

基于局部统计信息的快速 CV 模型 MR 图像分割

张建伟 葛琦

(南京信息工程大学数理学院, 南京 210044)

摘要 Chan-Vese (CV) 模型以其能较好地处理图像的模糊边界和复杂的拓扑结构而广泛运用于图像分割中。但由于核磁共振 (MR) 图像广泛存在强度不均匀性, 因此 CV 模型不仅不能进行准确的分割, 而且迭代过程需要对所有图像数据进行反复计算, 分割效率很低。针对以上缺点, 提出了一种基于局部统计信息的用于快速进行图像分割的 CV 模型, 即首先在局部区域内, 通过计算统计量来得到像素点归类的贝叶斯后验概率, 并以此作为曲线演化的依据, 这样, 就能对强度不均匀的 MR 图像进行准确的分割; 然后设置两个表分别存储曲线内外部邻点, 并通过更新这两个表内的点来实现曲线演化, 从而不但大幅提高了计算速度, 并保持了水平集方法能自动处理拓扑结构变化的优点。

关键词 CV 模型 贝叶斯后验概率 水平集 MR 图像分割

中图分类号: TP391.41 文献标志码: A 文章编号: 1006-8961(2010)01-0069-06

MR Image Segmentation of Fast CV Model Based on Local Statistic Information

ZHANG Jian-wei GE Qi

(College of Math & Physics, Nanjing University of Information Science & Technology, Nanjing Jiangsu 210044)

Abstract Chan-Vese (CV) model which has good ability to handle the blurry boundary and complex topological structures in images has been widely used in image segmentations. However, the MR image which has intensity inhomogeneity cannot be segmented accurately by the CV model. And it needs computing all the data of the image during the iterative course. Aiming at these disabilities, a fast method of CV model based on statistics in local regions is proposed. First, by calculating the statistics in local regions, Bayesian posterior probabilities that decide which class the pixels belong to are obtained, which are the foundations of the evolution of curve. In this way, the MR images can be segmented accurately. And then two lists are set for storing joint points inside and outside of the curve, and it only need to update the two lists to evolve the curve. By this method, it not only saves lots of time but also preserves the advantages of level set methods, such as the automatic handling of topological changes.

Keywords CV model, Bayesian posterior probabilities, level set, MR image segmentation

0 引言

核磁共振成像 (magnetic resonance imaging MRI) 以其具有非介入性、非损伤性以及很少受目标物体运动的影响等特点, 已被广泛运用于医学临床

诊断。由于人体解剖结构复杂和不规则以及成像质量受多种因素的影响, 致使医学图像分割成为一个难点。近年来, 人们对于将活动轮廓模型应用于医学图像分割进行了大量研究。目前活动轮廓模型大体可分为基于边界的模型^[1]和基于区域的模型^[2]两类。其中基于区域的模型, 由于不需要利用图像梯度, 因

基金项目: 江苏省教育厅“青蓝工程”项目 (JSK2006018)

收稿日期: 2008-05-04 改回日期: 2008-12-26

第一作者简介: 张建伟 (1965—), 男, 教授, 博士生导师。2006 年于南京理工大学获工学博士学位。主要研究方向为图像处理与分析、模式识别、数值分析与算法。E-mail: zhangjw@nuist.edu.cn

此对具有弱目标边界的图像能进行更好的分割,同时能自动处理曲线的拓扑改变,适用于分割具有复杂拓扑结构的图像。文献[2]提出的 Chan-Vese(CV)模型,就是一种基于区域的活动轮廓模型。该模型将图像分为两个区域,每个区域具有不同的像素强度均值。文献[3]将 CV 模型拓展为多相水平集方法,即用多个水平集函数表示多个区域。

