \sum_{i=1}^b \frac{S_n^2}{S_{nmax}^2} \quad (7)$$

式(7)中: S_n 为支路 i 送端容量; S_{nmax} 为支路 i 允许最大传输容量。

2.2 多目标优化

采用基于 Pareto 最优解思想的策略, 通过比较连续两次迭代解集的满意度指标, 以期找到整体目标的最优解决方案。

$$F_m^k = \begin{cases} 1, & f_m = f_{m,best} \\ \frac{f_{m,worst} - f_m}{f_{m,worst} - f_{m,best}}, & f_{m,best} < f_m < f_{m,worst} \\ 0, & f_m = f_{m,worst} \end{cases} \quad (8)$$

$$F^k = \frac{\sum_{f_m \in N(m)} F_m^k}{N_p \sum_{k=1}^{N_p} \sum_{f_m \in N(m)} F_m^k} \quad k = 1, 2, \dots, N_p \quad (9)$$

式中: F_m^k 为第 m 个目标对第 k 组解的满意度指标, 解越优, F_m^k 越大, 第 k 组解在第 m 个目标上取得最优值时 $F_m^k = 1$; f_m 为第 k 组解在第 m 个目标下的适应度值, $f_{m,best}$ 和 $f_{m,worst}$ 是第 m 个目标的最优值和最差值; F^k 为总目标满意度指标, F^k 最大时对应总目标的最优解; $N(m)$ 为优化目标个数; N_p 为解集中解的个数。

2.3 约束条件

(1) 潮流平衡约束。

$$\begin{cases} P_{i,t} + P_{DGi,t} = P_{Li,t} + U_{i,t} \sum_{j=1}^n U_{j,t} (G_{ij} \cos \theta_{ij,t} + B_{ij} \sin \theta_{ij,t}) \\ Q_{i,t} + Q_{DGi,t} = Q_{Li,t} + U_{i,t} \sum_{j=1}^n U_{j,t} (G_{ij} \sin \theta_{ij,t} - B_{ij} \cos \theta_{ij,t}) \end{cases} \quad (10)$$

式(10)中: $P_{i,t}$ 、 $P_{DGi,t}$ 和 $P_{Li,t}$ 分别为 t 时刻电源、DG 和负荷接入节点 i 的有功功率; $Q_{i,t}$ 、 $Q_{DGi,t}$ 和 $Q_{Li,t}$ 分别为 t 时刻电源、DG 和负荷接入节点 i 的无功功率; G_{ij} 和 B_{ij} 分别为节点 i 和节点 j 之间的电导和电纳; $\theta_{ij,t}$ 为 t 时刻节点 i 和节点 j 之间相角差。

(2) 节点电压约束。

$$V_{j,min} \leq V_{j,t} \leq V_{j,max} \quad (11)$$

式(11)中: $V_{j,max}$ 和 $V_{j,min}$ 为节点 j 电压的上、下限。

(3) 支路电流约束。

$$I_{i,min} \leq I_{i,t} \leq I_{i,max} \quad (12)$$

式(12)中: $I_{i,max}$ 和 $I_{i,min}$ 为支路 i 电流的上、下限。

(4) 辐射状网络拓扑约束。

要保证配电网以辐射状网络运行, 就要避免开关动作时产生环路和孤岛。采用文献[17]中的开关环路矩阵和节点分层矩阵策略, 有效剔除产生环路和孤岛的开关组合。

(5) 开关动作次数约束。

$$k \leq k_{max} \quad (13)$$

式(13)中: k_{max} 为允许开关动作次数上限。

(6) DG 出力约束。

$$\begin{cases} P_{DG,t,\min} \leq P_{DG,t} \leq P_{DG,t,\max} \\ Q_{DG,t,\min} \leq Q_{DG,t} \leq Q_{DG,t,\max} \end{cases} \quad (14)$$

式(14)中: $P_{DG,t,\min}$ 、 $P_{DG,t,\max}$ 、 $Q_{DG,t,\min}$ 和 $Q_{DG,t,\max}$ 分别为 t 时段 DG 能发出的有功和无功功率上下限。

3 改进星鸦优化算法 (INOA) 求解重构模型

3.1 NOA 算法

星鸦优化算法^[18]是一种元启发式算法。其思想来源于星鸦在不同时期表现出两种不同的行为:春夏之时,星鸦寻找种子并储藏在合适位置;秋冬之际,利用空间记忆策略并借助标记物作为参考点搜索储藏的种子。本文算法基于对以上两种主要行为的模拟,包括觅食和存储策略与储藏搜索和重获策略,两种搜索策略的选择是随机的。其中星鸦的位置代表实际问题的解。

3.1.1 觅食和存储策略

(1) 觅食阶段(探索阶段 1),星鸦在初始选定的松树上选择较好的种子,如果没有探索到好的种子,它们将在搜索区域的其他松树中探索。

$$\vec{X}_i^{t+1} = \begin{cases} X_{i,j}^t, & \tau_1 < \tau_2 \\ X_{m,j}^t + (X_{A,j}^t - X_{B,j}^t)\gamma + \mu(r^2 U_j - L_j), & \tau_1 \geq \tau_2 \text{ 且 } t \leq \frac{T_{\max}}{2} \\ X_{c,j}^t + \mu(X_{A,j}^t - X_{B,j}^t) + \mu(r_1 < \delta)(r^2 U_j - L_j), & \tau_1 \geq \tau_2 \text{ 且 } t > \frac{T_{\max}}{2} \end{cases} \quad (15)$$

