

基于局部熵的区域活动轮廓图像分割模型

李梦¹, 詹毅¹, 王艳²

(1. 重庆工商大学数学与统计学院, 重庆 400067; 2. 重庆师范大学数学科学学院, 重庆 401331)

摘要: 为解决区域活动轮廓模型不能有效分割灰度不均图像的问题, 提出了局部熵约束的区域活动轮廓模型应用于图像分割。首先基于局部熵信息将图像划分为两个特征区域, 然后利用局部熵特征信息构造二值拟合能量, 并与区域可放缩拟合 (Region-scalable fitting, RSF) 模型相结合, 最后得到水平集演化方程。该模型考虑了图像灰度分布的聚集特征和局部区域统计信息, 能有效处理灰度不均匀、弱边缘等图像分割问题, 且对轮廓初始位置更具鲁棒性, 医学图像实验结果验证了模型的有效性。

关键词: 图像分割; 二值拟合; 局部熵; 区域活动轮廓模型; 能量泛函

中图分类号: TP391 **文献标志码:** A

Regional Active Contour Image Segmentation Model Based on Local Entropy

LI Meng¹, ZHAN Yi¹, WANG Yan²

(1. School of Mathematics and Statistics, Chongqing Technology and Business University, Chongqing 400067, China; 2. School of Mathematical Science, Chongqing Normal University, Chongqing 401331, China)

Abstract: To solve the problem that the regional active contour model cannot effectively segment weak targets, a regional active contour model with local entropy constraints is proposed for image segmentation. Firstly, the image is divided into two feature regions based on local entropy information. Then a local entropy binary fitting energy is constructed by using local entropy feature information, and finally a level set evolution equation is obtained, which is combined with a region-scalable fitting (RSF) model. The model considers the clustering characteristics of the gray distribution and the statistical information of the local area of the image, and it is effective in handling intensity inhomogeneity, weak edge segmentation, and flexible contour initialization. Medical image experiment results verify the effectiveness of the proposed model.

Key words: image segmentation; binary fitting; local entropy; regional active contour model; energy functional

引言

图像分割是图像处理到图像分析的重要步骤, 其目的是将图像根据需要划分为不同区域, 以便于完成图像识别和目标跟踪等高级任务。而医学图像, 如血管造影、乳腺超声等图像受光衰减、人体组织干扰等影响, 往往具有高噪声、目标模糊以及图像灰度不均等特征, 精确的图像分割尤为困难。

传统图像分割方法主要有阈值法^[1]、区域增长法^[2]、小波变换^[3]、基于水平集方法的几何活动轮廓模型^[4]等,它们利用图像灰度、几何变化等特征直接对单帧或多帧图像数学建模,基于模型求解实现图像的简单分割,因此具有计算量小、实现简单、稳定性好、单个目标分割精确等优点,但由于其结果不依赖于人工标记和数据集的特征训练,因此很难实现复杂场景下自然图像的语义分割。近年来随人工智能发展而高度发展的深度网络包含丰富的语义信息,被广泛应用于复杂场景的医学图像分割,如文献[5]采用卷积神经网络(Convolutional neural networks, CNN)模型实现超声图像的肝脏分割;文献[6]采用多尺度全卷积神经网络(Fully convolutional networks, FCN)实现乳腺癌等病理图像分割;文献[7]采用生成对抗网络(Generative adversarial networks, GAN)实现MRI图像的脑肿瘤分割。这些模型的分割结果依赖于耗时耗力的数据集标记和样本学习,使其难于实时分割应用场景,且当训练样本不够时模型不能对目标规律进行无偏差估计,将导致分割结果的不准确。为克服分割不精确问题,一些研究将深度网络与几何活动轮廓模型相结合,如文献[8]先采用UNet网络粗略提取不同阶段的乳腺肿瘤特征,再利用水平集方法实现目标分割;文献[9]采用监督学习方法解决水平集方法的自动初始化问题,用于动脉粥样硬化斑块自动分割。这些方法通过深度学习获取图像语义特征,使得活动轮廓模型分割更有目的性,分割结果也更加精确。本文关注几何活动轮廓模型的改进,目的是解决水平集方法不能有效分割低对比度且灰度不均医学图像问题,提高模型对噪声的鲁棒性,该研究一方面可满足医学手术等实时需要,另一方面也可以和深度网络相结合,构造组合模型用于复杂场景医学目标的精准分割。

几何活动轮廓模型^[10-14]是20世纪80年代发展的非线性图像分割方法,它利用水平集函数的零水平集隐式描述演化曲线,通过偏微分方程的求解或能量泛函的极小获取目标边缘,其最大优点是能高效数值计算和有效处理复杂轮廓的拓扑变化。几何活动轮廓模型包含边缘模型^[10-11]和区域模型^[12-14]两类。边缘模型使用图像梯度等构造边缘停止函数约束曲线向目标边缘运动,但对噪声和初始位置敏感;区域模型使用图像全局或局部统计性质建模,如Chan和Vese^[12]利用全局均值二值拟合构造CV模型,能较好分割无明显边缘特征的图像,但不能有效分割灰度不均图像,且对初始位置敏感;Li等^[14]利用高斯核函数卷积实现图像局部信息的二值拟合,提出区域可放缩拟合(Region-scalable fitting, RSF)模型,它能有效分割灰度不均医学图像,因此其改进模型被广泛应用于生物医学领域^[15-17],但RSF模型对噪声敏感,不能有效分割噪声弱目标图像。

