

基于稀疏编码与方向-尺度描述子的海马体自动分割

刘颖¹ 张明慧¹ 阳维¹ 卢振泰¹ 冯前进¹ 苏榆生²

(南方医科大学医学图像处理重点实验室 广州 510515)¹

(佛山市三水区人民医院医学影像科 佛山 528100)²

摘要 海马体病变与神经疾病息息相关,海马体解剖结构的不规则性以及其与周围组织结构如杏仁体边界模糊增加了分割海马体的难度。提出一种新的基于稀疏编码和方向-尺度描述子(Sparse Coding and Orientation-Scale Descriptor, SCOSD)的算法来提高海马体分割精度。不同于主流的基于字典学习的方法,SCOSD算法用同时包含灰度纹理信息和空间结构信息的方向-尺度描述子(Orientation-Scale Descriptor, OSD)代替低维特征来描述像素特征,OSD的优点是它同时包含多种低维特征且能降低图谱间灰度不均匀性的影响。SCOSD算法包括4个步骤:1)图像预处理。2)特征提取,提取待分割图像像素和图谱图像像素的方向-尺度描述子。3)字典构建及稀疏编码,选取图谱像素的方向-尺度描述子作为目标像素来构建特有字典,用特有字典近似表达即重建目标像素并得到稀疏编码系数。4)标号融合及阈值判定,融合图谱像素的标号和编码系数得到目标像素的标号估计值;阈值判定估计值完成分割。为了验证SCOSD算法分割的准确性,分别用SCOSD算法,Simple, Major Voting, Staple, Collate分割MICCAI数据库内的海马体,以Dice值作为分割评判标准,实验结果表明,SCOSD方向-尺度描述子的分割精度高于Simple, Major Voting, Staple, Collate算法。

关键词 海马体分割,方向-尺度描述子,稀疏编码,标号融合,字典

中图分类号 TP391 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2017.01.058

Hippocampus Segmentation Based on Spare Coding and Orientation-Scale Descriptor

LIU Ying¹ ZHANG Ming-hui¹ YANG Wei¹ LU Zhen-tai¹ FENG Qian-jin¹ SU Yu-sheng²

(Laboratory of Medical Imaging Processing of Southern Medical University, Guangzhou 510515, China)¹

(Medical Imaging Department of Sanshui Hospital, Foshan 528100, China)²

Abstract As hippocampus is associated with neurodegenerative diseases, a lot of researchers have proposed many methods to segment hippocampus, but the irregularity and the boundary vaguely make the high precise of hippocampus segmentation more difficulty. We proposed a novel algorithm called SCOSD to increase the accuracy of hippocampus segmentation. Motivated by abundant existing dictionary-based methods, SCOSD uses orientation-scale descriptor(OSD) to describe the pixel feature. The OSD contains not only intensity information, such as texture and gradient information, but also the geometrical information. The advantage of OSD is that it reduces the inhomogeneity among different images while containing several low-dimension features. SCOSD method has four steps. Firstly, the orientation-scale descriptors are extracted and dictionaries for each target voxel are constructed. Secondly, corresponding dictionary is used to represent the orientation-scale descriptor of the target voxel approximately and the sparse coefficients can be obtained simultaneous. Thirdly, the label and coefficients of the dictionary are fused to make voxels. Finally, threshold the fusion value to get the finally label. Experiments based on competition data of medical image computing and computer assisted intervention(MICCAI) demonstrate that SCOSD has higher segmentation precise than other algorithms such as Simple, Major Voting, Staple, Collate.

Keywords Hippocampus segmentation, Orientation-Scale descriptor, Spare coding, Hippocampus label fusim, Dictionary

1 引言

海马体是大脑边缘系统的一部分,负责记忆及空间定位。日常生活中的短期记忆都储存在海马体中,如果一个记忆片段在短时间内被重复提及,那么海马体会将其转入大脑皮层,

成为永久记忆。海马体病变与记忆障碍疾病息息相关,如老年人常见的阿尔海默病就是由海马体的衰弱及萎缩引起的。海马体病变常表现为海马体体积的变化如萎缩、左右海马体不对称等。海马体分割是海马体体积测量的关键和基础,通过分割脑部磁共振图像中的海马体,可测量海马体体积及形

