

基于惯性因子自适应粒子群和模糊熵的图像分割*

张 伟^{1,2}, 隋青美¹

(1. 山东大学 控制科学与工程学院, 济南 250061; 2. 青岛科技大学 自动化与电子工程学院, 山东 青岛 266042)

摘要: 由于基本粒子群算法存在易陷入局部最优以及过早收敛的缺点,使得基于粒子群和模糊熵的图像分割算法难以得到理想的分割效果。针对此问题,提出了一种基于惯性因子自适应粒子群和模糊熵的图像分割算法,利用惯性因子自适应粒子群和高斯变异来搜索使模糊熵最大的参数值,得到模糊参数的最优组合,进而确定图像的分割阈值。通过与其他两种粒子群算法的分割结果进行比较,表明该算法取得了令人满意的分割结果,算法运算时间较小,具有很好的鲁棒性和自适应性。

关键词: 粒子群优化; 高斯变异; 模糊熵; 图像分割; 阈值分割

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 1001-3695(2010)04-1569-03

doi:10.3969/j.issn.1001-3695.2010.04.0104

Image segmentation based on inertia adaptive particle swarm optimization and fuzzy entropy

ZHANG Wei^{1,2}, SUI Qing-mei¹

(1. School of Control Science & Engineering, Shandong University, Jinan 250061, China; 2. School of Automation & Electronic Engineering, Qingdao University of Science & Technology, Qingdao Shandong 266042, China)

Abstract: Image segmentation algorithm based on particle swarm optimization (PSO) and fuzzy entropy can not have good performance because classic PSO easy to premature convergence. Focus on this shortcoming, this paper proposed a new segmentation algorithm based on inertia adaptive PSO and fuzzy entropy. Used the new algorithm inertia adaptive PSO and some particles Gaussian mutation to explore fuzzy parameters of maximum fuzzy entropy, and got the optimum fuzzy parameter combination, then obtained the segmentation threshold. According to experiment results of the new algorithm compare with other two algorithms, the new algorithm has the capability of good segmentation performance, low time cost, robust and self adaptive.

Key words: particle swarm optimization; Gaussian mutation; fuzzy entropy; image segmentation; threshold segmentation

0 引言

对图像进行有效的分割在图像分析、理解和目标识别中具有重要的意义。现有的图像分割方法大致可分为阈值法、边缘检测法、区域法、聚类法和结合特定理论的图像分割方法等,其中阈值法是最常用的方法。阈值法的关键是阈值的选取,其选取得是否合理直接关系到分割的质量和后续的图像处理。

目前,已有众多的阈值方法,如双峰法、迭代法、最大类间方差法等,但它们应用于不同的图像时,其自适应性不是很理想。近年来,模糊集合理论已成功应用于图像分割,并取得了较好效果。1983年,Pal等人^[1]引入图像灰度模糊数学描述,即通过计算图像的模糊熵来选取图像的分割阈值的方法。此后相关的研究相继提出,Murthy等人^[2,3]指出阈值不仅与隶属函数有关,还与隶属函数的分布有关。该方法通过计算图像的模糊熵、搜索使模糊熵最大时的参数值,以确定隶属函数的各参数,进而确定分割阈值,其模糊参数的寻优实际上是一个优化问题。解决优化问题的方法通常有穷举法、遗传算法、蚁群算法、粒子群算法等,其中粒子群优化算法由于其优越性已成为众多学者研究的热点^[4-8]。

普通粒子群优化算法存在易陷入局部最优以及过早收敛的缺点,使得该算法难以得到理想的优化效果。近年来出现了不少改进的 PSO 算法,改进算法主要有对惯性因子的改进^[9-12]以及引入遗传算法中的交叉、变异或进化思想对部分粒子进行相应的操作^[13-16]。Li 等人^[15]提出的高斯变异的粒子群算法(GMPSO)取得了不错的分割效果,但该算法的分割精度还有待进一步提高。本文提出一种基于惯性因子自适应粒子群和模糊熵的图像分割算法,能取得令人满意的分割结果。

1 基本粒子群算法

粒子群优化算法(PSO)是一种进化计算技术,最早由 Kenney 等人于 1995 年提出的。经过短短十余年时间的的发展,PSO 已成功应用于多目标优化、人工神经网络训练、模糊系统控制、模式识别和图像处理等领域,成为目前进化计算研究的一个新热点。

