

基于小波图像融合算法和改进FCM聚类的MR 脑部图像分割算法

耿艳萍¹ 郭小英¹ 王华夏² 陈磊³ 李雪梅¹

(山西大学软件学院 太原 030013)¹ (西北工业大学自动化学院 西安 710072)²

(北京交通大学计算机与信息技术学院 北京 100044)³

摘要 针对很多基于模糊C均值(FCM)的图像分割算法存在对噪声敏感和分割轮廓不清晰等问题,提出一种基于小波变换图像融合算法和FCM聚类算法的MR医学图像分割算法。在图像分割系统的第一阶段,利用Haar小波多分辨率特性保持像素间的空间信息;第二阶段,利用小波图像融合算法对得到的多分辨率图像和原始图像进行融合,进而增强被处理图像的清晰度并降低噪声;第三阶段,利用改进型FCM技术对所处理的图像进行分割。在BrainWeb数据集上进行实验,与现有相关算法相比,提出的算法具有较高的分割精度,且对噪声的鲁棒性比较强,处理时间也没有明显增加。

关键词 MR 脑部图像分割,小波图像融合,模糊C均值聚类,鲁棒性

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.12.047

MR Brain Image Segmentation Method Based on Wavelet Transform Image Fusion Algorithm and Improved FCM Clustering

GENG Yan-ping¹ GUO Xiao-ying¹ WANG Hua-xia² CHEN Lei³ LI Xue-mei¹

(School of Software Engineering, Shanxi University, Taiyuan 030013, China)¹

(College of Automation, Northwestern Polytechnical University, Xi'an 710072, China)²

(School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China)³

Abstract Concerning the problems that many image segmentation algorithms based on fuzzy C mean (FCM) are sensitive to noise and contour segmentation is not clear, an improved algorithm based on wavelet image fusion and FCM clustering algorithm was proposed. And it is applied to MR medical image segmentation successfully. In the first stage of the image segmentation system, the Haar wavelet multi-resolution characteristics were used to maintain spatial information between pixels. In the second stage, wavelet image fusion algorithm was adopted to fuse the obtained multi-resolution image and original image, thus to enhance the clarity of processed images and to reduce noise. In the third stage, FCM technology was used for image segmentation. Experiments on BrainWeb datasets show that compared with the current algorithms, the proposed algorithm has higher segmentation accuracy and robustness to noise, and the processing time is not obviously increased.

Keywords MR brain image segmentation, Wavelet image fusion, Fuzzy C-means clustering, Robustness

医学图像处理过程中的脑部核磁共振(Magnetic Resonance, MR)图像分割^[1]对医学诊断具有重要的作用。医学图像的分割过程可分为3个主要的图像问题:1)图像中的噪声干扰,图像中的噪声能够改变像素点的强度^[2];2)图像中存在的偏移场(即像素强度不连续变化),MR中的射频线圈使得图像中产生了偏移场,在利用计算机对MR数据进行分析的过程中,图像中的偏移场会对分析过程产生较大干扰;3)当一个像素中含有两个及两个以上组织信息时,部分容积会对其

产生影响^[3]。目前,存在许多图像分割方法的研究分支,比如基于纹理分析、基于直方图阈值、基于聚类和基于区域分裂与合并的分割方法^[3]。图像分割技术的种类非常多样化,因此很难为一种特定类型的图像选取一种适当的分割技术,也没有一种分割技术能够完美地处理所有种类的图像^[4]。

研究者已经提出了一些图像分割方法,这些方法在医学应用中得到了应用。根据特定的应用场景和不同的图像形态,应从这些方法中选出适宜的分割算法。图像中存在的噪

到稿日期:2017-09-08 返修日期:2017-11-08 本文受国家自然科学基金青年基金项目(61603228),国家自然科学基金(61702315)资助。

耿艳萍(1979—),女,硕士,讲师,主要研究方向为数字图像处理、情感计算、机器学习等;郭小英(1985—),女,博士,讲师,主要研究方向为图像分析、情感计算、视觉感性工学、模式识别、机器学习等;王华夏(1981—),男,博士生,主要研究方向为视觉导航、模式识别;陈磊(1979—),男,博士生,讲师,主要研究方向为云计算、机器学习、并行计算等;李雪梅(1962—),女,教授,主要研究方向为数据挖掘、图像分割、人工智能等。

