

文章编号: 1001-0920(2011)09-1358-05

## 求解模糊相关机会规划模型的混合差分进化算法

王 林<sup>1</sup>, 富庆亮<sup>1</sup>, 曾宇容<sup>2</sup>

(1. 华中科技大学 管理学院, 武汉 430074; 2. 湖北经济学院 信息管理学院, 武汉 430205)

**摘 要:** 针对不确定规划领域中存在的模糊相关机会规划模型, 基于群体智能的差分进化算法, 设计一种新的求解模糊相关机会规划模型的混合智能算法. 该算法基于粒子群优化算法对差分进化算法进行改进, 并运用模糊模拟技术对模糊相关机会规划模型进行分析和数值求解, 无需像传统的基于遗传算法的混合智能算法需要很长时间并经过复杂的计算才能得到合理的结果. 最后, 通过实例表明了所提混合智能算法的合理性和有效性.

**关键词:** 混合差分进化算法; 模糊相关机会规划; 模糊模拟

**中图分类号:** TP301.6

**文献标识码:** A

## Hybrid differential evolution algorithm for fuzzy dependent-chance programming model

WANG Lin<sup>1</sup>, FU Qing-liang<sup>1</sup>, ZENG Yu-rong<sup>2</sup>

(1. School of Management, Huazhong University of Science and Technology, Wuhan 430074, China; 2. School of Information Management, Hubei University of Economics, Wuhan 430205, China. Correspondent: ZENG Yu-rong, E-mail: zyr@hbue.edu.cn)

**Abstract:** Aiming at the existing fuzzy dependent-chance programming model in uncertainty planning field and the optimization approach of group intelligence-differential evolution algorithm, a novel hybrid intelligent algorithm for fuzzy dependent-chance programming models is designed. The proposed algorithm uses hybrid differential evolution algorithm improved by particle swarm optimization algorithm and fuzzy simulation to solve this kind of programming problems. It does not need a long time and complex calculations to get reasonable results like the hybrid intelligent algorithm based on traditional genetic algorithm. Numerical examples show the rationality and effectiveness of the proposed hybrid intelligent algorithm.

**Key words:** hybrid differential evolution algorithm; fuzzy dependent-chance programming; fuzzy simulation

### 1 引 言

由 Storn 和 Price<sup>[1]</sup>提出的差分进化 (DE) 算法是一种随机的并行直接搜索算法, 可对非线性不可微连续空间函数进行优化. DE 算法保留了基于种群的全局搜索策略, 采用实数编码、基于差分的简单变异操作以及一对一的竞争生存策略, 降低了遗传操作的复杂性, 适于求解一些利用常规数学规划方法所无法求解的复杂优化问题. 该算法以其易用性、稳健性和强大的全局寻优能力在众多领域取得了成功, 如多目标优化问题<sup>[2]</sup>、复杂的车间作业调度<sup>[3]</sup>、高性能聚类分析<sup>[4]</sup>和银行破产预测问题<sup>[5]</sup>等.

模糊规划理论和方法的研究源于 20 世纪 70 年

代提出的模糊决策概念和决策模型. 2000 年, Liu<sup>[6]</sup>提出了模糊相关机会规划 (FDCP) 问题, 即在选择决策时使事件得到满足的可能性在不确定环境下达到最大. 在确定性规划以及期望值模型和机会约束规划中, 对实际问题建模后, 其可行集本质上是确定的, 这可能会导致所给出的最优解在实际中无法执行. 而 FDCP 打破了可行集的概念, 不像其他模糊规划需假设可行集确定. 虽然它给出了一个确定的解, 但只要该解在实际问题中尽可能地执行, 便具有广泛的应用价值, 而且已在众多领域得到了应用. 如 Yang<sup>[7]</sup>将相关机会规划应用于交通领域, 研究将直接费用、固定费用、物资的运输需求和能力模糊化后固定收费的运

收稿日期: 2010-05-10; 修回日期: 2010-07-12.

