

基于非扩展熵相似度的三维医学图像配准

李碧草^{1,2,3} 李润川^{2,3} 刘洲峰¹ 李春雷¹ 王宗敏^{1,2,3}

¹(中原工学院电子信息学院 河南 郑州 450007)

²(郑州大学信息工程学院 河南 郑州 450001)

³(郑州大学互联网医疗与健康服务河南省协同创新中心 河南 郑州 450052)

摘要 针对互信息相似性测度中传统香农熵的扩展性,结合 Arimoto 非扩展熵的性质,构造一种新的相似性测度,提出基于该相似度的多模态三维医学图像配准算法。构造非扩展熵相似度,建立图像配准框架;利用基于 B 样条的帕曾窗估计联合概率分布,得到连续的目标函数;采用拟牛顿优化方法对配准模型进行求解。在三维临床医学图像的实验结果表明:与传统的基于互信息相似度的图像配准算法相比,该算法的配准精度较高。

关键词 Arimoto 熵 非扩展性 帕曾窗估计 拟牛顿法 多模态 图像配准

中图分类号 TP391

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2020.11.017

THREE-DIMENSIONAL MEDICAL IMAGE REGISTRATION BASED ON NONEXTENSIVE ENTROPIC SIMILARITY MEASURE

Li Bicao^{1,2,3} Li Runchuan^{2,3} Liu Zhoufeng¹ Li Chunlei¹ Wang Zongmin^{1,2,3}

¹(School of Electronic and Information Engineering, Zhongyuan University of Technology, Zhengzhou 450007, Henan, China)

²(School of Information Engineering, Zhengzhou University, Zhengzhou 450001, Henan, China)

³(Cooperative Innovation Center of Internet Healthcare, Zhengzhou University, Zhengzhou 450052, Henan, China)

Abstract For the expansibility of traditional Shannon entropy in the similarity measure based on mutual information, a novel similarity measure is proposed combining the Arimoto entropy, and an algorithm of multi-modal three-dimensional medical image registration based on the similarity is presented. An entropic measure with non-extension was constructed, and a framework of image registration was built; the B-splines Parzen window was employed to estimate the joint probability distribution between the images to be registered, and the continuous objective function was obtained; the registration model was optimized by the quasi-newton method. Experimental results on the 3D clinical medical images show that the proposed method provides higher registration accuracy compared with the traditional image registration methods based on mutual information similarity.

Keywords Arimoto entropy Non-extension Parzen window estimation Quasi-newton method Multi-modal Image registration

0 引言

在医学成像、计算机视觉、遥感成像领域,图像配准是一个非常重要的技术。配准算法在医学图像处理

研究中,如计算机辅助诊断和肿瘤放射治疗方面有着重要的作用。医学成像过程中,由于病人体位的变化及器官和组织的移动,不同时间采集的医学图像间往往存在空间变换,医生为了更好地掌握病灶的信息,往往需要从不同模态的图像(比如 MRI、CT 和 US 等医学

收稿日期:2019-08-13。国家自然科学基金项目(61772576,61872324);国家重点研发计划项目(2017YFB1401200);河南省科技攻关计划项目(192102210127);河南省高校科技创新团队支持计划项目(18IRTSTHN013);河南省博士后基金项目(19030018);河南省高校重点科研项目(17A510006,19B510011)。李碧草,讲师,主研领域:图像处理,模式识别。李润川,博士生。刘洲峰,教授。李春雷,副教授。王宗敏,教授。

