

# 基于 Markov 随机场理论的 鼠脑切片显微图像的分割研究\*

孙立晔 韩军伟 胡新韬 郭雷

(西北工业大学 自动化学院 西安 710072)

**摘要** 鼠脑中的神经细胞是生物学家的一个重要研究对象. 随着计算机视觉技术的飞速进步, 研究者们利用图像分割技术从鼠脑切片显微图像自动提取细胞, 为进一步分析提供便利. 文中提出一种基于马尔可夫随机场理论的鼠脑切片细胞分割算法. 相对于传统的算法, 文中创新是利用已有的专家标记图和原始图像的灰度特征, 结合期望最大化算法, 初步估计高斯混合模型的参数, 作为条件迭代模式算法的初始值, 不仅提高分割精度, 且减少迭代次数; 并将像素的灰度特征和像素间的距离加入到传统的 Potts 随机场模型中, 更加合理地描述像素间的定量关系. 实验结果表明, 与传统方法相比, 此方法具有较高的计算效率和分割精度.

**关键词** 细胞分割, 图像分割, 马尔可夫随机场, 高斯混合模型, 迭代条件模式

中图分类号 TP 391

## Cell Segmentation in Microscopic Images of Mice Brain Based on Markov Random Field Theory

SUN Li-Ye, HAN Jun-Wei, HU Xin-Tao, GUO Lei

(School of Automation, Northwestern Polytechnical University, Xi'an 710072)

### ABSTRACT

The neurons in sectioning microscope images of mice brain are important to biologists. Image segmentation algorithms are widely applied to automatically extract the neurons to facilitate further analysis. A method for cell segmentation in microscopic image of mice brain based on Markov Random Field (MRF) theory is proposed. Firstly, manually labeled images and original images are jointly analyzed to estimate the initial parameters in Gaussian Mixture Model, which significantly reduces the number of iterations and increases the precision of segmentation. Secondly, pixel intensity and distance between pixels are integrated into the conventional Potts model to improve the description of the quantitative relationship between pixels. The experimental results demonstrate that the proposed method improves the accuracy and the efficiency of cell segmentation compared to traditional methods.

**Key Words** Cell Segmentation, Image Segmentation, Markov Random Field, Gaussian Mixture Model, Iterated Conditional Mode

\* 国家自然科学基金项目 (No. 61005018, 91120005, 61103061)、西北工业大学研究生创业种子基金项目 (No. Z2013106) 资助

收稿日期: 2012-08-31; 修回日期: 2013-01-10

**作者简介** 孙立晔 (通讯作者), 女, 1988 年生, 博士研究生, 主要研究方向为多媒体处理、计算机视觉、机器学习. E-mail: iris.sunliye@gmail.com. 韩军伟, 男, 1977 年生, 教授, 博士生导师, 主要研究方向为计算机视觉、图像视频处理、模式识别、多媒体信息检索. 胡新韬, 男, 1981 年生, 副教授, 主要研究方向为生物医学图像处理、脑成像分析、多模态脑功能信息融合. 郭雷, 男, 1956 年生, 教授, 博士生导师, 主要研究方向为神经计算理论、生物医学图像处理、计算机视觉、图像融合等.

# 1 引言

自动图像分割常常作为一个在完成诸如目标识别、基于内容的图像检索等高级任务之前的重要的初始化步骤. 显微图像中细胞的分割是生物学及生命科学等研究领域的基础性问题. 小鼠脑切片显微图像是在高分辨率显微镜下观察到的脑组织图像, 有一些神经细胞是科学家们感兴趣的, 实验前期在鼠的 FOS 基因上添加绿色荧光蛋白基因, 当 FOS 基因在神经细胞中表达成 C-FOS 蛋白时, 结合荧光蛋白基因同时表达. 通过分子显微镜摄像, 可拍摄到包含荧光蛋白 (包含本文观察的 C-FOS 蛋白) 的神经细胞的轮廓. 为了在后续的工作中实现机器自动标记这些细胞且进一步分析它们, 首先要把这些细胞人工分割出来.

小鼠脑的体积只有不到  $1\text{cm}^3$ , 且整个小鼠脑被分割为近 300 片, 所以无论是用肉眼还是在显微镜下都难以快速而准确地分割出这些神经细胞.

