

双群体伪并行差分进化算法研究及应用

吴亮红^{1,2}, 王耀南², 周少武¹, 袁小芳²

(1. 湖南科技大学信息与电气工程学院, 湖南湘潭 411201; 2. 湖南大学电气与信息工程学院, 湖南长沙 410082)

摘要: 为了提高差分进化算法的全局搜索能力和收敛速率, 本文提出了一种双群体伪并行差分进化算法. 该算法结合差分进化算法DE/best/2/bin变异方式局部搜索能力强、收敛速度快, 和DE/rand/1/bin变异方式全局搜索能力强、鲁棒性好的特点, 采用串行算法结构实现并行差分进化算法独立进化、信息交换的思想. 为使初始化个体均匀分布在搜索空间, 提高算法收敛到全局最优解的鲁棒性, 提出了一种基于平均熵的初始化策略. 典型 Benchmarks函数测试和非线性系统模型参数估计结果表明, 该方法能显著提高算法的收敛速率和全局搜索能力.

关键词: 双群体; 差分进化算法; 平均熵; 参数估计

中图分类号: TP301 **文献标识码:** A

Research and application of pseudo parallel differential evolution algorithm with dual subpopulations

WU Liang-hong^{1,2}, WANG Yao-nan², ZHOU Shao-wu¹, YUAN Xiao-fang²

(1. School of Information and Electric Engineering, Hunan University of Science and Technology, Xiangtan Hunan 411201, China;
2. College of Electric and Information engineering, Hunan University, Changsha Hunan 410082, China)

Abstract: To improve the global searching ability and convergence speed of differential evolution algorithm (DE), a pseudo parallel differential evolution algorithm with dual subpopulations (DSPPDE) is proposed in this paper. Combining with the properties of good local searching ability and fast convergence speed of DE/best/2/bin mutation scheme and the properties of good global searching ability and robustness of DE/rand/1/bin mutation scheme, the algorithm employs the ideal of isolated evolution and information exchanging in parallel DE algorithm by serial program structure. To diversify the initial individuals in the search space and improve the robustness of convergence to the global optimum, an initialization tactic based on the mean entropy is proposed. The tests of several classic Benchmarks functions and the parameters estimation result of a nonlinear system model show that the proposed algorithm can improve the convergence speed and the global searching ability greatly.

Key words: dual subpopulations; DE algorithm; mean entropy; parameters estimation

1 引言 (Introduction)

差分进化算法(differential evolution, DE) 是 Rainer Storn和Kenneth Price于1995年共同提出的一种采用浮点矢量编码, 在连续空间中进行随机搜索的优化算法^[1]. 近年来, 差分进化算法作为一种性能卓越的优化算法正受到日益关注, 其应用领域也越来越广^[3~7].

差分进化算法的结构与实数编码的遗传算法相似, 但子代的生成方法不同, 其最大的特点是在子代生成过程中用到了父代多个个体的线性组合, 而不是遗传算法传统单一的父代染色体交叉技术. 同时,

差分进化算法子代的生成采用“贪婪”的选择方式. 这种方式能使算法具有快速的收敛特性, 但增加了算法陷入局部最优或早熟收敛的概率. 产生早熟收敛的根本原因是随迭代次数的增加种群多样性的快速下降. 增加种群的规模在一定程度上能克服早熟收敛, 但大大增加了算法对适应度函数的计算量. 为提高DE的性能, 一些学者提出了改进的方法. 文献[7]在算法中加入迁移算子和加速算子以提高算法的种群多样性和收敛速率. 文献[8]针对差分矢量缩放因子和交叉概率两参数对算法的影响, 提出了一种模糊自适应差分进化算法. 文献[9]将缩放因子

