

DOI: 10.7652/xjtuxb201312008

引入群体发现和加入行为的随机搜索算法

王虹, 卫军胡, 刘昌军, 曹建福

(西安交通大学机械制造系统工程国家重点实验室, 710049, 西安)

摘要: 针对自由搜索算法以及自适应随机搜索 (ASS) 算法效率低和寻优能力不足的问题, 提出了一种基于群体发现和加入行为的随机搜索 (HASS) 算法。HASS 算法采用搜索半径的自适应调整策略提高搜索效率, 利用区域混合搜索策略引导群体中的不同个体分别进行全局和局部搜索, 通过状态评估方法引入变异策略避免陷入局部最优。HASS 算法与 ASS 算法的主要区别体现在解的选择机制和搜索策略上, HASS 算法同时接受较优个体和较差个体, 分别为两类个体设计不同的寻优策略来指明搜索方向, 增强了算法跳出局部最优的能力和寻优效率。对 12 个标准测试函数的实验结果表明, 该算法的寻优成功率可达 100%, 较之其他 4 种算法具有更快的收敛速度和更强的全局搜索能力, 特别适于处理复杂的函数优化问题。

关键词: 群集智能; 自由搜索算法; 发现者加入者模型; 区域混合搜索策略

中图分类号: TP13; TP18 **文献标志码:** A **文章编号:** 0253-987X(2013)12-0043-07

A Novel Adaptive Stochastic Search Algorithm Based on Group Founding and Joining Behaviors

WANG Hong, WEI Junhu, LIU Changjun, CAO Jianfu

(State key Laboratory of Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: An adaptive stochastic search algorithm with hybrid strategy (HASS) is presented to improve the low search efficiency and the incompetitive optimization of the free search algorithm and the adaptive stochastic search algorithm (ASS). The algorithm is based on group founding and joining behaviors that exist widely in nature. The strategy to adaptively update the search radius of each individual is used to improve the search efficiency, and a hybrid search strategy is designed to guide different particles to respectively conduct global or local searches. A new mutation operator is introduced to the evolutionary state estimation of the involved particles to improve the population diversity and to avoid premature convergence effectively. The main differences between HASS and ASS are in selection mechanism of solutions and the search strategy. The experimental results on twelve classic benchmark functions show that the HASS algorithm has competitive performance to other four existing algorithms in terms of accuracy, robustness and convergence speed, especially for high-dimensional multimodal problems.

Keywords: swarm intelligence; free search; producer-scrounger; hybrid strategy

群集智能是模拟自然界中众多行为简单的个体通过相互作用产生群体行为的优化算法^[1-2]。蚁群

优化(Ant Colony Optimization, ACO)^[3]和粒子群优化(Particle Swarm Optimization, PSO)^[4]是目前

群集智能优化算法中两个最为典型的代表。前者是对蚂蚁觅食行为的抽象^[5],主要用于组合优化;后者是对鸟群、鱼群进行模拟^[6],主要用于函数优化。

自由搜索(FS)算法^[7]是由 Kalin Penev 和 Guy Littlefai 于 2005 年提出的一种新的群集智能优化法。它借鉴高等群居生物的嗅觉和机动性^[8]等生物特性,吸收了遗传算法(GA)^[9]的优胜劣汰机制以及 PSO 算法中群体的记忆功能等优点。FS 算法需要设置的参数较少,结构简单,但是研究发现,该算法对邻域搜索半径十分敏感,容易出现早熟收敛的现象。近年来一些研究者提出许多调整邻域搜索半径的策略。文献[8]采用线性减小的方法实时调整搜索半径,文献[10]采用指数下降策略动态改变个体的邻域搜索范围。文献[11]对个体搜索半径调整策略进行了深入研究,提出了一种自适应随机搜索算法(Adaptive Stochastic Search, ASS)。数值实验结果表明,ASS 算法比 FS 算法的收敛速度和精度都有所提高,但是,由于其在进化过程中采用随机方式不断地探索最优区域,具有一定的盲目性,因此局部寻优能力和收敛效率仍然不够理想。

