

# 基于 K-means 和图割的脑部 MRI 分割算法

田 换<sup>1</sup> 覃 晓<sup>1</sup> 元昌安<sup>1</sup> 刘致锦<sup>1</sup> 廖剑平<sup>2</sup>

(1. 广西师范学院计算机与信息工程学院, 南宁, 530032; 2. 南宁学院信息工程学院, 南宁, 530200)

**摘 要:** 为了克服原始图割算法在用户选定的像素种子点较少情况下, 目标边界容易出现错分这一现象, 本文提出了基于 K-means 和图割(Graph cut, GC)算法相结合的交互式 K-均值图割(K-means and graph cut, KMGC)算法, 对脑部核磁共振图像(Magnetic resonance image, MRI)进行交互式操作, 该算法通过 K-means 聚类, 对脑部 MRI 的灰度不均匀性进行了处理, 在此基础上, 再使用图割算法进一步对脑部 MRI 进行细化, 从而达到有效地分割脑白质和脑灰质的目的。本文分别在仿真和真实的脑部 MRI 数据上进行了大量的实验, 分别从定量分析和定性分析两个角度对实验结果进行了分析, 并与其他分割算法进行了对比, 对比实验结果表明, KMGC 算法能够有效地对脑部 MRI 进行分割, 并在分割效果上优于其他算法。

**关键词:** 图割; 交互式; 核磁共振图像; K-均值

**中图分类号:** TP391 **文献标志码:** A

## Brain MRI Segmentation Algorithm Based on K-means and Graph Cut

Tian Huan<sup>1</sup>, Qin Xiao<sup>1</sup>, Yuan Changan<sup>1</sup>, Liu Zhijin<sup>1</sup>, Liao Janping<sup>2</sup>

(1. College of Computer and Information Engineering, Guangxi Teachers Education University, Nanning, 530032, China; 2. College of Information Engineering, Nanning University, Nanning, 530200, China)

**Abstract:** To overcome the target boundary prone to be misclassification for an original image when the user-selected seed pixels become less in the graph cut algorithm. An interactive K-means and graph cut algorithm (KMGC) is proposed in the combination of the K-means with graph cut(GC) algorithm and the interactive segmentation with brain magnetic resonance image (MRI). The MRI intensity inhomogeneity is processed by K-means clustering algorithm. On this basis, the graph cut algorithm will further refine the MRI, so as to obtain effective segmentation of white matter and gray matter. We implement extensive segmentation experiments using both synthetic and real brain MRIs. Quantitative and qualitative analyses are carried out about the experimental results, and the results are compared with other segmentation algorithms. The experimental results show that the KMGC algorithm can effectively divide the brain MRI, and outperform others on the segmentation effect.

**Key words:** graph cut; interactive; brain magnetic resonance image (MRI); K-means

## 引 言

医学领域中,精神呆滞、癫痫、脑萎缩及老年痴呆等疾病通常会引起脑部组织脑白质(White matter, WM)或脑灰质(Gray matter, GM)的异常。从医学核磁共振图像(Magnetic resonance image, MRI)中识别并分割出脑灰质和脑白质,并通过与正常人的脑白质和脑灰质进行比较,分析脑灰质是否异位、脑白质中是否出现脑灰质信号、脑灰质与大脑皮层是否相连等,可以预测这些疾病,从而辅助医生及早的作出诊断方案。

目前脑 MRI 图像的分割技术有很多种,主要分为基于像素的方法、基于活动轮廓的方法以及基于图论的分割方法。例如文献[1]中提出了基于全局优化 K-均值聚类的医学图像分割方法(Global optimized K-means, GOK-means),其在仿真脑部 MRI 上进行了实验,并与金标准进行了对比,但该算法仅仅进行了简单的聚类,因此与黄金分割还存在一定的差距。文献[2]提出了基于人工交互分水岭区域合并的医学图像分割研究,其主要思想是在前两次区域合并的基础上进行第 3 次局部合并,用人机交互的方式分割出感兴趣的脑白质,但该算法只能够大致分割出脑白质,并且存在过分割现象。文献[3]提出了一种基于空间结构信息的模糊 C-均值(Fuzzy C-means, FCM)模型的脑部 MRI 分割,该算法利用图像的非局部信息和空间结构的相似性建立一个新的距离函数来进行图像分割,但是该算法也只是对 MRI 图像进行基于距离的聚类,不能达到更有效的分割目的。文献[4]提出了基于融合矢量量化和边缘检测的图像分割方法,对脑 MR 仿真图像进行分割,出现了很好的分割效果,并与黄金分割进行了对比,但是由于该算法是全自动分割,自动确定目标区域的种子点,使得分割并不总是能够反映出用户的意愿。

