

基于特征分类的MRI医学图像弹性配准

李静^{1),2)} 杨烜^{2),3)} 喻建平^{2),3)}

¹⁾(西安电子科技大学电子工程学院, 西安 710071) ²⁾(深圳大学信息工程学院, 深圳 518060)

³⁾(深圳大学 ATR 国防科技重点实验室, 深圳 518060)

摘要 基于互信息的弹性图像配准是医学图像配准的重要方法之一。然而由于互信息在小样本图像配准中,会出现多局部极值和极值偏离问题,从而容易出现配准误差,进而造成整图的弹性配准误差。为减少这种配准误差,提出了一种基于特征分类的互信息医学图像弹性配准方法。该方法先采用图像的灰度和梯度特征训练自组织映射(self-organized mapping, SOM)神经网络特征分类器,将图像由高维灰度空间映射到低维特征类别空间;然后在特征类别空间进行互信息图像弹性配准。实验结果表明,该方法大大提高了小样本图像配准的成功率,并可通用于有噪和无噪的医学图像弹性配准中。

关键词 图像配准 弹性配准 互信息 特征分类 特征标识

中图分类号: TP9 **文献标识码**: A **文章编号**: 1006-8961(2007)06-1069-10

Medical MRI Image Registration Based on the Feature Space

LI Jing^{1),2)}, YANG Xuan^{2),3)}, YU Jian-ping^{2),3)}

¹⁾(School of Electronic Engineering, Xi'dian University, Xi'an 710071)

²⁾(College of Information Engineering, Shenzhen University, Shenzhen 518060)

³⁾(ATR National Key Laboratory of Defense Technology, Shenzhen University, Shenzhen 518060)

Abstract Mutual information registration based on pixel intensity has been widely used in recent years. However, its application to sub-images with small samples is questionable, because many local maximums may happen or the global maximum may be away from the actual maximum value which causes unnecessary registration error. A new approach, mutual information registration based on feature-label (MIF), is proposed to solve such problem. This method first uses image's intensity and gradient features to train the self-organized mapping(SOM) neural network, and then builds up the feature classifier for each modal image. Using such a classifier, images are project into a feature space with decreased dimensions. Finally mutual information is evaluated in the feature space to match images. Our results demonstrate that this method increases the success rate of the sub-image registration, and is optimal for the whole images(either with or without noise) elastic registration.

Keywords image registration, elastic registration, mutual information(MI), feature classify, feature label

1 引言

弹性图像配准是图像配准中一个重要的研究课题。基于互信息的多尺度弹性配准方法^[1-3]是目前广泛使用的一种自动弹性图像配准方法。该方法是先将图像分解成多个子图,然后在每个子图之间分

别进行刚性配准,最后采用各子图的原中心点和刚性配准后的中心点作为标记点来对待配准图像进行弹性扭曲变换。由于这种方法不用事先选取控制点或提取图像特征,因此适用于图像的自动配准。

然而,互信息(mutual information, MI)度量是一个基于统计特征的相似性度量。当图像分解成子图进行刚性配准时,由于样本点数量较少,统计量容易

基金项目:国家自然科学基金项目(60572101);广东省自然科学基金项目(31789)

收稿日期:2005-10-09; 改回日期:2006-01-09

第一作者简介:李静(1976 -),女。2006年获深圳大学硕士学位,现为西安电子科技大学博士研究生。研究领域为医学图像配准。

E-mail: lijingzy@163.com

发生偏差,从而导致互信息的最大值并不一定对应最佳配准参数;同时,互信息在随配准参数变化的过程中由于存在多局部极值问题,因此易使优化算法陷入局部最优。有许多研究者尝试解决这些问题,如 Butz 等人通过费农(Fanon)不等式,先将图像配准的误差下界和特征效率关联,定义了特征效率系数(feature efficiency coefficient),然后以最大化特征效率作为特征分类和图像配准的优化目标^[4,5],然而其寻优过程是一个高维寻优过程,其求解过程较难实现。Rohlfing 等人提出基于类别空间而不是灰度空间来计算互信息,并在类别标记的图像上进行最近邻插值^[6]。Rogelj 等人基于图像分割定义了一个局部相似性度量^[7];Agostino 等人通过对每个像素进行模糊类别标记来将多模图像的配准转化为单模图像的配准^[8]。这些方法大多依赖图像分割,而图像分割一般的假设前提是单一组织灰度服从高斯分布,由于实际医学图像中存在灰度不一致的现象,需预先对图像进行灰度不一致修正,因此限制了其应用范围。

事实上,在小样本图像配准中,由于样本数目少和灰度等级划分过多(高维灰度空间),使得灰度联

合直方图的分布过于分散,从而使聚类不明显。因此在特征保持的前提下减少灰度等级是改善互信息性能的一种有效途径^[9,10]。本文在特征保持的前提下,提出了一种对图像像素进行分类的方法,用以降低灰度的划分等级。该方法先选用图像的灰度和梯度特征作为训练样本,组建 SOM (self-organizing mapping)神经网络特征分类器,然后将图像由高维灰度空间映射到低维特征分类空间,从而降低了统计样本空间的维数,同时减少了信息的冗余度。配准时,先基于图像的特征类别联合分布来计算基于特征分类的互信息(mutual information registration based on feature-label, MIF);然后利用特征空间中的互信息度量来配准小样本子图,以自动确定标记点对;最后采用薄板样条插值算法(thin plate spline, TPS)来实现弹性图像配准。

