

12-30-2023

Optimized scheduling of Distribution Network with Distributed Generation Based on Coronavirus Herd Immunity Optimizer Algorithm

Xiaomeng Wu

School of Electronic Engineering, Xi'an Shiyou University, Xi'an 710065, China, xmwu@xsyu.edu.cn

Rongze Yuan

AVIC Shaanxi Aero Electric Co. , Ltd, Xi'an 710065, China, 1264234737@qq.com

Yingliang Li

School of Electronic Engineering, Xi'an Shiyou University, Xi'an 710065, China

Qi Zhu

School of Electronic Engineering, Xi'an Shiyou University, Xi'an 710065, China

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

Optimized scheduling of Distribution Network with Distributed Generation Based on Coronavirus Herd Immunity Optimizer Algorithm

Abstract

Abstract: Following the large-scale entry of distributed new energy into the network, the uncertainty factor of the distribution network increases significantly, and the difficulty of reactive power optimization scheduling increases accordingly. Traditional optimization solutions have many limitations and shortcomings, and a dynamic reactive power optimization scheme for active distribution networks based on a multi-scenario approach is proposed. The mathematical modeling is carried out separately for the uncertainty of new energy and load, and the multi-scenario method is used to transform the uncertainty problem into a deterministic problem. A mathematical model is constructed on the distribution network side to pursue the integrated optimal value of the expected cost of network loss and reactive power compensation equipment regulation, and the coronavirus herd immunity optimizer is used to solve it. The results show that the optimization scheme obtained from the algorithm can effectively save the distribution network operation cost and reduce the network loss.

Keywords

distribution network, coronavirus herd immunity optimizer, reactive power optimization, power system simulation

Recommended Citation

Wu Xiaomeng, Yuan Rongze, Li Yingliang, et al. Optimized scheduling of Distribution Network with Distributed Generation Based on Coronavirus Herd Immunity Optimizer Algorithm[J]. Journal of System Simulation, 2023, 35(12): 2692-2702.

基于新冠病毒群体免疫算法的有源配电网优化调度

武晓朦¹, 袁榕泽^{2*}, 李英量¹, 朱琦¹

(1. 西安石油大学 电子工程学院, 陕西 西安 710065; 2. 陕西航空电气有限责任公司, 陕西 西安 710065)

摘要: 分布式新能源大规模入网的背景下, 配电网不确定性因素显著增加, 对其进行无功优化调度难度也相应增大, 传统的优化方案存在较多限制与不足。提出一种基于多场景法的有源配电网动态无功优化方案。针对新能源和负荷的不确定性分别进行数学建模, 并采用多场景方法将不确定性问题转化为确定性问题求解; 于配网侧构建了追求网损与无功补偿设备调节代价费用期望值达到综合最优的数学模型, 并采用新冠病毒群体免疫算法求解。结果表明: 该算法取得的优化方案可有效节约配网运行成本、降低网损。

关键词: 配电网; 新冠病毒群体免疫算法; 无功优化; 电力系统仿真

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2023)12-2692-11

DOI: 10.16182/j.issn1004731x.joss.22-0882

引用格式: 武晓朦, 袁榕泽, 李英量, 等. 基于新冠病毒群体免疫算法的有源配电网优化调度[J]. 系统仿真学报, 2023, 35(12): 2692-2702.

Reference format: Wu Xiaomeng, Yuan Rongze, Li Yingliang, et al. Optimized scheduling of Distribution Network with Distributed Generation Based on Coronavirus Herd Immunity Optimizer Algorithm[J]. Journal of System Simulation, 2023, 35(12): 2692-2702.

Optimized scheduling of Distribution Network with Distributed Generation Based on Coronavirus Herd Immunity Optimizer Algorithm

Wu Xiaomeng¹, Yuan Rongze^{2*}, Li Yingliang¹, Zhu Qi¹

(1. School of Electronic Engineering, Xi'an Shiyou University, Xi'an 710065, China; 2. AVIC Shaanxi Aero Electric Co., Ltd, Xi'an 710065, China)

Abstract: Following the large-scale entry of distributed new energy into the network, the uncertainty factor of the distribution network increases significantly, and the difficulty of reactive power optimization scheduling increases accordingly. Traditional optimization solutions have many limitations and shortcomings, and a dynamic reactive power optimization scheme for active distribution networks based on a multi-scenario approach is proposed. The mathematical modeling is carried out separately for the uncertainty of new energy and load, and the multi-scenario method is used to transform the uncertainty problem into a deterministic problem. A mathematical model is constructed on the distribution network side to pursue the integrated optimal value of the expected cost of network loss and reactive power compensation equipment regulation, and the coronavirus herd immunity optimizer is used to solve it. The results show that the optimization scheme obtained from the algorithm can effectively save the distribution network operation cost and reduce the network loss.

Keywords: distribution network; coronavirus herd immunity optimizer; reactive power optimization; power system simulation

收稿日期: 2022-07-31 修回日期: 2022-12-13

基金项目: 陕西省自然科学基金基础研究计划(2021JM-404); 陕西省教育厅科研计划(21JK0843)

第一作者: 武晓朦(1974-), 女, 教授, 博士, 研究方向为配电网自动化。E-mail: xmwu@xsyu.edu.cn

通讯作者: 袁榕泽(1995-), 男, 硕士生, 研究方向为配电网自动化。E-mail: 1264234737@qq.com

0 引言

电力系统无功分布与系统运行效率、供电电能质量等影响系统运行经济性与安全性的指标密切相关, 采用合理的无功优化方案对系统无功潮流进行优化, 对限制系统损耗、保障系统运行稳定具有重要意义^[1]。

电力系统无功调节设备中, 有载调压变压器与无功补偿电容器最为常见。前者可通过切换分接头位置调节变比, 在带负荷的情况下调节电压; 后者通过控制无功补偿电容的投切数量, 补充无功功率的同时, 改善系统电压水平^[2]。

