基于多通道信息融合的激光扫描共聚焦显微镜图像分割*

何 磊[1], 张 素[1], 肖昌炎[2], 陈亚珠[1]
(1. 上海交通大学 生物医学工程系, 上海 200030; 2. 湖南大学 电气与信息工程学院, 湖南 长沙 410082)

摘 要: 针对 LSCM 多通道成像的特点, 提出一种将可见光通道图像统计信息作为先验知识的通道信息融合分割荧光通道图像的方法。该方法在 LSCM 图像上进行测试, 并与 Chan-Vese 方法进行比较。

关键词: LSCM; 荧光通道; 可见光通道; 信息融合; C-V 模型
中图法分类号: TP334 **文献标识码**: A **文章编号**: 1001-3695(2006)12-0316-03

Segmentation of LSCM Images Based on Multi-channel Information Fusion

HE Lei[1], ZHANG Su[1], XIAO Chang-yan[2], CHEN Ya-zhu[1]
(1. Dept. of Biomedical Engineering, Shanghai Jiaotong University, Shanghai 200030, China; 2. College of Electric & Information, Hunan University, Changsha Hunan 410082, China)

Abstract: A new and integrated approach is proposed to segment images in the fluorescent light channel of LSCM, which have rather low SNR and can not provide sufficiently high intensity gradient at the boundary. Rather than relying on information of the image in the fluorescent light channel alone, statistical information of corresponding image in the visible light channel is also utilized as priori knowledge. The approach is tested on LSCM images and experimental results are compared with results of C-V model.

Key words: LSCM; Fluorescent Light Channel; Visible Light Channel; Information Fusion; C-V Model

激光扫描共聚焦显微镜(Laser Scanning Confocal Microscope, LSCM)是近代最先进的细胞生物医学分析仪器之一。它在荧光显微镜成像的基础上加装了激光扫描装置, 使用紫外线或可见光激发荧光探针, 利用计算机进行图像处理, 不仅可观察固定的细胞、组织切片, 还可对活细胞的结构以及分子、离子进行实时动态观察和检测。目前, 激光扫描共聚焦显微技术已用于细胞形态定位、立体结构重组、动态变化过程等研究, 并提供定量荧光测定、定量图像分析等实用研究手段, 在形态学、生理学、免疫学、遗传学等分子细胞生物学领域得到了广泛应用。

相比传统的光学显微镜, LSCM 的优势明显。传统的光学显微镜使用的是场光源, 标本上每一点的图像均会受到邻近点的衍射光或散射光的干扰。LSCM 采用激光作为光源, 激光束经照明针孔, 由分光镜反射至物镜并聚焦于样品上, 对标本内焦平面上的每一点进行扫描; 然后, 激发出的荧光经原入射光路反向回到分光镜, 通过探测针孔时先聚焦; 聚焦后的光被光电倍增管(PMT)探测收集, 并将信号输送到计算机, 在显示屏上形成图像。在此过程中, 只有焦平面上的光能穿过探测针共振, 焦平面上的点同时聚焦于照明针孔, 焦平面以外的点不会在探测针孔处成像。这样避免了传统光学显微镜由于光散射造成的图像信噪比降低、图像清晰度和分辨率不高的缺点。

LSCM(图 1)主要由光学显微镜、共聚焦装置和计算机系统三部分组成。LSCM 载物台上配有一个微量步进马达, 当载物台沿光轴方向移动时即可完成一层层图像的采集和显示, 即光学切割。借助计算机软件技术可以构建扫描样本的三维图像, 因而这不仅可以观察单一层面清晰的荧光图像, 还可以直接观察样本的三维结构。

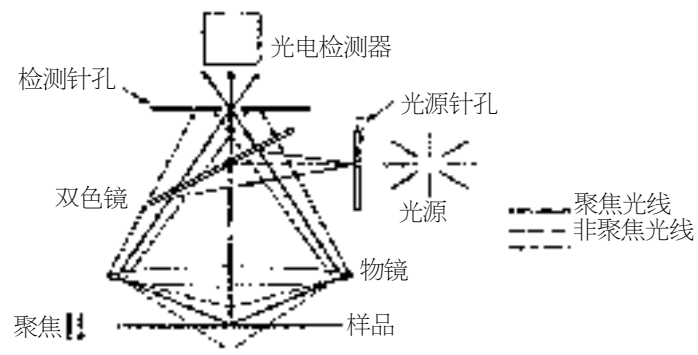

图 1 LSCM 光学原理图

试验采用上海交通大学传热与传质实验室提供的 LSCM 数据, 目的是研究纳米靶分子药物在微小血管中的输送。可见光通道提供了丰富的微小血管的结构信息, 而荧光通道提供了血管中药物颗粒分布的信息。在荧光通道中正确提取血管结构是研究药物动态扩散的先决条件。

