

◎图形、图像、模式识别◎

基于改进 PSO 算法的最大熵阈值图像分割

付阿利¹,雷秀娟^{1,2}FU A-li¹,LEI Xiu-juan^{1,2}

1.陕西师范大学 计算机科学学院,西安 710062

2.西北工业大学 自动化学院,西安 710072

1.College of Computer Science,Shaanxi Normal University,Xi'an 710062,China

2.College of Automation,Northwestern Polytechnical University,Xi'an 710072,China

E-mail:fuali121@163.com

FU A-li,LEI Xiu-juan.Maximum-entropy thresholding image segmentation method based on improved PSO algorithm. *Computer Engineering and Applications*,2008,44(29):174-176.

Abstract: Image segmentation is a key part in image processing field.At present,there are several image segmentation methods, among which the thresholding method has predominant advantages.But the key of the thresholding method is to find the optimum entropy threshold of an image effectively.To solve the problem,the location updating equation of the Geese-LDW-PSO algorithm has improved that the present position of all particles is replaced by the global best value of the population.And the improved algorithm is applied into entropy thresholding image segmentation method.The simulation results show that this algorithm can obtain the optimum threshold value of an image rapidly and stably and has good performance in the segmentation of a vehicle brand image.

Key words: particle swarm optimization;wild geese;linear descend inertia weight(LDW);Histogram;entropy

摘要:图像分割是目标识别的首要 and 关键步骤。目前的图像分割方法有多种,其中阈值方法优点比较突出,但是采用阈值方法分割的关键是要能高效率地找到被分图像的最佳熵阈值。针对这一问题,将 Geese-LDW-PSO 算法的位置更新公式作了改进,即用当前种群的全局极值取代所有粒子的当前位置,并将之用于熵阈值图像分割中。仿真实验表明,该算法可以快速稳定地获得一幅图像的最佳分割阈值。仿真结果显示,该方法对车牌分割具有较好的性能。

关键词:粒子群优化;雁群;线性递减惯性权重;直方图;熵

DOI:10.3778/j.issn.1002-8331.2008.29.049 **文章编号:**1002-8331(2008)29-0174-03 **文献标识码:**A **中图分类号:**TP391.41

1 引言

图像分割是图像处理和前期视觉中的基本技术,是大多数图像分析和视觉系统的重要组成部分。其目的是将目标和背景分离,为后续的分类、识别和检索提供依据。图像分割应用一种或多种运算将图像分成一些具有类似特性(如颜色、纹理、密度等)的区域。主要的分割方法有阈值方法、边缘检测法、区域跟踪法等。其中,阈值方法因其简单且性能稳定而成为图像分割中的基本方法之一。目前,阈值分割方法已有很多种,例如直方图阈值分割、类间方差阈值分割、最大熵阈值分割等。其中,最大熵阈值分割方法不需要先验知识,而且对于具有非理想双峰直方图的图像也可以进行分割,但是在确定阈值时,尤其是确定基于二维直方图的阈值时,其计算量很大。所以如何快速有效地选取最优阈值是基于阈值方法图像分割技术的一个关键。

基于雁群启示的线性递减惯性权重粒子群优化算法(Geese-LDW-PSO)^[1]是根据雁群飞行的特征对基本粒子群优化算法全局极值作了改进的一种改进的粒子群算法。其优点在于将基本粒子群中的全局极值变为排序后每个粒子前面那个较优粒子的个体极值,所有粒子不止向一个方向飞去,避免了粒子趋向于同一化,保持了粒子的多样性,扩大了搜索范围。

本文对基于雁群启示的线性递减惯性权重粒子群优化算法作了改进,并将其和最大熵阈值法结合起来用于图像分割中,取得了较好的效果。

2 基于雁群启示线性递减惯性权重的改进粒子群优化算法

在自然界中,雁群以“人”字或“一”字形飞行,这种方式使

基金项目:教育部科学技术研究重点项目(No.107106);教育部高等学校科技创新工程重大项目培育基金项目。

作者简介:付阿利(1980-),女,硕士研究生,研究方向为图像处理、智能优化;雷秀娟(1975-),女,博士,副教授,硕士生导师,博士后,研究方向为智能计算、粒子群优化。

收稿日期:2008-04-14 **修回日期:**2008-07-03

其飞行非常高效。雁群飞行时, 头雁扇动双翼产生尾涡, 其后尾随的同伴借力飞行, 所以头雁最为辛苦, 雁群以最强壮的大雁作为头雁, 其他大雁依次向后排。

2.1 基本粒子群优化算法(PSO)