由于受技术局限和目标成像的人工因素影响,强度不均匀性广泛存在于许多医学图像中。对于这种情况,有学者将核函数引入 CV 模型,用来平滑模型的适应能量,再加上一个规范项,使得水平集函数不需要重新初始化^[4],以此减少计算量。但由于该方法利用的核函数的方差为常数,对于不同区域的强度不均匀性没有区别考虑,而且以上模型都是利用偏微分方程进行演化,因此需要反复计算图像数据,计算量仍不小。

针对以上方法的缺点,本文提出了一种基于局部统计信息的快速 CV 模型 MR 图像分割方法。该方法首先将分布假设加入到模型中;然后在较小的窗口中计算局部统计信息,并构造一个控制项用来防止可能因出现局部扭转现象^[5]而导致的分割失败;最后通过设置存储水平集曲线内外邻点的两个表,结合改进的能量模型来判断像素点的归属,同时对表进行删除和插入操作,并以此来移动曲线。这样不仅能准确地分割含强度不均匀和复杂拓扑结构的图像,而且大幅减少了计算时间,提高了分割效率。

1 Chan-Vese模型

设定义域为 Ω 的图像 $I(x)$ 被闭合边界曲线 C 划分为目标和背景两个区域 R_{in} 和 R_{out} , 其分别在曲线 C 的内外部分, 两区域的灰度均值分别为 c_0 和 c_1 。CV 模型的能量泛函如下:

$$E(C, c_0, c_1) = \mu L(C) + \lambda_1 \int_{R_{in}} |I(x) - c_0|^2 dx + \lambda_2 \int_{R_{out}} |I(x) - c_1|^2 dx \quad (1)$$

其中, $L(C)$ 为曲线 C 的弧长, $\mu, \lambda_1, \lambda_2 > 0$ 是权重系数, 式 (1) 的后两项称为适应能量。 c_0 和 c_1 是两个分别逼近区域 R_{in} 和 R_{out} 的部分的图像强度常数。当曲线 C 与目标边界不符合时, 则能量泛函 $E(C, c_0, c_1)$ 没有达到极小值, 只有当曲线位于目标边界时, 才能达到极小值。演化曲线 C 以水平集函

数表示, 这样能量泛函极小化问题就可以转化为利用偏微分方程演化曲线的问题。但在 CV 模型中, 区域 R_{in} 和 R_{out} 因没有考虑局部区域的图像信息, 故适应能量并不能准确地逼近原图像的目标边界, 致使曲线根据最大迭代步数只能停止在非真实的目标边界上。

为了准确分割含强度不均匀的图像, Li 等人提出了一种改进的局部适应能量^[4], 也即把式 (1) 中最后两项的适应能量改为以下形式:

$$E_1(C, f_1(x), f_2(x)) = \lambda_1 \int_{R_{in}} K(x-y) |I(y) - f_1(x)|^2 dy + \lambda_2 \int_{R_{out}} K(x-y) |I(y) - f_2(x)|^2 dy \quad (2)$$

其中, $K(u)$ 为计算局部区域信息的核函数。

$$K(u) = \frac{1}{(2\pi)\sigma^2} e^{-|u|^2/2\sigma^2} \quad (3)$$

$f_1(x), f_2(x)$ 分别是像素点 x 邻域内逼近图像强度的函数。方差 $\sigma > 0$ 为常数不变。

为了加快演化的速度, 加上偏差惩罚项^[6]

$$Q(\varphi) = \int_{\Omega} \frac{1}{2} (|\nabla \varphi(x)| - 1)^2 dx \quad (4)$$

但是核函数 $K(u)$ 的方差 σ 固定不变, 没有区别考虑不同区域的强度不均匀性。文献[6]证明了偏差惩罚项 $Q(\varphi)$ 可以使偏微分方程在每次迭代时不需要重新初始化。但在计算机上实现演化曲线的偏微分方程, 不仅计算量较大, 而且存在数值不稳定性。

