

基于云模型的实数编码量子进化算法

李国柱*

(西安文理学院 物理与机械电子工程学院, 西安 710065)

(*通信作者电子邮箱 0071gz@sohu.com)

摘要:针对量子进化算法易陷入局部最优和求解精度不高的缺点,利用云模型具有随机性和稳定倾向性的特点,提出了一种基于云模型的实数编码量子进化算法。该算法利用单维云变异进行全局快速搜索,利用多维云进化增强算法局部搜索能力,探索全局最优解。依据算法的进化过程动态调整搜索范围并复位染色体,可以加提高收敛速度,并防止陷入局部最优。仿真结果表明,该算法搜索精度和效率得到提高,适合求解复杂函数优化问题。

关键词:云模型;量子进化算法;实数编码;全局优化;函数优化

中图分类号:TP181 **文献标志码:**A

Real-coded quantum evolutionary algorithm based on cloud model

LI Guozhu*

(School of Physics and Mechatronics Engineering, Xi'an University of Arts and Science, Xi'an Shaanxi 710065, China)

Abstract: To deal with the problems of easily falling into local optimum and low accuracy in the quantum evolutionary algorithm, a real-coded quantum evolutionary algorithm based on cloud model (CRCQEA) was proposed by using the characteristics of cloud model randomness and stable disposition. The algorithm used a single-dimensional variation of cloud for rapid global search, and used a multi-dimensional cloud evolution for enhancing local search ability to explore the global optimal solution. Dynamic adjustment of search range and resetting of the chromosomes, on the basis of the evolutionary process of algorithm, can speed up the convergence and prevent falling into local optimum. The simulation results show that the algorithm improves search accuracy and efficiency, and the algorithm is well suitable for the complex function optimization.

Key words: cloud model; quantum evolutionary algorithm; real-coded; global optimization; function optimization

0 引言

量子进化算法(Quantum-inspired Evolutionary Algorithm, QEA)^[1]是新近发展起来的一种概率进化算法。QEA具有良好的群体多样性和全局搜索能力,种群规模较小但不影响算法的性能。然而,大量研究表明:尽管QEA在求解组合优化问题时较传统进化算法表现出更优良的性能,但不适合于求解数值优化问题^[2]。QEA采用二进制编码,在用于数值优化问题时,因需要频繁的编码解码,无疑加大了计算量,随着函数维数的增加和求解精度的提高,引起染色体编码“长度灾”导致搜索效率低下。文献[3]构造了三链实数染色体,利用量子旋转门进化染色体,并以解析形式确定旋转角的大小和方向,但其在高维数函数优化上缺乏应用且求解精度不高;文献[4]以实数矩形区域表示基因,通过个体等位基因的叠加、变异及自学习来完成进化过程,但该算法存在易陷入局部最优的问题;文献[5]提出了一种改进实数编码量子进化算法(Improved Real-Coded Quantum Evolutionary Algorithm, IRCQEA),利用实数变量和量子位概率幅相角构成实数染色体,设计了互补变异算子来进化染色体,由于采用了动态缩小搜索空间的策略使得该算法的求解精度得到明显的提高,但该算法在较低维数函数优化上易陷入局部最优。上述工作均采用实数编码染色体代替量子位编码染色体,并基于染色体的具体形式设计新的进化算子。

文献[6]在传统模糊集理论和概率统计的基础上提出了

隶属云概念,并将它逐步完善形成了云模型理论。云模型因其能实现定性和定量之间互换的特性,已被用于解决一些算法的瓶颈问题,优化各种算法^[7-9]。

本文在文献[5]的基础上,结合云模型的优良特性,利用云模型实现染色体的单维互补变异和多维云进化,提出了一种基于云模型的实数编码量子进化算法(Cloud model Real-Coded Quantum Evolutionary Algorithm, CRCQEA)。标准函数仿真表明,该算法求解复杂函数优化问题具有很好的性能。