本文提出了一种两阶段脑部 MRI 分割算法——K-均值图割算法(K-means and graph cut, KMGC)算法。该算法首先利用 K-means 对脑部 MRI 的灰度不均匀性进行了处理,再使用图割算法在聚类的基础上进一步细化分割结果,同时又允许用户与算法进行交互,选择更准确的种子点,从而达到更有效的分割脑灰质的目的。

## 1 相关算法研究

### 1.1 图割算法<sup>[5]</sup>

图割(Graph cut, GC)算法思想来源于图论,它将图像映射成加权图  $G=(V, E, W)$ ,  $G$  中顶点对应图像中像素,每条边相应地连接两个相邻的像素,边上的权值表示对应像素之间的差异或相似性。根据邻接像素之间的相似性设计能量函数,通过最小化能量函数<sup>[6]</sup>对图进行分割,从而实现图像分割。

#### 1.1.1 能量函数

设  $X=(x_1, \dots, x_p, \dots, x_{|P|})$  为一个给定灰度图像  $I$  的像素值集;  $P=(1, \dots, p, \dots, |P|)$  作为  $I$  的像素索引集;  $N$  为 4 邻域或 8 邻域系统下的相邻像素的无序对集合,  $N=\{(p, q) | p, q \in P\}$ , 且标签  $L=(L_1, \dots, L_p, \dots, L_{|P|})$  为二进制向量,其分量  $L_p$  指分配给像素  $p$  的标签,每个  $L_p$  可以是“前景”或“背景”,因此,数组  $L$  定义图像  $I$  的分割。

GC 模型定义能量函数  $E(L)$ ,它描述了施加于  $L$  上边界和区域属性的软约束,有

$$E(L)=U(L)+\delta B(L) \quad (1)$$

式中: $U(L)$ 为一元项(或者区域项),表示给像素  $p$  标记为标签  $L_p$  的惩罚; $B(L)$ 为边界项(光滑项),表示相邻像素之间分配的标签不一致的惩罚;参数  $\delta$  表示区域项与边界项之间的重要因子。

#### (1) 区域属性项

$$U(L)=\sum_{p \in P} U_p(L_p) \quad (2)$$

式中: $U_p(L_p)$ 表示像素  $p$  标记为标签  $L_p$  的惩罚,通过求像素  $p$  属于标签  $L_p$  的概率,获得  $U_p(L_p)$  能量

项的权值, 像素  $p$  应该被标记为使其概率最大的标签  $L_p$ , 但是这时的能量最小, 所以取概率的负对数值作为图的权值, 即

$$U_p(1) = -\ln Pr(x_p | \text{'object'}); U_p(0) = -\ln Pr(x_p | \text{'back'}) \quad (3)$$

直观地解释为: 使用像素的灰度标记为种子来获得“目标”和“背景”的灰度分布直方图:  $Pr(x_p | \text{'object'})$  和  $Pr(x_p | \text{'back'})$ ,  $p$  为像素, 映射为图的顶点;  $L_p$  为二进制向量的标签,  $L_p = 0$  和  $L_p = 1$  分别对应背景和前景, 然后求其直方图。将  $p$  的像素值  $x_p$  代入直方图, 如果代入前景直方图的能量小于代入背景直方图的能量, 则  $p$  被标记为 1; 否则  $p$  被标记为 0。因此, 当所有像素都被正确地标记为 0 和 1 时, 此时的能量最小。

(2) 边界属性项

$$B(L) = \sum_{(p,q) \in N} B_{<p,q>} \cdot \mu(L_p, L_q) \quad (4)$$

$$B_{<p,q>} \propto \exp\left(-\frac{(x_p - x_q)^2}{2\sigma^2}\right) \quad (5)$$

$$\mu(L_p, L_q) = \begin{cases} 0 & L_p = L_q \\ 1 & L_p \neq L_q \end{cases} \quad (6)$$

式中: 像素  $p$  和  $q$  为邻域像素;  $x_p$  和  $x_q$  为两个像素的值;  $L_p$  和  $L_q$  为标签, 边界平滑项主要体现图像的边界属性;  $B_{<p,q>}$  表示像素  $p$  和  $q$  之间不连续的惩罚。由式(5)可以看出, 如果  $p$  和  $q$  相似度越大(例如灰度), 那么  $B_{<p,q>}$  就越大, 即能量越小, 如果它们差别很大, 那么  $B_{<p,q>}$  就接近于 0, 这时能量接近于 0。

