

一种新的量子蚁群优化算法^{*}

杨 佳¹, 许 强², 张金荣³, 曹长修¹

(1. 重庆大学自动化学院, 重庆 400030,
2. 重庆工商大学计算机科学与信息工程学院, 重庆 400067)
3. 重庆工学院计算机学院, 重庆 400050)

摘 要: 针对蚁群算法在求解连续空间优化问题时易于陷入局部最优和收敛速度慢的问题, 提出了一种新的基于量子进化的蚁群优化算法。该算法采用量子比特的概率幅表示蚂蚁当前位置信息; 设计了一种新的量子旋转门更新蚂蚁位置, 完成蚂蚁的移动; 最后采用量子非门实现蚂蚁所在位置的变异, 增加位置的多样性。不仅从理论上证明了所提出算法的收敛性, 而且通过仿真实验表明该算法可使搜索空间加倍, 比传统的蚁群算法具有更好的种群多样性, 更快的收敛速度和全局寻优能力。

关键词: 量子进化; 蚁群算法; 连续空间优化

中图分类号: TP18 **文献标识码:** A **文章编号:** 0529-6579(2009)03-0022-06

A Novel Quantum Ant Colony Optimizing Algorithm

YANG Jia¹, XU Qiang², ZHANG Jinrong³, CAO Changxiu¹

(1. College of Automation, Chongqing University, Chongqing 400030, China;
2. College of Computer Science and Information Engineering, Chongqing
Technology and Business University, Chongqing 400067, China;
3. Computer Science School of Chongqing Institute of Technology, Chongqing 400050, China)

Abstract: Aiming at the shortcoming of optimization problems in continuous space based on ant colony optimization which is easy to fall into local optimums and has a slow convergence rate, a novel quantum ant colony optimization algorithm is presented. In this algorithm, each ant position is represented by a group of quantum bits; a new quantum rotation gates are designed to update the position of the ant so as to enable the ant to move. Some quantum bits are mutated by quantum non-gate so as to increase the variety of ant positions. It not only proves the convergence of the proposed algorithms through theoretical analysis, but also demonstrates that the algorithm can double searching space, maintain better population diversity, rapider convergence speed and global optimal ability than the classical ant colony algorithm by simulation experiments.

Key words: quantum evolution; ant colony algorithm; continuous space optimizing

蚁群优化算法 (Ant Colony Optimization Algorithm, ACO) 是由意大利学者 Dorigo 等人于 20 世纪 90 年代初期通过模拟自然界中蚂蚁集体寻径的行为而提出的一种基于种群的启发式仿生进化算法。在求解了旅行商问题、指派问题、调度问题等

离散系统优化问题, 取得了一系列较好的实验结果。然而经典蚁群算法的生物学背景决定了它只限于解决离散系统优化问题, 如何利用蚁群算法高效实现连续空间优化问题求解是一项颇具挑战性的研究工作。近年来, 国内外的研究者对此作了一些尝

* 收稿日期: 2008-07-06

基金项目: 国家自然科学基金资助项目 (60506055), 重庆市科委自然科学基金资助项目 (CSTC2006BB2430)

作者简介: 杨佳 (1973 年生), 女, 讲师, 博士生; 通讯作者: 许强; E-mail: qingxu@.com

试性的应用研究。Monmarché 等人则提出, 蚂蚁从周期性移动的蚁巢出发, 独立地并行完成各自的搜索, 蚂蚁们一个跟着一个的连续的行走, 它适合求解部分离散、部分连续系统优化问题^[1]。Dréo 等人则修改了蚂蚁信息素的留存方式和行走规则, 利用存在于蚂蚁之间的两种通信方式(信息): 间接信息(信息素迹)和蚂蚁之间用触角交流信息的直接通讯方式来指导蚂蚁寻优, 实现连续空间优化问题^[2-3]。国内与此相关的文献^[4-6]大多是将国外文献中的算法用于求解连续空间优化问题, 对ACO算法求解连续空间优化问题的性能, 没有多少改进。仔细分析文献中的求解连续空间优化问题的ACO算法会发现它们的复杂性偏高。然而, 应用ACO算法求解连续空间优化问题的算法复杂性还可以进一步降低。