图像)获取病灶的互补信息,从而更精确地诊断病情。为了给医生提供不同模态图像的互补信息,需要一种鲁棒的多模态配准算法对图像进行配准融合。

目前的图像配准方法通常可以分为基于特征和基于密度两大类^[1]。基于特征的配准算法包括特征提取和特征匹配,该类方法的配准精度很大程度上取决于特征点的提取。由于人体组织和器官及医学成像设备自身的特点,利用常见的特征提取方法提取特征点相对较难而且精度不高。本文研究基于密度的配准方法。在基于密度的配准方法中,基于互信息的配准算法^[2-3]自问世之后就备受关注。一些学者对基于互信息的配准算法进行改进,提出归一化的互信息配准算法^[4]、结合梯度信息的互信息配准算法^[5]、基于互累积熵相似度的配准算法^[6]等。这些算法中的相似性测度都是由香农熵构造的,然而 Antolin 等^[7]指出香农熵的扩展性使得基于香农熵的信息论相似性测度并未考虑两个独立随机变量间的相互作用。为此,学者引入一个具有非扩展性的 Tsallis 熵,利用其性质^[8]提出一种相似性测度,以此相似度作为配准标准进行医学图像配准。受文献^[7]的启发,本文利用 Arimoto 非扩展熵提出一种新的相似性测度,以此建立多模态医学图像配准模型,提高图像配准的精度。

1 非扩展熵相似性测度

与香农熵不同, Arimoto 熵是一种非扩展熵,也是香农熵的一种推广。本文利用 Arimoto 熵的性质,构造一种相似性测度。

1.1 Arimoto 熵

假设一个离散随机变量 X , 其概率分布为 $P = (p_1, p_2, \dots, p_M)$, 则 X 的 Arimoto 熵定义为^[9]:

$$A_\alpha(X) = \frac{\alpha}{\alpha - 1} \left[1 - \left(\sum_{i=1}^M p_i^\alpha \right)^{\frac{1}{\alpha}} \right] \quad \alpha > 0, \alpha \neq 1 \quad (1)$$

依据洛必达法则求得当 $\alpha \rightarrow 1$ 时, Arimoto 熵的极限就等于香农熵, 因此 Arimoto 熵是一种广义熵。Boekee 等^[10]研究了 Arimoto 熵的一些重要的性质, 下面仅讨论本文用到的其中几个性质:

(1) 非负性。

$$A_\alpha(X) \geq 0 \quad \alpha > 0, \alpha \neq 1 \quad (2)$$

(2) 非扩展性。另给一个离散随机变量 Y , 当 X 与 Y 相互独立时, 它们的联合 Arimoto 熵与边缘 Arimoto

熵存在如下关系:

$$A_\alpha(X, Y) = A_\alpha(X) + A_\alpha(Y) - \frac{\alpha - 1}{\alpha} A_\alpha(X) A_\alpha(Y) \quad (3)$$

可见, 除了两个变量边缘 Arimoto 熵的和之外, 联合 Arimoto 熵还包含一个乘积项, 该乘积项表示两个随机变量间的相互作用。

(3) 凸性。

$$A_\alpha(tX_1 + (1-t)X_2) \geq tA_\alpha(X_1) + (1-t)A_\alpha(X_2) \quad (4)$$

(4) 对称性。对称性是指互换概率分布中任意两个概率分量的位置, Arimoto 熵的值不会发生变化, 即:

$$A_\alpha(\dots, p_i, \dots, p_j, \dots) = A_\alpha(\dots, p_j, \dots, p_i, \dots) \quad (5)$$

此性质与香农熵的对称性一样, 根据 Arimoto 熵的定义很容易验证。

(5) 极值性。

$$A_\alpha(p_1, p_2, \dots, p_M) \leq A_\alpha\left(\frac{1}{M}, \frac{1}{M}, \dots, \frac{1}{M}\right) = \frac{\alpha}{\alpha - 1} \left[1 - M^{\frac{1-\alpha}{\alpha}} \right] \quad (6)$$

式(6)中等号成立的条件是: 当且仅当 $p_i = 1/M$, $i = 1, 2, \dots, M$ 。极值性也是一个很重要的性质, 根据极值性和非负性可以看到, 当 M 和 α 的值给定时, Arimoto 熵的值是有界的。

1.2 Jensen-Arimoto 散度

受文献^[11]的启发, 根据詹森香农散度的定义并结合 Arimoto 熵的性质, 提出了一个新的散度测量——詹森 Arimoto 散度 (Jensen-Arimoto Divergence, JAD)。与詹森香农散度一样, JAD 也可以用来量化随机变量之间的相似程度。