随着新能源领域的高速发展, 配电网在传统的单电源、辐射型结构的基础上, 逐渐于用户侧引入小于 50 MW 的分布式电源供电并参与优化调度过程, 使系统结构愈发复杂, 分布式发电 (distributed generation, DG) 出力不确定性的影响往往与电网电压波动、节点电压越限等密切相关。不确定因素的增加为配电网电能质量控制及无功优化过程带来了巨大的挑战, 主要难点集中在不确定性建模与优化算法寻优能力的提高。对有源网络中的分布式新能源进行合理应用, 并将其与传统电压调节手段相结合, 以期达到更好的优化调度效果, 在相关领域已存在大量研究。

文献[3]提出了光伏入网背景下兼顾并网发电与无功功率补偿优化调度的有效解决方案, 充分发挥了分布式电源的无功优化潜力, 提高了系统的运行效率。文献[4]提出了一种分布式新能源于配电网渗透率不断增加背景下的动态无功优化调度方案, 分析了分布式电源接入对配网无功潮流产生的影响, 以系统网损最优为目标函数, 给出了对应的无功优化调度策略, 但未考虑负荷与分布式电源的动态变化特性。文献[5]以配电网经济成本与网损的综合最优为目标, 提出了一种考虑分布式电源的补偿电容器的投切方案, 但未考虑有载变压器与补偿电容器的协同配合。文献[6]在传统无功优化的基础上, 于目标函数中额外考虑

了电容器投资成本、节点电压偏移量的综合最优, 使控制更加灵活, 但是在无源电网中展开的, 未考虑分布式新能源入网对无功优化带来的影响。

电力系统无功优化问题作为一种多目标混合非线性规划问题, 具有自变量多、约束复杂、运算规模大等特点。常见算法: 以内点法、简化梯度法、牛顿法、二次规划法等算法为代表的传统方法; 以遗传算法、粒子群优化算法、模拟退火算法、禁忌搜索算法等为代表的人工智能算法。上述算法在一定程度上都可以用于无功优化问题的求解, 但随着配电系统中新能源渗透率不断增加, 优化过程中需考虑的不确定性因素逐步增加, 优化问题的规模与求解难度不断增大, 在求解过程中存在诸多限制, 难以保障求解精度。

文献[7]在传统粒子群算法的基础上, 通过优化惯性权重, 提出了一种反向学习伪梯度搜索粒子群算法, 可在确保算法寻优性能的前提下避免陷入局部最优。但该算法建立在无源配电网背景下, 未考虑分布式电源入网带来的影响。文献[8-9]对风电机组大规模入网的配电系统进行无功优化, 通过 Pareto 最优解集验证了算法性能, 但缺乏与其他同类算法的横向对比。

本文基于规划日风电、光伏、负荷的实际与预测数据, 采用拉丁超立方采样法与改进的基于密度的聚类算法生成并筛选出典型场景以应对系统的不确定性。考虑分布式新能源入网对配网无功潮流产生的影响, 建立了旨在控制网损且降低无功调节设备动作成本的数学模型, 并采用新冠病毒群体免疫算法对模型进行寻优。

1 多场景法应对系统不确定性

在对电力系统进行数学建模的过程中, 会存在多种不确定性因素, 例如, 风速变化导致的风电机组输出功率的不确定性, 太阳光照强度与光伏组件表面温湿度的变化导致的太阳能电源输出功率的不确定性, 负荷的随机性变化都会为分布式电源的选址和定容问题增添困难, 需在数学建

模阶段进行充分考虑^[10]。

风电机组的输出功率主要受风速影响，其分段表达式为

$$P_w(v) = \begin{cases} 0, & v \leq v_i \\ 0, & v > v_{out} \\ p_r \frac{v - v_i}{v_r - v_i}, & v_i \leq v \leq v_r \\ p_r, & v_r \leq v \leq v_{out} \end{cases} \quad (1)$$

式中： P_w 为风电机组输出的有功功率； v_i 为机组切入风速； v_r 为机组额定风速； v_{out} 为机组切出风速。

假定风速预测误差服从均值为0的正态分布，此时风速的概率分布密度函数为

$$\varphi(v) = \frac{1}{\delta \sqrt{2\pi}} \exp\left[-\frac{(v - \bar{v})^2}{2\delta_v^2}\right] \quad (2)$$

式中： \bar{v} 为风速预测值^[11]； δ_v 为标准差。

光伏发电的输出功率主要受光照强度与环境温度的影响，理想情况下表达式为

$$P_{PV} = P_{STC} \frac{S}{S_{STC}} [1 + k(T_c - T_r)] \quad (3)$$

式中： P_{STC} 为光伏设备于标准状态下的最大输出功率值； S 为光照强度实际值； S_{STC} 为标准光照强度； k 为功率温度系数； T_c 为工作温度； T_r 为标准温度。

实际应用中，光伏电站接收的光照强度受外界环境因素的影响，往往近似地认为服从Beta分布，光伏电站的出力以概率密度函数为

$$f(P_{PV}) = \frac{1}{P_{PV,max} B(\alpha, \beta)} \left(\frac{P_{PV}}{P_{PV,max}}\right)^{\alpha-1} \left(1 - \frac{P_{PV}}{P_{PV,max}}\right)^{\beta-1} \quad (4)$$

式中： $P_{PV,max}$ 为光伏机组最大输出功率^[12]。

采用正态分布建立概率模型对负荷的不确定性进行表征：

$$\begin{aligned} P_{load,i} &\sim N(\mu_{p,i}, \sigma_{p,i}^2) \\ Q_{load,i} &\sim N(\mu_{q,i}, \sigma_{q,i}^2) \end{aligned} \quad (5)$$

式中： $P_{Load,i}$ 、 $Q_{Load,i}$ 分别为负荷有功、无功随机变量； $\mu_{p,i}$ 、 $\mu_{q,i}$ 分别为负荷有功、无功功率期望

值； $\sigma_{p,i}^2$ 、 $\sigma_{q,i}^2$ 分别为负荷有功、无功功率的方差^[13]。

为解决模型精度与运算体量之间的矛盾，首先，生成足够规模与多样性的场景以满足对不确定性模型进行模拟的精度要求，随后，采用相应的场景缩减方法对典型场景进行筛选，在控制运算规模的同时，兼顾了优化问题模型精度的要求。

