

结合 MRF 能量和模糊速度的乳腺癌图像分割方法

冯宝^{1, 2, 3} 陈业航² 刘壮盛³ 李智² 宋嵘¹ 龙晚生³

摘要 乳腺癌灶的精确分割是乳腺癌计算机辅助诊断的重要前提。在动态对比增强核磁共振成像 (Dynamic contrast-enhanced magnetic resonance imaging, DCE-MRI) 的图像中, 乳腺癌灶具有对比度低、边界模糊及亮度不均匀等特点, 传统的活动轮廓模型方法很难取得准确的分割结果。本文提出一种结合马尔科夫随机场 (Markov random field, MRF) 能量和模糊速度函数的活动轮廓模型的半自动分割方法来完成乳腺癌灶的分割, 相对于专业医生的手动分割, 本文方法具有速度快、可重复性高和分割结果相对客观等优点。首先, 计算乳腺 DCE-MRI 图像的 MRF 能量, 以增强目标区域与周围背景的差异。其次, 在能量图中计算每个像素点的后验概率, 建立基于后验概率驱动的活动轮廓模型区域项。最后, 结合 Gabor 纹理特征、DCE-MRI 时域特征和灰度特征构建模糊速度函数, 将其引入到活动轮廓模型中作为边缘检测项。在乳腺癌灶边界处, 该速度函数趋向于零, 活动轮廓曲线停止演变, 完成对乳腺癌灶的分割。实验结果表明, 所提出的方法有助于乳腺癌灶在 DCE-MRI 图像中的准确分割。

关键词 乳腺癌, 动态对比增强核磁共振成像, 马尔科夫随机场能量, 活动轮廓模型, 模糊聚类

引用格式 冯宝, 陈业航, 刘壮盛, 李智, 宋嵘, 龙晚生. 结合 MRF 能量和模糊速度的乳腺癌图像分割方法. 自动化学报, 2020, 46(6): 1188–1199

DOI 10.16383/j.aas.c180759

Segmentation of Breast Cancer on DCE-MRI Images With MRF Energy and Fuzzy Speed Function

FENG Bao^{1, 2, 3} CHEN Ye-Hang² LIU Zhuang-Sheng³ LI Zhi² SONG Rong¹ LONG Wan-Sheng³

Abstract Accurate segmentation of breast cancer is an important step for computer-aided diagnosis. In images obtained from dynamic contrast-enhanced magnetic resonance imaging technique, the traditional active contour model method is difficult to obtain accurate segmentation results due to the low contrast, blurred boundary and intensity inhomogeneous of the breast cancer images. In this paper, a semi-automatic segmentation of active contour model combining Markov random field (MRF) energy and fuzzy velocity function is proposed to perform the segmentation of breast cancer in dynamic contrast-enhanced magnetic resonance imaging (DCE-MRI) images. This method has the advantages of fast speed, objectivity and the ability to reproduce the segmentation result compared to the manual segmentation of a professional doctor. First, the MRF energy of DCE-MRI is calculated to enhance the difference between the target area and the background. Second, the posterior probability of each pixel is calculated in the energy map. Then, region term of active contour model based on the posterior probability is developed. Finally, a fuzzy speed function, which derived by combining the image intensity, time domain characteristics of DCE-MRI and the Gabor texture feature, is introduced into the active contour model as edge function. At the boundary of breast cancer, the edge function approaches zero and the evolution of the contour curve will stop. The experimental results showed that the proposed segmentation method can accurately segment breast cancer in the images of DCE-MRI.

Key words Breast cancer, dynamic contrast-enhanced magnetic resonance imaging (DCE-MRI), Markov random field (MRF) energy, active contour model, fuzzy clustering

Citation Feng Bao, Chen Ye-Hang, Liu Zhuang-Sheng, Li Zhi, Song Rong, Long Wan-Sheng. Segmentation of breast cancer on DCE-MRI images with MRF energy and fuzzy speed function. *Acta Automatica Sinica*, 2020, 46(6): 1188–1199

收稿日期 2018-11-14 录用日期 2019-06-21

Manuscript received November 14, 2018; accepted June 21, 2019

国家自然科学基金(81960324, 61967004), 广西高等学校千名中青年骨干教师培育计划项目基金(2018GXQGFB160)资助

Supported by National Natural Science Foundation of China (81960324, 61967004) and Project Fund for the Cultivation of 1 000 Middle and Young Key Teachers in Guangxi Universities (2018GXQGFB160)

本文责任编辑 黄庆明

Recommended by Associate Editor HUANG Qing-Ming

1. 中山大学生物医学工程学院 广州 510006 2. 桂林航天工业

乳腺癌是现代女性最常见的恶性肿瘤之一, 严重威胁着女性患者的身心健康。如今, 乳腺癌检测

学院电子信息与自动化学院 桂林 541004 3. 江门市中心医院放射科 江门 529030

1. School of Biomedical Engineering, Sun Yat-sen University, Guangzhou 510006 2. School of Electronic Information and Automation, Guilin University of Aerospace Technology, Guilin 541004 3. Department of Radiology, Jiangmen Central Hospital, Jiangmen 529030

技术主要有乳腺 X 线摄影术和乳腺磁共振成像技术。乳腺 X 线摄影术的原理是利用 X 射线的物理特性进行投影成像，得到全乳的二维图像，其对非致密腺体组织的乳腺具有高敏感性，但在具有高密度腺体组织的乳腺诊断价值不大。乳腺动态增强核磁共振成像 (Dynamic contrast-enhanced magnetic resonance imaging, DCE-MRI) 是一种以病变区和正常组织中的微血管系统为生理基础的无辐射磁共振功能成像技术。患者在注射增强对比剂后，由于乳腺癌灶比正常组织具有更高的血管密度，在注射增强对比剂后的前中期乳腺癌灶的强化程度更高。DCE-MRI 与 X 线摄影相比，DCE-MRI 对乳腺癌病灶的检出不受腺体密度的影响，能够反映病变内部血流特征，且对早期乳腺癌的敏感性、乳腺癌的分期和病变范围的一致性都优于 X 线摄影，是进行乳腺癌研究的主要影像手段^[1-2]。在 DCE-MRI 图像上，乳腺癌灶表现为肿块型或非肿块型。由于乳腺癌灶大多沿腺体分布，导致非肿块型乳腺癌灶的形态极其不规则，肿瘤区域边界模糊且对比度低，对乳腺癌灶的准确分割带来了极大困难^[3]。

目前，国内外研究学者已经对乳腺癌灶分割算法进行了大量的研究，主要的方法包括边界活动轮廓模型 (Active contour model, ACM) 和区域活动轮廓模型。ACM 主要思想是建立一个能量泛函，在内力和外力的共同作用下使能量泛函趋近于最小值，从而轮廓曲线演变到目标边界^[4-6]。边界 ACM 依据图像的梯度信息构建边缘检测函数，在目标边界处速度函数为零，轮廓曲线停止演变；区域 ACM 依据目标边界内外区域信息构建能量泛函并驱动轮廓曲线演变^[7-9]。张旭梅等^[10] 提出一种整合全局和局部信息的区域 ACM，可以在乳腺核磁共振图像上分割多种灰度不均匀场景下的乳腺癌灶。虞红伟等^[11] 利用高斯金字塔模型得到粗尺度图像再使用局部区域 ACM 对粗尺度图像进行局部优化，提高乳腺癌灶的分割精度。但是，乳腺 DCE-MRI 的灰度图像可能无法在前景和背景图像统计之间提供足够大的差异（乳腺癌灶和正常乳腺具有低对比度），无法使区域 ACM 的轮廓趋近于乳腺癌灶的真实边界。范虹等^[12] 利用小波多尺度分解对图像进行多尺度空间分析，提出一种多分辨率水平集的活动轮廓模型算法应用在乳腺核磁共振图像的癌灶分割上，避免了核磁共振图像中灰度偏移场对分割精度的影响。然而小波变换只使用灰度变化信息，忽略了局部区域信息，不能准确分割具有灰度不均匀性的目标。Kuo 等^[13] 提出基于 3 维径向梯度指数和水平集演化的边界 ACM 并成功应用于乳腺 CT 图像的病灶分割。Rodtook 等^[14] 提出一个广义梯度矢量流的边界 ACM 应用于乳腺超声图像分割。但由于乳腺 DCE-MRI 图像具有边界模糊的特性，基