由固定数值设计为随机函数,减少了需调整的参数,实现了一个简化的DE版本。

本文结合DE/best/2/bin和DE/rand/1/bin^[2]两种不同变异方式的特点,采用双种群结构,其中一种种群采用DE/best/2/bin变异方式,另一种种群采用DE/rand/1/bin变异方式。两种种群独立进化,在适当的时候两种种群之间交换信息,从而维持种群多样性的同时加速进化过程。这类似于并行差分进化算法,但每一种群并未在不同的处理机上运行,仍以串行方式执行,将其称之为双群体伪并行差分进化算法(DSPPE)。同时,为了使初始种群具有尽可能的多样性,均匀分布在搜索空间,文章采用平均熵的策略来初始化种群,从而提高算法收敛于全局最优解的鲁棒性。对几种典型的Benchmarks函数测试和一非线性系统模型参数估计结果表明,与遗传算法和基本差分进化算法相比,本文提出的算法能有效避免早熟收敛,全局优化能力和收敛速率得到了显著提高。

2 基本差分进化算法 (Basic DE algorithm)

DE的基本操作包括变异、交叉和选择3种操作,但与其他进化算法如遗传算法(GA)不同。DE由NP(种群大小)个D维(变量个数)的参数矢量 x_i^t ($i = 1, 2, \dots, NP$)构成种群在搜索空间进行寻优(其中t表示第t代)。首先由父代两个不同随机个体相减得到的差分矢量加到随机选择的第3个个体上,生成一变异个体,接着按照一定的概率,父代个体与变异个体之间进行交叉操作,生成一试验个体,然后在父代个体与试验个体之间根据适应度函数值的大小进行选择操作,选择适应度更优的个体作为子代。

2.1 变异操作(Mutation operator)

DE最基本的变异成分是父代的差分矢量,每个矢量对包括父代两个不同的个体($x_{r_1}^t, x_{r_2}^t$)。根据变异个体的生成方法不同,形成了多种不同的差分进化算法方案^[2]。其中个体变异方式DE/rand/1/bin和DE/best/2/bin的方程为

$$x_m = x_{r_3}^t + F * (x_{r_1}^t - x_{r_2}^t), \quad (1)$$

$$x_m = x_{g_{best}}^t + F * [(x_{r_1}^t - x_{r_2}^t) + (x_{r_3}^t - x_{r_4}^t)]. \quad (2)$$

式(1)和(2)中: $x_{r_1}^t, x_{r_2}^t, x_{r_3}^t, x_{r_4}^t$ 为互不相同的随机个体, $x_{g_{best}}^t$ 为当前种群中适应度函数值最好的个体, $F \in [0, 2]$ 为缩放因子。

2.2 交叉操作(Crossover operator)

DE利用交叉操作以保持种群的多样性。对于种群中第i个个体 x_i^t ,将与 x_m 进行交叉操作,产生试验个体 x_T 。为保证个体 x_i^t 的进化,首先通过随机选择,使得 x_T 至少有一位由 x_m 贡献,而对于其他位,可利

用一个交叉概率因子CR,决定 x_T 中哪位由 x_m 贡献,哪位由 x_i^t 贡献。交叉操作的方程为

$$x_{Tj} = \begin{cases} x_{mj}, & \text{rand}() \leq CR, \\ x_{ij}^t, & \text{rand}() > CR, \end{cases} \quad j=1, 2, \dots, D. \quad (3)$$

式(3)中rand()为[0,1]之间的均匀分布的随机数, $CR \in [0, 1]$ 。由式(3)可知,如果CR越大,则 x_m 对 x_T 的贡献越多,当 $CR = 1$ 时, $x_T = x_m$,有利于局部搜索和加速收敛速率;如果CR越小,则 x_i^t 对 x_T 的贡献越多,当 $CR = 0$ 时, $x_T = x_i^t$,有利于保持种群的多样性和全局搜索。由此可见,在保持种群多样性与收敛速率之间是矛盾的。

2.3 选择操作(Selection operator)

DE采用“贪婪”的搜索策略,经过变异与交叉操作后生成的试验个体 x_T 与 x_i^t 进行竞争,只有当 x_T 的适应度较 x_i^t 更优时才被选作子代,否则,直接将 x_i^t 作为子代。选择操作的方程为

$$x_i^{t+1} = \begin{cases} x_T, & f(x_T) < f(x_i^t), \\ x_i^t, & f(x_T) \geq f(x_i^t). \end{cases} \quad (4)$$

