

基于改进自适应遗传算法的图像配准方法

李 伟¹, 杨绍清²

(1. 海军大连舰艇学院研究生1队, 辽宁 大连 116018; 2. 海军大连舰艇学院信息与通信工程系, 辽宁 大连 116018)

摘 要:采用遗传算法进行图像配准时,存在收敛速度慢、易早熟的问题,可能导致误配。为克服这些缺点,提出了改进的自适应遗传算法(improved adaptive genetic algorithm, IAGA)。该算法以互信息作为相似性测度,通过对遗传参数设置的改进,自适应的调节进化过程中的交叉概率和变异概率,既提高了遗传算法的收敛速度,又有效地防止了早熟。实验结果表明,改进算法具有更好的有效性和精确性。

关键词:图像配准;互信息;改进的自适应遗传算法

中图分类号:TP391.4 **文献标识码:**A

Image registration based on improved adaptive genetic algorithm

LI Wei¹, YANG Shao-qing²

(1. Postgraduate Team 1 of Dalian Naval Academy, Dalian 116018, China;
2. Dept. of Information and Communication Engineering, Dalian 116018, China)

Abstract: The usage of genetic algorithm in image registration has some shortcomings, such as slow convergence and premature, which will result in artifacts. To overcome these problems, an improved adaptive genetic algorithm (IAGA) was proposed. The algorithm regard mutual information as similarity measure, improve the setting of genetic parameter, adjust adaptively the probabilities of crossover and mutation during the evolutionary process. The convergence rate was accelerated and premature was avoided. Experimental results indicate that improved genetic algorithm can achieve better feasibility and accuracy.

Key words: image registration; mutual information; improved adaptive genetic algorithm

1 引 言

图像配准是指依据某一相似性测度来确定图像间的变换参数,使从不同传感器、不同视角、不同时间获取的同一场景两幅或多幅图像,变换到同一坐标系下,在像素层上得到最佳匹配的过程^[1]。在图像配准参数优化算法中,借鉴生物界自然选择和遗传机制的遗传算法是一种高效的随机搜索算法,由于具有鲁棒性和隐含并行性的特性使得它能够有效的进行全局搜索,从而可以克服局部极值,获得全局最优解^[2]。但由于遗传算法的随机性,其迭代收敛到最优解的时间可能很长,并且在迭代过程中容易出现未成熟收敛。为克服这些缺点,本文提出了一种基于改进的自适应遗传算法(improved adaptive

genetic algorithm, IAGA)的图像配准方法,利用互信息作为个体适应度评价函数(相似性测度),在编码、遗传参数的设置等方面做出改进,以提高配准的速度,克服早熟。

2 互信息测度

互信息是信息论的基本概念,用来测量一个随机变量包含另一个随机变量的信息量的总和或者是两个随机变量间的统计相关性,应用到图像配准中用来测量一幅图像包含另一幅图像的信息的

作者简介:李 伟(1978-),男,硕士研究生,主要研究方向是数字图像处理。E-mail: yjsyd013@163.com

收稿日期:2009-04-20

总量^[3]。

假设两组图像 A, B 为两个随机变量, 它们的灰度概率密度分布分别为 $P_A(a)$ 和 $P_B(b)$, 灰度联合概率分布为 $P_{AB}(a, b)$, 这些概率密度分布可通过图像的直方图和联合直方图来获得。

$$P_{AB}(a, b) = \frac{h(a, b)}{\sum_{a, b} h(a, b)} \quad (1)$$

$$P_A(a) = \sum_b P_{AB}(a, b) \quad (2)$$

$$P_B(b) = \sum_a P_{AB}(a, b) \quad (3)$$

其中, $h(a, b)$ 为 a, b 的联合直方图。

如果 A, B 独立不相关, 则有 $P_{AB}(a, b) = P_A(a)P_B(b)$ 。如果 A, B 完全相关, 则有 $P_A(a, b) = P_A(a) = P_B(b)$ 。互信息量就是用来衡量这两个随机变量 A, B 之间的相关性与独立不相关时的差距。在 Kullback-Leible 测度下, 互信息量 $I(A, B)$ 可表示为:

$$I(A, B) = \sum_{a, b} P_{AB}(a, b) \log \frac{P_{AB}(a, b)}{P_A(a)P_B(b)} \quad (4)$$