于梯度信息的 ACM 很难搜索到准确边界，从而极易发生边界泄露。Xie 等^[15] 提出一种基于学生 t 分布的马尔科夫随机场 (Markov random field, MRF) 的多相水平集聚类方法对各种噪声或无噪声图像和 fMRI 时间序列影像的分割。Yang 等^[16] 利用 MRF 能量函数，代数多重网格方法和稀疏场方法，提出一种具有快速性和鲁棒性的水平集方法，应用在合成噪声图像，自然图像和医学等图像的分割。上述两篇文献是将 MRF 能量嵌入到区域 ACM 的分割方法研究，也取得了较好的分割效果，但在乳腺 DCE-MRI 图像的分割中，同时将乳腺 DCE-MRI 图像的时域特征和 MRF 能量一起融入 ACM 中，分割效果可能会更好。此外，基于深度学习的分割方法（如卷积神经网络和全卷积神经网络）也被应用在乳腺 DCE-MRI 图像的病灶分割上。基于深度学习的分割方法旨在训练图像体素的分类模型，在病灶区域，体素被视为阳性样本，其余的被视为阴性样本。Kallenberg 等^[17] 把无监督深度学习应用到乳腺癌灶分割。Rouhi 等^[18] 提出两种基于神经网络的分割方法，一是通过训练人工神经网络确定自动区域的增长阈值达到分割乳腺癌灶的目的；二是通过细胞式神经网络来执行分割，而网络的参数由遗传算法得出。Ashraf 等^[19] 使用多通道 MRF 对动态观测模型的乳腺 DCE-MRI 数据进行自动分割。

为了解决 DCE-MRI 图像中乳腺癌灶边界模糊、对比度低和亮度不均匀等问题，本文提出一种结合 MRF 能量和模糊速度函数的活动轮廓模型方法来完成乳腺癌 DCE-MRI 图像分割。主要工作包括以下两个方面：1) 通过对乳腺 DCE-MRI 图像构建二维 MRF，将图像的灰度信息转化为 MRF 能量，加强乳腺癌灶和正常腺体的区分。然后在 MRF 能量图上计算每个像素点的后验概率，构建活动轮廓模型的区域项。2) 由于乳腺癌灶具有边界模糊的特点，边界处的梯度与非边界处梯度变化并不明显，采用梯度信息构造边缘检测函数易造成边界泄露，本文避免采用梯度信息构建边缘检测函数，而是利用乳腺癌灶边界处的模糊特性计算模糊速度函数，提出结合 Gabor 纹理特征、DCE-MRI 时域特征和灰度特征的模糊聚类算法计算模型边缘检测项的模糊速度函数。当轮廓曲线位于乳腺癌灶的边界时，该模糊速度函数为零，活动轮廓曲线停止演变。

1 结合 MRF 能量和模糊速度函数的活动轮廓模型方法

为了精确分割 DCE-MRI 图像中的乳腺癌灶，本文提出一种结合 MRF 能量和模糊速度函数的活动轮廓模型的乳腺癌灶分割方法。该算法流程如图 1 所示。

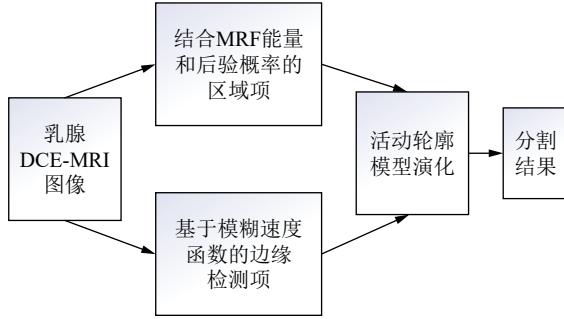


图 1 本文分割算法流程图

Fig. 1 The flowchart of segmentation algorithm in this paper

1.1 活动轮廓模型的能量函数定义

在活动轮廓模型中, 通常假设 C 是一条封闭的轮廓曲线, 曲线 C 将图像区域 Ω 划分为曲线内部区域 Ω_1 和曲线外部区域 Ω_2 . 活动轮廓模型的能量函数可定义为

$$E(C, \phi) = \mu E_1(\phi) + \lambda E_2(C) + \gamma E_3(\phi) \quad (1)$$

其中, $E_1(\phi)$ 是控制轮廓曲线演变方向的区域项, $E_2(C)$ 是控制轮廓曲线边界演化的边缘检测项, $E_3(\phi)$ 是控制轮廓曲线平滑程度的惩罚项, μ , λ 和 γ 分别是控制区域项、边缘检测项和惩罚项的权重参数, 在本文中 μ , λ 和 γ 的取值都为 1^[20]. ϕ 是水平集函数.

1.2 结合 MRF 能量和后验概率的活动轮廓模型区域项

由于 DCE-MRI 图像主要反映乳腺腺体供血变化情况, 癌灶组织通常以肿块形式散布于正常腺体中, 在图像上表现出空间聚类特性. MRF 能量在增强目标区域与背景对比度的同时, 也考虑像素间的空间相关性^[21-22]. 这一特点符合乳腺癌灶在 DCE-MRI 图像中的空间分布情况.

在计算 MRF 能量时, 通常把图像看作一个二维的 MRF, 构造 MRF 需要建立两个场: 标记场和特征场. 标记场是用来对待测图像进行分类标记; 特征场是对已分类的区域进行特征分析. 给定大小为 $M \times N$ 的图像, 内部的像素点集合用 S 表示且 $S = \{(x, y) | 1 \leq x \leq M, 1 \leq y \leq N\}$; 特征场用 $A = \{a_s, s \in S\}$ 表示, 任意像素点所对应的特征场的值为 a_s ; 标记场用 $B = \{b_s, s \in S\}$ 表示, 任意像素点所对应的标记场的值为 b_s ; 相空间用 $\Lambda = \{1, 2, \dots, L\}$ 表示, 即将图像分成 L 个区域, Λ 是标记场随机变量 b_s 的集合, 所以 $b_s \in \Lambda$. 由贝叶斯理论可得最大后验概率, 可表示为

$$\hat{B} = \arg \max_b P(B|A) = \arg \max_b \frac{P(B)P(A|B)}{P(A)} \quad (2)$$

其中, 在一幅图像中 $P(A)$ 是固定不变的, 所以式(2)可简化为

$$\hat{B} = \arg \max_b P(B|A) = \arg \max_b P(B)P(A|B) \quad (3)$$

由 Hammersley-Clifford 定理知, 式(3) 中的 $P(B)$ 可定义为

$$P(B) = \prod_{s \in S} P(b_s) = \prod_{s \in S} \frac{\exp \left(- \sum_{c \in G} W_c(b_s) \right)}{\sum_{b_s=1}^L \exp \left(- \sum_{c \in G} W_c(b_s) \right)} \quad (4)$$

其中, $W_c(b_s)$ 是包含有 b_s 的势团 c 的势函数, G 表示 s 中所有势团的集合. $W_c(b_s)$ 的建模(场建模)使用 Potts 模型. Potts 模型只考虑二元势函数, 其定义为

$$W_c(b_s) = W_2(b_x, b_y) = \begin{cases} 0, & b_x = b_y \\ \beta, & b_x \neq b_y \end{cases} \quad (5)$$

对于条件概率 $P(A|B)$ 的求解, 假设乳腺 DCE-MRI 图像像素的灰度服从混合高斯分布^[15, 23-24], 则可得到在标记场 B 条件下, 特征场 A 的条件概率 $P(A|B)$, 定义为

$$P(A|B) = \prod_{s \in S} P(a_s|b_s) = \prod_{s \in S} \frac{1}{\sqrt{2\pi}\sigma_m} \exp \left(- \frac{(a_s - \mu_m)^2}{2\sigma_m^2} \right) \quad (6)$$

其中, 参数 μ_m 和 σ_m 分别是第 m 目标区域的均值和方差, 可通过期望最大算法进行求解得到最优参数, 如下:

$$\begin{aligned} \mu_m^{(t+1)} &= \frac{\sum_{s=1}^S P(z_s = i | a_s, \theta_1^{(t)}) a_s}{\sum_{s=1}^S P(z_s = i | a_s, \theta_1^{(t)})} \\ \sigma_m^{(t+1)} &= \frac{\sum_{s=1}^S P(z_s = i | a_s, \theta_1^{(t)}) (a_s - \theta_1^{(t)})^2}{\sum_{s=1}^S P(z_s = i | a_s, \theta_1^{(t)})} \\ p(z_s = i | a_s, \theta_1^{(t)}) &= \frac{P(a_s | z_s = i, \theta_1^{(t)}) P(z_s = i | \theta_1^{(t)})}{\sum_{k=1}^L P(a_s | z_s = k, \theta_1^{(t)}) P(z_s = k | \theta_1^{(t)})} \end{aligned} \quad (7)$$

其中, $\theta_1 = (\mu_1 \cdots \mu_L, \sigma_1 \cdots \sigma_L, P(z=1) \cdots P(z=L))$, a_s 所从属的类用 z_s 表示, $P(z=i)$ 是先验概率, 有 $\sum_{i=1}^L P(z=i) = 1$. 结合式(4)和式(6), 对式(3)两边取对数, 可得

$$\begin{aligned} \hat{B} &= \arg \max_b [\ln P(B) + \ln P(A|B)] = \\ &\arg \max_b \left\{ - \sum_{c \in C} W(c)(b_s) - \left[\sum_{s \in S} \left(\ln(\sqrt{2\pi}\sigma_m) + \frac{(a_s - \mu_m)^2}{2\sigma_m^2} \right) \right] \right\} = \arg \min_b \left\{ \sum_{c \in C} W(c)(b_s) + \left[\sum_{s \in S} \left(\ln(\sqrt{2\pi}\sigma_m) + \frac{(a_s - \mu_m)^2}{2\sigma_m^2} \right) \right] \right\} = \\ &\arg \min_b (U_1(B, A) + U_2(B)) \end{aligned} \quad (8)$$

