

文章编号: 1001-0920(2013)09-1554-05

人工蜂群算法的收敛性分析

宁爱平^{1,2}, 张雪英¹

(1. 太原理工大学 信息工程学院, 太原 030024; 2. 太原科技大学 电子信息工程学院, 太原 030024)

摘要: 利用随机过程理论, 对人工蜂群算法收敛性进行理论分析, 给出人工蜂群算法的一些数学定义和蜜源位置的一步转移概率, 建立人工蜂群算法的 Markov 链模型, 分析此 Markov 链的一些性质, 论证了人工蜂群状态序列是有限齐次 Markov 链, 且状态空间是不可约的. 结合随机搜索算法的全局收敛准则, 证明了人工蜂群算法能够满足随机搜索算法全局收敛的两个假设, 保证算法的全局收敛.

关键词: 人工蜂群算法; Markov 链; 转移概率; 收敛性

中图分类号: TP301.6

文献标志码: A

Convergence analysis of artificial bee colony algorithm

NING Ai-ping^{1,2}, ZHANG Xue-ying¹

(1. College of Information Engineering, Taiyuan University of Technology, Taiyuan 030024, China; 2. College of Electronics and Information Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China. Correspondent: ZHANG Xue-ying, E-mail: tyzhangxy@163.com)

Abstract: The convergence of artificial bee colony algorithm is analyzed theoretically by using the stochastic process theory. Some mathematical definitions of artificial bee colony algorithm and one step transition probability of nectar source position are given and the Markov chain model of the algorithm is established. Some properties of the Markov chain are analyzed, and the conclusions that the artificial bee colony state sequence is a finite homogeneous of Markov chain and the state space of artificial bee colony is irreducible are obtained. It is proved that the artificial bee colony algorithm ensures the global convergence as the algorithm meets two assumptions of the random search algorithm for the global convergence.

Key words: artificial bee colony algorithm; Markov chain; transition probability; convergence

0 引言

人工蜂群算法(ABC)是一种模拟蜜蜂群智能采蜜行为的蜂群智能优化算法^[1]. 蜜蜂群中的蜜蜂根据各自的分工进行不同的活动, 并实现蜂群信息的共享和交流, 从而找到问题的最优解. 目前, ABC算法已在函数优化^[2-3]和工程领域^[4-8]等一系列问题中得到大量的应用, 并且已涌现出一些ABC算法的改进算法^[9-11]. 但这些研究都是从实验的角度说明了ABC算法的收敛性和有效性, 而有关ABC算法收敛性的理论分析还处于空白, 在一定程度上制约了算法的改进和发展.

Markov过程是一类占有重要地位且具有普遍意义的随机过程, 在自然科学、工程技术和经济管理的各领域都有广泛应用. Markov链理论在随机算法收敛性分析、拟概率收敛和算法处处强收敛上都具有

较强的能力, 目前已成功应用于遗传算法、粒子群算法、蚁群算法等随机算法的收敛性分析上^[12-16]. ABC算法中蜜蜂的运动过程本质上是一个随机过程, 因此, 本文利用Markov理论对ABC算法的收敛性进行分析, 通过建立ABC算法的Markov链模型, 研究人工蜂群状态的转移行为, 结合随机优化算法的收敛标准分析算法的收敛性能.

1 人工蜂群算法

ABC算法将人工蜂群分为引领蜂、跟随蜂和侦查蜂3类, 其中引领蜂和跟随蜂用来开采蜜源, 即寻找最优解, 而侦查蜂用来观察是否陷入局部最优. 每个蜜源代表问题的一个可能解, 蜜源的花蜜量对应相应解的质量(适应度值 fit_i). 在算法搜索过程中, 首先在搜索空间生成初始解 $x_i (i = 1, 2, \dots, SN)$, SN为蜜源个数, 每个解 x_i 是一个 d 维的向量, d 是问题的维

收稿日期: 2012-04-10; 修回日期: 2012-06-01.

基金项目: 国家自然科学基金项目(61072087); 山西省自然科学基金项目(2010011020-1).

作者简介: 宁爱平(1974-), 女, 讲师, 博士生, 从事智能信息处理、语音识别的研究; 张雪英(1964-), 女, 教授, 博士生导师, 从事语音信号处理、多媒体通信、嵌入式系统等研究.

