

局部熵驱动的 GAC 模型在生物医学图像分割中的应用

王顺风, 冀晓娜, 张建伟, 陈允杰, 方 林

(南京信息工程大学数学与统计学院, 江苏南京 210044)

摘 要: 针对测地线活动轮廓(GAC)模型不能对包含噪声和灰度不均匀现象这类复杂背景图像成功提取目标的问题, 本文提出局部熵驱动的 GAC 模型. 首先提取图像的局部信息熵来刻画图像的灰度变化, 再利用局部熵构造符号压力函数来指导轮廓曲线向目标边界靠近, 实现目标的分割. 为降低计算复杂度并提高模型对水平集变化的鲁棒性, 采用二值水平集方法进行求解. 实验结果表明, 本文方法可以克服噪声和灰度不均匀对图像分割的影响, 实现快速准确的分割.

关键词: 测地线活动轮廓模型; 局部熵; 符号压力函数; 二值水平集方法

中图分类号: ATP391 **文献标识码:** A **文章编号:** 0372-2112 (2013) 12-2487-06

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2013.12.026

Application of GAC Model Driven by the Local Entropy on Medical Image Segmentation

WANG Shun-feng, JI Xiao-na, ZHANG Jian-wei, CHEN Yun-jie, FANG Lin

(School of Mathematics and Statistics, Nanjing University of Information Science & Technology, Nanjing, Jiangsu 210044, China)

Abstract: The geodesic active contour model(GAC) can't identify the object of the images with complex background such as noise and intensity inhomogeneities successfully. For this reason, this paper proposes GAC model driven by the local entropy. First of all, the local information entropy of image is abstracted to describe the local intensity variation. Then, the signed pressure force function based on the local entropy are structured, which guides the contour curve close to the boundary of the object and achieves the segmentation of the object. In order to reduce the computational complexity and improve the robustness of the proposed model to different level sets, the proposed method is implemented by the binary level set method. The experimental results show that this method can overcome the influence of complex background to the segmentation results, and realize fast and accurate segmentation.

Key words: geodesic active contour model; local entropy; signed pressure force function; binary level set method

1 引言

生物医学图像分割是图像处理领域的主要应用之一, 它的发展大大促进了辅助医疗、临床医学等领域的成就. 然而由于人体结构差异性、成像设备等客观因素, 使得图像不可避免地受到噪声和灰度不均匀现象的影响, 这使得传统的分割模型得到的实验结果很不理想.

目前, 生物医学图像分割的方法主要有基于图谱理论的分割模型^[1,2]和基于变分理论的分割模型^[37], 其中基于变分理论的分割模型由于其较好的数学支撑得到了广泛的应用. 经典的变分分割模型是 Kass 等提出的蛇(Snake)模型^[3], 但是该模型的参数较多导致计算复杂度高, 且易陷入局部最优. Caselles 等提出测地活动轮

廓(Geodesic Active Contour, GAC)模型^[4], 避免了自由参数的影响, 简化了模型复杂度. 但是该模型是基于边缘信息的, 在轮廓线距离边界很近, 目标边界具有明显梯度变化时分割效果较理想. 生物医学图像目标边界往往是模糊的或者噪声污染较严重, 利用 GAC 模型进行分割时, 易导致错误结果.

近年来, 很多学者致力于对 GAC 模型的边缘停止函数进行改进. 例如, 文献[8]提出了一种基于区域的 GAC(Global Geodesic Active Contour, GGAC)模型. 该模型的符号压力函数 $f_{\text{spf}}^{[9]}$ (signed pressure force function, spf) 是基于全局信息的, 可以避免弱边界泄漏现象, 对噪声有较好的鲁棒性. 但是该模型是基于区域灰度均匀的条件假设, 因此对灰度不均匀图像分割结果很不理想. 文

献[10]借鉴局部化思想,通过核函数来控制区域的均值信息,进而构造基于局部信息的 GAC(Local Geodesic Active Contour, LGAC)模型.该模型考查图像局部区域的灰度均值信息,较好地反映了灰度变化,可以正确区分目标和背景区域.但是对于同时含有噪声和灰度不均匀性这类复杂背景的图像,分割效果仍不准确.

