

文章编号:1001-9081(2008)05-1240-04

基于 Ant-Tree 聚类算法的图像分割

方 新,赵卫东,杨晓春

(同济大学 计算机辅助设计(CAD)研究中心,上海 200092)

(fangxin0307@hotmail.com)

摘要:图像分割可以看作对具有不同特征的像素进行聚类的过程。综合考虑像素的灰度、梯度及邻域等特征,将 Ant-Tree 聚类算法引入图像分割中。针对 Ant-Tree 算法的聚类结果信息冗余的缺点,采用了一种改进的树结构模型来提高聚类速度。此外,还提出了一种新的初始化方法,结合 K-means 算法动态修正聚类中心,提高了聚类准确度和算法的鲁棒性。实验结果证明改进的 Ant-Tree 算法可以快速准确地分割出目标,是一种非常有效的图像分割方法。

关键词:Ant-Tree 算法;图像分割;树模型;聚类

中图分类号: TP391.41 文献标志码:A

Image segmentation based on improved Ant-Tree algorithm

FANG Xin, ZHAO Wei-dong, YANG Xiao-chun

(Research Center of CAD, Tongji University, Shanghai 200092, China)

Abstract: Image segmentation can be seen as the process of clustering the pixels with different characteristics. Considering the gray value, gradient and neighborhood of the pixels synthetically, the Ant-Tree algorithm was introduced into image segmentation. As the resulting tree of Ant-Tree algorithm contains redundant information, an improved tree model was proposed in this paper. Besides, in order to optimize the process of clustering, a new initialization method was presented, and the method of K-means was also employed to modify the clustering center dynamically. Experiments and comparisons show that the Ant-Tree based clustering algorithm is an effective and efficient approach in image segmentation.

Key words: Ant-Tree algorithm; image segmentation; tree model; clustering

0 引言

图像分割是图像处理和分析的关键技术,将整个图像区域分割成若干个互不交叠的非空子区域的过程。每个子区域的内部是连通的,同一区域内部的像素点具有相同或相似的特征,这里的特征可以是灰度、颜色、纹理等。只有在图像分割的基础上才能对目标进行特征提取和参数测量,使得更高层的图像分析和理解成为可能,因此对图像分割方法的研究具有十分重要的意义。

Ant-Tree 算法^[1]是根据生物学中蚂蚁的自我聚集行为而衍化的一种新的数据聚类算法,已经成功地应用于数据挖掘领域,如人类皮肤分析、面向 Web 的数据挖掘等。本文将这种智能算法应用于图像分割。Ant-Tree 算法所产生的树结构对图像分割包含了很多信息冗余,并且初始化对聚类的结果有较大的影响。针对这些缺陷,本文改进了 Ant-Tree 算法的树结构来降低聚类结果中的信息冗余,提高算法的效率。此外,还提出了一种新的初始化方法,并在聚类过程中结合 K-means^[2] 算法动态修正聚类中心,提高了聚类准确度和算法的鲁棒性。通过对多种不同种类图像使用该算法分割的实验结果说明,与传统分割算法相比,该算法精度高、效率快。

1 基于 Ant-Tree 算法的图像分割

1.1 Ant-Tree 算法描述

据观测,蚂蚁能够形成辅助性结构帮助其他蚂蚁通过障

碍,或进行巢穴的建设。通过模拟蚂蚁群体的这种自聚集行为,文献[1]提出了 Ant-Tree 聚类算法,构建树结构来对数据集进行划分。在 Ant-Tree 算法中,每只蚂蚁都对应数据集中的一条数据并代表树的一个节点。初始时蚂蚁都被放在一个称为支点的固定点上,这个点相当于树根。蚂蚁在这棵树上或已经固定在树上的蚂蚁身上移动,来寻找适合自己的位置。

