基于高斯混合分布和区域竞争主动轮廓的医学目标分割

尚岩峰 汪 辉 汪 宁

(中国科学院上海高等研究院 上海 201203)

摘 要 提出了一种基于高斯混合分布和区域竞争主动轮廓的医学目标提取模型。这一模型,把主动轮廓的能量函数表示为像素属于目标或背景的子类的最大概率的区域积分,在水平集合框架下使能量函数最小化,得到在高斯子类 区域间竞争演化的分割迭代方程。同时,附加的速度约束项使主动轮廓在越过目标边缘时速度降低,提高了分割的收敛性。通过大量肝脏CT图像的分割实验以及与几种经典模型和手工提取的比较,表明该模型在医学图像分割中具 有较好的健壮性、准确性和灵活性均较好。

关键词 医学图像,分割,高斯混合模型,主动轮廓,肝脏 中图法分类号 TP391.41 文献标识码 A

Medical Object Extraction by Gaussian Mixture Model and Region Competition Active Contour Model

SHANG Yan-feng WANG Hui WANG Ning

(Shanghai Advanced Research Institute, Chinese Academy of Sciences, Shanghai 201203, China)

Abstract This paper proposed a regional active contour model with an embedded classifier, based on a Gaussian mixture model fitted to the intensity distribution of the medical image. The difference between the maximum probability of the intensities belonging to the classes or subclasses of the object and those of the background is made as an energy term in the active contour model, and minimization of the whole energy function leads to a novel iterative equation. An additional speed controlling term slows down the evolution of the active contour when it approaches an edge, making it quickly convergent to the ideal object. The developed model has been applied to liver segmentation. Some comparisons are made between the geodesic active contour, C-V(active contour without edges), manual outline and our model. As the experiments show that our model is accurate, flexible and suited to extract objects surrounded by a complicated background.

Keywords Medical image, Segmentation, Gaussian mixture model, Active contour model, Liver

1 引言

在临床影像分析中,准确地分割出医学图像中特定的组 织器官是重建、量化分析和辅助诊断的重要前提。但由于医 学目标形状的差异性、待提取目标几何结构的复杂性、复杂背 景等噪声干扰,自动、准确地提取医学目标仍然是一个充满挑 战的课题。

在过去的数十年里,国内外研究者提出了大量的医学图 像分割模型,其中,主动轮廓模型是非常有效的目标提取方 法,在计算机视觉、模式识别和生物医学图像处理领域内得到 了广泛的应用。按照涉及到的特征图像和先验知识,主动轮 廓目标分割可以分为:基于边缘的^[1-3]、基于区域的^[4-7]和基于 先验知识的^[8-10]。在一些应用中,通过把这3种主动轮廓加 权组合来解决特定目标的提取问题。

基于边缘的主动轮廓分割是出现最早的,同时也是应用 最广泛的主动轮廓。此类模型采用图像梯度作为外部能量, 主动轮廓在各种力的综合作用下,向图像梯度最大的边缘演 化,一般取梯度图像的减函数作为中止轮廓演化的外部力量, 经典代表有测地轮廓模型(GAC)^[1]、几何轮廓模型^[2]和这两 种模型的扩展。比较详细的综述可以参考文献[11-13]。一 般来说,这类模型的缺点也比较明显,即它们在图像梯度比较 弱的地方容易泄漏,从而导致分割错误。

基于区域的主动轮廓在灰度平滑过渡的边缘分割效果要 优于基于边缘的。此类模型中,主动轮廓的演化主要依靠区 域和像素特征,演化速度一般由局部像素特征值、目标和背景 的统计特征等综合决定,典型代表有 C-V 模型^[4]和区域竞争 模型^[5]。此类模型在图像分割中得到了广泛的应用^[4-6]。但 是,此类模型有一个共同的缺点,即在图像灰度变化比较大的 目标边缘处,主动轮廓常常以比较高的速度往复移动,从而产 生分割误差。

一般地,对于 CT 等医学图像,图像的灰度信息反映了组 织结构的某种物理特征,是目标的最主要特征之一,可以用最 大期望(EM)方法^[14,15],通过混合高斯分布(GMM)拟和图像 的灰度直方图求得各个组织的灰度分布,包括软组织、肿瘤、