针对以上问题,本文利用图像熵的灰度分布聚集特征,提出基于局部熵的区域活动轮廓模型应用于图像分割。事实上已有基于图像熵的活动轮廓模型^[18-20],如Wang等^[18]利用局部熵加权RSF能量,提出双边强度拟合(Bilateral intensity fitting, BIF)模型,使得其在分割灰度不均图像时对初始位置更加鲁棒,但其每次运算都要双边滤波,导致时间效率不高。与这些方法不同,本文先设计基于图像局部熵的特征区域划分,再构造基于局部熵特征区域信息的二值拟合能量,并与RSF模型的能量泛函结合,通过能量泛函的最小,得到图像分割的水平集演化模型。本文模型的优点是二值拟合模型既考虑了图像灰度分布的聚集特征,又考虑了图像局部区域的统计信息,使得模型能够有效分割有噪声的灰度不均弱目标图像,并对演化曲线的初始位置鲁棒。

1 知识背景

1.1 CV模型^[12]

设 $\Omega \subset \mathbf{R}^2$ 是图像域, $I: \Omega \rightarrow \mathbf{R}$ 是输入图像, $\phi: \Omega \rightarrow \mathbf{R}$ 是水平集函数,CV模型为

$$E^{\text{CV}}(\phi, c_1, c_2) = \lambda_1 \int_{\Omega} |I(x) - c_1|^2 H(\phi(x)) dx + \lambda_2 \int_{\Omega} |I(x) - c_2|^2 (1 - H(\phi(x))) dx + \nu L(\phi) \quad (1)$$

式中: $\lambda_1, \lambda_2, \nu > 0$ 为常数, $H(\phi)$ 为 Heaviside 函数, c_1 和 c_2 分别为演化曲线 $\phi = 0$ 的内部和外部灰度均值, 其值随着曲线演化而迭代更新, 即 $c_i = \frac{\int_{\Omega} I(x) M_i(\phi) dx}{\int_{\Omega} M_i(\phi) dx}$, 其中 $M_1(\phi) = H(\phi), M_2(\phi) = 1 - H(\phi)$ 。

式(1)前两项的最小使得曲线 C 内部和外部灰度均值分别逐渐逼近于目标和背景的平均灰度, 从而实现图像分割, 第3项为长度正则项, 其最小可避免演化曲线产生不光滑现象。该模型的优点是可以分割无明显边缘特征目标, 但由于它使用的是演化曲线内和外图像灰度均值, 所以当图像表现为灰度不均时, 真实图像数据与均值 c_1 和 c_2 差别较大, 会导致曲线演化的错误, 以至于不能分割灰度不均图像, 且对初始位置敏感。

1.2 RSF 模型^[14]

为使模型能够分割灰度不均图像, Li 等^[14]引入高斯核函数实现图像局部信息拟合, 即

$$\epsilon_x^{\text{RSF}}(\phi, f_1, f_2) = \sum_{i=1}^2 \lambda_i \int_{\Omega} K_{\sigma}(x-y) |I(y) - f_i(x)|^2 M_i(\phi) dy \quad (2)$$

式中: $\lambda_1, \lambda_2 > 0$ 为常数, $K_{\sigma}(x-y)$ 是标准差为 σ 的高斯核函数, $f_i(x)$ 是演化曲线内和外的加权灰度平均值。RSF 模型定义为

$$E^{\text{Fit}}(\phi) = E^{\text{RSF}}(\phi) + \nu L(\phi) + \mu P(\phi) = \int_{\Omega} \epsilon_x^{\text{RSF}}(\phi, f_1(x), f_2(x)) dx + \nu L(\phi) + \mu P(\phi) \quad (3)$$

式中: $E^{\text{RSF}}(\phi)$ 是可变区域二值拟合项, 其作用是通过高斯核函数的卷积运算, 实现图像局部信息的二值拟合, 使模型能够分割灰度不均图像; $L(\phi)$ 为长度正则项, $P(\phi)$ 为距离正则项, 这两项的作用是保证水平集演化的光滑与稳定性, 避免产生不规则的轮廓。

基于变分法和最速下降法, 固定 ϕ , 式(3)最小化 $f_i(x)$ ($i = 1, 2$) 得到

$$f_i(x) = \frac{K_{\sigma}(x) * (I(x) M_i(\phi(x)))}{K_{\sigma}(x) * M_i(\phi(x))} \quad (4)$$

式中*为卷积运算。固定 $f_i(x)$, 式(3)最小化 ϕ 得到水平集演化方程为

$$\frac{\partial \phi}{\partial t} = \delta(\phi) (-\lambda_1 e_1 + \lambda_2 e_2) \quad (5)$$

式中

$$e_i(x) = \int_{\Omega} K_{\sigma}(x-y) |I(y) - f_i(y)|^2 dy \quad (6)$$

相比 CV 模型, RSF 模型考虑了图像的局部灰度均值信息, 提高了其分割灰度不均医学图像的能力, 但所有先验信息只与区域灰度均值相关, 使其仍然对初始位置敏感, 且在 σ 大时产生边缘模糊, 很难分割弱边缘目标图像。