到稿日期:2016-03-31 返修日期:2016-08-07 本文受广东省自然科学基金(2014A030313316,2016A030313574)资助。

刘颖(1992-),女,硕士,主要研究方向为医学图像分割;张明慧(1980-),女,副教授,主要研究方向为医学图像处理;阳维男,副教授,主要研究方向为医学图像处理;卢振泰(1981-),男,副教授,硕士生导师,主要研究方向为医学图像处理,E-mail:luzhentai@163.com(通信作者);冯前进男,教授,主要研究方向为医学图像处理;苏榆生(1989-),男,学士。

态变化,可对老年痴呆、精神分裂、颞叶癫痫等多种脑部疾病进行分析与诊断。由于海马体形状不规则且其与周围组织的分界模糊,因此加大了海马体自动分割的难度。图 1 为脑部 MRI 图像,图中曲线围成部分为海马体,从图中看出海马体在脑中所占的比例小,与周围组织的分界模糊,在图 1 中表现为与周围组织结构的灰度值相差较小。



图 1 脑部 MRI 图像,曲线围成部分为海马体

海马体分割算法层出不穷,常见的分割算法有:阈值分割^[1]、区域生长法^[2]、马尔科夫随机算法^[3]、聚类算法^[4]以及水平集分割算法^[5]。阈值分割操作简单,分割速度快,但对阈值的选取较为敏感,且只考虑了像素本身的灰度值,没有考虑图像的空间分布;区域生长法是一种鲁棒性强、速度快且无需调节参数的算法,但需要人机交互选取种子像素,且区域一致性准则对分割的影响较大,同时对噪声比较敏感;马尔科夫随机算法的关键是参数估计,若因先验知识不充分,不能准确估计参数,会导致分割误差较大;聚类算法是一种无监督的算法,但初始聚类数目及中心对分割影响较大;水平集分割算法规划容易且能灵活加入先验信息,但它对参数同样敏感,且容易陷入局部极值。目前应用较广泛的海马体分割方法是基于多图谱的标号融合技术分割法^[6]。在多图谱标号融合技术分割法中,一组图谱包括图谱灰度图像和已分割的标号图像,标号图像一般由专家手动勾画分割好,并将相同区域的像素标记为同一标号,目前由专家勾画区域是图像分割的金标准。本文实验数据中标号图像的海马体像素标记为 1,非海马体像素标记为 0。研究表明基于多图谱标号融合分割算法的分割精度依赖于图谱选择。图像配准一般作为第一阶段的图谱选择标准,将图谱图像配准到待分割图像,并将配准后的图谱图像与待分割图像的全局相似性作为选择图谱的依据,而全局相似性主要取决于大器官之间的相似性^[7],局部小器官的相似性与全局相似性的一致性差,而根据像素间的局部相似性选择图谱能降低大器官优势现象。计算局部相似性的方法多种多样,目前较主流的方法有基于互信息^[8]、差值平方和^[9]的方法等。局部相似性主要计算局部灰度小块间的相似性,由于局部灰度小块同时包含多种低维特征,且不用赋予特征权重,因此很多算法中常用局部灰度小块来描述像素特征。为了更好地描述像素特征,有些算法在计算局部相似性时,将图像空间信息等整合到灰度小块中,如文献^[10]中,将灰度、梯度、纹理特征结合在一起,然后再计算局部相似性。虽然基于局部灰度小块及改进的基于局部灰度小块的算法包含多种特征,但是在基于多图谱的分割中,图谱间的灰度不均匀性会影响灰度小块局部相似性的准确性。图 2 中第一列为不同的图谱图像,第二列为相同部位的灰度小块,为了更直观地显示第二列中的灰度小块间的差异,第三列显示了第二列的灰度图像的伪彩色图像。图 2 显示在不同图谱的相同部位,像素的灰度小块间差异明显。为降低由于图谱间灰度不均匀造成的分割误差,SCOSD 算法用方向-尺度描述子代替局部灰度

小块描述像素特征,与局部灰度小块相比,方向-尺度描述子用像素间的相似性代替像素的灰度值,即使图谱间灰度差异较明显,但在同一图谱中不同部位间的相似性变化较小,即将图谱灰度看成绝对变化量,不同部位间的变化看成相对变化量,即使图谱间的绝对变化量较大,图谱内的相对变化量变化仍然较小。因此方向-尺度描述子在包含像素的空间结构信息的同时能降低图谱间灰度不均匀性所造成的影响。