为了克服上述缺点,本文以高等生物群体行为为背景,基于 PS 模型^[12]提出了一种引入群体发现和加入行为的随机搜索算法(Adaptive Stochastic Search with Hybrid Strategy, HASS)。在寻优过程中,融合发现策略、加入策略以及变异策略来指导群体中的较优个体和较差个体在整个搜索空间进行全局和局部搜索,增强了算法跳出局部最优的能力和寻优效率,从而解决了不同形态的复杂问题。

1 FS 算法简介

FS 算法是模拟一些高等群居动物(例如马群、羊群等)寻找水源的过程,各个体的嗅觉、活动能力以及它们之间的相互关系存在多样性^[7-8]。其中,灵敏度代表嗅觉,表示个体在搜索域内具有的识别能力;搜索半径反映个体的活动能力,决定了个体的搜索范围;信息素作为个体间的通信手段,其大小反映了了解的质量。寻优过程中,个体在其搜索半径内产生多个候选解,通过信息素与灵敏度的比较来发现更好的解,直到满足终止规则。FS 算法的寻优机制如下。

(1)小步精细搜索。在搜索步内,每个个体在其邻域空间内进行 T 小步随机搜索,其行为描述为

$$\left. \begin{aligned} x_{ij} &= x_{0ij} - \Delta x_{ij} + 2\Delta x_{ij} U_{ij}(0,1) \\ \Delta x_{ij} &= R_{ij}^k (x_{\max j} - x_{\min j}) U_{ij}(0,1) \end{aligned} \right\} \quad (1)$$

式中: j 代表变量的第 j 维, $j=1, 2, \dots, N$; i 代表第 i 个个体, $i=1, 2, 3, \dots, M$; t 是搜索步中的当前小步, $t=1, 2, \dots, T$, T 是搜索步数; $U_{ij}(0,1)$ 是 $(0,1)$ 内均匀分布的随机数; $x_{\max j}$ 和 $x_{\min j}$ 是第 j 维变量的搜索边界; R_{ij}^k 为第 k 次迭代每个个体的邻域搜索半径, $R_{ij}^k \in [0,1]$ 。

(2)更新起始点。个体 i 在完成一个搜索步后所得到的当代最优值表示为

$$f_i = \max_t f(x_{ij}) \quad (2)$$

定义信息素为

$$P_i = f_i / \max(f) \quad (3)$$

式中: $\max(f)$ 是迄今为止所有个体的最佳值。定义灵敏度为

$$\left. \begin{aligned} S_i &= S_{\min} + \Delta S_i \\ \Delta S_i &= (S_{\max} - S_{\min}) U_i(0,1) \end{aligned} \right\} \quad (4)$$

式中: $S_{\max}$ 、 $S_{\min}$ 是灵敏度的最大值和最小值; $P_{\max}$ 和 $P_{\min}$ 是信息素的最大值和最小值,规定 $S_{\max} = P_{\max}$, $S_{\min} = P_{\min}$ 。

在完成一代搜索后,确定新一轮搜索的起始点

$$x'_{0ij} = \begin{cases} x'_{0ij}, & P_k < S_i \\ x_{ij}, & P_k \geq S_i \end{cases} \quad (5)$$

式中: $k=1, 2, 3, \dots, M$ 是标记信息素的点。

2 基于群体发现和加入行为的随机搜索算法

2.1 HASS 算法描述

动物的群居生活行为是一个普遍现象,这种行为特性引发了种群内部发现(finding)和加入(joining)^[13]两种觅食策略。为了分析加入的最优策略,提出了两个基本结构模型:①信息共享模型(Information-Sharing, IS)^[14];②发现者-加入者模型(Producer-Scrounger, PS)^[12]。IS 模型假设觅食者在寻找机会加入其他发现者的同时也会不断搜索自己的资源,而在 PS 模型中,觅食者只选取其中的一种策略来寻找资源,发现和加入不能共存。最新研究表明,对于大多数高等动物的加入策略而言,PS 模型可能更合乎情理。

