

基于目标模糊置信度描述驱动的区域能量进化增长 图像分割算法

胡正平^{1,2} 谭莹²

摘要 为了克服经典区域增长算法在复杂目标与背景分布情况下, 停止条件难以确定的不足, 提出基于目标模糊置信度描述驱动的区域能量进化增长图像分割算法. 该算法结合了主动轮廓模型 (Active contour model, ACM)、目标数据分布域描述与区域增长三者的优点, 首先利用分割目标的支持向量数据域描述将待分割图像转化为相对于分割目标的模糊置信度表示, 因为分割过程充分利用了有监督学习策略得到的目标特征分布情况, 使得本文提出的算法具有更高的稳定性和更加广泛的适用范围, 特别是对目标灰度分布不均或存在多纹理的目标也可以得到较好的分割结果. 在区域增长进行分割时, 引入了新的区域能量表示模型作为区域增长的结束判决条件, 分割时逐渐降低目标模糊置信度的门限, 通过对区域能量模型的动态优化来逼近最佳分割结果. 对比实验结果表明本文提出的算法具有更大的灵活性和更好的分割性能.

关键词 图像分割, 区域增长, 支持向量数据域描述, 模糊置信度
中图分类号 TP391

Novel Region Energy Evolution Image Segmentation Based on Fuzzy Object Confidence Description

HU Zheng-Ping^{1,2} TAN Ying²

Abstract To overcome the difficulty to search the stop condition in a conventional region growing algorithm, a novel region energy evolution image segmentation method is put forward, which couples the merits of support vector domain description, Mumford-Shah active contour energy model and region growing. The input image data are transform into fuzzy object confidence description firstly by using the support vector domain description model, so the advantages of supervised kernel learning model and the global region distribution information could be exploited to enhance the segmentation performance. On the other hand, a new region-based image energy term in region evolution based on the fuzzy object confidence description is presented. It is more robust than the classical region growing and active contour method, because it takes into account the optimal image object fuzzy confidence description knowledge of human being and feasible energy model as well. In the region growing processing step, the confidence threshold is updated gradually, so the optimal segmentation results are obtained by dynamic optimizing the novel energy model. Experimental results have demonstrated the flexibility and better performance of this novel region growing image segmentation method.

Key words Image segmentation, region growing, support vector domain description (SVDD), fuzzy confidence

图像分割是计算机视觉中的经典难题之一, 它的目的是把图像空间分割成若干个在某种意义上均匀的不重叠区域, 为后续工作做准备. 图像分割是建立在区域特征的相似性及非连续性两个概念上: 1) 相似性, 同一区域中像素的特征是相似的; 2) 非

连续性, 不同区域间像素的特征存在突变, 例如灰度的突然变化等. 区域增长是利用图像中目标区域的整体连通性对图像进行分割的, 区域增长关键技术在于目标区域的一致性描述与增长算法的停止条件的确定. 按照聚类准则的不同, 目前的区域增长分割分为两大类: 统计一致性分割与语义一致的分割, 前者强调把图像分割成统计意义具有一致性的区域, 而后者把图像分割成统计意义上可能并不具有一致性, 但在应用中更有意义的区域, 其目标是达到人类要求的分割结果, 这在实际的图像分割系统中具有更加广泛的适用意义^[1]. 为解决目标区域的一致性描述与增长算法的停止条件这两个问题, 一些学者通过引入模糊集理论提出基于模糊连通度、相对模糊连通度等分割思路^[2-3]; 另外神经网络、贝叶斯网络、高斯混合模型等也被引入区域增长算法中^[4-6].

收稿日期 2007-06-21 收修改稿日期 2007-11-11
Received June 21, 2007; in revised form November 11, 2007
北京大学视觉与听觉信息处理国家重点实验室开放基金 (0507), 燕山大学博士基金 (B287), 河北省自然科学基金 (F2008000891) 资助
Supported by the Found of State Key Laboratory on Machine Perception Open Research of Peking University (0507), the Doctoral Found of Yanshan University (B287), and the Nature Science Foundation of Hebei Province (F2008000891)
1. 燕山大学信息科学与工程学院 秦皇岛 066004 2. 北京大学视觉与听觉信息处理国家重点实验室 北京 100871
1. Colledge of Information Science and Engineering, Yanshan University, Qinhuangdao 066004 2. State Key Laboratory of Machine Perception, Peking University, Beijing 100871
DOI: 10.3724/SP.J.1004.2008.01047

