

文章编号:1007-2780(2017)09-0726-10

融合改进人工蜂群和 K 均值聚类的图像分割

赵文昌*, 李忠木

(大理大学 工程学院, 云南 大理 671003)

摘要:针对人工蜂群优化的 K 均值算法易陷入局部最优、搜索精度不够、分割图像不够细致等问题,本文融合自适应人工蜂群和 K 均值聚类,提出了一种新的图像分割算法。算法首先利用距离最大最小乘积对种群进行初始化;其次采用自适应搜索参数动态调整邻域搜索范围,使人工蜂群算法快速收敛于全局最优;然后将人工蜂群输出的所有蜜源进行 K 均值聚类,克服 K 均值聚类结果对初始聚类中心的依赖,再将聚类划分结果进行 Powell 局部搜索,加快算法收敛的速度,将得到的新聚类中心更新蜂群中蜜源位置。最后,将本文算法与其他两种同类分割算法进行试验对比。实验结果表明:与其他两种算法相比,本文提出的分割算法在保证运行时间的前提下,分割准确率比其他两种算法分别至少提高了 3.5% 和 4.8%,表现出了较高的分割质量。

关键词:自适应人工蜂群;K 均值聚类;图像分割;Powell 局部搜索;距离最大最小乘积

中图分类号:TP391.41 **文献标识码:**A **doi:**10.3788/YJYXS20173209.0726

Image segmentation algorithm based on improved artificial bee colony and K-mean clustering

ZHZO Wen-chang*, LI Zhong-mu

(College of Engineering Dali University, Dali 671003, China)

Abstract: In order to overcome the artificial colony optimization k -means which be fallen into local optimum easily, converged slowly, segmented roughly and other issues, a new image segmentation algorithm is proposed based on adaptive artificial bee colony and K -mean clustering. First, the population is initialized by the maximum and minimum product; Secondly, adaptive search parameters are used to adjust neighborhood search scope dynamically, that makes artificial bee colony algorithm quickly converge to global optimal and achieve a more optimal solution; Then, all nectaries will be clustered by K -mean to the dependence of clustering result on the initial center, and then clustering results are divided into Powell local search, which accelerate the algorithm convergence speed, that will receive a new clustering center update colony of nectar source location. Finally, the proposed algorithm is compared with the other two algorithms. The experimental results show that compared with the other two algorithms, the segmentation algorithm proposed in this paper can improve the segmentation accuracy by at least 3.5% and 4.8%, respectively, under the premise of guaranteeing the

收稿日期:2017-04-05;修订日期:2017-05-23.

基金项目:云南省教育厅科研项目(No.2014Y409)

Supported by Educational Scientific Research Projects of Yunnan Province(No. 2014Y409)

* 通信联系人, E-mail: zhaowenchang79@126.com

running time, showing a higher segmentation quality.

Key words: artificial bee colony; k-means clustering; image segmentation; powell local search; maximum minimum product distance

1 引言

图像分割是数字图像处理关键技术,是图像后续处理的基础^[1]。目前主要有4大类图像分割算法:基于边界的图像分割、基于灰度阈值的图像分割、基于区域的图像分割和基于聚类的图像分割,其中基于聚类的图像分割是将图像像素点当作数据处理,通过把不同的像素点聚到不同类中,实现图像的有效分割,此类分割算法不需要考虑图像的形状和边界,且可以将高维图像数据降到低维空间进行处理,分割方法稳定简便。在聚类算法中K均值聚类算法是解决聚类分析问题的经典算法,常应用于图像分割^[2]。但由于K均值聚类算法敏感于初始值和易受孤立点影响,容易陷入局部最优,并且全局搜索能力较弱,这些致命点严重影响图像分割的准确度^[3]。人工蜂群(Artificial Bee Colony Algorithm, ABC)算法是新兴的基于群体智能启发式算法,其具有设置简单、全局寻优强、易于实现等优点,与经典遗传算法、粒子群算法、蚁群算法相比,在全局寻优和寻优精度方面优于前几种算法^[4-5]。因此,许多学者将优化算法与聚类算法进行融合,发挥各自的优点,解决实际应用问题。文献[6]利用遗传算法优化K均值聚类算法,减少K均值聚类算法对初始值的依赖;文献[7]提出一种基于动态粒子群优化与K-均值聚类的图像分割算法,提高了图像分割质量和效率;文献[8]提出了一种基于改进蜂群优化投影寻踪与K最近邻的检测方法,提高了高光谱遥感图像小目标无监督检测方法的运算速度,降低了虚警率;文献[9]利用密度和距离初始化蜂群,并将聚类算法作为工蜂的一种编码,增强算法的局部搜索能力;文献[10]通过对人工蜂群更新位置公式,构造新的K均值适应度函数,获得了较好的寻优结果;文献[11]提出一种结合人工蜂群算法和K均值聚类的全局邻域聚类算法,算法利用人工蜂群具有收敛速度快的特性提高聚合速率;文献[12]对人工蜂群算法中的蜂群初始化和蜜源更新进行改进,并对K均值进行优化,

