

文章编号: 1000-5862(2013)06-0647-05

# 1 个单纯形搜索法和免疫进化的 微粒群算法的混合算法

苗 晨, 刘国志

( 营口理工学院基础教学部 辽宁 营口 115014)

**摘要:** 基于单纯形搜索法和免疫进化微粒群算法, 提出 1 个求解无约束最优化问题的新的混合算法—单纯形搜索法和免疫进化微粒群算法的混合算法. 由于它不需要梯度信息, 所以具有易实施、收敛速度快和计算准确的优点. 为了证明混合算法能够改进免疫进化微粒群算法的性能, 首先利用 6 个测试函数进行仿真计算比较, 计算结果表明, 新的混合算法在求解质量和收敛速率上都优于其它进化算法( IEP SO, PSOPC, GSPSO, LSPSO and CPSO); 其次, 将新混合算法和最新的 3 种混合算法进行鲁棒性分析比较, 结果表明, 新混合算法在解的搜索质量、效率和关于初始点的鲁棒性方面都优于其它算法.

**关键词:** 单纯形搜索法; 微粒群最优化; 无约束最优化; 免疫进化

**中图分类号:** TP 18

**文献标志码:** A

## 0 引言

函数优化在自然科学、多项式及非线性方程组求解和非线性函数的参数估计中有着广泛的应用<sup>[1-11]</sup>. 本文针对求解无约束优化问题  $\min f(x)$ ,  $x \in \mathbf{R}^n$ , 提出 1 个新的混合算法.

Nelder-Mead 单纯形搜索方法是 1 个用于求解无约束优化问题的直接搜索法, 由于它计算简单, 不需要函数导数信息, 因此被广泛应用于求解无约束不可微优化问题. 然而, 这种方法对初始点选择非常灵敏, 以至于不能保证寻找到全局最优解.

免疫进化的微粒群算法由刘国志于 2012 年提出, 它是免疫进化算法和微粒群算法的有机结合, 是一种改进的微粒群算法, 它保留了微粒群算法的优点, 提高了微粒群算法的收敛速度. 然而它与传统的直接搜索法(如 Hook-Jeeves 法和 Nelder-Mead 单纯形搜索法)相比收敛速度还是较慢.

为了克服免疫进化的微粒群算法收敛速度慢的缺点, 充分利用免疫进化的微粒群算法全局寻优能力强和 Nelder-Mead 单纯形搜索法的快速收敛性, 本文提出 1 个与单纯形搜索法相结合的免疫进化的微粒群算法的混合算法, 该算法继承了 2 种算法的优点, 克服了 2 种算法的缺点, 通过算例验证了混合

算法的有效性.

## 1 免疫进化的微粒群算法

令  $D$  表示搜索空间的维数,  $g_i = (g_{i1}, g_{i2}, \dots, g_{iD})$  表示微粒  $i$  曾经达到的最好位置,  $s_i = (s_{i1}, s_{i2}, \dots, s_{iD})$  表示微粒  $i$  当前的位置, 用  $b$  表示种群中最优微粒的序号, 用  $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})$  表示微粒  $i$  的速度. 微粒  $i$  根据 (1) 式来更新自己的速度、标准差和位置:

$$\begin{cases} v_i^{k+1} = \omega_i^k v_i^k + c_1 \text{rand}(\cdot) (g_i^k - s_i^k) + \\ c_2 \text{Rand}(\cdot) (g_b - s_i^k), \\ \delta^{k+1} = \delta^k \exp(-Ak/T), \\ s_i^{k+1} = s_i^k + v_i^{k+1} + \delta^{k+1} N(0, 1), \end{cases} \quad (1)$$

其中  $\text{rand}(\cdot)$  和  $\text{Rand}(\cdot)$  是  $[0, 1]$  区间的随机数,  $c_1, c_2$  为学习因子,  $k$  表示进化代数,  $\omega_i^k$  为惯性权重,  $T$  是总的进化代数,  $\delta^k$  表示第  $k$  代群体的标准差 ( $\delta^0 \in [1, 3]$ ),  $A$  是标准差动态调整系数 ( $A \in [1, 10]$ ),  $N(0, 1)$  是产生服从标准正态分布的随机数.

