

基于混合粒子群算法的配电网故障重构研究

陈 壮, 胡亚琼, 王风华, 刘学义, 刘 印

(国网河南省电力公司桐柏县供电公司, 河南 南阳 473000)

摘要: 为了实现含分布式电源的配电网故障时的恢复供电, 在分析粒子群算法基本原理与配电网结构模型的基础上, 提出一种基于混沌映射改进的自适应混合粒子群算法。将压缩因子与自适应权重引入粒子群算法, 并借鉴遗传算法中的杂交与自然选择思想, 在每次迭代中根据杂交率选取一定粒子进行两两杂交, 把每次迭代结果中优秀的一半替换差的一半, 并对适应度值良好的粒子进行 Logistic 混沌优化。接入分布式电源的 IEEE 33 节点算例, 模拟不同算法进行故障重构。仿真测试结果体现出了改进算法具有更快的收敛速度与更好的稳定性。

关键词: 配电网自动化; 故障重构; Logistic 混沌优化; 混合粒子群算法; 遗传算法

Research on distribution network fault reconfiguration based on hybrid particle swarm optimization

CHEN Zhuang, HU Yaqiong, WANG Fenghua, LIU Xueyi, LIU Yin

(State grid Henan Electric Power Co., Ltd., Tongbai county power supply company, Nanyang 473000, China)

Abstract: In order to restore power supply in distribution network with distributed power supply, an improved adaptive hybrid particle swarm optimization algorithm based on chaotic mapping is proposed based on the analysis of the basic principle of particle swarm optimization algorithm and distribution network structure model. The compression factor and adaptive weight are introduced into the particle swarm optimization algorithm, and the ideas of hybridization and natural selection in genetic algorithm are used for reference. In each iteration, certain particles are selected according to the hybrid rate for pairwise hybridization. In each iteration, the excellent half of the results are replaced by the poor half, and then the particles with good fitness value are carried out Logistic chaos optimization. An example of IEEE 33 nodes connected to the distributed power supply is given to simulate different algorithms for fault reconstruction. The simulation results show that the improved algorithm has faster convergence speed and good stability.

Key words: distribution network automation; fault reconstruction; Logistic chaos optimization; hybrid particle swarm optimization; genetic algorithm

0 引言

配电网的重构问题分两大类, 即网络优化重构与故障恢复重构。网络优化重构是通过改变分段开关与联络开关的状态, 使配电网具有更好的供电可靠性和经济性, 减少系统的损耗和电

压偏差^[1]; 故障恢复重构是针对出现故障后的配电网, 不仅要隔离故障区域, 还应快速恢复非故障区域的供电, 并使重构后的网络损耗最低。随着大量分布式电源 (Distributed Generator, DG) 逐步接入配电网, 改变了配电网的单

辐射结构,使配电网的潮流更加复杂多变^[2]。

含DG的配电网在发生故障后,恢复重构在面对非故障区域时有两种处理方式:一种是与主电源网络连接恢复供电;另一种是与相邻DG连接成为孤岛区域恢复供电^[3]。

配电网故障恢复重构是一个复杂的多时段、多目标和多约束的非线性优化问题,粒子群算法针对此类问题,可通过迭代计算快速寻得最优解^[4]。但粒子群算法容易陷入局部最优,遗传算法有局部能力搜索差的问题。针对以上不足,提出基于混沌映射改进的自适应混合粒子群算法,加入遗传算法中的杂交与自然选择机制,提升种群多样性,保留适应度更好的粒子。再引入混沌映射生成混沌序列,将混沌映射优化杂交与自然选择之后的优良种群,以增加算法的随机性和多样性。最后利用MATLAB对IEEE 33节点配电网验证算法的可行性,并与其他算法进行对比。经测试,该方法具有更快的收敛速度与更好的稳定性。