2 基于互信息多尺度弹性配准方法

2.1 互信息

参考图像 R 和待配准图像 S 可视作两个离散的

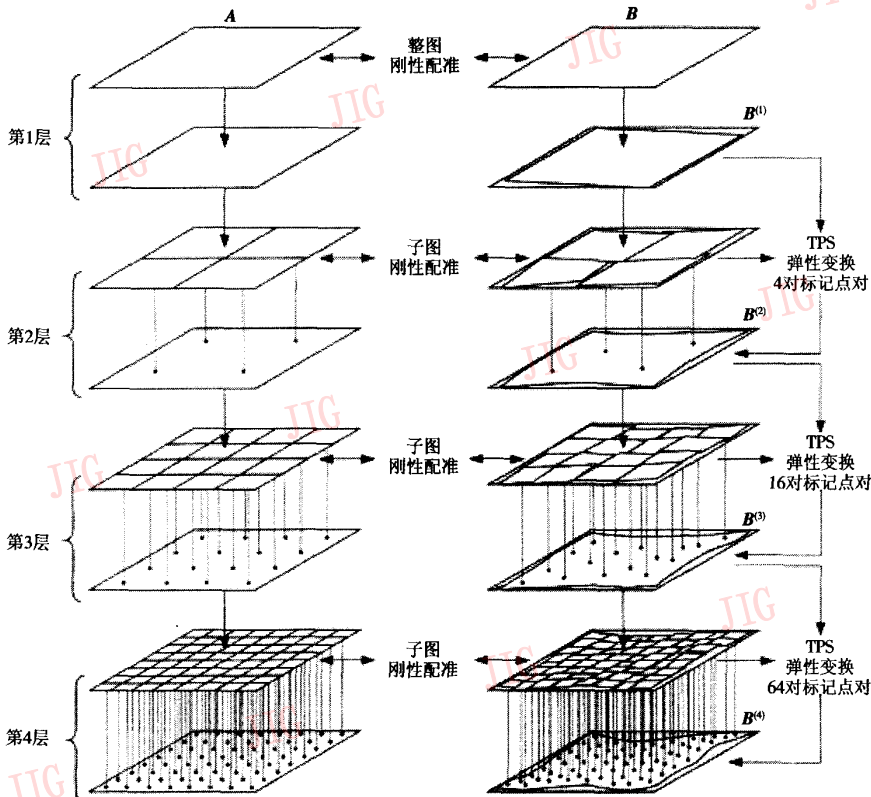


图 1 多尺度图像弹性配准^[2]

Fig. 1 Hierarchical approach of elastic registration

随机变量集合: $\mathbf{R} = \{r\}$ 和 $\mathbf{S} = \{s\}$, $r, s = 1, 2, \dots$ 分别为图像 \mathbf{R}, \mathbf{S} 像素的灰度值; 它们具有边缘分布及联合分布: $p_{\mathbf{R}}(r)$ 、 $p_{\mathbf{S}}(s)$ 及 $p_{\mathbf{R}, \mathbf{S}}(r, s)$ 。互信息 $MI(\mathbf{R}, \mathbf{S})$ 是图像 \mathbf{R} 与 \mathbf{S} 相似程度的一个统计度量^[11,12]:

$$\begin{aligned} MI(\mathbf{R}, \mathbf{S}) &= \sum_{r,s} p_{\mathbf{R}, \mathbf{S}}(r, s) \log \frac{p_{\mathbf{R}, \mathbf{S}}(r, s)}{p_{\mathbf{R}}(r)p_{\mathbf{S}}(s)} \\ &= H(\mathbf{R}) + H(\mathbf{S}) - H(\mathbf{R}, \mathbf{S}) \quad (1) \end{aligned}$$

其中, $H(\mathbf{R})$ 、 $H(\mathbf{S})$ 及 $H(\mathbf{R}, \mathbf{S})$ 分别是图像 \mathbf{R} 与 \mathbf{S} 的熵及联合熵。一般采用联合灰度直方图以及灰度直方图来近似联合分布和边缘分布, 以便进一步计算互信息。

2.2 多尺度弹性配准

多尺度图像弹性配准方法 (hierarchical image registration), 它首先通过对图像 \mathbf{A}, \mathbf{B} 进行全局的基于互信息的刚性配准来得到第 1 层的全局刚性配准结果 $\mathbf{B}^{(1)}$; 然后对图像 $\mathbf{A}, \mathbf{B}^{(1)}$ 进行第 2 层的基于灰度互信息的弹性配准。配准时, 首先将两图像分别等分为 4 个子图 $\mathbf{a}_k, \mathbf{b}_k^{(1)}$ ($k = 1, 2, \dots, 4$); 然后在各子图组中进行基于互信息的刚性配准得到第 1 层子图 $\hat{\mathbf{b}}_k^{(1)}$; 接着取子图 $\mathbf{b}_k^{(1)}$ 和 $\hat{\mathbf{b}}_k^{(1)}$ 的中心点对 $(\mathbf{c}_k^{(1)}, \hat{\mathbf{c}}_k^{(1)})$ 作为标记点对, 对图像 $\mathbf{B}^{(1)}$ 进行 TPS 变换, 得到第 2 层的弹性配准结果图 $\mathbf{B}^{(2)}$; 最后, 对图像 $\mathbf{A}, \mathbf{B}^{(2)}$ 再进行第 3 层的基于灰度互信息的弹性配准..., 其过程如图 1^[2] 所示。

在多尺度图像弹性配准中, 图像被逐级分成小样本子图。随着图像空间样本数目的减少, 噪声对联合灰度直方图统计能力的干扰作用就越大, 其表现为配准过程中的互信息函数出现多局部极值以及全局极值偏离现象。若样本空间越小和灰度级数越大, 则干扰作用就越明显; 当图像的样本空间大小是 64×64 或更小时, 使用基于灰度的图像配准方法已不能确保配准的正确性^[2]。为了保持互信息在小样本下的配准能力, 则需要降低计算互信息的灰度划分等级, 以便使联合直方图更集中, 下面介绍本文提出的像素特征分类方法。