基于以上分析,本文依据 PS 框架设计了一种区域混合搜索策略和变异策略来提高算法的优化性能。基本思想如下:初始个体都以发现者的身份在整个搜索空间进行随机搜索并逐步收缩各自的搜索区域,通过对粒子性能的动态评估进行角色分类。对于较优个体,继续作为发现者寻找资源,利用局部邻域最优位置和全局历史最优位置为进化过程指明

搜索方向,实现整个搜索空间的全局“探索”;对于较差个体,迫使其由发现者变为加入者,使其快速移动到群体历史最优位置进行局部“开发”,并且给予适度变异以增强跳出局部最优的能力。

2.2 HASS 算法模型

2.2.1 邻域搜索半径的动态调整 HASS 算法采用以下随机方法产生初始种群

$$x_{0ij} = x_{\min j} + (x_{\max j} - x_{\min j})U_{ij}(0,1) \quad (6)$$

针对 FS 算法对搜索半径敏感这一缺陷,文献[11]提出了两种实时调整策略,其特点都是由前期的广泛粗略搜索逐步演化为后期的局部精细搜索,使之不断逼近最优区域,但是对于不同的测试函数,ASS 算法中需要设定不同的初始搜索域,为了简化算法结构,本文统一采用如下公式进行实时调整

$$R_{ij}^k = \alpha(1 - k/G)^\beta U_{ij}(0,1) \quad (7)$$

式中: α 是第 k 次迭代的半径收缩系数; β 是迭代收缩指数。

2.2.2 粒子性能的动态评估与分类 在 HASS 算法中,个体的差异随着迭代过程不断发生变化,通过对所有粒子的动态评估确定“较优”个体和“较差”个体。

针对最大化问题,构造适应度函数

$$F_i = (f_i - \bar{f}) / (\max_i f_i - \bar{f}) \quad (8)$$

式中: $\bar{f} = \frac{1}{M} \sum_{i=1}^M f_i$ 。

定义可接受水平

$$L_i = U_i(0,1) \quad (9)$$

若 $F_i \geq L_i$,则个体 i 为较优个体,按照发现策略在整个空间进行探索;若 $F_i < L_i$,则个体 i 为较差个体,采用加入策略追随到群体的最优区域。以上处理方式既简单又保持了种群的多样性,但是这种随机选择策略存在一定的不确定性。本文分别为两类个体设计了适当的寻优策略,使其快速且有目的地进行区域随机搜索,从而减少种群在整个空间盲目搜索的概率。

2.2.3 基于 PS 模型的区域混合搜索策略 在较优个体的发现过程中,为了尽可能既保证算法的全局搜索能力又加快收敛速度,需要减少粒子只在自己周围寻找最优解的机会,本文采用了一个环形拓扑结构^[15],把所有粒子都储存在该环形列表中,则

$$y'_{ij} = \arg \max \{f_{i-1}, f_i, f_{i+1}\} \quad (10)$$

式中: $\max \{f_{i-1}, f_i, f_{i+1}\}$ 是第 $i-1, i, i+1$ 个个体中的最优值; $i=1, 2, 3, \dots, M$; y'_{ij} 为当前局部邻域结构的最优位置。

一轮搜索结束后,较优个体新的搜索中心位置更新为

$$x_{0ij} = \omega y'_{ij} + c_1(y_{ij} - y'_{ij}) + c_2(x_j^* - y'_{ij}) \quad (11)$$

式中: ω 为惯性权重; c_1 和 c_2 为 $[0,1]$ 内均匀分布的随机数; y_{ij} 是各个体的历史最优位置; x_j^* 是迄今整个种群搜索到的最优位置。

对于较差个体,文献[16]已经证明,让其向自身最优或种群最优学习有利于局部搜索,并且能够快速地把粒子引向最优区域。这类局部搜索算子不仅具有很强的局部寻优能力,而且能有效地提高算法的收敛效率。加入策略为

$$x_{0ij} = x_j^* \quad (12)$$

2.2.4 较差个体的变异策略 在较差个体的加入过程中,为了增强种群的多样性,当较差个体追随到历史最优位置附近后,基于粒子的搜索行为和种群的分布信息,利用一种进化状态评估(ESE)方法^[17]随机选取其中一维 q 进行变异。ESE 方法是以粒子之间的几何关系为依据计算种群的进化因子,并利用其分布信息区分进化过程中的探索、开发、收敛和跳出 4 种状态^[17]。

