

面向医学图像分割的蚁群密度峰值聚类

朱 红¹, 何瀚志¹, 方谦昊¹, 代 岳², 姜代红³

(1. 徐州医科大学医学信息学院, 江苏 徐州 221004)

(2. 徐州医科大学附属医院影像科, 江苏 徐州 221002)

(3. 徐州工程学院信电工程学院, 江苏 徐州 221008)

[摘要] 在医学图像分割研究中, 针对密度峰值聚类算法(density peaks clustering algorithm, DPC), 依靠先验知识给定截断距离 d_c 且人工选择聚类中心点具有主观随意性等缺陷, 提出了一种结合蚁群算法选取密度峰值聚类最优参数的医学图像分割方法. 该算法首先利用蚁群算法全局性和鲁棒性的优点, 使用图像熵计算信息素来指导蚁群的搜索路径; 再使用变量量化表示聚类中心个数, 蚁群通过迭代选择最优截断距离 d_c 和聚类中心, 实现了 DPC 算法的自适应分割并得到了较好的分割效果. 仿真实验分析证明了算法的有效性和实用性.

[关键词] 医学图像分割, 密度峰值, 聚类中心, 蚁群算法, 信息素

[中图分类号] TP18 [文献标志码] A [文章编号] 1001-4616(2019)02-0001-08

Ant Colony Algorithm and Density Peaks Clustering for Medical Image Segmentation

Zhu Hong¹, He Hanzhi¹, Fang Qianhao¹, Dai Yue², Jiang Daihong³

(1. School of Medical Information, Xuzhou Medical University, Xuzhou 221004, China)

(2. Radiology Department, The Affiliated Hospital of Xuzhou Medical University, Xuzhou 221002, China)

(3. School of Information and Electrical Engineering, Xuzhou Institute of Technology, Xuzhou 221008, China)

Abstract: In the medical image segmentation research, a medical image segmentation method based on ant colony algorithm for selecting the optimal parameters of density peaks clustering (DPC) was proposed. For some defects in DPC algorithm, such as cut-off distance d_c was given by DPC algorithm relied on prior knowledge, subjective randomness in cluster centers was selected by manual work. First, the algorithm took advantages of the overall robustness of the ant colony algorithm, used image entropy to calculate pheromone to guide the search path of ant colony. Then it was quantified the number of cluster centers by using variable quantification instead, and ant colony selected the optimal truncation distance d_c and cluster centers by iteration, and realized the adaptive segmentation of DPC algorithm and obtained better results. Simulation experiments proved the effectiveness and practicability of this algorithm.

Key words: medical image segmentation, density peaks, cluster centers, ant colony algorithm, pheromone

医学图像分割是针对医学研究和临床应用的需要, 从医学图像中分割出感兴趣的病灶区域或特定组织的技术与过程. 有效的医学图像分割能够辅助医生诊断, 有效减少误诊率和漏诊率, 在医学研究领域有着广泛的应用和重要的研究意义. 研究者致力于将新方法、新理念应用于医学图像分割领域, 将聚类算法应用于医学图像分割, 取得了较好的效果, 其中包括 K -means 算法^[1-2]、FCM 算法^[3-4]、AP 聚类算法^[5]等. 总的来说, 聚类分析较传统医学图像分割方法, 具有无监督性、高效性和自适应性, 但是由于医学图像具有灰度差异小、模糊性、复杂性以及个体差异性等特点, 目前为止没有哪一种聚类算法可以适用于所有医学图像.

国内外的研究人员对聚类分析进行了深入研究, 提出了各种有效的方法. 密度峰值算法是 Rodrigues 等人^[6]在 2014 年《Science》上提出的一种快速寻找和发现密度峰值的 (DPC) 聚类算法. 该算法能快速发

收稿日期: 2018-10-15.

基金项目: 国家自然科学基金项目 (61672522)、江苏省高等学校自然科学研究重大项目 (18KJA520012)、徐州市科技计划项目 (KC16SQ78).