其中, $U_1(B, A)$ 为条件能量函数 (特征场能量), $U_2(B)$ 为先验能量函数 (标记场能量), 分别为

$$\begin{aligned} U_1(B, A) &= \ln P(A|B) = \\ &\sum_{s \in S} \left(\ln(\sqrt{2\pi}\sigma_m) + \frac{(a_s - \mu_m)^2}{2\sigma_m^2} \right) \\ U_2(B) &= \sum_{c \in C} W_c(b_c) \end{aligned} \quad (9)$$

则 MRF 能量可定义为

$$U(B, A) = U_1(B, A) + U_2(B) \quad (10)$$

进一步计算 MRF 能量图中每一个像素点的后验概率. 假设乳腺 DCE-MRI 图像像素的 MRF 能量服从混合高斯模型, 该模型可定义为 K 个高斯分布的线性组合, 则

$$p(x) = \sum_{k=1}^K \pi_k N(x|\mu_k, \Sigma_k) \quad (11)$$

其中, K 取 2, $N(x|\mu_k, \Sigma_k)$ 表示均值为 μ_k 、协方差为 Σ_k 的高斯分布, π_k 表示系数, 且有

$$\sum_{k=1}^K \pi_k = 1, 0 \leq \pi_k \leq 1 \quad (12)$$

假设 $W = \{w_1, w_2, \dots, w_n\}$ 是由 n 个 MRF 能量样本组成的数据集合, 这 n 个样本的对数似然函数可定义为

$$L(\theta_2) = \ln p(W|\theta_2) \quad (13)$$

其中, θ_2 是参数 $\{\pi_k, \mu_k, \Sigma_k | k \in K\}$ 的集合, 通过期望最大法求解对数似然函数的最大值, 得到最优参数 θ_2 , 表示如下:

$$\begin{aligned} \pi_k^{(t+1)} &= \frac{1}{n} \sum_{i=1}^n p_k(w_{xy}|\theta_{2k}^{(t)}) \\ \mu_k^{(t+1)} &= \frac{\sum_{i=1}^n p_k(w_{xy}|\theta_{2k}^{(t)})}{\sum_{i=1}^n p_k(k|w_{xy}, \theta_{2k}^{(t)})} \\ \Sigma_k^{(t+1)} &= \frac{\sum_{i=1}^n (w_{xy} - \mu_k^{(t+1)})^2 p_k(k|w_{xy}, \theta_{2k}^{(t)})}{\sum_{i=1}^n p_k(k|w_{xy}, \theta_{2k}^{(t)})} \end{aligned} \quad (14)$$

其中, w_{xy} 表示像素点 (x, y) 处的 MRF 能量. 则 w_{xy} 服从第 k 个高斯分量的后验概率 $p(k|w_{xy}, \theta_{2k})$ 定义为

$$p(k|w_{xy}, \theta_{2k}) = \frac{\pi_k p_k(w_{xy}|\theta_{2k})}{\sum_{k=1}^K \pi_k p_k(w_{xy}|\theta_{2k})} \quad (15)$$

则活动轮廓模型的区域项可表示为

$$E_1(\phi) = \iint_{\Omega} p(1|w_{xy}, \theta) H(\phi(x, y)) + p(2|w_{xy}, \theta) [1 - H(\phi(x, y))] dx dy \quad (16)$$

其中, $H(\cdot)$ 是 Heaviside 函数, 定义为 $H(\phi) = 0.5 \times [1 + 0.5\pi \arctan(\phi/\varepsilon)]$, 参数 ε 控制 $H(\phi)$ 从 0 上升到 1 的快慢^[25].

图 2 是乳腺图像的 MRF 能量分布图和对应的后验概率分布图, 从图 2(b) 可以看出, 由于乳腺正常腺体和乳腺癌灶具有相似的灰度值, 很难从灰度图区分正常腺体和癌灶区域. 图 2(c) 的 MRF 能量分布图可区分出正常腺体和癌灶, 但癌灶区域还存在亮度不均匀的问题. 图 2(d) 是后验概率图, 其中癌灶区域明显增强.

1.3 构建基于模糊速度的边缘检测项

结合 Gabor 纹理特征、DCE-MRI 时域特征和灰度特征, 计算图像像素的模糊隶属度并构建模糊速度函数, 将其作为模型的边缘检测函数. 利用 Gabor 函数对图像进行纹理特征的提取^[26]. 图 3 是一个乳腺 DCE-MRI 图像的 Gabor 纹理特征的分析. 图 3(a) 和图 3(b) 分别是原始的 DCE-MRI 图像和经 Gabor 滤波器后的纹理图像. 图 3(c) 和图 3(d) 分别是乳腺癌灶和正常腺体像素的纹理值. 正如图 3(c) 和图 3(d) 所示, 乳腺癌灶和正常腺体之间的纹理值存在着明显的差异, 因此可用 Gabor 特征区分乳腺癌灶和正常腺体.

对于 DCE-MRI 图像, 由于乳腺癌病灶和正常

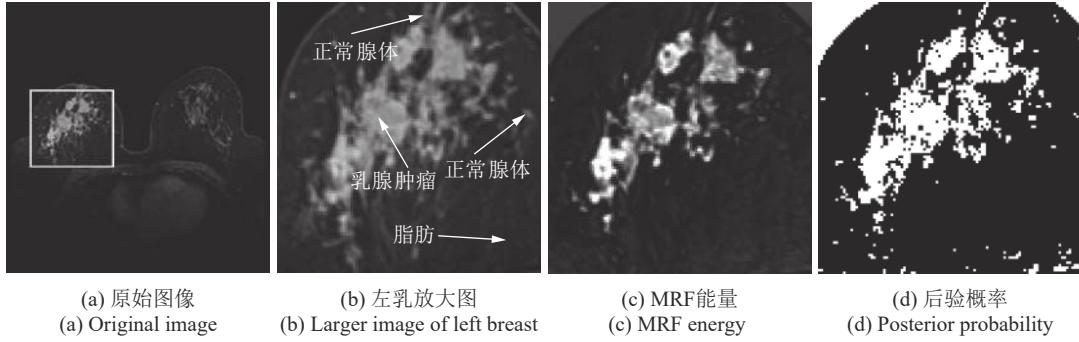


图 2 乳腺 DCE-MRI 图像的 MRF 能量和后验概率

Fig. 2 MRF energy and posterior probability of breast DCE-MRI image

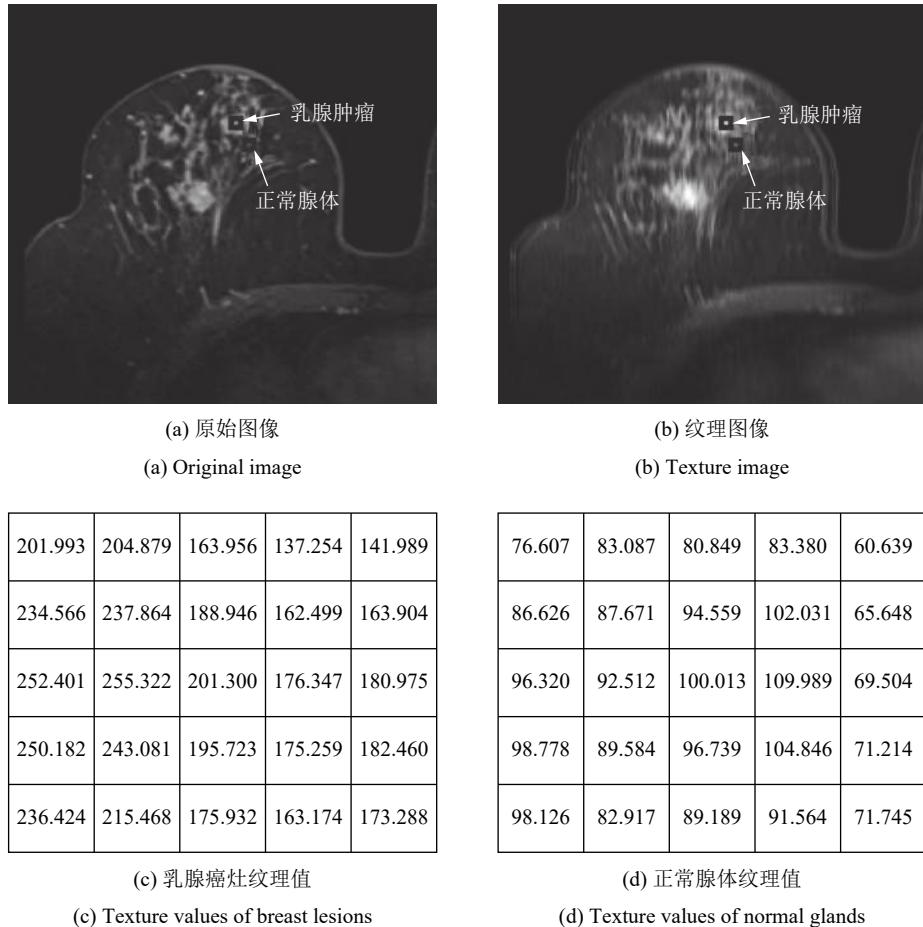


图 3 一个乳腺图像的纹理分析

Fig. 3 Texture analysis of a breast image

组织对所注射的对比剂吸收情况有差异, 乳腺癌病灶的吸收速度大于正常组织的吸收速度. 本文选取注射增强对比剂后的前中期 (T_1 期和 T_3 期) 计算信号增强比率作为 DCE-MRI 时域特征, 可表示为

$$Rate_{T1-T3} = \frac{f_{T3}(x, y) - f_{T1}(x, y)}{t} \quad (17)$$

其中, $f_{T1}(x, y)$ 和 $f_{T3}(x, y)$ 分别是 T_1 期和 T_3 期在

像素点 (x, y) 处的灰度值, t 是 T_1 期至 T_3 期的时间. 图 4 展示一个乳腺 DCE-MRI 图像的时域特征. 图 4(a) 和图 4(b) 分别是 T_1 期和 T_3 期图像, 图 4(c) 是 DCE-MRI 时域特征, 从图 4(c) 可以看出乳腺癌病灶的强化程度明显强于正常组织, 该特征有助于加强乳腺癌灶与正常组织的区别.