## 2 Nelder-Mead 单纯形搜索方法

Nelder-Mead 单纯形搜索方法是建立在

收稿日期: 2013-06-21

基金项目: 辽宁省自然科学基金(001084)资助项目.

作者简介: 苗 晨(1965-), 男, 辽宁锦州人, 副教授, 主要从事最优化理论与算法、智能算法的研究.

Spendley 等的工作基础上的一种局部搜索方法,其计算步骤为

(i) 给定初始单纯形,其顶点  $x^{(i)} \in \mathbf{R}^n (i = 1, 2, \dots, n+1)$  按如下确定: 给定初始点  $x^{(1)}$  及步长  $d$  后,可定义其它点为  $x^{(i)} = x^{(1)} + de_i (i = 2, 3, \dots, n+1)$ , 其中  $e_i$  为  $n$  维单位坐标向量. 反射系数  $\alpha > 0$  扩展系数  $\gamma > 1$  压缩系数  $\beta \in (0, 1)$  允许误差  $\varepsilon > 0$ , 计算函数值  $f(x^{(i)}) (i = 1, 2, \dots, n+1)$  置  $k = 1$ ;

(ii) 确定最高点  $x^{(h)}$ , 次高点  $x^{(g)}$ , 最低点  $x^{(l)}$ , 使得

$$f(x^{(h)}) = \max \{f(x^{(1)}), f(x^{(2)}), \dots, f(x^{(n+1)})\},$$

$$f(x^{(g)}) = \max \{f(x^{(i)}) \mid x^{(i)} \neq x^{(h)}\},$$

$$f(x^{(l)}) = \min \{f(x^{(1)}), f(x^{(2)}), \dots, f(x^{(n+1)})\},$$

计算除  $x^{(h)}$  外的  $n$  个点的形心  $\bar{x}$ , 令

$$\bar{x} = \frac{1}{n} \left[ \sum_{i=1}^{n+1} x^{(i)} - x^{(h)} \right],$$

计算出  $f(\bar{x})$ ;

(iii) 进行反射, 令  $x^{(n+2)} = \bar{x} + \alpha(\bar{x} - x^{(h)})$ , 计算  $f(x^{(n+2)})$ ;

(iv) 若  $f(x^{(n+2)}) < f(x^{(l)})$  则进行扩展, 令

$$x^{(n+3)} = \bar{x} + \gamma(x^{(n+2)} - \bar{x}),$$

计算  $f(x^{(n+3)})$  转步骤(v); 若  $f(x^{(l)}) \leq f(x^{(n+2)}) \leq f(x^{(g)})$  则置  $x^{(h)} = x^{(n+2)}$   $f(x^{(h)}) = f(x^{(n+2)})$  转步骤(vii); 若  $f(x^{(n+2)}) > f(x^{(g)})$  则进行压缩, 令

$$f(x^{(h)}) = \min \{f(x^{(h)}), f(x^{(n+2)})\},$$

其中  $h' \in \{h, n+2\}$ . 令  $x^{(n+4)} = \bar{x} + \beta(x^{(h')} - \bar{x})$ , 计算  $f(x^{(n+4)})$  转步骤(vi);

(v) 若  $f(x^{(n+3)}) < f(x^{(n+2)})$  则置  $x^{(h)} = x^{(n+3)}$ ,  $f(x^{(h)}) = f(x^{(n+3)})$ , 转步骤(vii); 否则, 置  $x^{(h)} = x^{(n+2)}$   $f(x^{(h)}) = f(x^{(n+2)})$  转步骤(vii);

(vi) 若  $f(x^{(n+4)}) \leq f(x^{(h)})$  则置  $x^{(h)} = x^{(n+4)}$ ,  $f(x^{(h)}) = f(x^{(n+4)})$  转步骤(vii); 否则进行压缩, 令

$$x^{(i)} = x^{(i)} + (x^{(l)} - x^{(i)}) / \delta \quad i = 1, 2, \dots, n+1,$$

计算  $f(x^{(i)}) (i = 1, 2, \dots, n+1)$  转步骤(vii);

(vii) 检验是否满足收敛准则. 若

$$\left\{ \sum_{i=1}^{n+1} [f(x^{(i)}) - f(\bar{x})]^2 / (n+1) \right\}^{1/2} < \varepsilon,$$

则停止计算, 现行最好点可作为极小点的近似; 否则, 置  $k = k + 1$  返回步骤(ii).