细胞分割是典型的图像分割问题. 常见的图像分割算法有基于阈值<sup>[1]</sup>、基于边缘<sup>[2]</sup>、基于模糊集理论<sup>[3]</sup>、基于随机场的算法<sup>[4]</sup>及基于形态学<sup>[5]</sup>、基于神经网络的方法<sup>[6]</sup>等. 基于随机场的方法是一类考虑空间像素点的邻域关系的统计学方法, 其中, 基于马尔可夫随机场 (Markov Random Field, MRF) 理论的图像分割方法<sup>[7]</sup>具有较多优点, 如集成像素间空间交互关系, 可方便的使用各种图像特征等.

考虑到鼠脑切片显微图像分割的难点及 MRF 模型的优势, 提出一种快速的基于 Markov 随机场理论的鼠脑切片显微图像细胞分割算法. 传统的基于 MRF 理论的图像分割方法刻画图像邻域信息不尽合理, 本文将邻域像素的强度差及像素距离引入经典的 MRF 势函数定义中, 使得当像素间的强度值相差越大或像素间距越大, 则随机场中这一对像素之间的势能越大, 根据能量最小迭代准则, 两像素被分入同一类的概率越小, 这样就有效避免将噪声错分为神经细胞. 此外, 针对传统 MRF-ICM 算法迭代次数多、计算结果依赖迭代初始值的问题, 本文利用 EM 算法估计出 MRF 模型的参数, 作为迭代的初始值, 减少迭代次数, 且提高分割准确度.

## 2 基于 MRF 图像分割的基本概念


### 2.1 MRF 中邻域系统和势团的概念

图像可表示为二维网格点集:

$$S = \{s = (i, j) \mid 1 \leq i \leq M, 1 \leq j \leq N\},$$

其中,  $M$  和  $N$  分别为图像的宽度和高度. 标号场  $X = \{X_1, X_2, \dots, X_{M \times N}\}$  为  $S$  所对应的随机场,  $x = \{x_1, x_2, \dots, x_{M \times N}\}$  是随机场的一个配置<sup>[8]</sup>.  $S$  中的每一个元素通过邻域系统来表示相互关联, 邻域系统定义为:  $N = \{N_i \mid \forall i \in S\}$ , 其中,  $N_i$  是位置  $i$  的邻域集合. 邻域系统  $N$  上的二维随机场  $X$  可称为马尔可夫随机场. 图 1 所示为二阶邻域系统中单像素和双像素势团图, 根据此图可构造邻域势团的势函数.

1	2	3
4	$x_i$	5
6	7	8



(a) 二阶邻域系统 (b) 单像素势团 (c) 双像素势团

(a) Second-order neighborhood system

(b) One-pixel clique

(c) Two-pixel clique

图 1 二阶邻域系统中的单像素和双像素势团

Fig. 1 One-pixel clique and two-pixel clique in second-order neighborhood system

### 2.2 图像分割的 MAP-MRF 框架理论

设  $X, Y$  是二维平面上的随机场,  $y$  是观测数据,  $x$  对应分割结果. 从  $y$  直接得到  $x$  是不可能的, 只能给出  $x$  的一个估计, 通常使用最大后验概率 (Maximum A Posterior, MAP) 准则<sup>[7]</sup>, 由 Bayes 公式得

$$P(X = x \mid Y = y) = \frac{P(Y = y \mid X = x)P(X = x)}{P(Y = y)}, \quad (1)$$

其中,  $P(Y = y \mid X = x)$  是条件概率, 也称为似然函数,  $P(X = x)$  是标号场  $X$  的先验的联合的 Gibbs 分布,  $P(Y = y)$  是观测数据的先验分布. 当数据给定后为常数, 所以不参与计算过程, 即

$$P(X = x \mid Y = y) \propto P(Y = y \mid X = x)P(X = x), \quad (2)$$

对上式取对数即得到目标函数<sup>[8]</sup>, 形成 MAP-MRF 框架下的目标函数的最优解问题:

$$\begin{aligned} \hat{x} &= \arg \max_x [\ln P(X = x) + \ln P(Y = y \mid X = x)] \\ &= \arg \max_x [U_c(x) + U_s(x, y)]. \end{aligned} \quad (3)$$

