

文章编号 1004-924X(2014)02-0497-11

# 面向时飞磁共振血管造影术的 脑血管统计分割混合模型

王醒策<sup>1</sup>, 文 蕾<sup>1,\*</sup>, 武仲科<sup>1</sup>, 周明全<sup>1</sup>, 田 运<sup>1</sup>, 刘新宇<sup>2</sup>

(1. 北京师范大学 信息科学与技术学院, 北京 100875;

2. 中国科学院 计算技术研究所 前瞻研究实验室, 北京 100190)

**摘要:** 由于人体脑血管结构复杂, 空间比例小, 三维分割和重构十分困难, 本文面向时飞磁共振血管造影 (TOF MRA) 数据提出了一种新的瑞利高斯有限混合模型来实现脑血管的自动提取和分割。首先, 对已有的混合模型进行了分析; 然后, 采用最大强度投影法 (MIP) 预处理脑部数据后采用高斯分布拟合血管类, 采用瑞利分布和高斯分布拟合非血管类。提出的模型构造简单, 参数向量较少; 在血管与非血管的混合区域, 模型与灰度直方图具有较好的拟合性。模型在传统期望最大化 (EM) 算法中加入随机扰动项构造随机期望最大化 (SEM) 算法来实现混合模型参数估计, 降低了算法对初值的依赖, 同时提高了鲁棒性。实验证明, 与已有双高斯模型相比, 血管点数增加了 27%, 可细分到三级血管且细节的连通性更好。本模型可更准确地拟合数据的灰度分布曲线, 有效地分割脑血管主分支及周围较细小分支, 泛化性较好并可应用于相似系统中。

**关键词:** 飞行时间磁共振血管造影术; 脑血管分割; 有限混合模型; SEM 算法; 灰度直方图; 瑞利分布

**中图分类号:** TP391 **文献标识码:** A **doi:** 10.3788/OPE.20142202.0497

## Finite mixture model of stochastic cerebrovascular segmentation based on TOF MRA

WANG Xing-ce<sup>1</sup>, WEN Lei<sup>1,\*</sup>, WU Zhong-ke<sup>1</sup>, ZHOU Ming-quan<sup>1</sup>, TIAN Yun<sup>1</sup>, LIU Xin-yu<sup>2</sup>

(1. College of Information Science and Technology, Beijing Normal University, Beijing 100875, China;

2. Advanced Computing Research Laboratory, Institute of Computing Technology,

Chinese Academy of Sciences, Beijing 100190, China)

\* Corresponding author, E-mail: lwengo@gmail.com

**Abstract:** As the brain vessel of human has complex topological structure and smaller space proportion, it is hard to be segmented and reconstructed in three dimensions. Therefore, this paper proposes an automatic statistical intensity based approach for extracting the 3D cerebrovascular system from time-of-flight (TOF) Magnetic Resonance Angiography (MRA) data. First, the Finite Mixture Model (FMM) is analyzed, and it is used to fit the intensity histogram of the brain image sequence preprocessed by the Maximum Intensity Projection (MIP). Then, the Gaussian distribution is used to fit the vessel, and the Gaussian distribution and Rayleigh distribution are used to fit other low intensity tissues. Since the model is easy to realize and has a short

**收稿日期:** 2013-06-14; **修订日期:** 2013-08-10.

**基金项目:** 国家自然科学基金资助项目 (61271366, 61170170, 61003134, 61170203), 首都科技条件平台 (Z131110000613062); 中央高校基本科研业务费专项基金资助项目 (2012LYB49)

parameter vector, it decreases the parameter drift problem and can fit the intensity histogram well, especially in the cross region between the cerebrovascular and other tissues. Moreover, the stochastic disturbance is added in the traditional Expectation Maximization (EM) to construct Stochastic Estimation Maximization (SEM) algorithm to estimate the parameter vector, by which the method shows low initial value dependence and a high robust. As compared with the experiments, this model can segment more 27% cerebrovascular voxels than two Gaussian models do and it can segment in three level for the small cerebrovascular branches with a better connectivity. The model can fit a gray distribution curve of the data accurately, segment the main branch of brain vessel and slight vessel branch and can be used in other similar systems.

**Key words:** Time-of-flight Magnetic Resonance Angiography (TOF MRA); cerebrovascular segmentation, finite mixture model, stochastic estimation maximization (SEM) algorithm, intensity histogram, Rayleigh distribution.

## 1 引言

脑血管疾病一直是威胁人类健康的头号杀手,是 50 岁以上中老年人的常见病<sup>[1]</sup>。在我国脑血管发病率依然处于上升阶段并呈年轻化,给社会和家庭带来了沉重的负担。脑血管疾病主要是由于血管压力和栓塞使得血管形态发生重大变化(血管狭窄和动脉瘤)。若能够及时发现并监测脑血管形态变化及动脉瘤生长,则可有效地实现脑血管疾病(主要为脑血管破裂和脑梗塞)的预防和早期治疗。通过医学图像技术以非入侵方式实现脑血管的检测具有无创高效的特点,已经成为脑病医学诊断的重要辅助手段。磁共振血管造影术(Magnetic Resonance Angiography, MRA)和 CT 血管造影术(CT Angiography, CTA)是最为常用的脑血管成像方式。而 CTA 图像中骨元素对造影血管的影响严重,仅适于小范围内大血管分析。本文意在面向全脑血管进行分割和形态研究,因此,应用 MRA 数据作为研究样本。根据成像原理不同, MRA 数据主要分为 3 种方式:时飞法(Time-of-Flight MRA, TOF-MRA),相位对比法(Phase Contrast Angiography, PCA)及对比增强法(Contrast Enhanced MRA, CE-MRA)。其中, TOF-MRA 和 PCA 仅利用血管内本身固有的血流作为对比探测的媒介,而 CE-MRA 需要注射对比增强剂。鉴于 TOF-MRA 在临床中应用更加广泛,本文主要关注 TOF-MRA 脑血管图像的统计分割方法研究。