模型所需场景的生成是根据历史数据建立的风电功率预测误差数学模型，通过拉丁超立方采样法随机模拟产生大量风电功率预测误差时间序列，通过将期望值和预测误差相加得到大量的模拟场景^[14]。使用基于网格单元的DBSCAN(density-based spatial clustering of applications with noise)聚类算法以单一规划日内数据为基本单元进行聚类，从而将原始风电时序场景消减为一个规模适应于模型计算且兼具代表性的场景集合^[15-16]，从而将不确定性问题转化为确定性问题的求解。

拉丁超立方采样法所生成的风光联合出力待削减场景集合如图1所示，图中的蓝色粗线代表初始选取的风电、光伏的实际发电功率数据，黄色粗线代表风电、光伏的日前预测数据，其余的彩色细线为拉丁超立方采样法取得的1000个互不相同的出力场景。可以看出，初始场景所涵盖的区域完全包括了实际出力曲线与预测曲线所处的范围。




图1 风光联合出力场景构成图

Fig. 1 Broken line diagram of wind power and photovoltaic joint output

采用聚类算法对初始场景集合进行聚类处理: 首先, 从数据集中任意选取一数据对象点, 若该点满足核心点判定条件, 则应用传统DBSCAN算法进行聚类, 若不满足, 则重新选取数据对象点重复上述步骤, 将所有的点遍历, 当簇的数量与构成逐渐趋于稳定时, 结束该循环^[17-18]。随后, 将DBSCAN算法得到的消减降噪后的场景作为K-Means算法的空间数据集, 随机选取初始聚类中心点展开新一轮的聚类迭代, 遍历解空间的所有样本集合, 分别将每个样本与欧氏距离最小的聚类中心划归为一类, 不断根据距离更新各个聚类中心, 对新聚类中心与上一次迭代取得的聚类中心进行比较, 若二者差异性不满足预设要求, 则返回上一循环重新聚类, 直至满足终止条件^[19]。

所获得的聚类后典型场景集合如图2所示, 图中的蓝色粗线代表初始选取的风电、光伏的实际发电功率数据, 黄色粗线代表风电、光伏的日前预测数据, 其余的彩色细线为拉丁超立方采样法取得的1000个互不相同的出力场景。应用本文的场景生成与削减策略, 可有效将初始生成的大量出力场景集合削减到少量具有代表性的出力场景, 从而得到可应用于后续仿真的最佳出力场景集合。采用相同的聚类策略, 对负荷的不确定性进行处理, 将不确定性问题转化为确定性问题的求解。




图2 最佳聚类场景集合图

Fig. 2 Best clustering scenarios collection graph

2 配电网无功优化数学模型

2.1 目标函数

本文旨在为配电网运行优化调度提供有价值的参考, 确保系统供电效率, 在多场景方法框架下, 于规划日内, 以系统网损最小以及无功调节设备动作成本最低为目标函数。

配电网一天内网损为

$$\begin{cases} f_{\text{loss}} = \sum_{t=1}^T \sum_{\omega=1}^I \sum_{j \in C(\omega)} P_{\omega j, t, s} \Delta t, \omega j \in I \\ P_{\omega j, t, s} = g_{\omega j} (V_{\omega, t, s}^2 + V_{j, t, s}^2 - 2V_{\omega, t, s} V_{j, t, s} \cos \theta_{\omega j, t, s}) \end{cases} \quad (6)$$

式中: I 为配电网所含负荷节点数; l 为线路集合; $P_{\omega j, t, s}$ 、 $g_{\omega j}$ 、 $\theta_{\omega j, t}$ 分别为支路 $\omega-j$ 的网损、电导、功角差; $V_{\omega, t, s}$ 为节点 ω 于 t 时段的电压值; $C(\omega)$ 为与节点 ω 相连的节点集合。

无功调节设备动作的成本为

$$f_c = \sum_{s=1}^{N_s} P_{t, s} \sum_{i=1}^T t_i \left(\sum_{k=1}^2 \mu_1 \times |Q_{ck, t+1} - Q_{ck, t}| + \mu_2 \times |R_{t+1} - R_t| \right) \quad (7)$$

式中: N_s 为场景数; T 为优化时段数; t_i 为 i 时段运行时间; $p_{t, s}$ 为不同场景所对应的概率; k 为无功补偿电容器数; μ_1 、 μ_2 分别为电容器单位容量投切费用、变压器分接头单次调节费用; $Q_{ck, t+1}$ 、 $Q_{ck, t}$ 为相邻规划时段第 i 个电容器的无功补偿容量; R_{t+1} 、 R_t 为相邻规划时段的变压器分接头位置。

追求总成本最低的经济性目标函数由网损成本与无功调节设备动作成本共同构成:

$$\min F = \min \sum_{s=1}^N P_{t, s} (a_{\text{loss}} f_{\text{loss}} + f_c) \quad (8)$$

式中: a_{loss} 为对应时段网损电价。

2.2 约束条件

节点有功无功约束:

$$\begin{cases} P_{\omega,t,s} = \sum_{j \in C(\omega)} [g_{\omega j} V_{\omega,t,s}^2 - \\ V_{\omega,t,s} V_{j,t,s} (g_{\omega j} \cos \theta_{\omega j,t,s} + b_{\omega j} \sin \theta_{\omega j,t,s})] \\ Q_{\omega,t,s} = \sum_{j \in C(\omega)} [-b_{\omega j} V_{\omega,t,s}^2 + \\ V_{\omega,t,s} V_{j,t,s} (b_{\omega j} \cos \theta_{\omega j,t,s} - g_{\omega j} \sin \theta_{\omega j,t,s})] \end{cases} \quad (9)$$

节点电压约束:

$$V_{\omega}^{\min} \leq V_{\omega,t,s} \leq V_{\omega}^{\max} \quad (10)$$

线路电流约束:

$$\begin{aligned} I_{\omega j,t,s}^2 &= (g_{\omega j}^2 + b_{\omega j}^2) \\ &(V_{\omega,t,s}^2 + V_{j,t,s}^2 - 2V_{\omega,t,s} V_{j,t,s} \cos \theta_{\omega j,t,s}) \leq (I_{\omega j}^{\max})^2 \end{aligned} \quad (11)$$