数. 初始化之后, 整个种群将进行引领蜂、跟随蜂和侦查蜂搜寻过程的重复循环, 直到达到最大迭代次数(MCN)或误差允许值 ε .

在搜索过程开始阶段, 每个引领蜂由下式产生一个新解(新蜜源位置):

$$v_{ij} = x_{ij} + \varphi_{ij}(x_{ij} - x_{kj}). \quad (1)$$

其中: $k \in \{1, 2, \dots, SN\}$, $j \in \{1, 2, \dots, d\}$, 且 $k \neq i$; φ_{ij} 为 $[-1, 1]$ 之间的随机数. 检验新解的 fit_i , 若新解的 fit_i 比旧解好, 则引领蜂将记住新解忘掉旧解; 反之, 将保留旧解. 在所有引领蜂完成搜寻过程之后, 引领蜂会在舞蹈区跳摇摆舞把解的信息及 fit_i 信息与跟随蜂分享. 跟随蜂根据下式计算每个解的概率:

$$p_i = fit_i / \sum_{k=1}^{SN} fit_k. \quad (2)$$

然后在 $[0, 1]$ 区间内产生一个随机数, 如果解的概率大于该随机数, 则跟随蜂由式(1)产生一个新解, 并检验新解的 fit_i , 若新解的 fit_i 比之前好, 则跟随蜂将记住新解忘掉旧解; 反之, 它将保留旧解. 在所有跟随蜂完成搜寻过程之后, 如果一个解通过有限次循环不能被进一步改良, 则该蜜源会被舍弃. 设蜜源 x_i 被舍弃, 则此蜜源对应的引领蜂将变成一个侦查蜂. 此侦查蜂由下式产生一个新的蜜源代替它:

$$x_{ij} = x_{\min j} + \text{rand}(0, 1)(x_{\max j} - x_{\min j}), \quad (3)$$

其中 $j \in \{1, 2, \dots, D\}$. 然后返回引领蜂搜索过程, 开始重复循环.

ABC算法的蜜源质量一般是越大越好, 即适应度值越大越好, 而对应于要优化的问题, 需要分两种情况考虑, 即最小值问题与最大值问题. 设 $f(\cdot)$ 是优化问题的目标函数, 若优化最小值问题, 则适应度函数为 $f(\cdot)$ 的变形, 一般用下式表示:

$$fit(x_i) = \begin{cases} \frac{1}{1 + f(x_i)}, & f(x_i) > 0; \\ 1 + \text{abs}(f(x_i)), & f(x_i) \leq 0. \end{cases} \quad (4)$$

若优化最大值问题, 则适应度函数即为目标函数.

ABC算法进行贪婪选择时, 按下式进行:

$$v_i = \begin{cases} v_i, & fit(v_i) > fit(x_i); \\ x_i, & fit(v_i) \leq fit(x_i). \end{cases} \quad (5)$$

以后不加特殊说明, 都按优化最小值问题考虑.

2 人工蜂群算法的 Markov 链模型

为了说明ABC算法的Markov链模型, 需要先给出一些相关的数学描述和定义^[17-18].

定义1(人工蜂状态和人工蜂状态空间) 人工蜂状态由人工蜂运动时蜜源的位置构成, 记为 X , $X \in A$, A 为可行解空间. 人工蜂的所有可能状态组成的集合构成人工蜂的状态空间, 记为 $\mathbf{X} = \{X | X \in A\}$.

定义2(人工蜂群状态和人工蜂群状态空间) 人

工蜂群中所有人工蜂的状态构成人工蜂群状态, 记为 $s = (X_1, X_2, \dots, X_{SN})$, X_i 表示第 i 个人工蜂的状态. 人工蜂群所有可能状态组成的集合构成人工蜂群的状态空间, 记为 $S = \{s = (X_1, X_2, \dots, X_{SN}) | X_i \in \mathbf{X}, 1 \leq i \leq SN\}$.

定义3(状态等价) 对于 $s \in S, X \in s$, 记 $\varphi(s, X) = \sum_{i=1}^{SN} \chi_{|X|}(X_i)$. 其中: χ_A 为事件 A 的示性函数, $\varphi(s, X)$ 为人工蜂群状态 s 中包含人工蜂状态 X 的数目. 有两个人工蜂群 $s_1, s_2 \in S$, 对于 $\forall X \in \mathbf{X}$, 若有 $\varphi(s_1, X) = \varphi(s_2, X)$, 则称 s_1 和 s_2 等价, 记作 $s_1 \sim s_2$.