1 云模型

云模型把随机性和模糊性完全集成到一起,构成定量和定性相互间的映射,云模型使用3个数字特征(期望值 E_x 、熵 E_n 、超熵 H_e)来表征定性的概念,它们反映了定性概念 C 的整体特征^[10],记作 $C(E_x, E_n, H_e)$,多维云模型的整体特征可由多组数字特征表示。期望值(E_x)是概念在论域中的中心值,是最能代表这个定性概念的值,通常是云重心对应的值。 E_x 是反映相应的定性知识的信息中心值。熵(E_n)是定性概念模糊度的度量,反映了在论域中可被这个概念所接受的数值范围,体现了定性概念亦此亦彼性的裕度。熵越大,概念所接受的数值范围也越大,概念越模糊。超熵(H_e)是熵的熵,反映了云滴的离散程度。超熵越大,云滴离散度越大,隶属度的随机性越大。

利用正态云算子,就可以把定性概念 $C(E_x, E_n, H_e)$ 变换为数值表示的云滴集合,一维正态云算子定义^[11]如下:

一维正态云算子是一个把定性概念的整体特征 $C(E_x, E_n, H_e)$ 变换为定量表示的映射 $\gamma: C \rightarrow \Gamma$, 满足以下条件:

1) $\Omega = \{\omega_i | \omega_i \text{ 为 } Norm(E_n, H_e) \text{ 的一次实现}, i = 1, 2, \dots, M\}$ 。

2) $A = \{\alpha_i | \alpha_i \text{ 为 } Norm(E_x, \omega_i) \text{ 的一次实现}, \omega_i \in \Omega, i = 1, 2, \dots, M\}$ 。

3) $\Gamma = \left\{ (\alpha_i, \beta_i) | \alpha_i \in A, \omega_i \in \Omega, \beta_i = \exp\left(\frac{-(\alpha_i - E_x)^2}{2\omega_i^2}\right) \right\}$ 。

其中 $Norm(\mu, \delta)$ 为期望为 μ 方差为 δ 的正态随机变量, M 为云滴的个数。

正态云算子实现了概念空间到数值空间的转换。一维正态云算子可以推广至 n 维正态云算子。

2 云模型实数编码量子进化算法

考虑数值优化问题:

$$\min f(x_1, x_2, \dots, x_n) \quad (1)$$

s. t. $x_i \in [l_i, u_i]; i = 1, 2, \dots, n$

其中: l_i 和 u_i 为决策向量 $X = (x_1, x_2, \dots, x_n) \in \mathbf{R}^n$ 的分量 x_i 的下限和上限, $L = (l_1, l_2, \dots, l_n) \in \mathbf{R}^n$ 和 $U = (u_1, u_2, \dots, u_n) \in \mathbf{R}^n$ 为定义的可行解空间, n 为决策向量 X 的维数。

2.1 实数编码染色体

在 CRCQEA 中, 染色体等位基因由决策向量 X 的分量 x_i 和量子位概率幅相角 θ_i 构成, 长度由决策向量的维数 n 决定, 则实数编码染色体描述为:

$$P = \begin{pmatrix} x_1 & x_2 & \dots & x_n \\ \theta_1 & \theta_2 & \dots & \theta_n \end{pmatrix} \quad (2)$$

2.2 单维云互补变异

文献[12]已证明, 单基因变异比全基因变异具有更高的搜索效率。CRCQEA 通过对群体中的每一个染色体的每个基因位实施单维云互补变异完成大范围搜索。设第 t 代时的群体为 $P(t) = \{p_1^t, p_2^t, \dots, p_N^t\}$, 其中 N 为群体规模。对于染色体 $p_j^t (j = 1, 2, \dots, N)$ 的第 i 位基因位 $[x_{j,i}^t, \theta_{j,i}^t]^T$ 进行如下操作:

以 $x_{j,i}^t$ 为期望 E_x , 以 $0.5(u_i - l_i) \cos^2 \theta_{j,i}^t$ 为熵 E_n , 以 $0.1E_n$ 为超熵 H_e , 构建基因云 C_{1i} , 通过一维正态云算子生成 m_1 个 C_{1i} 的云滴; 以 $x_{j,i}^t$ 为期望 E_x , 以 $0.5(u_i - l_i) \sin^2 \theta_{j,i}^t$ 为熵 E_n , 以 $0.1E_n$ 为超熵 H_e , 构建基因云 C_{2i} , 通过一维正态云算子生成 m_2 个 C_{2i} 的云滴。随着 $\theta_{j,i}^t$ 的增加, C_{1i} 的熵逐渐减小, 意味着搜索半径逐步减小, 实现对当前解领域的“求精”搜索; 而随着 $\theta_{j,i}^t$ 的增加, C_{2i} 的熵逐渐增大, 使得算法能够在更大范围搜索从而跳出局部最优解, 实现对当前解领域的“求泛”搜索, 互补变异由此而来。

