

基于多尺度连接模型的脑 MRI 模糊分类

裴红利, 喻 昱, 邓振生

(中南大学信息物理工程学院生物医学工程研究所, 长沙 410083)

摘要: 针对传统分割方法在分割数量上的限制, 以及模糊聚类方法在层次优化上的不足, 提出一种有效的基于多尺度连接模型的人脑磁共振图像模糊分类算法。对脑磁共振图像进行灰度不均匀性校正后, 该方法通过非线性扩散连接模型引入尺度间的模糊约束, 定义 2 个模糊距离, 并应用到模糊聚类算法中, 组合尺度间和尺度内的模糊约束, 给出一个多分辨模糊聚类框架。实验结果表明了该算法的准确性和有效性。

关键词: 多尺度连接模型; 模糊分类; 偏场校正

Fuzzy Segmentation Based on Multiscale Linking Model for Brain MRI

PEI Hong-li, YU Gang, DENG Zhen-sheng

(Institute of Biomedical Engineering, School of Info-physics and Engineering, Central South University, Changsha 410083)

【Abstract】 To make up for the restriction of traditional segmentation methods regarding the number of segmentation and fuzzy clustering method's lacking in levels of optimization, this paper presents an effective fuzzy segmentation approach based on multiscale linking model for brain MRI. The non-uniformity of gray-scale is corrected after analysis of the bias in brain MRI. A fuzzy inter-scale constraint via antistrophic diffusion linking model is introduced. Two fuzzy distances are developed and embedded into the fuzzy clustering algorithm. Moreover, a multiresolution framework combining the inter-scale and intra-scale constraints is presented. Experimental results show the accuracy and validity of this method in which a large deal of brain MRI data is used.

【Key words】 multiscale linking model; fuzzy segmentation; bias correction

1 概述

多尺度或多分辨率技术广泛地用于医学图像分析中, 主要的方法有: 金字塔(pyramid), 塔(stack)及小波(wavelets)。这些多分辨率技术提供了原始图像在不同尺度的观察结果, 极大地增强了算法对噪声、低对比度的鲁棒性。传统的金字塔^[1]分割方法是通过从一个尺度到另一个尺度向下投射实现的, 限制了分割的数量 $4i(i \in N)$ 。对于二维图像, 塔^[2]是一个有效的多分辨率方法, 但是当图像从二维变到三维时, 该方法就不理想了。文献[3-4]给出了一种新的多尺度图像分割技术, 如超塔(hyperstack)。近年来, 一些基于多分辨空间的模糊聚类技术被陆续提出^[5]。这些方法通常在尺度空间图像序列的每一个层次上直接进行模糊聚类方法, 上一尺度的分割结果经常作为下一尺度的初始状态, 没有引进有效的尺度之间的约束来优化尺度内的分割, 所以分割结果只在最后分割的层次得到优化。因此, 这些方法对于退化图像的鲁棒性不是很好。

本文提出了一个基于多尺度空间的模糊聚类方法, 该方法分 2 个步骤: 首先考虑人脑 MR 图像受到磁场不均匀性的影响, 对其进行不均匀性校正; 然后利用本文提出的分类方法对脑组织分类。

2 脑 MR 图像偏场校正

由于 MRI 设备获取的人脑核磁图像受噪声、射频场不均匀性和脑不同组织之间的差异性以及部分容积效应等因素影响, 造成 MR 图像的均匀性变差。由于受这些伪差的影响, 仅依靠图像的灰度密度信息给精确的脑图像分类带来了很大

困难, 如果要得到正确的脑组织分类, 首先必须对灰度进行校正。文献[6]提出一种偏场校正的自适应算法, 本文根据该方法得到偏场预测结果, 如图 1 所示。这种方法包含 2 个过程: (1)预测在第 i 个像素的组织类型; (2)预测图像第 i 个像素的灰度的偏移值。



图 1 偏场预测结果

3 多尺度连接模型的模糊分类

对图像偏场校正之后, 本文采用一种新的基于多尺度空间的模糊聚类方法, 该方法分 2 步: (1)建立非线性扩散连接模型; (2)多尺度模糊分类。

3.1 非线性扩散连接模型

连接模型的构造过程包括 2 步: (1)模糊和子采样: 尺度空间上的图像序列是通过偏微分扩散方程模糊原始图像, 然后子采样来获得的。(2)连接: 在相邻尺度上的图像中建立父