将 Gabor 特征、DCE-MRI 时域特征和灰度值

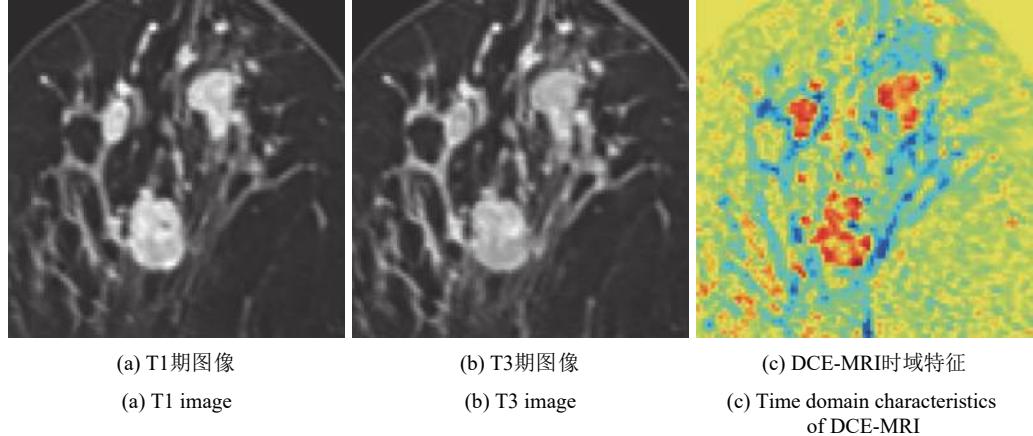


图 4 DCE-MRI 时域特征分析

Fig. 4 Time domain characteristic analysis of DCE-MRI

构成的特征向量, 利用模糊聚类算法计算每一个像素的隶属度, 从而计算模糊速度函数.

模糊聚类算法属于迭代聚类方法, 通过迭代寻找最优的目标函数, 目标函数可定义为^[27]

$$J(U, \mathbf{G}) = \sum_{l=1}^n \sum_{h=1}^2 (u_{lh})^o d^2(\mathbf{X}_l, \mathbf{G}_h) \quad (18)$$

其中, \mathbf{X}_l 由 Gabor 特征、DCE-MRI 时域特征和灰度特征构成的特征向量; $U = \{u_{lh}\}$ 是隶属度矩阵, 其大小为 $2 \times n$, u_{lh} 是向量 \mathbf{X}_l 隶属 h 类的程度; $\mathbf{G} = \{v_1, v_2\}$ 是聚类中心向量; o 是一个模糊控制常数; $d(\mathbf{X}_l, \mathbf{G}_h)$ 是 \mathbf{X}_l 和距离中心 \mathbf{G}_h 之间的距离, 该距离函数定义为

$$d(\mathbf{X}_l, \mathbf{G}_h) = \|\mathbf{X}_l - \mathbf{G}_h\| \quad (19)$$

重复计算 u_{lh} 和 \mathbf{G}_h , 使所有的特征被正确分离, 此时 $J(U, \mathbf{G})$ 目标函数达到最小值. u_{lh} 和 \mathbf{G}_h 可定义为

$$u_{lh} = \frac{1}{\sum_{k=1}^2 \left[\frac{d(\mathbf{X}_l, \mathbf{G}_h)}{d(\mathbf{X}_l, \mathbf{G}_k)} \right]^{\frac{2}{o-1}}}, \quad h = 1, 2; l = 1, 2, \dots, n$$

$$\mathbf{G}_h = \frac{\sum_{l=1}^n (u_{lh})^o \mathbf{X}_l}{\sum_{l=1}^n (u_{lh})^o}, \quad h = 1, 2 \quad (20)$$

然后, 根据 u_{lh} 构造隶属乳腺癌灶的模糊隶属度矩阵 E . 最后, 为了消除模糊隶属度矩阵中存在的噪声和保留边界信息, 采用结构元素 R 对 E 进行模糊开运算, 得到新的模糊隶属度矩阵 Z . 模糊开运算定义为

$$Z = D[F(E, R), R] \quad (21)$$

其中, F 和 D 分别为模糊腐蚀运算算子和模糊膨胀

运算算子, 其分别定义为

$$F(E, R)(x, y) =$$

$$\min \left\{ 1, \min_{(j, t) \in \mathbf{R}} [1 + u_E(x - j, y - t) - u_R(j, t)] \right\}$$

$$D(E, R)(x, y) =$$

$$\min \left\{ 0, \min_{(j, t) \in \mathbf{R}} [u_E(x - j, y - t) + u_R(j, t) - 1] \right\} \quad (22)$$

其中, $u_E(x - j, y - t)$ 是模糊矩阵 E 中的元素, $u_R(j, t)$ 是结构元素 R 中的元素. 则像素点 (x, y) 的模糊隶属度可表示为 $Z(x, y) \in (0, 1)$.

在理想的情况下, 乳腺癌灶的模糊隶属度大于 0.5, 在乳腺癌灶边界处模糊隶属度近似等于 0.5, 而背景的模糊隶属度小于 0.5. 模型的模糊速度函数需要有以下特点: 在乳腺癌灶边界处, 模糊速度函数等于零; 在远离乳腺癌灶边界处, 模糊速度函数越来越大; 在趋近乳腺癌灶边界处, 模糊速度函数越来越小. 则像素 (x, y) 的模糊速度函数可定义为

$$V(x, y) = e^{\alpha[Z(x, y) - 0.5]^2 - 1} \quad (23)$$

其中, α 为常数. 当轮廓曲线处于对象的边界时, 模糊速度函数 $V(x, y)$ 接近于零. 当轮廓曲线远离边界时, 模糊速度函数 $V(x, y)$ 越来越大. 图 5 显示某个图像 AB 段模糊速度函数的变化趋势, 可明显看到在边界 A 和 B 处模糊速度函数约等于零.

在所提出的活动轮廓模型中, 边缘检测项 $E_2(C)$ 可定义为

$$E_2(C) = \iint_{\Omega} V(x, y) \delta(\phi) |\nabla \phi| dx dy \quad (24)$$

其中, $\delta(\phi) = \frac{\varepsilon}{\pi} \frac{1}{\varepsilon^2 + \phi^2}$ 是 $H(\phi)$ 的导数.

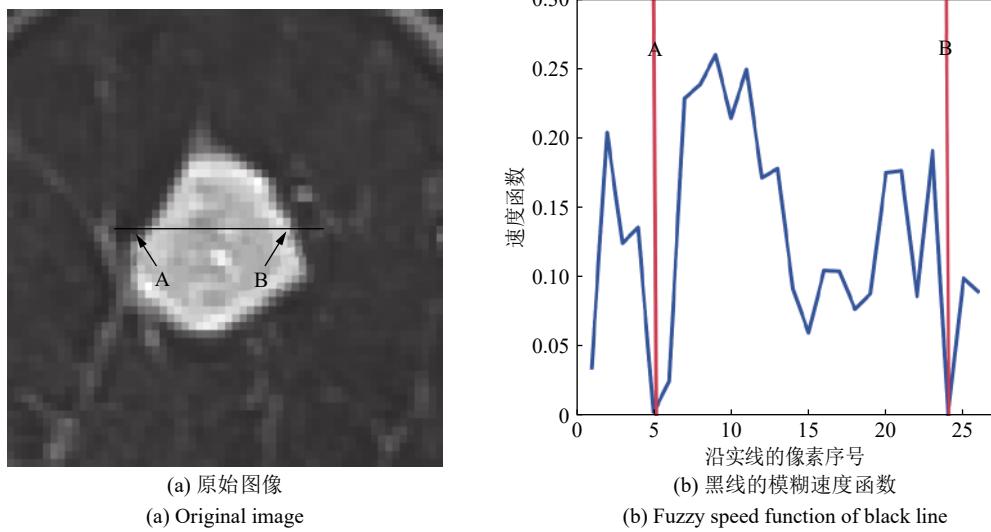


图 5 模糊速度函数

Fig. 5 Fuzzy speed function

1.4 活动轮廓模型能量泛函的构建与求解

1.4.1 构建能量泛函

将式 (16) 和式 (24) 代入式 (1) 可得到最终的活动轮廓模型的能量泛函

$$\begin{aligned} E(\phi) = & \mu \iint_{\Omega} p(1|w_{xy}, \theta) H(\phi(x, y)) + \\ & p(2|w_{xy}, \theta) [1 - H(\phi(x, y))] dx dy + \\ & \lambda \iint_{\Omega} V(x, y) \delta(\phi) |\nabla \phi| dx dy + \\ & \gamma \iint_{\Omega} \frac{1}{2} (|\nabla \phi| - 1)^2 dx dy \end{aligned} \quad (25)$$

其中, $\iint_{\Omega} \frac{1}{2} (|\nabla \phi| - 1)^2 dx dy$ 是对水平集函数 ϕ 的惩罚项, 可避免曲线演变过程中对 ϕ 进行重新初始化, ϕ 需要满足 $|\nabla \phi| = 1$, 其中 $|\nabla \phi| = \sqrt{\phi_x^2 + \phi_y^2}$.