定义 1 假定 $X = (x_1, x_2, \dots, x_M)$ 是一个随机变量, 其概率分布为 $P = (p_1, p_2, \dots, p_M)$, 则概率分布 P 的 JAD 定义为^[12]:

$$JA_\alpha(p_1, p_2, \dots, p_M) = A_\alpha\left(\sum_{i=1}^M \omega_i p_i\right) - \sum_{i=1}^M \omega_i A_\alpha(p_i) \quad \alpha > 0, \alpha \neq 1 \quad (7)$$

式中: $A_\alpha(\cdot)$ 代表 Arimoto 熵; ω_i 表示加权因子, 而且 $\omega_i \geq 0$, $\sum \omega_i = 1$ 。由于当 α 趋向于 1 时 Arimoto 熵的极限是香农熵, 因此当 $\alpha \rightarrow 1$ 时 JAD 的极限为詹森香农散度 (Jensen-Shannon Divergence, JSD)。

定理 1 当 p_1, p_2, \dots, p_M 为退化分布时, JAD 能获得最大值 $A_\alpha(\omega)$, 这里 $p_i = \delta_{ij}$, δ_{ij} 表示克罗内克符号 (Kronecker Symbol), 即当 $i = j$ 时, $\delta_{ij} = 1$, 否则 $\delta_{ij} = 0$ 。

2 图像配准算法

在医学成像领域,模态是指不同类型的成像方式,如磁共振成像、CT 成像、超声成像等。多模态医学图像配准中,待配准的对象是不同模态的图像。首先建立配准模型,然后选择合适的空间变换,再利用上文介绍的相似度作为目标函数,最后采用拟牛顿法对目标函数进行优化,获得最终的变换参数,完成多模态医学图像的精确配准。

2.1 图像配准框架

给定两幅待配准图像,一幅记为参考图像 R ,另一幅为浮动图像 F 。图像配准可以看作寻找待配准图像间的空间变换的过程。设 $\mathbf{x} = (x, y, z)^T$ 为参考图像上的任意一个像素点,它经过空间变换后对应于浮动图像中的点 $\mathbf{x}' = (x', y', z')^T$,两点之间的关系表述为:

$$\mathbf{x}' = T_{\mu}(\mathbf{x}) \quad (8)$$

式中: $T_{\mu}(\cdot)$ 是空间变换函数; μ 为变换参数,这里的变换可以是刚体变换、仿射变换甚至是弹性形变。图 1 表示两幅图像对应坐标之间的空间变换关系,(a) 中圆点的坐标为 \mathbf{x} , (b) 中星号点的坐标为 \mathbf{x}' 。




图 1 图像坐标的空间变换关系

由此 F 与 R 的配准过程可以看成如下优化问题:

$$\begin{aligned} \mu^* &= \arg \max_{\mu} S(F \circ T_{\mu}, R(\mathbf{x})) = \\ & \arg \max_{\mu} S(F(T_{\mu}(\mathbf{x})), R(\mathbf{x})) \end{aligned} \quad (9)$$

式中: S 用来衡量两幅图像的相似性测度,当 $R(\mathbf{x})$ 和 $F(T_{\mu}(\mathbf{x}))$ 完全配准时,该相似度取得最大值,符号“ \circ ”代表空间变换 T_{μ} 作用于浮动图像。图像配准框架的示意图如图 2 所示。