通讯联系人: 朱红, 博士, 教授, 研究方向: 人工智能、医学图像处理、机器学习、粒度计算. E-mail: zhuhongwin@126.com

现任意形状数据集的密度峰值点(即类簇中心),且不需要迭代,类簇分配一步即可完成.然而 DPC 算法仍然存在局限性:一是参数截断距离 d_c 需由人为事先指定,在个人没有先验知识的情况下很难给定合适的值;二是对于聚类中心点的选择上,使用人工选取 (ρ_i, δ_i) 对应的决策图(Decision Graph)上同时具有相对较大的 ρ_i 和 δ_i 点的方法,简单的定性分析具有主观随意性.作者 Rodrigues 提到的聚类中心个数可以自动确定,但实际上并没有实现.针对以上两个方面的缺陷,一些研究人员对 DPC 算法做了不同方面的改进.文献[7]提出一种基于 DPC 的前列腺 KVCT 图像 3D 分割方法,首先将超像素和灰度-梯度共生矩阵扩展到三维,然后使用 DPC 进行第一次聚类去掉差异性较大的部分,最后进行第二次聚类,并去掉黏连部分得到细化结果.文献[8]提出基于局部空间密度峰值的图像分割算法,结合密度峰值捕捉图像内部局部结构特征,获得较为准确的区域分割结果,对比 K-means 和 FCM 算法,改进算法获得更好的效果.这些研究者提出的改进方法,存在着大量的距离计算,对数据量较大的聚类问题会形成很高的复杂度,对于医学图像的分割至今没有很好的方法.

群智能算法是以仿生学为基础,通过模拟自然过程,提出的解决优化问题的算法,诸如遗传算法(GA)^[9]、模拟退火算法(SA)^[10]、粒子群算法(PSO)^[11]等.蚁群算法(ant colony algorithm, ACA)^[12]是继这些智能优化算法之后的又一种应用于解决组合优化问题的启发式搜索算法,该算法具有分布式计算机制、较强的鲁棒性和易于与其他算法相结合等优势.由此,本文提出一种基于蚁群算法优化选取密度峰值聚类最佳参数阈值的医学图像分割算法.将截断距离 d_c 和聚类中心作为决策变量,使用图像熵生成信息素和构建适应度函数;最后将其与 K-means、AP 和遗传-密度峰值等典型聚类算法做比较.

1 理论基础

1.1 密度峰值算法

DPC 聚类算法的核心思想在于对聚类中心(Cluster Centers)的刻画上,作者认为聚类中心同时具有以下两个特点:本身的密度大,即它被密度均不超过它的邻居包围且与其他密度更大的数据点之间的“距离”相对更大.考虑待聚类数据集 $S = \{X_i\} \mid N_i = 1, (N \in \mathbf{N}^+)$, 根据上面两个特征,算法对数据集 S 中的每一个数据点 X_i 为其定义局部密度 ρ_i 和相对距离 δ_i . 这两个变量与数据点之间的距离 d_{ij} 相关.

数据点 X_i 的局部密度定义为:

$$\rho_i = \sum_j \chi(d_{ij} - d_c). \quad (1)$$

其中函数

$$\chi(x) = \begin{cases} 1 & x < 0; \\ 0 & x \geq 0. \end{cases} \quad (2)$$

式中,参数 $d_c > 0$ 是截断距离,需事先指定; $d_{ij} = \text{dist}(X_i, X_j)$ 表示数据点 i 和 j 之间的距离.

对于距离 δ_i 可以定义为:

$$\delta_i = \begin{cases} \min_{j: \rho_j \geq \rho_i} (d_{ij}), & i \geq 2; \\ \min_{j \geq 2} (d_{ij}), & i = 1. \end{cases} \quad (3)$$

即 δ_i 是数据点 i 和 j 的距离, j 是密度比数据点 i 高的所有点中距离 i 最近的数据点.使用决策图画出 ρ_i 和 δ_i 的分布情况,人工选取同时较大的 ρ_i 和 δ_i 作为聚类中心点,然后按照密度由大到小将剩余数据点归属到距离最近的类簇,最终得到聚类结果.

