

文章编号: 1001-0920(2008)12-1401-06

## 求解动态优化问题的多群体 UMDA

武燕<sup>1a</sup>, 王宇平<sup>1b</sup>, 刘小雄<sup>2</sup>

(1. 西安电子科技大学 a. 理学院, b. 计算机学院, 西安 710071; 2. 西北工业大学 自动化学院, 西安 710072)

**摘要:** 提出一种求解动态优化问题的多群体单变量边缘分布算法(MUMDA)。首先,利用多个概率模型(对应多个群体)将搜索空间分成几个部分,通过对不同区域的搜索或探索将好解进行迁移,扩大搜索空间,增加种群多样性,跟踪最优解的变化;然后,利用对 UMDA 收敛性的证明分析了所提出算法的有效性;最后,对两个动态优化问题进行仿真计算,并与传统 UMDA 和基于随机迁移的 UMDA (iUMDA)进行了比较,结果表明, MUMDA 能快速适应环境的变化,跟踪最优解。

**关键词:** 单变量边缘分布算法; 动态优化; 多群体策略

**中图分类号:** TP18

**文献标识码:** A

## Multi-population univariate marginal distribution algorithm for dynamic optimization problems

WU Yan<sup>1a</sup>, WANG Yuping<sup>1b</sup>, LIU Xiaoxiong<sup>2</sup>

(1a. School of Science, 1b. School of Computer Science and Technology, Xidian University, Xi'an 710071, China; 2. College of Automation, Northwestern Polytechnical University, Xi'an 710072, China. Correspondent: WU Yan, E-mail: yanerch@163.com)

**Abstract:** An improved multi-population univariate marginal distribution algorithm (MUMDA) is proposed to solve dynamic optimization problems. The search space is divided into several parts by using several probability modals which correspond to several populations. Meanwhile, the algorithm explores and exploits in different regions and the best solutions are migrated. The objective is to enlarge the search space, increase the population diversity and adapt to the change of the environments rapidly. Moreover, the convergence of UMDA is proved, which is used to analyze the validity of the proposed algorithm. Finally, an experimental study is carried out to compare the performance of several UMDA. The experimental results show that the MUMDA is effective and can adopt the dynamic environments rapidly.

**Key words:** Univariate marginal distribution algorithm (UMDA); Dynamic optimization problems; Multi-population scheme

### 1 引言

进化算法已被广泛应用于静态优化问题的求解。然而,现实中多数优化问题是动态的,因而利用进化算法求解动态优化问题已引起人们越来越多的关注<sup>[1]</sup>。在动态优化问题中,目标函数(适应值)、自变量和约束条件会随着时间发生变化,在求解动态优化问题时,算法的目标已不再是找到一个最优解,而是要跟踪最优解的变化。

在利用传统进化算法求解动态优化问题时,首要问题是保持种群多样性。针对这一问题,研究者已

提出许多改进方法,这些方法可分为 4 类<sup>[1,2]</sup>: 1) 环境改变之后增加种群多样性; 2) 始终保持种群多样性,例如随机迁移<sup>[3]</sup>等; 3) 引入某种记忆策略; 4) 采用多群体策略<sup>[4-6]</sup>。

采用多群体策略改进进化算法可有效增加种群多样性,已有的利用多群体策略求解动态优化问题的方法有: Oppacher 等<sup>[4]</sup>提出的 Shifting balance GA, Branke 等<sup>[5]</sup>提出的 Modified forking GA<sup>[6]</sup>, 以及 Ursem<sup>[6]</sup>提出的 Multinational GA 等。这些方法的思想是将整个搜索空间分成几部分,不同区域

收稿日期: 2007-09-10; 修回日期: 2007-12-23.

基金项目: 国家自然科学基金项目(60374063, 60775013).

作者简介: 武燕(1976—),女,太原人,讲师,博士生,从事组合优化、进化算法等研究; 王宇平(1961—),男,西安人,教授,博士生导师,从事进化计算、最优化理论等研究。

安排不同的群体进行搜索或探索.然而,由于大都采用距离分割搜索区域,导致算法复杂,计算量大.

本文主要讨论采用多群体的单变量边缘分布算法(UMDA)求解动态优化问题.UMDA 通过从当前代的优秀解中提取信息建立概率模型,并由概率模型抽样产生新的解,指导种群进化,这是对遗传算法的一种改进<sup>[7]</sup>.与其他传统进化算法一样,UMDA 需改进后才能求解动态优化问题.近年来,已有作者讨论过利用改进的 UMDA 求解动态优化问题<sup>[8,9]</sup>,但它们都需检测环境的变化.然而,要准确检测环境的变化不但计算量较大,而且实现困难.基于以上分析,为了克服计算量大、环境变化不容易检测的缺点,结合 UMDA 需建立概率模型的特点,本文提出一种新的基于多群体策略的单变量边缘分布算法(MUMDA),并使用改进的算法求解动态优化问题.该算法利用多个概率模型(即多个群体)实现对搜索空间的分割,充分利用适应值对好解进行迁移,增加了种群多样性,快速跟踪解的变化.通过对两个动态问题进行测试比较,充分验证了本文所提出算法的有效性.

