

文章编号: 1001-0920(2013)12-1805-06

一种基于遗传算法的最小交叉熵阈值选择方法

汤可宗^{1,2}, 柳炳祥¹, 徐洪焱¹, 肖 绚¹, 李佐勇²

(1. 景德镇陶瓷学院 信息工程学院, 江西 景德镇 333403; 2. 闽江学院 计算机科学系, 福建 闽江 350108)

摘要: 最小交叉熵阈值法(MCET)在二级阈值中是有效的,但在多极阈值的穷尽搜索中却要付出昂贵的时间代价. 鉴于此,提出一种基于遗传算法(GA)的MCET选择方法:在执行图像分割(IS)任务之前,先将IS转化为在一定约束条件下待优化的问题;在寻找待优化问题最优解的计算过程中引入一种回归设计技巧以存储中间结果;使用这种回归设计技巧,在一组标准测试图像上利用GA搜索待优化问题的最优解. 实验结果表明,利用所提出的方法获得的多个阈值非常接近于穷尽搜索获得的结果.

关键词: 图像分割; 最小交叉熵; 阈值; 遗传算法; 回归程序设计

中图分类号: TP391.41

文献标志码: A

A minimum cross entropy threshold selection method based on genetic algorithm

TANG Ke-zong^{1,2}, LIU Bing-xiang¹, XU Hong-yan¹, XIAO Xuan¹, LI Zuo-yong²

(1. School of Information Engineering, Jingdezhen Ceramic Institute, Jingdezhen 333403, China; 2. Department of Computer Science, Minjiang University, Minjiang 350108, China. Correspondent: TANG Ke-zong, E-mail: tangkezong@126.com)

Abstract: Although minimum cross entropy thresholding(MCET) is efficient in the case of bilevel thresholding, it encounters expensive computation when involving multilevel thresholding for exhaustive search on multiple thresholds. Therefore, an improved scheme based on the genetic algorithm is presented for fastening threshold selection in multilevel MCET. Firstly, image segmentation is considered as an optimization problem. Then, this scheme uses a recursive programming technique to reduce the computational complexity of the objective function in multilevel MCET. Finally, a genetic algorithm is proposed to search several near-optimal multilevel thresholds. Simulation results show that the multiple thresholds obtained by using the proposed scheme are very close to the optimal ones via exhaustive search on the real images.

Key words: image segmentation; minimum cross entropy; thresholding; genetic algorithms; recursive programming

0 引 言

图像分割(IS)是模式识别及计算机视觉等诸多相关研究领域的关键问题之一,也是许多复杂系统中的预处理基本步骤,如医疗诊断系统、矿产探测仪器、机场安检系统等. IS旨在根据一些属性,将图像划分成若干相似区域并从这些区域中提取出感兴趣的目标区域,为后续的图像处理提供依据. 现有的IS方法主要有阈值法、边缘检测法、区域跟踪法以及基于某种特定理论的分割方法. 在众多IS方法中,阈值法因计算简单、运算效率较高、速度较快等特点而成为最有效的方法之一^[1]. 阈值法基于的假设是图像中的

不同目标能够根据其灰度级区分出来. 因此,寻找一个合适的灰度阈值,再由该阈值将图像分割成不同的区域(或是从背景中分割出所需要的目标)是阈值法的关键之处.

熵是一种在物理学中用于描述体系混乱程度的定量方法,而基于熵的阈值化方法被认为是IS中最为有效的技术之一,目前应用于IS中的熵形式有多种不同类型. Kapur等^[2]设定了一幅图像中的背景和目标概率分布,通过最大化被分割图像的总熵值来获得最优阈值. Abutaleb^[3]采用二维熵的形式进一步延伸了Kapur的工作,二维熵的构建从二维直方图获

收稿日期: 2012-07-09; 修回日期: 2012-10-29.

基金项目: 国家自然科学基金项目(61202313, 61202318, 61261027, 31260273); 国家科技支撑计划项目(2012BAH25 F02); 江西省自然科学基金项目(20122BAB201044); 江西省教育厅项目(GJJ12642).

作者简介: 汤可宗(1978—),男,讲师,博士,从事智能信息处理的研究; 柳炳祥(1966—),男,教授,博士,从事数据挖掘等研究.

