

文章编号: 1001-0920(2013)04-0557-06

基于快速自适应差分进化算法的电力系统经济负荷分配

吴亮红¹, 王耀南², 袁小芳², 曾照福¹

(1. 湖南科技大学先进矿山装备教育部工程研究中心, 湖南湘潭 411201; 2. 湖南大学电气与信息工程学院, 长沙 410082)

摘要: 提出一种求解复杂电力系统经济负荷分配问题的快速自适应差分进化算法(FSADE). 从矢量运算角度对变异算子进行分析, 提出了一种改进的变异算子, 大大提高了算法的收敛速率. 根据个体的进化过程, 引入自学习机制, 对个体的变异和交叉概率常数进行自适应地调整, 提高了算法的鲁棒性. 3个不同规模的算例仿真结果表明, 与其他4种典型智能优化算法相比, FSADE具有更好的计算精度和计算速度, 是一种求解电力系统经济负荷分配问题的有效方法.

关键词: 电力系统; 经济负荷分配; 阀点效应; 自适应; 差分进化算法

中图分类号: TM714; TP301.6

文献标志码: A

Fast self-adaptive differential evolution algorithm for power economic load dispatch

WU Liang-hong¹, WANG Yao-nan², YUAN Xiao-fang², ZENG Zhao-fu¹

(1. Engineering Research Center of Advanced Mining Equipment, Ministry of Education, Hu'nan University of Science and Technology, Xiangtan 411201, China; 2. College of Electrical and Information Engineering, Hu'nan University, Changsha 410082, China. Correspondent: WU Liang-hong, E-mail: lhwu@hnust.edu.cn)

Abstract: A fast self-adaptive differential evolution algorithm(FSADE) for the complex nonlinear power economic load dispatch problem is proposed. In the view of vector operation, the mutant operator of basic differential evolution algorithm is analyzed, then an improved mutant operator is proposed to improve the convergence speed greatly. According to the individual evolutionary process, a self-learning mechanism is introduced to adapt the mutation constant and crossover probability constant. As a result, the robustness of the proposed algorithm is improved. To demonstrate the effectiveness of the proposed algorithm, three classical test cases are conducted and compared with four other intelligent optimization algorithms. The experiment results show that the proposed FSADE is an very effective algorithm for solving the power economic dispatch.

Key words: power system; economic dispatch; valve-point effects; self-adaptation; differential evolution

0 引言

电力系统经济负荷分配(PED)对提高系统的经济性和稳定性具有重要意义,其目标是在满足发电机组和电力系统运行约束的条件下,在各台机组间合理地分配负荷使得发电成本最小化.但由于火电机组阀点效应的存在,机组的耗量特性函数为一不可导的非线性函数^[1];同时,受输电系统输送能力和系统稳定性等条件的限制,使得问题求解的可行域非凸^[2].可见,电力系统经济负荷分配是一个具有高维数、非

线性、不可微、多约束的复杂优化问题.求解该问题的经典数学方法,如等微增率法、二次规划、非线性规划等,要求目标函数连续可导,且定义于凸可行域,优化结果与初值选取有很大的关系^[2-3];动态规划法对目标函数无严格限制,但随着求解问题的维数增加,计算量急剧增大,面临“维数灾”问题^[4].

进化算法(EA)是一类模拟生物自然选择与自然进化的随机搜索算法,不依赖于目标函数和约束条件的连续性、可导性等,具有较好的通用性和鲁棒性,是求解大规模高维复杂非线性优化问题的有效方法,近

收稿日期: 2011-11-07; 修回日期: 2012-04-27.

基金项目: 国家自然科学基金重点项目(60835004); 国家自然科学基金项目(61203309, 61104088); 湖南省教育厅优秀青年项目(12B043); 湖南省自然科学基金项目(10JJ9007); 湖南省产学研结合创新平台项目(2010XK6066).

作者简介: 吴亮红(1977-),男,副教授,博士,从事智能优化算法及应用等研究; 王耀南(1957-),男,教授,博士生导师,从事智能控制、智能信息处理、智能图像处理等研究.

