

改进狼群优化算法的 Otsu 图像分割法

曹 爽, 安建成

(太原理工大学 计算机科学与技术学院, 山西 晋中 030600)

摘 要: 为减少算法的运行时间, 对狼群算法和二维 Otsu 算法进行分析研究, 提出改进狼群优化算法的 Otsu 图像分割法, 将 PSO 算法中求解当前局部最优的思想引入到狼群算法的游走、召唤行为中, 使狼群间实现信息交互, 提高搜索最佳阈值的准确度; 采用自适应化围攻行为, 加快算法寻优速度; 利用混沌法对得到的次优解进行优化, 避免陷入局部极值。仿真结果表明, 该算法既降低了分割时间, 又提高了分割精度。

关键词: 二维 Otsu; 狼群优化; 信息交互; 自适应化; 混沌法; 图像分割

中图分类号: TP391

文献标识码: A

文章编号: 1000-7180(2017)10-0016-06

Otsu Image Segmentation Method Based On Improved Wolf Pack Optimization Algorithm

CAO Shuang, AN Jian-cheng

(College of Computer Science and Technology, Taiyuan University of Technology,
Jinzhong 030600, China)

Abstract: In order to reduce the running time of the algorithm, Wolf pack algorithm and 2-D Otsu algorithm were studied, an Otsu image segmentation method based on improved Wolf pack optimization algorithm was proposed. In order to promote the exchange of information between the wolves, improve the accuracy of searching the best threshold, solving the current local optimal of PSO algorithm and scouting behavior, summoning behavior of Wolf Pack Algorithm were combined. An adaptive beleaguering strategy was introduced into beleaguered behavior, improve accuracy, the sub-optimal solution was optimized by chaos method to avoid local extreme. The results show that the algorithm not only reduces the segmentation time, but also improves the segmentation accuracy.

Key words: 2-D Otsu; wolf pack optimization; interactive information; adaptive; chaos method; image segmentation

1 引言

图像分割是根据一些特定的相似性标准, 将图像分割成若干互不重叠、具有特殊性质的区域, 在相同区域内, 满足一定的纹理、灰度、色彩等特征的相似性标准, 在不同区域内, 图像特征明显不同。由于阈值法实现简单而且计算速度较快, 在图像分割领域占据了重要地位^[1]。目前采用阈值分割的方法主要有双峰法^[2]、最大熵法^[3]、梯度统计法^[4]、最小误差法^[5]和 Otsu^[6]等。其中 Otsu 算法, 是以图像的直

方图为运算基础, 计算目标区域与背景区域之间的最大类间方差来获得分割阈值, 取得了良好的效果, 该算法与目标和背景像素的分布模型无关, 因此被广泛应用^[7-11]。

由于一维 Otsu 只应用了图像灰度信息, 没有应用像素之间的空间位置信息, 当图像的信噪比过低或图像的直方图没有明显双峰时, 该算法的分割效果较差, 易产生错误分割。

近年来许多学者利用群智能优化算法搜索最佳分割阈值, 包括基于粒子群算法 (Particle Swarm

Optimization, PSO)^[12]、蚁群算法(Ant Colony Algorithm, ACA)^[13]、萤火虫算法(Firefly Algorithm, FA)^[14]等分割方法. 由于群智能算法计算简单, 容易实现且计算效率较高, 因此得到了大量的应用^[15]. 狼群算法(Wolf Pack Algorithm, WPA)是一种新的群智能启发式算法^[16], 是对自然界当中狼群分工协作狩猎行为的模拟. 本文提出一种改进的狼群算法来求解最优二维阈值向量. 结果显示, 此算法和二维 Otsu 法以及文献[10]的改进 PSO 算法相比, 不仅可以求取全局最优二维阈值, 而且显著的提高了运算效率, 满足实时性应用要求.

2 二维 Otsu 阈值分割算法

二维 Otsu 算法的核心思想是应用像素灰度值和像素邻域的平均灰度值, 设计包含像素灰度及其邻域均值的二维直方图, 通过二维直方图求取最佳阈值来实现自动阈值选取.