### 3 单纯形搜索法和免疫进化的微粒群算法的混合算法

单纯形搜索法是直接搜索法中比较有效的一种

算法, 计算量小、收敛速度快, 但却不能保证收敛到全局最优解. 而免疫进化 PSO 算法在寻找全局最优解时, 不需要局部信息, 并且很少陷入到局部最优, 但它的计算成本相对较高. 免疫进化 PSO 算法重点在于探索即对于全局的开发; 而单纯形搜索法重点在于局部的开发以便达到更加精细的结果.

因此, 为了更好的利用每个算法的优点, 本文提出了 1 个混合算法(与单纯形搜索法相结合的免疫进化微粒群算法). 通过对微粒群算法和单纯形搜索法的改进, 使这种混合算法具有更加精确和快速地收敛到全局最优.

混合 NM-IEPSO 算法具体流程如下:

(i) 初始化一群微粒(群体规模为  $n+1$ );

(ii) 计算和排序. 计算每个微粒的适应值, 然后根据适应值从小到大排序;

(iii) 调用 Nelder-Mead 单纯形算法, 更新  $n+1$  个微粒;

(iv) 调用免疫进化微粒群算法更新  $n+1$  个微粒;

(v) 若达到停止准则, 则停止, 并输出结果; 否则, 转到步骤(ii).

## 4 数值实验

### 4.1 测试函数

在实验中, 为了评价比较单纯形搜索法和免疫进化微粒群算法的混合算法与其它进化算法的性能, 选择如下的著名的测试函数:

(i) Sphere 模型:  $f_1(x) = \sum_{i=1}^{30} x_i$ , 可行解空间  $[-100, 100]^{30}$ , 最优值  $f_{\min} = 0$ ;

(ii) Schwefel 问题 1.2:  $f_2(x) = \sum_{i=1}^{30} \left( \sum_{j=1}^i x_j \right)^2$ , 可行解空间  $[-100, 100]^{30}$ , 最优值  $f_{\min} = 0$ ;

(iii) Schwefel 问题 2.21:  $f_3(x) = \max\{|x_i| \mid 1 \leq i \leq 30\}$ , 可行解空间  $[-100, 100]^{30}$ , 最优值  $f_{\min} = 0$ ;

(iv) Generalized Rastrigin 函数:  $f_4(x) = \sum_{i=1}^{30} (x_i^2 - 10 \cos(2\pi x_i) + 10)^2$ , 可行解空间  $[-100, 100]^{30}$ , 最优值  $f_{\min} = 0$ ;

(v) Ackley 函数:

$$f_5(x) = -20 \exp \left( -0.2 \sqrt{\frac{1}{30} \sum_{i=1}^{30} x_i} \right) -$$

$$\exp \left( \frac{1}{30} \sum_{i=1}^{30} \cos(2\pi x_i) \right) + 20 + e,$$

可行解空间  $[-100, 100]^{30}$  , 最优值  $f_{\min} = 0$  ;

( vi) Generalized Griewank 函数:

$$f_6(x) = \frac{1}{4000} \sum_{i=1}^{30} (x_i - 100)^2 - \prod_{i=1}^{30} \cos\left(\frac{x_i - 100}{\sqrt{i}}\right) + 1 ,$$

可行解空间  $[-600, 600]^{30}$  , 最优值  $f_{\min} = 0$  .

上述测试函数被广泛用于测试算法的性能 , 函数  $f_1 - f_3$  是单峰值函数 ,  $f_4 - f_6$  是多峰值函数且其局部极小点的个数随着维数的增加按指数级增长 .

### 4.2 灵敏度分析

利用 6 个测试函数对混合算法 NM-IEPSO 中的参数进行研究 . 采用文献 [2] 中的成功率和平均迭代次数作为评判标准 . 参数选择过程中 , 假定参数之间相互影响忽略不计 , 它们彼此是相互独立的 , 每一次灵敏度分析 , 只有 1 个参数变化 , 其余参数不变 . 其参数选择如表 6 所示 .