得, 而二维直方图则使用像素的灰度值和局部平均灰度值来构建. Li 等^[4]将一种单点迭代方案应用于最小交叉熵并提出了一种分割图像的快速迭代方法. Albuquerque 等^[5]考虑了统计学近来发展的一种非广延统计熵, 较好地将 Tsallis 熵应用于 IS, 取得了良好的实验效果. Sahoo 等^[6]基于 Renyi 熵提出了一种数字图像通用阈值求解方法. 文献 [7] 根据概率划分、模糊划分及熵理论的组合策略提出一种新的模糊熵并应用于 IS 中. 文献 [8] 基于粒状多极粗糙熵进化阈值方法来划分图像的不同区域. 在基于熵的阈值化方法中, 文献 [9] 提出的用于求解复杂系统优化问题的交叉熵方法, 其理论与实验都较好地显示出该方法的可行性. 通常, 同一集合的两类数据间存在着较强的联系, Cross 熵可用于测量这两类数据分布间的信息理论距离, 求出原始图像和分割图像间信息量差异最小的最优阈值, 便可应用于 IS 阈值化方法. 尽管 MCET 在二级阈值情况中效果显著, 但在多级阈值分割实现时, 最优解的寻找往往使用穷尽搜索方法, 阈值个数的增加会导致计算时间呈指数级形式增长, 从而使得进一步的推广使用受到限制. 所以如何使用 MCET 快速有效地选取最优阈值是本文研究的一个重点.

近年来, 许多学者借鉴组合优化问题的概念对 IS 方法进行了研究, 主要思路^[10]是基于已有的分割定义约束条件, 最佳分割阈值则是通过使用某种智能优化方法求解待优化的目标函数来获得. 目前, 较为常用的智能优化方法有: 粒子群优化算法 (PSO)、遗传算法 (GA)、蚁群算法 (AC) 和模拟退火算法 (SA) 等. 在这些智能优化算法中, GA 寻找最优解借鉴的生物学基础是自然选择机制与细胞遗传机理, 在工程计算领域具有一定的借鉴意义. GA^[11]能够较好地应用于一些需要提供准确且时间较短的工程领域, 并且确保最优解的有效性及其鲁棒性, GA 在解决一系列特殊的复杂问题中, 对问题本身并没有过多严格的数学要求, 无论所求解问题的定义域空间是线性的还是非线性的, 连续的还是离散的, GA 都可以在较短的时间内给出稳定、高效的最优解搜索策略. GA 良好的平行搜索能力有利于在问题定义域空间内平衡局部和全局搜索, 而进化算子的各种灵活形态使得 GA 能够快速有效地进行全局意义的概率搜索. 因此, 将 GA 应用于多极阈值分割中, 加快最优阈值的搜索是可行的.

GA 求解问题的方法可以概括如下. 将待求解的系统优化问题通过某种方式转换成对应的适应度函数, 由多个不同的染色体组合成一个初始种群, 种群中的每一个染色体相当于一个初始解. 种群在每一次进化过程中要进行 3 种遗传运算 (选择、交叉和变异): 选择是从种群中按照某种条件挑选出优秀的染色体;

交叉是两个染色体生成后代的一种方式; 而变异则是染色体自身发生基因突变的一种方法, 变异能够增大染色体成为优秀个体的概率. 种群经过多代遗传运算操作, 整个种群最终的位置接近或位于最优解的位置. 此外, 与其他智能优化方法相比, 在 GA 迭代寻优过程中, 后继迭代过程对解的探索将会根据已有迭代中求得的解速度进行自相应调整.

本文通过分析最小交叉熵的特点, 将 GA 引入 MCET 选择过程, 提出一种新的 IS 方法. 首先, 通过某种回归方法将 IS 问题在一定约束条件下转换为一个待求解的优化问题; 然后, 给出一种中间结果存储计算方法以存储在 MCET 过程中出现的若干中间计算结果; 最后, 通过这种回归技巧策略, 对一组通用图像的分割使用改进后的 GA 搜索待优化问题的最优解. 与传统 GA 方法不同之处表现为两个方面: 1) 改进后的 GA 方法是一种全局搜索方法, 不会陷入局部最优解; 2) 在若干次连续迭代过程中, 能够更快地执行平行搜索. 所提出的方法与穷尽方法进行比较, 阈值搜索时间进一步缩短, 其效果接近于穷尽搜索方法的分割效果.