PSO 算法^[2]最初是为了图形化地模拟鸟群优美而不可预测的运动。人们通过对动物社会行为的观察, 发现在群体中对信息的社会共享有利于在演化中获得优势, 并以此作为开发 PSO 算法的基础。在此基础上, 通过加入近邻的速度匹配, 消除不必要的变量, 并考虑多维搜索以及根据距离的加速, 即每个粒子都有一个由被优化函数决定的适应值 (fitness value), 还有一个速度决定他们飞翔的方向和距离, 粒子们追随当前的最优粒子在解空间中搜索, 形成了 PSO 的最初版本。之后, Eberhart 和 Shi 提出了对基本粒子群算法的改进^[3], 即对速度更新方程加惯性权重 w , 得到了标准粒子群优化算法的速度和位置更新公式:

$$v_{id}^{k+1} = wv_{id}^k + c_1 r_1 (pbest_{id}^k - x_{id}^k) + c_2 r_2 (gbest^k - x_{id}^k) \quad (1)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (2)$$

其解决优化问题的基本思路是: PSO 初始化为一群随机粒子, 然后通过迭代找到最优解。在每一次迭代中, 粒子通过跟踪两个“极值”来更新自己。第一个就是粒子本身所找到的最优解。这个解叫做个体极值 $pBest$ 。另一个极值是整个种群目前找到的最优解。这个极值是全局极值 $gBest$ 。

2.2 基于雁群启示线性递减惯性权重的改进粒子群优化算法

借鉴雁群的飞行启示, 可以视大雁的强壮程度为粒子的优劣程度, 即粒子的历史最优适应值的好坏, 因此将所有粒子按历史最优适应值排序, 选出历史最优适应值最好的粒子作为头雁, 其他依次向后排。

大雁按照历史最优适应值的好坏从前到后排队, 后面每只大雁都只跟随其前面那只较优大雁飞行, 也就是说, 将其前面那只大雁的个体极值作为自己的全局极值, 即以 $P_{(i-1)d}$ 取代 P_{gd} , 而头雁为领头雁, 其全局极值仍然为其自身的个体极值。这就是根据雁群飞行的特征对 PSO 全局极值的改进^[4], 改进后的速度更新公式为:

$$v_{id}^{k+1} = v_{id}^k + c_1 r_1 (pbest_{id}^k - x_{id}^k) + c_2 r_2 (pbest_{(i-1)d}^k - x_{id}^k) \quad (3)$$

其中 $P_{(i-1)d}$ 为按历史最优适应值排序后的第 i 只大雁其前面的较好大雁 $i-1$ 的个体极值。这样, 所有粒子不止向一个方向飞去, 保持了粒子的多样性, 扩大了搜索范围, 但减弱粒子对全局极值的跟踪, 又存在算法不易收敛的缺点。

针对这一点, 对 Geese-LDW-PSO 算法的位置更新公式, 即式(2)作了改进, 每次在进行速度和位置更新时, 先作判断, 如果当前种群中所有粒子位置的适应度有一半以上都比种群的历史个体极值适应度好, 则按式(2)更新位置, 否则用当前种群的全局极值取代所有粒子当前的位置进行更新, 即用 $gbest_{id}^k$ 取代 x_{id}^k , 通过实验证明, 这样可以更有效的收敛到全局最优值。

3 最大熵阈值分割原理

将信息论中的 Shannon 熵概念用于图像分割, 其依据是使得图像中目标与背景分布的信息量最大^[5-8], 即通过测量图像灰度直方图的熵, 找出最佳阈值。

根据 Shannon 熵的概念, 对于灰度范围为 $\{0, 1, \dots, l-1\}$ 的图像, 其一维直方图的熵定义为:

$$H = - \sum_{i=0}^{l-1} p_i \ln p_i \quad (4)$$

其中 p_i 为第 i 个灰度出现的概率。在单阈值情况下, 设阈值 t 将图像划分为目标与背景两类, 令:

$$p_t = \sum_{i=0}^t p_i, \quad h_t = - \sum_{i=0}^t p_i \ln p_i \quad (5)$$

则目标和背景的熵分别 $H_0(t)$ 和 $H_B(t)$ 为:

$$H_0(t) = - \sum_{i=0}^t \frac{p_i}{p_t} \ln \frac{p_i}{p_t} = \ln p_t + \frac{h_t}{p_t} \quad (6)$$

$$H_B(t) = - \sum_{i=t+1}^{l-1} \frac{p_i}{1-p_t} \ln \frac{p_i}{1-p_t} = \ln(1-p_t) + \frac{H-h_t}{1-p_t} \quad (7)$$