声、部分容积效应和运动等因素,都会对分割算法的性能产生比较明显的影响^[5]。

文献[6]结合了马尔可夫随机场模型和最大期望(Expectation maximization, EM)算法,构建了一种被称为 WMEM 的医学图像分割算法。该算法的第一阶段利用 Haar 转换检测长度为 2 的像素空间的相关性;第二阶段,分别利用 2D Haar 小波变换和 EM 算法对原始图像进行处理,获取两个尺度缩放后的图像,然后生成 3 个分割图像,每个分割图像都含有权重或者阈值;第三阶段,根据这 3 个分割图像对图像中的每个像素进行划分和分类。

文献[7]提出了一种新的分割系统,称为 WFCM。该系统利用小波和模糊 C 均值(Fuzzy C-Means, FCM)聚类算法完成 MR 脑部图像的分割。这种算法能够鲁棒且有效地分割含有噪声的医学图像,算法主要包含两个步骤:特征的提取和聚类,即利用多级别 2D 小波分解特征完成特征提取过程,利用 FCM 算法对小波分解过程提取的特征进行聚类,从而将先前获取的图像分割成 3 个类别:白质(WM)、灰质(GM)和脑脊液(CSF),这 3 个类别都是人脑组织。

文献[8]提出了一种既可用于处理高分辨率的遥感图像,也可用于医学和非医学图像的计算。该算法利用双正交小波分解在多个分辨率下对遥感图像进行描述,并选取适当的分辨率,利用简单的灰度形态学方法对梯度图像进行评估。为了避免发生过分割的情况,算法在梯度图像上执行选择性最小值。该算法利用分水岭变换进行处理,然后利用反向小波变换将分割结果投影到一个更高的分辨率中,直至获取到分割图像完整的分辨率。

文献[9]提出了一种基于小波变化和核模糊 C 均值(Kernel Fuzzy C-means, KFCM)聚类的 MR 脑部图像分割方法。该方法首先利用小波变换来分解图像;然后在低频部分利用 KFCM 算法进行分割,以降低噪声干扰;最后通过逆变换将分割图像重构为一个全分辨率图像。

大多数的传统算法并不适合处理含有噪声的图像,虽然有很多对 FCM 改进的算法,但是这些算法并不能令人满意^[10]。因此,本文提出了一种有效的多分辨率 MR 脑部图像分割技术,将小波图像融合技术和 FCM 聚类算法进行了结合。本文主要关注于如何提高医学图像的分割精度,并减弱 MR 脑部图像中的噪声干扰,主要贡献如下:

1)对 FCM 聚类算法进行了改进,提高了其初始聚类中心选择的合理性,以提高分割精度;

2)利用小波变换图像融合技术将图像分解为多个图像并进行融合,以减弱 MR 图像的噪声干扰。

1 基于 Haar 小波的图像分解与融合

1.1 小波变换

为了创建一个多分辨率图像,可以采用 Haar 小波变换方法^[11],通过反向离散小波变换将分割的低分辨率图像恢复成全分辨率图像。小波的这些特性能够在空间中进行较精确的定位,因此非常适合对信号和图像进行空间域分析。对于

信号 $s(t) \in L^2$,以 $\psi(t)$ 为基小波的连续小波变换定义如下:

$$C_\psi(b, a) = \int_{-\infty}^{\infty} s(t)\psi(t)dt \quad (1)$$

其中:

$$\psi_{b,a}(t) = 1/\sqrt{a}\psi(t-b/a) \quad (2)$$

参数 a 和 b 分别为扩展参数和转移参数。标准化因子 $a^{-1/2}$ 使得 $\|\psi_{b,a}\| = \|\psi\|$ 。通过增加有限的能量函数 $\vartheta(t) \in L^2$ 可以完成对信号 $s(t)$ 的多分辨率分析,相关的 ψ 为尺度函数。式(3)给出了 ψ 和 ϑ 的一些属性:

$$\int_{-\infty}^{\infty} \psi(t)dt = 0, \int_{-\infty}^{\infty} \vartheta(t)dt = 1 \quad (3)$$

