

自适应混合变异文化算法

郭一楠, 刘丹丹, 程 健, 王 辉

(中国矿业大学信息与电气工程学院, 江苏徐州 221116)

摘 要: 只采用单一变异算子的进化规划算法在解决优化问题时,不能兼顾全局探索和局部搜索能力.本文提出柯西+混沌变异和柯西+高斯变异两类混合变异策略,采用文化算法的双层进化机制,提取进化过程中的隐含知识,并根据知识自适应调整两种变异算子的作用时机和作用比例,给出了自适应混合变异文化算法.针对标准测试函数的仿真结果表明,该算法具有更稳定的全局收敛性能及较快的收敛速度.

关键词: 自适应; 柯西变异; 高斯变异; 混沌变异; 文化算法

中图分类号: TP301 **文献标识码:** A **文章编号:** 0372-2112 (2011) 08-1913-06

Adaptive Cultural Algorithm Adopting Mixed Mutation

GUO Yi-nan, LIU Dan-dan, CHENG Jian, WANG Hui

(School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China)

Abstract: Evolutionary programming adopting single mutation operator can not give attention to exploration and exploitation both. So two kinds of mixed mutation strategy including Cauchy + chaotic mutation operator and Cauchy + Gaussian mutation operator are given. A novel adaptive cultural algorithm adopting above mixed mutation strategy is proposed by adopting dual structure in cultural algorithm. Implicit knowledge extracted from the evolution process is used to control occasion and proportion of each mutation operator in mixed mutation strategy. Simulation results indicate that the algorithm can effectively improve the speed of convergence and have better convergence.

Key words: adaptive; Cauchy mutation; Gaussian mutation; chaotic mutation; cultural algorithms

1 引言

进化规划(Evolutionary Programming, 简称 EP)中,变异算子是其主进化操作^[1,2].随着研究深入,多种变异算子被先后采用,如高斯变异^[3]、柯西变异^[4]、Levy 变异^[5]以及 q-Gaussian 变异^[6,7]等.

上述变异算子中,高斯变异的局部搜索能力较好,但是引导个体跳出局部较优解的能力较弱,不利于全局收敛.柯西变异相比于高斯变异会产生较大的变异步长,因此会使算法具有较好的全局搜索能力. Levy 变异通过改变 Levy 分布的参数来调整变异算子的随机数分布, q-Gaussian 变异则是把 q-Gaussian 分布的参数 q 作为决策变量参与到种群进化过程中. 骆晨钟等^[8]通过实验表明混沌变异算子具有与高斯变异等随机变异算子相似的搜索能力.文献[9]则进一步将混沌变异算子引入文化算法,利用进化过程隐含知识控制混沌序列分布,从而使混沌变异算子在不同进化阶段呈现出不同的局部搜索能力.

综上所述,单一的变异算子在解决优化问题时,不

能兼顾全局探索和局部搜索能力,因此本文提出柯西+混沌变异和柯西+高斯变异两类混合变异策略,旨在提高算法的收敛速度和进化性能.由于各种变异算子在进化过程中所起作用不同,因此有效控制和协调两种变异算子的作用时机和作用比例就成为算法的核心问题.

文化算法采用由种群空间和信度空间构成的双层进化结构,对进化信息进行有效提取和管理,并将其用于指导种群空间的进化过程.为此,本文提出一种自适应混合变异文化算法(adaptive cultural algorithm adopting mixed mutation, 简称 CAAMM).算法利用从进化过程中提取的隐含知识,根据进化阶段不同来灵活调整各类算子的作用程度,从而实现两种变异算子的有机结合.

2 自适应混合变异文化算法描述

CAAMM 中的上层信度空间实现进化过程中隐含知识的提取和存储,下层种群空间中的 EP 算法采用基于知识引导的混合变异策略.算法的具体步骤如下.

Step 1 初始化种群.设种群规模为 m , 变量个数为 n , 随机产生初始种群 $X(0) = [x]^{m \times n}$.

Step 2 初始化信度空间. 信度空间的初始知识记录搜索空间中各变量的取值范围.