3 特征分类

均匀等分减小灰度等级是一种简便方法, 虽然其在一定程度上也可以改善互信息的应用效果, 然而在真实的医学图像中, 由于组织类别并非只有单一灰度值, 而是具有一定范围的灰度值^[7], 所以应在特征保持的前提下, 依据不同组织特征进行组织

类别确定, 而非均匀分类。对于多模图像配准, 由于同一组织在不同的成像技术下, 尽管灰度值不完全相同, 但基本具有同向或反向的梯度矢量, 所以对多模图像的像素进行分类时, 应同时考虑它的灰度值和梯度特征。如果简单地采用组织类别数目作为特征分类的聚类数目, 则可能引入无法预计的误差, 本文采用自组织映射 (self-organizing mapping, SOM) 神经网络特征分类器, 依据输入的不同特征向量而选择性地调整神经元来自动聚类。

3.1 图像特征提取

提取图像特征时, 应同时考虑图像像素的灰度特征和与其相邻像素相关的梯度特征, 并选用图像的像素灰度和梯度特征值来提取图像特征。图像的灰度特征值可简单地以图像像素灰度值表示, 而梯度特征值则采用将 Plum 提出的梯度权函数 $g(\alpha)$ ^[13] 量化为 $1, 2, \dots, N$ 的整数值。具体而言, 就是先将图像与高斯内核的一阶微分通过卷积求得梯度矢量 $\nabla_x(\sigma)$ (x 为图像的像素, σ 为高斯内核函数的尺度参数, 实验中取 $\sigma = 0.5, N = 100$), 则梯度矢量的方向余弦为 $\alpha_x(\sigma) = \arccos \frac{\nabla_x(\sigma)}{|\nabla_x(\sigma)|}$ 。这样, 梯度特征函数就定义为

$$g_x(\alpha) = \left\lfloor \frac{\cos(2\alpha) + 1}{2} \times (N - 1) \right\rfloor + 1 \quad (2)$$

3.2 自组织映射神经网络分类器

Kohonen 认为, 神经网络中邻近的各个神经元可通过侧向交互作用彼此相互竞争, 自适应地发展成检测不同信号的特殊检测器^[14]。在竞争学习过程中, 神经元变化可依据不同输入模式 (刺激) 或者输入模式的类别而选择性地调整, 这样调整后的神经元 (即获胜神经元) 的位置彼此之间就成为有序的, 从而使得对于不同的输入特征, 可在网络上建立起有意义的坐标系^[14]。

分类时, 可采用图像 (图像大小 128×128 pixels) 中像素 x 的灰度 i_x 和梯度特征 $g_x(\alpha)$ 作为神经网络的训练样本 $\mathbf{V}_x = [i_x, g_x(\alpha)]$, 并且网络中每个神经元的突触权值向量和输入空间的维数相同, 即神经元 j 的突触权值向量为 $\mathbf{W}_j = [w_{j,1}, w_{j,2}]$ 。SOM 算法的步骤如下:

- (1) 初始化 对初始权值向量 $\mathbf{W}_j^{(0)}$ 选择随机值 ($m = 0$);
- (2) 取样 输入样本 $\mathbf{V}_x^{(m)}$;
- (3) 相似性匹配 寻找最匹配 (获胜) 的神

神经元 (最小 Euclid 距离准则): $j_x^{best} = \arg \min_j \|V_x^{(m)} - W_j^{(m)}\|$;

(4) 更新 对获胜神经元 j_x^{best} 以及其邻域内所有神经元的权值向量都依照 Kohonen 规则进行调整:

$$W_j^{(m+1)} = W_j^{(m)} + \eta^{(m)} h_{j_x^{best}}^{(m)} (V_x^{(m)} - W_j^{(m)}) \quad (3)$$

其中, $\eta^{(m)}$ 是学习率参数, $h_{j_x^{best}}^{(m)}$ 是获胜神经元的邻域函数;

(5) $m = m + 1$, 继续步骤 (2); 循环多次 (实验

中循环 25 次) 或在特征映射中观察不到明显的变化为止。

图 2 (a) 给出了图像 (模态为 M) 的神经网络特征分类器的一般构造步骤。训练时, 使用图 2 (b) 的灰度和梯度特征值作为输入样本 (图 2 (d)), 训练得到的网络分类器如图 2 (e) 所示。该特征分类器用于将图像由高维灰度空间 (图 2 (b)) 映射到低维类别空间 (图 2 (c))。

