

DOI: 10.19783/j.cnki.pspc.201356

基于改进灰狼优化算法的配电网动态重构

田书欣¹, 刘浪¹, 魏书荣¹, 符杨¹, 米阳¹, 刘舒²

(1. 上海电力大学电气工程学院, 上海 200090; 2. 国网上海市电力公司电力科学研究院, 上海 200437)

摘要: 为了更好地解决含分布式电源(Distributed Generation, DG)的配电网重构问题, 建立了考虑负荷需求与 DG 出力时变特性的配电网动态重构模型。首先采用 K-means++聚类算法对日负荷进行时段划分。然后以系统损耗、电压偏离量为目标函数, 并利用改进灰狼优化算法进行寻优计算。针对传统灰狼优化算法中存在的初始种群分布不均、缺少全局交流、容易陷入局部最优等问题, 在生成初始种群时引入 tent 映射, 增强初始种群的均匀性。引入合作竞争机制, 提高个体间有效信息的利用率。在灰狼种群位置更新时引入自适应惯性权值, 以满足不同时期的寻优要求。最后通过算例分析, 验证了该算法的可行性与优越性。

关键词: 分布式电源; K-means++聚类; 配电网动态重构; 改进灰狼优化算法

Dynamic reconfiguration of a distribution network based on an improved grey wolf optimization algorithm

TIAN Shuxin¹, LIU Lang¹, WEI Shurong¹, FU Yang¹, MI Yang¹, LIU Shu²

(1. College of Electrical Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. State Grid Shanghai Electric Power Research Institute, Shanghai 200437, China)

Abstract: To improve distribution network reconfiguration with Distributed Generation (DG), a dynamic distribution network reconfiguration model considering time-varying characteristics of DG output and load demand is established. First, the K-means++ clustering algorithm is used to divide the daily load period. Then, the system loss and voltage deviation are taken as the objective functions, and the improved grey wolf optimization algorithm is used to optimize the calculation. To tackle uneven initial population distribution, lack of global communication and 'easy to fall into local optima' in traditional grey wolf optimization algorithms, when generating the initial population, it introduces tent mapping to enhance the uniformity of the initial population. A cooperative competition mechanism is introduced to improve the utilization rate of effective information between individuals. An adaptive inertia weight is introduced when the grey wolf population position is updated to meet the optimization requirements of different periods. Finally, the feasibility and superiority of the proposed algorithm are verified by a numerical example.

This work is supported by the National Key Research and Development Program of China (No. 2017YFB0902800) and the Science and Technology Project of State Grid Corporation of China (No. 52094017003D).

Key words: distributed generation; K-means++clustering; distribution network dynamic reconfiguration; improved grey wolf optimization algorithm

0 引言

配电网网络重构是配电系统自动化的最重要模块之一。根据应用场景的不同, 重构可以分为两种类型: 正常状态下的优化重构和故障状态下的故障重构。前者通常旨在减少功率损耗, 提高可靠性, 在保持电源和负荷需求平衡的基础上, 通过分段开

关和联络开关的开断状态的组合, 以获得最佳的网络拓扑结构^[1]。后者也称为故障恢复, 通常旨在通过获得最佳的开关状态以将非故障停电区域的负荷通过转供来实现最大程度的供电, 从而尽可能降低停电带来的经济损失。本文研究的是正常状态下的优化重构。目前, 国内外对配电网重构已有大量的研究。配电网重构求解方法主要可分为数学优化算法^[2-3]、启发式算法^[4-5]和人工智能算法^[6-9]三大类。数学优化算法是利用数学理论中的优化原理进行重构求解, 如单纯形法^[2]、动态规划算法^[3]等。数学

基金项目: 国家重点研发计划项目资助(2017YFB0902800); 国家电网公司科技项目(52094017003D)资助

优化算法通常可以保证解的全局最优性，但当系统规模较大时，其求解变量大大增加，难以快速有效地求解。启发式算法是较早用于求解配电网重构的一类算法，主要包括支路交换法^[4]和最优流法^[5]。启发式算法虽然重构速度较快，但普遍存在得不到最优解的问题。人工智能算法由于在处理大规模、非线性优化问题上具有普适性高、兼容性强的优势，在配电网重构方面得到广泛应用。目前应用到配电网重构中的人工智能算法包括布谷鸟算法^[6]、粒子群算法^[7]、人工鱼群算法^[8]和遗传算法^[9]等。如何进一步提高算法的寻优精度和收敛速度是该类算法的重点研究方向。从 DG 和负荷的时序性角度考虑，配电网重构可分为静态重构^[2-9]和动态重构^[10-13]，静态重构是基于某一时间断面的负荷状态对网络进行重构，忽略负荷的时变特性，往往不能满足工程实际的需要。动态重构方式则由于能够根据系统状态的变化情况对网络结构进行动态调整，因而具有更高的实用性^[10]。文献[11]将负荷曲线单调区间的积分中值点作为分段点，选择最小负荷变化量的相邻时段进行合并，直至达到预设的分段数；文献[12]定义了最小收益阈值，合并相邻 2 个时段的评价函数差值小于最小收益阈值的时段。当前配网重构的研究大多忽略负荷与 DG 的时变特性，采用针对某一时间断面的静态重构方式，实际应用价值较低，动态重构研究还相对较少，此外所采用的人工智能算法没有很好地解决收敛速度慢、容易陷入局部劣解的问题。

在此基础上，本文将网络开关状态作为控制对象进行动态综合优化，建立了考虑负荷、DG 出力时变特性的配电网动态重构模型。首先采用 K-means++ 聚类算法对日负荷进行时段划分，然后以系统损耗、电压偏差量为目标函数，在求解算法方面，提出一种改进灰狼优化算法(Improved Gray Wolf Optimizer, IGWO)。通过在生成初始种群时引入 tent 映射混沌初始化，增强初始种群的均匀分布；引入合作竞争机制，提高个体间有效信息的利用率；在灰狼种群位置更新时引入自适应惯性权值，以满足不同时期的寻优要求。通过三方面进行改进，提高了算法跳出局部最优能力与寻优效率，更加有效地提高了种群的收敛速度。最后，以 IEEE33 和 PG&E 69 节点系统为例进行分析，验证了该模型和改进后的灰狼算法的可行性与优越性。

1 元件时序模型

作为主动配电网中的重要组成部分，分布式电

源及负荷的时序性对配电网的优化重构有着重要影响，而建立分布式电源与负荷的时序模型是进行配电网优化重构的基础。

1.1 风力发电机组模型

一般认为，风速近似服从 Weibull 分布， t 时刻风速 v 的概率分布密度函数可表示为^[14]

$$f(v_t) = \frac{k}{c} \left(\frac{v_t}{c}\right)^{k-1} \exp\left[-\left(\frac{v_t}{c}\right)^k\right] \quad (1)$$

式中： k 为风速的 Weibull 分布形状参数； c 为风速的 Weibull 分布尺度参数； v_t 为 t 时刻风速。

其中，Weibull 的参数可以根据风速的平均值 μ 和标准差 σ 近似算出。

$$k = \left(\frac{\delta}{\mu}\right)^{-1.086} \quad (2)$$

$$c = \frac{\mu}{\Gamma\left(1 + \frac{1}{k}\right)} \quad (3)$$

式中， $\Gamma(\cdot)$ 为 Gamma 函数。

风机(Wind Turbine Generator, WTG)出力模型中有功功率 $P_{w,t}$ 与风速 v_t 的关系可表达如式(4)^[15]。

$$P_{w,t} = \begin{cases} 0, & v_t \leq v_{ci} \text{ 或 } v_{co} \leq v_t \\ P_r \frac{v_t - v_{ci}}{v_r - v_{ci}}, & v_{ci} < v_t < v_r \\ P_r, & v_r < v_t < v_{co} \end{cases} \quad (4)$$

