

基于 Gmac 模型的乳腺肿块分割算法

吕泽华¹,赵盛荣²,梁 虎²,唐 赫¹

(1. 华中科技大学软件学院,湖北武汉 430074;2. 华中科技大学计算机科学与技术学院,湖北武汉 430074)

摘 要: 在乳腺 CAD 系统中,乳腺肿块分割是一个重要的先前步骤,分割结果的好坏直接影响到肿块的分类和检测.本文将 Gmac 模型应用到乳腺肿块分割上,并提出了求解 Gmac 模型的两种改进方法:改进的变分水平集法、改进的 split bregman 方法.实验选取了 483 幅医学乳腺肿块图片进行分割,得到了两种改进方法的 CM 均值分别为 64% 和 76%;AMED 均值分别为 4.4750 和 1.4602.结果表明:改进的 split bregman 方法对乳腺肿块进行了更有效的分割.实验也利用经典的 ACWE 模型和 GAC 模型对上述乳腺肿块图片进行了分割实验,与基于改进 split bregman 方法的 Gmac 模型相比,结果表明:Gmac 模型具有更好的分割性能.

关键词: 乳腺肿块分割; Gmac (Global minimum active contour) 模型; split bregman 方法

中图分类号: TP302 **文献标识码:** A **文章编号:** 0372-2112 (2014)02-0398-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2014.02.028

The Segmentation Algorithm of Mammographic Masses Based on the Gmac Model

LYU Ze-hua¹, ZHAO Sheng-rong², LIANG Hu², TANG He¹

(1. School of Software Engineering, Huazhong University of Science and Technology, Wuhan, Hubei 430074, China;

2. School of Computer Science and Technology, Huazhong University of Science and Technology, Wuhan, Hubei 430074, China)

Abstract: In breast-CAD system, the segmentation of breast mass is an important step for pretreatment. In this work, the Gmac model is applied for breast mass segmentation, meanwhile, two improved methods to solve the Gmac model are proposed: the improved Level-set algorithm and the improved split-bregman algorithm. In experiment part, we select 483 medical images for test. The CM for the two algorithms is 64% and 76% and AMED is 4.4750 and 1.4602 respectively. The experimental results show the improved split bregman method is more effective for breast-mass segmentation. Besides, the ACWE model and GAC model are used for comparison and the results indicate that the Gmac model is more suitable for breast-mass segmentation.

Key words: breast lumps segmentation; global optimal active contour model; split bregman method

1 引言

乳腺癌是一种严重危害女性身心健康甚至危及生命的常见恶性肿瘤.据资料统计,其发病率占各种恶性肿瘤的 7~10%, 占所有女性癌症的 16%.因而乳腺癌的早期发现和早期诊断,对于降低死亡率、提高生存率起着至关重要的作用.有效地分割乳腺肿块有助于对乳腺癌的诊断,为了有效地检测出肿块区域,国内外的众多学者进行了深入的研究和探索^[1~7].基于活动轮廓模型(Active Contour Model, ACM)的分割方法,以适应范围广、分割精度高、轮廓曲线闭合等特点,日益成为医学图像分割的主流方法之一^[8~10].曲线演化理论及水平集

一的数值解等.GACM 演化过程中的两个经典模型是测地线活动轮廓(Geodesic Active Contours, GAC)模型^[11]和无边缘活动轮廓(Active Contour Without Edge, ACWE)^[12]模型.GAC 模型对有凹陷边界的图像往往不能进行正确分割,使演化曲线停留在局部极小值状态;ACWE 模型在迭代过程中需计算所有的图像数据,极大地影响了分割效率.而全局最优活动轮廓模型(Global minimum active contour, 简称 Gmac 模型)^[13]在一个求解全局最优解的框架中整合了 GAC 模型和 ACWE 模型,不但存在全局最优解,而且还可以充分利用两种模型的优势.本文改进了求解 Gmac 模型的方法,首先利用快速 split bregman 方法分割出所有的可疑目标区域,然后基于目标区域的平均灰度、面积、区域中心与图片中心的距离,引入了粗选择和细选择公式,得到最佳目标区域,即肿块区域.

2 Gmac 模型

ACWE 模型的思想是最小化如下能量泛函:

$$E_{ACWE}(\Omega_c, c_a, c_b, \lambda_a, \lambda_b) = Per(\Omega_c) + \lambda_a \int_{\Omega_c} |I - c_a|^2 dx dy + \lambda_b \int_{\Omega \setminus \Omega_c} |I - c_b|^2 dx dy \quad (1)$$

其中, C 为演化曲线, $Per(\Omega_c)$ 为演化曲线的长度, c_a 为目标区域的平均灰度值, c_b 为背景区域的平均灰度值, $\lambda_a, \lambda_b > 0$ 分别为各能量项的权重系数.

