

基于多参数配准模型的脑核磁影像分割算法

张 万¹, 刘 刚¹, 朱 凯^{1,2}, 廖恒旭¹

(1. 上海电力学院自动化工程学院, 上海 200090; 2. 国网浙江省电力公司金华供电公司, 浙江金华 321000)

摘 要: 配准技术在基于多图谱的分割方法中能有效地将医学图谱的先验知识融入分割过程, 再结合以高效的标记融合算法, 最终实现精确地自动分割. 针对图谱配准的较大误差及其对标记融合的重要影响, 本文建立了一种新的概率图模型框架并以此提出了基于多参数配准模型的分割算法, 将此方法与高效的标记融合算法相结合, 可以提高目标图像中特定组织区域的分割精度, 更使其在少量图谱分割的情形下具有重要应用. 首先, 使用多种配准参数对所有目标图像进行配准; 然后, 分别采用不同的算法对配准图像进行灰度融合和标记融合, 实现训练图像的重构过程; 最后, 利用高效的标记融合算法对重构后的图像进行融合得到最终精确的分割结果. 实验结果表明该方法均优于本文其他分割算法, 能够有效提升脑部组织分割精度.

关键词: 图像分割; 图像配准; 标记融合; 多参数配准模型; 脑核磁影像

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2017)09-2202-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2017.09.022

Multi-parameter Registration Model for Brain MR Image Segmentation Based on Label Fusion

ZHANG Wan¹, LIU Gang¹, ZHU Kai^{1,2}, LIAO Heng-xu¹

(1. College of Automation Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. Jinhua Power Supply Company, State Grid Corporation, Jinhua, Zhejiang 321000, China)

Abstract: Registration technology can effectively integrate the prior knowledge of medical atlases into the segmentation process, and then combine with the efficient label fusion algorithm to obtain the segmentation results accurately and automatically. Aimed at the large error in registration of target image and its great influence on label fusion, a framework of probabilistic graphical model is established and the idea of multi-parameter registration model is proposed. Combined with an efficient algorithm on label fusion, this framework can improve the segmentation accuracy of specific tissue regions on target image, which has important application value in segmentation with a few available atlases. After the multi-parameter registration and the reconstruction process of training sets on target images, the final segmentation results are obtained by an efficient fusion algorithm. According to the experiment which was conducted on the brain magnetic resonance image segmentation with different segmentation methods, the proposed framework can effectively improve the accuracy of segmentation.

Key words: image segmentation; image registration; label fusion; multi-parameter registration model; brain magnetic resonance images

1 引言

人体脑部核磁共振图像 (Magnetic Resonance Images, MRI) 是临床上对大脑功能研究及大脑组织疾病预测、诊断、治疗的主要依据^[1,2], 其特定组织的精确分割是医学图像处理领域中的一个热点及难点问题. 目前, 脑部组织分割方法按照人工参与程度可大致分为: 手

动分割、半自动分割、自动分割. 近年来, 自动分割已逐渐成为图像分割领域的研究方向和发展趋势^[3].

基于图谱配准的分割方法能够充分利用手动分割的先验知识, 将图谱中存储的形状先验信息通过配准的形变参数直接映射到待分割图像中, 实现全自动的图谱先验信息下的特定组织分割. Baillard 等^[4] 利用基于单图谱的分割方法分割出脑部结构, 达到了基于图

谱配准的脑部图像组织分割的目的.但由于人体解剖结构的差异,单图谱分割难以适应不同个体脑部结构的差异,特别是图像边界处的分割,容易产生错误分割,致使分割精度急剧降低. Mert R. Sabuncu 等^[5]利用概率统计模型结合贝叶斯推理等知识以基于多图谱配准的标记融合方法实现了脑部图像特定组织的自动分割,并得到了较为准确的分割结果.刘宏、王婕等^[6]也提出了一种图谱图像与目标图像的以分割对象为中心的加权相似性度量方法,即多图谱分割方法.

基于多图谱配准的分割方法^[7-10]充分利用多个医学图谱的先验信息来降低图谱选择的不确定性,然后再使用融合算法将多个分割结果融合在一起,得到最终的分割结果.传统的基于多图谱配准的分割方法^[11,12]是将所有训练图像中图谱图像与目标图像通过一个有效的配准算法进行配准,然后对配准结果进行标记融合的过程.这样做虽然能得到较高的分割结果,但是却不能保证图谱配准中较大误差的出现及其对标记融合过程的重要影响.图谱配准是多图谱分割研究中的一个关键性问题,毫无疑问的说配准结果越高,分割效果越好.