基金项目: 国家自然科学基金项目(70801030); 湖北省教育厅科研项目(D20112201); 中央高校基本科研业务费项目(HUST: 2010MS133).

作者简介: 王林(1974-), 男, 副教授, 博士, 从事物流工程学研究; 富庆亮(1985-), 男, 硕士生, 从事物流工程的研究.

输问题; Wu 等人<sup>[8]</sup>将相关机会规划应用于随机网络瓶颈容量扩张问题, 研究在总成本增加的可能性上限中最大化网络容量; 王林等人<sup>[9]</sup>将相关机会规划应用于核电站备件库存管理, 得到了使企业库存费用不超过某一预算水平的可信度最大的最优订货量。

FDCP 因其非线性、非凸性及模糊性, 对经典的优化理论提出了极大的挑战. 已有一些方法应用于求解模糊机会约束规划模型, 包括禁忌搜索算法<sup>[7]</sup>、神经网络与遗传算法 (GA) 相结合的混合算法<sup>[8]</sup>、粒子群优化 (PSO) 算法<sup>[9]</sup>等, 其中使用最广且效果最佳的是 GA<sup>[6]</sup>.

DE 特有的记忆能力使其可以动态跟踪当前的搜索情况, 以调整其搜索策略, 具有较强的全局收敛能力和鲁棒性, 且不需要借助问题的特征信息. 因此, 本文在借鉴基于群体智能的 PSO 算法优点对 DE 算法进行改进的基础上, 结合模糊模拟技术, 设计一种求解模糊相关机会规划模型的混合智能算法, 并通过在具体模糊规划实例进行数值求解和对比, 表明了该算法的科学性和有效性.

## 2 差分进化算法及其改进

### 2.1 差分进化算法流程

DE 算法的基本操作包括变异、交叉和选择 3 种操作. 具体流程如下:

**Step 1:** 初始化. 确定种群规模 NP, 交叉概率 CR  $\in (0, 1]$ , 个体的变量维数  $D$ , 随机选取初始种群  $X(t) = (X_1(t), X_2(t), \dots, X_i(t), \dots, X_{NP}(t))$ . 其中:  $X(t)$  为第  $t$  代的种群,  $X_i(t)$  为第  $t$  代种群的第  $i$  个个体.

**Step 2:** 变异操作. 变异是 DE 算法中产生新个体的关键步骤. 从当代种群中随机选取与当前进行变异的个体不同的 3 个个体进行, 即

$$v_i(t+1) = X_{r_1}(t) + F * (X_{r_2}(t) - X_{r_3}(t)). \quad (1)$$

其中:  $r_1, r_2, r_3$  为在当代中随机选取的与  $i$  不同的 3 个个体;  $F$  为缩放因子, 一般取值范围为  $[0, 2]$ .

**Step 3:** 交叉操作. 交叉操作可以增加种群的多样性, 其方程为

$$\begin{cases} u_i^j(t+1) = v_i^j(t+1), \\ \text{rand}(0, 1) \leq \text{CR}, \text{ or } j = \text{rand}(i); \\ u_i^j(t+1) = X_i^j(t), \text{ else.} \end{cases} \quad (2)$$

其中: CR 为杂交概率,  $\text{rand}(i)$  为  $[1, D]$  间的随机整数,  $X_i^j(t)$  为第  $t$  代第  $i$  个个体的第  $j$  个基因位.

**Step 4:** 选择操作. DE 采用“贪婪”的搜索策略, 将经过变异与交叉操作后生成的实验个体  $u_i^j(t+1)$  与  $X_i(t)$  进行比较, 以决定  $X_i(t+1)$ , 即

$$\begin{cases} X_i(t+1) = u_i(t+1), f(u_i(t+1)) < f(X_i(t)); \\ X_i(t+1) = X_i(t), \text{ else.} \end{cases} \quad (3)$$

其中函数  $f$  为适应值函数.