## 3 基于 MRF 的鼠脑切片图像分割

### 3.1 标号场建模

常用的标号场模型有 Ising 模型<sup>[9]</sup>、MLL 模型<sup>[10]</sup>、Potts 模型<sup>[11]</sup>. Potts 模型包括统计学和格网理论中的大量问题, 考虑二元势函数, 定义为

$$V_c(x_i, x_j) = \begin{cases} \beta, & x_i \neq x_j \\ 0, & x_i = x_j \end{cases} \quad (4)$$

其中,  $\beta$  是对应的势团参数,  $x_i \in \{1, 2\}$ , 表示当前像素  $i$  的分类标记. 这种定义方法并没有考虑像素间灰度关系, 影响分类效果. 本文引入图像邻域中各个像素的强度差值及像素之间的距离因子, 提出新的势函数, 使图像空间上下文信息得到更加充分的利用, 即

$$V'_c(x_i, x_j) = \begin{cases} \beta, & x_i \neq x_j \\ -\frac{\beta \cdot |y_i - \mu_i|}{|y_i - \mu_i| + |y_i - y_j| \cdot D(x_i, x_j)}, & x_i = x_j \end{cases} \quad (5)$$

其中,  $y_i$  和  $y_j$  分别为  $x_i$  和  $x_j$  处的灰度值,  $D(x_i, x_j)$  为  $x_i$  和  $x_j$  之间的距离. 根据 Hammersley-Clifford 定理<sup>[12]</sup>, 改进后的标号场模型的局部概率:

$$P(X = x) = \frac{1}{Z} \exp \left\{ -\frac{1}{T} \sum_{c \in N} V'_c(x_i, x_j) \right\}, \quad (6)$$

其中,  $Z$  是归一化常量,  $T$  为温度常量. 这样改进势能函数是由于大部分噪声的亮度远低于神经细胞, 但仍有一小部分噪声与细胞亮度较为接近, 如果仅依据亮度信息可能会把噪声错分为细胞, 则噪声距离细胞较远, 且噪声彼此孤立, 噪声面积远小于细胞, 所以本文将像素间的亮度差和距离加入能量函数中, 亦即噪声与细胞的距离越大或噪声与细胞的距离越远, 它们间的势团能量就越大. 根据式(6), 把噪声错分为神经细胞的概率值就越小; 而噪声与其周围背景亮度接近且距离近, 其相对势能较小, 将噪声划分为背景的概率较大, 这样, 在能量最小准则下, 通过逐次迭代可以将噪声与细胞正确区分开来.

标号场的能量函数  $U_c$  反映邻域信息的能量, 定义为对先验概率  $P(X = x)$  取对数:

$$U_c = \ln P(X = x) = \sum_s \left[ -\sum_{c \in N} (V'_c(x_i, x_j)) / T - \ln Z \right], \quad (7)$$

根据上式, 邻域像素中具有相同标记的个数越多, 标号场能量越大; 反之越小. 因此, 标号场可以抹去分割结果中孤立的分割点, 使分割结果具有较好的区域性, 且本文改进势团能量的定义, 有效避免将细胞附近的背景像素点和噪声错分为细胞, 更加符合图像的局部状况.

### 3.2 特征场建模

图像区域的灰度特征可通过高斯函数来描述. 具体来说, 对于观测图像中的任意一点  $s$ , 其灰度可假定为  $y_s$ , 在标号场中对应  $x_s$ , 则每像素的灰度的条

件概率根据高斯混合分布得

$$f(y_s | x_s = l) = \prod_{l=1}^2 \pi_l \frac{1}{\sqrt{2\pi\sigma_l^2}} \exp \left\{ -\frac{(y_s - \mu_l)^2}{2\sigma_l^2} \right\}. \quad (8)$$

假设图像中的像素相互独立, 似然函数如下:

$$P(Y = y | X = x) = \prod_s P(y_s | x_s), \quad (9)$$

特征场的能量函数  $U_s$  反映观测场和标号场之间相关性的条件概率, 定义为对条件概率函数取对数:

$$U_s = \ln P(Y = y | X = x) = \sum_s \sum_{l=1}^2 \ln \pi_l \frac{1}{\sqrt{2\pi\sigma_l^2}} \exp \left\{ -\frac{(y_s - \mu_l)^2}{2\sigma_l^2} \right\}, \quad (10)$$

其中,  $l \in \{1, 2\}$ , 表示当前像素  $s$  的类别是属于背景或细胞. 可看出, 特征场能量的取值取决于对应位置的观测特征, 特征场的主要作用是尽可能地描述图像的有关细节信息, 使得图像的分割结果与观测图像具有较强的一致性.