为克服复杂背景的影响,本文利用局部熵^[11]量化图像的局部信息,构造 GAC 模型的符号压力函数,提出局部熵驱动下的 GAC 模型.为了快速准确的分割出目标,提高模型的实时性,本文给出基于二值水平集方法^[12]的快速求解算法.

2 GAC 模型

Kass 等提出的 Snake 模型^[3]在求解过程中受初始轮廓和自由参数的限制,为了克服这一缺陷,Caselles 等提出 GAC 模型^[4],该模型忽略了自由参数的影响,将其演化过程归结为最小化一个闭合曲线 C 的能量泛函:

$$E^{\text{GAC}} = \int_0^{L(C)} g(|\nabla I| [C(s)]) ds \quad (1)$$

式中, $L(C)$ 表示闭合曲线 C 的长度, ∇I 为图像的梯度, s 是弧长参数, $g = \frac{1}{1 + |\nabla G * I|^p}$ 为边缘停止函数, p 通常取 1 或 2. 最小化这个能量泛函,得到该泛函的欧拉-拉格朗日方程:

$$\frac{\partial E^{\text{GAC}}}{\partial s} = (\nabla g \cdot N - g\kappa) N \quad (2)$$

式(2)中, N 为曲线的内法向量, κ 为曲率. 能量 E^{GAC} 向极小值的演化过程可以描述为梯度下降方程

$$\frac{\partial C}{\partial t} = -\frac{\partial E^{\text{GAC}}}{\partial s} = F \cdot N \quad (3)$$

式(3)表示曲线以速度 F 沿着法向量 N 进行演化,其中 $F = g\kappa - \nabla g \cdot N$, t 为曲线向目标演化的时间步长.

利用水平集 $\{\phi: \phi(t) = k\}$ 来表示闭合曲线 C , 得到 GAC 模型的水平集演化形式

$$\frac{\partial \phi}{\partial t} = F \cdot |\nabla \phi| \quad (4)$$

其中, $N = -(\nabla \phi / |\nabla \phi|)$ 为曲线 C 的单位法向量.

利用 GAC 模型对图像进行分割时,边缘停止函数可以指导轮廓曲线向目标边界靠近,并最终停留在目标边界上.但是这种作用只有在轮廓线距离边界很近,边界具有明显梯度变化时才生效.对于生物医学等复杂图像,其目标边界模糊或者噪声污染较严重,利用图像梯度构造驱动力往往是不准确的,易导致错误分割.

3 局部熵驱动下的 GAC 模型

3.1 局部熵

对于图像 $I: \Omega \in \mathbf{R}^2 \rightarrow \mathbf{R}$, 像素点 $x \in \Omega$ 的局部熵为:

$$E_r(x) = - \sum_{y \in B(x,r)} p_x(y) \ln p_x(y) \quad (5)$$

式中, $p_x(y) = \frac{|\{y \in B(x,r): I(x) = y\}|}{|B(x,r) \cap \Omega|}$ 表示一个以 x 为中心、 r 为半径的圆形窗口 $B(x,r)$ 内的灰度级概率密度.

局部熵较好地描述了图像各个灰度级的像素点分布的离散程度和噪声情况,即反映了图像信息量的丰富程度. x 处于灰度均匀区域, $E_r(x)$ 越大;相反, x 处于灰度不均匀或者噪声区域, $E_r(x)$ 越小. 这种局部化技术可以在一定程度上解决图像的灰度不均匀性和噪声的干扰问题.

3.2 基于局部熵信息的 GAC 模型

为了准确分割复杂背景图像,本文利用局部熵构造符号压力函数 f_{lespf} (signed pressure force function based on local entropy, lespf) 代替式(1)中的边缘停止函数 g , 得到局部熵驱动的 LEGAC(Geodesic Active Contour driven by Local Entropy, LEGAC)模型

$$E^{\text{LEGAC}} = \int_0^{L(C)} g(|\nabla I| [C(s)]) ds \quad (6)$$

函数 $g = f_{\text{lespf}}$ 定义为

$$f_{\text{lespf}} = \frac{\int_{\Omega} w(x-y) E_r(x) (I(y) - \frac{f_1(x) + f_2(x)}{2}) dy}{\max(\left| \int_{\Omega} w(x-y) E_r(x) (I(y) - \frac{f_1(x) + f_2(x)}{2}) dy \right|)} \quad (7)$$