1 模型

1.1 水平集方法回顾

Osher 和 Sethian 提出的水平集方法可以自动适应拓扑结构变化, 对于曲线演化过程中可能产生的尖点、曲线的分裂和融合等复杂情况, 均可以有效处理。由于其出色的稳定性和拓扑无关性, 水平集方法在图像处理、计算机视觉等领域得到了

收稿日期: 2005-06-28; 修返日期: 2006-01-23
基金项目: 国家重点基础研究发展计划项目(2003CB716103); 教育部图像处理及智能控制重点实验室开放基金项目(JKLJ0306)

广泛的应用。水平集方法是一种跟踪轮廓和曲面演化的数值方法。演化的曲面表示为更高维度方程(水平集方程)的零水平集。水平集方程在微分方程的控制下演化。演化方程为

$$\frac{\partial\phi}{\partial t} = |\nabla\phi| V,\ \phi(0,x,y) = \phi_0(x,y) \tag{1}$$

其中　为水平集方程, $V(k)$ 为速度方程。

如果将水平集方程的曲率作为速度函数,得到如下特例:

$$V(k) = \mathrm{div}\left(\frac{\nabla\phi}{|\nabla\phi|}\right) \tag{2}$$

得到平均曲率流模型:

$$\begin{cases} \dfrac{\partial\phi}{\partial t} = |\nabla\phi|\,\mathrm{div}\left(\dfrac{\nabla\phi}{|\nabla\phi|}\right) \\ \phi(0,x) = \phi_0(x),\ t\in[0,\infty),\ x\in IR^N \end{cases} \tag{3}$$

著名的几何主动轮廓模型是在平均曲率流模型基础上提出的:

$$\begin{cases} \dfrac{\partial\phi}{\partial t} = g(|\nabla u_0|)\,|\nabla\phi|\left(\mathrm{div}\left(\dfrac{\nabla\phi}{|\nabla\phi|}\right) + v\right),\ \text{in}[0,\infty)\ IR^2 \\ \phi(0,x) = \phi_0(x),\ \text{in}\ IR^2 \end{cases} \tag{4}$$

其中 $g(|\nabla u_0|) = \dfrac{1}{1+|\nabla G_\sigma(x,y)\times u_0(x,y)|^2}$ 为边敏函数, v 为一正常数, $_0$ 为初始水平集方程。$g(|\ u_0|)$ 为调节零水平集曲线的演化速度。当曲线到达边界时,演化停止, g 消失。常数 v 为一校正项,保证 $\left(\mathrm{div}\left(\dfrac{\nabla\phi}{|\nabla\phi|}\right) + v\right)$ 为正。v 可描述为曲线内部区域的收缩子。

几何主动轮廓模型依靠边敏函数 g 停止曲线的演化,这样模型只能检测出边界由灰度定义的物体。对于边界模糊的图像,如 LSCM 荧光通道中的成像,其分割结果不理想。

1.2　全局信息的方法

可以考虑使用图像的全局信息,而不仅仅是边界信息构造速度函数。在此使用通用的水平集方程:

$$\frac{\partial\phi}{\partial t} = -\alpha A(x)\times\nabla\phi - \beta P(x)\,|\nabla\phi| + \gamma Z(x)\,\kappa|\nabla\phi| \tag{5}$$

其中 $\kappa = \mathrm{div}\left(\dfrac{\nabla\phi}{|\nabla\phi|}\right)$ 为曲率, $A(x)$ 为平流速度图, α 为平流尺度常数; $P(x)$ 为演化速度图, β 为演化尺度常数; $Z(x)$ 为曲率空间修改图, γ 为曲率尺度常数。