1 最小交叉熵阈值化方法

熵是一种描述系统内部不均匀变化的状态函数. 一般而言, 系统内部的均匀状态可以由熵值变化情况来反映, 熵值越小, 状态有序但内部越不均匀, 反之则状态无序而内部越均匀. 通常, 系统内部的状态总是在有序和无序这两种状态间变化, 而此时熵值也是在状态对应的熵值间变化. 假定 X 是一个离散型随机型变量, 其取值 x_i 出现的概率为 $p(x_i)$, 定义离散分布的熵为

$$D(p) = \sum_{i=1}^N p(x_i) \log \left(\frac{1}{p(x_i)} \right). \quad (1)$$

式 (1) 中的熵值与符号本身的表达形式无关, 但与这些符号出现的概率相关. 式 (1) 显示出熵函数的性质如下: 1) 如果 X 等于某一离散值 x_i 时均有 $p(x_i) = 0.5$, 则此时熵值为最大, 也意味着等概率事件时熵取最大值; 2) 如果 X 等于某一离散值 x_i 时均有 $p(x_i) = 0$ 或 1, 则此时熵值为最小, 也意味着对于确定性事件时熵取最小值.

将上述熵函数的特性应用于模式识别系统的相关领域, 例如衡量图像分割优劣的一个性能指标就是使得背景或目标区域内的像素灰度一致性尽可能好. 而 Cross 熵的概念较好地给出了区域内一致性的十分有效的判定依据. MCET 选择方法的策略是^[6]: 最优阈值必须使得两者 (背景和目标) 交叉熵之和为最小, 实现过程描述如下.

假定图像 Image1 的直方图灰度级设定在 $[1, L +$

1] 区间范围内, 通过给定的阈值 t , Image1 被划分为目标和背景两个部分, 目标和背景的灰度级范围分别介于 $[1, t]$ 和 $[t, L + 1]$ 区间, 划分后 Image1 的交叉熵定义为

$$I(t) = \sum_{i=1}^{t-1} ih(i) \log\left(\frac{i}{u(1, t)}\right) + \sum_{i=t}^L ih(i) \log\left(\frac{i}{u(t, L+1)}\right). \quad (2)$$

其中: i 是灰度值; $u(1, t)$ 和 $u(t, L + 1)$ 分别是目标和背景两者中的类内均值, 该均值的描述形式为

$$u(a, b) = \frac{\sum_{i=a}^{b-1} ih(i)}{\sum_{i=a}^{b-1} h(i)}. \quad (3)$$

基于上述单阈值分割方法, 设 t_1, t_2, \dots, t_n 是分割阈值, 将 MCET 方法应用于多极阈值分割中, 并有 $t_1 < t_2 < \dots < t_n$. 定义多极阈值交叉熵为

$$I(t_1, t_2, \dots, t_n) = \sum_{i=1}^{t_1-1} ih(i) \log\left(\frac{i}{u(1, t_1)}\right) + \sum_{i=t_1}^{t_2-1} ih(i) \log\left(\frac{i}{u(t_1, t_2)}\right) + \dots + \sum_{i=t_n}^L ih(i) \log\left(\frac{i}{u(t_n, L+1)}\right). \quad (4)$$

图像分割的最优阈值为

$$(t_1^*, t_2^*, \dots, t_n^*) = \arg \min \{I(t_1, t_2, \dots, t_n)\}.$$

2 本文算法描述

使用 MCET 分割图像时, 为了准确选择出分割的最优阈值, 通常使用的方式是穷尽搜索, 即对可能的每种阈值都代入方程 (2), 根据每种交叉熵值的最终大小来确定最优阈值, 这一过程往往需要大量的计算时间. 对此, 本文针对 MCET 选择过程出现的大量中间计算结果给出了一种回归程序设计技巧, 较好地简化了阈值计算过程中所出现的繁琐步骤; 同时, 最优解的搜索过程使用了 GA 并最终获得最优解.

