

结合近邻传播聚类的自适应图像分割

戴 珊 李广军

(北京行政学院信息部 北京 100044) (电信科学技术研究院 北京 100083)

摘要 提出一种统一的图像自动分割模型。为了将图像分为颜色、纹理相近的不同的区域,提出了一个处理方法,具体分为两个步骤,首先,用改进的简单线性迭代聚类算法对输入图像进行预处理,即过分割;然后,用其低阶颜色矩表示这些区域的特征,并进一步利用近邻传播聚类算法将这些区域进行合并。在公开的数据集上进行了详细的实验,结果证明了所提算法的有效性和健壮性。

关键词 图像分割, 过分割, 颜色矩, 近邻传播聚类

中图法分类号 TP391.41 文献标识码 A

Adaptive Image Segmentation Using Affinity Propagation Clustering

DAI Shan LI Guang-jun

(Department of Information, Beijing Administration Institute, Beijing 100044, China)

(China Telecommunication Technology Institute, Beijing 100083, China)

Abstract This paper presented a unified approach for automatic image segmentation. In order to segment the image into homogenous regions, a two-stage method was proposed. Firstly, an improved simple linear iterative clustering method is adopted for the over-segmentation of the image. Then, color moments of each local region are computed to represent the region, and the affinity propagation clustering is adopted to merge the regions which are segmented in the first stage. Numerous experiments were conducted on public available datasets to demonstrate the effectiveness and robustness of the proposed algorithm.

Keywords Image segmentation, Over-segmentation, Color moments, Affinity propagation clustering

1 引言

图像分割根据灰度、颜色、纹理和形状等特征将图像划分成若干互不重叠的区域,并使这些特征在同一区域内呈现出相似性,而在不同区域间呈现出明显的差异性^[1]。图像分割是计算机视觉、图像处理的最基本的研究问题之一。

经过多年研究,准确的图像分割仍然是一个具有挑战性的研究课题。就分割的目标来讲,主要可以分为两类,过分割,将分割的结果作为后续处理的基础,不要求同类区域被分在较大的一个区域内,而是可以分为多个区域,仅需保证一个区域内的像素特征相近^[2];目标分割,将图像中的目标对象整个分割出来,由于目标对象可能包含外观迥异的组成部分,能够用来完成这部分任务的方法主要有交互式图像分割^[3]、显著性检测方面的技术^[4,5]。此外,还有研究者关注于如何能够将同质的区域尽量分到一个分割区域^[6]。

本文将图像中颜色、纹理特征相似的区域尽量分割在一起进行进一步研究,提供了一种行之有效的解决办法,即结合近邻传播聚类的自适应图像分割算法。本文第 2 节对自动分割的研究现状做简单介绍,第 3 节对本文算法进行介绍,第 4 节进行实验测试,最后进行总结。

2 研究现状

为了取得较高的效率,适应不同的应用,大量图像分割算法被提出。现阶段图像分割算法主要分为以下 5 类。

基于阈值的分割方法,阈值法利用图像的灰度特征计算一个或多个灰度阈值,并将图像中每个像素的灰度值与阈值相比较,最后将像素根据比较结果分到合适的类别中。基于阈值的分割方法最关键的就是按照某个准则函数来求解最佳灰度阈值。

基于边缘的分割方法,基于边缘的分割方法是指在边缘检测的基础上对图像完成分割。边缘是图像局部特征不连续性的反映,体现了灰度、颜色、纹理等图像特性的突变,利用这种边缘灰度值会呈现出阶跃型变化这一观测基础,将图像分割为颜色纹理相近的不同区域。加州伯克利大学 Arbelaez P 提出了 OWT-UCM (Oriented Watershed Transform-Ultrametric Contour Map algorithm) 算法^[1],被认为是经典的基于边缘的分割方法,该算法将多种局部特征通过谱聚类统一起来获得加权的边缘检测结果,并采用分水岭算法进一步处理为分层表示的图像分割结果。但是该算法运算效率较低,为此 Arbelaez P 继续对此算法进行改进^[6],在谱聚类过程中,采用一种子采样的特征向量计算方法,在对分割效果影响较小。

戴 珊(1968—),女,工程师,主要研究方向为图像识别技术及应用、信息安全,E-mail: Daishan@bac.gov.cn;李广军(1969—),男,硕士,工程师,主要研究方向为视频比对技术、视频分析技术及应用。

