

自适应水平集方法乳腺超声肿块分割应用*

杨 谊^a, 申 洪^b

(南方医科大学 a. 生物医学工程学院; b. 基础医学院 病理教研室 附属南方医院病理科, 广州 510515)

摘要: 针对超声成像固有的噪声大、伪影斑点多、对比度低等特点,在利用 CV 和 LBF 模型优点的基础上,融合了动态变化制导的全局信息和局部信息,在能量泛函演化过程中,全局信息项和局部信息项的权重系数实时变化调整。实验结果表明,与两种已有模型相比,该方法能够较好地处理灰度非匀质乳腺超声图像的肿块病灶分割问题,分割准确性和病灶边缘细节处理更好,分割速度较快,临床适用性更强。

关键词: 自适应水平集方法; 乳腺超声图像; 肿块分割

中图分类号: TP391.4 **文献标志码:** A **文章编号:** 1001-3695(2013)12-3840-04

doi:10.3969/j.issn.1001-3695.2013.12.085

Application of auto-fitting level set method in lesion segmentation of breast ultrasound images

YANG Yi^a, SHEN Hong^b

(a. School of Biomedical Engineering, b. Dept. of Pathology of Subsidiary Southern Hospital, Pathological Staff Room, School of Basic Medicine, Southern Medical University, Guangzhou 510515, China)

Abstract: Taking ultrasound images properties (high noises, constructed defects and low SNR) into consideration, based on CV model and LBF model, this paper proposed a revised method in which both global and local image information, whose weights varied during the process, were integrated to the direct evolution of level set. Experiment results show that the proposed method behaves better than CV model and LBF model in dealing with lesion segmentation in breast ultrasound images, with higher accuracy, better detail identification, and less time consuming, which make it more applicable for clinical use.

Key words: auto-fitting level set; breast ultrasound image; lesion segmentation

近期公布的统计数据^[1]显示,乳腺癌位列女性发病率最高的恶性肿瘤之首。发达国家乳腺癌新发病例约占女性新发恶性肿瘤的30%,在我国乳腺癌同样是女性最常见的恶性肿瘤,发病率呈逐年上升趋势。但是,无论国内还是国外,尽管乳腺癌的发病率居高不下,死亡率却不断下降,其原因得益于女性乳腺癌筛查和早诊制度的建立,以及综合诊疗水平的提高。乳腺癌的疗效更多地取决于病期,提高早诊率是提高治愈率的关键,例如早期乳腺癌中导管原位癌的治愈率可达到95%以上,并获得更多保留乳房的机会^[2]。乳腺癌普查是提高治愈率行之有效的办法,B超扫描能够鉴别乳腺的囊性与实性病变(表现为形态不规则、内部回声不均匀的低回声肿块),显示肿块内部及周边的血流信号,对观察腋窝淋巴结方面也很有优势,具有无辐射、无侵入、无损伤疼痛、费用低廉、实时等优点,成为首选的普查方法^[2]。

在B超图像中准确定位病灶、确定病灶范围,对于诊断和治疗有着至关重要的影响。目前病灶区域的辨别和勾勒主要由专业医师进行手工操作,准确度受到医师技术和经验的影响,可重复性低,工作量繁重。计算机辅助诊断技术在提高诊断精度和效率方面发挥着越来越重要的作用。由于超声成像固有的特点使得图像噪声大、伪影斑点多、对比度不高、表征组织特征常不明显(如肿块形状复杂多变、内部灰度非匀质、边界不清晰),许多传统方法的分割结果往往不够理想。大量研

究实践表明,活动轮廓模型在医学噪声图像的分割中表现出了很好的性能,这方面的研究工作十分活跃,取得了快速进展。

本文对乳腺超声图像性质和肿块病灶的不同形态表现进行了详细分析,对著名的水平集方法 CV 模型进行适应性改进,引入了表达肿块病灶的全局和局部信息的自适应能量,实现了乳腺肿块病灶的准确快速分割。

1 CV模型和相关改进方案

活动轮廓模型是一种常用的边缘提取算法^[3],它采用参数方程控制初始曲线的动态形变和位移,直至到达目标边界处停止,实现图像分割的目的。作为活动轮廓模型的一个发展,水平集方法是一种新颖的求解几何曲线演化的方法^[4-6],它将平面曲线隐式地表达为三维连续函数(水平集函数)曲面的一个同值曲线,融合图像信息设计能量泛函和与之对应的曲线演化方程,水平集函数在演化方程控制下进行演化(形变和位移),最终停止于图像的真实边界。由于水平集函数在演化过程中能够灵活处理曲线的拓扑结构的变化,适合具有不规则属性的形状复杂的目标(如肿块病灶)的分割;泛函表达式能够用稳定的数值方式实现,计算效率较高;分割结果是闭合光滑的高精度曲线,为后续的分析识别提供了便利。