功率传输容量约束:

$$\begin{cases} V_{\omega,t,s} V_{j,t,s} (g_{\omega j} \cos \theta_{\omega j,t,s} + b_{\omega j} \sin \theta_{\omega j,t,s}) - \\ V_{\omega,t,s}^2 g_{\omega j} \leq P_{\text{line}} \\ V_{\omega,t,s} V_{j,t,s} (g_{\omega j} \cos \theta_{\omega j,t,s} + b_{\omega j} \sin \theta_{\omega j,t,s}) - \\ V_{\omega,t,s}^2 g_{\omega j} \geq -P_{\text{line}} \end{cases} \quad (12)$$

无功补偿器容量约束:

$$Q_{ci,t,\min} \leq Q_{ci,t} \leq Q_{ci,t,\max} \quad (13)$$

变压器分接头调节范围约束:

$$T_{i,\min} \leq T_i \leq T_{i,\max} \quad (14)$$

式中: $P_{\omega,t,s}$ 、 $Q_{\omega,t,s}$ 分别为注入节点 ω 的有功、无功功率; $b_{\omega j}$ 为支路 $\omega-j$ 的电纳; V_{ω}^{\max} 、 V_{ω}^{\min} 分别为节点 ω 的电压幅值上下限; $I_{\omega j}^{\max}$ 为流过支路 $\omega-j$ 的最大电流; P_{line} 为安全容量。

3 新冠病毒群体免疫算法

电力系统优化作为多目标非线性优化问题往往具有问题规模大、不确定性强、约束复杂的特点,传统算法往往难以取得一个可接受的最优解。鉴于实际工程问题往往并不要求严格的全局最优,在免疫算法的基础上进行优化,并与优化前算法进行寻优能力的对比。

新冠病毒群体免疫算法 (coronavirus herd immunity optimizer, CHIO) 是受当下大规模流行的新型冠状病毒的传播方式、传播群体免疫模式及其相应的群体免疫机理启发,在传统免疫粒子群算法优胜劣汰、迭代更新的寻优思想基础上,通

过对群体行为与病毒传播过程的模拟,将个体按照距离划分为“易感”“感染”“免疫”3种不同状态,并分别采取不同的交叉变异策略进行优化,进而构建的人工智能迭代求解算法。该算法由 Mohammed Azmi Al-Betar 等提出并应用于电力系统网架规划问题求解,可有效应对大规模、多目标、约束复杂的电力系统数学模型的优化问题^[20]。本文在分布式新能源大规模入网对配网无功潮流影响的前提下,将 CHIO 算法应用于配电网无功优化问题的寻优。其求解流程如图 3 所示。

该算法通过模拟病毒传播过程中传播群体由易感状态逐步转为群体免疫的过程,对复杂优化问题进行迭代寻优,其循环结构主要由 6 个阶段构成。

(1) 阶段 1: 参数初始化阶段

该阶段分别对 4 个算法参数和 2 个控制参数进行赋值。

C_0 : 基本再生数,即在完全易感、充分混合的人群中,一名感染者于一次接触传播过程中平均能感染的人数;

i_{\max} : 最大迭代数(达成群体免疫所需的最小迭代数),作为迭代过程的结束判据;

HIS : 传播群体规模,其数量在迭代过程中动态平衡;

n : 目标问题的维度即自变量个数;

BR_r : 基本增殖参数,与距离参数共同作用控制病毒传播与群体免疫行为的进程;

A_{\max} : 最高患病年龄,对迭代过程中单一个体无法有效寻优的最高代数做出限制,越限个体被认定为致死病例并且不再参与寻优进程,对应算法的淘汰与补充机制。

(2) 阶段 2: 初始免疫群体的生成

随机生成一组个体数为 HIS 的初始免疫群体,其中,矩阵的每一行对应群体中的 1 个个体,总数为 HIS ,每一列对应个体的 1 个基因片段即目标函数的一个自变量,其总数为 n 。