可以将小波分析从 1 维扩展到 2 维图像,利用 2-D 小波和一个 2-D 尺度函数对信号成分进行表示。下面构建 3 种不同的 2-D 小波和 1 种 2-D 概要函数^[12]:

$$\psi^{[1]}i, j(x, y) = \vartheta(x-i)\psi(y-j) \quad (4)$$

$$\psi^{[2]}i, j(x, y) = \psi(x-i)\vartheta(y-j) \quad (5)$$

$$\psi^{[3]}i, j(x, y) = \psi(x-i)\psi(y-j) \quad (6)$$

$$\vartheta^{[4]}i, j(x, y) = \vartheta(x-i)\vartheta(y-j) \quad (7)$$

对一幅图像进行 2-D 小波分析,可以获得 4 个输出结果(1 个低频和 3 个高频分量):低频分量 A 、水平高频分量 H 、垂直高频分量 V 和对角高频分量 D 。低频分量 A 表示一幅具有较粗分辨率的图像,其是图像在 x 和 y 两个方向上平均化的结果;利用 x 方向上的平均值和 y 方向上的差异值可获取水平高频分量 H ;利用 y 方向上的平均值和 x 方向上的差异值可获取垂直高频分量 V ;利用两个方向上的差异值可获取对角高频分量 D 。水平边界通常出现在水平高频分量 H 中,垂直边界通常出现在垂直高频分量 V 中,对角高频分量 D 中通常含有其他的详细信息。

1.2 Haar 小波信号的分解与重构

Haar 小波是小波变换中的一种基本小波函数,其信号分解与重构过程如下。

(1)信号采样。设定采样次数为 $N=2^n$,那么输入信号 $f(t)$ 就能够以离散信号 $f_n(x)$ 的方式进行近似表示,即:

$$f(t) \approx f_n(x) = \sum_{k \in Z} f(\frac{k}{2^n})\varphi(2^n x - k) \quad (8)$$

(2)信号分解。由于信号中的干扰部分往往存在于高频分量中,因此需要进行信号分解,将信号中的高频和低频分量分离。假设 $f_n(x)$ 可以被分解为:

$$f_n(x) = W_{n-1}(x) + W_{n-2}(x) + \dots + W_0(x) + f_0(x) \quad (9)$$

其中, $W_{i-1}(x) = \sum_{k \in Z} b_k^{-1}\psi(2^{i-1}x - k)$, $f_{i-1}(x) = \sum_{k \in Z} a_k^{-1}\varphi(2^{i-1}x - k)$, $i=0, 1, \dots, n$ 。 b_k^{-1} 和 a_k^{-1} 分别为第 i 层小波分解中的高频系数和低频系数。

(3)信号处理。将分解后的信号重新组合,以此来表示原始信号:

$$\begin{aligned} f_n(x) &= \sum_{i=0}^{n-1} W_i(x) + f_0(x) \\ &= \sum_{i=0}^{n-1} \sum_{k \in Z} b_k \psi(2^i x - k) + \sum_{k \in Z} \varphi(x - k) \end{aligned} \quad (10)$$

(4)信号重构。在信号分解和处理后,通过信号重构将信

号进行还原,形成 $\bar{f}_n(x)$,其中 $\bar{f}_n(x) = f_n(x)$,但原始信号与重构信号的小波系数不同。信号重构的表达式如下:

$$\begin{cases} \bar{a}_{2k} = \bar{a}_k + \bar{b}_k \\ \bar{a}_{2k+1} = \bar{a}_k - \bar{b}_k \end{cases} \quad (11)$$

1.3 基于小波变换的图像融合

图像融合即将图像集合中的相关信息拼接为一幅图像,图像集合中的图像都是同一场景中采集的图像。因此,融合后的结果图像中含有更多的信息量,融合图像具有比单个图像更强的全面性。可以将输入图像划分为多传感、多模式、多焦点或多时相图像,图像融合的一个重要目的就是重建一幅高性能图像,该幅图像能够满足人类视觉感知、目标检测或者目标识别的需求。图像融合有两个条件^[13]:1)融合后的结果图像中应该具有原图像中含有的相关信息;2)融合过程不能将任何人工或者不可预期的特征添加到融合图像中。图像注册可以看作是图像融合的一个非常重要的预处理过程,即将一幅图像关于另一幅图像进行坐标转换。图像融合算法可以划分为多个不同的级别:低、中和高级别;或者像素、特征和决策级别。

