

文章编号: 1001-0920(2011)10-1463-06

一种改进二进制编码量子行为粒子群优化聚类算法

陈伟, 傅毅, 孙俊, 须文波

(江南大学 物联网工程学院, 江苏 无锡 214000)

摘要: 为了改善二进制量子行为粒子群优化(BQP SO)算法的收敛性能, 提出了一种基于完全学习策略的改进 BQP SO 优化(CLBQP SO)算法, 并由此设计了一种新的数据聚类方法. 该算法在 4 个测试数据集上与其他一些聚类算法进行了聚类实验比较, 实验结果表明, 基于 CLBQP SO 的聚类算法不仅收敛速度快, 而且有较好的全局收敛性, 收敛精度优于其他聚类算法, 聚类效果更好.

关键词: 量子行为粒子群优化; 二进制编码; 完全学习策略; 聚类

中图分类号: TP39

文献标识码: A

Improved binary quantum-behaved particle swarm optimization clustering algorithm

CHEN Wei, FU Yi, SUN Jun, XU Wen-bo

(School of Internet of Things Engineering, Jiangnan University, Wuxi 214000, China. Correspondent: CHEN Wei, E-mail: chenwei_0906@yahoo.com.cn)

Abstract: A binary quantum-behaved particle swarm optimization(BQP SO) algorithm based on comprehensive learning strategy is proposed for improving the performance of convergence. Then a new data clustering method is designed according to comprehensive learning BQP SO(CLBQP SO). The new clustering algorithm is compared with some other clustering algorithms on four testing data sets in clustering experiment. The experiment results show that the CLBQP SO clustering algorithm not only converges faster but also owns the better global convergence. Contrast to other clustering algorithms, the better convergence accuracy and clustering solution are obtained.

Key words: quantum-behaved particle swarm optimization; binary coding; comprehensive learning strategy; clustering

1 引言

数据聚类是根据数据集中各数据点之间相似性的度量将其划分为若干个不同类别的过程. 通过聚类分析, 同一个类中的数据具有较高的相似性, 而不同类别中的数据具有较大的差异性. 目前, 数据聚类已经在许多科研领域有了广泛的应用, 包括数据挖掘、机器学习、生物信息以及图像处理等方面^[1]. 近年来, 随着聚类技术的不断发展, 许多研究人员开始将群体智能算法引入聚类方法中. 这一类新聚类算法的根本策略是将数据聚类问题归结为一个优化问题, 模拟自然界的某些群体智能行为进行启发式的搜索, 通过解种群的演变, 寻找具有最优目标函数值的聚类划分. 其中典型代表是基于粒子群优化(PSO)的聚类算法^[2]. 理论与实践证明, 量子行为粒子群优化^[3](QP SO)相对于 PSO 具有进化方程简单、控制参数少、

收敛速度快、收敛精度高等优点.

本文根据文献 [4] 对聚类解的编码原则, 为了解决离散空间优化问题, 提出了一种基于二进制编码的量子行为粒子群优化聚类算法(BQP SO), 并在实际应用中取得了一些成果^[5-6]. 针对 BQP SO 算法的进化过程, 本文对算法中粒子局部吸引子的更新进行了改进, 采用一种群体性更突出的学习策略, 提高了聚类算法的收敛性能. 通过聚类实验以及实验结果分析, 验证了基于改进 BQP SO 的数据聚类算法是一种有效的基于群体智能优化的数据聚类新方法.

2 二进制编码的 QP SO 优化算法

2.1 QP SO 算法简介

PSO 算法是由 Kennedy 等人^[7]根据对鸟群觅食行为的研究而提出的一种群体智能优化技术. Sun 等

收稿日期: 2010-06-03; 修回日期: 2010-09-19.

基金项目: 国家自然科学基金项目(60703106, 60474030); 国家 863 计划项目(2008AA02Z21).