Chan 等人^[7]提出一种基于 Mumford-Shah 模型的简化活

收稿日期: 2013-04-08; 修回日期: 2013-05-23 基金项目: 广东省科技计划资助项目(2010B060300001)

作者简介: 杨谊(1973-),女,广东河源人,副教授,博士,主要研究方向为医学图像处理、医学三维仿真(yiyang20110130@163.com);申洪(1958-),男,教授,博士,主要研究方向为定量病理学。

动轮廓模型。与测地活动轮廓模型不同,它不以图像梯度而是以匀质灰度信息作为停止项,由于利用了全局图像信息,对形状复杂、边界模糊的图像可以获得较好的分割结果。模型假设 $x \in \mathbb{R}^2$ 为图像平面 Ω 的像素点坐标,令 $I(x): \Omega \rightarrow Z$ 为从图像平面 Ω 到密度空间 Z 的映射,闭合边界 C 把图像 I 划分为目标(C 的内部)和背景(C 的外部)两个不重叠的区域,平均灰度分别为 c_1 和 c_2 。CV 模型能量泛函定义为

$$E_{CV}(c_1, c_2, C) = \lambda_1 \int_{\text{inside } C} |I(x) - c_1|^2 dx + \lambda_2 \int_{\text{outside } C} |I(x) - c_2|^2 dx + \gamma |C| \quad (1)$$

其中: $\lambda_1, \lambda_2, \gamma$ 为可调节常数; $|C|$ 是轮廓线长度。为求得 $E_{CV}(c_1, c_2, C)$ 的最小值,采用水平集方法,将未知的演化曲线 C 用水平集函数 $\phi(x)$ 来代替,得到水平集表示形式:

$$E_{CV}(c_1, c_2, C) = \lambda_1 \int_{\Omega} (I(x) - c_1)^2 H(\phi(x)) dx + \lambda_2 \int_{\Omega} (I(x) - c_2)^2 (1 - H(\phi(x))) dx + \gamma \int_{\Omega} |\nabla H(\phi(x))| dx \quad (2)$$

其中: H 是 Heaviside 函数; ϕ 表示水平集函数,在目标内部 $\phi(x) < 0$,在目标外部 $\phi(x) > 0$,在目标边界上 $\phi(x) = 0$ 。Heaviside 函数也被称为阶梯函数或单位阶跃函数,定义为

$$H(x) = \begin{cases} 1 & \text{if } x > 0 \\ 0 & \text{if } x < 0 \end{cases}$$

其作用是在以每个坐标格点为中心做球坐标的数值积分时,为了保证多格点的积分准确,要给密度乘一个形式上的值,使之在格点之外的区域值为 0,积分后只需做简单的求和。但是在实际计算中,由于 Heaviside 函数的不连续性可能引入很大的数值误差,需要用一种在 0 点处平滑过渡的函数来近似。定义修正的 Heaviside 函数为

$$H_{\epsilon}(x) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan\left(\frac{x}{\epsilon}\right) \right] \quad (3)$$

当闭合边界 C 位于两个区域的分界时,能量函数 $E_{CV}(c_1, c_2, C)$ 达到最小值,图像分割问题就转换为求解能量函数最小化问题。引入变量 t 并用最速下降法使得式(2)极小化,得到以水平集函数 ϕ 表达的偏微分方程:

$$\frac{\partial \phi}{\partial t} = \delta_{\epsilon}(\phi) \left[v \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - \lambda_1 (I - c_1)^2 + \lambda_2 (I - c_2)^2 \right] \quad (4)$$

其中: $\delta_{\epsilon}(x) = H'_{\epsilon}(x) = \frac{1}{\pi} \frac{\epsilon}{\epsilon^2 + x^2}$ (5)

式(4)中: $-\lambda_1 (I - c_1)^2 + \lambda_2 (I - c_2)^2$ 为全局信息; c_1 和 c_2 分别是轮廓曲线外部和内部区域灰度均值的近似,计算时取

$$c_1(\phi) = \frac{\int_{\Omega} H_{\epsilon} dx}{\int_{\Omega} H_{\epsilon} dx}, c_2(\phi) = \frac{\int_{\Omega} (1 - H_{\epsilon}) dx}{\int_{\Omega} (1 - H_{\epsilon}) dx}$$

