

# 利用改进图割的彩色图像分割算法

李磊<sup>1,2</sup> 董卓莉<sup>1</sup>

1 河南工业大学信息科学与工程学院,河南 郑州,450001

2 华中科技大学计算机学院,湖北 武汉,430074

**摘要:**针对基于多标签图割的分割算法因标签过多造成计算量大的问题,提出一种基于多组件图割的彩色图像分割算法。首先根据彩色梯度信息融合所提取的四元数 cut-off 窗口特征和 CIE Lab 颜色特征进行特征提取;然后使用多组件图割算法结合最大似然(ML)估计自动分割图像,在迭代过程中,每一个分割内不相邻的区域将作为该分割的多个组件以减少标签数;最后去除一些弱边界得到分割结果。理论和实验结果表明,新算法不仅具有收敛性,而且分割性能优于原始算法。

**关键词:**彩色图像分割;多组件图割;cut-off 窗口;最大似然估计

中图分类号:TP391

文献标志码:A

彩色图像分割是计算机视觉和图像处理领域的基本任务之一,其目的是把一幅彩色图像划分为有意义且同质的区域。近年来,图割算法已成为计算机视觉和图像处理领域研究的热点,基于图割的交互式分割算法<sup>[1]</sup>和非监督多标签分割算法<sup>[2-5]</sup>被相继提出。不同于交互式分割,基于图割的多标签分割一般需要预先指定分割数目,该分割数目对分割结果影响较大<sup>[2]</sup>。为了解决这个问题,文献[3]提出了一种基于标准  $s-t$  图割<sup>[1]</sup>的非监督分割算法,通过迭代分裂图像得到最优分割,但该方法针对不同类型的图像需要设置不同的参数。文献[4]提出了基于多尺度四元数 Gabor 滤波和标准  $s-t$  图割的非监督分裂框架,将标准  $s-t$  图割算法和最小描述长度<sup>[6]</sup>准则相结合,实现彩色图像的自动分割,相比文献[3],拓展了应用范围并较大提高了分割的质量,但该算法中参数的确定仍具有挑战性。文献[5]提出了一种最大后验概率(MAP)和最大似然(ML)估计的迭代分割算法(简称 MAP-ML),基于  $\alpha$ -扩展算法<sup>[2]</sup>和区域重标记迭代过程自动分割彩色图像。该算法首先使用 K-means 算法初始化相关参数(ML 估计),然后交互执行 MAP 和 ML 估计:使用  $\alpha$ -扩展估计 MAP 得到像素标记(labeling),并使用不同标签重标记每一个连通区域,再根据新标记进行 ML 估计,更新相关参数,直到所有标签不再发生

变化或达到最大迭代次数为止。尽管该算法通过重标记操作减少了分割错误,在 Berkeley 分割数据库上取得了较好的分割结果;然而,在迭代过程中易产生过多标签,大大增加了  $\alpha$ -扩展的计算量,降低了分割效率;同时,该算法也易产生过分割结果。

针对上述问题,本文提出一种基于多组件图割的彩色图像分割算法以改进 MAP-ML,通过使用多组件策略<sup>[7]</sup>取代重标记来降低图割推理的复杂度。此外,新算法使用四元数 cut-off 窗口<sup>[6,8]</sup>结合超像素提取图像的纹理特征,并根据彩色梯度信息自适应融合纹理特征和颜色特征,同时使用 Canny 边界检测算法结合彩色图像梯度去除弱边界。实验结果证明新算法的性能要优于 MAP-ML。

## 1 特征提取

CIE Lab 颜色空间符合人类视觉对颜色的感知区分能力,且采用欧氏距离就可以区分像素之间的颜色差异,因而被大部分彩色图像分割算法采用。本文选择图像的 CIE Lab 颜色值作为颜色特征: $F^C = (L, a, b)$ ,并使用欧氏距离度量两个像素之间的颜色差异。

分割含有纹理信息的彩色图像,仅使用颜色

收稿日期:2013-05-30

项目来源:国家自然科学基金资助项目(60972098);河南省教育厅自然科学基金资助项目(13A520177)。

第一作者:李磊,博士生,主要从事彩色图像、视频处理、计算机视觉和机器学习研究。E-mail:leilzld@gmail.com

特征很难得到较好的分割结果。因此,在分割过程中有必要加入图像的纹理信息。近期研究表明,使用简单的 cut-off 窗口提取纹理特征能够获得较好的分割结果<sup>[6]</sup>。基于文献<sup>[8]</sup>中的思想,本文采用四元数 cut-off 窗口和超像素技术提取图像的纹理特征。给定一幅 RGB 彩色图像,其纹理特征提取流程如图 1 所示,具体步骤如下。