### 3.3 ICM 算法

根据 Gibbs 分布与 MRF 的等价性, 可将分割问题转化为求后验能量的最大值所对应的标记问题, 在图像分割中优化目标就是式(3). 本文选择快捷且鲁棒的 ICM 迭代算法<sup>[11]</sup>, 迭代过程中, 每个像素都利用 MAP 准则进行分类, 在对每个像素进行分类后, 都需要利用已获得的像素类别重新估计每类的概率密度函数的参数. 直到每步迭代过程中变换类别的像素个数足够小, 迭代结束. ICM 算法的使用, 先通过迭代不断修正分割错误, 直至能量函数收敛至最小, 再考虑特征场和标号场的相互影响, 从而既利用总体特征, 也利用局部特征, 得到较好的分割结果.

但是 ICM 算法依赖于初始分割结果, 目前较为普遍的算法是利用  $K$  均值聚类的结果作为迭代的初始值, 但是  $K$  均值聚类的结果具有随机性, 往往并不能得到准确的聚类结果, 将其作为 ICM 算法迭代的初始值会增加迭代次数, 且可能由于初始分割结果较差, 即使迭代多次也无法收敛至最优解.

考虑到 ICM 算法的特点, 本文先根据专家标记的真实图及原始图像的灰度信息, 通过期望最大化算法 (Expectation Maximization, EM), 学习得到待求参数的值, 初步对特征场和标号场建模, 并将其作为 ICM 算法的初始迭代值. 由于已初步估计出一个较为准确的标记结果, 所以 ICM 算法可快速收敛到最优值, 从而得到良好的分割结果.

## 4 实验与结果分析

### 4.1 算法过程

本实验的实验数据为 600 幅鼠脑切片显微图像,分辨率为  $732 \times 732$ ,灰度级为 65 532. 用于实现本算法的硬件环境: Pentium 4, 2. 60GHz, 4GB 内存, 256MB 独立显卡. 运行的软件环境: Matlab 7. 0 和 Ubuntu 10. 04. 在上述实验环境下,对 400 幅图像进行分割,分割每幅图像平均时长为 2. 1s. 具体实验步骤:

1) 提取所有图像的灰度特征;

2) 随机选取 200 幅图像作为训练集,用已有的专家标记图,结合原始图像的观测特征,利用期望最大化算法,学习得到用于建模特征场的高斯混合模型的参数,即均值  $\mu_i$ , 方差  $\sigma_i^2$  及权重  $\pi_i$ ;

3) 对于一幅给定的待分割图像,利用 2) 学习得到的模型参数及改进的势能函数来建模图像,将特征场和标号场此时的配置作为 ICM 迭代算法的初始值;

4) 在 MAP-MRF 框架下,根据式(3)、(7)、(10) 计算后验能量,应用 ICM 算法进行迭代寻求后验能量的最大值,也就找到对应最大后验概率的分割结果.

### 4.2 实验结果分析与比较

本文使用图像分割中常用的  $F1$  值和准确度来定性度量分割结果,对于 400 幅鼠脑切片显微图像进行分割,统计出  $F1$  值和准确度的平均值见表 1. 在评价指标的定义公式中, $TP$  代表正确分类的细胞像素数, $TN$  代表正确分类的背景像素数, $FP$  代表被错分为细胞的像素数目, $FN$  代表被错分为背景的像素数目. 在此基础上定义查准率、召回率、 $F1$  值:

$$\text{查准率} = \frac{TP}{TP + FP}, \quad \text{召回率} = \frac{TP}{TP + FN}, \quad (11)$$

$$F1 \text{ 值} (F1 \text{ Score}) = \frac{2 \times \text{查准率} \times \text{召回率}}{\text{查准率} + \text{召回率}}. \quad (12)$$

$F1$  值 ( $F1 \text{ Score}$ )<sup>[14]</sup> 是分类问题中常用的衡量指标,它权衡查准率和查全率,查准率和查全率呈此消彼长的关系,只有当查准率和查全率同时取得相对最优时,才能得到最高的  $F1$  值. 考虑到本文的最终目的是将神经细胞从背景中正确分割出来,所以本文用式(12) 定义的  $F1$  值和式(13) 定义的准确度 ( $\text{Accuracy}$ )<sup>[15]</sup> 来衡量分类结果:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}. \quad (13)$$