年来取得了飞速发展和广泛应用. 进化算法在经济负荷分配中的应用得到了广泛关注^[1, 4-10]. 差分进化算法(DE)是Rainer和Kenneth^[11]于1995年共同提出的一种采用浮点矢量编码, 在连续空间中进行随机、并行、全局搜索的优化算法. DE原理简单, 受控参数少, 易于理解和实现, 是当前最有效的随机优化算法之一. 近年来, DE作为一种性能卓越的优化算法日益受到关注, 其应用领域也越来越广, 同时也为解决PED问题指出了新的方向. 文献[12]结合单纯形算法提出了一种基于双群体的混合差分进化算法(HDEDP)用于求解考虑阀点效应的PED问题, 并与改进的进化规划算法进行了比较分析. 文献[13]提出了一种自适应差分进化算法以求解考虑多燃料选择特性和阀点效应的PED问题, 得到了较好的优化结果. 但该文的参数自适应策略没有任何进化过程的指导, 是一种随机方式, 虽简化了参数选择, 但存在很大的盲目性, 对DE性能的改进效果甚微.

本文根据个体在进化过程中的状态, 借鉴人类向周围优秀个体学习的经验, 提出一种具有自学习能力的参数自适应策略; 同时, 为了提高算法的收敛速率, 从矢量运算的角度对变异算子进行分析, 提出一种新的变异策略. 本文所提出的改进算法称为快速自适应差分进化算法(FSADE). 通过对多个经济负荷分配问题进行仿真研究, 并与其他多种智能优化算法进行了比较, 实验结果表明, 本文方法是一种求解PED问题的有效方法.

1 电力系统负荷分配的数学模型

1.1 目标函数

PED问题是在满足系统运行约束条件下优化系统中发电机组功率, 使系统总发电成本最小. 其目标函数为

$$\min F_T = \sum_{j=1}^M F_j(P_j). \quad (1)$$

其中: M 为系统内发电机总数, F_T 为系统总发电费用, F_j 为第 j 台发电机耗量特性, P_j 为第 j 台发电机输出的有功功率.

对于发电机耗量特性 F_j , 一般用光滑的二次函数近似表示为

$$F_j(P_j) = a_j + b_j P_j + c_j P_j^2, \quad (2)$$

其中 a_j , b_j 和 c_j 为发电机耗量特性曲线系数.

由于汽轮机进气阀突然开启时会出现拔丝现象, 在机组耗量特性曲线上叠加一个脉动效果并产生阀点效应. 研究表明, 忽略阀点效应会使求解精度受到明显影响^[1]. 计及阀点效应的发电机耗量特性为

$$F_j(P_j) = a_j + b_j P_j + c_j P_j^2 + |d_j \sin[e_j(P_j - P_j^{\min})]|, \quad (3)$$

其中 d_j 和 e_j 为耗量特性系数.

1.2 约束条件

发电机运行约束为

$$F_j^{\min} \leq P_j \leq P_j^{\max}, \quad (4)$$

其中 P_j^{\max} 和 P_j^{\min} 为第 j 台发电机输出有功功率的上下限.

电力平衡约束为

$$\sum_{j=1}^M P_j = P_D + P_L. \quad (5)$$

其中: P_D 为系统总负荷, P_L 为系统总网损. 网损一般采用潮流法和B系统数法求得. 当电力系统覆盖密集时可以忽略网损, 本文在计算中忽略了网损, 故电力平衡约束可简化为

$$\sum_{j=1}^M P_j - P_D = 0. \quad (6)$$

2 快速自适应差分进化算法

2.1 基本差分进化算法

差分进化算法由NP个 n 维参数矢量 $X_i^t = (x_{i1}^t, x_{i2}^t, \dots, x_{in}^t)$ ($i = 1, 2, \dots, NP$)构成一代种群在搜索空间进行寻优. 其中: NP为种群规模, n 为问题的决策变量个数, t 为代数. 初始种群在参数空间中随机产生, 并应覆盖整个参数空间. 在进化的每一代中, 对每一目标个体进行变异和交叉操作以产生试验个体, 然后对目标个体和试验个体进行选择操作, 以选择适应值更优的个体进入下一代.