1.4.2 求解能量泛函

乳腺癌灶的分割可归结为最小化泛函 $E(\phi)$. 首先对能量泛函 $E(\phi)$ 关于 ϕ 求变分, 为了简化表示, $p(1|w_{xy}, \theta)$ 表示为 p_1 , 相应的 $p(2|w_{xy}, \theta)$ 表示为 p_2 , 忽略变量 (x, y) , $E(\phi)$ 可简化为

$$\begin{aligned} F(\phi, \phi_x, \phi_y) = & \mu p_1 H(\phi) + \mu p_2 (1 - H(\phi)) + \\ & \lambda V \delta(\phi) \sqrt{\phi_x^2 + \phi_y^2} + \frac{1}{2} \gamma \left(\sqrt{\phi_x^2 + \phi_y^2} - 1 \right) \end{aligned} \quad (26)$$

其中, 最小化式 (25) 对应于求解如下偏微分方程

$$\frac{\partial F}{\partial \phi} - \frac{d}{dx} \left(\frac{\partial F}{\partial \phi_x} \right) - \frac{d}{dy} \left(\frac{\partial F}{\partial \phi_y} \right) = 0 \quad (27)$$

其中, F 对 ϕ , ϕ_x , ϕ_y 的偏导数可以表示为

$$\begin{aligned} \frac{\partial F}{\partial \phi} &= \mu \delta(\phi) (p_1 - p_2) + \lambda V \delta'(\phi) \sqrt{\phi_x^2 + \phi_y^2} \\ \frac{\partial F}{\partial \phi_x} &= \lambda V \delta(\phi) \frac{\phi_x}{\sqrt{\phi_x^2 + \phi_y^2}} + \gamma \left(\phi_x - \frac{\phi_x}{\sqrt{\phi_x^2 + \phi_y^2}} \right) \\ \frac{\partial F}{\partial \phi_y} &= \lambda V \delta(\phi) \frac{\phi_y}{\sqrt{\phi_x^2 + \phi_y^2}} + \gamma \left(\phi_y - \frac{\phi_y}{\sqrt{\phi_x^2 + \phi_y^2}} \right) \end{aligned} \quad (28)$$

进一步对式 (28) 求导

$$\begin{aligned} \frac{d}{dx} \left(\frac{\partial F}{\partial \phi} \right) &= \lambda \left[V \delta'(\phi) \frac{\phi_x^2}{\sqrt{\phi_x^2 + \phi_y^2}} + V \delta(\phi) \frac{\phi_x}{\sqrt{\phi_x^2 + \phi_y^2}} \right] + \\ & \gamma \frac{d}{dx} \left(\phi_x \left(1 - \frac{1}{\sqrt{\phi_x^2 + \phi_y^2}} \right) \right) \\ \frac{d}{dx} \left(\frac{\partial F}{\partial \phi_x} \right) &= \lambda \left[V \delta'(\phi) \frac{\phi_y^2}{\sqrt{\phi_x^2 + \phi_y^2}} + V \delta(\phi) \frac{\phi_y}{\sqrt{\phi_x^2 + \phi_y^2}} \right] + \\ & \gamma \frac{d}{dy} \left(\phi_y \left(1 - \frac{1}{\sqrt{\phi_x^2 + \phi_y^2}} \right) \right) \end{aligned} \quad (29)$$

同时结合

$$\begin{aligned} \frac{d}{dx} \left(\frac{\phi_x}{|\nabla \phi|} \right) + \frac{d}{dy} \left(\frac{\phi_y}{|\nabla \phi|} \right) &= \operatorname{div} \frac{\nabla \phi}{|\nabla \phi|} \\ \frac{\phi_x^2}{|\nabla \phi|} + \frac{\phi_y^2}{|\nabla \phi|} &= |\nabla \phi| \end{aligned} \quad (30)$$

将式 (28)~(30) 代入式 (27), 可得到 F 关于水平集函数 ϕ 的欧拉-拉格朗日方程

$$\begin{aligned} \mu\delta(\phi)(p_1 - p_2) - \lambda\delta(\phi)\left(\operatorname{div}\left(V\frac{\nabla\phi}{|\nabla\phi|}\right)\right) - \\ \gamma\left(\Delta\phi - \operatorname{div}\frac{\nabla\phi}{|\nabla\phi|}\right) = 0 \end{aligned} \quad (31)$$

进一步由变分原理, 可得 ϕ 的梯度下降流

$$\begin{aligned} \frac{\partial\phi}{\partial t} = -\mu\delta(\phi)(p_1 - p_2) + \lambda\delta(\phi)\left(\operatorname{div}\left(V\frac{\nabla\phi}{|\nabla\phi|}\right)\right) + \\ \gamma\left(\Delta\phi - \operatorname{div}\frac{\nabla\phi}{|\nabla\phi|}\right) \end{aligned} \quad (32)$$

2 分割结果评价标准

在对比算法中, 金标准由影像科医生提供。医生首先在 DCE-MRI 图像中执行自动阈值的预分割, 然后通过观察 DCE-MRI 剪影图像, 再对肿瘤区域进行手动调整, 最终获得的肿瘤区域作为金标准。分割精度通过对算法分割结果与医生手动分割结果进行比较得到, 分别采用阳性率 (True positive ratio)、假阳性率 (False positive ratio) 和相似度 (Similarity degree) 三个指标来进行评价

$$\begin{aligned} R_{TP} &= \frac{|A_m \cap A_a|}{A_m} \\ R_{FP} &= \frac{|A_m \cup A_a - A_m|}{A_m} \\ D_S &= \frac{|A_m \cap A_a|}{|A_m \cup A_a|} \end{aligned} \quad (33)$$

其中, A_m 是医生手动分割区域, A_a 是分割方法获取的区域。 R_{TP} 反映的是算法分割区域对医生手动分割区域的覆盖率, 值越大, 说明分割效果越好。 R_{FP} 反映的是算法分割区域的背景区域对医生手动分割区域的占比, 值越小, 说明算法分割的区域包含更少的背景区域。当 D_S 值比较大时, 说明分割方法获取的区域与医生手动分割区域非常形似。

3 分割结果

为了验证本文所提方法的有效性, 采用中山大学附属江门市中心医院的临床数据进行验证分析。本次研究所使用的仪器设备主要为西门子 MAGNETO MESSENZA 1.5T MRA; 同时还有 4 通道乳腺专用的相控阵表面线圈。所有患者均处于俯卧位。使用 T1 加权脂肪抑制快速激发梯度回波采集双乳横轴位的 DCE 图像 (TR/TE: 4.6/1.7; 翻转角: 7 度; FOV: 280 × 340 mm; 矩阵大小: 280 × 340; 截面厚度/间隙: 1.0/0 mm; 扫描时间: 75 s)。

将所提出方法与结合二值水平集和形态学的分割方法^[28]、基于区域的 ACM、基于局部高斯能量的 ACM、基于 MRF 的区域 ACM^[29]、基于边界的 ACM、

深度学习框架中的 U-net 和 V-net 网络进行对比分析。V-net 和 U-net 使用的都是基础模型, V-net 的参数设置如下: batch_size = 10, 学习率 = 0.001, 迭代次数 = 400 000, 损失函数为 dice coefficient, 迭代终止条件是迭代次数; U-net 的参数设置如下: batch_size = 10, 学习率 = 0.00001, 迭代次数 = 10 000, 损失函数为 binary crossentropy, 迭代终止条件是迭代次数。其中共使用 2 255 幅乳腺 DCE-MRI 图像进行 V-net 和 U-net 网络的训练, 测试集共 50 幅乳腺 DCE-MRI 图像。V-net 和 U-net 在训练集中的表现如表 1 所示, 可以看出 U-net 出现了过分割的现象, V-net 的表现较好。