当两组图像的空间位置达到一致的时候, 也就是两幅图像处于配准位置的时候, 互信息达到最大值。因此基于互信息测度下的图像配准过程就是寻找最优变换 f 使得浮动图像 B 经过此变换后和参考图像 A 的互信息达到最大, 其关系可以表示为^[4]:

$$f = \arg \max_f I(A, f(B)) \quad (5)$$

3 标准遗传算法 (standard genetic algorithm, SGA) 搜索策略

图像配准是一个多参数最优化问题, 通过不断优化图像变换参数使相似性测度达到最优。遗传算法根据达尔文自然选择学说中的“适者生存, 优胜劣汰”的规律, 采用人工进化的方式对问题解进行优化搜索。应用标准遗传算法对实际问题最优解进行搜索时, 需要完成四个方面的准备工作^[5]: ①确定表示方案。即对待优化参数的编码方案, 一般用二进制编码表示。②确定适应度函数。即每个染色体的适应值。在图像配准中, 以互信息测度作为适应度函数。③确定算法中的参数, 如群体大小 P 、算法执行最大代数 N 、交叉概率 P_c 、变异概率 P_m 等。④确定算法停止运行的条件。算法终止条件的选择可以从以下两个方面考虑: 是否到了算法预先设置的最大执行代数, 或者是连续几次迭代后得到的最优解是否变化。标准遗传算法的实现步骤如图 1 所示。




图1 标准遗传算法流程

标准遗传算法的优越性主要表现在: 对问题依赖小, 搜索效率高, 全局搜索能力强, 对待优化函数无限制, 应用广泛。但是, 采用标准遗传算法对问题进行优化搜索时, 大量低适应度解的淘汰过程以及二进制的编码和解码减缓了最优解的搜索速度, 而某一代种群中个体适应度差别不大时会减小搜索区域使搜索落入局部最优解而过早收敛^[6]。

4 改进的自适应遗传算法搜索策略

4.1 自适应遗传算法 (adaptive genetic algorithm, AGA)

标准遗传算法无论适应度高的个体还是适应度低的个体都以同样的概率进行交叉和变异操作。显然, 这是不合理的。对此, Srinvas1994 年提出了自适应遗传算法^[7]。该算法对适应度高的个体采用较小的概率进行交叉和变异操作, 对适应度低的个体采用固定的概率进行交叉和变异操作。交叉概率 P_c 和变异概率 P_m 的确定如下:

$$P_c = \begin{cases} P_c = \frac{f_{\text{best}} - f_i}{f_{\text{best}} - f_{\text{agv}}}, & \text{当 } f_i > f_{\text{agv}} \\ P_c = 1 & \text{当 } f_i < f_{\text{agv}} \end{cases} \quad (6)$$

$$P_m = \begin{cases} P_m = 0.3 \times \frac{f_{\text{best}} - f_i}{f_{\text{best}} - f_{\text{agv}}}, & \text{当 } f_i > f_{\text{agv}} \\ P_m = 0.3 & \text{当 } f_i < f_{\text{agv}} \end{cases} \quad (7)$$

其中, f_i 是待交叉的两个个体中适应度较高者的适应度; f_{agv} 是当前种群中所有个体的平均适应度; f_{best} 是当前种群中适应度最高的个体适应度。

4.2 改进的自适应遗传算法

自适应遗传算法虽然克服了标准遗传算法中交叉概率 P_c 和变异概率 P_m 固定不变的缺点, 有效提高了算法的收敛速度, 但是仍存在着种群未成熟收敛, 容易陷入局部最优解的不足。因此, 本文从适应性遗传参数的设置入手, 提出一种改进的自适应遗

传算法(IAGA)。该算法以配对个体的相似度作为设置交叉概率的参考标准,并全程监测种群的整体相似程度,根据种群相似度调整当前种群变异概率的基数,同时为了克服传统意义上每个个体的不同基因座都设置相同变异概率的缺陷,采用了根据当前种群每个基因座的编码浓度来确定此基因座变异概率的方式,大大提高了新算法的持续进化能力。

4.2.1 交叉概率的设置

AGA 算法的一个缺陷是为了保护优良个体不被破坏,而给它们设置很小的交叉概率,使这些个体在算法进行中几乎处于不发生变化的状态,忽视了交叉操作本身的产生和搜索新模式的意义^[8]。在本文的算法中,以配对个体的差异度作为设置交叉概率的出发点,差异度越大说明它们通过交叉操作相互交换信息的价值也越大,且以差异度来衡量交叉率也可以避免近亲之间的交叉繁殖。

