

基于自适应区域限制 FCM 的图像分割方法

李 磊, 董卓莉, 张德贤

(河南工业大学信息科学与工程学院, 河南郑州 450001)

摘 要: 提出一种基于自适应区域限制 FCM (Fuzzy C-Means) 的彩色图像分割方法, 结合隐马尔科夫模型, 把超像素具有区域一致性作为先验知识自适应融入到聚类过程中, 以提升聚类性能. 算法首先生成图像的超像素, 计算像素对该超像素的贡献度, 以此计算该超像素的区域隶属度函数; 然后根据像素所属超像素是否具有主标签, 选择像素级隶属度函数或区域级隶属度函数计算该像素的点对先验概率, 以加强分割结果的区域一致性; 其中, 使用区域隶属度函数将引导聚类优化的方向, 因此在迭代过程中去除未被使用的标签; 最后迭代终止获得图像的分割结果. 实验结果表明, 相对于比较算法, 本文算法的分割性能有显著提升.

关键词: 图像分割; 模糊聚类; 超像素; 主标签; 区域限制

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 0372-2112 (2018)06-1312-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2018.06.006

Adaptive Region Constrained FCM Algorithm for Image Segmentation

LI Lei, DONG Zhuo-li, ZHANG De-xian

(College of Information Science and Engineering, Henan University of Technology, Zhengzhou, Henan 450001, China)

Abstract: An image segmentation method based on robust regional constraint FCM (Fuzzy C-Means) is proposed, which combines hidden Markov random field (HMRF) model with FCM. In order to improve the performance of the proposed method, the consistency of superpixels of the input image is adaptively used as a priori in clustering process. The proposed method first obtains the superpixels of the image, and for each superpixel, calculates a contribution of each pixel to the superpixel and the contributions are used to compute the superpixel's membership functions. And then the pointwise prior probabilities of pixels are calculated with pixel-level membership function or region-level membership function according to whether the superpixel to which the pixels belong has the dominant label. The use of region-level membership function is to guide the direction of clustering optimization, and thus there are some unused labels which are removed in the iteration process. Finally, the segmentation result is obtained after iteration stop. Experimental results demonstrate the good performance of the proposed method.

Key words: image segmentation; fuzzy clustering; super pixels; dominant label; region constraint

1 引言

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, 目的是把一幅彩色图像划分为有意义且同质的区域, 为下一步图像理解提供基本信息. 数十年来, 大量图像分割算法^[1-7]不断被提出, 并取得了较好的分割效果, 但随着图像应用的扩展, 促使学者们提出更多新的分割算法以满足不同的需求. 在这些分割方法中, 基于聚类的方法由于其简单直观而广泛用于医

学^[8]和遥感^[9]等图像分割, 也常和其它方法相结合用于图像的预处理^[10,11].

FCM^[12]作为一种软分割方法, 相对于 K-means 等硬分割方法, 不仅具有模糊鲁棒性, 而且在分割过程中更能保留图像的原始信息, 是聚类技术中最流行的方法之一. 然而, 由于未考虑图像的空间信息, FCM 对噪声和成像伪影较为敏感, 导致图像分割结果不具有区域一致性. 为此, 如何在 FCM 聚类过程中融入空间信息已成为目前研究的热点和重点. 一些改进方法^[13,14]通

收稿日期: 2017-06-12; 修回日期: 2017-11-10; 责任编辑: 孙瑶

基金项目: 河南省教育厅自然科学基金项目 (No. 15A520057); 河南省科技厅自然科学基金项目 (No. 132102210494, No. 162102210189); 高层次人才基金 (No. 21476062); 省属高校基本科研业务费专项资金 (No. 2016QNJH25)

过修改 FCM 的目标函数融入空间信息的方式提升其抗噪能力. Pham^[13] 通过修改 FCM 目标函数,在隶属度函数估算过程中加入了空间惩罚, Ahmed 等^[14] 则在目标函数中加入空间邻域项以补偿图像强度的不一致性,同时加强像素与邻域像素之间的影响. 这些方法相对于传统 FCM,性能得到提升的同时,计算复杂度也相应增加. 为提高运算效率,另一些算法^[15-17] 从邻域参数控制、局部空间信息的选择及边界保持等方面展开研究,进一步提升了 FCM 的分割效率和精度. 以上方法均是在传统 FCM 算法的基础上加入空间约束信息,从而提升了 FCM 的分割性能.