作者简介: 陈伟(1981-), 男, 博士生, 从事人工智能、群体智能算法的研究; 须文波(1946-), 男, 教授, 博士生导师, 从事人工智能、模糊控制等研究.

人^[3]在对 PSO 的智能行为以及收敛性能进行深入研究的基础上, 将量子力学的相关概念引入粒子的进化过程, 提出了 QPSO 算法. QPSO 算法相对于 PSO 算法具有进化方程简单、控制参数少、收敛速度快、精度高等优点, 在许多领域取得了优于 PSO 算法的效果^[8-11].

假设 M 为种群的粒子数目, 第 $i(1 \leq i \leq M)$ 个粒子在搜索空间中的当前位置为 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$, D 为粒子的维数, 即决策变量的个数. 在每一次迭代过程中, 算法记录当前每一个粒子经历的最好位置 p_{best} , 记为 $P_i = (P_{i1}, P_{i2}, \dots, P_{iD})$, 种群中所有粒子当前经历的全局最好位置 g_{best} 记为 $G = (G_1, G_2, \dots, G_D)$, 则 QPSO 中粒子在每一代中的位置更新公式为

$$q_i = \varphi P_i(t) + (1 - \varphi)G(t), \quad \varphi \sim U(0, 1); \quad (1)$$

$$m_{\text{best}}(t) = \frac{1}{M} \sum_{i=1}^M P_i(t) = \left(\frac{1}{M} \sum_{i=1}^M P_{i1}(t), \frac{1}{M} \sum_{i=1}^M P_{i2}(t), \dots, \frac{1}{M} \sum_{i=1}^M P_{iD}(t) \right); \quad (2)$$

$$X_i(t+1) = q_i(t) \pm \beta |m_{\text{best}}(t) - X_i(t)| \ln(1/u), \quad u \sim U(0, 1). \quad (3)$$

其中: φ 和 u 是 $[0, 1]$ 范围内均匀分布的随机数; β 是 QPSO 算法的参数, 称为收缩扩张系数, 在迭代过程中可以通过对其调节来控制算法的收敛性能; m_{best} 是种群中所有粒子各自当前最佳位置的平均值, 或者称为种群的重心位置; q_i 为每个粒子的局部吸引子, 由粒子的 p_{best} 和种群的 g_{best} 所决定.

2.2 二进制 QPSO 算法思想

QPSO 算法的进化方程与 PSO 算法大相径庭, 所以二进制 PSO 算法的一些定义和改进方法对于设计二进制 QPSO 算法是不适合的. 在 QPSO 中, 没有速度向量, 只有位置向量和距离. 由于粒子的位置被定义为一个二进制串, 设计二进制算法的第一步是对距离和位置变换进行定义.

文献 [12] 所提出的 BQPSO 为了表示两个粒子之间的距离, 引入了海明距离, 定义粒子含有决策变量的个数即为粒子的维数, 如 X_{ij} , 其下标 i 表示群体中的第 i 个粒子, j 表示该粒子的第 j 个决策变量. 若粒子的每一维决策变量用 m 个二进制位编码表示, 则每一个粒子的二进制位长度为 $l = mD$. 任意两个粒子 X_1 和 X_2 的距离可由海明距离表示为

$$|X_1 - X_2| = d_H(X_1, X_2), \quad (4)$$

其中 $d_H(\cdot)$ 是计算海明距离的函数, 其值为两个二进制位串中不同位的个数.

在 QPSO 中, 平均最好位置 m_{best} 通过求解个体最好位置 p_{best} 的均值获得; 在 BQPSO 中, m_{best} 的每一位二进制位的值由群体中所有粒子当前最优个体 p_{best} 的对应二进制位决定. 统计所有 p_{best} 二进制编码每一位出现 0 和 1 的次数, 若出现 0 的次数多, 则 m_{best} 对应位取 0; 反之, 则取 1; 若 0 和 1 出现的次数同样多, 则在该位等概率地取 0 或 1.