提高了K均值聚类的准确率;文献[13]将改进的人工蜂群算法和K均值算法迭代相结合,提出一种基于K均值的人工蜂群聚类算法,通过对邻域搜索范围的动态调整,提高算法的收敛速度,增强局部寻优能力;文献[14]通过增强人工蜂群算法搜索能力优化K均值聚类,提高了文本聚类质量。文献[15]提出了一种结合人工蜂群和K-均值的混合聚类算法,算法对人工蜂群算法进行改进,增加线性调整策略,并与收敛速度快的K均值算法相结合,来提高算法的鲁棒性。对人工蜂群和K均值聚类算法不同途径、角度的改进和结合,效果差异化较大,仍然存在搜索不高、收敛速度过慢等问题。而且,基于人工蜂群算法的图像处理研究还处于起步阶段,特别是将人工蜂群优化的K均值应用于图像分割的研究还较为匮乏。基于此,本文融合自适应人工蜂群和K均值聚类,提出了一种新的图像分割算法。

2 相关算法

2.1 人工蜂群算法

人工蜂群算法是Karaboga提出的一种基于蜜蜂群体的仿生智能优化算法,算法通过模拟蜂群分工寻找最优蜜源来求解最优问题^[4],由于其收敛速度较快、控制参数少、易于实现等优点,被广泛应用与最优求解中。函数优化测试实验表明,人工蜂群算法比遗传算法、差分演化算法和粒子群优化算法有更好的性能^[16]。自然界中,在复杂环境下蜂群通过分工合作进行蜜源寻找,蜜源的位置决定可行解的质量。现实生活中,蜂群中的引领蜂外出搜索蜜源,在找到蜜源后,引领蜂将蜜源的位置、含量等信息记录下来告知跟随蜂,跟随蜂根据蜜源优劣决定采蜜某个蜜源,并号召更多的蜜蜂进行采蜜,若某个蜜源即将枯竭或达到开采极限,则放弃该蜜源,相应的引领蜂转为侦查蜂角色,寻找新蜜源。人工蜂群算法的基本步骤如下:

步骤1:种群初始化。设种群大小为 n , n 个蜜源 $X = \{X_i \in R^d, i = 1, 2, \dots, n\}$,各个蜜源 X_i

是一个 d 维向量,最大循环次数为 MCN ;每个蜜源的最大开采次数为 $Limit$ 。计算每只蜜蜂的适应度值并按降序排列,一半作为引领蜂,另一半为跟随蜂。

步骤 2:根据公式(1)随机选择蜜源。

$$X_{ij} = X_{\min}^i + \text{rand}(0,1)(X_{\max}^j - X_{\min}^i). \quad (1)$$

步骤 3:根据公式(2)派出引领蜂在其近邻搜索,得到新的位置并计算其适应度值,比较两个解的优劣,保留质量较好的解。

$V_{ij} = X_{ij} + \text{rand}(-1,1)(X_{ij} - X_{kj})$, (2)
 V_{ij} 表示在 X_{ij} 附近新蜜源的位置,其中: $k \in \{1, 2, \dots, n\}$, k, i 是通过定义的随机公式产生的。引领蜂比较新蜜源 V_i 和原蜜源 X_i 的适应度,选择优者适应度进入下一代种群,保证种群不出现退化。

步骤 4:根据公式(3)计算当前每个引领蜂的概率,以此指导跟随蜂选择引领蜂。

$$P_i = f_i / \sum_{i=1}^n f_i. \quad (3)$$

步骤 5:引领蜂更新完蜜源后,跟随蜂根据引领蜂传递的蜜源适应度值选择所要跟随的引领蜂,并根据公式(2)在邻域内搜索更新蜜源,通过比较选择较好的蜜源前往采蜜。

步骤 6:某蜜源的搜索次数达到最大开采次数 $Limit$,但蜜源适应度不再变化时,放弃该蜜源。同时,将引领蜂转换为侦察蜂。

步骤 7:判断是否达到最大迭代次数或满足循环终止条件。若是,算法结束并输出适应度最好的蜜源作为最优解。若不是,返回步骤 2。

2.2 K 均值聚类算法

K 均值算法是依据参数 K 将给定数据集划分成 K 个簇,以每个点到其聚类中心的距离为目标函数,使用求解函数极值方式反复迭代,直到目标函数收敛。 K 均值聚类是解决聚类问题的经典算法^[2]。设聚类样本为 $X = \{X_i \in R^d, i = 1, 2, \dots, n\}$, X_i 为 d 维向量;聚类样本的划分 $C = \{C_1, C_2, \dots, C_k\}$, k 为聚类中心个数。