首先,为了估计种群在进化过程中的分布状态,计算每个粒子 i 与其余粒子的平均距离

$$d_i = \frac{1}{M-1} \sum_{k=1, k \neq i}^M \left(\sum_{j=1}^N (x_i^j - x_k^j)^2 \right)^{1/2} \quad (13)$$

比较所有粒子的 d_i ,分别确定出最大距离和最小距离,记为 $d_{\max}$ 和 $d_{\min}$ 。特别地,在收敛阶段,最优粒子到其他粒子的平均距离最小,而在跳出阶段,平均距离最大。

其次,定义整个种群的“进化因子”为

$$h = (d_g - d_{\min}) / (d_{\max} - d_{\min}) \in [0,1] \quad (14)$$

式中: d_g 表示当前全局最优粒子与其余粒子的平均距离。

最后,根据粒子的分布状态,变异半径按下式进行调整

$$R_{iq} = \min \left\{ \frac{(s+1)}{\alpha} R_i^k (1 - k/G) e^h, 1 \right\} \quad (15)$$

式中: s 为算法目前陷入停滞的代数。然后,再按照式(1)在迁移区域内进行 3 次随机搜索,取其最优位置作为新的坐标点,记最优位置为 x_{iq} 。

2.3 HASS 算法的实现

HASS 算法的具体步骤如下。

步骤 1 初始化。

步骤 1.1 设定参数值:种群大小 M ,搜索步数 T ,

最大搜索代数 G , 半径收缩系数 α , 迭代收缩指数 β , 每个个体的邻域搜索半径 R_{ij} 。

步骤 1.2 产生初始种群: 按式(6)产生初始种群。

步骤 2 寻优搜索。

步骤 2.1 区域随机搜索: 按式(7)计算个体的邻域搜索半径, 按式(1)在搜索区域内进行 T 次随机搜索。

步骤 2.2 计算适应度: 记录各个体的历史最优位置、各个体的环形拓扑结构最优位置、群体的当次迭代最大值和最小值以及群体历史最优值, 按式(8)计算个体相对适应度。

步骤 2.3 计算可接受水平: 按式(9)计算可接受水平。

步骤 2.4 更新起始点: 按式(11)、(12)选择新一轮的搜索中心, 在较差个体的加入过程中, 按式(15)随机选择其中一维进行变异, 然后按式(1)生成迁移区域, 在区域内进行 3 次随机搜索, 并取其最优位置作为新一轮搜索的起始点。

步骤 3 终止判断。若满足终止条件, 则运行结束,

输出结果; 否则, 更新迭代次数, 转至步骤 2。

3 仿真实验及结果分析

3.1 测试问题

为了评估 HASS 算法的寻优性能, 对文献[17]中的 12 个经典测试函数分别用 GA、SPSO、ASS、IFS(改进的 FS 算法)^[8] 和 HASS 算法进行仿真实验, 测试函数与参数设置如表 1 所示(其中 $f_1 \sim f_6$ 是单峰函数, $f_7 \sim f_{12}$ 是多峰函数)。

利用 Matlab7.5 的遗传算法优化工具箱(GAOT)^[18] 实现 GA 算法, 使用文献[19]中的粒子群优化工具箱(PSOt)实现 SPSO 算法, IFS、ASS 和 HASS 算法采用 C++ 编写。GA 和 SPSO 的种群大小均为 50, 最大进化代数为 4 000, 其余参数保持默认设置^[18-19]。IFS 算法采用文献[8]的参数设置方案。ASS 算法取 $\beta=15$, 其他参数设置参照文献[11]。HASS 算法的参数设置为: 种群数 $M=10$, 邻域随机搜索步数 $T=5$, 终止代数 $G=3\ 000$, 半径的两个收缩系数分别为 $\alpha=0.1, \beta=15$, 权重 $\omega=0.4$ 。