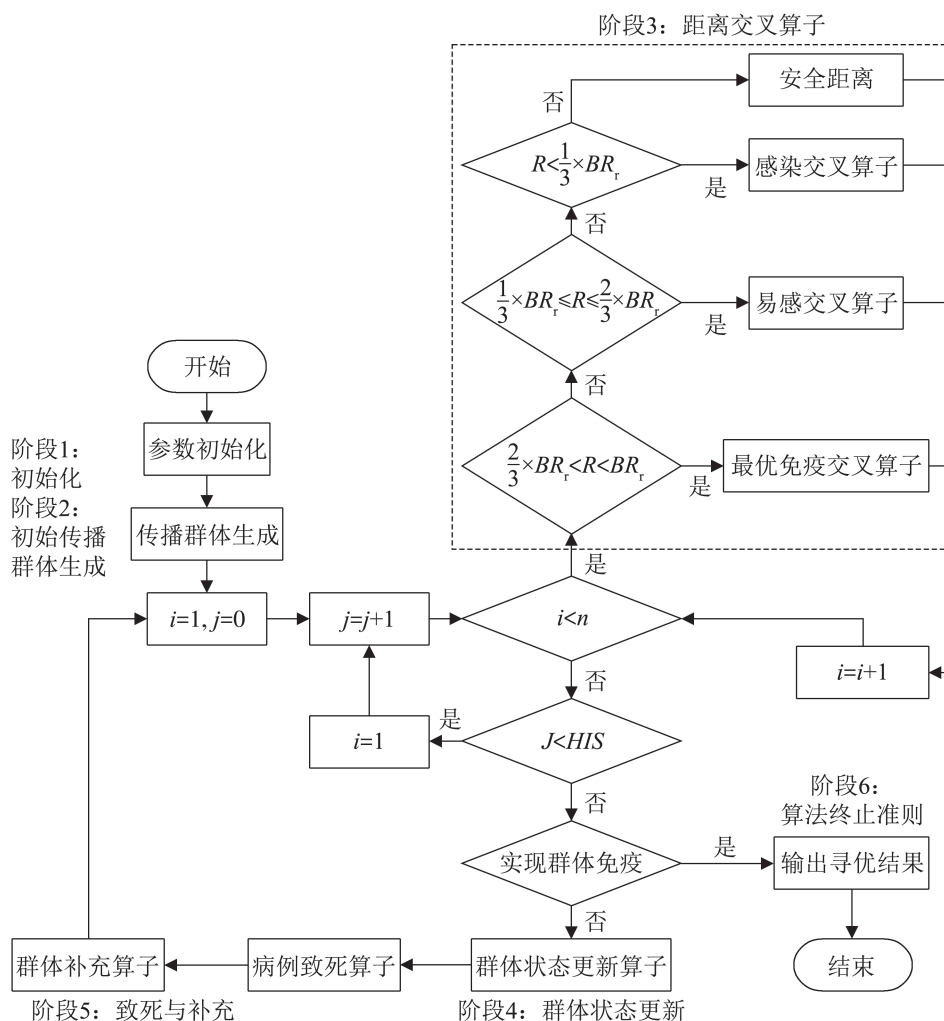


图 3 新冠病毒群体免疫算法流程
Fig. 3 Flow chart of coronavirus herd immunity optimizer

这里定义感染状态向量 S 以标记并记录每个个体在迭代过程中所处的状态。 $S=0$ 代表易感者； $S=1$ 代表感染者； $S=2$ 代表免疫者。在初始化阶段随机选取数量为 C_0 的个体使 $S=1$ ；其余个体 $S=0$ 以对病毒的首次传播进行模拟。定义年龄状态向量 A 记录每个个体参与的迭代次数以协同个体免疫率对个体寻优能力的强弱进行评估，初始化状态下 $A=0$ 。

(3) 阶段 3: 距离交叉算子的免疫行为模拟

社会行为的差异会让部分人更容易暴露给病毒，算法迭代过程中依据社交距离与安全距离的比例关系，通过模拟病毒对个体基因片段的影响情况，对不同的个体基因采取不同的交叉变异模

式。将距离交叉算子按个体社交距离的远近由小到大依次细分为感染交叉算子、易感交叉算子、最优免疫交叉算子。其对应关系为

$$x_i^j(t+1) = \begin{cases} x_i^j(t), R \geq BR_r \\ C(x_i^j(t)) = x_i^j(t) + r \times (x_i^j(t) - x_i^C(t)), \\ R < \frac{1}{3} \times BR_r \\ N(x_i^j(t)) = x_i^j(t) + r \times (x_i^j(t) - x_i^N(t)), \\ \frac{1}{3} \times BR_r \leq R \leq \frac{2}{3} \times BR_r \\ R(x_i^j(t)) = x_i^j(t) + r \times (x_i^j(t) - x_i^R(t)), \\ \frac{2}{3} \times BR_r < R < BR_r \end{cases} \quad (15)$$

感染交叉算子执行操作为任选被标记为 $S(i)=1$

的感染者基因片段，对原始基因片段进行交叉变异；易感交叉算子任选被标记为 $S(i)=0$ 的易感者基因片段，对原始基因片段进行交叉变异；最优免疫交叉算子从被标记为 $S(i)=2$ 的免疫者中选取最优个体，并从最优免疫个体中任意选取基因片段对原始基因片段进行交叉变异。

(4) 阶段 4: 群体状态更新

状态更新算子对每个新生成的个体进行免疫率计算，若新生成的个体对目标函数的寻优能力相较于原始个体有所提高，则对原始个体进行替换；若新个体寻优能力弱于原始个体，则保留原始个体。对新个体免疫率与群体免疫率阈值进行比较，当个体免疫率高于群体平均免疫率，说明整个群体的免疫能力有提高的趋势，当群体免疫能力足够强大足以抵抗病毒的传播，即实现了群体免疫。向量 S 、 A 在更新过程中于不同情况相应地发生改变。其相应的状态更新流程如图 4 所示。

(5) 阶段 5: 致死与补充

感染者 $S(i)=1$ 免疫率于规定的迭代次数内无法得到提高，代表个体对目标函数的寻优能力不足，当患病年限超过所规定的最大值即 A_{max} ，则判定为病例死亡，不再参与迭代过程，重新生成新个体，对群体数量进行补充。新个体生成方式：

$$x_i^j(t+1) = lb_i + (ub_i - lb_i) \times U(0, 1), \quad \forall i = 1, 2, \dots, n \quad (16)$$

其生成方式具有一定的随机性以确保群体内个体的多样性，目的是在确保算法寻优能力的前提下避免陷入局部最优。

(6) 阶段 6: 终止准则

达到最大迭代次数即 i_{max} 则判定迭代终止，此时传播群体已实现群体免疫并不再有新病例生成。

基于新冠病毒群体免疫算法对有源配电网进行无功优化调度的初始阶段，随机生成一组初始免疫群体矩阵：

$$HIP = \begin{bmatrix} x_1^1 & x_2^1 & \dots & x_n^1 \\ x_1^2 & x_2^2 & \dots & x_n^2 \\ \vdots & \vdots & \dots & \vdots \\ x_1^{HIS} & x_2^{HIS} & \dots & x_n^{HIS} \end{bmatrix} \quad (17)$$

矩阵的每一行对应群体中的一个个体，每一列对应个体的一个基因片段即目标函数的一个自变量，其生成方式为

$$x_i^j = lb_i + (ub_i - lb_i) \times U(0, 1), \quad \forall i = 1, 2, \dots, n \quad (18)$$

对于分布式发电背景下配电网无功优化问题，将各个无功补偿设备出力和有载调压变压器变比两类控制变量看做基因片段，每个基因片段的抗体为各个控制变量在其限制范围内的取值，分别对应无功补偿设备及有载调压变压器的投切数与档位值。基因片段中的抗体为离散变量，编码均采用实数编码。