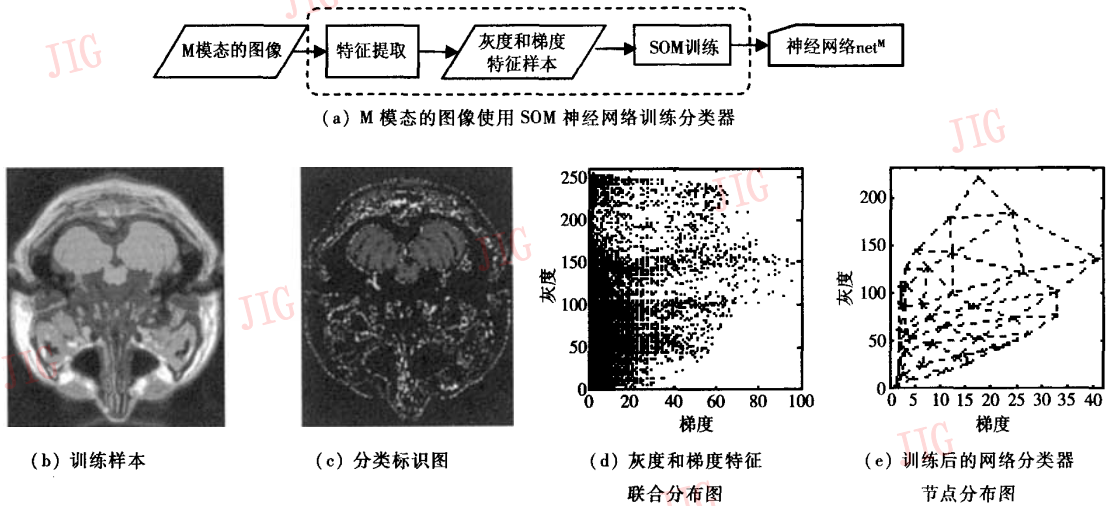


图 2 特征分类器示意

Fig. 2 Feature classifier

4 基于特征分类弹性图像配准方法

特征分类方法是通过提取参考图像 R 和待配准图像 S 的灰度和梯度特征值向量, 并将其分别输入到各自模态对应的特征分类器来将图像由高维灰度空间映射到低维特征类别空间, 进而得到对应的类别标识图: $R_C = \{r_c\}$ 和 $S_C = \{s_c\}$, 其中 r_c, s_c (下角 C 代表 class) 分别为对应图像像素的特征类别标识值。在特征空间中, 可根据特征类别标识图 R_C, S_C 的特征类别直方图以及它们的联合特征类别直方图来分别计算 $P_{R_C}(r_c), P_{S_C}(s_c)$ 及 $P_{R_C S_C}(r_c, s_c)$, 图像间相似程度可采用基于特征分类的互信息来度量。

定义 基于特征分类的互信息, 记为 $MIF(R_C, S_C)$:

$$MIF(R_C, S_C) = \sum_{r_c, s_c} P_{R_C S_C}(r_c, s_c) \log \frac{P_{R_C S_C}(r_c, s_c)}{P_{R_C}(r_c) P_{S_C}(s_c)} \quad (4)$$

具体的计算流程如图 3 所示。

基于特征分类互信息图像配准的过程也就是寻找最大化特征分类互信息映射 T^{best} 的优化过程, 即 $T^{best} = \arg \max_T MIF(R_C, \hat{S}_C)$, 其中, $T: S \rightarrow \hat{S}, \hat{S}_C$ 为 \hat{S} 的特征分类标识图。

基于特征分类互信息的多尺度弹性图像配准方法 (multi-scale mutual information based on feature, MMIF), 它的具体步骤如下:

(1) 先将图像 R 和 S 进行基于灰度互信息的整图刚性配准, 以得到配准后的图 $S^{(l)} (l=1)$;

(2) 然后进行第 $l+1$ 层基于特征分类互信息的弹性图像配准过程, 即分别将图像 R 和 $S^{(l)}$ 分成 K 块子图 $\Gamma_k, s_k^{(l)}, (k=1, 2, \dots, K, K=4^l)$, 再在各子图组中分别进行基于特征分类互信息的刚性配准来得到配准后的子图 $\hat{s}_k^{(l)}$:

① 提取输入子图 $\Gamma_k^c, s_k^{(l)}$ 的灰度和梯度特征, 并使用各自模态的分类器, 将子图映射到各自对应的特征分类标识图 $\Gamma_k^c, s_{k,l}^c$;

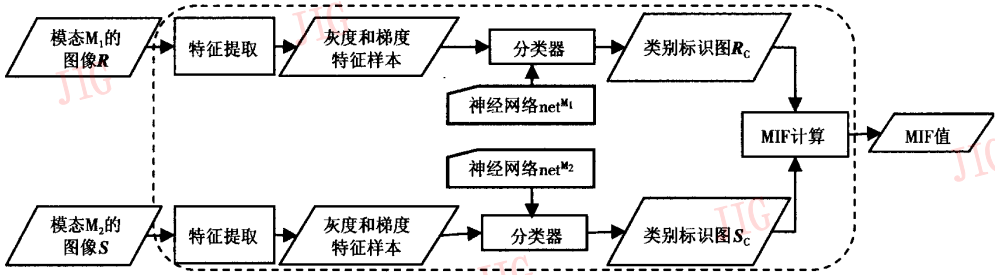


图 3 MIF 的计算流程图

Fig. 3 Compute flow of MIF

- ② 寻找 $T_{k,l}^{best}: T_{k,l}^{best} = \arg \max_{T_l^{(l)}} MIF(I_k^c, \hat{s}_{k,l}^c)$, 其中, $T_k^{(l)}: s_k^{(l)} \rightarrow \hat{s}_k^{(l)}, \hat{s}_{k,l}^c$ 为 $\hat{s}_l^{(l)}$ 的特征分类标识图;
- ③ 输出各子图 $s_k^{(l)}$ 和配准后子图 $\hat{s}_{k,l}^c$ 的中心点对 $(c_k^{(l)}, \hat{c}_k^{(l)})$;
- (3) 取以上 $(c_k^{(l)}, \hat{c}_k^{(l)})$ 为标记点对 (共 K 对), 采用薄板样条插值变换方法, 对图像 $S^{(l)}$ 进行弹性扭曲来得到配准结果图 $S^{(l+1)}, l = l + 1$;
- (4) 重复步骤(2), 直到子图的大小为 32×32 , 此时的 $S^{(l)}$ 即为最终的弹性配准结果图。