定义4(状态等价类) 由等价关系“ \sim ”在 S 上诱导的人工蜂群状态等价类记作 $L = S / \sim$, 简称人工蜂群等价类. 人工蜂群等价类存在以下性质:

- 1) 某等价类 L 内任意蜂群状态之间都是等价的, 即 $s_i \sim s_j, \forall s_i, s_j \in L$;
- 2) L 内任意蜂群状态与 L 外的任意蜂群状态不等价, 记作 $s_i \not\sim s_j, \forall s_i \in L, \forall s_j \notin L$;
- 3) 任意两个不同等价类没有交集, 即 $L_1 \cap L_2 = \emptyset, \forall L_1 \neq L_2$.

定义5(人工蜂状态转移) 对于 $\forall X_i \in s, \forall X_j \in s$, ABC算法迭代中, 人工蜂状态由 X_i 一步转移到 X_j , 记为 $T_s(X_i) = X_j$.

定理1 ABC算法中, 人工蜂状态由 X_i 一步转移到 X_j 的转移概率 $p(T_s(X_i) = X_j)$ 的表达式为

$$p(T_s(X_i) = X_j) = \begin{cases} p_{em}(T_s(X_i) = X_j), & \text{由引领蜂实现;} \\ p_{on}(T_s(X_i) = X_j), & \text{由跟随蜂实现;} \\ p_{sc}(T_s(X_i) = X_j), & \text{由侦查蜂实现;} \\ p_{em}(T_s(X_i) = X_j) \times p_{on}(T_s(X_i) = X_j), & \text{由引领蜂和跟随蜂共同完成.} \end{cases} \quad (6)$$

证明 视人工蜂群体为超空间的一组点集, 则人工蜂食物源的更新过程即是在超空间中进行点集之间的变换. 根据定义5和ABC算法的几何性质, 可得引领蜂由状态 X_i 一步转移到状态 X_j 的转移概率

$$p_{em}(T_s(X_i) = X_j) = \begin{cases} \frac{1}{|X_i - X_k|} p_1(x_i \rightarrow x_j), \\ X_j \in [X_i - (X_i - X_k), X_i + (X_i - X_k)]; \\ 0, & \text{otherwise.} \end{cases} \quad (7)$$

其中

$$p_1(x_i \rightarrow x_j) = \begin{cases} 1, & f(x_j) < f(x_i); \\ 0, & f(x_j) \geq f(x_i). \end{cases} \quad (8)$$

跟随蜂由状态 X_i 一步转移到状态 X_j 的转移概率为

$$p_{on}(T_s(X_i) = X_j) =$$

$$\begin{cases} \frac{1}{|X_i - X_k|} p_1(x_i \rightarrow x_j), \\ X_j \in [X_i - (X_i - X_k), X_i + (X_i - X_k)] \text{ 且} \\ \text{rand}[0, 1] < p_i; \\ 0, \text{ otherwise.} \end{cases} \quad (9)$$

当引领蜂陷入局部最优时, 侦查蜂将产生随机解 x_j 代替局部最优解 x_i , 所以侦查蜂由状态 X_i 一步转移到状态 X_j 的转移概率

$$p_{sc}(T_s(X_i) = X_j) = \begin{cases} \frac{1}{|X_{\max} - X_{\min}|}, \\ X_j \in [X_{\min}, X_{\max}] \text{ 且} \\ \text{状态 } X_i \text{ 的迭代次数 } \text{int} > \text{limit}; \\ 0, \text{ otherwise.} \end{cases} \quad (10)$$

其中 limit 是解未被更新的次数. 式 (7)~(10) 中 X 是多维数据, 加减号表示矢量加减, 绝对值表示超空间立方体的体积. X_k 是在可行解范围内随机选取的食物源位置.