## 2 动态优化测试问题

为了测试进化算法求解动态优化问题的性能,研究者提出了许多动态环境的构造方法<sup>[10]</sup>.本文利用两个静态优化问题构造相应的动态优化问题.

### 2.1 构造动态优化测试问题

对于给定的静态问题  $\max f(x), x \in \{0,1\}^l$ ,可按如下方式进行构造:首先,产生一个长为  $l$  的控制模板  $M$ ,然后,对群体中每个个体做异或运算  $x \oplus M$ (即  $1 \oplus 1 = 0, 1 \oplus 0 = 1, 0 \oplus 0 = 0$ ).假设在第  $t$  代环境发生变化,那么第  $t+1$  代个体的适应值为  $f(x, t+1) = f(x \oplus M)$ .

由此构造方法可以看出,若模板中某一位取值为 1,则个体的对应位发生变化;若取值为 0,则个体的对应位不变.因此,模板中含 1 越多,个体变化越大,即环境变化越大.设  $M$  中含  $\alpha l$  个 1,那么  $(0, 0, 1, 0)$  可用来控制环境变化的幅度.环境变化的速度用周期控制,设每隔  $\beta$  代环境发生一次变化.

下面给出构造动态问题所利用的两个静态优化问题.

### 2.2 静态优化问题

#### 1) 背包问题

背包问题是一个组合优化问题,也是一个 NP-难问题.此问题是从给定的  $l$  件物品中选出一部分物品,在满足背包约束条件的情况下,使所选物品总价值最大,其模型如下:

$$\max f(x) = \sum_{i=1}^l b_i x_i, \text{ s. t. } \sum_{i=1}^l w_i x_i \leq C.$$

其中:  $x = (x_1, x_2, \dots, x_l)$ ,  $x_i \in \{0, 1\}$ ;  $w_i$  和  $b_i$  分别为第  $i$  件物品的重量和价值;  $C$  为背包的容量.  $x_i = 1$  表示第  $i$  件物品被选择.本文  $C = 0.6 \times \sum_{i=1}^l w_i$ ,  $l$  取 100.

#### 2) 欺骗函数

欺骗函数是一类 GA 难的测试函数,由 Whitley 提出的 4 阶欺骗函数如下<sup>[11]</sup>:

$$\begin{aligned} f(0000) &= 28, f(0001) = 26, f(0010) = 24, \\ f(0011) &= 18, f(0100) = 22, f(0101) = 6, \\ f(0110) &= 14, f(0111) = 0, f(1000) = 20, \\ f(1001) &= 12, f(1010) = 10, f(1011) = 2, \\ f(1100) &= 8, f(1101) = 4, f(1110) = 6, \\ f(1111) &= 30. \end{aligned}$$

这些 4 阶欺骗函数的最优解为 1111,局部最优解为 0000,本文使用由 30 个 4 阶欺骗函数组成的欺骗函数.此函数的最优值为 900,最优解为

$\langle 111 \dots 111 \rangle$

共 120 个

## 3 多群体单变量边缘分布算法

### 3.1 单变量边缘分布算法

单变量边缘分布算法(UMDA)是由 Mühlenbein<sup>[7]</sup>提出的一类基于概率模型的进化算法.该算法结合了竞争学习和进化计算两个领域的知识.目前,已有许多关于 UMDA 的改进算法和数学分析<sup>[12,13]</sup>.

在二进制搜索空间,UMDA 使用一个概率向量

$$p(x, t) = (p(x_1, t), p(x_2, t), \dots, p(x_l, t)), \\ x = (x_1, x_2, \dots, x_l) \in \{0, 1\}^l$$

描述每一代的群体.这个概率向量的每一位表示对应变量(基因)取值为 1 的概率.新的群体通过对概率向量采样而生成.采用精英保留策略的 UMDA 算法描述如下:

Step1:  $t = 0$ , 初始化,  $p(x, 0) = (0.5, \dots, 0.5)$ , elitist =  $l$ ;

Step2: 由概率向量  $p(x, t)$  抽样产生  $N$  个个体,组成群体  $\text{Pop}(t)$ ,  $N$  为种群规模;

Step3: 利用某种选择机制从群体  $\text{Pop}(t)$  elitist 中选择  $\mu < N$  个个体组成中间群体  $S(t)$ , elitist =  $S(t)$  (本文采用截断选择);

Step4: 依据式(1)估计  $S(t)$  的概率分布  $p^s(x, t)$ ,  $p(x, t+1) = p^s(x, t)$ ;

Step5: 若终止条件不满足,则转 Step2;否则,算法结束.

在上述算法中,  $S(t)$  的概率分布(即概率向量)为

$$p^s(x_i, t) = \frac{1}{\mu} \sum_{k=1}^{\mu} x_i^k(t),$$

$$i = 1, 2, \dots, l, k = 1, 2, \dots, \mu, \quad (1)$$

其中  $x_i^k(t)$  表示群体  $S(t)$  中第  $k$  个个体的第  $i$  个变量(即第  $i$  个基因)的取值. 同时, 算法中截断选择算子为: 首先, 将群体中所有个体按适应值大小排序; 然后, 选择 100 % 个最优个体作为下一代群体的父个体, 其中  $\mu$  为截断阈值, 本文取 0.5.