表 1 和表 2 列出了参数  $c_1$  和  $c_2$  的分析结果 . 在这些分析中 ,  $c_1$  和  $c_2$  的变化范围为  $[0.2, 1.2]$  . 从表 1 可以看出 , 当  $c_1 = 1.0$  和  $c_1 = 1.2$  时 6 个测试函数获得的成功率和平均迭代次数最好 ; 从表 2 可以看出 , 当  $c_2 = 0.4$  时 6 个测试函数获得的成功率和平均迭代次数最好 .

表 3 ~ 表 5 分别列出了当  $\delta^0 = 1.0, 2.0, 3.0$  时 , 参数  $A$  的分析结果 . 在这些分析中 ,  $A$  的变化范围为  $[1, 10]$  . 从表 3 ~ 表 5 可以看出 , 当  $\delta^0 = 3.0$  ,  $A = 3.0$  时 6 个测试函数获得的成功率和平均迭代

次数最好 .

### 4.3 参数设置

每个函数评价次数 2 000 , 算法每次测试独立运行 50 次 . 标准差动态调整系数  $A = 3.0$  , 初始化标准差  $\delta^0 = 3.0$  , 种群大小  $n + 1$  , 最大的惯性权重  $w_{\max} = 0.9$  , 最小的惯性权重  $w_{\min} = 0.2$  , 最大速度  $v_{\max} = 10.0$  , 学习因子  $c_1 = 1.2, c_2 = 0.4$  .

### 4.4 实验结果与比较

本文提出的单纯形搜索法和免疫进化的微粒群算法的混合算法 ( NM-IEPSO) 与 IEPSO, PSOPC, GPSO, LPSO, CPSO 关于每一测试函数的实验结果 ( 即独立运行 50 次函数值的平均值和标准差) 列于表 7 中 .

从表 7 可以看出 , NM-IEPSO 的计算结果都优于其它的进化算法 . 除  $f_3$  和  $f_5$  外 , 几乎是全局最优解 .

其次 NM-IEPSO 与 POWELL-PSO, HOOK-JEEVES-PSO, NM-PSO 关于每个测试函数进行鲁棒性分析比较 , 其结果列于表 8 中 .

从表 8 可以看出 , NM-IEPSO 计算结果优于 HOOK-JEEVES-PSO, NM-PSO 除函数  $f_3$  外 , 稍逊于 POWELL-PSO ; 由于 POWELL-PSO 只适用于求解可微函数的最优解问题 , 而对不可微优化问题无能为力 , 所以 NM-IEPSO 对不可微优化问题优于 POWELL-PSO .

表 1 系数  $c_1$  的灵敏度分析

$c_1$	$f_1$	$f_2$	$f_3$	$f_4$	$f_5$	$f_6$
	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)
0.2	0%(2 000)	0%(2 000)	0%(2 000)	100%(574)	100%(919)	100%(543)
0.4	0%(2 000)	0%(2 000)	0%(2 000)	100%(399)	100%(641)	100%(397)
0.6	10%(1 985)	0%(2 000)	0%(2 000)	100%(331)	100%(528)	100%(334)
0.8	95%(1 860)	75%(1 893)	95%(1 880)	100%(289)	100%(470)	100%(302)
1.0	100%(1 770)	100%(1 812)	100%(1 790)	100%(264)	100%(434)	100%(276)
1.2	100%(1 790)	100%(1 864)	100%(1 803)	100%(256)	100%(419)	100%(268)

表 2 系数  $c_2$  的灵敏度分析

$c_2$	$f_1$	$f_2$	$f_3$	$f_4$	$f_5$	$f_6$
	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)
0.2	100%(1 300)	100%(1 331)	100%(1 209)	100%(216)	100%(371)	100%(242)
0.4	100%(1 182)	100%(1 215)	100%(1 154)	100%(198)	100%(324)	100%(223)
0.6	100%(1 205)	100%(1 249)	100%(1 209)	100%(202)	100%(329)	100%(224)
0.8	100%(1 317)	100%(1 348)	100%(1 313)	100%(213)	100%(341)	100%(233)
1.0	100%(1 498)	100%(1 556)	100%(1 150)	100%(229)	100%(375)	100%(247)
1.2	100%(1 790)	100%(1 864)	100%(1 803)	100%(256)	100%(419)	100%(268)

表 3 系数  $A$  的灵敏度分析( $\delta^0 = 1.0$ )