1 数学模型

1.1 目标函数

对于配电网故障恢复重构有四种指标,分别是网络有功损耗、电压偏差、开关操作次数与负荷平衡度^[5]。

网络有功损耗是配电网经济性能的重要指标之一,考虑配电网接入DG后对电压质量的影响,本文优化函数为最小网络有功损耗的目标函数,表达式为

$$F = \sum_{i=1}^n K_i R_i \frac{P_i^2 + Q_i^2}{U_i^2} \quad (1)$$

式中, n 为配电网支路数量; i 为支路编号; K_i 为开关的状态编码,当 K_i 为1时表示闭合,为0时表示断开; R_i 为第 i 条支路的电阻; P_i 和 Q_i 为第 i 条支路的有功与无功功率; U_i 为第 i 个节点上的电压。

1.2 约束条件

配电网故障重构应满足以下五种约束条件。

(1) 节点潮流约束

$$\begin{cases} P_i + P_{DG_i} = P_{L_i} + U_i \sum_{j=1}^m U_j (G_{ij} \cos \varphi_{ij} + B_{ij} \sin \varphi_{ij}) \\ Q_i + Q_{DG_i} = Q_{L_i} + U_i \sum_{j=1}^m U_j (G_{ij} \sin \varphi_{ij} - B_{ij} \cos \varphi_{ij}) \end{cases} \quad (2)$$

式中, P_{DG_i} 与 Q_{DG_i} 分别为DG并网后注入节点 i 的有功功率与无功功率; P_i 与 Q_i 为节点 i 处主系统提供的有功与无功功率; P_{L_i} 与 Q_{L_i} 为节点 i 负荷的有功与无功功率; m 为节点数; 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; φ_{ij} 为节点 i 与节点 j 之间的相角差^[6]。

(2) 支路功率约束

$$S_i \leq S_{i\max} \quad (3)$$

(3) 节点电压约束

$$U_{i\min} \leq U_i \leq U_{i\max} \quad (4)$$

(4) 支路电流约束

$$I_i \leq I_{i\max} \quad (5)$$

(5) 网络拓扑结构约束

$$g_i \in G_i \quad (6)$$

配电网重构后的网络不含孤岛,且不闭环运行。

2 二进制粒子群算法的原理与优化

2.1 粒子群算法基本原理

粒子群优化算法是一种基于群体智能的随机寻优算法,算法的基本思想是:通过合作和信息共享搜索最优解。每个粒子都有位置向量和速度向量,并根据目标函数确定的适应度进行优化。粒子群中的所有粒子按照一定速度飞行,根据自身的经验和群体的最优值更新自己的速度和位置,并通过追随当前的最优值寻找全局最优解^[7]。

粒子群算法将一只鸟抽象为一个粒子 i ,由 n 个粒子组成的种群 $X=(X_1, X_2, X_3, \dots, X_n)$;第 i 个粒子表示 D 维向量 $X_i=(X_{i1}, X_{i2}, X_{i3}, \dots, X_{iD})^T$;第 i 个粒子的速度为 $V_i=(V_{i1}, V_{i2}, V_{i3}, \dots, V_{iD})^T$; $P_i=(P_{i1}, P_{i2}, \dots, P_{iD})^T$ 为个体极值。这些可以看作个体粒子的自身移动,全局极值为 $P_g=(P_{g1}, P_{g2}, \dots, P_{gD})^T$,可以看作所有粒子的群体动作。在每次迭代中评价各粒子的目标函

数值, 确定 t 时刻每个粒子的最优位置 p_{best} 与群体发现的最优位置 g_{best} , 各粒子的速度与位置更新为^[8]

$$V_{ij}(t+1) = V_{ij}(t) + c_1 r_1 [p_{ij} - X_{ij}(t)] + c_2 r_2 [p_{gj} - X_{ij}(t)] \quad (7)$$

$$X_{ij}(t+1) = X_{ij}(t) + V_{ij}(t+1), j = 1, \dots, d \quad (8)$$

式中, c_1 和 c_2 为正的学习因子; r_1 和 r_2 为0~1之间均匀分布的随机数。而且调节粒子的速度区间 $[V_{\min}, V_{\max}]$ 与位置区间 $[X_{\min}, X_{\max}]$ 可以有效控制粒子的移动, 以此达到最优的效果。