3 DSPPE算法 (DSPPE algorithm)

对于DE/rand/1/bin变异方案,由式(1)可知,变异个体 x_m 由3个互不相同的随机个体组成,无需任何适应度函数值信息,有利于保持种群的多样性,因而全局搜索能力强,但收敛速度慢。对于DE/best/2/bin变异方式,由式(2)可知,变异个体 x_m 由 $x_{g_{best}}^t$ 作引导,因而局部搜索能力强,精度高,收敛速度快,但会加大算法陷入局部最优的可能性。因此,结合两者的特点,发挥各自的优点,提出了一种采用双群体结构的伪并行差分进化算法。图1为双群体伪并行差分进化算法的原理框图。

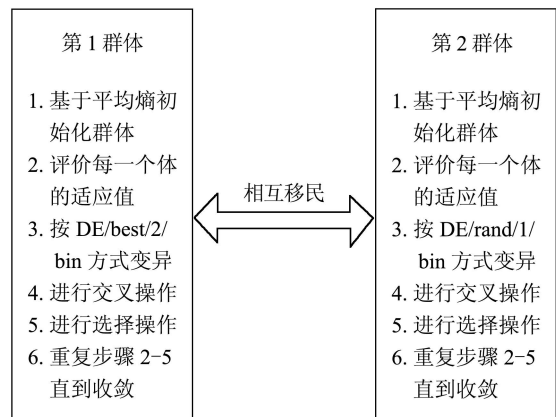


图1 基于平均熵的双群体伪并行差分进化算法原理框图

Fig. 1 Schematic diagram of DSPPE based on mean entropy

其基本思想是,一个群体采用DE/rand/1/bin变异方式,另一个群体采用DE/best/2/bin变异方式,每一群体在独立进化的同时,两群体之间在适当的时候

进行信息交流, 通过两群体之间的移民均衡全局探索能力和收敛速度之间的矛盾, 使得双群体差分进化算法在合理的计算复杂度下具有较高的全局收敛率. 双群体之间的移民采用对等的相互移民策略, 每一群体独立进化若干代(如5代)后, 将一个群体的最优适应度个体替换另一个群体的最差适应度个体. 但是, 每一群体并未在不同的处理器上运行, 仍在同一处理器上串行运算, 因而是一种伪并行的处理方式, 故称之为伪并行双群体差分进化算法.

4 基于平均熵的初始化 (Initialization based on mean entropy)

文献[10]提出了一种基于熵的群体初始化策略, 群体的初始化都遵守群体熵最大原则, 但文中提出的策略并不能保证初始化个体尽可能均匀分布在搜索区域中. 按文中对熵的定义, 若已有个体的群体熵值较大, 即使新增加的个体与已有个体重合时也能使群体熵大于设定的阈值, 此时, 基于熵的群体初始化策略根本不起作用, 仍为随机初始化. 而且实验研究表明, 一般随着个体数目的增加, 群体熵也会增加, 随机增加的新个体都能使得群体熵大于设定的阈值. 为此, 本文提出了一种基于平均熵的群体初始化策略. 设初始化后群体中包含 NP 个个体, 每个个体具有 D 维编码. 根据信息论熵的定义, 群体的熵 H 等于各位编码熵 $H_j(j = 1, 2, \dots, D)$ 的总和^[10], 即

$$H = \frac{1}{D} \sum_{j=1}^D H_j, \quad (5)$$

$$H_j = \frac{1}{m+1} \sum_{i=1}^m (-P_{ik} \log P_{ik}). \quad (6)$$

式(6)中, m 为已有的初始化个体数, k 为新的初始化个体, P_{ik} 是第 i 个个体的第 j 维编码与第 k 个个体的第 j 维编码的相似程度, 即

$$P_{ik} = 1 - \frac{|x_j(i) - x_j(k)|}{B_j - A_j}. \quad (7)$$

其中 A_j, B_j 为第 j 维变量的下边界和上边界.