DPC 算法的具体流程如表 1 所示:

定义 i, j 均是数据集 S 中的点, j 是密度比数据点 i 高的所有点中距离 i 最近的点.

1.2 蚁群算法

蚁群算法(ACA)是意大利学者 Marco Dorigo 等人提出的一种仿生启发式搜索算法.蚂蚁的群体具有高度的自组织行为,他们在搜索食物的过程中释放一种信息素,来指导其他蚂蚁选择路径.信息素与路径长度成反比,当某一条路径上经过的蚂蚁数目越多时,该路径上所有蚂蚁留下的信息素浓度就越大,其他蚂蚁选择这条路径的概率就会越大,随着越来越多的蚂蚁选择该条路径,该路径的信息素强度会逐步增大,这种选

择过程便形成了一种信息素正反馈机制,蚁群总能快速找到一条通往食物源和蚁穴之间的最短路径。

表 1 DPC 算法流程

Table 1 The flow of DPC algorithm

DPC 算法
Input:数据集 S ,截断距离 d_c
Output: S 的聚类结果,样本分类数
1. Begin
2. Initial:给定截断距离 d_c
3. 将 S 中样本点 i 按照密度从大到小的顺序排列
4. 计算数据点间的距离 δ 和截断距离 d_c 范围内数据点个数 ρ ,画出 ρ - δ 决策图
5. Cluster _{number} = k %手动选择聚类中心 k
6. For $i = 1$ to n
7. If $\rho_j > \rho_i, \delta_j > \delta_i$
8. Cluster _{i} = Cluster _{j} ; %选取 ρ 和 δ 均较大的点为聚类中心
9. A[Cluster _{j}] = A[Cluster _{Result}]; %将选择的聚类中心保存在数组 A 中
10. Else
11. Cluster _{i} = i ; %按密度由大到小顺序将其余点依次指派给距离最近的簇
12. End If
13. End For
14. End

2 密度峰值医学图像分割方法

DPC 算法从提出以来一直用于处理数据点的聚类问题,本文将改进的 DPC 算法扩展到医学图像分割领域. 如果对高分辨率的医学图像直接聚类,耗时过长. 因此,DPC 算法在用于医学图像分割时,实际是对所有灰度值进行聚类. 对每一个灰度值都要定义其局部密度 ρ_i ,及其与其他更大密度峰值点间的距离即差值 δ_i ,局部密度 ρ_i 就是算法中的定义小于 d_c 内灰度值的点的累加值. 对医学图像进行预处理,提取图像灰度值,灰度直方图横坐标是灰度级,纵坐标是其出现的频率. 在这里计算每个点之间的相邻距离,以灰度个数的差值作为距离数据. 聚类中心定义为 δ_i 和 ρ_i 同时较大的点.

如图 1(a)选取一张哈佛全脑图中神经影像学入门(Neuroimaging Primer)模块异常组织(Abnormal Tissue)MRI 的案例图片,一张典型的颅脑转移性腺癌 T_2 WI 图片,可见病灶为 T_2 高信号(明亮),瘤周有水肿与坏死区即低密度灶(黑暗)环绕. 画出 ρ - δ 决策图并且人工选取 ρ_i 值和 δ_i 值都较大的点作为聚类中心(图 1(b)),得出聚类结果. 实验发现,不同于其他数据集,由于医学图像的复杂性,人工可选取的聚类中心较少,进行图像分割后定性分析的效果不佳. 给定不同的截断距离 d_c ,手工选取聚类中心点,发现分割效果图(图 1(c))不能清晰地体现出病灶和水肿部位,属于欠分割. 多次实验表明原算法对聚类中心点的选择敏感,不适用于医学图像分割.