在 QPSO 中, 更新粒子的位置之前必须求出局部吸引子 q_i , 该点每一维坐标位于个体最好位置 (P_i) 和全局最好位置 (G) 在对应维的坐标之间, 从而使 $q_i = (q_{i1}, q_{i2}, \dots, q_{iD})$ 均匀分布于以 P_i 和 G 为对角线两端的超矩形中. 在 BQPSO 算法中, q_i 可以通过类似遗传算法中的交叉操作获得, 即通过 P_i 和 G 的单点或多点交叉产生两个子代, 随机地选择一个子代作为新的 q_i 点.

考虑 QPSO 的粒子位置进化式 (3), 将其改写为

$$|X_{ij}(t+1) - q_{ij}(t)| = \beta |m_{\text{best}j}(t) - X_{ij}(t)| \ln(1/u). \quad (5)$$

将距离看成海明距离, 式 (5) 可改写为

$$d_H[X_{ij}(t+1), q_{ij}(t)] = b, \quad (6)$$

$$b = \beta d_H[X_{ij}(t), m_{\text{best}j}(t)] \ln(1/u). \quad (7)$$

其中: $d_H[X_{ij}(t+1), q_{ij}(t)]$ 是粒子 i 和其局部吸引子第 j 维决策变量对应的二进制位串的海明距离; 因为海明距离为整数, 需要对 b 取整. 为了由式 (6) 得到更新后的粒子位置, X_{ij} 的每一位二进制位可以通过变异 q_{ij} 的对应位得到, 变异概率由 b 决定, 表达式为

$$p_m = \begin{cases} b/m, & b/m < 1; \\ 1, & b/m \geq 1. \end{cases} \quad (8)$$

其中 m 为粒子第 j 维的二进制位长度. 这样, 粒子位置在更新时, 随机产生一个 $[0, 1]$ 范围内的随机数 $\text{rand}(\cdot)$. 若 $\text{rand}(\cdot) < p_m$, 则相应位置的二进制位取与原来相反的状态; 否则, 保持状态不变.

根据以上对算法的设计和定义, BQPSO 算法的步骤可描述如下:

Step 1: 初始化粒子的位置, 即随机产生粒子当前位置 X_i , 并将个体最好位置 P_i 置为 $P_i = X_i$;

Step 2: 根据要求计算粒子群的平均最好位置 m_{best} ;

Step 3: 将粒子当前位置 X_i 解码并评价粒子的目标函数值 $f(X_i)$ (适应度值), 与个体最好位置的目标函数值 $f(P_i)$ 进行比较, 若 $f(X_i) < f(P_i)$, 则置 $P_i = X_i$;

Step 4: 找出群体的全局最好位置, 即求解 $g = \arg \min_{1 \leq i \leq M} (f(P_i))$, 令 $G = P_g$;

Step 5: 对于每一个粒子, 采用单点或多点交叉产生局部吸引子 q_i ;

Step 6: 由式 (6)~(8) 计算每一维决策变量二进制位的变异概率 p_m , 根据 p_m 更新粒子的新位置;

Step 7: 重复 Step 2~Step 6, 直到满足停止准则或达到给定的最大迭代数.

2.3 基于完全学习策略的改进 BQPSO 算法思想

虽然通过理论证明 BQPSO 算法的迭代过程是收敛的^[12], 但在 BQPSO 算法中, 粒子位置的更新是在其局部吸引子 (q_i) 的基础上进行变异获得的, 而 q_i 的位置是由单个粒子当前最优位置 (P_i) 和种群的全局最优位置 (G) 共同决定的, 这意味着在 BQPSO 中粒子的社会学习行为仅仅是通过粒子共享 G 的信息来实现的. 当优化问题具有多个局部最优解时, 尽管 G 的位置可能远离全局最优解, 但种群中的所有粒子仍会向其学习, 导致粒子容易陷入 G 所在的区域, 从而使算法收敛到一个局部最优解.

