

基于图像超像素分析的图像分割方法

张小凤,刘向阳

(河海大学 理学院,江苏 南京 211100)

摘要:图像分割是计算机视觉领域的传统问题,也是图像分析和模式识别的关键组成部分。传统的聚类图像分割方法是基于单个像素属性进行的图像分割方法,分割的结果有很大的噪声且具有不稳定性。针对以上不足,考虑超像素能够较好地描述区域信息,且有利于图像的局部特征的提取与结构信息的表达,提出了基于图像超像素分析的图像分割方法。首先利用SLIC算法将单个像素点聚类为超像素块,其次通过密度峰值聚类算法(DPCA)对超像素块进行聚类,将基于单个像素属性的图像聚类分析改变为基于超像素的分析,可以提高分割结果的稳定性及准确性。仿真结果表明,与SLIC算法和DPCA进行对比,发现该方法比另外两种方法更稳定且分割效果更好。

关键词:图像分割;超像素;SLIC算法;密度峰值聚类算法

中图分类号:TP391.41

文献标识码:A

文章编号:1673-629X(2018)07-0025-04

doi:10.3969/j.issn.1673-629X.2018.07.006

Image Segmentation Based on Image Superpixel Analysis

ZHANG Xiao-feng, LIU Xiang-yang

(School of Science, Hohai University, Nanjing 211100, China)

Abstract: Image segmentation is a traditional problem in the field of computer vision and also a key component of image analysis and pattern recognition. The traditional clustering image segmentation method is based on the single pixel attribute, and its segmentation result has great noise and is unstable. To resolve the above shortcomings, in view of the superpixel with better description of the region information, which is beneficial to extract the local feature of image and to express the structural information, we propose an image segmentation method based on image superpixel analysis. Firstly, single pixel is clustered into superpixel block by SLIC algorithm, and then the superpixel block is clustered by the density peak clustering algorithm (DPCA). Changing the image clustering analysis based on the single pixel attribute to the analysis based on the superpixel can improve the stability and accuracy of the segmentation result. After the simulation test, compared with the SLIC algorithm and DPCA, it is found that the proposed algorithm is more stable and has better segmentation than the other two methods.

Key words: image segmentation; superpixel; SLIC algorithm; density peak clustering algorithm

0 引言

图像分割是指将图像分割成一些互不重叠的区域,各区域内部具有相同或相近的某些特定属性,而不同区域之间的属性则相差明显,其实质就是按照像素的属性进行聚类的过程^[1-2]。图像分割是图像处理与计算机视觉领域的基本技术之一,它是图像分析和模式识别的重要组成部分,其目的是为了将图像中人们所感兴趣的部分提取出来,为后续处理分析打下基础^[3]。因为聚类图像分割方法是一种无监督的机器学习算法,所以在图像分割中应用广泛。

传统的聚类图像分割方法有k-means聚类算法^[4]、模糊聚类算法^[5-6]、基于密度的聚类算法^[7]和谱聚类算法^[8]等。k-means聚类算法思想简单,实现方便,但由于其聚类中心的选取具有不确定性,不能得到理想的结果。FCM^[9-10]作为模糊聚类算法的代表,有很多优点,但也存在聚类数目的选取以及算法迭代复杂度过高等问题。基于密度的聚类算法聚类速度快且能够有效处理噪声点,但当聚类的密度不均匀、聚类间距相差很大时,聚类质量较差,且可实性很差。谱聚类算法只需要数据之间的相似度矩阵,所以对于处理稀

收稿日期:2017-07-26

修回日期:2017-11-09

网络出版时间:2018-02-24

基金项目:国家自然科学基金(61001139)

作者简介:张小凤(1994-),女,硕士研究生,研究方向为图像处理;刘向阳,副教授,硕导,通讯作者,研究方向为图像与视频分析、数据分析和机器学习。

网络出版地址: <http://cnki.net/kcms/detail/61.1450.TP.20180224.1525.090.html>

疏数据的聚类很有效。它是属于图论的范畴,因此不可避免地存在图论分割算法的缺点,当聚类的维度非常高时,谱聚类的运行速度和最终分割结果都会受到影响。

上述聚类算法都是基于单个像素进行图像分割的,这样可能造成图像分割结果的不稳定性,且有很大的噪音。针对这些不足,提出了基于图像超像素分析的图像分割方法。该方法是基于超像素对图像进行聚类,因为超像素更有利于局部特征的提取与结构信息的表达,并且能够大幅降低后续处理的计算复杂度^[11]。首先利用 SLIC 算法^[12]对图像生成超像素并用其代替像素作为图像处理的基本单元^[13],然后计算每个超像素的颜色均值,提取超像素的颜色均值、聚类中心的空间位置以及颜色均值的方差作为超像素的特征属性,再计算两两超像素之间的距离,得到超像素的距离矩阵。最后利用基于密度峰值的聚类算法(DP-CA)^[14]对超像素进行聚类。

