

## 非达尔文效应多目标免疫算法

宋丹<sup>1,2,3</sup>, 赖旭芝<sup>1,2</sup>, 吴敏<sup>1,2†</sup>

(1. 中南大学信息科学与工程学院, 湖南长沙 410083;

2. 先进控制与智能自动化湖南省工程实验室, 湖南长沙 410083; 3. 湖南财政经济学院信息管理学系, 湖南长沙 410205)

**摘要:** 为了强化非基因信息的传承与利用, 提出一种非达尔文效应多目标免疫算法(non-Darwin effect multi-objective immune algorithm, NDIA). 首先, 利用区间记忆变异矩阵来保存进化中成功变异的区间信息, 以引导后续的进化操作, 加强局部搜索能力. 其次, 算法使用Pareto排序来选择非劣解. 当非劣解的数量超出预设规模时, 利用拥挤距离进行排序来选择相对稀疏的抗体保留. 最后, 算法对最后的非劣解集进行删减时设计了均匀度增强算子, 通过多次拥挤距离的排序反复删减最拥挤的抗体, 从而提高非劣解集在目标空间上的均匀性. 通过多目标测试函数的仿真试验, 与经典的多目标进化算法相比, 新算法得到的最终解集在覆盖性、收敛性和分布性均有明显的改善, 并能更好地逼近理论Pareto前沿.

**关键词:** 多目标问题; 非达尔文效应; 区间变异; 免疫算法; 优化; 拥挤距离

中图分类号: TP18 文献标识码: A

## Non-Darwin effect multi-objective immune algorithm

SONG Dan<sup>1,2,3</sup>, LAI Xu-zhi<sup>1,2</sup>, WU Min<sup>1,2†</sup>

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

2. Hunan Engineering Laboratory for Advanced Control and Intelligent Automation, Changsha Hunan 410083, China;

3. Department of Information Management, Hunan University of Finance and Economics, Changsha Hunan 410205, China)

**Abstract:** In order to strengthen the heritage and the exploitation of the non-genetic information, we propose the non-Darwin effect multi-objective immune algorithm (NDIA). Firstly, the range memory mutation matrix is used to store the information of the successful mutation range and then to guide subsequent evolution operations, which strengthens the ability of local search. Secondly, the algorithm uses Pareto order to choose non-inferior solutions. When the number of non-inferior solutions is bigger than the preseted value, the order constructed based on the crowded distance is applied to choose the relatively sparse antibody. Finally, the algorithm defines a homogeneous degree enhancement operator to reduce the final non-inferior solutions, and the homogeneous degree in the target space is increased after the repeated deletion of the most crowded antibodies. Based on the results of the simulation tests on several multi-objective optimization problems and the comparison with many classical methods, the resulting set of solutions provided by the proposed method is greatly improved in the spread ability, convergence, diversity, and can converge to global Pareto optimal front quickly.

**Key words:** multi-objective problem; non-Darwin effect; range variation; immune algorithm; optimization; crowded distance

### 1 引言(Introduction)

现实世界中的优化问题通常是多属性的, 一般是对多个目标的同时优化. 因此, 无论是科学研究还是工程应用方面, 多目标优化问题(multi-objective optimization problems, MOPs)都是非常重要的研究课题.

公茂果等提出进化多目标算法按其特征可以划分为3代<sup>[1]</sup>. 第1代进化多目标优化算法的特点是采用基于Pareto等级的个体选择方法和基于适应度共享机制的种群多样性保持策略, 如非劣分类遗传算法(nondo-

minated sorting genetic algorithm, NSGA)<sup>[2]</sup>. 第2代算法以精英保留为特征: 1999年, Zitzler等提出强度Pareto进化算法(strength pareto evolutionary algorithm, SPEA)<sup>[3]</sup>, 3年之后, 又提出改进版本SPEA2<sup>[4]</sup>; 同年, Deb在NSGA的基础上也提出改进版本NSGA2<sup>[5]</sup>, 此算法与SPEA2广泛应用于MOP的对比实验中. 第3代算法的主要特征表现在新占优机制和新型进化范例的引入, 如Mezura Montes等提出群体中最好的不可行解以一定的概率可以继续生存<sup>[6]</sup>. 这

收稿日期: 2012-10-14; 收修改稿日期: 2013-06-09.

†通信作者. E-mail: min@csu.edu.cn.

基金项目: 国家自然科学基金资助项目(60874042); 湖南省教育厅科学研究重点资助项目(13A010) 湖南省教育厅科学研究青年资助项目(12B021); 湖南省普通高校教改资助项目(20130511); 湖南省科技厅科技计划资助项目(2013FJ3079, 2011FJ3047).

种新的占优机制在全局最优解位于可行域边界上时有十分重要的作用. 2005年, Cai和Wang提出的CW (Cai Wang)算法采用一种不可行解存档和替换机制, 旨在引导群体快速向可行域逼近<sup>[7]</sup>. 2007年, Alfredo和Coello Coello等提出Pareto自适应占优<sup>[8]</sup>. Liu和Yang等进一步改进基于占优的多目标优化方法<sup>[9-10]</sup>. 新型进化范例的一个重要方面是人工免疫系统. 代表性的算法有Gong和Jiao等人基于免疫算法提出非劣邻域免疫算法(nondominated neighbor-based selection immune algorithm, NNIA)<sup>[11]</sup>, 在面对目标个数为9的DTLZ问题时, 仍能表现出较为令人满意的性能. 与进化计算相比, 人工免疫表现出较为优异的特性, 如能有效克服早熟收敛、骗等进化计算难以解决的问题<sup>[12-13]</sup>. 2011年, 林浒、彭勇为了增强人工免疫算法对决策空间的开发能力, 引入佳点搜索方法提出了面向多目标优化的适应度共享免疫克隆算法<sup>[14]</sup>. 2012年, 尚荣华、焦李成等提出修正免疫克隆约束优化算法<sup>[15]</sup>, 设计了一个修正算法对个体的目标函数值进行修正, 并在进化中对非支配可行解和约束偏离值小的不可行解进行有效利用.