到稿日期:2011-11-27 返修日期:2012-04-04 本文受国家 02 重大科技专项(2011ZX02505-002),上海市科委项目(10DZ1500600)资助。 尚岩峰(1976一),男,博士,主要研究方向为医学图像分析、视频图像处理识别等,E-mail:aysyf@126.com;**汪** 辉(1975一),男,博士,研究员,主 要研究方向为图像传感;**汪** 宁(1974一),女,硕士,副研究员,主要研究方向为图像处理等。

脂肪、血管、肌肉等的分布,从而实现对 CT 图像的分类^[16,17]。 分割过程,就是判定像素点灰度属于哪类高斯分布的概率最高,该像素就属于哪一类。但是,单纯的灰度分类,没有考虑 到目标整体的几何结构,对于复杂的医学目标,无法滤除灰度 接近的背景,并且目标的噪声点也很多。

本文把医学图像的混合高斯分布表达为主动轮廓线模型 的能量项,得到了一个新的模型:基于混合高斯分布的区域竞 争主动轮廓模型(GMMAC)。其通过添加速度控制项来降低 主动轮廓在目标边缘的演化速度,从而提高分割精度。

2 研究背景

主动轮廓模型通常定义为封闭曲线或曲面的一个能量函数,通过最小化该函数,得到理想目标轮廓。能量函数由内部和外部能量组成。外部能量使主动轮廓收敛于目标边缘,内部能量使主动轮廓在演化过程中保持连续和平滑。外部能量可以来自于图像灰度,即为基于区域(灰度)的主动轮廓^[4,5],也可以来自于边缘图像,即为基于边缘的主动轮廓^[1,2]。测地主动轮廓^[1]和 C-V 模型^[4]是比较典型的例子。轮廓平滑的内部能量,一般为轮廓上的线或面积分。

基于边缘的主动轮廓通常定义一个对封闭曲面积分的能 量函数,通过最小化能量函数得到理想轮廓。一般地,线或面 积分的能量函数为:

$$E(C) = \alpha \int_{0}^{1} |C'(q)|^{2} dq + \beta \int_{0}^{1} |C''(q)|^{2} dq - \gamma \int_{0}^{1} |\nabla I(C(q))| dq$$
(1)

式中, $I:[0,a] \times [0,b] \rightarrow \Re^+$ 是原始输入图像, $C:[0,1] \rightarrow \Re^+$ 是 一参数化的封闭曲线, $\alpha,\beta \pi \gamma$ 是正实数。其中,一个较为重 要的模型是测地轮廓线模型,它通过最大梯度法使能量函数 最小化,产生了水平集框架下的演化方程:

$$\frac{d\phi}{\partial t} = \alpha \cdot g(|\nabla I|)(k+v_0) |\nabla \phi| + \beta \cdot \nabla g(|\nabla I|) \cdot \nabla \phi$$
(2)

式中,*k* 是平均曲率,*v*₀ 是使主动轮廓膨胀($v_0 > 0$)或者收缩 ($v_0 < 0$)的常数力,*g*:[$0, \infty$)→ \Re^+ 是一个严格的单调减函数, 比如 *g*($|\nabla I|$)=($1+|\nabla I|$)⁻¹, α 和 β 是常数。

基于区域的主动轮廓通过最小化与区域有关的能量函数 使区域边界演化到理想目标,通常,要利用区域的统计特征。 作为基于区域主动轮廓的典型,C-V 模型通过在水平集框架 下最小化 Mumford-Shah^[5]能量函数来提取目标,其相应的轮 廓演化方程是:

$$\frac{d\phi}{\partial t} = \delta_{\epsilon}(\phi) \{ \mu \cdot \operatorname{div}(\nabla \phi / | \nabla \phi|) - v - \lambda_1 (I(x, y) - u_o)^2 + \lambda_2 (I(x, y) - u_b)^2$$
(3)

式中, u_o 和 u_b 分别是目标和背景的平均灰度; $\delta_c(\phi)$ 是一维的 Dirac 函数;v是膨胀或收缩常数项; $\mu_s\lambda_1$ 和 λ_2 是常系数。

3 基于混合高斯分布的区域竞争主动轮廓模型

对于一幅 n 维图像,假设图像内共有 K 类组织结构,每 类的统计分布参数为 α_i ,其中, $i=1,\dots,K$ 。那么,图像分割 问题就是每个像素的分类问题,即判定每个像素属于 K 类的 哪一个。由此,得到典型的能量函数^[5]:

$$E[\Gamma_i, \alpha_i] = \sum_{i=1,\dots,K} \{-\lambda \int_{\Omega_i} \log P(I(x) \mid \alpha_i) dx + \mu \int_{\Gamma_i} ds \}$$
(4)