从图谱中提取像素的方向-尺度描述子来构建目标像素的字典。许多算法利用图谱训练出共有字典,然后利用该字典重建所有目标像素特征^[11],这种方法可以利用图谱线下训练出共有字典,然后分割图像,虽然训练共有字典的计算量小于为不同目标像素训练特有字典,但后者的分割精度优于前者。因此 SCOSD 算法为不同目标像素训练特有字典,然后用像素特有字典重建目标像素特征。




图 2 图谱间灰度不均匀性显示

将组成字典的方向-尺度描述子看成字典的元素,用特有字典重建目标像素,即用字典元素的线性组合近似表达目标像素的特征,线性系数即为编码系数。稀疏编码指仅利用字典的部分元素重建目标像素特征,稀疏编码不仅能减少计算量而且能保证重建的准确性,它被广泛应用于去噪^[12]、压缩感知^[13]等图像处理领域。根据字典中的元素在重建目标像素时所作贡献的不同设置编码系数,稀疏编码过程将贡献小的或者没贡献的元素的系数置为 0,贡献越大的元素的系数越接近 1。SCOSD 算法采用局部线性嵌入法(Local Anchor Embedding, LAE)完成稀疏编码过程,并将稀疏编码系数作为标号融合的权重,融合标号和系数得出目标像素标号估计值。本文用 MICCAI 比赛数据验证算法的精确性,实验结果表明,海马体自动分割精度大于其他主流的基于标号融合的分割方法,如 Simple^[14], Collate^[15], Major Voting^[16], Staple^[17]。

2 实验数据与算法

2.1 实验数据

为了验证本文方法的精确性,用在线图像数据库

MICCAI 2013 的比赛数据作为实验数据,该数据集包含 35 组脑部磁共振三维数据,每组图谱包含灰度图像以及经专家勾画的标号图像,随机选取其中的 15 组作为测试图像,其余 20 组作为图谱图像。用本文方法以及国际主流的分割方法 Simple^[14], Collate^[15], Major Voting^[16], Staple^[17] 分割测试图像。