马尔科夫随机场 (Markov Random Fields, MRF) 模型因其利用了相邻像素之间的邻域信息,对噪声具有较强的鲁棒性、图像边界保持较好等优点,在图像处理和计算机视觉领域得到了广泛应用. 近年来,学者们研究提出多种融合 FCM 和 MRF 模型的聚类方法^[18-21],以取长补短,获得了较好的分割效果. Chatzis 和 Varvarigou^[20] 提出一种面向隐马尔科夫随机场 (Hidden MRF, HMRF) 的聚类方法 HMRF-FCM,通过把 HMRF 视为一幅图像模糊划分的定义,探索在聚类过程中 HMRF 的空间一致性建模能力. 该方法结合了 FCM 和 HMRF 模型,有效弥补了传统 FCM 的缺陷,并为后续如何更好地在聚类过程中融入 MRF 模型指出了研究方向,然而需要计算相邻像素之间的交互使得这种方法的计算复杂度较高. 为此, Zhang 等^[22] 利用距离函数和隶属度函数的均值模板提升运算效率,加强像素之间的空间关系,较大程度上提高了分割质量;而 Liu 等^[23] 在该算法的基础上做了进一步改进,提出一种融合自适应局部信息的 HMRF-FCM 方法,利用超像素具有区域同质性的特性,将区域信息 (或称超像素信息) 融入到距离函数和点对先验概率中,在分割精度和效率上均得到了较大提升. 受此启示,本文提出一种类似于高阶 MRF 能量模型的聚类方法,利用超像素的区域一致性估算像素的区域隶属度函数,使用均值模板技术计算点对先验概率,并根据像素所属超像素是否具有主标签选择像素级隶属度函数或区域级隶属度函数参与计算,从而充分利用超像素信息提升分割结果的区域一致性.

2 HMRF-FCM 及其改进算法

给定一幅输入图像 $I, S = \{1, 2, \dots, N\}$ 为一个有限集合用于指示图像中的像素,而 $y = \{y_i | i \in S\}$ 表示图像 I 的特征,如果图像被分割为 K 类,则分割结果表示为 $x = \{x_i | i \in S\}$,其中 $x_i (1 \leq x_i \leq K)$ 表示像素 i 的标签. 算法 HMRF-FCM^[20] 定义其目标函数为:

$$Q_\lambda = \sum_{i=1}^N \sum_{k=1}^K r_{i,k} d_{i,k} + \lambda \sum_{i=1}^N \sum_{k=1}^K r_{i,k} \log \left(\frac{r_{i,k}}{\pi_{i,k}} \right) \quad (1)$$

其中, $r_{i,k}$ 为隶属度函数, $d_{i,k}$ 表示相似度函数 (又称距离函数), $\pi_{i,k}$ 表示点对先验概率,而参数 λ 是模糊隶属度值的模糊程度. 式(1)利用了 KL 信息熵规则化,这种形式产生了基于 FCM 且可替代最大期望算法求解高斯混合模型的模糊聚类方法,明显提升了聚类的性能. 在 HMRF-FCM 算法中, $d_{i,k}$ 定义为高斯模型第 k 个组件相对于拟合像素 i 的负对数似然度:

$$d_{i,k} = -\log p(y_i | x_i = k, \theta_k) = \frac{1}{2} (B \log(2\pi) + (y_i - \mu_k)' \Sigma_k^{-1} (y_i - \mu_k) + \log(|\Sigma_k|)) \quad (2)$$

其中, θ_k 表示高斯分布的第 k 个组件,包含参数 μ_k 和 Σ_k ,分别为该组件的均值和协方差矩阵, B 是待分割图像的光谱数^[23]. 在聚类迭代过程中,先验概率函数 $\pi_{i,k}$ 和距离函数 $d_{i,k}$ 是影响 HMRF-FCM 分割性能的两个关键因素,其中 $\pi_{i,k}$ 包含相邻像素之间的空间信息,类似于 MRF 模型中的平滑项,以抑制噪声, $d_{i,k}$ 表示像素 i 和第 k 个高斯分布之间的相似度,作用同于 MRF 模型中的数据项. 相对于传统 FCM 以及基于空间限制改进 FCM 算法,尽管 HMRF-FCM 的抗噪能力有所提高,获取的分割结果更具有区域一致性,但由于只考虑了像素的小范围邻域信息,因此该算法仍会受到噪声的影响,而且运算效率有待提高.

