

基于球簇聚类的超像素分割迭代算法

刘垚, 官礼和

引用本文

刘垚, 官礼和. 基于球簇聚类的超像素分割迭代算法[J]. 计算机科学, 2023, 50(6A): 220600114-7.

LIU Yao, GUAN Lihe. [Superpixel Segmentation Iterative Algorithm Based on Ballk-means Clustering](#) [J]. Computer Science, 2023, 50(6A): 220600114-7.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于流线距离聚类的海洋数据向量场可视化](#)

Visualization of Ocean Data Vector Field Based on Streamline Distance Clustering
计算机科学, 2023, 50(6A): 220300284-7. <https://doi.org/10.11896/jsjcx.220300284>

[基于DBSCAN的动态邻域密度聚类算法](#)

Dynamic Neighborhood Density Clustering Algorithm Based on DBSCAN
计算机科学, 2023, 50(6A): 220400127-7. <https://doi.org/10.11896/jsjcx.220400127>

[基于SegFormer的超声影像图像分割](#)

Ultrasonic Image Segmentation Based on SegFormer
计算机科学, 2023, 50(6A): 220400273-6. <https://doi.org/10.11896/jsjcx.220400273>

[基于主动学习和U-Net++分割的芯片封装空洞率的研究](#)

Study on BGA Packaging Void Rate Detection Based on Active Learning and U-Net++ Segmentation
计算机科学, 2023, 50(6A): 220200092-6. <https://doi.org/10.11896/jsjcx.220200092>

[基于Doc2Vec增强特征的长文本主题聚类研究](#)

Study on Long Text Topic Clustering Based on Doc2Vec Enhanced Features
计算机科学, 2023, 50(6A): 220800192-6. <https://doi.org/10.11896/jsjcx.220800192>

基于球簇聚类的超像素分割迭代算法

刘 焱 官礼和

重庆交通大学数学与统计学院 重庆 400074

(474890301@qq.com)

摘要 针对超像素分割问题,为了进一步提高超像素边缘贴合度,提出了一种基于球簇聚类的超像素分割迭代算法。首先,将超像素视为五维超球体,对图像进行均匀分割得到初始超像素及其中心和半径;其次,依据邻接超像素中心间的距离及其半径搜索近邻超像素;然后,利用超像素与其近邻超像素中心间的距离,将超像素划分为稳定区和多个环形活跃区;最后,每个环形活跃区内的像素点仅根据其与其部分近邻超像素中心的距离将其分入最近的超像素,如此迭代实现超像素分割。为了减少距离计算量以加快收敛速度,给出了近邻超像素关系判定定理,对像素点的超像素类标签设计了一种自适应分区更新策略。在BSD500数据集上与多种典型超像素分割算法进行了实验对比,结果表明该算法对不同类型图像的分割效果均较好,边缘贴合度更高,且受参数影响较小,分割结果更稳定。

关键词: 图像分割;超像素;聚类;球簇

中图法分类号 TP391

Superpixel Segmentation Iterative Algorithm Based on Ball- k -means Clustering

LIU Yao and GUAN Lihe

School of Mathematics and Statistics,Chongqing Jiaotong University,Chongqing 400074,China

Abstract Considering the problem of superpixel segmentation, this paper propose an iterative algorithm of superpixel segmentation based on Ball- k -means clustering to further improve the edge fit of superpixels. Firstly, the superpixels are regarded as five-dimensional hyperspheres, and the image is evenly segmented to obtain the initial superpixels. Secondly, the neighbor superpixels are searched according to the radius and distance between the centers of adjacent superpixels. Then, using the distances between the superpixels and their neighbor superpixel centers, the superpixels are divided into a stable region and multiple ring active regions. Finally, the pixels in each annular active area are divided into the nearest neighbor superpixel only according to their distance from the center of some neighbor superpixels, so as to realize the superpixel segmentation iteratively. In order to reduce the distance calculation and speed up the convergence, a judgment theorem of the relation between the nearest neighbor superpixels is given, and an adaptive partition updating strategy is designed for the superpixel class labels of pixels. Experimental comparison and analysis on BSD500 data set show that the proposed algorithm has better segmentation effect on different types of images, with higher edge fitting degree, less influence by parameters, and more stable segmentation results.

Keywords Image segmentation, Superpixel, Clustering, Ball cluster

1 引言

超像素分割指将图像中具有相似颜色、纹理、灰度等特征的像素点聚集成一个像素块,从而降低后续图像特征提取的计算量和提高识别精度^[1]。超像素分割是当前图像处理的重要研究内容之一,在目标跟踪^[2-3]、显著性检测^[4-5]、遥感图像处理^[6-8]、医学影像分析^[9-10]等领域获得了广泛应用。

自超像素分割被提出以来,学者们将图像视为带权无向图,基于图的划分策略提出了超像素分割算法^[11-13]。该 Shi 等^[11]提出的规则化分割算法(Normalized Cuts, N-cuts),融合颜色、亮度、纹理、轮廓等信息,通过不断迭代优化图划分的代价函数,实现超像素分割。Felzensalb 等^[12]基于图的贪心聚类策略提出了一种超像素分割算法,而 Liu 等^[13]采用随机

游走的熵率和平衡项构建目标函数,提出了一种熵率超像素分割算法(Entropy Rate Superpixel Segmentation, ERS)。基于图的超像素分割算法由于所构造图结构的复杂性,导致了算法的复杂度较高、分割目标的边缘贴合度不高等问题。近年来,基于各种聚类策略的超像素分割算法已成为研究热点。Levinshstein 等^[14]通过水平集不断扩大种子像素的范围,提出了基于几何流的超像素分割算法(Turbopixel),该算法考虑了颜色和梯度,分割效果依赖于初始种子点的设置,且对细长物体的分割结果较差。Achant 等^[15]提出的简单线性迭代聚类算法(Simple Linear Iterative Clustering, SLIC),采用像素点的颜色空间和位置信息组成五维特征,均匀化种子点,进行局部聚类,得到较规则的超像素,但边缘贴合度不高。后来, Li 等^[16]将像素点映射成十维特征向量,提出了线性谱聚类

基金项目: 国家自然科学基金(12271067);重庆市高校创新研究群体项目(CXQT21021);重庆市研究生联合培养基地建设项目(JDLHPYJD2021016)

This work was supported by the National Natural Science Foundation of China(12271067),Chongqing University Innovation Research Group Project(CXQT21021) and Chongqing Postgraduate Joint Training Base Construction Project(JDLHPYJD2021016).