不少学者对进化算法的学习机制进行研究与改进: 如SPEA与SPEA2采用外部档案保留非劣解以提高算法整体收敛性<sup>[3-4]</sup>; CW算法则对不可行解选择性存档以利于群体通过不可行区域<sup>[7]</sup>; 王君等对局部最优Pareto解进行记忆并进行禁忌搜索以减少重复搜索<sup>[16]</sup>; 钱洁等采用群体统计学习的方法构建整个种群的吸引子<sup>[17]</sup>, 其记忆的本质仍是遗传信息, 是对群体的优秀基因信息统计后的综合信息. 综合上述文献, 其学习机制侧重记忆优秀解、优秀基因片段和综合基因, 重视遗传信息(基因)对性状的作用, 但较少关注非达尔文效应(非基因信息)对个体进化的推动作用.

非达尔文效应指生物代间进化中具有的基于非基因信息的生物体进化现象, 具体包含技能授予、经验传承等(尤其是人类社会的教育与培训). 它属于一种智能行为导致的效应, 主要表现在高等动物和人类社会中. 如高等动物对后代生存技巧的训练与培育中, 猎豹会教会小猎豹捕捉猎食时机、撕咬猎物颈部等生存技能. 特别的, 这一效应在人类社会得到更多体现, 文字和语言的运用使非达尔文效应记忆库具有无限扩张的潜力, 教育与培训等后天学习机制对个体成长起着至关重要的作用. 而这些效应都不是建立在基因遗传的基础上, 其需要对经验、知识或技能的记忆及对后代的引导与培育.

为了加强进化过程中的非基因遗传信息的记忆和利用, 本文在进化迭代中尝试引入非达尔文效应, 提出非达尔文效应多目标免疫算法(non-darwin effect multi-objective immune algorithm, NDIA).

## 2 多目标优化问题的描述(Description of MOPs)

多目标优化问题包括目标函数, 决策变量和定义域, 其一般结构如下:  $\min f(X) = (f_1(X), \dots, f_i(X), \dots, f_m(X))$ ,  $X = (X_1, \dots, X_j, \dots, X_n)$ ,

$$X_{j\min} \leq X_j \leq X_{j\max}, j = 1, 2, \dots, m, \quad (1)$$

其中:  $X \in \mathbb{R}^n$ 为带有 $n$ 个决策变量的向量, 它构成了决策空间;  $X_{j\min}$ 和 $X_{j\max}$ 为其上下界限;  $f(X) \in \mathbb{R}^m$ 为带有 $m$ 个目标函数的向量, 它构成了目标空间.

一般地, 多目标优化中常用的基本定义如下:

1) Pareto支配: 解 $X_1$ Pareto支配 $X_2$ ( $X_1 \prec X_2$ )当且仅当同时满足

$$f_i(X_1) \leq f_i(X_2), \forall i = 1, 2, \dots, n; \quad (2)$$

$$f_i(X_1) < f_i(X_2), \exists \{i = 1, 2, \dots, n\}. \quad (3)$$

2) Pareto最优: 若 $X$ 是Pareto最优的当且仅当

$$\neg \exists X_i : X_i \prec X. \quad (4)$$

3) Pareto最优集: 所有Pareto最优解构成的矢量集合

$$P_S = \{X | \neg \exists X_i \prec X\}. \quad (5)$$

4) Pareto前沿:  $P_S$ 中的解对应的目标向量组成的集合 $P_F$ :

$$P_F = \{f(X) = (f_1(X), f_2(X), \dots, f_m(X)) | X \in P_S\}. \quad (6)$$

## 3 区间记忆变异策略(Range memory mutation strategy)

基于非达尔文效应, 设计了区间记忆变异算子. 尝试将进化与学习相结合, 在达尔文进化的基础上, 考虑以经验学习以及经验遗传为特征的非达尔文效应(非基因信息)在进化中的作用. 新算法对变异尺度按数值大小划分为若干区间, 并计算祖辈成功变异的变异尺度所属区间, 然后, 设置记忆库对这些区间信息进行记忆, 以引导后续进化. 与传统优化算法相比, 区间记忆变异策略可以在很大程度上减少重复搜索和盲目搜索, 提高整体收敛性能.

在全局解空间, 算法的变异尺度区间field按式(7)计算:

$$\text{field} = \text{floor}((-1) \times \log_{10}^{\text{vrule}}) + 1, \quad (7)$$

其中: floor函数表示取小于或等于该值的最大整数, vrule为个体的变异尺度. 例如, 变异尺度属于区间(0.1, 1), 则区间标号为1; 变异尺度属于区间(0.01, 0.1], 则区间标号为2, ...

区间标号越高, 则变异尺度越小, 其变异在更小的邻域内发生, 其精度则越高. 所以, 高标号区间变异有

利于提高算法精度,低标号区间变异在较大范围内搜索,有利于跳出局部最优解.

设置区间记忆矩阵Array对当代群体的成功变异信息进行区间记忆,以指导后代在该维上的进一步进化.

$$\text{Array} = \{A_{pq}\}, p = 1, 2, \dots, c; q = 1, 2, \dots, j, \quad (8)$$

式(8)中 $A_{pq}$ 表示变量在第 $p$ 维上的第 $q$ 个区间上成功变异次数的累积信息. Array初始化时,每个元素的值都设为 $1/j$ ,表示初始时,在每个区间进行变异的概率是均等的.

每进化一代,会对矩阵Array进行归一化处理,让其每个维度上的元素之和为1.在对成功变异个体进行式(7)的计算后,其更新方法如式(8)所示.

$$A_{pq} = A_{pq} + k \times \frac{1}{j}, \quad (9)$$

式(9)中, $k$ 取值 $[0.5, 2]$ , $k$ 取值越大,则算法进化时表现出的局部收敛速度越快,因此,算法中称 $k$ 为收敛系数.

当克隆后的抗体进行区间记忆变异时,在随机选择变异的维度后,其引导策略如下:按轮盘赌的方式依据Array中对应维度上每个区间的概率来选择产生变异的主区间,然后在该区间或邻近的高标号区间随机生成新的变异尺度.在此,设置概率 $p$ (取值范围 $[0, 0.3]$ )在高标号区间生成,有利于变异尺寸向更高精度发展,加快局部收敛速度.

如图1所示,对应每一次成功变异,算法运用式(7)进行模糊化计算得到区间标号,再运用式(9)对记忆库A进行计算更新,即更新矩阵Array.另一方面,对于后续的每一次变异,算法运用上述的引导策略来指导生成新的变异尺度,在随机生成过程中加入指导性,可以在一定程度上避免盲目搜索,提高局部收敛性能.