图 1 使用  $w \times w$  的 cut-off 窗口提取 4 维的纹理特征流程  
Fig. 1 Flowchart of 4D Texture Feature Extracted by  $w \times w$  Cut-off Windows

(1) 使用 mean shift<sup>[9]</sup>生成图像的超像素,其中 mean shift 的参数设置为  $(h_s, h_r) = (13, 11)$ ,超像素的最小面积为 200,如图 1,图像被过分割为 6 个超像素;(2)如图 1 虚线以上部分所示,使用大小为  $w \times w$  的四元数 cut-off 窗口对图像中的超像素采样并生成  $w^2 \times n_s$  大小的四元数矩阵  $M$ ,其中  $n_s$  为采样数,采样步长设定为  $w/2$ ;其中采样像素均为超像素的内部像素;(3)使用四元数主成分分析<sup>[8]</sup>计算  $M$  的奇异值(特征值)和特征向量  $U$ ,选择最大特征值对应的特征向量  $U^1$  作为低维基向量;(4)如图 1 中虚线以下部分所示,再次使用 cut-off 窗口提取图像的四元数纹理特征矩阵  $M'$ (大小为  $w^2 \times n$ ),根据  $U^1$  把  $M$  投射到一维四元数空间: $M' = M \cdot U^1$ ,其中  $n$  为图像像素个数, $M'$  是  $M$  的转置;(5)使用大小为  $n \times 4$  的实数矩阵  $F^T$  代替  $M'$  得到图像的纹理特征,其中  $F^T$  表示图像的纹理特征。根据实验结果和文献<sup>[6]</sup>中的建议,窗口大小固定为  $7 \times 7$ 。最后借鉴文献<sup>[8]</sup>中的方法计算图像梯度直方图的稀疏度,依此融合颜色和纹理特征: $F^{CT} = (\rho F^C, (1-\rho)F^T)$ ,其中,  $\rho$  为图像直方图的稀疏度。

## 2 多组件 MAP-ML 估计分割

### 2.1 能量泛函

基于图割的优化算法一般使用一阶马尔柯夫随机场(MRFs)能量模型建模。给定标记集合  $L$  和图像像素集合  $P$ ,以及分割中心集合  $\Phi = \{m_l\}$ ,  $l=1, \dots, |L|$ ,赋予图像中每一个像素  $p \in P$  一个

标签  $f_p$ ,最大化  $P$  的后验概率等同于最小化下面 Gibbs 能量函数:

$$E(f|\Phi, P) = \sum_{p \in P} D_p(f_p, \Phi) + \gamma \cdot \sum_{\{p, q\} \in N} V_{p, q}(f_p, f_q) \quad (1)$$

式中,  $N$  表示一个 8 邻域系统;  $D_p$  和  $V_{p, q}$  分别表示数据项和平滑项,通过  $\gamma \geq 0$  调整二者之间的权重。数据项采用图像特征空间的非参数化模型: $D_p(f_p = l, m_l) = \| (F_p^{CT} - m_l) \|^2$ ,而平滑项则定义为标准 Potts 模型:

$$V_{p, q}(f_p, f_q) = \exp\left(-\frac{\|F_p^C - F_q^C\|^2}{\eta}\right) \delta(f_p \neq f_q) \quad (2)$$

式中,  $m_l = \frac{1}{n_l} \sum_{p \in l} F^{CT}(p)$  表示第  $l$  个分割中心;  $n_l$  表示该区域中像素个数;  $\eta = 2 \langle \cdot, \cdot \rangle$  且  $\langle \cdot, \cdot \rangle$  表示图像中所有邻接像素对之间距离的期望;  $\delta(\cdot)$  是一个指示函数,当参数为真时等于 1,否则等于 0;  $\| \cdot \|$  表示欧氏距离测度。

### 2.2 多组件策略

由于基于  $\alpha$ -扩展的 MAP-MRF 推理的时间复杂度和标签数量成正比<sup>[2]</sup>, MAP-ML 使用重标记操作会产生大量标签,造成分割复杂图像时效率低下。针对该问题,本文设计了一种多组件优化策略<sup>[3]</sup>,如图 2 所示。与 MAP-ML 不同,本文算法在 MAP 估计后不再把标记为 1 的两个不相邻的区域(图 2(a))使用新的标签重新标记(图 2(b)中标签 3),而是作为该分割的组件来处理(图 2(c)中标签 1 的两个组件 1-1 和 1-2)。因此,在迭代优化过程中可保证标签数是非递增的。