GC 方法借助于种子点的定义(其中种子标签预定义, 种子点手动添加), 将硬约束施加在分割结果中。GC 的目标是对满足硬约束  $p \in O, L_p = \text{"object"}$ ,  $p \in B, L_p = \text{"back"}$  所有割  $L$  求出最小割  $L_{\min}$ , 并且满足

$$L_{\min} = \operatorname{argmin} E(L) \quad (7)$$

文献[5]已经证明求解能量函数的最小值等价于求解  $s-t$  网络的最小割, 也就是说, 可以将能量最小化问题转化为求解最小割的问题。

1.1.2 最大流/最小割

本文实验用搜索树算法来计算最大流/最小割。该算法是基于寻找增广路径的思想, 文献[7]提出了一种利用两棵动态搜索树的方法来计算最大流/最小割的算法, 其极大地提高了增广路径的查找效率, 突破了图割理论在规模比较大的图的计算瓶颈。




图 1 搜索树与增广路径图示

Fig. 1 Search tree and augmenting path

本算法是首先构造两棵互不相交的树  $S$  和  $T$ , 如图 1 所示; 然后不断寻找增广路径的迭代算法, 此算法包含生长, 增流和采纳 3 个主要的阶段。算法结束时满足

$$S \subseteq V, s \in S, T \subseteq V, t \in T, S \cap T = \emptyset \quad (8)$$

搜索树算法如算法 1。

算法 1 搜索树算法

maxflow()

$S = \{s\}, T = \{t\}, A = \{s, t\}$ , // 初始化

While

Grow:  $P = \text{growth}(S \text{ or } T)$  // 生长  $S$  或  $T$ , 寻找一条从  $s$  到  $t$  的增广路径

If break // 若增广路径为空, 则算法终止

Augment: AugmentFun( $P$ ) //沿增广路径  $P$  增流

Adopt: AdoptFun(orphans) //重新采纳孤儿节点,即重建搜索树  $S$  和  $T$ 。

此时得到的一系列标签  $L$  就是满足式(7)的  $L_{\min}$ ,其中  $L_{\min}$  图像中每个像素  $p$  被标记为 0 和 1 的二进制向量。

## 1.2 K-means 算法

在医学图像处理中,聚类算法也是常用的算法之一。其中 K 均值算法是 MacQueen 于 1967 年提出的一种解决聚类问题的经典算法,也是一种简单高效的聚类算法。该算法是基于欧式距离的划分算法,它把  $n$  个对象划分为  $k$  个类,使样本点到所属类中心的(欧式)距离平方和(式(9))最小,有

$$E = \sum_{i=1}^k \sum_{j=1}^{N_i} \|X_{ij} - c_i\|^2 \quad (9)$$

式中: $X_{ij}$  为第  $i$  个类第  $j$  个样本; $c_i$  为第  $i$  个类的聚类中心; $N_i$  为第  $i$  类的样本个数; $k$  为将  $n$  个对象聚为  $k$  个类, $n$  个对象为脑部 MRI 中  $m \times h$  个像素。K-means 算法的主要步骤见算法 2。

### 算法 2 K-means 算法

输入:类的数目  $k$ ,包含  $n$  个对象的数据及迭代次数  $t$ 。

输出: $k$  个类,聚类中心,误差平方和。步骤为:

- (1)任意选取  $k$  个对象,这  $k$  个对象就是初始聚类中心;
- (2)计算每个对象到各个聚类中心的距离,将每个对象重新赋予离聚类中心最近的那个类;
- (3)更新新类的聚类中心,即计算新类中每个对象的平均值;
- (4)重复步骤(2,3),当满足收敛条件时,算法终止;即达到规定的迭代次数,或者  $\text{abs}(c(i+1) - c(i)) < \text{某个很小的阈值}$ ,其中  $c(i)$  为第  $i$  次迭代的聚类中心。

## 2 两阶段 MR 图像分割算法

由于 GC 算法中能量函数的区域项和边界项分别是通过背景/前景灰度直方图和灰度差异性/一致性计算的,因此对于背景复杂的脑组织不能有效地进行勾画。本文提出了改进算法——K-均值图割算法(K-means and graph cut, KMGC)算法,该算法引入 K-means 算法对脑部 MR 图像进行预处理,K-means 聚类算法一直都是比较经典的聚类算法,其主要优点就是简单高效,对于背景复杂的医学图像,使用 K-means 算法进行预处理,可以初步的分割出一些区域。GC 算法根据相邻像素之间的关系,将图像转化为带权图进行分割,而数学方面图的处理技术已经相当成熟,可以找到全局最优解。因此在聚类的基础上,利用 GC 算法进行优化细分,能够达到更有效地分割 GM 和 WM 的目的。

### 算法 3 KMGC 算法

输入:脑部 MR 图像,类的个数  $k$  及迭代参数  $t$ 。

输出:分割结果。步骤如下:

- (1)  $I = \text{imread}()$ ; //读入原始图像;
- (2)  $I_1 = \text{kmeans}(I, k, t)$ ; //调用 K-means 算法,对图像进行预处理,均匀 MR 图像灰度,得到初始分割  $I_1$ ;
- (3)  $H_1 = \text{Hist}(W('object'))$ ;  $H_2 = \text{Hist}(W('back'))$ ;  $H_3 = \text{Hist}(N(p))$ ; //调用 Hist()方法来计算图像  $I_1$  目标、背景种子及邻域  $N(p)$  内像素的灰度直方图。

$\text{Dist}(x_p, s_p) = X^2(H_1 \text{ or } H_2, H_3)$ ; //用  $X^2$  距离描述邻域  $N(p)$  和种子直方图的距离;

If  $s_p = 'object'$   $Pr(x_p | s_p) = \frac{\text{Dist}(x_p, 'object')}{\text{Dist}(x_p, 'object') + \text{Dist}(x_p, 'back')}$ ;

$$\text{Else } Pr(x_p | s_p) = \frac{\text{Dist}(x_p, 'back')}{\text{Dist}(x_p, 'object') + \text{Dist}(x_p, 'back')};$$

$$\text{Then } U(L) = \sum_{p \in P} -\ln Pr(x_p | 'object'/'back');$$

$$(4) B(L) = \sum_{(p,q) \in N} \exp\left(-\frac{(x_p - x_q)^2}{2\sigma^2}\right) \cdot \mu(L_p, L_q); // \text{根据式(4~6)计算边界项};$$

$$(5) E(L) = U(L) + \delta B(L); // \text{根据计算出的能量代价构造 } s-t \text{ 网络图};$$

(6)  $L_{\min} = \text{maxflow}()$ ; // 调用算法 1, 得到最小割  $L_{\min}$ , 此时, 每个像素都被标记为 0 或 1, 即分割出了结果。

通过  $K$  均值预处理后, 去除了医学图像复杂的背景, 均匀了 MR 图像灰度, 从而减少了人机交互, 使操作变得简单方便。只需在目标内部和背景区域标记少量“背景”种子点和“目标”种子点即可, 对种子点的具体位置和大小也没有严格要求。

### 3 实验与分析

本文实验工具为 Visual Studio 2013, Matlab 2012b。实验平台为联想台式计算机, CPU 为 Intel Core(TM)2 Quad/2.83 GHz, 内存 4.00 GB, 操作系统为 32 位 Windows7 旗舰版。

由于本文实验数据既有真实脑部 MRI, 又有仿真 MRI, 对于在不同的实验数据上做实验, 参数  $k$  不同。迭代次数  $t$  也不同;  $t$  过小会过早收敛, 陷入局部最优, 过大会影响运行速度, 所以要在实验中通过交叉验证选择合适的迭代次数。各实验的  $k, t$  参数如表 1 所示。

#### 3.1 KMGC 算法和原始 GC 算法的对比实验

本实验分别使用 GC 算法以及 KMGC 算法对 URNC 数据库中正常的脑部 MRI(292×323) 进行脑组织分割。KMGC 算法分割的图像与原始图像形态基本一致, 图像并未产生任何畸变。GC 算法不能很好地把 GM 和 WM 分割开来, 这是由于 GC 算法中能量函数的区域项和边界项分别通过背景/前景灰度直方图和灰度

差异性/一致性计算, 因此对于背景复杂的脑组织不能有效地进行分割, KMGC 算法和 GC 算法对脑 MRI 的分割结果如图 2 所示。从图 2 中可以看到, 经过  $k$  均值聚类之后, 将脑部 MRI 中不利于分割的组织已经去除, 从而简化了图像数据。接下来再通过 GC 算法对预分割后的图像进行处理, 最终实现 GM 和 WM 正确分割, 结果如图 2(f~i)。通过比较可以直观地看出, 本文提出的 KMGC 算法具有较好的分割效果, 明显优于传统 GC 算法。

#### 3.2 KMGC 算法和区域生长算法的对比实验

本实验数据来源同 3.1 节。实验两个算法都是交互式算法, 都需要选择种子点, 不同的是区域生长算法选择的种子点都是感兴趣区域, 每个种子点分割的区域连通, 因此在使用此算法之前需要知道相同感兴趣区域的数量, 数量越多, 人机交互越多; KMGC 算法分割不需要知道感兴趣区域的数量, 只需选择少量目标种子点和背景种子点就可以分割出完整的目标区域。两种算法的分割结果如图 3 所示。区域生长算法分割 WM 的阈值设置为 0.044, 分割 GM 的阈值设置为 0.055 5, KMGC 算法不需要考虑阈值的设置问题。从图 3 可以看出, KMGC 算法的分割效果优于区域生长算法。