表 1 Benchmark 函数与参数设置

测试函数	函数名	维数	搜索范围	最优值	接受度
f_1	Sphere	30	$[-100, 100]^N$	0	0.01
f_2	Schwefel's P2.22	30	$[-10, 10]^N$	0	0.01
f_3	Quadric	30	$[-100, 100]^N$	0	100
f_4	Rosenbrock	30	$[-30, 30]^N$	0	100
f_5	Step	30	$[-100, 100]^N$	0	0
f_6	Quadric Noise	30	$[-1.28, 1.28]^N$	0	0.01
f_7	Schwefel	30	$[-500, 500]^N$	-12 569.5	-10 000
f_8	Rastrigin	30	$[-5.12, 5.12]^N$	0	50
f_9	Noncontinuous Rastrigin	30	$[-5.12, 5.12]^N$	0	50
f_{10}	Ackley	30	$[-32, 32]^N$	0	0.01
f_{11}	Griewank	30	$[-600, 600]^N$	0	0.01
f_{12}	Generalized Penalized	30	$[-50, 50]^N$	0	0.01

所有实验均在 3.00 GHz Intel 处理器、2.0 GB 内存的微机上进行, 操作系统为 Windows XP3。

3.2 算法比较和分析

3.2.1 寻优精度的比较 对上述函数各自独立运行 30 次, 计算每种算法的平均最优值、标准差以及 30 次实验的成功率, 实验结果如表 2 所示。结果表明, 对于所有 12 个标准测试函数, HASS 算法在最优解精度、稳定性和成功率方面都有很大的提高, 总体性能明显优于其他 4 种算法。具体来说, 对于 $f_1 \sim f_6$ 这 6 个单峰函数, HASS 算法除了在 f_4 上稍

逊于 GA、IFS 和 ASS 外, 其他函数的优化结果均有较大幅度的改善。其中, 在 f_1, f_2, f_3, f_6 上的收敛精度是最高的, 在 f_5 上达到了最优解。特别地, IFS 和 ASS 算法都很难处理 f_3 函数, 而 HASS 算法却表现出一定的优势, 取得了比较满意的结果。对于 $f_7 \sim f_{12}$ 这 6 个多峰函数, HASS 算法的优化精度都是最高的, 并且在 f_7, f_8, f_9 和 f_{11} 上均能找到全局最优解, 表现出潜在的优越性。

3.2.2 收敛速度的比较 为了更直观地分析算法的寻优效率, 图 1~图 4 描述了 5 种算法求解部分

函数最优值的进化曲线。在相同的精度要求下,对于大多数测试问题,HASS 算法的收敛速度都明显快于其他 4 种算法,且目标函数值可以下降到更低的水平。个别函数在中期会出现收敛缓慢的情况,例如 f_1 函数,这是由于 HASS 算法为了加强局部

搜索能力,引入了局部搜索算子,增加了函数评价次数,因此在进化中期,HASS 收敛曲线的下降速度比 SPSO 稍慢一些,但在收敛前期和后期仍然具有一定的优势,且具有更低的目标函数值。