2.2 算法流程

SCOSD 算法包括 4 部分:预处理、提取像素特征、构建字典及完成稀疏编码、阈值处理融合的标号估计值,流程如图 3 所示,图 4 为海马体分割流程示意图。

(1) 预处理:将图谱配准到待分割图像并确定图谱和待分割图像目标像素。

(2) 提取方向-尺度描述子:根据式(1)分别提取出图谱图像和目标图像感兴趣区域内第三类像素的方向-尺度描述子。

(3) 构建字典并完成稀疏编码:用图谱图像方向-尺度描述子构建目标图像第三类像素特有字典,即为每一个目标像

素构建一个字典。用目标像素的特有字典重建目标像素,得到稀疏编码系数,编码系数即为标号融合的权重。

(4) 标号融合:融合字典像素标号,阈值处理标号融合结果,完成分割。

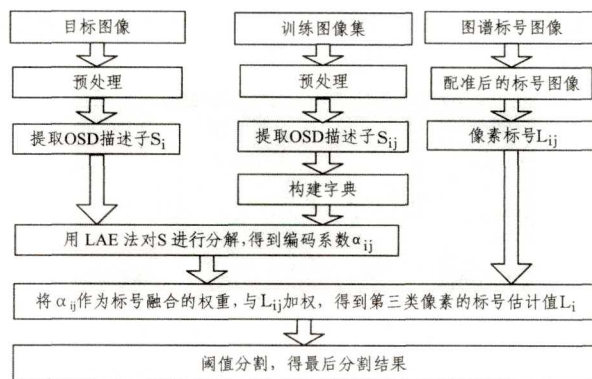


图3 SCOSD算法流程图

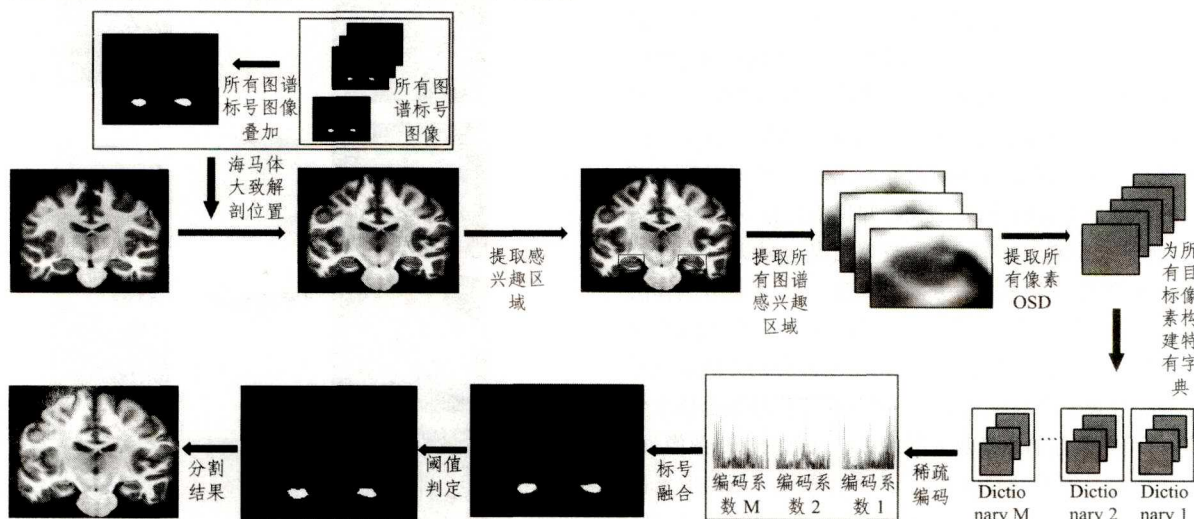


图4 海马体分割流程示意图

2.2.1 预处理

预处理包括将图谱图像配准到目标图像以及确定目标像素。首先用 DRAMMS^[18] 配准算法将图谱图像逐一配准到目标图像上,得到每个图谱配准的形变场,再将形变场作用到与图谱相对应的标号图像上,得到变形后的标号图像。在配准后的图谱图像中提取感兴趣区域,如图 5 所示。




图5 提取感兴趣区域,矩形框内即为感兴趣区域

将图 5 中矩形框内的区域提取出来,然后再利用图谱标号图像的先验信息确定待分割目标像素。80%以上的图谱标号图像标记为 1 的像素为第一类像素,直接标记为 1;80%以上的图谱标号图像标记为 0 的像素为第二类像素,直接标记为 0;其余不确定的像素为第三类像素,并用本文提出的分割算法进一步分割。本文中的图谱图像为 20,若 16 幅标号图

像在某像素的标记为 1,则该像素直接标记为 1,同理,若 16 幅标号图像在某像素的标记为 0,则该像素直接标记为 0。其余不确定的像素再用分割算法进一步分割。

2.2.2 提取方向-尺度描述子

像素特征主要有边缘、梯度、纹理和灰度值。基于灰度特征设计的分割算法只利用其中一个特征,若要整合不同的特征,需要定义整合方法,即需要给不同的特征设置权重^[19]。局部灰度小块^[20]不仅包含图像多种基本特征信息,并且不用为不同的基本特征设置权重,但局部灰度小块较适用于单图谱。在多图谱算法中,不同图谱间亮度不同,使得同一位置的局部灰度小块差异较大。

如图 2 所示,3 幅图像显示了不同组图谱图像同层脑部 MRI 图像,位置相同的像素的灰度小块存在差异,为了降低由于图谱间亮度差异造成的分割误差,本文提出了一种新的像素特征即方向-尺度描述子,方向-尺度描述子在包含像素的空间结构信息的同时能降低图谱亮度不均匀的影响。方向-尺度描述子包含两个因素,即方向性和尺度性。图 6 所示为方向-尺度描述子的含义。图 6 中不同的箭头代表不同方向,不同的黑色虚线框代表不同尺度。方向性表示计算不同方向上像素与中心像素间的距离,用两像素局部灰度小块间的欧氏距离衡量两像素间的距离, p_1 为计算两像素间距离的

块尺寸。尺度性决定了方向-尺度描述子的大小, p_2 表示方向-尺度描述子尺度大小, 计算 x 的方向-尺度描述子时, 计算以 x 为中心, $p_2 \times p_2 \times p_2$ 内所有像素与中心像素 x 之间的距离。




图 6 方向-尺度描述子示意图

方向-尺度描述子提取过程: 首先确定方向-尺度描述子的大小 $|p_2|$, 计算描述子中心像素与描述子内所有像素之间的欧氏距离^[21], 计算中心像素与所有 $N_1 = p_2 \times p_2 \times p_2$ 个像素之间的欧氏距离, 以灰度小块之间的欧氏距离代替像素灰度值之间的欧氏距离, 得到中心像素与方向-尺度描述子内所有像素间的相似性小块 D_p , 计算相似性小块 D_p 的方差 $V(I, x)$, 方向-尺度描述子即为以相似性小块 D_p 与方差 $V(I, x)$ 之比为幂的 e 的负幂次方小块。 S 的计算公式为:

$$S(I, x, r) = \exp\left(-\frac{D_p(I, x, r)}{V(I, x)}\right), r \in p_2 \quad (1)$$