设个体基因长度是 m ,而配对的两个个体不同的基因位数是 x (即它们的海明距离是 x),则任选交叉点而将这 x 个基因分在交叉点同侧的可能情形共有:

$$T = \begin{cases} 2 \times \sum_{i=\frac{m+1}{2}}^{m-1} C_i^x, & (m \text{ 为奇数时}) \\ 2 \times \sum_{i=\frac{m}{2}}^{m-1} C_i^x, & (m \text{ 为偶数时}) \end{cases} \quad \text{种} \quad (8)$$

其中,当 $x > i$ 时,令 $C_i^x = C_m^x$ 。

而基因排列和交叉点设置的所有可能情况为 $s = (m-1) \times C_m^x$ 种,因此将这两个个体信息交换后不产生新个体的可能性为 $q = T/S$,交叉概率为:

$$P_c = 1 - T/S \quad (9)$$

4.2.2 变异概率的设置

种群能够持续进化的原因在于种群的多样性,一旦种群的大部分个体趋于相似法的交叉操作就会丧失产生和搜索新模式的能力^[9],而变异是用来保持种群多样性一个重要手段。但是如果为了维持种群的多样性而过增大变异概率,亦会令算法沦为随机搜索算法而无法找到最优解^[10]。在本文提出的 IAGA 中,个体每个基因座的变异概率都设为当前种群基因座的编码浓度的函数;也就是说个体的变异率与自身的适应度无关,而是由当前群体各个基因座的编码浓度决定的。具体操作时,将算法分为两个阶段:当算法处于进化寻优阶段时,可设置较小的变异概率基数,使种群在进化的同时可以很好地进行局部搜索;当种群多样性低下,算法停滞时,增

大变异概率,使算法能够跳出局部最优解。参数设置公式如下:

$$P_{m_i} = \begin{cases} P_{m1} + (P_{m2} - P_{m1}) \times 2 |d_i - 0.5|, & \text{当算法进化时} \\ P_{m3} + (P_{m4} - P_{m3}) \times 2 |d_i - 0.5|, & \text{当算法停滞时} \end{cases} \quad (10)$$

其中, $i = 1, 2, \dots, n$, n 为个体的编码长度; P_{m_i} 为个体第 i 个基因座的变异概率; d_i 为种群第 i 个基因座编码的浓度, $d_i = e_i/P$, 其中 e_i 为当前种群第 i 个基因座上编码的个数, P 为种群规模; $P_{m1} < P_{m2} \leq P_{m3} < P_{m4}$ 为所设定的变异概率的基数,一般情况下,参数的设置为 $P_{m1} = 0.005$, $P_{m2} = P_{m3} = 0.05$, $P_{m4} = 0.5$ 。

从式(10)可以看出,变异概率设置的关键是对种群进化阶段与停滞阶段的判定,而算法的进化能力与种群个体的多样性密不可分,由此本文提出的判定方法为:当 $\text{sum}(|d_i - 0.5| \geq \varepsilon)/n \geq 0.6$ 时,认为算法仍处于进化阶段;当 $\text{sum}(|d_i - 0.5| \geq \varepsilon)/n < 0.6$ 时,认为群体多样性差,算法进化能力较低。其中 $\text{sum}(|d_i - 0.5| \geq \varepsilon)$ 表示当前种群中浓度满足 $|d_i - 0.5| \geq \varepsilon$ 条件的基因座的总数;通常情况下, ε 的值取为 0.2 即可。

4.2.3 算法具体步骤

设 A 为参考图像, B 为浮动图像, A 与 B 之间的变换为刚体变换,浮动图像 B 沿 x, y 轴的平移分别为 t_x, t_y , 旋转角度为 θ 。配准步骤如下:

(1) 采用浮点数编码方法对刚体变换参数空间的参数按 (θ, t_x, t_y) 的顺序进行编码。

(2) 定义适应度函数;用两幅图像 A, B 的互信息作为图像配准的相似性测度,即适应度函数,即:

$$I(A, B) = \sum_{a,b} P_{AB}(a, b) \log \frac{P_{AB}(a, b)}{P_A(a)P_B(b)} \quad (11)$$

(3) 确定种群数目 P 及遗传代数 N 。

(4) 初始化种群。在规定范围内随机产生初始种群,三个待确定参数的范围分别为:旋转角度为 $-10^\circ \sim +10^\circ$ 之间,平移范围为 -20 个像素到 $+20$ 个像素之间。