2 基于局部信息的 CV 模型的快速分割法

该方法首先在局部区域内, 通过计算统计信息来得到像素点归类的贝叶斯后验概率, 进而得到改进的能量模型; 然后采用一种快速水平集方法, 即通过设置两个表分别存储曲线内外部邻点, 并根据改进的能量模型来对这两个表内的点进行更新, 以实现曲线的演化。

2.1 基于局部区域的分布模型

设 $S = \{R_{in}, R_{out}\}$ 是 CV 模型的两个分类, R_{in} 代表目标类, R_{out} 代表背景类。一般来说, 整个图像的强度分布符合高斯分布。设 $P(R_{in})$ 和 $P(R_{out})$ 分别为目标类和背景类关于像素点 x 的类先验概率, 且两者相等。像素点 x 属于 R_{in} 或者 R_{out} 的概率分别

为 $p(\mathbf{R}_{in}|\mathbf{x})$ 和 $p(\mathbf{R}_{out}|\mathbf{x})$ 。

$$\begin{aligned} p(\mathbf{R}_{in}|\mathbf{x}) &= \frac{P(\mathbf{R}_{in})S(u(\mathbf{x})|\mathbf{R}_{in})}{T} \\ p(\mathbf{R}_{out}|\mathbf{x}) &= \frac{P(\mathbf{R}_{out})S(u(\mathbf{x})|\mathbf{R}_{out})}{T} \end{aligned} \quad (5)$$

其中, $u(\mathbf{x})$ 表示像素点 \mathbf{x} 的灰度值, $S(u(\mathbf{x})|\mathbf{R})$ 是 $u(\mathbf{x})$ 和类 \mathbf{R} 的相似度, 也即在类 \mathbf{R} 条件下出现点 \mathbf{x} 的灰度值的概率, T 是一常数, $T = P(\mathbf{R}_{in})S(u(\mathbf{x})|\mathbf{R}_{in}) + P(\mathbf{R}_{out})S(u(\mathbf{x})|\mathbf{R}_{out})$ 。根据贝叶斯决策规则, $u(\mathbf{x})$ 被归类于目标类 \mathbf{R}_{in} , 如果

$$P(\mathbf{R}_{in})S(u(\mathbf{x})|\mathbf{R}_{in}) > P(\mathbf{R}_{out})S(u(\mathbf{x})|\mathbf{R}_{out}) \quad (6)$$

则 $u(\mathbf{x})$ 归于背景类 \mathbf{R}_{out} 的情况类似。如果每个像素点被归类于正确的区域, 那么这个不等式始终成立。这样, 解决分割问题就是极小化以下能量函数:

$$\begin{aligned} E(\mathbf{C}) &= \mathcal{H}(\mathbf{C}) - \int_{\mathbf{R}_{in}} \log(P(\mathbf{R}_{out})S(u(\mathbf{x})|\mathbf{R}_{in})) \, dx \, dy - \\ &\quad \int_{\mathbf{R}_{out}} \log(P(\mathbf{R}_{out})S(u(\mathbf{x})|\mathbf{R}_{out})) \, dx \, dy \end{aligned} \quad (7)$$

2.2 局部适应能量

因为图像内存在不同的区域, 每个区域都可能具有强度不均匀性。文献 [4] 虽引入了由方差不变的核函数改进的适应能量, 但没有将不同区域区别考虑。本文通过在充分小的邻域内来计算图像的统计信息能更准确地考虑强度不均匀性。引入以点 \mathbf{x} 为中心, 大小为 3×3 的窗口函数 $\mathbf{W}(\mathbf{x})$, 设两个函数 $v_1(\mathbf{x})$ 和 $v_2(\mathbf{x})$ 分别为窗口 $\mathbf{W}(\mathbf{x})$ 中曲线 \mathbf{C} 的内部区域 \mathbf{R}_{in} 和外部区域 \mathbf{R}_{out} 的灰度均值, σ_1, σ_2 为方差, 内外两个区域的像素点个数分别为 N_1, N_2 。