的情况下，效率有了较大提升。

基于区域的分割方法，此类方法将图像按照相似性准则分成不同的区域，主要包括种子区域生长法、区域分裂合并法和分水岭法等几种类型。种子区域生长法获得代表不同生长区域的种子像素集合后，将种子像素邻域里符合条件的像素合并到种子像素所代表的生长区域中，并将新添加的像素作为新的种子像素继续合并，直到找不到符合条件的新像素为止。区域分裂合并法首先将图像任意分成若干互不相交的区域，然后再按照相关准则对这些区域进行分裂或者合并从而完成分割任务。分水岭法是一种基于拓扑理论的数学形态学的分割方法，该方法把图像看作是测地学上的拓扑地貌，图像中每一点像素的灰度值表示该点的海拔高度，每一个局部极小值及其影响区域称为集水盆，而集水盆的边界则形成分水岭，即分割的边界。

基于图论的分割方法，方法将图像分割问题抽象为图的最小割问题^[7]。基于图论的分割方法的本质就是移除特定的边，将图划分为若干子图从而实现分割。主要的基于图论的方法有 GraphCut^[7]、GrabCut^[8] 和 Random Walk^[9] 等。

基于能量泛函的分割方法，该类方法主要指的是活动轮廓模型以及在其基础上发展出来的算法，其基本思想是使用连续曲线来表达目标边缘，并定义一个能量泛函使得其自变量包括边缘曲线，因此分割过程就转变为求解能量泛函的最小值的过程，一般可通过求解函数对应的欧拉方程来实现，能量达到最小时的曲线位置就是目标的轮廓所在。按照模型中曲线表达形式的不同，活动轮廓模型可分为两类：参数活动轮廓模型^[10] 和几何活动轮廓模型^[11]。

3 算法介绍

3.1 自适应一次聚类预处理

本文对 SLIC 算法^[12] 进行简单改进，提出一种自适应一次聚类的方法，对图像进行预处理过分割，为进一步的聚类提供基础。算法首先根据图像的大小确定过分割的粒度，即超像素分割的数目：

$$k = \lambda \sqrt{S} \quad (1)$$

其中， λ 为 k 的控制参数， S 为图像的大小（像素的数目）。当超像素数目 k 获得后，可以进行超像素分割。

本文算法以 Lab 彩色空间的图像作为输入，依据式(1) 所求 k 值，将图像分为 k 个边长为 $S = \sqrt{N/k}$ 的正方形网格，在每个网格中心像素点的 3×3 区域内，选择梯度值最小的像素点初始化为聚类中心 $C_k = [l_k, a_k, b_k, x_k, y_k]^T$ 。将所有像素点的距离 $d(i)$ 设置为 ∞ ，分类标记 $l(i)$ 初始化为 -1 。随后遍历每个聚类中心 C_k ，在 $2S \times 2S$ 的范围内计算每个像素点 i 与聚类中心 C_k 的距离 D ，如图 1 所示，距离 D 的计算公式为：

$$D = \sqrt{d_c^2 + (\frac{d_i^2}{S})m^2} \quad (2)$$

其中， m 为空间距离影响因子， S 为正方形网格边长， d_c 为颜色信息距离， d_i 为空间位置距离，计算公式如下：

$$d_c = \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2} \quad (3)$$

$$d_i = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \quad (4)$$

当计算所得距离 $D < d(i)$ 时，令 $d(i) = D, l(i) = k$ ，否则仍然保持原值。

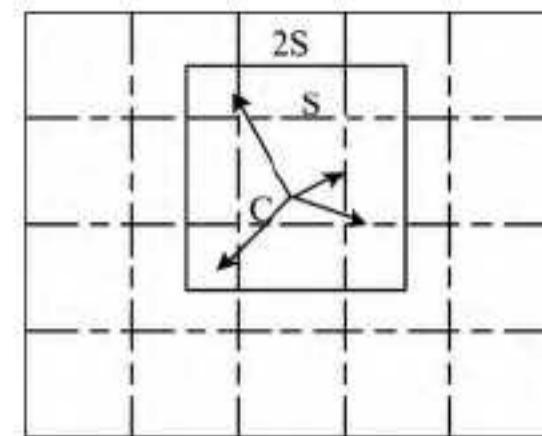


图 1 局部像素聚类示意图

标准的 SLIC 算法为了在不同的 k 值下取得好的分割效果，在经过第一次聚类后，再计算残余误差，当残余误差大于设定的阈值时，理论上需要根据 $l(i)$ 重新设定聚类中心的颜色和位置信息，并重复上述像素聚类过程，直至残余误差小于设定的阈值。在实际应用中固定设置为循环 10 次。本算法由于作为预处理步骤， k 值依据图像大小的平方根确定，取值较大，因此经过一次聚类后，已经可以满足预处理分割要求。