阈值 t 的确定可以先将方程 (2) 描述为如下形式:

$$I(t) = \sum_{i=1}^L ih(i) \log(i) - \sum_{i=1}^{t-1} ih(i) \log\left(\frac{\sum_{i=1}^{t-1} ih(i)}{\sum_{i=1}^{t-1} h(i)}\right) - \sum_{i=t}^L ih(i) \log\left(\frac{\sum_{i=t}^L ih(i)}{\sum_{i=t}^L h(i)}\right). \quad (5)$$

在某幅图像中, $\sum_{i=1}^L ih(i) \log(i)$ 为某一常数, 因此, 与方程 (5) 等价的一种形式为

$$\eta(t) = - \sum_{i=1}^{t-1} ih(i) \log\left(\frac{\sum_{i=1}^{t-1} ih(i)}{\sum_{i=1}^{t-1} h(i)}\right) -$$

$$\sum_{i=t}^L ih(i) \log\left(\frac{\sum_{i=t}^L ih(i)}{\sum_{i=t}^L h(i)}\right). \quad (6)$$

这里, 等式 $\eta(t) = 0$ 的一个必要条件是^[7]

$$\eta'(t) = h(t) \left\{ t \log \frac{u(1, t)}{u(t, L+1)} - (u(1, t) - u(t, L+1)) \right\}. \quad (7)$$

假定 $\eta'(t) = 0$, 则式 (6) 中“=”右端第 1 项 $h(t) = 0$ 或第 2 项为 0. 显然, 并不存在使得 $h(t) = 0$ 的阈值 t , 对图像的阈值分割并不会产生一个直接的影响, 故最优阈值 t^* 可设定第 2 项为 0 来获取, 即

$$t^* = \frac{u(t, L+1) - u(1, t)}{\log(u(t, L+1)) - \log(u(1, t))}. \quad (8)$$

根据图像的直方图, 设定 0 阶矩和 1 阶矩对应某个区域, 即

$$m^0(a, b) = \sum_{i=a}^{b-1} h(i), \quad m^1(a, b) = \sum_{i=a}^{b-1} ih(i).$$

由此, 式 (8) 可描述为

$$t^* = \frac{\frac{m^1(t, L+1)}{m^0(t, L+1)} - \frac{m^1(1, t)}{m^0(1, t)}}{\log\left(\frac{m^1(t, L+1)}{m^0(t, L+1)}\right) - \log\left(\frac{m^1(1, t)}{m^0(1, t)}\right)} = f(t). \quad (9)$$

设定一个初始值 t_0 和 $t_{i+1} = t_i + 1$. ε 是一个较小常量, 当收敛条件为 $|f(t_{i+1}) - f(t_i)| < \varepsilon$ 时, 最优阈值是 t_i . 使用穷尽搜索方法求解最优阈值 t_i 时需要为每个可能的阈值进行测试, 在某种程度上会大大增加计算的时间, 并且这种情况也会存在于图像的多级阈值分割中. 对此, 为加快方程 (8) 的计算过程, 本文提出一种回归程序设计方法. 假定 t 为初始阈值, 分别计算 $m^0(1, t)$, $m^1(1, t)$, $m^0(t, L+1)$ 和 $m^1(t, L+1)$ 等中间矩, 得到 $f(t)$ 后, 使用以下方程计算其他矩:

$$\begin{aligned} m^0(1, t+1) &= m^0(1, t) + h(t), \\ m^1(1, t+1) &= m^1(1, t) + th(t), \\ m^0(t+1, L+1) &= m^0(t, L+1) - h(t), \\ m^1(t+1, L+1) &= m^1(t, L+1) - th(t). \end{aligned} \quad (10)$$

图像分割若使用穷尽搜索方法, 则其复杂性为 $O(L^2)$, 当计算阈值 t 和 $t+1$ 分别对应 $f(t)$ 和 $f(t+1)$ 时, 可以看出, 两函数值 $f(t)$ 和 $f(t+1)$ 的计算差值表现为一常数, 这样, 在 MCET 选择过程中可大大减少计算复杂度.

将这种回归程序设计技巧通过上述类似的方法扩展到多极阈值分割中, 给定共需搜索 n 个阈值 $t_1, t_2, \dots, t_n, t_0 < t_1 < \dots < t_n < t_{n+1}$. 在此, 分别设定 $t_0 = 1$ 和 $t_{n+1} = L + 1$ 两个虚拟阈值, 则方程 (6) 可描述为

$$\eta(t_1, t_2, \dots, t_n) =$$

$$-\sum_{t=1}^{n+1} m^1(t_{i-1}, t_i) \log \left(\frac{m^1(t_{i-1}, t_i)}{m^0(t_{i-1}, t_i)} \right). \quad (11)$$