图 2 图像配准框架示意图

2.2 空间变换模型

由于本文的实验对象是脑部图像,因此我们主要考虑刚体变换。刚体变换包含平移和旋转,对于三维图像来说,刚体变换有 6 个自由度: x, y, z 方向上的平移量与绕 x, y, z 轴的旋转角度。三维图像的刚体变换可用矩阵形式表示为:

$$\mathbf{X}' = \mathbf{R}\mathbf{X} + \mathbf{t} \quad (10)$$

式中: $\mathbf{X} = (x, y, z)^T$ 和 $\mathbf{X}' = (x', y', z')^T$ 分别代表变换前后图像中像素点的坐标; \mathbf{R} 是 3×3 的旋转矩阵; \mathbf{t} 为 3×1 的平移向量。旋转矩阵 \mathbf{R} 可以用三个矩阵的乘积来表示:

$$\mathbf{R} = \mathbf{r}^{(x)} \mathbf{r}^{(y)} \mathbf{r}^{(z)} \quad (11)$$

矩阵 $\mathbf{r}^{(x)}$ 、 $\mathbf{r}^{(y)}$ 和 $\mathbf{r}^{(z)}$ 可以用三个旋转角度表示:

$$\mathbf{r}^{(x)} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & \cos\alpha & -\sin\alpha \\ 0 & \sin\alpha & \cos\alpha \end{pmatrix} \quad (12)$$

$$\mathbf{r}^{(y)} = \begin{pmatrix} \cos\beta & 0 & \sin\beta \\ 0 & 1 & 0 \\ -\sin\beta & 0 & \cos\beta \end{pmatrix} \quad (13)$$

$$\mathbf{r}^{(z)} = \begin{pmatrix} \cos\gamma & -\sin\gamma & 0 \\ \sin\gamma & \cos\gamma & 0 \\ 0 & 0 & 1 \end{pmatrix} \quad (14)$$

式中: α, β, γ 分别代表图像绕 x, y, z 轴的旋转角度。由此三维刚体图像配准的目的就是通过某种优化方法寻找使得待配准图像间的相似度最大时的 6 个变换参数。

2.3 相似性测度

本文利用第 1 节中构造的基于 Arimoto 熵的相似度来衡量两幅图像间的相似程度,将两幅图像看作随机变量,那么用它们的灰度概率分布计算其相似度。给定参考图像 R 和浮动图像 F ,及它们之间的空间变换 T_{μ} ,假设用于估计概率分布的箱子数 (Number of bins) 为 M ,让 $f = (f_1, f_2, \dots, f_M)$ 和 $r = (r_1, r_2, \dots, r_M)$ 分别为 $F(T_{\mu}(\mathbf{x}))$ 和 $R(\mathbf{x})$ 的灰度级。式(7)中,令 JAD 定义中的 $p_i = p_i(F(T_{\mu}(\mathbf{x})) | R(\mathbf{x}))$, $i = 1, 2, \dots, M$,表示已知参考图像前提下变换的浮动图像的条件概率分布,使用两幅图像的灰度级可以将条件概率分布重新写为 $p_i = p(F = f_j | R = r_i) = p(f_j | r_i)$,然后再用参考图像的概率分布作为加权因子,即 $\omega_i = p(R(\mathbf{x})) = p(R = r_i) = p(r_i)$,将 p_i 和 ω_i 代入 JAD 可得:

$$JA_{\alpha}(F(T_{\mu}(\mathbf{x})), R(\mathbf{x})) =$$

$$\frac{\alpha}{1 - \alpha} \left\{ \left[\sum_{j=1}^M \left[\sum_{i=1}^M p(r_i) p(f_j | r_i) \right]^{\alpha} \right]^{\frac{1}{\alpha}} -$$

$$\sum_{i=1}^M p(r_i) \left[\sum_{j=1}^M p(f_j | r_i)^\alpha \right]^{\frac{1}{\alpha}} = \frac{\alpha}{1-\alpha} \left\{ \left[\sum_{j=1}^M p(f_j)^\alpha \right]^{\frac{1}{\alpha}} - \sum_{i=1}^M \left[\sum_{j=1}^M p(r_i, f_j)^\alpha \right]^{\frac{1}{\alpha}} \right\} \quad (15)$$