UMDA 算法从一个中心概率向量  $p(x, 0) = (0.5, \dots, 0.5)$  开始, 它表示个体中的每个变量取值为 1 或 0 的概率是相等的, 以此概率产生的初始群体可均匀地分布在搜索空间. 算法通过提取当前代群体的一些好解提供的信息计算概率向量, 并利用此概率向量指导种群进化. 随着迭代次数的增加, 概率向量的值逐渐收敛于 0 或 1.

与传统进化算法一样, 当 UMDA 算法收敛时, 群体中个体趋于一致, 这样便失去种群多样性. 若这时环境发生变化, 则群体中的个体适应值之间并无区别, 不能跟踪环境的变化. 因此, 在求解动态优化问题时, 需改进 UMDA 以适应环境的变化.

### 3.2 多群体 UMDA

对于动态优化问题的求解, 本文提出一种新的基于多群体策略的单变量边缘分布算法(MUMDA). 首先利用适应值将群体分成分别由好解、次解和差解组成的 3 个子群体, 然后由这些子群体建立下一代好解、次解和差解对应的概率模型; 最后由概率模型抽样产生新的解. 如此重复, 直到满足终止条件. 该算法利用不同的概率模型形成对搜索空间的一个分割, 如图 1 所示. 利用适应值对好解进行迁移, 扩大了搜索空间, 增加了种群多样性, 从而跟踪最优解的变化. 第  $t-1$  代的 3 个子群体分别记为群体  $Pop_1(t-1)$ ,  $Pop_2(t-1)$  和  $Pop_3(t-1)$ . 下一代好解、次解和差解对应的概率向量分别记为  $p_1(x, t)$ ,  $p_2(x, t)$  和  $p_3(x, t)$ .

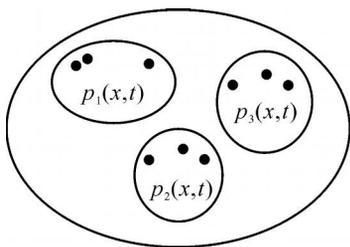


图 1 搜索空间的划分

多群体 UMDA 在每次迭代中首先按照已建立的 3 个概率向量  $p_1(x, t)$ ,  $p_2(x, t)$  和  $p_3(x, t)$  分别

抽样产生新的个体, 得到 3 个群体  $Pop_1(t)$ ,  $Pop_2(t)$  和  $Pop_3(t)$ ; 然后将这 3 个群体放在一起重新排序, 通过适应值将这些群体按原来的比例分成 3 部分, 仍记为  $Pop_1(t)$ ,  $Pop_2(t)$  和  $Pop_3(t)$ ; 最后利用这些群体以及前一代保留的精英建立下一代好解、次解和差解对应的概率向量. 设种群规模为  $N$ , 具体的概率向量描述如下.

1) 建立下一代好解对应的概率向量  $p_1(x, t+1)$ . 对于群体  $Pop_1(t)$  elitist(其中 elitist 为前一代保留下来的精英), 采用 UMDA 算法进行学习. 首先, 从  $Pop_1(t)$  elitist 中选择一部分(本文取  $\frac{1}{3} |Pop_1(t)|$  个个体, 其中  $| \cdot |$  为所含个体的个数)优秀解组成一个中间群体  $S_1(t)$ ; 然后, 根据式(1)建立概率向量. 由此可看出, 建立概率向量  $p_1(x, t+1)$  的目的是在潜在区域探索最优解.

2) 建立下一代差解对应的概率向量  $p_3(x, t+1)$ . 对于群体  $Pop_3(t)$  同样按 UMDA 算法过程执行, 不采用精英保留策略. 首先, 从  $Pop_3(t)$  中选择一部分(本文取  $\frac{1}{3} |Pop_3(t)|$  个个体)差解作为中间群体  $S_3(t)$ ; 然后, 根据式(1)建立差解对应的概率向量  $p_3(x, t+1)$ .

3) 建立下一代次解对应的概率向量  $p_2(x, t+1)$ . 对于群体  $Pop_2(t)$  直接按 UMDA 算法学习  $p_2(x, t+1)$  是不合适的, 这样易导致  $p_2(x, t+1)$  收敛, 失去种群多样性. 在本文算法中, 首先从群体  $Pop_1(t)$  elitist 中选择  $|S_1(t)|$  个适应值相对最差的个体组成群体  $S_2(t)$ ; 然后利用群体  $S_2(t)$  ( $Pop_2(t) \cup (Pop_3(t) \setminus S_3(t))$ ) 学习下一代次解对应的概率向量  $p_2(x, t+1)$ . 设  $p_2(x_i, t+1)$  表示第  $i$  个变量取值为 1 的概率, 由建立好解对应概率向量的过程可分析出群体  $(Pop_1(t) \text{ elitist}) \setminus (S_1(t) \cup S_2(t))$  的概率约等于  $p_1(x, t)$ , 再结合全概率公式可得

$$\frac{3}{13} p_1(x_i, t+1) + \frac{6}{13} p_2(x_i, t+1) + \frac{1}{13} p_3(x_i, t+1)$$

$$= \frac{6}{13} p_1(x_i, t) + \frac{2}{13} p_2(x_i, t) + \frac{2}{13} p_3(x_i, t),$$