在 Ant-Tree 算法中, $Sim(i, j)$ 表示两个数据(d_i, d_j)间的相似性,它的取值在 0 到 1 之间,0 表示完全不同,1 表示完全相同。移动的蚂蚁通过比较它与邻域中已固定在树结构上的其他蚂蚁的相似性来选择继续移动或固定在某个位置上。设初始树根节点为 a_0 ,蚂蚁逐步连接到这个初始节点上或连接到固定在该节点的蚂蚁上,直到所有的蚂蚁均连接到结构上。对每只蚂蚁都定义了一个相似度阈值 $T_{Sim}(a_i)$ 和相异度阈值 $T_{Dissim}(a_i)$,用来表示 a_i 对同类蚂蚁的接受程度。第一只蚂蚁直接连接在 a_0 上,对于其后的蚂蚁 a_i ,要考虑两种情况:

第一种情况是当 a_i 在 a_0 上,设 a^+ 表示固定在 a_0 上与 a_i 最相似的蚂蚁,如果 a_i 与 a^+ 足够相似,即 $Sim(a_i, a^+) \geq T_{Sim}(a_i)$,那么 a_i 向 a^+ 移动;如果 a_i 与 a^+ 足够相异,即 $Sim(a_i, a^+) < T_{Dissim}(a_i)$,那么 a_i 就直接连接到 a_0 ,表示新创建一棵子树;否则用 $T_{Sim}(a_i) \leftarrow T_{Sim}(a_i) * \alpha, T_{Dissim}(a_i) \leftarrow T_{Dissim}(a_i) + \beta$ 来更新阈值,增加 a_i 下次连接的概率。 α, β 为调节因子,通常选择 0.9 和 0.01 可以获得最佳的实验结果^[3]。

第二种情况: a_i 在蚂蚁 a_{pos} 上移动, a^+ 表示固定在 a_{pos} 上与 a_i 最相似的蚂蚁。如果 a_i 与 a_{pos} 足够相似,而与其子女足够

收稿日期:2007-11-17;修回日期:2008-01-03。

作者简介:方新(1985-),女,安徽桐城人,硕士研究生,主要研究方向:图像匹配、图像处理; 赵卫东(1965-),男,山东文登人,研究员,博士生导师,主要研究方向:企业信息化、CAD 技术应用、图形图像处理; 杨晓春(1981-),男,陕西铜川人,博士研究生,主要研究方向:图形图像处理。

相异,即 $\text{Sim}(a_i, a_{\text{pos}}) \geq T_{\text{Sim}}(a_i)$ 且 $\text{Sim}(a_i, a^+) < T_{\text{Dissim}}(a_i)$,那么 a_i 就连接在 a_{pos} 上,否则蚂蚁 a_i 随机选择向 a_{pos} 的邻居移动,并更新阈值,继续寻找合适的位置,直到所有蚂蚁都连接到结构中,算法结束。从得到的结果树中,将每个连接到 a_0 的子树作为一个分组,从而得到对数据的划分。由于 Ant-Tree 算法是基于树结构的,所以算法执行效率较高,并且不需要任何关于数据集的分类信息也能得出非常精确的分类结果。

1.2 图像分割特征提取

灰度值是像素点最重要和最常用的特征值。另外,边界点或噪声点往往是灰度发生突变的地方,而该点处的梯度体现出这种变化,是反映边界点与背景或目标区域内点区别的主要特征。最后,对于梯度值较高的边界点和噪声点,它们在图像中的邻域特征是不同的。边界点的邻域中与其类似的像素点数一般比较大,而对于噪声点,该值一般比较小。在此基础上可以利用像素的 3×3 邻域进行划分,邻域特征的提取过程如下:定义 NUM 为邻域像素个数,初始值为 0。对于邻域类的每个像素,其灰度差将被计算,并且和给定的阈值 T 比较,如果灰度差小于 T , NUM 自动加 1,重复这个过程,确保每个像素都计算出一个特定的 NUM 值。 NUM 实际上代表邻域中相似像素点的个数。对于物体和背景像素点, NUM 值一般为 8。边界像素点的该值比噪声像素点要大。同时,不同的图像 T 的值也是不同的。对于平滑图像 T 值较小,而对于较大的细节较多的图像, T 的值通常为 $50 \sim 90$ 。