表 1 V-net 和 U-net 训练集结果
Table 1 Results of V-net and U-net in training sets

分割 算法	R_{TP} (均值±标准差)	R_{FP} (均值±标准差)	D_S (均值±标准差)
U-net	0.9706±0.1189	0.6673±0.6662	0.6252±0.1456
V-net	0.9408±0.0637	0.0732±0.1287	0.8836±0.0917

3.1 肿块型乳腺癌分割结果

首先验证算法对肿块型乳腺癌的分割性能。由影像科医生选择 5 个典型的肿块型乳腺癌 DCE-MRI 图像进行分析。如图 6 所示, 所提出方法对乳腺癌灶的分割结果更接近于医生手动分割的结果, 优于其余 7 种方法。图 6(b) 展示结合二值水平集和形态学分割方法的结果, 可以发现受周围正常腺体的影响, 得到的乳腺癌灶边界朝周围腺体发生泄漏。图 6(c) 和图 6(d) 展示基于边界的 ACM 和基于局部高斯能量的 ACM 的结果, 可以看出受到乳房边缘和周围腺体的影响, 分割结果无法正常收敛甚至把乳房边缘错认为乳腺癌灶边界。图 6(e) 展示基于区域的 ACM 的结果, 由于癌灶内部存在亮度不均匀, 也影响了最终分割的准确性。图 6(f) 展示基于 MRF 的区域 ACM 的结果, 由于癌灶边界具有模糊特性, 分割结果存在欠分割问题。图 6(g) 和图 6(h) 分别展示 U-net 和 V-net 的分割结果, 也存在误分割的情况。对比图 6(a) 和图 6(i), 可以明显看出所提出方法得到的分割结果更接近于医生手动分割结果。

3.2 非肿块型乳腺癌分割结果

部分乳腺癌在 DCE-MRI 图像上表现为非肿块型, 且肿瘤区域与正常腺体组织往往交错存在。为了进一步验证算法性能, 由影像科医生从临床数据中选择了 10 个典型的非肿块型乳腺癌进行分割。从图 7(b) 和图 7(c) 可以看出, 由于乳腺癌灶和周围腺体组织具有极相近的对比度, 结合二值水平集和形态学的分割方法和基于边界的 ACM 的结果包

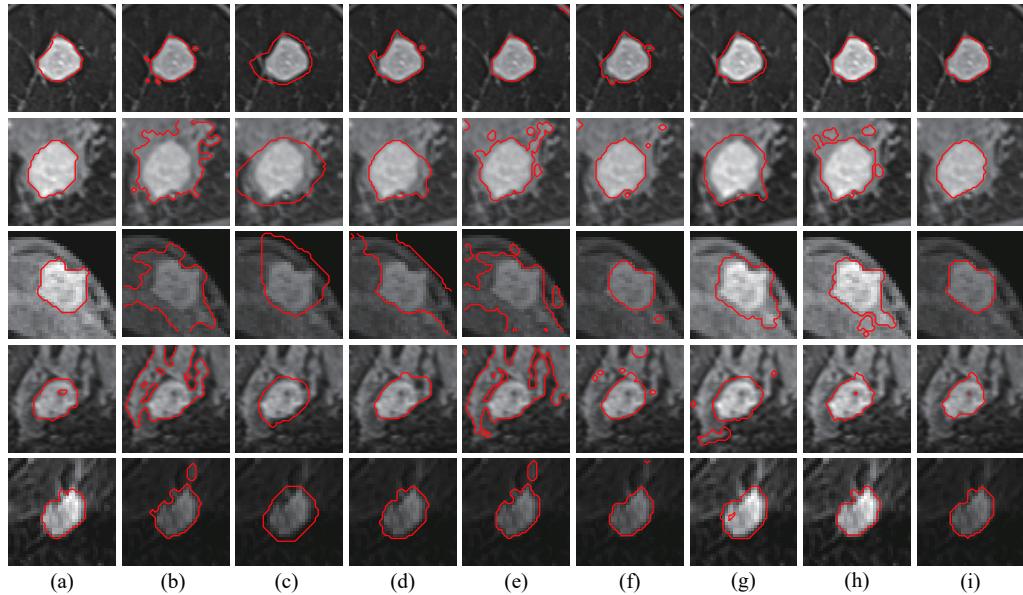


图 6 肿块形乳腺癌灶分割结果 ((a) 医生手动分割; (b) 结合二值水平集和形态学的分割方法; (c) 基于边界的 ACM; (d) 基于局部高斯能量的 ACM; (e) 基于区域的 ACM; (f) 基于 MRF 的区域 ACM; (g) U-net; (h) V-net; (i) 本文方法)

Fig. 6 Tumor-shaped breast lesion segmentation results ((a) Expert manual segmentation; (b) Segmentation method based on binary level set and morphological operation; (c) Edge-based ACM; (d) ACM based on local Gaussian energy; (e) Region-based ACM; (f) Regional ACM based on MRF; (g) U-net; (h) V-net; (i) The method in this paper)

含了较多的正常腺体，算法不能稳定收敛，出现了边界泄漏问题。图 7(d) 展示基于局部高斯能量的 ACM，也无法得到正确的分割结果。图 7(e) 展示基于区域的 ACM 和图 7(f) 展示基于 MRF 的区域 ACM，也无法分割低对比度下的乳腺癌灶，发生了边界泄漏。图 7(g) 和图 7(h) 分别展示 U-net 和 V-net 的分割结果。图 7(a) 和图 7(i) 对比，只有本文所提出方法提取出的乳腺癌灶更接近于医生手动分割结果。

对于基于局部高斯能量的 ACM 方法不能精确分割乳腺癌灶的原因主要是：将非负的核函数 $K(\cdot)$ 引入到 ACM 中。当局部窗口的大小取值不合适时，非负的核函数 $K(\cdot)$ 不能显著的减小为零，因此基于局部高斯能量的 ACM 会引起轮廓边界的泄露；对于基于边界的 ACM，当图像中的癌灶有较深的凹陷边界时，曲线 C 在这一局部的曲率必将是负的，模型可能使轮廓曲线 C 停止在使能量泛函局部最小的状态。

对于基于区域 ACM 和结合二值水平集和形态学的分割方法不能精确分割乳腺癌灶的原因主要是：1) 在乳腺癌灶和腺体之间具有非常相近的灰度值，在轮廓曲线演变时仅使用了图像的灰度信息而并没有考虑乳腺癌灶的局部形状信息，因此发生边界泄漏。2) 乳腺癌灶成分和周围腺体之间具有较低的对比度，使用梯度计算边界检测函数，无法准确检测低对比度下的癌灶边界，从而导致边界泄露。

而基于 MRF 的区域 ACM 并没有用到边界信息，所以对于模糊边界的癌灶存在欠分割。另外，深度学习框架 U-net 和 V-net 方法也取得了不错的分割结果，但是在有些图像样本上也出现了边界泄露问题，特别是在非肿块形的乳腺癌灶中分割结果不理想。原因可能是：1) 基于深度学习的分割算法是基于数据驱动的分割方法，无法加入有效的临床先验信息（如 DCE-MRI 图像的动态信息），导致分割效果有效；2) 乳腺 DCE-MRI 图像中存在严重的类平衡问题（病灶区域中的体素数（正类）远小于背景中的体素数（负类）），并且图像中混杂着多种背景（如血管结构、正常腺体等），导致算法的鲁棒性较差。

为了进一步验证算法性能，继续选择了 50 例乳腺癌临床样本。分别用 R_{TP} 、 R_{FP} 、 D_S 的平均值作为评价指标，对比了 7 种不同分割方法在 50 个临床样本中的分割结果。结果如表 2 所示，所提出方法能够较好地将乳腺癌灶分割出来，结合二值水平集和形态学的分割方法，基于边界的 ACM，基于局部高斯能量的 ACM，基于区域 ACM 方法和 U-net 方法虽然得到了更好的 R_{TP} 值，但 R_{FP} 值太大且 D_S 值太小，说明分割得到的结果含有大量背景。虽然所提出方法得到的 R_{TP} 值只达到了 92.97%，但在 R_{FP} 指标中，本文所提出方法分割得到的结果包含的背景最少 ($R_{FP} = 3.37\%$)。在 D_S 指标中，所提出方法与医生手动分割结果外形最相似 ($D_S = 89.96\%$)。