5 实验结果

为验证本文方法的配准效果, 使用仿真图库 Brainweb^[15] 中一组图像进行实验, 图像大小为 217×181 pixels。SOM 神经网络分类器组 I 系列为 $net_{b \times c}^{T1}, net_{b \times c}^{T2}$ 和 $net_{b \times c}^{PD}$, 该分类器先分别采用无噪声 (噪声 $n = 0\%$, 非均匀度为 0% , 序号为 20) 的模式分别为 T1、T2 和 PD 的图像各一幅进行训练, 神经网络分类器所使用的节点数分别为 $b \times c (b \in \{6, 8, 40, 12, 14\}, c \in \{8, 10, 12, 14\})$; 神经网络分类器组 II 为 net^{T1}, net^{T2} 和 net^{PD} , 该分类器分别采用有噪声 ($n = 3\%$), 非均匀度为 0% , 序号为 20 的模式分别为 T1、T2 和 PD 的图像各一幅进行训练, 使用的节点数为 6×8 。实验使用的计算机配置为 CPU AMD1. 1G, RAM 256M, 编程语言为 Matlab7. 0。分类器是采用 BrainWeb 图库中 217×181 大小的图像训练的神经网络分类器, 训练一组分类器时间约 1 200s。

5.1 不同节点数的神经网络分类器

在初步的灰度特征均匀等分的分类实验中, 当分类数目初始为 242 (灰度等级) 减为 48 级后, 就取得了较好的灰度互信息配准效果; 而再进一步减小

等级数时, 由于引入的分类误差增加, 致使配准效果下降。为了将本文提出基于特征分类互信息的图像配准方法与传统的基于灰度互信息的配准方法进行比较, 并且考察分类器节点数目对本文提出的方法的影响, 本文进行了图像配准的比较实验。实验分别采用基于灰度的图像配准方法 (image registration based on mutual information of intensity, 简记为 MII 方法), 以及使用具有不同节点数 ($b \times c$) 的神经网络分类器组 I 系列的基于特征空间的图像配准方法 (简记为 $MIF_{b \times c}$ 方法) 来进行图像配准。实验时, 图像先选用模式分别为 T1、T2 的 3 组图 (图像序号均为 1, 噪声含量分别为 0% 、 3% 和 5%); 然后对每组图进行下采样到 128×128 大小, 得到组图 $I_n (n = 0、3$ 和 5 , 分别对应不同噪声值 $n\%$)。在组图 I_n 中的各图先取大小分别为 $64 \times 64, 32 \times 32$ 的中心区域为组图 $II_n、III_n$; 接着, 以模式为 T1 的图像为参考图 R , 模式为 T2 的图像为待配准图 S 来进行水平平移图像配准 (原点为最佳配准位置)。图像配准过程中的互信息函数图 (以水平平移像素为横坐标, 互信息量为纵坐标) 见图 4 和图 5。

由图 4 可见, 在无噪声图组 $I_0、II_0$ 和 III_0 , 以及有噪声大样本图组 I_3 和 I_5 (下角数字为噪声含量, 下同) 的图像配准中, 基于灰度的图像配准 MII 方法和本文提出的 $MIF_{b \times c}$ 方法均很好地实现了配准, 然而在有噪声的小样本图组 $II_3、III_3、II_5$ 和 III_5 的实验中, MII 方法的互信息极值点则表现越来越不明显, 而且随着图像噪声含量的加大和图像样本空间的减小, 互信息还出现多极值和极值偏离现象。相反的, $MIF_{b \times c}$ 方法在有噪声的小样本图组 $II_3、III_3、II_5$ 和 III_5 的实验中, 随着分类器神经网络节点数 ($b \times c$) 的减少, 配准的效果却越理想。从图 5 中可明显地看出, 不仅在无噪声图像组的配准中, $MIF_{6 \times 8}$ 方法的

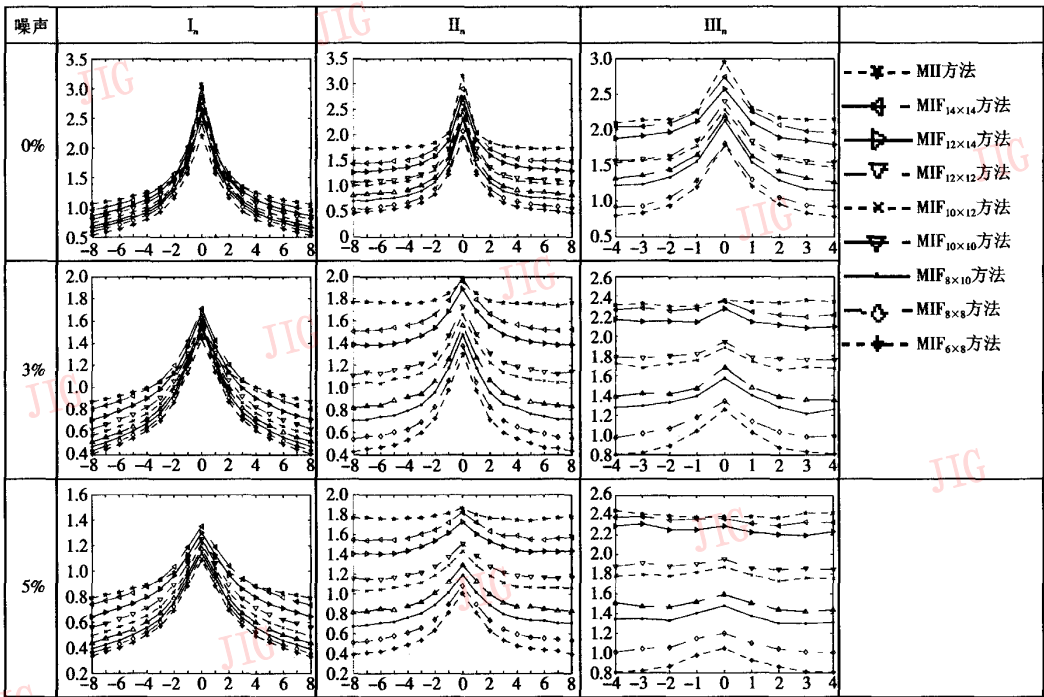


图 4 MII、MIF_{6×c}方法对不同大小图像配准的互信息函数比较

Fig. 4 Compares MI function of MII and MIF_{6×c} methods in image registration with different image size