$$\begin{aligned} v_1(\mathbf{x}) &= \frac{\sum_{y \in (\mathbf{R}_{in} \cap \mathbf{W}(\mathbf{x}))} I(y)}{N_1} \\ v_2(\mathbf{x}) &= \frac{\sum_{y \in (\mathbf{R}_{out} \cap \mathbf{W}(\mathbf{x}))} I(y)}{N_2} \end{aligned} \quad (8)$$

$$\begin{aligned} \sigma_1 &= \frac{\sum_{y \in (\mathbf{R}_{in} \cap \mathbf{W}(\mathbf{x}))} (I(y) - v_1(\mathbf{x}))^2}{N_1} \\ \sigma_2 &= \frac{\sum_{y \in (\mathbf{R}_{out} \cap \mathbf{W}(\mathbf{x}))} (I(y) - v_2(\mathbf{x}))^2}{N_2} \end{aligned} \quad (9)$$

由于点 \mathbf{x} 是演化曲线上一点, 曲线经过点 \mathbf{x} 所在的邻域, 将该邻域分为两个部分, 每个部分的图像为互相独立的高斯分布。通过在尽可能小的窗口中计算像素点的归属, 可得到更加准确的能量函数, 以便精确分割图像。

这样, 即得到以下新的能量函数:

$$\begin{aligned} E(\mathbf{C}; v_1, v_2) &= \\ &\mathcal{H}(\mathbf{C}) - \int_{\mathbf{R}_{in}} \left[\log(P(\mathbf{R}_{in})) - \log(\sigma_1) - \frac{(u-v_1)^2}{\sigma_1} \right] \, dx \, dy - \\ &\int_{\mathbf{R}_{out}} \left[\log(P(\mathbf{R}_{out})) - \log(\sigma_2) - \frac{(u-v_2)^2}{\sigma_2} \right] \, dx \, dy \end{aligned} \quad (10)$$

由于 $P(\mathbf{R}_{in})$ 和 $P(\mathbf{R}_{out})$ 相等, 所以 $\log(P(\mathbf{R}_{in})) = \log(P(\mathbf{R}_{out}))$ 。在水平集框架下, 可得到以下演化方程:

$$\frac{\partial \Phi}{\partial t} = \chi(\Phi) \left[\mathcal{H} \left| \frac{\nabla \Phi}{|\nabla \Phi|} \right| + \log \frac{\sigma_1}{\sigma_2} - \left| \frac{(u-v_1)^2}{\sigma_1} - \frac{(u-v_2)^2}{\sigma_2} \right| \right] \quad (11)$$

其中, v_1 和 v_2 可由以下公式计算:

$$\begin{aligned} v_1 &= \frac{(H(\Phi)u)^* \mathbf{W}}{H(\Phi)^* \mathbf{W}} \\ v_2 &= \frac{((1-H(\Phi))u)^* \mathbf{W}}{(1-H(\Phi))^* \mathbf{W}} \end{aligned} \quad (12)$$

* 是卷积, H 为 Heaviside 函数, δ 为 Dirac 函数, 一般取

$$\delta(x) = \frac{\epsilon}{\pi(x^2 + \epsilon^2)}, \text{ 或将 } \delta(x) \text{ 替换成 } |\nabla \Phi|.$$

局部统计信息就是当前像素点的邻域内的统计特征, 是判断像素点归类的重要依据。在较小的区域中计算统计信息, 不仅能准确将像素点归类, 而且有利于得到曲线的最佳停止位置。

2.3 全局到局部一致限制项

在 CV 分片常数模型中, 水平集函数 Φ 的符号和分割出的各区域有关。一般可把图像视为多个类组成的类集 \mathcal{S} , 当理想的分割完成时, 同类的元素会被归于水平集函数 Φ 的同侧, Φ 的正部 Φ^+ 和负部 Φ^- 将图像分为两个不同特征的区域。