其中, S 是以 x 为中心、与描述子内 N_1 个像素之间的方向-尺度距离小块。 D_p 计算两像素欧氏距离^[22], 两像素间的欧氏距离用两灰度小块之间的欧氏距离来衡量。 $D_p(I, x, y)$ 表示像素 x 和像素 y 之间的距离, 即计算分别以 x 和 y 为中心、 $|p_1|$ 内所有灰度之间的差值平方和。灰度小块包含了像素的灰度、纹理、梯度等信息, 并且用欧氏距离表示灰度小块的相似性程度, 计算便捷。计算灰度小块之间的欧氏距离 D_p :

$$D_p(I, x, y) = \sum_{p \in p_1 \times p_1 \times p_1} (I(x+p_1) - I(y+p_1))^2 \quad (2)$$

其中, 提取出以像素 x 为中心、 p_1 为半径的灰度小块 $I(x, x+p_1)$, 再提取出以像素 y 为中心、 p_1 为半径的灰度小块 $I(y, y+p_1)$, 计算 $I(x, x+p_1)$ 与 $I(y, y+p_1)$ 对应像素之间的灰度值之差, 最后求平方和。

分析中心像素与 $|p_2|$ 内其他像素之间的方向-尺度距离公式可知, 距中心像素空间位置越近的像素与中心像素距离越小。在式(1)中, $V(I, x)$ 为相似性小块 D_p 的方差估计, $V(I, x)$ 的值越大, 则说明 D_p 的波动性越大。 $V(I, x)$ 的计算公式为:

$$V(I, x) = \frac{1}{N_2} \sum_{n \in N_2} D_p(I, x, n) \quad (3)$$

其中, $N_2 = p_2 \times p_2 \times p_2$, 即 $p_2 \times p_2 \times p_2$ 内的像素总数。

2.2.3 构建字典及稀疏编码

提取出目标图像中第 i 个像素 x_i 的方向-尺度描述子 S_i , 训练图谱中与 x_i 位置相对应的像素为 x_k , 取出所有以 x_k 为中心、 $|p_3|$ 为搜索窗内的所有像素的方向尺度描述子 S_{ij} ,

用 S_{ij} 构建像素 x_i 的特有字典 D_i , 然后用像素 x_i 的特有字典重建 S_i 。稀疏编码系数 α_{ij} 表示 S_{ij} 与目标像素 S_i 的相似性大小, 系数 α_{ij} 越大, 说明 S_{ij} 与 S_i 越相似。本文采用局部锚点嵌入法(Local Anchor Embedding, LAE)^[23]完成稀疏编码。

首先为所有目标像素构建特有字典。对为所有目标像素的 S_i 构建特有字典。对目标图像中待分割像素 x_i , 取 K 幅图谱图像构建字典。对 K 幅图谱图像与 x 位置相对应的像素为 $x_{i1}, x_{i2}, \dots, x_{ik}$, 分别以这 k 个像素为中心、以 p_3 为搜索窗, 提取 K 幅图像中以 x_{ik} 为中心、 $|p_3|$ 内的所有像素的方向-尺度描述子 S_{ij} , 提取出共 $M = k \times p_3 \times p_3 \times p_3$ 个方向-尺度描述子构建像素 x_i 的特有字典 D_i 。图 7 所示为构建目标像素特有字典以及稀疏编码的过程。




图 7 目标像素特有字典构建过程及稀疏编码

为所有目标像素构建特有字典后, 用 LAE 法求重建系数。LAE 是局部线性嵌入法(Local Linear Embedding, LLE)^[23]的改进算法, LLE 主要用于非线性降维, 即将高维数据降到低维数据, 并且保证降维后的数据流形不变。但 LLE 不适用于处理数据量大、维数高的数据, LAE 可以将高维数据映射降维到低维数据, 并且可以处理数据量大、维数高的数据。