区域增长和主动轮廓模型 (Active contour model, ACM) 是图像分割的主流方法, 主动轮廓模型在无目标模型先验知识条件下, 可以有效地得到分割目标的封闭轮廓; 在已知目标先验形状的条件下, 发展为变形模板技术, 其在边缘检测、轮廓建模和图像分割领域获得广泛应用^[7-9]. 其主要思想是: 首先给出与目标边缘接近的初始轮廓, 然后在由初始位置逐渐向真实轮廓靠近过程中, 寻找一能量函数的局部极小值, 通过对能量函数的动态优化来逼近目标真实轮廓, 由此得到分割对象. 其优点是可以通过对能量函数的动态优化来逼近目标真实轮廓, 能够直接检测到闭合光滑轮廓, 且对噪声具有较强的鲁棒性, 缺点是对于初始轮廓位置敏感, 需要手工选择初始进化轮廓, 分割速度比较慢. 区域增长基本思想是将具有相似性质的像素集中起来构成区域, 该方法需要先选择一个种子点, 然后将种子点周围的相似像素合并到种子点像素所属的区域中. 其优点是需要较少的手工操作 (最多一个种子点, 自动选择时则不需要), 并能够快速分割出连续的区域, 缺点是对噪声比较敏感, 区域增长的最佳停止条件难以确定. 如何将二者的优点结合起来建立一种新的图像分割算法是本文研究的出发点, 为此提出了基于目标模糊置信度描述驱动的区域能量进化增长图像分割算法, 它结合了主动轮廓模型、目标数据分布域描述与区域增长三者的优点: 借鉴主动轮廓模型的能量最小保证了分割的最优性; 目标数据 (特征) 分布域描述将图像数据转化为属于目标区域的模糊置信度表示, 较好地解决了目标区域的统计一致性描述问题; 区域增长保证了区域分割的连续性和更少的手工操作. 实验结果表明: 本文提出的算法在复杂环境下具有更大的灵活性和更高的稳定性, 因为分割过程充分利用了有监督学习和人工交互操作的先验知识, 既可以实现全局图像分割, 也可以实现局部区域分割.

1 基于目标模糊置信度描述驱动的区域能量进化增长图像分割算法

1.1 目标模糊置信度描述

为了得到目标区域的模糊置信度描述, 我们需要引入 Tax 等在支持向量机 (Support vector machine, SVM) 的基础上提出的一种数据描述方法——支持向量数据域描述 (Support vector domain description, SVDD)^[10], 其基本思想是寻找包含目标区域数据 \mathbf{x}_j 的最小半径 R 的超球体, 同时要求其他非目标区域数据位于超球体外. 通常情况下, 即使去除奇异点数据, 目标区域数据依然不会呈现球状分布, 这时可以通过引入核函数将它映射到更高维

空间进行讨论. 同时为了减少奇异点数据的影响, 引入松弛变量 ξ_i 进行描述 (即允许存在错误), 求最小超球体体积可以转化为下面的二次规划问题

$$\min \left(R^2 + C \sum_i \xi_i \right) \quad (1)$$

这里 R 为超球体半径, 其约束条件为

$$(\mathbf{x}_i - \mathbf{a})^T (\mathbf{x}_i - \mathbf{a}) \leq R^2 + \xi_i \quad (2)$$

其中, $\xi_i > 0$, \mathbf{a} 为超球体中心, \mathbf{x}_i 为目标区域数据. 上面的优化问题通过引入拉格朗日系数变为

$$\min L = R^2 + C \sum_i (\xi_i) - \beta_i \sum_i \xi_i - \sum_i \alpha_i (R^2 + \xi_i - (\mathbf{x}_i - \mathbf{a})^T (\mathbf{x}_i - \mathbf{a})) \quad (3)$$

其中, $\alpha_i \geq 0$, $\beta_i \geq 0$. 求式 (3) 的最小值可转化为如下的对偶问题

$$\max F = \sum_i \alpha_i (\mathbf{x}_i, \mathbf{x}_j) - \sum_i \sum_j \alpha_i \alpha_j (\mathbf{x}_i, \mathbf{x}_j) \quad (4)$$

其中, $\sum_i \alpha_i = 1$, $0 \leq \alpha_i \leq C$. 通常情况下, 即使去除奇异点数据, 数据依然不会呈现球状分布, 这时可以通过引入核函数将它映射到更高维空间进行讨论.