设第 m 次产生云滴的值为 z_m , 若 z_m 值超出了可行解空间范围, 则重复式(3), 直到 z_m 值位于可行解空间。

$$z_m = \begin{cases} 2u_i - z_m, & z_m > u_i \\ 2l_i - z_m, & z_m < l_i \end{cases} \quad (3)$$

若由单维云互补变异生成的可行解 $(x_{j,1}^t, \dots, z_m, \dots, x_{j,n}^t)$ 优于 $(x_{j,1}^t, \dots, x_{j,i}^t, \dots, x_{j,n}^t)$, 则为有效进化, 用 z_m 代替 $x_{j,i}^t$; 否则为无效进化, $x_{j,i}^t$ 保持不变。 $m_1 + m_2$ 个云滴变异中, 若有效进化次数大于无效进化次数, 则概率幅相角 $\theta_{j,i}^t$ 保持不变; 反之, 对 $\theta_{j,i}^t$ 进行旋转更新, 旋转更新可用如下加法操作:

$$\theta_{j,i}^{t+1} = \theta_{j,i}^t + \Delta\theta_{j,i}^t \quad (4)$$

其中: $\theta_{j,i}^{t+1}$ 为更新后的第 j 条染色体第 i 个基因位的概率幅相角; $\Delta\theta_{j,i}^t$ 为对应基因位的概率幅相角变化量, 按照文献[5]中的方法计算, 符合式(5)。

$$\Delta\theta_{j,i}^t = \text{sgn}(\cos \theta_{j,i}^t \sin \theta_{j,i}^t) \theta_0 \exp\left(-|\tan \theta_{j,i}^t| - \frac{1}{|\theta_{j,i}^t|}\right) \quad (5)$$

其中: $\text{sgn}()$ 为符号函数, θ_0 为初始旋转角, $|\theta_{j,i}^t|$ 为目标函数在搜索点 X_j^t 第 i 维变量梯度绝对值的均值。

$$|\theta_{j,i}^t| = \frac{1}{m_1 + m_2} \sum_{m=1}^{m_1+m_2} \left| \frac{f(X_j^{t+1})_m - f(X_j^t)}{z_m - x_{j,i}^t} \right| \quad (6)$$

其中: $f(X_j^t)$ 为决策变量 X_j^t 的目标函数值, $f(X_j^{t+1})_m$ 为决策变量 X_j^t 第 i 个分量第 m 次变异后的目标值。

2.3 多维云进化

CRCQEA 利用单维云互补变异完成大范围搜索, 当决策变量的各维分量搜索到一定范围时, 若仅依靠单维搜索, 在求解精度上很难提高, 容易产生摇摆或陷入局部最优。为此, CRCQEA 在单维云互补变异的基础上, 增加了多维云进化操作, 提高了算法的求解精度。对于染色体 p_j^t 生成 1 个多维云云滴的算法如下:

步骤 1 $i = 1$ 。

步骤 2 以 $x_{j,i}^t$ 为期望 E_x , 以 $0.05(u_i - l_i) \cos^2 \theta_{j,i}^t$ 为熵 E_n , 以 $0.1E_n$ 为超熵 H_e , 通过一维正态云算子生成 1 个的云滴 $x_{j,i}^{t+1}$ 。

步骤 3 $i = i + 1$ 。

步骤 4 若 i 不大于 n , 返回步骤 2; 否则, 算法停止, 则 $(x_{j,1}^{t+1}, x_{j,2}^{t+1}, \dots, x_{j,n}^{t+1})$ 即为染色体 p_j^t 的一个多维云云滴, 同时也是优化问题的一个可行解。

CRCQEA 利用多维云产生 m_3 个可行解, 若有优于 $(x_{j,1}^t, x_{j,2}^t, \dots, x_{j,n}^t)$ 的解, 则用该解替换 $(x_{j,1}^t, x_{j,2}^t, \dots, x_{j,n}^t)$ 。多维云进化的搜索半径是单维云变异的十分之一, 又由于采用的是多维同时进化, 因此局部求解精度大大提高。