为了充分验证 KMGC 算法的优越性, 分别对实验 1, 2 进行定量分析, 利用重叠率和误差率两个指标对实验结果进行定量分析。在这两个指标中,  $R$  为预计分割,  $G$  为黄金分割。误差率及重叠率指标分别为

表 1 参数  $k$  和  $t$  的设置

实验	参数 $k$ /类数	参数 $t$ /次数
1, 2	4	50
3	4	30
4	5	50

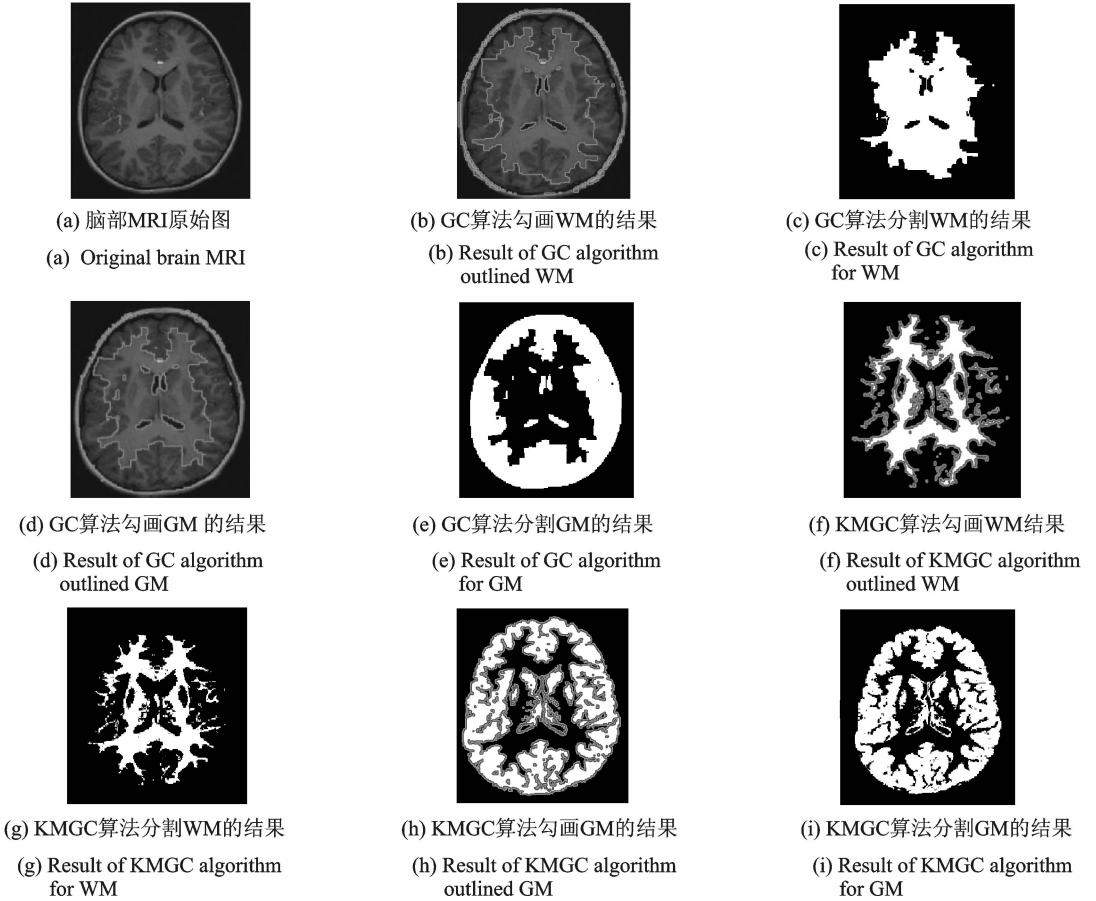


图 2 KMGC 算法和 GC 算法对脑 MRI 的分割结果  
Fig. 2 Results of KMGC and GC algorithms for brain MR image segmentation