设 $f(x, y)$ 和 $g(x, y)$ 分别为图像上像素点 (x, y) 的灰度值和该像素点 $k \times k$ 邻域的平均灰度值, 则

$$g(x, y) = \frac{1}{k^2} \sum_{l=-k}^k \sum_{q=-k}^k f(x+l, y+q) \quad (1)$$

令 $f(x, y) = i, g(x, y) = j, M_{i,j}$ 为二元组 (i, j) 出现的频数, 则定义相应的联合概率密度为:

$$p_{i,j} = \frac{M_{i,j}}{N} \quad (2)$$

式中, $N = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} M_{i,j}$ 为图像像素点总数; L 为图像灰度等级.

二维 Otsu 采用穷举法搜索遍历全部像素点来求解最佳阈值, 对于有效区域上一个可行的二维阈值向量 (s, t) , 可将图像二维直方图划分成四个区域, 如图 1. B, C 区域分别表示图像的目标和背景, A, D 区域代表边缘和噪声区. 令 ω_a, ω_b 分别为目标区域和背景区域像素点概率和, μ_a, μ_b 分别为两区域对应的像素点斜率均值矢量, 则求 $\omega_a, \omega_b, \mu_a, \mu_b$ 如式 (3) ~ (6) 所示.

$$\omega_a = \sum_{i=0}^s \sum_{j=0}^t p_{i,j} \quad (3)$$

$$\omega_b = \sum_{i=s+1}^{L-1} \sum_{j=t+1}^{L-1} p_{i,j} \quad (4)$$

$$\mu_a = (\mu_{ai}, \mu_{aj})^T = \left(\sum_{i=0}^s \sum_{j=0}^t \frac{ip_{i,j}}{\omega_a}, \sum_{i=0}^s \sum_{j=0}^t \frac{j p_{i,j}}{\omega_a} \right)^T \quad (5)$$




图 1 二维 Otsu 的阈值分割图

$$\mu_b = (\mu_{bi}, \mu_{bj})^T = \left(\sum_{i=s+1}^{L-1} \sum_{j=t+1}^{L-1} \frac{ip_{i,j}}{\omega_b}, \sum_{i=s+1}^{L-1} \sum_{j=t+1}^{L-1} \frac{j p_{i,j}}{\omega_b} \right)^T \quad (6)$$

二维直方图所有像素点的均值矢量为:

$$\mu = (\mu_i, \mu_j)^T = \left(\sum_{i=0}^{L-1} \sum_{j=0}^{L-1} ip_{i,j}, \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} j p_{i,j} \right)^T \quad (7)$$

大多数情况下, 远离二维直方图主对角线的像素点可以忽略, 则 $\omega_a + \omega_b \approx 1$ 且 $\mu \approx \omega_a \mu_a + \omega_b \mu_b$, 定义类间离散度矩阵为:

$$S_B(s, t) = \omega_a (\mu_a - \mu)^T (\mu_a - \mu) + \omega_b (\mu_b - \mu)^T (\mu_b - \mu) \quad (8)$$

将离散度矩阵的迹作为两类区域的类间距离度量函数, 如式 (9) 所示.

$$Tr(S_B(s, t)) = \omega_a [(\mu_{ai} - \mu_i)^2 + (\mu_{aj} - \mu_j)^2] + \omega_b [(\mu_{bi} - \mu_i)^2 + (\mu_{bj} - \mu_j)^2] \quad (9)$$

当 $Tr(S_B(s^*, t^*)) = \max\{Tr(S_B(s, t))\}, 0 \leq s, t \leq L-1$ 时, 则 (s^*, t^*) 为最佳分割阈值.

二维 Otsu 法的优点是提高了阈值选取的准确度和算法抗噪性, 良好地解决了一维 Otsu 法对噪声的敏感, 但缺点是计算量较大, 计算复杂度过高. 传统二维 Otsu 法需遍历整个图像求解最优阈值, 计算离散度矩阵需双重循环, 即需要在二维直方图目标和背景区域所对应的象限做累加计算, 参加运算的点数为 $s * t + (L-s) * (L-t)$, 复杂度为 $\sum_{t=0}^{L-1} \sum_{s=0}^{L-1} [s * t + (L-s) * (L-t)]$, 因此传统二维 Otsu 算法的计算复杂度是 $O(L^4)$.