(5) 确定当算法运行到预先设置的遗传代数 N 时,终止算法的运行。这时得到种群的最优个体即为问题的最终解。

(6) 计算个体适应性。按公式(11)计算种群中每个个体相应的目标函数值,即适应值。

(7) 选择。按最优保存策略把每一代种群中适应度最高的个体直接复制到下一代,对剩下的 $(N-1)$ 个个体采用轮盘赌法进行选择。

(8) 自适应交叉。按公式(8)~(9)确定交叉概

率 P_c ;然后在区间(0,1)中产生一个随机数 r ,若 $r < P_c$,就在交叉位置进行交叉操作,得到两个新个体。若 $r \geq P_m$,则不进行交叉操作。

(9)自适应变异。按公式(10)确定变异概率 P_m ,然后在区间(0,1)中产生一个随机数 r ,若 $r < P_m$,则对个体变异位进行变异,若 $r \geq P_m$,则不进行变异操作。

(10)若迭代次数达到设置的遗传代数 N 时,认为收敛指标已满足,求得的解即为最优解,否则转步骤(6)继续搜索,直到求得最优解。

5 仿真试验与分析

本文使用 Intel(R) Pentium E2140 CPU,1 GB的内

存计算机,在 Matlab 7.1 环境下进行仿真试验。用图像 Cameraman 对原始图像(参考图像)进行刚体变换后作为浮动图像。分别用标准遗传算法(SGA)、自适应遗传算法(AGA)、改进自适应遗传算法(IAGA)对浮动图像与参考图像进行配准。取群体数目 $P = 80$,迭代次数为 50。遗传参数设置为:

SGA: $P_c = 0.8 P_m = 0.05$

AGA: $P_c = [0.6, 0.8] P_m = [0.005, 0.05]$

IAGA: $P_{m1} = 0.005, P_{m2} = P_{m3} = 0.05, P_{m4} = 0.5$

三种方法的实验数据对比结果如表 1 所示。图 2 为 cameraman 浮动图像用三种方法与参考图像配准的结果。

表 1 SGA,AGA,IAGA 算法配准结果

配准方法	试验数据			误差			迭代次数	配准时间/s	最大互信息
	t_x /像素	t_y /像素	$\theta/(^\circ)$	t_x /像素	t_y /像素	$\theta/(^\circ)$			
SGA	-9.944	-9.957	-9.769	0.056	0.043	0.231	50	375	0.3263
AGA	-9.975	-9.965	-9.879	0.025	0.035	0.121	50	366	0.4023
IAGA	-9.993	-9.987	-9.939	0.007	0.013	0.061	50	344	0.4034

真实值: $t_x = -10, t_y = -10, \theta = -10^\circ$



图 2 配准结果

从表 1 可以看出,改进自适应遗传算法在 3 个配准参数的误差上要小于标准遗传算法和自适应遗传算法,其互信息是三者中最大的,配准效果最好。在配准时间上,改进自适应遗传算法迭代 50 次花费时间小于前两种算法。因此,本文提出的方法无论在时间还是精度上都有较大的提高。

6 结束语

针对标准遗传算法的图像配准收敛速度慢,容易早熟的缺陷,通过对遗传参数设置的改进,使算法能自适应地控制进化过程中的交叉概率和变异概率,很好的解决传统算法容易陷入局部最优,收敛慢的缺点,大大提高了图像配准的性能。

参考文献:

[1] Brown L G. A survey of image registration techniques[J]. ACM Computer Survey,2002,24(4):325-376.
[2] 陈国良,王煦法,庄镇泉,等. 遗传算法以及应用[M]. 北京:人民邮电出版社,1996.
[3] 马政德,杜云飞,周海芳,等. 遥感图像配准中相似性

测度的比较和分析[J]. 计算机工程与科学,2008,30(2):45-49.
[4] 曹蹊渺. 基于互信息的图像配准算法研究[D]. 北京:北京交通大学,2008.
[5] 杨日容. 一种基于改进遗传算法的医学图像配准算法[J]. 常熟理工学院学报:自然科学版,2008,22(8):122-124.
[6] 许亚军,陈小惠. 一种基于遗传算法和小波分解的刚体图像配准方法[J]. 江苏科技大学学报:自然科学版,2008,22(2):75-78.
[7] 田东平. 一种改进的模糊自适应遗传算法[J]. 计算机工程与应用,2008,44(11):60-63.
[8] 张文修,梁怡. 遗传算法的数学基础[M]. 西安:西安交通大学出版社,2001.
[9] 杨启文,蒋静坪,张国宏. 遗传算法优化速度的改进[J]. 软件学报,2001,12(2):270-276.
[10] Smith J E, Fogarty T C. Operator and parameter adaptation in genetic algorithm[J]. Soft computing, 1997, 11(2):81-87.