图 2 重标记和多组件处理结果比较

Fig. 2 Comparison of Relabeling and Multiple Components

为此,将数据项的计算公式改写为:

$$D_p(f_p = l, m_l) = \min_i \| (F_p^{CT} - m_{l_i}) \|^2 \quad (3)$$

而 ML 估计则重新定义为:

$$m_{l_i} = \frac{1}{n_{l_i}} \sum_{p \in l_i} F^{CT}(p) \quad (4)$$

式中,  $l_i$  表示第  $l$  个分割中第  $i$  个组件;  $n_{l_i}$  表示该组件内像素个数;  $m_{l_i}$  表示该组件的中心。

类似于 MAP-ML,多组件策略可以保证本文

算法收敛和能量递减。多组件处理后,由于模型参数和光滑项没有改变,能量没有变化;而在 ML 估计阶段,由于数据项  $D_p$  的值是像素  $p$  到一个分割中所有组件之间距离的最小值,加之光滑项仍未改变,所以能量变小或者不发生改变,亦即证明了本文算法是收敛的。

值得说明的是,MAP-ML 会把同标签、空间不相邻的区域重标记为不同的分割,在下次  $\alpha$  扩展处理中,尽管空间不相邻,但它们之间像素的标签可能发生移动;如图 2(b)中标记为 1 和 3 的区域,可能发生标记为 1 的像素被标记成了 3 的情况,这会产生更多的噪声区域。而本文算法中,因同一标签下不相邻区域之间像素的标签不会发生移动,在某种程度上缓解了过分割现象。

### 2.3 弱边界去除

由于图割算法的目的是获取能量最小化,这样可能会造成分割结果中某些同质区域被“弱边界”分裂。为解决这个问题,增加弱边界去除步骤。首先,采用文献[10]中的方法计算图像的梯度,并应用到 Canny 算法中得到二值边界图,以此作为图像边界的金标准(ground truth);然后,检查分割结果中任意两个相邻区域之间的边界和金标准的匹配程度来判断该边界是否是弱边界;如果该边界上成功匹配的像素个数和该边界长度的比值小于指定的阈值(本文设定为 0.5),则认为该边界为弱边界,并合并相关的两个区域。为了减少匹配过程中产生的误差,采用  $3 \times 3$  的窗口搜索匹配点。Canny 算法的边界比率参数设置为  $\rho$ (替代默认值 0.7),最小阈值设置为最大阈值的 0.4 倍,其中  $\rho$  是按照文献[11]计算出来的图像梯度直方图的稀疏度。

## 3 实现细节及时间复杂度分析

使用多组件策略时,优化过程中仍会出现噪声区域。为此,在每次迭代过程中,当一个连通区域的面积小于指定阈值时,认定它为噪声区域,将其合并到相同标签下最相似的其他组件。该面积阈值固定为图像大小的 0.005 倍。为了提高算法的运行效率和精确性,以及分割结果的空间一致性,由超像素内像素融合特征的均值表示超像素,采用文献[12]中的快速 K-means 算法对图像超像素进行聚类,根据结果设置超像素内部像素的标签,然后计算初始化参数  $\Phi$ 。此外,K-means 算法的初始类数固定为 10,MAP 和 ML 估计的最大迭代次数设定为 10。算法终止时,每一个连通

区域被视为一个分割。

在计算数据项时,要分别计算到多个组件的距离,与 MAP-ML 计算到多个分割中心之间的距离一致,并没有增加额外的时间开销。本文算法因控制了标签数量,所以图割优化阶段的时间复杂度为  $O(n \sum_{i=1}^K C_n K_{\alpha_n})$ ,其中  $n$  表示像素个数,  $C_n$  是标签个数,  $K_{\alpha_n}$  为  $\alpha$ -扩展内部迭代次数,  $K$  为执行  $\alpha$ -扩展的次数。在分割过程中本文算法的标签数一般为 1~10,而 MAP-ML 可能的标签数为 1~50。此外,去除弱边界的时间复杂度为  $O(n)$ 。

## 4 实验结果及分析

本文使用 Berkeley 分割数据库中的 300 幅图像来验证所提出的算法,并和 MAP-ML 进行比较。本文算法参数  $\gamma$  设置为 3 000,而 MAP-ML 中的参数根据作者建议设置为 4 000。采用两种主流的评价指标函数 Probabilistic Rand Index (PRI)和 Variation of Information (VoI)<sup>[5-6]</sup>对分割结果进行评价。统计机器分割和多个人工分割之间标签一致的像素对的个数占整个像素对个数的比率,称为 PRI,其取值范围为  $[0, 1]$ ;VoI 则把机器分割和人工分割之间的距离定义为在给定人工分割的条件下机器分割的平均条件熵,因此它能够测量机器分割中不能被人工分割所解释的随机性的量,其取值范围为  $[0, \infty)$ 。PRI 取值越大,VoI 取值越小,则机器分割结果与人工分割结果越接近。