**Step 5:** 判断是否达到停止迭代的条件. 如果满足, 则停止迭代; 否则, 转 Step 2.

基本的 DE 算法存在容易早熟、全局寻优效率偏低等缺点. 因此, 很多学者从多个角度致力于 DE 算法的改进<sup>[10]</sup>. Kaelo 等人<sup>[11]</sup>利用锦标赛竞争选择机制来选取进行变异操作的父代基向量, 同时在试验个体和种群内最好个体之间的区域, 利用反射和收缩操作来实施局部搜索. Oze<sup>[12]</sup>提出利用带有肯定的、不可预测的、非周期的和复杂的时空行为和随机特性的混沌映射方法, 对差分进化算法进行初始化, 可以改进算法的全局寻优能力. 本文将 DE 与 PSO 算法相结合, 利用 PSO 算法的算法简单, 没有很多参数需要调整, 不需要梯度信息等优点来弥补 DE 算法的缺陷, 得到一种全局寻优能力更强、收敛效率更好的混合差分进化算法.

### 2.2 基于 PSO 和 DE 算法的混合差分进化 (PSO-DE) 算法

PSO 算法的最大优点在于适应性强、稳定可靠, 能在可行的时间内以较大的概率获得问题的最优解或近似最优解<sup>[13]</sup>. 在 PSO 算法的每一次迭代中, 粒子都是通过跟踪比较粒子本身找到的最优解  $P_{\text{best}}$  和整个微粒群体所找到的最优解  $P_{\text{gbest}}$  来更新自己. 因此在基本的 PSO 算法中, 当前微粒总是追随种群中的最优微粒, 使得粒子极可能陷入局部极小点而无法逃离<sup>[14]</sup>.

本文提出的 PSO-DE 算法的改进思想是: 将种群的邻域结构的大小设为 3, 每个微粒的邻居随机产生于其他微粒, 这样可以增大微粒的全局搜索能力. 每个微粒速度的更新基于个体最优和其他微粒的最优, 全部微粒在进行完粒子群算法后, 在进入下一次迭代之前, 随机选择一定数量的微粒并按照一定规则进行差分进化, 这样可使陷入局部极小的粒子逃出, 增加粒子的多样性以保证算法的全局收敛. PSO-DE 算法的具体流程如下:

**Step 1:** 初始化. 种群大小  $N$ , 微粒位置  $P_i(0)$ , 微粒速度  $V_i(0)$ , 惯性权重  $w$ , 加速常数  $c_1$  和  $c_2$  以及交叉算子 CR, 变异算子  $F$ .

**Step 2:** 计算并确定微粒行走过的最佳位置  $P_{\text{pbest}} = (P_{\text{best1}}(t), P_{\text{best2}}(t), \dots, P_{\text{bestN}}(t))$  和所有微粒行走过的最佳位置  $P_{\text{gbest}}(t)$ .

Step 3: 利用 Step 2 确定的微粒的最佳位置, 全局最佳位置和公式  $V_i(t+1) = w * V_i(t) + \text{rand}(0, c_1) * (P_{\text{best}i}(t) - P_i(t)) + \text{rand}(0, c_2) * (P_{\text{gbest}}(t) - P_i(t))$  更新微粒的速度.

Step 4: 选取一定比例进行差分进化. 参与差分进化的粒子  $P_i$  其后代位置的产生来自不同于  $P_i$  的 3 个微粒, 这里分别为整个种群的最优粒子位置及其他两个粒子的个体最优位置.

Step 5: 更新种群. 若由差分算法形成的下一代粒子适应值好于  $P_i$ , 则  $P_i$  被取代; 否则,  $P_i$  保持不变,  $P_i$  的个体最优与速度保持不变, 只是改变其当前位置.

Step 6: 确定是否已满足终止条件. 若满足, 则结束; 否则, 转 Step 2.