LLE 法的关键是确定邻域像素及邻域像素的权重, 对于原始数据中的任意像素, 首先在原始数据中确定 q 个邻域像素, 然后计算与这 q 个邻域像素之间的距离, 最后在低维数据中确定该像素的位置。LAE 则是先确定基像素, 所有像素都能用基像素线性的线性组合重建。LAE 法将目标像素的 S_i 用其特有字典重建^[24], 用 LAE 法完成稀疏编码:

$$S_i = \alpha_{i1} S_{i1} + \alpha_{i2} S_{i2} + \alpha_{i3} S_{i3} + \dots + \alpha_{ij} S_{ij} + \dots + \alpha_{iM} S_{iM} + \epsilon_i \quad (4)$$

其中, ϵ_i 代表重建误差, 即用特有字典 D_i 重建 S_i 时产生的误差。 α_{ij} 表示重建 S_i 时 S_{ij} 的系数, 即字典中 S_i 与 S_{ij} 的相似性程度, M 表示组成字典的方向-尺度描述子 S_{ij} 的数量。

LAE 法规定所有的编码系数必须大于 0, 且所有编码系数之和为 1, 因此所有编码系数限定在 $(0, 1)$ 之间, 将重建误差最小作为目标函数, 即

$$\begin{aligned} \alpha_{ij}^* &= \arg \min \| S - (\alpha_{i1} S_{i1} + \alpha_{i2} S_{i2} + \alpha_{i3} S_{i3} + \dots + \alpha_{ij} S_{ij} + \dots + \alpha_{iM} S_{iM}) \|^2 \\ &= \arg \min \| S - \sum_{i=1}^M \alpha_{ij} S_{ij} \|^2 \\ \text{s. t. } & S_{ij} \in N_x, \alpha_{ij} = 0; \sum_{j=1}^M \alpha_{ij} = 1, \alpha_{ij} \geq 0 \end{aligned} \quad (5)$$

其中, N_x 表示以像素 x_i 及对应像素 $x_{i\#}$ 为中心的搜索窗。对不属于特有字典 D_i 内的像素的方向-尺度描述子 S_{ij} , 其编码系数 α_{ij} 置为 0。

2.2.4 标号融合

在基于标号融合的算法中, 图谱图像的标号都是已知的, 融合权重的获取是标号融合的关键, 不同算法中权重的获取方法不同。Voting 中不涉及标号融合权重计算, 在 Voting 中只取距离最近的若干个元素, 然后赋予这些元素相同的权重。在基于多图谱的分割算法中, 文献[25]直接将欧氏距离作为融合权重, 文献[26]直接将配准精度作为标号融合权重, 这些方法虽然操作简单, 计算量较小, 但是分割精度不理想。为了提高分割精度, 本文对目标像素的方向-尺度描述子 S_i 用特有字典重建完成稀疏编码, 并将编码系数作为标号融合的权重。设图谱图像像素的标号为 L_i , 融合图谱标号:

$$\begin{aligned} L_i &= \alpha_{i1} L_{i1} + \alpha_{i2} L_{i2} + \alpha_{i3} L_{i3} + \dots + \alpha_{ij} L_{ij} + \dots + \alpha_{iM} L_{iM} \\ &= \sum_{j=1}^M \alpha_{ij} L_{ij} \end{aligned} \quad (6)$$

其中, L_{ij} 为图谱标号融合后目标像素标号的估计值, 图谱标号图像中海马体的标号为 1, 非海马体的标号为 0, 因此 L_{ij} 的值为 0 或 1, 又由于 $\alpha_i \in (0, 1)$, 因此融合后得到的估计值 L_i 属于 $(0, 1)$, 设定阈值 T , 若 L_i 大于 T , 则将 L_i 置为 1, 即判定为海马体, 若 L_i 小于 T , 则将 L_i 置为 0, 即判定为非海马体, 对目标图像的所有目标像判定后完成图像分割:

$$L_i = \begin{cases} 1, & L_i \geq T \\ 0, & L_i < T \end{cases} \quad (7)$$

T 为设置的阈值参数。根据图谱图像标号图像中 0 和 1 的比例来设置阈值 T 。计算所有图谱待分割区域中海马体的所占比例 t , 即计算标号为 1 的比例, 并将 t 的均值作为阈值 T , 结果如表 1 所列。