K 均值聚类目标函数为:

$$J = \sum_{j=1}^k \sum_{X_i \in C_j} d(X_i, C_j). \quad (4)$$

K 均值聚类中心为:

$$C_j = \frac{1}{n_j} \sum_{i=1}^{n_j} X_i \quad j = 1, 2, \dots, k, \quad (5)$$

其中: $d(X_i, C_j)$ 是数据点 X_i 到所属类中心 C_j 的

欧式距离; n_j 是第 j 组分类的数据点个数。

2.3 两种算法缺点

K 均值算法思路简洁,局部寻优能力强、聚类速度较快,但也存在致命的缺点,比如敏感于初始中心,极易陷入局部最优,易受孤立点和噪声点的影响。人工蜂群算法本质上是利用群体的差分向量完成个体的寻优。但随着种群的不断缩小,种群内个体间的差异化越来越小,算法的搜索能力会随迭代次数的增加而降低,也容易陷入局部最优。并且,人工蜂群算法后期收敛较慢。

人工蜂群算法采用公式(2)实现引领蜂和跟随蜂邻域搜索,其中 $\text{rand}(-1,1)$ 是区间 $[-1,1]$ 的随机数,用于控制邻域搜索范围。如果在算法进化初期找不到最优蜜源,而随机产生的 $\text{rand}(-1,1)$ 却比较小,就会导致算法的全局寻优能力下降;如果算法在进化后期已经在最优蜜源附近,随机产生的 $\text{rand}(-1,1)$ 却比较大,就会导致算法产生震荡,效率降低。

本文通过对种群初始化、位置更新以及收敛速度等 3 个方面对人工蜂群算法进行改进,克服原有算法的缺陷。利用距离最大最小乘积算法初始化种群,使用距离乘积来放大点与点的差异,在稀疏初始点分布的同时,尽可能选取点密度大的;采用自适应搜索策略对公式(2)进行改进,通过不同时期动态调整 $\text{rand}(-1,1)$,自适应扩大或缩小搜索范围,精确更新位置;在得到最优解后对其进行 Powell 局部搜索,加快算法收敛的速度。

3 改进人工蚁群算法

3.1 自适应搜索策略

文章采用自适应搜索策略对公式(2)进行改进,可根据算法不同进化期对 $\text{rand}(-1,1)$ 的大小进行动态调整:

$$V_{ij} = X_{ij} + \delta \text{rand}(-1,1)(X_{ij} - X_{kj}), \quad (6)$$

其中: δ 为邻域搜索范围调整系数,计算方式为:

$$\delta = \begin{cases} \delta_{\min} - \frac{(\delta_{\max} - \delta_{\min}) \times (f_i - f_{\min})}{f_{\text{avg}} - f_{\min}}, & f_i \leq f_{\min} \\ \delta_{\max}, & f_i > f_{\min} \end{cases}, \quad (7)$$

其中: $\delta_{\max}, \delta_{\min}$ 为常数,用以控制邻域搜索范围。

f_i 为第 i 个蜜源的适应度值; f_{avg} 为当前所有蜜源的平均适应度, f_{min} 为当前所有蜜源的最小适应度。 δ 会随着 f_i 、 f_{avg} 和 f_{min} 的变化自动调整, 从而使 $\delta rand(-1, 1)$ 随之变化, 以此改变邻域搜索范围。当在算法迭代初期, 调整 δ 使 $\delta rand(-1, 1)$ 相对变大, 实现大范围搜索, 快速逼近最优解; 在算法迭代后期, 调整 δ 使 $\delta rand(-1, 1)$ 相对变小, 实现局部搜索, 加快收敛。

3.2 基于距离最大最小乘积初始化种群

无论 K 均值算法还是人工蜂群算法都敏感于种群的初始化, 而随机性的初始化可能会导致算法迭代的波动性, 种群初始化的优劣影响着算法的收敛速度和最优解的质量。文章在文献[17]的基础上提出一种新的基于距离最大最小乘积初始化蜂群方法。文献[17]提出了基于最大最小距离法解决最大最小距离法中初始点选取过于密集等问题。算法通过密度参数找到集合 S_n 中两个密度最高的中心 C_1 和 C_2 , 计算去除 C_1 和 C_2 的集合 S'_n 到 C_1 和 C_2 的距离, 满足 $\max(d(x_1, C_1) \times d(x_1, C_2) \times \dots \times d(x_1, C_{k-1}))$ 的点即为 C_k , 依次得到 k 个初始节点。但是此方法在遇到距离积相等或区域内节点密度相差较大时, 影响算法的稳定性, 并且需要手动设置密度参数。为了避免手动设置密度参数对初始种群的影响, 平稳算法的稳定性, 本文改进文献[17]提出的初始化种群算法, 提出了一种基于距离最大最小乘积初始化种群方法。设种群集合为 S , 种群数量为 Num , 选取节点数量为 k , C 为存放初始节点的集合, $Temp$ 为存放集合 S 中元素到集合 C 中元素相乘结果的临时数组。基本步骤如下:

步骤 1: 随机选择个初始点作为中心点 C_1 , 从集合 S 删除, 加入到集合 C 中;

步骤 2: 计算集合 S 中所有元素到 C_1 的距离, 将距离 C_1 最远的点 C_2 加入集合 C 中;

步骤 3: 计算集合 S 中所有元素与集合 C 中各元素的距离乘积, 存入临时数组 $Temp$, 将集合 S 中所有元素对应的临时数组 $Temp$ 中最大最小值乘积进行比较, 将乘积最大值所对应的节点作为下一个初始节点, 将其加入集合 C 中;

步骤 4: 判断初始节点是否达到 k 个, 若是则结束算法, 输出初始节点序列, 若没有, 则转到步骤 3。

通过改进文献[17]算法, 可以避免手动输入

最大距离积中的密度参数, 通过比较集合 S 中所有元素对应的临时数组 $Temp$ 中最大最小值乘积稀释初始点分布, 从而选取密度较大的节点, 利用乘积选取初始节点不仅可以放大节点间的差异, 还能提高算法的稳定性和健壮性。

3.3 Powell 局部搜索

Powell 算法是利用共轭方向可以加快收敛的一种搜索算法。该方法即使在目标函数导数不连续时也能应用, 并且不需要计算梯度, 搜索精度较高。Powell 算法基本步骤如下:

步骤 1: 根据基于距离最大最小乘积初始化种群结果, 设定初始点为 $c^{(0)}$, 搜索精度 ϵ , 一般取 m 个坐标轴方向为人工蜂群无关搜索方向 $d^{(i)}$ ($i = 0, 1, 2, \dots, m-1$), $j = 0$;

步骤 2: 令 $c^{(0)} = c^{(j)}$, 从 $c^{(0)}$ 开始依次沿 $d^{(i)}$ ($i = 0, 1, 2, \dots, m-1$) 搜索方向进行一维搜索, 可得 $c^{(i)}$ ($i = 1, 2, \dots, m$):

$$f(c^{(i)} + \omega_i d^{(i)}) = \min f(c^{(i)} + \omega d^{(i)}), \quad (8)$$

$$c^{(i+1)} = c^{(i)} + \omega_i d^{(i)}, \quad (i = 0, 1, 2, \dots, m), \quad (9)$$

式中 ω 为步长, 线性搜索得到的 ω_i 为一维最优化解;

步骤 3: 设 $d^{(m)} = c^{(m)} - c^{(0)}$, 假如 $\|d^{(m)}\| \leq \epsilon$, 求得解 $c^{(m)}$ 后结束计算; 否则, 从 $c^{(m)}$ 出发沿 $d^{(m)}$ 方向进行线性搜索直到得到 $c^{(m+1)}$;

步骤 4: 确定搜索方向, 按照以下公式(10)计算指标 t :

$$f(c^{(i)}) - f(c^{(i+1)}) = \max_{0 \leq i \leq m-1} \{f(c^{(i)}) - f(c^{(i+1)})\}. \quad (10)$$

步骤 5: 判断 $f(c^{(0)}) - 2f(c^{(m)}) + f(2c^{(m)} - c^{(0)}) < 2[f(c^{(i)}) - f(c^{(i+1)})]$ 是否成立, 若成立执行步骤 6, 否则执行步骤 7;

步骤 6: 说明 $d^{(0)}, d^{(1)}, \dots, d^{(m-1)}$ 线性相关, 调整搜索方向, 从点 $c^{(m)}$ 出发沿 $d^{(m)}$ 进行一维搜索, 求得 ω_m , 使 $f(c^{(m)} + \omega_m d^{(m)}) = \min f(c^{(m)} + \omega d^{(m)})$, 令 $c^{(j+1)} = c^{(m)} + \omega_m d^{(m)}$, $d^{(j)} = d^{(j+1)}$ ($j = t, t+1, \dots, m-1$), $j = j+1$, 返回步骤 2;

步骤 7: 说明 $d^{(0)}, d^{(1)}, \dots, d^{(m-1)}$ 线性无关, 不调整搜索方向, 令 $c^{(j+1)} = c^{(m)}$, $j = j+1$, 返回步骤 2。