2 本文模型

为分割灰度不均且目标不清晰图像, 本节构造基于局部熵的图像特征区域划分, 设计基于特征区域的二值拟合能量泛函应用于图像分割。

2.1 基于局部熵的图像特征区域划分

一般认为, 基于区域的活动轮廓模型不能很好地分割弱目标, 其最主要的问题是区域的划分都只与演化曲线区域划分有关, 即模型中的 c_1, c_2 或 f_1, f_2 描述的是水平集函数 $\phi > 0$ 和 $\phi < 0$ 区域内图像灰度值均值或加权均值。如果划分区域时能够考虑图像的空间统计分布信息, 即图像的局部熵信息, 则

可以使得水平集函数在演化过程中更好地分割目标和背景。为此,考虑基于统计特征的图像特征区域划分。

设 $x=(x_1, x_2)$ 是图像上的点, $B(x, r)$ 是点 x 的邻域, $B(x, r)=\{(z_1, z_2) \in \Omega: |z_1 - x_1| \leq r, |z_2 - x_2| \leq r\}$ 局部熵为

$$E_r(x) = - \sum_{y \in B(x, r)} p_x(y) \lg p_x(y) \quad (7)$$

式中 $p_x(y) = \frac{|\{z \in B(x, r) \cap \Omega\}: I(z) = y\}}{|B(x, r) \cap \Omega|}$ 表示以 x 为中心的矩形窗口 $B(x, r)$ 的灰度级概率密度。将

式(7)标准化得到

$$E_r(x) = \frac{E_r(x) - \min(E_r(x))}{\max(E_r(x)) - \min(E_r(x))} \quad (8)$$

由局部熵定义知道,图像像素分布的无序程度越高,信息量越小,则局部熵越大;反之局部熵越小。由此说明,在灰度急剧变化区域局部熵值会发生较大变化,在目标区域因灰度值比较接近而局部熵值较小,因此使用阈值 s 可以粗略把图像分割成目标和背景两个区域,即

$$O(E_r(x)) = \begin{cases} 1 & E_r(x) > s \\ 0 & E_r(x) \leq s \end{cases} \quad (9)$$

2.2 基于局部熵的特征拟合能量泛函

需要进一步说明的是,局部熵是图像窗口内所有像素共同贡献的结果,反应了图像灰度聚集特征所包含的信息量,在非目标区域也可能出现与目标区域相同的局部熵值,说明仅仅局部熵信息是不能准确分割图像目标的。为此,本文以局部熵为图像先验信息设计区域活动轮廓模型,通过特征区域的二值拟合约束水平集函数向边缘运动,实现图像的精确分割。

设 $\phi: \Omega \rightarrow R$ 是水平集函数,首先定义图像特征区域如下

$$\chi(x) = \begin{cases} 1 & x \in \{E_r(x) > s\} \cap \{\phi(x) > 0\} \\ 0 & \text{其他} \end{cases} \quad (10)$$

定义 m_1, m_2 分别为图像特征区域内部和外部的均值,即

$$m_i = \frac{\int_{\Omega} I(x) F_i(x) dx}{\int_{\Omega} F_i(x) dx} \quad i = 1, 2 \quad (11)$$

式中: $F_1(x) = \chi(x), F_2(x) = 1 - \chi(x)$ 。

结合式(10)和式(11),引入 Heaviside 函数,式(11)可以改写为

$$m_1 = \frac{\int_{\Omega} I(x) O(E_r(x)) H(\phi(x)) dx}{\int_{\Omega} O(E_r(x)) H(\phi(x)) dx}$$

$$m_2 = \frac{\int_{\Omega} I(x) (1 - O(E_r(x)) H(\phi(x))) dx}{\int_{\Omega} (1 - O(E_r(x)) H(\phi(x))) dx} \quad (12)$$

设计基于局部熵的特征拟合能量泛函为

$$E^z(\phi) = \frac{1}{2} \int_{\Omega} |I(x) - \epsilon^z(\phi(x))|^2 dx \quad (13)$$

式中

$$\varepsilon^x(\phi(x)) = m_1 H(\phi(x)) + m_2 (1 - H(\phi(x))) \quad (14)$$

2.3 总的能量泛函

结合 RSF 模型和本文提出的局部熵特征拟合能量泛函, 提出总的能量泛函为

$$E^{\text{LRSF}}(\phi) = \omega E^x(\phi) + (1 - \omega) E^{\text{RSF}}(\phi) + \nu L(\phi) + \mu P(\phi) = \frac{1}{2} \omega \int_{\Omega} |I(x) - \varepsilon^x(\phi)|^2 dx + \\ (1 - \omega) \int_{\Omega} \varepsilon_x^{\text{RSF}}(\phi, f_1(x), f_2(x)) dx + \nu \int_{\Omega} |\nabla H(\phi(x))| dx + \mu \int_{\Omega} \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx \quad (15)$$

式中: $0 \leq \omega \leq 1$; $\nu, \mu > 0$ 为常数; E^x 如式(13)和式(14)所示; E^{RSF} 如式(2)和式(3)所示; E^x 和 E^{RSF} 为数据拟合项, 其作用是作为外部驱动力迫使演化曲线向目标边缘运动; $L(\phi)$ 和 $P(\phi)$ 为长度正则项和距离正则项, 用来保证演化曲线的光滑以及水平集函数的平稳变化。