在以上提到的像素的三个特征的基础上,构成了一个以灰度、梯度和邻域为特征的三维向量。采用欧氏距离计算不同像素之间的相似度: $\text{Sim}(x_i, x_j) = \sqrt{\sum_{k=1}^3 p_k (x_{ik} - x_{jk})}$,其中 x_{ik} 代表着像素 x_i 三维向量中的第 k 个分量的值, p 表示权值,由每个分量的重要程度决定其值。

2 改进的 Ant-Tree 算法

Ant-Tree 算法的树结构保证了新的蚂蚁在连接到该结构时不需要搜索整个数据集,所以算法的执行效率较高。通常每棵直接连接到支点的子树作为一类,因此子树的层次结构包含了大量的无用信息。针对这个问题,本文改进了 Ant-Tree 的树结构模型;结合原始图像信息,提出了新的初始化聚类中心的方法,并结合 K-means 算法来提高算法的聚类准确性。

2.1 初始聚类中心

在 Ant-Tree 算法中,对于每个直接连到树根上的蚂蚁,越贴近真正的聚类中心,聚类效果越好。因此,选取一些具有代表性的像素点作为初始聚类中心,其他像素点通过与聚类中心比较可有效实现聚类。聚类中心的个数和特征值由以下步骤决定:

1) 初始聚类中心的个数和灰度值计算

属于同一类别的像素总是具有相似的灰度值,图像的灰度直方图反映了图像中不同灰度级像素出现的频数,相当于像素点根据灰度值的聚类结果。图 1(b)给出了图 1(a) Lena 图像的灰度直方图,从图 1(b)看出有峰值点处的灰度值所对应的像素数比平均值要高。因此,可以选取直方图的 n 个峰值点作为 n 个聚类中心的灰度特征,同时 n 也确定了初始聚

类中心的个数。

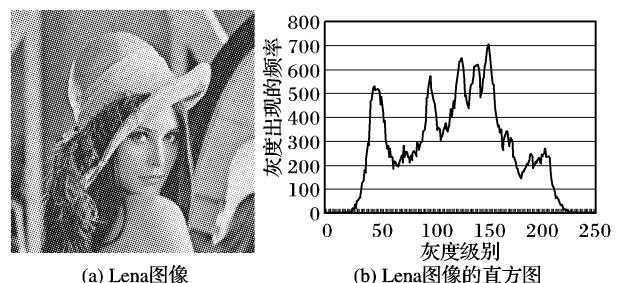


图 1 Lena 图像及其直方图

Ant-Tree 算法中最先连接到根节点的两只蚂蚁对聚类结果有着很重要的影响。在本文的算法中同样如此,聚类结果和初时阶段选取的聚类中心的数量 n 很相关。从对直方图的分析中我们得出 n 的数值。直方图的峰值处可以选作聚类的中心,这对聚类的效果很好。但是由于 n 值较大,一些比较接近的峰值导致可能将一个目标的像素点划分到不同的类里。因此在本文算法中,使用了灰度值的阈值 T 来初始化聚类中心,步骤如下:

(1) 从直方图中找出 n 个峰值所对应的灰度作为聚类中心;

(2) 对于每个灰度值 k ,找出一个与其最接近的灰度值 l :

$$\text{Diff}(k, l) = |\text{Gray}(k) - \text{Gray}(l)| = \min_{1 \leq j \leq n} |\text{Gray}(k) - \text{Gray}(j)| \quad (1)$$

(3) 如果 $\text{Diff}(k, l) < T$,将两个聚类中心合并,并且按式

(2) 重新计算新聚类中心对应的灰度值;

$$\text{aver} = \frac{\text{Gray}(k) \times \text{number}(k) + \text{Gray}(l) \times \text{number}(l)}{\text{number}(k) + \text{number}(l)} \quad (2)$$