对于每一目标个体 X_i^t , 对应的变异矢量 $V_i^t = (v_{i1}^t, v_{i2}^t, \dots, v_{in}^t)$ 由下式确定:

$$V_i^t = X_{r1}^t + F(X_{r2}^t - X_{r3}^t). \quad (7)$$

其中: F 为大于零的实数, 称为变异常数, 控制差分矢量的缩放以避免搜索的停滞, 根据Storn和Price^[11], F 的取值范围为 $[0, 2]$, 在实际使用过程中, F 的取值一般为 $[0, 1]$; $r1, r2, r3$ 为互不相同的个体索引, 随机取自于种群集 $\{i = 1, 2, \dots, NP\}$. 同时, 这些索引与当前目标个体索引 i 不相同, 所以种群规模不能少于4.

变异之后进行交叉操作, 以产生试验个体 V_i^t . 对于每一变异矢量, 按下式生成一试验个体 $U_i^t = (u_{i1}^t, u_{i2}^t, \dots, u_{in}^t)$, 即

$$u_{ij}^t = \begin{cases} v_{ij}^t, & \text{rand } j \leq CR \text{ or } j = \text{rand } n_i \\ x_{ij}^t, & \text{rand } j > CR \text{ and } j \neq \text{rand } n_i. \end{cases} \quad (8)$$

其中: $j = 1, 2, \dots, n$, $\text{rand } j$ 为 $[0, 1]$ 之间均匀分布的随机数; CR为交叉概率常数, 其取值范围为 $(0, 1]$;

$\text{rand } i \in (1, 2, \dots, n)$ 是一随机选择的变量索引, 以保证 U_i^t 至少有一维变量由 V_i^t 贡献, 否则可能没有新个体产生而导致整个种群不发生任何变化, 使搜索陷入停顿。

经变异与交叉操作后生成的试验个体 U_i^t 与 X_i^t 进行竞争。当 U_i^t 的适应度较 X_i^t 相等或更优时, 被选作子代; 否则, 直接将 X_i^t 作为子代。其选择操作的方程为

$$X_i^{t+1} = \begin{cases} U_i^t, & f(U_i^t) \leq f(X_i^t); \\ X_i^t, & \text{otherwise.} \end{cases} \quad (9)$$

值得指出的是, 当 U_i^t 与 X_i^t 的适应度相等时, U_i^t 也被选择进入下一代, 这有利于个体在适应度景观的平坦区域移动。

2.2 变异操作的改进

由式(7)可知, 基本DE的变异操作中用来被变异的基矢量 $X_{r_1}^t$ 是从随机选择的3个不同个体中随机选择的, 这有利于算法进行全局搜索, 但不利于算法的收敛速率提高。为了加快收敛速率, 本文从矢量运算的角度提出一种改进的变异算子。在进行变异时, 将3个随机选择的用于生成变异矢量的个体矢量按适应度值大小排序, 其中适应度值最优的个体记为 $X_{r_b}^t$, 次优的个体记为 $X_{r_m}^t$, 而最差的个体记为 $X_{r_w}^t$ 。从提高收敛速率的角度, 变异操作方程应以 $X_{r_b}^t$ 为变异基矢量(以 $X_{r_b}^t$ 为引导), 同时差分矢量应指向 $X_{r_m}^t$, 即以 $(X_{r_m}^t - X_{r_w}^t)$ 为差分矢量, 这种改进的变异操作方程如下式所示:

$$V_i^t = X_{r_b}^t + F(X_{r_m}^t - X_{r_w}^t). \quad (10)$$

由式(10)可知, 改进的变异操作不再是一种完全的随机搜索, 而是基矢量 $X_{r_b}^t$ 在确定的差分矢量 $(X_{r_m}^t - X_{r_w}^t)$ 方向搜索, 显然有利于提高收敛速率。但是, 任一个体每次进行变异的3个个体矢量都是从当前种群中随机选择的, 因而这种确定性是随机中的确定性, 不会影响算法的全局搜索性能。