式中, $(\Omega_1, \dots, \Omega_K)$ 是所有的组织结构区域, $\Omega = \bigcup_{i=1}^{\ell} \Omega_i, i \neq j$ 时 $\Omega_i \cap \Omega_j = o$ 。 Γ_i 为每一组织结构的轮廓,有 $\Gamma_i = \partial \Omega_i, x = [x_1, x_2, \dots]^T$ 。

值得注意的是,式(4)中的 α_i 为比较泛化的灰度分布,可 以根据目标特征选择合适的分布模型。 α_i 之间可以分布相 同,也可以是完全不同的分布模型。对于一些复杂的组织结 构,要提取的目标常常由多个子目标组成。比如肝脏器官包 括了肝脏组织、肝脏内动静脉血管和一些肿瘤囊肿等结构,在 提取整个肝脏时,就要视它们为肝脏大类中的多个子类。假设 要提取的目标包括 m 个子区域 $\Omega = \bigcup_{i=1}^{m} \Omega_i$,其背景就是 $\Omega_i = \sum_{i=m+1}^{K} \Omega_i$ 。在同类的多个子类间,采用概率最大策略来设计速 度函数,即在 $P(I(x) | \Omega_o) = \max_{i=1,...,m} P(I(x) | \alpha_i)$ 和 $P(I(x) | \Omega_o) = \max_{i=m+1,...,K} P(I(x) | \alpha_i)$ 时,目标和背景分类或分割错误的 概率最小。于是,得到如下能量方程:

$$E[\Gamma_{o}, \alpha_{i}] = \mu \int_{\Gamma_{o}} ds - \lambda \{ \int_{\Omega_{o}} \log \max_{i=1,\dots,m} P(I(x) \mid \alpha_{i}) dx + \int_{\Omega = \Omega_{o}} \log \max_{i=m+1,\dots,K} P(I(x) \mid \alpha_{i}) dx \}$$
(5)

为了使能量函数 E 最小化,目标区域 Ω_{o} 和背景区域 Ω_{o} 在边缘 Γ 处进行竞争,在竞争过程中,其受到局部平滑性、局 部边缘长度最小和区域整体统计特征的约束。水平集框架 下,轮廓嵌入在符号距离函数 $\phi(x)$ 中,定义轮廓 Γ 为 $\phi(x)$ 的 零水平($\{x | \phi(x) = 0\}$),符号距离函数有 $| \bigtriangledown \phi(x) | = 1$ 。目标 和背景区域可以用 Heaviside 函数 $H(\phi)$ 重新表示,则目标区 域为 $\Omega_{o} = \{(x) | \phi(x) > 0\} = H(\phi(x))$,背景区域为 $\Omega_{o} = \{(x) | \phi(x) > 0\} = H(\phi(x))$,背景区域为 $\Omega_{o} = \{(x) | \phi(x) > 0\} = H(\phi(x))$,背景区域为 $\Omega_{o} = \{(x) | \phi(x) = 0\} = \delta(\phi)$ (x))。其中 $\delta(\phi)$ 为 Dirac 函数, $\delta(\phi(x)) = H'(\phi(x))$ 。

按照函数 f()在曲面的积分定义 $\int_{\Omega} f(x) \delta(\phi(x)) | \nabla \phi(x) |$ dx,式(5)中第三项轮廓的面积分 $\int_{\Gamma} ds$ 表示为对目标的区域积 分,有:

$$\int_{\Gamma} ds = \int_{\Omega} \delta(\phi(x)) \mid \nabla \phi(x) \mid dx$$
(6)

能量函数式(5)随着轮廓面 Γ 的变化而变化, Γ 蕴含在函数 $\phi(x)零水平中,则能量函数可表示为 <math>\phi(x)$ 和 $\nabla \phi(x)$ 的函数,将式 $H(\phi)$ 和式(6)代人式(5)中,得到:

$$E[\phi(x), \nabla\phi(x), \{a_i\}] = \int_{\Omega} \delta(\phi(x)) | \nabla\phi(x) | dx - \lambda\{\int_{\Omega} \log \max_{i=1,\dots,m} P(I \mid a_i) H(\phi(x)) dx + \int_{\Omega} \log \max_{i=m+1,\dots,K} P(I \mid a_i) (1 - H(\phi(x))) dx\}$$

$$= \int_{\Omega} \{-\lambda \log \max_{i=1,\dots,m} P(I \mid a_i) H(\phi(x)) - \log \max_{i=m+1,\dots,K} P(I \mid a_i) (1 - H(\phi(x))) + \delta(\phi(x)) | \nabla\phi(x) | \} dx$$

$$= \int_{\Gamma} F(x, \phi, \nabla\phi) dx$$
(7)