图 1 手工选择聚类中心及分割效果

Fig. 1 Manual selection of cluster centers and segmentation effects

3 基于密度峰值聚类与蚁群算法的医学图像分割方法

以上测试结果表明,原始 DPC 算法在应用于医学图像分割过程中,不能自适应选择截断距离 d_c 且手工选择聚类中心点难以得到较好的聚类结果. 本文提出基于蚁群算法选取 DPC 最佳参数阈值的蚁群-密度峰值医学图像分割算法(density peaks clustering based on ant colony algorithm, ACA-DPC).

由于医学图像的复杂性、模糊性,噪声的干扰一直是医学图像分割的挑战性问题,噪声的存在会影响医学图像分割的质量,因此应当提前予以纠正. 对噪声大、图像模糊、边缘特征淹没的医学图像进行预处理,预处理使用基于空间域的图像增强技术,直接对图像的像素进行处理,形成灰度映射变换. 灰度变换(gray-scale transformation, GST)后的图像显示效果更加清晰,部分噪声减少,医学图像的病灶特征突出,达到了图像增强的目的,使模糊医学图像和含噪声图像更适合于分割应用^[13].

将蚁群算法同 DPC 医学图像分割算法结合起来关键要解决两个问题:一是如何选择蚁群搜索目标和定义域;二是如何定义蚁群食物参照物即信息素.

对密度峰值医学图像分割的参数寻优可理解为模拟蚁群行为的觅食过程. 首先计算每一个灰度值局部密度 ρ_i 及其距离 δ_i , 通过这两个变量来判断聚类中心,由此引入 γ_i :

$$\gamma_i = \rho_i * \delta_i. \tag{4}$$

γ_i 值越大越有可能是聚类中心,因此,将 γ_i 值降序排列,取前 k 个点为聚类中心点(如图 2(a)所示). 同时将截断距离 d_c 和聚类中心数 k 作为搜索目标(决策变量),使之对应蚁群算法中的 X 轴和 Y 轴. 对这两个参数进行迭代寻优,关键在于构建蚁群食物参照物(即信息素)来指导蚁群行为. 由于在数字图像处理中,图像灰度范围通常是 0~255 中的整数, d_c 的定义域根据文献[6]建议应使每个数据点的平均邻居个数不超过总数的 2%, 所以这里 d_c 取值 1~10 之间的数; k 代表的分类数应不小于 2 个分类,根据医学图像分割常识,分类数不宜过多,这里取值($2 \leq k \leq 40$).

然后针对蚁群算法的实验过程,按照蚁群算法规则,采用随机的搜索策略,并通过蒸发、转移和经过的路径上的增加来更新信息素的浓度,蚁群的每一代对应着一次信息素的更新,信息素越大,后来的蚂蚁选择该路径的几率也更大. 信息素更新的公式为:

$$\tau_{ij}(t+n) = (1-\rho)\tau_{ij}(t) + \Delta\tau_{ij}. \tag{5}$$

式中, t 是运行时间, n 是蚂蚁的坐标位置, τ_{ij} 是 (i, j) 上的信息素, ρ 是信息素蒸发系数.