本文建立了新的概率图模型并提出了一种基于多参数配准模型的分割算法.本方法可以将多种参数下的配准图像进行融合并与不同的标记融合算法相结合,主要通过减少配准误差来提高目标图像中特定组织区域的分割精度.另外,由于获取不同图谱的样本较为不易,本方法可在样本数量有限的条件下仍能得出较高的分割结果.首先,使用不同的配准参数对目标图像进行逐一配准;然后,采用不同的融合算法对已配准图像分别进行灰度融合和标记融合,实现训练图像的重构过程;最后,利用高效的标记融合算法对重构后的图像进行融合得到最终的分割结果.文中实验表明经此方法融合后的分割结果比未使用此方法融合的结果更精确、更接近真实值.

2 基于多参数配准模型的分割算法

2.1 概率图模型

图 1 为本文提出的概率图模型,也是本文基于多参数配准模型分割算法的理论依据及来源.图中 $\{I_n\}$, $\{L_n\}$, $n=1, \dots, N$, 分别表示 N 幅训练图像的图谱图像及标记图像.这里图谱(训练图像)指专家预先分割好的图像,可以将一个图谱理解为一幅图谱(灰度)图像及与其对应的标记图像的组合. ϕ_n 表示配准过程中的形变场, σ_n 为决定最终形变的平滑程度的参数,称为形变平滑参数. $\{\tilde{I}_n\}$, $\{\tilde{L}_n\}$ 分别为配准处理后的图谱图像与标记图像. M 为目标图像与训练图像之间的索引, $L(x)$ 为待分割的组织区域的标记值, Ω 表示整个图像

区域.图中阴影区域为已知量.




图1 基于多参数配准模型分割的概率图模型

配准就是寻找一个空间变换 ϕ , 使得形变后浮动图像 $S(\cdot)$ 和静态图像 $F(\cdot)$ 能够满足相似性测度的过程, 相似性测度 $SSD(\cdot, \cdot)$ 是衡量两幅图像配准过程中相互对应的具体标准, 衡量当前形变场是否满足配准要求. 基于灰度的配准中最基本的相似性测度就是均方误差:

$$\begin{aligned} SSD(F, S \cdot \phi) &= \frac{1}{2} \|F - S \cdot \phi\|^2 \\ &= \frac{1}{2|\Lambda|} \sum_{x \in \Lambda} |F(x) - S[\phi(x)]|^2 \quad (1) \end{aligned}$$

式中, Λ 为 F 和形变后 S 的共同区域, x 为图像中的某个像素点, 由于直接对式(1)最小化会导致不稳定的解, 所以需要加入某些先验知识, 一般是在式(1)中加入一个规则项 $Reg(\phi)$ 对 ϕ 作限制, 则图像配准的能量函数可以定义为:

$$E = SSD + \sigma \cdot Reg(\phi) \quad (2)$$

其中 E 为能量函数, SSD 表示两幅图像的相似性测度, σ 为形变平滑参数.

文中主要采用了 Demons 微分同胚的配准方法, 由于 Demons 算法的寻优过程和规则化分离的特点, 引入中间变量 C 来表示尚未规则化的空间变化, 而 ϕ 为规则化后的空间变化, 则 Demons 算法分为两个交替进行且容易计算的优化步骤: (1) 已知 ϕ 优化 $SSD(F, S \cdot C)$, 其中 C 的初值为上一轮估计的 ϕ ; (2) 已知 C 优化 $\sigma \cdot Reg(\phi)$.

多图谱分割的目的是根据灰度图像 I 求出感兴趣区域标记值 L , 这里可以用最大后验估计 (Maximum-A-Posteriori, MAP)^[5] 来实现:

$$\begin{aligned} \hat{L} &= \arg\max_L p(L | I; \{L_n, I_n\}) \cong \arg\max_L p(L, I; \{L_n, I_n\}) \\ &\approx \arg\max_L p(L | I; \{L_n, I_n, \phi_n\}) \\ &= \arg\max_L \int_{\phi_n} p(L | I; \{L_n, I_n, \phi_n\}) p(\{\phi_n\} | I; \{L_n, I_n\}) d\{\phi_n\} \quad (3) \end{aligned}$$

由于 σ_n 是控制形变场 ϕ_n 的平滑程度的重要参数, 故 σ_n 的变化决定着配准过程中形变场的变化. 文中假设 $\{\phi_n\}$

独立同分布,则有:

$$p(\{\phi_n\} | I; \{L_n, I_n\}) = \prod_{n=1}^N p(\phi_n | I; \{I_n\}) \approx \prod_{n=1}^N p(\sigma_n | I; \{I_n\}) \quad (4)$$

则将式(4)代入式(3)得到最终分割结果的最大后验估计为:

$$\begin{aligned} \hat{L} &= \operatorname{argmax}_L \prod_{n=1}^N \sum_{\sigma_n} p(L | I; \{L_n, I_n, \sigma_n\}) p(\sigma_n | I; \{I_n\}) \\ &= \operatorname{argmax}_L \sum_{n=1}^N \log \sum_{\sigma_n} p(L | I; \{L_n, I_n, \sigma_n\}) p(\sigma_n | I; \{I_n\}) \end{aligned} \quad (5)$$

为此我们提出了基于多参数配准模型的分割思想. 与常见的基于多图配准的分割方法相比,本文最大的不同点在于我们将不同参数下的配准结果融入一个多参数配准模型,并用于后续标记融合的分割.