基于变分法和梯度下降法, 最小化能量泛函(15), 得到关于水平集 ϕ 的演化方程, 即

$$\frac{\partial \phi}{\partial t} = \omega \delta(\phi) (I(x) - \varepsilon^x(\phi)) (m_1 - m_2) + (1 - \omega) \delta(\phi) (-e_1 + e_2) + \\ \nu \delta(\phi) \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \mu (\Delta \phi - \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right)) \quad (16)$$

式中: e_1, e_2 分别如式(4)和式(6)所表示; m_1, m_2 如式(12)所示定义。

与传统 CV 模型和 RSF 模型仅利用图像灰度均值或局部灰度均值来约束曲线运动相比较, 本文模型(15)既考虑了图像局部熵的空间灰度聚集性质, 又考虑了图像灰度均值的拟合, 既利用局部熵的计算来约束演化曲线向特征区域边缘运动, 还利用局部灰度均值来约束演化曲线向二值拟合区域边缘运动, 通过 ω ($0 \leq \omega \leq 1$) 值的调节来调整两个数据拟合项的作用。

2.4 数据拟合项 E^x 和 E^{RSF} 的作用分析

模型(15)的数据拟合项包含 E^x 和 E^{RSF} 两项, 本节利用血管活检图像实验(图1)分析图像分割中 E^x 和 E^{RSF} 的作用。血管活检图像具有灰度不均且噪声杂乱等特征, 很难精确分割。固定参数 $\sigma = 3, \mu = 0.1, \Delta t = 0.1, \nu = 0.001 \times 255^2$, 通过 ω 从小到大依次取值实验说明 E^x 和 E^{RSF} 的作用。显然, 当 $\omega = 0$ 时, 模型(15)退化为 RSF 模型, 模型外部驱动力仅包含 E^{RSF} ; 当 $\omega = 1$ 时, 模型(15)的外部驱动力仅包含 E^x ; 当 $\omega \in (0, 1)$ 时, 模型(15)由 E^x, E^{RSF} 和正则项共同作用于演化曲线。图1(a)是原始图像和水平集演化的初始轮廓, 图1(b)是 $\omega = 0$ 时模型(15)曲线演化结果, 说明外部驱动仅有 E^{RSF} 时, 模型对噪声敏感; 图1(f)是 $\omega = 1$ 时模型(15)曲线演化结果, 说明外部驱动仅包含数据驱动项 E^x 时, 模型对噪声鲁棒, 且能够实现图像的粗分割, 但分割结果较粗造, 边缘轮廓明显小于真实目标; 图1(c-d)是 $\omega = 0.1, 0.2, 0.3$ 时模型(15)的实验结果, 说明随着 ω 值增大, E^x 作用增强, 数据驱动项使得模型在粗分割




图1 模型(15)中 E^x 和 E^{RSF} 对图像分割的作用

Fig.1 Contribution of E^x and E^{RSF} in Eq.(15) to image segmentation

的基础上减少噪声对分割的影响,但增大到0.3之后, E^{RSF} 作用太小将导致分割精确降低,故适当选取 ω 值,可使分割结果在 E^x 的优点(粗分割,对噪声鲁棒)和 E^{RSF} 的优点(提高分割精度高)中达到最优,从而使得模型能够既能精确分割弱目标图像,又对噪声鲁棒,说明 ω 是数据项 E^x 和 E^{RSF} 的平衡系数,其取值应根据图像不同而有所差别。通过对不同类型医学图像反复实验,建议 $\omega \in [0.1, 0.3]$,对背景噪声图像以及目标与背景非常接近的超声图像,建议选取 $\omega = 0.3$,其他医学图像建议选取 $\omega \in [0.1, 0.2]$ 。

3 数值实现与优化

3.1 数值实现

本文图像分割是迭代求解式(16)数值实现。首先,采用光滑函数 $H_\epsilon(\phi)$ 代替 Heaviside 函数 $H(\phi)$,即

$$H_\epsilon(\phi) = \frac{1}{2} \left(1 + \frac{2}{\pi} \arctan \left(\frac{\phi}{\epsilon} \right) \right) \quad (17)$$

从而有

$$\delta_\epsilon(\phi) = H'_\epsilon(\phi) = \frac{1}{\pi} \cdot \frac{\epsilon}{\epsilon^2 + \phi^2}$$

本文所有实验取 $\epsilon = 1.2$ 。

记时间步长为 Δt ,空间步长为 h , $(x_i, y_i) = (ih, jh)$ 是空间网格点, $\phi_{i,j}^n$ 是函数 ϕ 在空间 (ih, jh) 和时间 $t = n\Delta t (n \geq 0)$ 的状态。式(16)右边中心差分,左边时间前向差分,对应的离散形式为

$$\phi_{i,j}^{k+1} = \phi_{i,j}^k + \Delta t L(\phi_{i,j}^k) \quad (18)$$

其中 $L(\phi_{i,j}^k)$ 是式(16)右边中心差分形式。

本文采用以下步骤实现图像分割:

(1) 初始水平集函数 $\phi = \phi_0(x)$

$$\phi_0(x) = \begin{cases} 1 & x \in \Omega_0 \\ -1 & x \in \Omega - \Omega_0 \end{cases};$$

(2) 根据式(7)和式(8)计算 $E_r(x)$;

(3) 根据式(9, 11, 12)计算 m_1 和 m_2 ;根据式(4)和式(6)计算 e_1 和 e_2 ;

(4) 根据式(16)和式(18)迭代求解,更新水平集函数,得到 ϕ^{k+1} ;