由上述公式可知, 粒子速度过大, 会很快达到全局最优解, 但靠近最优解时的控制条件难以发挥作用, 导致粒子飞行速度对全局收敛性影响较大。当算法缺少有效的约束条件时, 难以具备高效率的局部搜索能力, 所以引入惯性权重系数 ω , 此时各个粒子的速度与位置表达式为^[9]

$$V_{ij}(t+1) = \omega V_{ij}(t) + c_1 r_1 [p_{ij} - X_{ij}(t)] + c_2 r_2 [p_{gj} - X_{ij}(t)] \quad (9)$$

$$X_{ij}(t+1) = X_{ij}(t) + V_{ij}(t+1), j = 1, \dots, d \quad (10)$$

2.2 二进制粒子群算法 (BPSO)

BPSO可以由粒子速度的大小从概率角度定义粒子的位置, 使粒子每一维的位置 x_{in} 定位为0或者1。通过求解系统中0与1的概率搜寻最优解, 具体计算公式为

$$x_{id}^{m+1} = \begin{cases} 1 & \text{rand}() < \text{Sigmoid}(v_{id}^{m+1}) \\ 0 & \text{rand}() \geq \text{Sigmoid}(v_{id}^{m+1}) \end{cases} \quad (11)$$

式中, $\text{rand}()$ 为每次迭代之后生成的均匀分布于 $[0,1]$ 区间的随机数字, 代表着计算至第 $m+1$ 次时的第 i 个粒子的最新位置。

定义Sigmoid函数为

$$\text{Sigmoid} \begin{cases} -0.98 & v_{id}^{m+1} < -4 \\ \frac{1}{1 + e^{-v_{id}^{m+1}}} & -4 \leq v_{id}^{m+1} \leq 4 \\ 0.98 & v_{id}^{m+1} > 4 \end{cases} \quad (12)$$

由式(12)可得, 当速度 v_{id}^{m+1} 越小时, Sigmoid函数越靠近0; 当速度越大时, 函数值越逼近1。Sigmoid函数图像为S形状, 粒子速度限定范围为 $[-4, 4]$, 以免速度过快导致Sigmoid函数达到饱和, 对应的Sigmoid函数在

$[-0.98, 0.98]$ 内取值。

2.3 改进二进制粒子群算法

BPSO中粒子向最优解靠近, 形成快速趋同效应, 此时算法到达局部极值而过早停止。由于BPSO的性能对算法参数具有一定依赖性, 设置不同参数的结果会有差别。所以本文对BPSO算法进行以下改进, 使改进后的算法具有更高的准确度。

2.3.1 引入压缩因子

学习因子 c_1 与 c_2 决定粒子经验信息, 反映粒子之间的交流。学习因子 c_1 影响粒子向个体最优靠拢, 当 c_1 较大时, 粒子会在局部范围内徘徊, 导致粒子群的寻优能力变差。学习因子 c_2 影响粒子向群体历史最优位置靠拢, 当 c_2 设置较大时, 会使粒子过早收敛, 导致算法结果陷入局部最优。为了保证全局与局部寻优的平衡, 构造一个引入压缩因子的PSO模型, 式(9)可转化为

$$V_{ij}(t+1) = \varphi \{V_{ij}(t) + c_1 r_1 [p_{ij} - X_{ij}(t)] + c_2 r_2 [p_{gj} - X_{ij}(t)]\} \quad (13)$$

式中, φ 为收缩因子, 并且它的条件关系式为 $\varphi = 2 / \left| 2 - C - \sqrt{C^2 - 4C} \right|$, $C = c_1 + c_2$, $C > 4$, 本文取 $C = 4.1$ 。

2.3.2 加入自适应权重

采用非线性动态惯性权重系数平衡算法全局寻优与局部优化能力, 表达式为

$$\omega = \begin{cases} \omega_{\min} - \frac{(\omega_{\max} - \omega_{\min})(f - f_{\min})}{f_{\text{avg}} - f_{\min}} & f \leq f_{\text{avg}} \\ \omega_{\max} & f > f_{\text{avg}} \end{cases} \quad (14)$$

