

一种新的混沌差分进化算法

谭跃^{1,2}, 谭冠政¹, 涂立²

(1. 中南大学信息科学与工程学院, 长沙 410083; 2. 湖南城市学院物理与电信工程系, 益阳 413000)

摘要: 提出一种新的混沌差分进化(CDE)算法, 在每一代中通过差分进化(DE)算法找到最佳个体, 在最佳个体附近用混沌方法进行局部搜索, 通过引入调节因子加强其搜索能力。6个基本测试函数的优化结果表明, 当误差函数精度为 10^{-14} 时, 与 DE 相比, CDE 的寻优能力更强、收敛速度较快。

关键词: 差分进化; 混沌; 局部搜索

Novel Chaos Differential Evolution Algorithm

TAN Yue^{1,2}, TAN Guan-zheng¹, TU Li²

(1. School of Information Science and Engineering, Central South University, Changsha 410083;

2. Department of Physics and Telecom Engineering, Hunan City University, Yiyang 413000)

【Abstract】 This paper proposes a new Chaos Differential Evolution(CDE) algorithm. It uses Differential Evolution(DE) algorithm to find the best individual each generation, then chaos based local search is executed nearby the best individual. A scaling factor is introduced to enhance the searching ability of CDE. Experimental results on six benchmark functions show the error function value is 10^{-14} , both the ability of finding optimal solution and convergence speed using CDE are better than using DE.

【Key words】 Differential Evolution(DE); chaos; local search

差分进化(Differential Evolution, DE)算法已被多次改进, 其中, 混沌方法是一种重要的改进方法。文献[1]将混沌差分进化用于障碍物环境中的移动机器人路径规划, 它利用混沌方法改变 DE 的控制参数。文献[2]提出一种改进的差分进化算法, 利用混沌方法产生初始群体与子群体。本文提出的算法与以往的混沌差分进化算法不同, 它将进化算法和局部搜索相结合。

1 经典差分进化算法

DE 算法是一种连续空间全局优化启发式算法。它与标准遗传算法相同的是包含选择、交叉和变异 3 个操作, 与标准遗传算法不同的是它采用由变异到交叉, 再到选择的操作顺序。

变异操作是从种群中随机选择一个个体作为基向量, 以 2 个不同的个体作为差分向量, 变异向量如下:

$$v_i^{G+1} = x_{r_1}^G + F(x_{r_2}^G - x_{r_3}^G) \quad (1)$$

其中, $r_1, r_2, r_3 \in \{1, 2, \dots, N_p\}$, 且 $r_1 \neq r_2 \neq r_3$; N_p 为种群的规模; F 为缩放因子; G 为当前种群的代数, $G+1$ 表示下一代。

交叉操作在变异产生的第 i 个个体 v_i^{G+1} 和种群中的第 i 个个体 x_i^G 之间进行, 交叉操作的试验向量如下:

$$u_{i,j}^{G+1} = \begin{cases} v_{i,j}^{G+1} & \text{if } (\text{randb}(j) \leq CR) \text{ or } j = \text{rnbr}(j) \\ x_{i,j}^G & \text{if } (\text{randb}(j) > CR) \text{ or } j \neq \text{rnbr}(j) \end{cases} \quad (2)$$

其中, $j \in \{1, 2, \dots, D\}$, D 为问题的维数; CR 为交叉因子; $\text{randb}(j)$ 为第 j 次评价时的一个均匀分布的随机数, 其范围是 $(0, 1)$; $\text{rnbr}(j)$ 为 $\{1, 2, \dots, D\}$ 中随机选择的一个整数。

DE 的选择是一对一的, 选择操作是在试验向量 u_i^{G+1} 与原种群的个体 x_i^G 之间进行。选择原则是适应度较优的个体进入下一代, 即

$$x_i^{G+1} = \begin{cases} u_i^{G+1} & \text{if } f(u_i^{G+1}) \leq f(x_i^G) \\ x_i^G & \text{else} \end{cases} \quad (3)$$

其中, x_i^{G+1} 为下一代的第 i 个个体; f 为适应度函数。

2 混沌差分进化算法

2.1 混沌系统

遍历性是混沌系统的特征之一, 即系统由某个初始状态开始按其自身的运动规律, 在足够长的时间内, 遍历相空间中所有状态。利用此特性在最优解附近进行 k 次遍历, 即进行 k 次无重复的局部搜索。此搜索方式的最大优点是搜索步长按规律自动无重复地变化, 这样能有效搜索到当前最优解附近的更优解, 上述混沌和 DE 相结合的方法能增强 DE 的寻优能力。

混沌系统有多种形式, 文献[2]中有如下一种形式:

$$y_{k+1} = \mu y_k (1 - y_k) \quad (4)$$

其中, k 为迭代次数, $k=1, 2, \dots, K$, K 为最大的迭代次数; μ 为控制参数, 当 $\mu=4$ 时, $y_1 \in (0, 1)$, 且 $y_1 \neq \{0.25, 0.5, 0.75\}$ 时, 式(4)是一个混沌系统。