1 SLIC 算法生成超像素

超像素^[15]是指具有相似颜色、亮度、纹理等特征的像素组成的有一定视觉意义的不规则像素块,即同一个超像素内的像素具有很大的相似性。它是利用像素之间特征的相似性将像素进行分组,用少量的超像素代表大量的像素来表达图片特征。而且超像素能捕获图像的冗余信息,降低图像后续处理的复杂度,通常作为图像处理的预处理步骤。超像素已经成为计算机视觉领域中的重要技术,广泛应用于图像分割、图像分类以及目标跟踪等图像分析领域。

简单的线性迭代聚类算法(SLIC)^[12]能生成大小均匀、形状规则的超像素,且边界黏连、运算速度和分割质量都优于其他的超像素分割算法。SLIC 算法主要是应用 k-means 生成超像素,首先将彩色图片转换为 CIELAB 颜色空间和空间坐标下的 5 维特征向量 $[L \ a \ b \ x \ y]^T$,用 5 维特征向量来构造像素的度量标准,然后对像素进行聚类,完成超像素过程。

具体步骤如下:

(1) 初始化种子点:按照设定的超像素个数,在图像内均匀分配种子点。假设图片总共有 N 个像素点,预分割为 K 个相同尺寸的超像素,那么每个超像素的大小为 N/K ,则相邻种子点的距离近似为 $S = \sqrt{N/K}$ 。

(2) 在种子点的 3×3 邻域内,将种子点移到该邻域内梯度值最小的地方。这样做的目的是为了避免种子点落在梯度较大的轮廓边界上,以免影响后续聚类效果。

(3) 在每个种子点周围的邻域内为每个像素点分

配类标签,对于每个搜索到的像素点,分别计算它到该种子点的距离,将它分配到与其距离最近的类内。重复此步骤直到残余误差收敛。这里的距离包括颜色空间和距离空间,搜索范围为 $2S \times 2S$,相比 k-means 算法要计算每个像素之间的距离,SLIC 算法很大程度上提高了计算的速度。

距离定义如下:

$$\begin{cases} d_c = \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2} \\ d_s = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \\ D = \sqrt{d_c^2 + \left(\frac{d_s}{S}\right)^2 m^2} \end{cases} \quad (1)$$

其中, d_c 、 d_s 分别表示颜色距离和空间距离; S 表示种子点之间的距离; m 表示颜色与空间差异的权重, m 越大生成的超像素越紧凑, m 越小生成的超像素越不规则,但图像边界黏连很好。

2 超像素的距离矩阵的构建

利用 SLIC 算法生成超像素后,用超像素代替像素进行聚类。对每个超像素计算其颜色均值,用颜色均值、超像素的聚类中心的空间位置以及超像素的方差来表示每个超像素的特征属性,因此,每个超像素均可用 7 维向量来表示其特征属性,记为 $[l_i \ a_i \ b_i \ x_i \ y_i \ dl_i \ da_i \ db_i]^T$ 。其中 l_i 、 a_i 、 b_i 表示超像素的颜色分量均值; x_i 、 y_i 表示超像素聚类中心的空间坐标位置; dl_i 、 da_i 、 db_i 表示超像素颜色均值三个量的方差。其中颜色均值 $[l_i \ a_i \ b_i]^T$ 表示超像素之间颜色的相似性,当两个超像素的颜色距离越小时,说明两个超像素的颜色越接近。超像素聚类中心的空间位置 $[x_i \ y_i]^T$ 表示超像素之间的连通性,当两个超像素聚类中心之间的距离大于 $S = \sqrt{N/K}$ 时,说明两个超像素不相邻,不具有连通性。超像素的方差 $[dl_i \ da_i \ db_i]^T$ 表示每个超像素的纹理变化程度,当两个超像素的方差的距离越小时,说明两个超像素纹理越相似。