正如 Chan 等人指出的, CV 模型的前提是图像划分为大致同质的前景和背景区域,当图像中存在灰度不均匀现象时,实际灰度变化与常量 c_1 和 c_2 不符,造成曲线运动偏离真实边界。乳腺超声图像中乳房组织和病灶区域的灰度通常是非同质不均匀变化的,这使得 CV 模型在处理乳腺超声图像时容易产生冗余或偏移轮廓,造成分割不准确。

为了解决这个问题,文献[8~12]分别从不同角度进行运算修正,或者设计出包含图像先验信息的能量泛函,在一定程度上提高了分割精度,但仍未脱离灰度匀质的属性。文献[13]提出了基于局部二值调整能量(local binary fitting, LBF)模型,把 CV 模型中全局二值能量拟合泛函改成以高斯函数为核函数的局部二值拟合能量泛函,迭代中无须重新初始化轮廓,通过核函数 $K(x)$ 所控制像素点 x 邻域灰度均值来降低偏移场对分割的影响,对灰度不均匀图像取得了很好的分割结

果,并且具有区域尺度化的性质。LBF 模型定义如下:

$$E_{LBF}(c_1, c_2, C) = \lambda_1 \int \left(\int_{\Omega_{\text{in}}} K(x-y) (I(y) - f_{\text{in}}(x))^2 H(\phi(y)) dy \right) dx + \lambda_2 \int \left(\int_{\Omega_{\text{out}}} K(x-y) (I(y) - f_{\text{out}}(x))^2 [1 - H(\phi(y))] dy \right) dx + \gamma |C| \quad (6)$$

LBF 模型的特点是强化了图像的局部信息,也正由此在图像中存在大量的伪影和杂质时(如乳腺超声图像),可能导致能量泛函演化过程中陷于局部极小值,产生错误的停止收敛^[14,15]。

综上所述,本文吸收 LBF 模型的基本内核,针对乳腺超声图像特质,对其作改进,加入包含全局控制信息的自适应能量项,全局信息项和局部信息项的相互关系由权重系数来决定,在图像中灰度分布不均匀的区域,由局部信息主导轮廓曲线运动,引导曲线移向真实边界;在图像中灰度分布较均匀的区域,由全局信息主导轮廓曲线移动,避免陷于能量泛函的局部极小值。实验表明,这种方法无须引入形状先验信息且不明显增加能量泛函计算复杂度,能够更好地处理乳腺超声图像中目标病灶的模糊区域和弱边界,达到较满意的分割精度和较快的收敛速度。

2 本文方法

2.1 初始轮廓范围的确定

根据乳腺超声图像肿块病灶分布的性质,取初始轮廓为自动固定设置。这是因为,超声解剖分为四个区域:表皮层、皮下区域包括脂肪和淋巴管、腺体层、腺体后区域。绝大多数肿瘤的生长位置主要位于腺体层,即图 1 中两条白色平行线内部范围,该范围之上是表皮层和皮下区域,之下是腺体后区域,只有个别恶性肿瘤会浸润到这两部分。初始轮廓均由人工设置,将病灶或病灶主要部分包括在内。

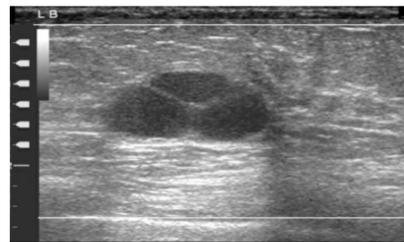


图 1 乳腺超声解剖示意图

乳腺良恶性肿瘤在超声图像中具有明显的形态学区别,对比指标如表 1 所示。临床诊断学认为,边界表现是鉴别良、恶性肿瘤最为重要的超声征象,图像分割算法可以利用的主要信息也体现在边界形态上。由于边界浸润不规则和钙化点的分割干扰,造成曲线演化收敛速度减慢,迭代次数增加,这两项数据能够为鉴别良恶性肿瘤提供一定依据。对于一些乳腺图像中存在的针尖状钙化点,可视为图像中局部散布的微小噪声,一般不会影响轮廓曲线演化。

表 1 乳腺超声图像肿块判读属性

类型	结节	边界	囊壁	血流	钙化
良性	实性,圆形或椭圆形	清晰,规整,有包膜	薄	无或偶见	少见微小钙化
恶性	质硬,多不甚规则	边界不清,不规则	增厚	常有血供	常见微小钙化