2.2 混沌差分进化算法的描述

混沌差分进化(Chaos Differential Evolution, CDE)算法中混沌搜索的基本原理是在每一代中用 DE 搜索到最佳个体 X_{best} , 在 X_{best} 的附近再进行 k 次混沌搜索, 得到 k 个个体, 在 k 个个体中找出适应度值最佳的个体 $X_{k\text{best}}$, 若 $X_{k\text{best}}$ 适应

基金项目: 国家自然科学基金资助项目(50275150)

作者简介: 谭跃(1974—), 男, 博士研究生, 主研方向: 进化计算, 机器人; 谭冠政, 教授、博士生导师; 涂立, 讲师

收稿日期: 2008-12-19 **E-mail:** tanyue7409@163.com

度值比 X_{best} 好, 则用 X_{kbest} 的适应度值取代 X_{best} 的适应度值, 并将 X_{kbest} 随机取代种群中的某个个体后返回; 若 X_{best} 适应度值比 X_{kbest} 好, 则直接返回。在 X_{best} 附近进行混沌搜索, 即

$$X_k = X_{best} + \alpha y_k \quad (5)$$

其中, y_k 是式(4)的解; α 为调节因子。由式(4)可知, 当初值 y_1 为(0, 1)时, 式(4)的解全为正解。引入调节因子 α 可使 X_k 朝正、反 2 个方向变化, α 的取值如下:

$$\alpha = \begin{cases} 1 & \text{if } r \geq 0.5 \\ -1 & \text{else} \end{cases} \quad (6)$$

其中, r 为(0, 1)中一个均匀分布的随机数。

CDE 算法的流程如下:

(1)初始化种群规模 N_p 、缩放因子 F 、交叉因子 CR 、种群最大进化代数 G_{max} 、输入变量的上界 $H_{i,j}$ 和下界 $L_{i,j}$, $i \in \{1, 2, \dots, N_p\}$, $j \in \{1, 2, \dots, D\}$ 、混沌控制参数 $\mu=4$ 、混沌搜索次数 k 。

(2)根据式(7)产生初始种群 P^0

$$P_{i,j}^0 = L_{i,j} + rand(1)(H_{i,j} - L_{i,j}) \quad (7)$$

其中, $i \in \{1, 2, \dots, N_p\}$; $j \in \{1, 2, \dots, D\}$; $rand(1)$ 为(0, 1)中一个均匀分布的随机数。

(3)对初始种群进行评价。找出适应度值最佳的个体 X_{best} , 记录 X_{best} 的适应度值 F_{best} 及其在种群中的索引 $index(X_{best})$, 置进化代数 $G=1$ 。

(4)由式(1)得变异向量 v_i^{G+1} 。

(5)由式(2)得试验向量 u_i^{G+1} 。

(6)由式(3)得下一代个体 x_i^{G+1} 。

(7)比较 $f(u_i^{G+1})$ 和 F_{best} , 若 $f(u_i^{G+1})$ 比 F_{best} 好, 则 $X_{best} = u_i^{G+1}$, $F_{best} = f(u_i^{G+1})$, $index(X_{best})=i$, 进入(8); 否则继续。

(8)重复执行(4)~(7) N_p 次。

(9) $y_1 = rand$, $rand$ 为(0, 1)中一个均匀分布的随机数, 且 $y_1 \neq \{0.25, 0.5, 0.75\}$ 。

(10)由式(4)~式(6)计算得 X_k 。

(11)重复执行(10) k 次。

(12)找出 X_k 中适应度值最好的个体 X_{kbest} , 若 $f(X_{kbest})$ 比 F_{best} 好, 则 $X_{best} = X_{kbest}$, $F_{best} = f(X_{kbest})$, 并产生一个随机整数 $j \in [1, N_p]$, $index(X_{best})=j$, $x_j^{G+1} = X_{kbest}$, 进入(13); 否则继续。

(13) $G=G+1$, 若 $G < G_{max}$, 则进入(4); 否则继续。

(14)输出 X_{best} 和 F_{best} 。

3 仿真实验

从文献[3]中选择 6 个基本的测试函数作为测试对象, 它们包括单峰独立、单峰非独立、多峰独立和多峰非独立, 具体描述如下:

$$(1) f_1(x) = \sum_{i=1}^{30} x_i^2, |x_i| \leq 100, \min(f_1) = f_1(0, 0, \dots, 0) = 0$$

$$(2) f_2(x) = \sum_{i=1}^{30} (\sum_{j=1}^i x_j)^2, |x_i| \leq 100, \min(f_2) = f_2(0, 0, \dots, 0) = 0$$

$$(3) f_3(x) = \sum_{i=1}^{29} [100(x_{i+1} - x_i)^2 + (x_i - 1)^2],$$

$$|x_i| \leq 30, \min(f_4) = f_4(1, 1, \dots, 1) = 0$$

$$(4) f_4(x) = \sum_{i=1}^{30} [x_i^2 - 10 \cos(2\pi x_i) + 10],$$

$$|x_i| \leq 5.12, \min(f_6) = f_6(0, 0, \dots, 0) = 0$$

$$(5) f_5(x) = -20 \exp(-0.2 \sqrt{1/30 \sum_{i=1}^{30} x_i^2}) - \exp(1/30 \sum_{i=1}^{30} \cos(2\pi x_i)) + 20 + e,$$