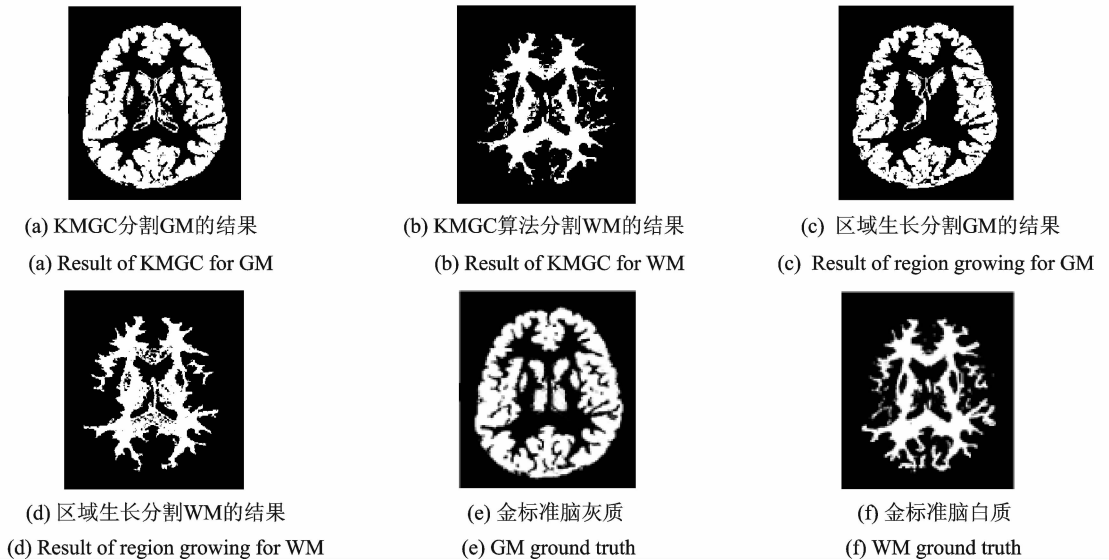


图 3 KMGC 算法和区域生长算法对脑 MRI 的分割结果  
Fig. 3 Results of KMGC and region growing algorithms for brain MRI segmentation

$$\text{误差率} = \frac{(R - G \cap R)}{G} \times 100\% \quad (10)$$

$$\text{重叠率} = \frac{(R \cap G)}{G} \times 100\% \quad (11)$$

本文还引入了时间指标来证明算法的可行性。由于在比较大的图像上 K-means 预处理时间比较长,但是为了使分割精度更高,本文算法以时间为代价来换取更高的精度。KMGC 算法消耗时间分为两个阶段:K-means 预处理阶段和 GC 优化阶段,运行算法 10 次求平均,分析结果如表 2 所示。

表 2 GC, KMGC 和区域生长算法的定量分析

Tab. 2 Quantitative analysis of GC, KMGC and region growing algorithms

算 法	误差率/%		重叠率/%		消耗时间/s	
	GM	WM	GM	WM	GM	WM
GC 算法	48.67	57.46			0.552	0.426
区域生长算法	21.58	24.60	85.21	88.27	1.793	2.875
KMGC 算法	5.22	10.08	98.33	90.55	28.651+0.225	28.651+0.158

由表 2 可以看出,本文 KMGC 算法的误差率比传统 GC 算法、区域生长算法都要低得多,而重叠率比区域生长算法高,由此可以看出,本文算法优于这两种算法。由于传统的 GC 算法基本上未分割出 GM 和 WM,所以其重叠率的计算没有意义。

### 3.3 KMGC 算法和 GOK-means 算法的对比实验

本实验分别实现了 KMGC 算法和 GOK-means 算法对来自 BRAINWEB 数据库的仿真人脑 MRI (102×124) 进行分割,并带有黄金分割标准,实验结果如图 4 所示。通过实验结果对比,本文算法得到了更好的分割精度。由实验结果可以看出, KMGC 算法分割结果比 GOK-means 算法分割结果更接近