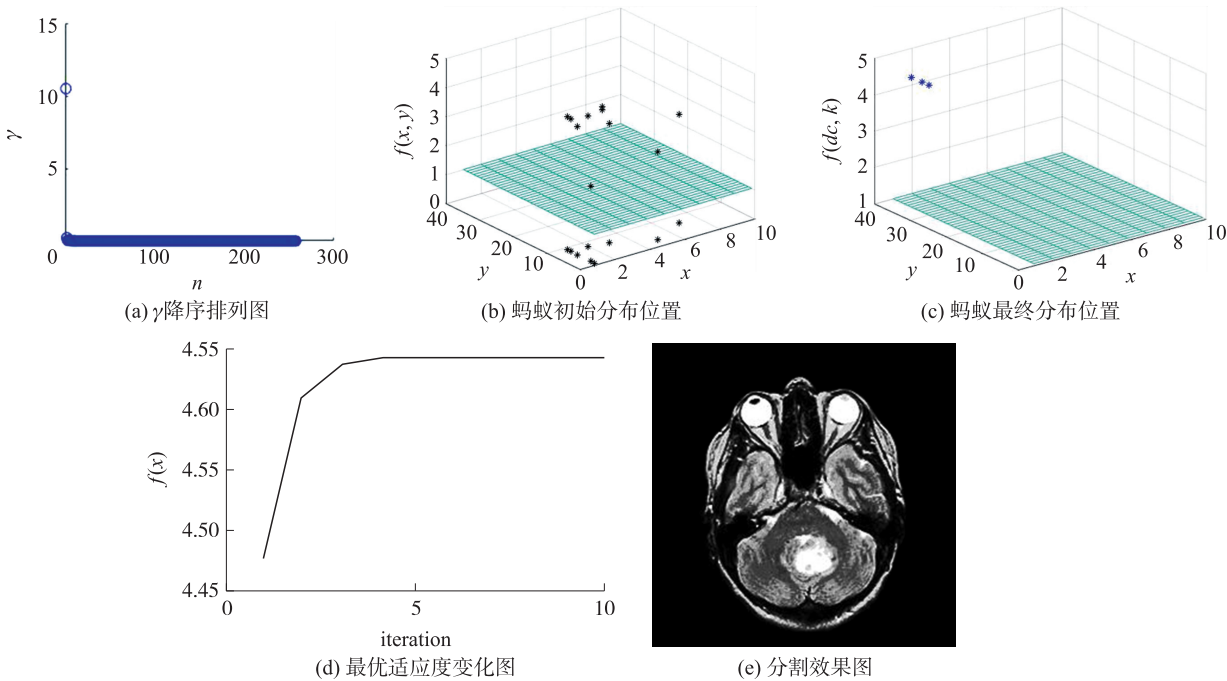


图 2 聚类中心的判断

Fig. 2 Decision of cluster centers

这里引入信息素函数(Pheromone Function)图像熵的定义. 图像熵是一种特征的统计形式^[14], 本文采用反映图像整体信息的一维熵, 用于表示图像中灰度分布的聚集特征所包含的信息量, 图像熵越高说明图像越清晰、内容越丰富. 灰度图像的一维熵的定义如式(6), 其中 p_i 表示灰度值为 i 的像素点在图像中出现的频率.

$$H = - \sum_{i=0}^{255} p_i \log p_i. \quad (6)$$

蚁群初始随机分布位置如图 2(b) 所示. 首先, 改进算法沿着 X 轴与 Y 轴蚁群分布的情况搜索当代蚁群在 DPC 上的局部最佳分割阈值, 不断迭代, 按照信息素更新情况, 蚁群将会更高概率地聚集在信息素更高的位置(如图 2(c)). 然后画出最优适应度变化趋势图(图 2(d)), 图中表明在迭代 5 次以后最佳信息素基本达到收敛. 多次实验, 参数值为 $d_c = 1, k = 15$ 时, 最优适应度值为 4.64. 最后将其余的灰度点归类到比他们的密度更大的最相近的类中心所属的类别中, 最终分割结果如图 2(e) 所示, 可以看出, 分割后的病灶、水肿部位依然清晰可见, 有助于医生做出判断.

基于蚁群算法的改进密度峰值的医学图像分割算法, 首先要对图像进行预处理, 包括读取医学图像、提取灰度值、计算图像灰度直方图, 对噪声大、边缘特征不明显的图像进行图像增强等. 具体分割步骤如表 2 所示.