式(15)中: \vec{X}_i^{t+1} 为第 i 个星鸦更新后的位置; $X_{i,j}^t$ 为第 t 代第 i 个星鸦的第 j 维位置; $X_{m,j}^t$ 为第 t 代种群全部星鸦的第 j 维位置均值; A 、 B 和 C 为从种群中随机选取的 3 个不同个体; τ_1 、 τ_2 、 r_1 和 r 为 $[0, 1]$ 之间的随机数; U_j 和 L_j 分别为星鸦位置第 j 维变量的上、下界; δ 取 0.05; γ 为莱维飞行生成的随机数,后文所提的莱维飞行随机数生成方式与此处相同; μ 为基于 τ_3 、 τ_4 和 τ_5 生成的随机数; T_{\max} 为最大迭代次数。

$$\gamma = \frac{w}{|v|^{\frac{1}{\beta}}} \quad (16)$$

$$\sigma_w = \left[\frac{\Gamma(1 + \beta) \sin \frac{\pi\beta}{2}}{\Gamma\left(\frac{1 + \beta}{2}\right) \beta 2^{\frac{\beta-1}{2}}} \right]^{\frac{1}{\beta}} \quad (17)$$

$$\mu = \begin{cases} \tau_3, & r_1 < r_2 \\ \tau_4, & r_2 < r_3 \\ \tau_5, & r_1 < r_3 \end{cases} \quad (18)$$

式中: w 服从 $N(0, \sigma^2)$; v 服从标准正态分布; β 取 1.5; r_1 、 r_2 、 r_3 和 τ_3 为 $[0, 1]$ 之间的随机数; τ_4 和 τ_5 分别为标准正态分布和莱维飞行生成的随机数。

(2) 存储阶段(开发阶段 1),星鸦将觅食阶段找到的种子运输到不同的储藏点。数学建模为

$$\vec{X}_i^{t+1} = \begin{cases} \vec{X}_i^t + \mu(\vec{X}_{\text{best}}^t - \vec{X}_i^t) |\lambda| + r_1(\vec{X}_A^t - \vec{X}_B^t), & \tau_1 < \tau_2 \\ \vec{X}_{\text{best}}^t + \mu(\vec{X}_A^t - \vec{X}_B^t), & \tau_1 < \tau_3 \\ \vec{X}_{\text{best}}^t l, & \tau_1 \geq \tau_2 \text{ 且 } \tau_1 \geq \tau_3 \end{cases} \quad (19)$$

式(19)中: λ 为莱维飞行生成的随机数; X_{best}^t 为当前最优位置; l 为从 1 ~ 0 线性递减的因子。

上述两阶段按式(20)进行轮换,保证探索和开发的平衡。

$$\vec{X}_i^{t+1} = \begin{cases} \text{式(15)}, & \phi > P_{\text{al}} \\ \text{式(19)}, & \phi \leq P_{\text{al}} \end{cases} \quad (20)$$

式(20)中: ϕ 为 $[0, 1]$ 之间的随机数; P_{al} 取 0.2。

3.1.2 储藏搜索和重获策略

(1) 储藏搜索阶段(探索阶段 2),星鸦利用参考点定位储藏位置,每个储藏位置有 2 个参考点,分别记为 $\text{RP}_{i,1}^t$ 和 $\text{RP}_{i,2}^t$ 。

$$\vec{\text{RP}}_{i,1}^t = \begin{cases} \vec{X}_i^t + \alpha \cos\theta(\vec{X}_A^t - \vec{X}_B^t) + \alpha \text{RP}, & \theta = \pi/2 \\ \vec{X}_i^t + \alpha \cos\theta(\vec{X}_A^t - \vec{X}_B^t), & \theta \neq \pi/2 \end{cases} \quad (21)$$

$$\vec{\text{RP}}_{i,2}^t = \begin{cases} \vec{X}_i^t + \{\alpha \cos\theta[(\vec{U} - \vec{L})\tau_3 + \vec{L}] + \alpha \text{RP}\} \vec{U}_2, & \theta = \pi/2 \\ \vec{X}_i^t + \alpha \cos\theta[(\vec{U} - \vec{L})\tau_3 + \vec{L}] \vec{U}_2, & \theta \neq \pi/2 \end{cases} \quad (22)$$

式中:

$$\alpha = \begin{cases} \left(1 - \frac{t}{T_{\max}}\right)^{\frac{2t}{T_{\max}}}, & r_1 > r_2 \\ \left(\frac{t}{T_{\max}}\right)^{\frac{2}{t}}, & r_1 \leq r_2 \end{cases} \quad (23)$$

$$\vec{U}_2 = \begin{cases} 1, & \vec{r}_2 < P_{rp} \\ 0, & \vec{r}_2 \geq P_{rp} \end{cases} \quad (24)$$

式中: $\vec{RP}_{i,1}^t$ 和 $\vec{RP}_{i,2}^t$ 分别为第 t 代第 i 个星鸦探索储藏时的 1 号参考点和 2 号参考点的更新位置; θ 为以星鸦位置为中心对参考点和储藏点视角夹角; RP 为一个随机参考位置; α 由式(23)生成; U_2 由式(24)生成; P_{rp} 取 0.2。