对于 MRA 脑血管数据,人工分割主观性强,再现性差且非常繁复。为了便于实际应用,全自

动 MRA 脑血管分割算法成为研究热点。现在主要的脑血管分割算法有模式识别方法,形变模型方法,追踪方法,智能方法,神经网络方法和管状物探测方法<sup>[2-4]</sup>,这些算法中大部分都可以在 ITK 工具中找到相应的软件包<sup>[5]</sup>。其中,基于模式识别的统计学方法由于无需人工输入参数和初始位置,比较适合普通用户实现自动分割。而传统的聚类算法(Fuzzy C-Means, FCM, KNN)或者 Parzen 窗等方法比较,参数统计模型可以用简单的模型描述物质的同质和异质性特征,且极大似然(Maximum Likelihood Methods, ML)可很好地实现参数估计。自从 Hartigan 提出频率混合聚类模型后<sup>[6]</sup>,很多研究者应用其实现 MRI 的组织分割和兴趣区域提取。特别是在 Dempster 提出了 EM(Expectation Maximization)算法后<sup>[7]</sup>, FMM 模型开始广泛应用,很多学者都在此框架下,应用不同模型模拟脑组织<sup>[8-10]</sup>。本文在前期工作的基础上<sup>[11-12]</sup>,将脑图像序列像素视为一系列的独立随机变量,通过定义瑞利高斯混合模型实现血管类和非血管类的分割;改进的 SEM(Stochastic Expectation Maximization)<sup>[13]</sup>算法实现了参数向量估计。

## 2 脑血管的有限混合模型

脑血管分割的数学描述为:假设脑图像序列可被定义为一有限集合  $X = \{x_{ijk} | 1 \leq i \leq I, 1 \leq j \leq J, 1 \leq k \leq Z\}$ ,其中:图像序列中体素个数为  $I \times J \times Z$ ;图像序列灰度水平集合定义为  $Q = \{0, 1, \dots, q\}$ ;体素灰度集合定义为  $I = \{I(x_{ijk}) | 1 \leq i \leq I, 1 \leq j \leq J, 1 \leq k \leq Z, I(x_{ijk}) \in Q\}$ 。脑血管分割

为集合  $X$  中的每一个元素设置标签  $L = \{\text{Background}_1, \dots, \text{Background}_n, \text{Vessel}\}$ , 即构造映射  $m: X \rightarrow L$ , 根据映射提取血管体素, 削减与血管无关的体素数据。

在统计学意义上, 脑图像序列体灰度可由某种混合分布产生, 这些混合分布被视为  $p$  个分布的线性融合, 即为公式(1):

$$I(x) = \sum_{i=1}^p \omega_i f_i(x), \quad (1)$$

其中:  $x$  为观测值;  $f_i$  是由参数  $\theta_i$  定义某种分布的概率密度函数; 而  $\omega_i$  则是混合的权值, 均为大于零的数, 应该满足  $\sum_{i=1}^p \omega_i = 1$ 。

通过假定给出混合分布中每个分量服从的概率分布, 则每个分量的概率密度函数形式为已知。设  $\Theta$  是混合分布的参数,  $\theta_t$  是第  $t$  个分布的参数, 则有限混合模型的概率密度函数可以写成:

$$f(x, \Theta) = \sum_{i=1}^p \omega_i f_i(x, \theta_i). \quad (2)$$

对于观测数据集  $X$ , 图像分割的目的是将每个观测值  $x_i$  都划分到其最可能属于的类中, 即找到最有可能的标签向量集  $L$ ,  $L_i$  是  $x_i$  的标签向量, 且

$$L_i = \{L_{i1}, \dots, L_{in+1}\}^T$$

$$L_{ik} = \begin{cases} 1 & x_i \text{ 属于第 } k \text{ 类} \\ 0 & \text{其他} \end{cases}. \quad (3)$$

观测数据  $x_i$  属于第  $k$  类的条件概率为:

$$p_k(x_i) = \frac{\omega_k f_k(x_i, \theta_k)}{\sum_{i=1}^p \omega_i f_i(x_i, \theta_j)}. \quad (4)$$

由此可见, 要得到观测数据的标签向量值, 即划分所有数据的类, 只需求出每个分布概率密度函数中的参数。可以将标签向量看成数据集中的隐含变量, 估计参数值。

MRA 图像序列是灰度图像, 其灰度直方图表示图像中具有每种灰度级的像素的个数, 反映图像中每种灰度出现的频率, 分析其直方图可知, 图像灰度是连续变化的。而有限混合模型中的概率密度函数反映的是某点属于某类或某一灰度的可能性, 表现为频率特征。若有限混合模型可以完全表征脑血管图像灰度分布情况, 将其图像序列的体素数  $I \times J \times Z$  相乘, 所得曲线必与血管体素的灰度直方图重合。因此, 可用此方法判定模型的拟合程度。

