

基于内分泌调节机制的粒子群算法

陈得宝^{1,2}, 赵春霞¹

(1. 南京理工大学 计算机科学与技术学院, 江苏 南京 210094; 2. 淮北煤炭师范学院 物理系, 安徽 淮北 235000)

摘要: 借鉴内分泌系统的高级调节机制, 提出一种基于内分泌调节机理的粒子群算法. 首先设计一种结合当前粒子群的最好适应度、平均适应度和局部适应度的情感评价方法, 对下一代粒子群进行情感评价, 然后用神经系统和内分泌系统共同作用, 对粒子群的行为进行更新, 在更新过程中, 引入动量项减少局部收敛的发生. 文中同时分析了算法的收敛性, 并对几个典型函数优化问题和机器人路径规划进行实验, 验证方法的有效性.

关键词: 内分泌系统; 神经系统; 粒子群算法; 函数优化

中图分类号: TP24 **文献标识码:** A

Particle swarm optimization based on endocrine regulation mechanism

CHEN De-bao^{1,2}, ZHAO Chun-xia¹

(1. Computer Department, Nanjing University of Science and Technology, Nanjing Jiangsu 210094, China;

2. Department of Physical, HuaiBei Coal Industry Teachers College, Huaibei Anhui 235000, China)

Abstract: Motivated by high-level regulation principle of endocrine system, a particle swarm optimization based on endocrine regulation mechanism is put forward. First, emotional evaluation method is designed combining with the best fitness, average fitness and local fitness of particles in current generation, and emotion in next generation is evaluated. Then, the behaviors of particles in next generation are updated by interaction of neural and endocrine systems, and momentum factor is used to reduce the probability of local convergence. The convergence of algorithm is analyzed, and the effectiveness is demonstrated by optimization experiments of typical functions and path planning.

Key words: endocrine system; neural system; particle swarm algorithm(PSO); function optimization

1 引言(Introduction)

粒子群算法^[1]操作简单, 易于实现, 计算量小, 易于工程应用, 已成功应用于函数优化^[2]、神经网络^[3]等不同的领域. 作为一种随机优化算法, 也具有局部收敛, 进化后期收敛速度慢, 精度较差等缺点. 近些年来, 对改善PSO的性能提出了一些解决方案, 并取得一定的效果, 基本可归纳成3类: 第1类是通过研究算法的参数来改善粒子群的性能^[4,5]; 第2类是PSO与其他进化方法结合的研究^[6], 其中在粒子群进化后期, 当粒子群进化停止时, 对最优个体进行变异^[7], 使其离开局部收敛区的变异粒子群方法, 取得较好的效果; 第3类是研究协作和竞争方法的粒子群^[8]. 这些方法都在一定的程度上对算法的性能有所改善. 本文将内分泌调节机制引入粒子群更新关系中, 重点研究粒子更新方法. 充分考虑个体周围的信息, 对粒子下时刻的情感进行评估, 设计一种新

的激素更新方法, 并将其融入对粒子位置的更新, 同时, 在位置更新中加入动量项, 使粒子群能逃离局部收敛. 文中对算法的工作原理和收敛性进行了分析, 最后, 通过实验验证了方法的有效性.

2 基于内分泌调节机制的PSO(PSO based on endocrine regulation mechanism)

本文对普通的粒子群不详细介绍, 具体方法可参照文献[1]. 在基本粒子群算法中粒子跟踪的是个体到目前为止的最优位置和当代粒子群的最优位置, 当代粒子群的最优位置可看成是全局信息, 个体到目前为止的最优位置可看成内部保留信息, 粒子通过神经系统很容易感觉到这两种信息. 然而, 对一个群体而言, 周围粒子的分布状况对粒子的行为也会造成不同的影响, 文献[9]对不同结构的粒子群的优缺点进行了分析. 在本文的设计中, 采用文献[9]中的环形粒子群结构. 设某一 N 个解的粒子群 P , 如图1.