2.2 多参数配准模型的分割

基于多参数配准模型的分割思想主要分为多参数配准阶段和标记融合阶段,对多配准处理的研究则为本文的重点. 当已知目标图像与多幅图谱图像时,首先用不同参数下的配准方法对目标图像与图谱图像进行逐一配准(registration)得到配准结果,此为多配准过程. 考虑到非刚性配准运算效率的问题,我们提出采用递进策略对图像进行不同参数的配准;然后采用不同的融合算法对配准结果分别进行灰度融合和标记融合,得到目标图像的估计结果,此为训练图像的重构过程;最后利用有效的标记融合算法(如局部加权投票法 Local Weighted Voting、半局部加权融合法 Semi-Local Weighted Fusion 等)对重构后的图像进行融合,从而得到最终精确的分割结果. 其多参数配准模型如图2所示.

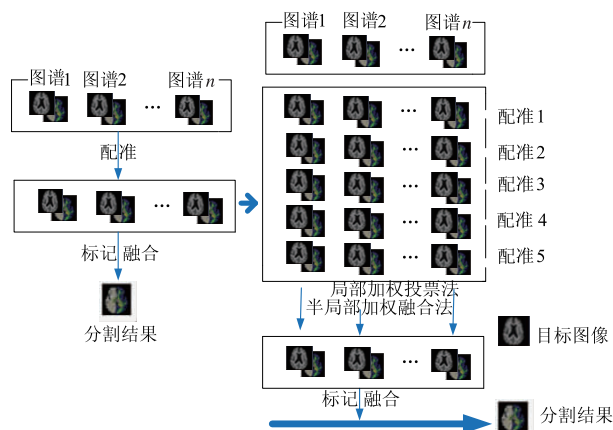


图2 基于多参数配准模型的组织分割示意图

由其过程可知,多参数配准融合的关键在于对配准结果中灰度图像和标记图像的处理. 对于配准图像中的灰度图像,本文采用式(6)对其进行融合:

$$\hat{I} = \sum_{n=1}^N \left[\frac{1}{Z} \exp \left[- \frac{\frac{1}{N} \sum_{x \in \Omega} (I_n(x) - I(x))^2}{\tau^2} \right] \times I_n \right] \quad (6)$$

式(6)中 N_Ω 为脑部灰度图像维数大小 $256 \times 256 \times 256$, $I_n(x)$ 为第 n 幅图谱的灰度图像的体素点, $I(x)$ 为目标图像中灰度图像的体素点, $x \in \Omega$ 为灰度图像的所有体素点, τ 为给定的标准差, I_n 为第 n 幅图谱的灰度图像, Z 为归一化函数. \hat{I} 为 N 幅图谱的灰度图像经过融合之后得到的灰度图,我们称之为训练图像重构后的灰度图.

对于配准结果中的标记图像,本文采用局部加权投票法^[5]对其进行处理,如式(7)所示,此结果被称之为重构后的标记图:

$$\hat{L}(x) = \operatorname{argmax}_{l \in \{1, \dots, j\}} \sum_{n=1}^N p_n(L(x) = l; L_n) p_n(I(x); I_n) \quad (7)$$

其中 $p_n(L(x) = l; L_n)$ 为脑部图像感兴趣标记区域的概率, $p_n(I(x); I_n)$ 为灰度先验概率,即标记区域的权重,如式(12)所示. 式(7)中 l 为脑部图像组织标记值, j 为第 n 个标记值.

2.3 标记融合策略

标记融合是多图谱分割方法的另一个关键. 合适的标记融合算法能够对脑部特定组织区域进行有效的分割提取进而提高分割精度. 为验证此模型的有效性,本文采用了两种标记融合算法对其进行实验,即多数投票法 (Majority Voting)、局部加权投票法 (Local Weighted Voting).