### 3 模糊相关机会规划问题

#### 3.1 相关模糊理论概述

一个复杂的决策系统通常要完成多项任务, 称之为事件. 决策者往往希望这些事件实现的机会尽可能的大, 且允许模糊约束条件在某种程度上不被满足, 但是模糊约束条件成立的可能性(必要性或可信性)不能小于决策者预先给定的水平. 相关机会规划可表示为

$$\begin{cases} \max \text{ch}\{f_k(x, \xi) \leq 0, k = 1, 2, \dots, q\}, \\ \text{s.t. ch}\{g_j(x, \xi) \leq 0, j = 1, 2, \dots, p\}. \end{cases} \quad (4)$$

其中:  $x$  为决策向量,  $\xi$  为不确定变量;  $\text{ch}\{f_k(x, \xi) \leq 0, k = 1, 2, \dots, q\}$  为目标函数; 事件由  $f_k(x, \xi) \leq 0$  表征; 不确定环境由  $g_j(x, \xi) \leq 0$  刻画;  $\text{ch}$  可分别代表概率  $\text{Pr}$ , 可信性测度  $\text{Cr}$ , 信任测度  $\text{Tr}$  等机会测度.

#### 3.2 相关机会规划模型类型

##### 1) 标准相关机会规划

$$\begin{cases} \max \text{Cr}\{h_k(x, \xi) \leq 0, k = 1, 2, \dots, q\}; \\ \text{s.t. } g_j(x, \xi) \leq 0, j = 1, 2, \dots, p. \end{cases} \quad (5)$$

其中:  $x$  为决策变量,  $\xi$  为模糊变量,  $h_k(x, \xi) \leq 0 (k = 1, 2, \dots, q)$  为模糊事件,  $g_j(x, \xi) \leq 0 (j = 1, 2, \dots, p)$  为不确定性环境. 决策变量  $x$  的不确定性是因与模糊变量  $\xi$  相关而带来的.

##### 2) 相关机会多目标规划

$$\begin{cases} \max \begin{bmatrix} \text{Cr}\{h_{1k}(x, \xi) \leq 0, k = 1, 2, \dots, q_1\} \\ \text{Cr}\{h_{2k}(x, \xi) \leq 0, k = 1, 2, \dots, q_2\} \\ \vdots \\ \text{Cr}\{h_{mk}(x, \xi) \leq 0, k = 1, 2, \dots, q_m\} \end{bmatrix}; \\ \text{s.t. } g_j(x, \xi), j = 1, 2, \dots, p. \end{cases} \quad (6)$$

其中:  $h_{ik}(x, \xi) \leq 0, k = 1, 2, \dots, q_i$ , 表示模糊事件.

##### 3) 相关机会目标规划

$$\begin{cases} \min \sum_{j=1}^l P_j \sum_{i=1}^m (u_{ij}d_i^+ + v_{ij}d_i^-). \\ \text{s.t. Cr}\{h_{ik}(x, \xi) \leq 0, k = 1, 2, \dots, q_i\} - \\ d_i^+ + d_i^- = b_i; \\ g_j(x, \xi) \leq 0, j = 1, 2, \dots, p; \\ d_i^+, d_i^- \geq 0, i = 1, 2, \dots, m. \end{cases} \quad (7)$$

其中:  $P_j$  为优先因子, 表示各个目标的相对重要性, 并且  $P_j \gg P_{j+1}$  对于  $\forall j$  均成立;  $u_{ij}$  为对应优先级  $j$  的第  $i$  个目标正偏差的权重因子;  $v_{ij}$  为对应优先级  $j$  的第  $i$  个目标负偏差的权重因子;  $d_i^+$  为目标  $i$  偏离目标值的正偏差;  $d_i^-$  为目标  $i$  偏离目标值的负偏差;  $h_{ik}$  为目标约束中的实值函数;  $g_j$  为在不确定环境中的实值函数;  $b_i$  为目标  $i$  的目标值;  $l$  为优先级个数;  $m$  为目标约束个数;  $p$  为系统约束个数.