在近 10 年中很多人进行过统计学的脑血管分割研究<sup>[14-19]</sup>, 但 Wilson 和 Noble<sup>[20]</sup> 首次提出应用统计模型实现 TOF-MRA 脑血管的分割, 通过分析 TOF-MRA 的灰度直方图可知, 灰度值最低的数据主要包括脑脊液、骨头和空气成分; 灰度值次低的数据是由脑灰质、脑白质以及部分眼部组织构成; 高灰度值区域则主要包括脑血管和皮下脂肪。在该研究中将 TOF-MRA 的灰度直方图根据数据灰度值划分为上述 3 个区域, 用 2 个高斯分布分别拟合直方图低灰度区域的双峰, 用一个均匀分布拟合血管像素的分布, 如公式(5)所示:

$$f(x) = \underbrace{\omega_{G1} f_{G1}(x) + \omega_{G2} f_{G2}(x)}_{\text{非血管类}} + \underbrace{\omega_U f_U(x)}_{\text{血管类}}, \quad (5)$$

其中: 函数  $f_{G1}(x)$  和  $f_{G2}(x)$  为正态分布密度函数,  $f_U(x)$  为均匀分布密度函数, 相对应的系数  $\omega_{G1}$ ,  $\omega_{G2}$  和  $\omega_U$  为混合比例。其中: 正态分布和均匀分布的概率密度函数分别为:

$$f_G(x) = \frac{1}{\sqrt{2\pi}\sigma_G} \exp\left(-\frac{(x-\mu_G)^2}{2\sigma_G^2}\right), l \in [1, 2] \quad (6)$$

$$f_U(x) = \frac{1}{I}. \quad (7)$$

之后, Hassouna 等人<sup>[21-22]</sup> 在从 TOF-MRA 数据中提取 3D 脑血管的自动统计分割方法中提出了新的统计分割模型。用 1 个瑞利分布和 2 个高斯分布来拟合背景区域, 其中: 瑞利分布和 1 个高斯分布用于拟合非血管区域的 2 峰值, 另一个高斯分布用于拟合峰值间的数据。血管类则用一个高斯分布拟合, 如下式所示:

$$f(x) = \underbrace{\omega_R f_R(x) + \omega_{G1} f_{G1}(x) + \omega_{G2} f_{G2}(x)}_{\text{非血管类}} + \underbrace{\omega_{G3} f_{G3}(x)}_{\text{血管类}}, \quad (8)$$

其中: 函数  $f_R(x)$ ,  $f_{G1}(x)$ ,  $f_{G2}(x)$  和  $f_{G3}(x)$  分别为瑞利分布和正态分布密度函数。瑞利分布的概率密度函数为:

$$f_R(x) = \frac{x}{\sigma^2} \exp\left(-\frac{x^2}{2\sigma^2}\right). \quad (9)$$

Nobel 模型曲线和原始数据的灰度直方图如图 1(a) 所示, 蓝色虚线为模型拟合曲线(彩图见期刊电子版), 该曲线可大致拟合出数据的灰度直方图, 但在局部极值周围都没有准确的匹配, 同时, 血管类的均匀分布过广, 和非血管类重合在一

起。结果表明,此混合高斯模型可较好地分割出 Willis 环周围的动脉和小动脉瘤,但对于大动脉瘤会出现过分割现象,较难分割出血管末梢等细节。Hassouna 模型曲线和原始数据的灰度直方图如图 1(b)所示(彩图见期刊电子版),该混合模型较为准确地拟合了原始像素的灰度直方图,分割结果与手工分割的像素绝对误差较小,但是原始数据量过大,该模型还需结合其他分割算法才能得到理想的分割结果,并且在参数估计上要求的精度极高。理论上,联合高斯分布可以逼近拟合任何原始数据分布,但是如果在模型中设置过多的成分则会使待估计的参数急剧增加,计算复杂度较高。脑血管在脑图像序列中比例较小,大约为 5%左右,细微的参数偏移即会造成脑血管类的较大改变,所以设定合适的统计模型非常重要。

在前阶段工作中,采用双高斯模型来拟合经过 MIP 预处理后的数据集<sup>[11]</sup>,预处理后的数据仅包括血管和周围脑组织两部分,再用高斯分布分别对血管类和非血管类进行建模,这样能清晰地分割出 Willis 环周围的血管,但对细小的血管分割效果较差,血管断裂较多。郝聚涛<sup>[23]</sup>也做过相似的工作,他们的混合统计模型的概率密度分布函数如下式所示:

$$f(x) = \underbrace{w_{G1} f_{G1}(x)}_{\text{非血管类}} + \underbrace{w_{G2} f_{G2}(x)}_{\text{血管类}},$$

$$w_{G1} + w_{G2} = 1 \quad (0 \leq w_{G1} \leq 1, 0 \leq w_{G2} \leq 1).$$
(10)

上述各种混合模型均可以分割出脑血管<sup>[11,14-23]</sup>,但从数据拟合和参数估计分析可知,现有的有限混合模型存在下述局限性:

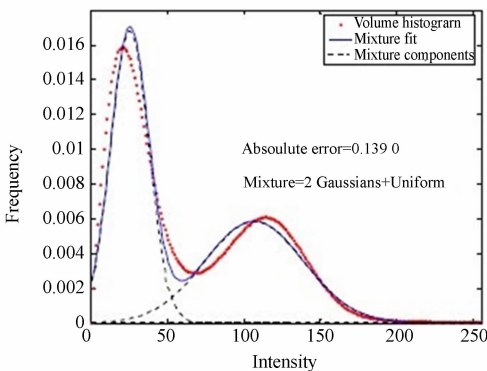
(1)强调拟合整体灰度直方图,对曲线局部极值处要求较高。大量的实验证明,直方图中血管类和非血管类交界处是拟合的关键,交界处数据拟合越精确,分割效果越好,其它低灰度值区域的拟合对准确分割的影响就较小。