表 2 ACA-DPC 算法流程
Table 2 The flow of ACA-DPC

基于蚁群密度峰值聚类的医学图像分割算法(ACA-DPC)	
Input: 医学图像, 蚁群规模 n , 迭代变量 NC , 迭代次数 NC_{\max} , 转移选择因子 P_0 , 信息素 τ_{ij} , 信息素增量 $\Delta\tau_{ij}$, 决策变量范围 $x(d_c, k)$	
Output: 最优阈值, 图像分割结果	
1. Begin	
2. Initial: 初始化 $n, NC, NC_{\max}, \tau_{ij}, \Delta\tau_{ij}, x$ 等参数, 随机产生第一代种群 pop ;	
3. While $NC \leq NC_{\max}$	
4. do {	
5. For $i = 1:n$ %对 n 只蚂蚁进行循环	
6. Fit(i) $\leftarrow \text{obj}(x, \rho_i, \delta_i)$ %计算种群 pop 中每一个体的适应度 fit(i);	
7. If 转移概率 $> P_0$	
8. 蚂蚁在临近区间位置选择转移	
9. Else If	
10. 不发生转移 }	
11. End If %结束对蚂蚁的循环	
12. End For	
13. do {	
14. 计算每代蚁群信息素浓度, 通过蒸发, 增强等规则更新(i, j)上的信息素;	
15. 并将结果记录到信息素数组(pheromone)中	
16. }	
17. $NC = NC + 1$	
18. End	
19. 返回最佳参数值和分割结果	

4 实验结果与分析

4.1 实验设计

4.1.1 实验环境和数据集

本文实验的硬件平台为 Windows7 64 位操作系统, Intel Core i5-6500 CPU、4GB 内存, 算法在 MATLAB-R2016b 环境下实现.

常见的脑部疾病包括脑肿瘤、脑外伤、急性脑血管疾病(脑出血、脑梗塞)、脑萎缩等, 其影像学表现不一. 实验中选取哈佛全脑图中的多张脑部案例 MRI 的 T_2 WI 影像数据, 该数据库具有噪声少, 图像格式标准的特点, 是标准的脑部疾病全脑影像图谱.

4.1.2 对比算法

本文同时采用分析法和实验法对改进算法 ACA-DPC 算法与经典算法 K -means、AP、遗传-密度峰值算法(density peaks clustering based on genetic algorithm, GA-DPC)进行比较, 检验改进算法的有效性.

- (1) *K*-means 算法:经典的无监督学习算法,在多个领域应用广泛,当数据类簇比较密集或连续时,各类簇区别较为明显,分割效果较好.
- (2) 仿射传播(affinity propagation, AP) 聚类算法,无需指定聚类数目,面向大规模、类数很多的数据时,AP 算法运行速度较快,从而使得聚类效果更可靠.
- (3) GA-DPC 算法:是一种结合遗传算法选取最优参数的改进密度峰值聚类的图像分割方法,使用图像熵作为最佳适应度判别函数,实现了对图像的无监督分割.

4.1.3 评估方法

类间方差和图像熵可以定量地描述图像分割的效果,值越大,表明不同类间差别更大、图像内容更丰富. 比较类间方差是根据区域间特性对比度的大小判断分割图像的质量^[15]. 类间方差定义如下:

$$SEC = \sum_{i=1}^{k-1} \left(\frac{N}{N+M} (U_1-U)^2 + \frac{M}{N+M} (U_2-U)^2 \right).$$

(7)

式中, k 为聚类中心个数, M 、 N 分别指第一、二个区域的面积(一般是相邻区域像素点个数), U_1 、 U_2 为第一、二个区域平均灰度值, U 指两个区域的平均灰度值.

4.2 实验结果

4.2.1 分析法

分析法主要选取先验信息、算法类型、时间复杂度、误差平方和、鲁棒性等指标,从理论上分析 *K*-means、AP、GA-DPC 和 ACA-DPC 算法的性能.

