

文章编号:1001-0920(2011)02-0276-04

基于改进粒子群优化的模糊熵煤尘图像分割

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: 针对基本粒子群算法易陷入局部最优和过早收敛的缺陷, 提出权重因子自适应的粒子群算法, 并对部分粒子进行 Morlet 变异操作, 由此得到改进粒子群优化算法. 将该算法和模糊熵相结合并用于图像分割, 利用改进粒子群优化算法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, 该算法取得了令人满意的分割结果, 且算法运算时间较小, 满足煤尘浓度实时精确测量的要求.

关键词: 粒子群; Morlet 变异; 权重因子自适应; 模糊熵; 图像分割

中图分类号: TP 391.41

文献标识码: A

Coal dust image segmentation based on improved particle swarm optimization and fuzzy entropy

ZHANG Wei^{1,2}, SUI Qing-mei¹

(1. School of Control Science and Engineering, Shandong University, Ji'nan 250061, China; 2. School of Automation and Electronic Engineering, Qingdao University of Science and Technology, Qingdao 266042, China. Correspondent: ZHANG Wei, E-mail: zwqd2008@163.com)

Abstract: Basic particle swarm optimization(PSO) can not get good optimization performance, because it is easy to get stuck into local optima. Therefore, an algorithm named improved PSO which combines proposed inertia adaptive PSO with partial particles Morlet mutation is proposed. The proposed algorithm and fuzzy entropy are applied to image segmentation, and improved PSO is used to explore fuzzy parameters of maximum fuzzy entropy, which gets the optimum fuzzy parameter combination, then obtains the segmentation threshold. By comparing the proposed algorithm with other two algorithms, the experiment results show that the proposed algorithm has the capability of good segmentation performance and low time cost, which can be use to real time and precision measure coal dust image.

Key words: particle swarm optimization; Morlet mutation; inertia adaptive; fuzzy entropy; image segmentation

1 引 言

对煤尘图像进行有效的分割是煤尘浓度测量的重要研究内容之一, 在煤尘图像分析和识别中具有重要意义. 阈值法是最常用的图像分割方法, 其关键是阈值的选取, 用图像灰度模糊熵来确定分割阈值是一种有效的阈值确定方法^[1]. 图像灰度模糊熵中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 Kennedy 和 Eberhart^[2-6]提出的粒子群优化算法(PSO)因其优越性而成为研究的热点.

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^[7-10], 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^[11-14]. Li 等人^[15]提出的高斯变异粒子群(GMPSO)算法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. 本文在此基础上, 提出一种综合 Morlet 变异和惯性因子自适应的改进粒子群优化算法, 让该算法和模糊熵结合应用于图像分割, 利用改进粒子群优化(IPSO)算法来搜索, 使模糊熵最大时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. 实验结果表明, 该算法取得了令

收稿日期: 2009-12-04; 修回日期: 2010-01-13.

基金项目: 山东省自然科学基金项目(Z2006G06).

作者简介: 张伟(1975—), 男, 讲师, 博士生, 从事数字图像处理的研究; 隋青美(1963—), 女, 教授, 博士生导师, 从事检测理论及应用等研究.

人满意的分割结果, 算法运算时间较小, 能满足对煤尘浓度实时精确测量的要求。

2 基本粒子群算法

粒子群优化 (PSO) 算法是一种进化计算技术, 最早由 Kenney 和 Eberhart 于 1995 年提出的。源于对鸟群捕食行为研究的 PSO 算法同遗传算法类似, 是一种基于迭代的优化工具。在 PSO 算法中, 每个个体称为粒子, 所有的粒子都有一个由被优化的函数决定的适应值, 每个粒子还有一个速度决定他们飞翔的方向和距离, 然后粒子就追随当前的最优粒子在解空间搜索。假定粒子规模为 N , 搜索空间为 M 维, 则第 i 个粒子的位置表示为 $X_i(x_{i1}, x_{i2}, \dots, x_{iM})$, 第 i 个粒子的速度表示为 $V_i(v_{i1}, v_{i2}, \dots, v_{iM})$, 每个粒子具有最好适应值的位置称为个体最好位置, 记为 $P_i(p_{i1}, p_{i2}, \dots, p_{iM})$, 整个种群中的最好适应值位置称为全局最好位置, 记为 $P_g(p_{g1}, p_{g2}, \dots, p_{gM})$ 。在找到这两个最优值时, 每个粒子根据如下公式来更新自己的速度和位置:

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

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

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; $\text{rand}()$ 为均匀分布在 $(0, 1)$ 上的随机数; ω 为惯性因子。

3 改进粒子群优化算法

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, 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。本文针对惯性因子的改进提出了惯性因子自适应算法, 同时引入了 Morlet 变异操作, 克服了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。

3.1 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 较小或固定时也会出现这种现象, 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。为了解决该问题, 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。

本文对上述方法作了改进, 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 为当前粒子距离全局最优值之间的欧几里得距离, 即

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

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, 从而避免出现过早收敛的现象。

3.2 Morlet 变异

为了克服过早收敛, 还有一种方法就是引入遗传算法中的变异操作, 即用基本 PSO 算法对粒子的位置和速度进行更新后, 再对部分粒子进行变异操作, 使得粒子种群呈现多样性。一般可用均匀变异或非均匀变异来进行变异操作, Natsuki^[11] 引入了高斯变异操作, 有

$$\text{mut}(x_{ij}(t)) = x_{ij}(t) \times (1 + \text{gaussian}(\sigma)). \quad (5)$$

其中: $\text{mut}(x_{ij}(t))$ 为高斯变异后的位置; $\text{gaussian}(\sigma)$ 为 σ 的高斯分布, $\sigma \in [0, 1]$ 。

Natsuki 指出可以对粒子以一定概率进行高斯变异, 也可以当粒子的位置停止更新时进行高斯变异。

本文中的 Morlet 变异能对粒子起到微调的作用, 每个粒子变异的概率为 $p_m \in [0, 1]$, p_m 的大小根据粒子群的维数决定。Morlet 变异的方程式如下:

$$\text{mut}(x_{ij}(t)) = \begin{cases} x_{ij}(t) + \sigma \times (x_{\max} - x_{ij}(t)), & \sigma > 0; \\ x_{ij}(t) + \sigma \times (x_{ij}(t) - x_{\min}), & \sigma \leq 0. \end{cases} \quad (6)$$

其中: $\text{mut}(x_{ij}(t))$ 为变异后的 $x_{ij}(t)$, x_{\max} 和 x_{\min} 分别为 x 的最大最小值, σ 的计算公式如下:

$$\sigma = \frac{1}{\sqrt{a}} e^{-(\phi/a)^2/2} \cos(5(\phi/a)). \quad (7)$$

其中: $\phi \in [-2.5a, 2.5a]$,

$$a = e^{-\ln(g)(1-t/t_{\max})^{\xi_{wm} + \ln(g)}}. \quad (8)$$

这里: ξ_{wm} 为上式单调递增方程的形状参数, g 为 a 的上限值, t 为当前迭代次数, t_{\max} 为最大迭代次数。

4 改进粒子群优化的模糊熵图像分割算法

4.1 图像的最大模糊熵

根据模糊理论, $m \times n$ 图像可看成是一个模糊事

件. 根据模糊熵理论, 若分割阈值 T 将原始图像的像素分成黑和亮两个模糊集, 则这两个集合的隶属函数 $\mu_d(k)$, $\mu_b(k)$ 和模糊熵分别为

$$\mu_d(k) = \begin{cases} 1, & k \leq a; \\ 1 - \frac{(k-a)^2}{(c-a) \times (b-a)}, & a < k \leq b; \\ \frac{(k-c)^2}{(c-a) \times (c-b)}, & b < k \leq c; \\ 0, & c < k. \end{cases} \quad (9)$$

$$\mu_b(k) = \begin{cases} 0, & k \leq a; \\ \frac{(k-a)^2}{(c-a) \times (b-a)}, & a < k \leq b; \\ 1 - \frac{(k-c)^2}{(c-a) \times (c-b)}, & b < k \leq c; \\ 1, & c < k. \end{cases} \quad (10)$$

$$H_d = \sum_{k=0}^{255} \frac{p_k \mu_d(k)}{p_d} \ln \left(\frac{p_k \mu_d(k)}{p_d} \right). \quad (11)$$

$$H_b = \sum_{k=0}^{255} \frac{p_k \mu_b(k)}{p_b} \ln \left(\frac{p_k \mu_b(k)}{p_b} \right). \quad (12)$$