为求解上述模型, 需要用到不确定原理<sup>[15]</sup>: 在不确定环境下, 一个模糊事件的机会等于此事件相容的可信性(可能性或必要性). 假设在不确定环境  $g_j(x, \xi) \leq 0$  下, 有  $m$  个事件  $h_{ik}(x, \xi) \leq 0, k = 1, 2, \dots, q_i$ , 分别记为  $\xi_i$ . 由不确定原理, 第  $i$  个事件  $\xi_i$  的机会函数为

$$f_i(x) = \text{Cr}\{h_{ik}(x, \xi) \leq 0, k = 1, 2, \dots, q_i; g_j(x, \xi) \leq 0, j \in J_i\}. \quad (8)$$

其中  $J_i = \{j \in \{1, 2, \dots, p\} | g_j(x, \xi) \leq 0\}$  是事件  $\xi_i$  的相关约束.

### 4 基于模糊模拟方法和 PSO-DE 算法的可信度求解算法

#### 4.1 模糊模拟

用常规的解析法很难得到式 (5)~(7) 中的可信度; 采用模糊模拟的方法不仅可以得到隶属度函数为三角或梯形函数时的可信度, 而且可求解隶属度函数为其他复杂的任意形式时的可信度. 因此, 可用模糊模拟方法来估计每一个设定  $x$  值的  $\text{Pos}\{f(x, \xi) \leq 0\}$  或  $\text{Cr}\{f(x, \xi) \leq 0\}$ .

**算法 1** 直接求  $\text{Pos}\{f(x, \xi) \leq 0\}$  的步骤如下:

Step 1: 令  $\text{Pos}\{f(x, \xi) \leq 0\} = 0$ .

Step 2: 从模糊向量  $\xi$  的  $\alpha$ -截集中均匀产生  $\xi^0$ , 其中  $\alpha$  是预先设定的.

Step 3: 如果  $f(x, \xi) \leq 0$  且  $\text{Pos}\{f(x, \xi) \leq 0\} < \mu(\xi_0)$ , 则令  $\text{Pos}\{f(x, \xi) \leq 0\} = \mu(\xi_0)$ .

Step 4: 重复 Step 1 和 Step 2, 执行  $N$  次.

Step 5: 返回  $\text{Pos}\{f(x, \xi) \leq 0\}$ .

**算法 2** 直接求  $\text{Cr}\{f(x, \xi) \leq 0\}$  的步骤如下:

Step 1: 设  $e_1 = 0, e_2 = 0, n = 1$ .

Step 2: 在  $\Phi = \theta_1 \times \theta_2 \times \dots \times \theta_n$  中均匀产生一

系列  $(\theta_{1n}, \theta_{in}, \dots, \theta_{nn})$ , 使得  $\text{Pos}\{\theta_{in}\} > \varepsilon (i = 1, 2, \dots, n, \varepsilon \text{ 是一个足够小的数})$ . 这样, 可以得到一组数据  $(\xi(\theta_{1n}), \xi(\theta_{in}), \dots, \xi(\theta_{nn}))$ .

Step 3: 计算  $f(x, \xi) < 0$ , 且  $\mu = \min\{\mu_\xi(\xi(\theta_{1n})), \mu_\xi(\xi(\theta_{in})), \dots, \mu_\xi(\xi(\theta_{nn}))\}$ .

Step 4: 如果  $f(x, \xi) < 0$  且  $e_1 < \mu$ , 则  $e_1 = \mu$ ; 如果  $f(x, \xi) \geq 0$  且  $e_2 < \mu$ , 则  $e_2 = \mu$ .

Step 5: 令  $n = n + 1$ , 返回 Step 2, 直到迭代次数达到设定值.