即

$$p_2(x_i, t+1) = \frac{1}{2} p_1(x_i, t+1) + \frac{1}{3} p_2(x_i, t) + \frac{1}{3} p_3(x_i, t) - \frac{1}{6} p_3(x_i, t+1).$$

由上式可得, 当  $p_1(x_i, t+1)$  收敛到 1 时,  $p_2(x_i, t+1) > 0.5$ ; 当  $p_1(x_i, t+1)$  收敛到 0 时,  $p_2(x_i, t+1)$

< 0.5, 而且  $p_2(x_i, t+1)$  的值总是接近于  $p_1(x_i, t+1)$  的值. 因此, 本文采用式(2) 近似计算次解对应的概率向量

$$p_2(x_i, t+1) = \begin{cases} 0.5 + (p_1(x_i, t+1) - 0.5), & p_1(x_i, t+1) > 0.5; \\ 0.5 - (0.5 - p_1(x_i, t+1)), & p_1(x_i, t+1) < 0.5; \\ 0.5, & p_1(x_i, t+1) = 0.5; \end{cases} \quad (2)$$

其中参数  $\alpha = 0.8$ . 由式(2) 可以看出, 用来控制  $p_1(x_i, t+1)$  与  $p_2(x_i, t+1)$  的接近程度, 越大越接近, 而且  $p_2(x, t+1)$  始终介于概率向量  $p_1(x, t+1)$  与中心概率向量  $(0.5, \dots, 0.5)$  之间, 这样既能描述次解, 也能避免  $p_2(x, t+1)$  收敛, 保持了种群多样性.

根据上面的分析, 多群体 UMDA 描述如下:

Step1:  $t = 0$ , 初始化  $p_1(x, 0) = (0.5, \dots, 0.5)$   
 $= p_2(x, 0) = p_3(x, 0)$ , elitist = [ ],  $m = 0.6N$ ,  $n_2 = 0.2N$ ,  $n_3 = 0.2N$ .

Step2: 由概率向量  $p_1(x, t)$  抽样产生  $m$  个个体, 组成群体  $Pop_1(t)$ ; 由概率向量  $p_2(x, t)$  抽样产生  $n_2$  个个体, 组成群体  $Pop_2(t)$ ; 由概率向量  $p_3(x, t)$  抽样产生  $n_3$  个个体, 组成群体  $Pop_3(t)$ .

Step3: 令  $Pop = Pop_1(t) \cup Pop_2(t) \cup Pop_3(t)$ , 并计算  $Pop$  的适应值, 按适应值选择排在最前的  $m$  个个体组成群体  $Pop_1(t)$ , 选排在最后的  $n_3$  个个体组成群体  $Pop_3(t)$ .

Step4: 利用截断选择从群体  $Pop_1(t)$  中选中  $n_1$  个好解组成群体  $S_1(t)$ ; 利用截断选择从群体  $Pop_3(t)$  中选中  $n_3$  个差解组成群体  $S_3(t)$ ; elitist =  $S_1(t)$ .

Step5: 依据式(1) 估计  $S_1(t)$  的概率向量  $p_1^s(x, t)$ ,  $p_1(x, t+1) = p_1^s(x, t)$ ; 依据式(1) 估计  $S_3(t)$  的概率向量  $p_3^s(x, t)$ ,  $p_3(x, t+1) = p_3^s(x, t)$ ; 依据式(2) 建立概率向量  $p_2(x, t+1)$ .

Step6: 若终止条件不满足, 则  $t = t + 1$ , 转 Step2; 否则, 算法结束.

#### 4 收敛性证明及算法分析

在截断选择算子下, 个体  $x$  被选择的概率为<sup>[14]</sup>

$$p^s(x, t) = \begin{cases} p(x, t) / (t), & f(x) < f(x^*) \\ 0, & \text{其他.} \end{cases}$$

其中:  $f(x)$  为实数, 并满足  $f(x^*) = \min_{x \in D} f(x)$ . 由于算法中采用了精英保留策略, 基于上面的选择概率, 给出采用精英保留策略的截断选择概率

$$p^s(x, t) = \begin{cases} (1 - \alpha) p(x, t) / (t), & f(x) < f(x^*) \\ \alpha p(x, t), & f(x) \geq f(x^*) \\ 0, & \text{其他.} \end{cases}$$

其中:  $f(x)$  为实数, 并满足  $f(x^*) = \min_{x \in D} f(x)$ .