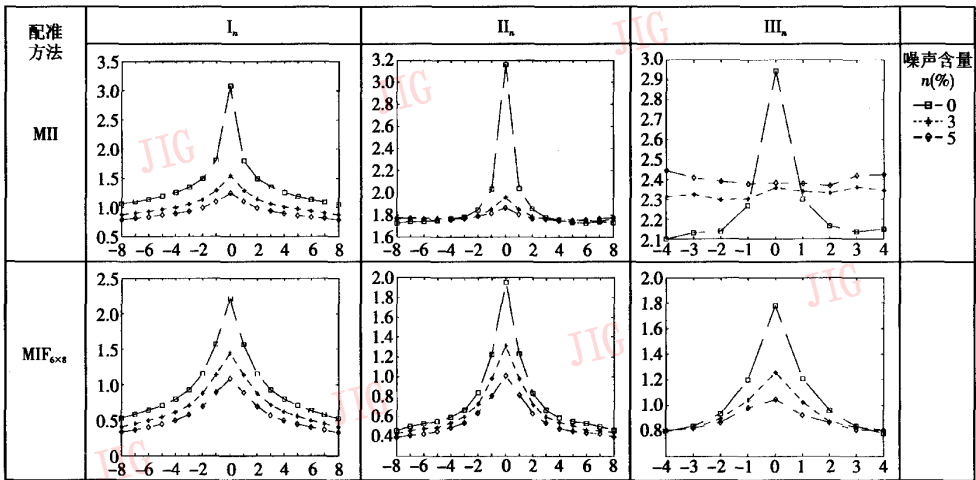


图 5 MII、MIF_{6×8}方法对不同大小图像配准的互信息函数比较

Fig. 5 Compares MI function of MII and MIF_{6×8} methods in image registration with different image size

表现与 MII 方法的效果近似,而且在含有不同程度的噪声的大样本和小样本的图组中,MIF_{6×8}方法均表现理想。

5.2 小样本 (32 × 32) 多模图像的配准

先在 Brainweb 图库中选取 T1、T2 和 PD 模态的图像,然后在各模态的图像中选用序号分别为 1、20、70、140 和 150 的图像序列,并在各序列图像中

选取 5 幅图像(图像的噪声含量 n 和非均匀度分别对应为 0% 和 0%、0% 和 20%、3% 和 0%、3% 和 20%、5% 和 0%),共得到各模态的图像各 25 幅。实验时,先将各图像分块成 32 × 32 大小的子图,用于进行多模态(T1-T2、T1-PD)小样本图像的配准实验。配准时,对每组子图(不含背景子图)分别在水平方向上通过[-8,8]区间内的平移来进行图像配

准,原点为最佳配准位置。本文进行了以下 3 种图像配准方法的对比实验:基于灰度空间的互信息图像配准 MII 方法及采用不同分类器组的本文提出的

基于特征分类互信息的图像配准方法:①MIF1 方法——采用分类器 I 系列($b = 6, c = 8$);②MIF2 方法——采用分类器 II 系列。实验结果见表 1。

表 1 小样本图组配准实验的配准成功率
Tab.1 Successful rate of small sample image registration

| 配准方法 | 配准成功率(%) | | | | | | | | |
|------|---------------|------|-------|---------------|-------|------|---------------|------|------|
| | 无噪声图组 $n = 0$ | | | 有噪声图组 $n = 3$ | | | 有噪声图组 $n = 5$ | | |
| | 边界子图 | 内部子图 | 总计 | 边界子图 | 内部子图 | 总计 | 边界子图 | 内部子图 | 总计 |
| MII | 100 | 100 | 100 | 12.5 | 52.18 | 47.4 | 0 | 29.2 | 25.7 |
| MIF1 | 95.3 | 100 | 99.4 | 53.1 | 100 | 94.5 | 46.9 | 98.3 | 92.3 |
| MIF2 | 90.6 | 100 | 98.75 | 67.2 | 100 | 96.1 | 46.9 | 97.5 | 91.5 |

注:实验中共使用 544 个子图,其中 64 个边界子图(背景占 50% 以上的子图), 480 个内部子图。

由表 1 可见,对无噪声的小样本图像组, MII 方法和 MIF1、MIF2 方法的配准效果均较理想;对含噪声 3%、5% 的小样本图像组, MII 方法不适用,其对应的配准成功率只有 47.3%、25.7%;而 MIF1 和 MIF2 方法则仍然配准效果理想,其对应的配准成功率分别为 94.5%、92.3% 和 96.1%、91.5%,远大于前者方法的成功率,而且对含噪 3% 的内部子图的配准成功率均为 100%。可见, MIF1 和 MIF2 方法对无噪声和有噪声小样本的图像配准均适用。同时, MIF1 方法采用的是无噪声图像训练的分类器, MIF2 方法采用的是有噪声图像训练的分类器,而两者的配准成功率相差不大。由此可见,在本文提出的配准方法中,神经网络分类器对训练样本的要求不高。

为了进一步比较 MIF1、MII 方法和基于梯度互信息的图像配准方法 (image registration based on mutual information of gravity, 记为 MIG 方法)^[13] 的