在此不考虑平流场和曲率空间的变化,因此式(5)中 $A(x) = 0$, $Z(x) = 1$。此时,通用公式简化为

$$\frac{\partial\phi}{\partial t} = -\beta P(x)\,|\nabla\phi| + \gamma\kappa|\nabla\phi| \tag{6}$$

假设图像 $u_0(x, y)$ 仅由待检测的物体和背景两部分组成,则得到最小分区模型。物体的平均值为 c_1,背景的平均值为 c_2。我们希望演化曲线在物体内部时模型扩张,而在物体外部时模型收缩。故将演化速度方程定义为

$$P(x) = v + \lambda_1(u_0 - c_1)^2 - \lambda_2(u_0 - c_2)^2 \tag{7}$$

联立方程式(6)、式(7),可得到水平集方程:

$$\frac{\partial\phi}{\partial t} = -\beta[v + \lambda_1(u_0 - c_1)^2 - \lambda_2(u_0 - c_2)^2]\,|\nabla\phi| + \gamma\kappa|\nabla\phi| =$$

$$|\nabla\phi|\left\{v.\,\mathrm{div}\left(\frac{\nabla\phi}{|\nabla\phi|}\right) - \beta[v + \lambda_1(u_0 - c_1)^2 - \lambda_2(u_0 - c_2)^2]\right\} \tag{8}$$

1.3　Chan-Vese 模型

在 Mumford-Shah 模型的基础上, Chan 等人提出了一种简化的模型,即 C-V 模型。该模型的速度函数不再依赖图像梯度,而是基于目标区域的灰度信息。它实际上是一种最小分区问题的数值解法,同时适用于梯度有意义和无意义的轮廓检测,比如边缘很平滑或不连续的图像分割。另外,该方法的速度函数定义于所有水平集,因此,可以检测出带有空洞的目标内部区域。在此首先对该模型进行回顾。C-V 模型有以下形式:

$$F(c_1, c_2, C) = \mu\,\mathrm{Length}(C) + \lambda_1\int_{\mathrm{inside}(C)}|u_0(x,y) - c_1|^2\,\mathrm{d}x\mathrm{d}y + \lambda_2\int_{\mathrm{outside}(C)}|u_0(x,y) - c_2|^2\,\mathrm{d}x\mathrm{d}y \tag{9}$$

其中 c_1 和 c_2 分别为曲线内部和外部灰度的均值。参数 $\mu > 0$ 和 λ_1, $\lambda_2 > 0$ 分别为各个能量项的权重系数。

最终分割轮廓线的位置由最优化式(9)得到,分割问题变为以下最小化问题:

$$\inf_{c_1, c_2, C} F(c_1, c_2, C) \tag{10}$$

在水平集框架下,用水平集方程　代替未知的演化轮廓 C。假设　为 Lipschitz 连续。

定义 Heaviside 函数和 Dirac 量度 δ_0

$$H(z) = \begin{matrix} 1 & z\geq 0 \\ 0 & z<0 \end{matrix},\quad \delta_0(z) = \frac{\mathrm{d}}{\mathrm{d}z}H(z) \tag{11}$$

能量方程可被重写为

$$F(c_1, c_2, C) = \mu\int_\Omega\delta_0(\ (x,y))\,|\nabla\phi(x,y)| + \lambda_1\int_\Omega|u_0(x,y) - c_1|^2 H(\ (x,y))\,\mathrm{d}x\mathrm{d}y + \lambda_2\int_\Omega|u_0(x,y) - c_2|^2(1 - H(\phi(x,y)))\,\mathrm{d}x\mathrm{d}y \tag{12}$$

以水平集函数　表达的 Euler-Lagrange 方程如下:

$$\begin{cases} c_1(\phi) = \dfrac{\int_\Omega u_0 H(\phi)\,\mathrm{d}x}{\int_\Omega H(\phi)\,\mathrm{d}x}\ \left(\int_\Omega H(\phi) > 0\right) \\ c_2(\phi) = \dfrac{\int_\Omega u_0(1 - H(\phi))\,\mathrm{d}x}{\int_\Omega(1 - H(\phi))\,\mathrm{d}x}\ \left(\int_\Omega(1 - H(\phi)) > 0\right) \\ \dfrac{\partial\phi}{\partial t} = \delta_\varepsilon(\phi)\left[\mu\,\mathrm{div}\left(\dfrac{\nabla\phi}{|\nabla\phi|}\right) - v - \lambda_1(u_0 - c_1)^2 - \lambda_2(u_0 - c_2)^2\right] \\ \text{边界条件}: \dfrac{\delta_\varepsilon(\phi)}{|\nabla\phi|}\dfrac{\partial\phi}{\partial\vec{n}} = 0 \end{cases} \tag{13}$$