3 改进狼群优化算法的二维 Otsu 法

3.1 狼群体系分析

狼群算法是一种新的群智能算法, 通过模拟狼群的捕食行为, 并利用个体狼与狼群间信息交互来达到协同寻优的目的. 整个狼群机制包括头狼、探

狼、猛狼这三种角色。其中,头狼是群体中最强大、最智慧的首领,依照采集到的信息进行合理决策,为整个狼群下达准确的行动指令;探狼主要负责勘察猎物,根据猎物气味浓度进行判断,猎物气味浓度越强烈表明狼离猎物越近,探狼始终朝着气味浓度最强的方向搜索;当探狼发现猎物会即刻向头狼报告,在头狼确定猎物位置后,头狼向猛狼发起召唤,猛狼听从行动指令向猎物源逼近进行围攻。此外,为保证种群的生存和发展,狼群一直延续着弱肉强食以及适者生存的自然法则,根据生存环境和群体情况进行种群更新,除去弱小,保存狼群力量^[17-18]。

3.2 相关定义

设人工狼总数为 N ,待寻优的阈值变量数为 D ,则整个狼群可被抽象为 $N \times D$ 的欧式空间。记待寻优的阈值向量为 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$,则每匹人工狼感知的猎物气味浓度 $Y_i = f(X_i)$,其中 Y 是目标函数,即离散度矩阵迹的值。

3.3 智能行为与规则描述

利用狼群算法优化二维 Otsu 法的本质是在像素点灰度和该像素点邻域灰度平均值组成的二维位置空间上,寻找一组最优解 (s^*, t^*) ,使得式(9)的值最大,即以目标函数最大化为前提确定最佳阈值。

3.3.1 选取头狼、探狼和猛狼

初始化 N 个可行的二维阈值向量,根据人工狼 i 的位置 X_i 计算猎物气味浓度 Y_i ,选择狼群当中最大的个体狼为头狼,则头狼感知的猎物气味浓度为 $Y_{\text{lead}} = \max\{Y_i\} (i = 1, 2, \dots, N)$,位置为 $X_{\text{lead}} = X_i$ 。若多匹个体狼感知的气味浓度相同且最大,则随机选取其中一匹作为头狼。头狼不参加游走和奔袭围攻行为,直至其被更强壮的人工狼替代。选取除头狼外 $g\text{-num}$ ($g\text{-num}$ 取 $\lceil n/(\alpha + 1) \rceil, n/\alpha$ 之间的随机整数, α 为探狼比因子) 匹感知猎物气味浓度最强的人工狼作为探狼。将头狼和探狼以外的其他个体狼作为猛狼。

3.3.2 交互游走行为

游走过程中,探狼从当前所处位置随机向 h 个方向分别前进 step_a (游走步长),并记录前进后的猎物气味浓度(即目标函数值)后退回原位置,则向第 m ($m = 1, 2, \dots, h$) 个方向前进后,探狼 i 在第 d 维搜索空间中所处位置为:

$$x_{id}^m = x_{id} + \sin(2\pi \times m/h) * \text{step}_a^m \quad (10)$$

此时,探狼 i 感知的猎物气味浓度为 Y_{im} 。上述

游走行为,探狼自身随机向 h 个方向进行搜索,缺少“同伴”间必要的信息交流,若 h 过大,求解精度虽高,但算法收敛速度较慢; h 过小,导致搜索过程粗糙,寻优不精确。为增加个体狼间的交互性并提高探狼寻优能力,引入 PSO 算法中求解当前局部最优解的思想,提出交互游走策略,如式(11) 和式(12):

$$V_{id}^{l+1} = V_{id}^l + c_1 r_1 (p_{id}^l - x_{id}^l) + c_2 r_2 (p_{gd}^l - x_{id}^l) \quad (11)$$

$$x_{id}^{l+1} = x_{id}^l + v_{id}^{l+1} \quad (12)$$

式中, l 为当前迭代次数; c_1, c_2 为非负常数,称为加速度因子; r_1, r_2 为 $[0, 1]$ 之间的随机数,用以保证种群多样性; P_i 为人工狼个体最优极值, $P_i = (p_{i1}, p_{i2}, \dots, p_{iD})$; P_g 为人工狼群体最优极值, $P_g = (p_{g1}, p_{g2}, \dots, p_{gD})$; V_i 为人工狼交互游走速度, $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$, 设定 $-x_{\text{maxd}} \leq x_{id} \leq x_{\text{maxd}}$, x_{maxd} 为第 d 维搜索空间的上限,则 $v_{\text{maxd}} = k * x_{\text{maxd}}$, 其中 $0.1 \leq k \leq 1.0$, 速度变化范围为 $[-v_{\text{maxd}}, v_{\text{maxd}}]$ 。