其中: 参数 a, b, c 满足 $0 \leq a < b < c \leq 255$, $b = (a + c)/2$; $p_k = n_k/(m \times n)$, 这里 n_k 为 D_K 中元素的个数. 模糊事件的总模糊熵为

$$H(a, c) = H_d + H_b. \quad (13)$$

由熵理论可知, 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, 即得到使总模糊熵 $H(a, c)$ 达到最大值时对应 $(a_{\text{opt}}, c_{\text{opt}})$, 并据此确定最优阈值

$$T_{\text{opt}} = b_{\text{opt}} = (a_{\text{opt}} + c_{\text{opt}})/2. \quad (14)$$

4.2 改进粒子群优化的模糊熵图像分割算法

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. 本文将改进粒子群优化 (IPSO) 算法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:

Step 1: 初始化. 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 2 个参数, $D = 2$), 设定

$$x_{ij} = x_{\min} + (x_{\max} - x_{\min}) \times \text{rand}(), \quad (15)$$

$$X = \begin{pmatrix} x_{11} & x_{12} \\ x_{21} & x_{22} \\ \vdots & \vdots \\ x_{N1} & x_{N2} \end{pmatrix}, \quad (16)$$

$$v_{ij} = -v_{\max} + 2v_{\max} \times \text{rand}(), \quad (17)$$

$$V = \begin{pmatrix} v_{11} & v_{12} \\ v_{21} & v_{22} \\ \vdots & \vdots \\ v_{N1} & v_{N2} \end{pmatrix}. \quad (18)$$

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

Step 2: 选择式 (13) 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 .

Step 3: 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.

Step 4: 根据式 (6) 以一定概率对部分粒子进行 Morlet 变异.

Step 5: 若达到最大迭代次数, 则算法结束; 否则, 转 Step 2.

Step 6: 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.

5 实验结果及分析

利用本文算法对不同类型图像进行分割实验, 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 $t_{\max} = 50$, 普通 PSO 算法中的惯性因子 $\omega_{\max} = 0.9$, $\omega_{\min} = 0.4$, 学习因子 $c_1 = c_2 = 1.4962$. Morlet 变异参数为: 随即抽取 50% 的粒子进行变异操作, 即变异概率 $P_m = 0.5$, $g = 1000$, $\xi_{wm} = 2$.

实验中采用的图像分别为 Lena, Boat 和 3 幅真实煤尘图像, 它们代表几种不同类型的图像. 图 1 为

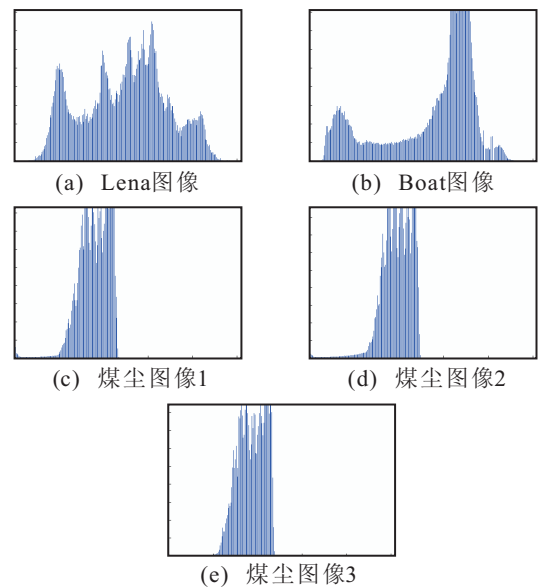


图 1 实验图像直方图

它们的灰度直方图, Lena 图像呈多峰模式; Boat 图像为明显的双峰; 3 幅煤尘图像为单峰模式.

利用本文 (IPSO) 算法和基本 PSO 算法, 文献[15] 的 (GMPSO) 算法对 3 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. 图 2 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, $i = 1, 2, \dots, 5$. 由图 2 的分割结果可以看出, 本文算法的分割效果优于其他两种算法, 特别是在对具有单峰特性的 3 幅煤尘图像, 本文算法的优势非常明显.