图1 粒子群的循环排列图

Fig. 1 Circle rank map of particle swarm

若每个粒子 P_i 为 D 维, 给粒子的每个分量都分配一个激素因子 E_i , 因此粒子可描述为 (X_{id}, V_{id}, E_{id}) , $i = 1, 2, \dots, N$, $d = 1, 2, \dots, D$, X_{id}, V_{id}, E_{id} 分别为粒子的位置、速度和激素分量, 记第 K 代粒子群的最大适应度为 f_{\max} , 平均适应度为 f_{avg} , 将 f_{\max} 作为粒子群的全局信息, f_{avg} 作为粒子群的平均信息, 记第 i 个粒子的适应度为 f_i , 其前后的粒子适应度记为 f_{i-1}, f_{i+1} . 由于每个粒子对自己当前的状态具有记忆和衡量能力, 反映到内分泌系统, 就是对激素的评估, 考虑这几方面的信息, 设计激素更新函数如下:

$$EM(S) = fun_1\left(\frac{f_{\max} - f_i}{f_{\max} - f_{\text{avg}}}\right) \cdot \left(\frac{\pi}{2} + fun_2\left(f_i - \frac{f_{i-1} + f_{i+1}}{2}\right)\right). \quad (1)$$

其中: S 表示状态, $fun_1(\cdot)$ 是增函数, $fun_2(\cdot)$ 是减函数, 通常激素的更新是一个非线性过程, 本文取 $fun_1(x) = \text{atan}(x)$, $fun_2(x) = \text{atan}(-x)$. 由于内分泌系统对好的状态, 激素更新不需很剧烈, 相反, 对较差的粒子, 为了让其尽快成长起来, 需分泌更多的激素, 促进其快速达到新的较好平衡. 选择式1中函数满足要求, 分析如下: $fun_1(\cdot)$ 是内分泌系统对群体信息的一种反应, 当 $f_i > f_{\text{avg}}$ 时, i 个体的性能较好, 个体内分泌系统对群体信息反应不会很剧烈, 且随着适应度的增加, 反应程度继续减弱, 即激素更新幅度变小, 当 $f_i = f_{\max}$ 时, $fun_1(\cdot) = 0$ 全局信息对其情感不产生影响. 当 $f_i < f_{\text{avg}}$ 时, i 个体的性能较差, 内分泌系统对环境反应随着适应度的减少变得剧烈, 因此, 激素的更新幅度变大. 为避免激素的引入对现有粒子模式造成很大的破坏, 因而激素的更新必须限制在一定的范围内, 选用 $\text{atan}(\cdot)$ 函数就可将其限制在 $[0, \pi/2]$, 因此 $fun_1(\cdot)$ 的选择能满足要求. $fun_2(\cdot)$ 是内分泌系统对局部信息的一种反应, 通常选用减函数的形式, 当 $f_i > (f_{i-1} + f_{i+1})/2$ 时, 粒子的局部特性认为较好, 情感因子只需要较小幅度的更新, 反之, 内分泌系统将分泌更多的激素, 促进粒子 i 超越周围粒子, 向更合适的位置移动. 显然

选择 $fun_2(\cdot)$ 也能满足这一要求, $\pi/2$ 是为限制激素范围而设定的常数. 根据以上分析可得粒子群在下一时刻的激素为

$$EM_i(k+1) = c_4 E_i(k) + c_3 \text{rand}(\cdot) EM(S). \quad (2)$$

式(2)中: $E_i(k), E_i(k+1)$ 分别为 k 和 $k+1$ 时刻第 i 个粒子的激素, c_3 为更新幅度系数, c_4 为激素尺度变量, 其范围通常为 $[0.01, 0.1]$, $\text{rand}(\cdot)$ 是均值为零方差为1的随机数. 结合普通粒子群更新方法和式2得粒子群位置更新公式为

$$\begin{aligned} X_i(k+1) = & X_i(k) + wV_i(k) + c_1 \text{rand}(\cdot) \cdot (X_{pbest_i}(k) - \\ & X_i(k)) + c_2 \text{rand}(\cdot) (X_{gbest} - X_i(k)) + \\ & c_4 E_i(k) + c_3 \text{rand}(\cdot) EM(S). \end{aligned} \quad (3)$$

为减小局部最优发生的可能, 采用增加动量项的方法^[10], 使粒子群摆脱局部最优, α 的取值如式4, 如果粒子群的最大适应度在连续的 G 代内不变, 则 $\alpha = 0.1$, 其他情况下为0.

$$\begin{cases} \alpha = 0.1, & \text{if } f_{\max} = \text{constant}, \text{ gen} = g_i, \dots, g_{i+G}, \\ 0, & \text{其他.} \end{cases} \quad (4)$$

联合式(3)(4)得最终的粒子更新方式为

$$\begin{aligned} X_i(k+1) = & X_i(k) + wV_i(k) + c_1 \text{rand}(\cdot) \cdot (X_{pbest_i}(k) - \\ & X_i(k)) + c_2 \text{rand}(\cdot) (X_{gbest} - X_i(k)) + \\ & c_4 E_i(k) + c_3 \text{rand}(\cdot) EM(S) + \\ & \alpha \cdot \text{rand}(\cdot), \quad i = 1, 2, \dots, N. \end{aligned} \quad (5)$$

式中 X_{pbest_i} 和 X_{gbest} 分别为系统进化到当前代第 i 个个体的最好位置和粒子群中最优粒子的位置.