(4) 重复(2)和(3),直到没有聚类中心被合并。

2) 初始聚类中心梯度特征选择

在步骤(1)中, n 个聚类中心被选取出来。灰度特征对应的像素点个数较多的一般对应着背景或目标,同时边界点或噪声对应的像素点个数较少。图像中背景或目标内部像素点的梯度一般较小,而边界点或噪声像素点的梯度较大。如果某些聚类中心的灰度特征对应的像素点个数远大于其他,则设置该聚类中心梯度特征为零。对其余的聚类中心,其梯度值为梯度图像最大梯度列的均值:

$$\text{Grad}_{\text{aver}} = \frac{1}{m} \max_{j=1, 2, \dots, n} \left\{ \sum_{i=1}^m \text{grad}(i, j) \right\} \quad (3)$$

其中, $\text{Grad}_{\text{aver}}$ 为所求的梯度特征, $\text{grad}(i, j)$ 是像素 i 和 j 间的梯度, $m \times n$ 是图像的尺寸。

3) 初始聚类中心邻域特征选择

与上一步相对应,根据图像中不同种类像素邻域特点,将梯度为零的聚类中心邻域特征设为 8,梯度值较高的聚类中心;如果灰度特征对应的像素点个数较多,则该聚类中心可能为边界,邻域特征设为 6;如果灰度特征对应的像素点个数较少,则该聚类中心可能为噪声,邻域特征一般设小于 3。

2.2 优化聚类方法

Ant-Tree 算法所得到的层次结构中包含了大量无用的信息,针对这个问题,本节中对 Ant-Tree 算法的树结构进行了改进以减少信息冗余,加速聚类过程。

在 Ant-Tree 算法中树除了根节点以外,每个节点都代表一个数据。而在本节所提出的树结构中,采用了更多的虚拟

节点。这些虚拟节点作为聚类中心直接连接在根节点上。每个蚂蚁都可以在虚拟节点上移动，并通过与聚类中心的相似度比较选择自己在树结构中的固定位置。Ant-Tree 算法中每只蚂蚁与其子女构成的子树也同样具有层次结构，而在本文所采用的树结构中，蚂蚁聚集组成，这些组直接连接到虚拟节点上。当算法结束，一组蚂蚁实际上就对应着像素点的一个分组。改进后树结构如图 2 所示。

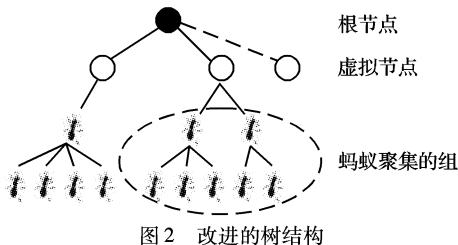


图 2 改进的树结构

本文所改进的树结构具有较为丰富的表现方式，每棵子树可以通过它根节点的邻域值来区分其类别。通常，当虚拟节点邻域值大于 7 时，子树所包含的像素点对应着图像的背景或者图像中的目标。当邻域值小于 3 时，子树所包含的像素点很可能是噪声。边界像素点所对应的邻域值取值范围是 4 到 6。可以简单地将包含目标和噪声像素点的子树归为一类，边界像素点作为另一类，这样本算法中就可以用来对图像进行边缘检测。在本文中，只是将每个直接连接到根节点的子树作为一个单独的聚类。

为了使聚类结果更精确，在聚类过程中结合了 K-means 算法，不断修正虚拟节点使其更接近于实际的聚类中心。每次蚂蚁连接到虚拟节点或其子女节点时，虚拟节点的特征向量会更新以使其更接近实际的聚类中心。这也将使蚂蚁更快地聚集，并得到更好的聚类结果。改进的 Ant-Tree 算法流程如下：

- 1) 根据 2.1 节所描述的方法初始化聚类中心，并将它们连接到根节点 a_0 ；
- 2) 将所有的蚂蚁都放到根节点处，并设置所有蚂蚁的状态为未连接；对每只蚂蚁 a_i ，设定相似度和相异度阈值 $T_{\text{Sim}}(a_i) = 1, T_{\text{Dissim}}(a_i) = 0$ ；
- 3) 选择一只未连接到结构中的蚂蚁 a_i ，按照下面的规则进行活动直到所有蚂蚁都连接到结构中：