上面的 SVDD 仅仅考虑一类目标区域数据, 如果利用到目标区域和背景区域不同类别样本数据的信息, 其基本思想就是寻找包含目标区域类数据的最小半径的超球体, 同时要求其他背景区域类数据位于超球体外. 其支持向量数据域描述的二次规划优化问题形式变为

$$\min \left(R^2 + C_1 \sum_i \xi_i + C_2 \sum_l \xi_l \right) \quad (5)$$

约束条件为

$$(\mathbf{x}_i - \mathbf{a})^T (\mathbf{x}_i - \mathbf{a}) \leq R^2 + \xi_i \quad (\text{目标区域数据})$$

$$(\mathbf{x}_l - \mathbf{a})^T (\mathbf{x}_l - \mathbf{a}) \geq R^2 - \xi_l \quad (\text{背景区域数据})$$

其中, $\xi_i \geq 0$, $\xi_l \geq 0$, $\forall i, l$. 通过引入拉格朗日系数, 上面的优化问题变为

$$L = R^2 + C_1 \sum_i \xi_i + C_2 \sum_l \xi_l - \sum_i \gamma_i \xi_i - \sum_l \gamma_l \xi_l - \sum_i (R^2 + \xi_i - (\mathbf{x}_i - \mathbf{a})^T (\mathbf{x}_i - \mathbf{a})) - \sum_l \alpha_l ((\mathbf{x}_l - \mathbf{a})^T (\mathbf{x}_l - \mathbf{a}) - R^2 + \xi_l) \quad (6)$$

令对 $L, R, \mathbf{a}, \xi_i, \xi_l$ 求导并等于 0, 得到

$$\sum_i \alpha_i - \sum_l \alpha_l = 1$$

$$\mathbf{a} = \sum_i \alpha_i \mathbf{x}_i - \sum_l \alpha_l \mathbf{x}_l$$

其对偶优化形式为

$$L = \sum_i \alpha_i (\mathbf{x}_i, \mathbf{x}_i) - \sum_l \alpha_l (\mathbf{x}_l, \mathbf{x}_l) - \sum_{i,j} \alpha_i \alpha_j (\mathbf{x}_i, \mathbf{x}_j) + 2 \sum_{j,l} \alpha_l \alpha_j (\mathbf{x}_j, \mathbf{x}_l) - \sum_{l,m} \alpha_l \alpha_m (\mathbf{x}_l, \mathbf{x}_m) \quad (7)$$

令 $\alpha'_i = y_i \alpha_i$, 则 $\sum_i \alpha'_i = 1$, $\mathbf{a} = \sum_i \alpha'_i \mathbf{x}_i$. 式 (7) 可以简化为与式 (4) 相似的形式

$$\max F = \sum_i \alpha'_i (\mathbf{x}_i, \mathbf{x}_i) - \sum_i \sum_j \alpha'_i \alpha'_j (\mathbf{x}_i, \mathbf{x}_j) \quad (8)$$

这里我们使用高斯核函数, 其定义为

$$K(\mathbf{x}, \mathbf{z}) = \exp\left(\frac{-\|\mathbf{x} - \mathbf{z}\|^2}{\delta^2}\right) \quad (9)$$

对于目标区域的测试数据 \mathbf{z} 来说, 满足

$$\text{SVDD}(\mathbf{z}) = K(\mathbf{z}, \mathbf{z}) - 2 \sum_i \alpha_i k(\mathbf{x}_i, \mathbf{z}) + \sum_{i,j} \alpha_i \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) \leq R^2$$

对于非目标区域的测试数据 \mathbf{z} 来说, 满足

$$\text{SVDD}(\mathbf{z}) = K(\mathbf{z}, \mathbf{z}) - 2 \sum_i \alpha_i k(\mathbf{x}_i, \mathbf{z}) + \sum_{i,j} \alpha_i \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) > R^2$$