(5) 检验演化曲线是否收敛,当满足 $\frac{1}{\bar{m}MN} \sum_{j=1}^N \sum_{i=1}^M |\phi_{ij}^{k+1} - \phi_{ij}^k| < \tau$ 时收敛,曲线停止演化,其中 τ 为

阈值, \bar{m} 为 ϕ^k 平均值;否则不收敛,转到步骤(3)。

3.2 结果优化

为进一步避免演化结果包含非正则小孔或噪声,本文对演化结果进行优化,即设置阈值 m ,去掉演化结果中面积小于 m 的曲线。具体做法为

(1) 将已经收敛水平集函数 $\phi^n(x)$ 二值化,即

$$\chi(\phi^n(x)) = \begin{cases} 1 & \phi^n > 0 \\ 0 & \phi^n < 0 \end{cases}$$

(2) 记录 $\chi(\phi^n(x))$ 的连通区域,标记为 $\chi_k(\phi^n(x))$, $k = 1, 2, \dots, L$, L 为总的连通区域数。

(3) 设定阈值 m ,计算每个连通区域的面积,记为 $S_{\chi_k(\phi^n(x))}$, $k = 1, 2, \dots, L$,如果 $S_{\chi_k(\phi^n(x))} < m$,则该区

域水平集函数值取其相反数,即

$$\left\{ \phi^n(x) = -\phi^n(x) \mid x \in \chi_k(\phi^n(x)), S_{\chi_k(\phi^n(x))} < m \right\}$$

其他区域函数值不变。

4 实验结果

实验平台操作系统为 Windows10,程序用 MATLAB2016a 编写。

4.1 实验参数选择说明

本文模型(15)的参数包含高斯核函数 $K_\sigma(x)$ 的尺度参数 σ 、数据驱动项 E^x 和 E^{RSF} 的平衡系数 ω 、正则项系数 ν 、 μ 和时间步长 Δt 。在 RSF 模型中已经阐明,参数 σ 的大小决定图像局部信息的二值拟合窗口,为实现灰度不均图像的分割, σ 取值不能太大,本文所有实验选取 $\sigma=3$;文献[21]指出,为避免较快演化导致水平集函数急剧变化,时间步长一般较小, μ 和 Δt 必须满足 $\mu \cdot \Delta t < 4$,为此,本文所有实验采用 $\Delta t=0.1$ 和 $\mu=0.1$;关于参数 ω 的取值范围,3.3 节已经给出建议。以下血管造影图像实验选取 $\omega=0.15$ 。

接下来通过血管造影图像实验(图2)来说明长度正则项系数 ν 的取值建议。由于光照不均等原因,血管造影图像具有灰度不均且目标边缘弱等特征,不易分割。图2(a)是原始图像和初始轮廓,图2(b—e)是 ν 从小到大取值的实验结果,由图2(b)知道,当 $\nu=0.0005 \times 255^2$ 时模型能够分割血管,但有不规则错误轮廓出现,说明 ν 值太小,长度正则项作用力不够;由图2(c)知道,随着 ν 值增大,不规则轮廓消失,当 $\nu=0.001 \times 255^2$ 时,模型有较好的分割效果;随着 ν 值进一步增大,图2(d)和图2(e)显示,过度正则使得演化曲线达不到距离初始位置较远的目标体(见图2(d)和图2(e)下半部分)。因此,适当选取 ν 值可使水平集演化在不规则轮廓和过度正则间找到均衡。本文主要是医学图像分割,通过反复实验,建议 $\nu \in [0.001 \times 255^2, 0.003 \times 255^2]$,对目标与背景比较接近的医学图像,需要弱正则避免弱目标边缘泄露,建议 $\nu=0.001 \times 255^2$,对于噪声图像,需要强正则来避免不规则轮廓的产生,建议 $\nu=0.003 \times 255^2$ 。




图2 不同 ν 值下本文模型作用于血管图像分割结果

Fig.2 Segmentation results of the proposed model on real vessel image with different ν

4.2 实验结果

为说明本文模型 $E^{\text{LRSF}}(\phi)$ 的有效性,采用大量医学造影和超声噪声弱目标图像进行 $E^{\text{LRSF}}(\phi)$ 模型实验,并与 CV 模型^[12]、RSF 模型^[14]和 BIF 模型^[18]进行比较。本文模型参数选择如下: $\sigma=3, \varepsilon=1.2, \mu=0.1, \Delta t=0.1, \nu$ 和 ω 值随实验图像不同而变化,具体取值在实验中给出。对于模型 CV、RSF 和 BIF 的参数选择,固定参数值是根据模型本身的论文给出,动态参数 ν 则是依据图像不同,反复调整其参数值,选取最好的实验结果进行展示,以此获得比较的公平性。

图3是4个模型作用于血管造影图像的实验结果。图3(b)显示,不管怎样定义初始轮廓,CV模型在曲线演化中都会陷入局部最小,而不能正确分割血管;图3(c)显示,RSF模型只在初始轮廓面积小且覆盖部分目标时,能正确分割血管((I)),其余初始位置则会产生错误的伪边缘,说明RSF模型在一定程度上能够分割灰度不均图像,但是对初始位置敏感;图3(d)显示,前两种初始轮廓下BIF模型能正确分割血管((I)和(II)),第三种情况左下边陷入局部最小((III)),第四种情况则产生了错误的轮廓线((IV)),说明双边滤波加权拟合能量仍对演化曲线的初始位置敏感;图3(e)结果显示,采用不同大小,不同位置的初始轮廓,本文模型都能正确分割低对比度且灰度不均的血管图像,且对初始位置鲁棒。