3.4 改进人工蜂群算法

通过 3 个方面的改进, 文章提出了一种基于融合人工蜂群和 K 均值聚类算法。算法利用距

离最大最小乘积初始化种群,对初始种群进行聚类,计算每只蜜蜂适应度值,以此划分引领蜂和跟随蜂,然后引领蜂位置搜索获取蜜源,根据引领蜂蜜源信息计算招募跟随蜂概率,跟随蜂根据概率选择引领蜂后利用公式进行蜜源搜索对比,将所有跟随蜂所搜索的蜜源进行 K 均值聚类,将聚类划分结果进行 Powell 局部搜索,将得到的新聚类中心更新蜂群中蜜源位置,如此反复,直到算法结束。整体算法的步骤如下:

步骤 1:初始化引领蜂、跟随蜂以及侦察蜂数量,设引领蜂和跟随蜂数量相等,最大循环次数为 MCN ;每个蜜源的最大开采次数为 $Limit$,当前迭代次数为 $Cycle$,聚类个数为 k ;

步骤 2:利用距离最大最小乘积初始化种群,得到 $\{C_1, C_2, \dots, C_k\}$ 个初始蜂群;

步骤 3:对 $\{C_1, C_2, \dots, C_k\}$ 初始蜂群中的每只蜜蜂计算其适应度值并按降序排列,对半划分为引领蜂和跟随蜂;

步骤 4:引领蜂根据公式(2)进行搜索获取新蜜源,如果新蜜源比原蜜源的适应度函数值大,保留新蜜源,否则保持原蜜源;

步骤 5:当所有引领蜂根据公式(2)进行蜜源搜索后,根据引领蜂当前所获取的蜜源信息利用公式(3)计算招引跟随蜂概率 P_i ;

步骤 6:跟随蜂基于轮盘赌选择引领蜂,引领蜂招引跟随蜂的多少由概率 P_i 决定。跟随蜂选择引领蜂后根据公式(2)进行邻域搜索,选择质量好的蜜源并保存信息;

步骤 7:当所有跟随蜂完成迭代搜索后得到新蜜源对应的中心,对保存的所有蜜源中心进行 K 均值聚类,对当前群体中的最优蜜源位置按照改进的 Powell 算法进行局部搜索,得到最新的聚类中心点以此更新蜂群中蜜源位置;

步骤 8:当某引领蜂迭代次数超过最大开采次数 $Limit$ 后,判断是否存在有未更新的蜜源,若无则舍弃此蜜源,由侦察蜂随机产生新蜜源取代原蜜源;

步骤 9:判断是否达到最大循环次数 MCN ,若是结束算法,否则转到步骤 3。

通过上文分析知道,本文改进算法与人工蜂群算法相比具有更强的全局寻优能力,能更快逼近全局最优,算法前期利用距离最大最小乘积初始化种群,对初始种群进行聚类,将所有

跟随蜂所搜索的蜜源进行 K 均值聚类,寻找全局最优解,实现算法快速寻优,当算法局部寻优陷入困境时,利用 Powell 局部搜索对聚类划分结果进行精细搜索,将得到的新聚类中心更新蜂群中蜜源位置。

算法是否已逼近全局最优解或进化缓慢,可通过蜜源群体适应度方差进行判断。在算法寻优前期,蜜源 i 的适应度计算公式为:

$$f_i = \sum_{i=1}^n \sum_{j=1}^d \|X_i - C_j\|^2, \quad (11)$$

设 σ^2 为蜜源群体适应度方差,计算公式如下:

$$\sigma^2 = \sum_{i=1}^n (f_i - f_{avg})^2. \quad (12)$$

在算法迭代过程中,随着蜜源的不断更新, f_i 与 f_{avg} 之间的差异逐渐变小。当所有蜜源的适应度从整体上不再变化时, σ^2 会缩小到某个范围。因此, σ^2 反映了所有蜜源的收敛程度。

3.5 改进人工蜂群算法的有效性

为了验证本文改进算法的有效性,使用标准函数对本文改进人工蜂群算法和其他寻优算法进行测试。实验环境为 Intel(R) Core(TM) i5-2520M CPU @ 2.5 GHz、4G RAM、Matlab R2013a。参数设置如下:种群大小为 100,个体维数为 5,最大开采次数 $Limit$ 为 20,最大循环次数 $MCN=500$,搜索精度 $\epsilon=0.000\ 01$ 。人工蜂群算法和本文改进算法均在同一条件下执行 20 次。测试函数及其参数设置如表 1 所示。

表 1 标准测试函数参数设置

Tab.1 Standard test function parameter setting

函数名称	维数	搜索区间	全局最优值
Sphere	20	$[-100, 100]$	0
Griewank	20	$[-600, 600]$	0
Rastrigrin	20	$[-5.12, 5.12]$	0
Rosenbrock	20	$[-100, 100]$	0

本研究在测试时,记录了人工蜂群算法和本文改进算法迭代过程比较图、输出最优解和单次运行时间,如图 1 所示。

通过图 1 曲线可知,对于 Sphere 函数,人工蜂群算法和本文改进算法分别在经过了大约 300 次和 200 次迭代后不再进化,两者的全局最优值分别为 $1.363\ 15E-15$ 和 $7.3860\ 3E-17$;对于 Rastrigrin 函