则测试数据 \mathbf{z} 属于目标区域的模糊置信度描述为

$$\text{confidence}(\mathbf{z}) = \frac{\left(1 - 2 \sum_i \alpha_i k(\mathbf{x}_i, \mathbf{z}) + \sum_{i,j} \alpha_i \alpha_j K(\mathbf{x}_i, \mathbf{x}_j)\right)}{R^2} \quad (10)$$

根据上面的公式, 就可以完成图像空间到模糊置信度空间的转换. 显然测试数据 \mathbf{z} 属于目标区域的模糊置信度 $\text{confidence}(\mathbf{z}) \leq 1$, 而属于背景区域的模糊置信度很大部分都大于 1. 这里 R 为目标区域数据分布描述的超球体半径.

1.2 区域能量进化模型

经典的区域能量进化模型包括基于边缘和区域的两类, 前者充分利用图像边缘的梯度信息, 这种方法利用图像的局部信息, 往往不易得到全局最佳结果; 后者充分利用全局的图像分布统计信息, 即使在复杂情况下, 仍然可以获得全局最优结果, 因而得到

广泛关注. 基于区域描述的能量模型主要包括两项: 内部能量约束其分割对象区域特征的一致性, 外部能量约束内外区域之间的差异性. 定义图像平面中基于某一置信度门限 Th 的一个划分 C , 它将图像平面 Ω 分成目标区域 (包含种子点的最大连通分割区域) 和剩余的背景区域两部分, 经典的能量函数形式为

$$F(Th, C) = \lambda_1 \int_{\text{inside}} |u_0(x, y) - c_1|^2 dx dy + \lambda_2 \int_{\text{outside}} |u_0(x, y) - c_2|^2 dx dy \quad (11)$$

其中, $\lambda_1 \geq 0, \lambda_2 \geq 0$ 为固定加权参数, 而 c_1, c_2 分别为目标区域与背景区域的平均密度, 于是通常的区域能量函数表示为

$$E(Th, C) = E_{\text{inside}}(C) + E_{\text{outside}}(C) \quad (12)$$

其中, C 为基于门限 Th 的一个区域划分, 其最优 Th 划分 C 满足

$$\tilde{C} = \arg \min_{Th} E(C) \quad (13)$$

通过式 (11) 和 (12) 可以看出, 基于区域的内外能量项对于分割性能影响最大, 而经典的基于区域的能量模型用内外区域的特征方差定义其能量函数, 对于内外区域特征一致性较好的分割问题可以得到准确的分割结果, 而对于内外区域一致性差的复杂目标与背景的分割问题, 算法的准确性与稳定性将急剧下降. 为解决此问题, 本文将基于目标模糊置信度描述引入区域能量表示模型中, 得到新定义的目标区域内部能量表示

$$E_{\text{inside}}(C) = \left| \sum_{i=1}^M \text{confidence}(\mathbf{x}_i) \right| \quad (14)$$

其中, $\mathbf{x}_i, i = 1, 2, \dots, M$ 为基于 Th 划分 C 的目标区域内部点集. 按照同样的方式定义目标区域外部能量函数

$$E_{\text{outside}}(C) = \left| \sum_{k=1}^N \frac{1}{\text{confidence}(\mathbf{x}_k)} \right| \quad (15)$$

其中, $\mathbf{x}_k, k = 1, 2, \dots, N$ 为基于 Th 划分 C 的背景区域的点集. 在理想的情况下, 当曲线进化到真实的分割对象边界时 E_{outside} 与 E_{inside} 同时达到最小值.