式(11) 是对探狼的交互游走速度进行更新,由三部分构成。第一部分为探狼当前的速度,联系探狼当前的状态,起到平衡狼群全局搜索和局部搜索的作用;第二部分为个体狼认知,是探狼自身的思考,体现探狼向自身最有目标值游走的能力,表示探狼自身的探索能力;第三部分为探狼间信息交互,体现探狼向全局最优极值游走的能力,表示狼群间的信息共享和合作。在三部分的共同作用下,探狼根据自身游走的历史经验同时结合探狼间信息共享机制不断调整自身的位置,从而找到问题的最优解,提高人工狼群的搜索精度。

游走后对于每匹探狼 i ,选择最大气味浓度的 Y_{im} 作为 P_i (个体最优值);对于整个探狼群,选择最好个体最优值 P_i 作为 P_g (全局最优值)。接着探狼执行信息交互行为,根据式(11),式(12) 进行一次交互搜索(此时 l 取 1)。信息交互后探狼 i 感知的猎物气味浓度记作 $Y'_{i[h+1]}$ 。游走交互搜索后探狼 i 在 $(h+1)$ 个猎物源中选取气味浓度最大且大于当前气味浓度的方向前进,更新探狼所在位置 X_i ,重复以上游走交互行为直至某匹探狼 i 感知的猎物气味浓度 $Y_i > Y_{\text{lead}}$,则探狼 i 成为新的头狼,并进入召唤行为,否则,探狼继续下次游走交互搜索直至游走交互次数 T 达到最大游走交互次数 T_{max} 。

3.3.3 交互召唤行为

召唤过程中,头狼发起召唤,猛狼感知召唤后以

相对较大的奔袭步长 step_b 快速逼近头狼位置,则猛狼 i 第 $k+1$ 次迭代在第 d 维搜索空间中所处位置为:

$$x_{id}^{k+1} = x_{id}^k + \text{step}_b^d * (g_d^k - x_{id}^k) / |g_d^k - x_{id}^k| \quad (13)$$

式中, g_{dk} 为第 k 代头狼在第 d 维搜索空间的位置. 狩猎途中,若猛狼感知的猎物气味浓度 $Y_i > Y_{\text{lead}}$, 则 $Y_{\text{lead}} = Y_i$, 该猛狼转化为头狼发起召唤, 否则继续狩猎直至其与头狼 S 之间的距离 d_{is} 小于 d_{near} 时进入围攻行为. d_{near} 可由式(14)得到:

$$d_{\text{near}} = \frac{1}{D \times \omega} * \sum_{d=1}^D |x_{\text{max}d} - x_{\text{min}d}| \quad (14)$$

式中, ω 为距离判定因子; $x_{\text{min}d}$ 为第 d 维搜索空间的下限.

上述召唤行为中,猛狼间仍然缺少信息交流,不能充分了解其他人工狼的信息,导致猛狼的搜索能力下降,为此猛狼每次执行一次式(13) 搜索后再执行一次式(11)、式(12) 的交互搜索过程,更新猛狼位置 X_i , 选取感知气味浓度最大的猛狼作为头狼.

3.3.4 自适应围攻行为

设第 k 代狼群,猎物在第 d 维变量空间中的位置为 G_{dk} , 则围攻行为可用式(15) 表示:

$$x_{id}^{k+1} = x_{id}^k + \lambda * \text{step}_c^d * |G_d^k - x_{id}^k| \quad (15)$$

式中, step_c 为围攻步长; λ 为随机步长因子, 是 $[-1, 1]$ 内均匀分布的随机数. 围攻后若人工狼感知的猎物气味浓度大于其原位置感知的猎物气味浓度则更新人工狼位置, 否则人工狼位置不变.

围攻过程中,要求猛狼具有较强的局部寻优能力,而上述围攻过程具有随机性和不确定性. 随着迭代次数的增加,当前最优目标函数值越趋近于全局最优值,导致猛狼局部寻优能力下降,为此提出自适应围攻策略,将随机数 λ 改为随着算法迭代次数 k 增加线性变化的自适应步长公式,如式(16):

$$x_{id}^{k+1} = x_{id}^k + \lambda \left(1 - \frac{\beta k}{k_{\text{max}}}\right) * \text{step}_c^d * |G_d^k - x_{id}^k| \quad (16)$$