$A$	$f_1$	$f_2$	$f_3$	$f_4$	$f_5$	$f_6$
	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)
10	100%(1 180)	100%(1 217)	100%(1 159)	100%(198)	100%(326)	100%(222)
9	100%(1 181)	100%(1 217)	100%(1 159)	100%(198)	100%(324)	100%(222)
8	100%(1 179)	100%(1 210)	100%(1 151)	100%(198)	100%(324)	100%(222)
7	100%(1 174)	100%(1 209)	100%(1 146)	100%(198)	100%(324)	100%(222)
6	100%(1 174)	100%(1 219)	100%(1 153)	100%(201)	100%(328)	100%(222)
5	100%(1 177)	100%(1 215)	100%(1 149)	100%(201)	100%(328)	100%(222)
4	100%(1 179)	100%(1 215)	100%(1 154)	100%(201)	100%(323)	100%(222)
3	100%(1 179)	100%(1 215)	100%(1 146)	100%(201)	100%(324)	100%(222)
2	100%(1 181)	100%(1 213)	100%(1 145)	100%(201)	100%(325)	100%(222)
1	100%(1 180)	100%(1 214)	100%(1 154)	100%(199)	100%(326)	100%(222)

表 4 系数  $A$  的灵敏度分析( $\delta = 2.0$ )

$A$	$f_1$	$f_2$	$f_3$	$f_4$	$f_5$	$f_6$
	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)
10	100%(1 184)	100%(1 209)	100%(1 147)	100%(198)	100%(321)	100%(222)
9	100%(1 177)	100%(1 218)	100%(1 154)	100%(198)	100%(321)	100%(222)
8	100%(1 177)	100%(1 216)	100%(1 150)	100%(198)	100%(328)	100%(222)
7	100%(1 184)	100%(1 219)	100%(1 149)	100%(198)	100%(321)	100%(222)
6	100%(1 184)	100%(1 217)	100%(1 145)	100%(198)	100%(324)	100%(222)
5	100%(1 182)	100%(1 215)	100%(1 154)	100%(198)	100%(324)	100%(222)
4	100%(1 182)	100%(1 219)	100%(1 150)	100%(199)	100%(328)	100%(222)
3	100%(1 184)	100%(1 216)	100%(1 152)	100%(201)	100%(328)	100%(222)
2	100%(1 182)	100%(1 215)	100%(1 149)	100%(200)	100%(324)	100%(222)
1	100%(1 183)	100%(1 215)	100%(1 150)	100%(199)	100%(328)	100%(222)

表 5 系数  $A$  的灵敏度分析( $\delta = 3.0$ )

$A$	$f_1$	$f_2$	$f_3$	$f_4$	$f_5$	$f_6$
	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)	成功率(平均迭代次数)
10	100%(1 177)	100%(1 208)	100%(1 151)	100%(198)	100%(326)	100%(222)
9	100%(1 185)	100%(1 208)	100%(1 149)	100%(198)	100%(324)	100%(222)
8	100%(1 180)	100%(1 213)	100%(1 149)	100%(198)	100%(328)	100%(222)
7	100%(1 180)	100%(1 210)	100%(1 149)	100%(198)	100%(323)	100%(222)
6	100%(1 174)	100%(1 217)	100%(1 154)	100%(201)	100%(326)	100%(222)
5	100%(1 174)	100%(1 206)	100%(1 157)	100%(198)	100%(324)	100%(222)
4	100%(1 180)	100%(1 215)	100%(1 154)	100%(198)	100%(323)	100%(222)
3	100%(1 173)	100%(1 210)	100%(1 146)	100%(198)	100%(322)	100%(223)
2	100%(1 174)	100%(1 209)	100%(1 147)	100%(199)	100%(323)	100%(225)
1	100%(1 174)	100%(1 211)	100%(1 149)	100%(200)	100%(323)	100%(222)

表 6 关于 NM-IEPSO 参数的最佳建议

NM-IEPSO 参数	原始值	最佳建议值
$c_1$	1.20	1.20
$c_2$	1.20	0.40
初始标准差系数 $\delta^0$	2.00	3.00
标准差动态调整系数 $A$	5.00	3.00