3 算法的收敛性(Convergence of algorithm)

定义1 设粒子群中某粒子在 t 时刻的位置为 $x(t)$, P 为搜索空间内的任意位置, 则粒子收敛定义如下^[11]:

$$\lim_{t \rightarrow \infty} X(t) = P. \quad (6)$$

定理1 在一定的条件下, EPSO算法总能收敛.

证 与文献[11]类似, 将粒子群更新过程用简单的表达式表示:

$$\begin{aligned} V(t+1) = & wV(t) + \phi_1(X_p(t) - X(t)) + \\ & \phi_2(X_g(t) - X(t)), \end{aligned} \quad (7)$$

$$\begin{aligned} X(t+1) = & X(t) + wV(t) + \phi_1(X_p(t) - \\ & X(t)) + \phi_2(X_g(t) - X(t)) + \\ & c_4 E(t) + \phi_3 EM(S) + \phi_4, \end{aligned} \quad (8)$$

则粒子运动的递推方程变为

$$X(t+1) = (1+w-\phi_1-\phi_2)X(t) - wX(t-1) + \phi_1X_p + \phi_2X_g + c_4E(t) + \phi_3EM(S) + \phi_4, \quad (9)$$

$$\begin{bmatrix} X(t+1) \\ X(t) \\ 1 \end{bmatrix} = \begin{bmatrix} A_{11} & -w & A_{13} \\ 1 & 0 & 0 \\ 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} X(t) \\ X(t-1) \\ 1 \end{bmatrix}. \quad (10)$$

其中:

$$A_{11} = 1 + w - \phi_1 - \phi_2, \quad (11)$$

$$A_{13} = \phi_1X_p + \phi_2X_g + E_c, \quad (12)$$

$$E_c = c_4E(t) + \phi_3EM(S) + \phi_4. \quad (13)$$

X_p, X_g 分别为个体运动到当前时刻的最优值和当前代最优解, $\phi_1 = c_1\text{rand}(\cdot), \phi_2 = c_2\text{rand}(\cdot), \phi_3 = c_3\text{rand}(\cdot), \phi_4 = c_4\text{rand}(\cdot)$. 式(11)的特征方程为

$$(1-\lambda)(w-\lambda(1+w-\phi_1-\phi_2)+\lambda^2)=0, \quad (14)$$

特征根为

$$\lambda_1 = \frac{1+w-\phi_1-\phi_2+\zeta}{2},$$

$$\lambda_2 = \frac{1+w-\phi_1-\phi_2-\zeta}{2},$$

$$\zeta = \sqrt{(1+w-\phi_1-\phi_2)^2-4w}.$$

假定初始状态 $X(0), X(1)$ 已知, 则式(10)的解为

$$X(t) = k_1 + k_2\lambda_1^t + k_3\lambda_2^t, \quad (15)$$

$$k_1 = \frac{\phi_1X_p(t) + \phi_2X_g(t) + E_c(t)}{\phi_1 + \phi_2}, \quad (16)$$

$$k_2 = \frac{\lambda_2(X(0) - X(1)) + X(2) - X(1)}{\zeta(\lambda_1 - 1)}, \quad (17)$$

$$k_3 = \frac{\lambda_1(X(1) - X(0)) + X(1) - X(2)}{\zeta(\lambda_2 - 1)}, \quad (18)$$

当满足 $\|\max(\lambda_1, \lambda_2)\| < 1$ 时,

$$\lim_{t \rightarrow \infty} X(t) = M. \quad (19)$$

式(19)中 M 为一有界常数, 根据定义, 定理得证.

4 实验(Experiments)

说明 实验中权值均采用线性下降方法^[5].