利用 1 号参考位置更新星鸦当前位置, 即

$$\vec{X}_i^{t+1} = \begin{cases} \vec{X}_i^t & f(\vec{X}_i^t) < f(\vec{RP}_{i,1}^t) \\ \vec{RP}_{i,1}^t & f(\vec{X}_i^t) \geq f(\vec{RP}_{i,1}^t) \end{cases} \quad (25)$$

式(25)中: f 为适应度函数。

(2) 重获阶段(开发阶段 2), 利用 1 号参考点找到的储藏中, 可能有种子, 也可能没有, 建模为

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t, & \tau_6 < \tau_7 \\ X_{i,j}^t + r_1(X_{best,j}^t - X_{i,j}^t) + r_2(\vec{RP}_{i,1}^t - X_{i,j}^t), & \tau_6 \geq \tau_7 \end{cases} \quad (26)$$

式(26)中: $X_{best,j}^t$ 为当前最优位置的第 j 维数值; τ_6 、 τ_7 为 $[0, 1]$ 之间的随机数。

如果星鸦忘记了 1 号参考点, 那么将利用 2 号点进行搜索, 建模为

$$\vec{X}_i^{t+1} = \begin{cases} \vec{X}_i^t, & f(\vec{X}_i^t) < f(\vec{RP}_{i,2}^t) \\ \vec{RP}_{i,2}^t, & f(\vec{X}_i^t) \geq f(\vec{RP}_{i,2}^t) \end{cases} \quad (27)$$

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t, & \tau_8 < \tau_9 \\ X_{i,j}^t + r_1(X_{best,j}^t - X_{i,j}^t) + r_2(\vec{RP}_{i,2}^t - X_{i,j}^t), & \tau_8 \geq \tau_9 \end{cases} \quad (28)$$

式(28)中: τ_8 、 τ_9 为 $[0, 1]$ 之间的随机数。

上述两阶段按式(29)进行轮换, 保证探索和开发的平衡。

$$\vec{X}_i^{t+1} = \begin{cases} \text{式(26)}, & r_4 < r_5, \phi > P_{a2} \\ \text{式(28)}, & r_4 \geq r_5, \phi > P_{a2}, \\ \text{式(25)}, & f(\vec{RP}_{i,1}^t) < f(\vec{RP}_{i,2}^t), \phi \leq P_{a2} \\ \text{式(27)}, & f(\vec{RP}_{i,1}^t) \geq f(\vec{RP}_{i,2}^t), \phi \leq P_{a2} \end{cases} \quad (29)$$

式(29)中: r_4 、 r_5 、 ϕ 为 $[0, 1]$ 之间的随机数; P_{a2} 取 0.4。

3.2 INOA 算法

3.2.1 初始化改进

如果初始种群成员能够均匀地散布在整个解空间中, 这将有助于算法更有效地找到全局最优解, 并且提高求解速度。原始 NOA 算法采用随机初

始化, 很难保证初始解在解空间的均匀分布, 进而影响配电网重构结果。混沌序列具有确定性、敏感依赖初始条件和遍历性, 其中 Tent 映射能产生均匀分布的序列, 因此用 Tent 映射来初始化星鸦种群。

$$x_{t+1} = \begin{cases} \frac{x_t}{\alpha}, & 0 \leq x_t \leq \alpha \\ \frac{1-x_t}{1-\alpha}, & \alpha \leq x_t \leq 1 \end{cases} \quad (30)$$

式(30)中: α 取 0.499。

由于 Tent 映射对初始条件敏感, 特别是数据量较小的情况, 需要合适的初始值才能使生成数据均匀分布在解空间。为了得到均匀分布且质量较高的解, 引入文献[19]提出的准反射学习策略。如图 1 所示, x 是由 Tent 映射生成的初始解, 以解空间中点进行反向得到反向值 x_0 , 反向解 x^{qr} 在 $[(l_b + u_b)/2, x_0]$ 之间随机生成, 反向解同样以解空间中点进行反向得到反射值 x_r , 反射解 x^{qr} 在 $[x_r, (l_b + u_b)/2]$ 之间随机生成。

$$x_i^{qo} = \text{rand}\left(\frac{l_{b_i} + u_{b_i}}{2}, x_{oi}\right) \quad (31)$$

$$x_i^{qr} = \text{rand}\left(\frac{l_{b_i} + u_{b_i}}{2}, x_{ri}\right) \quad (32)$$

式中: u_b 和 l_b 分别为解空间的上、下界; x_0 为解初始解 x 关于解空间中心的对称点; x_r 为反向解 x_{qo} 关于解空间中心的对称点; i 为解的维度。

比较 Tent 解和其生成的准反射解的适应度值, 适应度较优的选入最终的初始化种群。




图 1 反射值示意图

Fig. 1 Reflection diagram

3.2.2 探索和开发阶段改进策略

原始 NOA 算法性能强大, 但在某些问题上难以避免局部最优解。针对配电网重构, 对 NOA 算法的探索机制进行了改进, 以提高其实用性。

“切线飞行”是切线搜索算法中提出的一种以切线函数为基础的步长策略^[20]。这一方法的设计旨在提高搜索空间的探索效率^[21]。切线飞行具体公式如下

$$X^{t+1} = X^t + s_{tep} \tan \theta \quad (33)$$

$$s_{tep} = 0.3(\text{rand} - 0.5) \text{norm}(X_{best}) \times \ln(1 + 10d_{im}/t) \quad (34)$$

式中: X 为种群位置; s_{tep} 为步长; θ 决定了新解与当前解的距离, θ 越接近 0 距离越小, θ 越接近 $\pi/2$ 距离越大; s_{tep} 由式(34)生成; $\tan \theta$ 在 $[0, \pi/2.1]$ 之间