表 3 分析法比较 *K*-means、AP、GA-DPC 和 ACA-DPC 算法

Table 3 Comparative analysis of *K*-means, AP, GA-DPC and ACA-DPC algorithms

分析指标	<i>K</i> -means	AP 算法	GA-DPC 算法	ACA-DPC 算法
先验信息	需要事先指定聚类数目	不需要事先指定聚类数目	不需要事先指定聚类数目	不需要事先指定聚类数目
算法类型	基于划分	基于密度	基于密度	基于密度
时间复杂度	$O(n * k * t)$	$O(n^2 * \log n)$	$O(p * t * n^2)$	$O(p * t * n^2)$
鲁棒性	弱	弱	较强	强

分析法比较几种算法发现,相较于 *K*-means 算法,AP、GA-DPC 和 ACA-DPC 算法不需要事先指定聚类数目,体现了其可以在没有先验知识的情况下自主分割图像的优势;时间复杂度方面,表 3 中 n 是数据元素个数, k 是聚类中心数, t 是迭代次数, p 是种群数量;改进算法的量级要高于 *K*-means 和 AP 算法;GA-DPC 算法和 ACA-DPC 算法复杂度相当,但是遗传算法需要较大的种群规模和迭代次数,较难收敛,而蚁群算法收敛迅速,运行时间更短,即有更高的搜索能力和更强的鲁棒性.


4.2.2 实验法

仿真实验选取哈佛全脑图 MRI 的 T2 加权图像,对于 *K*-means 和 AP 算法,实验使用作者提供的原始代码进行实验. 对于每个比较的算法,将内部参数值设置为最佳:如根据医学图像先验知识,*K*-means 算法参数 k 设置为 7 时,分割效果较理想;AP 算法、ACA-DPC 算法和 GA-DPC 算法可以自适应选择参数. 具体的实验结果如图 3 所示,实验结果取多次实验的最大值和稳定值. 由于图 3(b)中第 1 张和第 4 张图像较模糊、噪声大,病灶边缘不清晰,所以在预处理中考虑这些因素使用了灰度变换图像增强方法. 可以看出本文算法分割后,根据医学图像区域间的异质性将图像分割成多个不同区域,不同特性的区域特征明显,但互不交叉,算法迭代选取含有最优图像熵的分割结果,能够很好地区分异质性. 本文算法分割效果良好,要优于其他几种算法.

4.2.3 实验分析

从实验测试结果可以看出(图 3 和表 4),ACA-DPC 算法在针对区域灰度差不明显、聚类数目大的复杂医学图像时,不需要先验知识,分割的效果比较理想. 其中 ACA-DPC 算法分割后的图像比 *K*-means 和 AP 算法分割后的图像熵都大,且 SEC 基本上都大于后面两种算法,说明 ACA-DPC 算法在分割灰度图像时,保留信息更完整更接近原图像且不同类之间差别更大,即分割效果更好. 与 GA-DPC 算法相比,虽然寻优的结果一致,但 ACA-DPC 总是更快地收敛,整体运算结果耗时接近 GA-DPC 算法的 1/4,但和简单的 *K*-means、DPC 相比,运行时间要长,主要是在蚁群更新信息素和按照信息素迭代寻优中消耗了较多的时

间. 总体来说,在时间消耗可以接受的情况下,ACA-DPC 算法较其他几种分割算法更有优势. 实验结果与分析法结果一致.



实验数据第 1 行:脑出血;第 2 行:脑膜瘤;第 3 行:肉瘤;第 4 行:急性脑梗死;第 5 行:脑梗塞

图 3 几种聚类算法分割结果对比

Fig. 3 Segmentation results of four algorithms

表 4 K-means、AP、GA-DPC 和 ACA-DPC 聚类算法的评价指标值比较

Table 4 Comparison of evaluation index values of K-means, AP, GA-DPC and ACA-DPC algorithms

方法	指标	实验图片				
		1	2	3	4	5
K-means	SEC	1 468.79	1 858.31	1 426.70	1 512.50	2 099.70
	图像熵	4.50	4.11	4.31	4.09	4.61
	时间/s	0.12	0.10	0.11	0.12	0.10
AP	SEC	735.27	1 252.10	640.62	839.23	1 454.89
	图像熵	4.43	4.12	3.89	3.86	4.45
	时间/s	0.25	0.39	0.24	0.20	0.21
GA-DPC	SEC	2 217.95	2 188.63	2 105.17	2 105.01	1 856.72
	图像熵	4.87	4.39	4.72	4.50	4.97
	时间/s	42.95	39.99	40.18	40.25	43.15
ACA-DPC	SEC	2 217.95	2 188.63	2 105.17	2 105.01	1 856.72
	图像熵	4.87	4.39	4.72	4.50	4.97
	时间/s	12.59	12.66	12.43	12.20	11.99