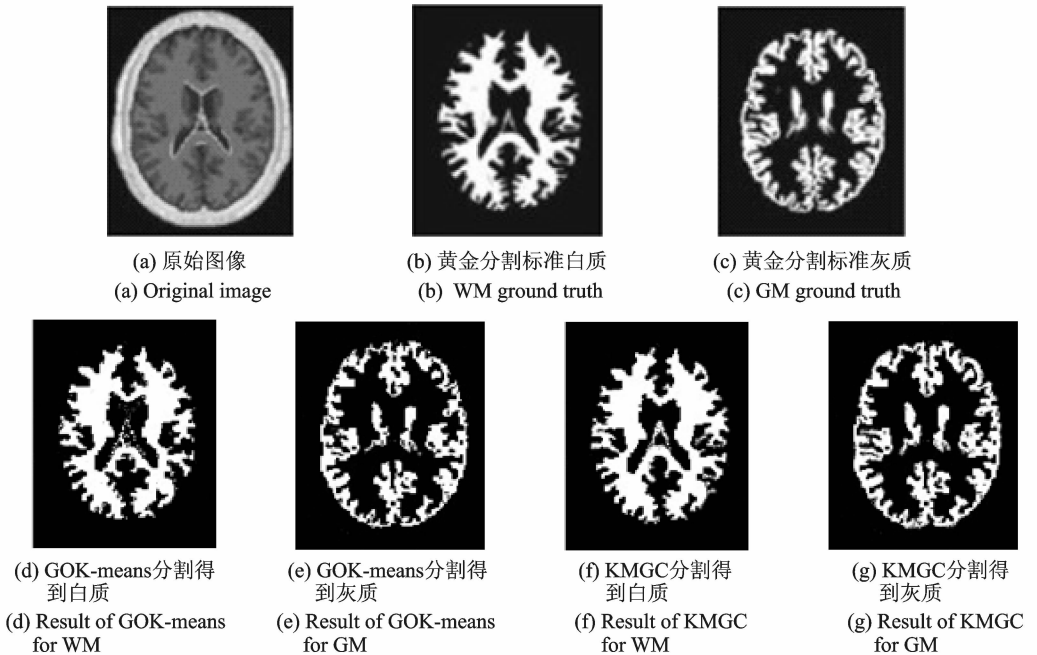


图 4 KMGC 算法和 GOK-means 算法对脑 MRI 的分割结果

Fig. 4 Results of KMGC and GOK-means algorithms for brain MRI

表 3 KMGC 算法和 GOK-means 算法的定量分析

Tab. 3 Quantitative analysis of KMGC and GOK-means algorithms

算法	GM 重叠率/%	WM 重叠率/%	GM 消耗时间/s	WM 消耗时间/s
KMGC	68.61	90.83	1.418+0.073	1.418+0.092
GOK-means	67.00	87.84	1.418	1.418

黄金分割。为了更能充分地验证 KMGC 算法的优越性,本实验利用重叠率对实验结果进行定量分析如表 3 所示。由表 3 可以看出,KMGC 算法的重叠率比 GOK-means 算法高,因此本文算法精度更高。

### 3.4 KMGC 算法和人工交互分水岭区域合并算法的对比实验

本实验数据来自于文献[9],使用 KMGC 算法和人工交互分水岭区域合并算法分别实现了从脑部 MRI(318×418)中分割出脑白质,并与金标准图作对比,该金标准由医生手动勾画。实验结果及金标准如图 5 所示。由实验结果可以直观看出,KMGC 算法分割结果比人工交互分水岭区域合并算法分割出的结果更接近金标准,并且没有出现过分割现象,只分割出感兴趣的脑白质。依据式(10,11)对其进行定量分析如表 4 所示。由表 4 定量分析表明,本文提出算法比交互式分水岭区域合并算法的重叠率高,误差率低,因此本文算法分割效果更好。

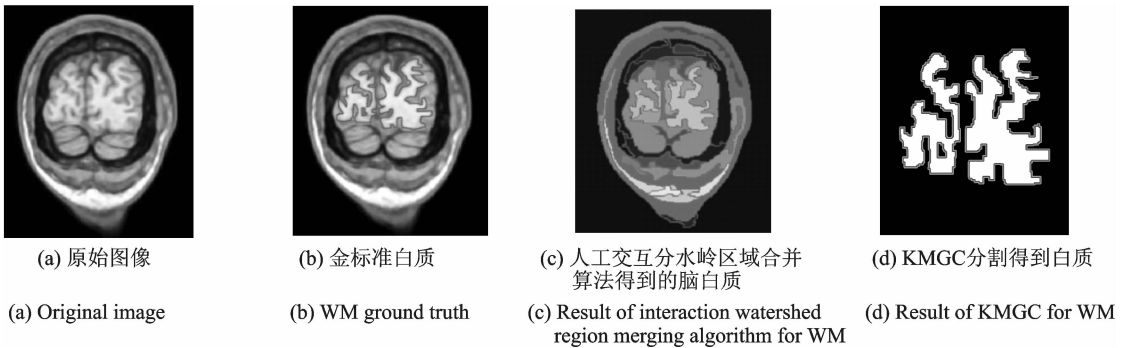


图 5 KMGC 算法和人工交互分水岭区域合并算法对脑部 MRI 的分割结果

Fig. 5 Results of KMGC and interaction watershed region merging algorithms for brain MRI segmentation

表 4 KMGC 算法和交互式分水岭区域合并算法的定量分析

Tab. 4 Quantitative analysis of KMGC and interactive watershed region merging segmentation algorithms

算法	重叠率/%	误差率/%	消耗时间/s
交互式分水岭区域合并算法	49.16	59.96	0.594
KMGC	97.92	3.38	53.803+0.122