2.3.1 多数投票法

多数投票法为经典的标记融合方法,用该方法进行实验更具说服力. 这里采用 Mert R. Sabuncu 等人的方法^[5],将所有图谱赋予相等的权重,则该方法的标记融合如式(8)所示:

$$\hat{L}(x) = \operatorname{argmax}_{l \in \{1, \dots, j\}} \sum_{n=1}^N p_n(L(x) = l; L_n) \quad (8)$$

其中 $L(x)$ 为标记图像的体素点, $p_n(L(x) = l; L_n)$ 为脑部图像组织标记区域的概率:

$$p_n(L(x) = l; L_n) = \frac{1}{Z_{n,\rho(x)}} \exp(\rho \tilde{D}_n^l(\phi_n(x))) \quad (9)$$

其中 $Z_{n,\rho(x)} = \sum_{l=1}^j \exp(\rho \tilde{D}_n^l(\phi_n(x)))$ 为归一化函数, ρ 为斜率常数, \tilde{D}_n^l 表示第 n 幅训练图像的标记 l 的符号距离变换 (signed distance transform)^[13].

将此方法融入本文多参数配准模型框架下,则得到最终分割算法如式(10)所示:

$$\hat{L}(x) = \operatorname{argmax}_{l \in \{1, \dots, j\}} \sum_{n=1}^N \log \sum_{\sigma_n} p_n(L(x) = l; L_n) p(\sigma_n | I; \{I_n\}) \quad (10)$$

2.3.2 局部加权投票法

局部加权投票法是目前国际上主流且高效的标记融合方法,此方法更具有说服力和代表性.这里采用基于体素点的局部加权投票法^[5],如式(11)所示:

$$\hat{L}(x) = \operatorname{argmax}_{l \in \{1, \dots, j\}} \sum_{n=1}^N p_n(L(x) = l; L_n) p_n(I(x); I_n) \quad (11)$$

其中 $p_n(L(x) = l; L_n)$ 与式(9)相同. $p_n(I(x); I_n)$ 为灰度先验概率,即利用高斯分布来计算训练图像的权重,如式(12)所示:

$$P_n(I(x); I_n) = \frac{1}{\sqrt{2\pi\delta^2}} \exp\left[-\frac{1}{2\delta^2}(I(x) - I_n(x))^2\right] \quad (12)$$

其中 $I(x)$ 、 $I_n(x)$ 分别为目标图像和第 n 幅训练图像的体素点, δ 为高斯分布的标准差.

将式(11)代入本文配准模型框架下,则最终标记融合如式(13)所示:

$$\hat{L}(x) = \operatorname{argmax}_{l \in \{1, \dots, j\}} \sum_{n=1}^N \log \sum_{\sigma_n} p_n(L(x) = l; L_n) \cdot p_n(I(x); I_n) \times p(\sigma_n | I; \{I_n\}) \quad (13)$$

2.4 分割结果的评价

本文实验采用 Dice Score^[14] 作为分割结果的评价指标.它是对目标图像的真实分割结果(金标准)和自动分割结果的重叠率进行评价,如式(14)所示:

$$\operatorname{Dice}(l_{\text{man}}; \hat{L}_{\text{auto}}) = \frac{2V(l_{\text{man}} \cap \hat{L}_{\text{auto}})}{V(l_{\text{man}}) + V(\hat{L}_{\text{auto}})} \quad (14)$$

其中 l_{man} 为专家手工划分的分割结果即金标准, \hat{L}_{auto} 为融合算法得到的自动分割结果, V 为相应的体积大小.评价指标 Dice Score 值越大,说明目标图像的真实分割结果和融合算法得到的分割结果的重叠率越高,则自动分割结果越接近真实值.

3 实验及结果分析

为验证本文提出的基于多参数配准模型分割方法的有效性,我们分别采用两组实验并以两种标记融合方法(多数投票法、局部加权投票法)与之结合对脑部图像特定组织区域进行分割.最后,我们设计了第三组实验用以突出该方法的适用性及其应用价值.

3.1 实验素材

本文从脑部 MR 图像扫描数据^[5] 中选取 20 幅图谱图像及相应的标记图像.这些 T1 加权的核磁共振脑部图像的分别率为 1mm,图像维数大小为 $256 \times 256 \times 256$,并经过 FreeSurfer 软件剥去头颅、修正偏差、灰度归一化等处理.标记图像中均有 45 个经专家标记的组织区域,但本文只研究脑部图像中 9 个感兴趣区域的分

割,即白质(White Matter, WM)、脑皮质(Cerebral cortex, CT)、侧脑室(Lateral Ventricle, LV)、海马体(Hippocampus, HP)、下丘脑(Thalamus, TH)、尾状核(Caudate, CA)、壳核(Putamen, PU)、苍白球(Pallidum, PA)和杏仁核(Amygdala, AM).