随机生成;norm 为欧式范数; d_{im} 为解的维度。

将切线飞行策略引入探索阶段1,如式(35)所示。

$$\vec{X}_i^{t+1} = \begin{cases} X_{i,j}^t + s_{\text{tep}} \tan \theta, & \tau_1 < \tau_2 \\ X_{m,j}^t + \gamma(X_{A,j}^t - X_{B,j}^t) + \mu(r^2 U_j - L_j), & \tau_1 \geq \tau_2 \text{ 且 } t \leq \frac{T_{\max}}{2} \\ X_{C,j}^t + \mu(X_{A,j}^t - X_{B,j}^t) + \mu(r_1 < \delta)(r^2 U_j - L_j), & \tau_1 \geq \tau_2 \text{ 且 } t > \frac{T_{\max}}{2} \end{cases} \quad (35)$$

动态适应度-距离平衡选择方法(dynamic fitness distance balance, dFDB)^[22]是在适应度-距离平衡选择方法^[23]基础上提出的,相比原始方法可以通过调节适应度和距离所占比重来平衡探索与开发。该方法通过适应度-距离值指导种群个体更新,相比NOA算法中的随机选择有更好的指导作用。假设种群 $\mathbf{X} = [X_1, X_2, \dots, X_n]^T$,每个候选解都有相应的适应度值,以该种群最大最小适应度值的差值为基准值,将每个候选解适应度值归一化得 $\mathbf{F} = [F_1, F_2, \dots, F_n]^T$;第*i*个候选解到当前最优解的欧式距离由式(36)得到,以该种群其余候选解到当前最优解的最大最小距离差值为基准值归一化得 $\mathbf{D} = [D_1, D_2, \dots, D_n]^T$ 。使用归一化的适应度值和距离值计算每个候选解的dFDB评分 S_i ,如式(37)所示。

$${}_{i=1}^n \forall X_i, D_i = [(x_{i,1} - x_{\text{best},1})^2 + (x_{i,2} - x_{\text{best},2})^2 + \dots + (x_{i,m} - x_{\text{best},m})^2]^{1/2} \quad (36)$$

$${}_{i=1}^n \forall X_i, S_i = \omega_{\text{dFDB}} D_i + (1 - \omega_{\text{dFDB}}) F_i \quad (37)$$

$$\omega_{\text{dFDB}} = \frac{h}{\max F_E} (1 - l_b) + l_b \quad (38)$$

$$\max F_E = \frac{T_{\max}}{H} \quad (39)$$

$$h = \text{mod}(t, \max F_E) \quad (40)$$

式中: ω_{dFDB} 为距离权重; $\max F_E$ 为一个 ω_{dFDB} 更新周期所迭代的次数; T_{\max} 为最大迭代次数; H 为更新频率,决定了 ω_{dFDB} 更新周期; $\text{mod}(x, y)$ 表示*x*对*y*求余; l_b 为 ω_{dFDB} 的下限, l_b 在 $[0, 0.5]$ 之间取值; ω_{dFDB} 越接近0开发性能越强,越接近1探索性能越强,取 l_b 为0.3可以保证较强的探索性能。

选择dFDB评分最高的候选解指导NOA算法探索阶段2的选择过程,具体公式为

$$\vec{RP}_{i,1}^t = \begin{cases} \vec{X}_i^t + \alpha \cos \theta (\vec{X}_A^t - \vec{X}_S^t) + \alpha \text{RP}, & \theta = \pi/2 \\ \vec{X}_i^t + \alpha \cos \theta (\vec{X}_A^t - \vec{X}_S^t), & \theta \neq \pi/2 \end{cases} \quad (41)$$

式(41)中: X_i^t 为第*t*次迭代中的第*i*个解; X_A^t 为*t*次

迭代时随机选择的一个解; X_S^t 为*t*次迭代时dFDB评分最高的候选解。

3.2.3 柯西-高斯变异扰动策略

为了增强改进算法搜索性能,在开发阶段2中引入柯西-高斯变异扰动策略^[24],式(25)和式(27)改进如式(42)和式(43)所示。

$$\vec{X}_i^{t+1} = \begin{cases} \vec{X}_i^t [1 + \mu_1 \text{Cauchy}(0, 1) + \mu_2 \text{Gauss}(0, 1)], \\ f(\vec{X}_i^t) < f(\vec{RP}_{i,1}^t) \\ \vec{RP}_{i,1}^t, f(\vec{X}_i^t) \geq f(\vec{RP}_{i,1}^t) \end{cases} \quad (42)$$

$$\vec{X}_i^{t+1} = \begin{cases} \vec{X}_i^t [1 + \mu_1 \text{Cauchy}(0, 1) + \mu_2 \text{Gauss}(0, 1)], \\ f(\vec{X}_i^t) < f(\vec{RP}_{i,2}^t) \\ \vec{RP}_{i,2}^t, f(\vec{X}_i^t) \geq f(\vec{RP}_{i,2}^t) \end{cases} \quad (43)$$

式中: $\mu_1 = 1 - t^2/T_{\max}^2$; $\mu_2 = t^2/T_{\max}^2$; $\text{Cauchy}(0, 1)$ 为标准柯西分布; $\text{Gauss}(0, 1)$ 为标准正态分布。