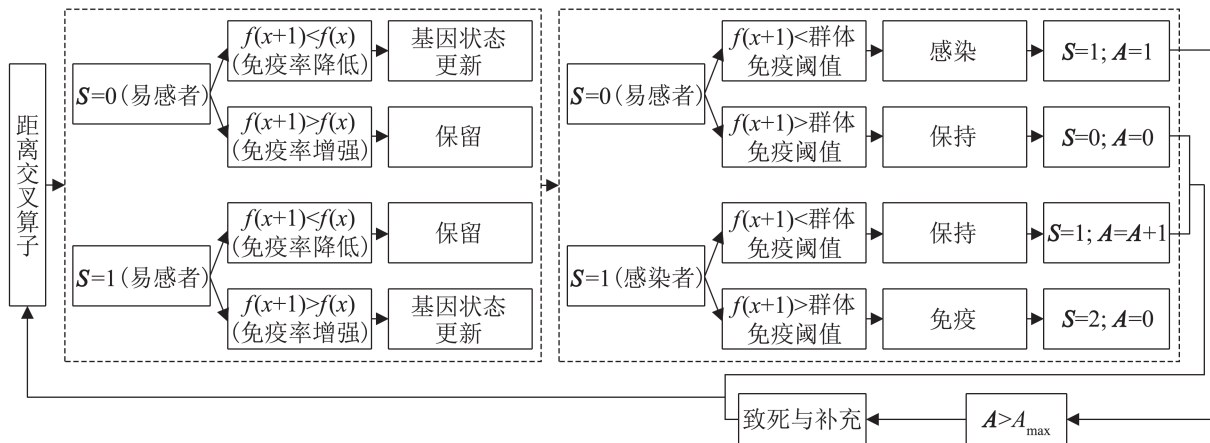


图 4 状态更新
Fig. 4 Status update

其初始种群即为对应的并联电容器容量及有载调压变压器电压比的全部可能取值, 构成初始群体后, 其数值在一次迭代循环的过程中保持不变。对于每一个个体都要以目标函数作为亲和度, 计算公式通过潮流计算进行亲和度计量与比较, 参与系统优化的风电与光伏本身具有一定的无功调节能力, 在潮流计算作为 PQ 节点。

在算法迭代过程中, 不同的优化方案即个体之间根据其解空间中相似度的强弱, 不断交叉变异基因片段即改变其自变量的取值; 免疫能力强的个体即对系统而言具备更好经济性的优化调度方案不断得以补充, 优化能力经过多轮迭代未得到提升的个体不再加入循环, 对应算法中的致死与补充环节。通过这种基于距离对变量进行智能优化以逼近整体最优的策略, 可有效保障寻优效率, 提高系统性能。

4 算例仿真

为验证所采用的双层规划模型的有效性, 本文采用 IEEE-33 节点配电系统进行无功优化计算, 配电网模型所需参数来自文献[21]。1 号节点为系统平衡节点, 节点电压初始值均设为 1, 安装于松弛节点的有载调压器电压调节范围为 0.9~1.1, 可调节档位范围为 ± 8 ; 于节点 11、32 分别接入 8 组 50 kvar、10 组 100 kvar 的并联电容器, 规划日内最高无功补偿电容器投切次数为 8 次; 于节点 11、32 分别接入 3 台、2 台分布式风电机组; 于节点 17、30 分别接入 2 台分布式光伏机组, 在潮流计算过程中当作 PQ 节点处理。单台分布式电源额定容量为 100 kW。

CHIO 算法参数设置: 最大迭代数 i_{\max} 取 100 000 次; 传播群体规模 HIS 取 30; 基本增殖参数 BR 取 0.01; 最高患病年龄 A_{\max} 取 100。

规划日内的配网负荷数据如图 5 所示。

在 Matlab 2018a 环境下, 分别采用典型日与多场景法, 应用本文的优化策略对网损与节点电

压值进行仿真, 并与 PSO、GA、免疫算法 (immune algorithm, IA) 进行对比测试, 结果如表 1 所示。




图 5 系统单日负荷曲线

Fig. 5 System single day load curve

表 1 不同算例下优化结果

Table 1 Optimization results under different examples

方案	网损/MW	最低电压 p.u.	峰谷差/ MW	目标函 数值/元
典型日法	2.409	0.958	1.653	1 839
CHIO	2.201	0.980	1.347	1 521
PSO	2.346	0.976	1.430	1 671
GA	2.351	0.970	1.436	1 730
IA	2.302	0.981	1.427	1 628

经过对比分析可知, 本文所研究的电力系统模型下, 采用多场景方法框架比单一场景的典型日法的优化结果更好。这是由于多场景方法可有效处理系统的不确定性, 有利于数学模型的寻优。

从多场景框架下 3 种不同算法的优化结果可以看出, CHIO 算法在控制网损与平抑峰谷差方面均优于其他 3 种算法。本文采用该算法所取得的无功优化策略, 可有效降低配电网于规划日内产生的总网损; 通过提高规划期内最低电压值, 避免了电压越限影响配电网正常运行; 将电压峰谷差控制在合理的范围内。

为进一步分析算法性能差距, 选取 PSO 算法与 CHIO 算法分别对本文的配电系统无功优化策略进行对比分析, 即有载调压器与补偿电容器的动作情况进行对比分析, 如图 6 所示。

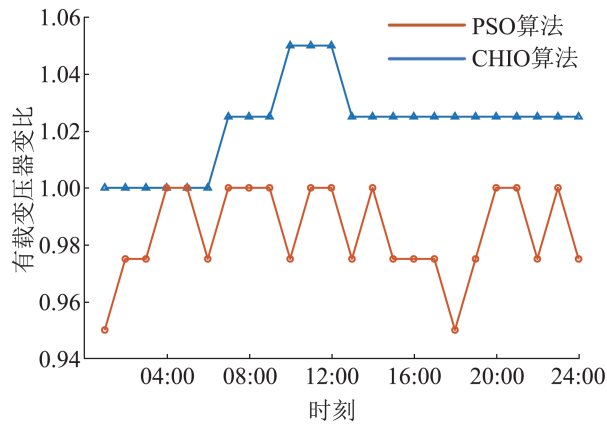


图6 有载调压器变比

Fig. 6 Transformation ratio of on load voltage regulator


由图6可见, 相对于传统 PSO 算法, 使用 CHIO 算法所取得的优化方案中, 对变压器变比进行调节的次数明显减少, 有效控制了调压器频繁动作导致的寿命折损与成本增加。

采用 PSO 算法与 CHIO 算法分别对无功优化问题进行寻优, 结果如图7所示。


图7(a)、(b)的 PSO 算法中, 节点13与节点27处所设有的无功补偿装置分别动作了10次与11次, 无功容量投切频繁, 且均已超过日最高投切次数的限制; 图7(c)、(d)的 CHIO 算法中, 节点13与节点27处所设有的无功补偿装置分别动作了5次与4次, 相较于图6(a)、(b), 其动作次数明显降低, 电容器的投切次数均在限制范围内。