其中 $H_\varepsilon(z) = \dfrac{1}{2}\left(1 + \dfrac{2}{\pi}\arctan\left(\dfrac{z}{\varepsilon}\right)\right)$, $\delta_\varepsilon(z) = H'_\varepsilon(z) = \dfrac{1}{\pi}\dfrac{\varepsilon}{\varepsilon^2 + z^2}$。

比较式(8)和式(12),其不同点在于:式(8)中的 Dirac 方程 $\delta_\varepsilon(\ )$ 被 $|\nabla\phi|$ 替代。$\delta_\varepsilon(\ )$ 有狭窄的定义范围,从而限制了 C-V 模型的全局表现。而 $|\nabla\phi|$ 包含了图像的全局信息并突破了定义域的限制。改进的 C-V 模型有更好的全局性能。

C-V 模型可以自动检测没有灰度的轮廓。该模型可以方便地推广到多通道或彩色图像中。

设 $u_{0,i}$ 为图像第 i 个通道, $i = 1, \cdots, N$, Ω 为定义域, C 为演化曲线。每一个通道分量通常包含同一目标不同波长或模态的成像。很容易得到向量情况下的最小分区能量为

$$F(\vec{c}^{\,+}, \vec{c}^{\,-},\ ) = \mu\,\mathrm{Length}(C) + \int_{\mathrm{inside}(C)}\frac{1}{N}\sum_{i=1}^{N}\lambda_i^+\ |u_{0,i}(x,y) - c_i^+|^2\,\mathrm{d}x\mathrm{d}y + \int_{\mathrm{outside}(C)}\frac{1}{N}\sum_{i=1}^{N}\lambda_i^-\ |u_{0,i}(x,y) - c_i^-|^2\,\mathrm{d}x\mathrm{d}y \tag{14}$$

其中 $\vec{c}^{\,+} = (c_1^+, \cdots, c_N^+)$ 和 $\vec{c}^{\,-} = (c_1^-, \cdots, c_N^-)$ 分别为 C 内部和外部的均值向量。

水平集形式为

$$F(\vec{c}^{\,+}, \vec{c}^{\,-}, \phi) = \mu\int_\Omega\delta_0(\ \phi(x,y)\ |\ \ \phi(x,y)\ |\mathrm{d}x\mathrm{d}y + \int_\Omega\frac{1}{N}\sum_{i=1}^{N}\lambda_i^+\ |u_{0,i}(x,y) - c_i^+|^2 H(\phi(x,y))\,\mathrm{d}x\mathrm{d}y + \int_\Omega\frac{1}{N}\sum_{i=1}^{N}\lambda_i^-\ |u_{0,i}(x,y) - c_i^-|^2(1 - H(\phi(x,y)))\,\mathrm{d}x\mathrm{d}y \tag{15}$$

的 Euler-Lagrange 方程为

$$\begin{cases} c_i^+ = \dfrac{\int_\Omega u_{0,i}(x,y)\,H(\ (x,y))\,\mathrm{d}x\mathrm{d}y}{\int_\Omega H(\ (x,y))\,\mathrm{d}x\mathrm{d}y} \\ c_i^- = \dfrac{\int_\Omega u_{0,i}(x,y)\,(1-H(\ (x,y)))\,\mathrm{d}x\mathrm{d}y}{\int_\Omega (1-H(\ (x,y)))\,\mathrm{d}x\mathrm{d}y} \\ \dfrac{\partial\phi}{\partial t} = \delta_\varepsilon[\ \mu\mathrm{div}(\dfrac{\nabla\phi}{|\nabla\phi|}) - \dfrac{1}{N}\sum_{i=1}^{N}\lambda_i^+(u_{0,i}-c_i^+)^2 + \\ \dfrac{1}{N}\sum_{i=1}^{N}\lambda_i^-\ (u_{0,i}-c_i^-)^2] \\ \text{With the Boundary Condition}\ \dfrac{\delta_\varepsilon(\phi)}{|\nabla\phi|}\dfrac{\partial\phi}{\partial\vec{n}} = 0 \end{cases} \tag{16}$$