**定理 1** 在无限群体模型下, 设  $p(x, 0) > 0$ , 利用传统 UMDA 求解离散优化问题, 采用精英保留策略的截断选择算子, 则 UMDA 算法收敛.

**证明** 设所求问题为  $\max_{x \in D} f(x)$ ,  $G^*$  表示  $f(x)$  的最优值,  $f(x^*) = G^*$ ,  $x^*$  为最优解. 由传统 UMDA 可知, 在无限群体模型下有  $p(x, t+1) = p^s(x, t)$ , 那么可得

$$\begin{aligned} 1 - p(x^*, t) &= 1 - p^s(x^*, t-1) = \\ 1 - p(x^*, t-1) - p(x^*, t-1) / (t) &= \\ \left(1 - \frac{p(x^*, t-1)}{(t-1)(1-p(x^*, t-1))}\right) (1 - p(x^*, t-1)). \end{aligned} \quad (3)$$

因为  $\frac{p(x^*, t-1)}{1-p(x^*, t-1)}$  是一个单调递增函数, 且在无限群体模型下, 截断选择概率  $p(x^*, t-1)$  单调递增, 所以

$$0 < 1 - \frac{p(x^*, t-1)}{(t-1)(1-p(x^*, t-1))} < 1 - \frac{p(x^*, 0)}{(t-1)(1-p(x^*, 0))} \triangleq c,$$

其中  $0 < c < 1$ , 故  $0 < c < 1$ . 由式(3) 可得

$$1 - p(x^*, t) < c(1 - p(x^*, t-1)) < \dots < c^t(1 - p(x^*, 0)).$$

又因为  $p(x, 0) > 0$ , 所以  $\lim_{t \rightarrow \infty} (1 - p(x^*, t)) = 0$ , 即  $\lim_{t \rightarrow \infty} p(x^*, t) = 1$ . 所以 UMDA 算法收敛.

本文提出的算法 MUMDA 采用多群体建立多个概率向量, 实现对搜索空间的分割, 不同概率向量的作用和目标是不同的. 对于  $p_1(x, t)$  采用的是带有精英保留策略的 UMDA. 由定理 1 可知, 当环境不发生变化时, 算法收敛到最优解; 当环境发生变化时, 由算法 MUMDA 可知, 不断有优秀解迁移到群体  $Pop_1(t)$  中,  $Pop_1(t)$  不断在潜在区域进行探索, 可快速适应环境, 当环境静止时间足够时算法收敛到最优解. 此外,  $p_3(x, t)$  也是收敛的, 不过算法的目标是通过  $p_3(x, t)$  收敛而划分出一块适应值差的区域, 当环境发生变化时, 若差解变成好解, 则算法 MUMDA 可通过  $p_3(x, t)$  快速找到好解并将它迁移到群体  $Pop_1(t)$  中. 对于  $p_2(x, t)$ , 是为了分割出一块对应于次解的区域, 当环境发生变化时, 若次解变成好解, 则算法 MUMDA 可通过  $p_2(x, t)$  快速找到好解并将它迁移到群体  $Pop_1(t)$  中. 由  $p_1(x, t)$ ,  $p_2(x, t)$  和  $p_3(x, t)$  实现对搜索空间的分割, 当环境

发生变化时,不论最优解落入哪个搜索区域,算法 MUMDA 都可很快找到最优解的潜在区域并通过  $p_i(x, t)$  进行探索,最终找到最优解.综上所述,算法能快速适应环境的变化,并找到最优解.

### 5 实验分析

利用第 2 节给出的动态优化测试问题,对本文提出的 MUMDA,传统 UMDA 和 iUMDA<sup>[10]</sup> 进行仿真比较. iUMDA 是在 UMDA 的基础上引入随机迁移,即对概率向量抽样产生  $N$  个个体后,利用随机产生的个体随机替换抽样中的  $r \times N$  个个体,其中  $r$  是迁移率.随机迁移是增加种群多样性的一种非常有效的方法,已被用于求解动态优化问题<sup>[3]</sup>.因此,本文将 MUMDA 的性能与 iUMDA 和 UMDA 的性能进行比较.其中:种群规模均为 120,  $\mu = 0.5N$ ,  $r = 0.2$ .实验中,最大代数数为 2000,环境变化的速度 分别取 200 和 25,变化的幅度 分别取 0.05, 0.4 和 0.95.用 MUMDA,UMDA 和 iUMDA 对每个测试问题每组实验参数分别独立运行 10 次,图 2 ~ 图 5 为算法运行 10 次结果的平均值.对于文献[8,9]中提出的利用 UMDA 求解动态优化问题的两种算法,这些算法需检测环境的变化,而 MUMDA 不需检测机制,因此本实验未对 MUMDA 与文献[8,9]中的两种算法进行比较.