(2)单纯假设各种组织的灰度分布为高斯分布,这使得所采用的混合模型和原始数据的灰度直方图间存在误差。

(3)若将血管数据简单地用均匀分布表示,血管的灰度值分布范围较广且有上下起伏,单一的均匀分布不能准确地描述血管灰度值的统计特性。

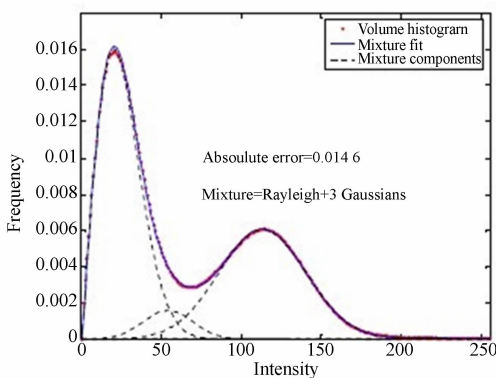
(4)若模型过多且复杂,会直接增加参数向量的长度,使得参数估计(EM)时,初始值设定过程复杂,同时算法计算量大且易收敛于局部极点。

由于血管数据和非血管数据的分布范围差异较大,前期工作所采用的双高斯模型简明地表示出数据的特征。实验结果证明,该模型可以较好地分割出 Willis 环周围的动脉血管<sup>[11]</sup>。但若获得细小的血管分支和更精细完整的血管轮廓,需要设计和数据更为匹配的统计模型。用最少的统计分量拟合原始数据,简化参数估计过程。通过分析 8 套 TOF-MRA 脑数据,经过大量实验和数学分析,本文提出了瑞利高斯混合模型,可有效的拟合实验数据的灰度直方图,特别可获得血管末梢等细节信息鲜明的血管模型。



(a) Wilson 和 Noble(1999)模型<sup>[3]</sup>

(a)FMM of Wilson 和 Noble model(1999)<sup>[3]</sup>



(b) Hassouna(2006)模型<sup>[3]</sup>

(b)FMM of Hassouna model(2006)<sup>[3]</sup>

图 1 脑血管有限混合模型分析

Fig. 1 FMM analysis of brain vessel

### 3 瑞利高斯混合模型

MIP 处理后<sup>[11]</sup>的血管灰度直方图如图 2 所示。分析直方图可见,此图的统计特征与 Hassouna<sup>[22]</sup>的灰度直方图明显不同。此图数据可分为两类,一类处于低灰度值区域,另一类处于高灰度值区域。血管的灰度值较亮,处于高灰度值区,非血管类分布在低灰度值区域。针对图像特征,应用多种统计模型对灰度直方图曲线进行拟合,利用瑞利高斯混合模型即可较准确地拟合曲线。采用瑞利分布对低灰度值区域的第一个峰处进行建模,可以较平滑的使拟合曲线过渡至第二个峰。对于处于低灰度区域的第二个峰,用高斯分布来拟合,以连接前后两区域。由于在整个数据中,颅内动脉的灰度分布较广,并且血管的灰度分布的起始值未知,所以选择高斯分布来拟合脑血管数据,从而确保了血管分布的广度和精度。




图 2 预处理后体数据的灰度直方图和瑞利高斯混合模型

Fig. 2 Rayleigh Gauss mixture model and histogram of TOF-MRA brain sequence after pretreatment

因此,混合统计模型的概率密度分布函数可写为:

$$f(x) = \omega_R f_R(x) + \omega_{G1} f_{G1}(x) + \omega_{G2} f_{G2}(x), \quad (11)$$

$$\omega_R + \omega_{G1} + \omega_{G2} = 1 \quad (0 \leq \omega_R \leq 1, 0 \leq \omega_{G1} \leq 1, 0 \leq \omega_{G2} \leq 1)$$

其中:系数  $\omega_R, \omega_{G1}$  和  $\omega_{G2}$  满足归一化条件,非血管类由  $f_R(x)$  和  $f_{G1}(x)$  拟合,血管类为  $f_{G2}(x)$ 。根据最大后验分类法则,若一个体素  $x_i$  属于血管类,则该体素属于血管类的概率要大于非血管类的概率,即满足下式条件:

$$f(G_2 | x_i) > f(R | x_i) + f(G_1 | x_i). \quad (12)$$

也可表示为:

$$\omega_{G2} f_{G2}(x_i) > \omega_R f_R(x_i) + \omega_{G1} f_{G1}(x_i). \quad (13)$$

若要正确分割脑血管,需要对公式(10)中概率密度函数的参数进行估计。包括各个分布的比例系数  $\omega$ ,瑞利分布中的  $\sigma$  以及高斯分布中的均值  $\mu_{G_l}$  和方差  $\sigma_{G_l}^2$ ,其中:  $l \in [1, 2]$ 。本文采用 SEM 算法进行参数估计。

### 4 SEM 参数估计

对有限混合模型的参数估计通常采用极大似然估计思想,即在已知结果的条件下,找到使这个结果出现的可能性最大的参数值。极大似然估计法虽然思路明确,但计算非常复杂,且受样本噪声影响较大,可采用 EM 算法对其进行改进。EM 算法通过在观测数据的基础上加入一些潜在数据来解决缺失数据下的参数估计,这种方法虽然计算过程简单,并可解决数据缺失的问题,但对初始值的依赖性较大、容易收敛到局部最大值且收敛速度较慢。所以,近年来,很多学者也提出了一些可以弥补 EM 算法缺点的改进算法,SEM 算法就是其中之一。