图像的总熵 $H(t)$ 为 $H_0(t)$ 和 $H_B(t)$ 之和, 即:

$$H(t) = H_0(t) + H_B(t) = \ln p_t (1-p_t) + \frac{h_t}{p_t} + \frac{H-h_t}{1-p_t} \quad (8)$$

最佳阈值 t' 为使得图像的总熵取得最大值:

$$t' = \max_{0 \leq t \leq l-1} \{H(t)\} \quad (9)$$

在双阈值情况下, 设 t_1, t_2 是分割阈值, 且有 $t_1 < t_2$, 则图像的总熵为:

$$H(t_1, t_2) = \ln \left(\sum_{i=0}^{t_1} p_i \right) + \ln \left(\sum_{i=t_1+1}^{t_2} p_i \right) + \ln \left(\sum_{i=t_2+1}^{l-1} p_i \right) - \frac{\sum_{i=0}^{t_1} p_i \ln p_i}{\sum_{i=0}^{t_1} p_i} - \frac{\sum_{i=t_1+1}^{t_2} p_i \ln p_i}{\sum_{i=t_1+1}^{t_2} p_i} - \frac{\sum_{i=t_2+1}^{l-1} p_i \ln p_i}{\sum_{i=t_2+1}^{l-1} p_i} \quad (10)$$

最佳阈值 t'_1, t'_2 为使得总熵取得最大值:

$$H(t'_1, t'_2) = \max_{0 \leq t_1 < t_2 \leq l-1} \{H(t_1, t_2)\} \quad (11)$$

4 基于 Geese-LDW-PSO 算法的最佳熵阈值确定

4.1 算法流程

该优化算法的基本思想是: 在图像灰度空间上搜索参数, 使得目标函数式(9)(单阈值)或式(11)(双阈值)取得最大值的优化问题。

综合考虑最大熵分割原理和 Geese-LDW-PSO 算法的特点, 分别以熵函数式(9)和式(11), 作为评价粒子好坏的适应度函数, 通过迭代寻找最优解, 也就是寻找让图像灰度熵取得最大值的点, 基本流程如下:

(1) 初始化粒子群: 给定群体规模 M , 在相应的灰度空间中, 随机产生每个粒子的位置 X_i 和速度 V_i (对于单阈值, 群体的位置和速度是元素取值在 $0 \sim 255$ 之间的整数的含有 M 个元素的行向量, 对于双阈值, 群体的位置和速度是元素取值在 $0 \sim 255$ 之间的整数的 2 行 M 列的矩阵), X_i 同时也是开始时每个粒子的最优位置 p_i 。再以相应的适应度函数分别计算每个粒子的当前适应值 $f(X_i)$, 同时做为每个粒子开始时的历史最优适应值, 并把当前所有粒子中个体适应度最好的粒子的位置作为群体的全局最优适应值 (p_g)。

(2) 计算新的适应值: 用适应度函数(10)分别计算每个粒子的当前适应值。

(3) 更新个体极值和历史最优适应值: 对每个粒子的适应值进行评价, 即将第 i 个粒子的当前适应值 $f(X_i)$ 与该粒子个体

表1 原 Geese-LDW-PSO 算法 10 次实验结果(单阈值)

	1	2	3	4	5	6	7	8	9	10
阈值 $s't'$	147	147	147	147	147	147	147	147	147	147
适应值	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2
时间/s	0.062 5	0.062 5	0.062 5	0.062 5	0.078 1	0.046 9	0.046 9	0.062 5	0.046 9	0.062 5

表2 改进的 Geese-LDW-PSO 算法 10 次实验结果(单阈值)

	1	2	3	4	5	6	7	8	9	10
阈值 $s't'$	147	147	147	147	147	147	147	147	147	147
适应值	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2	8.278 2
时间/s	0.078 1	0.046 9	0.078 1	0.062 5	0.046 9	0.078 1	0.062 5	0.062 5	0.046 9	0.078 1

表3 原 Geese-LDW-PSO 算法 10 次实验结果(双阈值)

	1	2	3	4	5	6	7	8	9	10
阈值 $s't'$	210	154	154	154	212	215	211	211	211	211
适应值	11.404 7	11.410 6	11.410 6	11.410 2	11.410 4	11.408 7	11.410 6	11.410 6	11.410 6	11.410 6
时间/s	0.062 5	0.078 1	0.078 1	0.078 1	0.093 8	0.062 5	0.062 5	0.062 5	0.062 5	0.062 5