表 7 各种算法计算结果比较

函数	函数平均值(标准差)					
	NM-IEPSO	IEPSO	PSOPC	GSPSO	LSPSO	CPSO
$f_1$	4.25e-120 (4.35e-120)	1.6e-52 (6.9e-52)	9.5e-29 (5.9e-28)	1.9e-12 (3.7e-12)	3.0e-3 (5.3e-3)	2.3e-15 (4.9e-15)
$f_2$	2.87e-122 (2.91e-122)	1.2e-24 (4.2e-24)	2.71 (2.79)	62.33 (34.69)	1 805.03 (458.70)	2.29 (1.99)
$f_3$	9.78e-61 (9.25e-61)	4.8e-11 (1.4e-10)	7.5e-3 (1.0e-2)	1.2 (5.1e-1)	11.37 (1.93)	6.1e-2 (4.2e-2)
$f_4$	1.0e-323 (1.0e-323)	0.855 4 (0.848 3)	2.91 (1.65)	21.56 (5.12)	59.07 (10.00)	43.76 (12.13)
$f_5$	5.88e-16 (5.75e-16)	1.8e-14 (3.3e-15)	2.3e-14 (2.2e-14)	9.0e-8 (9.3e-8)	1.41 (8.6e-1)	1.6e-8 (1.8e-8)
$f_6$	1.0e-323 (1.0e-323)	1.2e-2 (1.4e-2)	3.2e-3 (5.6e-3)	1.4e-2 (1.6e-2)	9.6e-2 (1.0e-2)	1.9e-2 (2.0e-2)

表 8 4 种混合算法的鲁棒性分析

函数	POWELL-PSO		HOOK-JEEVES-PSO		NM-PSO		NM-IEPSO		精度
	平均迭代次数	达优率/%	平均迭代次数	达优率/%	平均迭代次数	达优率/%	平均迭代次数	达优率/%	
$f_1$	750	100	2 000	0	1 806	100	1 173	100	5.0e-120
$f_2$	745	100	2 000	0	1 872	90	1 210	100	3.0e-122
$f_3$	/	/	2 000	0	1 828	100	1 146	100	1.0e-60
$f_4$	121	100	2 000	0	258	100	198	100	1.0e-323
$f_5$	142	100	2 000	0	423	100	322	100	5.9e-016
$f_6$	135	100	2 000	0	269	100	223	100	1.0e-323

### 5 结论

本文在单纯形搜索法和免疫进化微粒群算法的基础上提出了 1 个新的混合算法. 利用 6 个典型测试函数进行计算比较. 结果表明, 该算法继承了 2 种算法的优点, 克服了 2 种算法的缺点. NM-IEPSO 的计算结果都优于其它的 5 种进化算法. 另外 NM-IEPSO 与 POWELL-PSO, HOOK-JEEVES-PSO, NM-PSO 进行鲁棒性分析比较, NM-IEPSO 优于 HOOK-JEEVES-PSO 和 NM-PSO 的 2 种混合算法, 而与 POWELL-PSO 相当, 对于不可微优化问题优于 POWELL-PSO.

### 6 参考文献

[1] He Shan, Wu Q Henry, Wen Jinyu et al. A particle swarm optimizer with passive congregation [J]. BioSystems 2004, 78(1/2/3): 135-147.  
 [2] Fan Shu-Kai S, Erwie Zahara. A hybrid simplex search and particle swarm optimization for unstrained optimization [J]. European J of Operational Research 2007, 182(2):

527-548.  
 [3] 刘国志, 刘倩囡. 箱型约束优化问题的免疫进化的算法 [J]. 长春理工大学学报 2012, 35(3): 89-92.  
 [4] 刘国志. 一个求解约束优化问题的混合算法 [J]. 江西师范大学学报: 自然科学版 2011, 35(1): 50-53.  
 [5] 刘国志, 苗晨. 一个与 POWELL 搜索相结合的混合免疫进化算法 [J]. 江西师范大学学报: 自然科学版, 2010, 34(1): 53-56.  
 [6] 李俊武, 俞志富. 改进粒子群算法在 DOA 估计中的应用 [J]. 计算机工程与应用 2013, 49(9): 203-206.  
 [7] 陈义雄, 梁昔明, 黄亚飞. 一种改进的混合量子粒子群优化算法 [J]. 计算机工程 2013, 39(8): 253-256.  
 [8] 仲昭明, 李向阳. 混合择优的多目标免疫进化粒子群算法 [J]. 计算机工程与应用 2013, 49(13): 43-47.  
 [9] 刘国志. 求解非线性极大极小问题的一种新的混合算法 [J]. 长春理工大学学报 2011, 34(4): 164-166.  
 [10] 刘国志, 刘倩囡. 关于约束工程设计问题的一个新的混合算法 [J]. 长春理工大学学报, 2012, 35(1): 119-121.  
 [11] 刘国志, 苗晨. Powell 搜索法和惯性权重非线性调整局部收缩微粒群算法相结合的混合算法 [J]. 吉林大学学报: 自然科学版 2008, 46(6): 1149-1154.