然而, 若仅利用局部统计信息进行演化, 则将使上述性质难以保持, 因为对于结构复杂的图像, 多个具有相同特征的区域可能被演化到 Φ 相反的一侧^[5], 出现这种情况会使分割失败。使用 Φ^+ 表示图像灰度值较高的部分, 用 Φ^- 表示图像灰度值较低的部分, 即可利用以下控制项来指导 Φ 的演化

$$\text{sgn}(v_1(\mathbf{x}) - v_2(\mathbf{x})), \text{ 对所有 } \mathbf{x} \in \Omega \quad (13)$$

其中, $\text{sgn}(t) = 1$, 如果 $t > 0$, $\text{sgn}(t) = 0$ 其他情况。当 $v_1 > v_2$ 时, 则控制项 $\text{sgn}(v_1(\mathbf{x}) - v_2(\mathbf{x}))$ 为 1。当 $v_1 < v_2$ 时, 则控制项阻止了水平集函数在像素点 \mathbf{x} 处的更新, 这就避免了错误归类的情况发生。改进

的演化方程为

$$\frac{\partial \varphi}{\partial t} = \operatorname{sgn}(v_1 - v_2) \delta(\varphi) \left| \operatorname{div} \left[\frac{\nabla \varphi}{|\nabla \varphi|} \right] + \log \frac{\sigma_1}{\sigma_2} - \left| \frac{(u - v_1)^2}{\sigma_1} - \frac{(u - v_2)^2}{\sigma_2} \right| \right| \quad (14)$$

如果利用偏微分方程进行演化, 则因为迭代步数不能根据图像情况决定, 而且要反复计算图像数据, 故速度很慢。若采用一种不使用偏微分方程演化的快速水平集方法, 同时在较小的区域中计算图像的统计信息, 则既能准确地对具有强度不均匀性和复杂结构的图像进行分割, 又能提高分割效率和节省时间。

2.4 快速水平集方法

2.4.1 快速水平集方法的思想

快速水平集方法就是首先建立存储曲线内外邻点的链表; 然后根据曲线上点的邻域的适应能量场, 对最佳逼近目标边界位置的收敛条件进行定义; 最后在演化过程中, 根据邻点适应能量的符号, 判断像素点的归属。若符合收敛条件, 则停止演化。由此可见, 实现演化曲线只需更新这两个表。

式(14)中的适应能量为

$$E_1 = \operatorname{sgn}(v_1 - v_2) \delta(\varphi) \left| \log \frac{\sigma_1}{\sigma_2} - \left| \frac{(u - v_1)^2}{\sigma_1} - \frac{(u - v_2)^2}{\sigma_2} \right| \right| \quad (15)$$

它也是曲线移动的主要推动力。若 $E_1 > 0$ 说明曲线应该扩张, 则曲线外部邻点应该转变为内部邻点; 若 $E_1 < 0$ 则曲线应该收缩, 即曲线的内部邻点应该转变为外部邻点, 并且该适应能量只有严格在目标部分或背景部分的点, 才与其相邻点具有相同的符号。作为理想状态, 当演化停止时, 曲线上的点必停止在目标边界上, 从而该点位于曲线内外部邻点的适应能量项的符号必相反。

设 $N_4(\mathbf{x})$ 表示像素点 \mathbf{x} 的 4 邻点。对于 $\forall \mathbf{x} \in \Omega$, 有两个邻域, 即在曲线外部的 $N_{\text{out}}(\mathbf{x})$ 和曲线内部的 $N_{\text{in}}(\mathbf{x})$ 。