在基于 Haar 小波变换的图像融合中,融合处理后小波系数矩阵的高频分量系数 D_k 的表达式如下:

$$D_k = c(D_k^A + D_k^B) \quad (12)$$

其中, c 为调整因子; D_k^A 和 D_k^B 分别表示在第 k 层小波变换中原始图像 A 和 B 的系数矩阵。

2 改进 FCM 聚类

2.1 传统 FCM 聚类

FCM 聚类算法是一种考虑样本模糊归属的软划分方法,常用于图像分割中。在 FCM 算法中,利用模糊隶属度函数将像素分配到每个聚类中,用 $X = \{x_1, x_2, \dots, x_N\}$ 表示含有 N 个像素点的一幅图像,将 N 个像素点划分为 C 个聚类。聚类数量由输入参数设定,对于一个已知聚类个数的给定数据集,模糊分类过程是通过目标函数的最小化过程完成的。目标函数定义为:

$$J(U, Z) = \sum_{i=1}^N \sum_{j=1}^C u_{ij} d_{ij}^2 \quad (13)$$

其中, u_{ij} 表示第 i 个像素点对第 j 类的隶属度值; d_{ij} 表示第 i 个像素点与第 j 个聚类中心的距离,这里采用 Minkowski 距离进行度量; z_j 表示聚类中心。

FCM 算法根据预设定的聚类数量 C ,通过迭代过程来最小化目标函数 J 。由于传统 FCM 随机选择初始聚类中心,且只考虑距离度量来进行聚类,因此其聚类效果不是很理想。

2.2 改进的 FCM 聚类中心选取方法

针对传统 FCM 中存在聚类中心初始化的问题,提出一种用于聚类中心选取的方法,以改进传统 FCM。该方法定义了一个聚类中心近似度量 Q_i ,用于表示第 i 个像素点 I_i 到其他任一像素点的距离。 Q_i 的表达式为:

$$Q_i = \sum_{j=1}^K e^{-\phi \|I_i - I_j\|^2} \quad (14)$$

其中, ϕ 为常数。

提出的改进 FCM 聚类算法的步骤如下:

1)计算每个像素点的 Q_i 值,选择具有最大 Q_i 值的像素点作为第一个聚类中心 c_1 。

2)计算像素点与该聚类中心的隶属度值,根据隶属度值将 c_i 点和与 c_i 具有很高隶属度值的像素点从下一次迭代中移除,防止产生伪聚类中心。

3)通过再次计算 Q_i 值来确定下一个聚类中心,即 $Q_{i+1} = Q_i - Q_i^2 e^{-\phi \|I_i - I_j\|^2}$ 。距离聚类中心越近的像素点,其 Q_i 值就越小,成为下一个聚类中心的概率就越低。

4)迭代执行上述过程,直到第 t 次迭代的 Q_i^t 满足 $Q_i^t < \epsilon Q_i^{t-1}$ 为止。其中, ϵ 为一个很小的正数,本文取 $\epsilon = 10^{-3}$ 。

3 MR 脑部图像分割方法

本节讨论提出的基于小波变换图像融合和 FCM 算法的 MR 脑部图像分割系统,其利用融合后的多分辨率小波图像来增强分割过程的精确度。软分割算法(如 FCM)可以保存大量的信息,但是这种算法不能包含任何空间内容的信息。因此,本文利用离散小波来克服 FCM 算法的缺点。

如图 1 所示,提出的系统由 3 个主要阶段构成。第一阶段,创建多分辨率或者多级别 2D 小波分解。第二阶段,利用小波图像融合技术对 3 幅结果图像进行处理,对原始图像和两个多分辨率 2D Haar 小波级别进行融合。本文对原始图像和 2D Haar 小波变换第一个级别的图像进行融合,或者对原始图像和第二个级别的 2D Haar 小波转换进行融合,除了原始图像之外,本文还获取了两幅图像。在最后一个阶段中,输入 3 幅图像,利用 FCM 聚类算法进行分割。