当满足欧拉-拉格朗日差分方程时^[20],能量函数 E 最小: $\frac{\partial F}{\partial \phi} - \frac{\partial}{\partial x} \frac{\partial F}{\partial \phi_x} - \frac{\partial}{\partial y} \frac{\partial F}{\partial \phi_y} - \frac{\partial}{\partial z} \frac{\partial F}{\partial \phi_z} = 0$ (8)

• 258 •

式(8)的第一项为:

$$\frac{\partial F}{\partial \phi} = -\lambda \left[\log \max_{i=1,\dots,m} P(I|\alpha_i) - \log \max_{i=m+1,\dots,K} P(I|\alpha_i) \right] \cdot \delta(\phi) + \mu \frac{\mathrm{d}\delta(\phi)}{\mathrm{d}\phi} |\nabla \phi|$$
(9)

式(8)的后三项为:

$$\frac{\partial}{\partial x} \frac{\partial F}{\partial \phi_x} + \frac{\partial}{\partial y} \frac{\partial F}{\partial \phi_y} + \frac{\partial}{\partial z} \frac{\partial F}{\partial \phi_z}$$

 $= div(\frac{\partial F}{\partial \phi_x}, \frac{\partial F}{\partial \phi_y}, \frac{\partial F}{\partial \phi_z})$
 $= div(\mu\delta(\phi) \frac{\partial |\nabla \phi|}{\partial \phi_x}, \mu\delta(\phi) \frac{\partial |\nabla \phi|}{\partial \phi_y}, \mu\delta(\phi) \frac{\partial |\nabla \phi|}{\partial \phi_z})$
 $= div(\mu\delta(\phi) \frac{\phi_x}{|\nabla \phi|}, \mu\delta(\phi) \frac{\phi_y}{|\nabla \phi|}, \mu\delta(\phi) \frac{\phi_z}{|\nabla \phi|})$
 $= \mu div(\delta(\phi) \frac{\nabla \phi}{|\nabla \phi|})$
 $= \mu \delta(\phi) div(\frac{\nabla \phi}{|\nabla \phi|}) + \mu \nabla \delta(\phi) \frac{\nabla \phi}{|\nabla \phi|}$
 $= \mu \delta(\phi) div(\frac{\nabla \phi}{|\nabla \phi|}) + \mu \frac{d\delta(\phi)}{d\phi} |\nabla \phi|$ (10)

式(9)和式(10)相减,得到静态方程:

$$\delta(\phi) \{-\lambda [\log \max_{i=1,\dots,m} P(I \mid \alpha_i) - \log \max_{i=m+1,\dots,K} P(I \mid \alpha_i)] - \sum_{i=1}^{K} P(I \mid \alpha_i) \} = 0$$

 $\mu div(\frac{\nabla \varphi}{|\nabla \phi|}) = 0 \tag{11}$

为了得到静态方程,一般采用最大梯度法,即从一个初始的水平集函数 $\phi(x)$ 逐步向理想轮廓演化。当能量达到最小值时,轮廓收敛不再变化,有 $\frac{\partial \phi}{\partial t}=0$,这时,满足能量最小:

$$\frac{\partial \phi}{\partial t} = \delta(\phi) \left\{ \lambda \left[\log \max_{i=1,\dots,m} P(I \mid a_i) - \log \max_{i=m+1,\dots,K} P(I \mid a_i) \right] + \mu div(\frac{\nabla \phi}{\mid \nabla \phi \mid}) \right\}$$
(12)

目标和背景各自最大概率的对数差,形成了主动轮廓的演 化力。当某像素以较大概率属于目标时, $\log \max_{i=1,\dots,m} P(I|\alpha_i) - \log \max_{i=m+1,\dots,K} P(I|\alpha_i) > 0$ 表示主动轮廓生长;反之, $\log \max_{i=1,\dots,m} P(I|\alpha_i) - \log \max_{i=m+1,\dots,K} P(I|\alpha_i) < 0$ 表示主动轮廓收缩。max ()在类内取概率最大的子类,从而把类内所有子类自动地合并为同一目标区域。