针对以上问题,文献[23]提出了一种融入自适应局部信息的 HMRF-FCM 改进方法,利用图像超像素信息提高算法的抗噪能力,同时保持图像的边界信息. 为此,文献[23]重定义目标函数为:

$$Q_\lambda = \sum_{i=1}^N \sum_{k=1}^K r_{i,k} D_{i,k} + \lambda \sum_{i=1}^N \sum_{k=1}^K r_{i,k} \log \left(\frac{r_{i,k}}{\pi_{i,k}} \right) \quad (3)$$

这里,

$$D_{i,k} = \frac{d_{i,k} + d_{v_i,k}}{2} \quad (4)$$

$$\pi_{i,k} = \frac{(\sum_{j \in \partial_i} w_j \eta_j r_{j,k})^\gamma}{\sum_{k=1}^K (\sum_{j \in \partial_i} w_j \eta_j r_{j,k})^\gamma} \quad (5)$$

其中, γ 是强度因子取常数 2, ∂_i 为像素 i 的邻域, w_j 为空间权重用于控制相邻像素在空间距离上对中心像素的影响,定义为:

$$w_j = \frac{1}{(2\pi c)^{0.5}} \exp \left(-\frac{L_{i,j}^2}{2c^2} \right)$$

$L_{i,j}$ 定义为像素 i 和 j 之间的空间欧氏距离, $c = (ws - 1)/4$, 这里 ws 是邻域窗口大小; η_j 为区域级迭代强度,表示像素 i 和其相邻像素 j 所属超像素 v_i 和 v_j 之间的相似度,定义为:

$$\eta_j = \frac{1}{Z} (E_{v_i, v_j} + 1)^{-1} \quad (6)$$

其中, $E_{v_i, v_j} = |\mu_{v_i} - \mu_{v_j}|$, $d_{v_i, k} = \frac{1}{a_{v_i}} \sum_{j \in \partial_i} d_{j,k}$ 为区域级距离

函数, a_{v_i} 为区域 v_i 中像素的个数, Z 是归一化常数.

利用拉格朗日乘子及梯度下降法很容易估算出像素的隶属度函数及组件参数均值 μ_k 和协方差矩阵 Σ_k [23]:

$$r_{i,k} = \frac{\pi_{i,k} \exp\left(-\frac{1}{\lambda} D_{i,k}\right)}{\sum_{k=1}^K \left(\pi_{i,k} \exp\left(-\frac{1}{\lambda} D_{i,k}\right)\right)} \quad (7)$$

$$\mu_k = \frac{\sum_{i=1}^N r_{i,k} (y_i + \mu_{v_i})}{2 \sum_{i=1}^N r_{i,k}} \quad (8)$$

$$\Sigma_k = \frac{\sum_{i=1}^N r_{i,k} \left[\begin{array}{l} (y_i - \mu_k)(y_i - \mu_k)' \\ + (\mu_{v_i} - \mu_k)(\mu_{v_i} - \mu_k)' + \Sigma_{v_i} \end{array} \right]}{2 \sum_{i=1}^N r_{i,k}} \quad (9)$$

其中 $\mu_{v_i} = a_{v_i} / \left(\sum_{j \in v_i} y_j\right)$ 是超像素 v_i 内像素特征的均值,

$\Sigma_{v_i} = \frac{1}{a_{v_i}} \sum_{j \in v_i} (y_j - \mu_{v_i})(y_j - \mu_{v_i})'$ 是超像素 v_i 内像素相对于均值 μ_{v_i} 的协方差矩阵. 最后根据 $r_{i,k}$ 得到图像像素的标记, 即

$$x_i = \arg \max_{k=1}^K \{r_{i,k}\}$$

式(5)增强了同一区域内像素之间的影响, 同时减弱了处于不同区域中的相邻像素之间的关系, 尽可能使同一区域内的像素具有相同的先验概率; 而式(4)则通过把区域 v_i 的信息加入隶属度函数的计算过程中, 从而推导出不同的均值和协方差矩阵计算方式(式(8)和式(9)), 加强了超像素信息对分割结果的影响, 以尽可能促使分割结果中同一超像素内像素具有相同的类标签, 并保持图像的边界信息.