式中 $H_\varepsilon(z) = \frac{1}{2}(1+\frac{2}{\pi}\arctan(\frac{z}{\varepsilon}))$, $\delta_\varepsilon(z) = H'_\varepsilon(z)$。

1.4 多通道信息融合的方法

在实验中发现,用 C-V 模型分割 LSCM 可见光通道的图像可以得到良好的结果,而分割荧光通道图像时,结果的可信度有所下降。我们提出的方法基于以下的观察:可见光通道和荧光通道提供了同一物体不同模态的图像。荧光通道描绘了血管中药物颗粒运动的情况,可见光通道的图像包含了更多的细微结构信息。药物颗粒在充分运动的情况下,可以运动到血管中的各个位置。因此可见光通道的图像可以作为荧光通道图像分割的可信参考。

通过观察灰度密度直方图可以发现,可见光通道中图像的像素密度遵循高斯分布。令 u_0 为荧光通道中待分割的图像,而 u'_0 为可见光通道中相应的图像。假设 P_0 和 P_b 分别为 u'_0 各个像素点的物体或背景的后验概率。

最大化以下概率能量方程:

$$E\ (t) = \int_{\text{inside}} P_0\,\mathrm{d}x\mathrm{d}y + \int_{\text{outide}} P_b\,\mathrm{d}x\mathrm{d}y \tag{17}$$

曲线 的演化方程可以通过下式给出:

$$\frac{\partial\phi}{\partial t} = (P_0 - P_b)\ \times\vec{n} \tag{18}$$

其中 $\vec{n}$ 为 ϕ 的单位法向量,并且 $-1 \le (P_0 - P_b) \le 1$。

该信息可以用统计力 F_s 描述为

$$F_s = P_0 - P_b \tag{19}$$

根据式(7),速度场信息可用 F_v 描述:

$$F_v = \lambda_1(u_0 - c_1)^2 - \lambda_2(u_0 - c_2)^2 \tag{20}$$

其中 c_1, c_2 分别为曲线内部和外部的灰度均值。

结合参考图的统计信息和原图的速度场信息,式(18) 可以修改为

$$\frac{\partial\phi}{\partial t} = (k + w_s \times F_s + w_v \times F_v)\ \times\vec{n} \tag{21}$$

其中 w_s, w_v 分别为相应力的权值。

2 实验结果

试验中采用的数据集是德国蔡司公司 LSM510 获取的小鼠背部血管网。空间分辨率为 477nm, 数据大小为 512 × 512 ×32。

分割结果如图 2 ~图 5 所示。图 2 和图 3 是分割各个 LSCM 的每个通道中的图像。图 2 是荧光通道的图像,而图 3 是可见光通道的图像。图 2(a) 和图 3(a) 是原始 LSCM 图像,图 2(b) 和图 3(b) 是使用 C-V 模型的分割结果。在图 2 中可以发现,很多信息丢失了。

图 4 是使用基于向量的 C-V 模型的分割结果。各个通道的权值可以调节从而获得不同的分割结果。图 4(a) 中两个通道权重相同而,图 4(b) 中荧光通道和可见光通道的权重比为 3 :1。

(a) (b)

图 2 C-V 方法分割荧光通道图像

(a) (b)

图 3 C-V 方法分割可见光通道图像

图 5 是用通道信息融合的方法所得到的分割结果。

(a) (b)

图 4 向量图 C-V 方法分割荧光通道图像

图 5 通道信息融合的方法分割荧光通道图像

3 结论

本文提出了一个新的分割 LSCM 荧光通道图像的方法,该方法结合了图像速度场信息和可见光通道图像的统计信息,可看作多通道信息融合的分割方法。可见光通道提供的微小血管的结构信息可以作为荧光通道缺少的信息的补充和校正。这种信息补偿的方法带来了更好的分割结果。该方法被应用于 LSCM 图像,将分割结果和 C-V 模型的分割结果相比较可以发现,本方法更易操作并提供了更好的药物运动情况的描绘。将此方法扩展到三维数据集,遇到的问题主要在于以下两方面:①分辨率为 512 ×512 ×32 的三通道体数据大小达到 24MB,考虑时变因素时,数据量甚至还要大大增加。本方法有时无法满足实时可视化的要求。②空间分辨率至少比 X 方向分辨率低 2 ~4 倍,这导致了不规则网格。而插值有可能破坏血管的细微结构。今后的工作将争取在这两方面改进。

参考文献:

[1] ony F Chan, Luminita A Vese. Active Contours without Edges[J]. Image Processing, 2001, 10(2): 266-277.