表 2 5 种算法实验结果的比较





算法	项目	f_1	f_2	f_3	f_4	f_5	f_6
GA	平均值	8.79×10^{-9}	2.96×10^{-2}	9.90×10^{-3}	15.865 81	7.00×10^{-1}	1.609 23
	标准差	4.69×10^{-9}	3.80×10^{-2}	7.16×10^{-3}	27.048 42	8.37×10^{-1}	9.37×10^{-1}
	成功率	100%	46.67%	100%	100%	53.33%	0
SPSO	平均值	1.60×10^{-65}	1.63×10^{-13}	8.63×10^{-3}	34.516 07	1.33×10^{-1}	8.07×10^{-1}
	标准差	4.86×10^{-65}	8.91×10^{-13}	1.23×10^{-2}	24.323 08	3.46×10^{-1}	2.95×10^{-1}
	成功率	100%	100%	100%	100%	86.67%	0
IFS	平均值	1.22×10^{-7}	1.75×10^{-4}	6 634.3	22.307 8	0	3.81×10^{-2}
	标准差	1.41×10^{-8}	1.16×10^{-5}	1 007.5	1.432 7	0	7.26×10^{-3}
	成功率	100%	100%	0	100%	100%	0
ASS	平均值	1.15×10^{-22}	4.36×10^{-10}	12 424.9	24.076 7	0	6.35×10^{-2}
	标准差	9.43×10^{-23}	3.92×10^{-10}	2 606.33	2.384 33	0	1.37×10^{-2}
	成功率	100%	100%	0	100%	100%	0
HASS	平均值	5.09×10^{-78}	1.02×10^{-39}	5.67×10^{-76}	27.190 3	0	3.80×10^{-6}
	标准差	2.81×10^{-78}	3.21×10^{-40}	4.96×10^{-76}	0.398 911	0	6.46×10^{-6}
	成功率	100%	100%	100%	100%	100%	100%

算法	项目	f_7	f_8	f_9	f_{10}	f_{11}	f_{12}
GA	平均值	-118.359	6.964 715	23.966 67	6.67×10^{-5}	1.60×10^{-10}	1.13×10^{-10}
	标准差	9.31×10^{-10}	3.731 954	4.055 506	1.69×10^{-5}	8.95×10^{-11}	9.89×10^{-11}
	成功率	0	100%	100%	100%	100%	100%
SPSO	平均值	-9 082.752	35.387 34	11.100 60	3.19×10^{-14}	8.14×10^{-17}	3.80×10^{-2}
	标准差	462.849 7	9.016 092	5.701 804	1.22×10^{-14}	1.09×10^{-16}	8.81×10^{-2}
	成功率	0	96.67%	100%	100%	100%	76.67%
IFS	平均值	-9 720.9	108.251 1	0.833 37	8.13×10^{-5}	3.63×10^{-7}	3.94×10^{-10}
	标准差	364.17	13.514 2	0.636 84	4.40×10^{-6}	6.57×10^{-8}	4.75×10^{-10}
	成功率	20%	0	100%	100%	100%	100%
ASS	平均值	-9 167.56	77.770 6	2.666 67	1.08×10^{-11}	1.85×10^{-16}	1.06×10^{-21}
	标准差	278.266	9.494 27	1.043 5	5.33×10^{-12}	1.41×10^{-16}	1.11×10^{-21}
	成功率	0	0	100%	100%	100%	100%
HASS	平均值	-12 569.5	0	0	3.88×10^{-15}	0	3.62×10^{-32}
	标准差	5.00×10^{-12}	0	0	6.38×10^{-16}	0	6.54×10^{-32}
	成功率	100%	100%	100%	100%	100%	100%

3.2.3 HASS 算法性能分析 大量的数值研究发现, β 值的大小直接影响着搜索半径的收缩速度。HASS 算法中 β 的调整范围一般在 3~15,而为了保证其收敛速度,实验中统一取 $\beta=15$,较大的 β 值削减了算法的全局搜索能力,所以导致 HASS 算法

对病态函数 f_4 的优化结果改善有限。由此可以得出结论,针对类似 Rosenbrock 的病态优化问题,适当选取较小的 β 值可以有效避免 HASS 算法陷入局部最优。

由表 2 可见,HASS 比 ASS 算法的优化性能有

图1 f_1 函数的收敛曲线图2 f_3 函数的收敛曲线图3 f_7 函数的收敛曲线图4 f_8 函数的收敛曲线

了很大提高,充分说明基于PS模型的区域混合搜索策略克服了粒子搜索过程中方向性差、目的性弱的缺点,增强了局部搜索能力;此外,对于 f_5 、 f_7 、 f_8 、 f_9 和 f_{11} 而言,HASS算法搜索到了全局最优

解,这表明基于ESE方法提出的变异策略增加了种群的多样性,使HASS算法具有较好的跳出局部最优的能力。由此可见,引入群体发现和加入行为的HASS算法既保证了个体不会出现差异较大的情况,也避免了“群集”现象,很好地实现了“探索”与“开发”之间的平衡。