3 本文方法

文献[23]通过把超像素信息加入到距离函数 $D_{i,k}$ 和点对先验概率 $\pi_{i,k}$ 计算过程中, 提升了分割结果的质量, 尤其在 $D_{i,k}$ 中, 融合像素级距离函数 $d_{i,k}$ 和区域级距离函数 $d_{v_i,k}$, 从而引导聚类过程使超像素内的像素尽可能聚为一类. 由此可见, 在聚类过程中融入基于超像素的区域限制信息将能够明显提高分割结果的区域一致性和抗噪能力. 此外, 在 MRF 模型应用中, 高阶 MRF 模型受到了广泛的关注, 在分割过程中加入基于超像素的高阶能量项进一步提升了分割结果的质量. 受此启发, 本文从区域级和像素级隶属度函数计算方面出发, 利用高阶 MRF 能量模型思想, 提出了一种基于自适应隶属度的 HMRF-FCM 方法, 通过使用基于超像素的区域级隶属度函数, 并根据区域一致性为像素自适应选择像素级隶属度函数或区域级隶属度函数参与点对先

验概率的计算, 以提升分割质量.

为此, 本文方法的目标函数同于式(3), 定义为:

$$Q_\lambda = \sum_{i=1}^N \sum_{k=1}^K r_{i,k} D_{i,k} + \lambda \sum_{i=1}^N \sum_{k=1}^K r_{i,k} \log\left(\frac{r_{i,k}}{\pi_{i,k}}\right)$$

首先计算像素 i 对其所属超像素的贡献度 c_i :

$$c_i = \frac{a_{v_i}}{C} \cdot \frac{b(i, v_i)}{f(i, v_i)} \quad (10)$$

其中 $b(i, v_i)$ 表示像素 i 到其所属超像素 v_i 边界的距离, $f(i, v_i) = |y_i - \mu_{v_i}|$ 表示像素 i 对超像素 v_i 的相似度, 而 $C = \sum_{j \in v_i} \frac{b(j, v_i)}{f(j, v_i)}$ 为归一化常数. 从式(10)可以看出, c_i 值越大(例如大于1), 表示像素 i 对超像素 v_i 的贡献度就越大, 就越能代表该超像素, 反之, 说明像素 i 处于超像素的边界位置或者是噪声点. 以此计算区域级的隶属度函数, 将更能体现图像的区域一致性. 由于超像素生成的质量原因, 并不是所有超像素都具有区域一致性, 由于噪声原因, 在超像素生成过程中一些像素会被错误划分. 因此, 本文在计算区域信息时, 不再简单计算超像素内像素信息的平均值, 而以像素的贡献度为权重, 将超像素的隶属度函数定义如下:

$$r_{v_i,k} = \frac{\sum_{j \in v_i} c_j r_{j,k}}{\sum_{j \in v_i} c_j} \quad (11)$$

为了判断何时使用超像素级信息, 本文借鉴高阶 MRF 能量模型优化的思想, 在式(5)的基础上重定义点对先验概率计算公式:

$$\pi_{i,k} = \frac{\left(\sum_{j \in d_i} w_j \eta_j R_{j,k}\right)^\gamma}{\sum_{k=1}^K \left(\sum_{j \in d_i} w_j \eta_j R_{j,k}\right)^\gamma} \quad (12)$$

其中, γ 的定义同式(5), $R_{j,k}$ 是基于超像素内标签一致性自适应选择的隶属度函数, 其定义如下:

$$R_{i,k} = \begin{cases} r_{v_i,k}, & \text{if } dl(v_i) = 1 \\ r_{i,k}, & \text{otherwise} \end{cases} \quad (13)$$

这里 $r_{v_i,k} = \sum_{j \in v_i} c_j r_{j,k}$ 定义为超像素 v_i 的区域隶属度函数, $dl(v_i)$ 则用于指示超像素 v_i 是否有主标签, 定义如下:

$$dl(v_i) = \begin{cases} 1, & \text{if } \frac{N_k(v_i)}{a_{v_i}} > Q \\ 0, & \text{otherwise} \end{cases} \quad (14)$$

其中, $N_k(v_i) = \max(n_k(v_i))$, $n_k(v_i)$ 表示超像素内标记为 k 的像素个数, 从而称 $N_k(v_i)$ 为标记为主标签的像素个数, Q 为指定的阈值. 式(13)中 $R_{i,k}$ 的取值依赖于当前超像素内像素标记情况, 一旦超像素内大部分像素标记为同一标签, 即认为该超像素存在主标签, 则

$R_{i,k}$ 代表区域级的隶属度函数 $r_{v_i,k}$, 否则仍使用 $r_{i,k}$. 这种方式可以有效保证超像素的区域一致性, 而且一个超像素一旦具有主标签, 则后续迭代过程中将有可能不再变化, 有效提升了算法的收敛速度.