将式(15)中的 JA 测度替换 S 代入式(9)的配准框架,接下来的工作就变成如何求该配准框架最优解的问题。

2.4 优化方案

与梯度下降的优化方法相比,牛顿法中二阶信息的应用能够提供更好的理论收敛性质^[13],但是海森矩阵(Hessianmatrix)及其求逆的计算非常耗时,为此有学者提出拟牛顿法。该方法不需要计算海森矩阵的逆,而是用它的估计来代替,因此并不需要计算目标函数的二阶导数。本文采用拟牛顿法的一个变种——L-BFGS 优化方法^[14],来寻找目标函数的最大值。利用泰勒级数对目标函数进行展开,只保留前三项得到:

$$S(\mu + \Delta\mu) \approx S(\mu) + \Delta\mu^T \cdot \nabla S(\mu) + \frac{1}{2} \Delta\mu^T \cdot \nabla^2 S(\mu) \cdot \Delta\mu \quad (16)$$

式中: $\Delta\mu$ 表示参数向量的增量。对于 L-BFGS 方法,参数向量第 $k+1$ 步迭代更新可以由第 k 步得到:

$$\mu^{(k+1)} = \mu^{(k)} - (H^{(k)})^{-1} \cdot \nabla S(\mu^{(k)}) \quad (17)$$

式中: $(H^{(k)})^{-1}$ 代表每次迭代的步长,是海森矩阵逆的估计,并非真实计算的海森矩阵的逆; ∇ 表示梯度算子。接下来需要计算目标函数关于变换参数的导数:

$$\frac{\partial S}{\partial \mu} = \left[\frac{\partial S}{\partial \mu_1}, \frac{\partial S}{\partial \mu_2}, \dots, \frac{\partial S}{\partial \mu_n} \right] \quad (18)$$

式中: n 表示空间变换模型中参数(自由度)的个数。对于三维图像的仿射变换, $n=12$ 。

要计算目标函数关于参数 μ 的导数,首先要推导出连续的目标函数表达式,本文将采用基于 B 样条的 Parzen 窗来估计图像的概率密度函数。设 $\beta^{(0)}$ 和 $\beta^{(3)}$ 分别代表零阶和三阶 B 样条函数,由于参考图像在配准过程中并不受变换参数 μ 的影响,因此采用零阶 B 样条函数来估计参考图像的概率分布。对于空间变换后的浮动图像,三阶 B 样条函数用于估计其概率密度函数。那么根据多维 B 样条函数的可分离性, $R(\mathbf{x})$ 和 $F(T_\mu(\mathbf{x}))$ 的联合概率密度函数可由它们各自的边缘概率密度函数相乘得到:

$$\tilde{p}(r_i, f_j; \mu) = \frac{1}{V} \sum_{x \in \Omega} \beta^{(0)} \left(r_i - \frac{R(\mathbf{x}) - R^0}{\Delta b_R} \right) \times \beta^{(3)} \left(f_j - \frac{F(T_\mu(\mathbf{x})) - F^0}{\Delta b_F} \right) \quad (19)$$

通过计算得到相似性测度 S 关于变换参数 μ 的导数如下:

$$\frac{\partial S(F(T_\mu(\mathbf{x})), R(\mathbf{x}))}{\partial \mu} = \frac{\alpha}{1-\alpha} \sum_i \sum_j \left[\left(\sum_j \tilde{p}(f_j)^\alpha \right)^{\frac{1}{\alpha}-1} \tilde{p}(f_j)^{\alpha-1} - \left(\sum_j \tilde{p}(f_j | r_i)^\alpha \right)^{\frac{1}{\alpha}-1} \tilde{p}(f_j | r_i)^{\alpha-1} \right] - \frac{\partial \tilde{p}(r_i, f_j)}{\partial \mu} \quad (20)$$