将每个超像素看成图像处理的基本单元^[8],计算两两超像素之间的欧氏距离 d_{ij} ,形成一个 $m \times m$ 维的矩阵 $\mathbf{d} = (d_{ij})_{m \times m}$,其中 d_{ij} 定义如下:

$$d_1 = \sqrt{(l_i - l_j)^2 + (a_i - a_j)^2 + (b_i - b_j)^2} \quad (2)$$

$$d_2 = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (3)$$

$$d_3 = \sqrt{(dl_i - dl_j)^2 + (da_i - da_j)^2 + (db_i - db_j)^2} \quad (4)$$

$$d_{ij} = d_{1c} + \gamma d_{1s} + \alpha d_3 \quad (5)$$

其中, d_1 、 d_2 和 d_3 分别表示超像素 C_i 和 C_j 之间的颜色距离、中心位置距离和超像素的协方差距离; m 为超像素个数; γ 为中心位置权重,当 γ 越大时,距离

权重较大,但此时图像分割越不稳定,可能把不一样的区域分割在一起,当 γ 越小时,会把同一个区域分割成多个部分; α 为纹理特征权重,当 α 越大时,图像的纹理分割得越清晰,可能会把同一个区域分成很多小的部分。文中当 γ 的取值范围为 $[0,1]$, α 取值范围为 $[0,0.1]$ 时,分割效果最好。在以下实验中,将 γ , α 设置为最佳值。

3 利用密度峰值聚类算法对超像素进行聚类

2014年Alex Rodriguez^[14]等提出了基于密度峰值的聚类算法(DPCA)。DPCA的主要思想是计算每个像素的局部密度值 ρ_i 和“距离” δ_i (δ_i 是指与具有更高局部密度点的距离),以寻找聚类中心。聚类中心具有两个特点:第一,其本身的密度很大,即它被密度均不超过它的邻居所包围;第二,与其他局部密度更大的数据点之间的距离相对更大。文中用该算法实现了对超像素的聚类,且详细过程如下所述。

3.1 计算局部密度和距离

超像素的数据集 $S = \{C_i\}_{i=1}^m$, $I_s = \{1, 2, \dots, m\}$ 为相应的指标集,其中 C_i 表示相应的超像素的特征属性, d_{ij} 表示超像素 C_i 和超像素 C_j 之间的欧氏距离(见式5)。对于每个超像素 C_i ,可以为其定义 ρ_i 和 δ_i :

$$\rho_i = \sum_{j \in I_s \setminus \{i\}} \chi(d_{ij} - d_c) \quad (6)$$

其中函数

$$\chi(x) = \begin{cases} 1, & x < 0 \\ 0, & x \geq 0 \end{cases} \quad (7)$$

参数 d_c 为截断距离,使得每个数据点的平均邻居个数约为总数据点的1%~2%。由定义可知, ρ_i 表示 S 中与 C_i 之间的欧氏距离小于 d_c 的超像素的个数,定义如下:

$$\delta_i = \begin{cases} \min_j(d_{ij}), & \rho_j > \rho_i \\ \max_j(d_{ij}), & \forall j \in I_s, \rho_i \geq \rho_j \end{cases} \quad (8)$$

由定义可知,当 C_i 具有最大局部密度时, δ_i 表示 S 中与 C_i 距离最大的超像素与 C_i 之间的距离;否则, δ_i 表示在所有局部密度大于 C_i 的超像素中,与 C_i 距离最小的超像素与 C_i 之间的距离。

3.2 确定聚类中心

这里把每个超像素看作一个数据点。一般选取局部密度较大的且同时有很大“距离”(与最近邻的高局部密度的超像素的距离)的数据点为聚类中心。计算综合考虑 ρ 值和 δ 值的一个量,定义为:

$$\gamma_i = \rho_i \delta_i, i \in I_s \quad (9)$$

由定义可知,由 γ 值越大的数据点越有可能为聚类

中心。因此,只需要对其进行降序排列,然后选取前 k 个 γ 值较大的数据点作为聚类中心,聚类中心对应的数据点编号记为 $\{n_j\}_{j=1}^k$,即 C_{n_j} 为第 j 个类的中心。