设在 n 维解空间中,每个粒子 i 有一位置 $X_i(x_{i1}, x_{i2}, \dots, x_{in})$ 和速度 $V_i(v_{i1}, v_{i2}, \dots, v_{in})$,前者表示问题的解,对应的目标函数值作为评价该粒子优劣程度的适应度;后者表示粒子从当前位置移动到下一个位置的速度大小。每一个粒子所经历过

收稿日期: 2009-07-09; 修回日期: 2009-08-11 基金项目: 山东省自然科学基金资助项目(Z2006G06)

作者简介: 张伟(1975-),男,重庆人,讲师,博士研究生,主要研究方向为数字图像处理(zwqd2008@163.com);隋青美(1963-),女,教授,博导,主要研究方向为新型检测技术。

的具有最好适应值的位置称为个体最好位置,记为 $P_i(p_{i1}, p_{i2}, \dots, p_{im})$;种群中所有粒子所经历过的最好适应值位置称为全局最好位置,记为 $P_g(p_{g1}, p_{g2}, \dots, p_{gn})$ 。对 PSO 算法的每一次迭代,粒子通过动态跟踪 P_i 和 P_g 来更新自身的速度和位置。速度和位置的更新方程为

$$v_{ij}(t+1) = \omega v_{ij}(t) + c_1 \text{rand}() (p_{ij}(t) - x_{ij}(t)) + c_2 \text{rand}() (p_{gj}(t) - x_{ij}(t)) \quad (1)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (2)$$

其中: i 表示第 i 个粒子, j 表示粒子的第 j 维, t 表示第 t 次迭代, c_1, c_2 为加速常数,通常在 $0 \sim 2$ 间取值; $\text{rand}()$ 表示均匀分布在 $(0,1)$ 上的随机数, ω 为惯性因子。

2 惯性因子自适应粒子群算法

当粒子群中大多数粒子在连续的迭代中未找到最优值前停止更新时,就会出现过早收敛的现象。当惯性因子 ω 较小或固定时就会出现这种现象。从式(1)可以看出,当 $v_{ij}(t)$ 较小并且 $|p_{ij}(t) - x_{ij}(t)|$ 和 $|p_{gj}(t) - x_{ij}(t)|$ 很小时, $v_{ij}(t+1)$ 也很小,即相应的粒子失去搜索能力。这种情况通常会出现在当粒子本身是全局最优时,即 $|p_{ij}(t) - x_{ij}(t)|$ 和 $|p_{gj}(t) - x_{ij}(t)|$ 等于零时的迭代早期阶段,这样在以后的迭代中粒子就失去了多样性。为了解决这个问题,一般将 ω 设为 $\omega = \omega_{\max} - t \times (\omega_{\max} - \omega_{\min}) / t_{\max}$ 。其中: t_{\max} 表示总迭代次数; ω_{\max} 和 ω_{\min} 分别表示最大和最小惯性因子。

本文对上述方法进行了改进,根据粒子距离全局最优值之间的距离对 ω 进行调节,即

$$\omega = \omega_0 \times (1 - \text{dist}_i / \text{dist}_{\max}) \quad (3)$$

其中: $\omega_0 = \text{rand}(0.5, 1)$, dist_i 是当前粒子距离全局最优值之间的欧几里得距离,即

$$\text{dist}_i = \left[\sum_{j=1}^n (p_{gj} - x_{ij})^2 \right]^{1/2} \quad (4)$$

则 dist_{\max} 为最大 dist_i 距离。

这样对 ω 进行调节能保证粒子在偏离全局最优时,粒子和全局最优值之间的吸引力将保证粒子不会偏离最优值太远,从而有效避免出现过早收敛的现象。

3 基于惯性因子自适应粒子群和模糊熵的图像分割算法

3.1 图像的最大模糊熵

给定一幅灰度级为 L 的 $m \times n$ 的图像 Y ,令 $D = \{(i, j) : i=0, 1, \dots, m-1; j=0, 1, \dots, n-1\}$ 和 $G = \{0, 1, \dots, L-1\}$,定义 y_{ij} 为图像 Y 中 (i, j) 点的灰度值。令

$$D_k = \{(i, j) : y_{ij} = k, (i, j) \in D\}, k=0, 1, \dots, L-1$$

$$h_k = n_k / (m \times n) \quad (5)$$

其中: n_k 为 D_k 中元素的个数,则 $H = \{h_0, h_1, \dots, h_{L-1}\}$ 为图像的直方图,其概率分布为 $p_k = h_k, k=0, 1, \dots, L-1$ 。