式中： v_{ci} 为切入风速； v_r 为额定风速； v_{co} 为切出风速； P_r 为风机额定有功功率。

根据一天每小时的风速计算当天风速的平均值和标准差，从而由式(2)、式(3)求出参数 k 和 c ，再根据风速数据，并按式(4)计算风机的出力^[16]。

1.2 光伏发电机组模型

根据文献[17]，可建立基于 Beta 分布的光伏出力概率模型。根据 Beta 分布可估计 t 时刻光伏功率的概率分布密度函数 $f(p_t)$ 如式(5)。

$$f(p_t) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} \left(\frac{p_t}{p_{\max}}\right)^{\alpha-1} \left(1 - \frac{p_t}{p_{\max}}\right)^{\beta-1} \quad (5)$$

式中： p_t 表示 t 时刻的光照强度； p_{\max} 表示光照强度最大值； α 和 β 均为光伏功率 Beta 分布的形状参数。其中，光强 Beta 分布的形状参数可根据光强的平均值 μ' 和标准差 σ' 近似算出。

$$\alpha = \mu' \left[\frac{\mu'(1-\mu')}{\sigma'^2} - 1 \right] \quad (6)$$

$$\beta = (1 - \mu') \left[\frac{\mu'(1 - \mu')}{\sigma'^2} - 1 \right] \quad (7)$$

光伏(Photovoltaic Generator, PVG)功率受太阳光照强度影响, PVG 输出有功 $P_{pv,t}$ 可表示为

$$P_{pv,t} = P_t \sum_{k=1}^K A_k \eta_k \quad (8)$$

式中: K 为光伏电池板的总数; A_k 表示第 k 个电池板的面积; η_k 表示电池板转换效率。

根据一天每小时的光照强度可以计算当天光照强度的平均值和标准差^[18], 从而由式(6)、式(7)求出参数 α 和 β , 再根据光照强度数据, 按式(8)计算光伏的有功出力。

1.3 负荷模型

本文将负荷预测的结果看成一个随机变量并采用正态分布近似表示^[16], 其概率密度函数可表示为

$$f(P_t^{\text{Load}}) = \frac{1}{\sqrt{2\pi}\sigma_p} \exp \left[-\frac{(P_t^{\text{Load}} - \mu_p)^2}{2\sigma_p^2} \right] \quad (9)$$

$$f(Q_t^{\text{Load}}) = \frac{1}{\sqrt{2\pi}\sigma_q} \exp \left[-\frac{(Q_t^{\text{Load}} - \mu_q)^2}{2\sigma_q^2} \right] \quad (10)$$

式中: P_t^{Load} 和 Q_t^{Load} 分别表示 t 时刻有功负荷和无功负荷大小; μ_p 和 σ_p 分别表示有功负荷的平均值和标准差; μ_q 和 σ_q 分别表示无功负荷的平均值和标准差。

2 配电网重构模型

2.1 目标函数

(1) 系统有功网损最低

$$f_1 = \min \sum_{t=1}^T \sum_{ij=1}^b k_{ij} R_{ij} \frac{P_{ij,t}^2 + Q_{ij,t}^2}{U_{i,t}^2} \quad (11)$$

式中: T 表示重构的时间段总数; b 为配电系统中所有支路集合; R_{ij} 为支路 ij 的电阻值; $P_{ij,t}$ 和 $Q_{ij,t}$ 分别表示 t 时段流过支路 ij 的有功功率和无功功率; k_{ij} 表示支路 ij 上的开关状态, $k_{ij} = 1$ 表示线路闭合, $k_{ij} = 0$ 表示线路断开。

(2) 电压偏移量最低

$$f_2 = \min \sum_{t=1}^T \sum_{i=1}^n \frac{|U_{i,t} - U_N|}{U_N} \quad (12)$$

式中: i 为节点编号; n 为配电网节点数; $U_{i,t}$ 表示 t 时刻节点 i 的电压; U_N 表示系统额定电压。

2.2 约束条件

(1) 节点功率平衡方程约束

$$-P_{i,t}^{\text{Load}} + P_{i,t}^{\text{DG}} + P_{i,t} = 0 \quad (13)$$

$$-Q_{i,t}^{\text{Load}} + Q_{i,t}^{\text{DG}} + Q_{i,t} = 0 \quad (14)$$

式中: $P_{i,t}^{\text{Load}}$ 、 $P_{i,t}^{\text{DG}}$ 和 $P_{i,t}$ 分别代表节点 i 在 t 时刻的有功负荷、DG 出力和网络注入功率。 $Q_{i,t}^{\text{Load}}$ 、 $Q_{i,t}^{\text{DG}}$ 和 $Q_{i,t}$ 分别代表节点 i 在 t 时刻的无功负荷、DG 出力和网络注入功率。其中 $P_{i,t}$ 与 $Q_{i,t}$ 可通过式(15)、式(16)求得。

$$P_{i,t} = U_{i,t} \sum_{j=1}^N U_{j,t} (G_{ij} \cos \theta_{ij,t} + B_{ij} \sin \theta_{ij,t}) \quad (15)$$

$$Q_{i,t} = U_{i,t} \sum_{j=1}^N U_{j,t} (G_{ij} \sin \theta_{ij,t} - B_{ij} \cos \theta_{ij,t}) \quad (16)$$

式中: $U_{i,t}$ 、 $U_{j,t}$ 分别为 t 时刻节点 i 处电压和节点 j 处电压; $\theta_{ij,t}$ 为 t 时刻节点 i 和 j 的相角差; G_{ij} 为节点 i 与节点 j 之间的电导; B_{ij} 为节点 i 与节点 j 之间的电纳。

(2) 节点电压约束

$$U_i^{\min} \leq U_{i,t} \leq U_i^{\max} \quad (17)$$

式中, U_i^{\max} 和 U_i^{\min} 分别为节点 i 电压幅值的上限和下限。

(3) 支路电流约束

$$I_{ij,t} \leq I_{ij}^{\max} \quad (18)$$

式中: $I_{ij,t}$ 为 t 时刻支路 ij 的电流幅值; I_{ij}^{\max} 为支路 ij 允许流过的最大电流值。其中 $I_{ij,t}$ 可由式(19)获得。

$$I_{ij,t}^2 = (G_{ij}^2 + B_{ij}^2) (U_{i,t}^2 + U_{j,t}^2 - 2U_{i,t}U_{j,t} \cos \theta_{ij,t}) \quad (19)$$

(4) 分布式电源功率约束

$$P_{i,t}^{\text{DG}} = \hat{P}_{i,t}^{\text{DG}} \quad (20)$$

$$Q_{i,t}^{\text{DG}} = P_{i,t}^{\text{DG}} \tan \theta_{i,t}^{\text{DG}} \quad (21)$$

$$\sqrt{(P_{i,t}^{\text{DG}})^2 + (Q_{i,t}^{\text{DG}})^2} \leq S_i^{\text{DG}} \quad (22)$$

