

新的自适应免疫量子粒子群优化算法

朱颢东, 李红婵

(郑州轻工业学院 计算机与通信工程学院, 河南 郑州 450002)

摘 要: 为了克服粒子群优化算法早熟收敛以及粒子在进化过程中缺乏很好的方向指导的问题, 算法中采用了量子技术以及免疫机制来提高粒子群的收敛速度和寻优能力, 从而获得了一个新的自适应免疫量子粒子群优化算法. 仿真试验表明该算法具有较好的性能.

关键词: 粒子群优化; 量子技术; 免疫机制

中图分类号: TP301

文献标识码: A

文章编号: 1000-7180(2011)03-0123-03

New Adaptive Immune Quantum-Behaved Particle Swarm Optimization Algorithm

ZHU Hao-dong, LI Hong-chan

(School of Computer and Communication Engineering,
Zhengzhou University of Light Industry, Zhengzhou 450002, China)

Abstract: In order to escape from premature convergence and lack good direction in particles the evolutionary process, quantum technology and immunologic mechanism were employed to improve the convergence speed and the optimization ability of particle swarm, and a new adaptive immune quantum-behaved particle swarm optimization (NAIQPSO) algorithm was provided. Simulation experiments show that the provided algorithm has better performance.

Key words: particle swarm optimization; quantum technology; immunologic mechanism

1 引言

粒子群优化 (Particle Swarm Optimization, PSO) 算法^[1]是 20 世纪 90 年代中期由 Kennedy 等人提出的一种模拟自然界群鸟觅食行为的智能优化算法. 同其他智能优化算法相比, 粒子群算法具实现简单、易于理解的优点, 这在解决高维复杂的非线性问题上具有较好的优势^[2-3]. 但是, 在一些具有多个局部最优点的搜索空间求解时, 粒子易被束缚在局部最优点、整个种群全局最优点附近进行搜索, 从而使得搜索区域有限、容易陷入局部最优. 受量子力学启发, 文献[4-5]提出了量子粒子群 (QPSO) 算法. 在量子系统中, 粒子能够以某一确定的概率出现在可行解空间中的任意位置, 因此有更大的搜索范围,

与传统粒子群算法相比, 更有可能避免粒子陷入局部最优.

虽然量子有更大的搜索空间, 但是在粒子进化过程中, 缺乏很好的方向指导. 针对这个缺陷, 文中对进化过程中的粒子进行有效疫苗接种, 使它们朝着更好的进化方向发展^[6], 从而提高量子粒子群的收敛速度和寻优能力. 仿真实验结果表明该算法具有较好的性能.

2 NAIQPSO 所涉及的核心方案设计

在文中提出的 NAIQPSO 算法中, 粒子编码方式、粒子适应度函数和初始种群的设计, 需要根据具体要解决的实际问题而设计, 这里不作介绍. 下面详细介绍核心方案设计.

收稿日期: 2010-03-10; **修回日期:** 2010-05-12

基金项目: 河南省基础与前沿技术研究计划项目(102300410266); 郑州轻工业学院博士科研基金项目

2.1 疫苗抽取方案设计

Step1: 根据具体问题计算出各个粒子的适应度;

Step2: 根据粒子适应度, 求取粒子疫苗: $H(i) = \frac{\text{fitness}(i) - \text{fitness}_{\min}}{\text{fitness}_{\max} - \text{fitness}_{\min}}$, 其中 i 代表粒子, $\text{fitness}_{\max}$ 为种群最大适应度, $\text{fitness}_{\min}$ 为种群最小适应度.

Step3: 获得粒子群的疫苗: $HC = \{H(i) \mid i = 1, 2, \dots, n\}$, n 为粒子总数.

2.2 位置更新策略

由于在量子空间中, 粒子的速度和位置不能同时确定, 因此粒子的状态可使用波函数来描述, 粒子在空间某一点出现的概率密度函数(该函数是波函数的平方)可以通过求解薛定谔方程而得到, 粒子在量子空间的位置可通过蒙特卡罗随机模拟的方式来获得^[7]:

$$p = a \times p_b(i) + (1 - a) \times g_b \quad (1)$$

$$m_b = \frac{1}{N} \sum_{i=1}^N p_b(i) \quad (2)$$

$$b = 1 - i_t / i_{t \max} \times 0.5 \quad (3)$$

$$p_{\text{pos}} = p \pm b \times |m_b - p_{\text{pos}}| \times \ln \frac{1}{u} \quad (4)$$