2.4 动态调整

数值优化问题的搜索空间大小对算法的搜索效率有重要的影响。通常情况下覆盖全局最优的搜索空间越小, 搜索越容易; 反之, 搜索越困难。CRCQEA 在最优解连续 T_r 代没有提高时缩小搜索空间。设当前的搜索空间由向量 $L = (l_1^t, l_2^t, \dots, l_n^t)$ 和 $U = (u_1^t, u_2^t, \dots, u_n^t)$ 确定。则满足调整条件后, 第 i 维决策变量 x_i 的取值范围 $[l_i^{t+1}, u_i^{t+1}]$ 由式(7)确定。

$$\begin{cases} l_i^{t+1} = \min \{x_{1,i}^t, x_{2,i}^t, \dots, x_{N,i}^t\} - \zeta(u_i^t - l_i^t)/2 \\ u_i^{t+1} = \max \{x_{1,i}^t, x_{2,i}^t, \dots, x_{N,i}^t\} + \zeta(u_i^t - l_i^t)/2 \end{cases} \quad (7)$$

其中: $i = 1, 2, \dots, n; \zeta = \text{rand}(0, 1)$

为确保新搜索区域不大于之前的搜索区域, 对新确定的搜索区域进行如下修正:

$$l_i^{t+1} = \begin{cases} l_i^{t+1}, & l_i^{t+1} > l_i^t \\ l_i^t, & l_i^{t+1} \leq l_i^t \end{cases} \quad (8)$$

$$u_i^{t+1} = \begin{cases} u_i^{t+1}, & u_i^{t+1} < u_i^t \\ u_i^t, & u_i^{t+1} \geq u_i^t \end{cases} \quad (9)$$

当算法连续 T_r 代没有提高时, 一方面可以通过缩小搜索空间来提高搜索精度, 另一方面考虑到此种情况有可能是部分染色体陷入局部最优所导致, 因此 CRCQEA 在缩小搜索范围的同时保留历史最优解, 并重新生成 N 条染色体, 在新的求解空间内开始新的进化。

2.5 染色体的全局学习

为充分利用历史最优解的信息,每隔 T_s 代对每个染色体进行一次全局迁徙操作。设历史最优解为 $P_{best} = (x_{b,1}, x_{b,2}, \dots, x_{b,n})$, 对于染色体 $p_j^i (j=1, 2, \dots, N)$ 形成的可行解 $(x_{j,1}^i, x_{j,2}^i, \dots, x_{j,n}^i)$ 任选第 k 位, 用历史最优解的第 k 位 $x_{b,k}$ 替换 $x_{j,k}^i$ 形成新的可行解 $(x_{j,1}^i, \dots, x_{b,k}, \dots, x_{j,n}^i)$, 若该解优于 $(x_{j,1}^i, \dots, x_{j,k}^i, \dots, x_{j,n}^i)$, 则用 $x_{b,k}$ 代替 $x_{j,k}^i$; 否则 $x_{j,k}^i$ 保持不变。

2.6 CRCQEA 流程

CRCQEA 的具体算法流程如下:

步骤1 $t=1$, 初始化种群, 生成形如式(2)的实数编码染色体 N 条, 概率幅相角均初始化为 $\pi/4$ 。

步骤2 评价初始种群, 记录最优解 P_{best} 。

步骤3 对当代种群中的每条染色体的每个基因位实施单维云互补变异。

步骤4 对当代种群中的每条染色体实施多维云进化。

步骤5 若 t 为 T_s 的整数倍, 对当代种群中的每条染色体进行全局学习。

步骤6 评价种群记录历史最优解 P_{best} , 若 P_{best} 连续 T_r 代没有变化则缩小搜索范围, 重置 N 条染色体。

步骤7 若算法不满足结束条件, 则 $t=t+1$, 返回步骤3; 否则, 算法停止, 最优解 P_{best} 即为所求数值优化问题的解。

3 实验及分析

3.1 测试函数

为了考察 CRCQEA 的性能, 本文采用 4 个标准测试函数对算法性能进行测试, 并与全面学习的量子进化算法 (Comprehensive Learning Quantum-inspired Evolutionary of Distribution Algorithm, CLQEDA)^[13] 和 IRCQEA^[5] 进行比较。

所采用的标准数值优化问题表达式分别为:

$$\min F_1 = 0.5 + \frac{\sin^2 \sqrt{x_1^2 + x_2^2} - 0.5}{[1 + 0.001(x_1^2 + x_2^2)]^2} \quad (10)$$