2.2 融合全局和局部图像信息的自适应水平集变分方法

为引入全局和局部两种信息,定义自适应函数为

$$F(C) = \alpha F_l(C) + (1 - \alpha) F_g(C) \quad (7)$$

其中: F_l 为局部图像信息; F_g 为全局图像信息; $\alpha (0 \leq \alpha \leq 1)$ 为自适应平衡因子,调节全局和局部信息的作用权重。

局部图像信息采用 LBF 模型的定义,对于图像中的每个像素点 x ,关于它的半径为 ρ 的圆形邻域 $O(x)$ 的局部能量定义为

$$E_x = \sum_{i=1}^N \int_{\Omega_i} K(x-y)(I(y) - f_i(x))^2 \quad (8)$$

其中: $I(y)$ 为每个像素点 y 的灰度, $f_i(x)$ 为以像素点 x 为中心的邻域 $O(x)$ 的灰度估值。显然,在邻域 $O(x)$ 内, $K(x-y) > 0$;在邻域 $O(x)$ 外, $|x-y| > \rho$ 时, $k(x-y) = 0$,且满足 $\int_{O_x} K(x-y)dy = 1$ 。根据观察,当 y 距离中心 x 越近时, $K(x-y)$ 越大,反之越小,因此将 K 取为高斯核函数 G 。由 $F = \int_{\Omega} E_x dx$,局部信息表示为

$$F_l(C, f_{in}, f_{out}) = \int_{\Omega} [\lambda_1 \int_{\Omega_{in}} G_{\varepsilon}(x)(I(y) - f_{in}(x))^2 + \lambda_2 \int_{\Omega_{out}} G_{\varepsilon}(x)(I(y) - f_{out}(x))^2] dy dx \quad (9)$$

全局信息项用图像目标内部和外部的分布概率表示。采用巴氏距离(Bhattacharyya distance) $D = -\log B$ 定义全局信息:

$$F_g(C) = B(C) = \int \sqrt{\frac{\int_{\Omega_1} G_{\varepsilon}(z-I(x)) dx}{area_{in}} \cdot \frac{\int_{\Omega_2} G_{\varepsilon}(z-I(x)) dx}{area_{out}}} dz \quad (10)$$

其中: $area_{in}$ 和 $area_{out}$ 分别为轮廓内外的面积。采用巴氏距离而不用欧式距离是为了保证与原始数据的测量单位无关,由标准化数据和中心化数据(即原始数据与均值之差)计算出的两点之间的巴氏距离相同,还可以排除变量之间相关性的干扰。这样,计算 D 的最大值就等于最小化 $B(C)$ 。至此,总的能量泛函为

$$F_{CV}(c_1, c_2, C) = F_l + F_g + \gamma C = \alpha(I) \cdot [\lambda_1 \int_{\Omega} G_{\varepsilon}(x)(I(x) - c_1)^2 H(\phi(x)) dx + \lambda_2 \int_{\Omega} G_{\varepsilon}(x)(I(x) - c_2)^2 (1 - H(\phi(x))) dx] + (1 - \alpha(I)) \cdot \int \sqrt{\frac{\int_{\Omega_1} G_{\varepsilon}(z-I(x)) dx}{area_{in}} \cdot \frac{\int_{\Omega_2} G_{\varepsilon}(z-I(x)) dx}{area_{out}}} dz + \gamma \int_{\Omega} | \nabla H(\phi(x)) | dx \quad (11)$$

如果在式(11)中把全局信息项与局部信息项的系数 α 设置为(0,1)间的常数,测试发现,当将初始轮廓放置在距离目标较远处时,曲线会发生演化很慢的现象。分析原因是此时局部梯度变化对曲线位移的吸引力不够,应当加大全局信息项的权重(同时弱化局部信息项的权重),由全局信息项驱动轮廓运动;而当轮廓距离真实边界很近时,应当增大局部信息项的权重(同时弱化全局信息项的权重),促使轮廓形变符合真实边界的形状。因此,在应用中把系数修正为可变量:

$$\alpha(I) = \kappa \cdot (\nabla G_{\sigma} \times I) \quad (12)$$

即将权重系数定义为图像高斯滤波梯度。由于它的大小由图像梯度决定,就能够自适应地变化,当轮廓远离目标边界时,该值较小,使得全局信息项起主要作用,驱使零水平集快速向目标边界靠近;而当轮廓接近目标边界时,该值迅速增大,使得局部信息项起主要作用,引导零水平集较快地调整形状,以停止在目标边界上。系数 κ 的作用是保持 $\alpha(I)$ 始终在(0,1)之间,实验中按 $\kappa = 1/i^2$ 衰减,一般在 $i \leq 2$ 时满足要求。