为了分析算法在医学应用的可行性，对算法进

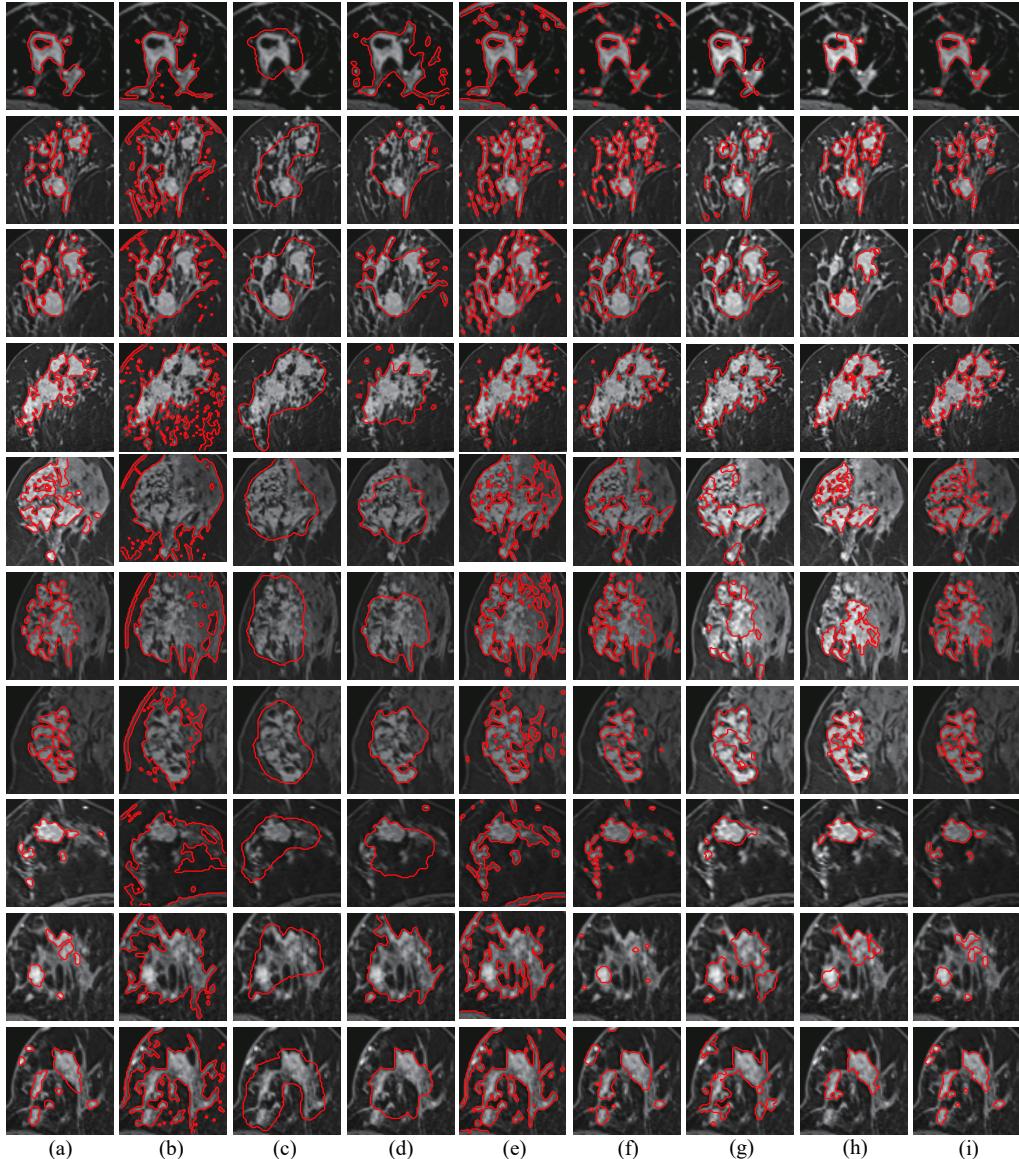


图 7 非肿块形乳腺癌灶分割结果 ((a) 医生手动分割; (b) 结合二值水平集和形态学的分割方法; (c) 基于边界的 ACM; (d) 基于局部高斯能量的 ACM; (e) 基于区域的 ACM; (f) 基于 MRF 的区域 ACM; (g) U-net; (h) V-net; (i) 本文方法)

Fig. 7 Non tumor-shaped breast lesion segmentation results ((a) Expert manual segmentation; (b) Segmentation method based on binary level set and morphological operation; (c) Edge-based ACM; (d) ACM based on local gaussian energy; (e) Region-based ACM; (f) Regional ACM based on MRF; (g) U-net; (h) V-net; (i) The method in this paper)

行时间复杂度的分析。表 3 展示了各个对比算法的时间复杂度和分割 50 个临床样本的平均执行时间 (U-net 和 V-net 只考虑分割 50 个临床样本的时间)。从表 3 中看出, 本文方法的时间复杂度为 $O(n^2)$, 平均执行时间为 4.6575 s, 耗时略高于其余方法, 但在可接受范围之内。

4 结论

为了在 DCE-MRI 图像上精确分割乳腺癌灶, 提出一种结合 MRF 能量和模糊速度函数的活动轮廓模型方法。通过对乳腺 DCE-MRI 图像构建二维

MRF, 将图像的灰度信息转化为 MRF 能量, 并在 MRF 能量的基础上计算每个像素点的后验概率, 构建活动轮廓模型的区域项, 在增强乳腺癌灶和正常组织差异时, 也考虑了乳腺癌灶在 DCE-MRI 上的空间聚类特性。对于乳腺癌灶边缘模糊的问题, 放弃了基于梯度的边界检测函数构建方式, 转而结合乳腺 DCE-MRI 时域特征、灰度特征和 Gabor 纹理特征来计算模糊速度函数, 并将其作为边缘检测函数。当轮廓曲线位于乳腺癌灶的边界时, 该模糊速度函数为零, 活动轮廓模型停止演变。通过对临床数据的验证分析, 发现本文所提出方法从乳腺

表2 50个临床样本分割结果
Table 2 Segmentation results of 50 clinical samples

分割算法	R_{TP} (均值±标准差)	R_{FP} (均值±标准差)	D_S (均值±标准差)
结合二值水平集和形态学的分割方法	0.9759±0.0276	0.9100±1.6139	0.6910±0.2537
基于边界的ACM	0.9676±0.0551	0.6270±0.4238	0.5146±0.2272
基于局部高斯能量的ACM	0.9548±0.0818	0.8368±1.0217	0.6147±0.2040
基于区域的ACM	0.9892±0.0135	1.0604±1.0193	0.5857±0.2357
基于MRF的区域ACM	0.8709±0.1178	0.2018±0.3271	0.7524±0.1438
U-net	0.9389±0.1156	0.5988±0.3772	0.6143±0.1456
V-net	0.8762±0.1408	0.1131±0.0961	0.7920±0.1402
本文方法	0.9297±0.0413	0.0337±0.0222	0.8996±0.0410

表3 算法的时间复杂度
Table 3 Time complexity of the algorithm

分割算法	时间复杂度	平均执行时间 (s)
结合二值水平集和形态学的分割方法	$O(n)$	3.3500
基于边界的ACM	$O(n)$	3.2550
基于局部高斯能量的ACM	$O(n)$	3.6790
基于区域的ACM	$O(n)$	1.1188
基于MRF的区域ACM	$O(n^2)$	2.7925
U-net	$O(n)$	1.6102
V-net	$O(n)$	3.3669
本文方法	$O(n^2)$	4.6575

DCE-MRI 图像中分割得到的边界更接近于医生给出的结果。下一步，我们将探索将深度学习方法和活动轮廓模型方法进行结合，拟进一步提高乳腺癌 DCE-MRI 图像分割的准确性。