为了更好地利用种群中有用的信息, 提出了一种新的学习策略来改进原来的 BQPSO 算法. 在改进的算法中, 种群中所有粒子的当前最优位置均用来更新粒子的局部吸引子, 这种新的学习策略保证了种群的多样性, 从而改善了算法的收敛性能.

在新的 BQPSO 学习策略中, 采用新的局部吸引子 q_i 的更新方式为

$$q_i = P_{f_i(d)} = (P_{f_i(1)1}, P_{f_i(2)2}, \dots, P_{f_i(D)D}). \quad (9)$$

其中 q_i 的位置不再由 P_i 和 G 通过交叉操作获得, 而是每一维的坐标均可能取自任何一个粒子当前最佳位置所对应维的二进制串. 其中函数 $f_i = (f_i(1), f_i(2), \dots, f_i(D))$ 决定了粒子 i 的吸引子各维应取自哪一个粒子的 p_{best} .

为了确定函数 f_i 中各维的值, 首先引入参数 p_c , 称为学习概率. p_c 决定了 q_i 中每一维应该取自粒子 i 自身的 p_{best} 还是取自其他粒子的 p_{best} . 在学习过程中, 对于粒子 i 的每一维, 产生一个随机数 $\text{rand}()$, 若 $\text{rand}() > p_c$, 则 q_i 对应维的二进制位串取自其自身的 p_{best} ; 否则, 需向其他粒子的 p_{best} 进行学习. 当 q_i 的某一维需要向其他粒子的 p_{best} 学习时, 首先从种群中随机选取两个粒子的 p_{best} , 比较这两个粒子 p_{best} 的目标函数值, 选择其中较好的一个, 此时 q_i 在该维的二进制位串更新为被选择粒子 p_{best} 相应维的二进制串. 如果 q_i 的所有维决策变量所对应的二进制串均取自其自身的 p_{best} , 则在该 q_i 中随机选择某一维决策变量向其他粒子的 p_{best} 进行学习.

采用以上粒子局部吸引子更新方式的 BQPSO 算法在迭代更新时, 能够充分利用种群中所有粒子的当前最佳位置所提供的有用信息, 是一种基于完全学习策略^[13]的二进制量子行为粒子群优化 (CLBQPSO) 算法.

3 基于 CLBQPSO 的聚类算法

已知数据集包含 N 个数据点, 每一个数据点是一个包含 D 个属性特征的模式向量. 基于 CLBQPSO 的聚类算法是在使用欧几里德距离作为相似性度量的基础上, 将该数据集划分为指定的 K 类, 所得到的聚类划分能使总体类间差异 (TWCV) 最小化.

设 $\{Y_1, Y_2, \dots, Y_N\}$ 为包含 N 个模式向量的数据集, y_{nd} 代表模式向量 Y_n 的第 d 维属性 ($n = 1, 2, \dots, N$). 对于该数据集的每一个聚类划分可以用一个整数数码串 a_1, a_2, \dots, a_N 表示, 其中 a_n 取 $1 \sim k$ 内的任一整数, 代表模式向量 Y_n 在这个划分中所属的类标签. 这样, 若将此整数数码串中的每一位转换为一个长度为 m 的二进制串, 则此时转换得到的二进制码串即可作为 CLBQPSO 聚类算法中的一个粒子, 代表一个聚类问题的解. m 的取值为能够表示 K 的最短二进制数的位数.

若用 G_k 代表第 k 个类, Z_k 代表 G_k 中的模式向量个数, 则类 G_k 的聚类中心 $C_k = (c_{k1}, c_{k2}, \dots, c_{kD})$ 可以表示为

$$C_k = \sum_{Y_n \in G_k} Y_n / Z_k. \quad (10)$$

由此第 k 类的类内差异 (WCV) 可以表示为

$$\text{WCV}(k) = \sum_{Y_n \in G_k} \sum_{d=1}^D (y_{nd} - c_{kd})^2. \quad (11)$$