Step 3 变异操作. 由父代种群 $X(t)$ 依据信度空间的知识, 通过混合变异操作生成子代种群 $X^M(t)$.

Step 4 评价操作. 合并 $X(t)$ 和 $X^M(t)$, 对生成的合并种群 $\bar{X}(t)$ 计算个体的适应度.

Step 5 选择操作. 在合并种群 $\bar{X}(t)$ 中, 采用 q-选择选出优势个体, 组成下一代种群 $X(t+1)$.

Step 6 知识更新. 每代按照一定接受比例, 从种群 $X(t+1)$ 中选取优势个体作为样本; 并依据样本集提取优势信息, 更新信度空间的知识.

Step 7 判断是否满足终止条件, 若满足则停止, 否则 $t = t + 1$, 转 Step3. 本文采用最优个体适应度与种群个体平均适应度的差值作为终止判断条件, 当该差值小于某阈值时算法终止.

可见, CAAMM 算法的核心在于: 信度空间知识的提取及更新方法、基于知识的混合变异策略.

3 信度空间的知识描述与更新

文化算法信度空间通常包含状况知识、标准知识、拓扑知识、领域知识和历史知识等五类知识^[10]. 各类知识记录的进化信息不同, 对进化过程会产生不同的引导作用. CAAMM 算法旨在平衡进化过程中的全局探索和局部搜索能力, 因此, 本文中信度空间采用标准知识和拓扑知识.

3.1 标准知识

标准知识 K_1 记录待优化问题的可行搜索范围 S_{K_1} , 引导算法在搜索空间进行全局探索, 记为

$$K_1 = \langle L(t), U(t) \rangle \quad (1)$$

其中, $L(t) = \{l_1(t), l_2(t), \dots, l_n(t)\}$, $U(t) = \{u_1(t), u_2(t), \dots, u_n(t)\}$. l_i, u_i 分别是第 i 维变量的下限和上限.

显然, 在标准知识的引导下, 算法在整个搜索空间作全局探索, 从而避免算法陷入局部较优解.

3.2 拓扑知识

拓扑知识 K_2 记录进化过程中优势个体的适应度分布状况, 对优势个体所在区域进行局部搜索. 它采用栅格结构, 记录进化过程中各代优势个体在搜索空间的分布情况, 提取优良进化区域, 并依此对搜索空间进行动态划分.

以 2 维变量优化问题为例, 若拓扑知识记录的可行搜索空间中 $L(t) = \{-10, -10\}$, $U(t) = \{10, 10\}$. 假设每次的栅格细分程度为 2, 则 K_1 记录的初始搜索空间被划分为 4 个大小相同的子区域, 如图 1 所示.

各子区域的状态通过区域属性值来加以描述. 区

域属性是根据该子区域内的最优样本个体适应度与样本集个体平均适应度的高低来获得. 记 $f(x_{S_{K_2}^i}^{\text{Best}}(t))$ 为区域 $S_{K_2}^i$ 中最优样本个体适应度, $\bar{f}_S(t)$ 为当前样本库个体的平均适应度, 则区域属性描述为:

$$\omega_{S_{K_2}^i}(t+1) = \begin{cases} H, & \text{if } f(x_{S_{K_2}^i}^{\text{Best}}(t)) \geq \bar{f}_S(t) \\ L, & \text{if } f(x_{S_{K_2}^i}^{\text{Best}}(t)) < \bar{f}_S(t) \\ \#, & \text{if } \forall x(t) \notin S_{K_2}^i \end{cases} \quad (2)$$

拓扑知识的更新包含两种情况:

(1) 子区域细化. 当最优样本个体优于其所在区域的最优样本个体时, 对该区域进一步细化:

$$x_{S_{K_2}^i}^j(t) = \arg \max_{j=1,2,\dots,m_{S_{K_2}^i}} f(x_{S_{K_2}^i}^j(t)) \quad (3)$$

$$\text{if } f(x_{S_{K_2}^i}^j(t)) > f(x_{S_{K_2}^i}^{\text{Best}}(t-1))$$

式中, $m_{S_{K_2}^i}$ 是位于区域 $S_{K_2}^i$ 的样本个体数. 划分过程如图 1 中的区域 $S_{K_2}^1$ 所示. 进一步根据当前样本库中的样本个体更新区域属性.