量子进化算法(Quantum-Inspired Evolutionary Algorithm, QEA)^[7]是新近发展起来的一种概率进化算法, 它以量子计算的一些概念和理论, 诸如量子比特和量子叠加态为基础, 使用现有计算机模拟量子的态矢量表述和量子旋转门操作。同经典的进化算法(EA)相比, QEA具有许多优点, 例如更好的群体多样性和全局寻优能力; 群体规模较小但不影响算法的性能等, 比传统遗传算法在某些问题中表现出更好的性能^[8], 并已在多种优化问题中有所应用^[9-10]。受其启发, 本文针对连续空间的优化问题, 引入量子计算理论和进化计算理论并将其与蚁群算法相融合, 提出一种量子蚁群优化算法(Quantum ant colony optimization, QACO)。在QEA中, 量子旋转门旋转角的取值直接影响算法的收敛速度和搜索能力, 而通过查表方式给出的旋转角是不连续的、离散的, 对问题解空间的搜索具有跳跃性, 不够精细和全面, 并且费时。为此, 提出以蚂蚁信息素强度的增量来计算量子旋转门旋转角的新方法, 以克服上述不足, 进而形成改进量子进化算法。将改进后的QEA融合到ACO中, 提出一种量子蚁群优化算法(Quantum ant colony optimization, QACO)。该算法与前述用于连续优化的蚁群算法不同之处在于: 采用量子位对蚂蚁的当前位置进行编码; 将普通ACO中蚂蚁经过路径的信息素强度的增量转变为量子旋转门旋转角的更新。量子非门实现蚂蚁变异以避免算法出现早熟收敛。理论和实验证明, 该算法与文献[5]提的改进蚁群算法(Improved Ant Colony Optimization, IACO)及文献[7]的QEA算法相比, 具有快速搜索和摆脱局部最优解的能力, 同时也降低了算法的时间复杂性,

对连续空间的优化问题是有效和可行的。

1 量子蚁群优化算法(QACO)

1.1 连续函数优化问题数学模型

若将 n 维连续空间优化问题的解看作 n 维空间中的点或向量, 则连续优化问题可表述为:

$$\begin{cases} \min f(x) = f(x_1, x_2, \dots, x_n) \\ \text{s. t. } a_i \leq x_i \leq b_i; i = 1, 2, \dots, n \end{cases} \quad (1)$$

$[a_i, b_i]$ 为变量 X_i 的定义域; f 为目标函数, 其值可作为蚂蚁的适应度。下面详细给出 QACO 的具体操作。

1.2 产生初始种群

在 QACO 中, 直接采用量子位的概率幅作为蚂蚁当前位置的编码。考虑到种群初始化时, 编码的随机性, 我们采用如下编码方案

$$q_i = \begin{bmatrix} \left| \cos(\theta_{i1}) \right| & \left| \cos(\theta_{i2}) \right| & \dots & \left| \cos(\theta_{in}) \right| \\ \left| \sin(\theta_{i1}) \right| & \left| \sin(\theta_{i2}) \right| & \dots & \left| \sin(\theta_{in}) \right| \end{bmatrix} \quad (2)$$

其中 $\theta_{ij} = 2\pi \times \text{rnd}$; rnd 为 $(0, 1)$ 之间随机数; $i = 1, 2, \dots, m$; $j = 1, 2, \dots, n$; m 是种群规模; n 是空间维数。由此可见, 种群中每个蚂蚁占据遍历空间中两个位置, 这样在蚁群规模不变时, 可使搜索到的空间加倍, 从而加快了收敛速度。这两个位置分别对应量子态 $|0\rangle$ 和 $|1\rangle$ 的概率幅。

$$q_{i0} = (\cos(\theta_{i1}), \cos(\theta_{i2}), \dots, \cos(\theta_{in})) \quad (3)$$

$$q_{i1} = (\sin(\theta_{i1}), \sin(\theta_{i2}), \dots, \sin(\theta_{in})) \quad (4)$$