最后，本文算法对分割结果进行进一步优化，当超像素区域像素数小于 $(w \times h)/(n \times k)$ 时，将该超像素与邻近超像素进行合并，这里的 w, h 为图像的宽度和长度， $n=100$ 。在优化的同时计算各超像素的颜色信息：

$$\{l_k, a_k, b_k\} = \left\{ \frac{\sum l_i}{s_k}, \frac{\sum a_i}{s_k}, \frac{\sum b_i}{s_k} \right\} \quad (5)$$

其中， s_k 为超像素区域 k 的像素点数。

3.2 紧邻传播聚类

本文算法通过颜色矩对自适应一次聚类预处理后所得分割区域的颜色特征进行描述。由于颜色分布信息主要集中在低阶矩中，因此仅采用颜色的一阶矩、二阶矩和三阶矩（足以表达图像的颜色分布）：

$$\mu_i = \frac{1}{N} \sum_{j=1}^N p_{ij} \quad (6)$$

$$\sigma_i = \left(\frac{1}{N} \sum_{j=1}^N (p_{ij} - \mu_i)^2 \right)^{\frac{1}{2}} \quad (7)$$

$$s_i = \left(\frac{1}{N} \sum_{j=1}^N (p_{ij} - \mu_i)^3 \right)^{\frac{1}{3}} \quad (8)$$

其中， μ_i 表示一阶矩， σ_i 为二阶矩， s_i 为三阶矩， p_{ij} 是图像中第 j 个像素的第 i 个颜色分量值（式(5)）。

近邻传播聚类算法（Affinity Propagation, AP）可以根据节点的复杂程度自动确定分类的类数，且把参与聚类的节点都作为聚类中心的候选节点，通过在节点之间传播信息找到最终的聚类中心，能够取得更稳定、质量更高的聚类效果。

经自适应一次聚类预处理后，将预处理所得的超像素作为近邻传播聚类的数据点，数据点 i 和 k 之间的相似度使用负的欧氏距离的平方进行表示，由此构成相似度矩阵 S ，矩阵第 (i, k) 位置的元素表示如下：

$$s(i, k) = - \| X_i - X_k \|^2, i \neq k \quad (9)$$

其中， X_i, X_k 为数据点 i 和 k 的颜色矩特征向量，并将相似度矩阵 S 对角线上的 p 值设定为相似度矩阵的均值。计算过程中，所需的吸引度矩阵 $R = [r(i, k)]_{n \times n}$ 和归属度矩阵 $A = [a(i, k)]_{n \times n}$ 的值初始化为 0，并设置最大迭代次数 $maxits$ 为 1000 以及聚类中心不发生改变的连续迭代次数 $convits$ 为 10。近邻传播聚类的运算过程可以总结为以下步骤：

1) 依据式(10)–式(12)不断更新 $r(i, k), a(i, k)$ 和 $a(k, k)$ ：

$$r(i, k) \leftarrow s(i, k) - \max_{k' \neq i, k' \neq k} \{a(i, k') + s(i, k')\} \quad (10)$$

$$a(i, k) \leftarrow \min\{0, r(k, k) + \sum_{i' \in S, i' \notin \{i, k\}} \max\{0, r(i', k)\}\} \quad (11)$$

$$a(k,k) \leftarrow \sum_{i' \in \Omega, i' \neq k} \max\{0, r(i',k)\} \quad (12)$$

2) 这里设定权值 λ 对更新的步长进行控制(本文设定 $\lambda=0.5$):

$$\begin{cases} r_{new}(i,k) = \lambda \times r_{old}(i,k) + (1-\lambda) \times r(i,k) \\ a_{new}(i,k) = \lambda \times a_{old}(i,k) + (1-\lambda) \times a(i,k) \end{cases} \quad (13)$$