规则 1 如果蚂蚁 a_i 已经在根节点 a_0 上：

- (1) 如果没有一只蚂蚁连接到 a_0 ，则将 a_i 直接连接到 a_0 ；
- (2) 否则，假设 a^+ 是所有连接到 a_0 上的蚂蚁中与 a_i 最相似的，如果 a_i 与 a^+ 足够相异，即 $\text{Sim}(a_i, a^+) < T_{\text{Dissim}}(a_i)$ ，生成一个虚拟节点 a_{virtual} ，它的特征向量与 a_i 完全相同，将 a_{virtual} 连接到 a_0, a_i 移向 a_{virtual} ；
- (3) 否则如果 a_i 与 a^+ 足够相似，即 $\text{Sim}(a_i, a^+) \geq T_{\text{Sim}}(a_i)$ ，则 a_i 朝 a^+ 移动， a^+ 的值根据 $a_{\text{new}}^+ = \frac{J}{J+1}a_{\text{old}}^+ + \frac{1}{J+1}a_i$ 重新计算， J 是 a^+ 的后继节点的数量；

(4) 如果 a_i 与 a^+ 不够相似也不够相异，则根据公式 $T_{\text{Sim}}(a_i) \leftarrow T_{\text{Sim}}(a_i) \times 0.9, T_{\text{Dissim}}(a_i) \leftarrow T_{\text{Dissim}}(a_i) + 0.01$ 更新相似度和相异度阈值。

规则 2 如果蚂蚁 a_i 在虚拟节点 a_{pos} 上， a_k 表示在其兄弟节点中随机选择的一只蚂蚁：

- (1) 如果 a_i 和 a_{pos} 足够相似，即 $\text{Sim}(a_i, a_{\text{pos}}) \geq T_{\text{Sim}}(a_i)$
- a) 如果 a_{pos} 没有子女，则将 a_i 连接到 a_{pos} ；

b) 否则假设 a^+ 表示 a_{pos} 子女中与 a_i 最相似的蚂蚁，如果 a_i 和 a^+ 足够相异，即 $\text{Sim}(a_i, a^+) < T_{\text{Dissim}}(a_i)$ ，则将 a_i 连接到 a_{pos} ；

c) 如果 a_i 和 a^+ 足够相似，即 $\text{Sim}(a_i, a^+) \geq T_{\text{Sim}}(a_i)$ ，则将 a_i 连接到 a^+ ；

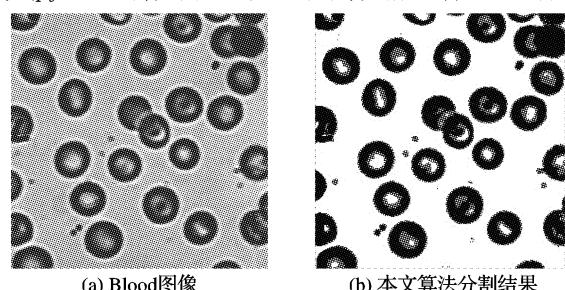
d) 否则根据公式 $T_{\text{Dissim}}(a_i) \leftarrow T_{\text{Dissim}}(a_i) \times 0.9, T_{\text{Sim}}(a_i) \leftarrow T_{\text{Sim}}(a_i) + 0.01$ 更新相似度和相异度阈值，并将 a_i 移到 a_k 处；