为表述方便, 称 q_{i0} 为 $|0\rangle$ 态位置, 称 q_{i1} 为 $|1\rangle$ 态位置。

1.3 连续优化问题的解空间变换

在 QACO 中, 由于蚂蚁的遍历空间每维均为 $[-1, 1]$, 为计算蚂蚁目前位置的优劣性, 需要进行解空间的变换, 即将每个蚂蚁占据的 2 个位置由单位空间 $I = [-1, 1]^n$ 映射到优化问题的解空间。蚂蚁上量子位的每个概率幅对应解空间的一个优化变量。记蚂蚁 q_i 上第 j 个量子位为 $[\cos \theta_{ij}, \sin \theta_{ij}]^T$, 则相应的解空间变量为

$$\begin{bmatrix} p_{i0}^j \\ p_{i1}^j \end{bmatrix} = \begin{bmatrix} \frac{b_i - a_i}{2} & 0 \\ 0 & \frac{b_i - a_i}{2} \end{bmatrix} \begin{bmatrix} \cos \theta_{ij} \\ \sin \theta_{ij} \end{bmatrix} + \begin{bmatrix} \frac{b_i + a_i}{2} \\ \frac{b_i + a_i}{2} \end{bmatrix}$$

将上式整理化简, 得

$$\begin{bmatrix} p_{i0}^j \\ p_{i1}^j \end{bmatrix} = \frac{1}{2} \begin{bmatrix} 1 + \cos \theta_{ij} & 1 - \cos \theta_{ij} \\ 1 + \sin \theta_{ij} & 1 - \sin \theta_{ij} \end{bmatrix} \begin{bmatrix} b_i \\ a_i \end{bmatrix} \quad (5)$$

因此, 每个蚂蚁对应优化问题的两个解。其中量子态 $|0\rangle$ 的概率幅对应 X_{i0}^j ; 量子态 $|1\rangle$ 的概率幅

对应 X_{ij}^t 。其中 $i=1, 2, \dots, m; j=1, 2, \dots, n$ 。

1.4 蚂蚁位置更新

在 QACO 中, 首先将普通 ACO 中蚂蚁经过路径的信息素强度的增量转变为量子旋转门旋转角的更新; 然后采用量子旋转门更新蚂蚁携带的量子比特, 完成蚂蚁的移动; 因此, 蚂蚁位置的更新转变为蚂蚁上量子位概率幅的更新。

1.4.1 量子旋转门转角的大小和方向

使用如下旋转门更新量子位相位:

$$U(\Delta\theta) = \begin{bmatrix} \cos(\Delta\theta) & -\sin(\Delta\theta) \\ \sin(\Delta\theta) & \cos(\Delta\theta) \end{bmatrix}$$

关于转角 $\Delta\theta$ 的方向, 通常的做法是构造一个查询表, 列出各种可能的情况, 十分繁琐。而旋转的目的是使当前解逼近当前全局最优解, 仔细观察这两个解中量子位的相位关系不难得出下列结论。

定理 1 令 α_0 和 β_0 是当前搜索到的全局最优解中某量子位的概率幅, α_1 和 β_1 是当前解相应量子位概率幅, 记

$$A = \begin{vmatrix} \alpha_0 & \alpha_1 \\ \beta_0 & \beta_1 \end{vmatrix}$$

转角 $\Delta\theta$ 的方向可由如下公式确定:

$$\text{sgn}(\Delta\theta) = \begin{cases} -\text{sgn}(A) & \text{当 } A \neq 0 \\ \pm & \text{当 } A = 0 \end{cases} \quad (6)$$

证明 记量子位 $[\alpha_0, \beta_0]^T$ 和 $[\alpha_1, \beta_1]^T$ 在单位圆中的幅角分别为 θ_0 和 θ_1 , 则

$$A = \begin{vmatrix} \cos \theta_0 & \cos \theta_1 \\ \sin \theta_0 & \sin \theta_1 \end{vmatrix} = \sin(\theta_1 - \theta_0)$$

(1) 当 $A \neq 0$ 时, 若 $0 < |\theta_1 - \theta_0| < \pi$, 则

$$\begin{aligned} \text{sgn}(\Delta\theta) &= -\text{sgn}(\theta_1 - \theta_0) = \\ &= -\text{sgn}(\sin(\theta_1 - \theta_0)) = -\text{sgn}(A) \end{aligned}$$

若 $\pi < |\theta_1 - \theta_0| < 2\pi$, 则

$$\begin{aligned} \text{sgn}(\Delta\theta) &= \text{sgn}(\theta_1 - \theta_0) = \\ &= \text{sgn}(\sin(2\pi - (\theta_1 - \theta_0))) = \\ &= -\text{sgn}(\sin(\theta_1 - \theta_0)) = -\text{sgn}(A) \end{aligned}$$