ABC 算法是人工蜂通过不同角色之间的交流转换及协作来实现的, 所以人工蜂状态由 X_i 一步转移到 X_j 的转移概率 $p(T_s(X_i) = X_j)$ 由式 (7)~(10) 共同决定. \square

定义 6 (人工蜂群的状态转移概率) 对于 $\forall s_i \in S, \forall s_j \in S$, ABC 算法迭代中, 人工蜂群状态由 s_i 一步转移到 s_j , 记作 $T_S(s_i) = s_j$. 人工蜂群状态由 s_i 一步转移到 s_j 的转移概率为

$$p(T_S(s_i) = s_j) = \prod_{m=1}^{\text{SN}} p(T_s(X_{im}) = X_{jm}). \quad (11)$$

即人工蜂群状态由 s_i 一步转移到 s_j 的概率为蜂群 s_i 内所有人工蜂的状态同时转移成蜂群 s_j 内所有人工蜂的状态.

定义 7 (人工蜂群等价类间的转移) 假设由等价关系“ \sim ”在 S 上引起的任意两个蜂群状态等价类 $L_i = (s_{i1}, s_{i2}, \dots, s_{in}), L_j = (s_{j1}, s_{j2}, \dots, s_{jm})$, 则 L_i 一步转移到 L_j , 记为 $T_L(L_i) = L_j$, 相应的一步转移概率为

$$p(T_L(L_i) = L_j) = \sum_{c=1}^n \sum_{b=1}^m p(T_S(s_{ic}) = s_{jb}). \quad (12)$$

表明蜂群等价类间的转移包括等价类 L_i 中的所有蜂群转移到等价类 L_j 中的所有蜂群.

定理 2 ABC 中人工蜂群状态序列 $\{s(t) : t > 0\}$ 是有限齐次 Markov 链.

证明 任何优化算法的搜索空间都是有限的, 任一人工蜂状态中 x_i 都是有限的, 因此人工蜂的状态空间 X 是有限的. 又因为一个人工蜂群状态空间 $s = (X_1, X_2, \dots, X_{\text{SN}})$ 由 SN 个人工蜂组成, SN 是有限正

整数, 所以人工蜂群状态空间 S 也是有限的.

由定义 6 可知, 人工蜂群状态序列 $\{s(t) : t > 0\}$ 中, $\forall s(t-1) \in S, \forall s(t) \in S$, 其转移概率 $P(T_s(s(t-1)) = s(t))$ 由蜂群内所有人工蜂的转移概率 $p(T_s(X(t-1)) = X(t))$ 决定. 由定理 1 可知, 蜂群内任一人工蜂的状态转移概率 $p(T_s(X(t-1)) = X(t))$ 仅与 $t-1$ 的状态 $X(t-1)$ 、随机因子 ψ_{ij} 、随机食物源 X_k 、优化问题解的最大值和最小值相关, 所以 $P(T_s(s(t-1)) = s(t))$ 也仅与 $t-1$ 时刻的状态相关, 即人工蜂群状态序列 $\{s(t) : t > 0\}$ 具有 Markov 性. 又因为状态空间为可列集, 所以其构成一个有限 Markov 链.

由定理 1 可知, $p(T_s(X(t-1)) = X(t))$ 仅与 $X(t-1)$ 时刻 $t-1$ 的状态有关, 而与时刻 $t-1$ 无关, 因此状态序列 $\{s(t) : t \geq 0\}$ 是有限齐次 Markov 链. \square

3 人工蜂群算法收敛性分析

ABC 算法属于随机搜索算法的范畴, 可以通过文献 [19] 给出的随机算法收敛准则判定 ABC 的收敛行为.

3.1 收敛准则

对于优化问题 $\langle A, f \rangle$, 有随机优化算法 D , 第 k 次迭代的结果为 x_k , 则下一次迭代的结果为 $x_{k+1} = D(x_k, \zeta)$. 其中: A 为可行解空间, f 为适应度函数, ζ 为算法 D 迭代中曾经搜索到的解.

在 Lebesgue 测度空间定义搜索的下确界

$$\psi = \inf\{t : v[x \in A | f(x) < t] > 0\}, \quad (13)$$

其中 $v[x]$ 表示在集合 x 上的 Lebesgue 测度. 因此, 可定义最优区域为

$$R_{\epsilon, M} = \begin{cases} \{x \in A | f(x) < \psi + \epsilon\}, \psi \text{ 有限}; \\ \{x \in A | f(x) < -M\}, \psi = -\infty. \end{cases} \quad (14)$$

其中: $\epsilon > 0, M$ 为充分大的正数, 如果算法找到 $R_{\epsilon, M}$ 中的一个点, 则可认为算法找到了可接受的全局最优或近似全局最优解.