通信作者:官礼和(guanlihe@cjtu.edu.cn)

算法 (Linear Spectral Clustering, LSC), 得到边缘贴合度较好的超像素。Zhang 等^[17] 基于密度峰值搜索聚类策略, 提出了一种无需迭代的超像素分割算法, 该方法仅根据像素点的密度计算归属产生大小和数目可控的超像素, 但分割结果欠规则。Lei 等^[18] 基于 SLIC 生成初始超像素, 不断对边缘不稳定像素点进行迭代标记得到紧凑的超像素。为提高效率, Loke 等^[19] 使用并行 DBSCAN 聚类算法简化了搜索过程, 利用内存缓冲区处理像素点的分配过程, 提高了处理速度。同时, 为了利用图像信息, Wu 等^[20] 结合图像纹理信息, 优化了强梯度纹理图像的分割效果。

超像素分割本质上是一个像素点聚类问题。 k -means 聚类每次迭代都会遍历整个解空间以获得最优聚类。最近, Xia 等^[21] 为了减少经典的 k -means 聚类中的距离计算量, 提出了一种无界快速自适应的 Ball- k -means 算法。该方法使用超球体来划分度量空间, 视每个类为一个超球, 获得了超球间更加精确的近邻关系, 提高了聚类效率。为了更精确地分割图像, 提升超像素边缘贴合度, 本文将 Ball- k -means 聚类算法^[21] 用于超像素分割, 提出了基于球簇聚类的超像素的分割迭代算法。该算法将每个超像素视为五维的超球体, 通过计算其中心和半径, 依据超像素中心间距离与半径的关系得到超像素间的近邻关系, 同时对超像素进行分区聚类, 提高了超像素的分割效率和稳定性, 获得了与物体真实边界贴合度高、轮廓清晰的分割结果。

2 基于球簇聚类的超像素分割

本文算法的基本思想是以五维超球体描述超像素, 利用 Ball- k -means 聚类方法^[21] 进行超像素分割。首先, 依据超像素设定数目对图像进行均匀分割, 得到初始超像素; 其次, 依据超像素的半径与其邻接超像素中心距离的关系定义超像素间的近邻关系; 然后, 以超像素的中心与其每个近邻超像素中心距离的一半为临界值, 将超像素划分为稳定区和多个环形活跃区; 最后, 稳定区内像素点的超像素类标签保持不变, 而环形活跃区的像素点仅需计算其与部分近邻超像素中心的距离, 并将其分入最近的超像素, 如此达到最大迭代次数, 使得所有超像素中心稳定, 实现图像的超像素分割。算法的流程如图 1 所示。

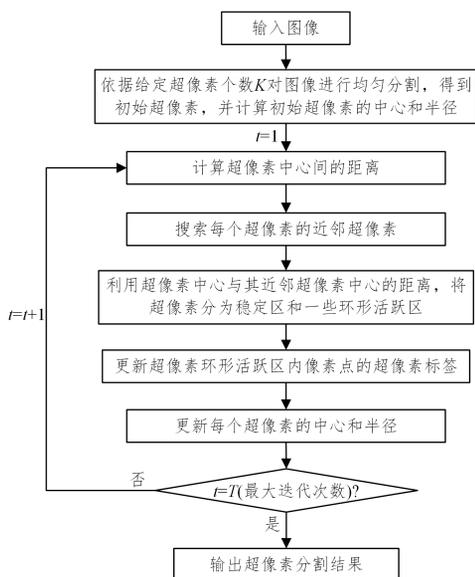


图 1 算法流程图

Fig. 1 Algorithm flow chart

2.1 初始化超像素

输入 CIELAB 颜色空间的彩色图像, 每个像素点均可描述为一个五维特征向量, 即 $(x_i, y_i, l_i, a_i, b_i)^T, i=1, 2, \dots, N$, 其中 x_i, y_i 为像素点 i 的平面位置信息, l_i, a_i 和 b_i 分别为像素点 i 的亮度和两个色度, N 表示图像像素总数。图像进行初始分割时, 为避免随机分割带来的不稳定性, 对输入图像依据设定的超像素个数 K 进行均匀分割为一种合适的选择。将图像分割为大小均匀的 K 个图像块, 使得每一个图像块包含 N/K 个像素点, 同时给每个图像块分配唯一的超像素标签, 即可得到图像的初始超像素分割, 并作为迭代算法的输入。

2.2 计算超像素中心和半径

每个像素点包含 5 个特征信息, 由此本文采用五维超球体来描述超像素。每个超像素内所有像素点的特征均值作为超球中心, 即超像素中心; 像素点与中心最远的距离值作为超球半径。像素点 i 和 j 的距离计算式定义为^[15]:

$$D(p_i, p_j) = \sqrt{D_1^2 + \alpha (D_2/s)^2} \quad (1)$$

其中, p_i 和 p_j 分别表示像素点 i 和 j 的特征向量, 像素点 i 和 j 的平面距离和颜色特征距离分别为 $D_1 = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}$ 和 $D_2 = \sqrt{(l_i - l_j)^2 + (a_i - a_j)^2 + (b_i - b_j)^2}$, 参数 $s = \sqrt{N/K}$, α 为 D_2 权重调整参数, 其取值范围一般为 $[1^2, 40^2]$ 。