式中, $\omega_{\max}$ 与 $\omega_{\min}$ 为 ω 的最大值与最小值; f 为目标函数值; f_{avg} 和 $f_{\min}$ 为所有粒子的平均目标值与最小目标值。本文令最大权重系数为0.9, 最小值为0.6。

2.4 混合粒子群算法

2.4.1 杂交与自然选择机理

遗传算法中的自然选择机制是在每次迭代过程中, 根据粒子的适应度值对粒子进行排序。好的一半粒子会替换掉差的一半, 同时保留每个个体的历史最优值。这个机制确保每一代参与迭代的粒子都具有良好的性能, 使算法能够快速收敛到全局最优解。

杂交的原理借鉴了遗传算法中的交叉机制。在每一次迭代中,根据设定的杂交率,取一定数量粒子放入杂交池中。这些粒子两两随机地进行交叉操作,产生与父代数量 m 相同的子代粒子 n 。子代粒子的位置通过父代粒子的交叉操作得到^[10],即

$$n_x = \sigma m_x(1) + (1 - \sigma) m_x(2) \quad (15)$$

式中, m_x 表示父代粒子的位置; n_x 表示子代粒子的位置; σ 是0~1之间的随机数。

子代的速度公式为

$$n_v = \left| \frac{m_v(1) + m_v(2)}{m_v(1) + m_v(2)} \right| |m_v| \quad (16)$$

式中, m_v 表示父代粒子的速度; n_v 表示子代粒子的速度。

通过杂交操作,子代粒子可以结合父代粒子的优点,进一步增加搜索空间的多样性。子代粒子会替换掉父代粒子,成为下一代种群的一部分,继续参与下一次迭代。引入选择与杂交机制后的算法能够有效地搜索解空间并逐步逼近全局最优解。

2.4.2 Logistic混沌优化

混沌优化是在迭代过程中产生遍历性轨迹对所有解进行检测,在满足终止条件后认为此最佳状态解已接近最优解,以此解作为下一次迭代的起点。其中Logistic混沌是一种常见且典型的混沌系统,它因为具有较强的空间遍历性被广泛运用于算法的优化中。Logistic混沌映射公式为

$$z_{k+1} = \mu z_k(1 - z_k), \mu \in (0, 4) \quad (17)$$

式中, μ 为混沌系数,在给定条件下通过式(17)将初值以迭代的方式生成所需长度的Logistic序列。

本文选用Logistic混沌映射优化混合粒子群算法。Logistic混沌映射提供随机性和非线性变换,将混沌序列用作粒子群算法中的速度更新,可以增加搜索的多样性,避免陷入局部最优,提高算法的全局搜索能力。其次Logistic混沌映射可以通过调节控制参数来控制混沌序列,使混沌序列具有较好的收敛性,加速粒子群算法的收敛过程,减少迭代次数,提高算法效率。

2.4.3 混合粒子群算法的步骤流程

根据以上描述,基于混沌映射改进自适应混

合粒子群(CM-BNPSO)算法步骤如下:

1) 随机初始化粒子速度与位置。

2) 评价各粒子适应度值,将粒子位置与适应值存储在个体极值 p_{best} 中,将 p_{best} 中最优适应值的个体位置与适应度值保留在全局极值 g_{best} 中。

3) 更新粒子位移与速度,将每个粒子的适应度值与最优位置比较,相近则将当前值作为最优位置,比较所有 p_{best} 与 g_{best} ,更新 g_{best} 。