5 结束语

蚁群通过形成一种信息素正反馈机制快速地搜索到食物,寻优结果不依赖于初始路线的选择,且搜索过程无需人工干预.基于此,为了克服DPC算法的缺陷,本文提出一种结合蚁群算法选取最优参数的密度峰值聚类的医学图像分割方法,使用图像熵作为信息素判断函数,实现了对图像的自适应分割.实验结果表明了ACA-DPC算法的有效性和鲁棒性,而且大大减少了结合群智能算法(如GA-DPC)的分割时间,提高了运算速度.本文算法有着简洁高效的特点,但针对群智能算法的迭代和运算量大的缺点仍有改进的空间,这将是下一步工作的目标.

[参考文献]

- [1] SHRIVASTAVA K, GUPTA N, SHARMA N. Medical image segmentation using modified *K*-means clustering[J]. Journal of gerontological nursing, 2014, 24(1): 54.
- [2] YADAV H, BANSAL P, SUNKARIA R K. Color dependent *K*-means clustering for color image segmentation of colored medical images[C]//2015 First International Conference on Next Generation Computing Technologies. Dehardun, India: IEEE, 2016: 858–862.
- [3] ZHOU N, YANG T, ZHANG S. An improved FCM medical image segmentation algorithm based on MMTD[J]. Computational and mathematical methods in medicine, 2014(1): 690349.
- [4] 唐文静, 许兆新, 张小峰. 峰值检测 FCM 算法的医学图像分割[J]. 智能系统学报, 2014(5): 584–589.
- [5] ZHU H, XU J, HU J, et al. Medical image segmentation using improved affinity propagation[C]//Fifth International Symposium Computational Modeling of Objects Represented in Images. Niagara Falls NY, USA: Springer, Cham, 2016: 208–215.
- [6] RODRIGUEZ A, LAIO A. Clustering by fast search and find of density peaks[J]. Science, 2014, 344(6191): 1492–1496.
- [7] 杨光. 基于密度峰值聚类的前列腺 KVCT 图像 3D 分割[D]. 西安: 西安电子科技大学, 2015.
- [8] 杨悦, 刘向阳. 基于局部空间密度峰值的图像分割算法[J]. 信息技术, 2017(9): 84–87.
- [9] 王泽, 张宏军, 张睿, 等. 基于遗传算法与密度及距离计算的聚类方法[J]. 计算机应用, 2015, 35(11): 3243–3246.
- [10] DENG S L, CHEN W D. *K*-means clustering method based on genetic simulated annealing algorithm[J]. Electronic design engineering, 2014, 22(6): 54–56.
- [11] 杨志, 罗可. 一种改进的基于粒子群的聚类算法[J]. 计算机应用研究, 2014, 31(9): 2597–2599.
- [12] ZHANG Z, YUE B, PAN Q, et al. Image segmentation algorithm of fuzzy clustering based on ant colony and adaptive filtering[J]. Application of electronic technique, 2015, 41(4): 144–147.
- [13] YANG J, TAN W, MA S, et al. Automatic MRI brain tissue extraction algorithm based on three-dimensional gray-scale transformation model[J]. Journal of medical imaging and health informatics, 2014, 4(6): 907–911.
- [14] JENG J H, HSU S L, CHANG Y. Entropy improvement for fractal image coder[J]. International Arab journal of information technology, 2012, 9(5): 403–410.
- [15] GUI Y, LIN D, LIANG S, et al. A coarse-to-fine horizon detection method based on between-class variance[C]//Ninth International Symposium on Computational Intelligence and Design. Hangzhou, China: IEEE, 2017: 376–380.

[责任编辑: 黄 敏]