图 2 和图 3 给出了 3 种算法对两个测试问题在相同变化速度  $\tau = 200$ ,不同变化幅度  $\rho = 0.05, 0.4, 0.95$  下的实验结果.由图可知,当变化速度不太大时,MUMDA 和 iUMDA 明显优于 UMDA.这

是因为在环境变化较慢情况下,当环境发生变化时 UMDA 算法已收敛,失去种群多样性,所以很难适应环境的变化,不能跟踪最优解的变化.对于 iUMDA,引入随机迁移机制可始终保持种群多样性,因此除图 3(a) 外,iUMDA 可适应环境的变化.但随机迁移存在盲目性,对于变化幅度较小的情况易产生负作用,降低算法的收敛速度,如图 3(a) 所示.图 2(a) 中变化幅度也较小,但背包问题相对欺骗函数较简单,此时 iUMDA 也可适应环境的变化.对于 MUMDA,由图 2 和图 3 可知,当变化幅度较大和中等时,效果稍好于 iUMDA;变化幅度较小时,明显优于 iUMDA,如图 3(a) 所示.总之,MUMDA 总体上优于 iUMDA,这是因为 MUMDA 利用概率模型将搜索空间分成 3 部分,当环境发生变化时,不同搜索空间找到的最优解均迁移到第一部分,因此可很快适应环境的变化.

图 4 和图 5 给出了 3 种算法对两个测试问题在相同变化速度  $\tau = 25$ ,不同变化幅度  $\rho = 0.05, 0.4, 0.95$  下的实验结果.由图可知,当变化速度较大时,UMDA 的性能同样是最差的,但好于变化速度较慢的情况.这是因为环境变化时算法还没有收敛,仍保持一定的种群多样性.在环境变化较快的情况下,总体上 MUMDA 好于 iUMDA.当变化幅度较小时,如图 4(a) 和图 5(a) 所示, MUMDA 明显好于 iUMDA,说明随机迁移策略在环境变化幅度较小的情况下,效果较差;当变化幅度中等或较大时, MUMDA 稍好于 iUMDA,说明 MUMDA 采用多群