4) 根据适应度值对种群排序,适应度差的一半被好的一半替换,保留原粒子的历史最优值。

5) 设置杂交率,提取指定数量粒子放入杂交池,杂交生成对应数量的子代粒子,保持 p_{best} 和 g_{best} 不变。

6) 将 p_{best} 与 g_{best} 映射到混沌方程的定义域中,通过迭代得到混沌序列并映射回原解空间,计算最优解的适应度值。

7) 算法达到停止条件时,停止搜索并输出结果,否则返回步骤3)继续进行搜索。

2.4.4 算法流程图

算法流程如图1所示。




图1 算法流程图

Fig. 1 Algorithm flow chart

3 孤岛划分

3.1 孤岛划分准则

配电网故障后的孤岛划分应基于最初的环路划分与当下网络情况实时生成，这是一个多目标、多组合的非线性优化问题^[11]，考虑以下准则：

- 1) 网络中各节点根据负荷需求分为各个等级，重要负荷应最先恢复供电。
- 2) 孤岛中的DG应被分配与其总供电容量相匹配的总负荷，过大会危害系统与设备性能，过小使DG不被充分利用，经济效率低^[12]。

3.2 孤岛划分步骤

首先以DG为中心，以DG的容量为约束条件

(划分半径) 来确定孤岛划分的范围，再将划分区域内的负荷节点由高到低进行编号^[13]，结果见表1，余下节点均为第三等级负荷。

表 1 节点负荷等级参数
Tab. 1 Node load grade parameters

负荷等级	节点
一级负荷	5、6、12、13、23、24、29、31
二级负荷	7、11、15、22、26、30、32

以IEEE 33节点系统为例，接入DG后的配电网结果如图2所示，接入DG数据见表2，使用算法以网损最小与DG承受容量为目标对DG进行划分孤岛求解，结果见表3。




图 2 33 节点配电网示意图
Fig. 2 Schematic diagram of 33-node power distribution network

表 2 DG 接入点与容量
Tab. 2 DG access points and capacity

接入节点	有功功率 /kW	功率因数
13	500	0.9
25	1 200	0.8
32	650	0.9

表 3 孤岛划分结果
Tab. 3 Results of islanding division

	孤岛负荷点	断开开关
DG1	13、12、15、11、14、10	S9、S15
DG2	25、24、23、22	S21
DG3	32、33、31、30	S30

4 算例仿真与分析

本次实验将本文改进的CM-BNPSO算法与其他算法在标准IEEE 33节点配电网中进行仿真对比。

图2中，G表示主电源，并接入DG1、DG2与DG3三个分布式电源。1~33为节点编号，(1)~(32)为分段开关编号，(33)~(37)为联络开关编号。整个实验的基准电压为12.66 kV，网络总负荷为(6.431+j2.821) MV·A。

4.1 算例仿真

- (1)当配电网支路(26)单独故障时
发生故障后，首先切断支路(26)与网络联

系, 对其进行隔离。支路(26)下游区域有DG3。根据表3, 令开关S30断开, 使DG3切换为孤岛运行模式。故障重构后的网络如图3所示, 重构结果见表4。




图3 重构后网络拓扑结构
Fig.3 Network topology after reconstruction

表4 系统重构结果
Tab. 4 Results of system reconstruction

	断开开关	有功损耗 /kW	最低电压 (pu)
故障前	S33、S34、S35、S36、S37	202.547	0.9691
CM-BNPSO	S9、S26、S29、S33、S34、S36	144.607	0.9749

(2) 当配电网支路(9)和支路(21)故障时
发生故障后, 首先切断支路(9)和支路(21)与网络联系, 对其进行隔离。支路(9)和支路(21)下游区域有DG1与DG2。根据表3令开关S9与S15断开, 使DG1与DG2切换为孤岛运行模式, DG1参与剩余系统的故障恢复重构。故障重构后的网络如图4所示, 重构结果见表5, 电压曲线如图5所示。




图4 重构后网络拓扑结构
Fig. 4 Network topology after reconstruction

表5 系统重构结果

Tab. 5 Results of system reconstruction

	断开开关	有功损耗 / kW	最低电压 (pu)
故障前	S33、S34、S35、S36、S37	202.547	0.9691
CM-BNPSO	S8、S9、S15、S18、S21、S34、S35、S37	133.911	0.9717