一般地,假设图像中医学目标的灰度为高斯分布 $G(\mu, \sigma)$,这在大多数医学图像中均是成立的。整幅图像的灰度分 布可以描述为多个高斯分布的混合, $\sum_{i=1}^{K} \beta_i G(\mu_i, \sigma_i)$,其中, β_i, μ_i 和 σ_i 分别为各个子目标区域 Ω_i 的先验概率、均值和方差, K 为总的类别数目。图 1 是肝脏 CT 图像的灰度直方图和其混 合高斯分布。其中,横坐标是 CT 图像的灰度值,纵坐标是某 灰度像素占总像素个数的比率。红色是原始灰度直方图,蓝 色虚线是各个目标估计出的高斯概率函数,绿色是混合高斯 概率曲线。高斯分布的参数 $\alpha_i = \{\beta_i, (\mu_i, \sigma_i)\}$ 可以用最大期 望算法(EM)来计算^[14]。以下是对灰度直方图用 EM 算法估 计混合高斯分布:

$$\omega_{ni} = p(\Omega_i | h(n), (\mu_1, \sigma_1), \cdots, (\mu_K, \sigma_K))$$
$$= \frac{\beta_i p_i(h(n) | (\mu_i, \sigma_i))}{\sum\limits_{i=1}^{K} \beta_j p_i(h(n) | (\mu_j, \sigma_j))} \sim P(I(x) | \alpha_i)$$

其中,

$$\beta_{i}^{pew} = \frac{1}{N} \sum_{n=1}^{N} \omega_{ni} h(n)$$

$$\mu_{i}^{pew} = (\frac{1}{\sum_{n=1}^{N} \omega_{ni} h(n)}) \sum_{n=1}^{N} \omega_{ni} \cdot h(n) \cdot n$$

$$\sigma_{i}^{pew} = (\frac{1}{\sum_{n=1}^{N} \omega_{ni} h(n)}) \sum_{n=1}^{N} \omega_{ni} h(n) \cdot (n - \mu_{i}^{pew}) (n - \mu_{i}^{pew}) \quad (14)$$

式中,N为灰度直方图的N个子类,每个子类对应区域 Ω_i ; ω_{ni} 为类权重,表示某一灰度(n)属于类 Ω_i 的程度,因此, ω_{ni} 用 来调和概率 $P(I(x)|_{\alpha_i})$ 。



图 1 肝脏 CT 图像的直方图和其混合高斯分布

于是,最终得到如下迭代方程:

$$\frac{\partial \phi}{\partial t} = \delta(\phi) \left\{ \mu div(\frac{\nabla \phi}{|\nabla \phi|}) + \lambda \left[\max_{i=1,\dots,m} \left(\frac{(I-\mu_i)^2}{2\sigma_i^2} - \log \beta_i \right) - \max_{i=m+1,\dots,K} \left(\frac{(I-\mu_i)^2}{2\sigma_i^2} - \log \beta_i \right) x \right] \right\}$$
(15)

参数项 δ(φ)限制主动轮廓在零水平处有效,数值化产生 零水平附近的一个窄带。当主动轮廓以较大步长进行演化 时,很容易跑出窄带,从而产生不能预料的错误。用 | マφ | 替 换 δ(φ),使得可以在一个很大范围内自由演化。在演化过程 中,也可以设置一个较大的时间步长,从而较少分割时间。

较大的时间步长可以加速迭代,但容易使主动轮廓跨过 相邻目标区域间的狭小间隔。同时,由于灰度在边缘处变化 较大,使得相应的相邻像素灰度概率差异很大,因此导致主动 轮廓在边缘处以较高的速度往复迭代运动。为了使主动轮廓 在边缘处收敛,可添加速度控制项1/(1+a | ▽I・▽¢|)。当 ▽I和▽¢的绝对值较大并且方向一致时,速度控制项的值很 低,从而大大降低了主动轮廓的演化速度,使得分割结果在边 缘处收敛。用高斯滤波器平滑图像可以使速度控制项更加平 稳,最终得到如下演化方程:

$$\frac{\partial \phi}{\partial t} = \frac{|\nabla(\phi)|}{1 + \alpha |\nabla G(I) \cdot \nabla \phi|} \left\{ \mu div \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \lambda \left[\max_{i=1,\dots,m} \left(\frac{(I - \mu_i)^2}{2\sigma_i^2} - \log \beta_i \right) - \max_{i=m+1,\dots,K} \left(\frac{(I - \mu_i)^2}{2\sigma_i^2} - \log \beta_i \right) \right] \right\}$$
(16)