方程(1)是一个非凸问题,其最小化问题可能存在局部最优解. Chan 和 Vese^[12]提出了一个基于水平集的演化方程来求解区域 Ω_c ,他们用水平集函数的 Heaviside 函数来表示 Ω_c 和 $\Omega \setminus \Omega_c$,因此,能量方程 E_{ACWE} 可以写成关于数 φ 的水平集方程:

$$E_{ACWE}^2(\varphi, c_a, c_b, \lambda_a, \lambda_b) = \int_{\Omega} |\nabla H_{\epsilon}(\varphi)| dx + \lambda_a \int_{\Omega} (H_{\epsilon}(\varphi)(c_a - I)^2) dx + \lambda_b \int_{\Omega} (H_{\epsilon}(-\varphi)(c_b - I)^2) dx \quad (2)$$

其中 Heaviside 函数 $H(Z)$ 的离散形式为:

$$H(Z) = \begin{cases} 1, & \text{if } Z > 0 \\ 0, & \text{if } Z < 0 \end{cases} \quad (3)$$

水平集函数在目标区域取正值,在背景区域取负值,则水平集函数的 Heaviside 函数在目标区域内取值为 1,在背景区域内取值为 0,模拟了分割的特征函数.

方程(2)的梯度下降流为:

$$\partial_t \varphi = H'_{\epsilon}(\varphi) \left\{ \operatorname{div} \left(\frac{\nabla \varphi}{|\nabla \varphi|} \right) - (\lambda_a (c_a - I)^2 - \lambda_b (c_b - I)^2) \right\} \quad (4)$$

使用 Heaviside 函数的非紧支撑光滑严格单调近似函,并令 $r(x, c_a, c_b) = \lambda_a (c_a - I)^2 - \lambda_b (c_b - I)^2$,则方程(4)的稳态解可表示为:

$$\partial_t \varphi = \operatorname{div} \left(\frac{\nabla \varphi}{|\nabla \varphi|} \right) - r(x, c_a, c_b) \quad (5)$$

式(5)是如下能量方程的梯度下降流:

$$E_{ACWE}^3(\varphi, c_a, c_b, \lambda_a, \lambda_b) = \int_{\Omega} |\nabla \varphi| dx + \int_{\Omega} r(x, c_a, c_b) \varphi dx \quad (6)$$

基于以上的推导,对于任意给定的原图像 $I \in L^1(\Omega)$ 及任意参数 $\lambda_a, \lambda_b > 0$ 提出了 Gmac 能量方程^[14,15]:

$$E(u, c_a, c_b, \lambda_a, \lambda_b) = TV_g(u) + \int_{\Omega} r(x, c_a, c_b) u dx \quad (7)$$

方程(6)和方程(7)的不同之处在于后者加入了特征函数 u 的带权全变分能量 $TV_g(u)$. 当 g 是一边界检

测函数, u 是特征函数 1_{Ω_c} 时, ACWE 模型和 GAC 模型便被联系到了一起. 当 u 取特征函数时,方程(7)等同于:

$$E(u = 1_{\Omega_c}, c_a, c_b, \lambda_a, \lambda_b) = TV_g(1_{\Omega_c}) + \int_{\Omega} r(x, c_a, c_b) 1_{\Omega_c} dx = \int_{\Omega} C g ds + \int_{\Omega} (\lambda_a (c_a - I)^2 - \lambda_b (c_b - I)^2) 1_{\Omega_c} dx \quad (8)$$

此时,最小化能量方程(8)等价于在最小化 $E_{GAC}(C) = \int_{\Omega} C g ds$ 的同时,在 L^2 的意义下,用灰度值分别为 c_a, c_b 的区域 $\Omega_c, \Omega \setminus \Omega_c$ 来近似图像 I .

3 算法改进

由于(1)增强(增强方法见文献[16])以后大部分图片的肿块轮廓仍不明显,并且肿块区域的灰度有逐渐变暗的趋势,由中央向周围递减;分割后得到的边缘为“衍生状”;(2)本实验选取的 483 幅 ROI 图像中,肿块的有效半径的最大值、均值、最小值分别为 50、19 和 7 个像素大小;(3)含有肿块的 ROI 和含有正常组织的 ROI 均是 125×125 的区域;故本实验首先选取以 (62, 62) 为中心,大小为 30×30 的中央区域,如图 1 中黑色方框包围的区域所示. 则在初始化的阈值时,本实验依赖中央区域的灰度值选取 $ulevel$ 和 $ulevel1 = 0.85$.