TWCV 可以表示为

$$\text{TWCV} = \sum_{k=1}^K \text{WCV}(k) = \sum_{k=1}^K \sum_{Y_n \in G_k} \sum_{d=1}^D (y_{nd} - c_{kd})^2. \quad (12)$$

CLBQPSO 聚类算法首先定义代表聚类划分的解的编码规则, 解种群在随机初始化后随着迭代过程逐步进化; 每一次进化均在当前代粒子基础上进行 CLBQPSO 位置更新操作和 K 均值 (K -means) 聚类操作以产生新一代粒子种群, 并通过目标函数 TWCV 评价粒子的适应度值, 找出聚类问题的当前最优解, 进化过程一直持续到满足事先定义的终止条件. 具体的 CLBQPSO 聚类算法过程描述如下:

Step 1: 随机地将数据集中的数据向量分配到 K 个类中, 将表示一个聚类划分的整数数码串 a_1, a_2, \dots, a_N 的每一位转换为一个 m 位的二进制位串, 得到一个二进制编码的初始化粒子, 反复多次操作,

生成聚类算法的初始粒子群.

Step 2: 每个粒子的当前最好位置 p_{best} 定义为粒子的初始位置, 根据式 (10)~(12) 计算每个粒子 p_{best} 对应的 TWCV 值, 将具有最小 TWCV 的 p_{best} 定义为种群的初始 g_{best} .

Step 3: 根据当前所有的 p_{best} 确定 m_{best} 的位置, 对于粒子 i , 通过定义的完全学习策略得到粒子局部吸引子 q_i 的位置, 由式 (6)~(8) 计算粒子 i 每一维决策变量二进制位的变异概率 p_m ; 根据 p_m , 更新粒子的新位置, 若更新后某一维决策变量对应二进制位串表示的类标签超出了 $[1, K]$ 的范围, 则该维的随机变量在整数 $[1, K]$ 内随机取值.

Step 4: 为了加快聚类算法的收敛速度, 引入了一项单步的 K -means 操作. 对于每次更新后的各个粒子, 将其解码后由式 (10) 计算对应的聚类中心, 由此得到新的类标签整数串 $\hat{a}_1, \hat{a}_2, \dots, \hat{a}_N$, 并将此整数串重新编码为二进制串后取代当前粒子的位置.

Step 5: 对于粒子 i , 将当前位置 X_i 解码并评价粒子的目标函数值 $TWCV(X_i)$, 与个体最好位置的目标函数值 $TWCV(P_i)$ 进行比较, 如果 $TWCV(X_i) < TWCV(P_i)$, 则置 $P_i = X_i$, 更新群体的全局最好位置, 即求解 $g = \arg \min_{1 \leq i \leq M} (TWCV(P_i))$, 令 $G = P_g$.

Step 6: 重复 Step 3~Step 5, 直到满足停止准则或达到给定的最大迭代数为止.

4 聚类实验及分析

为了验证 CLBQPSO 聚类算法的有效性和优越性, 将其与其他 4 种聚类算法进行聚类实验比较. 4 种聚类方法分别为经典的 K -means 聚类、文献 [4] 中基于遗传算法的 GKA (genetic K -means algorithm) 聚类以及采用相同聚类解编码规则的 BPSO 聚类和 BQPSO 聚类. 聚类实验采用 iris plants database, glass, wisconsin breast cancer 和 wine^[4] 4 个数据集, 各数据集特性如表 1 所示.


表 1 聚类数据集的特性

数据集	数据个数 N	数据维数 D	标准类数 K
iris plants database	150	3	3
glass	214	9	6
wisconsin breast cancer	683	9	2
wine	178	13	3


聚类实验中 4 种智能聚类算法的种群粒子数 (对于 GKA 而言为染色体的数目) 均设为 20. GKA 算法的变异概率 $p_m = 0.05$ ^[4]; BPSO 算法的粒子最大速度 $V_{max} = 6$, 加速常数 $c_1 = c_2 = 1$ ^[5]. 通过对 BQPSO 算法的数值仿真实验发现, 当系数 $0 < \beta \leq 2$ 时算法往往是收敛的, 经过对同一数据集进行多次聚类实

验后, 根据经验取 $\beta = 1.4$ 时, 能够得到相对较好的聚类结果. 另外, CLBQPSO 中局部吸引子的学习概率 $p_c = 0.5$, 所有聚类算法的最大迭代次数均设为 50.