前期以柯西扰动为主,有利于探索;后期以高斯扰动为主,提升收敛精度。

3.3 基于INOA的配电网动态重构流程

具体重构步骤如下,重构流程图如图2所示。

步骤1 利用Kmeans++-PAM对负荷和DG预测值进行时段划分,获得最优分时段方案。

步骤2 采用文献[17]中的潮流计算编码方式进行整数型编码。

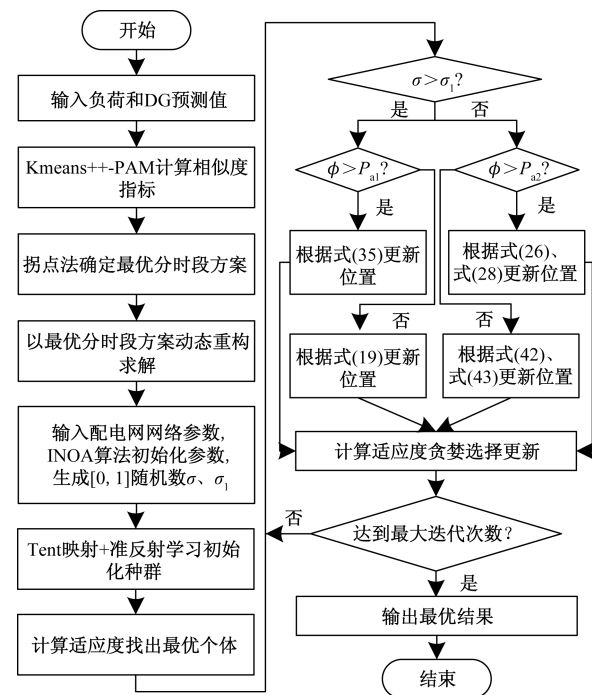


图2 重构流程图

Fig. 2 Reconfiguration flowchart

步骤3 设置算法参数:种群数 N , 维度 M , 最大迭代次数 T_{max} , 解空间的上界 U_B 和下界 L_B 。

步骤4 使用 Tent 映射 + 准反射学习策略初始化种群, 计算每个候选解的适应度。

步骤5 随机选择觅食和存储策略与储藏搜索和重获策略。

步骤6 如果执行觅食和存储策略, 按照式(20)选择式(35)或式(19)更新候选解。

步骤7 如果执行储藏搜索和重获策略, 按照式(29)选择式(26)、式(28)、式(42)或式(43)更新候选解。

步骤8 贪婪选择: 新解若适应度更低则替换, 否则保留原解。

步骤9 若迭代次数达上限, 则输出最优解; 未达到则返回步骤5。

4 算例分析

4.1 相关参数设置

应用 IEEE33 节点系统进行仿真分析, 线路及负荷预测数据来源于文献[9], 系统总负荷 3 746 kW + j2 352 kVar, 基准值 $V_B = 12.66$ kV, $S_B = 10$ MW, 系统结构如图3所示。配电网负荷分为商业负荷、居民负荷和工业负荷, 其最大负荷分别为 2.017 2、1.375 2、1.065 6 MW, 配电网负荷系数如图4所示。各时段风光出力数据参照文献[25]。节点14、节点22、节点32接入光伏 (photovoltaic, PV), 最大功率 450 kW; 节点7、节点25接入风电 (wind turbine, WT), 最大功率 405 kW。风光出力系数如图5所示。网损成本设为 0.7 元/(kW·h), 单个开关动作成本为 7 元/次。




图3 系统结构图

Fig. 3 System structure diagram




图4 负荷预测曲线

Fig. 4 Load forecasting curve




图5 风光出力曲线

Fig. 5 Wind and solar power output curve

4.2 时段划分

将1 d的等值负荷以1 h为步长划分为24个基本时段, 采用 Kmeans ++ -PAM 聚类算法进行时段划分, 求出各时段数下的等值负荷相似度指标值 S_k , 绘制相似度指标曲线如图6所示, 根据“拐点法”可知最优分段数介于4~5。分时段数为3~6对应的相似度指标值如表1所示。

表1 分时段数3~6时相似度指标值

Table 1 The value of similarity index when the number of time periods is 3 ~ 6

分时段数 k	3	4	5	6
相似度 S_k	3.803 8	2.980 7	2.433 1	2.084 6




图6 相似度曲线

Fig. 6 Similarity curve

求出分时段数为4和5时的斜率变化率分别为 1.384 和 1.796, 因此, 最终的最优分段数为5。时段划分最终结果为 0~7 h、7~11 h、11~15 h、15~21 h、21~24 h, 等值负荷曲线具体时段划分结果如图7所示。

4.3 INOA 算法有效性验证

以 IEEE33 节点系统为对象, 网损为目标函数, 将 INOA 算法与 GWO、HHO 和原始 NOA 算法进行比较。统一参数为种群数 $N = 50$, 最大迭代数 $T_{max} = 100$ 。HHO 中能量初值 $E_0 = 1$; NOA 中 $\delta = 0.05$, $P_{tp} = 0.2$, $P_{az} = 0.4$; INOA 参数同 NOA, $f = 10$ 。每种算法执行 50 次独立运算, 得出平均结果, 具体数据如表2所示。




图7 时段划分结果

Fig. 7 Period division result

表2 重构性能对比

Table 2 Reconstruction performance comparison

算法	平均网损/kW	最小迭代次数	平均迭代次数	平均耗时/s	寻优率/%
SWO	44.399 1	43	94.2	14.1	16
HHO	44.860 0	9	90.3	45.6	24
NOA	42.868 1	4	63.2	30.7	66
INOA	42.161 5	5	21.8	30.1	100