根据模糊理论,图像 Y 可看成是一个模糊事件; $\mu_Y(y_{ij})$ 为该点属于某种特征的隶属度, $0 \leq \mu_Y(y_{ij}) \leq 1, 0 \leq i \leq m, 0 \leq j \leq n$ 。对于单阈值分割,设分割阈值 T 根据灰度值将原始图像的像素分成两个模糊集,即黑(dark)和亮(bright)两个集合。黑模糊集包含低灰度值的像素,对应图像的背景;亮模糊集包含

高灰度值的像素,对应图像的目标。这两个模糊集的隶属函数 $\mu_d(k), \mu_b(k)$ 可分别定义^[17]如下:

$$\mu_d(k) = \begin{cases} 1 & k \leq a \\ 1 - \frac{(k-a)^2}{(c-a) \times (b-a)} & a < k \leq b \\ \frac{(k-c)^2}{(c-a) \times (c-b)} & b < k \leq c \\ 0 & c < k \end{cases} \quad (6)$$

$$\mu_b(k) = \begin{cases} 0 & k \leq a \\ \frac{(k-a)^2}{(c-a) \times (b-a)} & a < k \leq b \\ 1 - \frac{(k-c)^2}{(c-a) \times (c-b)} & b < k \leq c \\ 1 & c < k \end{cases} \quad (7)$$

其中:参数 a, b, c 满足 $0 \leq a < b < c \leq 255, b = (a+c)/2$,则 $[a, c]$ 是模糊区间, $[0, a]$ 和 $[c, 255]$ 是非模糊区间。综合以上各式,可得这两个集合的模糊熵为

$$H_d = \sum_{k=0}^{255} \frac{p_k \times \mu_d(k)}{p_d} \ln \left(\frac{p_k \times \mu_d(k)}{p_d} \right) \quad (8)$$

$$H_b = \sum_{k=0}^{255} \frac{p_k \times \mu_b(k)}{p_b} \ln \left(\frac{p_k \times \mu_b(k)}{p_b} \right) \quad (9)$$

则模糊事件的总模糊熵为

$$H(a, c) = H_d + H_b \quad (10)$$

由信息论可知,一个事件的熵越大,所含有的信息量就越大。为了实现目标与背景的最佳分割,模糊事件的模糊熵应为最大。为此,可通过优化模糊参数 $(a_{\text{opt}}, c_{\text{opt}})$ 选择其最佳组合,使总模糊熵 $H(a, c)$ 达到最大值,据此确定最优阈值 T_{opt} 。最优阈值满足如下条件:

$$\mu_d(T_{\text{opt}}) = \mu_b(T_{\text{opt}}) = 0.5 \quad (11)$$

因此,最优阈值为

$$T_{\text{opt}} = b_{\text{opt}} = (a_{\text{opt}} + c_{\text{opt}}) / 2 \quad (12)$$

3.2 惯性因子自适应粒子群算法和最大模糊熵的图像分割算法

根据最大模糊熵原理,基于最大模糊熵的图像分割算法其本质是在图像的整个灰度空间上搜索一组参数 (a, c) 使图像的总模糊熵取最大值的优化问题。本文将基于惯性因子自适应粒子群和高斯变异的算法(IAPSO)用于搜索一组最优参数 (a, c) ,提高了算法的分割性能。

算法的基本步骤如下:

a)初始化。按下式初始化粒子群的位置矩阵 X 和速度矩阵 V ,设定粒子群规模 N 和维数 D (由于需寻优两个参数,因此 $D=2$),设定

$$x_{ij} = x_{\min} + (x_{\max} - x_{\min}) \times \text{rand}() \quad (13)$$

$$X = \begin{bmatrix} x_{11} & x_{12} \\ x_{21} & x_{22} \\ \vdots & \vdots \\ x_{N1} & x_{N2} \end{bmatrix} \quad (14)$$

$$v_{ij} = -v_{\max} + 2v_{\max} \times \text{rand}() \quad (15)$$

$$V = \begin{bmatrix} v_{11} & v_{12} \\ v_{21} & v_{22} \\ \vdots & \vdots \\ v_{N1} & v_{N2} \end{bmatrix} \quad (16)$$