实验结果是各聚类算法在所有数据集上 (聚类之前经过了归一化处理) 独立运行 30 次之后进行统计平均处理后得到的. 图 1 显示了各聚类算法在对 4 个数据集进行聚类时的收敛过程, 表 2 列出了各聚类算法得到的目标函数值 (TWCV) 及其标准差 (括号内数值为标准差). 从图 1 中的收敛曲线可以看出, 引入了 K -means 操作的群体智能优化聚类算法 (GKA, BPSO, BQPSO 和 CLBQPSO) 能够有效加快整个聚类过程的收敛速度, 继承了单纯的 K -means 聚类收敛快的优点, 并且凭借群体智能算法的有效进化策略, 改




(a) iris 数据集聚类收敛过程



(b) glass 数据集聚类收敛过程



(c) breast cancer 数据集聚类收敛过程



(d) wine 数据集聚类收敛过程

图 1 各聚类算法对 4 组实验数据聚类时的收敛曲线

表 2 聚类结果的目标函数值

	iris plants	glass	breast cancer	wine
<i>K</i> -means	2.733 1(0.544 0)	0.566 5(0.094 1)	3.312 2e003(32.959 7)	1.219 3(3.172 7e-4)
GKA	2.633 8(4.516 8e-16)	0.493 5(0.018 7)	3.280 7e003(5.421 1)	1.218 9(6.231 1e-4)
BPSO	2.645 1(0.019 7)	0.494 0(0.010 4)	3.279 6e003(0.031 8)	1.270 1(0.022 1)
BQPSO	2.633 8(4.516 8e-16)	0.482 0(0.022 7)	3.286 3e003(17.249 1)	1.218 3(4.740 1e-4)
CLBQPSO	2.633 8(4.516 8e-16)	0.476 6(0.012 2)	3.279 6e003(9.250 4e-13)	1.218 1(6.775 2e-16)

表 3 聚类结果的 Rand 指数评价

	iris plants	glass	breast cancer	wine
<i>K</i> -means	0.870 8(0.081 4)	0.253 3(0.027 5)	0.308 9(0.027 0)	0.153 7(0.146 7)
GKA	0.885 7(4.516 8e-16)	0.270 5(0.015 1)	0.325 5(0.013 8)	0.164 2(0.016 9)
BPSO	0.884 9(0.017 6)	0.262 0(0.010 1)	0.313 5(0.014 2)	0.163 1(0.002 6)
BQPSO	0.885 7(4.516 8e-16)	0.270 5(0.013 7)	0.334 8(0.010 5)	0.165 0(0.109 5)
CLBQPSO	0.885 7(4.516 8e-16)	0.275 5(0.007 2)	0.338 2(2.823 0e-16)	0.201 5(1.129 2e-16)

善了 *K*-means 聚类算法受初始化影响大、收敛精度差的缺点。尤其对于 CLBQPSO 聚类, 从表 2 可以看出, 在采用完全学习策略进行粒子局部吸引子更新后, 进一步提高了目标函数的收敛精度, 获得了具有最佳目标函数值的聚类结果。另外, 由于 GKA 聚类算法中染色体的更新包括了交叉和变异等复杂操作, CLBQPSO 聚类在算法的执行时间上要比 GKA 聚类更有优势。

由于实验中所使用的数据集在未进行聚类分析之前, 其外部的标准分类是已知的, 除了目标函数值, 对于聚类结果的评价, 实验中还采用 Rand 指数^[16]来衡量各算法所得聚类划分和数据集本身的外部标准分类之间的一致性程度, 如表 3 所示(括号内数值为标准差)。从表 3 中的数据可以看出, 5 种聚类算法的 Rand 指数聚类评价与之前的目标函数值评价结果基本一致, CLBQPSO 算法得到的聚类结果与外部标准分类之间具有较高的吻合度。