式中: $\tilde{p}(f_j)$ 和 $\tilde{p}(f_j | r_i)$ 分别为得到的边缘概率和条件概率; $\partial \tilde{p}(r_i, f_j) / \partial \mu$ 表示联合概率关于参数 μ 的导数。式(20)中描述的联合概率密度函数关于参数 μ 的导数为:


$$\frac{\partial \tilde{p}(r_i, f_j)}{\partial \mu} = - \frac{1}{V \cdot \Delta b_F} \sum_{x \in \Omega} \beta^{(0)} \left(r_i - \frac{R(\mathbf{x}) - R^0}{\Delta b_R} \right) \cdot \beta^{(3)} \left(f_j - \frac{F(T_\mu(\mathbf{x})) - F^0}{\Delta b_F} \right) \cdot \left(\frac{\partial F(t)}{\partial t} \Big|_{t=T_\mu(\mathbf{x})} \right) \cdot \frac{\partial (T_\mu(\mathbf{x}))}{\partial \mu} \quad (21)$$

式中: $\beta^{(3)}$ 表示三阶 B 样条函数的导数; $\partial F(t) / \partial t$ 代表变换的浮动图像 $F(T_\mu(\mathbf{x}))$ 的梯度; $\partial (T_\mu(\mathbf{x})) / \partial \mu$ 为空间变换模型关于参数 μ 的导数。


本文的配准实验中,采用的 L-BFGS 优化算法的停止条件为:相邻两步迭代的目标函数值之差小于 0.01 或者迭代次数大于预先设定的值,本文设定该值为 100。

3 实验结果与分析


为了验证本文算法的性能,我们选择不同模态的三维头部磁共振图像进行实验。这些测试图像来源于蒙特利尔神经医学部的 BrainWeb 数据库^[15],包含三种不同类别的磁共振图像:T1 加权、T2 加权和 PD 加权的 MRI。三组数据的尺寸都为 $181 \times 217 \times 181$,在物理坐标下每个体素的大小为 $1 \text{ mm} \times 1 \text{ mm} \times 1 \text{ mm}$ 。而且这三组图像的所有层都是相互对应的。图 3 显示了三个 MRI 图像的三个正交层。



(a) T1 加权 MR



(b) T2 加权 MR




(c) PD 加权 MR, 每一行分别表示轴向面、矢状面和冠状面

图 3 脑部磁共振图像

接下来的实验采用图 3 中的 (a)、(b) 和 (c) 作为实验图像来执行配准算法。使用本文算法进行图像配准时,需要考虑两个主要因素:参数 α 对 Arimoto 熵的影响和计算熵时所选取的图像块尺寸。

为了验证所提算法的性能,三种 MR 图像组成三对测试图像:MR T1&MR T2、MR T1&MR PD 及 MR PD&MR T2,将每组测试数据中的前者作为参考图像,然后利用已知的 3D 刚体变换(真实值)对后者执行变换,把变换后的图像作为浮动图像,如图 4 所示。



(a) MR T1 图像作为参考图像 (b) MR T2 图像 (c) 3D 刚体变换后的 MR T2 图像作为浮动图像

图 4 测试图像

在每组测试图像中,选择 30 个 3D 刚体变换对后者图像进行变换生成 30 幅浮动图像,这些变换的平移及旋转参数随机产生,并服从以 (10 mm, 8°) 为均值, (2 mm, 2°) 为标准差的正态分布。由于三组测试图像最初是对齐的,所以这 30 个刚体变换的参数即为配准的真实值。为了能定量地评估配准方法的精度,我们将利用配准方法得到的参数值与真实值的差异作为配准误差,然后比较所提算法 (JAD) 与另外两种方法 NMI 和 CCRE 的配准误差。

表 1 展示了这三种方法应用到三组实验数据的配准误差。可以看出,在处理多模态图像配准时,与另外两种方法相比本文方法获得了较低的配准误差。三组实验的配准精度都达到了亚像素级,而基于 CCRE 相似度的算法配准效果相对较差,特别在配准 T2 加权 MR 与 PD 加权 MR 时,误差超过了一个像素。收敛范围也是衡量一个相似度优劣的重要指标,也就是说,当待配准图像之间存在不同大小的变换时,尤其是当图像间的误匹配很大时,一个鲁棒的配准算法也能够获得最优变换。为了测试 JAD 相似度的收敛范围,使用三维的 MR T1 和 MR PD 作为测试图像,并执行五组实验,每一组中采用 30 个 3D 刚体变换生成 30 幅浮动图像。