本文方法与 LBF 模型相比,增加了新的全局信息项,以及全局信息项和局部信息项的权重系数,数值化计算仍采用文献[13]的中心差分法。

3 实验结果及讨论

为了验证本文方法的有效性,用40例包含肿块的乳腺超声图像作为样本组进行分割实验,样本全部来自于南方医科大学附属医院乳腺外科临床教学影像资源,遵循临床医学实验数据使用原则。在 Intel® Core™2 Duo CPU 3.0 GHz,2 GB RAM 计算机上采用 MATLAB 7.0 实现。将本文方法与文献[9]的 revised CV(RCV)模型和文献[13]的 LBF 模型作实验对照,三种方法均采用相同的初始轮廓。本文方法的常参数设置为: $\lambda_1 = \lambda_2 = 1$,时间步长 $\Delta t = 0.01$ s, $\gamma = 1$,高斯核函数 G_{ε} 中 $\varepsilon = 3$ 。

为定量评价分割的质量,通常的做法是以专业医师手工分割的结果为标准,将算法分割得到的结果与之进行像素级比较。由一位专业医师对测试图片进行手动分割,校准后的分割结果作为标准轮廓。图2~4分别显示了对于同一样本,三种自动分割算法的处理结果与手工分割结果的比较。

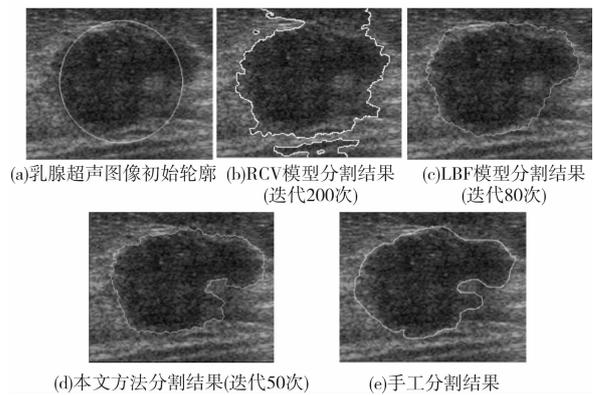


图2 实验结果1

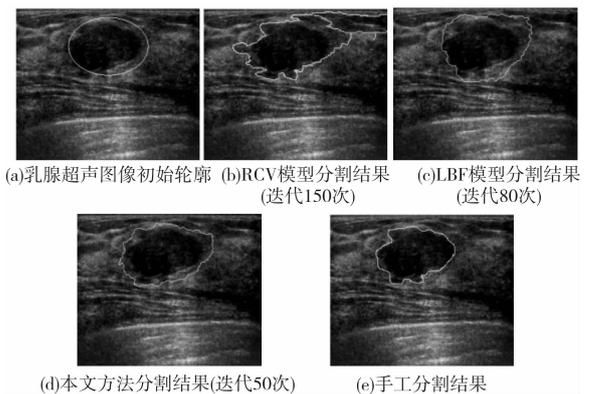


图3 实验结果2

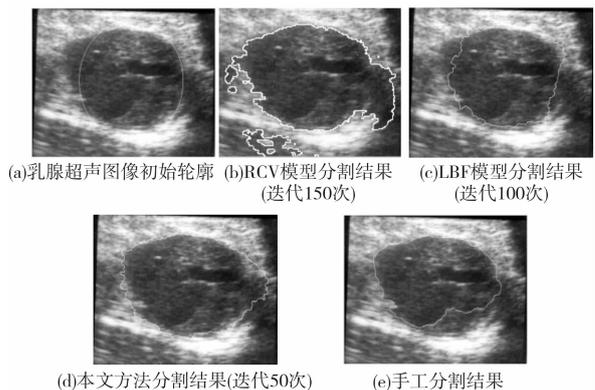


图4 实验结果3

从待分割原始超声图像图2(a)、图3(a)、图4(a)可看到,无论是肿块内部还是周围区域,灰度分布都不均匀,且存在大

量伪影干扰。RCV 模型(图 2(b)、图 3(b)、图 4(b))虽然可以大致地分割出肿块轮廓,但存在较多冗余轮廓,常常把伪影区当成病灶,并且对肿块边缘细节的分割也存在一定偏差。LBF 模型(图 2(c)、图 3(c)、图 4(c))由于局部作用力强,促使曲线轮廓快速向梯度大的地方移动,使得轮廓在局部极小值处多次陷入停顿。本文方法的分割(图 2(d)、图 3(d)、图 4(d))由于全局信息项和局部信息项在轮廓演化的不同阶段权重发生相应变化,交替占主导作用,对于伪影干扰的处理比前面两种模型好,在最终轮廓线的形状和边界细节方面更为准确,肉眼主观判读最为接近真实轮廓。另外,本文方法在初始轮廓变化的情况下,达到稳定的迭代次数没有明显变化,而当初始轮廓与目标偏移加大时,RCV 和 LBF 模型都增加了迭代次数。

根据医学临床的检验原则,本文采用了以下四项指标来量化评价分割准确度:

$$\text{真阳性率(true positive ratio) TP} = \frac{|S_m \cap S_a|}{|S_m|}$$

$$\text{假阳性率(false positive ratio) FP} = \frac{|S_m \cup S_a - S_m|}{|S_m|}$$