式中: $\hat{P}_{i,t}^{\text{DG}}$ 为 t 时刻节点 i 处 DG 有功功率的预测值; $\theta_{i,t}^{\text{DG}}$ 为 t 时刻节点 i 处 DG 功率因数角; S_i^{DG} 为节点 i 上 DG 的容量。

3 基于 K-means++ 聚类算法的时段划分

3.1 K-means++ 聚类原理

传统的 K-means 聚类方法, 在确定了 k 的个数后, k 个初始化聚类中心的位置选择对聚类结果有着较大的影响, 若初始值选取的较集中, 最后的聚类结果就可能不理想。

因此为了选择合适的初始的 k 个聚类中心, 本文采用 K-means++ 聚类算法对负荷进行时段划分。

K-means++算法就是对 K-means 随机初始化质心的方法进行优化, 具体思路就是初始的聚类中心之间的相互距离要尽可能的远。

K-means++对于初始化聚类中心的优化策略如下述。

(1) 设聚类数为 k , 从数据集中任意选取一点将其作为初始聚类的中心。

(2) 计算每个样本 x_i 与已有聚类中心点的最短距离(即与最近一个聚类中心的距离), 用 $D(x)$ 表示。

(3) 计算得到的距离累加和 $\sum D(x)$, 然后计算每个样本被选为下一个聚类中心点的概率:

$$P(x) = \frac{D(x)}{\sum D(x)} \quad (23)$$

(4) 用轮盘法选出下一个聚类中心: 将 $P(x)$ 概率依次计算累加和, 生成每个样本对应的概率区间, 随机生成一个 0-1 之间的随机数, 判断它属于哪个区间, 那么该区间对应的序号就是被选择出来的第二个聚类中心。

(5) 重复步骤(2)–(4), 直到选出 k 个聚类中心。

对于 K-means++ 聚类算法的分析, 最佳聚类数的确定也非常重要, 本文采用“手肘法”来确定 k 的取值, 首先定义用来评价聚类好坏的评价标准: 误差平方和 SSE 。

$$SSE = \sum_{i=1}^k \sum_{p \in c_i} |p - m_i|^2 \quad (24)$$

式中: SSE 是所有样本的聚类误差, 其值的大小代表着聚类效果的优劣; c_i 表示第 i 个簇; p 是 c_i 中的样本点; m_i 是 c_i 的聚类中心。

当 k 小于最佳聚类数时, SSE 的下降程度较为明显, 而当 k 到达最佳聚类数附近时, 再增大 k 值, SSE 的下降程度变小, 然后继续增大 k 值, SSE 的变化变得平缓, 通过比较 SSE 与 k 的数据大小可以发现随着 k 的增大, SSE 的变化图形类似手肘的形状, 而这个肘部对应的 k 值就是数据的最佳聚类数。

但是在某些情况下, 用“手肘法”进行聚类簇数划分时, 有时候拐点不明显, 无法通过直接观察得到, 而只能根据手肘法判断这个拐点的大致范围, 在这种情况下, 可以利用聚类评估方法中的轮廓系数法来进一步对聚类的簇数划分进行确定。对任意一个数据样本 x 而言, 其轮廓系数 $y(x)$ 可表示为

$$y(x) = \frac{b(x) - a(x)}{\max[a(x), b(x)]} \quad (25)$$

式中: $a(x)$ 表示样本 x 到其所在类簇中的其他各点距离的平均值; $b(x)$ 代表样本到除自身所在簇外的其他簇样本的均值; $y(x)$ 取值在 $[-1, 1]$ 之间, 当 $y(x)$ 的值越接近于 1 时, 说明聚类簇数的划分越合理,

因为在这种情况下有 $b(x) > a(x)$ 。

3.2 基于 K-means++ 聚类的时段划分方法

配电网中各个节点的负荷状态是随时间而动态变化的, 在一定的时间范围内的所有时间点的负荷状态构成一个数据集合, 每个负荷状态对应一个时间点, 数据的维度对应系统的节点数。假设在主动配电网重构过程中, 以一个小时为一个时间段, 在单个时间段中, 网络中各个节点的负荷大小恒定; 将各时段内节点负荷的状态 S 看成是聚类分析的样本, $S = \{S_1, S_2, \dots, S_{24}\}$, S_t 表示第 t 个时段内的负荷状态, 其中 $S_t = \{S_{t1}, S_{t2}, \dots, S_{tm}\}$, S_{tj} 表示第 t 时段节点 j 的有功功率。

将 S 划分为 k 类, 对应的聚类中心为 $m = \{m_1, m_2, \dots, m_k\}$, 第 i 个聚类中心 $m_i = \{m_{i1}, m_{i2}, \dots, m_{im}\}$, 其中 m_{in} 为第 i 个聚类中心节点 n 的负荷有功功率。具体步骤如下述。

(1) 令初始 k 值为 1, 采用 K-means++ 算法对于初始化聚类中心的优化方法, 选取 k 个初始聚类中心。

(2) 根据设置的数据向量 S , 计算每个数据对象分别到这 k 个中心的欧式距离大小。

(3) 将每个数据对象分到与它距离最近的聚类中心, 形成 k 个簇。划分完类簇后, 计算每个簇的均值, 将它重新设定为每个类簇的聚类中心。

(4) 重复步骤(2)–(3), 直到 k 个聚类中心位置不再变化, 或者达到最大迭代次数。

(5) 根据公式(24)计算在 k 个聚类下的误差平方和, 并令 $k = k + 1$, 重复步骤(1)–(4)。

(6) 利用手肘法确定最佳聚类的范围, 再根据式(25)比较范围内各聚类数目轮廓系数的大小, 其最大值即为最佳聚类数。输出聚类数以及各时段节点负荷聚类的结果。

4 改进灰狼优化算法

4.1 初始灰狼优化算法

灰狼优化^[19](Gray Wolf Optimizer, GWO)算法的灵感来自于灰狼的狩猎机制, 在优化过程中, 将可能存在的解视为狼, 将所有解中存在的那个最优解看作猎物。通过参考狼群的等级排序、狩猎技术分别对各解进行分级、搜索, 直到找到最优解^[20]。

(1) 狼群等级分级

在 GWO 算法结构中, 根据体力、智力、领导能力和年龄等相关因素, 狼群中的个体被分为了 4 个等级, 自上而下分别为 α 、 β 、 δ 、 ω 。其中, α 狼是狼群中的领导者, 为狼群中最优个体, 有权做出重要决定, 如狩猎、睡觉时间、醒来时间等。 β 狼

属于第二等级, 是仅次于 α 的存在。其次为 δ 狼, 剩余的则为 ω 狼。捕猎过程由 α 、 β 、 δ 狼决定、引导完成, 处于最底层的 ω 狼听从高级别狼的指令来进行捕食。

(2) 灰狼进攻行为

在灰狼优化算法中, 将每次迭代中获得的最好的三个解分别赋予 α 、 β 、 δ 狼, 其他灰狼则根据 α 、 β 、 δ 狼更改自身位置, 具体表达式为

$$D_\alpha = |C \cdot x_\alpha^k - x_i^k| \quad (26)$$

$$D_\beta = |C \cdot x_\beta^k - x_i^k| \quad (27)$$

$$D_\delta = |C \cdot x_\delta^k - x_i^k| \quad (28)$$

式中: D_α 、 D_β 、 D_δ 分别为第 k 代时第 i 个个体与 α 、 β 、 δ 的距离; x_α^k 、 x_β^k 、 x_δ^k 分别为第 k 代时 α 、 β 、 δ 所在的位置。 $C = 2 \cdot rand$, $rand$ 为 $[0,1]$ 之间的随机数。