式中 $E_r(x)$ 为窗口函数 w 控制的区域范围内像素点 x 的局部熵. 若 x 是高斯邻域内概率密度很小的点(如噪声),则 $E_r(x)$ 较小,对局部均值的贡献率就很小,相当于在局部范围内进行滤波;相反,若 x 的概率密度较大,则 $E_r(x)$ 较大,对局部均值的贡献率就很大. f_1 、 f_2 分别为窗口范围内轮廓曲线内部和外部的灰度均值,其表达式为

$$f_1 = \frac{\sum w(E_r \cdot |\text{sign}(\phi < 0)|)}{\sum w E_r |\text{sign}(\phi < 0)|}, f_2 = \frac{\sum w(E_r \cdot |\text{sign}(\phi \geq 0)|)}{\sum w E_r |\text{sign}(\phi \geq 0)|} \quad (8)$$

求解式(6)的梯度下降方程,其水平集演化形式为

$$\frac{\partial \phi}{\partial t} = f_{\text{lespf}} \cdot |\nabla \phi| \cdot \text{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \nabla f_{\text{lespf}} \cdot \nabla \phi \quad (9)$$

利用目标灰度小于背景灰度的情形来解释函数 f_{lespf} 的含义. $x \in \Omega$ 为像素点,窗口函数 w 控制的区域范围为 Ω_x . 在小的局部范围内,灰度变化缓慢,可近似为灰度均匀的. 在 Ω_x 上,轮廓线内部和外部的灰度分别记为 I_o 和 I_b , 则 $I_o < I_b$. 且灰度值满足不等式

$$\min(I_o) < \frac{f_1(x) + f_2(x)}{2} < \max(I_b) \quad (10)$$

在目标区域, $I_o - \frac{f_1(x) + f_2(x)}{2} < 0$, 由式(7)可知,

$f_{\text{lespf}} < 0$, 轮廓曲线向灰度增加的方向靠近, 即向目标边界扩张; 在背景区域, $I_b - \frac{f_1(x) + f_2(x)}{2} > 0$, 由式(7)可知, $f_{\text{lespf}} > 0$, 轮廓曲线向灰度减小的方向靠近, 即向目标边界收缩. 通过反复检测 f_{lespf} 的符号, 指导轮廓曲线向目标边界靠近, 最终停留在目标边界上. 此外, 由式(10)可知, f_{lespf} 的取值范围为 $[-1, 1]$, 满足符号压力函数的定义.

3.3 数值实现

利用二值水平集方法对式(9)进行数值实现, 采用简单的中间差分方案. 通过计算轮廓曲线内外像素点个数的变化量来判断水平集函数是否收敛, 判断准则如下:

$$Q = (\sum |\text{sign}(\phi^{n+1} < 0) - \text{sign}(\phi^n < 0)| + |\sum \text{sign}(\phi^{n+1} \geq 0) - \text{sign}(\phi^n \geq 0)|) / M \quad (11)$$

式中 M 表示图像的大小. 算法步骤如下:

- Step1: 初始化水平集函数 $\text{sign}(\phi)$;
- Step2: 由式(8)计算 f_1, f_2 , 并代入式(7)计算 f_{lespf} ;
- Step3: 根据式(9)演化水平集方程;
- Step4: 利用高斯函数对水平集进行光滑;
- Step5: 代入判断准则(11), 若 $Q < \epsilon$, ϵ 为一个很小的常数, 则方程(11)收敛, 停止演化; 否则返回 Step2.

4 实验结果与分析

本文的实验均是在 Dell 台式机(Intel CPU 2.0GHz, 内存 1GB)上实现的, 实验工具为 Matlab R2010b. 实验

中, 水平集 ϕ 被初始为一个二值函数, 实验参数设置如下: 高斯核函数的参数 $\sigma = 3, \epsilon = 1E-3, r = 5$.