3.2 实验流程

本文实验流程如下,先将目标图像与训练图像分别配准得到多参数下的配准结果,再分别用灰度融合、标记融合算法得到目标图像的估计结果,最后用三组实验结合不同的标记融合算法得到最终精确的分割结果.第一组实验中,我们用 20 幅图谱图像分别与两种融合算法相结合;第二组实验中,我们只选取前 10 幅图谱图像分别与两种融合算法结合;第三组实验中,我们采用不同数量下的图谱图像(分别取 2, 5, 10, 20 幅)与两种融合算法中最优的方法结合.文中所有实验均采用留一交叉验证法进行,即分割每一幅目标图像时,剩余图像作为训练图像.

实验中主要采用 Mert R. Sabuncu 等人的微分同胚配准方法^[2] 进行配准,此方法中参数 γ 控制高斯牛顿优化法的步长,参数 σ_n 决定最终形变的平滑程度,也是配准过程最关键的因素.由参考文献^[5] 及实验可知,当 σ_n 为 2 时 ($N_{\sigma_n} = 1$),配准效果最好, N_{σ_n} 为配准方法的个数,其中我们采用互信息对配准结果进行评价.实验中我们改变参数 σ_n 的大小,将其它 σ_n 的配准作为不同参数下的配准方法,即将 σ_n 分别为 1、2、3、4、5 时的配准结果作为 5 种参数下的配准结果.我们选取最优值即 σ_n 为 2 时的分割结果作为对照,将 σ_n 分别为 1 至 5 时 ($N_{\sigma_n} = 5$) 的 5 种配准方法和 σ_n 分别为 1 至 10 时 ($N_{\sigma_n} = 10$) 的 10 种配准方法融合之后的分割结果与之对比.得到多参数下的配准图像后,分别用式(6)进行灰度融合、式(7)进行标记融合,再将此重构后的粗估计结果分别用不同的标记融合算法式(10)或式(13)进行目标图像的分割,得出精确的分割结果.图 3 为实验流程示

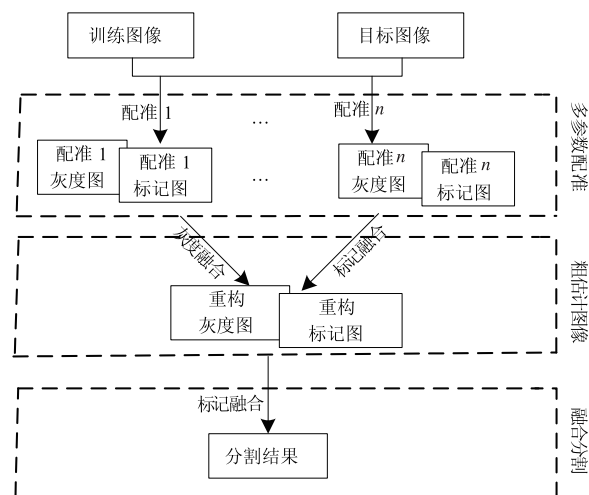


图3 基于多参数配准模型的实验流程示意图

意图.

3.3 实验结果

实验时先求出最优值 σ_n 为 2 时多数投票法、局部加权投票法的分割结果,再分别求出多参数配准模型与之结合后的分割结果. 经过反复测试,本文选取式(9)中的斜率常数 ρ 为 1,式(12)中 δ 为 6 作为最优参数. 图 4(a)、图 5(a)分别为前两组实验不同方法与多数投票法结合后 9 个 ROI (Regions Of Interest) 区域分割结果的平均 Dice Scores 值和 9 个 ROI 区域的 Dice Scores 值,图 4(b)、图 5(b)分别为前两组实验与局部加权投票法结合后 9 个 ROI 区域的分割结果. 其中

1registration 是配准 σ_n 为最优值 2 时(即 N_{σ_n} 为 1)的分割结果,其余两种方法均为经过多参数配准模型结合后的实验结果,5registration、10registration 分别是 N_{σ_n} 为 5 和 10 时融合后的分割结果. 图中空心与实心的盒形图分别代表第一组与第二组实验的结果.

表 1 与表 2 分别给出了前两组实验中不同方法结合多数投票法、局部加权投票法得到的平均 Dice Scores 值. 表 3 为第三组实验中最优参数配准和 5 种配准参数融合后与局部加权投票法结合的分割结果. 表中 N_{σ_n} 为配准方法的个数,Atlases 为训练图谱的个数. 表中黑色字体分别代表每组实验的最优结果.