2.3 参数自适应策略

DE的变异常数 F 和交叉概率常数 CR 对算法的优化性能有着重要的影响作用, 而选择合适的控制参数通常与问题相关, 不同的优化问题对应着不同的控制参数。原创DE算法的整个群体共享同一个 F 和 CR , 且 F 和 CR 在整个进化过程中始终保持不变。为了使参数的选择独立于优化问题, 提高算法的鲁棒性, 文献[12-15]提出了不同的自适应策略, 使控制参数在个体进化过程中自适应地变化。但这些自适应策略没有进化过程的指导, 具有很大的盲目性。本文根据优化过程中个体的进化状态, 提出一种新

的具有自学习能力的参数自适应策略。如图1所示, 将 F 和 CR 参与个体编码, 每一个体矢量 X_i^t 对应一个 F_i^t 和 CR_i^t 。初始化时, F_i^t 在给定的范围 $[0.1, 0.9]$ 内随机生成, 而 CR_i^t 在给定的范围 $(0, 0.9]$ 内随机生成。

X_1^t	F_1^t	CR_1^t
X_2^t	F_2^t	CR_2^t
\vdots	\vdots	\vdots
X_{NP}^t	F_{NP}^t	CR_{NP}^t

图1 个体编码格式

在进化过程中, 如果任何个体连续 α 代(如5代)不能生成一个更优的试验个体, 则说明该个体的当前控制参数不合适而应重新设置; 反之, 在每一连续的 α 代, 如果一个个体生成了一个或多个更优的子个体, 则认为该个体的当前控制参数是合适的而应保留进入后面的进化代。因此, 当前种群中生成更优试验个体次数最多的个体的控制参数即为当前种群中最合适的参数。显然, 不合适的个体控制参数在重新设置时应向当前种群中最合适的控制参数学习, 这也符合群体进化的一般规律。

基于以上思想, 本文提出的具有学习能力的参数自适应修正策略为

$$F_i^t = F_i + (1 - C_i/C_b) * (F_b^t - F_i), \quad (11)$$

$$CR_i^t = CR_i + (1 - C_i/C_b) * (CR_b^t - CR_i). \quad (12)$$

其中: F_i 和 CR_i 分别为个体 X_i^t 的当前变异和交叉常数值, F_b^t 和 CR_b^t 分别为当前种群中持续改进次数最多的个体对应的变异和交叉常数值(最合适的控制参数), C_i 为个体 X_i 的累计改进次数, C_b 为当前最大累计改进次数; F_i^t 和 CR_i^t 则分别为自适应调整后的变异和交叉常数。这里, $(1 - C_i/C_b)$ 称为学习步长, 累计改进次数越少的个体其学习步长越大(向最合适的控制参数学习得越多), 而累计改进次数越多的个体其控制参数相对较为合适, 因而学习步长越小(向最合适的控制参数学习得越少)。以上参数自适应更新规则表明, 进化过程中每 α 代没能产生更优子代的个体的控制参数, 以一定的学习步长不断向当前种群中最合适的控制参数靠近, 具有自学习的能力。

上述参数适应更新规则是对人类学习行为的模拟, 与原创DE相比计算复杂度增加很小。控制参数更新在变异操作之前完成, 从而新的控制参数能够影响到子代个体的变异、交叉和选择操作。通过利用该策略, 对于每一优化问题无须试凑合适的变异和交叉常数值, 算法能根据优化过程自动地进化到合适的控制参数值, 从而提高了算法的鲁棒性。

3 PED问题的 FSADE 求解方法

3.1 可行化调整机制

按照式(11)和(8),经过变异和交叉后生成的试验个体往往不能满足等式约束(6).常用的方法是采用惩罚函数法或由寻优群体在搜索域内求得前 $M-1$ 维变量,剩余 1 维变量的值由等式约束来确定^[4],但这种方法很容易导致最后一维解不满足运行约束(4)而造成无效解.大量无效解的产生会降低解的多样性和收敛速度,导致无法找到全局最优解.对此,本文采用一种基于不可行解违反等式约束程度和各维变量可松弛度的等式约束新方法^[7],能有效保证解的可行性.