$\eta(t_1, t_2, \dots, t_n)$ 的导数为

$$\frac{d\eta}{dt_i} = h(t_i) \left\{ t_i \log \frac{u(t_i, t_{i+1})}{u(t_{i-1}, t_i)} - \frac{(u(t_i, t_{i+1}) - u(t_{i-1}, t_i))}{t_i} \right\}. \quad (12)$$

与单阈值分割情况类似, 假定第 2 项为 0, 可得方程

$$t_i^* = \frac{u(t_i, t_{i+1}) - u(t_{i-1}, t_i)}{\log u(t_i, t_{i+1}) - \log u(t_{i-1}, t_i)} = f(t_i), \quad (13)$$

其中 t_{i+1} 和 t_{i-1} 是两个已知常量. 假定初始阈值为 $t_{i_n} \in [t_{i-1}, t_{i+1}]$, 且 $t_{i_{n+1}} = t_{i_n} + 1$. 当收敛条件满足 $|f(t_{i_{n+1}}) - f(t_{i_n})| < \varepsilon$ 时, n 维多极阈值向量的第 i 个分量是 t_i . 于是, 获取多极阈值分割的最优解可以使用与单阈值相同的回归程序设计方法. 相比于穷尽搜索方法的复杂性 $O(L^{n+1})$, 计算量显著减少. 为进一步减少搜索过程的寻优时间, 基于上述回归程序设计方法, 使用 GA 搜索多极阈值分割中的最佳阈值.

本文提出的搜索最优阈值的 GA 中, 初始种群个体使用实数编码形式, 若 $[1, L]$ 为某一图像的灰度级区间范围, 则需要的阈值个数是 n . GA 中每个染色体编码为一个字符串 $x = (x_1, x_2, \dots, x_n)$, $x_i \neq x_j$, $i \neq j$. x_i 代表 n 维多极阈值向量中的第 i 个分量. GA 中的交叉算子为离散形式. 算法在搜索最优阈值的过程中, 每次迭代将从当前种群中任意挑选出两个新的个体, 将其进行交叉操作得到两个新的子个体. 若挑选出的两个个体分别为 $x = (x_1, x_2, \dots, x_n)$, $y = (y_1, y_2, \dots, y_n)$, 生成后代 $z = (z_1, z_2, \dots, z_n)$, $z_i = \{x_i\}$ 或 $\{y_i\}$, 则 $\forall i \in \{1, 2, \dots, n\}$, x_i 和 y_i 被选择的概率分别为 P_c 和 $1 - P_c$. 对交叉操作生成的两个新的子个体执行高斯变异操作, 其变异概率设为 $P_m = 1/n$, 且 $z_i = x_i + 0.1(x_i^U - x_i^L) \times N(0, 1)$. 其中: $N(0, 1)$ 是一个满足高斯分布的随机常数, x_i 的上限值和下限值分别是 x_i^U 和 x_i^L . 个体 Z 的优劣将根据方程 (13) 的计算结果来确定. 因此, 本文算法中 $z_0 = 1$ 和 $z_{n+1} = L + 1$ 分别是假定的两个虚拟的阈值, 且 $z_0 < z_1 < \dots < z_n < z_{n+1}$. 令 $t_{i_0} = z_i$, $t_{i_{n+1}} = t_{i_n} + 1$, t_{i+1} 和 t_{i-1} 分别等于 z_{i+1} 和 z_{i-1} . 当算法的收敛条件满足 $f(t_{i_{n+1}}) - f(t_{i_n}) < \varepsilon$ 时, t_{i_n} 即为所求的最优阈值中的第 i 个分量. 本文所提出的算法具体描述如下.

Step 1: 利用回归程序设计方法计算 $m^0(a, b)$ 和 $m^1(a, b)$, $1 < a < b < L$, a 和 b 是两个随机整数;

Step 2: 随机生成 P 个个体;

Step 3: 根据最初设定的矩概念形式, 个体的优劣通过方程 (13) 得到的适应度值的大小来确定;

Step 4: 执行选择操作, u 个个体将从种群中随机选出以进行后续的交叉和变异操作;

Step 5: 执行交叉和变异操作得到 $u \times v$ 个新的个体, 其中 v 是两者 (后代和父代) 间的比率系数;

Step 6: 对新生成的个体 s^* 和当前种群中的个体进行优劣比较, 若 s^* 的适应度优于目前种群中的某个个体 s , 则新个体 s^* 将进入到下一代种群中;

Step 7: 测试算法停止条件, 若满足算法停止条件, 则算法执行结束, 否则转 Step 3.