图4 不同方法下20/10幅图谱图像的平均Dice Scores值(空心为20atlases,实心为10atlases)

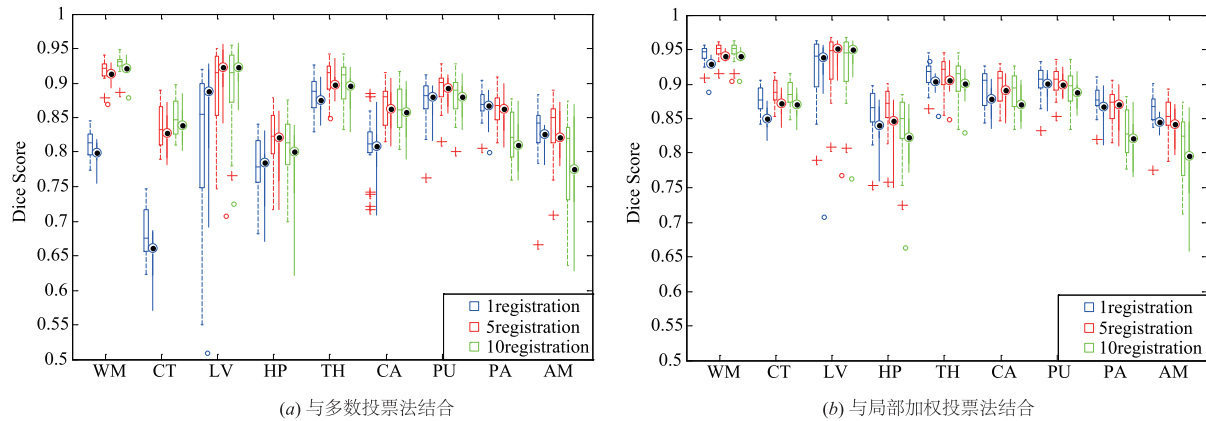


图5 不同方法下20/10幅图谱图像9个ROI区域(左脑)的分割结果(空心为20atlases,实心为10atlases)

表 1 不同方法下 20/10 幅图谱图像 9 个感兴趣区域(左脑)的平均 Dice Scores 值(多数投票法)

N_{σ_n}	Atlases	WM	CT	LV	HP	TH	CA	PU	PA	AM
1	10	0.794 0	0.648 1	0.832 9	0.766 0	0.782 7	0.797 8	0.870 1	0.857 7	0.817 7
	20	0.810 8	0.648 0	0.812 1	0.782 7	0.882 5	0.8076	0.874 1	0.869 4	0.828 4
5	10	0.909 8	0.825 9	0.898 8	0.802 6	0.895 9	0.859 5	0.887 9	0.852 8	0.823 2
	20	0.919 2	0.839 2	0.891 1	0.821 3	0.905 8	0.869 7	0.891 8	0.864 1	0.832 1
10	10	0.919 9	0.838 4	0.904 8	0.776 2	0.888 1	0.852 9	0.875 5	0.809 9	0.775 0
	20	0.928 3	0.851 1	0.899 8	0.801 8	0.899 6	0.864 0	0.880 3	0.823 8	0.786 0

表 2 不同方法下 20/10 幅图谱图像 9 个感兴趣区域(左脑)的平均 Dice Scores 值(局部加权投票法)

N_{σ_n}	Atlases	WM	CT	LV	HP	TH	CA	PU	PA	AM
1	10	0.926 7	0.849 4	0.913 7	0.836 5	0.901 4	0.873 0	0.896 7	0.861 3	0.843 8
	20	0.943 1	0.878 2	0.922 1	0.860 0	0.913 9	0.893 3	0.903 1	0.877 0	0.861 9
5	10	0.938 0	0.870 5	0.927 4	0.839 9	0.901 8	0.879 8	0.899 3	0.855 7	0.837 2
	20	0.949 2	0.889 6	0.931 1	0.863 8	0.915 0	0.898 7	0.904 5	0.867 8	0.851 9
10	10	0.938 3	0.868 3	0.927 3	0.809 3	0.893 8	0.871 6	0.886 1	0.815 6	0.789 6
	20	0.948 8	0.887 0	0.929 7	0.839 8	0.906 6	0.889 2	0.891 6	0.830 7	0.809 8

表 3 不同图谱数量下 1/5 种配准参数 9 个感兴趣区域(左脑)的平均 Dice Scores 值(局部加权投票法)

Atlases	N_{σ_n}	WM	CT	LV	HP	TH	CA	PU	PA	AM
2	1	0.663 3	0.530 5	0.890 5	0.706 5	0.836 1	0.759 4	0.759 1	0.752 5	0.723 3
	5	0.823 3	0.710 0	0.924 8	0.710 1	0.853 7	0.776 4	0.792 2	0.751 5	0.641 7
5	1	0.873 5	0.775 6	0.940 5	0.800 9	0.885 6	0.825 3	0.848 7	0.824 2	0.793 0
	5	0.915 8	0.833 0	0.939 6	0.816 5	0.889 3	0.865 0	0.878 1	0.830 3	0.800 5
10	1	0.926 7	0.849 4	0.913 7	0.836 5	0.901 4	0.873 0	0.896 7	0.861 3	0.843 8
	5	0.938 0	0.870 5	0.927 4	0.839 9	0.901 8	0.879 8	0.899 3	0.855 7	0.837 2
20	1	0.943 1	0.878 2	0.922 1	0.860 0	0.913 9	0.893 3	0.903 1	0.877 0	0.861 9
	5	0.949 2	0.889 6	0.931 1	0.863 8	0.915 0	0.898 7	0.904 5	0.867 8	0.851 9