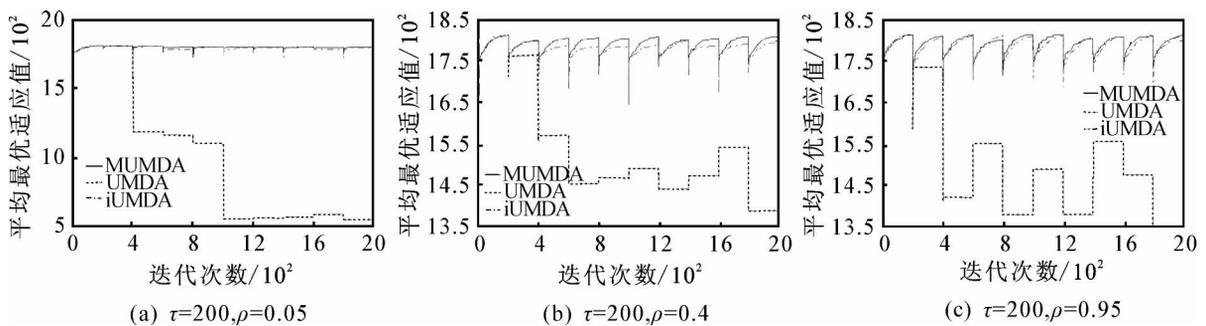


图 2 环境变化速度较慢情况下求解动态背包问题的仿真结果

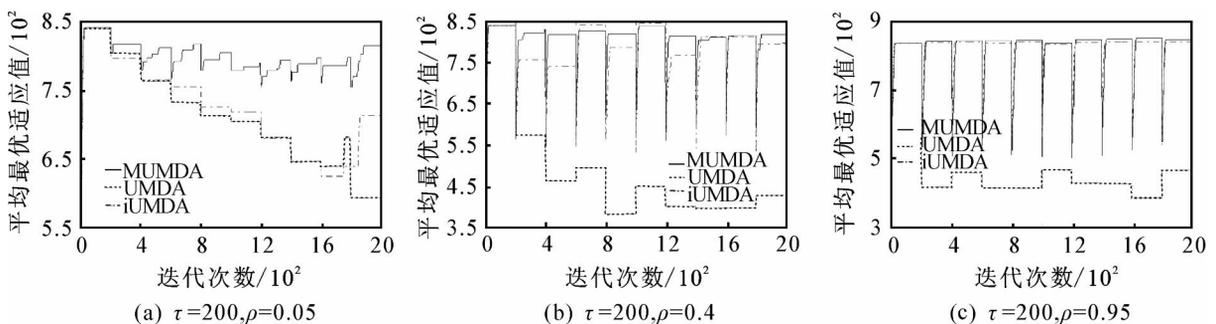


图 3 环境变化速度较慢情况下求解动态欺骗函数的仿真结果

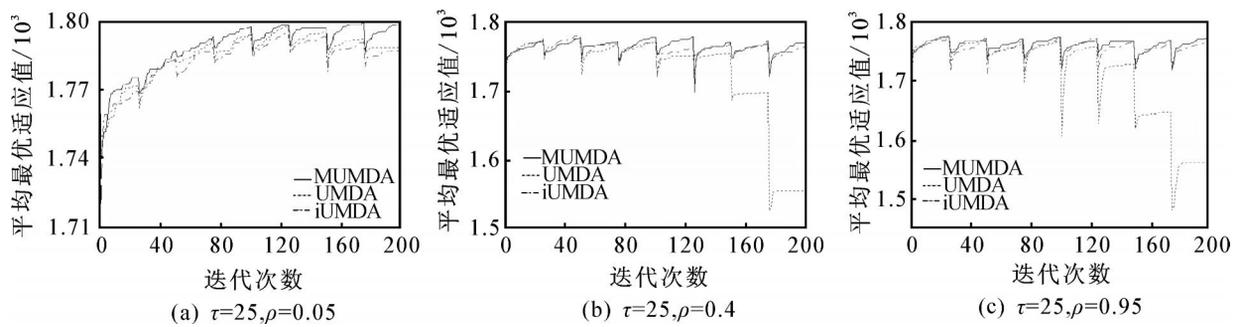


图 4 环境变化速度较快情况下求解动态背包问题的仿真结果

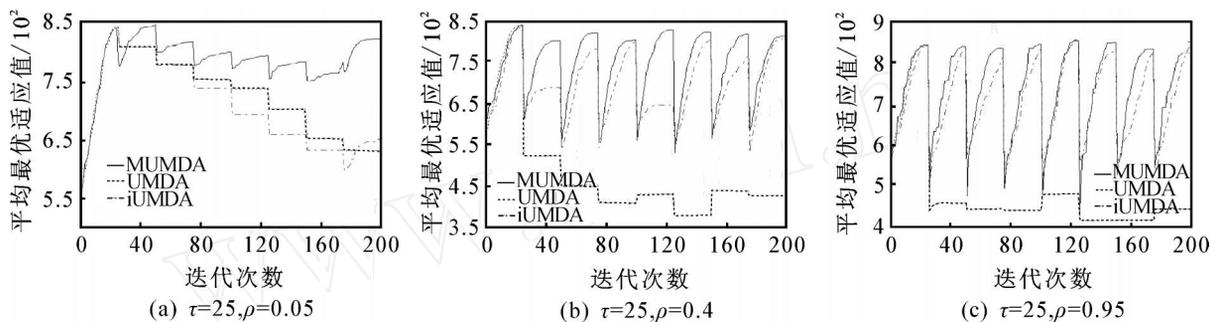


图 5 环境变化速度较快情况下求解动态欺骗函数的仿真结果

体策略,形成对搜索空间的分割,并对每个区域搜索到的好解进行迁移,可克服随机迁移的盲目性.上述分析表明,无论在何种环境下,MUMDA 的适应能力都要好于 iUMDA 和 UMDA.

## 6 结 论

由于许多科学和工程问题都可归结为动态优化问题,近年来利用进化算法求解动态优化问题受到越来越多的关注.本文提出一种改进的 UMDA,用于求解动态优化问题,利用对 UMDA 收敛性的证明,分析了所提出算法的有效性.算法的基本思想是利用概率模型将搜索空间分成几个部分,这样不论环境如何变化,不论最优解落入哪个搜索空间,它都可很快找到最优解的潜在区域,并对其进行探索.利用文中给出的动态测试函数,对 MUMDA, iUMDA 和 UMDA 在不同动态环境下分别进行计算,实验结果表明, MUMDA 能快速适应环境的变化,跟踪最优解.

## 参考文献(References)

- [1] Yaochu J, Branke J. Evolutionary optimization in uncertain environments — A survey[J]. IEEE Trans on Evolutionary Computations, 2005, 9(3): 1-15.
- [2] 王洪峰,汪定伟,杨圣祥. 动态环境中的进化算法[J]. 控制与决策, 2007, 22(2): 127-131.  
(Wang H F, Wang D W, Yang S X. Evolutionary algorithms in dynamic environments[J]. Control and Decision, 2007, 22(2): 127-131.)
- [3] Grefenstette J J. Genetic algorithms for changing environments [C]. Parallel Problem Solving from

Nature. Brussels, 1992: 137-144.

- [4] Oppacher F, Wineberg M. The shifting balance genetic algorithm: Improving the GA in a dynamic environment [C]. Proc of Genetic and Evolutionary Computation. San Francisco: Morgan Kaufmann Publisher, 1999: 504-510.
- [5] Branke J, Kaubler T, Schmidt C, et al. A multi-population approach to dynamic optimization problems [C]. Adaptive Computing in Design and Manufacturing 2000. Berlin: Springer-Verlag, 2000: 299-308.
- [6] Ursem R K. Multinational GA optimization technique in dynamic environments [C]. Proc of Genetic and Evolutionary Computation. San Francisco: Morgan Kaufmann Publisher, 2000: 19-26.
- [7] Mühlenbein H. The equation for response to selection and its use for prediction [J]. Evolutionary Computation, 1998, 5(6): 303-346.
- [8] Yang S X. Memory-enhanced univariate marginal distribution algorithms for dynamic optimization problems [C]. The IEEE Congress on Evolutionary Computation. Edinburgh: IEEE Press, 2005: 2560-2567.
- [9] Ghosh A, Muhlenbein H. Univariate marginal distribution algorithms for non-stationary optimization problems[J]. Int J of Knowledge-based and Intelligent Engineering Systems, 2004, 8(3): 129-138.
- [10] Shengxiang Y, Xin Y. Experimental study on population-based incremental learning algorithms for dynamic optimization problems[J]. Soft Computation, 2005, 9(6): 815-834. (下转第 1412 页)

图 6 中  $S_{i1}$  至  $S_{i2}$  及图 7 中  $S_{i2}$  至  $D_i$  间航迹连接起来, 即为  $i$  号无人机经多机自主协同优化后的航迹.