$$|x_i| \leq 32, \min(f_7) = f_7(0, 0, \dots, 0) = 0$$

$$(6) f_6(x) = 1/4 \cdot 000 \sum_{i=1}^{30} x_i^2 - \prod_{i=1}^{30} \cos(x_i / \sqrt{i}) + 1,$$

$$|x_i| \leq 600, \min(f_8) = f_8(0, 0, \dots, 0) = 0$$

为使 DE 达到更好的优化, 选择 3 组有代表性的参数作为缩放因子和交叉因子, 每个测试函数的进化代数根据实验结果动态调整, 最大进化代数不超过 1 500 代, 记录 DE 在不同参数下的最优值。选择最优的一组 F 和 CR 值作为 DE 和 CDE 的最终实验参数, 最大进化代数作为 DE 和 CDE 的停止条件, 以多次实验的最大值、最小值、平均值、收敛速度作为评价标准比较 CDE 和 DE 的优化效果。所有实验均采用 $DE/rand/1/bin$ 的形式。

从现有的文献中, 选择 3 组数据 $F_1=0.2, CR_1=0.1; F_2=0.5, CR_2=0.5; F_3=0.5, CR_3=0.9$ 作为缩放因子和交叉因子, 种群规模为 60。在实验过程中, 进化代数动态调整, 得到 f_1 的最大进化代数为 1 000 代, 其他函数为 1 500 代。每个测试函数在 DE 作用下单独优化 5 次, 得到最优值的平均结果如表 1 所示。

表 1 DE 对 6 个测试函数优化 5 次的最优解平均值

| 函数 | $F_1=0.2$ $CR_1=0.1$ | $F_2=0.5$ $CR_2=0.5$ | $F_3=0.5$ $CR_3=0.9$ |
|-------|-------------------------|-------------------------|-------------------------|
| f_1 | 6.987 9e-19 | 3.953 3e-11 | 9.239 4e-14 |
| f_2 | 5.714 0e+3 | 1.392 0e+4 | 0.113 0 |
| f_3 | 42.085 6 | 23.359 9 | 22.463 0 |
| f_4 | 0.204 7 | 129.928 7 | 152.220 6 |
| f_5 | 4.085 6e-15 | 2.863 6e-10 | 2.660 1e-12 |
| f_6 | 0.360 9 | 0.951 0 | 0.993 3 |

由表 1 可知, f_1, f_4, f_5, f_6 的 $F=0.2, CR=0.1$; f_2, f_3 的 $F=0.5, CR=0.9$, 每一代混沌搜索 30 次。根据上述参数, 用 DE 和 CDE 分别对每个测试函数优化 25 次, 得到结果如表 2 所示, 其中, 粗体为最好结果, 由此可见, 一般情况下 CDE 比 DE 好。

表 2 DE 和 CDE 对 6 个测试函数优化 25 次的结果

| 函数 | 算法 | 最小值 | 最大值 | 平均值 |
|-------|-----|--------------------|--------------------|--------------------|
| f_1 | DE | 1.555 3e-19 | 7.437 0e-19 | 4.007 1e-19 |
| | CDE | 2.529 6e-28 | 3.063 2e-26 | 8.202 1e-27 |
| f_2 | DE | 0.035 5 | 0.290 6 | 0.136 3 |
| | CDE | 1.414 7e-21 | 2.881 9e-18 | 3.200 5e-19 |
| f_3 | DE | 19.354 6 | 24.619 8 | 22.243 1 |
| | CDE | 20.309 6 | 23.596 9 | 21.903 4 |
| f_4 | DE | 0 | 0.995 0 | 0.199 0 |
| | CDE | 0 | 0 | 0 |
| f_5 | DE | 2.664 5e-15 | 6.217 2e-15 | 4.440 9e-15 |
| | CDE | 2.664 5e-15 | 2.664 5e-15 | 2.664 5e-15 |
| f_6 | DE | 0.316 3 | 0.407 3 | 0.366 6 |
| | CDE | 0 | 0 | 0 |

为比较 CDE 和 DE 的收敛速度, 对 25 次测试结果进行排序, 选择第 13 次的测试结果作为收敛结果^[3], 其收敛曲线如图 1~图 6 所示。




图 1 f_1 收敛曲线




图 2 f_2 收敛曲线




图 3 f_3 收敛曲线




图 4 f_4 收敛曲线

其中, 纵坐标为误差函数 $f(x) - f(x^*)$ 的对数值; $f(x^*)$ 为全局最优值; $f(x)$ 为算法找到的最优值; 虚线和实线分别表示 DE 和 CDE 的优化曲线。在图中一些曲线在达到最大代数前

(下转第 220 页)