基金项目: 国家自然科学基金资助项目(60551003)

作者简介: 裴红利(1983 -), 女, 硕士, 主研方向: 图像处理, 可视化; 喻 昱, 讲师、博士; 邓振生, 教授、博士

收稿日期: 2009-09-06 **E-mail:** bmedzs@csu.edu.cn

子联系。

3.1.1 模糊和子采样

利用非线性扩散方程来模糊图像，可以在去除噪声时有效地保护边界。在图像 I 中位置 (x, y) 处的热扩散方程可以定义为

$$\frac{\partial I(x, y)}{\partial t} = \text{div}(D \cdot \nabla I(x, y)) \quad (1)$$

其中， ∇ 是梯度算子； D 是热扩散系数。

原始图像在建立尺度空间时，应该根据要保护的图像结构类型，选择合适的扩散系数。通过非线性扩散技术，可以在模糊图像去除噪声，最大限度地保护感兴趣的目标。对模糊图像子采样，得到粗尺度图像，依此类推可以得到尺度空间上更多的层次。

3.1.2 连接

在连接阶段，定义了尺度空间上 2 个相邻尺度的父子关系，这个关系可以用许多相似性量度来评估。其中，2 个连续尺度上的空间关系总是已知的，这个空间关系描述了尺度空间上各个元素之间的父子关系。例如，在一个 2×2 子采样的尺度空间中，高层次上的 1 个像素是低层次上对应的 4 个邻近像素的父亲。所以，每个孩子有唯一的父亲，依据空间关系定义的父子关系是唯一确定的，没有异议。这里将依据空间关系定义的父亲称为显式父亲，因为这个父亲是明确的、唯一的。类似的，这些孩子也称为显式孩子，因为只要父亲确定了，孩子也就确定了。然而，在一个连接模型中的父子关系是隐式的，或者说是模糊的，底层的孩子依据不同的相似性量度连接到高层的父亲。不同依据空间关系定义的连接，预定义的孩子(隐式孩子)和潜在的多个父亲(隐式父亲)之间的相似性量度决定了它们之间的相似性。在连接阶段，孩子和父亲的相似性(也叫连接长度)需要被量化。相似性是一个从 0~1 的数值，是一些相似项的加权求和。文献[4]中提出了 2 个常用的相似项，这里用所有相似项的加权和来定义影响度，也称为连接长度。在连接阶段，从潜在的父亲中选择具有最大影响度的像素作为父亲。影响度定义如下：

$$L(x, y) = \sum_{i=1}^2 \omega_i S_i(x, y) \quad (2)$$

其中， x 和 y 分别是给定的孩子和隐式父亲； w_1 和 w_2 是权值； $S_i(x, y)$ 是文献[4]中提出的 2 个相似性项。

3.2 多尺度模糊分类

3.2.1 自相似性和尺度内、尺度间约束

尺度空间的一系列图像都具有自相似性，因为它们都是原始图像在不同尺度的近似表示。显然，自相似性包括 2 个方面：

(1) 尺度内的相似性：尺度的相似性表示了明显的聚类特性，所有属于一类的像素具有相似性。常规的模糊 C 均值算法可以描述尺度内相似性，但是这种相似性对噪声非常敏感。

(2) 2 个相邻尺度的相似性：连接模型表示了父子关系，孩子和父亲是相关的。孩子继承了父亲的特征，并且显示了新的特征。被继承的特征有亮度、梯度、模糊聚类等等。

为了更好地描述这些关系，一些数学符号被引入。令 $X^{(L)} = \{x_k^{(L)} | k \in I^{(L)}\}$ 是层次 L 上的图像或图像的特征图像。 $x_k^{(L)}$ 是像素 k 的图像值。 $I^{(L)}$ 是层次 L 的数据集。被标记的图像定义为 $I^{(L)} = \{I_k^{(L)} | k \in I^{(L)}\}$ ，其中， $I_k^{(L)} \in \{1, 2, \dots, c\}$ 表示像素 k 的标记； c 表示聚类的个数。多分辨分割可以描述为：给定高层次的 $X^{(L+1)}$ 和 $I^{(L+1)}$ ，当前层次 $I^{(L)}$ 的优化分割应该同时