其中: 自变量 $x_i \in [-100, 100] (i=1, 2)$, 全局最小值在 $X=(0, 0)$ 处为 0。

$$\min F_2 = 100(x_1^2 - x_2)^2 + (1 - x_1)^2 \quad (11)$$

其中: 自变量 $x_i \in [-2.048, 2.048] (i=1, 2)$, 全局最小值在 $X=(1, 1)$ 处为 0。

$$\min F_3 = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1 \quad (12)$$

其中: 自变量 $x_i \in [-600, 600]$, 维数 $n=30$, 全局最小值在 $X=(0, 0, \dots, 0)$ 处为 0。

$$\min F_4 = 10n + \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i)) \quad (13)$$

其中: 自变量 $x_i \in [-5.12, 5.12]$, 维数 $n=30$, 全局最小值在 $X=(0, 0, \dots, 0)$ 处为 0。

在本文的实验中, 所有算法的群体规模均为 $N=10$, CRCQEA 初始旋转角 $\theta_0=0.02\pi$, 云变异和进化次数 $m_1=6$, $m_2=2$, $m_3=10$, 全局学习周期 $T_s=100$, 动态调整搜索范围周期 $T_r=10$; CLQEDA 的决策变量 x_i 均采用 18 位二进制数表示, 其余参数设定与文献[13]一致; IRCQEA 为实数编码, 其参数设置与文献[5]一致。算法终止条件为达到一定的进化代数, 最大进化代数取 500。

3.2 实验结果与分析

针对以上 4 个测试函数, 各算法分别独立运行 30 次。运算结果如表 1 所示。

表 1 三种算法在求解复杂函数优化问题的统计结果

函数	算法	最优值	最劣值	平均值	标准差
F_1	CLQEDA	2.91E-7	3.14E-2	7.15E-3	6.97E-3
	IRCQEA	4.01E-8	9.72E-3	3.24E-3	4.66E-3
	CRCQEA	7.65E-10	2.72E-4	1.44E-5	5.15E-5
F_2	CLQEDA	1.73E-9	9.73E-3	1.50E-3	2.58E-3
	IRCQEA	7.00E-6	9.81E-2	1.50E-2	2.27E-2
	CRCQEA	6.59E-14	8.55E-11	1.31E-11	1.95E-11
F_3	CLQEDA	1.58E+1	1.65E+2	6.71E+1	3.75E+1
	IRCQEA	1.52E-7	2.28E-3	2.30E-4	4.43E-4
	CRCQEA	6.46E-8	8.76E-4	4.97E-5	1.60E-4
F_4	CLQEDA	1.51E+2	2.74E+2	2.15E+2	3.79E+1
	IRCQEA	1.05E-7	2.58E-4	3.33E-5	5.85E-5
	CRCQEA	2.98E-11	4.26E-6	4.33E-7	9.54E-7

从表 1 给出的测试结果可以看出, CLQEDA 在维数不高的情况下具有一定的搜索最优值的能力, 当维数较高时, 在组合优化问题中表现优异的 CLQEDA^[13] 根本无法有效寻优, 再次证明了二进制编码的量子进化算法不适合求解数值优化问题。IRCQEA 算法在函数维数较低时易陷入局部最优, 该算法在低维数情况下的表现明显不如高维数, 是因为其染色体长度过短, 不能很好地发挥算法的优势。CRCQEA 在 4 个函数优化问题的各项指标上均优于另外两种算法, 算法利用了正态云模型云滴的随机性和稳定倾向性的特点, 随机性可以保持个体多样性从而提高算法避免陷入局部极值的能力, 稳定倾向性可以较好地保护较佳个体从而实现对最优值的自适应定位, CRCQEA 通过单维度的变异进行全局快速搜索, 采用多维度的云进化操作增强了算法的局部搜索能力, 因此即使在决策变量维数不高的情况下也能获得令人满意的求解精度。