3 实验结果及分析

实验测试中, 本文提出的新算法简称为 GA-based 方法. 实验所处的环境: 操作系统为 Windows XP, 处理器为 2.27 GHz, 内存为 2.00 GB, 使用的软件编写工具 Matlab 7.0. 4 种图像分割中常用的标准测试图像分别为: 硬币 (Coin)、细胞 (Cell)、林娜 (Lena) 和辣椒 (Pepper), 不同类型的图像规格大小分别为: 256×256 、 265×272 、 512×512 、 512×512 .

新算法执行时, 涉及到的参数如下: 初始种群大小初始化为 $\text{Pop} = 30$; 最佳的个体数目 $u = 10$ 且交叉率 $P_c = 0.5$; 新生成的子代种群和父代种群的个体比例系数 v 设定为 3; 当算法的迭代次数 iter 达到 100 时, 算法停止执行. 为了对比所提出算法在标准测试图像上的分割性能, 对每幅图像中的目标和背景的分布形状, 通过直方图的形式加以描绘.

测试图像及其对应的直方图分别如图 1 所示. 将本文提出的 GA-based 方法应用于“硬币”和“细胞”两幅图像的二级阈值分割中, 图 2 的分割效果表明本文提出的回归程序设计方法是可行的. 对于图像细节较简单的两幅图像而言, 待分割的目标能够很好地从背景中被划分出来; 但对 Lena 和 Pepper 两幅包含较多细节的图像而言, 多极阈值分割方法更适合于分割若干个不同的目标区域.

在利用 GA-based 方法和穷尽搜索方法对 Lena 和 Pepper 两幅图像进行多极阈值分割后, 对比 GA-based 方法和穷尽搜索方法间的性能差异, 所使用的两项测定算法性能的准则分别为: 1) 寻找最优分割阈值的 CPU 时间; 2) 测定阈值分割图像质量的均匀性准则^[6]

$$U = 1 - 2C \times \frac{\sum_{j=0}^c \sum_{i \in R_j} (f_i - u_i)^2}{N \times (f_{\max} - f_{\min})^2}. \quad (14)$$

其中: C 是分割图像需要的阈值个数, R_j 是对应于图像阈值分割的第 j 个部分, 像素 i 的灰度级设定为 f_i , u_j 是图像阈值分割后的第 j 个区域中所有像素的平均灰度值, N 是测试图像中的像素总数, f_{\max} 是被测试图像中的像素最大值, f_{\min} 是被测试图像中的像素最小值.