式中, k 为当前迭代次数; k_{max} 为最大迭代次数; β 为 $(0, 1)$ 内的随机数. β 的作用是避免算法在迭代后期 $\lambda \left(1 - \frac{\beta k}{k_{\text{max}}}\right)$ 趋近于 0; λ 的作用是避免搜索范围局限 $|G_d^k - x_{id}^k|$ 的方向,从而可以有效全面搜索到 x_{id} 附近区域. 游走步长 step_a , 奔袭步长 step_b , 围攻步长 step_c 满足以下关系:

$$\text{step}_a^d = \text{step}_b^d / 2 = 2 * \text{step}_c^d \quad (17)$$

$$\text{step}_a^d = |x_{\text{max}d} - x_{\text{min}d}| / s \quad (18)$$

式中, s 为步长因子.

3.3.5 群体更新

为维持种群的生存和发展,人工狼群体需按照“由强到弱”的选择进行食物分配,即算法中除去目标函数值最差(离散度矩阵的迹最小)的 R 匹人工狼,同时随机产生 R 匹狼. 其中 R 取 $[n/(2 \times \xi), n/\xi]$ 之中的随机数, ξ 是狼群更新比例因子.

3.4 混沌优化法

混沌优化法是将给定的函数变量线性映射在 $[0, 1]$ 区间内,把求解过程对应为混沌轨迹的搜索过程,这样可避免所求解陷入局部最优,最终取得全局最佳值.

采用 logistic 映射,通过下式将算法所得的次优点生成混沌变量序列.

$$x_{k_0+1} = \mu * x_{k_0} (1 - x_{k_0}) \quad (19)$$

式中, x_{k_0} 为变量, k_0 为混沌变量迭代次数 ($k_0 = 0, 1, 2, \dots$), μ 为控制参数.

将离散度矩阵迹的值 $f(X)$ 作为待优化函数,待寻优的阈值向量 $X = (x_1, x_2, \dots, x_D)$ 为优化变量, $X^{(k_0)} = (x_1^{k_0}, x_2^{k_0}, \dots, x_D^{k_0})$ 为第 k_0 次迭代混沌求解的结果, $x_j^{k_0}$ 为 $X^{(k_0)}$ 的第 j 个分量, $X^{(0)}$ 为最初点, x^* 为混沌求解最优点, $f(x^*)$ 为最优值. 混沌优化法主要步骤如下:

(1) 初始化 $k_0 = 0, X^{(k_0)} = X^{(0)}, x^* = X^{(0)}, f(x^*) = f(X^{(0)})$, 将优化变量按下式映射为 0 到 1 内的混沌变量 $hx_j^{k_0}$.

$$hx_j^{k_0} = \frac{x_j^{k_0} - x_j^{\min}}{x_j^{\max} - x_j^{\min}} \quad (20)$$

式中, $x_j^{\max}$ 和 $x_j^{\min}$ 分别是第 j 维变量的上下限.

(2) 将 $hx_j^{k_0}$ 按式(19) 计算求出下一次迭代的混沌变量 $hx_j^{k_0+1}$.

$$hx_j^{k_0+1} = \mu hx_j^{k_0} (1 - hx_j^{k_0}) \quad (21)$$

(3) 将 $hx_j^{k_0+1}$ 按式(22) 转化成优化变量 $x_j^{k_0+1}$.

$$x_j^{k_0+1} = x_j^{\min} + hx_j^{k_0+1} (x_j^{\max} - x_j^{\min}) \quad (22)$$

(4) 通过优化变量 $x^{(k_0+1)} = (x_1^{k_0+1}, x_2^{k_0+1}, \dots, x_j^{k_0+1}, \dots, x_D^{k_0+1})$, 对所得新解进行性能对比.

(5) 若新解较优,则 $x^* = x^{(k_0+1)}$, 否则 x^* 不变.

(6) 当混沌搜索次数达到最大次数 k_0 时输出

$x *$, 否则令 $k_0 = k_0 + 1$, 并返回步骤(2).

3.5 算法步骤

(1) 参数初始化. 设置人工狼位置 X_i 及其数目 N , 最大迭代次数 $k_{\max}$, 探狼比因子 α , 最大交互游走次数 $T_{\max}$, 距离判定因子 w , 步长因子 s , 更新比例因子 ζ , 最大混沌迭代次数 k_0 , 控制参数 μ .

(2) 用个体狼位置代表待搜索的二维阈值向量, 通过式(9) 计算人工狼感知的猎物气味浓度, 根据浓度值大小依次选出头狼、探狼和猛狼.