假设 1 $f(D(x, \zeta)) \leq f(x)$, 若 $\zeta \in A$, 则有

$$f(D(x, \zeta)) \leq f(\zeta).$$

假设 2 对于 A 的任意 Borel 子集 B , s.t. $v[B] > 0$, 则有 $\prod_{k=0}^{\infty} (1 - u_k[B]) = 0$. 其中 $u_k[B]$ 为算法 D 第 k 次迭代搜索解在集合 B 上的概率测度.

算法 D 满足假设 1 即能保证算法的适应度值 $f(x)$ 是非递增的; 满足假设 2 即能说明算法连续无穷次搜索不到近似全局最优解的概率为 0.

定理 3 (全局收敛的充要条件)^[19] 设 f 是可测的, 可测空间 A 是 R^n 上可测度的子集, 算法 D 满足假设 1 和假设 2, $\{x_k\}_{k=0}^{\infty}$ 是算法 D 产生的解序列, 则有

$$\lim_{k \rightarrow \infty} P(x_k \in R_{\epsilon, M}) = 1.$$

其中 $P(x_k \in R_{\epsilon, M})$ 是算法第 K 步的解 x_k 在 $R_{\epsilon, M}$ 中的概率测度。

3.2 ABC 算法的收敛性

引理 1 ABC 算法满足假设 1.

证明 ABC 算法的每一次迭代都需要进行贪婪选择, 即

$$v_i = \begin{cases} v_i, & f(v_i) \leq f(x_i); \\ x_i, & f(v_i) > f(x_i). \end{cases}$$

所以, ABC 算法每次迭代都保存了群体最佳位置, 满足假设 1. \square

下面证明 ABC 算法是否满足假设 2.

定义 8(人工蜂群最优状态集 G) 设优化问题 $\langle A, f \rangle$ 的最优解是 g^* , 定义人工蜂群的最优状态集 $G = \{s^* = (X) | f(X) = f(g^*), s \in S\}$.

若 $G = S$, 则在可行解的空间中, 每个解不仅是可行解而且是最优解, 此时进行优化是无意义的, 所以下面的讨论都是在 $G \subset S$ 的情形下进行的.

定理 4 ABC 算法中, 对人工蜂群状态序列 $\{s(t); t \geq 0\}$ 而言, 最优人工蜂群状态集合 G 是状态空间 S 上的一个闭集.

证明 设 $\forall s_i \in G, \forall s_j \notin G$, 对于任意转移步长 $l, l \geq 1$, 由 Chapman-Kolmogorov 方程可得

$$P_{s_i, s_j}^l = \sum_{s_{r_1} \in S} \cdots \sum_{s_{r_{l-1}} \in S} P(T_s(s_i) = s_{r_1}) \cdots P(T_s(s_{r_{l-1}}) = s_j). \quad (15)$$

P_{s_i, s_j}^l 表示蜂群状态 s_i 经过 l 步转移到状态 s_j 的概率, 在式 (15) 展开式的每一项乘积表达式中都存在一项 $P(T_s(s_{r_{c-1}}) = s_{r_c})$, 满足 $s_{r_{c-1}} \in G$ 且 $s_{r_c} \notin G$, 其中 $1 \leq c \leq l$, 根据定义 6 可得蜂群转移概率为

$$p(T_s(s_{r_{c-1}}) = s_{r_c}) = \prod_{m=1}^{SN} p(T_s(X_{im}) = X_{jm}).$$

由 $s_{r_{c-1}} \in G$ 和 $s_{r_c} \notin G$, 有 $f(X_c) > f(X_{c-1}) = f(g^*) = \inf(f(a)), a \in A$, 则至少存在 $p(T_s(s_{r_{c-1}}) = s_{r_c}) = 0$, 故此时 $P_{s_i, s_j}^l = 0$, 因此 G 是 S 上的一个闭集. \square

定理 5 人工蜂群状态空间 S , 不存在非空闭集 M , 使得 $M \cap G = \emptyset$.