3) 根据归属度矩阵和吸引度矩阵的计算值确定点 i 的类中心点:

$$k = \arg \max_k \{a(i,k) + r(i,k)\} \quad (14)$$

4) 当聚类结果稳定或者达到最大迭代次数时, 终止迭代, 算法结束, 否则返回执行步骤 1)。

通过以上 4 步迭代, 可以对预处理的结果进行进一步的归类, 获得更好的分割结果。

4 实验

为验证本文算法的有效性, 本文在标准的 BSDS300 与 BSDS500 图像库上进行测试, 如表 1 所列。本文算法分别与 Meanshift^[14]、NCuts^[15]、Felz-Hutt^[16]、SWA^[17] 和 Quad-Tree 进行对比。在 BSDS300 数据集上, 本文算法的 F-measure 值较高, 仅比 Meanshift 稍次, 在 BSDS500 上能够取得较高的得分。

表 1 BSDS 数据集测试结果

| 算法 | F-measures | |
|---------------------------|------------|---------|
| | BSDS300 | BSDS500 |
| 人工标注 | 0.79 | 0.80 |
| 本文算法 | 0.62 | 0.64 |
| Meanshift ^[14] | 0.63 | 0.64 |
| NCuts ^[15] | 0.62 | 0.64 |
| Felz-Hutt ^[16] | 0.58 | 0.61 |
| SWA ^[17] | 0.56 | — |
| Quad-Tree | 0.37 | 0.38 |