(2) 否则， a_i 移到 a_k 。

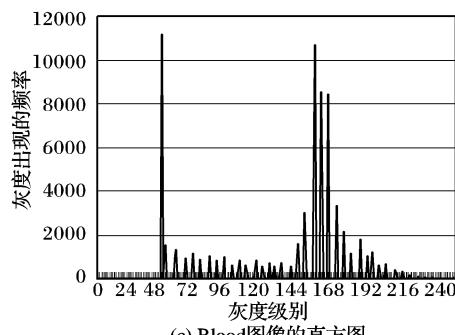
由上可知，在本文聚类算法中将 Ant-Tree 算法中蚂蚁之间的比较换成了蚂蚁和聚类中心的比较。另外，由于使用了图像的直方图中包含的信息，减少了聚类中心的个数，可以有效地减少蚂蚁比较的时间。同时，在聚类过程中优化虚拟节点，使得聚类结果更加准确。

3 实验结果与分析

实验选取 Blood 和 Lena 图像来测试改进 Ant-Tree 算法的分割效果。计算相似性的权值 (p_1, p_2, p_3) 对于图像分割的结果有很重要的影响。通过实验发现 (p_1, p_2, p_3) 的值需要根据图像的直方图来设置。如图 1(b) 所示的 Lena 图像的直方图，它的峰值比较平坦，那么较小的 p_1 和 p_2 可以获得较好的分隔效果，故设定 $p_1 = 0.3, p_2 = 0.7, T = 50$ ，采用该参数对图 1(a) 的分割效果见图 4；如果峰值比较尖锐，则需要具有较大值的 p_1 和 p_2 ，如图 3(c) 所示的 Blood 图像的直方图中峰值较为尖锐，在处理图像时设定 $p_1 = 1.8, p_2 = 1.2, T = 30$ ，分割效果如图 3(b) 所示。 p_3 的取值范围通常是 5 到 15，这是由于邻域值的差值远小于灰度差和梯度差。较大的 p_3 值可以容易地探测出噪声和边界，但是会使得分割结果比较粗糙；小的 p_3 值会使得分割结果比较平滑但会丢失一些边界像素点。从图 4 对图 1(a) Lena 图像的处理中可以看出不同的 p_3 的值对分割的影响。两幅处理结果对比发现当 $p_3 = 5$ 时整体分割效果较好，但帽子、鼻梁还有右部分的细节均未能很好地分割；当 $p_3 = 15$ 时，分割出了更多细节，但帽子部分出现噪声。



(a) Blood 图像 (b) 本文算法分割结果



(c) Blood 图像的直方图

在本文的算法中，初始化聚类中心时需要用到阈值 T ，它

对于分割效果有着较大影响。如图 5 所示,其中 $(p_1, p_2, p_3) = (1, 1, 10)$ 。 T 的取值范围一般为 $[20, 60]$, 相对应的聚类中心一般为 2~6 个。 T 值越大, 聚类中心越少, 分割结果越平滑, 但有可能导致一些细节被忽略。如图 5(a)所示的对 Lena 图像的处理中, 右边的部分细节没有被分割出来。反之, 聚类中心数目会增多, 分割结果会更为细致, 但同一物体的像素会被分到不同的组里, 导致过度分割, 如图 5(b) 和图 6(c) 所示, Lena 原图中的鼻梁和右部分都呈现了很好的分割效果, 但也都存在着不同程度的过度分割现象。

为了测试我们的算法, 采用 K-means 和模糊 C 均值 (Fuzzy C Mean, FCM)^[3] 这两种聚类算法来和本文的算法进行比较。图 6 和图 7 分别显示了这三种算法对 Lena 图像和 Blood 图像的分割结果。三种聚类方法根据图像的直方图分别初始化为 5 个和 3 个聚类中心。



图 4 p_3 值对分割结果的影响



图 5 阈值 T 对分割结果的影响



图 6 三种不同算法对 Lena 图像的分割结果

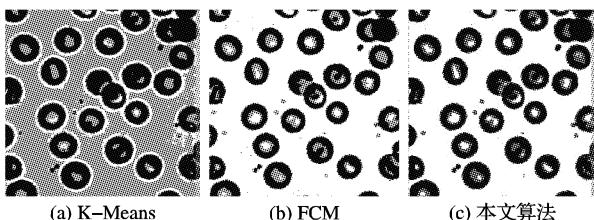


图 7 三种不同算法对 Blood 图像的分割结果

对于 Lena 图像, 设置 $(p_1, p_2, p_3) = (1, 1, 10)$, 将初始阈值 T 设为 30。从图 6 可以看出, 三种聚类算法都存在过度分割的现象。但是本文算法的分割结果则相对平滑, 比如 Lena 的手臂部分没有出现图 6(a) 及图 6(b) 的过度分割。此外, 从图 6(c) 可以看出本文所提出的算法对 Lena 图像右下部分的纹理有着较好的分割结果, 而 K-mean 和 FCM 对这一部分