表4 改进的 Geese-LDW-PSO 算法 10 次实验结果(双阈值)

	1	2	3	4	5	6	7	8	9	10
阈值 $s't'$	211	154	154	154	154	154	211	211	211	211
适应值	11.410 6	11.410 6	11.410 6	11.410 6	11.410 6	11.410 6	11.410 6	11.410 6	11.410 6	11.410 6
时间/s	0.062 5	0.062 5	0.062 5	0.093 8	0.062 5	0.062 5	0.062 5	0.062 5	0.062 5	0.093 8

极值 p_i 的适应值(即该粒子的历史最优适应值)进行比较,若前者优,则更新 p_i 和历史最优适应值;否则保持 p_i 和历史最优适应值不变。

(4)粒子群排序:将所有粒子按历史最优适应值排序,选出历史最优适应值最好的粒子作为头雁,其他大雁依次向后排,整个种群所有粒子的历史最优适应值也要按照排列后的顺序进行更新。

(5)计算新的全局极值:头雁的全局极值保持不变,后面每只大雁均以其前面那只较优大雁的个体极值作为其全局极值。

(6)更新粒子的速度和位置:按照式(3)和式(2)分别更新粒子的速度和位置,在更新时,设一判断语句,对当前种群的适应度情况进行判断,如果当前群体中有超过一半粒子的当前适应度比种群的历史适应度差,则用 $gbest_{id}^k$ 取代 x_{id}^k 。

(7)检查是否满足中止条件,若满足,则退出,当前的全局极值就是要获取的最优阈值;否则,转至步骤(2)。

4.2 算法复杂度分析

(1)需要对 M 个粒子进行初始化,而且每个粒子又是 N 维,其时间复杂度即为 $O(MN)$;

(2)对 M 个粒子通过适应度函数计算适应值,而适应度函数的复杂度一般都是 $O(N)$,所以其时间复杂度为 $O(MN)$;

(3)对 M 个粒子更新个体极值,时间复杂度为 $O(M)$;

(4)将 M 个粒子进行排序,排序算法的最小时间复杂度为 $O(M \lg M)$;

(5)每个粒子以其前面那个较优粒子的个体极值作为其全局极值,时间复杂度为 $O(M)$;

(6)需要对每个粒子的每个维都更新速度和位置,因此其时间复杂度为 $O(MN)$;

(7)判断终止条件,为常数时间。

从以上分析可以看出,(2)~(7)步骤中的最大时间复杂度为 $O(\max(MN, M \lg M))$ 。假设算法的实际迭代次数为 T ,那么

该算法的时间复杂度为 $O(T \cdot \max(MN, M \lg M))$ 。同理,可以分析 PSO 算法的时间复杂度为 $O(TMN)$ 。当 $N > \lg M$ 时,该算法的时间复杂度和原始算法的时间复杂度相同;当 $M > 2^n$,该算法比原始算法时间复杂度高。因为 $M > 2^n$ 的情况比较少见,所以可以说,在大多数情况下,新算法并没有增加太多复杂度,基本和原算法复杂度相当。

5 实验结果与分析

实验中选取种群的规模 $M=10$,最大迭代次数为 50,所选图像的大小为 768×512 的灰度级图像(该灰度图像是通过用数码相机获得的真彩色图像转换而来)。用原 Geese-LDW-PSO 算法和本文改进的 Geese-LDW-PSO 算法分别对图像的单阈值和双阈值函数进行优化,做 10 次独立实验,得到的结果如表 1~表 4。

从表 1、表 2、表 3 和表 4 可以看出,对于单阈值,原 Geese-LDW-PSO 算法和本文改进后的 Geese-LDW-PSO 算法精确度和稳定性都比较好,且最终能够收敛到最优值,但是对于双阈值,经改进的 Geese-LDW-PSO 算法明显比原 Geese-LDW-PSO 算法更稳定,每次都能收敛到最优值。此外,不管是单阈值还是双阈值,每次实验消耗的时间均不超过 0.1 s,说明该算法能快速、有效、稳定地找到一幅图像的最佳熵阈值。

用实验得到的最佳熵阈值对原图像进行阈值分割,结果如图 1~图 3。

从图 2 和图 3 可以看到,以该算法得到的最佳熵阈值对车牌图像进行单阈值和双阈值分割,均能较好地识别出图像中车牌的信息。

6 结论

粒子群算法易于实现,算法中粒子的更新操作简单,是一种能够有效解决大多数全局优化问题的新方法。无论是从理论

(下转 187 页)