随后, 狼群其他个体利用 α 、 β 和 δ 之间的位置判断猎物位置, 对猎物进行围剿, 该过程可描述为

$$X_1 = x_\alpha^k - A \cdot D_\alpha \quad (29)$$

$$X_2 = x_\beta^k - A \cdot D_\beta \quad (30)$$

$$X_3 = x_\delta^k - A \cdot D_\delta \quad (31)$$

$$X_i^{k+1} = (X_1 + X_2 + X_3) / 3 \quad (32)$$

式中: X_i^{k+1} 为第 i 个个体更新后的位置; $A = (2rand - 1)a$, $a = 2 - 2k/k_{max}$, k 为当前迭代次数, k_{max} 为最大迭代次数; X_1 、 X_2 、 X_3 分别为各狼受 α 、 β 、 δ 狼影响后的移动方位, 由式(32)可判断出猎物的移动方向, 通过不断迭代搜索, 寻找全局最优解。

4.2 改进灰狼优化算法

4.2.1 基于 Tent 映射的种群初始化

初始种群在搜索空间的分布越均匀, 对提升算法的寻优效率和求解的精度越有利。传统的灰狼优化算法的初始灰狼群是随机产生的, 无法保证初始种群个体均匀分布在解空间内, 而种群的过度集中可能会造成局部最优, 影响配电网最优重构方案的产生。混沌序列具有较好的随机性、规律性以及遍历性等特点。与其他映射相比较, Tent 映射能生成更均衡分布的序列^[21], 因此采用 Tent 映射用来初始化灰狼种群。

Tent 映射表达式:

$$x_{t+1} = \begin{cases} x_t & 0 \leq x_t < u \\ u & \\ 1 - x_t & u \leq x_t \leq 1 \\ 1 - u & \end{cases} \quad (33)$$

当 $u = 0.5$ 时, 可以产生最为均匀的分布序列, 这时的分布密度对参数变化不敏感, 这种属于最典型的 Tent 映射, 此时上式可变为

$$x_{t+1} = \begin{cases} 2x_t & 0 \leq x_t < 0.5 \\ 2(1 - x_t) & 0.5 \leq x_t \leq 1 \end{cases} \quad (34)$$

基于 Tent 映射, 种群 X 表示为

$$X = X_{min} + x_t \cdot (X_{max} - X_{min}) \quad (35)$$

式中, X_{max} 和 X_{min} 分别为 X 的搜索上下界。

4.2.2 竞争合作机制

GWO 算法中, 种群个体遵从 α 、 β 、 δ 的指挥进行狩猎, 而个体之间是相互独立的, 缺乏个体之间的信息交流, 有效的信息不能好好利用, 导致算法会出现收敛速度慢、寻优精度不高等缺点, 故引入合作竞争机制, 在对猎物进行围捕前, 除 α 、 β 、 δ 的每只狼 x_i^k 会随机选择另一只狼 x_j^k 进行交流, 如果 x_i^k 所在位置优于 x_j^k , 则 x_j^k 向 x_i^k 靠近, x_j^k 按式(36)进行移动, x_i^k 远离 x_j^k , x_i^k 按式(37)进行移动; 否则执行相反操作。

$$x_j^{k'} = x_j^k + rand \cdot (x_i^k - x_j^k) \quad (36)$$

$$x_i^{k'} = x_i^k + rand \cdot (x_i^k - x_j^k) \quad (37)$$

式中, $x_i^{k'}$ 、 $x_j^{k'}$ 分别为合作竞争机制后第 i 个个体和第 j 个个体所在的位置。

4.2.3 自适应调整权重系数

为满足 GWO 算法在不同迭代周期的寻优要求, 提高收敛速度和寻优精度, 在位置更新中引入自适应惯性权值 ω 。

$$\omega = \omega_{min} + (\omega_{max} - \omega_{min}) \frac{\max_iter - t}{\max_iter} \quad (38)$$

式中: ω_{max} 、 ω_{min} 分别为权重系数的上下限; t 为迭代次数; \max_iter 为最大迭代次数。

ω 值随着迭代次数的不同而动态变化, 使得粒子在全局寻优和局部搜索中不断平衡。算法迭代初期 ω 较大, 有利于算法的全局搜索; 迭代后期 ω 逐渐减小, 使得灰狼在更新位置的同时能够更好地寻找猎物周围是否存在更优解, 以此提高算法的局部搜索能力。

改进后的位置公式如式(39)一式(41)所示。

$$X_1 = \omega \cdot x_\alpha^k - A \cdot D_\alpha \quad (39)$$

$$X_2 = \omega \cdot x_\beta^k - A \cdot D_\beta \quad (40)$$

$$X_3 = \omega \cdot x_\delta^k - A \cdot D_\delta \quad (41)$$

4.3 算法步骤

(1) 设置算法参数。初始设置的参数主要有种群数 M 、最大迭代次数 T 、维度 D 、求解空间的上限 UB 和下限 LB 。

- (2) 进行混沌初始化, 按式(35)生成初始种群。
 - (3) 计算种群中每个个体的适应度值, 并选取适应度值最小的 3 个个体的位置分别作为 α 、 β 和 δ 。
 - (4) 除 α 、 β 、 δ 的灰狼个体按式(36)、式(37)执行合作竞争机制。
 - (5) 根据式(26)一式(28)计算其他灰狼与 α 、 β 和 δ 的距离。根据式(39)一式(41)更新其他灰狼的位置。
 - (6) 若达到最大迭代次数, 转至步骤(8); 否则转至步骤(7)。
 - (7) 重新排序, 确定灰狼的位置, 转至步骤(3)。
 - (8) 输出当前最优解, 算法结束。
- 改进 GWO 算法计算的流程图如图 1 所示。

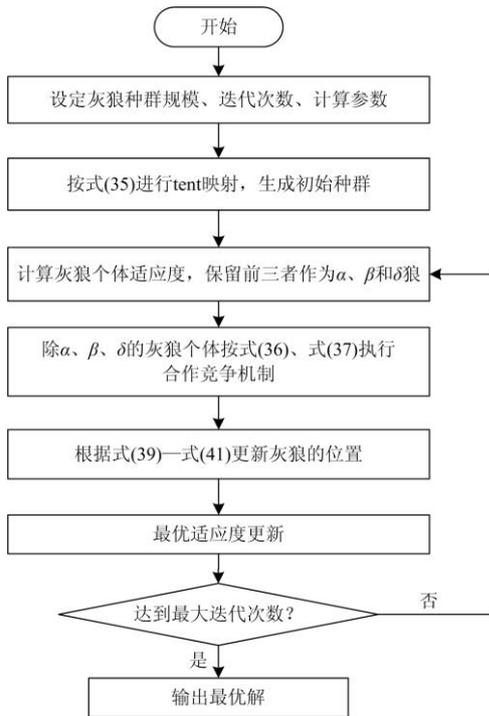


图 1 改进 GWO 算法流程图

Fig. 1 Flow chart of improved GWO algorithm

5 算例

5.1 基本参数

本文以 IEEE33 节点配电网系统^[22]为例, 在使用 inter(R) core(TM) i5-9300H CPU、8 G 内存的计算机的 Matlab R2014a 平台上进行测试, 系统结构图如图 2 所示。分别在 9、18、19、21、32 节点上接入 DG, 其中节点 9、18、21 上接入的是风机, 而节点 19、32 上接入的是光伏。一天中各时段风速和光照强度参考文献[23]。风电和光伏的参数如表 1 和表 2 所示。算法种群规模设为 50, 最大迭代次数为 100, $\omega_{\max}=0.9$, $\omega_{\min}=0.4$ 。本文设定在重构时段内开关动作总次数不超过 20 次, 单个开关动作次数