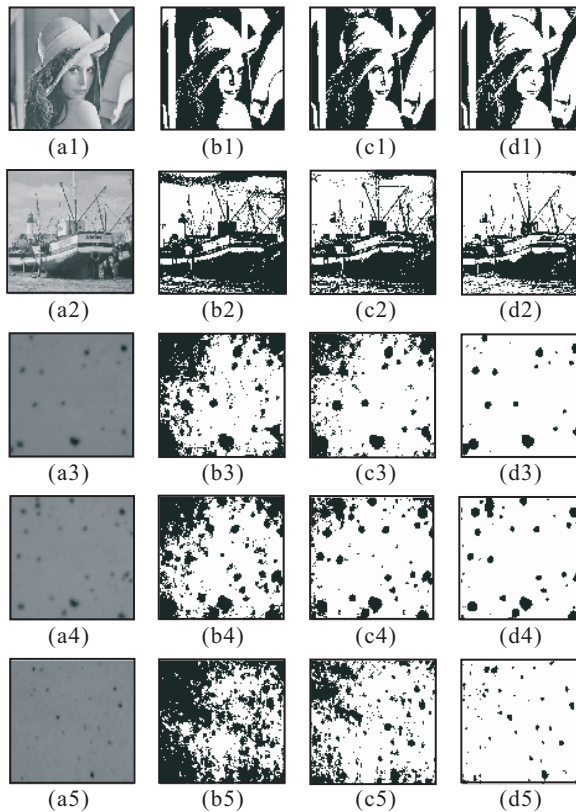


图 2 实验结果比较图

表 1 列出了不同算法的分割阈值、运算时间以及广泛使用的无差异测量^[16]. 其数据是在 Pentium Dual E2200 2.0 GHz CPU, 1G 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

$$u = 1 - 2 \times c \times \frac{\sum_{j=0}^c \sum_{i \in R_j} (y_i - \mu_j)^2}{m \times n \times (L_{\max} - L_{\min})^2}. \quad (19)$$

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.

由表 1 可以看出, 本文提出的 IPSO 分割算法在阈值和分割性能指标上具有明显的优势, 同时运算时间也相应增加, 但运算时间最大也在 250 ms 之内, 完全能满足实时精确分割的要求, 为煤尘浓度的实时精确测量打下了坚实的基础.

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/s	UM
Lena 256×256	PSO	134.6105	0.075	0.9764
	GMPSO	130.8517	0.078	0.9773
	IPSO	121.7496	0.194	0.9787
Boat 512×512	PSO	160.0200	0.078	0.9577
	GMPSO	156.8155	0.094	0.9647
	IPSO	144.6209	0.109	0.9752
Coal dust 1 512×512	PSO	110.4098	0.098	0.9670
	GMPSO	108.3135	0.125	0.9782
	IPSO	102.5000	0.235	0.9989
Coal dust 2 512×512	PSO	117.8226	0.101	0.9680
	GMPSO	115.0620	0.132	0.9784
	IPSO	111.9050	0.234	0.9989
Coal dust 3 512×512	PSO	114.0127	0.110	0.9662
	GMPSO	111.0235	0.125	0.9783
	IPSO	106.0174	0.242	0.9984

6 结 论

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, 提出了一种基于改进粒子群优化的模糊熵图像分割算法, 用惯性因子自适应粒子群来搜索使模糊熵最大时的参数值, 并对部分粒子进行 Morlet 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. 实验结果充分地表明, 该算法对不同类型的图像均能取得较好的分割结果, 且计算量较小, 稍加改进即可在 DSP 等硬件上实现, 因此能满足对煤尘浓度实时测量的要求.

参考文献(References)

- [1] Murthy C A, Pal S K. Histogram thresholding by minimizing graylevel fuzziness[J]. Information Sciences, 1992, 60(2): 107-135.
- [2] Zhao B, Guo C X, Cao Y J. A multiagent-based particle swarm optimization approach for optimal reactive power dispatch[J]. IEEE Trans Power System, 2005, 20(2): 1070-1078.
- [3] 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 Power System, 2006, 21(1): 411-418.
- [4] Leandro dos, Santos Coelho, Bruno M H. Fuzzy identification based on a chaotic particle swarm optimization approach applied to a nonlinear yo-yo motion system[J]. IEEE Trans Industrial Electronics, 2007, 54(6): 3234-3245.
- [5] Wu Jiekang, Zhu Jianquan, Chen Guotong, 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 284 页)