定义 1 设 $C_k (k=1, 2, \dots, K)$ 为一个超像素, 将其看作一超球体, 则其中心 c_k 和半径 r_k 定义为:

$$c_k = \frac{1}{n_k} \sum_{i=1}^{n_k} (x_i, y_i, l_i, a_i, b_i)^T = (\bar{x}_k, \bar{y}_k, \bar{l}_k, \bar{a}_k, \bar{b}_k)^T \quad (2)$$

$$r_k = \max\{D(c_k, p) \mid p \in C_k\} \quad (3)$$

其中, n_k 表示超像素 C_k 中像素点的总数, p 表示 C_k 中像素点的特征向量。

2.3 近邻超像素搜索

在 SLIC 算法^[15] 中, 聚类中心是利用像素点的平面位置关系在其 $2s \times 2s$ 范围内进行搜索, 未考虑像素点的颜色特征, 导致超像素边缘贴合度不高。为此, 可综合像素点的五维特征信息定义超像素间的近邻关系, 如定义 2 所示。

定义 2 设第 t 次迭代时超像素 C_k 的中心为 c_k^t 、半径为 r_k^t , 考虑与 C_k 在平面上有共同边界的邻接超像素 C_i^t , 其中心为 c_i^t , 若 $D(c_k^t, c_i^t) < 2r_k^t$, 则称超像素 C_i^t 是超像素 C_k^t 的近邻超像素。

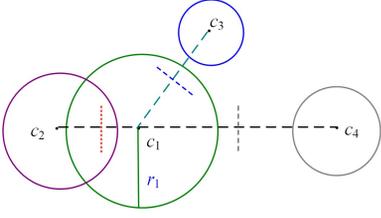
本文中, 记 $NB(C_k)$ 为与超像素 C_k 在平面上有共同边界的所有邻接超像素中心的集合, 称为超像素 C_k 的邻接超像素中心集; $N(C_k) = \{c_i^t \in NB(C_k) \mid D(c_k^t, c_i^t) < 2r_k^t\}$ 为超像素 C_k 的近邻超像素中心集。

定理 1 设第 t 次迭代时超像素 C_k 的中心为 c_k^t 、半径为 r_k^t , 考虑超像素 C_m (中心为 c_m^t) 和 C_n (中心为 c_n^t), 若 $c_m^t \in N(C_k)$ 且 $c_n^t \notin N(C_k)$, 则超像素 C_k 中的像素点可能会分配给 C_m^t , 但不会分配给 C_n^t 。

证明: 首先, 由 $c_m^t \in N(C_k)$ 可知, C_m 是 C_k 的近邻超像素, 于是有 $D(c_k^t, c_m^t) < 2r_k^t$ 。考虑 c_k^t 与 c_m^t 连线上的像素点 $q \in C_k$ 且 $2D(c_k^t, q) > D(c_k^t, c_m^t)$, 由 $D(c_k^t, c_m^t) = D(c_k^t, q)$, 即 $D(c_k^t, q) > D(c_m^t, q)$ 。因此, C_k 中的像素点可能会分配给其近邻超像素 C_m^t 。

其次,对于 $\forall q \in C_k^i$,有 $D(c_k^i, q) \leq r_k^i$ 。由 $c_n^i \notin N(C_k^i)$ 可知, C_n^i 不是 C_k^i 的近邻超像素,于是 $D(c_k^i, c_n^i) \geq 2r_k^i$,从而 $D(c_k^i, c_n^i) \leq D(c_k^i, q) + D(c_n^i, q)$ 。又因为 $D(c_k^i, c_n^i) \leq D(c_k^i, q) + D(c_n^i, q)$,因此 $2D(c_k^i, q) \leq D(c_k^i, q) + D(c_n^i, q)$,即 $D(c_k^i, q) \leq D(c_n^i, q)$ 。因此, C_k^i 中的像素点不会分配给其非近邻超像素 C_n^i 。

定理1表明,算法在迭代过程中,给定超像素中的像素点只可能分配到其近邻超像素中,但不会分配到非近邻超像素中。因此,在每次迭代时可先搜索出每个超像素的所有近邻超像素,然后将该超像素中的像素点仅在其近邻超像素中调整即可。超像素间的近邻关系不一定是对称的,如图2所示。 C_1 与 C_2 互为近邻超像素; C_3 是 C_1 的近邻超像素,但 C_1 不是 C_3 的近邻超像素; C_1 与 C_4 互不为近邻超像素。



注:虚线表示超像素中心连线的平分线

图2 超像素间近邻关系说明

Fig. 2 Description of neighbor relation between superpixels

2.4 超像素中心间的距离计算

依据定义2可知,超像素中心间的距离计算是判定超像素间近邻关系的关键,定理2给出了一种超像素间近邻关系的简单判定方法。

定理2 设第 t 次迭代时超像素 C_k^i 的中心为 c_k^i ,在第 $t-1$ 和第 t 次迭代中距离变化量 $\Delta(c_k^i) = D(c_k^{t-1}, c_k^t)$ 。考虑超像素 C_l^i (中心为 c_l^i),若 $D(c_k^{t-1}, c_l^{t-1}) \geq 2r_k^i + \Delta(c_k^i) + \Delta(c_l^i)$,则在第 t 次迭代中 C_l^i 不是 C_k^i 的近邻超像素。

证明:由图3所示的超像素中心间距离变化关系可知, $D(c_k^i, c_l^i) \geq D(c_k^{t-1}, c_l^{t-1}) - \Delta(c_k^i) - \Delta(c_l^i)$ 。由 $D(c_k^{t-1}, c_l^{t-1}) \geq 2r_k^i + \Delta(c_k^i) + \Delta(c_l^i)$,得 $D(c_k^i, c_l^i) \geq 2r_k^i + \Delta(c_k^i) + \Delta(c_l^i) - \Delta(c_k^i) - \Delta(c_l^i) = 2r_k^i$,即 $D(c_k^i, c_l^i) \geq 2r_k^i$ 。由定义2可知,在当前迭代中 C_l^i 不是 C_k^i 的近邻超像素,从而可在当前迭代中省略两个中心间的距离计算。