$$\text{假阴性率(false negative ratio) FN} = \frac{|S_m \cup S_a - S_a|}{|S_m|}$$

$$\text{误差(misclarification erro) ME} = \frac{|S_m \cup S_a - S_m \cap S_a|}{|S_m \cup S_a|}$$

其中: S_m 为手工分割结果, S_a 为自动分割结果。

对于样本组计算上述四项指标的平均值,结果如表 2 所示。从表中可以看到,RCV 模型处理样本的平均真阳性率较高(93.57%),平均假阴性率较低(6.37%),说明它能够做到较少遗漏病灶组织,但它的平均假阳性率很高,达到 27.15%。这表明冗余的和向外发散的轮廓段把一些正常组织也认做病灶包围起来,产生大于真实边界的分割结果,这样的结果可能使医生造成偏大的病情评估,导致不必要的过度活检切片,手术时不必要地切除正常组织,给病患带来更多的身体损伤和精神压力。LBF 方法处理样本的假阳性率虽然较低,但它的平均假阴性率较高(10.53%),这是因为它容易受到局部极值的干扰,收敛到位于目标内部的地方(钙化点或噪声点),在临床指导中这意味着可能会“错过”部分病灶组织,也会对诊断产生不利的导向。本文方法处理样本的平均真阳性率略高于 RCV 模型,比 LBF 模型高出较多,同时平均假阳性率和平均假阴性率两个指标都表现很好,平均误差最小。专业医师认为此结果能够达到辅助诊断的要求。

表 2 乳腺超声图像肿块病灶分割准确率量化指标表

方法	TP/%	FP/%	FN/%	ME/%
RCV 模型	93.57	27.15	6.37	14.36
LBF 模型	86.36	5.94	12.53	10.25
本文方法	94.82	7.58	4.23	6.09

本文方法的另一个优点是收敛速度较快,三种模型的耗时(取 10 幅全部分割成功的图像样本统计时间开销)如表 3 所示。由于本文方法引入了全局信息项,并且全局信息与局部信息的权重是自适应调整的,使得能量泛函的收敛速度加快,尽管在计算全局能量和可变权重系数时增加了一定的时间开销,但总体运行时间比 RCV 模型有明显减少;与 LBF 模型相比,虽然样本组分割实验平均用时略多,但 LBF 模型能够较快停止的一个原因是过早地停顿到了局部极值点。经专业医师试用,

本文方法的处理等待时间在用户的等待时限之内,能够达到实时要求。

表 3 三种模型的耗时比较

方法	总时间/s	平均时间/s
RCV 模型	343.29	8.58
LBF 模型	154.78	3.87
本文方法	168.82	4.22

4 结束语

本文提出一种融合全局和局部图像信息的自适应能量水平集的乳腺超声肿块病灶分割方法,全局信息从轮廓内外部的灰度概率分布函数计算得到,局部信息则表现为以像素点为中心的小邻域的梯度变化,在能量泛函演化过程中,全局信息项和局部信息项的权重系数实时变化调整。实验结果表明,本文方法能够较好地处理灰度变化非均匀、噪声大、对比度低的乳腺超声图像的肿块病灶分割问题,与 RCV 模型、LBF 模型相比,本文方法在分割准确性和处理病灶边缘细节方面更好,分割速度较快,临床适用性更强。