SEM 算法是 EM 算法的一个随机变体。它在 EM 算法的基础上加入了随机元,即包含了标签变量的随机指定过程。SEM 算法主要克服了 EM 算法的 3 个不足:对初始划分的依赖性、易收敛于似然函数的局部最小值、收敛速度慢。SEM 算法步骤如下:

SEM 算法随机选定参数向量的初始值  $\Theta^{(0)}$ ,第  $t+1$  次迭代的过程如下:

E 步:同 EM 算法的 E 步,计算样本的条件概率密度  $p_k^{(t+1)}(x_i)$ :

$$p_k^{(t+1)}(x_i) = \frac{\omega_k^{(t)} f_k(x_i)}{\sum_{j=1}^G \omega_j^{(t)} f_j(x_i)}$$

$$i = 1, \dots, n \quad k = 1, 2, \dots, G, \quad (14)$$

其中: $p_k^{(t+1)}(x_i)$  表示第  $i$  个样本属于第  $k$  个成分的条件概率密度; $n$  是样本数; $G$  是混合成分数, $\omega_k$  是第  $k$  个成分的权值; $f_k(x)$  是第  $k$  个成分的概率密度函数。

S 步:对每一个样本生成一个随机变量,根据随机变量和样本的条件概率密度将其划分到某一成分中。最终得到对样本集  $X = (x_1, x_2, \dots, x_n)$  的一个随机划分:

$$P^{(t+1)} = (P_1^{(t+1)}, P_2^{(t+1)}, \dots, P_G^{(t+1)}) .$$

M 步:在划分的子空间  $p_k^{(t+1)}$  ( $k=1, 2, \dots, G$ ) 中计算参数的极大似然估计,使分类似然函数最大。分类似然函数定义如下:

$$SL(\Theta) = \sum_{i=1}^n \sum_{k=1}^G L_{ik} \ln[\omega_k p(x_i | \Theta_k)], \quad (15)$$

其中:  $p(x_i | \Theta_k)$  是样本对第  $k$  个成分的条件概率密度函数,  $\omega_k$  是第  $k$  个成分在总体分布中所占的权值,  $L$  是标签矩阵。

迭代过程持续到收敛或达到一定迭代次数为止。停止迭代后,用最终得到的结果参数计算每个数据的条件概率,并根据条件概率将像素进行分类,以保留脑血管像素。

## 5 区域增长后处理

受采样设备的影响,脑图像血管灰度值分布不均匀,虽然统计分割后血管结构清晰可见,但是血管内部灰度不一致和血管分支繁多,这在统计分割中极易造成血管漏检和断裂。同时数据的局部噪声也会使得提取出来的血管存在不连续的现象,不仅是血管末梢,甚至主干部分都存在这种现象。为了解决这个问题,可将统计分割的结果作为种子点,采用区域增长或形态学方法填充不连续的血管。区域增长的基本思想是选定初始种子。将种子周围具有相似性质的点归并到种子所在的区域。对血管数据进行开闭运算,先对图像以结构元素进行膨胀,再对该结果用结构元素进行腐蚀,可以起到填充物体的小洞,连接相近的物体、平滑物边界的效果。改进方法计算简单,对于均匀连续的目标有很好的分割效果。


## 6 实验结果及分析

本系统现在已经存储了 32 位病患的脑 CT 或脑 MRI 数据,相关系统已经在北京 304 医院脑神经外科和北京海军总医院的放射科初步上线测试应用,同时在天津医科大学的医学影像专业的教学中也得到了部分应用。应用一组 DICOM 格式的临床人脑医学体数据测试本文所提方法的效果,这组数据包含 136 幅 TOF-MRA 图像序列,图像间最大间隔为 2.1 mm,最小间隔为 0.7 mm,重构直径为 200 mm。由于其它数据涉及患

者隐私,故此不再提供。本系统软件平台为 Windows 7, VC 6.0 及 VTK 5.0,使用普通 PC 机构造平台。硬件系统为 Windows 7 ultimate 32-bit, Inter(R) Xeon(R) E5410 2.33 GHz,显卡为 NVIDIA GeForce GTX 570。

### 6.1 脑血管分割效果对比

136 张脑图像预处理后,得到脑血管的最大连通图,如图 3 所示。对脑图像序列数据进行最大强度投影,得到如图 3(a)所示的 MIP 图,经过 2 次区域增长分割后得到最大连通图,如图 3(b)所示:



(a) 脑图像 MIP 投影图

(a) MIP projection of brain image



(b) 双区域增长构造的最大连通图

(b) Maximal connected graph based on dual-zone growth

图 3 脑血管预处理结果

Fig. 3 Processing results of brain vessel blood


应用 SEM 算法估计瑞利高斯混合模型的参数,设置迭代误差  $\epsilon=0.001$ ,根据参数估计后得到的高斯混合模型对血管与非血管像素进行分类,经过区域增长后处理得到的最终结果如图 4 所示。可以看出该模型可以清晰地分割出左右大脑前动脉、左右大脑中动脉、左右大脑后动脉和交通动脉等大型血管,另外,还可以很好地分割豆纹动脉等细小血管。三级血管处依然清晰。