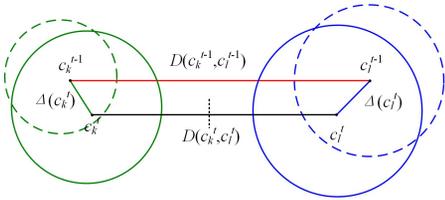


图3 超像素中心变化距离说明

Fig. 3 Superpixel center change distance description

定理2表明,算法在每次迭代中可利用超像素中心变化距离和中心间距离对超像素间的非近邻关系进行提前判定,在当前迭代中就可避免非近邻超像素中心间的距离计算,随着迭代次数增加,超像素中心间距离的计算量会大幅度减少。

2.5 超像素分区聚类

根据定理1可知,每个超像素中像素点的超像素标签只在其近邻超像素中调整。为了使像素点的超像素标签能够更快更精确地被调整,可利用超像素中心与其所有近邻超像素中心的距离,将该超像素划分为稳定区和多个环形活跃区,对

不同区域内像素点的标签分别进行调整。具体操作为:考虑一个给定的超像素,首先利用定义2搜索出其所有近邻超像素,然后计算超像素中心与其近邻超像素中心的距离,以每一个中心间距离的一半为半径,在给定超像素内画出一些同心超像素,最小的同心超像素即为稳定区,其余相邻同心超像素间的区域为环形活跃区,如定义3所示。

定义3 设第 t 次迭代时超像素 C_k^i 的中心为 c_k^i ,且近邻超像素中心集 $N(C_k^i)$ 非空,不妨设 $N(C_k^i) = \{c_h^i | h = 1, 2, \dots, m\}$ 且满足 $D(c_k^i, c_h^i) < D(c_k^i, c_{h+1}^i)$,则超像素 C_k^i 的稳定区为 $SR(C_k^i) = \{p \in C_k^i | 2D(c_k^i, p) \leq D(c_k^i, c_1^i)\}$,活跃区为 $AR(C_k^i) = C_k^i - SR(C_k^i)$,第 h 个环形活跃区为:

$$(1)R_h(C_k^i) = \{p \in C_k^i | \frac{1}{2}D(c_k^i, c_h^i) < D(c_k^i, p) \leq \frac{1}{2}D(c_k^i, c_{h+1}^i)\}, h = 1, 2, \dots, m-1;$$

$$(2)R_m(C_k^i) = \{p \in C_k^i | \frac{1}{2}D(c_k^i, c_h^i) < D(c_k^i, p) \leq r_k^i\}, h = m.$$

在定义3中, $D(c_k^i, c_1^i) = \min_{c_l^i \in N(C_k^i)} D(c_k^i, c_l^i)$,且若 $N(C_k^i)$ 为

空,则该超像素 C_k^i 的稳定区就是其本身。对超像素稳定区和环形活跃区内像素点的超像素标签调整方法如定理3所述。

定理3 考虑第 t 次迭代时的超像素 C_k^i ,中心为 c_k^i ,近邻超像素中心集为 $N(C_k^i)$,则在当前迭代中:1)稳定区 $SR(C_k^i)$ 内像素点的超像素标签保持不变;2)第 $h(h = 1, 2, \dots, m)$ 个环形活跃区 $R_h(C_k^i)$ 内像素点的超像素标签仅可能在前 h 个近邻超像素中调整或保持不变。

证明:(1)对于 $\forall p \in SR(C_k^i)$,由定义3有 $2D(c_k^i, p) \leq \min_{c_l^i \in N(C_k^i)} D(c_k^i, c_l^i) = D(c_k^i, c_1^i)$ 。又因为 $D(c_k^i, c_1^i) \leq D(c_k^i, p) + \min_{c_l^i \in N(C_k^i)} D(c_l^i, p)$,故 $2D(c_k^i, p) \leq D(c_k^i, p) + \min_{c_l^i \in N(C_k^i)} D(c_l^i, p)$,即 $D(c_k^i, p) \leq \min_{c_l^i \in N(C_k^i)} D(c_l^i, p)$ 。因此,像素点 p 的超像素标签保持不变。由 p 的任意性可知,在当前迭代中稳定区像素点的超像素标签不变。

(2)当 $h = m$ 时,对于 $\forall p \in R_m(C_k^i)$,由定义3有 $D(c_k^i, p) \leq r_k^i$,依据定理1可知像素点 p 的超像素标签只可能在 C_k^i 的所有近邻超像素中调整或保持不变,故此时结论成立。当 $h < m$ 时,由定义3有 $2D(c_k^i, p) \leq D(c_k^i, c_{h+1}^i)$,又因为 $D(c_k^i, c_{h+1}^i) \leq D(c_k^i, p) + D(c_{h+1}^i, p)$,从而有 $2D(c_k^i, p) \leq D(c_k^i, p) + D(c_{h+1}^i, p)$,即 $D(c_k^i, p) \leq D(c_{h+1}^i, p)$ 。故此时环形活跃区 $R_h(C_k^i)$ 内像素点的超像素标签仅可能在前 h 个近邻超像素中调整或保持不变。综上所述,结论成立。

定理3表明,在当前迭代中,超像素稳定区内像素点的超像素标签保持不变,而不同环形活跃区内像素点的超像素标签仅在部分近邻超像素中调整或保持不变。如图4所示, c_1 和 c_2 分别是超像素 C 的近邻超像素 C_1 和 C_2 的中心,且 C_1 是最近邻超像素,绿色的区域为 C 的稳定区,黄色和白色区域分别为 C 的第1和第2环形活跃区, p_0, p_1 和 p_2 分别处于稳定区和第1、2环形活跃区,于是 p_0 的超像素标签保持不变, p_1 仅可能分配到 C 和 C_1 两者之一, p_2 仅可能分配到 C, C_1 和 C_2 三者之一。显然,环形活跃区离超像素中心越远,其内的像素点越有可能是边界像素点。

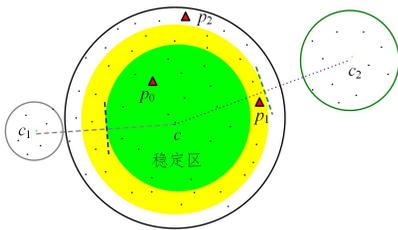


图4 分区示意图(电子版为彩图)