算法 1 描述了本文方法的具体流程, 首先使用 Mean shift^[3]生成图像的超像素, 为了提高算法效率, 如算法 1 步骤 1 所示, 预先计算像素级迭代强度和区域级迭代强度, 除此之外, 还需预先计算像素对于所属超像素的贡献度 c_i . 本文方法主要创新点在于算法 1 步骤 3, 即计算点对先验概率时利用超像素是否具有主标签选择像素级隶属度函数 $r_{i,k}$ 或区域级隶属度函数 $r_{v_i,k}$. 其依据如下: 在迭代过程中, 若超像素内大部分像素 (如 90%) 均归为同一类, 那么这种情况可作为一种先验知识认为超像素具有主标签, 即超像素具有区域一致性, 在后续迭代过程中应保持该超像素的先验关系, 从而尽可能保证具有主标签的超像素内像素均属于同一类. 为了达到该目标需要执行算法 1 中步骤 6 及步骤 7; 当迭代次数 t 达到最大值 T , 或者两次迭代过程分类结果不一致像素个数占整个图像的比率效率阈值 ε , 算法迭代终止.

算法 1 本文算法

输入: 输入图像 I , 聚类个数 K , 参数 ε , T 和 Q

输出: 分割结果 x

- 1: 提取图像特征 y , 生成超像素 v , 计算 μ_v , Σ_v , a_v 及 c_i (式 (10)); 计算 w_j 和 η_j ;
- 2: 首次迭代设置 $t = 1$, 初始化 $\{r_{i,k}^t\}$, 计算 $dl(v_i)$ 和 $\{r_{v_i,k}^t\}$;
- 3: 在 t 次迭代, 使用式 (12) 计算 $\pi_{i,k}^t$;
- 4: 根据式 (8) 和式 (9) 计算高斯分布组件参数 μ_k 和 Σ_k , 计算 $D_{i,k}$ (式 (4));
- 5: 根据式 (7) 和 $D_{i,k}$ 计算新的隶属度函数 $r_{i,k}$;
- 6: 去除没有标记任何像素的标签, 更新 K 的值;
- 7: 获取当前区域标记 x , 计算超像素的主标签 $dl(v_i)$ (式 (14)) 及像素的 $R_{i,k}$ (式 (13));
- 8: 若 $\sum_{i=1}^N \delta(x_i^t - x_i^{t-1}) / N < \varepsilon$ 或 $t < T$, 迭代终止, 否则设置 $t = t + 1$, 跳转步骤 3;
- 9: 重新标记每一个不相邻的区域.

由于本文方法把超像素具有一致性先验知识融入了 $\pi_{i,k}$ 的计算过程中, 并没有改变其它参数, 因此, 由目标函数利用梯度下降法和拉格朗日乘子技术得到参数估算同于文献[23], 这里不再赘述.

4 实验结果及分析

为了验证所提算法的有效性, 使用了 Berkeley 自然图像集和合成图像集进行测试, 并和 HMRF-FCM 改进算法^[23] (简称 Liu's) 在分割性能和鲁棒性方面进行比较; 其中, 合成图像集中每幅图像由 5 种不同颜色的区

域组成, 并分别加入标准方差为 0.01 至 0.2 的高斯噪声, 生成 300 幅测试图像集.

图 1 展示了原始合成图像和部分加入噪声后的图像. 为了方便比较, 本文实现了算法 Liu's. 采用四种主流的评价指标函数^[2]: Probabilistic Rand Index (PRI)、Variation of Information (VoI)、Global Consistency Error (GCE) 和 Boundary Displacement Error (BDE). 对分割结果进行评价, 其中, PRI 是统计机器分割和多个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, 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 $[0, \infty)$, GCE 主要测量机器分割结果和人工标记结果之间的一致性, 取值范围为 $[0, 1]$, 而 BDE 测量分割结果和人工标记结果之间边界像素的平均位移误差, 取值范围 $[0, \infty)$. 量化结果中 PRI 值越大, VoI、GCE 和 BDE 值越小, 则机器分割结果与人工分割结果越接近.