一直以来没有一个普适的规律来指导势团参数  $\beta$  的确定,本文进行多次尝试,对 400 幅鼠脑切片显

微图像的实验结果进行统计, $F1$  值和准确度随  $\beta$  的变化趋势及各自的方差见图 2,可看出  $\beta=8$  时,准确度取得最大值,说明分割效果最好;且  $F1$  值取得相对最大,说明查准率和查全率的取值均达到相对最优;方差相对较小,说明整体分割效果稳定. 因此在实验中取  $\beta=8$ .

表 1 5 种分割算法的结果对比

Table 1 Comparison of 5 segmentation methods

算法	准确度	$F1$ 值
MRF-ICM 算法	0. 7139	0. 0996
MRF-SA 算法	0. 8156	0. 1484
文献[16]算法	0. 8586	0. 1020
文献[17]算法	0. 9074	0. 2062
本文算法	0. 9483	0. 5217




图 2 势团参数  $\beta$  取不同值时对应的平均准确度和  $F1$  均值以及各自标准差

Fig. 2 Mean and standard deviations of accuracy and  $F1$  measure under different potential  $\beta$

将本文的算法与经典的 MRF-ICM 算法、MRF-SA 算法及两种基于 MRF 理论的细胞分割算法 [16]、[17] 进行比较,实验结果见图 3. 直观上看,本文算法得到的分割图与真实标定结果非常接近,尤其是在细胞与噪声融合严重的区域,如图 3 左图中的右下方区域,依然可准确区分出细胞与噪声. 而传统的 MRF-ICM 算法的分割结果依赖于初始的聚类情况,若初始聚类错误,就无法收敛至局部最优值,也就无法得到准确的分割结果;此外,对比图 3 (b) 与 (f) 可发现,传统的 Potts 模型对像素邻域关系的刻画不合理,使得分割结果中局部一致性不佳,噪声较多;且有较多错分点,这也说明算法未能收敛至局部最优值. 基于 MRF-SA 的分割算法并不总是能跳出局部最大值陷阱,尤其是当随机产生的初始解不准确时,往往经过多次转移仍旧无法寻求到全局最优解;此外,SA 算法中有较多参数的设置难以把握,而这些参数会在很大程度上影响分割结果. 事

实上,图 3(a)左图中正上方的阴影部分原本应该属于背景,但是 MRF-SA 算法将其错分成细胞,这是由于未能收敛至全局最优值所致.文献[16]首先对图片进行去噪、锐化,然后利用大津法进行分割,作为 ICM 迭代算法的初始值,接下来进行迭代求解.由于显微图片中细胞与噪声混杂,在进行去噪、锐化时破坏随机场的完整信息,导致最终分割结果无法正确区分出细胞与背景,如图 3(d)中,被破坏的随机场里,临近像素之间的联系遭到破坏,且无法正确建模特征场能量,也就无法正确分割细胞.文献[17]提出一种结合小波域模糊系数的多分辨率 MRF 模型,在传统多分辨率 MRF 模型的基础上,另外引入一个多分辨率模糊场,这个模糊场可体现出相邻分辨率之间的关于特征的空间约束,从而辅助估计 MRF 模型参数.这种算法利用多尺度之间的相互约束信息,

更合理地考虑临近像素之间的空间关系,因此分割效果较好,但计算繁琐,且模糊场的建立并不能减少噪声的误分割,分割结果过分保留图像的边缘信息.

相较于上述算法,本文的算法没有破坏随机场的整体信息;且无须应用诸如多尺度算法的繁琐计算,将邻域像素之间的灰度值与距离信息引入能量函数的定义中,就可合理刻画随机场的局部信息;此外,本文利用 EM 算法,在真实标记结果的指导下,结合图像的灰度特征,估计出特征场及标号场的一个配置,这个配置较为符合真实的分割结果,因此将这个配置作为迭代算法的初始值,可使 ICM 算法快速收敛至最优值,既可提高分割效果,又大大减少迭代次数;而针对 ICM 算法需手动设置的参数  $\beta$ ,本文通过大量的实验,运用统计学方法分析得出合理的参数取值,在实验数据集里取得良好的分割效果.