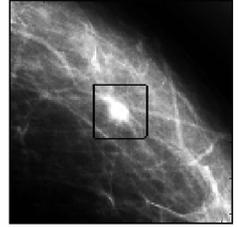
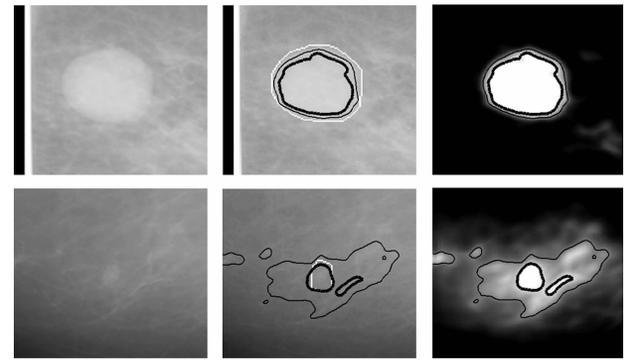


图1 中央区域的选择

其中 $ulevel$ 的取值由中央区域像素的平均灰度值决定,若此区域较暗则 $ulevel = 0.3$,否则 $ulevel = 0.5$,则基于变分水平集法 (Variational Level Set Method, VLSM)^[17]、split bregman 方法^[18~21]的分割结果(称为初分割结果)中有两个可疑目标区域: $U1: u > ulevel$, $U2: u > ulevel1$. 将两个可疑目标区域与金标准进行比较. 第一组图片中区域 $U1$ 更接近金标准;而第二组图片中区域 $U2$ 更接近金标准,如图 2 所示.



(a) 原图 (b) 初分割结果 (c) 分割函数 u
图2 细黑线、粗黑线和白线包围的区域分别为: $U1$ 、 $U2$ 和金标准

增强处理后的图片中的干扰仍比较明显(如血管、皮肤组织等),初分割结果并不理想,一些干扰区域亦被当作目标区域分割出来,如图3所示。

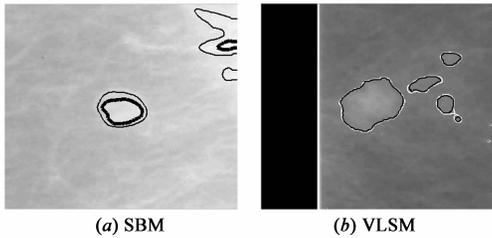


图3 初分割结果 (a)中细黑线包围的区域为U1,粗黑线包围的区域为U2;(b)中白线包围的区域为U1,黑线包围的区域为U2

以图3中SBM的初分割结果为例,其中区域U1、U2分别包含了两个(如图4(a))和三个(如图4(b))可疑目标区域,我们想要得到的最佳目标区域(即肿块区域)便位于其中.针对出现多可疑目标区域这种情况,本文对上述两种算法做了如下的改进:

(1)使用选择函数对初分割结果进行粗选择和细选择,其中选择函数以图像的自身信息为变量,如各目标区域的平均灰度(gray)、面积(area)、区域中心与图片中心的距离(distance),其中选取gray项是由于ROI图片经过增强后,与周围区域相比肿块区域的灰度值较高,area项可以减小那些距离图片中心很近但面积很

小的区域的干扰,distance项的设置则是考虑到ROI图片中肿块的位置。

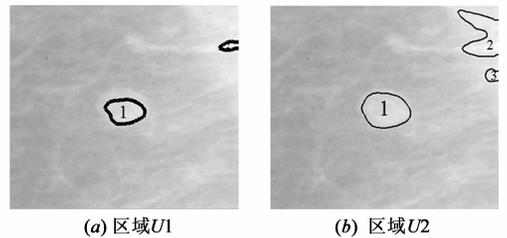


图4 可疑目标区域

(2)粗选择和细选择分别得到的最佳可疑目标区域,利用两者的面积比和区域边缘点距区域中心最近距离差选择最佳目标区域。

以SBM为例,SBM对图片进行分割后得到的初分割结果大概分为四类,如图5所示,第一幅图中区域U1和U2均有干扰区域,第二、三幅图中分别是U1、U2有干扰区域,第四幅图中两个可疑区域均无干扰区域。

粗选择函数(如图6所示):

$$f1 = \alpha_1 \text{gray}1 + \beta_1 \text{area}1 + \gamma_1 \text{distance}1 \quad (9)$$

其中 γ_1 取负值。

细选择函数(对U1最佳可疑目标区域中的U2区域(部分或者全部)进行再选择,如图7所示):

$$f2 = \alpha_2 \text{gray}2 + \beta_2 \text{area}2 + \gamma_2 \text{distance}2 \quad (10)$$