设不可行解向量 $P_i = [P_{i1}, P_{i2}, \dots, P_{iM}]$ 违反等式约束的程度为

$$D_i = \sum_{j=1}^M P_{ij} - P_D. \quad (13)$$

对 M 维变量 P_i ,按式(14)和(15)求出其与上限 P_j^{\max} 和下限 P_j^{\min} 之差 ($j = 1, 2, \dots, M$, 上下限差均为正数),即

$$\bar{P}_i = P_i^{\max} - P_i = [\bar{P}_{i1}, \bar{P}_{i2}, \dots, \bar{P}_{iM}], \quad (14)$$

$$\underline{P}_i = P_i - P_i^{\min} = [\underline{P}_{i1}, \underline{P}_{i2}, \dots, \underline{P}_{iM}]. \quad (15)$$

然后,根据各维变量可松弛度的大小,将 D_i 分配给各维变量,求得各维变量的浮动值 ΔP_{ij} .

当 $D_i > 0$ 时,有

$$\Delta P_{ij} = \frac{P_{ij}}{\sum_{j=1}^M P_{ij}} D_i, \quad j = 1, 2, \dots, M, \quad (16)$$

则可行化调整得到的可行解为

$$P'_i = P_i - \Delta P_i = [P_{i1} - \Delta P_{i1}, P_{i2} - \Delta P_{i2}, \dots, P_{iM} - \Delta P_{iM}]. \quad (17)$$

当 $D_i < 0$ 时,有

$$\Delta P_{ij} = \frac{\bar{P}_{ij}}{\sum_{j=1}^M \bar{P}_{ij}} |D_i|, \quad j = 1, 2, \dots, M, \quad (18)$$

则可行化调整得到的可行解为

$$P'_i = P_i + \Delta P_i = [P_{i1} + \Delta P_{i1}, P_{i2} + \Delta P_{i2}, \dots, P_{iM} + \Delta P_{iM}]. \quad (19)$$

3.2 算法流程

Step 1: 初始化种群规模 NP,并按可行化调整机制进行调整;每一个体的差分变异矢量收缩因子 F_i^0 ,交叉概率 CR_i^0 ;在参数空间随机初始化每一个个体;设置最大迭代次数 T ,令 $t = 1$.

Step 2: 计算每个个体的适应度值,求出当前种群中最优适应度值及最优个体 X_{best}^t .

Step 3: 判断是否满足终止条件.若是则退出,否

则执行下一步.

Step 4: 判断每一个体 X_i 的适应度值连续 α 代是否有改进.若没有,则对该个体的控制参数 F_i 和 CR_i 按式(11)和(12)进行自适应调整,得到新的控制参数.

Step 5: 对每一个体 X_i^t 执行以下 Step 6 ~ Step 9,生成第 $t+1$ 代种群.

Step 6: 在种群中随机选择 3 个不同的个体,按式(11)进行变异操作,生成变异个体 V_i^t .

Step 7: 按式(8)进行交叉操作,生成试验个体 U_i^t .

Step 8: 对试验个体 U_i^t 进行可行化调整.

Step 9: 按式(9)进行选择操作,生成 $t+1$ 代个体 X_i^{t+1} .

Step 10: $t = t + 1$,返回 Step 2.

4 算例分析

为验证本文 FSADE 算法求解高维、非凸、不可微和多约束非线性 PED 优化问题的有效性,对 3 个不同规模的典型 PED 问题进行了仿真研究,并与其他 4 种智能优化算法进行对比实验,即进化规划算法(EP)^[4]、改进遗传算法(IGA)^[8]、自调节粒子群优化算法(SPSO)^[7]以及双种群混合差分进化算法(HDEDP)^[13].实验中所有算例均考虑耗量特性的阀点效应,忽略网损.FSADE 算法的实验参数如表 1 所示,其他算法的参数设置见对应文献.FSADE 每隔 5 代进行一次控制参数自适应调整.