图 1 本文提出的图像分割系统的流程图

3.1 Haar 小波变换阶段

多分辨率分析已经成功应用于图像处理领域,特别是图像分割方面。在 Haar 小波变换阶段,本文将头骨条纹图像作为输入图像,通过 Haar 离散小波变换利用多分辨率获取小波分解。然后,利用 Haar 小波对图像进行处理,执行一个二级小波变换,从而获取两个输出结果:低通和高通,再利用反向离散小波变换(IDWT)对概要内容进行处理,以获取多分辨率图像^[14]。这个阶段的结果是得到两个多分辨率图像,分别为级别 1 的 L_1 和级别 2 的 L_2 。

3.2 小波变换图像融合阶段

Haar 小波变换图像融合过程如下:1)对输入图像进行配

对;2)确定每对输入图像分解和重构的融合级别;3)分解过程中,在第二级对输入图像进行滤波,即开始过滤和关闭过滤;4)图像对大幅度降低;5)对最终获取的融合图像进行重建。

在这一阶段,本文将原始图像和 2D Haar 小波变换的第一级图像进行融合,或者将原始图像和 2D Haar 小波变换的第二级图像进行融合。融合后,除了原始图像之外,还可以获取两幅新图像。换句话说,对两个图像对进行融合:第一个图像对是原始图像(I_0)和 2D Haar 小波变换的第一级图像(L_1),第二个图像对是原始图像(I_0)和 2D Haar 小波变换的第二级图像(L_2)。对图像进行低通滤波,目的是消除噪声并使图像变得平滑,但不能改变图中目标的形状和位置。通过对每两个图像对进行抽取,获取最后的融合图像,这个过程的具体过程如下所述,利用从图像对中选取的最小值生成最后的矩阵。

- 1)取($I_0 \& L_1$)和($I_0 \& L_2$)的平均;
- 2)取($I_0 \& L_1$)和($I_0 \& L_2$)中的最小值;
- 3)取($I_0 \& L_1$)和($I_0 \& L_2$)中的最小值。

3.3 FCM 聚类阶段

在这个阶段中,采用 FCM 聚类算法对先前阶段生成的 3 幅结果图像进行分割。3 幅图像分割完成后,将 FCM 聚类的结果传递给 4 个条件,这 4 个条件控制最后的分割图像,FCM 技术的流程如图 2 所示。

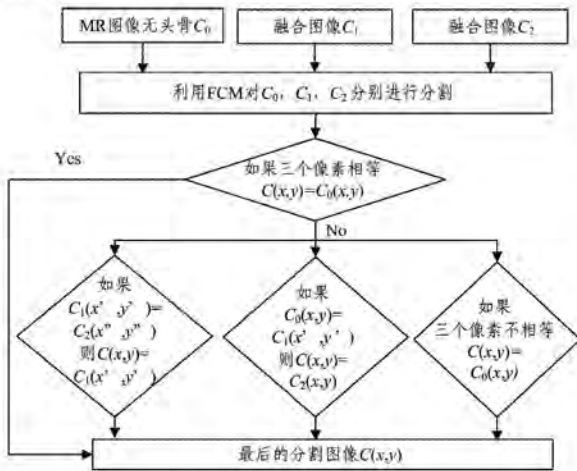


图 2 FCM 技术的流程图

对图像 I_0 的子图 A_1 和其子图 A_2 进行小波变换融合。本文对 I_0, L_1 和 L_2 进行融合,然后利用 FCM 算法对融合结果进行分割,在这个过程中每个图像对的分割过程都是相对独立的,最后获取了 3 个分割图像。换句话说,这个步骤获取了 3 个分类度量,分别是 C_0, C_1 和 C_2 ,利用这 3 个分类度量重新对图像 I_0 中的每个像素点进行分割,具体过程如下所述:

- (1)如果 $C_0(x,y)=C_1(x',y')=C_2(x'',y'')$, C_0, C_1 和 C_2 中所有的 3 个像素都从属于同一个类,那么 $C(x,y)=C_0(x,y)$ 。
- (2)如果 $C_1(x',y')=C_2(x'',y'') \neq C_0(x,y)$,那么 $C(x,y)=C_1(x',y')$ 。
- (3)如果 $C_0(x,y)=C_1(x',y') \neq C_2(x'',y'')$,或者 $C_0(x,y)=C_2(x'',y'') \neq C_1(x',y')$,那么 $C(x,y)=C_2(x,y)$ 。