3.4 实验方法比较

实验中本文采用了多种主流方法对相同的脑部图像进行分割,并同上文中的分割结果进行比较. FreeSurfer(FS)方法^[15]是直接采用 FreeSurfer 软件逐个自动分割目标图像的全部组织结构,此方法是唯一不需要预先将目标图像与训练图像进行配准处理的分割方法,其核心命令为“recon-all”. 联合标记融合法(Joint Label Fusion, JF)是 Wang Hongzhi 等人^[7,8]考虑到不同图谱可能产生相似的标记误差,进而采用加权投票策略结合图像块 patch 的方法对图谱之间的标记误差进行最小期望估计,最后用算法得出全部组织结构的分割结果. 图 6 为多种实验方法分割结果的对比图. FS, JF, LW 分别表示 FreeSurfer, 联合标记融合法, 局部加权投票法分割结果的 Dice Scores 值, 其中 20 幅训练图像均经过微分同胚配准处理. MRLW (Multi Registration Local Weighted Voting) 表示上文 5 种参数下的配准与局部加权投票策略结合后的分割结果.




图 6 以上方法分割结果的 Dice Scores 值对比图

3.5 实验结果分析

从图 4 可以看出,结合多数投票法的多配准实验不论是 5 种配准参数还是 10 种配准参数的融合,其分割结果均比未经过多参数配准时的分割结果高;而在结合局部加权投票法的实验中,5 种配准参数融合后的分割结果比未经过多参数配准的分割结果高,说明本文提出的基于多参数配准模型的分割方法能够有效的提升分割精度. 但是,从图 4(b) 及图 5 可以看出,10 种配准参数融合后的分割结果比其余两种方法要低,说明该方法并不是配准参数越多分割结果越好,效果较差的配准参数经融合后会降低整体的分割精度. 因此,选用多种高效的配准方法与高效的标记融合算法相结合,才能得出更精确的分割结果,其中互信息可以作为配准效果的衡量标准^[16]. 从以上各表可以看出,虽然有少数组织区域(如 PA、AM)通过单一配准的分割结果比多参数配准模型下的结果稍好,但其它组织标记区域的分割结果均符合本文的结论.

第三组实验结果也形象地说明了本文方法的有效性,同时更体现了该方法的适用性. 由表 3 纵向对比可以看出,利用 5 个参数配准融合后的分割结果与单一配准的实验结果相比,当图谱数量越少时,其精确度的提升幅度越大(如以表中 WM 区域为例,2,5 atlases 的精度分别由 0.6633 提升为 0.8233, 0.8735 提升为 0.9158;而 10,20 atlases 分别由 0.9267 提升为 0.9380, 0.9431 提升为 0.9492). 由于实际操作中获取较多的脑部图像样本需要耗费大量的人力、物力,因此样本越少、分割精度越高的方法越有利于医学研究. 本方法更适用于图谱数量较少时的图像组织分割,从而具有一定的实际意义.

从图 6 可以看出,经过 5 种参数的配准与局部加权投票法结合后的分割结果除少数区域(如 HP)外,其他区域均比现在主流的 FreeSurfer 方法和基于 patch 的联合标记融合法更好.因此,通过实验结果可以说明本文提出的多参数配准模型的分割思想是行之有效的.

4 结论

本文建立了一种新的概率图形模型框架并以此提出了基于多参数配准模型的分割方法,该方法将不同参数下的配准方法处理后的图像分别用不同算法进行灰度融合和标记融合,并将重构后的图像与高效的标记融合策略相结合,用于目标图像特定组织区域的分割.本方法对于图谱数量较少时仍能得出较为准确的分割结果具有重大意义.另外,此模型框架也可以适用于其他不同策略的配准方法.本文实验结果表明该方法能够有效提升脑部组织区域的分割精度.