[2] Tony F Chan, B Yezrielev, Luminita A Vese. Active Contours without Edges for Vector-Valued Images[J]. Image Representation, 2000, 11: 130-141.

[3] D Mumford, J Shah. Optimal Approximation by Piecewise Smooth Functions and Associated Variational Problems[J]. Comm. Pure Appl., 1989, 42(5): 577-685.

[4] S Osher, J A Sethian. Fonts Propagating with Smooth Curvature-Dependent Speed: Algorithms Based on Hamilton-Jacobi Formulation[J]. Journal of Computational Physics, 1998, 79(1): 12-49.

[5] V Caselles, F Catté, T Coll, *et al*. A Geometric Model for Active Contours in Image Processing[J]. Numerische Mathematik, 1993, 66(1): 1-31.

[6] Luis Ibáñez, Will Schroeder, Lydia Ng, *et al*. The ITK Software Guide[M]. Kitware Inc., 2003. 337-367.

[7] Albert C S Chung, J Alison Noble, Paul Summers. Fusing Speed and Phase Information for Vascular Segmentation of Phase Contrast MR Angiograms[J]. Medical Image Analysis, 2002, 6: 109-128.

[8] 杨新. 图像偏微分方程的原理与应用(第 1 版)[M]. 上海: 上海交通大学出版社, 2003.

(下转第 325 页)

(1) 使用聚类融合的 SVM 分类器。直接将融合的向量作为带有第一级多项式核的 SVM 分类器的输入, 与作为更高级多项式核的 SVM 分类器的输入, 其结果相差不大。所以本文选择前者。40 幅海滩图像和 20 幅城市图像被选择作为给定数据库的分类样本, 使用这些样本在 SVM 分类器中训练数据集。数据库中剩余的 707 幅图像被用作测试。表 1 中的结果显示, 当几种低层特征进行融合时, 分类的效率会提高; 三种一起融合时, 达到最佳效率为 89%。

(2) 使用 BP 融合的 K 近邻分类器。此种方法中, 当两幅图像属于同一类时, 它们之间的距离设为 0; 反之, 设为 1。由于网络的预期响应是独立于每对图像的排列顺序的, 所以为了改善训练, 每对图像均会建立正向和反向两个训练样本。因此, 可以建立 2 800 个训练样本来训练 BP 网络。剩余的 707 幅图像用于评价 BP 融合。将网络中所有可能的图像对表示出来, 一个如第 2 节描述的对称距离矩阵就建立了, 并且可被用于 K 近邻分类器。

(3) Falcon-ART 神经网络。将上面 BP 融合的同样的 60 幅图像用于 Fuzzy-ART 分类器和 Falcon-ART 模糊神经网络的训练集, 同时利用网络中随机输入的融合描述符来训练网络。在训练集中匹配成功率可以达到 95.8%, 在测试集中可以达到 87.7%, 并且 Fuzzy-ART 算法可以建立八个超盒, Falcon-ART 模糊神经网络被训练为 275 个初相。为了让 Fuzzy-ART 算法建立的规则更接近于人类感知, 图像描述符的每一维均被分成三个相同部分, 对应的值是 low, medium, high。由 Fuzzy-ART 算法建立的超盒引出的规则就使用这些值。

使用第 1 节中表达的 EHD 描述符作为分类时提取的特征。每幅图像被分成上、中、下三个子图像部分, 每个边界均被赋上 low, medium, high 这三个定性的值。这样, 我们得到如下的模糊规则:

IF　图像上部分的 0 边界值是 low And 图像上部分的 45 °边界值是 medium And… And 图像下部分的无方向边界值是 high

THEN　这个图像属于海滩类

利用 EHD 描述符, Falcon-ART 建立了五个模糊规则, 详细描述如表 2 所示。

4　结论

实验表明, 使用 MPEG-7 描述符来进行图像分类的三个测试方法都可以成功应用, BP 融合显示出最好的分类结果。然而, 由于使用Falcon-ART的融合可以提供潜在分类机制的语义描述, 因而也是很有用的。未来的工作将会集中于使用更多的 MPEG-7 描述符并应用到更多的分类中。另外, 这些分类策略也可以扩展到预定义对象模型的图像分割中。