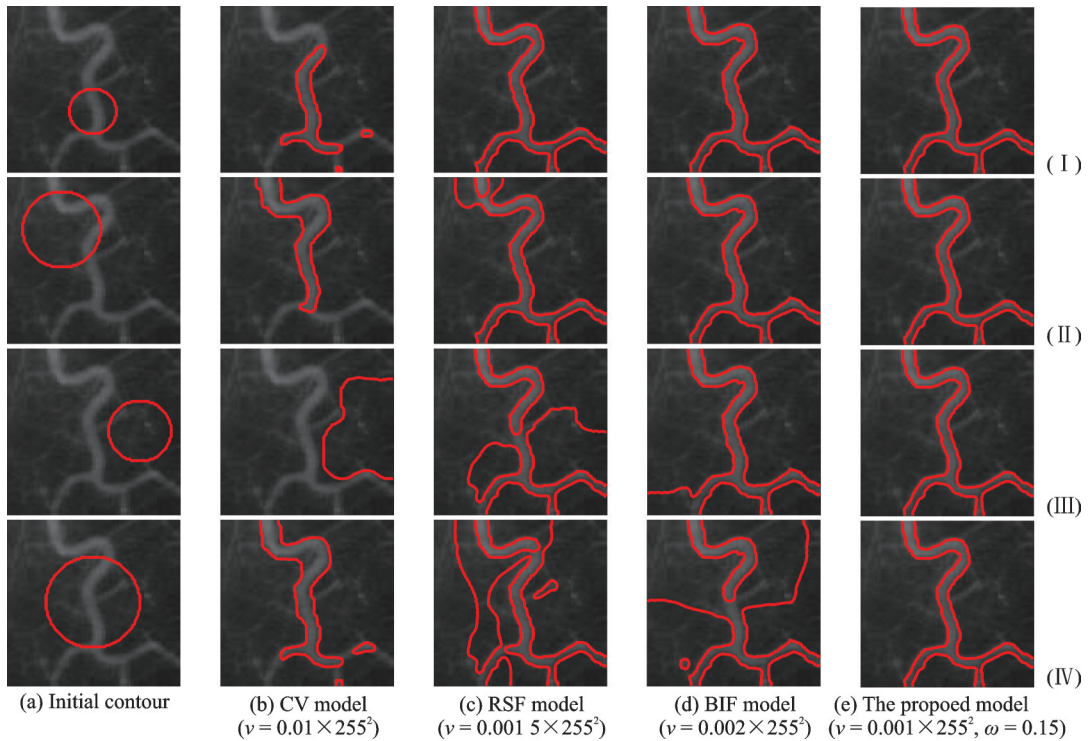


图3 不同初始轮廓下四个模型作用于血管图像分割结果

Fig.3 Segmentation results of four models on real vessel images with different initial contours

表1是4个模型作用于图3实验的迭代次数和CPU时间比较,只记录演化次数和正确分割算法的收敛时间,对于不能收敛到正确边缘的实验,设置最大迭代次数1000次,不记录CPU时间。由表1可以看出,本文模型比RSF模型更快收敛于目标边缘,CPU时间也更少;BIF迭代次数略少于本文模型,但由于其计算复杂,其迭代时间反而高于本文模型,本文模型能够更快收敛到目标边缘。

表1 4个模型作用于图3实验的CPU时间和迭代次数

Table 1 Comparison of CUP time and iteration counts by four models for images shown in Fig.3

模型	图3(I)		图3(II)		图3(III)		图3(IV)	
	CUP时间/s	迭代次数	CUP时间/s	迭代次数	CUP时间/s	迭代次数	CUP时间/s	迭代次数
CV模型		1 000		1 000		1 000		1 000
RSF模型	3.64	440		1 000		1 000		1 000
BIF模型	2.31	40	3.44	60		1 000		1 000
本文模型	0.47	40	1.47	160	0.88	80	2.50	300

图4是4个模型作用于超声图像实验结果,实验对象是乳腺囊肿和皮肤肿瘤图像,这类图像具有组织噪声,分割比较困难。图4(b)和(d)显示,当初始轮廓覆盖部分目标时,CV模型和BIF模型都能正确分割目标体((I)和(III)),当初始轮廓偏离目标时,CV模型和BIF模型均陷入局部最小而不能正确分割目标体((II)和(IV));图4(c)显示,不管怎样的初始轮廓大小和位置,RSF模型都产生了错误的轮廓线,说明其对噪声敏感;图4(e)结果显示,不同的初始位置和不同轮廓大小,本文模型都能分割高噪声医学超声图像。




图4 4个模型作用于医学噪声图像分割结果

Fig.4 Segmentation results of four models on medical noisy images

表2是4个模型作用于图4实验的CPU时间和迭代次数,仍然只比较能够分割的情况,对于图4(I)和图4(III),CV模型、BIF模型和本文模型到收敛时迭代次数相同,但CV模型和BIF模型CPU时间多于本文模型;RSF模型不能分割图4(I),能够分割4(III),但迭代次数多于本文模型,导致其CPU时间仍然多于本文模型,再次说明本文模型在CPU时间上优于其他3个模型。