(2) 当 $A = 0$ 时, 即 $\sin(\theta_1 - \theta_0) = 0$, 则 $\theta_1 = \theta_0$ 或 $|\theta_1 - \theta_0| = \pi$

所以正向旋转与反向旋转效果相同, $\text{sgn}(\Delta\theta)$ 取正负都可以 (证毕)。

关于转角大小的确定, 文献 [11] 虽然给出了一个范围 $(0.005\pi, 0.1\pi)$, 但没有给出具体选择的依据。文献 [12] 给出的策略是依据一个自变量为进化代数的负指数函数自适应调整, 实际上是一种转角随迭代步长单调下降的调整策略。我们给出的策略是: 把普通 ACO 中蚂蚁经过路径的信

息素强度的增量局部调整和全局调整加入到转角步长函数的设计中。提出如下转角步长函数。

$$\Delta\theta_{ij}(t+1) = -\text{sgn}(A)(\Delta\theta_{ij}(t) + c_1\Delta\tau_{Lij}(t) + c_2\Delta\tau_{Gij}(t)) \quad (7)$$

$$\Delta\tau_{Lij}(t) = \sum_{k=1}^m \frac{Q}{L_k} \quad (8)$$

$$\Delta\tau_{Gij}(t) = \sum_{k=1}^m \frac{Q}{d_{ij}} \quad (9)$$

其中 c_1 和 c_2 分别表示信息素强度的局部调整和全局调整系数。 Q 是信息素强度, L_k 表示第 k 只蚂蚁在本次循环中所走路径的总长度, d_{ij} 表示第 k 只蚂蚁经过路径 ij 的距离。

1.5 蚂蚁位置的变异处理

在很多种情况下, ACO 算法容易陷入局部最小, 主要归因于种群在搜索空间中多样性的丢失。进化算法当中引入变异算子的目的就是增加了种群的多样性, 避免算法早熟收敛。在 QACO 中, 变异算子由量子非门实现。首先给定变异概率 p_m , 对每个蚂蚁赋予一个 $(0, 1)$ 之间随机数 rand_i , 若 $\text{rand}_i < p_m$, 则随机选择该蚂蚁中的 $\lfloor \frac{n}{2} \rfloor$ 个量子位, 用量子非门交换两个概率幅, 其记忆的自身最优位置保持不变。

$$\begin{bmatrix} 0 & 1 \\ 1 & 0 \end{bmatrix} \begin{bmatrix} \cos(\theta_{ij}) \\ \sin(\theta_{ij}) \end{bmatrix} = \begin{bmatrix} \sin(\theta_{ij}) \\ \cos(\theta_{ij}) \end{bmatrix} = \begin{bmatrix} \cos(\theta_{ij} + \pi/2) \\ \sin(\theta_{ij} + \pi/2) \end{bmatrix} \quad (10)$$

其中, $i \in \{1, 2, \dots, m\}; j \in \{1, 2, \dots, n\}$ 。

由上式可以看出, 这种变异也是一种旋转, 对于第 j 个量子位, 转角大小为 $\Delta\theta_{ij} = \pi/2$ 。由于这种旋转与自身记忆的最优位置无关, 与种群当前的最优位置也无关, 所以能够增加蚂蚁个体的多样性。

1.6 QACO 算法描述

综上所述, QACO 算法实施步骤如下:

Step1 蚁群初始化。由 (2) 式生成蚂蚁位置组成初始种群 $Q(t)$;

Step2 按 (5) 式进行解空间变换生成解 $P(t)$, 根据具体优化函数, 计算每个蚂蚁的适应度。若蚂蚁目前位置优于自身记忆的最优位置, 则用目前位置替换; 若目前全局最优位置优于到目前为止搜索到的全局最优位置, 则用目前全局最优位置替换;

Step3 按 (7)、(8)、(9) 式完成蚂蚁位置的更新;

Step4 对每个蚂蚁根据变异概率, 按 (10) 式

变异;

Step5 返回步骤 step2 循环计算, 直到满足收敛条件或代数达到最大限制。

1.7 算法的时间复杂性分析

假设待优化问题的求解规模 (即允许搜索的解的数量) 为 n , 种群大小为 m , 对于 QACO 算法, 将体现在蚂蚁的数量上, 假设算法的迭代次数为 N_c , 因此算法的时间复杂度为 $T(n)$, 考虑算法执行的主体部分: Step2, Step3 和 Step4, 可知 QACO 算法的时间复杂性为 $O(N_c(3nm + m))$, 同理文献 [5] 中的改进蚁群算法 (以下简称 IACO) 时间复杂性为 $O(N_c(n^2m))$, 文献 [7] QEA 算法的时间复杂性为 $O(N_c(nm + m))$, 从时间复杂性比较可以看出: IACO 时间复杂性最大, 其次是 QACO, 最小的是 QEA。