图1 两种算法寻优收敛曲线

Fig.1 Optimal convergence curve of two algorithms

数,人工蜂群算法和本文改进算法分别在经过了大约380次和240次迭代后不再进化,两者的全局最优值分别为 $3.920\ 89\text{E-}10$ 和 $2.842\ 14\text{E-}14$;对于Rosenbrock函数,人工蜂群算法和本文改进算法分别在经过了大约360次和200次迭代后不再进化,两者的全局最优值分别为 $6.884\ 98$ 和 $0.580\ 009$,结果表明在对Sphere、Rastrigrin和Rosenbrock函数的测试中,本文改进算法比人工蜂群算法能更快找到更优值。对于Griewank函数,人工蜂群算法和本文改进算法分别在经过了大约250次和400次迭代后不再进化,两者的全局最优值分别为 $0.010\ 052\ 8$ 和 $5.783\ 89\text{E-}8$,本文改进算法的最优值远比人工蜂群算法更好。

表2 两种算法的性能比较

Tab2 Performance comparison of two algorithms

测试函数	算法	平均运行时间/ms	平均最优值
Sphere	人工蜂群	592	$5.253\ 51\text{e-}16$
	本文改进算法	413	$0.738\ 40\text{e-}17$
Griewank	人工蜂群	812	$0.054\ 557\ 3$
	本文改进算法	779	$1.210\ 44\text{e-}4$
Rastrigrin	人工蜂群	659	$0.857\ 331$
	本文改进算法	599	$0.009\ 180\ 96$
Rosenbrock	人工蜂群	628	$5.476\ 62$
	本文改进算法	561	$2.249\ 89$

为说明人工蜂群算法和本文改进算法性能,在相同参数情况下,本研究统计并计算了本文改进算法和人工蜂群两种算法在 20 次实验中的平均运行时间和平均最优值,如表 2 所示。

从表 2 可以看出,在相同参数设置情况下,本文改进算法对 4 种函数的平均运行时间均比人工蜂群算法少,而且可以找到更优解。

以上结果表明本文改进算法比人工蜂群算法具有更高的执行效率和更强的全局寻优能力。

4 基于本文改进算法的图像分割

为了验证本文所提算法的性能,将本文改进算法与文献[18]、文献[19]等同类图像分割算法对 4 幅不同的实验图像进行分割并进行对比。4 幅实验图像分别为 Lena(256×256)、Orchid(128×100)、Speaker(128×128)、Sperm(182×194)。分割准确率评价准则一般使用杰卡德相似系数进




图 2 三种分割算法结果

Fig.2 Results of three segmentation algorithms

行定量分析^[20],公式如下:

$$\text{面积准确率} = \frac{\text{card}(P \cap Q)}{\text{card}(P \cup Q)}, \quad (13)$$

式中: P 为真实标准分割集合, Q 为算法分割结

果集合, $\text{card}(\cdot)$ 表示集合中的元素,面积准确率取值于 $[0,1]$ 之间,其值越大表明分割的效果越好,分割结果如图3所示。




图3 四种算法对红外图像的分割结果

Fig.3 Results of four algorithms for infrared image segmentation

图2第一列为实验原图;第二列至第四列分别为文献[18]、文献[19]和本文算法的分割结果。

对于Lena的分割,本文算法在Lena帽顶和肩膀头发处(如图中箭头所指)的分割结果要比文献[18]、文献[19]算法更加清晰、细致;对于Orchid图像的分割,文献[18]和文献[19]算法的分割结果丢失了叶片部分细节(如图中方框、圆形及三角形标注区域);而本文算法能精准区分花瓣和叶片的轮廓,分割结果与原图原貌高度一致;对于Speaker图像的分割,文献[18]、文献[19]算法的分割结果丢失了扬声器的部分细节,比如扬声器的悬边、防尘盖波纹(如图中箭头所指),而本文算法能分割到这些细节,但也不够细致;对于Sperm图像的分割,本文算法体现出了较为精准的分割水平,在细节分割和轮廓保持上均优于其他两种算法。

为定量分析比较3种算法图像分割的优劣,文章对4幅图像分别重复20次分割实验,计算平均运行时间,结果如表3所示。

表3 三种算法的分割准确率和平均运行时间

Tab.3 Segmentation accuracy and average running time of the three algorithms

图像名称	文献[18]		文献[19]		本文算法	
	准确率 /%	耗时 /ms	准确率 /%	耗时 /ms	准确率 /%	耗时 /ms
Lena	74.9	468	76.7	608	79.5	585
Orchid	77.3	389	78.4	512	81.2	494
Speaker	70.6	354	71.8	492	75.4	467
Sperm	80.1	317	82.3	448	85.6	429