其中, p_b 是上一代所有粒子的最佳位置; g_b 为上一代群体获得的最佳位置; p 为 p_b 与 g_b 之间的随机位置; m_b 是上一代所有粒子个体最佳位置 p_b 的平均值; n 为粒子群规模; b 为收缩扩张系数, 在算法收敛的过程中该系数线性减小; $i_{t \max}$ 为设定的最大迭代次数; i_t 为当前迭代次数; p_{pos} 是粒子的当前位置; a 和 u 都是 $[0, 1]$ 区间的随机数, 当 $0 < u < 0.5$ 时, 式(4)取“+”号; 当 $u \geq 0.5$ 时, 式(4)取“-”号.

由于收缩扩张系数 b 关系到整个算法的收敛性能, 这使得对该系数的选择和控制变得至关重要. 在文献^[7]中已经证明: 当 $b < 1.7$ 时, 粒子收敛, 靠近粒子群的当前最佳位置; 当 $b > 1.8$ 时, 粒子发散, 远离粒子群的当前最佳位置. 从式(3)可以看出, 在粒子进化过程随着进化代数的增加收缩扩张系数 b 线性减小, 这种变化并不能避免粒子群的早熟趋势. 为此, 文中作如下改进:

$$h = \text{fitness}_b / \text{fitness}(i)$$

$$\text{If } h < 0.5 \text{ Then } b = 2 \times h \quad (5)$$

$$\text{If } h \geq 0.5 \text{ Then } b = 1 + h \quad (6)$$

其中, fitness_b 为 g_b 的适应度; $\text{fitness}(i)$ 为第 i 个粒子的当前适应度. h 为两者的比值, h 越小, 说明粒子越远离粒子群的当前最佳位置, h 越大, 说明粒子越

靠近粒子群的当前最佳位置. 文中以 0.5 为界限, 如果 $h \geq 0.5$, 说明粒子 g_b , 此时将 b 设为 $1 + h$, 增加其 > 1.8 的概率, 使它尽量发散, 扩大搜索范围; 如果 $h < 0.5$, 说明粒子 g_b , 此时 b 应该小于 1.7, 使它收敛, 因此将 b 设为 $2 \times h$, 使它不大于 1.

2.3 精英策略

为了使粒子群更快更好地朝着目的地移动, 文中设置精英策略如下: 设 i' 为 t 时刻的粒子 i , i^{t+1} 为该粒子下一刻移动后的粒子, 如果 $\text{fitness}(i^{t+1}) \leq \text{fitness}(i')$, 则, $i^{t+1} = i'$, $i = 1, 2, \dots, n$.

2.4 变异概率

如果粒子 i 的第 k 位为 i_k , i_k 对应的疫苗位为 $H(i_k)$, 则定义 i_k 发生变异的概率:

$$\beta_k = K_1 (H(i_k) - i_k)^2 - K_2 \quad (7)$$

$H(i_k)$ 同 i_k 相差越大, β_k 就越大, 发生变异的概率也就越大; $H(i_k)$ 同 i_k 相差越小, β_k 就越小, 发生变异的概率也就越小. 其中 K_1 、 K_2 为参数, 文中分别取值 0.2 和 0.05.

2.5 疫苗接种和免疫选择

对每个粒子 i , 按位进行疫苗接种产生新粒子 i^* . 具体过程如下^[8]:

对 i 中的任一位 i_k , 按照式(7) 计算该位的变异率 β_k . 然后判断:

if (Rand $< \beta_k$), then $i_k^* = 1 - i_k$

Else $i_k^* = i_k$.

Rand 为 $[0, 1]$ 区间的随机数.

免疫选择:

if $\text{Fitness}(i^*) \geq \text{Fitness}(i)$

Then $i = i^*$

3 NAIQPSO 算法简述

Step1: 设定各个参数: 粒子规模 N , 总的迭代次数 T , 这需要根据具体要解决的问题而定;

Step2: 随机生成 N 个初始粒子群 $P(0)$, 初始速度 $V(0)$ 向量为 0 向量, 局部最有 $\text{Lbest}(0, t) = 0$, 全局最优 $\text{Gbest} = 0$, 初始化已经迭代次数: $t = 1$;

Step3: 按照 2.1 节所述抽取疫苗;

Step4: 计算 t 时刻各个粒子 i 的适应度, 更新 $\text{Lbest}(t) = \max(\text{Lbest}(t), \text{Fitness}(i))$, $\text{Gbest} = \max(\text{Lbest}(t), \text{Gbest})$;