图1 区间记忆变异


Fig. 1 Range memory mutation

#### 4 均匀度增强策略(Uniformity enhancement strategy)


NDIA算法在进化迭代中采用拥挤距离排序来“裁剪”非劣解集的规模,考虑算法复杂度,使用一次排序来进行删减较拥挤的个体.图2表示一个2目标最大值优化问题,点线代表Pareto理论前沿,星号代表非劣个体.设定非劣解集规模为10,需要删减3个非劣个

体,通过一次拥挤距离排序会将 $A, B, C$ 3个个体删减,结果如图2(b)所示.删减后形成较大的空白,非劣解集的均匀度降低.


为了有效地维护群体的均匀度,在NDIA算法的进化末端(通常是进化最后的gen代,  $gen \leq g_{max}/N$ ),引入均匀度增强算子.它进行多次排序与删减操作,每次删减拥挤密度最高的个体,反复进行拥挤距离的计算与删减,直到达到预设规模.结果如图2(c)所示,与图2(b)对比,非劣解集在目标空间上的均匀度明显增强.



(a) 删减前的非劣解集



(b) 经拥挤距离一次删减后的非劣解集



(c) 经均匀度增强算子删减后的非劣解集

图2 非劣解集在目标空间的分布

Fig. 2 Non-inferior solutions in the objective space

#### 5 非达尔文效应免疫多目标优化(Non-darwin effect multi-objective immune algorithm)

非达尔文效应关注个体成长中的后天因素,如教育、经验传承等.这些后天因素不同于先天遗传基因,具有较强的灵活性,使个体的生长呈现出更好的多样性和可塑性.将这一机制引入到多目标优化算法中,对群体的多样性及进化的智能性起到积极的推动作用.

生物的免疫响应中存在多样性抗体共生、少数抗体激活进行免疫应答的生物机制. 因此, NDIA算法中选择少数相对稀疏的非劣个体进行激活, 按其拥挤程序进行比例克隆, 对克隆后的抗体进行变异, 以加强对当前Pareto前沿的较稀疏区域的搜索.

### 5.1 选择策略(Selecting strategy)

选择策略主要包含非劣排序和拥挤距离排序. 在确定最优非劣解集时需要进行非劣排序以选择非劣个体, 在缩减非劣解集规模和选择活动个体时使用拥挤距离排序.

非劣排序: 若  $X$  是 Pareto 最优, 即非劣抗体, 当且仅当

$$\neg \exists X_i : X_i \prec X. \quad (10)$$

拥挤距离: 支配抗体种群  $D$  内每个个体的拥挤距离定义如下:

$$\lambda(d, D) = \sum_{i=1}^m \frac{\lambda_i(d, D)}{f_i^{\max} - f_i^{\min}}, \quad (11)$$

式(11)中,  $f_i^{\max}$  和  $f_i^{\min}$  分别指第  $i$  个目标函数的最大值与最小值,  $\lambda_i(d, D)$  取值如下:

$$\lambda_i(d, D) = \begin{cases} \infty, & f_i(d) = \min\{f_i(d') | d' \in D\}, \\ \infty, & f_i(d) = \max\{f_i(d') | d' \in D\}, \\ \min\{f_i(d') - f_i(d'') | d', d'' \in D, \\ & f_i(d'') < f_i(d) < f_i(d')\}, & \text{other,} \end{cases} \quad (12)$$

式(12)中: other分式满足条件  $d', d'' \in D$ , 并且  $f_i(d'') < f_i(d) < f_i(d')$ .

### 5.2 非一致性变异(Non-consistency mutation)

NDIA算法采用分阶段变异策略, 在进化早期, 进化历程的有效经验不足, 采用区间记忆变异的效果不佳, 所以算法采用非一致性变异, 可以加快收敛速度; 在进化中后期, 算法引入区间记忆变异, 可以有效利用进化历程中的经验传承, 加强收敛性能. 其中, 非一致性变异的具体描述如下:

设  $s = (v_1, v_2, \dots, v_n)$  是一个父代抗体, 分量  $v_k$  被选中进行变异, 其定义区间  $[a_k, b_k]$ , 则变异后的解为  $s' = (v_1, v_2, \dots, v'_k, \dots, v_n)$ .

$$v'_k = \begin{cases} v_k + \Delta(it, b_k - v_k), & \text{rand}(2) = 0, \\ v_k + \Delta(it, v_k - a_k), & \text{rand}(2) = 1, \end{cases} \quad (13)$$

式(13)中: rand(2)表示将随机产生的正整数模2所得的结果;  $it$ 为当前进化代数;  $\Delta(it, y)$ 如式(14):

$$\Delta(it, y) = y(1 - r^{(1-it/T)^\lambda}), \quad (14)$$

式(14)中:  $r$ 为  $[0, 1]$ 上的随机数;  $T$ 为最大进化代数, 即  $G_{\max}$ ;  $\lambda$ 是调整局部搜索区域的一个参数, 其取值一般为  $2 \sim 5$ , NDIA算法中取值为2.

### 5.3 比例克隆(Proportion cloning)

对于个体  $A_i$ , 其克隆规模  $C_i$  采用如下公式计算:

$$C_i = \lfloor N_c \times \frac{\lambda(A_i, A)}{\sum_{j=1}^{|A|} \lambda(A_j, A)} \rfloor, \quad (15)$$

式(15)中:  $\lambda(A_i, A)$ 为抗体  $A_i$ 的拥挤距离,  $N_c$ 为克隆后群体规模的期望值. 当抗体的拥挤距离越大, 则克隆次数越多. 而边界解的拥挤距离为无穷大, 在此处计算时, 设定边界解的拥挤距离为非边界解的最大拥挤距离的2倍.