表 1 FSADE 算法实验参数

算例	种群规模 NP	迭代次数 T	变异常数 F	交叉常数 CR
1	30	50	[0.1, 0.9]	(0, 0.9]
2	50	300	[0.1, 0.9]	(0, 0.9]
3	100	600	[0.1, 0.9]	(0, 0.9]

算例 1 是 3 机 6 母线系统,总负荷 $P_D = 850$ MW;算例 2 是 13 机系统,总负荷 $P_D = 1800$ MW;算例 3 是 40 机系统,总负荷 $P_D = 10500$ MW.各算例的原始数据参见文献[4].为了克服随机性影响,每一算例均用 5 种算法分别独立计算 50 次.表 2 ~ 表 4 给出了上述 5 种算法的运算结果,其中 F_{\min} 、 F_{\max} 和 F_{mean} 分别为 50 次独立运行中求得的目标函数值的最小值、最大值和平均值.

由表 2 ~ 表 4 可知,算例 1 的维数较低,SPSO、HDEDP 以及 FSADE 均能搜索到最优解,所求得的目标函数最小值相同,且 HDEDP 每次均能找到最优解,

表 2 算例 1 计算结果比较

算法	FSADE	HDEDP ^[12]	SPSO ^[7]	IGA ^[8]	EP ^[4]
F_{\max}	8241.59	8234.07	8241.58	8361.86	8315.14
F_{mean}	8235.83	8234.07	8236.95	8245.01	8259.34
F_{\min}	8234.07	8234.07	8234.07	8241.58	8234.07

表3 算例2计算结果比较

算法	FSADE	HDEDP ^[12]	SPSO ^[7]	IGA ^[8]	EP ^[4]
F_{max}	18 145.33	18 239	18 443.66	18 789.89	18 658.33
F_{mean}	18 063.67	18 131	18 177.45	18 413.73	18 358.56
F_{min}	17 972.81	17 979	17 972.88	18 277.41	18 232.37

表4 算例3计算结果比较

算法	FSADE	HDEDP ^[12]	SPSO ^[7]	IGA ^[8]	EP ^[4]
F_{max}	121 512.58	123 102	128 844.66	129 519.40	140 537.81
F_{mean}	121 390.08	122 702	124 070.40	129 519.40	136 077.66
F_{min}	121 265.46	122 177	122 108.98	129 516.40	131 460.05

而EP和IGA每次都找不到最优解;虽然SPSO所求得的目标函数最大值略优于FSADE,但FSADE的平均值优于SPSO,说明FSADE算法比SPSO更稳定,鲁棒性更强.对于算例2,SPSO和HDEDP与FSADE所求得目标函数的最小值有相似的精度,但FSADE所求得平均值和最大值均明显优于其他4种算法;EP和IGA均无法搜索到最优解,求解精度低.随着维数的增加,问题的复杂程度越高,例如算例3,SPSO、EP和IGA的求解精度都较差,对于高维复杂优化问题易陷入局部最优解;虽然HDEDP也有较高的求解精度,但FSADE的计算精度和解的分布情况均明显优于HDEDP,表明本文算法是解决大规模、多变量、非线性复杂优化问题的有效方法.

另外,为了说明本文提出的改进变异操作和具有自学习能力的参数自适应策略的有效性,以算例2为优化对象,与基本差分进化算法和文献[13]中提出的自适应差分进化算法(SADE)进行比较.基本差分进化算法的变异常数 F 和交叉概率常数 CR 均为0.5,SADE的参数设置见文献[13],FSADE的参数设置同前.3种算法的种群规模和最大迭代次数分别为50和300.为了避免随机性带来的影响,每一算法均独立运行100次,其平均最优适应度曲线如图2所示.