(4)如果 $C_0(x,y) \neq C_1(x',y') \neq C_2(x'',y'')$,那么 $C(x,y)=C_0(x,y)$,其中(x',y')表示子图,(x'',y'')表示子图(x',y')的子图。

4 实验及分析

4.1 实验设置

为了检测本文提出的图像分割算法的性能,在 MATLAB R2011a 上执行了本文提出的算法。实验的硬件配置为:Core™ 2 Due 2GHz 处理器和 4GB RAM。将一个包含 152 幅图像的标准数据集作为大脑 BrainWeb 数据集^[15],其中含有根据正常和多种硬化情况(MS)模拟的 MR 脑部数据。对于这两种模型,利用 3 个序列(T1-加权、T2-加权和质子密度加权)以及各种片厚度、噪声级别和亮度不均匀性级别对三维数据量进行仿真。本文选择的图像层厚度为 1mm,并具有 3%~11%级别的高斯噪声(以最亮的组织进行计算),亮度不均匀性(RF)为 20%。

4.2 分割性能度量

本文使用组织分割精度(TSA)评价方法来验证分割的准确性,其描绘了一个给定分割片段 A 和一个已知正确分割片段 B 的匹配程度,其中 A 和 B 是分割像素的集合。计算正确分类和错误分类像素的个数,进而对分割图像的二值分割结果与参考图像进行比较。TSA 的表达式如下:

$$TSA = \frac{2N_{CTk}}{N_{CTk} + N_{GTk}} \times 100\% \quad (15)$$

其中, N_{CTk} 为算法正确分配给组织 k 的像素数量, N_{CTk} 为算法分配给组织 k 的总像素数量, N_{GTk} 为属于组织 k 的真实像素数量(标定好的真实数据)。

4.3 分割性能验证

为了验证所提算法的有效性,本文利用一个知名大脑数据集对提出的算法进行了运行和测试。利用 T_1 权重 MR 对被噪声腐蚀的图像进行处理,通过头骨剔除软件中的 FM-RIB FSL 软件库可以获取脑核图。本文的目标是将一幅图像分割为 3 个类别,即 WM,GM 和 CSF。图 3 给出了数据集中的一幅 MR 脑部原图、脑核图和已经标定的正确 WM,GM,CSF 图像。




图 3 标准数据集中的一幅 MR 图像以及各部分真实图像

对于该幅图像,运用本文分割方法,首先从脑部图像中剔除头骨;然后利用 2D 多级别处理头骨剔除后的图像,并对图像进行融合;最后采用 FCM 对 MR 脑部图像进行分割。分割后的结果如图 4 所示。可以看出,采用本文分割方法得到的 WM,GM 和 CSF 图与真实图像基本一致,证明了本文方法的有效性。



图 4 所提算法对 MR 图像各部分的分割图

另外,为了证明本文方法对图像噪声和偏移的鲁棒性,对该 MR 脑部图像加入 3% 的高斯噪声和 20% 的偏移,如图 5 (a)所示;然后执行本文分割方法,分割出的 WM,GM 和 CSF 图如图 5(b)~图 5(d)所示。可以看出,分割出的各部分图像仍然清晰可辨,没有受到噪声和偏移的影响。




图 5 所提算法对具有噪声和偏移的 MR 图像的分割图

4.4 性能比较

将本文提出的方法与几种现有方法进行比较。比较方法有:文献[6]提出的马尔可夫随机场+EM 的分割算法(WMEM);文献[7]提出的小波变换+FCM 的分割算法(WFCM);文献[9]提出的小波变换+KFCM 的分割算法(WKFCM)。其中,KFCM 算法具有两个版本:KFCM_S1 和 KFCM_S2,本文采用的是 KFCM_S2,这种算法是取 x_j 附近窗口中的领域中值,而 KFCM_S1 算法是取 x_j 附近窗口中的领域均值。本文采用 KFCM_S2 算法是因为它具有比 KFCM_S1 算法更好的噪声鲁棒性。由于参数 σ 是离散的,在本文中 将 KFCM_S2 的参数设为 $\alpha=2$ 和 $\sigma=50$ 。

首先,在 MR 脑部图像数据集上选取 50 张测试图像,执行各种分割算法,并统计其各部分分割的 TSA。图 6 给出了其中 10 幅图像的分割结果。可以看出,在 WM,GM 和 CSF