表 1 执行 30 次 3D 刚体配准实验的误差均值 \pm 标准差

数据集	算法	$\theta_x / (^\circ)$	$\theta_y / (^\circ)$	$\theta_z / (^\circ)$	t_x / mm	t_y / mm	t_z / mm
MR T1 & MR T2	JAD($\alpha = 1.25$)	0.13 \pm 0.01	0.03 \pm 0.02	0.07 \pm 0.02	0.03 \pm 0.01	0.11 \pm 0.01	0.03 \pm 0.01
	JAD($\alpha = 1.50$)	0.12 \pm 0.01	0.03 \pm 0.02	0.07 \pm 0.02	0.03 \pm 0.01	0.12 \pm 0.01	0.02 \pm 0.01
	NMI	0.14 \pm 0.01	0.04 \pm 0.02	0.08 \pm 0.02	0.04 \pm 0.01	0.09 \pm 0.01	0.07 \pm 0.01
	CCRE	0.19 \pm 0.03	0.19 \pm 0.05	0.29 \pm 0.06	0.07 \pm 0.02	0.08 \pm 0.02	0.03 \pm 0.02
MR T1 & MRPD	JAD($\alpha = 1.25$)	0.13 \pm 0.03	0.06 \pm 0.03	0.01 \pm 0.01	0.03 \pm 0.01	0.03 \pm 0.01	0.25 \pm 0.01
	JAD($\alpha = 1.50$)	0.12 \pm 0.03	0.06 \pm 0.03	0.01 \pm 0.01	0.03 \pm 0.01	0.06 \pm 0.01	0.21 \pm 0.01
	NMI	0.18 \pm 0.04	0.05 \pm 0.03	0.01 \pm 0.01	0.04 \pm 0.01	0.01 \pm 0.01	0.33 \pm 0.02
	CCRE	0.45 \pm 0.09	0.43 \pm 0.12	0.60 \pm 0.19	0.22 \pm 0.07	0.19 \pm 0.03	0.51 \pm 0.05
MR T2 & MRPD	JAD($\alpha = 1.25$)	0.02 \pm 0.01	0.03 \pm 0.01	0.04 \pm 0.01	0.02 \pm 0.01	0.09 \pm 0.00	0.10 \pm 0.00
	JAD($\alpha = 1.50$)	0.02 \pm 0.01	0.03 \pm 0.01	0.04 \pm 0.01	0.02 \pm 0.01	0.09 \pm 0.00	0.10 \pm 0.00
	NMI	0.01 \pm 0.01	0.04 \pm 0.01	0.05 \pm 0.01	0.02 \pm 0.01	0.09 \pm 0.00	0.10 \pm 0.01
	CCRE	0.43 \pm 0.13	0.59 \pm 0.18	1.05 \pm 0.31	0.15 \pm 0.07	0.24 \pm 0.05	0.05 \pm 0.04

五组实验中采用的刚体变换参数分别来自五个不同大小的区间: $[-10, 10]$, $[-20, 20]$, $[-30, 30]$, $[-40, 40]$ 和 $[-50, 50]$, 单位是 mm 或度数。为定量分析配准结果,引入成功率的概念,算法的成功率定义为在所有的实验中成功次数所占的比例,所谓的“成功”代表优化算法在 100 次迭代中能够收敛于最优解。

图 5 描述了利用三种方法执行五组配准实验的成功率。可以看出,当初始变换较小时,三种方法都能获得很高的成功率,而随着变换的增大,CCRE 方法的配准成功率下降很明显,JAD 和 NMI 相似度的成功率也有所降低,但 JAD 能够提供比 NMI 稍高的成功率。综上所述,JAD 拥有较大的收敛范围,并且当图像间存在