3.3 数据点归类

对于非聚类中心数据点的归类,是按照 ρ 值从大到小的顺序进行遍历的,它与局部密度比它大的最近邻的数据点为同一个类簇。

定义 $\{p_i\}_{i=1}^m$: p_i 表示 S 中所有局部密度比 C_i 大的数据点与 C_i 最近邻的数据点的编号。

初始化数据点归类属性标记 $\{c_i\}_{i=1}^m$,定义为:

$$c_i = \begin{cases} k, & C_i \text{ 为聚类中心} \\ -1, & \text{否则} \end{cases} \quad (10)$$

即若数据点 C_i 为聚类中心,则把它归类到第 k 个类簇;否则,当 $c_{q_i} = -1$ 时, $c_{q_i} = c_{p_{q_i}}$,即把它归类到局部密度比它大的最近邻的数据点所在的类簇中。其中 $\{q_i\}_{i=1}^m$ 表示数据点局部密度 $\{\rho_i\}_{i=1}^m$ 的降序排列下标序。

3.4 划分每个类簇中的数据点属性

在每个类簇中,数据点又可分为核心点和边缘点。首先确定该类簇的边界区域,边界区域内的数据点具有这样的属性,即本身属于该类簇,但在其 d_c 的领域内包含有其他类簇的数据点。对于每个类簇,确定其边界区域后,利用边界区域上的点生成一个平均局部密度上界 $\{\rho_i^b\}_{i=1}^{n_c}$ 。对于每一个数据点,如果 $\rho_i < \rho_{c_i}^b$,则该数据点为边缘点;否则,为该类簇的核心点。

4 算法流程

文中方法主要包括两步,第一步是利用SLIC算法对图像进行超像素分割,生成超像素,然后计算每个超像素的颜色均值,提取超像素的特征属性 $[l_i \ a_i \ b_i \ x_i \ y_i \ d_i \ da_i \ db_i]^T$,之后再利用式5计算两两超像素之间的欧氏距离 d_{ij} ,得到超像素的距离矩阵 $d = (d_{ij})_{m \times m}$;第二步是把生成的超像素作为图像处理的基本单元,利用基于密度峰值的聚类算法对生成的超像素进行聚类。文中算法流程如图1所示。

首先输入要分割的图像、超像素的大小和最终分割类簇,根据图像的大小计算超像素个数,并在图像内均匀分配种子点(等于超像素个数),在聚类中心的 $2S \times 2S$ 邻域内利用式1计算每个像素到聚类中心的距离 D ;然后将每个像素分配到距离其最近的聚类中心所在的类簇中,迭代更新聚类中心的位置,得到超像素,再根据式5计算两两超像素之间的距离 d_{ij} ,得到超像素的距离矩阵 $d = (d_{ij})_{m \times m}$,并计算每个超像素的局部密度 ρ_i 和与局部密度比它大的最近邻的超像素的距离 δ_i ;最后对超像素进行聚类,输出分割结果。

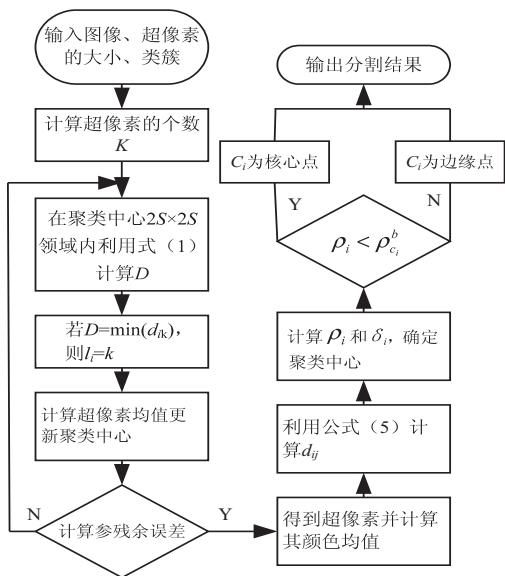


图 1 文中算法流程

5 实验结果与分析

为了验证该方法的可行性和有效性,选取了一些自然图像和纹理图像进行分割实验,并与 SLIC 算法和 DPCA 聚类算法进行了比较。

5.1 纹理图像的实验结果

纹理图像的分割结果如图 2 所示。可以看到,使用 SLIC 算法进行纹理图像分割不能把区域分割开来;使用 DPCA 聚类算法对图像进行分割会产生很大的噪声,并且把同一区域分割成很多小的部分。图(d)是文中算法的分割结果。对于每种对比算法,都将内部参数设置为最佳;对于文中算法,将超像素的大小设置为 $K=80$ 或 $K=100$,从上至下分别取 $\gamma=0.5$, $\alpha=0.05$, $\gamma=0.5$, $\alpha=0.001$ 。由实验结果可以看到,文中算法得到的分割结果要优于其他两种方法。