结合图6与图7所获得的仿真结果可看出, 于规划日内从电力系统无功调节设备的动作情况出发, 本文所采用的 CHIO 算法相较于 PSO 算法, 在求解无功优化问题的过程中, 可更好地限制无功调节设备的动作次数, 节约了设备动作费用, 避免了不必要的设备损耗。


不同算例下的配网节点电压分布仿真结果如图8所示。由图8可见采用本文的调度方案后, 显示为绿色的缓冲区域明显拓宽, 由峰值到低谷的过渡过程电压分布趋于均匀平缓。该仿真结果说明采用本文的优化策略, 可对配网节点电压分布带来积极影响, 使之更为均匀平缓, 从而更好地确保系统稳定性与经济性。




(a) PSO算法13节点



(b) PSO算法27节点



(c) CHIO算法13节点



(d) CHIO算法27节点

图7 不同优化算法下的电容器动作情况

Fig. 7 Capacitor action under different optimization algorithms

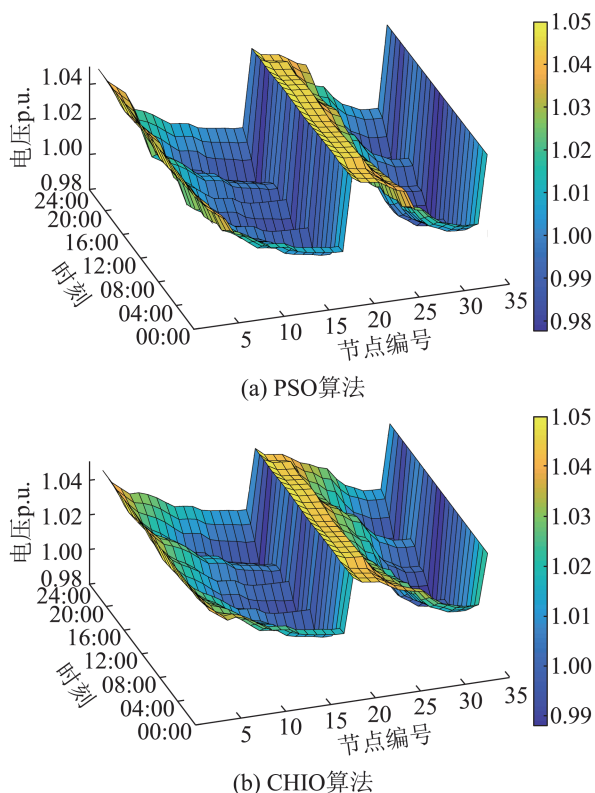


图8 配电网电压标幺值时空分布
Fig. 8 Spatial and temporal distribution of voltage per unit in distribution network

5 结论

伴随着电力系统发展过程中对新能源的需求不断增加, 分布式新能源于配网侧的渗透率不断提高, 针对配网日益复杂的潮流进行优化对保障系统稳定安全运行具有重要意义, 也对无功优化的策略与方法提出了更高的要求。本文采用多场景方法处理不确定性, 并将 CHIO 算法应用于配电网无功优化模型寻优, 得出结论如下:

(1) 相对于传统的 PSO、SGA 算法, 本文采用的 CHIO 算法在测试函数验证下, 反映出更加优秀的寻优性能与收敛特性, 可有效适用于以配电网无功优化为代表的多目标、约束复杂的数学模型的寻优运算。

(2) 本文提出的基于多场景方法、采用 CHIO 求解算法的配网无功优化策略, 针对含分布式新能源的配电系统进行优化调度, 可有效应对系统

固然存在的不确定性与多目标、大规模数学模型的复杂性, 在控制系统网损的同时, 降低了无功调节成本, 稳定了系统节点电压, 确保了系统运行的经济性、稳定性、高效性。

(3) 需要进一步开展的工作包括: 结合更复杂的实际电力系统架构与历史数据, 进一步对算法性能与寻优能力进行验证; 在本文研究的基础上, 在可入网电动汽车等新兴调度对象大规模入网的背景下, 进一步探究本文所提出算法针对更复杂的优化调度问题的适应性等。

参考文献:

- [1] 李旭炯, 孙林花. 基于粒子群优化算法的无功和电压控制及仿真[J]. 电力电容器与无功补偿, 2022, 43(3): 14-20. Li Xujiong, Sun Linhua. Reactive Power and Voltage Control and Simulation Based on a Particle Swarm Optimization Algorithms in Electric Power Systems[J]. Power Capacitor & Reactive Power Compensation, 2022, 43(3): 14-20.
- [2] 陆秋瑜, 夏天, 朱誉, 等. 基于有载调压变压器线性化模型的配电网无功优化二阶锥松弛建模及仿真[J]. 智慧电力, 2019, 47(9): 91-96. Lu Qiuyu, Xia Tian, Zhu Yu, et al. SOCP Relaxed Modeling and Simulation of VAR Optimization in Distribution Networks Based on Linearized Model of OLTC Transformer[J]. Smart Power, 2019, 47(9): 91-96.
- [3] 汪海宁, 苏建徽, 张国荣, 等. 光伏并网发电及无功补偿的统一控制[J]. 电工技术学报, 2005, 20(9): 114-118. Wang Haining, Su Jianhui, Zhang Guorong, et al. Unitive Control of PV Grid Connected Generation and Reactive Compensation[J]. Transactions of China Electrotechnical Society, 2005, 20(9): 114-118.
- [4] 刘磊, 郝思鹏. 含微电网的主动配电网分级优化运行策略[J]. 电测与仪表, 2019, 56(20): 76-81. Liu Lei, Hao Sipeng. Hierarchical Optimal Operation Strategy of Active Distribution Network With Micro-grid[J]. Electrical Measurement & Instrumentation, 2019, 56(20): 76-81.
- [5] 谭煌, 张璐, 丛鹏伟, 等. 计及分布式电源与电容器协调的配电网日前无功计划[J]. 电网技术, 2014, 38(9): 2590-2597. Tan Huang, Zhang Lu, Cong Pengwei, et al. Day-ahead Reactive Power Scheduling for Distribution Network Considering Coordination of Distributed Generation With Capacitors[J]. Power System Technology, 2014, 38(9): 2590-2597.