配准效果,本文还采用这 3 种方法分别进行了小样本图像平移、旋转配准实验。实验首先选取 T1、T2 和 PD 模态图各 8 幅(在 Brainweb 图库中的各模态图像中选用 1、20、70、140 序列的图像,并在每个序列中选用噪声分别为 0% 和 3%,且非均匀度均为 0% 的 2 幅图)。再将各图像分块成 32×32 大小的子图,用于多模态 (T1-T2、T1-PD) 小样本的图像配准实验。实验时,对每组内部子图(背景占 50% 以下)分别进行图像的刚性配准(水平、垂直方向和旋转变化范围均在 $[-3, 3]$ 区间,采用像素级精度配准及穷举法搜索),原点为最佳配准位置。由实验结果(表 2)可以看出,在无噪声图组的配准中, MIF1 方法和传统的 MII 方法配准的成功率均优于 MIG 方法;而在含噪声 3% 的图组配准中, MIF1 方法均明显优于另两种方法,而其中 MII 方法配准结果最差。在运算速度方面, MIF1 方法和 MIG 方法相当,均慢于 MII 方法。

表 2 不同配准方法的比较
Tab.2 Compares of different registration

| 配准方法 | I 无噪声图组 $n = 0$ (共 180 组) | | II 有噪声图组 $n = 3$ (共 180 组) | | 总成功率 (%) | 运算时间 (s/图组) |
|------|---------------------------|-----------|----------------------------|-----------|----------|-------------|
| | 配准成功图组数目 | 配准成功率 (%) | 配准成功图组数目 | 配准成功率 (%) | | |
| MII | 179 | 99.44 | 18 | 10 | 54.7 | 56.97 |
| MIF1 | 180 | 100 | 152 | 84.44 | 92.22 | 89.54 |
| MIG | 161 | 89.44 | 98 | 54.44 | 71.94 | 88.76 |

5.3 多模图像的多尺度图像配准

实验时,先将序号分别为 50、90,噪声含量 n 分

别为 0%、3% 和 5%,且模态分别为 T1、T2 的 6 组图像下采样到 128×128 大小;然后,在每组 T1-T2 图

组中,以 T1 模态的图像作为参考图 R ,而对 T2 模态的图像则分别进行全局和局部扭曲,从而获得待配准的图像 S_1^* 和 S_2^* (上角 w 代表 warp),即待配准的图像组 (R, S_1^*) 和 (R, S_2^*) 。这样共计 12 组图像(图 6 给出了其中 4 组图像示例)。在图像配准实验中,对每组图像分别采用基于灰度互信息的多尺度弹性配准方法(image registration based on multiresolution mutual information of intensity, 记为 MMII 方法)和本文提出的基于特征分类的多尺度弹性配准方法(记为 MMIF 方法),来进行多尺度的

图像弹性配准。由参考图与各配准结果的边缘比较图(见图 7 和图 8,图中的暗灰色表示参考图的边缘,亮白色表示待配准图或配准结果图的边缘)可见,本文提出的 MMIF 方法的配准结果图的边缘与参考图的内部边缘能较好重合,明显优于传统的 MMII 方法的配准结果,而且由参考图与配准结果图的互信息值表(表 3)可见,在无噪和含噪图像的配准结果中,本文提出的 MMIF 方法的互信息值均高于 MMII 方法的互信息值。本文提出的 MMIF 方法配准精度高于 MMII 方法。




图 6 配准参考图和待配准图(无噪)

Fig. 6 Reference image and source image(without noise)

表 3 参考图与配准结果图的互信息量列表

Tab. 3 Mutual information of reference image and the registration result image

| 序号 | 含噪比例(0%) | | | 含噪比例(3%) | | | 含噪比例(5%) | | | |
|----|----------|---------|----------|----------|---------|----------|----------|---------|----------|--------|
| | MMII 方法 | MMIF 方法 | Δ | MMII 方法 | MMIF 方法 | Δ | MMII 方法 | MMIF 方法 | Δ | |
| I | 50 | 1.7538 | 1.7653 | 0.0115 | 1.3259 | 1.5532 | 0.22737 | 1.2009 | 1.4065 | 0.2056 |
| | 90 | 1.6327 | 1.6676 | 0.0349 | 1.2513 | 1.4843 | 0.23291 | 1.187 | 1.3777 | 0.1907 |
| II | 50 | 1.5101 | 1.5291 | 0.0191 | 1.2494 | 1.3353 | 0.08586 | 1.0809 | 1.2444 | 0.1634 |
| | 90 | 1.4696 | 1.4767 | 0.0071 | 1.242 | 1.3095 | 0.06751 | 1.1739 | 1.2023 | 0.0284 |




图 7 MMII 和 MMIF 方法的配准效果的边缘图比较(图组序号为 50)

Fig. 7 Edge compares of MMII and MMIF registration(slice = 50)