证明 反证法. 假设状态空间 S 还存在一个非空闭集 M , 且 $M \cap G = \emptyset$. 设 $s_i = (g^*, g^*, \dots, g^*) \in G, \forall s_j = (x_{j1}, x_{j2}, \dots, x_{jd}) \in M$, 有 $f(x_{jc}) > f(g^*)$, 则经过有限次迭代会满足定理 1 中条件 (10), 出现 $p_{sc}(T_s(X_i) = X_j) > 0$. 所以当步长 l 足够大时, P_{s_i, s_j}^l 展开式中必存在某项乘积表达式, 使得其中的每一步转移概率 $P(T(s_{r_{c+i}}) = s_{r_{c+i+1}})$ 都满足定理 1 中条件 (6), 即 $P(T(s_{r_{c+i}}) = s_{r_{c+i+1}}) > 0$. 由定理 4 中式 (15) 可知 $P_{s_i, s_j}^l > 0$, M 不是闭集, 与题设矛盾, 因此人工蜂群状态的 Markov 链是不可约的, 状态空间 S 不

含除 G 之外的闭集. \square

定理 6 假定马尔科夫链有一个非空闭集 E , 且不存在另一个非空闭集 O , 使得 $E \cap O = \emptyset$, 则当 $j \in E$ 时, 有 $\lim_{n \rightarrow \infty} P(X_n = j) = \pi_j$, 且当 $j \notin E$ 时, 有 $\lim_{n \rightarrow \infty} P(X_n = j) = 0$ [16].

定理 7 当蜂群内部迭代趋于无穷时, 蜂群状态序列必将进入最优状态集 G .

由定理 4 ~ 定理 6 即可得出定理 7 成立.

引理 2 ABC 算法满足假设 2.

证明 若使假设 2 成立, 则要求算法 D 连续无穷次未搜索到 B 中元素的概率为 0, 由定理 7, 算法连续无穷次搜索不到全局最优解的概率为 0, 则有 $0 < u_k[B] < 1$, 即 $\prod_{k=0}^{\infty} (1 - u_k[B]) = 0$ 满足假设 2. \square

定理 8 ABC 算法收敛到全局最优.

由于 ABC 算法满足假设 1 和假设 2, 通过定理 3 可以得出 ABC 算法是一个全局收敛算法.

4 结 论

在 ABC 算法的基础上, 描述了人工蜂和人工蜂群的状态空间, 给出了人工蜂群 Markov 链模型一系列定义及人工蜂和人工蜂群的一步转移概率的具体表达式, 同时分析了 Markov 链的几种性质, 并结合随机搜索算法的收敛准则, 验证了 ABC 算法的全局收敛性. 本文对算法随机过程的理论分析和得出的结论对算法的具体理解和算法的改进有一定的理论指导意义, 如提高算法的搜索效率可以考虑用更好的局部搜索来代替随机解的产生. 下一步将对 ABC 算法进行更加深入的理论研究, 如利用非线性动力学的理论对人工蜂运动轨迹和算法的稳定性进行研究, 利用鞅序列收敛理论对算法的收敛性进一步研究等. 另外, 从实际应用角度出发, 算法的参数选择、算法的基本运动方程的改进和算法与其他优化算法的融合也将是接下来研究的内容.

参考文献(References)

- [1] Karaboga D. An idea based on honey bee swarm for numerical optimization[R]. Erciyes University, Engineering Faculty, Computer Engineering Department, 2005.
- [2] Dervis Karaboga, Bahriye Akay. A comparative study of artificial bee colony algorithm[J]. Applied Mathematics and Computation, 2009, 214(1): 108-132.
- [3] Guopu Zhu, Sam Kwong. Gbest-guided artificial bee colony algorithm for numerical function optimization[J]. Applied Mathematics and Computation, 2010, 217(7): 3166-3173.
- [4] Xu Chunfan, Duan Haibin. Artificial bee colony(ABC) optimized edge potential function(EPF) approach to target