4 实现及试验

在以上基于混合高斯分布的主动轮廓模型(GMMAC)的 基础上,我们开发出一套医学目标提取系统,用于特定组织器 官的提取。GMMAC模型有3个输入:CT等原始三维医学 图像、初始零水平和先验混合高斯分布,如图2所示。根据预 先设定的待提取目标,GMMAC输出特定的轮廓面。通常 地,初始主动轮廓取为待提取目标上的几个鼠标拾取点,随 后,在 GMMAC模型驱使下,演化到整个目标轮廓。 用 12 个肝脏造影 CT 图像病例来验证 GMMAC 模型的 有效性。所有的图像由 Philips 64 排 Brilliance 设备扫描,使 用 Iomeron 造影剂。一个典型的体数据分辨率是512 * 512 * 120 像素,每层图像的物理分辨率是 0.58 * 0.58 mm²,2mm 的层厚,1mm 的层重叠。所有的病例均得到病人的许可。



图 2 GMMAC 模型框架图

对 GMMAC, GAC, C-V 和混合高斯模型分类器(GM-MC)等几种经典的分割模型进行了比较。取一个包含有两个 囊肿(两个深色区域)和一个肿瘤(白色区域)的肝脏病例图示 说明,如图3所示。肿瘤的灰度非常接近肝脏组织的灰度, GAC 和 C-V 无法准确地将其分割出,两种模型在肿瘤边缘均 产生泄漏。由 EM 算法求灰度直方图上的混合高斯分布得到 的分类器——GMMC,通过判定像素属于哪一高斯分布的概 率最高从而判定像素的类别,也可以提取出肿瘤区域,但其单 纯使用灰度信息,而没有利用像素的空间信息,会使得 GM-MC 对噪声极其敏感(见图 3),在肿瘤内部有很多噪声点。在 图像顶部小肿瘤的分割中,GAC由于不善于提取小的物体, 因此无法将其分割出;由于小肿瘤非常靠近肝脏外部的软组 织,并且灰度也很接近,C-V模型分割出现泄漏导致分割错 误。在肝脏分割中,C-V模型无法判别出肝脏、肾脏和一些软 组织;GAC比C-V模型果好一些,但在某些软组织处依然发 生泄漏。所有的模型参数均经过多次优化,以得到最好的分 割效果。图 4 是另一病例的分割比较。



蓝色是肝脏,红色是肿瘤和囊肿,绿色是血管, 左上的黄色矩形点是分割不同目标的初始主动轮廓

图 3 GAC(a)、C-V(b)、GMMC(c)、GMMAC(d)对肝脏的分割比较



图 4 GAC、C-V、GMMAC 对肝脏的分割比较

如图 3、图 4 所示,在目标背景比较复杂的情况下,GM-MAC 比 GAC 和 C-V 模型提取目标更准确、健壮。GAC 是 一基于边缘的主动轮廓模型,它采用 g(|▽I|)减函数作为中 止演化项。当主动轮廓向目标边缘演化时,g(|▽I|)能把演 化速度降低到零。相反地,一旦它穿过边缘,主动轮廓就再也 不能返回。因此,为了防止泄漏,一般用平滑滤波器对图像进 行过滤使得边缘区域突出和变宽,但其缺点是将导致分割的

目标变小,这在分割狭小目标时更为不利。C-V模型是基于 区域的主动轮廓模型,它采用图像灰度作为演化的控制力。 该模型本质上取 $\lambda_1(I-u_s)^2 - \lambda_2(I-u_s)^2$ 作为目标背景的分 类器,于是,当主动轮廓演化出目标时,灰度力变为负数,驱使 主动轮廓反方向收缩,向轮廓边缘移动。但是,λ1(1-u_)²λ₂(I-u_b)² 仅仅是一个阈值二类分类器,当目标和背景分布 比较复杂时,绝大多数医学图像无法简化为两类灰度目标。 并且,目标和背景的灰度平衡很容易受局部背景影响,背景某 区域灰度偏高或偏低,都会导致目标和背景间阈值的左右偏 移,偏移量和背景的偏高偏低量呈线性关系,如图1所示。因 此,C-V模型容易产生不可控制的分割误差。GMMAC采用 基于 GMM 分类器的速度控制项,可以灵活地提取任何兴趣 目标或者多个目标的混合,且不会产生错误分类。又由于 log $\max P(I|a_i) - \log \max P(I|a_i)$ 的自动选择作用,任意 相邻两类间的阈值均为两类混合分布的波谷。其唯一的缺点 是,它比GAC和C-V模型计算量多出一个混合高斯分布的 优化过程。对于分辨率为 512 * 512 * 120 的 CT 图像, 整个 肝脏的模型化,包括肝脏、肿瘤和血管,在一台奔腾4的3.4G 计算机上,大约要计算10分钟。图5是肝脏模型的重建结 果, 左图是图 3 的重建结果; 右图是图 4 的重建结果。