参考文献

- [1] Shi Yong-gang, Zhang Xue-ping, Liu Zhi-wen. Automatic segmentation of hippocampal subfields based on multi-atlas image segmentation techniques[J]. *Journal of Electronics*, 2014, 31(2): 121 - 128.
- [2] 胡昊,张明慧,卢振泰,冯前进,陈武凡.基于多图谱配准的海马自动分割[J]. *计算机工程与设计*, 2014, 35(3): 975 - 980.
Hu Hao, Zhang Ming-hui, Lu Zhen-tai, Feng Qian-jin, Chen Wu-fan. Multi-atlas based auto-segmentation for hippocampus[J]. *Computer Engineering and Design*, 2014, 35(3): 975 - 980. (in Chinese)
- [3] 王爱民,沈兰荪.图像分割研究综述[J]. *测控技术*, 2000, 19(5): 1 - 16.
Wang Ai-min, Shen Lan-sun. Study surveys on image segmentation[J]. *Measurement & Control Technology*, 2000, 19(5): 1 - 16. (in Chinese)
- [4] Baillard C, Hellier P, Barillot C. Segmentation of brain 3D MR images using level sets and dense registration[J]. *Medical Image Analysis*, 2001, 5(3): 185 - 194.
- [5] Mert R. Sabuncu, BTT Yeo, Koen Van Leemput, Bruce Fischl, et al. A generative model for image segmentation based on label fusion[J]. *IEEE Transactions on Medical Imaging*, 2010, 29(10): 1717 - 1729.
- [6] 刘宏,王婕,宋恩民,等.基于加权相似度量的脑 MR 图像特定组织分割[J]. *计算机学报*, 2014, 37(6): 1241 - 1250.
Liu Hong, Wang Jie, Song En-min, et al. Segmentation of specific tissue in brain MR images based on weighted similarity measurement[J]. *Chinese Journal of Computers*, 2014, 37(6): 1214 - 1250. (in Chinese)
- [7] Wang Hong-zhi, JW Suh, SR Das, et al. Multi-atlas segmentation with joint label fusion[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(3): 611 - 623.
- [8] Wang Hong-zhi, Paul A. Yushkevich, et al. Multi-atlas segmentation with joint label fusion and corrective learning - an open source implementation[J]. *Neuroinformatics*, 2013, 7(27): 1 - 12.
- [9] Jia HJ, Yap PT, Shen DG. Iterative multi-atlas-based multi-image segmentation with tree-based registration[J]. *Neuroimage*, 2012, 59(1): 422 - 430.
- [10] Zhu Kai, Liu Gang, Zhao Long, Zhang Wan. Label fusion for segmentation via patch based on local weighted voting[J]. *Frontiers of Information Technology & Electronic Engineering*, 2017, 18(5): 680 - 688.
- [11] Zhang Wan, Liu Gang, Zhu Kai. Multi-atlas segmentation with novel LARS label fusion based on local weighted voting[A]. *International Symposium on Information Technology Convergence [C]*. Shanghai, China: ISITC, 2017.
- [12] 靳婧.医学图像配准与分割算法研究[D].成都:电子科技大学, 2014.
Jing Jin. Research of algorithm of medical image registration and segmentation[D]. Cheng Du: University of Electronic Science and Technology of China, 2014. (in Chinese)
- [13] KM Pohl, J Fisher, M Shenton, et al. Logarithm odds maps for shape representation[A]. *Proceedings of International Conference on Medical Image Computing and Computer Assisted Interventions 2006 [C]*. New York, USA: Springer, 2006. 955 - 963.
- [14] Lee R Dice. Measures of the amount of ecologic association between species[J]. *Ecology*, 1945, 26(3): 297 - 302.
- [15] B Fischl, DH Satlat, et al. Sequence-independent segmentation of magnetic resonance images[J]. *Neuroimage*, 2004, 23: 69 - 84.
- [16] 詹天明,张军,韦志辉,等.基于参数化互信息的脑 MR 图像分割与偏移场矫正模型及快速算法[J]. *电子学报*, 2011, 39(12): 2807 - 2812.
Zhan Tian-ming, Zhang Jun, Wei Zhi-hui, et al. Brain image segmentation and bias field correction model based on parametric mutual information and fast algorithm[J]. *Acta Electronica Sinica*, 2011, 39(12): 2807 - 2812. (in Chinese)

作者简介




张 万 男,1990 年 3 月出生于湖北省孝感市. 现为上海电力学院自动化工程学院硕士研究生. 主要研究方向为机器视觉与图像处理.
E-mail: zwsark@163. com



刘 刚(通信作者) 男,1977 年 2 月生于内蒙古包头市. 博士学位,现为上海电力学院教授、硕士研究生导师. 主要研究方向为模式识别和机器学习.
E-mail: lukelg@ gmail. com



朱 凯 男,1988 年 7 月生于河南省永城市. 现为国网浙江省电力公司金华供电公司员工,2016 年毕业于上海电力学院. 主要研究方向为机器学习与图像处理.
E-mail: zhukai0729@163. com



廖恒旭 男,1993 年 2 月出生于上海市. 现为上海电力学院自动化工程学院硕士研究生. 主要研究方向为深度学习与图像处理.
E-mail: liaohengxu@126. com