1.3 系统及其算法描述

基于目标模糊置信度描述驱动的区域能量进化增长图像分割算法的主要思想是: 1) 利用分割目标

的支持向量数据域描述将待分割图像转化为相对于分割目标的模糊置信度表示, 由于 SVDD 优良的数据分布描述特性, 即使在复杂的环境下仍然可以得到稳定的目标模糊置信度表示; 2) 利用区域增长算法得到分割结果并建立分割区域内外能量函数; 3) 不断更新区域增长门限, 只要内外区域特征满足可分性, 就可以利用该模型得到最佳的分割目标边缘, 即通过对新的能量函数的动态优化可以在复杂环境下逼近目标的真实轮廓. 其系统原理框图如图 1 所示, 基本步骤描述如下:

步骤 1. 利用分割目标的支持向量数据域描述将待分割图像转化为相对于分割目标的模糊置信度表示;

步骤 2. 设置区域增长的种子点, 设置初始模糊置信度门限;

步骤 3. 利用当前区域增长门限得到分割结果, 并利用式 (11) 和 (12) 计算分割区域内外能量函数;

步骤 4. 更新区域增长门限;

步骤 5. 重复步骤 3, 直到寻找到最小能量模型的分割结果.

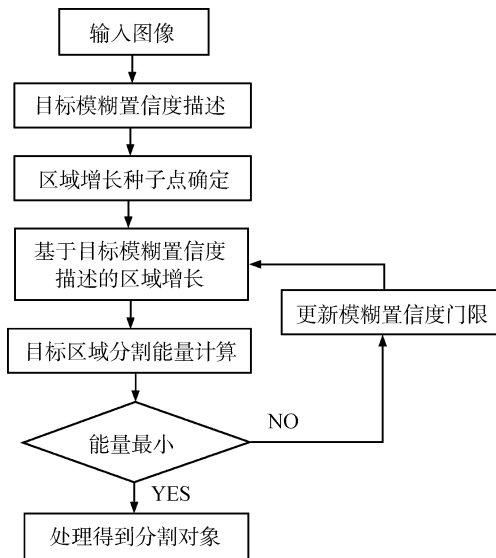


图 1 基于目标模糊置信度描述驱动的区域能量进化增长图像分割算法框图

Fig. 1 Flow chart of region energy evolution image segmentation based on fuzzy object confidence description

2 实验结果

本文分别利用灰度图像和两类纹理图像验证算法的性能. 图 2 针对合成灰度图像进行处理, 图 3 为实际医学脑肿瘤切片图像, 灰度图像直接采用归一化平均灰度值作为输入特征. 因为目标与背景灰度存在一定差别, 且背景与目标区域具有较好的一致性, 经典区域增长、经典主动轮廓以及基于目标模糊

置信度描述驱动的区域能量进化增长算法都能正确分割目标区域. 图 4 针对单一纹理图像进行分割处理, 经典区域增长、经典主动轮廓以及基于目标模糊

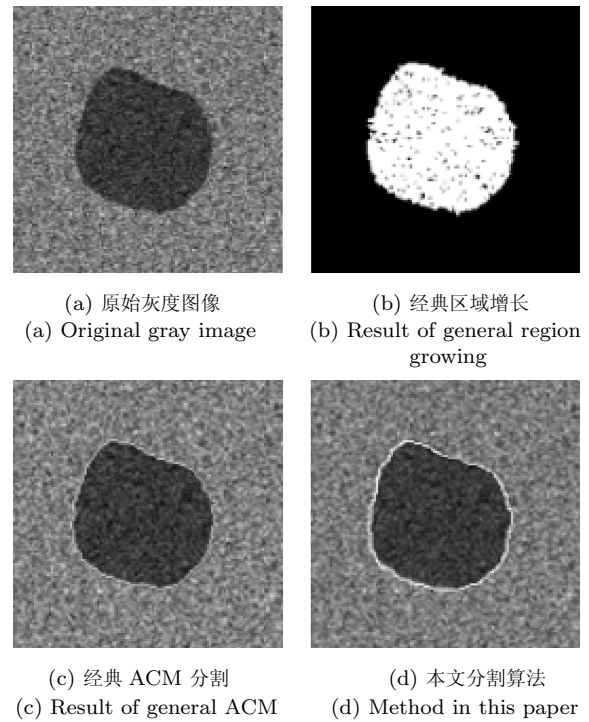


图 2 合成灰度图像分割结果对比

Fig. 2 Compared results with manmade image




图 3 医学肿瘤图像分割结果

Fig. 3 Segmentation results with medical tumor image

置信度描述驱动的区域能量进化增长算法都能够分割出目标区域, 而后者分割结果更为准确. 图 5 针对多纹理图像进行处理, 因为背景与目标区域一致性较差, 经典区域增长和主动轮廓模型不能得到正确的分割结果, 而基于目标模糊置信度描述驱动的区域能量进化增长算法仍然可以得到准确的分割结果. 这里采用 3 尺度 6 方向 Gabor 分解后的能量均值与方差作为纹理特征 (窗口大小为 9).