图5是4个模型作用于肺部阴影超声图像的实验结果,该图像目标弱且内外均值接近,很难分割,特别是左肺部的阴影区域很难识别。图5(b)显示,CV模型在初始轮廓较小时,演化曲线基本保持初始状态,不发生改变,在初始轮廓较大时,演化曲线在目标凹陷区域陷入局部最小,说明弱目标图像在曲

表2 4个模型作用于图4实验的CPU时间和迭代次数

Table 2 Comparison of CUP time and iteration counts by four models for images shown in Fig.4

模型	图4(I)		图4(II)		图4(III)		图4(IV)	
	CUP时间/s	迭代次数	CUP时间/s	迭代次数	CUP时间/s	迭代次数	CUP时间/s	迭代次数
CV模型	0.82	40		1 000	0.72	40		1 000
RSF模型			1 000		1.31	150		1 000
BIF模型	2.98	40		1 000	2.45	40		1 000
本文模型	0.55	40	5.81	600	0.47	40	0.48	40

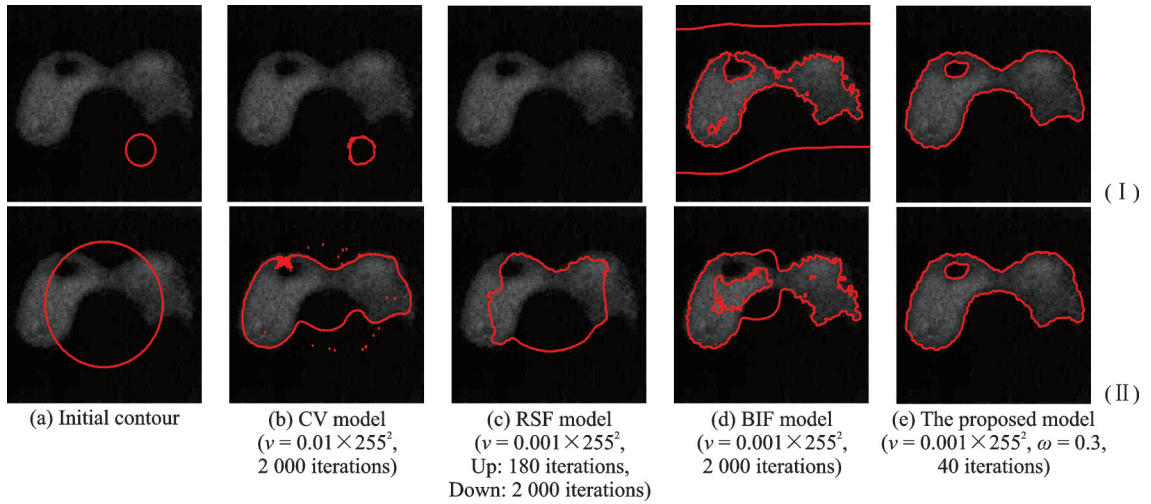



图5 4个模型作用于肺部阴影图像分割结果
 Fig.5 Segmentation results of four models on real lung shadow image

线内外灰度均值基本相同,导致CV模型演化动力不足,不能分割该类图像;图5(c)显示,RSF模型在初始轮廓较小时,仅迭代180次后轮廓消失,当初始轮廓较大时,RSF模型在图像凹陷区域也会陷入局部最小,说明RSF模型也不能分割弱目标图像;图5(d)显示,BIF模型能粗略识别目标体,但不能正确分割肺部阴影,且曲线在演化过程中产生多余的伪边界;图5(e)结果显示,不同初始位置和不同轮廓大小,本文模型仅用40次迭代,就能快速准确分割低对比度肺部整体以及内部阴影区域,说明本文模型能够很好分割弱目标物体。

图6是4个模型作用于超声盆底提肌裂孔图像的实验结果,目的是分割裂孔和提肌外壁,便于医学分析,值得注意的是裂孔内有强干扰,提肌也灰度不均,使其分割比较困难。图6(b)显示,CV模型经2000次迭代才粗略分割目标,说明图像非目标光亮区域影响了CV模型的分割准确性,且在复杂场景中CV模型收敛速度慢;图6(c)显示,不管怎样定义初始轮廓,RSF模型都在演化中产生很多错误的轮廓线,说明RSF模型不适宜分割这类图像;图6(d)显示,当初始轮廓较小时,BIF模型能识别目标体内轮廓,但目标内部和外部有错误的小轮廓,当初始轮廓面积较大时,BIF模型不能正确识别目标体内轮廓;图6(e)显示,采用不同的初始位置和不同大小轮廓,本文模型都能较好地分割出复杂且灰度不均的超声盆底提肌裂孔图像的目标内外轮廓,这对医学临床应用非常重要。






图6 4个模型作用于超声盆底提肌裂孔图像分割结果

Fig.6 Segmentation results of four models on pelvic floor levator hiatus in ultrasound

5 结束语

本文构建了基于图像局部熵特征划分的二值拟合模型用于医学图像分割。该模型即考虑了图像灰度的聚集特征,也考虑了图像灰度均值的二值拟合,使得模型能够很好的分割包含噪声的灰度不均弱目标医学图像,并对演化曲线的初始位置具有鲁棒性。值得注意的是,本文模型处理的是静态灰度不均医学图像分割问题。下一步工作将考虑模型与深度网络相结合,用于复杂场景医学图像的精准语义分割,先采用深度学习方法从大样本中获取特定目标的语义特征,实现水平集函数的自动初始化,再采用本文模型实现目标的精确分割。