2 量子蚁群优化算法的收敛性分析

定理 2 基于量子进化的蚁群优化算法 QACO 的种群序列 $\{Q_k, k \geq 0\}$ 是有限齐次马尔可夫链。

证明 QACO 是由旋转角确定蚂蚁位置的随机映射, 蚁群的位置转移情况可表示成如下随机过程:

$$Q_k \xrightarrow{\text{观察}} P_k \left(\begin{array}{c} \xrightarrow{\text{旋转门}} P'_k \xrightarrow{\text{变异}} P''_k \\ \xrightarrow{\text{保留最优解, 更新}} Q_{k+1} \end{array} \right)$$

QACO 采用量子比特染色体

$$q_i = \left[\begin{array}{c} \left| \cos(\theta_{i1}) \right| \left| \cos(\theta_{i2}) \right| \cdots \left| \cos(\theta_{in}) \right| \\ \left| \sin(\theta_{i1}) \right| \left| \sin(\theta_{i2}) \right| \cdots \left| \sin(\theta_{in}) \right| \end{array} \right]$$

因为 $\cos \theta_{ij}$ 的取值是连续的, 所以理论上种群所在的状态空间是无限的。但另一方面, 实际运算中 $\cos \theta_{ij}$ 是有限精度的, 设 $\cos \theta_{ij}$ 的精度为 ε (例如 ε 可为 10^{-5} 或 10^{-6}), 则其维数为 $V = (O_h - O_l)/\varepsilon$ 。 O_h 是 $\cos \theta_{ij}$ 取值的上限, O_l 是 $\cos \theta_{ij}$ 取值的下限, 在量子比特表示中, $O_h = 1$, $O_l = -1$, 所以 $V = 2/\varepsilon$ 。假设染色体长度为 M , 种群规模为 N , 则种群所在的状态空间大小为 N^{VM} , 因此种群序列是有限的。而算法中采用的解空间变换矩阵, 量子旋转门状态转移矩阵以及量子非门变异均与进化代数 k 无关。因此, $Q(k+1)$ 仅与 $Q(k)$ 有关, 故 $\{Q_k, k \geq 0\}$ 是有限齐次马尔可夫链 (证毕)。

设 S 为状态空间, 设 f^* 是 S 中优化问题的最优解, 令 $Q^* = \{\min(f(Q) = f^*, Q \in S)\}$ 。

定义 1 $\{Q(n), n \geq 0\}$ 是种群序列, 如果对于任意的初始分布 $S_0 \in S$ 均有

$$\lim_{k \rightarrow \infty} P\{Q(k) \in Q^* \mid Q(0) = S_0\} = 1$$

则称算法收敛。

定义 1 表明, 算法收敛是指当算法迭代到足够的次数后, 种群中包含全局最优个体的概率几乎为 1。这种定义即为通常所说的概率 1 收敛。

记 $P\{Q(k) \in Q^* \mid Q(0) = S_0\}$ 为 P_k , 则

$$P_k = \sum_{i \in Q^*} P\{Q(k) = i \mid Q(0) = S_0\}$$

记 $P\{Q(k) = i \mid Q(0) = S_0\}$ 为 $P_i(k)$, 则

$$P_k = \sum_{i \in Q^*} P_i(k) \quad (11)$$

算法采用了最优保留策略, 所以转移概率 $P_{ij}(k) = P\{Q(k) = j \mid Q(0) = i\}$ 有以下两种特殊情况:

当 $i \in Q^*, j \notin Q^*$ 时, 有 $P_{ij}(k) = 0$;

(12)

当 $i \in Q^*, j \in Q^*$ 时, 有 $P_{ij}(k) = 1$;

(13)

定理 3 QACO 是概率 1 收敛的。

证明 由式 (11) $P_k = \sum_{i \in Q^*} P_i(k)$, 有

$$P_{k+1} = \sum_{i \in Q^*} \sum_{j \in Q^*} P_i(k) P_{ij}(k) + \sum_{i \in Q^*} \sum_{j \notin Q^*} P_i(k) P_{ij}(k)$$