(2) 区域属性更新. 若没有优于区域当前最优样本个体适应度的个体出现, 则不对区域进行细化, 只根据当前样本库中的样本个体更新区域属性.

显然, 拓扑知识反映了进化过程中个体目标值的分布情况. 利用它可以引导算法对优势区域进行细致地搜索, 并引导个体从属性为 L 的区域跳出.




图1 拓扑知识 (2维搜索空间)

3.3 接口函数

接口函数为信度空间和种群空间提供作用通道, 由接受函数和影响函数组成.

接受函数从种群中选取优势个体, 送入信度空间的样本集. 本文选用固定比例接受函数, 即按接受比例 k_a 依适应度降序从种群中选取样本个体. 记每代选取的样本个体数目为 m_a , 则有: $m_a = k_a m$.

影响函数的核心在于确定各类知识对种群的影响比例和作用形式. 本文中知识作用于自适应混合变异算子, 以控制受各类变异算子作用的种群比例. 因此, 各类知识对种群的影响比例就是两类变异算子在种群中的作用比例, 依据知识影响成功率动态确定. 假设 m_{K_i} 为受知识 K_i 影响所生成的个体数目:

$$P_{K_i}(t) = \begin{cases} 1/N_K, & t = 0 \\ \alpha + \beta \frac{m_{K_i}(t-1)}{m}, & t \neq 0 \end{cases} \quad (4)$$

且满足 $N_K\alpha + \beta = 1$

其中, N_K 为知识类型, 这里 $N_K = 2$; α 选取 0.3 以保证每类知识的影响比例至少占种群的 30%.

4 知识引导的混合变异策略

4.1 柯西变异、高斯变异及混沌变异

在传统 EP 算法中, 父代个体 $x_i(t)$ 在变异算子的作用下生成新个体 $x_i^M(t)$. 该变异操作记为

$$\sigma_{ij}^M(t) = \sigma_{ij}(t) \exp(\tau_1 \cdot \eta_i(t) + \tau_2 \eta_{ij}(t)) \quad (5)$$

$$x_{ij}^M(t) = x_{ij}(t) + \sigma_{ij}^M(t) \cdot \delta_j(t), i = 1, \dots, m, j = 1, \dots, n \quad (6)$$

其中, $\eta_i(t) \sim N(0, 1)$ 为对应于个体 $x_i(t)$ 的随机数, $\eta_{ij}(t) \sim N(0, 1)$ 是对应于个体 $x_i(t)$ 第 j 维的随机数, 二者满足正态分布. $\tau_1 = (\sqrt{2 \cdot n})^{-1}$ 和 $\tau_2 = (\sqrt{2 \cdot \sqrt{n}})^{-1}$ 为两个常数; 一般取 $\sigma_{ij}(0) = 3\sqrt{n}^{[5]}$.

在上述变异操作中, 当 $\delta_j(t)$ 选取满足不同分布的随机数时, 其变异算子也不尽相同.

(1) 当 $\delta_j(t)$ 为服从柯西分布的随机数时, 式(6)为柯西变异算子. 记一维柯西分布概率密度函数为

$$f_a(x) = \frac{1}{\pi} \frac{\alpha}{\alpha^2 + x^2}, \quad -\infty < x < \infty \quad (7)$$

当 $\alpha = 1$ 时, 柯西分布如图 2 中实线所示, 显然相比于满足 $N(0, 1)$ 的高斯分布, 柯西分布的两翼较宽, 因此采用服从柯西分布随机数的柯西变异算子可以产生较大的变异步长, 有利于算法引导个体跳出局部最优解, 保证了算法的全局探索能力.




图2 柯西分布和高斯分布概率密度函数

(2) 当 $\delta_j(t)$ 是混沌序列产生的数列时, 式(6)拓展为混沌变异算子. 一般混沌序列采用一维 Logistic 映射. 然而针对高维变量优化问题, 将一维 Logistic 映射数列简单叠加所得到的混沌序列存在盲区, 不能满足要求, 如图 3 所示.