从表2可以看出,相比其他算法,INOA算法的平均网损最小、迭代次数最少以及寻优率最高。虽然在平均耗时上不如SWO算法,但在寻优率方面,SWO算法仅为16%,极易陷入局部最优。各算法进化特性曲线如图8所示,INOA迭代7次收敛,相比其他算法收敛快精度高。综合来看,在配电网重构中,INOA算法寻优效果突出。

4.4 重构结果比较分析

以一天24h的重构结果进行对比分析,经过动态重构的多目标优化求解,得到部分Pareto前沿重构方案如表3所示,动态重构方案1、方案2、方案3和方案4分别以网损、电压偏移、负荷均衡度和按照第2节多目标优化策略得到的总目标满意度为目标函数得出的最优方案。

为了验证动态重构的优越性,将动态重构与其他重构策略进行比较如表4所示。

单一重构、全时段重构和动态重构方案1都是以网损为目标函数。从表4可以看出动态重构方案1相比未重构方案除开关动作次数外各项指标都更优;相比单一重构虽然开关动作次数和综合成本有所提高,但网损、电压偏移和负荷均衡度指标分别下降21.1%、18.5%和4.9%,而且在实际电力系统中,负荷和网损都是相当大的,降损相比减少少量开关动作带来的经济效益会更高;相比全时段重构,网损、电压偏移和负荷均衡度指标分别上升0.3%、0.5%和0.1%,全时段重构较优,但是全时段重构开关频繁动作,会给电力系统带来极大的不稳定性。未重构、单一重构、全时段重构和动态重构方案1各时段网损如图9所示,可以看到在负荷




图8 各算法进化特性

Fig. 8 Evolutionary characteristics of various algorithms

表3 部分Pareto前沿重构方案

Table 3 Part of Pareto front reconfiguration results

方案	重构时段	断开开关
1	00:00—07:00	8~21,14~15,9~10,32~33,28~29
	07:00—11:00	7~8,9~15,10~11,32~33,25~29
	11:00—15:00	6~7,13~14,9~10,32~33,28~29
	15:00—21:00	6~7,14~15,9~10,18~33,28~29
	21:00—24:00	6~7,14~15,10~11,18~33,28~29
2	00:00—07:00	8~21,14~15,9~10,18~33,28~29
	07:00—11:00	7~8,9~15,10~11,17~18,28~29
	11:00—15:00	6~7,13~14,9~10,31~32,28~29
	15:00—21:00	6~7,13~14,9~10,17~18,28~29
	21:00—24:00	6~7,14~15,10~11,17~18,28~29
3	00:00—07:00	6~7,14~15,9~10,32~33,28~29
	07:00—11:00	7~8,13~14,9~10,30~31,28~29
	11:00—15:00	6~7,13~14,9~10,30~31,28~29
	15:00—21:00	6~7,14~15,9~10,31~32,28~29
	21:00—24:00	6~7,14~15,10~11,32~33,28~29
4	00:00—07:00	6~7,14~15,9~10,18~33,28~29
	07:00—11:00	7~8,13~14,9~10,18~33,28~29
	11:00—15:00	6~7,13~14,9~10,31~32,28~29
	15:00—21:00	6~7,14~15,9~10,18~33,28~29
	21:00—24:00	6~7,14~15,10~11,18~33,28~29

表4 几种重构策略的比较

Table 4 Compares several reconstruction strategies

重构方案	网损/(kW·h)	开关动作次数	综合成本/元	电压偏移/p.u.	负荷均衡度
未重构	742.573	0	519.801	11.703	2.882
单一重构	594.129	10	485.890	8.465	1.947
全时段重构	467.352	64	775.146	6.867	1.854
动态重构方案1	468.752	26	510.126	6.903	1.852
动态重构方案2	486.105	28	536.274	6.783	1.900
动态重构方案3	506.016	18	480.211	7.851	1.816
动态重构方案4	470.010	16	441.007	6.796	1.836

较重且波动比较大的情况下,动态重构方案1的降损效果显著。




图9 不同方案各时段网损

Fig. 9 Network loss of different schemes in different periods


上述4种方案一天内的电压分布如图10所示。可以看到动态重构明显提高了电压水平,大幅降低了电压波动性,提升电压质量的效果与全时段重构相近。综合来看,动态重构方法相比其他重构方法有一定优越性,更适用于实际应用。

为了更加清晰地比较这几种方案对系统稳定性的影响,取负荷较重的19:00—20:00的电压分布如图11所示。可以清晰地看出动态重构后,电压水平提升明显,电压分布更加均衡,此时未重构、单一重构、全时段重构和动态重构方案1的电压偏移分别为0.975、0.775、0.576、0.580 p.u.。从数据来看,动态重构相比不重构和单一重构提升电压水平较大,同时电压偏移指标非常接近全时段重构,说明动态重构方法的有效性。


配电网重构在实际应用中需要考虑多个目标,但一般很难让每个目标同时达到最优。利用Pareto前沿解集可以得到多目标模型中每个单目标函数的最优解,以及对每个目标都相对较优的解。动态重构各方案的指标对比如图12所示。在动态重构方案中,动态重构方案1的网损指标最优;动态重构方案2的电压偏移指标最优;动态重构方案3的负荷均衡度指标最优;动态重构方案4是以2.2节多目标优化后求解的结果,虽然它的网损、电压偏移和负荷均衡度三个指标没有一个达到最优,但是它的这三个指标同时接近最优,且开关次数和综合成本最优,达到了对每个目标都相对较优的效果,有非常高的实用价值。具体的方案选择,可以根据实际的需求来进行选择。