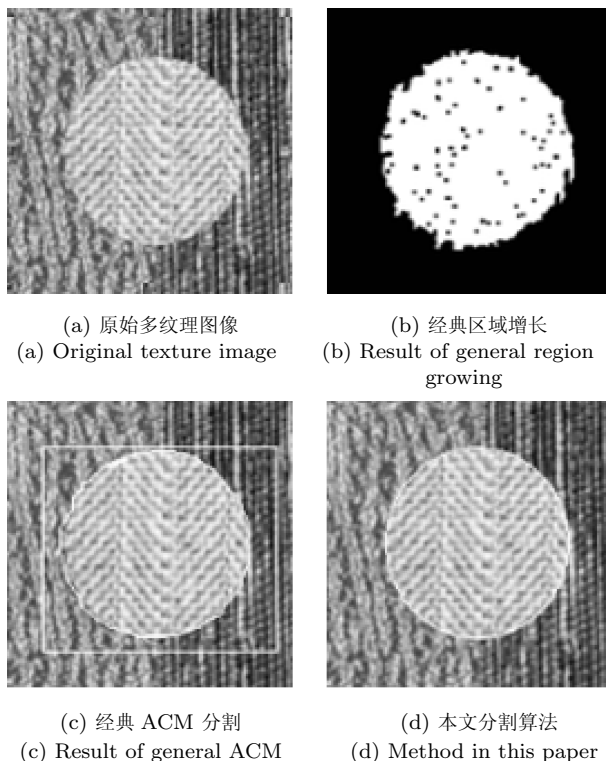


图 4 单一纹理图像分割结果对比

Fig. 4 Compared results with simple texture image

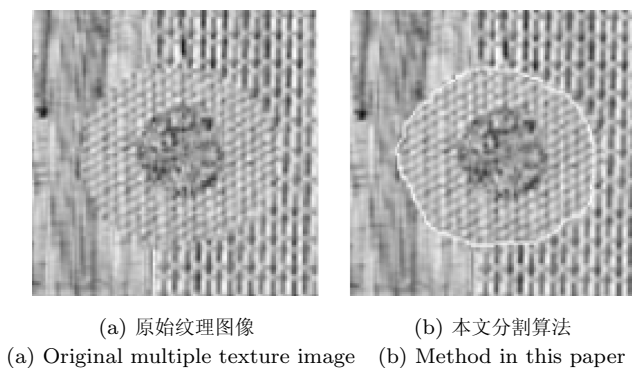


图 5 多纹理图像分割结果

Fig. 5 Segmentation results with multiple texture image

表 1 给出了四种不同方法的运行时间和分割准确度对比, 对比结果表明本文提出的方法相对于经典主动轮廓方法具有更快的速度与更高的稳定性,

其根本原因在于本文提出的方法是用区域并行处理代替经典主动轮廓模型中基于像素的处理. 尽管经典区域增长在目标与背景一致性较好时运行速度较快, 但是在复杂环境下往往不能得到正确的分割结果, 缺乏稳定性. 需要说明的是本文中的初始门限, 我们选择种子点对应的模糊置信度作为目标区域的初始门限, 门限步长变化的大小对于分割精度和速度都有一定程度的影响. 我们实验选取的步长为 0.01. 这里分割准确度采用实际正确分割结果与理想分割结果的平均比例来度量.