设置存储边界点的外部邻域点的链表 L_{out} 和内部邻域点的链表 L_{in} :

$$\begin{aligned} L_{\text{out}} &= \{\mathbf{x} \mid \varphi(\mathbf{y}) < 0 \text{ 并且 } \exists \mathbf{y} \in N_4(\mathbf{x}) \text{ 使得 } \varphi(\mathbf{y}) \geq 0\}; \\ L_{\text{in}} &= \{\mathbf{x} \mid \varphi(\mathbf{y}) > 0 \text{ 并且 } \exists \mathbf{y} \in N_4(\mathbf{x}) \text{ 使得 } \varphi(\mathbf{y}) \leq 0\} \end{aligned} \quad (16)$$

检查当前点是否符合收敛条件, 即

$$\operatorname{Con}(\mathbf{x}) = \begin{cases} 1 & \forall \mathbf{x} \in L_{\text{out}}(\mathbf{x}), \exists \mathbf{y} \in N_4(\mathbf{x}) \text{ 有 } \varphi(\mathbf{x})\varphi(\mathbf{y}) \leq 0 \text{ 且 } I(\mathbf{x})I(\mathbf{y}) > 0 \\ 0 & \forall \mathbf{x} \in L_{\text{out}}(\mathbf{x}), \forall \mathbf{y} \in L_{\text{in}}(\mathbf{y}) \text{ 有 } I(\mathbf{x})I(\mathbf{y}) < 0 \end{cases} \quad (17)$$

如果 $\operatorname{Con}(\mathbf{x}) = 0$ 即符合收敛条件, 则停止演化。也即当表 L_{in} 和表 L_{out} 内所有点的适应能量的符号完全相反, 则说明曲线和目标边界相符合。如果 $\operatorname{Con}(\mathbf{x}) = 1$, 则因收敛条件不符合, 故需要根据适应能量项的符号决定向内或向外移动演化曲线上的点。曲线演化时, 需要计算每个当前考察点的收敛条件, 即需要计算该点邻域内所有点的适应能量, 以取得相应的符号, 若取 8 邻域考察, 则会增加重复计算和存储开销。

式(14)中, $\operatorname{sgn}(v_1 - v_2) \delta(\varphi) \operatorname{div} \left[\frac{\nabla \varphi}{|\nabla \varphi|} \right]$ 是与曲率有关的在演化中用于保持曲线的几何特性和平滑性的正则项。由文献[7]知, 正则项的作用相当于高斯平滑, 因此在完成以上演化后, 即可利用高斯滤波对当前表 L_{out} 和 L_{in} 中的点 \mathbf{x} 上的水平集函数 $\varphi(\mathbf{x})$ 进行平滑; 再根据计算后的水平集函数 φ 的符号进行判断, 若为正, 则将该点归于表 L_{in} ; 若为负, 则归于 L_{out} 。最后根据收敛条件, 判断是否停止演化。

建立数组 D 用来存放水平集函数 φ 。建立数组 I 用来存放适应能量符号。

将 φ 初始化为: 若 $\varphi(\mathbf{x}) = -3$ 则点 \mathbf{x} 在曲线 C 外部, 且 $\mathbf{x} \notin L_{\text{out}}$; 若 $\varphi(\mathbf{x}) = -1$, 则 $\mathbf{x} \in L_{\text{out}}$; 若 $\varphi(\mathbf{x}) = 0$ 则点 \mathbf{x} 在零水平集曲线上; 若 $\varphi(\mathbf{x}) = 3$ 则点 \mathbf{x} 在曲线 C 的内部, 且 $\mathbf{x} \notin L_{\text{in}}$; 若 $\varphi(\mathbf{x}) = 1$, 则 $\mathbf{x} \in L_{\text{in}}$ 。

2.4.2 L_{out} 和 L_{in} 的快速符号表和更新算法

算法 1 快速符号表算法步骤如下:

- 1) 初始化记号表, 建立一个 2 维数组 $FH(\mathbf{p})$, 每一个数组元素对应于一个网格点, 将与所有网格点对应的记号表值初始化为 -3 ;
- 2) 在零水平集所包含的区域内取一个种子点 \mathbf{p}_1 ;
- 3) 建立工作栈 H_{in} , 将点 \mathbf{p}_1 存入, 并将种子点 \mathbf{p}_1 所对应的记号表值修改为 3 ;
- 4) 反复执行以下操作, 直到栈 H_{in} 为空。取出