图 3 给出了本文算法和 MAP-ML 分割 300 幅图像部分结果的比较。可以看出,由于使用多组件图割,本文算法在某种程度上可以缓解 MAP-ML 的过分割问题,分割结果中噪声区域比较少,部分弱边界得以去除。由于使用了四元数 cut-off 窗口特征,提高了本文算法对纹理图像的鉴别能力,如图 3(b)-2(表示从图 3(b)中从上到下第二幅图像)、图 3(b)-4 和图 4(b)-1 和图 4(d)-4,对含有纹理特征的图像分割结果要优于 MAP-ML 分割结果。如图 3(b)-1、图 4(d)-1 和图 4(b)-3 所示,相对于 MAP-ML,本文算法使用弱边界去除能有效提升分割的质量和视觉效果。另外,对于 MAP-ML,参数  $\gamma$  取值应较大,减少噪声区域和过分割现象,如图 4(c)-3 和图 4(a)-4;然而,如果  $\gamma$  取值过大,光滑项占优势,如图 3(a)-2, 3(a)-3 和图 3(c)-3 及图 4(a)-1,就会造成欠分割或边界错位。而本文算法同一标签下的区域之

间没有任何交互,一定程度上减少了噪声区域。




图 3 本文算法和 MAP-ML 分割结果的比较(一)

Fig. 3 Some Segmentation Results (part one) of our Algorithm and MAP-ML on Berkeley Segmentation Database

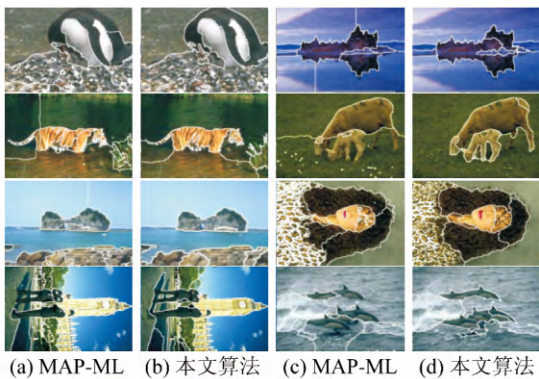


图 4 本文算法和 MAP-ML 分割结果的比较(二)

Fig. 4 Some Segmentation Results (part two) of our Algorithm and MAP-ML on Berkeley Segmentation Database

表 1 给出了两种算法分割 300 幅图像结果的量化分析,可以看出本文算法在 PRI 和 VoI 指标上要优于 MAP-ML。为了验证两种算法分割单幅图像的性能,图 5 中给出了 300 幅图像分割结果的 PRI 和 VoI 曲线,图中的数据是按升序排列的。

表 1 分割 300 幅图像的性能比较

Tab. 1 Average Values of PRI and VoI on the 300 Test Images from the Berkeley Segmentation Database

评估指标	人工分割	MAP-ML	本文算法
PRI	0.901 8	0.780 6	0.797 8
VoI	0.898 8	2.057 3	1.813 5

从图 5 中可以看出,本文算法的 PRI 值和 MAP-ML 比较接近,但 VoI 值要小于 MAP-ML。表 2 给出了算法分割耗时比较,本文算法平均分割一幅图像的耗时少于 50 s(其中包括约 15 s 的纹理特征提取的开销),远低于 MAP-ML 所需的




图 5 分割每一幅图像结果的 PRI 和 VoI 值

Fig. 5 PRI and VoI Values Achieved on Individual Images by the Two Algorithms

近 100 s,证明了本文算法的有效性。为了验证本文算法的鲁棒性,表 3 中给出了当参数  $\gamma$  取不同值时分割 300 幅图像结果的平均 PRI 和 VoI。可以看出,当参数  $\gamma$  取值范围在 [1 000, 4 000] 时,本文算法分割结果的 PRI 和 VoI 仅发生了轻微变化。所有实验均在 2 G 内存、2.60 GHz Pentium Dual-Core CPU 的台式机上执行的。

表 2 本文算法和 MAP-ML 平均耗时比较/s

Tab. 2 Running Times of Our Algorithm and MAP-ML for Each Image/s

	MAP-ML	本文算法
时间	89.41	45.45

表 3 参数  $\gamma$  取不同值时的平均 PRI 和 VoI 及耗时

Tab. 3 Average Values of PRI, VoI and Running Time for Our Algorithm when  $\gamma$  is Changed