表 1 不同方法运行性能对比

Table 1 Performance compared with different methods

方法/速度	时间 (s) (图 2)	时间 (s) (图 3)	时间 (s) (图 4)	时间 (s) (图 5)
经典区域增长	96	136	132	无
经典主动轮廓	313	292	260	无
本文方法	34	47	41	49

方法/准确度 (%)	准确度 (图 2)	准确度 (图 3)	准确度 (图 4)	准确度 (图 5)
经典区域增长	99.8	97.6	97.3	无
经典主动轮廓	99.8	98.2	98.0	无
本文方法	99.8	98.5	98.0	97.5

3 结论

本文提出支持向量数据分布域描述的目标模糊置信度描述思路, 并利用目标模糊置信度对于划分的区域构造了一种新的图像能量表示方法, 该思路吸收了 Mumford-Shah 主动轮廓中利用内外区域的全部信息, 可得到全局最优分割结果的优点; 同时克服了经典区域划分的内外区域能量定义在复杂目标与背景分布情况下的不足, 使得本文提出的算法具有更高的稳定性和更加广泛的适用范围, 特别是对目标灰度分布不均或存在多纹理的目标也可以得到较好的分割结果. 需要指出的是: 对于某一类图像, 基于支持向量数据分布域描述的目标模糊置信度描述模型只需要训练一次即可. 分割时的计算量主要在于区域划分过程中能量函数的计算, 进行图像分割时, 首先利用分割目标的支持向量数据域描述将待分割图像转化为相对于分割目标的模糊置信度表示, 由于 SVDD 优良的数据分布描述特性, 即使在复杂的环境下仍然可以得到稳定的模糊置信度表示; 然后利用区域增长算法得到分割结果并建立分割区域内能量函数; 最后不断更新区域增长门限, 通过对新的能量函数的动态优化可以在复杂环境下逼近目标的真实轮廓. 本文提出的方法为解决复杂环境下的图像分割问题提供了新的思路, 有望在医学

图像分析和运动目标分割中得到应用.

References

- 1 Tang Ming, Ma Song-De. Non-parametric region competition: a new scheme for image segmentation. *Acta Automatica Sinica*, 2001, **27**(6): 737–743
(唐明, 马颂德. 非参数化区域竞争方法: 一种新的图像分割框架. 自动化学报, 2001, **27**(6): 737–743)
- 2 Chris C K, Udupa J K, Saha P K, Zhu G Y. Iterative relative fuzzy connectedness for multiple objects with multiple seeds. *Computer Vision and Image Understanding*, 2007, **107**(3): 160–182
- 3 Udupa J K, Saha P K, Lotufo R A. Relative fuzzy connectedness and object definition: theory, algorithms, and application in image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, **24**(11): 1485–1500
- 4 Lee S, Crawford M M. Unsupervised multistage image classification using hierarchical clustering with a Bayesian similarity measure. *IEEE Transactions on Image Processing*, 2005, **14**(3): 312–320
- 5 Stewart R D, Fermin I, Opper M. Region growing with pulse-coupled neural networks: an alternative to seeded region growing. *IEEE Transactions on Neural Networks*, 2002, **13**(6): 1557–1562
- 6 Greenspan H, Ruf A, Goldberger J. Constrained Gaussian mixture model framework for automatic segmentation of MR brain images. *IEEE Transactions on Medical Imaging*, 2006, **25**(9): 1233–1245
- 7 Raquel V C, Veronical M B, Oscar Y S. Coupling of radial-basis network and active contour model for multispectral brain MRI segmentation. *IEEE Transactions on Biomedical Engineering*, 2004, **51**(3): 459–470
- 8 Bresson X, Pierre V, Thiran J P. Multiscale active contours. *International Journal of Computer Vision M*, 2006, **70**(3): 197–211
- 9 Jacob M, Blu T, Unser M. Efficient energies and algorithms for parametric snake. *IEEE Transactions on Image Processing*, 2004, **13**(9): 1231–1244
- 10 Tax D M J, Duin R P W. Support vector domain description. *Pattern Recognition Letters*, 1999, **20**(11-13): 1191–1199



胡正平 燕山大学信息科学与工程学院副教授, 博士. 主要研究方向为统计学习理论, 医学图像处理和模式识别. 本文通信作者. E-mail: tnpochw@263.net
(**HU Zheng-Ping** Associate professor at Colledge of Information Science and Engineering, Yanshan University. His research interest covers statistical learning, medical image processing, and pattern recognition. Corresponding author of this paper.)



谭 营 北京大学视觉与听觉信息处理国家重点实验室教授. 主要研究方向为智能计算, 数字信号处理和模式识别.
(**TAN Ying** Professor, Ph. D. at National Laboratory on Machine Perception, Peking University. His research interest covers intelligent computing, digital signal processing, and pattern recognition.)