较大变换时,可以得到更多的配准次数。




图5 不同大小变换下三种配准方法的成功率比较

4 结 语

针对传统基于互信息相似度的图像配准方法,本文提出一种基于非扩展熵相似度的多模态医学图像配准算法。首先,研究 Arimoto 非扩展熵的性质,利用 Arimoto 熵构造相似性测度,用其衡量两幅图像间的相似度;其次,结合空间变换模型建立图像配准框架;然后,利用基于 B 样条的帕曾窗方法估计待配准图像间的联合概率分布,得到连续的目标函数;最后,采用拟牛顿优化方法对配准模型进行求解,得到待配准图像间最优的空间变换参数,实现多模态医学图像的精确配准。三维脑部磁共振图像配准实验结果表明,与归一化互信息算法和基于互累积熵的配准方法相比,本文算法能够获得更高的配准精度。未来研究将考虑三维弹性配准,并进一步提高配准精度。

参 考 文 献

[1] Maintz J B A, Viergever M A. A survey of medical image registration-under review[J]. Medical Image Analysis, 1998, 2(1):1-36.

[2] Chen S H, Li X R, Zhao L Y, et al. Medium-low resolution multisource remote sensing image registration based on SIFT and robust regional mutual information [J]. International Journal of Remote Sensing, 2018, 39(10):3215-3242.

[3] Shen L, Huang X T, Fan C Y, et al. Enhanced mutual information-based medical image registration using a hybrid optimisation technique[J]. Electronics Letters, 2018, 54(15): 926-928.

[4] Pilankar M, Ghosh S, Deshpande R. Image registration using particle filter with combined normalized mutual information and correlation coefficient [C]//2018 4th International

Conference on Computing Communication Control and Automation(ICCUBEA). IEEE, 2018:1-6.

- [5] Rao F, Li W L, Zhang X M, et al. Non-rigid registration of multi-modality medical image using combined gradient information and mutual information[J]. Journal of Medical Imaging and Health Informatics, 2018, 8(7):1374-1383.
- [6] Wang F, Vemuri B C. Non-rigid multi-modal image registration using cross-cumulative residual entropy[J]. International Journal of Computer Vision, 2007, 74(2): 201-215.
- [7] Antolin J, Lopez-Rosa S, Angulo J C, et al. Jensen-Tsallis divergence and atomic dissimilarity for position and momentum space electron densities[J]. The Journal of Chemical Physics, 2010, 132(4):044105.
- [8] Khader M, Hamza A B. An information-theoretic method for multimodality medical image registration[J]. Expert Systems with Applications, 2012, 39(5):5548-5556.
- [9] Arimoto S. Information-theoretical considerations on estimation problems[J]. Information and Control, 1971, 19(3): 181-194.
- [10] Boekee D E, Lubbe J C A V D. The R-norm information measure[J]. Information and Control, 1980, 45(2):136-155.
- [11] Lin J. Divergence measures based on the Shannon entropy [J]. IEEE Transactions on Information Theory, 1991, 37(1): 145-151.
- [12] Li B C, Shu H Z, Liu Z F, et al. Nonrigid medical image registration using an information theoretic measure based on arimoto entropy with gradient distributions [J]. Entropy, 2019, 21(2):189.
- [13] Klein S, Staring M, Pluim J P W. Evaluation of optimization methods for nonrigid medical image registration using mutual information and B-splines[J]. IEEE transactions on image processing, 2007, 16(12):2879-2890.
- [14] Boggs P T, Byrd R H. Adaptive, limited-memory BFGS algorithms for unconstrained optimization [J]. SIAM Journal on Optimization, 2019, 29(2):1282-1299.
- [15] BrainWeb; Simulated brain database[DB/OL]. [2019-08-13]. <http://brainweb.bic.mni.mcgill.ca/brainweb/>.

(上接第 94 页)

- [12] Everingham M, Eslami S M A, Gool L V, et al. The pascal visual object classes challenge: A retrospective[J]. International Journal of Computer Vision, 2015, 111(1):98-136.
- [13] Deng J, Dong W, Socher R, et al. ImageNet: A large-scale hierarchical image database [C]//2009 IEEE Conference on Computer Vision and Pattern Recognition, 2009.