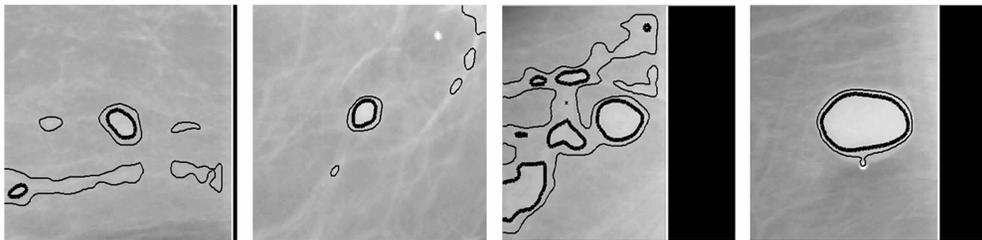


图5 细黑线、粗黑线包围的区域分别为U1和U2

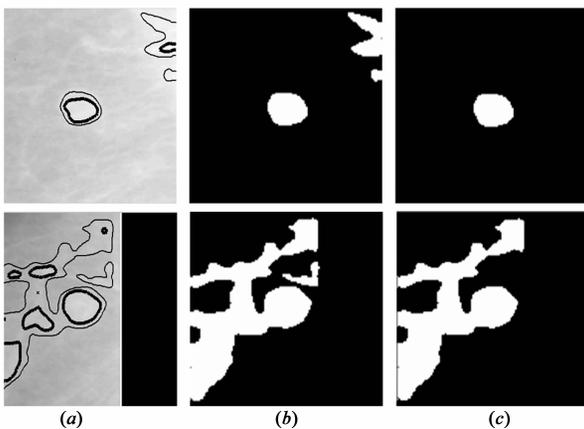


图6 (a)初分割结果;(b)二值化初分割结果,白色区域为二值化的区域U;(c)中白色区域为U1中f1值最大的目标区域,即:U1最佳可疑目标区域

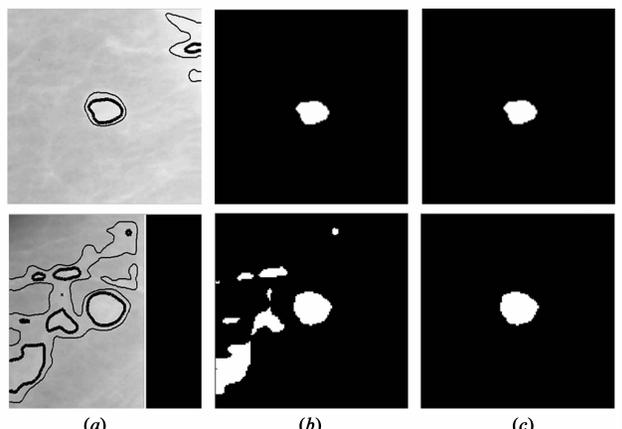
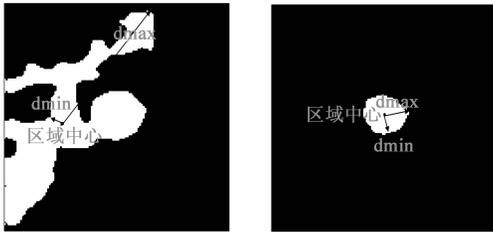


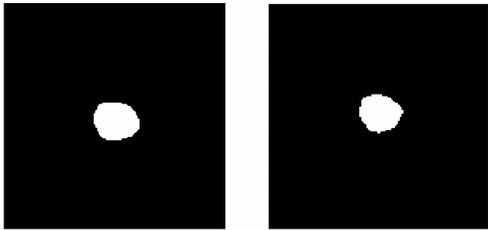
图7 (a)初分割结果;(b)二值化初分割结果,白色区域是将U1最佳可疑目标区域中的U2二值化;(c)中白色区域为U2中f2值最大的目标区域,即:U2最佳可疑目标区域

其中 γ_2 取值.

以图 7 中 (a) 下图为例, 经过粗选择和细选择以后, 得到两个最佳可疑目标区域, 如图 8 所示; 按照本实验设置的两个参考标准: 面积比值 ($\frac{\text{Area}(U1)}{\text{Area}(U2)}$) 和区域边缘点距中心最远、最近距离差 ($d_{\max} - d_{\min}$), 得到最终的最佳目标区域, 如图 9 所示.