4 结 论

针对FS算法在局部搜索能力上的缺陷,本文提出了一种引入群体发现和加入行为的随机搜索算法。该算法继承了FS和ASS的简洁以及自适应的优点,同时引入区域混合搜索策略和变异策略增强其寻优能力。对12个典型的Benchmark函数的数值实验验证了HASS算法的正确性和有效性,特别是在处理非线性和多峰值的复杂函数时具有显著的优势。该算法不仅结构简单,设置的参数较少,而且具有内在的并行性,易于与其他算法相结合,特别适用于多种不同类型的复杂多模态函数优化问题。另外,HASS本质上是一种随机搜索算法,对环境的适应性、鲁棒性仍有待提高。在未来的研究中,可以考虑采用反馈机制来减少算法的随机因素并提高其自适应性。

参考文献:

- [1] KENNEDY J, EBERHART R, SHI Y H. Swarm intelligence [M]. San Mateo, CA, USA: Morgan Kaufmann, 2001.
- [2] 肖人彬, 陶振武. 群集智能研究进展 [J]. 管理科学学报, 2007, 10(3): 80-96.
XIAO Renbin, TAO Zhenwu. Research progress of swarm intelligence [J]. Journal of Management Sciences in China, 2007, 10(3): 80-96.
- [3] DORIGO M, BLUM C. Ant colony optimization theory: a survey [J]. Theoretical Computer Science, 2005, 344(2/3): 243-278.
- [4] EBERHART R, KENNEDY J. A new optimizer using particle swarm theory [C]//Proceedings of the 6th International Symposium on Micro Machine and Human Science. Piscataway, NJ, USA: IEEE, 1995: 39-43.
- [5] DORIGO M, BONABEAU E, THERAULAZ G. Ant algorithms and stigmergy [J]. Future Generation Computer Systems, 2000, 16(8): 851-871.
- [6] CARLOS A, SEBASTIAN L. A particle swarm optimization algorithm for part-machine grouping [J]. Robotics and Computer-Integrated Manufacturing, 2006, 22(5/6): 468-474.

- [7] PENEV K, LITTLEFAIR G. Free search: a comparative analysis [J]. *Information Sciences*, 2005, 172 (1/2): 173-193.
- [8] 周晖, 李丹美, 邵世煌, 等. 一种新的群集智能优化及其改进研究 [J]. *系统工程与电子技术*, 2008, 30 (2): 337-340.
ZHOU Hui, LI Danmei, SHAO Shihuang, et al. Novel swarm intelligence algorithm and its improvement [J]. *Systems Engineering and Electronics*, 2008, 30 (2): 337-340.
- [9] HOLLAND J H. *Adaptation in natural and artificial systems* [M]. Cambridge, USA: MIT Press, 1992: 6-24.
- [10] LI Tuanjie, CAO Yuyan, SUN Guoding. Free search algorithm with the variable neighbourhood and step [J]. *Journal of Xidian University*, 2010, 37(4): 737-742.
- [11] LIU Changjun, WEI Junhu, QIAO Yan, et al. An adaptive stochastic search algorithm [C]//*Proceedings of the 2011 IEEE International Conference on Automation and Logistics*. Piscataway, NJ, USA: IEEE, 2011: 154-158.
- [12] BAMARD C J, SIBLY R M. Producers and scroungers: a general model and its application to captive flocks of house sparrows [J]. *Animal Behaviour*, 1981, 29(5): 543-550.
- [13] GIRALDEAU L A, BEAUCHAMP G. Food exploitation: searching for the optimal joining policy [J]. *Trends in Ecology and Evolution*, 1999, 14(3): 102-106.
- [14] CLARK C W, MANGEL M. Foraging and flocking strategies: information in an uncertain environment [J]. *American Naturalist*, 1984, 123(3): 626-641.
- [15] LI Xiaodong, YAO Xin. Cooperatively coevolving particle swarms for large scale optimization [J]. *IEEE Transactions on Evolutionary Computation*, 2012, 16 (2): 210-224.
- [16] LIANG J J, QIN A K, SUGANTHAN P N, et al. Comprehensive learning particle swarm optimizer for global optimization of multimodal functions [J]. *IEEE Transactions on Evolutionary Computation*, 2006, 10 (3): 281-295.
- [17] ZHAN Zhihui, ZHANG Jun, LI Yun, et al. Adaptive particle swarm optimization [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B Cybernetics*, 2009, 39(6): 1362-1381.
- [18] HOUCK C R, JOINES J, KAY M. A genetic algorithm for function optimization: a MATLAB imple-