4.1 函数优化实验(Experiments of function optimization)

函数1的最大值:

$$fun1: f(x) = 10 + \frac{\sin(1/x)}{(x-0.16)^2 + 0.1}, x \in (0, 1).$$

函数2的最小值:

$$fun2: f(x) = x_1^2 + x_2^2, -2 \leq x_1, x_2 \leq 2.$$

函数3: Rosenbrock函数的最小值($n = 10$):

$$f(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2],$$

$$x_i \in [-10, 10].$$

函数4: Schaffe函数的最大值:

$$f(x_1, x_2) = 0.5 - \frac{(\sin \sqrt{x_1^2 + x_2^2})^2}{(1 + 0.001(x_1^2 + x_2^2))^2} \in [-100, 100].$$

本文对4个函数进行了仿真实验, 验证方法的性能, 对4个函数分别进行了20次实验, 公共参数为: $c_1 = c_2 = 2, w_{\max} = 0.9, w_{\min} = 0.4, G = 10, N = 50$. 对函数1, 初始参数为: $c_3 = c_4 = 0.05, X_{\max} = 1.0, X_{\min} = 0, V_{\max} = 1.0, E_{\max} = 0.5, maxgen = 100$. 函数2实验中初始参数 $X_{\max} = 2.0, X_{\min} = -2, maxgen = 100$, 其他参数与函数1实验中使用的参数一致. 表1中给出了PSO算法和EPSO算法对函数1和2的结果.

表1 PSO与EPSO对函数1,2的结果
Table 1 Results of PSO and EPSO for function 1 and function 2

	函数	理论解	平均代数	局部收敛次数	实验平均解
PSO	1	19.8949	92.6	0	19.8948
	2	0	147.1	0	4.8981×10^{-23}
EPSO	1	19.8949	59.45	0	19.8949
	2	0	90.1	0	5.2687×10^{-27}

函数3,4是两个典型广泛用于优化算法的测试函数, 函数3实验中初始参数为: $c_3 = 0.03, c_4 = 0.05, X_{\max} = 10.0, X_{\min} = -10.0, V_{\max} = 1.0, E_{\max} = 0.05, maxgen = 6000$. 函数4实验中初始参数为: $c_3 = c_4 = 0.05, X_{\max} = 100.0, X_{\min} = -100.0, E_{\max} = 0.05, maxgen = 400$. 表2中给出了PSO算法和EPSO算法对函数3和4的结果.

表2 PSO与EPSO对函数3,4的结果
Table 2 Results of PSO and EPSO for function 3 and function 4

	函数	理论解	平均代数	局部收敛次数	实验平均解
PSO	3	0	—	4	2.2476(16次)
	4	1	—	3	0.9992(17次)
EPSO	3	0	4732.58	0	0.0281
	4	1	282.62	0	0.9999

表2中“—”表示出现局部最优时平均进化代数无法给出.

图2为适应值变化图, 对PSO方法, 选择20次实验中较好一次的实验结果; 对EPSO方法, 取20次实验的平均适应值. 由表1知对函数1和2这样简单的函数, PSO与EPSO算法性能差别不大, EPSO只是在

收敛速度上较优. 对Rosenbrock函数3, 由于其全局极小值位于狭长的抛物线形状曲面峡谷中, 求取最优解相当困难, 特别在高维情况下, 本文对10维函数进行了仿真实验; 对函数4, 它的全局最优解1被0.99903的脊包围着, 寻找其全局最优解也比较困难. 在对这两个函数优化实验中EPSO比普通的PSO方法具有较快的收敛速度和较强全局收敛能力.