(a) U1 最佳可疑目标区域 (b) U2 最佳可疑目标区域
图 8 参考标准



(a) 图 7(a) 上图的最佳目标区域 (b) 图 7(a) 下图的最佳目标区域
图 9 最佳目标区域

4 实验结果

本文所采用的数据库是来自美国佛罗里达大学的数

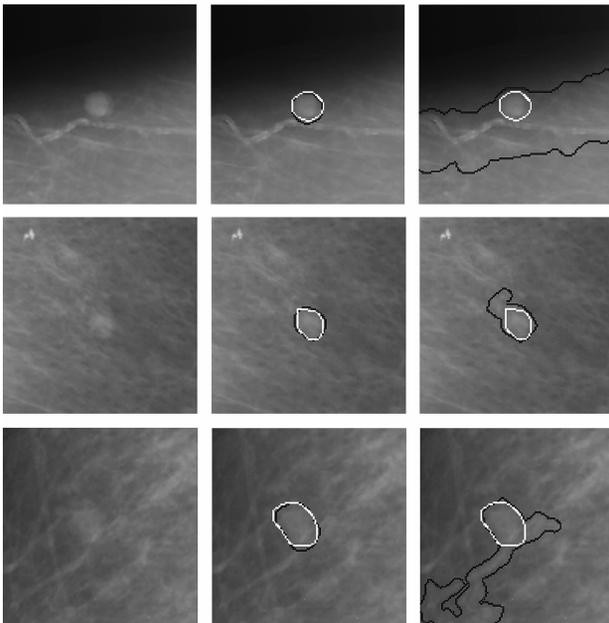


图 10 左列是原图像, 中列是 split bregman 方法的分割结果与金标准对比图, 右列是变分法的分割结果与金标准对比图. 白线包围的区域是金标准, 黑线包围的区域是分割结果

字乳腺 X 线图像数据库 (Digital Database for Screening Mammography, 简称 DDSM). 我们从数据库的 473 幅乳腺 X 线摄片中随机选取了 483 个肿块作为实验数据, 483 幅 ROI 图像中含有 269 个恶性 (malignant) 和 214 个良性 (benign) 肿块, 除有效半径外, 483 幅 ROI 图像边界类型分为清晰、不规则、小分叶、浸润和毛刺等. 本文首先将实验结果和基于 VLSM 的分割结果进行比较. 选取如下的 6 种指标^[22]来评价算法的性能: 面积重叠率 (AOM)、欠分割度量 (AUM)、过分割度量 (AVM) 和综合度量 (CM), 豪斯道夫距离 (HD) 以及平均最小距离 (AMED).

实验过程中 SBM 方法的参数设置为: $\mu = 2$, $\lambda_1 = \lambda_2 = 1/255^2$, $d_0^x = d_0^y = b_0^x = b_0^y = 0$. 图 10 和表 1、表 2 是分别对分割结果进行了定性和定量分析, 结果表明 SBM 不仅具有 VLSM 不可比拟的计算效率优势, 而且在分割准确度上也要高于 VLSM.

表 1 AOM 和 CM 值在各区间的分布情况

Method	≥ 0.9	≥ 0.8	≥ 0.7	≥ 0.6	≥ 0.5	≥ 0.4	≥ 0.3	≥ 0.2	≥ 0.1	≥ 0
AOM 在各区间的分布情况										
VLSM	5	81	181	218	243	273	304	350	408	483
SBM	9	108	246	344	408	433	456	470	477	483
CM 在各区间的分布情况										
VLSM	32	172	228	266	314	402	477	478	478	483
SBM	42	226	366	430	459	475	481	482	482	483

表 2 算法性能的度量值分布情况

度量值	方法	最小值	第一四分位数	均值	中值	第三四分位数	最大值	方差
AOM	VLSM	0	0.1811	0.4762	0.064	0.7629	0.9293	0.0889
	SBM	0	0.568	0.6595	0.7059	0.7918	0.9460	0.0325
AUM	VLSM	0	0	0.0919	0.0383	0.1296	1.0000	0.0219
	SBM	0	0.0299	0.1745	0.1114	0.2686	1.0000	0.0344
AVM	VLSM	0	0.1064	0.4617	0.4757	0.8193	1.0000	0.1257
	SBM	0	0.0320	0.1916	0.1291	0.2828	1.0000	0.0414
CM	VLSM	0	0.4452	0.6409	0.659	0.8368	0.9525	0.0431
	SBM	0	0.7059	0.7645	0.7941	0.8558	0.9635	0.0166
HD (mm)	VLSM	0.5657	4.4721	15.159	17.618	23.9232	31.9625	95.8679
	SBM	0.8000	2.0000	4.8453	3.4409	6.3246	27.5536	17.7858
AMED (mm)	VLSM	0.2141	1.2171	4.4750	3.5452	7.0356	21.2070	13.6393
	SBM	0.2227	0.6620	1.4602	1.0701	1.7808	17.8276	1.8204

在文献[22]中已采用 ACWE、GAC 模型对 483 幅 ROI 图片进行了分割. 下面对 Gmac、ACWE、GAC 模型的分割结果进行对比分析.