图1 合成图像集部分图像示例

4.1 参数设置

本文方法与 Liu's 所涉及的参数均保持一致, 其参数 $\lambda = 1$, 最大迭代次数 T 和迭代错误率 ε 分别设置为 50 和 0.95, 对于 Berkeley 图像集和合成图像测试集, 邻域窗口大小 w_s 分别设置为 5×5 和 3×3 ; 本文方法参数 Q 分别设置为 0.85 和 0.99; 参数 γ 设置请参照文献[23]; 超像素生成算法 mean shift 有三个参数: 空间带宽 h_s 、范围带宽 h_r 和最小区域面积 a_r , 对于合成图像测试集, 设置 $h_s = 4$, $h_r = 4$ 及 $a_r = 5$, 而对于 Berkeley 图像集, 则设置 $h_s = 10$, $h_r = 10$ 及 $a_r = 100$.

4.2 结果比较与分析

(1) Berkeley 数据库测试结果

首先使用 Berkeley 图像集 BSD300 进行测试, 该图像集由 300 幅自然图像组成, 并提供多个人工标记结果. 由于 BSD300 图像集包括分割难易程度不一的图像, 因此为了说明算法的有效性, 针对每幅图像, 设置聚类个数 K 为与其对应人工标记结果中聚类个数的最小值.

表 1 展示了两种算法分割 300 幅图像结果的评价情况。从中可以看出本文方法在四种评价指标上均优于算法 Liu's。其原因主要在于:根据对超像素内像素标签一致性的判断,选择不同的隶属度函数(即像素级隶属度函数和区域级隶属度),一旦超像素内标记相同标签的像素个数达到指定的阈值,则在计算点对先验概率时,每一个像素的隶属度函数均被替换成所属超像素的隶属度函数,从而加强了 $\pi_{i,k}$ 针对主标签类的先验概率;与此同时,使用区域隶属度函数也会使部分标签未被使用,因此需要执行算法 1 步骤 6 去除未被使用的标签,减少了分割结果中区域的个数,使分割结果更具有区域一致性。

表 1 2 种算法分割 Berkeley 图像集性能评估

	PRI	Vol	GCE	BDE
人工分割	0.902	0.899	0.065	6.038
Liu's	0.764	2.628	0.343	14.103
本文方法	0.792	2.525	0.153	13.399

图 2 给出了 300 幅图像分割结果评价对比情况,从中也能看出本文法在 4 种评价方法上均优于算法 Liu's。图 3 展示了 2 种方法分割 Berkeley 图像集部分分割结果视觉效果图,可以看出,由于在分割过程中使用了高阶区域信息,本文方法所获得的分割结果相对于 Liu's 的分割结果更具有区域一致性,并提升了算法的抗噪声能力。

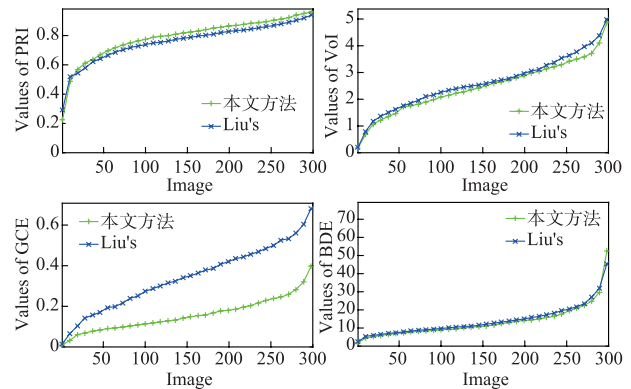


图 2 2 种算法分割 Berkeley 图像集的 PRI、Vol、GCE 及 BDE 值




图 3 2 种算法分割 Berkeley 自然图像集部分分割结果

由于 BSD300 数据库人工标记结果中每一个区域均被看作一类,因此算法 1 步骤 9 对聚类结果进行了重标记,重标记操作将能在 4 种评价指标上有所提升。为保持公正,表 2 展示了在不进行重标记的情况下两种比较算法的分割结果,从中可以看出,本文方法同样优