(下转第 656 页)

- [10] Juan Ramón Barrada ,Paloma Mazuela ,Julio Olea. Maximum information stratification method for controlling item exposure in computerized adaptive testing [J]. *Psicothema* 2006 ,18( 1) :156-159.
- [11] 程小扬,丁树良,严深海,等. 引入曝光因子的计算机化自适应测验选题策略 [J]. *心理学报* ,2011 ,43( 2) :203-212.
- [12] 程小扬,丁树良. 子题库题量不平衡的按  $\alpha$  分层选题策略 [J]. *江西师范大学学报:自然科学版* 2011 ,35( 1) :5-9.
- [13] 汤楠,丁树良,余丹. 结合优先级指标和曝光因子的多级评分选题策略 [J]. *江西师范大学学报:自然科学版* 2011 ,35( 6) :646-650.

## Similar Distributed Stratification Method for Computerized Adaptive Testing

ZHANG Hu-chao ,DING Shu-liang\*

( College of Computer Information Engineer ,Jiangxi Normal University ,Nanchang Jiangxi 330022 ,China)

**Abstract:** Item selection method is a key part of computerized adaptive testing ,it will have a direct impact on accuracy ,safety ,efficiency and reliability of the testing. Besides ,stratified method is a most important part of item selection method. For the relatively high item exposure rate shortcoming against  $\alpha$ -stratified(  $\alpha$ -STR) and maximum information stratification( MIS) method ,two kinds of methods are proposed: similar distributions of discrimination parameters/maximum information stratification( A-SDS/MI-SDS) . The results of the Matlab simulation study show that the new item selection methods obtain lower average exposure rates than  $\alpha$ -STR and MIS methods while maintaining the approximate accuracy and efficiency of testing.

**Key words:** computerized adaptive testing; item selection method; similar distributions of discrimination parameters stratification; similar distributions of maximum information stratification

( 责任编辑: 冉小晓)

( 上接第 651 页)

## A Hybrid Simplex Search and Particle Swarm Optimization Algorithm with Immune Evolutionary

MIAO Chen ,LIU Guo-zhi

( Department of Fundamental Teaching ,Yingkou Institute of Technology ,Yingkou Liaoning 115014 ,China)

**Abstract:** The hybrid NM-IEPSO algorithm is proposed based on the Nelder-mead( NM) simplex search method and particle swarm optimization algorithm with immune evolutionary( IEPSO) for unstrained optimization. NM-IEPSO is very easy to implement in practice since it does not require gradient computation and intends to produce faster and more accurate convergence. The main propose is to demonstrate how the IEPSO can be improved by incorporating a hybridization strategy. In a suit of 6 test function problems taken from the literature ,computational results ,show that the hybrid NM-IEPSO approach outperforms five relevant search techniques( i. e. ,IEPSO ,PSOPC ,GSPSO ,LSPSO and CPSO) in terms of solution quality and convergence rate. In a later part of the comparative experiment ,the NM-IEPSO algorithm is compared to three hybrid algorithms procedures appearing in the literature. The comparison report still largely favors the NM-IEPSO algorithm in the performance of accuracy ,robustness and function evaluation. As evidenced by the overall assessment based on two kinds of computational experience ,the new algorithm has demonstrated to be extremely effective and efficient at locating best-practice optimal solutions for unstrained optimization.

**Key words:** simplex search method; particle swarm optimization; unstrained optimization; immune evolutionary

( 责任编辑: 曾剑锋)