Step5: 更新粒子群

Step5.1: 对粒子群 $P(t)$ 的各个粒子按照适应度从小到大排序排列, 取前 K 个适应度最高的粒子组成一个粒子群, 记为 $KM = \{p_1, p_2, \dots, p_k\}$;

Step5.2:按照2.2节所述的策略更新粒子群 $P(t)$ 中粒子的位置;

Step5.3:对 Step5.1 选出的 KM 按照 2.3 节所述的精英策略进行更新;

Step5.4:按照 2.4 节和 2.5 节所述进行疫苗接种和粒子更新;

Setp6:若满足 $t \geq T$, 则算法结束, 输出最优粒子对应的解; 否则 $t = t + 1$, 转 Step4.

4 仿真试验

文中选择如下四个标准函数来验证 NAIQPSO 的性能, 它们的最小都为 0:

① Griewank 函数

$$f_1(x) = \frac{1}{4000} \sum_{i=1}^n (x_i - 100)^2 - \prod_{i=1}^n \cos \frac{x_i - 100}{\sqrt{i}}$$

+1, 搜索范围 $(-600, 600)^n$, 初始化范围 $(-600, 600)^n$;

② Rastrigin 函数

$$f_2(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10], \text{搜索范围}(-5.12, 5.12)^n, \text{初始化范围}(2.56, 5.12)^n;$$

③ Rosenbrock 函数

$$f_3(x) = \sum_{i=1}^{n-1} 100(x_{i+1} - x_i)^2 + (x_i - 1)^2, \text{搜索范围}(-50, 50)^n, \text{初始化范围}(15, 30)^n;$$

④ Schaffer 函数

$$f_4(x) = \frac{(\sin \sqrt{x_1^2 + x_2^2})^2}{1 + 0.001 \times (x_1^2 + x_2^2)^2}, \text{搜索范围}(-100, 100)^2, \text{初始化范围}(15, 30)^2.$$

使用文献[7]的 QPSO 算法与文中所提出的 NAIQPSO 算法作对比. 在测试实验中, 问题的维数分别为 10 维、20 维、30 维, 每次运行迭代次数为 1000 次、1500 次、2000 次, 粒子规模为 80. 对每一个标准函数, 运行 50 次记录最佳值的平均值以及平均消耗的时间, 其结果如表 1 所示.

从表 1 试验结果对比可以看出, 在四个标准函数上, 文中 NAIQPSO 算法运行 50 次记录的最佳值平均值以及平均消耗的时间都要优于文献[7]的 QPSO 算法, 这说明文中算法具有一定的优越性.

5 结束语

文中对传统粒子群优化算法易陷入局部最优和在粒子进化过程中缺乏很好的方向指导的缺点进行了改进, 提出了一个新的自适应免疫量子粒子群优

表 1 试验结果对比

函数名称	问题维数	迭代次数	QPSO		NAIQPSO	
			值	耗时/s	值	耗时/s
$f_1(x)$	10	1000	0.01128	1.2091	0.00581	0.5012
	20	1500	0.03796	2.7361	0.01831	1.8037
	30	2000	0.05183	4.9207	0.03751	3.7481
$f_2(x)$	10	1000	1.8639	1.3841	0.7149	0.6134
	20	1500	10.0923	2.5073	4.0962	1.6370
	30	2000	21.4519	4.9528	11.5705	3.3031
$f_3(x)$	10	1000	9.7159	1.2747	5.3147	0.6132
	20	1500	35.4890	2.6490	24.0082	1.7026
	30	2000	98.3917	5.0417	75.3059	3.4061
$f_4(x)$	2	1000	9.96E-4	0.4280	1.52E-4	0.2214
	2	1500	8.89E-5	0.6671	3.61E-5	0.3213
	2	2000	5.73E-5	0.8529	1.88E-5	0.3850

化算法. 以四个常见的标准函数为例进行了性能测试, 并与其他文献中的同类算法的测试结果进行了对比. 结果表明, 无论是搜索能力还是运行时间, 文中算法都具有较明显的优势, 从而能够为解决复杂优化问题提供一种有力手段.