References

- Fitzmaurice C, Akinyemiju T F, Al Lami F H, Alam T, Alizadeh-Navaei R, Allen C, et al. Global, regional, and national cancer incidence, mortality, years of life lost, years lived with disability, and disability-adjusted life-years for 29 cancer groups, 1990 to 2016: A systematic analysis for the global burden of disease study. *JAMA Oncology*, 2018, 4(11): 1553–1568
- Uematsu T, Kasami M, Watanabe J. Is evaluation of the presence of prepectoral edema on T2-weighted with fat-suppression 3 T breast MRI a simple and readily available noninvasive technique for estimation of prognosis in patients with breast cancer? *Breast Cancer*, 2014, 21(6): 684–692
- Cheon H, Kim H J, Lee S M, Cho S H, Shin K M, Kim G C, et al. Preoperative MRI features associated with lymphovascular invasion in node-negative invasive breast cancer: A propensity-matched analysis. *Journal of Magnetic Resonance Imaging*, 2017, 46(4): 1037–1044
- Fasihi M S, Mikhael W B. Overview of current biomedical image segmentation methods. In: Proceedings of the 2016 International Conference on Computational Science and Computational Intelligence. Las Vegas, USA: IEEE, 2016. 803–808
- van Dijk N P, Maute K, Langelaar M, van Keulen F. Level-set methods for structural topology optimization: A review. *Structural and Multidisciplinary Optimization*, 2013, 48(3): 437–472
- Ma Chao, Liu Ya-Shu, Luo Gong-Ning, Wang Kuan-Quan. Combining concatenated random forests and active contour for the 3D MR images segmentation. *Acta Automatica Sinica*, 2019, 45(5): 1004–1014
(马超, 刘亚淑, 骆功宁, 王宽全. 基于级联随机森林与活动轮廓的3D MR 图像分割. 自动化学报, 2019, 45(5): 1004–1014)
- Sun Wen-Yan, Dong En-Qing, Cao Zhu-Lou, Zheng Qiang. A robust local segmentation method based on fuzzy-energy based active contour. *Acta Automatica Sinica*, 2017, 43(4): 611–621
(孙文燕, 董恩清, 曹祝楼, 郑强. 一种基于模糊主动轮廓的鲁棒局部分割方法. 自动化学报, 2017, 43(4): 611–621)
- Zhang K H, Zhang L, Lam K M, Zhang D. A level set approach to image segmentation with intensity inhomogeneity. *IEEE Transactions on Cybernetics*, 2016, 46(2): 546–557
- Rouhi R, Jafari M. Classification of benign and malignant breast tumors based on hybrid level set segmentation. *Expert Systems with Applications*, 2016, 46: 45–59
- Zhang Xu-Mei, Fan Hong, Qiao Zhu. Level set method combined global and local information and its application to breast MRI. *Application Research of Computers*, 2015, 32(1): 307–311
(张旭梅, 范虹, 乔柱. 融合全局和局部信息的水平集乳腺 MR 图像分割. 计算机应用研究, 2015, 32(1): 307–311)
- Yu Hong-Wei, Li Li-Hua, Xu Wei-Dong, Liu Wei, Zhang Juan, Shao Guo-Liang. Multi-scale approach for breast mass segmentation using level set method. *Chinese Journal of Scientific Instrument*, 2010, 31(6): 1418–1423
(虞红伟, 厉力华, 徐伟栋, 刘伟, 张娟, 邵国良. 一种基于水平集的多尺度乳腺肿块分割方法. 仪器仪表学报, 2010, 31(6): 1418–1423)
- Fan Hong, Zhu Yan-Chun, Wang Fang-Mei, Zhang Xu-Mei. Segmentation of breast MR images based on multiresolution level set algorithm. *Acta Physica Sinica*, 2014, 63(11): Article No.118701
(范虹, 朱艳春, 王芳梅, 张旭梅. 多分辨率水平集算法的乳腺 MR 图像分割. 物理学报, 2014, 63(11): Article No.118701)
- Kuo H C, Giger M L, Reiser I, Boone J M, Lindfors K K, Yang K, et al. Level set segmentation of breast masses in contrast-enhanced dedicated breast CT and evaluation of stopping criteria. *Journal of Digital Imaging*, 2014, 27(2): 237–247
- Rodtook A, Makhanov S S. Multi-feature gradient vector flow snakes for adaptive segmentation of the ultrasound images of breast cancer. *Journal of Visual Communication and Image Representation*, 2013, 24(8): 1414–1430
- Xie Q Y, Pan X, Zhu H Q. A multiphase level set clustering approach using MRF-based Student's-t mixture model. In: Proceedings of the 8th International Conference on Wireless Communications and Signal Processing. Yangzhou, China: IEEE, 2016. 1–5
- Yang X, Gao X B, Tao D C, Li X L, Li J. An efficient MRF embedded level set method for image segmentation. *IEEE Transactions on Image Processing*, 2015, 24(1): 9–21
- Kallenberg M, Petersen K, Nielsen M, Ng A Y, Diao P F, Igel C, et al. Unsupervised deep learning applied to breast density segmentation and mammographic risk scoring. *IEEE Transactions on Medical Imaging*, 2016, 35(5): 1322–1331
- Rouhi R, Jafari M, Kasaei S, Keshavarzian P. Benign and malignant breast tumors classification based on region growing and CNN segmentation. *Expert Systems with Applications*, 2015, 42(3): 990–1002
- Ashraf A B, Gavenonis S, Daye D, Mies C, Feldman M, Rosen M, et al. A multichannel Markov random field approach for automated segmentation of breast cancer tumor in DCE-MRI data using kinetic observation model. In: Proceedings of the 14th International Conference on Medical Image Computing and Computer-Assisted Intervention. Toronto, Canada: Springer,

2011. 546–553
- 20 Achuthan A, Rajeswari M, Ramachandram D, Aziz M E, Shuaib I L. Wavelet energy-guided level set-based active contour: A segmentation method to segment highly similar regions. *Computers in Biology and Medicine*, 2010, **40**(7): 608–620
- 21 Shahvaran Z, Kazemi K, Helfroush M S, Jafarian N, Noorizadeh N. Variational level set combined with Markov random field modeling for simultaneous intensity non-uniformity correction and segmentation of MR images. *Journal of Neuroscience Methods*, 2012, **209**(2): 280–289
- 22 Song Yan-Tao, Ji Ze-Xuan, Sun Quan-Sen. Brain MR image segmentation algorithm based on Markov random field with image patch. *Acta Automatica Sinica*, 2014, **40**(8): 1754–1763 (宋艳涛, 纪则轩, 孙权森. 基于图像片马尔科夫随机场的脑 MR 图像分割算法. 自动化学报, 2014, **40**(8): 1754–1763)
- 23 Li B, Chen K, Peng G M, Guo Y X, Tian L F, Ou S X, et al. Segmentation of ground glass opacity pulmonary nodules using an integrated active contour model with wavelet energy-based adaptive local energy and posterior probability-based speed function. *Materials Express*, 2016, **6**(4): 317–327
- 24 Zhang Zhe, Han De-Qiang, Yang Yi. Image segmentation based on evidential Markov random field model. *Control and Decision*, 2017, **32**(9): 1607–1613 (张喆, 韩德强, 杨艺. 基于证据马尔可夫随机场模型的图像分割. 控制与决策, 2017, **32**(9): 1607–1613)
- 25 Li C M, Kao C Y, Gore J C, Ding Z H. Minimization of region-scalable fitting energy for image segmentation. *IEEE Transactions on Image Processing*, 2008, **17**(10): 1940–1949
- 26 Khan S, Hussain M, Aboalsamh H, Mathkour H, Bebis G, Zakkariah M. Optimized Gabor features for mass classification in mammography. *Applied Soft Computing*, 2016, **44**: 267–280
- 27 Kwedlo W. A new random approach for initialization of the multiple restart EM algorithm for Gaussian model-based clustering. *Pattern Analysis and Applications*, 2015, **18**(4): 757–770
- 28 Zheng Qiang, Dong En-Qing. A new local segmentation method based on binary level set and morphological operation. *Journal of Electronics and Information Technology*, 2012, **34**(2): 375–381 (郑强, 董恩清. 一种新的基于二值水平集和形态学的局部分割方法. 电子与信息学报, 2012, **34**(2): 375–381)
- 29 Xu J, Monaco J P, Madabhushi A. Markov random field driven region-based active contour model (MaRACel): Application to medical image segmentation. In: Proceedings of the 13th International Conference on Medical Image Computing and Computer-Assisted Intervention. Beijing, China: Springer, 2010. 197–204



冯 宝 2014 年获华南理工大学博士学位. 现为中山大学博士后. 主要研究方向为机器学习, 模式识别及其在生物医学信号处理中的应用.

E-mail: fengbao1986.love@163.com

(FENG Bao Received his Ph.D. degrees from South China University of Technology in 2014. Now, he is a postdoctoral fellows at Sun Yat-sen University. His research interest covers machine learning, pattern recognition and their application in biomedical signal processing.)



陈业航 桂林电子科技大学研究生. 主要研究方向为生物医学信号处理与模式识别.

E-mail: cyh93yl@163.com

(CHEN Ye-Hang Master student at Guilin University of Electronic Technology. His research interest covers biomedical signal processing and pattern recognition.)



刘壮盛 广东省江门市中心医院副主任医师. 2010 年获中山大学影像医学与核医学硕士学位. 主要研究方向为乳腺及骨骼肌肉系统影像诊断.

E-mail: zhuangshengliu@126.com

(LIU Zhuang-Sheng Associate professor of Jiangmen Central Hospital.

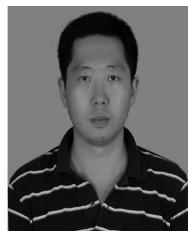
He received his master degree from Sun Yat-sen University in 2010. His research interest covers breast and musculoskeletal medical imaging diagnosis.)



李 智 2003 年获电子科技大学博士学位. 桂林航天工业学院教授. 主要研究方向为智能仪器系统, 现代测试理论与技术.

E-mail: cclizhi@guet.edu.cn

(LI Zhi Received his Ph.D. degree from University of Electronic Science and Technology of China in 2003. Now, he is a professor at Guilin University of Aerospace Technology. His research interest covers intelligent instrument systems, modern testing theory and technology.)



宋 嶸 2006 年获中国香港理工大学生物医学工程博士学位. 现为中山大学生物医学工程学院教授. 主要研究方向为肌肉骨骼建模, 生物医学信号处理, 人体运动分析和机器人辅助中风康复.

E-mail: songrong@mail.sysu.edu.cn

(SONG Rong Received his Ph.D. degree in biomedical engineering from Hong Kong Polytechnic University, China, in 2006. He is currently a professor at the School of Biomedical Engineering, Sun Yat-sen University. His research interest covers musculoskeletal modeling, biomedical signal processing, human motion analysis, and robot-assisted stroke rehabilitation.)



龙晚生 广东省江门市中心医院主任医师. 1990 年获四川大学放射诊断硕士学位. 主要研究方向为腹部影像鉴别诊断. 本文通信作者.

E-mail: jmlws2@163.com

(LONG Wan-Sheng Professor of Jiangmen Central Hospital. He received his master degree in radiological diagnosis from Sichuan University in 1990. His research interest covers differential diagnosis of abdominal imaging. Corresponding author of this paper.)