5 结论


针对风光荷时变下的配电网重构问题,以综合成本、电压偏移和负荷均衡度为目标函数建立重构模型,并进行多目标优化;对时变DG和负荷,运用Kmeans++-PAM聚类方法对时间轴进行聚类,确定最佳重构时段数;提出改进的星鸦算法对重构模型




(a) 未重构电压分布



(b) 单一重构电压分布



(c) 全时段重构电压分布



(d) 动态重构方案1电压分布

图10 不同方案的电压分布

Fig. 10 Voltage distribution of different schemes

求解。通过IEEE33节点系统进行仿真分析,得到以下结论。

(1) Kmeans++-PAM聚类方法能够精确识别时变负荷数据间的相似性进行时段划分,所提最优分段数确定方法有效平衡了划分时段数过多开关动作频繁与划分时段数不足达不到降损提目的




图 11 19:00—20:00 下电压分布

Fig. 11 Voltage distribution from 19:00 to 20:00




图 12 动态重构各方案对比

Fig. 12 Comparison of dynamic reconstruction schemes

间的矛盾,为建立配电网动态重构模型打下基础。

(2)通过 Tent 映射 + 准反射学习提供优质初始种群,动态适应度-距离平衡选择方法和切线飞行策略提高全局搜索能力,柯西-高斯变异扰动克服局部最优,提升了原始星鸦算法在配电网重构中的运行效率和计算精度。

(3)建立以综合成本、电压偏移和负荷均衡度为目标函数的重构模型,求解得到部分 Pareto 前沿解,根据具体需求选择相应的解,有效提升了配电网实际运行经济性与稳定性。

参 考 文 献

[1] 周步祥,姚先禹,臧天磊. 计及电-气双向耦合的综合能源配电网优化重构[J]. 电测与仪表, 2024, 61(2): 17-24.
Zhou Buxiang, Yao Xianyu, Zang Tianlei. Optimization and reconfiguration of the integrated energy distribution network considering the electricity-gas two-way coupling [J]. Electrical Measurement & Instrumentation, 2024, 61(2): 17-24.

[2] 孙文治,张惠娟,谢姿,等. 含多微网系统的主动配电网分层能量优化管理[J]. 科学技术与工程, 2022, 22(1): 202-210.
Sun Wenzhi, Zhang Huijuan, Xie Zi, et al. Hierarchical energy optimization management of active distribution network with multi-microgrid system [J]. Science Technology and Engineering, 2022,

22(1): 202-210.

[3] 黄鸣宇,张庆平,张沈习,等. 高比例清洁能源接入下计及需求响应的配电网重构[J]. 电力系统保护与控制, 2022, 50(1): 116-123.
Huang Mingyu, Zhang Qingping, Zhang Shenxi, et al. Distribution network reconfiguration considering demand-side response with high penetration of clean energy [J]. Power System Protection and Control, 2022, 50(1): 116-123.

[4] 袁天梦,侯鑫垚,廉杰. 主动配电网下分布式能源系统双层两阶段调度优化模型[J]. 科学技术与工程, 2023, 23(5): 1978-1983.
Yuan Tianmeng, Hou Xinyao, Lian Jie. Two-level and two-stage scheduling optimization model of distributed energy system under active distribution network [J]. Science Technology and Engineering, 2023, 23(5): 1978-1983.

[5] Zheng W, Huang W, Hill D J, et al. An adaptive distributionally robust model for three-phase distribution network reconfiguration [J]. IEEE Transactions on Smart Grid, 2020, 12(2): 1224-1237.

[6] 赵静翔,牛焕娜,王钰竹. 基于信息熵时段划分的主动配电网动态重构[J]. 电网技术, 2017, 41(2): 402-408.
Zhao Jingxiang, Niu Huanna, Wang Yuzhu. Dynamic reconfiguration of active distribution network based on information entropy of time intervals [J]. Power System Technology, 2017, 41(2): 402-408.

[7] 高纯,于艾清,丁雨. 基于改进递归有序聚类的有源配电网多时段动态重构[J]. 电力自动化设备, 2021, 41(2): 84-90.
Gao Chun, Yu Aiqing, Ding Yu. Multi-period dynamic reconfiguration of active distribution network based on improved recursive ordered clustering [J]. Electric Power Automation Equipment, 2021, 41(2): 84-90.

[8] 周步祥,姚先禹,臧天磊,等. 基于马氏 DTW 时段划分和 FCPSOGSA 算法的配电网动态重构[J]. 智慧电力, 2021, 49(11): 66-72, 80.
Zhou Buxiang, Yao Xianyu, Zang Tianlei, et al. Dynamic reconfiguration of distribution network based on markov DTW time division and FCPSOGSA algorithm [J]. Smart Power, 2021, 49(11): 66-72, 80.

[9] 徐俊斐,高志强,周雪松,等. 考虑负荷与 DG 随机性特征的配电网多目标动态重构[J]. 电测与仪表, 2020, 57(21): 32-39.
Xu Junfei, Gao Zhiqiang, Zhou Xuesong, et al. Multi-objective dynamic reconstruction of distribution network considering load and DG randomness characteristics [J]. Electrical Measurement & Instrumentation, 2020, 57(21): 32-39.