图2 不同算法求得算例2的平均最优适应度进化曲线

由图2可知,FSADE由于采用改进的加速变异算子,其收敛速率显著提高.100次独立实验表明,改进的变异操作并不影响算法的全局搜索能力;同时,由于利用自学习机制对控制参数进行自适应地更新,算法具有更强的鲁棒性,其参数的选择不依赖于具体

问题.从图2还可以看出,SADE每一个体有对应的控制参数,虽然其自适应机制没有进化过程的引导,但控制参数是动态变化的,好于基本差分进化算法中的固定控制参数.

为了进一步说明本文提出的参数自适应策略的自学习能力,图3和图4分别给出了FSADE求解算例2时变异常数 F 和交叉常数 CR 的自适应变化情况.从图3和图4可以看出,随机初始化的控制参数随着进化的进行不断向种群中最合适的控制参数学习并逼近,最终大多数个体的控制参数都收敛或分布在最合适控制参数附近.对于算例2,变异常数 F 和交叉常数 CR 分别选取0.146和0.174是比较合适的.

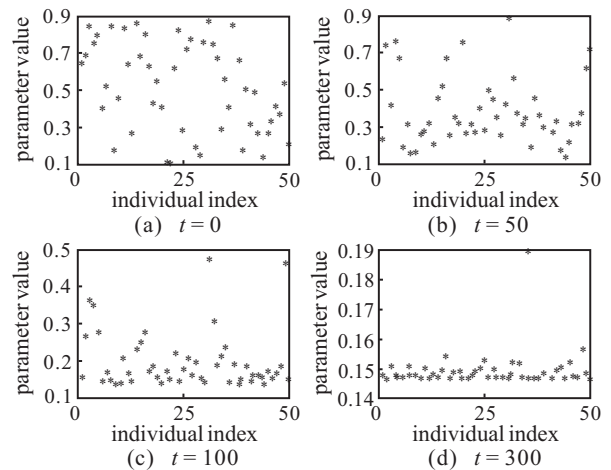


图3 FSADE求解算例2时变异常数 F 的自适应过程

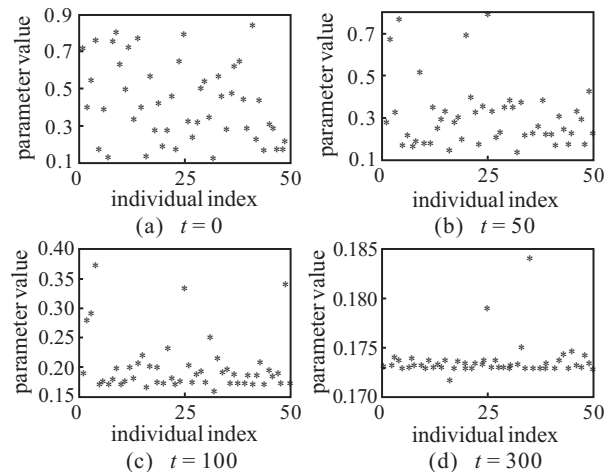


图4 FSADE求解算例2时交叉常数 CR 的自适应过程

5 结论

本文提出了一种用于求解非凸、非线性、多约束复杂电力系统经济负荷分配优化问题的加速自适应差分进化算法.算法以矢量运算为基础,对变异操作进行了改进,在不改变算法全局收敛能力的前提下,大大提高了算法的收敛速率.同时,根据个体的进化过程,引入自学习机制对控制参数进行自适应地调整,解决了算法控制参数设置对问题的依赖性,提高了算

法的鲁棒性. 针对等式约束问题, 根据不可行解违反等式约束程度和各维变量的可松弛度, 对不可行解进行可行性调整, 有效保证了解的可行性. 对 3 个不同规模的典型算例进行了仿真研究, 并与其他 4 种智能优化方法进行了比较, 实验结果表明, 本文方法是一种求解大规模电力系统经济负荷分配问题的有效方法. 由于该算法的所有改进操作几乎没有增加原来算法的计算量, 可广泛地用于电力系统的其他优化问题.