由于脑血管的分割精度与脑图像质量直接相



(a) 瑞利高斯混合模型分割结果平视图

(a) Plan view of segmentation results with Rayleigh Gauss mixture model(axial)




(b)瑞利高斯混合模型分割结果正面图

(b)Front view of segmentation results with Rayleigh Gauss mixture model(sagittal)

图 4 基于瑞利高斯混合模型的脑血管分割结果图

Fig. 4 Segmentation results of brain blood vessel with Rayleigh Gauss mixture mode



(a) 瑞利高斯混合模型分割结果平视图

(a) Plan view of segmentation results with Rayleigh Gauss mixture model(sagittal)



(b) 双高斯混合模型分割结果正面图


(b) Front view of segmentation results with double Gauss mixture model

图 5 两模型分割整体对比图-正面视角

Fig. 5 Comparison of segmentation results with different models

关,而脑图像质量受采样设备的影响较大。另一方面,由于生物磁自旋成像技术发展迅速,故现在还未出现公认的 MRA 脑血管金标准数据。本文的实验标准均基于医院提取的实测数据。由于医生手工分割数据受主观影响,个体差异性太大,且对于二级以上血管处无法进行精确判断。为说明算法的有效性,采用同样的预处理和后处理操作,将瑞利高斯混合模型和双高斯模型进行对比,结果如图 5 所示。图 5(a)为瑞利高斯混合模型算法的分割结果,图 5(b)为双高斯混合模型的分割结果。通过比较可以看出,两模型的大致轮廓基本相同,但是瑞利高斯混合模型算法可以分割出更多细小的血管,且血管的连通性较好。图 6 是分割结果的局部放大图,在圆圈处可以明显看到新模型的分割结果在细节上更为丰富。

为了更加明显地观测 2 个统计模型的整体分割效果,对分割后的血管数据应用改进的梯度向量流<sup>[24]</sup>算法提取骨架线,根据骨架线的分布来比



(a) 瑞利高斯混合模型

(b)双高斯混合模型

(a)Rayleigh Gauss mixture model

(b) Double Gauss mixture model

图 6 分割结果局部细节对比图


Fig. 6 Comparison of local details of segmentation results with different models

较 2 种分割算法模型的拓扑差异。如图 7 所示,其中:图 7(a)为瑞利高斯混合模型分割后的血管骨架线,图 7(b)为双高斯混合模型分割后的血管骨架线。可以看出,图 7(a)中血管的分支较图 7(b)中的更加丰满,环状血管连接完整,断点明显较少,可更准确地反映脑血管的拓扑结构。



(a) 瑞利高斯混合模型分割结果骨架线

(a) Skeleton of segmentation with Rayleigh Gauss mixture model



(b) 双高斯混合模型分割结果骨架线

(b) Skeleton of segmentation with double Gauss mixture model

图 7 瑞利高斯混合模型与双高斯模型分割结果血管骨架线对比

Fig. 7 Comparison of segmentation skeletons with different models

从图 5~图 7 可以看出,应用瑞利高斯混合模型的分割结果得到的有效血管点较多,且可以分割到更细小的血管。这主要是由于瑞利高斯混合模型可以更加准确地逼近原始数据的分布,其得到的概率分布函数可以选择出灰度值较低的像素,从而也使得小血管处的连通性更强。

## 6.2 脑血管分割算法数据分析

鉴于视觉分析可能会由于模型遮挡及人眼误差造成偏差,因此,下面通过数据分析瑞利高斯混合模型的优越性。体数据经过 MIP 预处理后,去除了大量的非血管组织,同时也减少了数据噪声。


经过多次试验获得的瑞利高斯混合模型以及双高斯模型的平均参数值如表 1 所示。经过比较可以发现,瑞利高斯混合模型的血管类比例高于双高斯模型的血管类比例,这表明该模型分割出的血管点占总数据的比例将高于双高斯模型,即可以分割出更多的血管点;瑞利高斯混合模型中血管类的均值明显小于双高斯模型中血管类的均值,约相差 25 个像素值,方差大于双高斯模型中血管类的方差,这表明瑞利高斯混合模型中血管的拟合可覆盖到灰度值更低的区域,可以分割出灰度值较低的血管点。

表 1 瑞利高斯混合模型与双高斯模型参数值

Tab. 1 Parameters of Rayleigh Gauss mixture model and double Gauss mixture model


		瑞利高斯混合模型	双高斯模型
	$w_R$	0.095 776 9	
非血管类	$\sigma_R$	25.176 1	
	$w_{G1}$	0.882 856	0.980 892
	$\mu_{G1}$	199.868	185.287
	$\sigma_{G1}$	47.891 5	65.992 1
血管类	$w_{G1}$	0.021 367 4	0.019 108 4
	$\mu_{G1}$	606.807	627.822
	$\sigma_{G1}$	148.213	142.662

通过数学拟合方法分析预处理后数据集的灰度直方图,再用迭代后的参数拟合直方图。拟合曲线与灰度直方图的贴近程度直接反映了有限混合模型对像素灰度分布的描述的准确性。具体拟合曲线如图 8 所示。从图 8 中可以看出,瑞利高斯混合模型较准确地拟合了匹配直方图曲线,使



(a) 瑞利高斯混合模型拟合灰度直方图效果

(a) Intensity histogram of TOF MRA brain sequence fitted by using Rayleigh Gauss mixture model



(b) 双高斯混合模型拟合灰度直方图效果

(b) Intensity histogram of TOF MRA brain sequence fitted by using double Gauss mixture model