不超过 4 次; 风机、光伏系统在各个时间段的最大出力 and 负荷需求情况如图 3 所示。

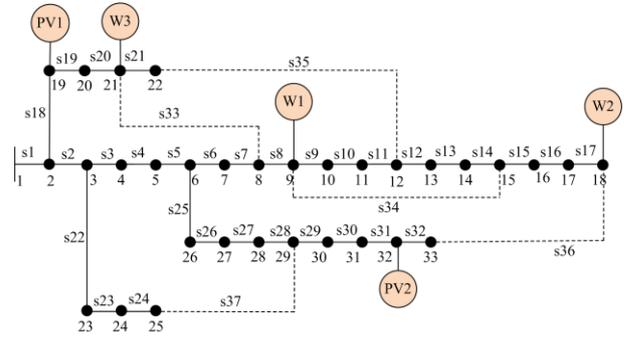


图 2 含 DG 的 IEEE33 节点配电系统

Fig. 2 IEEE33 nodes distribution system containing DG

表 1 风电机组参数

Table 1 Wind turbine parameters

风电机组	P_r/kW	$v_{ci}/(m/s)$	$v_r/(m/s)$	$v_{out}/(m/s)$
W1	500	3.5	14.5	20
W2	600	3.0	13.0	19
W3	500	3.5	15	20

表 2 光伏电池参数

Table 2 Photovoltaic cell parameters

光伏电池	A/m^2	$\eta/\%$	$p_{\max}/(W/m^2)$
PV1	7 000	15	20
PV2	6 000	15	20

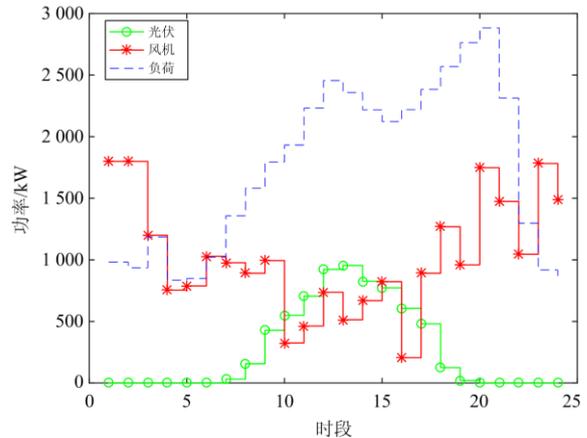


图 3 风光荷出力曲线

Fig. 3 Curve of DG and load

运用 K-means++ 聚类算法对重构时段进行划分, 根据聚类簇数划分的“手肘法”, 可得簇数划分分数 x 与数值 $f(x)$ 的关系如图 4 所示。

由图 4 可知, 初步确定拐点“明显点”为 3、4、5, 即聚类数目在 3、4、5 中选择, 再利用轮廓系数进行评估, 可得各个划分类数的轮廓系数如表 3 所示。

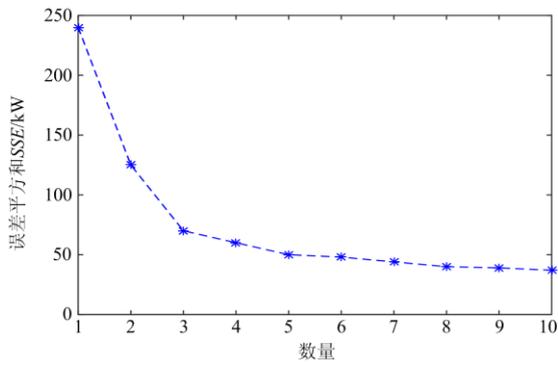


图4 手肘法

Fig. 4 Elbow method

表3 轮廓系数

Table 3 Silhouette coefficient

划分聚类数	3	4	5
轮廓系数	0.917	0.92	0.918

根据轮廓系数, 将故障时段划分为4个类簇, 各个类簇所包含的时段如图5所示。

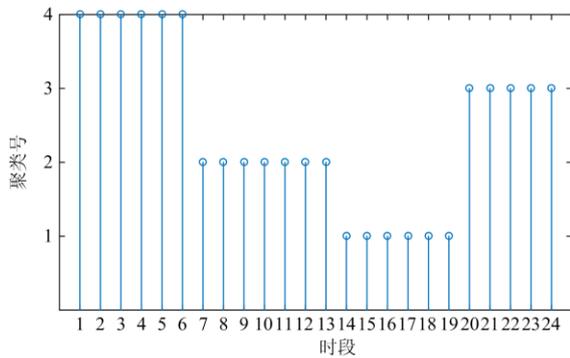


图5 聚类分类结果

Fig. 5 Clustering segmentation results

5.2 重构结果分析

为验证本文所提方法的有效性, 设置以下三种方案进行对比分析。

方案 1: 不进行网络重构。

方案 2: 采用本文所提的改进灰狼优化算法, 但全天重构一次, 没有进行动态优化。

方案 3: 采用本文所提的方法。

对以上三种方案各运行 50 次, 取其中最好的一次运行结果作为最终结果, 则三种方案的重构对比结果如表 4 所示。

根据表 4 的方案 1 与方案 2 的对比可知: 不进行网络重构的配电网在重构时段内分段开关不动作, 没有任何的优化措施, 导致系统的整体网损较高, 电压偏离度较大。经过本文改进灰狼优化算法进

行重构后, 网损从 1 268.6 kWh 降为 914.2 kWh, 降低了 27.94%, 降损效果明显; 电压偏差从 24.6 p.u. 降为 18.3 p.u., 降低了 25.6%。通过方案 2 与方案 3 的对比, 虽然利用改进灰狼优化算法能够提升网损与电压质量, 但由于重构方案是在全时段内仅优化了一次, 没有在开关动作最大允许的动作范围内, 合理利用配电网拓扑结构的动态变化, 单一重构方式虽然开关动作次数较少, 但相比方案 3 的网损和电压情况, 方案 3 的动态重构虽然增加了开关动作次数, 但重构效果要好于方案 2。方案 3 通过对负荷时段进行聚类, 在各个划分时段内分别求取最优的配电网重构方案, 相比于方案 2, 网损从 914.2 kWh 降低为 713 kWh, 降低了 22%, 电压偏差从 18.3 p.u. 降为 15.8 p.u., 降低了 13.67%。以上结果表明, 本文方法相比方案 1 与方案 2 能够显著降低配电网网损, 改善节点电压偏离度, 提高电能质量, 从而提升系统的经济性和可靠性。三种方案各时段网损值如图 6 所示。

表4 重构结果对比

Table 4 Comparison of reconstruction results

方案	时段	断开支路	网损/kWh	电压偏差/p.u.
方案 1	全时段	s33、s34、s35、s36、s37	1 268.6	24.6
方案 2	全时段	s7、s14、s9、s36、s37	914.2	18.3
方案 3	00:00—06:00	s7、s34、s9、s31、s37	713	15.8
	06:00—13:00	s7、s14、s9、s31、s36		
	13:00—19:00	s7、s14、s9、s32、s28		
	19:00—24:00	s7、s14、s9、s32、s28		