Fig. 4 Partition diagram

2.6 算法描述

基于 Ball-k-means 聚类^[21]的思想,将每个超像素描述为一个五维超球体,综合前述讨论和分析,算法1详细描述了基于球簇聚类的超像素分割迭代算法。

算法1 基于球簇聚类的超像素分割迭代算法

输入:图像 I,超像素个数 K,距离计算权重参数 α 以及最大迭代次数 T
输出:超像素分割结果

1. 初始化:设图像 I 的像素总数为 N,距离计算参数 $s = \sqrt{N/K}$ 。以网格形式将图像均匀分割成 K 个初始超像素,记为 C_k^0 ,中心为 c_k^0 ,且 C_k^0 中像素点 p 的超像素标签 $label(p) = k$,其中 $k = 1, 2, \dots, K$ 。
2. FOR $t = 1$ to T DO
3. FOR $k = 1$ to K DO
4. 计算超像素 C_k^t 中心 c_k^t 和半径 r_k^t ;
5. 计算超像素的近邻超像素中心集 $N(C_k^t) = \{c_l^t \in NB(C_k^t) \mid D(c_k^t, c_l^t) < 2r_k^t\}$,其中 $NB(C_k^t)$ 为 C_k^t 的邻接超像素中心集,且若 $D(c_k^{t-1}, c_l^{t-1}) \geq 2r_k^t + \Delta(c_k^t) + \Delta(c_l^t)$,否则 $D(c_k^t, c_l^t) = \sqrt{(D_1(c_k^t, c_l^t))^2 + \alpha (D_2(c_k^t, c_l^t)/s)^2}$;
6. IF $N(C_k^t) \neq \emptyset$ THEN
7. 对于 $\forall c_l^t \in N(C_k^t)$,计算超像素的中心 c_k^t 与其近邻超像素中心 c_l^t 间的距离 $D(c_k^t, c_l^t)$,不妨设 $D(c_k^t, c_l^t) \leq D(c_k^t, c_2^t) \leq \dots \leq D(c_k^t, c_m^t)$,其中 $m = |N(C_k^t)|$;
8. 对 $\forall q \in C_k^t$,更新 $label(q)$:若 $2D(c_k^t, p) \leq D(c_k^t, c_l^t)$,则 $label(q) = k$;若 $D(c_k^t, c_h^t) < 2D(c_k^t, q) \leq D(c_k^t, c_{h+1}^t)$,则 $label(q) = \arg \min_{l \in \{k, 1, 2, \dots, h\}} D(c_l^t, q)$;若 $2D(c_k^t, q) \geq D(c_k^t, c_m^t)$,则 $label(q) = \arg \min_{l \in \{k, 1, 2, \dots, m\}} D(c_l^t, q)$;
9. ENDIF

10. ENDFOR
11. $t = t + 1$
12. ENDFOR
13. 输出超像素分割结果。

2.7 复杂度分析

设待超像素分割的图像包含 N 个像素点,超像素个数为 K ,算法1在每次迭代中需对每个超像素搜索其近邻超像素,同时更新该超像素内所有像素点的超像素标签。由定义2和定理2可知,进行近邻超像素搜索需计算中心间的距离,其复杂度最大为 $O(K^2)$ 。同时,在对像素点进行分类时,需计算像素点与其初始中心的距离,复杂度为 $O(N)$ 。设近邻超像素个数为 $m (1 \leq m < K)$,活跃区内像素点个数为 N' ,在更新活跃区内像素点的超像素标签时,需计算活跃区像素点与近邻超像素中心的距离,并对这些距离进行排序,其复杂度约为 $O(mN' + Km \log m)$ 。因此,算法1在最坏情况下,每次迭代的复杂度约为 $O(K^2 + N + mN' + Km \log m)$ 。随着迭代次数的增加,每次迭代的复杂度会降低。

3 实验结果与分析

为了验证算法1的视觉分割和边缘拟合效果,选取了4种超像素分割算法 SLIC^[15], LSC^[16], Turbopixel^[14] 和 ERS^[13] 进行实验对比。实验数据集采用 Berkeley 数据集 BSD500^[22],该数据集有500幅 321×481 的图像,每幅图像带有5~10人手工标注的分割结果。本文根据不同类型图像选取了部分图像,对算法1在视觉分割效果、边缘拟合效果和算法稳定性3个方面进行了实验分析。算法编程语言为 MATLAB R2019a,运行环境为 Intel (R) Core (TM) i5-8265U 1.6 GHz 和 8 GB 内存,64 位 window10 系统。算法1中各类图像的最大迭代次数 $T = 12$ 。此外,4种有代表性的算法采用公开可用代码实现,参数均采用默认参数。

3.1 视觉分割效果

从 BSD500 中选取了编号为 118035, 135069 和 24063 的3幅不同类型图像进行实验,超像素个数统一设为 $K = 100$,参数 $\alpha = 200$ 。各种算法的超像素分割效果图如图5所示,其中图5(a)~图5(c)的左边为整体效果图,右边为部分细节分割图。

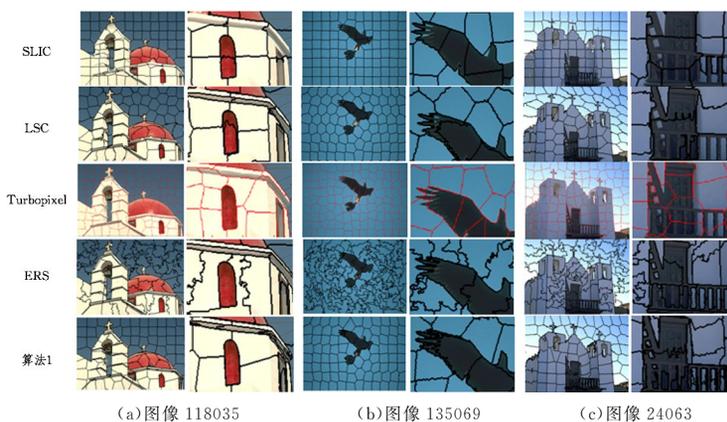


图5 各种算法超像素分割结果对比

Fig. 5 Comparison of superpixel segmentation results of various algorithms

从图5(a)可见,仅有算法1能将十字架、窗户、门等物体完整分割成独立的超像素块;从图5(b)可见,ERS算法和算法1的分割结果对老鹰翅膀能够完全贴合;从图5(c)可见,仅有算法ERS和算法1能将栏杆和扶梯的