首先对分割结果进行定性分析, 如图 11 所示, 经实验证明, 对于背景灰度和目标灰度差别不大的肿块图像, GAC 模型无法有效利用边界信息, 即使肿块的形状比较规则时, 仍无法对可疑肿块进行正确分割; 虽然 ACWE 模型结合了图像的边界信息和区域信息, 具有较好的抗噪性, 但对于伪影、噪声等干扰较多的乳腺肿块图片来说, 该模型并不适用.

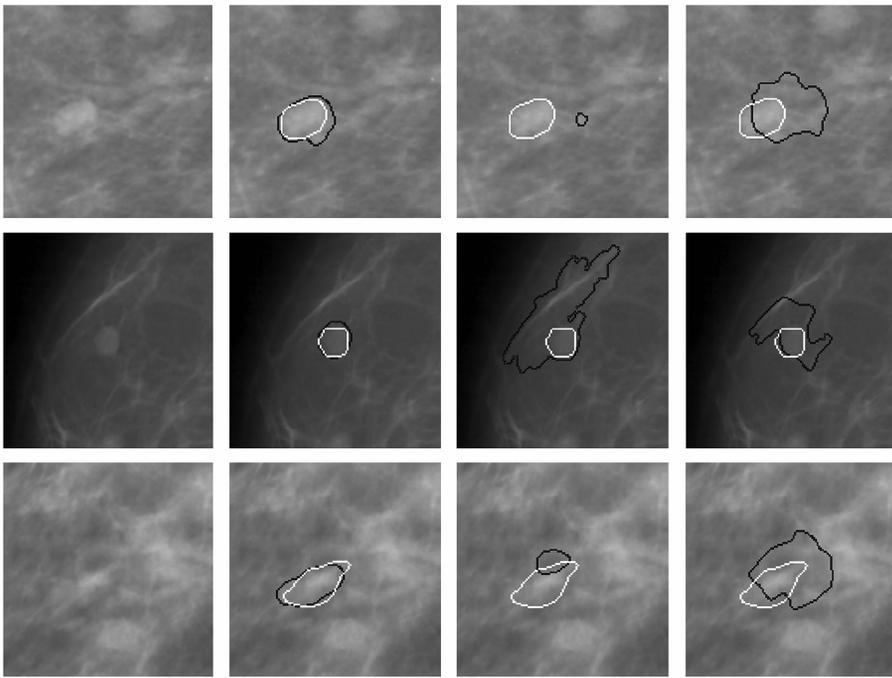


图11 第一列是原图像,第二列是Gmac模型的分割结果与金标准对比图,第三、第四列分别是GAC模型、ACWE模型的分割结果与金标准对比图;白线包围的区域是金标准,黑线包围的区域是分割结果

以上对模型及算法进行了定性的分析,下面对其进行定量分析:

表3 AOM 和 CM 值在各区间的分布情况

Method	≥ 0.9	≥ 0.8	≥ 0.7	≥ 0.6	≥ 0.5	≥ 0.4	≥ 0.3	≥ 0.2	≥ 0.1	≥ 0
AOM 在各区间的分布情况										
ACWE	4	73	199	302	383	410	438	462	474	483
GAC	4	34	109	204	282	355	410	463	480	483
Gmac	9	108	246	344	408	433	456	470	477	483
CM 在各区间的分布情况										
ACWE	26	192	326	401	444	473	478	478	480	483
GAC	13	93	228	336	430	476	483	483	483	483
Gmac	42	226	366	430	459	475	481	482	482	483

如表3可以看出:ACWE、GAC、Gmac模型分别有85%、73%、90%的肿块分割结果的AOM值在0.4以上,它们的AOM值均值分别为0.6170、0.5348、0.6595,方差分别为0.0375、0.0370、0.0325;虽然在 ≥ 0.1 的区间段上,ACWE、GAC模型要优于Gmac模型,但是在其他区间段统计值上均不及Gmac模型;在区间段 $\geq 0 \sim \geq 0.4$ 上,ACWE、GAC、Gmac模型CM值的分布情况相差无几,但Gmac模型有89%的肿块分割结果为“良好”,CM均值为0.7645,明显高于其它两种模型,因此Gmac模型得到的分割结果更接近金标准。