遵守尺度内和尺度间的自相似性。

令 $P(x_k^{(L)})$ 是依据连接模型定义的像素 k 的隐式父亲。

$PS(x_k^{(L)})$ 是依据空间关系定义的显式父亲。 $P(x_k^{(L)})$ 定义为

$$P(x_k^{(L)}) = \arg \max \{L(x_m^{(L+1)}, x_k^{(L)})\} \quad m \in N_p(PS(x_k^{(L)})) \quad (3)$$

其中， $N_p(PS(x_k^{(L)}))$ 是 $PS(x_k^{(L)})$ 的邻居。式(3)是易于理解的，被连接的父亲应该是显示父亲邻居中具有最大影响度数值的一个像素。这个邻居的范围描述了潜在父亲的搜索范围，例如，4-邻域或者 8-邻域是常用的搜索范围。类似的，依据连接模型定义的孩子可以描述如下。令 $S(x_k^{(L+1)})$ 是像素 $x_k^{(L+1)}$ 最可能的孩子：

$$S(x_k^{(L+1)}) = \arg \max \{L(x_k^{(L+1)}, x_m^{(L)})\} \quad m \in N_c(x_k^{(L+1)}) \quad (4)$$

其中， $N_c(x_k^{(L+1)})$ 是像素 $x_k^{(L+1)}$ 的显式孩子，例如多分辨空间利用了 2×2 子采样，在层次 $L+1$ 中的每个像素有 4 个显示的孩子。 $S(x_k^{(L+1)})$ 是这 4 个孩子中具有最大影响度的孩子。在建立连接关系时，通常从底层向高层建立，此时求孩子时可以直接利用连接好的父子关系得到。

依据上面描述的自相似性，一个像素和聚类中心的模糊距离应该包括 2 个部分：(1) 在一个尺度内的模糊距离。(2) 在 2 个相邻尺度之间的模糊距离。尺度内的模糊距离可以用常规的模糊 C 均值算法定义： $\|x_k^{(L)} - v_i^{(L)}\|$ 。2 个相邻尺度的相似性表明父亲和孩子所属的聚类是类似的，而且，相邻尺度的聚类中心也是类似的。因此，2 个尺度间的模糊距离被引入： $\|P(x_k^{(L)}) - v_i^{(L+1)}\|$ 和 $\|v_i^{(L)} - S(v_i^{(L+1)})\|$ 。如图 2 所示，虚线表示了依据连接关系建立的父子关系。第 1 个模糊距离描述了层次 L 上像素 $x_k^{(L)}$ 连接的父亲 $P(x_k^{(L)})$ 和高层次上对应的聚类中心 $v_i^{(L+1)}$ 的距离。第 2 个模糊距离描述了相邻层次上 2 个对应的聚类中心之间的距离。

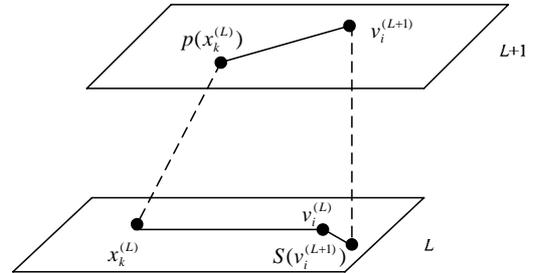


图 2 尺度之间的模糊距离

首先，这 2 个模糊距离描述了这个事实：具有父子关系的 2 个像素应该属于具有父子关系的 2 个聚类中心，这显示了不同尺度的父子像素的相似性。其次，2 个距离也描述了这个事实：低尺度的聚类中心 $v_i^{(L)}$ 应该不远离高层次对应的聚类中心 $v_i^{(L+1)}$ 的孩子，这显示了不同尺度上的聚类中心的相似性。显然，这 2 个事实类似于人眼在不同尺度上的观察结果。当模糊聚类收敛到全局优化解的时候，这 2 个距离应该被最小化。

在当前层次 L 和高层次 $L+1$ 上的尺度间约束可以定义如下：

$$J_m^{(L, L+1)}(U; V; X) = \sum_{k=1}^n \sum_{i=1}^c u_{ik}^{(L)m} \left[\alpha \cdot \|P(x_k^{(L)}) - v_i^{(L+1)}\|^2 + \beta \cdot \|v_i^{(L)} - S(v_i^{(L+1)})\|^2 \right] \quad (5)$$