表 1 左右海马体分割阈值 T

组别	左海马	右海马	组别	左海马	右海马
1	0.4898	0.5414	11	0.4259	0.4893
2	0.4512	0.4097	12	0.5158	0.5211
3	0.5305	0.4482	13	0.4536	0.3623
4	0.5730	0.6445	14	0.4898	0.4586
5	0.3829	0.4477	15	0.5153	0.4560
6	0.4977	0.4321	16	0.5498	0.5492
7	0.4327	0.5310	17	0.4943	0.6163
8	0.5277	0.4373	18	0.5696	0.5882
9	0.5871	0.5148	19	0.3580	0.3488
10	0.5300	0.5357	20	0.4417	0.4997
			T	0.4898	0.4916

3 实验结果与参数调节

本文实验数据为 2013 年 MICCAI 比赛数据。用 SCOSD 算法分割海马体, 并将实验结果与主流的分割方法如 Simple, Collate, Major Voting, Staple 进行对比。将 Dice 相似性测度作为分割精度的评估标准, Dice 计算公式为:

$$Dice = \frac{2|A \cap B|}{|A| + |B|}$$

其中, A 和 B 分别表示专家分割结果以及算法分割的结果。Dice 值越大表明分割准确度越高。

为了得到最佳分割效果, 需要优化参数。本文需要优化的参数有: 计算像素间欧氏距离的灰度小块大小 p_1 , 方向-尺度描述子大小 p_2 , 构建特有字典的搜索窗 p_3 。逐一优化参数 p_1, p_2, p_3 。首先优化 p_1 , 固定 p_2, p_3 。由于 p_1, p_2, p_3 的取值为奇数, 首先设定 p_2, p_3 为 3, p_1 分别取 3, 5, 7。 p_1 优化完成后, 取 p_1 为最优值, 然后优化 p_2 , p_2 优化完成后, 取 p_2 为最优值, 最后优化 p_3 。如图 8 所示, 第一列为 p_2 和 p_3 设为 3, p_1 取 3, 5, 7 时 15 组测试图像左右海马体的分割精度, 当 p_1 取 3 时, 左右海马体分割精度最高。设置 $p_1 = 3, p_2$ 分别取 3, 5, 7, 9, p_3 设定为 3, 调节 p_2 , 第二列为调节 p_2 时 15 组测试图像左右海马体的分割精度, 当 p_2 取 5 时, 左右海马体分割精度最高。同理, 设置 $p_1 = 3, p_2 = 5, p_3$ 分别取 3, 5, 7, 9, 调节 p_3 , 第三列显示当 p_3 取 3, 5, 7, 9 时 15 组测试图像左右海马体的分割精度, 当 p_3 取 7 时左右海马体分割精度最高。

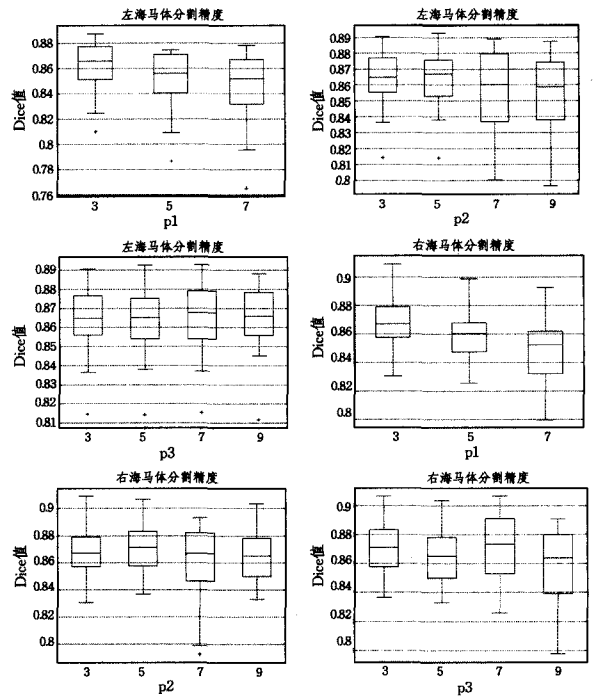


图 8 不同参数下 15 组测试数据左右海马体分割精度

为了验证 SCOSD 算法的准确性, 对 15 组测试数据按照图 3 所示的流程分割目标像素, 分割 15 组数据中的左海马体和右海马体, 分割结果如表 2 所列。

表 2 左右海马体分割 Dice 值

组别	左海马	右海马	组别	左海马	右海马
1	0.8814	0.8805	9	0.8639	0.8537
2	0.8623	0.8625	10	0.8390	0.8230
3	0.8755	0.8814	11	0.8506	0.8636
4	0.7927	0.8814	12	0.8713	0.8823
5	0.8478	0.8539	13	0.8631	0.8696
6	0.8750	0.8818	14	0.8681	0.8530
7	0.8789	0.9073	15	0.8537	0.8374
8	0.9138	0.8700	Dice 均值	0.8625	0.8668