空隙分割出来。由此可见,从超像素的形状和边缘贴合程度来看,算法1能得到边缘贴合度较高和边缘附着性能较好的超像素分割结果,且对于弱边界也有很好的分割效果。

3.2 边缘拟合效果

边缘召回率(Boundary Recall, BR)、欠分割误差率(Under-segmentation Error, UE)和可达分割精度(Achievable Segmentation Accuracy, ASA)是衡量超像素边缘与真实物体边缘一致性的3个常用评价指标^[23-24]。BR指与超像素边缘的距离小于2像素的真实边缘占有所有真实边缘的比例,其值越高,说明真实边缘丢失得越少,超像素边缘的贴合度越高。UE反映了超像素分割中溢出到真实分割之外的像素数,而ASA则反映了超像素分割在真实分割之内的像素数。BR,

UE和ASA的具体定义可见文献[23]。

图6给出了各种算法在BSD500图像集^[18]中随机选取100张图片的平均指标曲线,其中图6(a)~图6(c)分别是BR,UE,ASA与超像素个数K的关系。从各项性能可见,算法1的分割效果最佳。表1列出了各种算法在10幅不同类别图像上进行超像素分割结果的ASA, BR和UE,超像素个数统一设定为K=300。从表1可以发现,算法1在边缘贴合度方面具有优势,尤其是图像边缘召回率普遍高于其余几种算法。

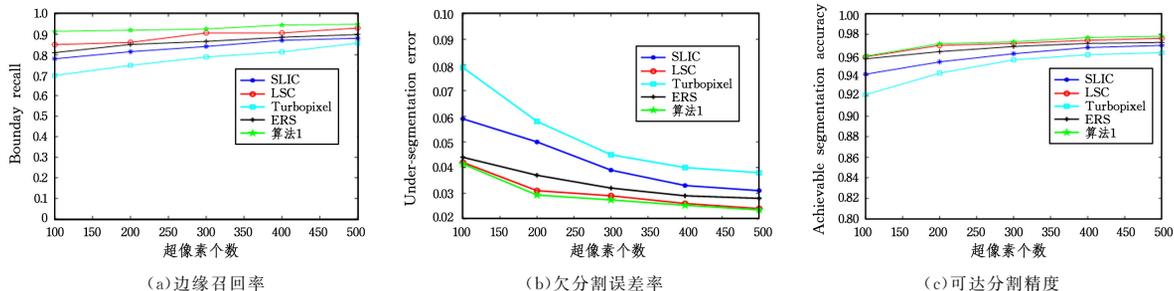


图6 各种算法在BSD500上的性能对比

Fig. 6 Performance comparison of various algorithms on BSD500

表1 K=300时各类图像边缘贴合能力对比

Table 1 Comparison of boundary fitting ability of various images when K=300

图像类型	图片编号	SLIC (ASA, BR, UE)	LSC (ASA, BR, UE)	ERS (ASA, BR, UE)	算法1 (ASA, BR, UE)
建筑	24063	(0.961, 0.675, 0.039)	(0.959, 0.810, 0.042)	(0.961, 0.810, 0.047)	(0.978, 0.935, 0.022)
	118035	(0.965, 0.770, 0.035)	(0.976, 0.871, 0.024)	(0.972, 0.914, 0.027)	(0.968, 0.901, 0.032)
	3063	(0.991, 0.874, 0.009)	(0.994, 0.936, 0.006)	(0.987, 0.930, 0.006)	(0.994, 0.958, 0.006)
动植物	135069	(0.993, 0.843, 0.007)	(0.997, 0.983, 0.004)	(0.987, 0.988, 0.003)	(0.998, 0.996, 0.002)
	124084	(0.964, 0.754, 0.037)	(0.974, 0.961, 0.020)	(0.961, 0.907, 0.024)	(0.977, 0.986, 0.023)
	196027	(0.921, 0.543, 0.079)	(0.948, 0.808, 0.052)	(0.946, 0.752, 0.046)	(0.932, 0.824, 0.063)
	163014	(0.914, 0.512, 0.086)	(0.959, 0.853, 0.041)	(0.948, 0.754, 0.047)	(0.939, 0.863, 0.061)
	42049	(0.958, 0.721, 0.042)	(0.971, 0.841, 0.029)	(0.969, 0.902, 0.021)	(0.966, 0.923, 0.034)
人物	302003	(0.912, 0.613, 0.088)	(0.951, 0.851, 0.045)	(0.957, 0.883, 0.042)	(0.920, 0.913, 0.080)
	302008	(0.936, 0.588, 0.064)	(0.925, 0.831, 0.047)	(0.904, 0.726, 0.089)	(0.942, 0.813, 0.058)

注:表中加粗数据表示算法获得的最好结果

3.3 算法稳定性

算法1中,距离权重参数 α 的大小影响相应的距离计算值,每次迭代均依据超像素标号从小到大依次顺序更新,且超像素个数需事先设定。为了检验这些因素对算法1超像素分割结果的影响,本节将分别针对 α 取值、超像素个数大小和超像素更新顺序进行实验分析。