图5 重构前后节点电压对比图

Fig. 5 Node voltage comparison before and after reconstruction

4.2 算法对比分析

为清晰表明改进后算法的优越性, 将改进算法CM-BNPSO与其他算法进行不同故障类型的对比。两者的种群数量均为50, 最大迭代次数为50, 种群的维度 $D=37$ 。改进算法的惯性权重系数设置为 $\omega_{\max}=0.9$, $\omega_{\min}=0.6$; 学习因子设置为 $c_1=2.05$, $c_2=2.05$ 。算法对比如图6所示。




图6 算法迭代曲线对比图

Fig. 6 Comparison of algorithm iteration curves

从图6能明显看出CM-BNPSO算法迭代次数少,收敛快速,在两种情况下都能快速取得全局最优值,稳定性良好,具有较高的容错能力,可以有效地应用于接入DG后支路复杂的配电网络。

5 结束语

本文针对愈发复杂的配电网络故障重构问题,通过增加压缩因子、引入自适应权重来改进BPSO算法,并融合了遗传算法中的杂交与自然选择机制,加入了Logistic混沌映射,提高了全局搜索能力。利用CM-BNPSO算法对含DG的故障配电网络进行故障重构,验证了此优化算法具有良好的性能,可以适用于复杂配电网络。通过与其他算法的对比,表明CM-BNPSO算法有着更好的计算效率与容错性能,证明其在含DG的配电网络故障重构中的可行性与优越性。

参考文献

- [1] 陈新岗, 罗浩, 金雅珍, 等. 基于ICQPSO的配电网故障恢复重构[J]. 重庆理工大学学报(自然科学), 2020, 34(9): 245-251.
- [2] 潘磊. 基于GA-QPSO算法的配电网故障区段定位与恢复重构研究[D]. 北京: 中国矿业大学, 2023.
- [3] 郑海广. 基于GA-BFGS算法的配电网故障恢复性重构研究[D]. 北京: 中国矿业大学, 2020.
- [4] 宫宇, 张莲, 李涛, 等. 量子粒子群算法在配电网恢复重构中的应用[J]. 重庆理工大学学报(自然科学), 2022, 36(10): 200-207.
- [5] KAHOULI O, ALSAIF H, BOUTERAA Y, et al. Power system reconfiguration in distribution network for improving reliability using genetic algorithm and particle swarm optimization[J]. Applied Sciences, 2021, 11(7): 3092.
- [6] WANG H, CHEN Z, ZHAO H, et al. Reconstruction strategies for fault recovery of active distribution network with distributed generation uncertainties[J]. Power Syst. Technol, 2022, 46: 4356-4364.
- [7] 宫宇. 基于粒子群算法的配电网故障区段定位与恢复重构研究[D]. 重庆: 重庆理工大学, 2022.
- [8] 岳晓峰, 刘天. 基于粒子群算法的RBF神经网络零件表面缺陷分类[J]. 电子技术与软件工程, 2019(4): 18-20.
- [9] 刘子俊, 王廷凤, 黄福全, 等. 基于粒子群破坏的主动配电网故障重构协同优化[J]. 电力信息与通信技术, 2021, 19(4): 84-90.
- [10] 韩富春, 刘利红, 岳永新. 基于改进粒子群算法的电力系统无功优化研究[J]. 电气技术, 2011(7): 6-8.
- [11] YIDA T, ZHI W U, WEI G U, et al. Research on active distribution network fault recovery strategy based on unified model considering reconstruction and island partition [J]. Power System Technology, 2020, 44(7): 2731-2740.
- [12] 钟建伟, 刘佳芳, 倪俊, 等. 基于粒子群蚁群混合算法的配电网故障后重构研究[J]. 水电能源科学, 2017, 35(3): 195-198.
- [13] 刘星, 崔双喜. 孤岛与重构相配合的配电网故障恢复策略[J]. 华电技术, 2020, 42(1): 29-34.

作者简介

陈壮(1984—), 男, 主要研究方向为配电网故障定位与恢复重构。

(收稿日期: 2023-12-14)