图 5 GMMAC 得到的肝脏模型的重建图

对于不同的待提取目标(例如肝脏、肿瘤和血管),GM-MAC采取不同的提取策略。对于肿瘤,由于单个目标灰度分 布相对均匀,可以设定待提取目标为单一肿瘤的高斯灰度区 域,在待提取的肿瘤上给出一个粗略的初始零水平,然后,经 过一定的迭代演化,就可以自动提取出肿瘤。对于血管,仅仅 在血管内部的主动轮廓演化是不足以提取出整个血管树的, 因为 GMMCAC 无法驱使主动轮廓演化到狭小血管内部,我 们采用血管外部演化策略来提取血管。具体步骤如下:1)设 定血管和肝脏为待提取的目标,GMMAC 经过迭代演化,可 以得到包括血管和肝脏组织的模版;2)在上一模板内,设置 肝脏为待提取目标,血管为背景,GMMCAC 迭代演化得到仅 仅包括肝脏的另一模板;3)两模板相减,即得到分割出的血 管树;4)使用 GMMCAC 中的曲率平滑项对血管结果进行进 一步的平滑调整(增加平滑项权重,设置一个较小的迭代次 数)。在调整过程中,用主动轮廓面的最小主曲率 k2 替换平 均曲率 div(\no \no / | \no \no |),可以更好地保持血管狭长的几何形 状。在已经提取出的肝脏、肿瘤和血管等的基础上,可以对临 床肝脏进行建模。

表1 肝脏3种分割算法的结果比较

病例	模型	VOE(%)	RVD(%)	ASD(mm)	RMS(mm)	MSD(mm)
1	GAC	8, 9	-6.1	1.5	2.4	29.2
1	C-V	9.5	5.1	1.3	2.6	22.6
1	GMMAC	5.1	2.9	0.8	1.5	16, 3
2	GAC	12.0	-4.3	1.6	3, 5	24, 5
2	C-V	13.1	10.4	2, 1	4.3	41.2
2	GMMAC	6.8	2.9	0.9	1.8	12.7

在文献[18]中,还利用特定的参数对分割结果做出了一 个综合评测,用百分制的形式进行表示,以便对分割效果进行 快速的判断,涉及到的参数有体积重叠错误率(VOE)、体积 差异(RVD)、平均面距离(ASD)、平方根面距离(RMS)、最大 面距离(MSD)。表1是两组肝脏和肿瘤 GMMAC 分割结果 与临床专家手工分割结果的比较。肝脏的分割误差比肿瘤的 误差大,这是因为肝脏背景组织复杂,主动轮廓演化过程中容 易溢出。整体上,自动分割结果还是可以接受的。

结束语 本文给出了基于混合高斯分布的区域竞争主动 轮廓模型。基于医学图像统计概率分布和水平集的三维目标 分割模型,把能量函数表示为目标和背景的子类属于该类高 斯概率的积分,在水平集框架下使能量函数最小化。附加的 速度约束项使得主动轮廓越过目标边缘时速度降低,从而提 高分割的准确性。把该模型应用于肝脏的建模,包括肝脏、血 管和肿瘤的分割。通过与 GAC 模型、C-V 模型、GMM 分类 器以及手工分割的试验比较,表明 GMMAC 模型是一种快 速、收敛、准确的分割模型。由于先验混合高斯分布的控制, 因此该模型可以灵活机动地从复杂背景下提取出多重目标。