首先随机初始化几个(如3个)个体作为初始种群, 然后随机初始化一个新个体, 并按式(5)~(7)计算群体的平均熵, 若群体的平均熵大于设定的阈值, 则将新个体加入到已有的初始化群体中, 直到获得了 NP 个初始个体. 这样得到的初始化群体将尽可能均匀分布在搜索空间, 以提高算法搜索到全局最优解的鲁棒性. 图2为某次随机初始化与基于平均熵的初始化结果的比较, 其中变量维数为2, 变量的取值范围为 $[-20, 20]$. 从图2可以看出, 随机初始化有时会分布不均匀, 而基于极大平均熵的初始化则较

为均匀的分布在搜索空间.




图2(a) 随机初始化结果

Fig. 2(a) Initialization result of random




图2(b) 基于平均熵的初始化结果

Fig. 2(b) Initialization result of mean entropy based

5 实验研究 (Experiment research)

为验证本文提出的算法的有效性, 下面通过4个典型的Benchmarks函数来进行测试, 同时与实数编码的简单遗传算法和两种不同变异方式的基本DE算法进行了比较. 其中 f_1 为Schaffer函数, 全局极大点是(0, 0), 在距离全局极大点大约3.14的范围内存在无限多的次全局极大点, 函数强烈震荡的性态使其很难于全局最优化. f_2 为Rosenbrock函数, 是一个非凸、病态函数. f_3 为Rastrigin函数, 多峰, 在 $S = \{x_i \in (-5.12, +5.12), i = 1, 2, \dots, n\}$ 范围内大约存在 $10n$ 个局部极小点. f_4 为Griewank函数, 多峰, 存在大量局部极小点.

$$f_1 = 0.5 - \frac{\sin^2 \sqrt{x_1^2 + x_2^2} - 0.5}{(1 + 0.001(x_1^2 + x_2^2))^2}, \quad -100 \leq x_1, x_2 \leq 100, \quad (8)$$

$$f_2 = \sum_{i=1}^{30} (100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2), \quad -30 \leq x_i \leq 30, \quad (9)$$

$$f_3 = \sum_{i=1}^{30} (x_i^2 - 10 \cos(2\pi x_i) + 10),$$

$$-5.12 \leq x_i \leq 5.12, \tag{10}$$

$$f_4 = \frac{1}{4000} \sum_{i=1}^{30} x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1,$$

$$-60 \leq x_i \leq 60. \tag{11}$$

实验中, 基于平均熵的初始化的阈值设为0.096, 双群体伪并行差分进化算法中各种群每独立进化4代后进行移民操作. 差分进化算法中其他实验参数的设置如表1所示. 表中种群规模 NP 为种群规模的总数, 实验中两种群的规模各占总种群规模的一半. 遗传算法采用算术交叉和非一致变异算子, 其交叉概率为0.8, 变异概率为0.05, 每一测试函数的种群规模和迭代次数与差分进化算法相同.

表1 差分进化算法实验参数设置
Table 1 Experiment parameters of DE

| f | DE/rand/1 | | DE/best/2 | | NP | 迭代次数 |
|-------|-----------|-----|-----------|-----|------|------|
| | F | CR | F | CR | | |
| f_1 | 0.5 | 0.9 | 1 | 0.1 | 40 | 200 |
| f_2 | 0.5 | 0.9 | 0.5 | 0.9 | 200 | 1500 |
| f_3 | 0.5 | 0.9 | 1 | 0.1 | 200 | 1500 |
| f_4 | 0.5 | 0.9 | 1 | 0.1 | 200 | 800 |

表2 各种算法运行30次的函数平均最优解与标准差

Table 2 Mean of 30 runs and standard deviations for all algorithms

| f | 理论最优 | SGA | | DE/best/2/bin | | DE/rand/1/bin | | DSPPDE | |
|-------|------|--------------------|--------------------|---------------|--------|-----------------------|-----------------------|-----------------------|-----------------------|
| | | 平均最优解 | 最优解标准差 | 平均最优解 | 最优解标准差 | 平均最优解 | 最优解标准差 | 平均最优解 | 最优解标准差 |
| f_1 | 1 | 0.9765 | 0.0145 | 0.9958 | 0.0040 | 0.9981 | 0.0041 | 1.00 | 0 |
| f_2 | 0 | 2.09×10^4 | 1.47×10^4 | 0.80 | 1.6809 | 15.067 | 0.5833 | 5.89×10^{-8} | 7.89×10^{-8} |
| f_3 | 0 | 17.98 | 6.6879 | 20.73 | 0.9605 | 183.28 | 9.5465 | 4.20×10^{-9} | 8.02×10^{-9} |
| f_4 | 0 | 0.71 | 0.1869 | 0.81 | 0.0525 | 1.18×10^{-4} | 2.37×10^{-4} | 2.00×10^{-7} | 5.73×10^{-7} |