### 5.4 算法描述(Algorithm description)

**Step 1** 初始化. 设置最大进化代数  $G_{\max}$ , 活动群体规模  $N_a$ , 克隆群体规模  $N_c$ , 区间变异记忆矩阵 Array, 随机生成规模为  $N$ 的初始抗体群 POP<sub>0</sub>;

**Step 2** 对抗体群 POP <sub>$t$</sub> 进行非劣排序, 得到非支配抗体集(非劣抗体集)BPOP <sub>$t$</sub> ;

**Step 3** 当BPOP <sub>$t$</sub> 的规模超过  $N$ 时, 据拥挤距离对其进行选择前  $N$ 个保留得到BPPOP <sub>$t$</sub> ';

**Step 4** 如果  $t$ 大于1时, 与BPPOP <sub>$t-1$</sub> '进行比较, 对其进行区间统计: 对BPPOP <sub>$t$</sub> '中出现的新抗体进行变异区间的统计, 并更新矩阵Array, 具体更新策略见第3节;

**Step 5** 据拥挤距离选择前  $N_a$ 个为活动抗体群 APOP <sub>$t$</sub> ;

**Step 6** 按拥挤距离进行比例克隆得到APOP <sub>$t$</sub> ' <sub>$t$</sub> , 克隆后的群体规模为  $N$ ;

**Step 7** 如果  $t < (0.2 \times G_{\max})$ , 进行非一致性变异, 具体方式见5.2节; 否则, 据矩阵Array对APOP <sub>$t$</sub> ' <sub>$t$</sub> 进行区间记忆指导下的变异得到MPOP <sub>$t$</sub> , 具体方式见第3节;

**Step 8** 合并MPOP <sub>$t$</sub> 和BPPOP <sub>$t$</sub> ' <sub>$t$</sub> 组成POP <sub>$t$</sub> ,  $t = t + 1$ ; 检测均匀度增强条件是否满足, 如果是, 转Step 9, 如果不是, 转Step 2;

**Step 9** 均匀度增强算子, 具体策略见第4节. 判断算法终止条件是否满足, 如果不是, 转Step 2, 如果是, 算法结束.

### 5.5 算法复杂性分析(Computational complexity of the proposed algorithm)

依据算法流程进行计算复杂度分析如下( $M$ 表示求解问题的目标数):

Step 2中, NDIA算法通过非劣排序从POP <sub>$t$</sub> (由两部分组成, 分别为最大规模为  $N$ 的BPPOP <sub>$t-1$</sub> 和规模为  $N$ 的MPOP <sub>$t-1$</sub> )中选择出非支配抗体, 其时间复杂度为  $O(M(2N)^2)$ ;

Step 3与Step 5中, 算法通过拥挤距离进行比较, 其时间复杂度为  $O(M(2N)\log(2N)g_{\max})$ ;

Step 4中,算法通过比较进行区间统计,其时间复杂度为 $O(N)$ ;

Step 6与Step 7中,算法进行比例克隆、非一致性变异或区间变异的时间复杂度均为 $O(N)$ ;

Step 9中均匀度增强算子,采用了多次拥挤距离排序,其时间复杂度为 $O(NM(2N)\log(2N))$ .但其最大运算代数数为 $g_{\max}/N$ ;

所以,算法总的时间复杂度为

$$O(M(2N)^2g_{\max}) + O(M(2N)\log(2N)g_{\max}) + O((N)g_{\max}) + O((N)g_{\max}) + O((N)g_{\max}) + O(NM(2N)\log(2N)(g_{\max}/N)),$$

即 $O(M(2N)^2g_{\max}) + O(M(2N)\log(2N)g_{\max})$ .考虑到符号 $O$ 的运算规则,算法总的时间复杂度为 $O(MN^2 \cdot g_{\max})$ .

NSGA-II算法的时间复杂度为 $O(MN^2 \cdot g_{\max})$ ;SPEA与其改进算法SPEA2为 $O(MN^3 \cdot g_{\max})$ ;非一致性算法(non-consistency evolutionary algorithm, NCEA)算法为 $O(MN^2 \cdot g_{\max})$ .因此,算法NDIA, NSGA-II和NCEA的时间复杂度相当, SPEA2算法的时间复杂度仍为种群的立方.

### 6 仿真试验(Experimental study)

为了测试NDIA算法的性能,采用标准测试函数来进行仿真实验(ZDT1, ZDT2, ZDT3, DTLZ1, DTLZ2, DTLZ3, DTLZ4, DTLZ6共8个函数).这些多目标测试问题已被多目标领域的许多研究所采用. ZDT问题的目标个数为2,其 $|X_k|$ 分别设定如下:对ZDT1, ZDT2, ZDT3,  $|X_k| = 30$ . DTLZ问题可以设置任意维数的决策空间和目标空间,本文DTLZ问题的 $k$ 和 $|X_k|$ 设定如下:所有的DTLZ问题,  $k = 3$ ;对DTLZ1,  $|X_k| = 7$ ,对DTLZ2, DTLZ3, DTLZ4,  $|X_k| = 12$ ,对DTLZ6,  $|X_k| = 22$ .

为了比较不同算法的性能差异,采用如下3种性能指标:覆盖性指标 $C$ 、分布性指标 $SP$ 和收敛性指标 $C_v$ .具体如下所示:

$$C(A, B) = \frac{|\{b \in B : \exists a \in A, a \succeq b\}|}{|B|}. \quad (16)$$

指标 $C$ 表示集合 $B$ 中至少被 $A$ 中一个解支配的个体数与集合 $B$ 中个体总数之比.当 $C(A, B)$ 大于 $C(B, A)$ 时,表示解集 $A$ 在非劣排序上整体表现优于解集 $B$ .

$$\begin{cases} SP = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (\bar{d} - d_i)^2}, \\ d_i = \min_{j=1,2,\dots,n} \left( \sum_{k=1}^M |f_k^i - f_k^j| \right) \bar{d} = \frac{1}{n} \sum_{i=1}^n d_i. \end{cases} \quad (17)$$

分布指标 $SP$ 描述非劣解在目标空间上的分布范

围.  $d_i$ 表示在目标空间上与 $i$ 的综合最近距离的解的取,  $SP$ 值越小表示非劣解集越均匀.  $SP$ 的理论最优值为0.

$$\begin{cases} C_v(A) = \left( \sum_{i=1}^{|A|} d_i \right) / |A|, \\ d_i = \min_{j=1}^{|P_F|} \sqrt{\sum_{m=1}^M \left( \frac{f_m(a_i) - f_m(p_j)}{f_m^{\max} - f_m^{\min}} \right)^2}. \end{cases} \quad (18)$$

收敛性指标 $C_v$ 表示非劣解集与理论最优解集之间的距离,式(18)中: $p_j$ 表示理论最优解 $j$ 在目标空间的值,  $m$ 表示第 $m$ 个目标.该指标越小越好,等于零为理论最优.

此数值与理论最优解集的取点规模有关(本文的所有算法均取点100).理论最优解集越大,则指标精度越高.但运算时间成本也越高.