表4 算法性能的度量值分布情况

度量值	方法	最小值	第一四分位数	均值	中值	第三四分位数	最大值	方差
AOM	ACWE	0	0.5262	0.6170	0.6622	0.7615	0.9070	0.0375
	GAC	0.0661	0.3902	0.5348	0.5536	0.6888	0.9266	0.0370
	Gmac	0	0.5680	0.6595	0.7059	0.7918	0.9460	0.0325
AUM	ACWE	0	0.0865	0.2160	0.1899	0.3208	1.0000	0.0299
	GAC	0	0.0215	0.1738	0.1050	0.2655	0.9335	0.0370
	Gmac	0	0.0299	0.1745	0.1114	0.2686	1.0000	0.0345
AVM	ACWE	0	0.0165	0.2056	0.0874	0.3256	1.0000	0.0648
	GAC	0	0.0877	0.3292	0.2785	0.5655	0.9152	0.0685
	Gmac	0	0.0320	0.1916	0.1291	0.2828	1.0000	0.0414
CM	ACWE	0	0.6712	0.7318	0.7619	0.8336	0.9380	0.0211
	GAC	0.3401	0.5742	0.6773	0.6824	0.7795	0.9508	0.0172
	Gmac	0	0.7059	0.7645	0.7941	0.8558	0.9635	0.0166
HD	ACWE	0.8000	2.5613	6.4018	4.4721	8.2365	31.3968	28.3475
	GAC	1.1314	4.4000	6.0597	6.0000	7.2111	19.8716	6.5611
	Gmac	0.8000	2.0000	4.8453	3.4409	6.3246	27.5536	17.7858
AMED	ACWE	0.1951	0.7225	1.7325	1.3228	2.2311	8.5725	2.0150
	GAC	0.2970	1.2086	2.1341	1.9070	2.7554	12.5318	1.7174
	Gmac	0.2227	0.6620	1.4602	1.0701	1.7808	17.8276	1.8204

由表4可知ACWE、GAC和Gmac的HD均值分别为:6.4018、6.0597和4.8453,方差分别为:28.3457、6.5611和17.7857;AMED的均值分别为:1.7325、2.1341和1.4602,方差分别为:2.0150、1.7174和1.8204,可见Gmac模型的均值要小于前两者。虽Gmac模型的HD和AMED的最大值大于其它两种模型,但通过总体统计值的比较知Gmac模型要优于ACWE和GAC模型。

5 结束语

本文首次将 Gmac 模型应用到乳腺肿块分割上,并且提出了改进的 VLSM 和改进的 SBM. 结果证明,改进的 SBM 不仅可以提高计算效率,而且其分割结果更接近金标准;进一步将基于改进的 SBM 的 Gmac 模型的分割结果与经典模型 ACWE 和 GAC 进行比较,实验表明 Gmac 模型具有更好的分割性能.