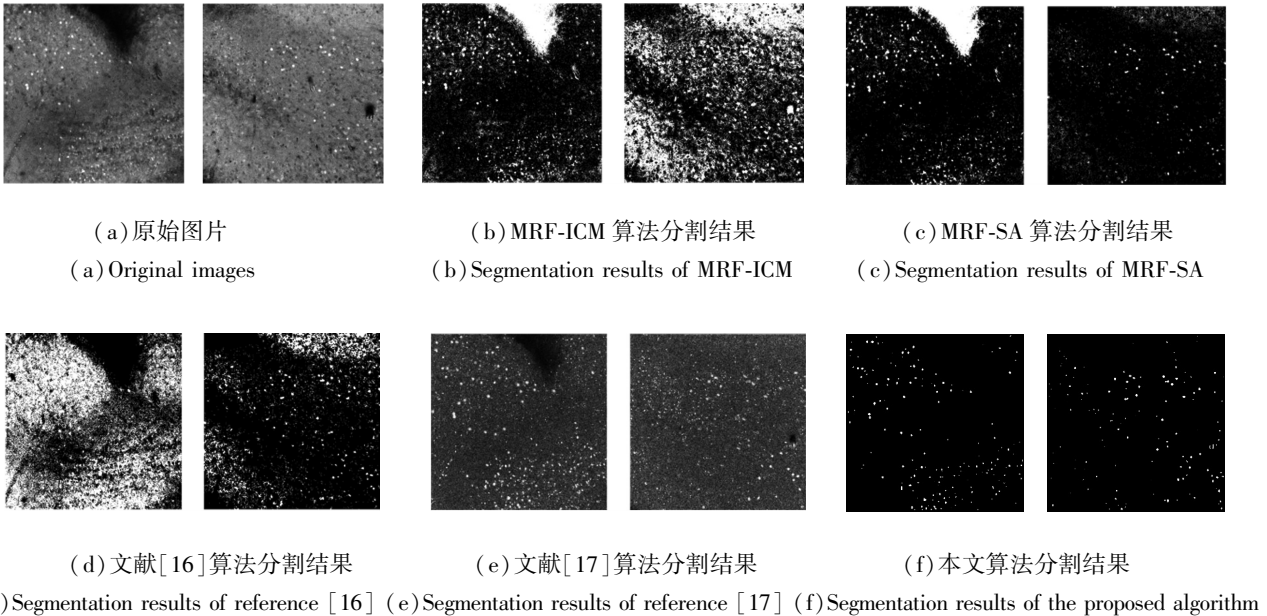


图 3 5 种算法对图像的分割结果

Fig. 3 Segmentation results of 5 algorithms

## 5 结束语

鼠脑切片显微图像的细胞分割是生物学研究中一个必要步骤,为快速精确地完成神经细胞的分割,在传统 MRF 图像分割方法的基础上,本文提出一种改进的势团能量的定义方法,即在传统的 Potts 模型势函数中引入像素亮度差值和像素间的距离信息,从而更加充分利用图像的空间信息,可有效避免错分噪声与细胞.此外,本文利用已有的真实标记图,初步学习出算法模型的未知参数,作为 ICM 算法的迭代初始值,不仅提高分割的准确程度,且提高算法

的计算效率.实验结果表明,相较于近年来基于 MRF 模型的细胞分割算法,本文算法可更加准确快速地分割出神经细胞.

## 参 考 文 献

- [1] Van Aarle W, Batenbur K J, Sijbers J. Optimal Threshold Selection for Segmentation of Dense Homogeneous Objects in Tomographic Reconstructions. *IEEE Trans on Medical Imaging*, 2011, 30(4): 980-989
- [2] Mishra A K, Aloimonos Y, Cheong L F, *et al.* Active Visual Segmentation. *IEEE Trans on Pattern Analysis and Machine Intelli-*

gence, 2012, 34(4): 639-653

[3] Yuksel M E, Borlu M. Accurate Segmentation of Dermoscopic Images by Image Thresholding Based on Type-2 Fuzzy Logic. *IEEE Trans on Fuzzy Systems*, 2009, 17(4): 976-982

[4] Feng W, Jia J, Liu Z Q. Self-Validated Labeling of Markov Random Fields for Image Segmentation. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2010, 32(10): 1871-1887