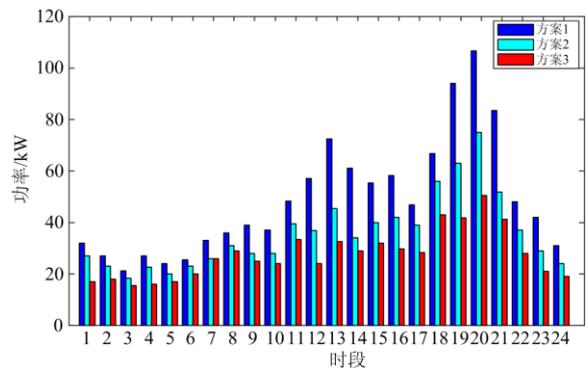


图6 不同方案下各时段的网损

Fig. 6 Network loss at each time period under different schemes

由图 6 可知, 方案 3 与方案 1 和方案 2 相比, 在每个时段都能够有效地降低网损。其中在 19:00—21:00 时段, 配电系统的网损较高, 这是因为该时段是一天中的峰荷时期, 此时光伏出力基本为零, 线路重载, 从而导致网损增大, 在这一时段降损幅度最大, 对网损改善明显。

三种方案下系统各节点电压波动分别如图 7、图 8 和图 9 所示。通过比较可知, 方案 3 与方案 1 和方案 2 相比, 网络节点电压在整体上普遍有所提升, 电压分布较为均匀。

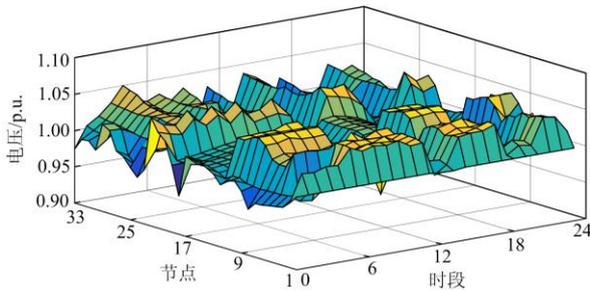


图 7 方案 1 各节点电压水平

Fig. 7 Voltage levels of each node in scheme 1

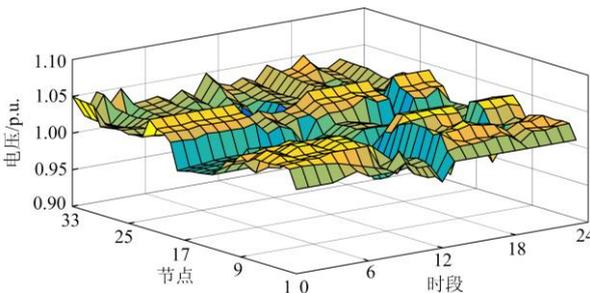


图 8 方案 2 各节点电压水平

Fig. 8 Voltage levels of each node in scheme 2

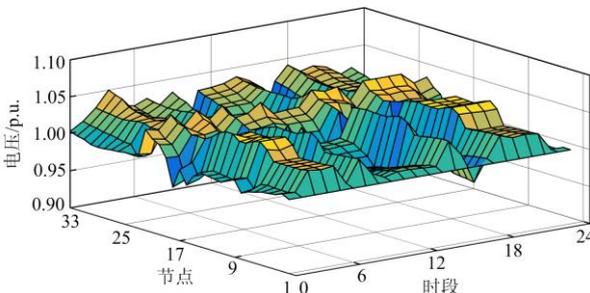


图 9 方案 3 各节点电压水平

Fig. 9 Voltage levels of each node in scheme 3

5.3 不同算法的对比分析

为了进一步说明本文所提算法的性能, 将本文算法与粒子群算法和传统灰狼优化算法进行比较,

每种算法独立进行 50 次运算, 然后计算平均值, 计算结果如表 5 所示。

表 5 不同算法重构结果比较

Table 5 Reconfiguration results comparison of different algorithms

算法	平均网损/ kWh	平均电压 偏差/p.u.	平均迭 代次数	平均 耗时/s
粒子群算法	1 074.4	21.6	49	19.56
传统灰狼算法	897.5	17.8	41	16.35
本文算法	726.2	16.3	24	8.54

由表 5 可见, 本文算法的最优解优于传统灰狼优化算法与粒子群算法, 而本文算法通过在生成初始种群时引入 tent 映射混沌初始化, 引入合作竞争机制和引入自适应惯性权值三方面改进后, 由三种算法在平均迭代次数与平均耗时上的对比可知, 本文算法能够兼顾全局寻优和局部寻优能力, 不仅在收敛迭代次数上优于另外两种方法, 平均迭代次数在 24 次左右, 且收敛时间更短, 与传统灰狼优化算法相比, 速度提升了 47.76%。

5.4 通用性验证

为证明上述方法的通用性, 本文利用改进 PG&E 69 节点系统^[24]再次进行仿真, 系统结构如图 10 所示。分别在节点 5、33、64 处接入风机, 在节点 14、50 处接入光伏, 光伏与风机的参数与 5.1 节参数相同。方案设置与前文相同, 每种方案运行 50 次, 取其中最好的一次做最终结果, 仿真结果如表 6 所示。

表 6 重构结果对比

Table 6 Comparison of reconstruction results

方案	时段	断开支路	网损/kWh	电压偏差/ p.u.
方案 1	全时段	s69、s70、s71、 s72、s73	1 409.6	43.36
方案 2	全时段	s12、s18、s58、 s61、s69	1 119.7	35.21
方案 3	00:00—08:00	s14、s47、s50、 s69、s70	827.2	24.8
	08:00—14:00	s10、s19、s26、 s71、s73		
	14:00—17:00	s8、s19、s26、 s36、s66		
	17:00—24:00	s17、s25、s59、 s67、s73		

与 IEEE33 节点系统重构相似, 本文提出的 K-means++ 聚类算法, 将重构周期 24 h 划分成 4 个时段: 00:00—08:00, 08:00—14:00, 14:00—17:00 以及 17:00—24:00。从表 6 中可以看出, 方案 3 与

方案 1 和方案 2 相比, 有功总网损大大减小, 由重构前的 1409.6 kWh 降低至 827.2 kWh, 降低了 41.32%, 此外节点电压偏差也由 43.36 p.u.降低至

24.8 p.u., 降低了 42.8%, 电压质量显著改善。三种方案各时段网损值如图 11 所示, 系统各节点电压波动分别如图 12、图 13 和图 14 所示。