于算法 Liu's。

本文方法不同之处还在于参数 Q ,该参数用于控制超像素是否具有主标签的阈值,其值不能设置过小,否则超像素就可能会出现多个“主标签”,为此,建议参数 Q 设置为大于 0.5 的值。为了验证该参数对本文方法分

割性能的影响,表 3 展示了 Q 取不同值时,本文方法分割 Berkeley 300 幅图像集分割结果在 4 种评价指标上的比较.可以看出, Q 取值越小,分割的结果越好.其原因在于:算法充分利用了超像素的区域一致性,使得处于在同一超像素内的像素尽量聚为一类,而忽略了区域内的像素的不一致性,这种情况下,分割质量极大程度上依赖于超像素的生成质量;反之, Q 取值越大,越不易获取超像素的主标签,如 $Q = 1$ 的情况下,分割结果在 4 种评价指标上类似于算法 Liu's 的分割结果.

表 2 无重标记时 2 种算法分割 Berkeley 图像集性能评估

	PRI	Vol	GCE	BDE
Liu's	0.764	2.628	0.343	14.103
本文方法	0.777	2.435	0.314	13.438

表 3 参数 Q 取不同值时本文方法分割性能评估

Q	PRI	Vol	GCE	BDE
0.6	0.796	2.514	0.158	13.261
0.7	0.795	2.528	0.158	13.362
0.8	0.794	2.565	0.158	13.430
0.9	0.790	2.672	0.157	13.672
1.0	0.784	2.769	0.144	13.973

(2) 合成图像集测试结果

为了说明算法对噪声的鲁棒性,本文测试了 300 幅合成图像,表 4 展示了两种算法分割整个合成图像测试集所得结果的评价情况,从中可以看出,本文方法在四种评价指标都要优于算法 Liu's.

表 4 2 种算法分割合成图像集的性能评估

	PRI	Vol	GCE	BDE
Liu's	0.877	1.166	0.167	7.097
本文方法	0.882	1.068	0.147	6.968

在本次试验中,由于合成图像与自然图像有所差别,参数 Q 设置为 0.99. 原因在于:超像素内像素的像素级隶属度函数本身易受到噪声的影响,如果 Q 设置过小,在开始迭代过程中,一些超像素内大部分像素被错误分割,从而在计算点对先验概率时会使用像素区域级的隶属度函数,传递了错误信息,造成最终分割结果不正确.因此设置 Q 为较大值,可以避免这种情况的发生,一旦超像素绝大部分像素标记为同一标签,才能认为该超像素具有区域一致性.

5 结语

本文提出了一种自适应区域空间限制的 HMRFCM 分割算法,把超像素具有区域一致性的先验知识融入到点对先验概率计算过程中,通过依据像素对所

属超像素的贡献度计算区域级隶属度函数,并依据超像素是否具有主标签动态选择像素的像素级和区域级隶属度函数,不仅有效提高了分割结果的区域一致性,而且抑制了图像中的噪声、提高了分割的质量.在 Berkeley 分割数据库 300 幅彩色图像集和 400 幅合成图像集上的实验结果表明:新算法的分割性能优于当前种主流的比较算法.未来工作包括设计新的能量项(如高阶势能、标签代价等)和解决超像素本身生成质量割割以进一步提高图像分割性能.

参考文献

- [1] 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.
- [2] Yang A Y, 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.
- [3] 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.
- [4] Shi J, Malik J. Normalized cuts and image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(8): 888-905.
- [5] 蔡强,刘亚奇,曹健,等.一种基于自适应标记与区域间近邻传播聚类的分水岭图像分割算法[J].电子学报,2017,45(8):1911-1918.
CAI Qiang, LIU Ya-qi, CAO Jian, et al. A watershed image segmentation algorithm based on self-adaptive marking and interregional affinity propagation clustering [J]. Acta Electronica Sinica, 2017, 45(8): 1911-1918. (in Chinese)
- [6] 李磊,董卓莉,张德贤,等.基于区域限制的 EM 和图割的非监督彩色图像分割方法[J].电子学报,2016,44(6): 1349-1354.
LI Lei, DONG Zhuo-li, ZHANG De-xian, et al. An unsupervised color image segmentation method based on region-constrained EM and graph cuts [J]. Acta Electronica Sinica, 2016, 44(6): 1349-1354. (in Chinese)
- [7] 徐超,詹天明,孔令成,等.基于学生 t 分布的鲁棒分层模糊算法及其在图像分割中的应用[J].电子学报,2017, 45(7): 1695-1700.
XU Chao, ZHAN Tian-ming, KONG Ling-cheng, et al. A robust hierarchical fuzzy algorithm with student's t -distribution for image segmentation application [J]. Acta Electronica Sinica, 2017, 45(7): 1695-1700. (in Chinese)
- [8] Zhu H, Pan X. Robust fuzzy clustering using nonsymmetric