图 2 纹理图像的图像分割结果

5.2 自然图像的实验结果

自然图像的图像分割结果如图 3 所示。可以看到,使用 SLIC 算法进行图像分割不能把目标物与背景分割开来;图(c)中,第一张图 DPCA 聚类算法未能把目标物分割出来,其他两张图的分割结果也都有很大的噪声;图(d)是文中算法分割结果。将超像素的大小设置为 $K=80$ 或 $K=100$,从上至下分别取 $\gamma=$

$0.1, \alpha=0.05, \gamma=0.5, \alpha=0.01, \gamma=0.1, \alpha=0.01$ 。由仿真实验结果可看出,文中算法能够很好地将目标物与背景分割出来,且有相对较好的分割效果。




图 3 自然图像的图像分割结果

5.3 算法存在的不足

图 4 中,图(a)、(c)为原始图像,图(b)、(d)为文中算法分割结果。从图(b)可看出,因为目标物的颜色不相似,小狗身上的黑色区域不连通,该算法不能把目标物分割开。而在对超像素进行聚类的过程中,缺乏对空间信息的考虑,所以对这类图像进行图像分割时,会把原本应该分割成同一区域的分割成了很多部分,达不到分割的效果。从图(d)可看出,天空、白云和山脉分割效果较好,而目标物因为与背景颜色很相近,未把它分割出来。这些缺点也是后续要继续努力的地方。

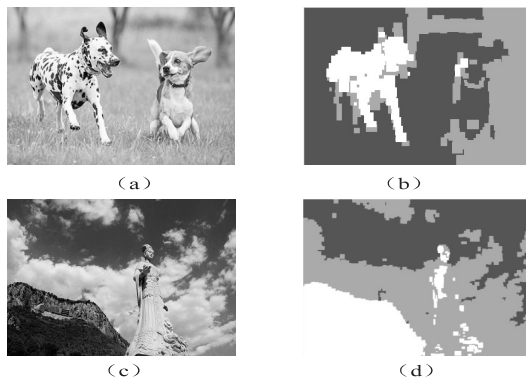


图 4 文中算法分割结果

6 结束语

针对传统图像分割方法基于单个像素对图像进行分割造成的分割结果不稳定等问题,提出了一种基于图像超像素分析的图像分割方法。通过构建超像素的距离矩阵,将 SLIC 算法与 DPCA 聚类算法相结合,实现对图像的分割。实验结果表明,该方法有较好的分割效果,能够将目标物和背景清晰地分割开。但该方法

(下转第 47 页)

参考文献:

[1] BAR-SHALOM Y,FORTMANN T E. Tracking and data association[M]. [s. l.] :Academic Press,1988.

[2] BAR-SHALOM Y,LI X R,KIRUBARAJAN T. Estimation with applications to tracking and navigation[M]. New York: Wiley-Interscience,2001.

[3] HALL D L. Mathematic techniques in multi-sensor data fusion[M]. Boston,MA:Artech House Publishers,1992.

[4] KALMAN R E. A new approach to linear filtering and prediction problems[J]. Journal of Basic Engineering Transactions,1960,82,35-45.

[5] SIMON D. Optimal state estimation[M]. New York:Wiley-Interscience,2006.

[6] 韩崇昭,朱洪艳,段战胜. 多源信息融合[M]. 第2版. 北京:清华大学出版社,2010.

[7] ARULAMPALAM M S,MASKELL S,GORDON N,et al. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking[J]. IEEE Transactions on Signal Processing,2002,50(2):174-188.

[8] CAPPE O, GODSILL S J, MOULINES E. An overview of existing methods and recent advances in sequential Monte Carlo[J]. Proceedings of the IEEE,2007,95(5):899-924.

[9] JULIER S,UHLMANN J K. Unscented filtering and nonlinear estimation[J]. Proceeding of the IEEE,2004,92(2):401-422.