Step 6: 计算  $e = \frac{1}{2}(e_1 + 1 - e_2)$ , 即为 Cr 的值.

#### 4.2 基于混合 DE 算法与模糊模拟的可信度计算流程

Step 1: 初始化, 设置  $t = 1$ .

Step 2: 在第  $t$  代,  $P_i(t)$  是粒子  $i$  的当前位置, 利用算法 2 通过计算  $\text{Cr}\{f(P_{\text{best}i}(t), \xi) \leq \bar{f}\} = \max_{1 \leq l \leq t} \text{Cr}\{f(P_i(l), \xi) \leq \bar{f}\}$  确定粒子  $i$  当前可得到的最佳位置  $P_{\text{best}i}(t)$ ; 再利用算法 2 计算  $\text{Cr}\{f(P_{\text{gbest}}(t), \xi) \leq \bar{f}\} = \max_{1 \leq i \leq N} \text{Cr}\{f(P_{\text{best}i}(t), \xi) \leq \bar{f}\}$  以确定种群当前的全局最佳位置  $P_{\text{gbest}}(t)$ .

Step 3: 利用 Step 2 确定的粒子的最佳位置, 全局最佳位置和公式  $V_i(t+1) = w * V_i(t) + \text{rand}(0, c_1) * (P_{\text{best}i}(t) - P_i(t)) + \text{rand}(0, c_2) * (P_{\text{gbest}}(t) - P_i(t))$  更新粒子的速度.

Step 4: 选取一定比例进行差分进化. 在差分进化的选择操作中需将第 2 节中的式 (3) 改为如下形式:

$$X_i(t+1) = \begin{cases} u_i(t+1), & \text{Cr}\{f(u_i(t+1), \xi) \leq \bar{f}\} < \\ & \text{Cr}\{f(X_i(t), \xi) < \bar{f}\}; \\ X_i(t), & \text{Cr}\{f(u_i(t+1), \xi) \leq \bar{f}\} \geq \\ & \text{Cr}\{f(X_i(t), \xi) \geq \bar{f}\}. \end{cases} \quad (9)$$

并利用算法 2 计算 Cr 值.

Step 5: 更新种群. 若由差分算法形成的下一代微粒适应值好于  $P_i$ , 则  $P_i$  被取代; 否则,  $P_i$  保持不变,  $P_i$  的个体最优与速度均保持不变, 只是改变其当前位置.

Step 6: 确定是否已满足终止条件. 若满足, 则结束; 否则, 转 Step 2.

### 5 数值模拟

例 1 (标准相关机会规划)

$$\begin{aligned} & \max \text{Cr}\{x_1^2 + x_2^2 + x_3^2 = 1\}; \\ & \text{s.t.} \begin{cases} \tilde{b}(x_1 + x_2 + x_3) \geq \tilde{a}, \\ x_1, x_2, x_3 > 0. \end{cases} \end{aligned} \quad (10)$$

其中:  $\tilde{a}$  为三角模糊变量  $(0, 1, 2)$ , 模糊变量  $\tilde{b}$  的隶属

度函数为  $\mu_{\tilde{b}}(\xi) = \exp(-|\xi - 2|)$ .

在模型 (10) 中, 事件为  $x_1^2 + x_2^2 + x_3^2 = 1$ , 记为  $\xi$ ; 其相关支撑  $\xi^{**} = \{x_1, x_2, x_3\}$ . 根据不确定原理, 事件  $\xi^{**} = \{x_1, x_2, x_3\}$  的机会函数为

$$\begin{aligned} f(x) &= \text{Cr}\{x_1^2 + x_2^2 + x_3^2 = 1, \\ & \tilde{b}(x_1 + x_2 + x_3) \geq \tilde{a}, \\ & x_1, x_2, x_3 > 0\}. \end{aligned}$$

利用 Matlab 编程. 本文算法中定义群体个数为 50,  $w = 0.4, c_1 = c_2 = 2, \text{CR} = 0.6, F = 1.1$  (经过多次实验比较确定的参数). 共进行 5 次实验, 每次迭代 300 代, 得到的 Cr 相同. 算法比较结果如表 1 所示, GA 结果参见文献 [15].