H_{in} 的栈顶元素 top 逐个考察 top 的四邻点中的值为 -3 的邻点 p_N 。若邻点 p_N 与 top 构成的网格线与当前零水平集不相交, 则将邻点 p_N 的记号表值修改为 3 并将邻点 p_N 放入栈 H_{in} 。若邻点 p_N 与 top 构成的网格线与零水平集相交, 则将 top 的记号表值改为 1 并将 top 放入表 L_{in} 。

5) 对于表 L_{in} 中的各点, 依次考察其 4 邻点, 若邻点的记号表值为 -3 则将该邻点存入表 L_{out} 并标记值为 -1 ; 如果邻点恰好在零水平集上, 则继续考察该邻点的 4 邻点, 若邻点的记号表值为 -3 则将该邻点存入表 L_{out} 并标记为 -1 ; 否则, 跳过。

算法结束时, 记号表中, 值为 3 的点是内部点, 记号表值为 1 的点是表 L_{in} 中的点, 记号表值为 -1 的点是表 L_{out} 中的点, 记号表值为 -3 的点是外部点。

算法 2 L_{out} 和 L_{in} 的更新算法

将 $change_in(x)$ 操作定义为将表 L_{out} 中的点转移到表 L_{in} 中的过程。其具体算法步骤如下:

1) 删除表 L_{out} 中的点 x , 并加入到表 L_{in} 中, 同时设 $\varphi(x) = 1$ 。

2) $\forall y \in N_4(x)$ 满足 $\varphi(y) = -3$ 将点 y 加入到表 L_{out} 中, 令 $\varphi(y) = -1$ 。

将 $change_out(x)$ 操作定义为将表 L_{in} 中的点转移到表 L_{out} 的过程, 具体算法步骤如下:

1) 删除表 L_{in} 中的点 x , 并加入到表 L_{out} 中, 同时设 $\varphi(y) = -1$;

2) $\forall y \in N_4(x)$ 满足 $\varphi(y) = 3$ 将点 y 加入到表 L_{out} 中, 令 $\varphi(y) = 1$ 。

2.5 总体算法

总体算法步骤如下:

1) 初始化水平集函数 φ , 二值化适应能量 E_1 , 建立表 L_{in} , L_{out} 。

2) 对于表 L_{out} 中每一个点 x , 如果 $Con(x) = 1$ 且 $E_1(x) > Q$ 则进行 $Change_in(x)$ 操作。

3) 对于表 L_{in} 中每一个点 x , 如果 $\forall y \in N_4(x)$, $\varphi(y) > Q$ 则从表 L_{in} 中删除点 x , 并设 $\varphi(x) = 3$ 。

4) 对于表 L_{in} 中每一个点 x , 如果 $Con(x) = 1$ 且 $E_1(x) < Q$ 则进行 $Change_out(x)$ 的操作。

5) 对于表 L_{out} 中每一个点 x , 如果 $\forall y \in N_4(x)$, $\varphi(y) < Q$ 则从 L_{out} 中删除该点, 并设 $\varphi(y) = -3$ 。

检查是否符合收敛条件, 若符合, 则转步骤 6); 若不符合, 则转步骤 2)。

6) 先用高斯滤波对表 L_{out} 中每一个点 x 上的函数 $\varphi(x)$ 进行平滑, 若 $\varphi(x)$ 的符号为正, 则将该点转移到表 L_{in} 中, 同时调整相应各部分上 φ 的值; 再用高斯滤波对表 L_{in} 中每点上的函数 $\varphi(x)$ 进行平滑, 若 $\varphi(x)$ 的符号为负, 则将该点转移到表 L_{out} 中, 并调整相应各部分上 φ 的值。