表 2　由 Falcon-ART 建立的模糊规则

图像部分	边界类型	规则 1	规则 2	规则 3	规则 4	规则 5
上部	0	M	L	M-L	M-L	L
	45 °	M	L	M-L	M	M
	90 °	M	L	M	M	M
	135 °	H	M	M	M	M
	无方向	M	M	M	M	M
中部	0 °	M	L	M	M	M
	45 °	M	M-L	H	M	H
	90 °	M	M	M	M	H
	135 °	H	M	M-L	H	H
	无方向	H	M	M	H	M
底部	0 °	M	L	L	M	L
	45 °	M	M	H	H	H
	90 °	H	M	M	H	H
	135 °	M	M-L	M	H	M
	无方向	M	M	M-L	H	M
类别		城市风景	海滩风景	城市风景	海滩风景	海滩风景

注: H 表示 high, M 表示 medium, L 表示 low。

参考文献:

[1] 徐杰, 施鹏飞. 基于内容的图像检索技术[J]. 中国图像图形学报, 2003, 8(9): 977-983.

[2] R O Duda, P E Hart. Pattern Classification[M]. New York: John Wiley and Sons, 2001. 97-103.

[3] Vapnik V. Statistical Learning Theory[M]. New York: John Wiley and Sons, 1998. 214-218.

[4] D H Wang, Q Tian, *et al*. News Sports Video Shot Classification with Sports Play Field and Motion Features[C]. IEEE International Conference on Image Processing, Singapore, 2004. 2247-2250.

[5] Manjunath B, Ohm J R, *et al*. Color and Texture Descriptors[J]. IEEE Trans. on Circuits and Systems for Video Technology, 2001, 11: 703-715.

[6] Carpenter G, *et al*. A Neural Network Realization of Fuzzy-ART[R]. Technical Report CAS/CNS-91-021, 1991. 115-120.

[7] Vapnik V. The Nature of Statistical Learning Theory[M]. New York: Springer-Verlag, 1995. 205-221.

作者简介:

王松(1978-), 男, 讲师, 主要研究方向为图形图像、多媒体技术等; 王卫红(1969-), 男, 副教授, 主要研究方向为地理信息系统、网络安全等; 秦绪佳(1968-), 男, 副教授, 研究方向为图形图像、模式识别等。

(上接第 318 页)

[9] 肖昌炎, 赵永明, 张素, 等. 水平集方法中符号距离函数快速重构[J]. 信号处理, 2003, 19(6): 551-555.

[10] 王德军, 唐云, 于洪川, 等. 水平集方法与距离函数[J]. 应用数学和力学, 2003, 24(8): 839-848.

[11] 杨猛, 汪国平, 董士海. 基于 Level Set 方法的曲线演化[J]. 软件学报, 2002, 13(9): 1858-1865.

[12] 朱付平, 田捷, 林瑶, 等. 基于 Level Set 方法的医学图像分割[J]. 软件学报, 2002, 13(9): 1867-1872.

[13] 赵启韬, 苗俊英. 激光共聚焦显微镜在生物医学研究中的应用[J]. 北京生物医学工程, 2003, 22(1): 52-54.

[14] 邢军. 激光扫描共聚焦显微镜及在生物医学中的应用[J]. 仪器评介, 2001, (3): 23-25.

[15] 张旭, 徐维奇. 激光扫描共聚焦显微镜技术的发展及应用[J]. 现代科学仪器, 2001, (2): 21-23.

作者简介:

何磊(1980-), 男, 硕士研究生, 主要研究方向为医学图像处理; 张素(1968-), 女, 副教授, 主要研究方向为医学图像处理; 肖昌炎(1972-), 男, 博士, 主要研究方向为偏微分方程图像处理和计算机辅助手术; 陈亚珠(1936-), 女, 中国工程院院士, 博导, 主要研究方向为物理治疗肿瘤技术研究、肿瘤综合治疗机理研究、光学检测技术。