另外, 我们选取了一些分割的结果, 处理的图像和人工标注来自 PASCAL 图像库, 本文算法能够将图像中的同类区域较好地分割出来, 如图 2 所示。

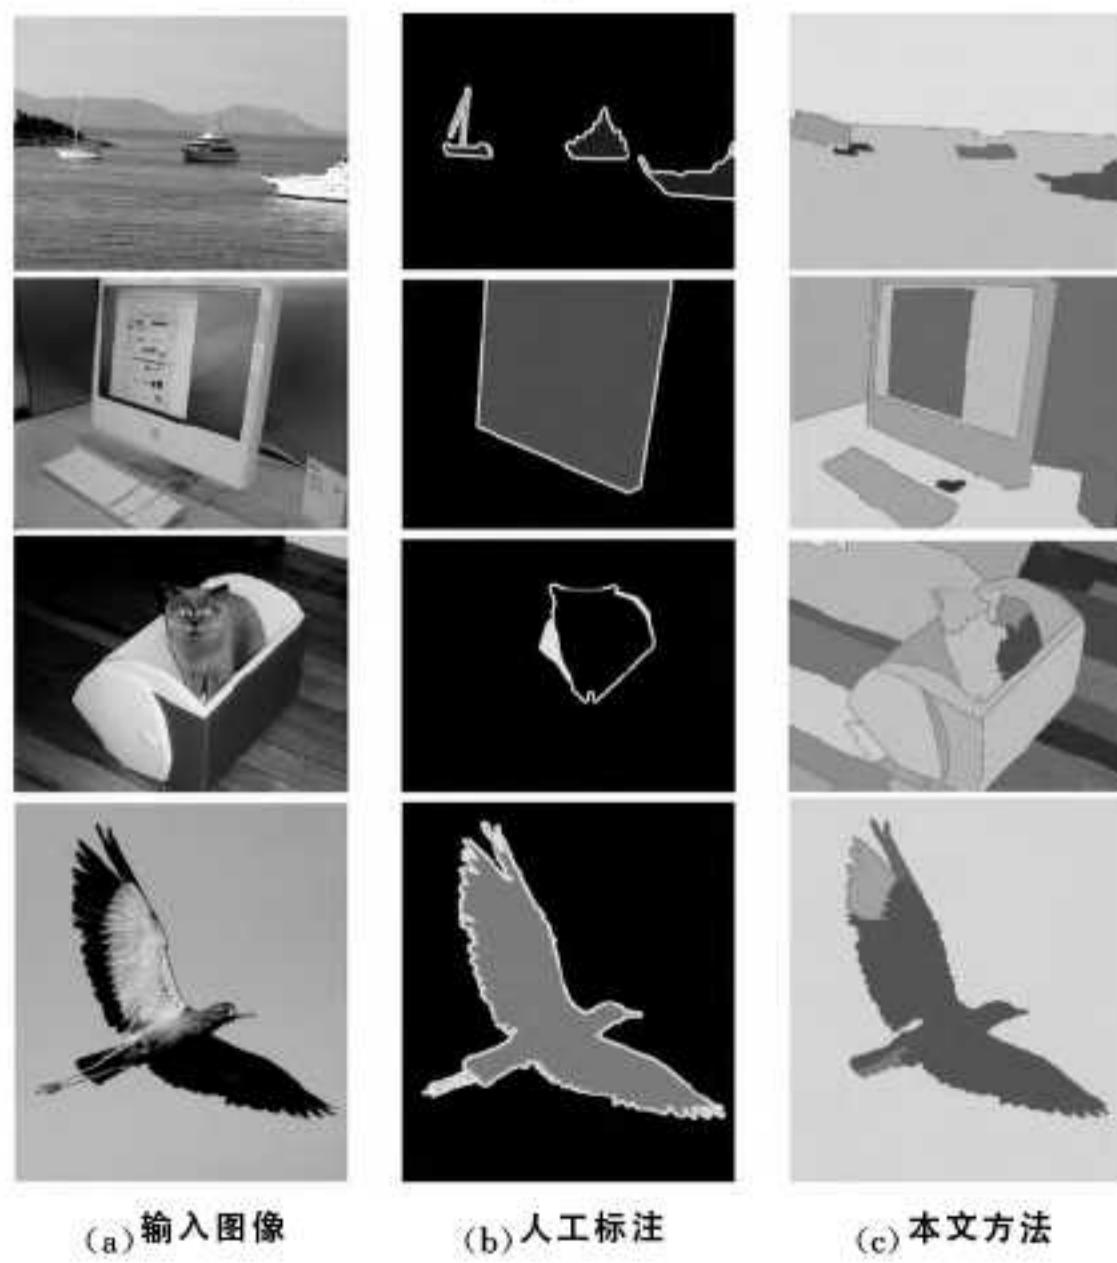


图 2 图像分割结果

结束语 本文利用对 SLIC 算法的改进, 自适应一次聚类的预处理分割算法对图像进行第一步的预处理, 然后利用近邻传播聚类将分割出来的结果进行进一步的聚类, 能够将颜色、纹理相近的部分进行分割到一个区域中。经过实验证

明, 本文算法能够取得较好的结果。

参 考 文 献

- [1] Arbelaez P, Maire M, Fowlkes C, et al. Contour detection and hierarchical image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(5): 898-916
- [2] Van den Bergh M, Boix X, Roig G, et al. Seeds: Superpixels extracted via energy-driven sampling[C]// European Conference on Computer Vision. 2012: 13-26
- [3] Wu J, Zhao Y, Zhu J Y, et al. Milcut: A sweeping line multiple instance learning paradigm for interactive image segmentation [C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2014: 256-263
- [4] Borji A, Cheng M M, Jiang H, et al. Salient object detection: A survey[OL]. <http://arxiv.org/abs/1411.5878>
- [5] Borji A, Cheng M M, Jiang H, et al. Salient object detection: A benchmark [J]. IEEE Transaction on Image Processing, 2015, 24(12)
- [6] Arbelaez P, Pont-Tuset J, Barron J, et al. Multiscale combinatorial grouping[C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2014: 328-335
- [7] Boykov Y, Kolmogorov V. An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(9): 1124-1137
- [8] Rother C, Kolmogorov V, Blake A. Grabcut: Interactive foreground extraction using iterated graph cuts[J]. ACM Transactions on Graphics (TOG), 2004, 23(3): 309-314
- [9] Grady L. Random walks for image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(11): 1768-1783
- [10] Zimmer C, Labruyere E, Meas-Yedid V, et al. Segmentation and tracking of migrating cells in videomicroscopy with parametric active contours: A tool for cell-based drug testing [J]. IEEE Transactions on Medical Imaging, 2002, 21(10): 1212-1221
- [11] Chen Y, Tagare H D, Thiruvenkadam S, et al. Using prior shapes in geometric active contours in a variational framework [J]. International Journal of Computer Vision, 2002, 50(3): 315-328
- [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 and Machine Intelligence, 2012, 34(11): 2274-2282
- [13] Frey B J, Dueck D. Clustering by passing messages between data points[J]. Science, 2007, 315(5814): 972-976
- [14] Comaniciu D, Meer P. Mean shift: A robust approach toward feature space analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(5): 603-619
- [15] Cour T, Beneit F, Shi J. Spectral segmentation with multiscale graph decomposition[C]// IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2005, 2: 1124-1131
- [16] Felzenswalb P F, Huttenlocher D P. Efficient graph-based image segmentation[J]. International Journal of Computer Vision, 2004, 59(2): 167-181
- [17] Sharon E, Galun M, Sharon D, et al. Hierarchy and adaptivity in segmenting visual scenes[J]. Nature, 2006, 442(7104): 810-813