[5] Chen Yufei, Wang Zhicheng, Zhao Weidong, *et al.* Liver Segmentation from CT Images Based on Region Growing Method // *Proc of the 3rd International Conference on Bioinformatics and Biomedical Engineering*. Beijing, China, 2009: 1-4

[6] de Santis A, Lacoviello D. Discrete Image Modeling for Piecewise Constant Segmentation by Artificial Neural Networks. *IET Image Processing*, 2008, 2(1): 37-47

[7] Geman S, Geman D. Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1984, 6(6): 721-741

[8] Li S Z. *Markov Random Field Modeling in Image Analysis*. Berlin, Germany: Springer-Verlag, 2001

[9] Ising E. Beitrag zur Theorie des Ferromagnetic-smus. *Zeitschrift für Physik A Hadrons and Nuclei*, 1952, 48(1): 253-258

[10] Potts R B, Domb C. Some Generalized Order-Disorder Transformations. *Mathematical Proceedings of the Cambridge Philosophical Society*, 1952, 48: 106-109

[11] Derin H, Elliott H, Cristi R, *et al.* Bayes Smoothing Algorithms for Segmentation of Binary Images Modeled by Markov Random Fields. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 1984, 6(6): 707-720

[12] Hammersley J M, Clifford P. *Markov Fields on Finite Graphs and Lattices* [EB/OL]. [2012-01-30]. <http://www.statslab.cam.ac.uk/~grg/books/hammfest/hamm-cliff.pdf>

[13] Besag J. On the Statistical Analysis of Dirty Pictures. *Journal of the Royal Statistical Society: Series B*, 1986, 48(3): 259-302

[14] van Rijsbergen C J. *Information Retrieval*. 2nd Edition. London, UK: Butterworth-Heinemann, 1979: 70-74

[15] Olson D L, Delen D. *Advanced Data Mining Techniques*. Berlin, Germany: Springer-Verlag, 2008: 180-189

[16] Zhu Yu, Zuo Tan, Wang Yuzhou. SEM Microscopic Image Segmentation Based on Markov Field Models // *Proc of the 5th International Conference on Image and Graphics*. Xi'an, China, 2009: 177-182

[17] Zheng C, Qin Q, Liu G, *et al.* Image Segmentation Based on Multiresolution Markov Random Field with Fuzzy Constraint in Wavelet Domain. *IET Image Processing*, 2012, 6(3): 213-221

\*\*\*\*\*

(上接第 491 页)

## 二、重要日期

论文提交截止日期: 2013 年 7 月 30 日。

## 三、征文要求

1. 论文写作用中、英文均可。每篇文章署名作者不能超过 4 位,每位作者以第一作者身份投稿不能超过 2 篇。ABB 员工不能参与投稿。
2. 参赛稿件未在全国公开出版发行的刊物上发表过、未在全国性学术会议上报告过、未参评过前五届 ABB 杯论文大赛。
3. 稿件篇幅原则上 A4 纸不低于 4 页、不超出 8 页(包括插图、表格等)。
4. 稿件要求论点鲜明,内容新颖实用,数据可靠,条理清晰,文字简洁通顺,图文清晰。
5. 稿件首页应包括:题目、200 字以内的中文摘要和 3~5 条关键词;与中文内容相对应的英文题目、英文摘要和英文关键词。摘要为不加评论的补充解释,能够简明、确切地记述文章重要内容,包括目的、方法、结果、结论四要素。如来稿属于基金项目(写明基金编号)、国家攻关项目等,请在首页底行注明。
6. 稿件应严格按照要求排版,本大赛拒收未按要求排版的稿件。文中所有文字符号、公式、图形符号要使用国家最新标准。稿件中外文字母分清大小写、正斜体,上下角的字母、数码和符号的位置高低应区别明显。
7. 表格使用"三线表",表中包括:说明、量的名称、量的符号及单位。插图和照片不用复印件,图表放在正文中相应的位置上。图表和公式分别用阿拉伯数字全文统一编号。
8. 参考文献不超过 15 条,综述文章的参考文献可根据内容而定。参考文献格式见网站。
9. 文章末尾须注明:作者真实姓名、详细工作单位、姓名的汉语拼音、工作单位的英文名称及前两位作者简介、电话、Email、邮编、通讯地址等联系方式。
10. 投稿请务必遵守征文要求,以免优秀文章被过早淘汰。