- student's t finite mixture model for MR image segmentation [J]. *Neurocomputing*, 2016, 175 (Part A) :500 – 514.
- [9] Li Z, Shi W, Zhang H, et al. Change detection based on gabor wavelet features for very high resolution remote sensing images [J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14 (5) :783 – 787.
- [10] Liu G, Zhao Z, Zhang Y. Image fuzzy clustering based on the region-level Markov random field model [J]. *IEEE Geoscience and Remote Sensing Letters*, 2015, 12 (8) :1770 – 1774.
- [11] Bai X, Chen Z, Zhang Y, et al. Infrared ship target segmentation based on spatial information improved fcm [J]. *IEEE Transactions on Cybernetics*, 2016, 46 (12) :3259 – 3271.
- [12] Bezdek J C. *Pattern Recognition with Fuzzy Objective Function Algorithms* [M]. Holland: Kluwer Academic Publishers, 1981.
- [13] Pham D L. Fuzzy clustering with spatial constraints [A]. *Proceedings of the International Conference on Image Processing* [C]. USA:ICIP, 2002. II-65 – II-68.
- [14] Ahmed M N, Yamany S M, Mohamed N, et al. A modified fuzzy C-means algorithm for bias field estimation and segmentation of MRI data [J]. *IEEE Transactions on Medical Imaging*, 2002, 21 (3) :193 – 199.
- [15] Chen S, Zhang D. Robust image segmentation using FCM with spatial constraints based on new kernel-induced distance measure [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2004, 34 (4) :1907 – 1916.
- [16] Cai W, Chen S, Zhang D. Fast and robust fuzzy c-means clustering algorithms incorporating local information for image segmentation [J]. *Pattern Recognition*, 2007, 40 (3) :825 – 838.
- [17] Gong M, Liang Y, Shi J, et al. Fuzzy c-means clustering with local information and kernel metric for image segmentation [J]. *IEEE Transactions on Image Processing*, 2013, 22 (2) :573 – 584.
- [18] Liu S, Li X, Li Z. A new image segmentation algorithm based on the fusion of Markov random field and fuzzy c-means clustering [A]. *Proceedings of IEEE International Symposium on Communications and Information Technology* [C]. USA:IEEE, 2005. 144 – 147.
- [19] Wang C, Liu J, Gong M, et al. Fuzzy c-means clustering with weighted energy function in MRF for image segmentation [A]. *Proceedings of IEEE International Conference on Fuzzy Systems* [C]. USA:IEEE, 2014. 210 – 215.
- [20] Chatzis S, Varvarigou T. A fuzzy clustering approach toward hidden Markov random field models for enhanced spatially constrained image segmentation [J]. *IEEE Transactions on Fuzzy Systems*, 2008, 16 (5) :1351 – 1361.
- [21] Gong M, Su L, Jia M, et al. Fuzzy clustering with a modified MRF energy function for change detection in synthetic aperture radar images [J]. *IEEE Transactions on Fuzzy Systems*, 2014, 22 (1) :98 – 109.
- [22] Zhang H, Wu Q M J, Zheng Y, et al. Effective fuzzy clustering algorithm with Bayesian model and mean template for image segmentation [J]. *IET Image Processing*, 2014, 8 (10) :571 – 581.
- [23] Liu G, Zhang Y, Wang A. Incorporating adaptive local information into fuzzy clustering for image segmentation [J]. *IEEE Transactions on Image Processing*, 2015, 24 (11) :3990 – 4000.

作者简介



李 磊 男, 1979 年出生, 河南杞县人, 博士, 讲师. 主要研究方向: 图像处理、计算机视觉与机器学习.
E-mail: llhaut@163.com



董卓莉 女, 1980 年出生, 河南洛宁人, 讲师. 主要研究方向: 图像处理、计算机视觉与机器学习.
E-mail: dong_lily2002@haut.edu.cn