表2列出了各种算法运行30次的函数平均最优解与各次最优解的标准差. 由表2可知, 遗传算法对4个函数在表1给定的迭代次数内都不能收敛到最优解. 实验表明, 即使将迭代次数设为5000, 对于 $f_2 \sim f_4$ 高维多峰函数, 简单遗传算法也难以收敛到最优解, 其收敛速度慢, 精度不高. 对于DE/best/2/bin变异方式的基本DE算法, 为保持种群的多样性, 将CR设为较小的值0.1, 这样使得收敛速度较慢, 在给定的迭代次数内, 优化函数 $f_2 \sim f_4$ 时, 都不能得到最优解. 实验表明, 若增加迭代次数, DE/best/2/bin变异方式的基本DE对于函数 $f_2 \sim f_4$ 可以收敛到最优解. 对于DE/rand/1/bin变异方式的基本DE, 由表2可知, 除对 f_1, f_4 优化效果较好之外, 对其他两个函数的优化效果不佳, 增加迭代次数可以得到最优解, 但精度不高. 4个测试函数结果表明, DSPPDE算法优化速度快, 收敛精度高, 鲁棒性好, 在相同的参数设置下, DSPPDE的优化效果远远优于DE/best/2/bin和DE/rand/1/bin变异方式基本DE的效果.

图3是上述4个函数采用四种算法运行30次后求得平均最优适应度函数值进化曲线. 为方便比较, 图3中(b)~(d)的纵坐标都采用适应度函数值的对数表示.




图3(a) f_1 30次平均最优适应度曲线

Fig. 3(a) Average best fitness curves of 30 runs for f_1




图3(b) f_2 30次平均最优适应度曲线

Fig. 3(b) Average best fitness curves of 30 runs for f_2

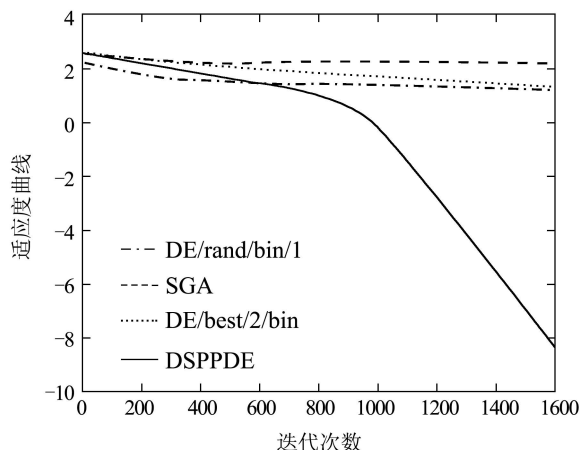


图 3(c) f_3 30次平均最优适应度曲线

Fig. 3(c) Average best fitness curves of 30 runs for f_3

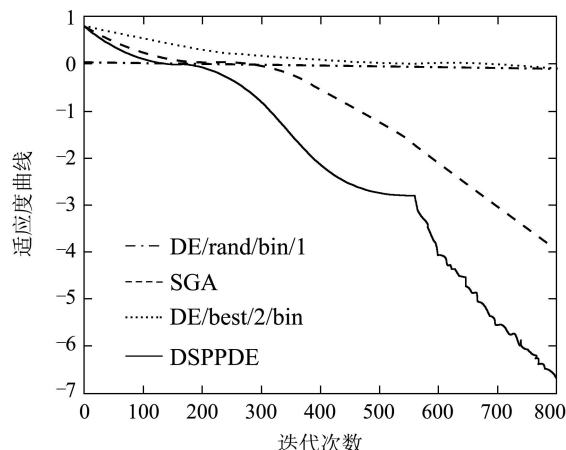


图 3(d) f_4 30次平均最优适应度曲线

Fig. 3(d) Average best fitness curves of 30 runs for f_4

6 应用实例 (Application)

为进一步验证算法的有效性, 将DSPPDE应用于一个非线性系统模型参数的估计. 非线性系统模型参数估计问题都可归结为对性能指标函数的优化问题.