因此, 这里采用高维混沌序列, 记为

$$a_{ij}^h(t) = A \sin \left\{ \left[(A + B) \left(\alpha + \frac{j}{n} (\beta - \alpha) \right) + \frac{j}{n} \right] \pi \right\} \quad (8)$$

$$A = \sum_{l=1}^{Lm} y_{q+1}^l, B = \sum_{l=1}^{Lm} y_q^l$$

式中, y_q^l 是一维 Logistic 映射, Lm 是混沌序列规模, $\alpha =$

2.3, $\beta = 3.99$. 取该高维混沌序列的任意 2 维, 其空间分布如图 4 所示. 可见, 该高维混沌序列空间遍历性较好. 显然, 由于混沌序列的遍历性, 采用混沌变异算子的 EP 算法具有较强的局部探索能力.




图3 一维Logistic映射空间分布 图4 高维混沌序列空间分布

算法在优化过程中, 初期需要具有较好的全局探索能力和多样性, 而在中后期则需要加强局部搜索, 同时避免算法陷入局部较优解. 显然, 不同进化阶段对算法搜索能力的要求也不同, 单一的变异算子很难满足这一要求. 因此, 本文将上述柯西变异和混沌变异算子有机结合, 利用文化算法中信念空间提取的进化过程中隐含信息, 确定柯西变异算子和混沌变异算子作用于种群的比例和时机.

4.2 两类变异算子的知识引导方式

采用柯西变异算子可以保证算法的全局探索能力, 有利于算法跳出局部较优解. 标准知识引导算法做全局探索, 为有效利用知识的引导作用, 由标准知识引导柯西变异算子, 从而指导种群进化.

采用混沌变异算子或者采用高斯变异的算法具有较强的局部搜索能力. 拓扑知识是引导种群对优势区域作局部搜索. 因此, 将拓扑知识用于引导混沌变异算子或者高斯变异算子, 从而增强算法的局部搜索能力. 两类知识的具体引导方式如下.

(1) 标准知识引导的柯西变异算子

标准知识引导种群在可行区域进行全局探索. 在柯西变异算子的作用下, 父代个体 $x_i(t)$ 生成子代个体 $x_i^M(t)$, 记为

$$x_{ij}^M(t) = \begin{cases} l_j(t) + (u_j(t) - l_j(t)) Rnum, & \text{if } x_{ij}(t) \notin S_{K_i} \\ x_{ij}(t) + \sigma_{ij}^M(t) C_{ij}, & \text{if } x_{ij}(t) \in S_{K_i} \end{cases} \quad (9)$$

式中, $Rnum \sim U(0, 1)$ 为服从均匀分布的随机数, $C_{ij} \sim C(0, 1)$ 为柯西随机数.

(2) 拓扑知识引导的混沌变异算子

拓扑知识引导种群对优势区域进行深入搜索, 若父代个体属于拓扑知识记录的区域 $S_{K_i}^i(t)$, 则 $x_i(t)$ 在知识的影响下生成 $x_i^M(t)$, 记为

$$x_{ij}^M(t) = \begin{cases} x_{ij}(t) + \sigma_{ij}^M(t) a_{ij}^h(t), & \text{if } (x_{ij}(t) \in S_{K_2}^i) \wedge (\omega_{S_{K_2}^i} = H \text{ or } \#) \\ x_j^H(t) + \sigma_j^H(t) a_{ij}^h(t), & \text{if } (x_{ij}(t) \in S_{K_2}^i) \wedge (\omega_{S_{K_2}^i} = L) \end{cases} \quad (10)$$

式中, $x_j^H(t) \in S_{K_2}^C(t)$, $\omega_{S_{K_2}^C(t)} = H$, $x_j^H(t)$ 是区域 $S_{K_2}^C(t)$ 的最优样本个体. $S_{K_2}^C(t)$ 从区域属性为 H 的优势区域中随机选出. $a_{ij}^h(t)$ 是混沌序列数.