[10] 王瑞峰,王庆荣. 基于改进双层聚类多目标优化的配电网动态重构[J]. 电力系统保护与控制, 2019, 47(21): 92-99.
Wang Ruifeng, Wang Qingrong. Multi-objective optimization of dynamic reconfiguration of distribution network based on improved bilayer clustering [J]. Power System Protection and Control, 2019, 47(21): 92-99.

[11] 田书欣,刘浪,魏书荣,等. 基于改进灰狼优化算法的配电网动态重构[J]. 电力系统保护与控制, 2021, 49(16): 1-11.
Tian Shuxin, Liu Lang, Wei Shurong, et al. Dynamic reconfiguration of a distribution network based on an improved grey wolf optimization algorithm [J]. Power System Protection and Control,

- 2021, 49(16): 1-11.
- [12] 吴艳敏, 刘家旗, 王璐, 等. 基于改进哈里斯鹰优化算法的配电网动态重构[J]. 科学技术与工程, 2024, 24(8): 3251-3259.
Wu Yanmin, Liu Jiaqi, Wang Lu, et al. Dynamic reconfiguration of distribution network based on improved harris HAWK optimization algorithm[J]. Science Technology and Engineering, 2024, 24(8): 3251-3259.
- [13] 张照堃, 何莉, 吴霜. 基于改进非支配排序遗传算法的配电网动态重构[J]. 科学技术与工程, 2021, 21(21): 8916-8922.
Zhang Zhaolong, He Li, Wu Shuang. Dynamic reconfiguration of distribution network based on improved NSGA-II [J]. Science Technology and Engineering, 2021, 21(21): 8916-8922.
- [14] 魏凯, 程静. 基于 IRSO 算法的含分布式电源配 网重构[J]. 科学技术与工程, 2024, 24(3): 1075-1082.
Wei Kai, Cheng Jing. Distribution network reconfiguraion with distributed generation based on improved rat swarm optimization [J]. Science Technology and Engineering, 2024, 24(3): 1075-1082.
- [15] 王云, 王美蕴, 周健, 等. 基于改进层次聚类和 GL-APSO 算法的配电网动态重构[J]. 智能科学与技术学报, 2022, 4(3): 410-417.
Wang Yun, Wang Meiyun, Zhou Jian, et al. Dynamic configuration of distribution network based on improved hierarchical clustering and GL-APSO algorithm[J]. Chinese Journal of Intelligent Science and Technology, 2022, 4(3): 410-417.
- [16] 黄曜, 林凌雪, 管霖. 考虑 DG 与负荷时变性的配电网分时段动态重构[J]. 电气自动化, 2022, 44(6): 25-27, 31.
Huang Yao, Lin Lingxue, Guan Lin. Timedivided dynamic reconfiguration of distribution network considering time-varying DG and load[J]. Electrical Automation, 2022, 44(6): 25-27, 31.
- [17] 关万琳. 分布式电源优化配置与配电网重构[D]. 长沙: 湖南大学, 2014.
Guan Wanlin. Distributed generation optimal allocation and distribution network reconfiguration[D]. Changsha: Hunan University, 2014.
- [18] Abdel-Basset M, Mohamed R, Jameel M, et al. Nutcracker optimizer: a novel nature-inspired metaheuristic algorithm for global optimization and engineering design problems [J]. Knowledge-Based Systems, 2023, 262: 110248.
- [19] Fan Q, Chen Z, Xia Z. A novel quasireflected Harris hawks optimization algorithm for global optimization problems [J]. Soft Computing, 2020, 24: 14825-14843.
- [20] Layeb A. Tangent search algorithm for solving optimization problems [J]. Neural Computing and Applications, 2022, 34(11): 8853-8884.
- [21] 徐亦凤, 刘升, 刘宇淞, 等. 融合差分变异和切线飞行的天鹰优化器[J]. 计算机应用研究, 2022, 39(10): 2996-3002.
Xu Yifeng, Liu Sheng, Liu Yusong, et al. Aquila optimizer integrating differential mutation and tangent flight [J]. Application Research of Computers, 2022, 39(10): 2996-3002.
- [22] Kahraman H T, Bakir H, Duman S, et al. Dynamic FDB selection method and its application; modeling and optimizing of directional overcurrent relays coordination [J]. Applied Intelligence, 2022, 52: 4873-4908.
- [23] Kahraman H T, Aras S, Gedikli E. Fitnessdistance balance (FDB): a new selection method for metaheuristic search algorithms [J]. Knowledge Based Systems, 2020, 190: 105169.
- [24] 陈海旭, 余畅文, 卢银均, 等. 基于高斯-柯西变异帝国竞争算法的微电网优化调度[J]. 电气自动化, 2024, 46(1): 1-4.
Chen Haixu, Yu Changwen, Lu Yinjun, et al. Optimal dispatching of microgrid based on Gauss-Cauchy mutation imperialist competitive algorithm [J]. Electrical Automation, 2024, 46(1): 1-4.
- [25] 刘洁, 赵晓君, 贾宇琛, 等. 基于改进烟花算法的含高比例新能源的交直流配电网动态重构[J]. 南方电网技术, 2024, 18(10): 64-72.
Liu Jie, Zhao Xiaojun, Jia Yuchen, et al. Dynamic reconstruction of AC/DC distribution network with high proportion of new energy based on improved fireworks algorithm [J]. Southern Power System Technology, 2024, 18(10): 64-72.