对比算法NSGA2, SPEA2采用模拟二进制交叉和多项式变异,种群规模都为100, SPEA2的外部种群的最大规模为100,为了更好的对比算法的性能,NDIA的种群规模为100,活动种群规模为20,克隆后的种群规模为100.各种算法的终止条件为函数评估次数达到50000,对每个测试函数,每个算法随机运行30次.为了对比变异策略对算法的影响,设计了一个只采用非一致性变异的对比算法,简称非一致性算法(non-consistency evolutionary algorithm, NCEA).

对于ZDT2, DTLZ1, DTLZ3, DTLZ6这4个函数,NDIA算法在中后期的变异方式中采用了混合变异策略,将区间记忆变异与非一致性变异混合,每2代区间记忆变异后进行一代非一致性变异.这样的多样性变异方式使算法能更有效地跳出局部最优的陷阱,强化算法整体的搜索性能.

#### 6.1 C指标(C metric)

表1列出NDIA与其他3种算法关于指标 $C$ 的仿真结果,其中: $I$ 表示NDIA所获得的解,  $N$ 表示NSGA2的解,  $S$ 表示SPEA2的解,  $E$ 表示NCEA的解.考虑到测试的偶然性,表1平均值的统计是删除30次中一个最好值与一个最差值之后的 $C$ 指标平均值.

表1的 $C(I, E)$ 和 $C(E, I)$ 表示NDIA与NCEA2种算法的最终解集的相互覆盖率.在8个标准函数的对比仿真试验中,除DTLZ1外,其余7个函数的 $C(I, E)$ 明显高于 $C(E, I)$ ,表明NDIA的解集覆盖性明显优于NCEA.以DTLZ2函数的最好值为例, NCEA的最终解集(100个抗体)中有86%(即86个抗体)被NDIA的最终解集中的抗体所支配,而NDIA的最终解集的所有抗体皆不被NCEA的最终解集所支配.

NDIA与NSGA2关于 $C$ 指标的对比数据表明,除DTLZ3与DTLZ1外,其余6个函数的 $C(I, N)$ 明显高

于  $C(N, I)$ . 对于 DTLZ3 函数, NSGA2 在最好值与平均值上优于 NDIA, 对于 DTLZ1 函数, NSGA2 在平均值上优于 NDIA. 综合 8 个函数的结果分析, NDIA 的解集覆盖性明显优于 NSGA2.

表 1 的  $C(I, S)$  和  $C(S, I)$  表示 NDIA 与 SPEA2 这两种算法的最终解集的相互覆盖率. 从最具代表性的平均

值来看, 8 个函数中有 ZDT3, DTLZ1, DTLZ2, DTLZ3 和 DTLZ4 这 5 个函数的  $C(I, S)$  高于  $C(S, I)$ , NDIA 略优. 从表 1 中 8 个函数共 24 个指标值中, 有 10 个数值  $C(I, S)$  高于  $C(S, I)$ , 有 8 个数值  $C(I, S)$  低于  $C(S, I)$ , 其余 6 个数值相等. 综合分析, 关于解集覆盖性, NDIA 略优于 SPEA2.

表 1 NDIA 与 NCEA, NSGA2, SPEA2 关于指标  $C$  的仿真结果

Table 1 Table results of the metric  $C$  obtained by NDIA, NCEA, NSGA2 and SPEA2

		$C(I, E)$	$C(E, I)$	$C(I, N)$	$C(N, I)$	$C(I, S)$	$C(S, I)$
ZDT1	最好值	0.11	0.04	0.15	0.03	0	0.02
	最差值	0.03	0	0.03	0	0	0
	平均值	0.059	0.014	0.074	0.011	0	0.02
ZDT2	最好值	1	0.04	0.12	0.02	0	0.06
	最差值	0.01	0	0.02	0	0	0
	平均值	0.147	0.012	0.063	0.015	0	0.016
ZDT3	最好值	0.12	0.03	0.15	0	0.03	0.03
	最差值	0.02	0	0.04	0	0	0
	平均值	0.071	0.005	0.102	0	0.011	0.010
DTLZ1	最好值	0.09	0.99	1	0.87	0.2	0.99
	最差值	0	0	0	0	0	0
	平均值	0.046	0.024	0.039	0.131	0.059	0.015
DTLZ2	最好值	0.86	0	0.13	0	0.13	0
	最差值	0.47	0	0.04	0	0.02	0
	平均值	0.762	0	0.075	0	0.071	0
DTLZ3	最好值	1	0.99	1	0.95	1	1
	最差值	0	0	0	0	0	0
	平均值	0.975	0.005	0.329	0.433	0.58	0.1
DTLZ4	最好值	0.09	0.02	0.12	0.01	1	0.03
	最差值	0.04	0	0	0	0.02	0
	平均值	0.071	0.002	0.07	0	0.051	0.001
DTLZ6	最好值	0.13	0.11	0.13	0.11	0.05	0.13
	最差值	0.04	0	0.02	0	0	0
	平均值	0.093	0.040	0.078	0.045	0.012	0.071

### 6.2 SP 指标 (SP metric)

图 3 描述了关于分布性指标  $SP$  的盒状图, 可看出, 对于 DTLZ1 函数 NDIA 表现最优, 对于 DTLZ3 函数 NSGA2 表现最优, 对于 DTLZ6 函数 NCEA 表现最优, 而其他 5 个函数 SPEA2 的  $SP$  值最好, 说明 SPEA2 的分布性能最佳, 但 SPEA2 复杂的档案维护过程使其时间复杂性最差. 除 SPEA2 之外, NDIA 在 ZDT1, ZDT2, ZDT3, DTLZ1, DTLZ2 的盒状图低于 NSGA2 与 NCEA 的盒状图, 表示最优解集在目标空间上分布的均匀性更好. 综合而言, 4 种算法获得的最优解集在目标空间的分布性能上, SPEA2 分布性最佳, NDIA 次之.

### 6.3 $C_v$ 指标 ( $C_v$ metric)

图 4 描述了 30 次独立运行基础上所得到的收敛性指标盒状图, 为了计算收敛性指标, 从问题的 Pareto 前端上均匀取值 100 个点.

从所有 8 个函数的统计情况来看, NDIA 算法在 ZDT1, ZDT2, ZDT3 上的盒状图低于其他 3 种算法, 收敛性能表现最优; 对于 DTLZ1 函数, NSGA2 的收敛性最好, 对于 DTLZ2 函数 SPEA2 的收敛性最好; 对于其余 3 个函数, NDIA, NCEA 与 NSGA2 取得相近的收敛性能. 综合比较, NDIA 以微弱优势在收敛性上表现最优, 得到的最优解集能较好地逼近理论 Pareto 前沿.