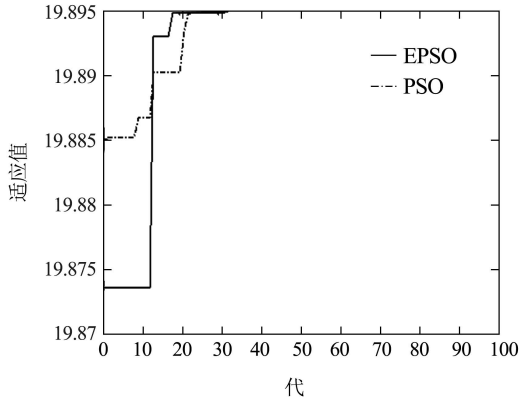


图 2(a) 函数1的适应度图
Fig. 2(a) Fitness map for fun1




图 2(b) 函数2的适应度图
Fig. 2(b) Fitness map for fun2

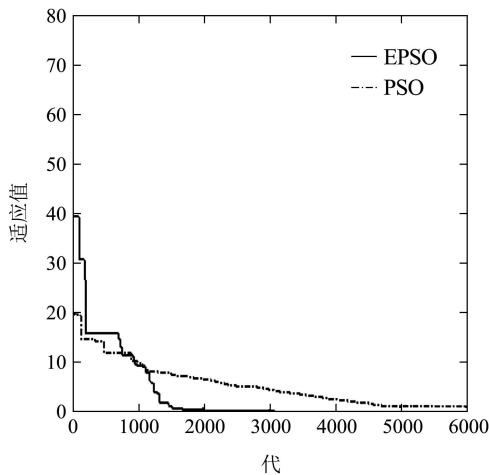
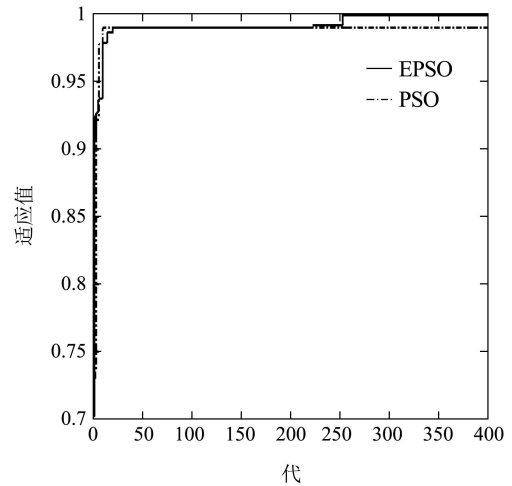


图 2(c) 函数3的适应度图
Fig. 2(c) Fitness map for fun3



2(d) 函数4的适应度图

Fig. 2(d) Fitness map for fun4

4.2 路径规划实验(Experiment of path planning)

机器人的路径规划通常是在一个有障碍的环境下, 寻找一条满足要求的从起始点到目标点的一条无碰撞路径^[12]. 本文首先对障碍膨胀, 用圆表示环境中的障碍, 再采用坐标映射的方法将粒子的编码变换成一维^[13]对路径进行规划. 避碰检测遵循两个原则; 一是路径点不在障碍内; 二是路径点不与障碍相交. 以总的路径长度作为适应度, 形式如下:

$$fit(l) = \sum_{i,k} dis(i, k). \quad (20)$$

式(20)中 $dis(i, k)$ 表示由位置 i 到 k 的距离. EPSO算法的初始参数为: $c_1 = c_2 = 2, c_3 = 0.05, c_4 = 0.06, w_{max} = 0.9, w_{min} = 0.4, X_{max} = 200, X_{min} = -200.0, V_{max} = 1.5, E_{max} = 0.1, G = 10, N = 40, maxgen = 70$. 普通粒子群(PSO)和MPSO^[7]方法中 $c_1 = c_2 = 2, w = 0.9$. 利用MATLAB软件对3种不同的方法进行20次实验, 结果如表3.

表 3 PSO,MPSO(变异粒子群)、EPSO的路径规划性能

Table 3 Performance of PSO,MPSO and EPSO for path planning

	平均代数	平均路径长度/cm	局部收敛次数	时间/ms
PSO	—	512.3752(16次)	4	57.2348
MPSO	—	499.1834(18次)	2	45.7149
EPSO	33.27	484.1480	0	23.1503

表3中“—”表示局部收敛, 平均进化代数不便准确给出, 由实验可知EPSO方法收敛速度较快, 不易陷入局部极小, 3种方法的最优路径如图3, EPSO方法的路径长度为484.0578 cm, MPSO方法的路径长度为494.2570 cm, PSO方法的路径长度为499.4675 cm.

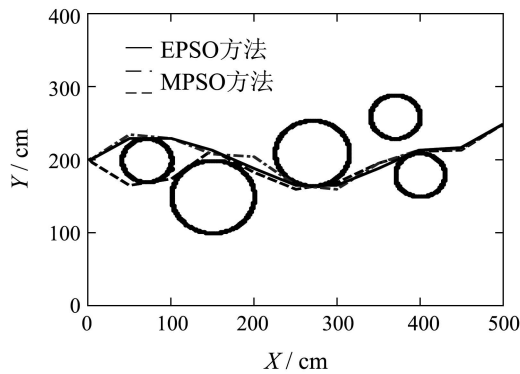


图3 3种方法的最优路径

Fig. 3 Optimal path of three methods

5 结论(Conclusion)

本文结合激素的高级调节原理, 将内分泌调节机制引入粒子群算法, 在粒子位置的更新过程中, 不仅考虑到粒子的认知特性和社会特性, 而且为每个粒子都设计了情感因子, 根据当前的最优信息, 局部信息, 平均信息, 对粒子群的激素进行更新, 设计了一种适合激素更新的方法. 通过动量因子的引入, 极大减少了早熟现象发生的可能, 通过对四个函数的测试和机器人路径规划实验, 证明EPSSO方法有较好的性能.