$\gamma$	PRI	VoI	时间/s
1 000	0.790 1	1.998 2	45.67
2 000	0.792 7	1.882 3	45.39
3 000	0.797 8	1.813 5	45.45
4 000	0.787 5	1.789 7	45.08

## 5 结 语

本文对基于 MAP-ML 估计的彩色图像分割算法进行了改进,解决了使用  $\alpha$  扩展进行 MAP-MRF 推理过程中因标签过多导致计算量过大的问题,并在一定程度上抑制了过分割现象;同时,使用四元数 cut-off 窗口特征提高了算法对图像的鉴别能力,结合弱边界去除有效提升了分割性能。在 Berkeley 分割数据库 300 幅图像上的实验结果表明,新算法在分割效率和分割精度上优于 MAP-ML。

## 参 考 文 献

[1] Kolmogorov V, Zabih R. What Energy Functions can be Minimized via Graph Cuts? [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004, 26(2): 147-159

[2] Boykov Y, Veksler O, Zabih R. Fast Approximate

- Energy Minimization via Graph Cuts [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2001, 23(11): 1 222-1 239
- [3] Kim J S, Hong K S. Color-texture Segmentation Using Unsupervised Graph Cuts [J]. *Pattern Recognition*, 2009, 42(5): 735-750
- [4] Li L, Jin L H, Xu X Y, et al. Unsupervised Color-texture Segmentation Based on Multiscale Quaternion Gabor Filters and Splitting Strategy [J]. *Signal Processing*, 2013, 93(9): 2 559-2 572
- [5] Chen S F, Cao L L, Wang Y M, et al. Image Segmentation by MAP-ML Estimations [J]. *IEEE Transactions on Image Processing*, 2010, 19(9): 2 254-2 264
- [6] Yang A, Wright J, Ma Y, et al. Unsupervised Segmentation of Natural Images via Lossy Data Compression [J]. *Computer Vision and Image Understanding*, 2008, 110(2): 212-225
- [7] Li L, Jin L, Song E, et al. Unsupervised Color Image Segmentation Using Graph Cuts with Multi-components[C]. *The Multispectral Image Processing and Pattern Recognition (MIPPR)*, Wuhan, 2013
- [8] Shi L L, Funt B. Quaternion Color Texture Segmentation[J]. *Computer Vision and Image Understanding*, 2007, 107(1): 88-96
- [9] 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
- [10] Jin L, Liu H, Xu X, et al. Improved Direction Estimation for Di Zeno's Multichannel Image Gradient Operator[J]. *Pattern Recognition*, 2012, 45(12): 4 300-4 311
- [11] Hoyer P O. Non-negative Matrix Factorization with Sparseness Constraints[J]. *The Journal of Machine Learning Research*, 2004, 5: 1 457-1 469
- [12] Elkan C. Using the Triangle Inequality to Accelerate K-means[C]. *The 12th International Conference on Machine Learning (ICML)*, Washington DC, 2003

## Color Image Segmentation Using Improved Graph Cuts

LI Lei<sup>1,2</sup> DONG Zhuoli<sup>1</sup>

<sup>1</sup> College of Information Science and Engineering, Henan University of Technology, Zhengzhou 450001, China

<sup>2</sup> School of Computer Science and Technology, Huazhong University of Science and Technology, Wuhan 430074, China

**Abstract:** A novel unsupervised color image segmentation method using graph cuts with multiple components is proposed, which can overcome the problem of the higher computational complexity caused by more labels during inferring by graph cuts. First, the quaternion cut-off window feature and CIE Lab color feature of a given image are extracted and fused based on the gradient information of the image. Then the segmentation is formulated as a labeling problem and solved by an iterative process based on graph cuts and maximum likelihood (ML) estimation. At each iteration, the connected regions in a segment are handled as sub-components of the segment instead of relabeling them with unique labels. In doing so, the number of labels does not increase, and thus the computational complexity can be reduced during inference by graph cuts. Finally, the segmentation result is obtained after removing some weak edges. Experimental results and theoretical proof demonstrate the good performance of the proposed method.

**Key words:** color image segmentation; multi-component graph cuts; cut-off window; maximum likelihood estimation

**First author:** LI Lei, PhD, specializes in image and video processing, computer vision and machine learning. E-mail: leilzd@gmail.com

**Foundation support:** The National Natural Science Foundation of China, No. 60972098; the Natural Science Research Project of Department of Education, Henan Province, China, No. 13A520177.