参考文献:

- [1] Hamidian D, Seyedpoor S M. Shape optimal design of arch dams using an adaptive neuro-fuzzy inference system and improved Particle swarm optimization [J]. Applied Mathematical Modelling, 2010, 34(6): 1574-1585.
- [2] Kuok K K, Harun S, Shamsuddin S M. Particle swarm optimization feedforward neural network for modeling runoff [J]. International Journal of Environmental Science and Technology, 2010, 7(1): 67-78.
- [3] Yannis Marinakis, Magdalene Marinaki. A hybrid particle swarm optimization algorithm for the vehicle routing problem [J]. Engineering Applications of Artificial Intelligence, 2010, 23(4): 463-472.
- [4] Arya L D, Titare L S, Kothari D P. Improved particle swarm optimization applied to reactive power reserve maximization [J]. International Journal of Electrical Power & Energy Systems, 2010, 32(5): 368-374.
- [5] 刘怀亮, 苏瑞娟, 许若宁, 等. 协同粒子群优化算法[J]. 计算机应用, 2009, 29(11): 3068-3073.
- [6] Hamidreza Modares, Alireza Alf. Parameter identification of chaotic dynamic systems through an improved particle swarm optimization [J]. Expert Systems with Applications, 2010, 37(5): 3714-3720.

(下转第 129 页)

1.85%.




图4 外接电阻变化时,恒流输出特性曲线




图5 驱动电流随电源电压变化曲线

设置 R_{set} 为 500Ω 、 V_{cc} 为 $3V$, 令电路工作的环境温度为 $25^{\circ}\text{C} \sim 85^{\circ}\text{C}$ 时, 恒流输出情况如图 6. 驱动电流由 37.3mA 变化到 38.1mA , 波动百分比 2.14% .




图6 驱动电流随温度变化曲线

4 结束语

文中给出一种 LED 恒流驱动电路, 可用于 LED 显示屏. 利用电流负反馈结构并拟合工作区, 电路恒流工作电压低, 同时实现外部数字信号的使

能控制, 控制信号响应速度快, 可用于实现 PWM 数字调光. 驱动电流大小可以有外接电阻实现控制. 仿真显示, 电路 $5V$ 的电源电压波动 $\pm 10\%$ 时, 驱动电流波动小于 1.85% . 环境温度在 $25^{\circ}\text{C} \sim 85^{\circ}\text{C}$ 时, 驱动电流变化 2.14% . 驱动电流为 91.5mA 时, 恒流工作电压仅为 $0.38V$. 电路驱动电流可由外接信号实现输出使能控制, 响应时间为 7ns . 驱动电流大小通过外接电阻设置实现, 设置范围 $200\Omega \sim 1300\Omega$, 对应驱动电流变化范围是 $14.5\text{mA} \sim 91.5\text{mA}$.

参考文献:

- [1] 关积珍, 陆家和. 2007 全国 LED 显示屏产业与市场发展综述[J]. 现代显示, 2008, 87: 9-12.
- [2] Maxim-Dallas Semiconductor, Why Drive White LEDs with Constant Current[EB/OL]. [2010-02-01]. <http://www.maxim-ic.com/app-notes/index.mvp/id/3256>, 2004-8-24.
- [3] 沈慧, 朱大中. 半导体照明光源恒流驱动芯片的研究[J]. 固体电子学与进展, 2006, 26(2): 100-103.
- [4] 郭嘉帅, 王小力. 便携式系统中高效率、高精度、低噪声 LED 驱动电路设计研究[J]. 微电子学与计算机, 2010, 27(2): 80-84.
- [5] 王世军, 王新安. LCD 驱动中的带隙基准电压源的设计与实现[J]. 微电子学与计算机, 2007, 24(4): 47-49.
- [6] 许小丽, 冯全源. 一种高温性能 CMOS 带隙基准源[J]. 微电子学与计算机, 2010, 27(1): 25-28.

作者简介:

辛晓宁 男, (1965-), 博士, 教授, 硕士生导师. 研究方向为大规模集成电路和 SOC 的低功耗设计方法、现场总线技术.

陈丽丽 女, (1986-), 硕士研究生. 研究方向为集成电路设计与研究.

(上接第 125 页)

- [7] Sun Jun, Feng Bin, Xu Wenbo. Particle swarm optimization with particles having quantum behavior [C]. //Proc of 2004 Congress on Evolutionary Computation. USA: Piscataway, 2004: 325-330.
- [8] 胡江强, 郭晨, 尹建川. 分级变异的动态克隆选择算法[J]. 控制与决策, 2007, 22(6): 608-612.

作者简介:

朱颢东 男, (1980-), 博士, CCF 会员. 研究方向为文本挖掘、智能信息处理、计算智能.

李红婵 女, (1983-), 硕士, CCF 会员. 研究方向为智能信息处理.