从表3可以看出,在对4幅图像进行分割时,文献[18]算法平均运行时间最少,这是由于算法只是对标准人工蜂群算法较为简单的改进,对位置更新时增加了学习因子,一定程度上提高了搜索精度;本文算运行平均时间要少于文献[19],但就准确率来讲,本文算法图像分割的准确率明

显好于其他两种算法,分割准确率比其他两种算法分别至少提高了 3.5% 和 4.8%。文献[19]利用随机权重粒子群优化全局搜索,同样也利用 K 均值聚类实现快速收敛,但是本文算法前期利用距离最大最小乘积初始化种群,对初始种群进行聚类,将散乱的种群数据聚集化,同时将聚类划分后的结果再次进行 Powell 局部搜索,在实现精细化局部搜索的同时加速收敛,获得了较为细致的分割结果

红外图像是利用红外热像仪接受来自目标和景物的红外辐射,经过光电转换,将不可见的辐射转变成可见的图像,图像的各像素点的明暗(亮度)变化对应着目标物体辐射能量的强弱。这就造成红外图像像素分辨率低、边缘模糊、对比度较差。图像分割可以快速获得红外图像的显著信息,为准确提取红外区域信息打下基础。为了检验本文算法对分辨率较低的红外图像的分割效果,选取 4 幅不同的红外图像进行分割,并将本文算法与其他算法做对比分析,实验结果如下:

图 3 第一列为红外原图;第二列至第五列分别为文献[18]、文献[19]、文献[21]和本文算法的分割结果。文献[18]算法不能很好地处理红外原图中的噪声和混叠分布,算法没能有效地将目标和背景区分开来;文献[19]较好地处理了灰度的混叠,但对于目标的边缘定位处理的不是很精确,

致使分割目标不完整,如对第四幅红外图像的分割;文献[21]较好地处理了红外原图中的噪声、混叠分布和边缘模糊,分割的效果比前两种算法好,能较为准确地地区分目标与背景,但没能有效地遏制对比度较差区域噪声点的影响,致使分割结果中出现了噪声污染点,如第二幅和第四幅中出现了白点;本文算法体现出了较为精准的分割水平,不仅较好地处理原图中混叠分布,还能准确地定位边缘,抑制噪声点,分割效果优于其他 3 种算法。

5 结束语

本文针对 K 均值聚类和人工蜂群算法缺点,提出了一种融合改进人工蜂群和 K 均值聚类的图像分割算法。算法利用距离最大最小乘积初始化种群,解决人工蜂群算法迭代的波动性,采用自适应搜索参数动态调整邻域搜索范围,使人工蜂群算法快速收敛于全局最优,最后将所有跟随蜂所搜索的蜜源进行 K 均值聚类,将聚类划分结果进行 Powell 局部搜索,提高收敛的速度和精度。将算法应用于图像分割中,与改进的人工蜂群分割算法和随机权重粒子群和 K -均值聚类的分割算法相比,本文的分割结果能有效保持轮廓骨架,细节分割较为精确。

参 考 文 献:

- [1] SONKA M, HLAVAC V, BOYLE R, *et al.* Image processing, analysis and machine vision [J]. *Journal of Electronic Imaging*, 1996, 5(3): 423.
- [2] MACQUEEN J. Some methods for classification and analysis of multivariate observations [C]//*Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability*. Berkeley: University of California Press, 1967: 281-297.
- [3] ISA N A M, SALAMAH S A, NGAH U K. Adaptive fuzzy moving K-means clustering algorithm for image segmentation [J]. *IEEE Transactions on Consumer Electronics*, 2009, 55(4): 2145-2153.
- [4] KARABOGA D, BASTURK B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm [J]. *Journal of Global Optimization*, 2007, 39(3): 459-471.
- [5] KARABOGA D, AKAY B. A modified artificial bee colony (ABC) algorithm for constrained optimization problems [J]. *Applied Soft Computing*, 2011, 11(3): 3021-3031.
- [6] 柳景青, 郭东进, 叶萍. 改进的给水管网节点 K 均值空间聚类[J]. *浙江大学学报(工学版)*, 2015, 49(11): 2128-2134.
- [7] LIU J Q, GUO D J, YE P. Improved K average spatial clustering method for nodes of water distribution system [J]. *Journal of Zhejiang University (Engineering Science)*, 2015, 49(11): 2128-2134. (in Chinese)
- [7] LI H Y, HE H Z, WEN Y G. Dynamic particle swarm optimization and K-means clustering algorithm for image