方面,本文方法的分割精度都较高,且波动较小。这说明了本文方法具有很好的稳定性。

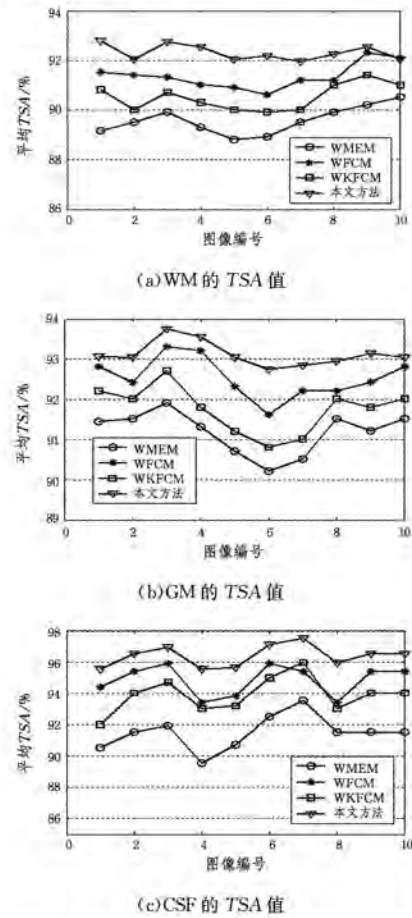


图 6 各种方法对图像中各部分的分割性能

为了更加直观地进行比较,本文统计了各部分分割 TSA 的平均值,同时比较了各种方法的平均分割时间,结果如表 1 所列。

表 1 各种方法在原始数据集上的比较结果

	TSA/%				时间/s
	WM	GM	CSF	平均	
WMEM	89.17	91.45	91.52	90.71	6.53
WFCM	91.53	93.12	93.42	92.69	10.18
WKFCM	90.82	92.71	94.01	92.51	12.74
本文算法	92.78	93.06	96.55	94.13	11.95

可以看到,本文提出的算法比其他参与测试的算法具有更高的精确度。在 WM,GM 和 CSF 上,本文算法的分割 TSA 值都达到了 92% 以上,整体平均 TSA 达到了 94%。另外,各种方法对于 CSF 的分割精度都较高,而对 WM 的分割精度都相对较低。同时,从时间成本来看,WMEM 花费的时间成本最低,因为其算法最为简单;WKFCM 花费的时间成本最高,但其获取的精度要优于 WFCM 算法;本文算法的时间成本也较高,但低于 WKFCM 算法,且获得了最高的准确性。

图 7 给出了各种方法在不同的噪声等级下对图像的分割性能,其中图像无偏移操作。可以看出,各种方法的平均 TSA 随着噪声等级的升高而降低,且噪声越大,降低速度越

快。其中,本文方法获得了最高的 TSA 性能,证明了其对噪声的鲁棒性最好。

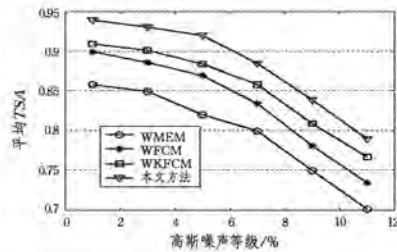


图 7 各种方法在不同高斯噪声等级下的分割性能

结束语 一般情况下,医学图像中含有未知的噪声,很难获得可接受的分割性能。传统的 FCM 算法是一种最常用的医学图像分割算法,但是这种算法并不适合处理含有噪声的图像;虽然有很多对 FCM 改进的算法,但是这些算法都不能以一种令人满意的方式克服 FCM 的缺陷。因此,本文提出了一种有效的多分辨率 MR 脑部图像分割技术,该方法采用了小波图像融合和 FCM 聚类算法。通过采用组织分割精度百分比对分割算法的结果进行确认。实验结果表明,所提算法的性能要明显优于 WMEM, WFCM 和 WKFCM 算法。

为了降低 MR 图像中的噪声,我们将利用不同的轮廓或者不同类型的脑部医学图像进行融合,以实现多模态联合分割,如 CT 和 MR 图像。对不同类型图像的同级别进行融合将是未来的研究重点。