其中， α, β 是参数，控制了尺度间约束的敏感性。根据 FCM，层次 L 尺度内的约束可以定义为

$$J_m^{(L)}(U;V;X) = \sum_{k=1}^n \sum_{i=1}^c u_{ik}^{(L)m} \cdot \left[\omega \cdot \|x_k^{(L)} - v_i^{(L)}\|^2 \right] \quad (6)$$

其中, ω 是一个参数, 控制了尺度内约束的影响。合并式(5)和式(6), 组合了尺度内和尺度间约束的多分辨能量函数可以定义为

$$E(U^{(L)}, V^{(L)}) \Big| U^{(L+1)}, V^{(L+1)} = J_m^{(L)} + J_m^{(L+1)} \quad (7)$$

3.2.2 多尺度模糊分类算法

在提出的多尺度模糊聚类方法中, 分割从连接模型的最高层开始, 其中利用一个常规的模糊聚类算法, 如模糊 C 均值方法, 来进行预分割。预分割结果用于低层次的分割, 每个层次的优化问题是最小化能量函数:

$$(U^{(L)}, V^{(L)}) = \arg \min E, \sum_{i=1}^c u_{ik}^{(L)} = 1 \quad (8)$$

对所有 x_k 依据 Lagrange 方法, 让 $J = E - \lambda(\sum_{i=1}^c u_{ik}^{(L)} - 1)$ 。

优化结果可以通过公式 $\frac{\partial J}{\partial u_{ik}^{(L)}} = 0$ 和 $\frac{\partial J}{\partial v_i^{(L)}} = 0$ 得到:

$$u_{ik}^{(L)} = \frac{\left(\frac{1}{H}\right)^{\frac{1}{m-1}}}{\sum_{i=1}^c \left(\frac{1}{H}\right)^{\frac{1}{m-1}}} \quad (9)$$

$$H = \left[\omega \|x_k^{(L)} - v_i^{(L)}\|^2 + \alpha \|P(x_k^{(L)}) - v_i^{(L+1)}\|^2 + \beta \|v_i^{(L)} - S(v_i^{(L+1)})\|^2 \right] \text{ 时,}$$

$$v_i^{(L)} = \frac{\sum_{k=1}^n \left[u_{ik}^{(L)m} \cdot (\omega \cdot x_k^{(L)} + \beta \cdot S(v_i^{(L+1)})) \right]}{\sum_{k=1}^n \left[u_{ik}^{(L)m} \cdot (\beta + \omega) \right]} \quad (10)$$

4 实验结果

本文设计了 2 组实验, 一个是合成图像实验, 一个是医学上的 MR 图像实验。在这里, 选择常规的 P-M 方程作为扩散方程来建立连接模型。在第一组实验中, 设计了一个 123×112 的合成图像。其中, 目标的灰度值是 186, 背景是 125。最原始的合成图像中的目标和背景是已知的, 没有任何噪声。接下来, 设计具有 10% 高斯噪声的中度噪声图像。图 3 是中等噪声图像的分割结果, 图中的分割结果用黑白 2 种颜色表示。

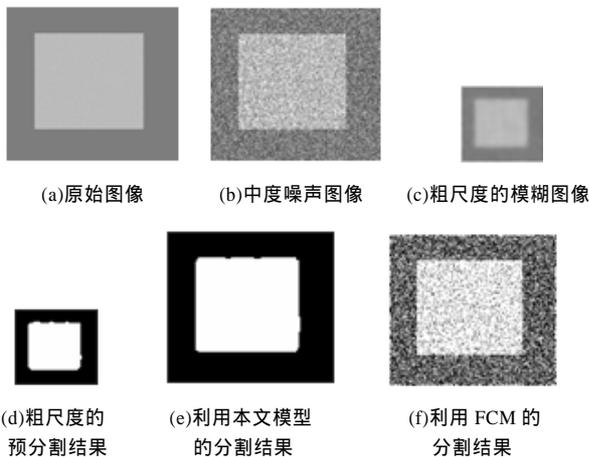


图 3 图像分割结果

如图 3(e) 所示, 通过本文模型成功提取了目标。和图 3(e) 相比, FCM 对噪声过于敏感, 许多像素被错误地分割了。

实验中的 MR 图像是从 McGill 大学 Montreal 神经学研究所的 BrainWeb 得到的。图谱库中具有不同切片的不同噪声与偏场的脑 MR 图像, 噪声分布从 0~9%。从数据库中下载了数据集, 并且分割这些切片来抽取 3 种物质: 脑灰质, 脑