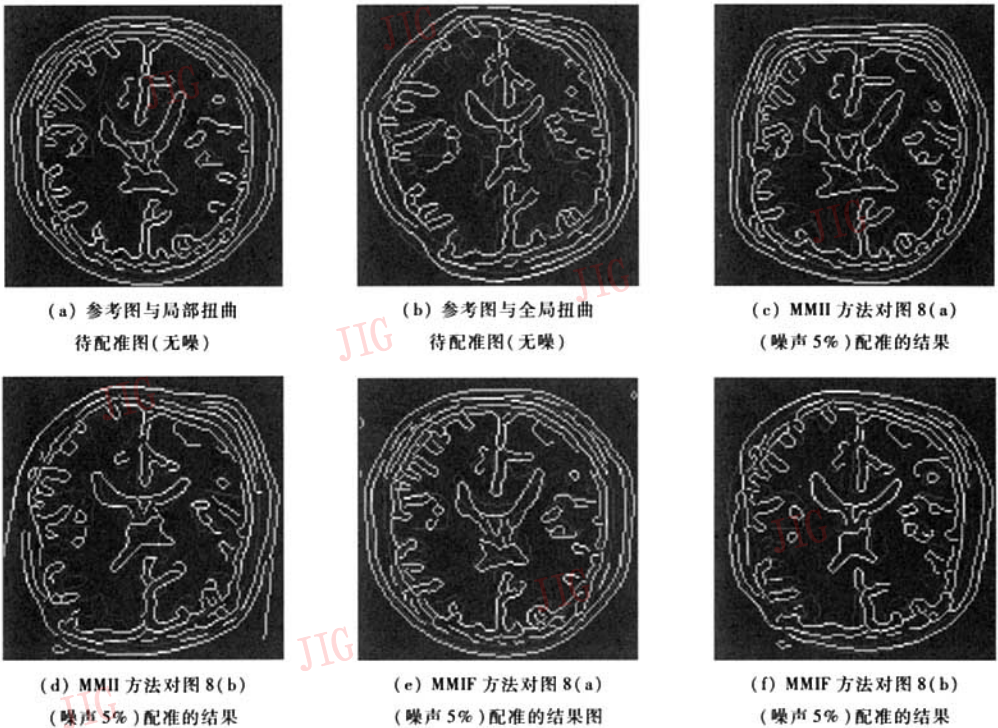


图 8 MMII 和 MMIF 方法的配准效果的边缘图比较(图组序号为 90)

Fig. 8 Edge compares of MMII and MMIF registration(slice = 90)

6 结 论

实验表明,基于灰度的互信息配准方法可以成功应用于图像刚性配准中,由于互信息在小尺度图像配准中存在多局部极值和极值偏离现象,因此,该方法在图像弹性配准中存在问题。本文提出一种基于特征分类的互信息图像配准方法,它的独特之处在于互信息的计算不再是基于配准图像的联合灰度分布空间,而是基于图像的联合特征类别分布空间。该方法先选用图像的灰度和梯度特征来训练 SOM 神经网络特征分类器,并通过特征分类器将图像由高维的灰度空间映射到低维的特征类别空间;然后在特征类别空间进行互信息图像配准,而且用于特征分类的神经网络分类器对训练样本的要求不高(训练样本有噪、无噪均可)。这样就可利用特征空间中的互信息来度量配准小样本子图,以自动确定标记点对;然后采用薄板样条 TPS 插值算法实现弹性图像配准。本文提出的方法不仅可以应用于无噪声图像,而且同样适用于有噪声图像的弹性配准。

参考文献 (References)

- 1 Kostelec P, Weaver J, Healy D. Multiresolution elastic image registration[J]. *Medical Physics*, 1998, 25(9): 1593 ~ 1604.
- 2 Likar B, Pernuš F. A hierarchical approach to elastic registration based on mutual information[J]. *Image and Vision Computing*, 2001, 19(1-2): 33 ~ 44.
- 3 Maintz J B A, Meijering E H W, Viergever M A. General multimodal elastic registration based on mutual information[A]. In: *Proceedings of SPIE on Medical Imaging and Image Processing*[C], San Diego, CA, USA, 1998, 3338: 144 ~ 154.
- 4 Butz T, Thiran J P. Feature-space mutual information for multi-modal signal processing with application to medical image registration[A]. In: *Processing of European Signal Conference 2002*[C], Toulouse, France, 2002, 1: 3 ~ 10.
- 5 Butz T, Thiran J P. From error probability to information theoretic (multi-modal) signal processing [J]. *Signal Processing*, 2005, 85(5): 875 ~ 902.
- 6 Rohlfing T, Brand R, Maurer C R Jr, et al. Bee brains, B-splines and computational democracy: generating an average shape atlas[A]. In: *Proceedings of the IEEE Workshop on Mathematical Methods in Biomedical Image Analysis*[C], Kauai, Hawaii, USA, 2001: 187 ~ 194.
- 7 Rogelj P, Kovacic S. Similarity measures for non-rigid registration [A]. In: *Proceedings of SPIE on Medical Imaging and Image Processing*[C], Bellingham, WA, USA, 2001, 4322: 569 ~ 578.
- 8 Agostino E D, Maes F, Vandermeulen D, et al. An information theoretic approach for non-rigid image registration using voxel class probabilities[J]. *Medical Image Analysis*, 2006, 10(3): 413 ~ 431.
- 9 Tsao J. Interpolation artifacts in multimodality image registration based on maximization of mutual information[J]. *IEEE Transactions on Medical Imaging*, 2003, 22(7): 854 ~ 864.
- 10 Ji Xiu-quan, Pan Hao, Liang Zhi-Pei. Further analysis of interpolation effects in mutual information-based image registration [J]. *IEEE Transactions on Medical Imaging*, 2003, 22(9): 1131 ~ 1140.
- 11 Viola P, Wells W M. Alignment by maximization of mutual information[J]. In: *Proceedings of IEEE Computer Society the Fifth International Conference on Computer Vision*[C], Los Alamitos, CA, USA, 1995: 16 ~ 23.
- 12 Collignon A, Maes F, Delaere D, et al. Automated multimodality image registration based on information theory[A]. In: *Proceedings of the Information Processing in Medical Imaging*[C], Dordrecht, Netherlands: Kluwer Academic Publishers, 1995: 263 ~ 274.
- 13 Pluim J P, Maintz J B A, Viergever M A. Image registration by maximization of combined mutual information and gradient information [J]. *IEEE Transactions on Medical Imaging*, 2000, 19(8): 809 ~ 814.
- 14 Kohonen T. The self-organizing map[J]. *Proceedings of the Institute of Electrical and Electronics Engineers*, 1990, 78(9): 1464 ~ 1480.
- 15 McConell 医学图像仿真图库 [DB/OL]. <http://www.bic.mcgill.ca/brainweb/>.