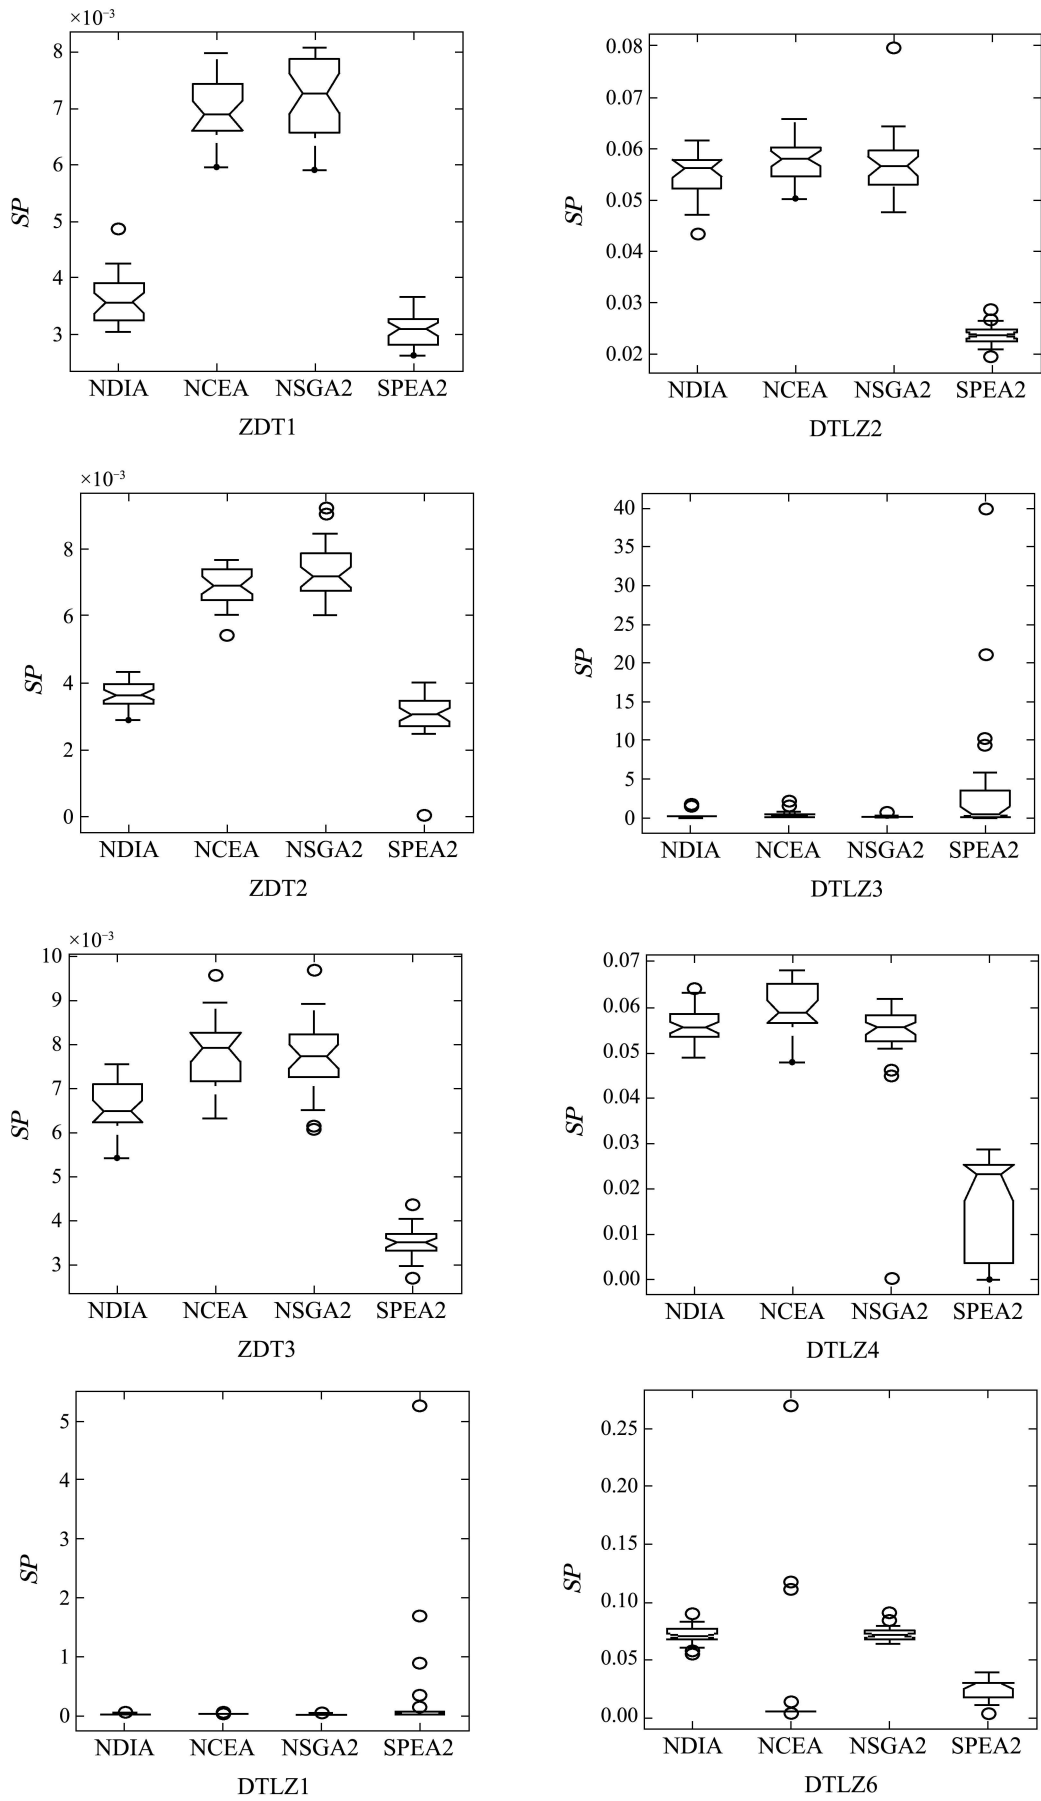


图3 4种算法的分布性指标的对比

Fig. 3 Box plots of the spacing metric obtained by NDIA, NCEA, NSGA2 and SPEA2

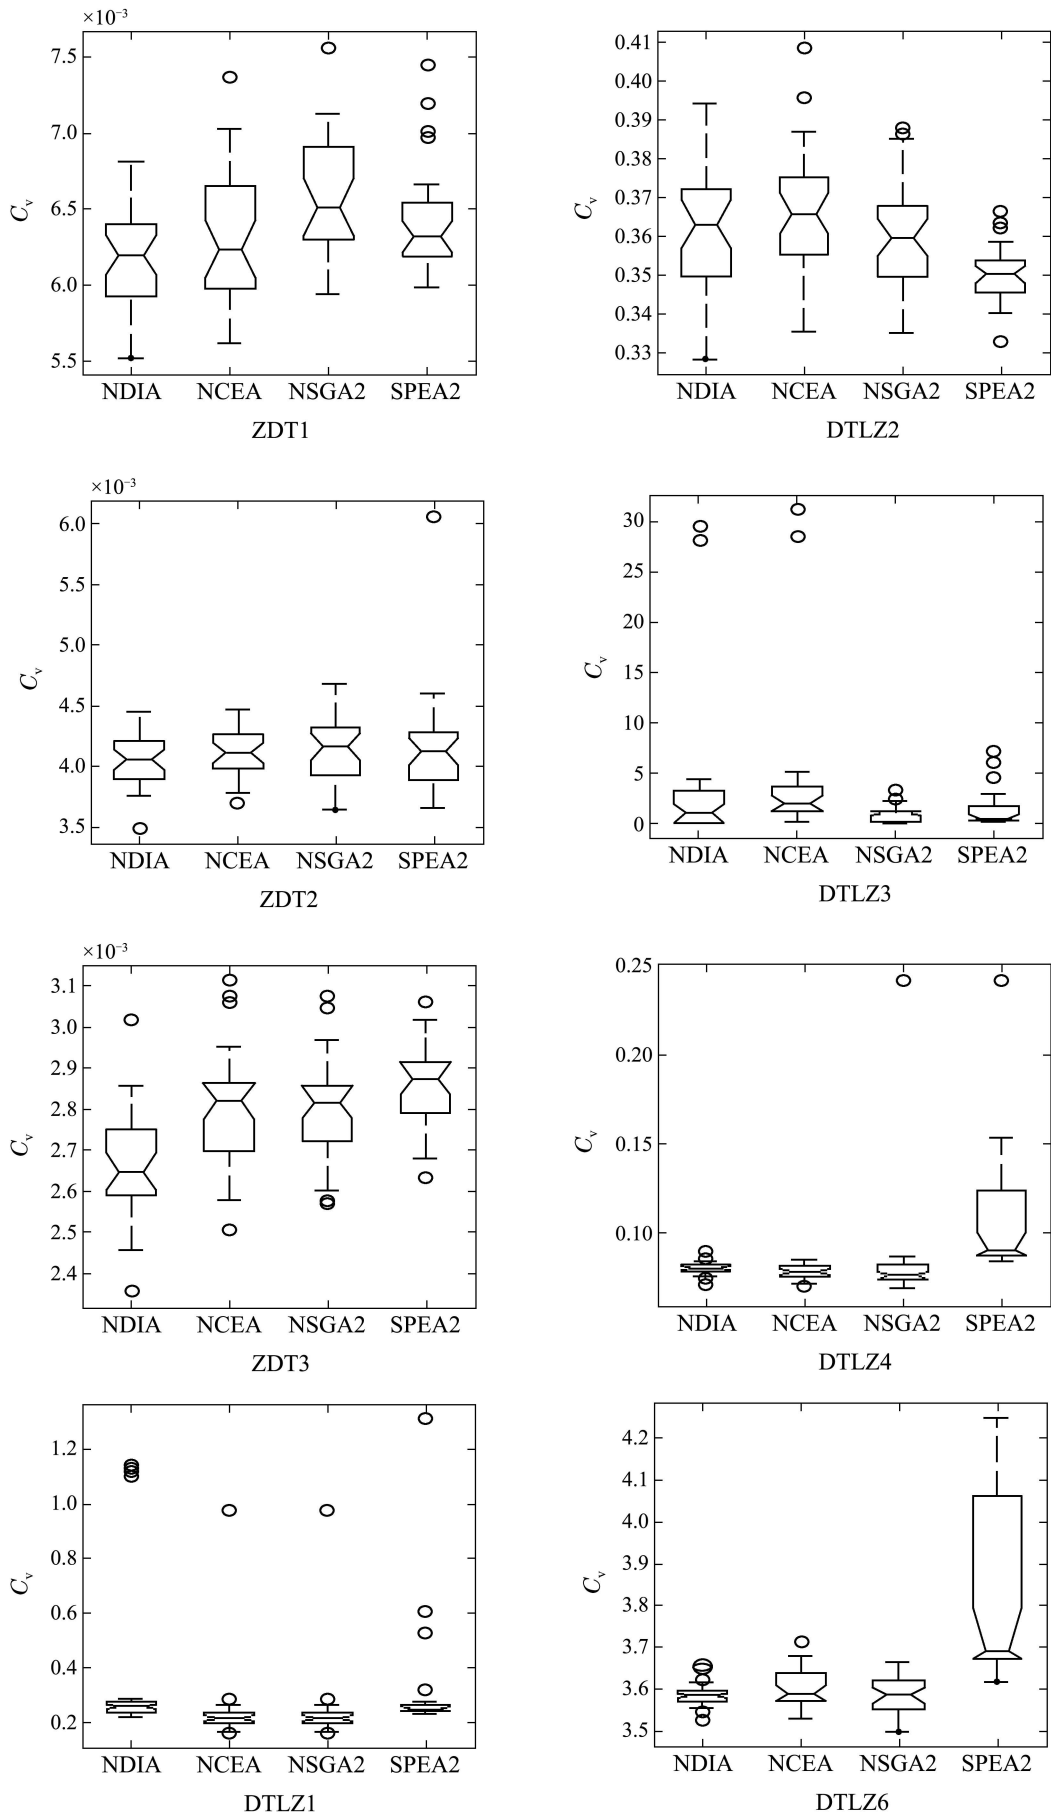


图 4 4种算法的收敛性指标的对比

Fig. 4 Box plots of the convergence metric obtained by NDIA, NCEA, NSGA2 and SPEA2



## 7 结论(Conclusions)

文章针对多目标优化问题,以免疫优化算法为基本框架,引入了非达尔文效应,设计了区间记忆变异方式,结合分阶段变异的策略,加强算法在不同阶段的收敛性能;在进化末端增设了均匀度增强算子以强化最优解集的分布性能.通过8个典型的多目标测试函数的仿真试验,NDIA最优解集与其他最优解集的相互覆盖对比中表现出更强的覆盖性能;收敛性指标与分布性指标的统计盒状图表明算法能兼顾解集的收敛性能和分布性能,即得到的最优解集能有效逼近理论Pareto前沿,并具有良好的分布性.