参考文献

- [1] Michael A W . Segmentation of the breast region in mammograms using snakes [A]. Alexei S. Canadian Conference on Computer and Robot Vision[C]. Canada: IEEE Computer Society, 2004. 385 – 392.
- [2] 邱建峰. 于兹喜, 李月卿, 等. 数字乳腺 X 线照片 CAD 中可疑密度区域的自动分割[J]. 泰山医学院学报, 2005, 26(2): 136 – 139.
Qiu Jian-feng, Yu Zi-xi, Li Yue-qing, et al. Segmentation of suspicious densities in digital mammograms. computer-aided detection [J]. Journal of Taishan Medecial College, 2005, 26(2): 136 – 139. (in Chinese)
- [3] Yu Hong-wei, Xu Wei-dong, Liu Wei, et al. Gaussian pyramid based multi-scale GVF for mass segmentation in digitized mammograms[A]. 2009 3rd International Conference on Bioinformatics and Biomedical Engineering[C]. Beijing: IEEE Computer Society, 2009. 1 – 4.
- [4] J E Ball. Three stage level set segmentation of mass core, periphery, and spiculations for automated image analysis of digital mammograms[D]. Starkville: Mississippi State Univ, 2007: 55 – 80.
- [5] Chan H P. Computer-aided breast cancer diagnosis[A]. Pertrick N , Sahiner B. In Artificial Intelligence Techniques in Breast Cancer Diagnosis and Prognosis[C]. Nanjing: World Scientific Press. 2002: 179 – 264.
- [6] Sahiner B , Chan H P , Petrick N , et al. Improvement of mammographic mass characterization usingspiculation measures and morphological features[J]. Medical Physics, 2001, 28(7): 1455 – 1465.
- [7] John E Ball. Lori Mann Bruce. Digital mammogram spiculated mass detection and spicule segmentation using level sets[A]. 29th Annual International Conference of the IEEE EMBS[C]. Lyon, France: IEEE Computer Society, 2007. 1979 – 1984.
- [8] 张建伟, 方林, 陈允杰, 等. 基于活动轮廓模型的左心室 MR 图像分割[J]. 电子学报, 2011, 11(39): 2670 – 2673.
Zhang Jian-wei, Fang Lin, Chen Yun-jie, et al. Left ventricle MRI segmentation based on active contour Mode [J]. Acta Electronica Sinica, 2011, 11(39): 2670 – 2673. (in Chinese)
- [9] 许新征, 于世飞, 史忠植, 等. 图像分割的新理论和新方法[J]. 电子学报, 2010, 38(2A): 76 – 82.
Xu Xin-fei, Yu Shi-fei, Shi Zhong-zhi, et al. New theories and methods of image segmentation [J]. Acta Electronica Sinica, 2010, 38(2A): 76 – 82. (in Chinese)
- [10] 王颖, 李洁, 高新波. 基于 MCA 的乳腺 X 线图像中肿块的自适应检测方法[J]. 电子学报, 2011, 39(3): 525 – 530.
Wang Ying, Li Jie, Gao Xin-bo. An adaptive mass detection method on mammography based on MCA[J]. Acta Electronica Sinica, 2011, 39(3): 525 – 530. (in Chinese)
- [11] Caselles V, Morel J M, Sapiro G. Geodesic active contour models[J]. International Journal of Computer Vision, 1997, 22: 61 – 79.
- [12] Tony F Chan, Luminita A Vese. Active contours without edges [J]. IEEE Transactions, 2001, Image Processing-10(2): 266 – 277.
- [13] X Bresson, S Esedoglu, P Vanderghyest, et al. Fast global minimization of the active Contour/Snake model[J]. Journal of Mathematic Imaging and Vision, 2007, 28(2): 151 – 167.
- [14] X Bresson. A short guide on a fast global minimization algorithm for active contour models[J]. Energy, 2009: 1 – 19.
- [15] 王琦, 潘振宽, 魏伟波. 多项图像分割的 Split-Bregman 方法及对偶方法[J]. 计算机辅助设计与图形学报, 2010, 22(9): 1561 – 1569.
Wang Qi, Pan Zhen-kuan, Wei Wei-bo. Split-bregman method and dual method form multiphase image segmentation [J]. Journal of Computer-Aided Design & Computer Graphics. 2010, 22(9): 1561 – 1569. (in Chinese)
- [16] 兰义华. 基于图像内容检索的乳腺肿块诊断方法研究 [D]. 武汉: 华中科技大学图书馆, 2011: 70 – 82.
Lan Yi-hua. Research on computer-aided diagnose of mammographic masses using content-based image retrieval [D]. Wu han: The Library of Huazhong University of Science and Technology, 2011: 70 – 82. (in Chinese)
- [17] Zhao H K, Chan T F, Merriman B, et al. A variational level-set approach to multiphase motion[J]. Journal of Computational Physics, 1996, 127: 179 – 195.
- [18] Bregman L. The relaxation method of finding the common points of convex sets and its application to the solution of problems in convex optimization [J]. USSR Computational Mathematics and Mathematical Physics, 1967, 7: 200 – 217.
- [19] T Goldstein, X Bresson, S Osher. Geometric applications of the split bregman method: segmentation and reconstruction [J]. Journal of Scientific Computing, 2009, 45(1 – 3): 272 – 293
- [20] Osher S, Burger M, Goldfarb D, et al. An iterative regularization method for total variation-based image restoration [J]. Multiscale Modeling and Simulation, 2005, 4(2): 460 – 489.
- [21] T Goldstein, S Osher. The split bregman method for L1 Regularized problems [J]. SIAM Journal on Imaging Sciences,

2009, 2(2): 323 - 343.

[22] Rojas D A, Nandi A K. Improved dynamic-programming-

based algorithms for segmentation of masses in mammograms

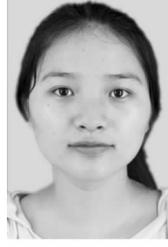
[J]. Medical Physics, 2007, 34(11): 4256 - 4269.

作者简介



吕泽华 男, 1976 年 12 月生, 湖北宜昌人, 讲师, 研究方向为图像处理与模式识别、人工智能、近似计算.

E-mail: lzhus@gmail.com



赵盛荣(通信作者) 女, 1986 年出生, 博士研究生, 主要方向: 图像分析与处理.

E-mail: 165598236@qq.com