表 1 两种算法结果比较

算法	$x_1$	$x_2$	$x_3$	最优值	迭代次数
PSO-DE	0.5827	0.5931	0.5556	0.8250	50
GA	0.6016	0.7497	0.2757	0.8209	400

由表 1 可见, 利用 GA 得到的最优值为 0.8209, 而 PSO-DE 算法得到的为 0.8250, 比 GA 的结果更加优化.

#### 例 2 (相关机会目标规划)

$\text{lexmin}\{d_1^-, d_2^-, d_3^-\}$ .

$$\text{s.t.} \begin{cases} \text{Cr}\{x_1 + x_3^2 = 3\} + d_1^- - d_1^+ = 0.95, \\ \text{Cr}\{x_2 + x_3^2 = 2\} + d_2^- - d_2^+ = 0.90, \\ \text{Cr}\{x_4 + x_3^2 = 1\} + d_3^- - d_3^+ = 0.85; \\ x_1 + x_2 \leq \tilde{a}, x_3 + x_4 \leq \tilde{b}, \\ x_5 \leq \tilde{c}, x_6 \leq \tilde{d}; \\ x_i \geq 0, i = 1, 2, \dots, 6; \\ d_i^+, d_i^- \geq 0, i = 1, 2, 3. \end{cases} \quad (11)$$

其中:  $\tilde{a}, \tilde{b}$  和  $\tilde{c}$  分别为三角模糊变量  $(3, 4, 5), (2, 3, 4)$  和  $(1, 2, 3)$ , 模糊变量  $\tilde{d}$  的隶属度函数为  $\mu_{\tilde{d}}(\xi) = 1/[1 + (\xi - 1)^2]$ .

同例 1 的分析方法, 根据不确定原理, 模型 (11) 的事件  $\xi_1, \xi_2, \xi_3$  的机会函数  $f_1(x), f_2(x), f_3(x)$  分别为

$$\begin{aligned} f_1(x) &= \text{Cr}\{x_1 + x_3^2 = 3, x_1 + x_2 \leq \tilde{a}, \\ & x_3 + x_4 \leq \tilde{b}, x_1, x_2, x_3, x_4 \geq 0\}, \\ f_2(x) &= \text{Cr}\{x_2 + x_3^2 = 2, x_1 + x_2 \leq \tilde{a}, \\ & x_5 \leq \tilde{c}, x_1, x_2, x_5 \geq 0\}, \\ f_3(x) &= \text{Cr}\{x_4 + x_3^2 = 1, x_3 + x_4 \leq \tilde{b}, \\ & x_6 \leq \tilde{d}, x_3, x_4, x_6 \geq 0\}. \end{aligned}$$

利用 Matlab 编程, 参数设置与例 1 相同. 算法比较结果如表 2 所示, GA 结果参见文献 [15].

表 2 两种算法结果比较

算法	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	最优值
PSO-DE	1.840	0.604	1.077	1.000	1.182	0	0.0990
GA	1.899	0.154	1.049	0.532	1.359	0.684	0.1079

由表 2 可见, GA 和 PSO-DE 算法得到的结果均能满足前 2 个目标,但在第 3 个目标上 GA 得到的结果为 0.1079,而 PSO-DE 得到的结果为 0.0990,优于 GA. 另外,在寻优时间上,PSO-DE 只迭代 40 次便寻找到了最优解,而 GA 却需要迭代 200 次.