- recognition for low-altitude aircraft[J]. Pattern Recognition Letters, 2010, 31(13): 1759-1772.
- [5] Szeto W Y, Wu Yongzhong, Sin C Ho. An artificial bee colony algorithm for the capacitated vehicle routing problem[J]. European J of Operational Research, 2011, 215(1): 126-135.
- [6] Omkar S N, Senthilnath J, Rahul Khandelwal, et al. Artificial bee colony(ABC) for multi-objective design optimization of composite structures[J]. Applied Soft Computing, 2011, 11(1): 489-499.
- [7] Ming-Huwi Horng. Multilevel thresholding selection based on the artificial bee colony algorithm for image segmentation[J]. Expert Systems with Applications, 2011, 38(11): 13785-13791.
- [8] Karaboga D, Ozturk C. A novel clustering approach: artificial bee colony(ABC) algorithm[J]. Applied Soft Computing, 2011, 11(1): 652-657.
- [9] 毕晓君, 王艳娇. 加速收敛的人工蜂群算法[J]. 系统工程与电子技术, 2011, 33(12): 2755-2761.
(Bi X J, Wang Y J. Artificial bee colony algorithm with fast convergence[J]. Systems Engineering and Electronics, 2011, 33(12): 2755-2761.)
- [10] 罗钧, 李研. 具有混沌搜索策略的蜂群优化算法[J]. 控制与决策, 2010, 25(12): 1913-1916.
(Luo J, Li Y. Artificial bee colony algorithm with chaotic-search strategy[J]. Control and Decision, 2010, 25(12): 1913-1916.)
- [11] Gao Wei-feng, Liu San-yang. A modified artificial bee colony algorithm[J]. Computers & Operations Research, 2012, 39(3): 687-697.
- [12] 郑金华, 吕卉, 伍军, 等. 基于空间交配遗传算法的收敛性分析[J]. 模式识别与人工智能, 2010, 23(2): 639-645.
(Zheng J H, Lv H, Wu J, et al. Convergence analysis of genetic algorithm based on spaceMating[J]. PR&AI, 2010, 23(2): 639-645.)
- [13] 任子晖, 王坚, 高岳林. 马尔科夫链的粒子群优化算法全局收敛性分析[J]. 控制理论与应用, 2011, 28(1): 462-466.
(Ren Z H, Wang J, Gao Y L. The global convergence analysis of particle swarm optimization algorithm based on Markov chain[J]. Control Theory & Applications, 2011, 28(1): 462-466.)
- [14] 冯远静, 冯祖仁, 彭勤科. 一类自适应蚁群算法及其收敛性分析[J]. 控制理论与应用, 2005, 22(2): 713-717.
(Feng Y J, Feng Z R, Peng Q K. Adaptive ant colony optimization algorithms and its convergence[J]. Control Theory & Applications, 2005, 22(2): 713-717.)
- [15] 苏兆品, 蒋建国, 梁昌勇, 等. 蚁群算法的几乎处处强收敛性分析[J]. 电子学报, 2009, 37(8): 1646-1650.
(Su Z P, Jiang J G, Liang C Y, et al. An almost everywhere strong convergence proof for a class of ant colony algorithms[J]. Acta Electronica Sinica, 2009, 37(8): 1646-1650.)
- [16] 骆剑平, 李霞, 陈泯融. 混合蛙跳算法的 Markov 模型及其收敛性分析[J]. 电子学报, 2010, 38(12): 2875-2880.
(Luo J P, Li X, Chen M R. The Markov model of shuffled frog leaping algorithm and its convergence analysis[J]. Acta Electronica Sinica, 2010, 38(12): 2875-2880.)
- [17] 李宁. 粒子群优化算法的理论分析与应用研究[D]. 武汉: 华中科技大学自动化学院, 2006.
(Li N. Analysis and application of particle swarm optimization[D]. Wuhan: School of Automation, Huazhong University of Science and Technology, 2006.)
- [18] 张波, 张景肖. 应用随机过程[M]. 北京: 清华大学出版社, 2004.
(Zhang B, Zhang J X. Applied stochastic processes[M]. Beijing: Tsinghua University Press, 2004.)
- [19] 曾建潮, 介婧, 崔志华. 微粒群算法[M]. 北京: 科学出版社, 2004.
(Zeng J C, Jie J, Cui Z H. Particle swarm algorithm[M]. Beijing: Science Press, 2004.)

2014 全球智能控制与自动化大会 (WCICA) 征文通知

全球智能控制与自动化大会 (WCICA) 是在中国召开的每两年一次的重要国际会议. 经会议录用的论文将由 IEEE 出版, EI 检索. WCICA 2014 会议将针对控制理论与工程、工程优化、系统感知建模与分析、大数据自动化和智能自动化系统 5 个方向面向全球广泛征集稿件, 并邀请智能控制与自动化领域国际著名教授作大会主报告和分会报告. 会议将于 2014 年 6 月 27-30 日在沈阳举行.

会议相关内容详见会议网站 <http://2014.wcica.info>