## 6 结 论

本文在构建基于动态贝叶斯网络威胁体感知模型的基础上, 利用 DBN 中状态转移网络及观测转移网络参数变化, 实现了对空天环境中突发威胁体的动态感知, 进而提出了基于图形模型动态感知下的多无人机航迹自主协同规划方法. 实验结果表明, 这种自主规划方法, 可实现多无人机航迹协同, 并充分利用 DBN 的学习和推理算法, 有效解决多无人机协同飞行过程中对当前形势估计不足以及对未来情况预测的问题, 具有较强的实效性. 这种基于图形模型的动态感知框架, 还可应用于协同空战中的干扰协同、攻击协同和火力分配等方面, 为辅助决策提供了一种行之有效的办法.

## 参考文献(References)

- [1] McLain T W, Chandler P R, Pachter M. A decomposition strategy for optimal coordination of unmanned air vehicles [C]. 2000ACC. Chicago, 2000: 369-373.
- [2] Chandler P R, Rasmussen S, Pachter M A. UAV cooperative path planning [C]. 2001ACC. Denver, 2001: 50-55.
- [3] Murphy K. Dynamic Bayesian networks: Representation, inference and learning [D]. Berkeley: Computer Science Division, 2002.
- [4] 肖秦琨, 高晓光, 高嵩. 基于混合动态贝叶斯网络的无人机路径重规划[J]. 系统仿真学报, 2006, 18(5): 1301-1306.  
(Xiao Q K, Gao X G, Gao S. Local path replanning for UCAV based on mix-state dynamic Bayesian networks [J]. J of System Simulation, 2006, 18(5): 1301-1306.)
- [5] 史建国, 高晓光, 李相民. 离散模糊动态贝叶斯网络用于无人作战飞机目标识别[J]. 西北工业大学学报, 2006, 24(1): 45-49.  
(Shi J G, Gao X G, Li X M. Improving identification capability of UCAV [J]. J of Northwestern Polytechnical University, 2006, 24(1): 45-49.)
- [6] Russell S, Norvig P. Artificial intelligence: A modern approach [M]. 2nd ed. New Jersey: Prentice Hall, 2003.
- [7] 杨有龙, 高晓光. 无人战斗机的态势感知模型框架[J]. 飞行力学, 2003, 21(3): 6-9.  
(Yang Y L, Gao X G. A model framework of situation awareness for uninhabited combat air vehicle [J]. Flight Dynamics, 2003, 21(3): 6-9.)
- [8] Digalakis V, Rohlicek J R, Osterdorf M. ML estimation of a stochastic linear systems with the EM algorithm and its application to speech recognition [J]. IEEE Trans Speech and Audio Proc, 1993, 1(4): 431-442.
- [9] Pavlovic V. Dynamic Bayesian networks for information fusion with applications to human-computer interfaces [D]. Urbana Champaign: University of Illinois, 1999.
- [10] 孟波波, 高晓光, 丁琳. 基于突发任务多无人作战飞机攻击多目标研究[J]. 系统仿真学报, 2007, 19(1): 176-179.  
(Meng B B, Gao X G, Ding L. Research on method of multiple UCAVs multi-target attacking path planning based on pop-up mission [J]. J of System Simulation, 2007, 19(1): 176-179.)
- [11] 杨有龙. 基于图形模式的表达方式[D]. 西安: 西北工业大学, 2003.  
(Yang Y L. Intelligent optimization based on graphical models [D]. Xi 'an: Northwestern Polytechnical University, 2003.)

(上接第 1406 页)

- [11] Whitley L D. Fundamental principles of deception in genetic search [J]. Foundations of Genetic Algorithms, 1991, 1(3): 221-241.
- [12] Zhang Q. On stability of fixed point of limit models of univariate marginal distribution algorithm and factorized distribution algorithm [J]. IEEE Trans on Evolutionary Computation, 2004, 8(1): 80-93.
- [13] Zinchenko L, Muhlenbein H, Kureichik V, et al.

- Application of the univariate marginal distribution algorithm to analog circuit design [C]. Proc of NASA/DoD Conf on Evolvable Hardware. Washington: IEEE Computer Society Press, 2002: 93-101.
- [14] Zhang Q, Muhlenbein H. On the convergence of a class of Estimation of distribution algorithms [J]. IEEE Trans on Evolutionary Computation, 2004, 8(2): 127-136.