参 考 文 献

- [1] LIN X L, CHEN X H, XIAO L Y. Medical Image Segmentation Based on Region-based Hybrid Active Contour Model [J]. Computer Science, 2016, 43(4): 303-307. (in Chinese)
林喜兰, 陈秀宏, 肖林云. 基于区域混合活动轮廓模型的医学图像分割[J]. 计算机科学, 2016, 43(4): 303-307.
- [2] ZHOU W G, SUN T, ZHU H. Image segmentation algorithm based on FCM optimized by adaptive spatial information [J]. Application Research of Computers, 2015, 32(7): 2205-2208. (in Chinese)
周文刚, 孙挺, 朱海. 一种基于自适应空间信息改进 FCM 的图像分割算法[J]. 计算机应用研究, 2015, 32(7): 2205-2208.
- [3] CUI Z H, SUN S, CHEN S G, et al. Mean shift based FCM image segmentation algorithm [J]. Control and Decision, 2014, 29(6): 1130-1134. (in Chinese)
崔兆华, 孙穗, 陈思国, 等. Mean shift 模糊 C 均值聚类图像分割算法[J]. 控制与决策, 2014, 29(6): 1130-1134.
- [4] AGRAWAL S, PANDA R, DORA L. A study on fuzzy clustering for magnetic resonance brain image segmentation using soft computing approaches [J]. Applied Soft Computing, 2014, 24(12): 522-533.
- [5] WANG W H, FENG Q J, LIU L, et al. Segmentation of Brain MR Images Through Class-adaptive Gauss-Markov Random Field Model and the EM Algorithm [J]. Journal of Image and Graphics, 2008, 13(3): 488-493. (in Chinese)
王文辉, 冯前进, 刘磊, 等. 基于类自适应高斯-马尔可夫随机场模型和 EM 算法的 MR 图像分割[J]. 中国图象图形学报, 2008, 13(3): 488-493.
- [6] KHALIFA I, YOUSSTAF A, YOUSRY H. MRI Brain Image Segmentation based on Wavelet and FCM Algorithm [J]. International Journal of Computer Applications, 2012, 47(16): 32-39.
- [7] ZHANG F, FAN H. Research on medical image segmentation based on fuzzy C-means clustering algorithm [J]. Computer Engineering and Applications, 2014, 34(4): 144-151. (in Chinese)
张翥, 范虹. 基于模糊 C 均值聚类的医学图像分割研究[J]. 计算机工程与应用, 2014, 34(4): 144-151.
- [8] PARVATHI K, RAO B S P, DAS M M, et al. Pyramidal Watershed Segmentation Algorithm for High-Resolution Remote Sensing Images Using Discrete Wavelet Transforms [J]. Discrete Dynamics in Nature & Society, 2009, 57(2): 332-337.
- [9] FRANCIS K J, PREMI M S G. Kernel weighted FCM based MR image segmentation for brain tumor detection [C] // International Conference on Circuit, Power and Computing Technologies. IEEE, 2015: 1-6.
- [10] JAVED A, CHAI W Y, THURAMAIYER N K, et al. Automated segmentation of brain MR images by combining contourlet transform and K-Means clustering techniques [J]. Theor. Appl. Inf. Technol., 2013, 54(2): 82-91.
- [11] CHEN G B, ZHANG G Q. Prediction method of actual traffic based on α -stable distribution and wavelet transform [J]. Application Research of Computers, 2014, 31(8): 2457-2460. (in Chinese)
陈国彬, 张广泉. 基于 α -稳定分布和小波变换的实际流量预测算法[J]. 计算机应用研究, 2014, 31(8): 2457-2460.
- [12] BORA D J, GUPTA A K. Clustering Approach Towards Image Segmentation: An Analytical Study [J]. Eprint Arxiv, 2014, 2(7): 115-124.
- [13] RAJIV S, ASHISH K. Multiscale medical image fusion in wavelet domain. [J]. Scientific World Journal, 2013, 17(5): 1-10.
- [14] YANG Y, HUANG S. Image Segmentation by Fuzzy C-Means Clustering Algorithm with a Novel Penalty Term [J]. Computing & Informatics, 2007, 26(1): 17-31.
- [15] COCOSCO C A, KOLLOKIAN V, KWAN K S, et al. BrainWeb: Online Interface to a 3D MRI Simulated Brain Database [J]. Neuroimage, 1997, 5(3): 425-429.