## 6 结 论

DE 算法降低了遗传操作的复杂性,其特有的记忆能力可以动态跟踪当前的搜索情况,以调整其搜索策略,具有较强的全局收敛能力和鲁棒性以及强大的全局寻优能力. 模糊相关机会规划模型可以将不确定模糊事件转化为清晰的等价式来解决实际问题,具有广泛的应用价值. 本文利用 PSO 算法的优点,弥补了基本 DE 存在容易早熟、全局寻优效率低等缺点;进而将改进的 DE 算法与模糊模拟技术相结合,设计了一种新的求解模糊相关机会规划的混合智能算法,扩大了 DE 算法的应用范围. 下一步的工作是利用本文算法解决更多具有实际意义的模糊相关机会规划问题,并根据应用效果对算法进行针对性的改进.

## 参考文献(References)

- [1] Storn R, Price K. Differential evolution—A simple and efficient adaptive scheme for global optimization over continuous spaces[J]. *J of Global Optimization*, 1997, 11(3): 41-59.
- [2] Qian W Y, Li A J. Adaptive differential evolution algorithm for multiobjective optimization problems[J]. *Applied Mathematics & Computation*, 2008, 201(1/2): 431-440.
- [3] Pan Q K, Wang L, Qian B. A novel differential evolution algorithm for bi-criteria no-wait flow shop scheduling problems[J]. *Computers & Operations Research*, 2009, 36(8): 2498-2511.
- [4] Maulik U, Saha I. Modified differential evolution based fuzzy clustering for pixel classification in remote sensing imagery[J]. *Pattern Recognition*, 2009, 42(9): 2135-2149.
- [5] Chauhan N, Ravi V, Chandra D K. Differential evolution trained wavelet neural networks: Application to bankruptcy

- prediction in banks[J]. *Expert Systems with Applications*, 2009, 36(4): 7659-7665.
- [6] Liu B D. Dependent chance programming in fuzzy environments[J]. *Fuzzy Sets and Systems*, 2000, 109(1): 133-140.
- [7] Yang L X. Fuzzy fixed charge solid transportation problem and algorithm[J]. *Applied Soft Computing*, 2007, 7(3): 879-889.
- [8] Wu Y, Zhou J, Yang J. Dependent-chance programming model for stochastic network bottleneck capacity expansion based on neural network and genetic algorithm[J]. *Lecture Notes in Computer Science*, 2005, 3612: 120-128.
- [9] 王林, 刘君, 曾宇容, 等. 基于粒子群优化算法和模糊模拟的核电备件模糊 EOQ 模型研究[J]. *系统工程*, 2008, 26(11): 123-126.  
(Wang L, Liu J, Zeng Y R, et al. A fuzzy EOQ inventory model for spare parts in a nuclear power station based on particle swarm optimization algorithm and fuzzy simulation[J]. *System Engineering*, 2008, 26(11): 123-126.)
- [10] Chiou J P, Chang C F, Su C T. Variable scaling hybrid differential evolution for solving network reconfiguration of distribution systems[J]. *IEEE Trans on Power Systems*, 2005, 20(2): 668-674.
- [11] Kaelo P, Ali M M. A numerical study of some modified differential evolution algorithms[J]. *European J of Operational Research*, 2006, 169(3): 1176-1184.
- [12] Oze A B. CIDE: Chaotically initialized differential evolution[J]. *Expert Systems with Applications*, 2010, 37(6): 4632-4641.
- [13] Lei D M. A Pareto archive particle swarm optimization for multi-objective job shop scheduling[J]. *Computers & Industrial Engineering*, 2008, 54(4): 960-971.
- [14] Liu B, Wang L, Jin Y H. An effective hybrid PSO-based algorithm for flow shop scheduling with limited buffers[J]. *Computers & Operations Research*, 2008, 35(9): 2791-2806.
- [15] 刘宝碁, 赵瑞清, 王纲. 不确定规划与应用[M]. 北京: 清华大学出版社, 2003.  
(Liu B D, Zhao R Q, Wang G. Uncertainly programming with applications[M]. Beijing: Tsinghua University Press, 2003.)