- segmentation [J]. *Optik-International Journal for Light and Electron Optics*, 2015, 126(24): 4817-4822.
- [8] 吴一全,周杨,龙云淋.基于蜂群优化投影寻踪的高光谱小目标检测[J].仪器仪表学报,2016,37(6):1347-1355.
WU Y Q, ZHOU Y, LONG Y L. Detection of hyperspectral small targets based on projection pursuit optimized by bee colony [J]. *Chinese Journal of Scientific Instrument*, 2016, 37(6): 1347-1355. (in Chinese)
- [9] 罗可,李莲,周博翔.一种蜜蜂交配优化聚类算法[J].电子学报,2014,42(12):2435-2441.
LUO K, LI L, ZHOU B X. A Honey-bee mating optimization clustering algorithm [J]. *Acta Electronica Sinica*, 2014, 42(12): 2435-2441. (in Chinese)
- [10] 喻金平,郑杰,梅宏标.基于改进人工蜂群算法的K均值聚类算法[J].计算机应用,2014,34(4):1065-1069,1088.
YU J P, ZHENG J, MEI H B. K-means clustering algorithm based on improved artificial bee colony algorithm [J]. *Journal of Computer Applications*, 2014, 34(4): 1065-1069, 1088. (in Chinese)
- [11] KRISHNAVENI V, ARUMUGAM G. The performance analysis of a novel enhanced artificial bee colony inspired global best harmony search algorithm for clustering [C]//*Proceedings of the International Conference on Information Systems Design and Intelligent Applications 2012 (INDIA 2012) held in Visakhapatnam, India*. Berlin Heidelberg: Springer, 2012: 21-28.
- [12] 曹永春,蔡正琦,邵亚斌.基于K-means的改进人工蜂群聚类算法[J].计算机应用,2014,34(1):204-207, 217.
CAO Y C, CAI Z Q, SHAO Y B. Improved artificial bee colony clustering algorithm based on K-means [J]. *Journal of Computer Applications*, 2014, 34(1): 204-207, 217. (in Chinese)
- [13] 柯钢,杨俊.基于增强蜂群优化与K-means的文本聚类算法[J].计算机应用研究,2016,33(8):2298-2302.
KE G, YANG J. Enhanced bee colony optimal and K-means based document clustering algorithm [J]. *Application Research of Computers*, 2016, 33(8): 2298-2302. (in Chinese)
- [14] 毕晓君,宫汝江.一种结合人工蜂群和K均值的混合聚类算法[J].计算机应用研究,2012,29(6):2040-2042,2046.
BI X J, GONG R J. Hybrid clustering algorithm based on artificial bee colony and K-means algorithm [J]. *Application Research of Computers*, 2012, 29(6): 2040-2042, 2046. (in Chinese)
- [15] 李莲,罗可,周博翔.一种改进人工蜂群的K-medoids聚类算法[J].计算机工程与应用,2013,49(16):146-150.
LI L, LUO K, ZHOU B X. K-medoids clustering algorithm based on improved artificial bee colony [J]. *Computer Engineering and Applications*, 2013, 49(16): 146-150. (in Chinese)
- [16] 熊忠阳,陈若田,张玉芳.一种有效的K-means聚类中心初始化方法[J].计算机应用研究,2011,28(11):4188-4190.
XIONG Z Y, CHEN R T, ZHANG Y F. Effective method for cluster centers' initialization in K-means clustering [J]. *Application Research of Computers*, 2011, 28(11): 4188-4190. (in Chinese)
- [17] 宋锦,高浩,王保云.改进人工蜂群算法在图像分割中的应用[J].电视技术,2016,40(8):8-14,25.
SONG J, GAO J, WANG B Y. Multilevel image segmentation based on improved artificial colony algorithm [J]. *Video Engineering*, 2016, 40(8): 8-14, 25. (in Chinese)
- [18] 李海洋,文永革,何红洲,等.基于随机权重粒子群和K均值聚类的图像分割[J].图学学报,2014,35(5):755-761.
LI H Y, WEN Y G, HE H Z, et al. An image segmentation algorithm based on random weight particle swarm optimization and K-means clustering [J]. *Journal of Graphics*, 2014, 35(5): 755-761. (in Chinese)
- [19] 李彬,刘同.基于D-S证据理论的多发性硬化症病灶分割算法[J].计算机应用研究,2011,28(1):378-380.
LI B, LIU T. Segmentation of multiple sclerosis lesions based on D-S evidence theory [J]. *Application Research of Computers*, 2011, 28(1): 378-380. (in Chinese)
- [20] WEI S, HONG Q, HOU M S. Automatic Image segmentation based on PCNN with adaptive threshold time constant [J]. *Neurocomputing*, 2011, 74(9): 1485-1491.

作者简介:赵文昌(1979—),男,云南剑川人,硕士,讲师,主要从事图形图像处理与模式识别方面的研究。Email: zhao-wenchang79@126.com

李忠木(1980—),男,云南楚雄人,博士,教授,主要从事天体物理与图像处理方面的研究。