7) 检查是否符合收敛条件, 若符合, 则结束算法; 若不符合, 则转步骤 2)。

3 实验结果与分析

为验证本文算法的分割效果, 采用两幅 MR 图像进行了分割实验。

实验是在 Pentium 4 0/2 0GHz/1GB RAM 计算机上, 利用 Matlab 7.0 实现。

图 1 是大脑 MR 图像, 图像中脑灰质与脑白质分布复杂, 具有细长拓扑结构和弱边界, 并具有强度不均匀性。图 1(a) 是原始图像及初始曲线; 图 1(b) 是 CV 模型的分割结果。由图 1 可看出, CV 模型还会将目标外的同质区域分割出来。这是因为没有考虑图像的局部统计信息, 所以使得分割不准确, 而且利用偏微分方程演化还会导致数值不稳定, 并无法动态地设置最佳迭代步数。图 1(c) 是本文模型的分割结果, 由于它基于了局部统计信息, 因此能准确地分割出主要目标边界, 不仅较好地克服了强度不均匀性的影响, 而且保持了水平集方法能自动操纵拓扑变化的优点。

图 2 是具有强度不均匀性和含噪声的心脏左心室的 MR 图像。图 2(a) 为原始图像及初始曲线。图 2(b) 是 CV 模型的分割结果。由图 2(b) 可看出, CV 模型在分割出目标边界的同时, 也分割出了非感兴趣的区域边界和噪声, 耗时 15.52s。图 2(c) 为本文模型的分割结果, 耗时 0.67s。由图 2(c) 可看出, 改进的模型能分割出主要的目标边界, 并具有分割出复杂拓扑结构的能力。相对于 CV 模型分割方法, 本文算法的计算速度提高了 23 倍。



图 1 大脑 MR 图像的分割结果
Fig. 1 Segmentation result of a brain MR image




图 2 左心室 MR 图像分割结果
Fig. 2 Segmentation result of a left-heart MR image

4 结 论

针对 CV 模型计算量大, 对于具有强度不均匀性和复杂结构的 MR 图像不能准确分割的缺点, 提出了一种基于局部统计信息的快速 CV 模型的图像分割方法。该方法不仅充分考虑了图像的局部统计信息和克服了由于图像强度的不均匀性而导致的分割不准确的缺点, 而且不使用偏微分方程演化曲线, 避免了数值的不稳定性、计算量较大以及无法动态的设定最佳迭代步数的问题。实验结果表明, 该方法不仅能准确分割出目标边界, 而且比利用偏微分方程演化方法的分割效率明显提高。但对于含强噪声的图像, 本文模型的分割结果仍不太理想, 今后将对这一问题做进一步研究。

参考文献 (References)

[1] Caselles V, Kimmel R, Sapiro G. Geodesic active contours[J]. International Journal of Computer Vision, 1997, 22(1): 61-79

- [2] Chan T, Vese L. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277.
- [3] Vese L, Chan T. A multiphase level set framework for image segmentation using the Mumford and Shah model[J]. International Journal of Computer Vision, 2002, 50(3): 271-293.
- [4] Li Chunming. Implicit active contours driven by local binary fitting energy[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Minneapolis, Minnesota, USA, 2007: 220-228.
- [5] Liu Jun-dong, Chelberg David. Automatic subcortical structure segmentation using local likelihood-based active contour[C]//Proceedings of the 10th International Conference on Medical Image Computing and Computer Assisted Intervention, Brisbane, Australia, 2007: 91-98.
- [6] Li C, Xu C, Gui C, et al. Level set evolution without re-initialization: A new variational method[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, San Diego, CA, USA, 2005: 430-436.
- [7] Shi Yon-gang. A Fast level set method without solving PDES[C]//Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2005), Philadelphia, Penn., USA, 2005: 97-100.