参考文献

- Caselles V, Kimmel R, Sapiro G, Geodesic active contours[J]. International Journal of Computer Vision, 1997, 22:61-79
- [2] Malladi R, Sethian J A, Vemuri B C. Shape Modeling with Front Propagation - a Level Set Approach[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1995, 17: 158-175
- [3] Salah M B, Ayed I B, Mitiche A. Active Curve Recovery of Region Boundary Patterns[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34:834-49
- [4] Chan T F, Vese L A. Active contours without edges[J]. IEEE Transaction Image Processing, 2001, 10(2): 266-277
- [5] Zhu Song-cun, Yuille A. Region competition: Unifying snakes, region growing, and Bayes/MDL for multiband image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1996, 18:884-900
- [6] Precioso F, Barlaud M, Blu T, et al. Robust real-time segmentation of images and videos using a smooth-spline snake-based algorithm[J]. IEEE Transactions on Image Processing, 2005, 14: 910-924
- [7] Mukherjee D P, Ray N, Acton S T. Level set analysis for leuko-

(上接第239页)

- [18] Beckmann M J. On knowledge networks in science: collaboration among equals[J]. The Annals of Regional Science, 1994(28): 233-242
- [19] Beckmann M J. Economic models of knowledge networks[M]// Bat- Ten D, Casti J, Thord R, eds. Networks in Action, Springer-Verlag, Berlin, Germany, 1995, 159-174
- [20] Herlocker J L, Konstan J A, Terveen L G, et al. Evaluating collaborative filtering recommender systems[J]. ACM Trans. Inf. Syst, 2004, 22(1):5-53
- [21] Cleverdon C W. Introduction [J]. Information Storage and Retrieval, 1968, 4(2):85
- [22] Geisser S. Predictive Inference: an Introduction[M]. CRC Press,

cyte detection and tracking[J]. IEEE Transactions on Image Processing,2004,13:562-572

- [8] Cremers D, Tischhauser F, Weickert J, et al. Diffusion snakes: Introducing statistical shape knowledge into the Mumford-Shah functional[J]. International Journal of Computer Vision, 2002, 50,295-313
- [9] Chen Y M, Tagare H D, Thiruvenkadam S, et al. Using prior shapes in geometric active contours in a variational framework [J]. International Journal of Computer Vision, 2002, 50, 315-328
- [10] Shang Yan-feng, Yang Xin, Zhu Ming, et al. Prior based cardiac valve segmentation in echocardiographic sequences; geodesic active contour guided by region and shape prior[C]// Second Iberian Conference, IbPRIA 2005. 2005; 447-54
- [11] Suri J S, Liu K C, Singh S, et al. Shape recovery algorithms using level sets in 2-D/3-D medical imagery: A state-of-the-art review
 [J]. IEEE Transactions on Information Technology in Biomedicine, 2002, 6:8-28
- [12] Heimann T, Meinzer H P. Statistical shape models for 3D medical image segmentation: A review[J]. Medical Image Analysis, 2009, 13:543-563
- [13] Cremers D, Rousson M, Deriche R. A review of statistical approaches to level set segmentation: Integrating color, texture, motion and shape[J]. International Journal of Computer Vision, 2007,72:195-215
- [14] Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via the EM algorithm[J]. Journal of the Royal Statistical Society, Series B, 1977, 39(1): 1-38
- [15] 李新仕,王天江,刘芳. 基于高斯混合模型的视频运动对象自动 分割算法[J]. 计算机科学,2009,36(1):205-207
- [16] Soler L, Delingette H, Malandain G, et al. Fully Automatic Anatomical, Pathological, and Functional Segmentation from CT Scans for Hepatic Surgery[J]. Comp. Aid. Surg., 2001, 6(3): 131-142
- [17] Markova A, Deklerck R, Nyssen E, et al. Comparison of the trust-region and the expectation-maximization algorithm for the application of automatic liver segmentation[C] // IEEE Benelux EMBS Symposium, Brussels, Belgium, 2006
- [18] Heimann T, van Ginneken B, Styner M A, et al. Comparison and evaluation of methods for liver segmentation from CT datasets
 [J]. IEEE Trans Med Imaging, 2009, 28(8)

1993

- [23] Rafols I, Meyer M. Diversity and Network Coherenceas Indicators of Interdisciplinarity[J]. Case Studyies in bionanoscience, Scientometrics, 2010, 82(2): 263-287
- [24] Lin D. An Information-Theoretic Definition of Similarity[C]// Proceedings of the Fifteenth International Conference on Machine Learning (ICML 1998). Madison, Wisconsin, USA, 1998; 296-304
- [25] Budanitsky A, Hirst G. Evaluating WordNet-based Measures of Lexical Semantic Relatedness [J]. Computational Linguistics, 2006,32(1):13-47
- [26] Tversky A. Features of similarity [J]. Psychological Review, 1977,84(2):327-352