的分割结果则不是很理想。我们已经通过实验证明, 在本文所提出的算法中, 过度分割的问题可以通过使用具有较小值的 p_1 和 p_2 来解决。对于 Blood 图像, 设置 $(p_1, p_2, p_3) = (1, 8, 1, 10)$, 将初始阈值 T 设为 50。从图 7 可以看出, K-means 分割效果较为粗糙, 而本文算法和 FCM 分割出了更多的细节, 如正中间的血液细胞以及左边中部的 L 图形都清晰地分割出来。但在 FCM 的分割结果中, Blood 图像的左上和下部中间部分都出现了一些噪声。同时从表 1 中看出, 分割两幅图像 K-means 所用的时间都是最短的, 但本文算法较之 FCM 耗时较短, 效率上有很大提高。总的说来, 本文所提出的算法是一种快速有效的图像分割方法。

表 1 算法性能比较

图像	尺寸	聚类中心个数	聚类中心	耗时/s		
				K-means	FCM	本文算法
Blood	256×256	3	46, 155, 206	1.29	8.91	3.82
Lena	256×256	5	46, 91, 127, 154, 208	2.14	15.42	4.74

4 结语

本文改进了 Ant-Tree 聚类算法中的树结构, 有效地减少了 Ant-Tree 算法中产生的冗余信息; 根据原始图像信息提出了新的初始化聚类中心的方法, 提高了算法的聚类的准确度; 结合 K-means 算法的使用也提高 Ant-Tree 算法的效率。实验中通过将算法用于不同的图像, 获得了较好的图像分割结果, 通过与 K-Means 和 FCM 算法分割结果的比较, 可以看出本文算法的图像分割效果要好一些, 同时在保证分割精度的同时, 提高了算法执行的速度。进一步研究工作包括更好地融入模糊聚类分析的思想与提高蚂蚁的活动灵活度, 以更好提高算法的效率和准确度。

参考文献:

- [1] AZZAG H, MONMARCHE N, SLIMANE M, et al. AntTree: a new model for clustering with artificial ants [C]// The 2003 Congress on Evolutionary Computation(CEC'03). Washington, DC: IEEE Computer Society, 2003: 2642–2647.
- [2] LUO MING, MA YUN-FEI, ZHANG HONG-JIANG. A spatial constrained K-means approach to image segmentation [C]// Proceedings of the 2003 Joint Conference of the 4th International Conference on Information, Communication, and Signal Processing 2003 and the 4th Pacific Rim Conference on Multimedia. Washington, DC: IEEE Computer Society, 2003: 738–742.
- [3] HANDL J, KNOWLES J, DORIGO M. On the performance of ant-based clustering [M]// ABRAHAM A, KÖPPEN M, FRANKE K. Design and application of hybrid intelligent systems. Amsterdam: IOS Press, 2003: 204–213.
- [4] CHEN SONG-CAN, ZHANG DAO-QIANG. Robust image segmentation using FCM with spatial constraints based on new kernel-induced distance measure [J]. IEEE Transactions on Systems, Man, and Cybernetics, 2004, 34(4): 1907–1916.
- [5] 刑婷, 宋振方. 基于图分割的蚁群聚类算法 [J]. 哈尔滨商业大学学报: 自然科学版, 2006, 22(2): 96–100.
- [6] 张建华, 江贺, 张宪超. 蚁群聚类算法综述 [J]. 计算机工程与应用, 2006, 42(16): 171–174.