临床中常利用血流分布来区别良恶性肿瘤:良性肿瘤常表现为周边血流,无穿支血管,内部少量分布规则的血流;恶性肿瘤多为血供丰富,分布紊乱,显示穿支血管,但小乳癌、合并坏死或硬化明显的恶性肿瘤内部无或少许血流;炎性病灶常出现类似于恶性肿瘤的超声表现。本文为测试改进水平集算法对模糊边界和低对比度图像中目标的分割有效性,并未将含有彩色血供信息的超声图像选入样本组,今后将考虑结合肿物内和周边血供形状和大小进行分割分析,为肿物性质的鉴别提供更多依据。

参考文献:

- [1] SIEGEL R, NAISHADHAM D, JEMAL A. Cancer statistics, 2012 [J]. CA: a Cancer Journal for Clinicians, 2012, 62(1):10-29.
- [2] HIGGINS M J, BASELGA J. Targeted therapies in breast cancer[J]. Journal of Clinical Investigation, 2011, 121(10):3797-3803.
- [3] KASS M, WITKIN A, TERZOPOULOS D. Snakes: active contour models[J]. International Journal of Computer Vision, 1988, 1(4):321-331.
- [4] MUMFORD D, SHAH J. Boundary detection by minimizing functionals[C]//Proc of IEEE Conference on Computer Vision Pattern Recognition. 1985.
- [5] MUMFORD D, SHAH J. Optimal approximations by piecewise smooth functions and associated variational problems[J]. Communications on Pure and Applied Mathematics, 1989, 42(5):577-685.
- [6] MALLADI R, SETHIAN J, VEMURI B. Shape modeling with front propagation: a level set approach[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1995, 17(2):158-175.
- [7] CHAN T, VESE L. Active contours without edges[J]. IEEE Trans on Image Processing, 2001, 10(2):266-277.
- [8] VESE L, CHAN T. A multiphase level set framework for image segmentation using the Mumford and Shah model[J]. International Journal Computer Vision, 2002, 50(3):217-293.
- [9] TSAI A, YEZZI A, WILLSKY A S. Curve evolution implementation of the Mumford-Shah functional for image segmentation, denoising, interpolation, and magnification [J]. IEEE Trans on Image Process, 2001, 10(8):1169-1186. (下转第 3853 页)

如图 9、10 所示。实验表明本文算法对常见失真鲁棒。



图 8 图 5 中抽取的水印



图 9 图 5 失真版本(高斯低通滤波)抽取的水印



图 10 图 5 失真版本(添加高斯噪声)抽取的水印

4 结束语

本文提出了一种结合非下采样 Contourlet 变换与奇异值分解的多水印算法。嵌入算法充分利用了非下采样 Contourlet 变换的高冗余性,使得降低虚警率和实现多水印都有了可能。将水印图像的正交矩阵 U_w 嵌入到原始图像的两个高频方向子带中,以便为抽取水印时提供一个控制算法是否执行的参数;在抽取水印时先从待检测图像中抽取 U'_w , 计算其与 U_w 的相似度,比较该相似度与阈值的大小关系,决定检测算法是否执行,这就较好地解决了高虚警率问题。同时,本文算法还保持了奇异值分解水印算法通常的鲁棒性。

参考文献:

- [1] 李海峰,宋巍巍,王树勋. 基于 Contourlet 变换的稳健性图像水印算法[J]. 通信学报,2006,27(4):87-94.
- [2] 叶建兵,谭沈阳,张学华. 一种基于双边假设检验的 Contourlet 域乘性水印盲检测算法[J]. 包装工程,2011,32(11):89-92.
- [3] 丁兴号,章登峰,钱坤,等. 基于无下采样 Contourlet 变换和人眼视觉系统的稳健盲水印算法[J]. 光学学报,2009,29(12):3344-3350.
- [4] 陈开亮,王建军. 一种 HVS 和 Contourlet 结合的图像水印算法[J]. 计算机辅助设计与图形学学报,2007,19(6):217-223.