参考文献(References):

- [1] KENNEDY J, EBERHART R C. Particle swarm optimization[C]// *Proc of IEEE Int Conf on Neural Network*. USA: IEEE Press, 1995: 1942 – 1948.
- [2] JANG Ho Seo, CHANG Hwan Im, CHANG Geun Heo, et al. Multimodal function optimization based on particle swarm optimization[J]. *IEEE Trans on Magnetics*, 2006, 42(4): 1095 – 1098.
- [3] YI Da, GE Xiuyun. An improved PSO-based ANN with simulated annealing technique[J]. *Neuro Computing*, 2005, 63(11): 527 – 533.
- [4] SHI Y, EBERHART R C. A modified swarm optimizer[C]// *Proc of IEEE Int Conf on Evolutionary Computation*. Piscataway: IEEE Press, 1998: 69 – 73.
- [5] RATNAWEERA A, HALGAMUGE S K, WATSON H C. Self-organizing hierarchical particle swarm optimizer with time-varying

acceleration coefficients[J]. *IEEE Trans on Evolutionary Computation*, 2004, 8(3): 240 – 255.

- [6] SHI X H, LIANG Y C, LEE H P, et al. An improved GA and a novel PSO-GA-based hybrid algorithm[J]. *Information Processing Letters*, 2005, 93(1): 255 – 261.
- [7] HIGASSHI N, IBA H. Particle swarm optimization with Gaussian mutation[C]// *Proc of IEEE Swarm Intelligence Symp*. Indianapolis: IEEE Inc, 2003: 72 – 79.
- [8] FRANKEN N, ENGELBRECHT A P. Particle swarm optimization approaches to coevolve strategies for the iterated prisoner's dilemma[J]. *IEEE Trans on Evolutionary Computation*, 2005, 19(6): 562 – 579.
- [9] KENNEDY J. Small worlds and mega-minds: effects of neighborhood topology on particle swarm performance[C]// *Proc of IEEE Congress on Evolutionary Computation*. Piscataway: NJ, 1999: 1931 – 1938.
- [10] 王科俊, 金鸿章, 李国斌. 综合反向传播算法[J]. *控制理论与应用*, 1999, 16(5): 739 – 743.
(WANG Kejun, JIN Hongzhang, LI Guobin. A synthetically back-propagation algorithm[J]. *Control Theory & Applications*, 1999, 16(5): 739 – 743.)
- [11] VAN DEN BERGH F, ENGELBRECHT A P. A study of particle swarm optimization particle trajectories[J]. *Information Sciences*, 2006, 176(8): 937 – 971.
- [12] 樊晓平, 李双艳, 陈特放. 基于新人工势场函数的机器人动态避障规划[J]. *控制理论与应用*, 2005, 22(5): 49 – 53.
(FAN Xiaoping, LI Shuangyan, CHEN Tefang. Dynamic obstacle-avoiding path plan for robots based on a new artificial potential field function[J]. *Control Theory & Applications*, 2005, 32(1): 49 – 53.)
- [13] 陈华华, 杜歆, 顾伟康. 基于遗传算法的静态环境全局路径规划[J]. *浙江大学学报(理学版)*, 2005, 32(1): 49 – 53.
(CHEN Huahua, DU Xin, GU Weikang. Genetic algorithm based global path planning in a static environment[J]. *J of Zhejiang University(Science Edition)*, 2005, 32(1): 49 – 53.)

作者简介:

陈得宝 (1975—), 男, 副教授, 博士生, 目前主要研究方向为人工智能、进化计算和机器人等, E-mail: chendb.8@163.com;

赵春霞 (1964—), 女, 教授, 博士生导师, 目前主要研究方向为模式识别、图像处理、人工智能和机器人等, E-mail: zhaochx@mail.njust.edu.cn.