(3) 探狼进行交互游走行为, 直至某匹探狼 i 感知的猎物气味浓度 Y_i 大于头狼 Y_{lead} , 则该探狼 i 代替头狼进行召唤或达到最大交互游走次数 $T_{\max}$, 则转步骤(4).

(4) 猛狼采用交互召唤策略向猎物逼近, 若途中其感知的猎物气味浓度 $Y_i > Y_{\text{lead}}$, 则 $Y_{\text{lead}} = Y_i$, 猛狼取代头狼发起召唤; 若 $Y_i \leq Y_{\text{lead}}$, 则猛狼继续搜索直至 $d_{is} \leq d_{\text{near}}$, 则转步骤(5).

(5) 按式(16) 对进行围攻行为的人工狼的位置进行更新, 执行围攻行为.

(6) 围攻后, 计算每匹个体狼当前适应度值 Y_i 以及平均适应度值 Y_{avg} .

(7) 让狼群中所有适应度值大于 Y_{avg} 的个体狼根据 3.4 节执行混沌局部搜索, 并记录混沌搜索后每匹人工狼的最佳位置和最佳值.

(8) 将感知猎物气味浓度 Y_i 最大的人工狼作为头狼, 对狼群群体进行更新.

(9) 判断算法是否达到寻优精度或最大迭代次数 $k_{\max}$, 若达到则输出头狼位置, 作为图像最优分割阈值, 并对图像采用二值化分割, 否则返回步骤(2).

4 实验仿真与分析

实验利用 MATLAB R2016a 编写仿真程序. 为保证搜索的阈值可以在最佳阈值附近收敛, 算法中狼群的群体规模 N 设置为 100, 向量空间维数 D 为 2, 最大迭代次数 $K = 200$, 最大游走次数 $T_{\max} = 20$, 探狼比因子 $\alpha = 4$, 更新比例因子 $\zeta = 6$, 经过多次实例仿真, 发现距离判定因子 $w = 600$, 步长因子 $s = 1\ 000$ 时, 结果可较稳定的收敛在最佳阈值附近, 最大混沌迭代次数 $k_0 = 10$, 控制参数 $\mu = 4$. PSO 算法的参数设置为: 粒子总数 N 为 100, 粒子空间维数 D 为 2, 最大迭代次数 $K = 200$, 惯性系数 $\omega_{\max} = 0.95$ 随着迭代次数不断增加, 惯性系数逐渐减小到 $\omega_{\min} = 0.4$, 粒子每一

维最大速度 $V_{\max} = 4, C_1 = C_2 = 1.29$.

采用改进 PSO 优化^[10]二维 Otsu 法、二维 Otsu 法和本文算法分别对 Lena、Lake 和 Cameraman 图像进行分割, 运行结果如表 1、表 2 和表 3 所列.

表 1 三种算法的分割阈值对比(灰度级)

图像	Otsu 法	文献[10]法	本文算法
Lena	128 107	146 128	123 101
Lake	132 108	133 106	122 98
Cameraman	78 89	78 90	76 84

表 2 三种算法计算分割阈值用时对比 ms

图像	Otsu 法	文献[10]法	本文算法
Lena	51 266	632	491
Lake	53 478	631	527
Cameraman	59 462	654	529

表 3 三种算法区域一致性对比

图像	Otsu 法	文献[10]法	本文算法
Lena	0.983 2	0.974 6	0.990 1
Lake	0.921 5	0.963 8	0.986 2
Cameraman	0.972 1	0.987 6	0.993 3

从图 2 中可看出, 利用本文算法分割得到的图像中, Lena 的面部轮廓更清晰, Lake 和 Cameraman 在图像底部的噪声点比前两种方法更少, 分割效果较优.




图 2 三种算法的分割效果比较

从表 1 中可观察到, 本文算法的分割阈值小于其他两种算法, 由于算法采用粒子群法和混沌法进行优化, 不易陷入局部最优, 能精准找到最佳阈值, 这样可避免因阈值过高, 把部分较亮的背景区域误分到目标区域中.

从表 2 中可看出, 在时间消耗方面, 本文算法较

其他两种方法用时更短,这是因为算法采用自适应围攻策略,加快搜索最优解的收敛速度.