- [5] 梁栋,殷兵,于梅,等. 基于非抽样 Contourlet 变换的彩色图像数字水印算法[J]. 光学学报,2008,28(8):1469-1474.
- [6] 曾凡娟,周安民. 基于 Contourlet 变换和奇异值分解的图像零水印算法[J]. 计算机应用,2008,28(8):2033-2035.
- [7] 刘如京,杨韬,王玲. 基于 NMF 和 SVD 相结合的 Contourlet 域鲁棒水印算法[J]. 计算机应用研究,2010,27(9):3504-3509.
- [8] 刘如京,王玲. 一种 NMF 和 SVD 相结合的鲁棒水印算法[J]. 计算机科学,2011,38(2):271-273.
- [9] 熊顺清,周卫红. 一种基于非采样 Contourlet 变换的图像水印算法[J]. 广西师范大学学报:自然科学版,2011,29(2):195-199.
- [10] 马婷,黄剑华,赵勇,等. 基于非采样 Contourlet 变换和 SVD 的数字水印算法研究[J]. 云南民族大学学报:自然科学版,2011,20(4):305-309.
- [11] 张飞艳,全恒立,林立宇,等. 基于奇异值分解的 Contourlet 域稳健性数字水印算法[J]. 计算机应用研究,2012,29(4):1402-1404.
- [12] 陈宁,马会杰. 基于 Contourlet 和 SVD 的鲁棒双水印算法[J]. 计算机应用研究,2012,29(7):2700-2702.
- [13] LAI C C, TSAI C C. Digital image watermarking using discrete wavelet transform and singular value decomposition[J]. IEEE Trans on Instrumentation and Measurement, 2010, 59(11): 3060-3063.
- [14] 刘瑞祯,谭铁牛. 基于奇异值分解的数字图像水印方法[J]. 电子学报,2001,29(2):168-171.
- [15] GANIC E, ESKICIOGLU A M. Robust embedding of visual watermarks using DWT-SVD[J]. Journal of Electronic Imaging,2005, 14(4):043004.
- [16] CUNHA A L, ZHOU Jian-ping, DO M N. Nonsubsampled contourlet transform: theory, design, and applications [J]. IEEE Trans on Image Processing, 2006, 15(10): 3089-3101.
- [17] 梁婷,李敏,何玉杰,等. Arnold 变换在图像置乱中的应用研究[J]. 贵州大学学报:自然科学版,2011,28(6):79-81.
- [18] YAVUZ E, TELATAR Z. Improved SVD-DWT based digital image watermarking against watermark ambiguity [C]// Proc of the 22nd Annual ACM Symposium on Applied Computing. 2007:1051-1055.
- [19] XIAO Liang, WEI Zhi-hui, YE Jian-bing. Comments on "Robust embedding of visual watermarks using discrete wavelet transform and singular value decomposition" and theoretical analysis [J]. Journal of Electronic Imaging, 2008, 17(4):040501.
- [20] 肖亮,叶建兵,韦志辉. 一类基于 SVD 的数字水印虚警分析与改进算法[J]. 南京理工大学学报:自然科学版,2010,34(2):227-231.
- [21] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error visibility to structural similarity [J]. IEEE Trans on Image Processing, 2004, 13(4): 600-612.

(上接第 3843 页)

- [10] MIO W, SRIVASTAVA A. Elastic-string models for representation and analysis of planar shapes [C]//Proc of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2004:10-15.
- [11] SUNDARAMOORTHY G, YEZZI A, MENNUCCI A. Sobolev active contours [J]. International Journal of Computer Vision, 2007, 73(3):345-366.
- [12] JOSHI N, BRADY M. Non-parametric mixture model based evolution of level sets and application to medical images [J]. International Journal of Computer Vision, 2010, 88(1):52-68.
- [13] LI Chun-ming, KAO C Y, GORE J C. Minimization of region-scalable fitting energy for image segmentation [J]. IEEE Trans on Image Process, 2008, 17(10):1940-1949.
- [14] LI Chun-ming, XU Chen-yang, GUI Chang-feng, et al. Level set evolution without re-initialization: a new variational formulation [C]//

Proc of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington DC: IEEE Computer Society, 2005: 430-436.

- [15] 孔丁科,汪国昭. 用于图像分割的边界保持局部拟合模型 [J]. 浙江大学学报:工学版,2010,44(12):2236-2240.
- [16] 鲜敏,黄剑华,张英涛,等. 乳腺超声图像肿瘤全自动定位方法研究 [J]. 计算机应用研究, 2011, 28(12):4752-4756.
- [17] 张兴建. 乳腺超声诊断学 [M]. 北京:人民卫生出版社,2012.
- [18] 薛维琴,周志勇,张涛,等. 灰度不均的弱边缘血管影像的水平集分割方法 [J]. 软件学报,2012,23(9):2489-2499.
- [19] 郑伟,陈彦江. 基于局部区域信息的水平集医学图像分割方法 [J]. 计算机工程与应用,2010,46(31):209-211.
- [20] BROWN E S, TONY F C, BRESSON X. Completely convex formulation of the Chan-Vese image segmentation model [J]. International Journal of Computer Vision, 2012, 98(1):103-121.