(3) 拓扑知识引导的高斯变异算子

若父代个体属于拓扑知识记录的区域 $S_{K_2}^i(t)$, 则 $x_i(t)$ 在知识的影响下生成 $x_i^M(t)$, 记为

$$x_{ij}^M(t) = \begin{cases} x_{ij}(t) + \sigma_{ij}^M(t) N_{ij}(t), & \text{if } (x_{ij}(t) \in S_{K_2}^i) \wedge (\omega_{S_{K_2}^i} = H \text{ or } \#) \\ x_j^H(t) + \sigma_j^H(t) N_{ij}(t), & \text{if } (x_{ij}(t) \in S_{K_2}^i) \wedge (\omega_{S_{K_2}^i} = L) \end{cases} \quad (11)$$

式中, $N_{ij}(t) \sim N(0, 1)$ 为服从正态分布的随机数.

基于此, 本文给出两种基于知识引导的混合变异策略: 一种采用柯西 + 混沌变异的混合变异策略, 记为 CAAMM I; 一种采用柯西 + 高斯变异的混合变异策略, 记为 CAAMM II.

4.3 两类变异操作的作用比例及作用时机

标准知识通过柯西变异算子影响种群进化过程, 而混沌变异算子或高斯变异算子是在拓扑知识记录的优势搜索区域内实现新个体生成. 因此, 柯西变异算子的作用比例与标准知识的影响比例相同; 而混沌变异算子或高斯变异算子的作用比例与拓扑知识的影响比例相同.

设第 t 代柯西变异算子的作用比例为 $P_C(t)$, 混沌变异算子的作用比例为 $P_T(t)$, 则有:

$$P_C(t) = P_{K_1}(t), P_T(t) = P_{K_2}(t) \quad (12)$$

两类变异操作何时作用于种群, 根据两类变异操作的作用比例, 通过轮盘赌选择来确定. 对于种群中的某个个体, 选取变异操作的具体步骤如下:

Step 1 依据变异算子的作用概率, 通过轮盘赌选择选出个体采用的变异操作.

Step 2 采用选取的变异算子对个体实施变异操作, 生成新个体.

5 仿真结果与分析

为深入分析 CAAMM 的算法性能, 针对高维函数优化问题, 对算法 CAAMM I 中两类变异算子的影响比例演化情况, 以及关键参数对算法性能的影响进行了对比分析; 并将 CAAMM I 和 CAAMM II 与文化算法^[10] (Cultural Algorithm, 简称 CA) 以及采用柯西变异的进化规划^[4] (Faster Evolutionary Programming, 简称 FEP) 进行

比较.

采用的标准测试函数及其最优解分布如表 1 所示. 仿真分析中算法主要参数取值如表 2 所示.

表 1 测试函数

测试函数	变量维数	变量范围	最优解 x^*	最优值 $f(x^*)$
$\min f_1(x) = \sum_{i=1}^{n-1} (100 \times (x_{i+1} - x_i^2)^2 + (1 - x_i)^2)$	10	$x_i \in [-30, 30]$	$(1, 1, \cdots, 1)$	0
$\min f_2(x) = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10)$	10	$x_i \in [-5.12, 5.12]$	$(0, 0, \cdots, 0)$	0
$\min f_3(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}})^2 + 1$	10	$x_i \in [-600, 600]$	$(0, 0, \cdots, 0)$	0
$\min f_4 = \sum_{i=1}^n x_i^2$	30	$x_i \in [-100, 100]$	$(0, 0, \cdots, 0)$	0

表 2 主要参数取值

种群规模 m	进化终止代数 T	样本库规模 m_s	接受比例 k_a	运行次数	收敛阈值
50	1000	20	0.2	30	$10^{-2} \sim 10^{-5}$

5.1 知识影响下两种变异算子的影响比例

在信度空间知识的引导下, 两种变异算子共同作用于种群, 并在进化过程的不同阶段呈现出对种群不同的影响程度. 不失一般性, 以测试函数 f_3 的寻优过程为例, 记录两类变异算子作用比例曲线, 如图 5(a) 所示. 图 5(b) 放大了前 50 代两类变异算子的作用比例曲线.