5 结 论

本文提出了一种基于完全学习策略的二进制编码量子行为粒子群优化算法。在新的 CLBQPSO 算法中, 种群中所有粒子的当前最优位置均可用来更新粒子的局部吸引子, 有效利用了种群中粒子提供的社会信息, 使得粒子间的相互学习更充分, 从而改善了 BQPSO 的收敛性能。由此设计了基于 CLBQPSO 的数据聚类算法, 并进行了实验验证。实验结果表明, CLBQPSO 聚类算法继承了 *K*-means 聚类算法收敛速度快的优点, 并与其他基于群体智能的聚类算法相比, 具有更高的收敛精度。因此, CLBQPSO 聚类算法在数据聚类相关领域中有着良好的应用前景。

参考文献(References)

[1] Taher N, Babak A. An efficient hybrid approach based on PSO, ACO and *k*-means for cluster analysis[J]. Applied

- Soft Computing, 2010, 10(1): 183-197.
- [2] 李峻金, 向阳, 芦英明, 等. 粒子群聚类算法综述[J]. 计算机应用研究, 2009, 26(12): 4423-4427.
(Li J J, Xiang Y, Lu Y M, et al. Survey of particle swarm clustering algorithms[J]. Application Research of Computers, 2009, 26(12): 4423-4427.)
- [3] Sun J, Feng B, Xu W B. Particle swarm optimization with particles having quantum behavior[C]. Proc 2004 Congress on Evolutionary Computation. Piscataway, 2004: 325-331.
- [4] Lu Y, Lu S, Fotouhi F, et al. Incremental genetic K-means algorithm and its application in gene expression data analysis[J]. BMC Bioinformatics, 2004, 5: 172-181.
- [5] 周颀, 孙俊, 须文波. 基于二进制具有量子行为的粒子群算法的多边形近似[J]. 计算机应用, 2007, 27(8): 2030-2032.
(Zhou D, Sun J, Xu W B. Polygonal approximation of curves using binary quantum-behaved particle swarm optimization[J]. J of Computer Applications, 2007, 27(8): 2030-2032.)
- [6] 奚茂龙, 孙俊, 耿汝年, 等. 基于二进制编码 QPSO 算法的机器人路径规划[J]. 系统仿真学报, 2009, 21(17): 5516-5523.
(Xi M L, Sun J, Geng R N, et al. Path planning for mobile robot based on binary quantum-behaved particle swarm optimization[J]. J of System Simulation, 2009, 21(17): 5516-5523.)
- [7] Kennedy J, Eberhart R. Particle swarm optimization[C]. Proc of IEEE Int Conf on Neural Networks. Piscataway: IEEE, 1995: 1942-1948.
- [8] Omkar S N, Khandelwal R, Ananth T V S, et al. Quantum behaved particle swarm optimization(QPSO) for multi-objective design optimization of composite structures[J]. Expert Systems with Applications, 2009, 36(8): 11312-11322.