- [6] 陈月娟. 低压配电网多目标无功优化配置模型及求解方法[J]. 机电信息, 2016(33): 166-167.
- [7] 高金兰, 雷星雨, 朱佳丽. 动态改变惯性权重的伪梯度搜索粒子群算法在无功优化中的应用[J]. 化工自动化及仪表, 2018, 45(1): 35-40.
Gao Jinlan, Lei Xingyu, Zhu Jiali. Application of Pseudo-gradient Search Particle Swarm Optimization with Dynamically-changed Inertia Weight in Reactive Power Optimization[J]. Control and Instruments in Chemical Industry, 2018, 45(1): 35-40.
- [8] 付英杰, 汪泓, 谭阳红. 基于Pareto最优解的含分布式电源配电网无功优化[J]. 电力系统及其自动化学报, 2017, 29(1): 18-23.
Fu Yingjie, Wang Feng, Tan Yanghong. Reactive Power Optimization of Distribution Network Containing Distributed Generation Based on Pareto Optimal[J]. Proceedings of the CSU-EPSA, 2017, 29(1): 18-23.
- [9] 金尚婷, 吴杰康, 覃炜梅, 等. 考虑风电消纳的配电网多目标无功协同优化[J]. 广东电力, 2019, 32(1): 52-59.
Jin Shangting, Wu Jiekang, Qin Weimei, et al. Multi-objective Collaborative Reactive Power Optimization for Distribution Network Considering Wind Power Accommodation[J]. Guangdong Electric Power, 2019, 32(1): 52-59.
- [10] 白斌, 韩明亮, 林江, 等. 含风电和光伏的可再生能源场景削减方法[J]. 电力系统保护与控制, 2021, 49(15): 141-149.
Bai Bin, Han Mingliang, Lin Jiang, et al. Scenario Reduction Method of Renewable Energy Including Wind Power and Photovoltaic[J]. Power System Protection and Control, 2021, 49(15): 141-149.
- [11] 潘超, 李润宇, 蔡国伟, 等. 基于属性约简重构的自校正卷积记忆风速预测[J]. 中国电机工程学报, 2023, 43(7): 2721-2731, S20.
Pan Chao, Li Runyu, Cai Guowei, et al. Wind Speed Prediction with Self-tuning Convolutional Memory Based on Attribute Reduction Reconstruction[J]. Proceedings of the CSEE, 2023, 43(7): 2721-2731, S20.
- [12] 张聂鹏, 张楠, 邓媛. 考虑新能源不确定性的储电站储能容量配置优化技术[J]. 自动化技术与应用, 2021, 40(9): 90-93.
Zhang Niepeng, Zhang Nan, Deng Yuan. Optimization Technology of Energy Storage Capacity Allocation Considering New Energy Uncertainty[J]. Techniques of Automation and Applications, 2021, 40(9): 90-93.
- [13] 傅钰. 考虑风光不确定性的多能源电源多点布局规划研究[D]. 保定: 华北电力大学, 2021.
Fu Yu. Research on Multi-point Layout Planning of Multi-energy Power Supply Considering Wind and Solar Uncertainty[D]. Baoding: North China Electric Power University, 2021.
- [14] 张友骞, 张靖, 何宇, 等. 基于蒙特卡洛法和拉丁超立方采样的含风电场的概率可用输电能力研究对比[J]. 新型工业化, 2018, 8(9): 30-34, 39.
Zhang Youqian, Zhang Jing, He Yu, et al. Comparison of the Probability Available Transfer Capability of Containing Wind Farms Based on Monte Carlo and Latin Hypercube Sampling[J]. The Journal of New Industrialization, 2018, 8(9): 30-34, 39.
- [15] 刘淑芬, 孟冬雪, 王晓燕. 基于网格单元的DBSCAN算法[J]. 吉林大学学报(工学版), 2014, 44(4): 1135-1139.
Liu Shufen, Meng Dongxue, Wang Xiaoyan. DBSCAN Algorithm Based on Grid Cell[J]. Journal of Jilin University(Engineering and Technology Edition), 2014, 44(4): 1135-1139.
- [16] 冯玲, 刘克剑, 唐福喜, 等. 一种基于网格查询的改进DBSCAN算法[J]. 西华大学学报(自然科学版), 2016, 35(5): 25-29.
Feng Ling, Liu Kejian, Tang Fuxi, et al. Improvements of DBSCAN Algorithm Based on Grid[J]. Journal of Xihua University(Natural Science Edition), 2016, 35(5): 25-29.
- [17] 陈叶旺, 曹海露, 陈谊, 等. 面向大规模数据的DBSCAN加速算法研究进展[J/OL]. 计算机研究与发展(2022-10-27) [2022-12-13]. <http://kns.cnki.net/kcms/detail/11.1777.TP.20221026.1942.014.html>.
Chen Yewang, Cao Hailu, Chen Yi, et al. Survey on Accelerating DBSCAN for Large Scale Data[J/OL]. Journal of Computer Research and Development(2022-10-27) [2022-12-13]. <http://kns.cnki.net/kcms/detail/11.1777.TP.20221026.1942.014.html>.
- [18] 何选森, 何帆, 徐丽, 等. K-Means算法最优聚类数量的确定[J]. 电子科技大学学报, 2022, 51(6): 904-912.
He Xuansen, He Fan, Xu Li, et al. Determination of the Optimal Number of Clusters in K-means Algorithm[J]. Journal of University of Electronic Science and Technology of China, 2022, 51(6): 904-912.
- [19] 袁国栋, 何明, 马子玉, 等. 基于K-means聚类的多智能体跟随多领导者算法[J]. 系统仿真学报, 2023, 35(3): 616-622.
Yuan Guodong, He Ming, Ma Ziyu, et al. Multiagent Following Multileader Algorithm Based on K-means Clustering[J]. Journal of System Simulation, 2023, 35(3): 616-622.
- [20] Al-Betar M A, Alyasserli Z A A, Awadallah M A, et al. Coronavirus Herd Immunity Optimizer (CHIO)[J]. Neural Computing and Applications, 2021, 33(10): 5011-5042.
- [21] Baran M E, Wu F F. Network Reconfiguration in Distribution Systems for Loss Reduction and Load Balancing[J]. IEEE Transactions on Power Delivery, 1989, 4(2): 1401-1407.