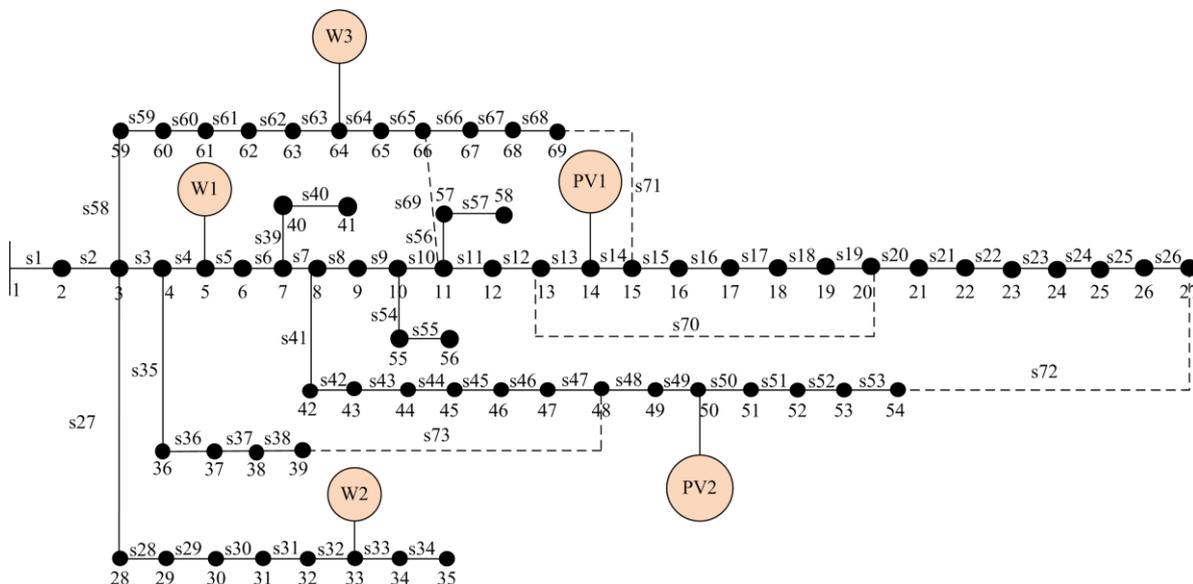


图 10 含 DG 的 PG&E 69 节点配电系统

Fig. 10 PG&E 69 nodes distribution system containing DG

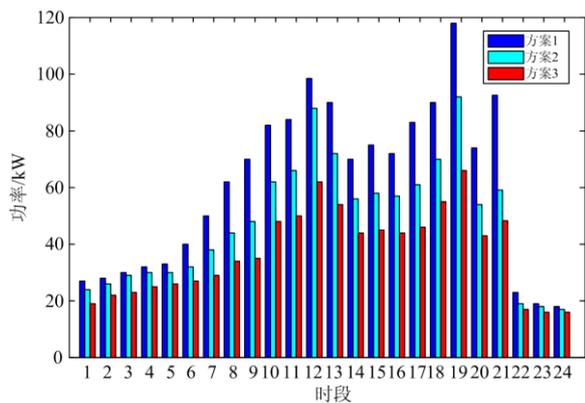


图 11 不同方案下各时段的网损(PG&E 69)

Fig. 11 Network loss at each time period under different schemes (PG&E 69)

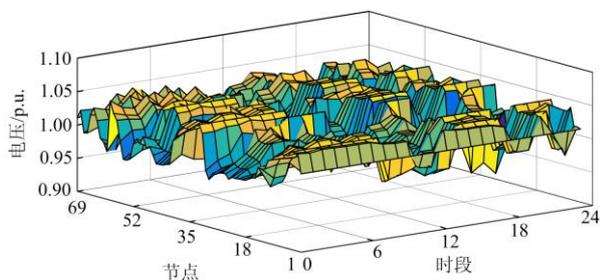


图 12 方案 1 各节点电压水平(PG&E 69)

Fig. 12 Voltage levels of each node in scheme 1 (PG&E 69)

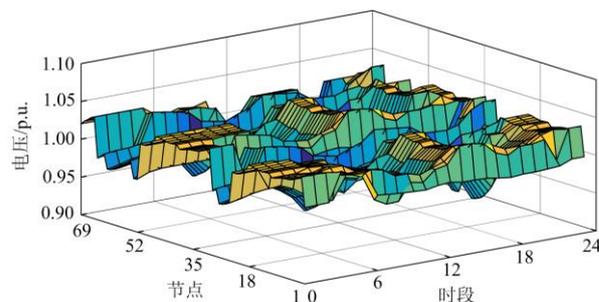


图 13 方案 2 各节点电压水平(PG&E 69)

Fig. 13 Voltage levels of each node in scheme 2 (PG&E 69)

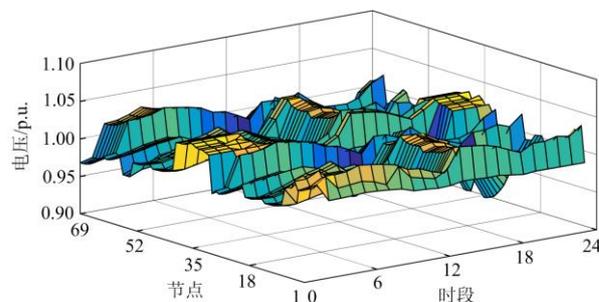


图 14 方案 3 各节点电压水平(PG&E 69)

Fig. 14 Voltage levels of each node in scheme 3 (PG&E 69)

通过比较可知, 方案 3 与方案 1 和方案 2 相比, 不仅在各个时段都能够有效降低网损值且网络节点电压在整体上普遍有所提升, 电压分布较均匀。

综上, 本文提出的改进灰狼算法的动态配网重构方法在 IEEE33 节点系统和 PG&E 69 节点系统中都表现出良好的效果, 证明了本文方法在配网重构应用中的优越性和通用性。

6 结论

针对配电网重构问题, 文中将线路开关状态作为控制变量, 采用 K-means++ 聚类算法对日负荷进行时段划分, 建立了以网络损耗、电压偏离量为目标的配电网动态重构模型, 利用改进后的灰狼优化算法对配电网进行动态优化重构。通过在初始种群生成、自适应权重调整、个体间信息交流三方面进行改进, 提高了算法跳出局部最优的能力与寻优效率。通过优化结果分析得出, 所提算法及重构优化策略在降低网损、提高电压质量等方面均有显著成效, 具有一定的实际意义。