非线性系统模型参数估计问题的性能指标函数为一非线性、多极值函数. 考虑式(12)非线性状态空间系统^[12,13]:

$$\begin{cases} \begin{bmatrix} x_1(t+1) \\ x_2(t+1) \end{bmatrix} = \begin{bmatrix} \theta_1 x_1(t) x_2(t) \\ \theta_2 x_1^2(t) \end{bmatrix} + \begin{bmatrix} 0 \\ u(t) \end{bmatrix}, \\ y(t) = \theta_3 x_2(t) - \theta_4 x_1^2(t) + g(t), \\ x_1(0) = x_2(0) = 1, \\ t = 0, 1, \dots, 50. \end{cases} \quad (12)$$

式中输入为 $u(t)$, 输出为 $y(t)$, $g(t)$ 为随机白噪声序列, 它满足均值为零, 方差 $\sigma^2 = 0.05$. 待估计参数为 $\theta_1, \theta_2, \theta_3, \theta_4$. 根据模型的特点, 其参数 θ_1, θ_2 必须小于1, 否则系统发散, 因此在初始化时必须将 θ_1, θ_2 限定在(0,1)之间. 输入 $u(t)$ 用正弦函数, 在一个周期内采样50个输入输出对. 文献[11]与文献[12]在对参数辨识时都没有考虑测量随机白噪声的影响, 本文分别对无噪声和有噪声影响的情况进行了实验, 为消除随机干扰, 算法对模型进行了20次随机实验. 实验中种群规模为40, 迭代次数为100, 其他参数与表1相同. DSPPDE对该系统的辨识结果如表3所示. 由表3可知, 没有白噪声影响时, 用DSPPDE估计结果与真实值一致; 当有白噪声影响时, DSPPDE的辨识精度也很高, 能达到没有白噪声影响时文献[11]和文献[12]的精度.

表 3 非线性系统模型参数估计结果

Table 3 Parameters estimation result of nonlinear system model

| 参数 | θ_1 | θ_2 | θ_3 | θ_4 |
|--------|------------|------------|------------|------------|
| 真实值 | 0.5 | 0.3 | 1.8 | 0.9 |
| 文献[11] | 0.4916 | 0.3014 | 1.8432 | 0.9267 |
| 文献[12] | 0.5069 | 0.3048 | 1.8095 | 0.9077 |
| 无噪声估计 | 0.5 | 0.3 | 1.8 | 0.9 |
| 有噪声估计 | 0.4951 | 0.3000 | 1.8011 | 0.8998 |

7 结论 (Conclusions)

针对DE/best/2/bin变异方式基本DE局部搜索能力强, 收敛速率快, 但易于早熟, 以及DE/rand/1/bin变异方式基本DE全局搜索能力强, 鲁棒性好, 但收敛速率慢的特点, 结合两种基本DE的优点, 采用串行算法结构实现并行差分进化算法独立进化、信息交换的思想, 提出了一种双种群伪并行差分进化算法. 该算法采用双种群结构, 其中一群体采用DE/best/2/bin变异方式, 另一群体采用DE/rand/1/bin变异方式, 两种群每独立进化若干代后进行移民操作, 将一种群的最优解替换另一群体的最差解, 在保持群体多样性的同时, 提高算法的收敛速率. 同时, 为使初始化个体尽可能均匀分布在搜索空间, 提高算法收敛到全局最优的鲁棒性, 提出了一种基于平均熵的初始化策略. 对4个典型的Benchmark函数测试和一非线性系统模型参数估计结果表明, 与两种不同变异方式的基本DE算法和简单GA相比, 本文提出的DSPPDE算法全局搜索能力强, 鲁棒性好, 收敛速度快, 能广泛应用于各种高维复杂连续函数的优化问题中.