其中,rand()是均匀分布在(0,1)上的随机数; v_{max} 是 v 的最大值; x_{max} 和 x_{min} 分别为 x 的最大值、最小值,一般取 $x_{max} = L_{max}$, $x_{min} = L_{min} + 1$, L_{max} 和 L_{min} 分别为图像的最大灰度、最小灰度。

b)选择 $H(a,c)$ (式(10))作为粒子群算法的适应度函数,计算粒子群中每个粒子的适应值,并根据适应值选择每个粒子的当前最好位置 P_i 和粒子群的全局最好位置 P_g 。

c)根据式(3)计算权重因子,再根据式(1)和(2)更新粒子的速度和位置。

d)根据下式对部分粒子进行高斯变异^[15]:

$$mut(x_{ij}(t)) = x_{ij}(t) \times (1 + gaussian(\sigma)) \quad (17)$$

e)若达到最大迭代次数,则算法结束,否则,转步骤 b)。

f)求出全局最优解 P_g 对应的参数组合 (a,c) ,计算分割阈值 T_{opt} 对图像进行分割。

4 仿真结果及分析

利用本文算法对不同类图像进行分割实验,并与其他算法的结果进行对比。实验中粒子群算法相关参数选择如下:粒子群规模 $N = 10$,维数 $D = 2$,最大迭代次数 $t_{max} = 50$,惯性因子 $\omega_{max} = 0.9$, $\omega_{min} = 0.4$,学习因子 $c_1 = c_2 = 1.4962$,高斯变异概率 $p_m = 0.5$ 。

实验中采用的图像分别为 Lena、rice 和真实煤尘图像,它们代表几种不同类型的图像。图 1 是它们的灰度直方图,其中 Lena 图像呈多峰模式;rice 图像为明显的双峰;煤尘图像为单峰模式。




图 1 实验图像直方图

用本文算法(IAPSO)、基本 PSO 算法和文献[15]的算法(GMP SO)对三种不同类型的图像进行了分割效果比较实验,实验效果如图 2 所示。其中, (a_i) 为原始图像; (b_i) 为基本 PSO 算法的分割结果; (c_i) 为文献[15]的分割结果; (d_i) 为本文算法的分割结果, $i = 1, 2, 3$ 。从图 2 的分割结果可以看出,本文提出算法的分割效果优于其他两种算法,特别是在对具有多峰值特性的 Lena 图像和具有单峰特性的煤尘图像,本文的优势非常明显。




图 2 实验结果比较图

表 1 列出了不同算法的分割阈值、运算时间(s)以及广泛使

用的 Sahoo 等人^[18]提出的无差异测量。其数据是在 Pentium Dual E2200 2.0 GHz CPU、1 GB RAM 的 PC 机以及 MATLAB 7.0 软件环境下得到的。无差异测量定义为

$$u = 1 - 2 \times c \times \frac{\sum_{j=0}^c \sum_{i \in R_j} (y_i - \mu_j)^2}{m \times n \times (L_{max} - L_{min})^2} \quad (18)$$

其中: c 为阈值数量; R_j 为 j 阶分割区域; y_i 为像素 i 的灰度值; μ_j 为 j 阶分割区域灰度平均值; $m \times n$ 为图像总的像素点; L_{max} 和 L_{min} 为图像的最大、最小灰度值。 $u \in [0, 1]$, u 越接近于 1 说明分割效果越好。

表 1 本文算法与其他算法进行图像分割性能比较

| 图像 | 算法 | 阈值 | 时间 | 无差异测量 |
|-----------|--------|-----------|-------|---------|
| Lena | PSO | 134.610 5 | 0.075 | 0.976 4 |
| | GMP SO | 130.851 7 | 0.078 | 0.977 3 |
| 256 × 256 | IAPSO | 123.672 8 | 0.096 | 0.985 3 |
| | PSO | 102.192 7 | 0.078 | 0.984 5 |
| rice | GMP SO | 102.323 7 | 0.078 | 0.984 5 |
| | IAPSO | 107.063 1 | 0.088 | 0.985 7 |
| coal dust | PSO | 110.409 8 | 0.098 | 0.967 0 |
| | GMP SO | 108.313 5 | 0.125 | 0.978 2 |
| 512 × 512 | IAPSO | 105.421 1 | 0.146 | 0.998 2 |

从表 1 看出,本文提出的 IAPSO 分割算法在阈值和分割性能指标上具有明显的优势,同时运算时间也有所增加,但总体来说运算时间不长,运算时间最长也在 150 ms 之内。