图5 两类变异算子影响比例曲线

为对比分析受两类变异算子影响下的个体迁移情况, 分别选取第 1、10、20、34、82、114 及 172 代两类变异算子作用下产生的最优个体, 个体第 6 维和第 8 维的进化情况如图 6 和 7 所示.

可见, 进化初期的种群中多数个体采用柯西变异, 算法的全局探索能力较强; 随着进化深入, 混沌变异的作用比例逐渐增加, 算法的局部搜索能力得到加强以加快算法收敛. 从图 5 可知, 柯西变异的作用比例有时会有些增加, 以帮助算法从局部收敛点跳出, 从而保证算法全局寻优能力.




图6 柯西变异产生最优个体进化情况




图7 混沌变异产生最优个体进化情况

5.2 α 对算法性能的影响

两类变异算子对种群的作用比例根据知识的影响比例确定.知识的影响比例取决于知识影响成功率和 α .不同 α 值,导致知识作用于种群的基础比例变化,影响了变异算子作用于种群的基础比例,从而对算法性能产生影响.

选取 4 个不同 α 值所得实验结果如表 3 所示.表中, $M1$ 表示平均最优目标值, $M2$ 表示最优值均方差, $M3$ 表示获得最优解的平均进化代数.

表 3 不同 α 取值算法性能比较

函数	f_1	f_2	f_3	f_4	
$\alpha = 0$	$M1$	14.64	11.54	0.33	1.17×10^2
	$M2$	24.56	7.67	0.46	1.44×10^2
	$M3$	806	96	193	463
$\alpha = 0.1$	$M1$	6.98	13	0.33	1.69×10^2
	$M2$	3.61	8.15	0.24	2.74×10^2
	$M3$	380	110	221	507
$\alpha = 0.3$	$M1$	11.12	6.14	0.19	8.55
	$M2$	19.51	2.4	7.95×10^{-2}	16.22
	$M3$	824	181	214	801
$\alpha = 0.5$	$M1$	8.18	7.79	0.27	2.38×10^2
	$M2$	9.77	4.55	0.25	3.2×10^2
	$M3$	823	214	326	673

可见, $\alpha = 0.3$ 时算法的求解精度最好.分析表明: α 取值较小时, 由于混沌变异算子的局部搜索能力较强, 在进化初期混沌变异算子产生的个体很快占据种群, 使混沌变异算子的作用比例快速增加, 柯西变异算子的作用比例减

小, 无法起到增强算法全局探索能力的作用, 因此算法收敛速度较快, 但是求解精度不高, 容易陷入局部较优解. 若 $\alpha = 0.5$, 则两类变异算子的作用比例固定, 不能根据进化情况调整其作用程度, 因此算法的收敛速度较慢, 并且求解精度一般. 综上所述, 本文选取 $\alpha = 0.3$.

5.3 与其它算法性能对比分析

为深入分析混合变异策略在进化过程的作用, 分别采用 CAAMM I、CAAMM II、CA 和 FEP 进行仿真实验, 统计其运行结果如表 4 所示.

表 4 不同算法性能比较

函数		f_1	f_2	f_3	f_4
CA	$M1$	54.78	17.67	0.74	1.23×10^3
	$M2$	82.65	8.84	0.83	1.73×10^2
	$M3$	618	290	251	889
FEP	$M1$	24.96	1.18	0.42	0.45
	$M2$	71.43	0.93	0.41	1.4
	$M3$	1000	1000	225	965
CAAMM I	$M1$	11.12	6.14	0.19	8.55
	$M2$	19.51	2.4	7.95×10^{-2}	16.22
	$M3$	824	181	214	801
CAAMM II	$M1$	79.96	11.99	0.24	0.1
	$M2$	2.22×10^2	5.89	0.2	0.32
	$M3$	583	388	225	268

抽取任意一次运行过程, 其平均目标值曲线如图 8 所示. 图 8(a) 中 CAAMM I 算法的收敛速度较快, 且得到的解精度较高. 图 8(b) 中 CAAMM I 算法与 FEP 算法




图8 标准测试函数平均目标值

具有相近的求解精度,但是 CAAMM I 算法的收敛速度更快.图 8(c)中 CAAMM II 算法收敛较快,但是求解精度不如 CAAMM I 算法.