图 1 给出了各算法在 30 次独立运行中最优值的平均值随代数变化的情况, 从求解质量和收敛速度两个方面再次表明了 CRCQEA 的优良性能。

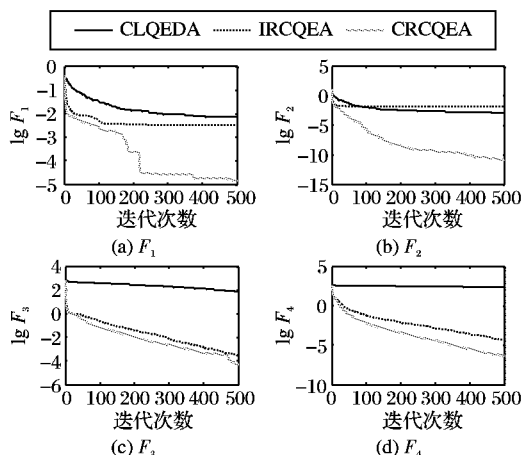


图 1 三种算法求解复杂函数优化问题的进化曲线

4 结语

本文提出了一种基于云模型的实数编码量子进化算法 (CRCQEA), 利用正态云模型云滴的随机性和稳定倾向性的特点对实数编码的量子进化算法进行改造, 云理论的随机性可以避免搜索陷入局部极值, 而稳定倾向性又可以很好地定位全局最优值。通过对标准测试函数的实验验证了本文算法的有效性。

(下转第 2569 页)

表4 模糊统计模型与 FNN 模型判别结果对比

实际等级	模糊统计判别结果	FNN 判别结果	实际等级	模糊统计判别结果	FNN 判别结果
4	0.907 7 (4)	4.056 106 (4)	2	0.752 9 (3)	2.361 317 (2)
4	0.914 5 (4)	4.089 258 (4)	2	0.711 4 (2)	1.961 287 (2)
4	0.915 6 (4)	3.959 003 (4)	2	0.697 6 (2)	1.976 905 (2)
4	0.895 7 (4)	4.150 994 (4)	2	0.660 0 (2)	2.005 117 (2)
4	0.898 4 (4)	4.095 558 (4)	2	0.610 3 (1)	1.951 462 (2)
3	0.871 7 (4)	3.249 229 (3)	1	0.647 1 (2)	1.404 496 (1)
3	0.845 3 (3)	3.018 143 (3)	1	0.637 8 (2)	1.075 475 (1)
3	0.818 6 (3)	3.022 092 (3)	1	0.511 3 (1)	0.998 06 (1)
3	0.776 2 (3)	3.027 622 (3)	1	0.404 6 (1)	0.937 603 (1)
3	0.798 0 (3)	2.954 456 (3)	1	0.325 1 (1)	0.982 752 (1)

注:单元格中 * * * * (*) 的含义为上面数据表示模型实际输出值,下面括号里的表示最后的判别结果。

从表4中可得,文献[4]中基于模糊统计的热轴判别模型激热等级判别一致率为100%,强热等级判别一致率为80%,微热和正常运转热等级判别一致率为60%,总的等级判别一致率为75%;而模糊神经网络充分训练后热轴的等级判别一致率约为95%,达到了理想的效果。

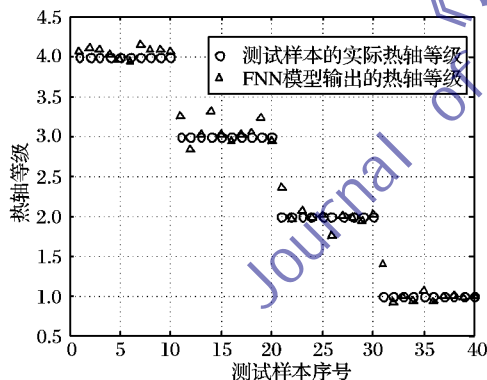


图4 测试样本数据与FNN输出结果

4 结语

热轴等级判别没有固定的公式及模型,根据已有方法中的门限值对其进行判断难免出现一定误差。本文结合神经网络与模糊数学的优点建立热轴判别模型,给出了具体的模型参数指标,通过样本数据和误差反向传播算法对FNN模型进行训练和优化,使得热轴判别一致率达到95%,最后通过与文献[4]中的判别模型进行对比,进一步验证了该模型的有效性和准确性。

因热轴等级之间界限模糊,使用该模型使热轴判别更加科学化,将模糊推理转化为神经网络结构进行训练,使得系统各参数达到最优的值,而各个等级也无需设置门限值,大大减少了判别参数。但热轴判别关系重大,既不能漏报也不能误报,因此还需要用更多、更全面的现场数据对模型进一步完善,从而实现该模型应有的实用性和价值。