5 结束语

针对基本粒子群算法存在易陷入局部最优以及过早收敛的问题,提出了一种基于惯性因子自适应粒子群和最大模糊熵的图像分割算法。用惯性因子自适应粒子群搜索使模糊熵最大时的参数值,并对部分粒子进行高斯变异操作,得到模糊参数的最优组合,进而确定图像的分割阈值。与基本粒子群分割算法和高斯变异粒子群分割算法的比较实验结果充分表明,该算法对不同类型的图像均能取得较好的分割结果。


参考文献:

- [1] PAL S K, KING R A, HASHIM A A. Automatic graylevel thresholding through index of fuzziness and entropy[J]. Pattern Recognition Letter, 1983, 1(3): 141-146.
- [2] MURTHY C A, PAL S K. Histogram thresholding by minimizing graylevel fuzziness[J]. Information Sciences, 1992, 60(1-2): 107-135.
- [3] MURTHY C A, PAL S K. Bound for membership function: a correlation-based approach[J]. Information Sciences, 1992, 65(1-2): 143-171.
- [4] ZHAO Bo, GUO Chuang-xin, CAO Yi-jia. A multiagent-based particle swarm optimization approach for optimal reactive power dispatch[J]. IEEE Trans on Power Systems, 2005, 20(2): 1070-1078.
- [5] TING T O, RAO M V C, LOO C K. A novel approach for unit commitment problem via an effective hybrid particle swarm optimization[J]. IEEE Trans on Power Systems, 2006, 21(1): 411-418.
- [6] LEANDRO D, SANTOS C, BRUNO M H. Fuzzy identification based on a chaotic particle swarm optimization approach applied to a nonlinear yo-yo motion system[J]. IEEE Industrial Electronics, 2007, 54(6): 3234-3245.
- [7] WU Jie-kang, ZHU Jian-quan, CHEN Guo-tong, et al. A hybrid method for optimal scheduling of short-term electric power generation of cascaded hydroelectric plants based on particle swarm optimization and chance-constrained programming[J]. IEEE Trans on Power Systems, 2008, 23(4): 1570-1579. (下转第 1587 页)

的选择问题,但是当选取一个更合适的 ρ 值时,能够获得更好的分类性能。

从表中还可以看出,基于分类图的提升图嵌入模型获得了最优的分类结果。由于三种提升图嵌入模型的惟一区别就在于近邻图的加权方法,因此可以认为是由于分类图能够提供更多的分类信息给图嵌入模型,而基于欧氏距离和全为1的加权方法并不适合于人脸表情识别这个分类问题。这个实验结果与构造分类图的目标是相吻合的。由于在所有的图嵌入模型中都需要构建加权近邻图,分类图对于LPP以外其他的图嵌入模型都是有效的。图2更加清楚地显示了分类图的优势,基本上在整个提升迭代过程中,B-LPP-3都要优于其他两种模型。

图2是实验1在 $\rho = 1/3$ 时的提升过程。从图中可以看出,虽然提出的方法在绝大多数时间优于LDA,但是什么时候停止迭代以达到最优解或者避免过拟合是很难决定的。过拟合的现象可以在测试4和6中看到,随着迭代次数增加,分类错误个数也在增加,最后甚至超过了LDA方法。如何避免此类现象是以后需要研究的一个问题。



注: X轴是迭代次数, Y轴是错误分类个数。结果包括LDA, B-LPP-1, B-LPP-2和B-LPP-3。

图2 实验1中当 $\rho = 1/3$ 时的10次提升过程

4 结束语

图嵌入模型作为一种更泛化的特征提取技术,受到越来越多的关注。本文将图嵌入模型和提升算法结合起来,提出了提升图嵌入框架。此外,本文还提出了一种新的近邻图加权方法——分类图,它使用分类错误信息来构建,因此能够向提升图嵌入框架提供更多的分类信息。为了验证本文算法的有效性,在Cohn-

Kanade facial expression database 上进行测试,并将其与LDA、LPP、boosting-LPP-1、boosting-LPP-2作了比较,结果表明所有采用提升算法的图嵌入模型都要优于LDA和LPP,并且采用分类图的提升图嵌入模型具有最优的分类性能。

参考文献:

- [1] BISHOP C M, SVENSEN M, WILLIAMS I. GTM: The generative topographic mapping [J]. *Neural Computation*, 1998, 10(1): 215-234.
- [2] TENENBAUM J B, De SILVA E, LANGFORD J C. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, 290(5552): 2319-2323.
- [3] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, 290(5550): 2323-2326.
- [4] LU Ju-wei, PLATANIOTIS K N, VENETSANOPOULOS A N, et al. Ensemble-based discriminant learning with boosting for face recognition [J]. *IEEE Trans on Neural Networks*, 2006, 17(1): 166-178.
- [5] HE Xiao-fei, NIYOI P. Locality preserving projections [M]. Cambridge: MIT Press, 2003.
- [6] FREUND Y, SCHAPIRE R E. A decision-theoretic generalization of on-line learning and an application to boosting [J]. *Journal of Computer System and Sciences*, 1997, 55(1): 119-139.
- [7] AMORES J, SEBE N, RADEVA P. Boosting the distance estimation application to the K-nearest neighbor classifier [J]. *Pattern Recognition Letters*, 2006, 27(3): 201-209.
- [8] SKURICHINA M, DUIN R P W. Bagging, boosting and the random subspace method for linear classifiers [J]. *Pattern Analysis & Applications*, 2002, 5(2): 121-135.
- [9] CHANG Ya, HU Chang-bo, TURK M. Manifold of facial expression [C] // Proc of IEEE International Workshop on Analysis and Modeling of Faces and Gestures. 2003: 28-35.
- [10] LIANG Dong, YANG Jie, ZHENG Zhong-long, et al. A facial expression recognition system based on supervised locally linear embedding [J]. *Pattern Recognition Letters*, 2005, 26(15): 2374-2389.
- [11] HE Xiao-fei, YAN Shui-cheng, HU Yu-xiao, et al. Face recognition using laplacianfaces [J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2005, 27(3): 328-340.
- [12] NATSUKI H, HITOSHI I. Particle swarm optimization with Gaussian mutation [C] // Proc of IEEE Swarm Intelligence Symposium. 2003: 72-79.
- [13] CHEN P H. Pumped-storage scheduling using evolutionary particle swarm optimization [J]. *IEEE Trans on Energy Conversion*, 2008, 23(1): 294-301.
- [14] LI Lin-yi, LI De-ren. Fuzzy entropy image segmentation based on particle swarm optimization [J]. *Progress in Natural Science*, 2008, 18(9): 1167-1171.
- [15] LING S H, LU H H C, CHAN K Y, et al. Hybrid particle swarm optimization with wavelet mutation and its industrial applications [J]. *IEEE Trans on Systems, Man, Cybernetics, Part C: Application and Reviews*, 2008, 38(3): 743-763.
- [16] TAO Wen-bing, TIAN Jin-wen, LIU Jian. Image segmentation by three-level thresholding based on maximum fuzzy entropy and genetic algorithm [J]. *Pattern Recognition Letters*, 2003, 24(16): 3069-3078.
- [17] SAHOO P K, SOLTANI S, WONG A K C, et al. A survey of thresholding techniques [J]. *Computer Vision Graphics Image Processing*, 1998, 41(2): 233-260.

(上接第1571页)

- [8] LIN C H, CHEN Cheng-hung, LIN C T. A hybrid of cooperative particle swarm optimization and cultural algorithm for neural fuzzy networks and its prediction applications [J]. *IEEE Trans on Systems, Man, Cybernetics, Part C: Application and Reviews*, 2009, 39(1): 55-68.
- [9] YANG Xue-ming, YUAN Jin-sha, YUAN Jiang-ye, et al. A modified particle swarm optimizer with dynamic adaptation [J]. *Applied Mathematics and Computation*, 2007, 189(2): 1205-1213.
- [10] TRIPATHI P K, BANDYOPADHYAY S, PAL S K. Multi-objective particle swarm optimization with time variant inertia and acceleration coefficients [J]. *Information Sciences*, 2007, 177(22): 5033-5049.
- [11] ARUMUGAM M S, RAO M V C. On the improved performances of the particle swarm optimization algorithms with adaptive parameters, cross-over operators and root mean square (RMS) variants for computing optimal control of a class of hybrid systems [J]. *Applied Soft Computing*, 2008, 8(1): 324-336.
- [12] JIAO Bin, LIAN Zhi-gang, GU Xing-sheng. A dynamic inertia weight particle swarm optimization algorithm [J]. *Chaos, Solitons and Fractals*, 2008, 37(3): 698-705.