由表 4 可知,CAAMM 在整体上具有较高的求解精度、较好的解稳定性和收敛能力;而 CA 算法容易陷入局部较优解,解稳定性较差;采用柯西变异的 FEP 算法收敛速度较慢.其中,对于测试函数 f_4 ,CAAMM II 算法与 FEP 算法的求解精度相近,但 CAAMM II 算法的求解精度和收敛速度更好.

综上所述,本文采用的混合变异策略,根据进化过程隐含知识有机结合两种变异操作,在进化初期通过柯西变异保证算法的全局探索能力;在进化后期通过混沌变异提高求解精度,加快算法的收敛速度.因此,CAAMM 在整体上能兼顾全局探索和局部搜索能力,具有相对较好算法性能.

6 结论

进化规划中单纯采用柯西变异算子局部搜索能力较差,而采用混沌变异算子则算法容易早熟收敛.针对该问题,本文借鉴文化算法的双层进化结构,提出一种自适应混合变异策略.在知识的引导下,自适应调整两类变异算子的作用比例和作用时机,从而将两种变异操作有机结合,共同作用于种群.基于高维测试函数的仿真实验结果表明,算法在整体上具有较好的全局寻优能力,且收敛速度较快.面向多模函数优化问题的进化过程隐含知识的提取与利用,还有待于进一步深入研究.

参考文献

- [1] 周方俊,王向军,张民.基于 t 分布变异的进化规划[J].电子学报,2008,36(4):667-671.
Zhou Fang-jun, et al. Evolution programming using mutations based on the t probability distribution[J]. Acta Electronica Sinica, 2008, 36(4): 667-671. (in Chinese)
- [2] 王凌.智能优化算法及其应用[M].北京:清华大学出版社,2001.
- [3] 刘芳,李人厚.基于自适应 mutation 规则的一种有效的进化规划[J].控制与决策,2002,17(2):148-150.
- [4] X Yao, Y Liu, G M Lin. Evolutionary programming made faster[J]. IEEE Transactions on Evolutionary Computation, 1999, 3(2): 82-102.
- [5] C Y Lee, X Yao. Evolutionary programming using mutations based on the Levy probability distribution[J]. IEEE Transactions on Evolutionary Computation, 2004, 8(1): 1-13.
- [6] R Tinos, S X Yang. Self-adaptation of mutation distribution in evolutionary algorithms [A]. IEEE Congress on Evolutionary

Computation[C]. Piscataway, NJ, USA: IEEE, 2007. 79-86.


- [7] R Tinos, S X Yang. Evolutionary programming with q-Gaussian mutation for dynamic optimization problems [A]. IEEE Congress on Evolutionary Computation [C]. Piscataway, NJ, USA: IEEE, 2008. 1823-1830.
- [8] 骆晨钟,邵惠鹤.采用 chaotic mutation 的进化算法[J].控制与决策,2000,15(5):557-560.
- [9] 郭一楠,王辉,程健.一类自适应混沌文化算法[J].控制与决策,2009,24(4):514-519.
- [10] Bin Peng. Knowledge and Population Swarms in Cultural Algorithms for Dynamic Environments [D]. USA: Wayne State University, 2005.

作者简介



郭一楠 女,1975 年生于山西太原.博士,中国矿业大学信息与电气工程学院教授.主要从事智能优化算法、机器学习、多 agent 技术的研究工作.

E-mail: nanfly@126.com



刘丹丹 女,1988 年生于安徽淮北.中国矿业大学信息与电气工程学院硕士生.研究方向为智能优化算法.



程 健 男,1974 年生于四川平昌.博士,中国矿业大学信息与电气工程学院副教授.主要从事核机器学习、智能计算等的研究工作.



王 辉 女,1982 年生于山东兖州.中国矿业大学信息与电气工程学院硕士生.研究方向为智能优化算法.