图 8 灰度直方图拟合曲线

Fig. 8 Fitting curves of intensity histogram

血管分割误差降低。

因为血管与非血管类的主要灰度混淆区域大概在 250~350 之间,因此,以 10 灰度阶次为单位,计算在此区域中双高斯模型与瑞利高斯模型之间的拟合数值。由表 2 可看出,对于大多数的灰度水平,瑞利高斯模型的拟合曲线数值比双高斯模型拟合曲线数值更加贴近预处理结果。

表 2 不同灰度水平下两模型拟合曲线与原灰度直方图对比  
Tab. 2 Comparison of fitting curves and initial intensity histogram for two different models in different gray levels

灰度值	预处理数据	双高斯模型	瑞利高斯模型
250	12 464	11 394	13 220
260	8 222	9 711	10 403
270	5 231	8 088	7 839
280	3 566	6 585	5 658
290	2 467	5 241	3 913
300	1 684	4 078	2 595
310	1 252	3 102	1 652
320	1 033	2 309	1 014
330	861	1 682	603
340	666	1 201	352
350	607	842	208

定义整体的灰度直方图误差为  $err_{HIS}^M$ , 该值用于表征模型  $M$  下曲线拟合误差。

$$err_{HIS}^M = \sum_{q=0}^Q |p_{Initial}^q - p_M^q|, \quad (16)$$

其中:  $p_{Initial}^q$  表示在灰度水平  $q$  下, 预处理后的直方

图对应的点数;  $p_M^q$  表示在灰度水平  $q$  下, 模型  $M$  拟合的直方图对应的点数。通过实验可知, 在数据 1 上, 双高斯模型的整体灰度直方图误差为  $err_{HIS}^{DG} = 654\ 046$ , 而瑞利高斯模型的整体灰度直方图误差为  $err_{HIS}^G = 1.292\ 28 \times 10^6$ , 也就是说在整体的拟合过程中, 瑞利高斯模型与预处理结果更为相近。表 3 为分别采用瑞利高斯混合模型和双高斯混合模型分割后的有效血管点, 可以看出新模型分割出的有效血管点比双高斯模型多 27.17%。

表 3 瑞利高斯混合模型与双高斯模型分割出血管有效点

Tab. 3 Number of valid points in the segmentation result with different models

模型	有效血管点
瑞利高斯混合模型	84 217
双高斯模型	67 819

对于单层图像, 2 种模型分割出的血管点的对比曲线如图 9 所示, 由图 9 可知, 瑞利高斯混合模型分割出的血管点在每层几乎都明显多于双高斯模型。为比较有效血管点, 本文以手动分割的结果作为标准, 比较两统计模型的单层分割效果, 如表 4 所示。对于同组数据, 在低层数据中, 血管细小, 灰度值低, 血管分布较少, 采用瑞利高斯混合模型分割出的血管比例较小; 对于中间层次, 分布有主动脉, 可以明显分割出绝大多数的血管点, 总体而言, 瑞利高斯混合模型比双高斯模型分割出的有效血管点更多。




图 9 两种模型单层分割血管点统计曲线

Fig. 9 Number of segmented blood voxel in each layer with different models

表 4 单层分割统计数据比较

Tab. 4 Number of cerebrovascular segmented by three methods in different layers

层数	手动分割	瑞利高斯混合模型	对应比率	双高斯模型	对应比率
14	532	396	74.43%	258	48.49%
30	627	560	89.31%	332	52.95%
44	759	697	91.83%	396	52.17%
67	1 672	1 473	88.09%	1 291	77.21%
86	1 082	983	90.85%	832	76.89%
118	1 794	1 588	88.51%	1 433	79.87%

通过实验结果可以看出,本文采用的新模型的分割效果明显优于双高斯模型,用 SEM 参数估计后得到的混合概率密度函数可以更加准确地拟合分割数据的灰度直方图,能分割出许多双高斯混合模型遗漏的血管体素。误分割现象减少,整体的分隔精度有很大提高,且减轻了体素之间的离散度,更好地平滑了离散点,使构成血管的体素排列更加紧凑,分割结果更加准确。

## 参考文献:

- [1] 心脑血管疾病. 百度百科[OL]. [2013-03-20] <http://baike.baidu.com/view/783095.htm>. Cardiovascular and cerebrovascular diseases, Baidu Encyclopedia [OL]. [2013-03-20]. <http://baike.baidu.com/view/783095.htm>. (in chinese)
- [2] LESAGE D, ANGELINI E D, BLOCH I, *et al.*. A review of 3D vessel lumen segmentation techniques: Models, features and extraction schemes [J]. *Medical Image Analysis*, 2009, 13(6): 819-845.
- [3] KIRBAS C, QUEK F. A review of vessel extraction techniques and algorithms[J]. *ACM Computing Surveys (CSUR)*, 2004, 36(2): 81-121.
- [4] 田运, 周明全, 武仲科. 心脑血管三维分割研究进展[J]. *计算机辅助设计与图形学学报*, 2012, 24(7): 839-851.  
TIAN Y, ZHOU M Q, WU ZH K. On 3D cardiac-cerebrovascular segmentation [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2012, 24(7): 1-13. (in chinese)
- [5] IBANEZ L, SCHROEDER W, NG L, *et al.*. The ITK software guide[J]. *NLM Insight Toolkit Publications*, <http://www.itk.org/>.