NDIA在多目标免疫算法中引入非达尔文效应,对变异环节进行设计以记忆非遗传信息而强化算法的搜索性能.其优点在于进化迭代时后代能从祖辈经验和遗传基因两方面获益,从而提高算法的整体性能.进一步的,如何有效设计进化环节,有机地将非达尔文效应与其他智能算法结合以提升算法整体性能是值得探索的研究方向.

## 参考文献(References):

- [1] 公茂果, 焦李成, 杨咚咚, 等. 进化多目标优化算法研究 [J]. 软件学报, 2009, 20(2): 271 – 289.  
(GONG Maoguo, JIAO Licheng, YANG Dongdong, et al. Evolutionary multi-objective optimization algorithms [J]. *Journal of Software*, 2009, 20(2): 271 – 289.)
- [2] SRINIVAS N, DEB K. Multi-objective optimization using non-dominated sorting in genetic algorithms [J]. *Evolutionary Computation*, 1994, 2(3): 221 – 248.
- [3] ZITZLER E, THIELE L. Multi-objective evolutionary algorithms: a comparative case study and the strength Pareto approach [J]. *IEEE Transactions on Evolutionary Computation*, 1999, 3(4): 257 – 271.
- [4] ZITZLER E, LAUMANN M, THIELE L. SPEA2: improving the strength Pareto evolutionary algorithm [C] // *Evolutionary Methods for Design, Optimization and Control with Applications to Industrial Problems*. Athens: International Center for Numerical Methods in Engineering, 2002: 95 – 100.
- [5] DEB K, PRATAP A, AGRAWAL S, et al. A fast elitist multi-objective genetic algorithm: NSGA2 [J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(2): 182 – 197.
- [6] MEZURA M E, COELLO C C A. A simple multimembered evolution strategy to solve constrained optimization problems [J]. *IEEE Transactions on Evolutionary Computation*, 2005, 9 (1): 1 – 17.
- [7] CAI Z, WANG Y. A multiobjective optimization based evolutionary algorithm for constrained optimization [J]. *IEEE Transactions on Evolutionary Computation*, 2006, 10(6): 658 – 675.
- [8] HERNHERNÁNDEZ-DÍAZ A G, SANTANA-QUINTERO L V, COELLO C C A, et al. Pareto-adaptive  $\epsilon$ -dominance [J]. *Evolutionary Computation*, 2007, 15(4): 493 – 517.
- [9] LIU L, LI M Q, LIN D. The  $\epsilon$ -dominance based multi-objective evolutionary algorithm and an adaptive  $\epsilon$  strategy [J]. *Chinese Journal of Computers*, 2008, 31(7): 1063 – 1072.
- [10] 杨咚咚, 马晶晶, 焦李成, 等. 一种改进 $\epsilon$ 支配的等度规映射方法 [J]. 软件学报, 2011, 22(9): 2291 – 2304.  
(YANG Dongdong, MA Jingjing, JIAO Licheng, et al. Improved  $\epsilon$  dominance by isomap [J]. *Journal of Software*, 2011, 22(9): 2291 – 2304.)
- [11] GONG M G, JIAO L C, DU H F, et al. Multiobjective immune algorithm with nondominated neighbor-based selection [J]. *Evolutionary Computation*, 2008, 16(2): 225 – 255.
- [12] CRUZ-CORTES N, RODRIGUEZ-HENRIQUEZ F, COELLO C C A. An artificial immune system heuristic for generating short addition chains [J]. *IEEE Transactions on Evolutionary Computation*, 2008, 12(1): 1 – 24.
- [13] KARAKASIS V K, STAFYLOPAPIS A. Efficient evolution of accurate classification rules using a combination of gene expression programming and clonal selection [J]. *IEEE Transactions on Evolutionary Computation*, 2008, 12(6): 662 – 678.
- [14] 林洪, 彭勇. 面向多目标优化的适应度共享免疫克隆算法 [J]. 控制理论与应用, 2011, 28(2): 206 – 214.  
(LIN Hu, PENG Yong. Immune clonal algorithm with fitness sharing for multi-objective optimization [J]. *Control Theory & Applications*, 2011, 28(2): 206 – 214.)
- [15] 尚荣华, 焦李成, 胡朝旭, 等. 修正免疫克隆约束多目标优化算法 [J]. 软件学报, 2012, 23(7): 1773 – 1786.  
(SHANG Ronghua, JIAO Licheng, HU Chaoxu, et al. Modified immune clonal constrained multi-objective optimization algorithm [J]. *Journal of Software*, 2012, 23(7): 1773 – 1786.)
- [16] 王君, 李波. 带模糊预约时间的车辆路径问题的多目标禁忌搜索算法 [J]. 计算机集成制造系统, 2011, 17(4): 858 – 866.  
(WANG Jun, LI Bo. Multi-objective tabu search algorithm for vehicle routing problem with fuzzy due-time [J]. *Computer Integrated Manufacturing Systems*, 2011, 17(4): 858 – 866.)
- [17] 钱洁, 郑建国. 采用群体统计学习的量子进化算法 [J]. 西安交通大学学报, 2012, 46(2): 51 – 58.  
(QIAN Jie, ZHENG Jianguo. A quantum evolutionary algorithm based on population statistical learning [J]. *Journal of Xi'an Jiaotong University*, 2012, 46(2): 51 – 58.)

## 作者简介:

宋丹 (1976–), 男, 副教授, 博士, 从事人工智能、免疫算法研究, E-mail: s1020d@126.com;

赖旭芝 (1966–), 女, 教授, 博士生导师, 从事智能系统、机器人、非线性控制研究, E-mail: xuzhi@csu.edu.cn;

吴敏 (1963–), 男, 长江学者特聘教授, 博士生导师, 从事先进控制理论及应用、过程控制和智能系统研究, E-mail: min@csu.edu.cn.