(1) 参数 α 对分割结果的影响

对于编号135069和118035的图像,设定超像素个数K=100,参数 α 取8个不同值分别计算超像素分割结果的ASA, BR和UE,如图7所示。

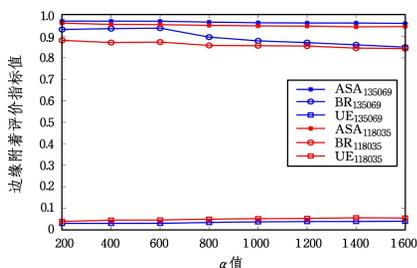


图7 α 变化的边缘贴合评价指标曲线

Fig. 7 Boundary fit evaluation index curve as α changes

从图7可见,参数 α 对ASA和UE的影响很小,而BR则

随着参数 α 的增大有所下降,特别是在图像135069上较明显。其原因在于 α 的取值会影响超像素规则性,其值越大,超像素越规则,与边界的贴合度会略微下降。从整体来看,参数 α 对分割结果的影响较弱。

(2) 超像素个数对分割结果的影响

对于编号118035和135069的图像,超像素个数K分别设定为100, 150, 200, 250, 300,各种算法的超像素分割结果如表2所列。从表2可见,算法SLIC边缘贴合能力指标均值最差,虽然算法LSC和ERS对图像118035的指标均值略优于算法1,但是对于图像135069,算法1的指标均值却是更优的。并且,算法1在不同的K值下,边缘贴合能力指标值的方差都最小,说明分割效果最稳定,受超像素个数影响较小。

(3) 超像素更新顺序对分割结果的影响

对算法1中,超像素迭代更新计算分别采取顺序更新和随机选择更新两种策略进行对比实验分析。顺序更新是依据超像素标号从小到大依次进行的,而随机选择更新指从当前未更新的超像素中随机选择一个进行。选取编号为118035和3063的两幅图像为分割对象,超像素分割的边缘贴合效果如表3所列。从表3可见,两种超像素更新策略的ASA, BR和UE指标差异较小,表明算法1具有较高的稳定性。综上所述,与典型的超像素分割算法相比,算法1对于不同类型的

图像能获得较好的分割效果,虽然在色彩丰富的区域分割的超像素形状欠规则,但更加贴合物体的真实边缘,有助于后续

图像的处理。同时,算法 1 对超像素个数和距离权重参数均具有较好的稳定性,且迭代次数少。

表 2 超像素个数的边缘贴合能力对比

Table 2 Comparison of boundary fitting ability of the number of superpixels

图像类型	图片编号	SLIC	LSC	ERS	算法 1
		(ASA, BR, UE)	(ASA, BR, UE)	(ASA, BR, UE)	(ASA, BR, UE)
118035	K=100	(0.9486, 0.7096, 0.0514)	(0.9666, 0.8562, 0.0334)	(0.9687, 0.8934, 0.0284)	(0.9616, 0.8814, 0.0384)
	K=150	(0.9537, 0.7160, 0.0463)	(0.9757, 0.8709, 0.0243)	(0.9717, 0.9136, 0.0271)	(0.9588, 0.8902, 0.0412)
	K=200	(0.9526, 0.7105, 0.0474)	(0.9778, 0.8833, 0.0222)	(0.9799, 0.9191, 0.0191)	(0.9670, 0.8906, 0.0330)
	K=250	(0.9543, 0.7440, 0.0457)	(0.9800, 0.8732, 0.0200)	(0.9810, 0.9343, 0.0183)	(0.9682, 0.9017, 0.0318)
	K=300	(0.9654, 0.7698, 0.0364)	(0.9804, 0.9108, 0.0196)	(0.9844, 0.9550, 0.0151)	(0.9702, 0.9017, 0.0292)
	均值	(0.9549, 0.7299, 0.0451)	(0.9761, 0.8788, 0.0239)	(0.9771, 0.9230, 0.0216)	(0.9652, 0.8931, 0.0348)
	方差	(0.0056, 0.0235, 0.0056)	(0.0050, 0.0181, 0.0050)	(0.0059, 0.0206, 0.0052)	(0.0043, 0.0077, 0.0042)
135069	K=100	(0.9904, 0.8508, 0.0096)	(0.9970, 0.9792, 0.0030)	(0.9828, 0.9883, 0.0025)	(0.9966, 0.9948, 0.0034)
	K=150	(0.9884, 0.7886, 0.0106)	(0.9965, 0.9559, 0.0035)	(0.9867, 0.9883, 0.0026)	(0.9973, 0.9961, 0.0027)
	K=200	(0.9963, 0.9144, 0.0037)	(0.9962, 0.9637, 0.0038)	(0.9893, 0.9883, 0.0024)	(0.9974, 0.9922, 0.0026)
	K=250	(0.9955, 0.8560, 0.0045)	(0.9968, 0.9805, 0.0032)	(0.9976, 0.9948, 0.0023)	(0.9974, 0.9961, 0.0026)
	K=300	(0.9934, 0.8431, 0.0066)	(0.9964, 0.9883, 0.0036)	(0.9941, 0.9922, 0.0023)	(0.9976, 0.9961, 0.0024)
	均值	(0.9928, 0.8505, 0.0070)	(0.9965, 0.9735, 0.0034)	(0.9901, 0.9903, 0.0024)	(0.9973, 0.9951, 0.0027)
	方差	(0.0030, 0.0400, 0.0027)	(0.0003, 0.0118, 0.0003)	(0.0053, 0.0027, 0.0003)	(0.0003, 0.0015, 0.0003)

注:表中加粗数据表示算法获得的最好结果

表 3 两种超像素迭代更新策略迭代 5 次时的分割结果对比

Table 3 Comparison of segmentation results at 5 iterations of the two superpixel iterative updating strategies