由转移概率的性质, 有

$$\sum_{j \in Q^*} P_{ij}(k) + \sum_{j \notin Q^*} P_{ij}(k) = 1$$

故

$$P_k = \sum_{i \in Q^*} P_i(k) = \sum_{i \in Q^*} P_i(k) \left(\sum_{j \in Q^*} P_{ij}(k) + \sum_{j \notin Q^*} P_{ij}(k) \right) = \sum_{i \in Q^*} \sum_{j \in Q^*} P_i(k) P_{ij}(k) + \sum_{i \in Q^*} \sum_{j \notin Q^*} P_i(k) P_{ij}(k)$$

由式 (12), 有 $\sum_{i \in Q^*} \sum_{j \notin Q^*} P_i(k) P_{ij}(k) = 0$,

故

$$P_k = \sum_{i \in Q^*} \sum_{j \in Q^*} P_i(k) P_{ij}(k)$$

$$P_{k+1} = P_k + \sum_{i \in Q^*} \sum_{j \notin Q^*} P_i(k) P_{ij}(k) > P_k$$

所以 $1 > P_{k+1} > P_k > P_{k-1} > \cdots > 0$ 。因此 $\lim_{k \rightarrow \infty} P_k = 1$ 。由定义 1, QACO 是概率 1 收敛的 (证毕)。

3 仿真结果对比

为了验证上述量子蚁群算法求解连续空间优化问题的可行性, 本文对文献 [5] 中所采用的连续空间优化问题中一个典型的指数正弦组合优化问题进行了仿真研究:

$$\begin{cases} \min J = 5e^{-0.5x} \sin(30x) + e^{0.2x} \sin(20x) + 6 \\ x \in [0, 8] \end{cases} \quad (14)$$

由图 1 可见, 该目标函数具有多个局部极小点, 因此在连续空间优化问题中非常具有代表性。

对 QACO 与 QEA^[7]、IACO^[5] 算法进行对比实验, 结果如图 2 所示。




图1 计算机在线仿真目标函数曲线

Fig. 1 Objective function curves for computer simulation online



(a) 20个个体迭代100次的结果
(运行20次的平均值)(b) 5个个体迭代100次的结果
(运行20次的平均值)

图2 目标函数随迭代次数的进化曲线

Fig. 2 Evolution curves of objective function with iteration times

图2(a), (b)描绘了各算法在20次独立运算中最优解平均值随迭代次数的变化情况,从求解质量和收敛速度两个方面再次表明QACO比IACO和QEA具有更好的性能:一方面,在整个进化过程中,QACO和QEA的求解质量明显要优于IACO,而QACO的求解质量要优于QEA;另一方面,QACO的收敛速度都要优于QEA和IACO,同时,虽然QEA和IACO在进化初始阶段收敛速度几乎相同,但随着进化代数的增加,QEA的收敛速度明显高于IACO.更值得注意的是,尽管QACO和QEA的群体规模小于IACO,但性能却优于IACO,

原因在于量子进化算法使用量子染色体,增加了了解的多样性,量子旋转门作为进化策略,充分利用了群体进化的历史信息,加快收敛速度,提高了全局搜索能力.而QACO的性能优于QEA,原因在于QACO采用计算量子旋转门旋转角的新方法,实现了了解的多样性和收敛速度的平衡以及解的稳定性.

为了进一步体现信息素强度的局部调整系数 c_1 和全局调整系数 c_2 对实验结果的影响,本文选择了三组不同的参数 c_1 和 c_2 ,进行同一实验,结果如图3所示.图3实验结果表明,信息素强度的局部调整和全局调整系数的参数选择对算法的性能也有很大的影响,对 c_1 和 c_2 的不同选择,会导致最终结果的差异.参数 c_1 控制蚁群能够在小范围内继续搜索,以提高蚂蚁适应度,因而 c_1 要求尽量大,而 c_1 过大又会导致陷入局部最优,所以要保持种群多样性以扩大搜索范围,从而可以减小参数 c_1 ,相对提高参数 c_2 ,保证全局最优,但 c_2 的取值又不能过大,否则会影响算法的收敛速度.