参考文献:

- [1] 赵长波,陈雷. 铁路货车轴温探测与应用概论[M]. 北京: 中国铁道出版社,2010: 18-34.
- [2] 傅英晖. 铁路车辆轴温智能探测系统存在的问题分析及改进建议[J]. 中国科技信息,2010(14): 275-277.
- [3] 刘战功. 红外线轴温探测系统热轴误报分析及建议[J]. 铁道机车车辆,2006(4): 63-64.
- [4] 陶贤湘. 红外线轴温探测系统探测可靠性和热轴预报兑现率的研究[D]. 长沙: 中南大学,2010.
- [5] 杨秋兰. 提高红外线轴温探测系统可靠性的研究[D]. 长沙: 中南大学,2011.
- [6] 王家琦. HTK型热轴判别模型分析与建立[J]. 哈尔滨铁道科技,2012(2): 17-18.
- [7] 北京康拓红外技术有限公司. 一种列车红外轴温探测系统的热轴判别方法: 中国,200710178606[P]. 2008-05-21.
- [8] 周润景,张丽娜. 基于Matlab与fuzzyTECH的模糊与神经网络设计[M]. 北京: 电子工业出版社,2010: 198-200.
- [9] 周春光,梁艳春. 计算智能: 人工神经网络·模糊系统·进化计算[M]. 长春: 吉林大学出版社,2009: 176-180.
- [10] 徐兵,程旭德,王宏利,等. 基于Matlab的Mamdani与Sugeno型模糊推理研究[J]. 计算机应用,2006,26(S2): 223-224.
- [11] HORIKAWA S, FURUHASHI T, CHIKAWA Y U. On fuzzy modeling using fuzzy neural networks with the back propagation algorithm[J]. IEEE Transactions on Neural Networks, 1992, 3(5): 801-806.
- [12] 张泽旭. 神经网络控制与Matlab仿真[M]. 哈尔滨: 哈尔滨工业大学出版社,2011: 244-252.
- [13] 袁荣昌,孙龙清,董晨曦,等. 基于模糊模式识别的籽棉品质分级模型[J]. 计算机应用,2011,31(8): 2097-2011.

(上接第2552页)

参考文献:

- [1] HAN K H, KIM J H. Quantum-inspired evolutionary algorithm for a class of combinatorial optimization[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(6): 580-593.
- [2] ZHANG G X, JIN W D, HU L Z. Quantum evolutionary algorithm for multiobjective optimization problems[C]// Proceedings of the 2003 IEEE International Symposium on Intelligent Control. Piscataway, NJ: IEEE Press, 2003: 703-708.
- [3] 李盼池. 基于量子位 Bloch 坐标的量子遗传算法及其应用[J]. 控制理论与应用,2008,25(6): 985-989.
- [4] 覃朝勇,郑建国,朱佳俊. 一种实数编码量子进化算法及其收敛性[J]. 控制与决策,2009,24(6): 854-858.
- [5] 高辉,张锐. 改进实数编码量子进化算法及其在参数估计中的应用[J]. 控制与决策,2011,26(3): 418-422.
- [6] 李德毅,孟海军,史雪梅. 隶属云和隶属云发生器[J]. 计算机研

究与发展,1995,32(6): 15-20.

- [7] 戴朝华,朱云芳,陈维荣,等. 云遗传算法及其应用[J]. 电子学报,2007,35(7): 1419-1424.
- [8] 张煜东,吴乐南,韦耿. 一种改进的基于隶属云模型的蚁群算法[J]. 计算机工程与应用,2009,45(27): 11-14.
- [9] 张朝龙,余春日,江善和,等. 基于混沌云模型的粒子群优化算法[J]. 计算机应用,2012,32(7): 1951-1954.
- [10] 李德毅,刘常昱,杜鹃,等. 不确定性人工智能[J]. 软件学报,2004,15(11): 1583-1594.
- [11] 张光卫,何锐,刘禹,等. 基于云模型的进化算法[J]. 计算机学报,2008,31(7): 1082-1090.
- [12] 王湘中,喻寿益. 适用于高维优化问题的改进进化策略[J]. 控制理论与应用,2006,23(1): 148-151.
- [13] 谭立湘,郭立. 基于全面学习的量子分布估计算法[J]. 模式识别与人工智能,2010,23(3): 314-319.