参考文献(References)

- [1] David C W, Gerald B S. Genetic algorithm solution of economic dispatch with valve point loading[J]. IEEE Trans on Power Systems, 1993, 8(3): 1325-1332.
- [2] Lin W, Cheng F, Tsay M. Nonconvex economic dispatch by integrated artificial intelligence[J]. IEEE Trans on Power Systems, 2001, 16(2): 307-311.
- [3] Ralin A J, Alun H C, Brian J C. A homogenous linear programming algorithm for the security constrained economic dispatch problem[J]. IEEE Trans on Power Systems, 2000, 15(3): 930-936.
- [4] Sinha N, Chakrabarti R, Chattopadhyay P K. Evolutionary programming techniques for economic load dispatch[J]. IEEE Trans on Evolutionary Computer, 2003, 7(1): 83-94.
- [5] 侯云鹤, 熊信良, 吴耀武, 等. 基于广义蚁群算法的电力系统经济负荷分配[J]. 中国电机工程学报, 2003, 23(3): 59-64.
(Hou Y H, Xiong X Y, Wu Y W, et al. Economic dispatch of power systems based on generalized ant colony optimization method[J]. Proc of CSEE, 2003, 23(3): 59-64.)
- [6] Park J B, Lee K S, Shin J R, et al. A particle swarm optimization for economic dispatch with nonsmooth cost function[J]. IEEE Trans on Power Systems, 2005, 20(1): 34-42.
- [7] 张雪雯, 李艳君. 基于自调节粒子群算法的电力系统经济负荷分配[J]. 电网技术, 2006, 30(18): 8-14.
(Zhang X W, Li Y J. Self-adjusted particle swarm optimization algorithm based economic load dispatch of power system[J]. Power System Technology, 2006, 30(18): 8-14.)
- [8] Chiang C L. Improved genetic algorithm for power economic dispatch of units with valve-point effects and multiple fuels[J]. IEEE Trans on Power Systems, 2005, 20(4): 1690-1699.
- [9] 蒙文川, 邱家驹, 卞晓猛. 电力系统经济负荷分配的人工免疫混沌优化算法[J]. 电网技术, 2006, 30(23): 41-45.
(Meng W C, Qiu J J, Bian X M. Artificial immune algorithm integrated with chaotic optimization for economic dispatch of power system[J]. Power System Technology, 2006, 30(23): 41-45.)
- [10] 王爽心, 韩芳, 朱衡君. 基于改进变尺度混沌优化方法的经济负荷分配[J]. 中国电机工程学报, 2005, 25(24): 90-96.
(Wang S X, Han F, Zhu H J. Economic load dispatch based on improved mutative scale chaotic optimization[J]. Proc of the CSEE, 2005, 25(24): 90-96.)
- [11] Rainer S, Price K. Differential evolution — A simple and efficient heuristic for global optimization over continuous spaces[J]. J of Global Optimization, 1997, 11(4): 341-359.
- [12] 王凌, 黄付卓, 李灵坡. 基于混合双种群差分进化的电力系统经济负荷分配[J]. 控制与决策, 2009, 24(8): 1156-1160.
(Wang L, Huang F Z, Li L P. Economic distribution of power systems based on hybrid differential evolution with double populations[J]. Control and Decision, 2009, 24(8): 1156-1160.)
- [13] Balamurugan R, Subramanian S. Self-adaptive differential evolution based power economic dispatch of generators with valve-point effects and multiple fuel options[J]. Int J of Computer Science and Engineering, 2007, 1(1): 10-17.
- [14] Wu L H, Wang Y N, Zhou S W. Self-adapting control parameters modified differential evolution for trajectory planning manipulator[J]. J of Control Theory and Applications, 2007, 5(4): 365-374.
- [15] Wu L H, Wang Y N, Yuan X F, et al. Multiobjective optimization of HEV fuel economy and emissions using the self-adaptive differential evolution algorithm[J]. IEEE Trans on Vehicular Technology, 2011, 60(6): 2458-2470.