表 3 中,区域一致性反映了算法对图像的分割效果,在同一类别区域内,像素相似度越大,表明一致性越好,分割效果越佳.区域一致性可定义为:

$$V = 1 - \frac{1}{C} \sum \left\{ \sum_{(x,y) \in R_i} \left[f(x,y) - \frac{1}{I_i} \sum_{(x,y) \in R_i} f(x,y) \right]^2 \right\} \quad (23)$$

式中, R_i 为图像分割后的第 i 个区域. I_i 为第 i 个区域的面积. $f(x,y)$ 为图像 (x,y) 处的灰度值. C 为图像像素点总数. V 的范围在 $[0,1]$ 内, V 越大则区域内部的均匀性越好.

由表 3 可知,采用本文算法分割后的图像,区域一致性均优于其他两种算法.由此可知,本文算法既提高了图像的分割精度,又减少了算法的运行时间.

5 结束语

本文提出应用改进的狼群算法来搜索最优二维阈值向量.实验结果表明,该算法不仅能获得与二维 Otsu 算法相当的分割结果,而且使计算量大大减少,比改进 PSO 优化二维 Otsu 算法的寻优能力更强,缩短了算法的运行时间,因此本文算法具有较好的鲁棒性和适应性,为二维 Otsu 算法的实时性应用提供了新的途径.

参考文献:

- [1] 潘红,申铨京.基于 Otsu 的医学图像分割算法研究[D].吉林:吉林大学,2016.
- [2] 谢懿,王辉,张雪锋.图像阈值分割技术中的部分和算法综述[J].西安邮电学院学报,2011,16(3):1-5.
- [3] 张新明,张爱丽,郑延斌,等.改进的最大熵阈值分割及其快速实现[J].计算机科学,2011,38(8):278-283.
- [4] Sczgin M, Sankur B. Survey over image t-hresholding techniques and quantitative perfo-rmance evaluation [J]. Journal of Electronic I-maging, 2004, 13 (1): 146-168.
- [5] 龙建武,申铨京,陈海鹏.自适应最小误差阈值分割算法[J].自动化学报,2012,38(7):1134-1144.
- [6] 何志勇,孙立宁,陈立国. Otsu 准则下分割阈值的快速

计算[J].电子学报,2013,41(2):267-272.

- [7] 刘建庄,栗文清.灰度图像的二维 Otsu 自动阈值分割方法[J].自动化学报,1993,19(1):101-105.
- [8] Abutaleb A S. Automatic thresholding of gray-level pictures using two-dimensional entr-opy[J]. Computer Vision, Graphics and Image Processing, 1989, 47 (1): 22-32.
- [9] 徐长新,彭国华.二维 Otsu 阈值法的快速算法[J].计算机应用,2012,32(5):1258-1260.
- [10] 刘桂红,赵亮,孙劲光,等.一种改进粒子群优化算法的 Otsu 图像阈值分割方法[J].计算机科学,2016,43(3):309-312.
- [11] 袁建,程国涛.基于二维直方图双斜率划分的快速 OT-SU 图像分割算法[J].计算机应用研究,2017,33(6):1905-1908.
- [12] 黄港,李俊,潘金贵.基于粒子群优化方法的 2 维 Otsu 快速图像分割算法[J].中国图象图形学报,2011,16(3):377-381.
- [13] 邢旭东,周旭,米健.基于改进的人工蚁群的图像分割算法[J].无线电通信技术,2013,39(6):71-73.
- [14] 周晨航,田力威,赵宏伟.基于改进萤火虫算法的二维 Otsu 图像分割法[J].沈阳大学学报,2016,28(1):45-50.
- [15] 王水花,张煜东,吉根林.群智能算法的理论及应用综述[J].南京师范大学学报,2014,14(4):31-38.
- [16] 吴虎胜,张凤鸣,吴庐山.一种新的群体智能算法—狼群算法[J].系统工程与电子技术,2013,35(11):2430-2438.
- [17] 王瑞琪,张承慧,李珂.基于改进混沌优化的多目标遗传算法[J].控制与决策,2011,26(9):1391-1397.
- [18] Sthitpattanapongsa P, Srinark T. A two-stage OTSU's thresholding based method on a 2D histogram[C]//Proc of IEEE International Conference on Intelligent Computer Communication and Processing. Cluj-Napoca, Romania, 2011:345-348.

作者简介:

曹爽女,(1992-),硕士研究生.研究方向为图像处理和人工智能.

安建成(通讯作者)男,(1963-),副教授.研究方向为机器学习和图像处理. E-mail:2274982189@qq.com.