mentation, NCSU-IE TR 95-09 [R]. Raleigh, North Carolina, USA: North Carolina State University, 1995.

- [19] BIRGE B. PSOT: a particle searm optimization toolbox for use with MATLAB [C]//*Proceedings of the 2003 IEEE Swarm Intelligence Symposium*. Piscataway, NJ, USA: IEEE, 2003: 182-186.

[本刊相关文献链接]

- 杨清宇, 孙凤伟. 一种迭代改进的球向量机故障诊断算法. 2013, 47(10): 1-6. [doi:10.7652/xjtuxb201310001]
- 仲兆平, 严青, 邓学群, 等. 采用非线性粒子群算法的同步糖化发酵参数辨识. 2013, 47(7): 124-128. [doi:10.7652/xjtuxb201307023]
- 傅文渊, 凌朝东. 自适应折叠混沌优化方法. 2013, 47(2): 33-38. [doi:10.7652/xjtuxb201302006]
- 莫同, 褚伟杰, 李伟平, 等. 采用超图的微博群落感知方法. 2012, 46(11): 120-126. [doi:10.7652/xjtuxb201211022]
- 徐健, 景明利, 齐春, 等. 采用遗传算法的分层贪婪字典训练算法. 2012, 46(4): 18-23. [doi:10.7652/xjtuxb201204004]
- 薛咏, 冯博琴, 等. 扩展主题图本体融合策略与算法. 2011, 45 (10): 13-18. [doi:10.7652/xjtuxb201110003]
- 彭柳青, 张军英. 一种鲁棒的子空间聚类算法. 2011, 45(6): 13-19. [doi:10.7652/xjtuxb201106003]
- 豆增发, 高琳. 应用粒子群优化-条件随机域的文本生物实体识别. 2010, 44(12): 38-42. [doi:10.7652/xjtuxb201012008]
- 郑巍, 刘三阳, 寇晓丽. 一种面向传感器网络的蚁群优化路径恢复算法. 2010, 44(1): 83-86. [doi:10.7652/xjtuxb201001018]
- 魏平, 徐成贤, 段成德. 全局智能优化集成算法研究. 2009, 43 (12): 60-64. [doi:10.7652/xjtuxb200912013]
- 王峰, 邢科义, 徐小平. 系统辨识的粒子群优化方法. 2009, 43 (2): 116-120. [doi:10.7652/xjtuxb200902025]
- 张育林, 庄健, 李小虎, 等. 小世界邻域优化的局部线性嵌入算法. 2008, 42(12): 1486-1489. [doi:10.7652/xjtuxb200812011]
- 吴慧卓, 张可村. 基于拉格朗日对偶的一类全局优化算法. 2008, 42(8): 1031-1034. [doi:10.7652/xjtuxb200808022]
- 夏克文, 苏昶, 沈钧毅, 等. 一种改进的 Grover 量子搜索算法. 2007, 41(10): 1127-1131. [doi:10.7652/xjtuxb20071001]
- 李清华, 邵志标, 耿莉. 一种多层平面电感设计的全局优化方法. 2007, 41(6): 665-668. [doi:10.7652/xjtuxb200706008]
- 贺群武, 王秋旺, 索晓娜, 等. 直接模拟蒙特卡罗方法下的逆温度抽样算法. 2006, 40(1): 22-25. [doi:10.7652/xjtuxb200601006]

(编辑 武红江)