参考文献 (References):

- [1] STORN R, PRICE K. *Differential Evolution—a Simple and Efficient Adaptive Scheme for Global Optimization over Continuous Spaces*, TR-95-012[R]. Berkeley: International Computer Science Institute 1995.
- [2] RAINER S, PRICE K. Differential evolution - a simple and efficient heuristic for global optimization over continuous spaces[J]. *J of Global Optimization*, 1997, 11(4): 341 – 359.
- [3] CHEONG F, LAI R. Designing a hierarchical fuzzy logic controller using differential evolution[C] // *Proc of 1999 IEEE Int Fuzzy Systems Conf*. Seoul: [s.n.], 1999, 1: 277 – 282.
- [4] MOALLA S, ALIM I A M, DERBEL N. Design of beta neural systems using differential evolution[C] // *2002 IEEE Int Conf on Systems, Man and Cybernetics*. Tunisia: [s.n.], 2002, 3: 6 – 9.
- [5] URSEM R K, VADSTRUP P. Parameter identification of induction motors using differential evolution[C] // *Proc of the Fifth Congress on Evolutionary Computation Conference*. Canberra: [s.n.], 2003, 2: 790 – 796.
- [6] VESTERSTROM J, THOMSEN R. A comparative study of differential evolution, particle swarm optimization, and evolutionary algorithms on numerical benchmark problems[C] // *Proc of Congress on Evolutionary Computation*. Portland: [s.n.], 2004, 2: 1980 – 1987.
- [7] CHIOU J P, WANG F S. A hybrid method of differential evolution with application to optimal control problems of a bioprocess system[C] // *Proc of IEEE Int Conf on Evolutionary Computation*. New York: [s.n.], 1998: 627 – 632.
- [8] LIU J H, LAMPINEN L. A fuzzy adaptive differential evolution algorithm[C] // *IEEE Region 10 Conference on Computers, Communications, Control and Power Engineering*. Beijing: [s.n.], 2002: 606 – 611.
- [9] 谢晓峰, 张文俊, 张国瑞, 等. 差异演化的实验研究[J]. *控制与决策*, 2004, 19(1): 49 – 52.
(XIE Xiaofeng, ZHANG Wenjun, ZHANG Guorui, et al. Empirical study of differential evolution[J]. *Control and Decision*, 2004, 19(1): 49 – 52.)
- [10] 杨小芹, 黎明, 周琳霞. 基于熵的双群体遗传算法研究[J]. *模式识别与人工智能*, 2005, 18(3): 286 – 289.
(YANG Xiaoqin, LI Ming, ZHOU Linxia. Entropy based genetic algorithm with dual subpopulations[J]. *PR & AI*, 2005, 18(3): 286 – 289.)
- [11] 姜波, 汪秉文. 基于遗传算法的非线性系统模型参数估计[J]. *控制理论与应用*, 2000, 17(1): 150 – 152.
(JIANG Bo, WANG Bingwen. Parameter estimation of nonlinear system based on genetic algorithms[J]. *Control Theory & Applications*, 2000, 17(1): 150 – 152.)
- [12] 王凌, 郑大钟. 基于一类混合策略的模型参数估计控制器参数整定研究[J]. *控制与决策*, 2001, 16(15): 530 – 534.
(WANG Lin, ZHENG Dazhong. Estimating model-parameter and tuning controller-parameter by a class of hybrid strategy[J]. *Control and Decision*, 2001, 16(15): 530 – 534.)

作者简介:

吴亮红 (1978—), 男, 硕士生, 湖南科技大学信息与电气工程学院讲师, 研究方向为智能控制、计算智能等, E-mail: lhwu@hnust.edu.cn;

王耀南 (1957—), 男, 博士后, 湖南大学电气与信息工程学院博士生导师, 研究方向为智能控制、智能信息处理、智能图像处理等, E-mail: w.yaonan@hotmail.com;

周少武 (1964—), 男, 博士, 湖南科技大学信息与电气工程学院教授, 研究方向为非线性时滞系统鲁棒控制等, E-mail: swzhou@hnust.edu.cn;

袁小芳 (1979—), 男, 湖南大学电气与信息工程学院博士生, 研究方向为智能控制、计算智能等, E-mail: yuanxiaof@21cn.com.