## 7 结 论

本文首先采用瑞利高斯混合模型对预处理后的脑部数据建模,然后用 SEM 进行参数估计,得到完整的混合概率密度函数,并利用最大后验概率法则分割出脑血管。该统计模型用高斯分布拟合血管类,用一个瑞利分布和高斯分布拟合非血管类。该模型可以较好地分割出脑血管 Willis 环结构,对细小血管的分割效果较好,可以分割出灰度值较低的血管点。由于受采样设备影响,脑图像血管灰度值分布不均匀,分割统计的结果存在不连续或空洞。为了解决这一问题,可将统计分割的结果作为种子点,采用区域增长或形态学方法填充不连续的血管。由于本文的研究只考虑了图像像素的灰度信息,没有考虑像素空间信息和脑血管本身的形态特征,在后续的研究中可考虑加入形态学信息进行统计,以提高分割精度。

- [6] HARTIGAN J A. *Clustering Algorithms* [M]. John Wiley & Sons, Inc., 1975.
- [7] 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 (Methodological)*, 1977, 39(1): 1-38.
- [8] RUAN S, JAGGI C, XUE J, *et al.*. Brain tissue classification of magnetic resonance images using partial volume modeling [J]. *IEEE Transactions on Medical Imaging*, 2000, 19(12): 1179-1187.
- [9] PRASTAWA M, GILMORE J H, LIN W, *et al.*. Automatic segmentation of MR images of the developing newborn brain [J]. *Medical Image Analysis*, 2005, 9(5): 457-466.
- [10] ADELINOR, SILVA F D. A Dirichlet process mixture model for brain MRI tissue classification [J]. *Medical Image Analysis*, 2007, 11(2): 169-182.
- [11] 徐丰, 王醒策, 周明全, 等. SEM 混合模型脑血管分割算法 [J]. *计算机辅助设计与图形学学报*, 2010, 22(11): 1905-1911.  
XU F, WANG X C, ZHOU M Q, *et al.*. Segmentation algorithm of brain vessel image based on SEM statistical mixture model [J]. *Journal of*

- Computer-Aided Design & Computer Graphics*, 2010, 22(11):1905-1911. (in chinese)
- [12] TIAN Y, DUAN F, ZHOU M, *et al.*. Active contour model combining region and edge information [J]. *Machine Vision and Applications*, 2013, 24(1): 47-61.
- [13] DIAS J G, WEDEL M. An empirical comparison of EM, SEM and MCMC performance for problematic Gaussian mixture likelihoods [J]. *Statistics and Computing*, 2004, 14(4): 323-332..
- [14] GAO X, UCHIYAMA Y, ZHOU X, *et al.*. A fast and fully automatic method for cerebrovascular segmentation on time-of-flight (TOF) MRA image [J]. *Journal of Digital Imaging*, 2011, 24(4): 609-625.
- [15] CHAPMAN B E, STAPELTON J O, PARKER D L. Intracranial vessel segmentation from time-of-flight MRA using pre-processing of the MIP Z-buffer: accuracy of the ZBS algorithm [J]. *Medical Image Analysis*, 2004, 8(2): 113-126..
- [16] ADEL M, MOUSSAOUI A, RASIGNI M, *et al.*. Statistical-based tracking technique for linear structures detection: Application to vessel segmentation in medical images [J]. *Signal Processing Letters, IEEE*, 2010, 17(6): 555-558.
- [17] HUDA S, YEARWOOD J, TOGNERI R. A stochastic version of expectation maximization algorithm for better estimation of hidden Markov model [J]. *Pattern Recognition Letters*, 2009, 30(14): 1301-1309.
- [18] LINGURARU M G, PURA J A, PAMULAPATI V, *et al.*. Statistical 4D graphs for multi-organ abdominal segmentation from multiphase CT[J]. *Medical Image Analysis*, 2012, 16(4): 904-914.
- [19] ROY S, CARASS A, BAZIN P L, *et al.*. Consistent segmentation using a Rician classifier [J]. *Medical Image Analysis*, 2012, 16(2): 524-535.
- [20] WILSON D L, NOBLE J A. An adaptive segmentation algorithm for time-of-flight MRA data [J]. *IEEE Transactions on Medical Imaging*, 1999, 18(10): 938-945.
- [21] HASSOUNA M S, FARAG A A, HUSHEK S, *et al.*. Statistical-based approach for extracting 3D blood vessels from tof-myra data [C]. *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2003, Springer Berlin Heidelberg*, 2003: 680-687.
- [22] HASSOUNA M S, FARAG A A, HUSHEK S, *et al.*. Cerebrovascular segmentation from TOF using stochastic models [J]. *Medical Image Analysis*, 2006, 10(1): 2-18.
- [23] HAO J, LI M. A supervised bayesian method for cerebrovascular segmentation [J]. *WSEAS Trans. Signal Process*, 2007, 3(12): 487-495.
- [24] WU Z K, SEAH H S, ZHOU M Q. Skeleton based parametric solid models: Ball B-Spline curves [C]. 2007 *10th IEEE International Conference on Computer-Aided Design and Computer Graphics*, 2007:421-424.

## 作者简介:



王醒策(1977—),女,北京人,工学博士,副教授,1999年、2002年、2005年于哈尔滨工程大学分别获得学士、硕士及博士学位,主要从事图像处理,医学可视化及智能优化算法等方面的研究。  
E-mail: wangxingce@bnu.edu.cn



文 蕾(1987—),女,陕西人,工学硕士,2010年于华中师范大学获得学士学位,主要从事脑图像统计分割研究。  
E-mail: lwengo@gmail.com