本文利用块相似系数(Dice Similarity Coefficient, DSC), 假负比率(False Negative Ratio, FNR), 假正比率(False Positive Ratio, FPR), 分割错误比率(Ratio of Segmentation Error, RSE)^[11]四个指标描述分割结果的精度. 假设 S_1 和 S_2 分别代表标准分割结果和待判断分割结果, 这四个指标定义分别为:

$$\text{DSC} = \frac{2N(S_1 \cap S_2)}{N(S_1) + N(S_2)}, \text{FNR} = \frac{N(S_1 \setminus S_2)}{N(S_1)},$$

$$\text{FPR} = \frac{N(S_2 \setminus S_1)}{N(S_2)}, \text{RSE} = \frac{N(S_1 \setminus S_2) + N(S_2 \setminus S_1)}{N(\Omega)}$$

式中, $N(\cdot)$ 代表所围区域的像素个数, Ω 是图像区域. 理想的分割结果为 $\text{DSC} \rightarrow 1, \text{FPR} \rightarrow 0, \text{FNR} \rightarrow 0, \text{RSE} \rightarrow 0$.

4.1 人工合成图像的分割实验

图 1 是对人工合成图像的分割结果比较. 图 1(a)是具有明显灰度不均匀性的人工合成图像和初始轮廓; 图 1(b)是 CV 模型^[5]的分割结果, 由于该模型的前提假设图像是灰度均匀的, 很难克服灰度不均现象的影响, 从而导致了错误的分割结果; 图 1(c)是 GGAC 模型的分割结果, 该模型的全局信息使其不能对灰度不均匀图像进行准确分割; 图 1(d)和图 1(e)分别是 LBF 模型^[6]和 LGAC 模型的分割结果, 二者利用图像的局部信息提高了对灰度不均匀性的鲁棒性, 从而准确找出目标边界; 图 1(f)本文方法的分割结果, 该模型充分考虑了图像的局部信息和灰度变化, 从而可以准确提取目标.




图 1 人工合成图像的分割结果

表 1 是 LBF 模型、LGAC 模型和本文方法的分割结果的比较. 利用阈值法可以准确获得原图的真实目标. 采用 DSC、FNR、FPR、RSE 这四个指标对分割结果进行量化评估, 结果如表 1 所示. 表 1 中数据显示, LBF 模型、LGAC 模型和本文方法都达到了相当理想的分割效果. 利用二值水平集方法有效地避免了 LBF 模型重新初始化过程, 因此本文方法的求解效率较 LBF 模型提

高了 36.69%.

表 1 精度指标及时间比较

模型	DSC	FNR	FPR	RSE	Time(s)
LBF 模型	0.9902	0.0131	9.7201×10^{-5}	4.8522×10^{-5}	6.9459
LGAC 模型	0.9917	0.0115	7.3862×10^{-5}	5.1734×10^{-5}	4.8019
本文方法	0.9911	0.0098	8.4470×10^{-5}	5.5921×10^{-5}	4.6976

4.2 左心室图像的分割实验

图2是左心室MR图像的分割实验.该类图具有模糊、伪影、边界断裂和灰度不均匀等特点.自上到下分别是添加0,0.01,0.03,0.05的高斯噪声图像的分割实验结果.可以看出,GGAC模型的全局信息虽然对噪声具有鲁棒性,但是对复杂图像进行分割会导致错误结果.LGAC模型仅考虑到局部均值信息,忽略了噪声对

分割产生的影响,因此没有完全将伪影区域和背景区域区分.本文方法引入的局部熵可以较好地检测强噪声对该区域均值的贡献大小,起到一个低通滤波的作用,从而准确地找出目标边界.同时解决了伪影、弱边界、噪声、灰度不均匀等因素对分割的影响,使得演化曲线有较大的自由度.




图2 不同噪声左心室MR图像的分割实验

表2是本文方法对含有0,0.01,0.03,0.05的高斯噪声的左心室核磁共振图像的DSC、FNR、FPR、RSE值比较.表2数据可以看出,在复杂背景的影响下,本文方法仍然可以较好地识别伪影区域,得到较为理想的分割结果.