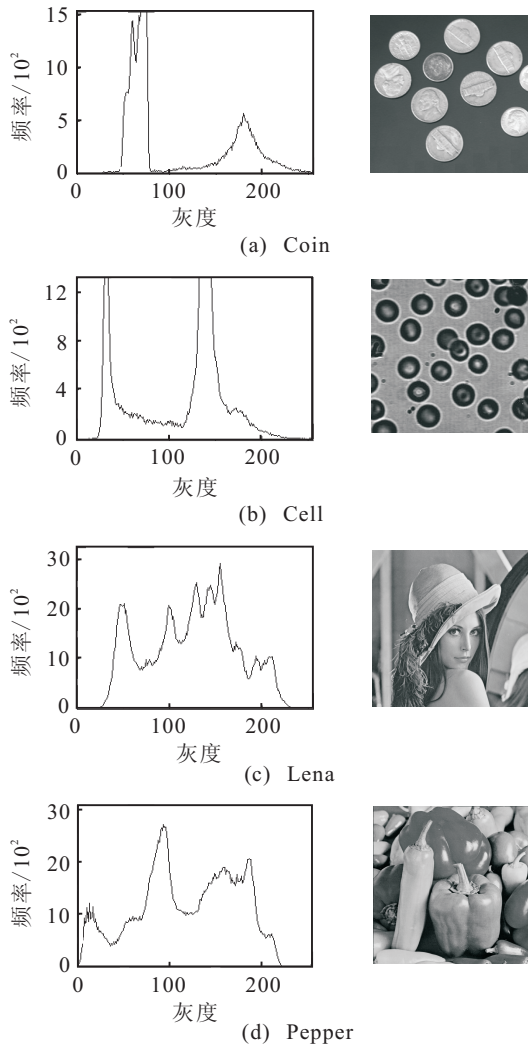


图 1 测试图像和对应的直方图

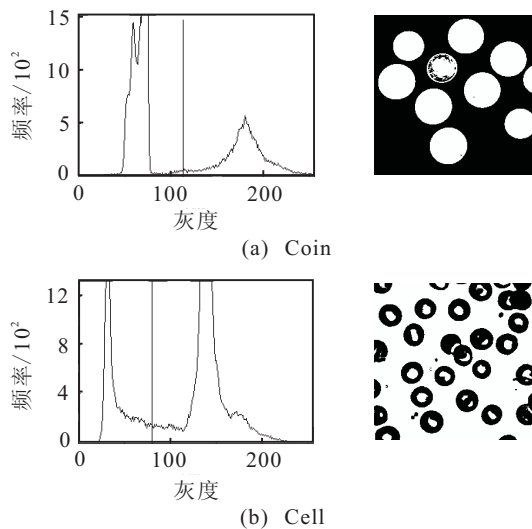


图 2 最小交叉熵最优二级阈值和对应的分割图

U 的值在一定程度上反映了 IS 的优劣, 其取值为 0 和 1 之间. 通常, U 值越大越能表明阈值分割的效果越好; 相反, 值越小则说明图像分割后的质量越差. 该均匀性准则测定的 U 值在某种程度上可以较好地反映不同 IS 算法分割图像后得到的图像分割质量, 定

量地说明各 IS 算法的性能优劣.

表 1 给出了图像 Lena 使用两种方法分别得到的阈值, C 代表阈值的个数, 介于 1 和 4 之间. 表 1 中数据显示出两种方法所得到的阈值相等 ($C = 1, 2$) 或非常接近 ($C = 3, 4$), GA-based 方法得到的阈值非常接近于穷尽搜索方法得到的阈值, 两者之间并无显著的差距, 均在一个相似的合理范畴内. 穷举方法得到的分割阈值的计算时间会因 C 的增加而呈指数级增长; GA-based 方法的计算时间能够保持在一个较为合理的时间范畴内, 随 C 的增加变化不大, 在一定程度上, 这种差异间的变化甚至可以忽略不计. 此外, 就 U 值而言, 待测试的两种方法分割图像后的结果也非常接近.

表 1 图像 Lena 使用不同方法得到的实验结果

方法	C	Thresholds	CPU time	Uniformity
GA-based 方法	1	107	0.013 5	0.998 637
	2	93, 147	0.016 6	0.996 083
	3	85, 126, 170	0.020 1	0.994 096
	4	81, 115, 148, 179	0.026 9	0.993 859
穷尽搜索方法	1	107	0.103 5	0.998 637
	2	93, 147	0.210 7	0.996 083
	3	85, 127, 169	15.705 1	0.994 045
	4	81, 116, 146, 179	850.206 5	0.993 971

为了更准确地描绘实验结果, 图 3 显示了阈值 ($C = 3, 4$) 分割图像后的结果. 图 3 的分割效果表明, 图 3(a)、图 3(c) 与图 3(b)、图 3(d) 的分割效果非常接近, 图 1(c) 中原始 Lena 图像中的帽沿, 人物脸形的轮廓及肩膀的边沿在图像 3 中由不同方法分割后的结果均能较好地提取出来. 分割后的许多目标细节部分均能从背景中分离出来, 并且分割出的目标细节在纹理、区域所占面积及位置方面均表现得非常接近. 从复杂图像的分割结果来看, 本文使用 GA-based 方法寻找多极阈值向量是可行的.



图 3 图像 Lena 分别使用两种方法得到的分割效果

类似于 Lena 的实验过程,表 2 显示出图像 Pepper 使用两种测试方法所得到的实验数据,表中数据显示出两种方法得到的最优阈值非常接近,差异在较为合理的范围内.此外,从计算时间来看,表 2 数据显示出 GA-based 方法的计算时间远远小于穷尽搜索方法,在一定程度上,使用 GA-based 方法所得计算时间在一个较理想的范围内.而就 U 值而言,GA-based 方法和穷尽搜索方法间的差异并不明显,所得分割的图像效果非常接近.表中 3 项测试性能表明,本文提出的 GA-based 方法与穷尽搜索方法在对通用图像测试上均能表现出较为理想的效果.