[10] TO K, XIONG K. Gaussian filters for nonlinear filtering

(上接第28页)

法也存在一定的不足,未来做进一步改进,把 SLIC 算法和 DPCA 聚类算法更好地结合在一起,使分割效果达到更好。

参考文献:

[1] 何 俊,葛 红,王玉峰. 图像分割算法研究综述[J]. 计算机工程与科学,2009,31(12):58-61.

[2] 张旭东,吕言言,缪永伟,等. 基于区域协方差的图像超像素生成[J]. 计算机科学,2016,43(5):318-322.

[3] STOCKMAN G,SHAPIRO L G. Computer vision[M]. [s. l.] :Prentice Hall,2001:201-213.

[4] KANUNGO T,MOUNT D M,NETANYAHU N S,et al. An efficient k-means clustering algorithm: analysis and implementation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2002,24(7):881-892.

[5] SON L H,CUONG B C,LANZI P L,et al. A novel intuitionistic fuzzy clustering method for geo-demographic analysis[J]. Expert Systems with Applications,2012,39(10):9848-9859.

[6] 周文刚,孙 挺,朱 海. 一种基于自适应空间信息改进 FCM 的图像分割算法[J]. 计算机应用研究,2015,32(7):2205-2208.

[7] ESTER M,KRIEDEL H P, SANDER J. et al. A density-

problems[J]. IEEE Transactions on Automatic Control,2000,45(5):910-927.

[11] ARASARATNAM I,HAYKIN S,ELLIOTT R J. Discrete-time nonlinear filtering algorithms using Gauss-Hermite quadrature[J]. Proceedings of the IEEE,2007,95(5):953-977.

[12] ARASARATNAM I,HAYKIN S. Square-root quadrature Kalman filtering[J]. IEEE Transactions on Signal Processing,2008,56(6):2589-2593.

[13] 周东华,席裕庚,张钟俊. 非线性系统的带次优渐消因子的扩展卡尔曼滤波[J]. 控制与决策,1990,5(5):1-6.

[14] 周东华,席裕庚,张钟俊. 一种带多重次优渐消因子的扩展卡尔曼滤波器[J]. 自动化学报,1991,17(6):689-695.

[15] 付梦印,邓志红,闫丽萍. Kalman 滤波理论及其在导航系统中的应用[M]. 北京:科学出版社,2010:100-103.

[16] 范文兵,刘春风,张素贞. 一种强跟踪扩展卡尔曼滤波器的改进算法[J]. 控制与决策,2006,21(1):73-76.

[17] 张文玲,朱明清,陈宗海. 基于强跟踪 UKF 的自适应 SLAM 算法[J]. 机器人,2010,32(2):190-195.

[18] 胡昌华,张 琪,乔玉坤. 强跟踪粒子滤波算法及其在故障预报中的应用[J]. 自动化学报,2008,34(12):1522-1528.

[19] 马丽丽,贺 珊,陈金广. 强跟踪求积分卡尔曼滤波算法[J]. 计算机工程与设计,2014,35(5):1802-1806.

[20] 钱华明,葛 磊,黄 蔚. 一种改进的强跟踪滤波算法[J]. 应用科学学报,2015,33(1):32-40.

based algorithm for discovering clusters a density-based algorithm for discovering clusters in large spatial databases with noise[C]//International conference on knowledge discovery and data mining. [s. l.] : AAAI Press,1996:226-231.

[8] 李志梅,肖德贵. 改进的快速模糊聚类图像分割算法[J]. 计算机仿真,2009,26(8):212-215.

[9] 关 昕,周积林. 基于改进谱聚类的图像分割算法[J]. 计算机工程与应用,2014,50(21):184-188.

[10] 曾 山. 模糊聚类算法研究[D]. 武汉:华中科技大学,2012.

[11] 宋熙煜,周利莉,李中国,等. 图像分割中的超像素方法研究综述[J]. 中国图象图形学报,2015,20(5):599-608.

[12] ACHANTA R,SHAJI A,SMITH K,et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2012,34(11):2274-2282.

[13] 由柏娇. 一种基于超像素的彩色图像分割算法[D]. 哈尔滨:哈尔滨工程大学,2015.

[14] RODRIGUEZ A,LAIO A. Machine learning: clustering by fast search and find of density peaks[J]. Science,2014,344(6191):1492-1496.

[15] REN X,MALIK J. Learning a classification model for segmentation[C]//Ninth IEEE international conference on computer vision. Nice,France:IEEE,2003:10-17.