白质和脑脊液。图 4 给出 40% 偏场、9% 噪声的 T1 图像的切片 91, 100, 110 的实验结果。

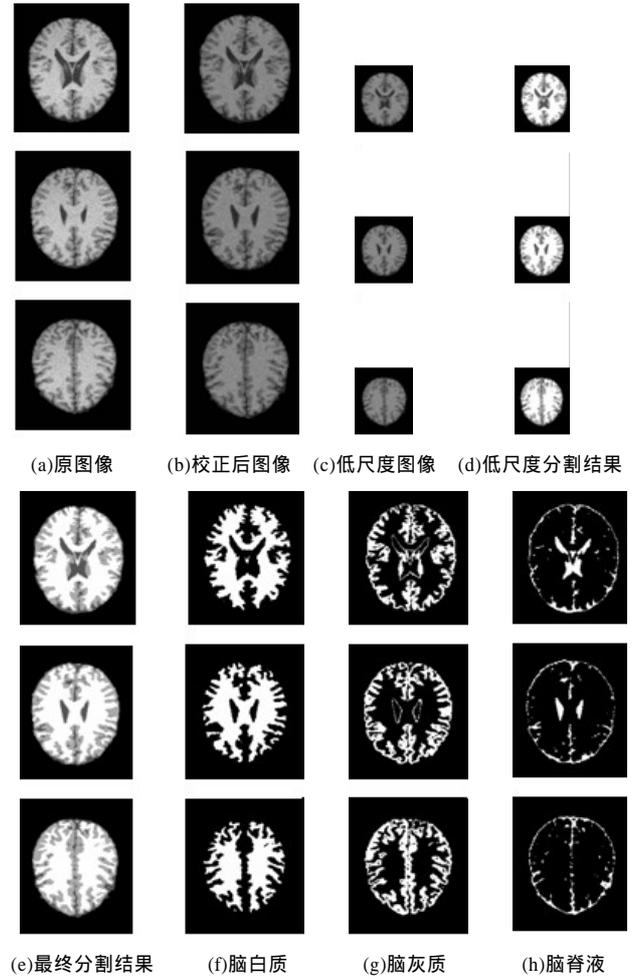


图 4 具有 40% 偏场、9% 噪声的切片校正、分割和分类结果

实验中参数应该按照噪声的大小来选择。通常情况下, 为了简单, ω 设置为 1。其他参数成比例地选择以控制尺度内和尺度间的约束的权重。其中, $\alpha \in [0.5, 10]$ 和 $\beta \in [1, 3]$ 表示了对尺度间约束的信任。当原始图像中的噪声变得更加严重时, α, β 应该相应地增加。在多次实验后, 发现 α, β 对分割实验结果不是太敏感, 2 个参数的一点改变几乎不影响结果。大多数情况下, 可以选择 α, β 设置为整数。

为评估算法结果, 先请专家对无噪声的均匀图像进行手动分割, 作为标准的分割结果, 再计算相似性准则。给出上述分割结果的相似性准则, 用来评估算法的精确性, 见图 5。

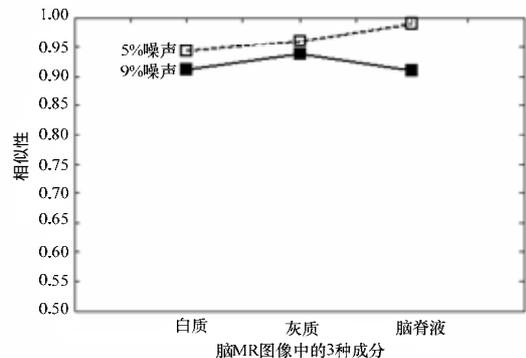


图 5 算法分割结果的相似性准则评估

(下转第 179 页)