参考文献

- [1] 田昊, 吕林, 高红均, 等. 计及电网运行特性的配电网动态重构[J]. 电力系统保护与控制, 2015, 43(1): 9-14.
TIAN Hao, LÜ Lin, GAO Hongjun, et al. Dynamic reconfiguration of distribution network considering power grid operation characteristic[J]. Power System Protection and Control, 2015, 43(1): 9-14.
- [2] FAN Jiyuan, ZHANG Lan, MCDONALD J D. Distribution network reconfiguration: single loop optimization[J]. IEEE Transactions on Power Systems, 1996, 11(3): 1643-1647.
- [3] 刘柏私, 谢开贵, 周家启. 配电网重构的动态规划算法[J]. 中国电机工程学报, 2005, 25(9): 29-34.
LIU Baisi, XIE Kaigui, ZHOU Jiaqi. Dynamic programming algorithm for distribution network reconstruction[J]. Proceedings of the CSEE, 2005, 25(9): 29-34.
- [4] 黄伟, 纪双全. 基于馈线偶的配电网快速减小网损重构方法[J]. 电力系统自动化, 2015, 39(5): 75-80.
HUANG Wei, JI Shuangquan. A method for fast loss reduction and reconstruction of distribution network based on feeder couple[J]. Automation of Electric Power Systems, 2015, 39(5): 75-80.
- [5] 张重实, 王高猛, 张檀雍, 等. 基于最优流法与 Mayeda 生成树算法相结合的单阶段配网重构新方法[J]. 中国电力, 2018, 51(9): 110-117.
ZHANG Zhongshi, WANG Gaomeng, ZHANG Tanyong, et al. A new method for one-stage distribution system reconfiguration based on optimal flow algorithm and Mayeda spanning tree algorithm[J]. Electric Power, 2018, 51(9): 110-117.
- [6] ABDELAZIZ M. Distribution network reconfiguration using a genetic algorithm with varying population size[J]. Electric Power Systems Research, 2017, 142: 9-11.
- [7] 徐渊. 改进粒子群算法在含分布式电源配电网优化重构中的应用[J]. 电测与仪表, 2021, 58(3): 98-104.
XU Yuan. Application of improved particle swarm optimization algorithm in the optimization and reconstruction of distribution network with distributed power[J]. Electrical Measurement & Instrumentation, 2021, 58(3): 98-104.
- [8] 阳晓明, 吕红芳, 朱辉. 基于改进人工鱼群算法的配电网网络重构[J]. 电测与仪表, 2020, 57(17): 72-78, 98.
YANG Xiaoming, LÜ Hongfang, ZHU Hui. Reconfiguration of distribution network based on improved artificial fish swarm algorithm[J]. Electrical Measurement & Instrumentation, 2020, 57(17): 72-78, 98.
- [9] 李镭, 王利利, 刘向实, 等. 基于门当户对遗传算法的配电网多目标主动重构研究[J]. 电力系统保护与控制, 2019, 47(7): 30-38.
LI Meng, WANG Lili, LIU Xiangshi, et al. Multi-objective active reconfiguration of distribution network based on the "properly matched marriage" genetic algorithm[J]. Power System Protection and Control, 2019, 47(7): 30-38.
- [10] JASTHI K, DAS D. Simultaneous distribution system reconfiguration and DG sizing algorithm without load flow solution[J]. IET Generation, Transmission & Distribution, 2018, 12(6): 1303-1313.
- [11] 陈禹, 唐巍, 陈昕玥, 等. 基于负荷-光伏等效负荷曲线动态分段的配电网联络开关优化配置[J]. 电力自动化设备, 2015, 35(3): 47-53.
CHEN Yu, TANG Wei, CHEN Xinyue, et al. Tie switch allocation optimization based on dynamic segment of equivalent load-PV curve[J]. Electric Power Automation Equipment, 2015, 35(3): 47-53.
- [12] 田昊, 吕林, 高红均, 等. 计及电网运行特性的配电网动态重构[J]. 电力系统保护与控制, 2015, 43(1): 9-14.
TIAN Hao, LÜ Lin, GAO Hongjun, et al. Dynamic reconfiguration of a distribution network taking into account its operating characteristics[J]. Power System Protection and Control, 2015, 43(1): 9-14.
- [13] 江东林, 刘天琪, 李樊. 采用时段动态划分和分层优化策略的配电网重构[J]. 电网技术, 2012, 36(2): 153-157.
JIANG Donglin, LIU Tianqi, LI Fan. Dynamic distribution

- network reconfiguration based on dynamic partition of time intervals and hierarchical optimization[J]. *Power System Technology*, 2012, 36(2): 153-157.
- [14] 黄伟, 杨舒文, 葛良军. 基于概率潮流的主动配电网供需群体协同优化运行策略[J]. *电力系统自动化*, 2017, 41(13): 39-44.
HUANG Wei, YANG Shuwen, GE Liangjun. Cooperative optimization operation strategy of supply and demand groups in active distribution networks based on probabilistic power flow[J]. *Automation of Electric Power Systems*, 2017, 41(13): 39-44.
- [15] 倪识远, 张林垚. 考虑动态重构的主动配电网多目标双层优化调度方法[J]. *电力系统保护与控制*, 2020, 48(20): 38-47.
NI Shiyuan, ZHANG Linyao. Multi-objective two-layer optimal dispatching method for active distribution networks considering dynamic reconstruction[J]. *Power System Protection and Control*, 2020, 48(20): 38-47.
- [16] 张美霞, 陈洁, 杨秀, 等. 考虑风光和负荷随机性的微网三相潮流计算[J]. *中国电机工程学报*, 2013, 33(13): 101-107.
ZHANG Meixia, CHEN Jie, YANG Xiu, et al. Calculation of three-phase power flow for micro grid considering randomness of scenery and load[J]. *Proceedings of the CSEE*, 2013, 33(13): 101-107.
- [17] 徐俊俊, 戴桂木, 吴在军, 等. 计及电动汽车和光伏不确定性的主动配电网量测优化配置[J]. *电力系统自动化*, 2017, 41(1): 57-64.
XU Junjun, DAI Guimu, WU Zaijun, et al. Optimization of measurement and configuration of active distribution network with uncertainty of electric vehicles and photovoltaic[J]. *Automation of Electric Power Systems*, 2017, 41(1): 57-64.
- [18] LI Jianlin, XUE Yushi, TIAN Liting, et al. Research on optimal configuration strategy of energy storage capacity in grid-connected microgrid[J]. *Protection and Control of Modern Power Systems*, 2017, 2(4): 389-396. DOI: 10.1186/s41601-017-0067-8.
- [19] 吴亚雄, 高崇, 曹华珍, 等. 基于灰狼优化聚类算法的日负荷曲线聚类分析[J]. *电力系统保护与控制*, 2020, 48(6): 68-76.
WU Yaxiong, GAO Chong, CAO Huazhen, et al. Daily load curve clustering analysis based on grey Wolf optimization clustering algorithm[J]. *Power System Protection and Control*, 2020, 48(6): 68-76.
- [20] TAHA I M, ELATTAR E E. Optimal reactive power resources sizing for power system operations enhancement based on improved grey wolf optimiser[J]. *IET Generation, Transmission & Distribution*, 2018, 12(14): 3421-3434.
- [21] 雍静, 赵瑾, 郇嘉嘉, 等. 基于混沌增强烟花算法的多能源系统并网优化调度[J]. *电网技术*, 2019, 43(10): 3725-3732.
YONG Jing, ZHAO Jin, HUAN Jijia, et al. Grid optimization scheduling of multi-energy systems based on chaotic enhanced fireworks algorithm[J]. *Power System Technology*, 2019, 43(10): 3725-3732.
- [22] 刘爱国, 王志平, 张志豪. 考虑电动汽车有序充电的配电网重构[J]. *电测与仪表*, 2019, 56(11): 14-19.
LIU Aiguo, WANG Zhiping, ZHANG Zhihao. Distribution network reconfiguration considering the ordered charging of electric vehicles[J]. *Electric Measurement & Instrumentation*, 2019, 56(11): 14-19.
- [23] 易海川, 张彼德, 王海颖, 等. 提高 DG 接纳能力的配电网动态重构方法[J]. *电网技术*, 2016, 40(5): 1431-1436.
YI Haichuan, ZHANG Bide, WANG Haiying, et al. Dynamic reconstruction method of distribution network to improve the reception capacity of DG[J]. *Power System Technology*, 2016, 40(5): 1431-1436.
- [24] SAVIER J S, DAS D. Impact of network reconfiguration on loss allocation of radial distribution systems[J]. *IEEE Transactions on Power Delivery*, 2007, 22(4): 2473-2480.

收稿日期: 2020-11-05; 修回日期: 2021-01-08

作者简介:

田书欣(1985—), 男, 博士, 讲师, 主要从事电力系统规划、智能配电网运行等方面的研究工作; E-mail: tsx396@163.com

刘浪(1996—), 男, 硕士研究生, 主要从事主动配电网自愈技术方面的研究工作; E-mail: 2450694687@qq.com

魏书荣(1980—), 女, 博士, 副教授, 主要从事海上风电优化规划与故障诊断等方面的研究工作。E-mail: wsrmail@163.com

(编辑 魏小丽)