图像编号	超像素数	顺序更新 (ASA ₁ , BR ₁ , UE ₁)	随机更新 (ASA ₂ , BR ₂ , UE ₂)	差异值
				(ASA ₁ - ASA ₂ , BR ₁ - BR ₂ , UE ₁ - UE ₂)
118035	K=100	(0.9579, 0.8842, 0.0419)	(0.9546, 0.8667, 0.0454)	(0.0033, 0.0175, 0.0035)
	K=150	(0.9581, 0.8782, 0.0421)	(0.9581, 0.8699, 0.0419)	(0.0000, 0.0083, 0.0002)
	K=200	(0.9671, 0.8897, 0.0329)	(0.9612, 0.8778, 0.0388)	(0.0059, 0.0119, 0.0059)
3063	K=100	(0.9706, 0.9358, 0.0294)	(0.9663, 0.8965, 0.0337)	(0.0043, 0.0573, 0.0043)
	K=150	(0.9727, 0.9101, 0.0273)	(0.9710, 0.8821, 0.0290)	(0.0017, 0.0280, 0.0017)
	K=200	(0.9731, 0.8968, 0.0269)	(0.9754, 0.8852, 0.0246)	(0.0023, 0.0116, 0.0023)

结束语 超像素分割是图像预处理的重要研究内容,如何设计边缘附着能力强、紧凑、规则、高效且超像素数目可控的实时超像素分割算法仍旧是一个具有挑战性的问题。本文基于 Ball- k -means 聚类思想,将超像素视为五维的超球体,提出了一种基于球簇聚类的超像素分割迭代算法。利用超球中心和半径,通过分析超像素间的近邻关系,得到了近邻超像素关系判定定理和超像素的自适应分区聚类方法,减少了超像素迭代计算时搜索范围和距离计算量,提高了超像素的分割效率。实验对比分析结果表明,本文算法生成的超像素与物体边界贴合度高,参数依赖性小,分割效果稳定,在颜色均匀区域超像素形状大小较规则,但对色彩丰富区域形状欠规则。

参考文献

- REN X F, MALIK J. Learning a classification model for segmentation[C]//Proceedings of the 9th IEEE International Conference on Computer Vision. Washington, 2003: 10-17.
- YANG F, LU H, YANG M H. Robust Superpixel Tracking [J]. IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society, 2014, 23(4): 1639-1651.
- ZHOU X E, WANG Y N, ZHU Q, et al. SSG: superpixel segmentation and GrabCut-based salient object segmentation[J]. The Visual Computer, 2019, 35(3): 385-398.
- HE S, LAU R, LIU W, et al. SuperCNN: A Superpixel wise Convolutional Neural Network for Salient Object Detection[J]. International Journal of Computer Vision, 2015, 115(3): 330-344.
- LI B, YANG Y, LIU Q. RGB-D video saliency detection via superpixel-level conditional random field[J]. Journal of Image and Graphics, 2021, 26(4): 872-882.
- ZHANG Y M, SUN H Y, XU Y L. An improved hyperspectral image segmentation method based on superpixel[J]. Remote Sensing for Natural Resources, 2019, 31(1): 58-64.
- WANG Y, LIU C, TANG J G. Fuzzy-means clustering with a adaptive multiple features reduction for remote sensing image segmentation [J]. Application Research of Computer, 2022, 39(3): 906-910.
- CHEN B B, FAN J L, LEI B, et al. SLIC superpixel granulation-based rough entropy image segmentation algorithm[J]. Transducer and Microsystem Technologies, 2022, 41(2): 105-107.
- LUCCHI A, SMITH K, ACHANTA R, et al. Supervoxel-based Segmentation of Mitochondria in EM Image Stacks with Learned Shape Features [J]. IEEE Transactions on Medical Imaging, 2012, 31(2): 474-486.
- HU C Y, SI M M, CHEN W. Brain MRI Tumor Segmentation Method Based on Superpixel and Mean Shift [J]. Journal of Chinese Computer Systems, 2022, 43(1): 91-97.
- SHI J B, MALIK J. Normalized cuts and image segmentation [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2000, 22(8): 888-905.
- FELZENSEALB P F, HUTTENLOCHER D P. Efficient graph-based image segmentation [J]. International Journal of Computer Vision, 2004, 59(2): 167-181.
- LIU M Y, TUZEL O, RAMALINGAM S, et al. Entropy rate

- superpixel segmentation[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2011:2097-2104.
- [14] LEVINSHTEIN A, STERE A, KUTULAKOS K N, et al. TurboPixels: Fast superpixels using geometric flows [J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2009, 31(12): 2290-2297.
- [15] ACHANTA R, SHAJI A, SMITH K, et al. Slic superpixels compared to state-of-art superpixel methods[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2012, 34(11): 2274-2282.
- [16] LI Z, CHEN J. Superpixel segmentation using linear spectral clustering[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015:1356-1363.
- [17] ZHANG Z L, LI A H, LI C W. Superpixel Segmentation Based on Clustering by Finding Density Peaks[J]. Chinese Journal of Computers, 2020, 43(1): 1-15.
- [18] LEI T, LIAN Q, JIA X H. Fast Simple Linear Iterative Clustering for Image Superpixel Algorithm [J]. Computer Science, 2020, 47(2): 143-149.
- [19] LOKE S C, MACDONALD B A, PARSONS M, et al. Accelerated superpixel image segmentation with a parallelized DBSCAN algorithm[J]. Journal of Real-Time Image Processing, 2021, 18: 2361-2376.
- [20] WU J, LIU C X. Superpixel segmentation with texture awareness[J]. Journal of Image and Graphics, 2021, 26(5): 1006-1016.
- [21] XIA S, PENG D, MENG D, et al. A Fast Adaptive k-means with No Bounds[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 44(1): 87-99.
- [22] MARTIN D, FOWLKES C, TAL D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics[C]// IEEE International Conference on Computer Vision. IEEE, 2002:1-8.
- [23] STUTZ D, HERMANS A, LEIBE B. Superpixels: An evaluation of the state-of-the-art[J]. Computer Vision and Image Understanding, 2018, 166(1): 1-27.
- [24] XIE X, XIE G, XU X, et al. Adaptive high-precision superpixel segmentation [J]. Multimedia Tools and Applications, 2019, 78(9): 12353-12371.



LIU Yao, born in 1993, postgraduate. Her main research interests include image processing and so on.



GUAN Lihe, born in 1975, Ph.D, associate professor, postgraduate supervisor. His main research interests include intelligent information processing and machine learning.