- [9] Jalilzadeh S, Shayeghi H, Safari A, et al. Output feedback UPFC controller design by using quantum particle swarm optimization[C]. The 6th Int Conf on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology. Piscataway, 2009: 28-31.
- [10] Sabat S L, Coelho L S, Abraham A. MESFET DC model parameter extraction using quantum particle swarm optimization[J]. *Microelectronics Reliability*, 2009, 49(6): 660-666.
- [11] Coelho L S, Alotto P. Global optimization of electromagnetic devices using an exponential quantum-behaved particle swarm optimizer [J]. *IEEE Trans on Magnetics*, 2008, 44(6): 1074-1077.
- [12] 奚茂龙, 孙俊, 吴勇. 一种二进制编码的量子粒子群优化算法[J]. *控制与决策*, 2010, 25(1): 99-104.
(Xi M L, Sun J, Wu Y. Quantum-behaved particle swarm optimization with binary encoding[J]. *Control and Decision*, 2010, 25(1): 99-104.)
- [13] Liang J J, Qin A K. Comprehensive learning particle swarm optimizer for global optimization of multimodal functions[J]. *IEEE Trans on Evolutionary Computation*, 2006, 10(3): 281-295.
- [14] Blake C, Keough E, Merz C J. UCI repository of machine learning database[EB/OL]. [2010-03]. <http://archive.ics.uci.edu/ml/>.
- [15] Shi Y, Eberhart R C. A modified particle swarm particle swarm optimizer[C]. Proc of the IEEE Int Conf on Evolutionary Computation. Piscataway: IEEE Press, 1998: 69-73.
- [16] Bandyopadhyay S, Mukhopadhyay A, Maulik U. An improved algorithm for clustering gene expression data[J]. *Bioinformatics*, 2007, 23: 2859-2865.

(上接第1462页)

- [12] 邵青, 冯汝鹏. 非线性系统模糊辨识的新方法[J]. *控制与决策*, 2001, 16(1): 83-85.
(Shao Q, Feng R P. New method of fuzzy identification of nonlinear systems[J]. *Control and Decision*, 2001, 16(1): 83-85.)
- [13] 刘福才, 关新平, 裴润. 基于一种新模糊模型的非线性系统模糊辨识[J]. *控制理论与应用*, 2003, 20(1): 113-116.
(Liu F C, Guan X P, Pei R. Fuzzy identification based on new fuzzy model for nonlinear systems[J]. *Control Theory and Applications*, 2003, 20(1): 113-116.)
- [14] 边润强, 陈增强, 袁著祉. 一种改进的遗传算法及其在系统辨识中的应用[J]. *控制与决策*, 2000, 15(5): 623-625.
(Bian R Q, Chen Z Q, Yuan Z Z. Improved genetic algorithm and its application in system identification[J]. *Control and Decision*, 2000, 15(5): 623-625.)
- [15] Kristinsson K. System identification and control using genetic algorithms[J]. *IEEE Trans on Systems, Man and Cybernetics*, 1992, 22(5): 1033-1046.
- [16] 代冀阳, 张建刚, 毛建琴. 基于遗传算法的模糊树建模方法[J]. *自动化学报*, 2000, 26(5): 707-710.
(Dai J Y, Zhang J G, Mao J Q. Fuzzy-tree modeling based on genetic algorithm[J]. *Acta Automatica Sinica*, 2000, 26(5): 707-710.)
- [17] Chen Y X, Wang J Z. Support vector learning for fuzzy rule based classification systems[J]. *IEEE Trans on Fuzzy Systems*, 2003, 11(6): 716-728.
- [18] Kaieda K, Abe S. A kernel fuzzy classifier with ellipsoidal regions[C]. Proc of the Int Joint Conf on Neural Networks. Portland: Institute of Electrical and Electronics Engineers Inc, 2003: 2043-2048.
- [19] Lee C, Teng C C. Identification and control of dynamic systems using recurrent fuzzy neural network[J]. *IEEE Trans on Fuzzy Systems*, 2000, 8(4): 349-366.
- [20] 张建刚, 毛建琴, 夏天, 等. 模糊树模型及其在复杂系统辨识中的应用[J]. *自动化学报*, 2000, 26(3): 378-381.
(Zhang J G, Mao J Q, Xia T, et al. Fuzzy-tree model and its applications to complex system modeling[J]. *Acta Automatica Sinica*, 2000, 26(3): 378-381.)
- [21] Campi M C, Kumar P R. Learning dynamical systems in a stationary environment[J]. *Systems and Control Letters*, 1998, 34(3): 125-132.
- [22] Everitt B S. Cluster analysis[M]. New York: Halsted Press, 1993: 278-279.