## 4 结束语

本文针对脑部 MRI 分割提出了一种交互式分割算法——KMGC 算法,该算法结合了 K-均值和图割模型对脑部 MRI 中的 GM 和 WM 进行分割,既能够在聚类的基础上进一步细化分割效果,又允许用户与算法进行交互,选择更准确的种子点,从而达到更有效地分割 GM 和 WM 的目的。通过与传统 GC 算法、区域生长算法、GOK-means 算法以及交互式分水岭区域合并算法的对比实验验证了 KMGC 算法的有效性,其分割结果更符合人类视觉效果,并且交互式操作更能满足用户的需求。今后的研究方向:通常灰质被认为负责大脑的信息处理,而其中的海马、壳、尾状核等神经核与人的情绪、心理、神经系统疾病等密切相关,但是海马、壳及尾状核在灰质中对比度很低,要想把它们从灰质中分割出来,仅利用图



像灰度信息是不够的,因此在今后的研究中,要在 GC 的能量函数中增加一些图像的纹理或空间信息,或者在使用 GC 优化之前,利用这些对象模板库中的模板进行粗略分割,这些都是以后要研究的重点。

### 参考文献:

- [1] 余柳青,覃晓,元昌安,等. 基于全局优化 K-均值聚类的医学图像分割方法[J]. 广西师范学院学报:自然科学版,2015(1): 071-076.  
Yu Liuqing, Qin Xiao, Yuan Changan, et al. A medical image segmentation method based on global optimized K-means clustering[J]. Journal of Guangxi Teachers Education University: Natural Science Edition, 2015(1): 071-076.
- [2] 吕晓琪,范运洲,古宇,等. 基于人工交互分水岭区域合并的医学图像分割研究[J]. 中国医学影像学杂志,2010,18(6):516-520.  
Lü Xiaoqi, Fan Yunzhou, Gu Yu, et al. A study of medical image segmentation based on human interactive region merges of watershed[J]. Chinese Journal of Medical Imaging, 2010, 18(6): 516-520.
- [3] Wang Shunfeng, Geng Zhiyuan, Zhang Jianwei, et al. A fuzzy C-means model based on the spatial structural information for brain MRI segmentation[J]. International Journal of Signal Processing, Image Processing and Pattern Recognition, 2014, 7(1): 313-322.
- [4] De Ailing, Guo Chengan. An image segmentation method based on the fusion of vector quantization and edge detection with applications to medical image processing[J]. Int J Mach Learn & Cyber, 2014, 5: 543-551.
- [5] Boykov Y, Jolly M P. Interactive organ segmentation using graph cuts[C]//Proceedings of the 3rd International Conference on Medical Image Computing and Computer-Assisted Intervention. Pittsburgh, USA: Springer, 2000: 276-286.
- [6] Boykov Y, Jolly M P. Interactive graph cuts for optimal boundary & region segmentation of objects in N-D images[C]//ICCV 2001. [S. l.]: IEEE, 2001: 105-112.
- [7] Boykov Y, Kolmogorov V. An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(9): 1124-1137.
- [8] Shi J, Malik J. Normalized cuts and image segmentation[J]. IEEE Trans Patt Anal Mach Intell, 2000, 22(8): 888-905.
- [9] Greig D, Porteous B, Seheult A. Exact maximum a posteriori estimation for binary images[J]. Journal of the Royal Statistical Society, Series B, 1989, 51(2): 271-279.
- [10] 郑馨,王勇,汪国有. EM 聚类和 SVM 自动学习的白细胞图像分割算法[J]. 数据采集与处理, 2013, 28(5): 614-619.  
Zheng Xin, Wang Yong, Wang Guoyou. White blood cell segmentation using expectation-maximization and automatic support vector machine learning[J]. Journal of Data Acquisition and Processing, 2013, 28(5): 614-619.
- [11] 刘松涛,殷福亮. 基于图割的图像分割方法及其新进展[J]. 自动化学报, 2012, 38(6): 911-922.  
Liu Songtao, Yin Fuliang. The basic principle and its new advances of image segmentation methods based on graph cuts[J]. Acta Automatica Sinica, 2012, 38(6): 911-922.

### 作者简介:



田换(1989-),女,硕士研究生,研究方向:数据挖掘、数字图像处理, E-mail: 1101746040@qq.com。



覃晓(1973-),女,副教授,研究方向:数据挖掘、数字图像处理, E-mail: 7670172@qq.com。



元昌安(1964-),男,教授、博士,研究方向:数据库与知识工程、数据挖掘及智能计算。



刘致锦(1991-),男,硕士研究生,研究方向:数据挖掘、数字图像处理。



廖剑平(1979-),女,副教授,研究方向:医学图像处理、数据挖掘。