图3 QACO算法在不同参数值下的对比实验

Fig. 3 Contrast experiments of QACO algorithms with different parameters

所以,本算法中蚂蚁个体的位置更新是基于当前解和局部最优解的.本文还定义了蚂蚁个体的量子非门变异算子,目的就是增加种群的多样性,从而扩大算法的搜索空间.

4 结 论

No Free Lunch 定理表明,没有哪一种方法能够最有效地解决所有问题,这也是目前混合算法受到重视的一个原因.本文分析了量子蚁群算法的机制,并从理论上证明了量子蚁群算法的收敛性.实验数据表明,本文提出的基于量子进化的蚁群算法是有效可行的,为连续空间优化问题中的工程应用提供了一条新的途径.

与此同时,我们也认识到蚁群算法是一种新型

的拟生态系统智能优化算法, 其严格的理论依据至今尚未奠定, 对信息素强度的局部调整系数 c_1 和全局调整系数 c_2 的确定, 本文也只是采用经验的方法来予以确定, 如何更有效的确定上述两个参数将是下一步的研究方向。

参考文献:

- [1] MONMARCHÉ N, VENTURINI G, SLIMANE M. On how Pochycondyla apicalis ants suggest a new search algorithm [J]. Future Generation Computer Systems, 2000, 16: 937 - 946.
- [2] DRÉO J, SIARRY P. A new ant colony algorithm using the heterarchical concept aimed at optimization of multi-minima continuous functions [C]. Proc of the 3rd Int Workshop on Ant Algorithms ANTS '2002, Brussels, 2002: 216 - 221.
- [3] DRÉO J, SIARRY P. Continuous interacting ant colony algorithm based on dense hierarchy[J]. Future Generation Computer Systems, 2004, 20 (5): 841 - 856.
- [4] 汪镭, 吴启迪. 蚁群算法在连续空间寻优问题求解中的应用 [J]. 控制与决策, 2003, 18(1): 45 - 48.
WANG L, WU Q D. Ant system algorithm in continuous space optimization [J]. Control and Decision, 2003, 18 (1): 45 - 48.
- [5] 段海滨, 马冠军, 王道波, 等. 一种求解连续空间优化问题的改进蚁群算法 [J]. 系统仿真学报, 2007, 19(5): 974 - 977.
DUAN H B, MA G J, WANG D B, et al. Improved ant colony algorithm for solving continuous space optimization problems [J]. Journal of System Simulation, 2007, 19 (5): 974 - 977.
- [6] 杨勇, 宋晓峰. 蚁群算法求解连续空间优化问题 [J]. 控制与决策, 2003, 18(5): 573 - 576.
YANG Y, SONG X F. Ant colony algorithm for continuous space optimization [J]. Control and Decision, 2003, 18(5): 573 - 576.
- [7] HYUN K, KIM J H. Quantum-inspired evolutionary algorithm for a class of combinational optimization [J]. IEEE Transactions on Evolutionary Computing, 2002, 6 (6): 580 - 593.
- [8] HAN K H, KIM J H. Genetic quantum algorithm and its application to combinatorial optimization problem [C]. Proceedings of the 2000 Congress on Evolutionary Computation, Piscataway, 2000: 1354 - 1360.
- [9] 邢焕来, 潘炜, 邹喜华. 一种解决组合优化问题的改进型量子遗传算法 [J]. 电子学报, 2007, 35(10): 1999 - 2002.
XING H L, PAN W, ZOU X H. A novel improved quantum genetic algorithm for combinatorial optimization Problems [J]. Acta Electronica Sinica, 2007, 35(10): 1999 - 2002.
- [10] HAN K H, PARK K H, LEZ C H, et al. Parallel quantum-inspired genetic algorithm for combinatorial optimization problem [C]. Proceedings of the 2001 Congress on Evolutionary Computation, IEEE Press, 2001: 1422 - 1429.
- [11] HAN K H, KIM J H. Quantum-inspired evolutionary algorithms with a new termination criterion gate, and two-phase scheme [J]. IEEE Transaction on Evolutionary computation, 2004: 1108 - 1112.
- [12] 杨俊安, 庄镇泉, 史亮. 多宇宙并行量子遗传算法 [J]. 电子学报, 2004, 32(6): 923 - 928.
YANG J A, ZHUANG Z Q, SHI L. Multi-universe parallel quantum genetic algorithm [J]. Acta Electronica Sinica, 2004, 32(6): 923 - 928.