4.3 血管图像的分割实验

图3是不同初始曲线血管图像的分割结果.该图像具有明显的灰度不均匀性和细长的拓扑结构.本文方

表2 不同程度噪声图像的精度指标值比较

高斯噪声	DSC	FNR	FPR	RSE
0	0.9782	0.0014	0.0160	0.0032
0.01	0.9611	0.0380	0.0399	0.0069
0.03	0.9585	0.0333	0.0499	0.0074
0.05	0.9312	0.1009	0.0384	0.0126

法利用局部熵量化局部信息,充分刻画了图像的细节,

从而可以较好地避免初始曲线对分割结果的影响,同时克服灰度不均匀现象和细长拓扑结构的影响,得到

正确的分割结果.




图3 真实血管图像的分割结果

5 结论

本文针对复杂背景图像分割问题,提出局部熵驱动的 GAC 模型,并给出基于二值水平集方法的快速求解算法.局部熵可以量化局部范围内的灰度变化,构造基于局部熵的符号压力函数,提高了模型的实时性以及对复杂背景和水平集变化的鲁棒性.

参考文献

- [1] Ding C, HE X F, ZHA H Y, et al. A min-max cut algorithm for graph partitioning and data clustering [A]. IEEE International Conference on Data Mining [C]. San Jose: IEEE, 2001. 107 - 114.
- [2] Grady L, Schwartz E L. Isoperimetric graph partitioning for image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(3): 469 - 475.
- [3] Kass M, Witkin A, Terzopoulos D. Snake active contours models [J]. International Journal of Computer Vision, 1988, 1(4): 321 - 331.
- [4] Caselles V, Kimmel R, Sapiro G. Geodesic active contours [J].

International Journal of Computer Vision, 1997, 22(1): 61 - 79.

- [5] Chan T, Vese L. Active contours without edges [J]. IEEE Transactions on Image Processing, 2001, 10(2): 266 - 277.
- [6] Li C, Kao C, Gore J C, Ding Z. Minimization of region-scalable fitting energy for image segmentation [J]. IEEE Transactions on Image Processing, 2008, 17(10): 1940 - 1949.
- [7] 许新征, 丁世飞, 史忠植, 贾伟宽. 图像分割的新理论和新方法 [J]. 电子学报, 2010, 38(2): 76 - 81.
XU Xin-zheng, DING Shi-fei, SHI Zhong-zhi, JIA Wei-kuan. New theories and methods of image segmentation [J]. Acta Electronica Sinica, 2010, 38(2): 76 - 81. (in Chinese)
- [8] YANG Y, XU C, PAN W M. Image segmentation method using binary level set based on regional GAC model [J]. Journal of Computer Applications, 2009, 29(9): 2414 - 2417.
- [9] Xu C, YEZZI A, PRINCE J L. On the relationship between parametric and geometric active contours [A]. The 34th Asilomar Conference on Signals, Systems and Computers [C]. Pacific Grove: IEEE, 2000. 483 - 489.
- [10] 张建伟, 方林, 陈允杰, 等. 局部 GAC 模型在医学图像分

割中的应用[J]. 中国图象图形学报, 2012, 17(2): 215 - 221.

ZHANG Jian-wei, FANG Lin, CHEN Yun-jie, et al. Application of local GAC model for medical image segmentation[J]. Journal of Image and Graphics, 2012, 17(2): 215 - 221. (in Chinese)

[11] HE C, WANG Y, CHEN Q. Active contours driven by

weighted region-scalable fitting energy based on local entropy [J]. Signal Processing, 2012, 92(1): 587 - 600.

[12] LIE J, LYSAKER M, TAI X C. A binary level set method and some applications to mumford-shah image segmentation[J]. IEEE Transactions on Image Processing, 2006, 15(1): 1171 - 1181.

作者简介



王顺风 女, 1964 出生, 江苏宜兴人, 教授, 硕士生导师, 主要研究方向: 图像处理与分析模式识别、数值分析与算法.

E-mail: wsfnuist@yahoo.com.cn



冀晓娜 女, 1988 出生, 内蒙古赤峰人, 硕士研究生, 主要研究方向: 图像分析与处理与模式识别、数值分析与算法.

E-mail: jixiaona1@yahoo.com.cn