参考文献:

- [1] CHEN Y, WANG M, HEIDARI A A, et al. Multi-threshold image segmentation using a multi-strategy shuffled frog leaping algorithm[J]. *Expert Systems with Applications*, 2022, 194(15): 1-25.
- [2] 刘松涛,刘振兴,姜康辉. 基于模糊 Renyi 熵和区域增长的图像目标分割方法[J]. *系统工程与电子技术*, 2018, 40(8): 1693-1701.
LIU Songtao, LIU Zhenxing, Jiang Kanghui. Image target segmentation method based on fuzzy Renyi entropy and region growing[J]. *Systems Engineering and Electronics*, 2018, 40(8): 1693-1701.
- [3] RAMYA J, VIJAYLAKSHMI H C, SAIFUDDIN H M. Segmentation of skin lesion images using discrete wavelet transform [J]. *Biomedical Signal Processing and Control*, 2021, 69: 102839.
- [4] SHU Xiu, YANG Yunyun, WU Boying. A neighbor level set framework minimized with the split Bregman method for medical image segmentation[J]. *Signal Processing*, 2021, 189: 1-16.
- [5] CZIPCZER V, MANNO-KOVACS A. Adaptable volumetric liver segmentation model for CT images using region-based features and convolutional neural network[J]. *Neurocomputing*, 2022, 505: 388-401.
- [6] SCHMITZ R, MADESTA F, NIELSEN M, et al. Multi-scale fully convolutional neural networks for histopathology image segmentation: From nuclear aberrations to the global tissue architecture[J]. *Medical Image Analysis*, 2021, 70: 101996.
- [7] DING Yi, ZHANG Chao, CAO Mingsheng. ToStaGAN: An end-to-end two-stage generative adversarial network for brain tumor segmentation[J]. *Neurocomputing*, 2021, 462 (28): 141-153.
- [8] HUSSAIN S, XI X, ULLAH I, et al. A discriminative level set method with deep supervision for breast tumor segmentation [J]. *Computers in Biology and Medicine*, 2022, 149(24): 105995.

- [9] QIAN C, SU E, NI X. Learning-based initialization for correntropy-based level sets to segment atherosclerotic plaque in ultrasound images[J]. Ultrasonics, 2023, 127: 106826.
- [10] CASELLES V, KIMMEL R, SAPIRO G. Geodesic active contours[J]. International Journal of Computer Vision, 1997, 22 (1): 61-79.
- [11] MEDEIROS A G, GUIMARAES M T, PEIXOTO S A. A new fast morphological geodesic active contour method for lung CT image segmentation[J]. Measurement, 2019, 148: 106687.
- [12] CHAN T F, VESE L A. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10 (2): 266-277.
- [13] ZHANG K, ZHANG L, SONG H, et al. Active contours with selective local or global segmentation: A new formulation and level set method[J]. Image and Vision Computing, 2010, 28: 668-676.
- [14] LI C, KAO C, GORE J C, et al. Minimization of region-scalable fitting energy for image segmentation[J]. IEEE Transactions on Image Processing, 2008, 17 (10): 1940-1949.
- [15] SHU Xiu, YANG Yunyun, WU Boying. A neighbor level set framework minimized with the split Bregman method for medical image segmentation[J]. Signal Processing, 2021, 189: 108293.
- [16] MIN H, XIA L, HAN J. A multi-scale level set method based on local features for segmentation of images with intensity inhomogeneity[J]. Pattern Recognition, 2019, 91: 69-85.
- [17] RAHALI R, DRIDI N, SALEM Y B. et al. Biological image segmentation using region-scalable fitting energy with b-spline level set implementation and watershed[J]. Innovation and Research in Biomedical Engineering, 2022 (9): 1-14.
- [18] WANG Y, HE C, LI X, et al. Bilateral intensity fitting energy for image segmentation[J]. East Asian Journal on Applied Mathematics, 2018, 8 (2): 296-312.
- [19] 王顺风, 冀晓娜, 张建伟, 等. 局部熵驱动的 GAC 模型在生物医学图像分割中的应用[J]. 电子学报, 2013, 41(12): 2487-2492.
WANG Shunfeng, JI Xiaona, ZHANG Jianwei, et al. Application of GAC model driven by the local entropy on medical image segmentation[J]. Acta Electronica Sinica, 2013, 41(12): 2487-2492.
- [20] FANG L, ZHAO W, LI X, et al. A convex active contour model driven by local entropy energy with applications to infrared ship target segmentation[J]. Optics & Laser Technology, 2017, 96(1): 166-175.
- [21] LI C, XU C, GUI C, et al. Level set formulation without re-initialization: A new variational formulation[C]//Proceedings of the 2005 IEEE Computer Society Conference Vision and Pattern Recognition. San Diego: IEEE, 2005: 430-436.

作者简介:



李梦(1973-),女,博士,副教授,研究方向:偏微分方程及其在图像处理中的应用, E-mail: limeng7319@email.ctbu.edu.cn.



詹毅(1971-),男,博士,副教授,研究方向:图像处理。



王艳(1984-),通信作者,女,博士,教授,研究方向:图像处理的偏微分方程方法,医学影像处理与分析, E-mail: wycq2006@sina.com.

(编辑:王静)