表 2 图像 Pepper 使用不同方法得到的实验结果

方法	C	Thresholds	CPU time	Uniformity
GA-based 方法	1	108	0.0125	0.998 259
	2	68, 134	0.0168	0.997 359
	3	64, 118, 165	0.0237	0.995 215
	4	51, 86, 125, 169	0.0271	0.995 277
穷尽搜索方法	1	108	0.1317	0.994 383
	2	68, 134	0.2864	0.997 359
	3	64, 117, 164	19.2183	0.995 215
	4	51, 87, 126, 167	901.1162	0.994 749

图 4 是使用 GA-based 方法和穷尽搜索方法对图像 Pepper 分割得到的图像效果.可以看出,图像 Pepper 中的 3 个主要青椒的边缘可以明显地由 GA-based 方法和穷尽搜索方法提取出来,青椒表面的光鲜部分在一定程度上能够分离出来.图 4 分割结果显示,图 4(a)、图 4(c)与图 4(b)、图 4(d)非常接近.以上实验数据表明:GA-based 方法能够在比较复杂的图像分割中获得较为理想的分割效果.



(a) GA-based 方法
3 级阈值化图像



(b) 穷尽搜索方法
3 级阈值化图像



(c) GA-based 方法
4 级阈值化图像



(d) 穷尽搜索方法
4 级阈值化图像

图 4 图像 Pepper 分别使用两种方法获得的分割效果

4 结 论

本文通过分析最小交叉熵的特点将 GA 引入

MCET 选择过程,提出了一种新的 IS 方法,在一组通用图像上的实验结果验证了所提出算法的合理性和有效性.值得注意的是,为了减少阈值计算过程的中间过程,本文算法给出的回归设计技巧在一定程度上是可行的.将本文算法应用于其他工程优化问题,以及借鉴其他智能优化算法的优点(如 PSO、SA、ACO 等),进一步改进本文算法在实际应用中的性能效果,是未来需要进一步研究的课题.

参考文献(References)

- [1] 汤可宗. 遗传算法与粒子群优化算法的改进及应用研究[D]. 南京: 南京理工大学计算机科学与技术学院, 2011: 56-66.
(Tang K Z. Modifications and application research on genetic algorithm and particle swarm optimization algorithm[D]. Nanjing: School of Computer Science and Technology, Nanjing University of Science and Technology, 2011: 56-66.)
- [2] Kapur J N, Sahoo P K, Wong A K C. A new method for gray-level picture thresholding using the entropy of the histogram[J]. Computer Vision Graphics Image Process, 1985, 29(20): 273-285.
- [3] Abutaleb A S. Automatic thresholding of gray level pictures using two dimensional entropy[J]. Computer Vision Graphics Image Process, 1989, 47(13): 22-32.
- [4] Li C H, Tam P K S. An iterative algorithm for minimum cross entropy thresholding[J]. Pattern Recognition Letters, 1998, 19(13): 771-776.
- [5] Albuquerque M Portes de, Esquef I A, Gesualdi Mello A R. Image thresholding using Tsallis entropy[J]. Pattern Recognition Letters, 2004, 25(9): 1059-1065.
- [6] Sahoo P, Wilkins C, Yeager J. Threshold selection using renyi's entropy[J]. Computer Pattern Recognition, 1997, 30(1): 71-84.
- [7] Tao W B, Tian J W, Liu Jian. Image segmentation by three-level thresholding based on maximum fuzzy entropy and genetic algorithm[J]. Pattern Recognition Letters, 2003, 24(30): 3069-3078.
- [8] Malyszko A, Stepaniuk J. Adaptive multilevel rough entropy evolutionary thresholding[J]. Information Sciences, 2010, 180(12): 1138-1158.
- [9] Kullback S. Information theory and statistics[M]. New York: Dover, 1997: 15-25.
- [10] 潘喆. 智能交通 x 图像阈值分割方法研究[D]. 南京: 南京航空航天大学信息科学与技术学院, 2010: 1-10.
(Pan Z. Research on thresholding segmentation for intelligent traffic images[D]. Nanjing: School of Information Science and Technology, Nanjing University of Aeronautics and Astronautics, 2010: 1-10.)

- [11] 汪海洋. 基于可见光航空遥感的水下目标自动识别技术研究[D]. 南京: 南京理工大学计算机科学与技术学院, 2008: 64-68.
(Wang H Y. Study on underwater object automatic recognition based on aerial visible remote sensing[D]. Nanjing: School of Computer Science and Technology, Nanjing University of Science and Technology, 2008: 64-68.)