从表 2 中看出右海马分割 Dice 均值略大于左海马, 右海马的 Dice 均值为 0.8668, 左海马的 Dice 均值为 0.8625, 左右海马体的分割结果的箱线图如图 9 所示。




图 9 左右海马分割结果箱线图

为了进一步验证 SCOSD 的精确性,将实验结果与 Simple, Collate, Major Voting, Staple 方法进行比较,对同样的数据,用 Simple, Collate, Major Voting, Staple 方法分割左右海马体,并都以 Dice 相似性测度作为分割精度的评判标准进行比较,结果如图 10 和图 11 所示。图 10 为所有算法对左海马体进行分割的结果的箱线图,图 11 为所有算法对右海马体进行分割的结果的箱线图。




图 10 不同分割方法分割左海马的结果





图 11 不同分割方法分割右海马的结果

从图 10 和图 11 可以看出, Simple, Major Voting, Staple, Collate 方法分割的 Dice 均值低于 SCOSD 算法,且 SCOSD 算法分割结果的箱线图较集中,即算法分割结果较稳定。

SCOSD 算法用方向-尺度描述子描述像素特征,结合线性编码技术,融合标号得到目标像素标号估计值,阈值判定标号估计值得出最后分割结果,完成海马体分割。通过实验验证, SCOSD 算法对海马体的分割结果 Dice 均值高于 Major Voting, Staple, Simple, Collate 等方法,且分割结果相对稳定。

4 讨论

SCOSD 算法分割结果的二维视图如图 12 所示。



左边曲线为 SCOSD 算法分割结果,右边曲线为专家手动分割结果

图 12 SCOSD 算法分割结果示意图

从图 12 可以看出, SCOSD 算法与专家手动分割结果基本相符,图中专家分割左海马体时由于手抖等原因明显产生

了误分割, SCOSD 算法利用了所有图谱的分割信息,若将每一图谱看成一个专家, SCOSD 综合了所有专家的分割结果,因此降低了分割错误率。

右海马体分割结果三维重建视图如图 13 所示。图 14 为分割误差三维视图。




图 13 分割结果三维重建视图




图 14 分割误差三维视图

本文实验中用 SCOSD 算法仅分割第三类像素以减少计算量,为了验证分割错误率集中在第三类像素,随机抽取 3 幅目标图像,用 SCOSD 算法分割这 3 幅图像中感兴趣区域内所有的像素,分割对比结果如表 3 所列。

表 3 比较分割所有像素与只分割第三类像素的分割结果

	Left		Right	
	All	Thirid	All	Thirid
1012	0.8843	0.8799	0.8928	0.8973
1101	0.8580	0.8537	0.8796	0.8758
1116	0.8600	0.8691	0.8570	0.8726

注: All 表示分割感兴趣区域内所有像素的分割结果, Thirid 表示只分割第三类像素的分割结果。

从表 3 中只能看出两种情况下的分割精度基本相同,但不能确定分割错误的像素主要源于第三类像素。为了验证只分割第三类像素不会对分割结果造成影响,对目标图像的兴趣区域内的所有像素进行分割,分析将第一类像素直接判定为海马体时与用 SCOSD 算法分割的差异,以及将第二类像素直接判定为非海马体时与 SCOSD 算法判定的差异,结果如图 15 所示。从图中可看出,直接将第一类像素判定为海马体时与用 SCOSD 算法分割得到的结果无差异,将第二类像素判定为非海马体与用 SCOSD 算法分割得到的结果差异较小。只分割第三类像素可以减少分割计算量,节省分割时间,所以本实验只对第三类像素进行分割。




图 15 第二类像素判定为非海马体与用 SCOSD 算法分割的结果差异

结束语 SCOSD 算法首先提取目标像素方向-尺度描述

子,然后提取图谱图像像素的方向-尺度描述子构建目标像素的特有字典,用特有字典重建目标像素方向-尺度描述子,并用LAE法实现稀疏编码过程,将编码系数作为标号融合的权重,加权融合标号得到目标像素的标号估计值,设定分割阈值,判定目标像素标号,完成分割。SCOSD算法用方向-尺度描述子代替灰度小块描述像素特征,由于方向-尺度描述子描述的是像素与邻域像素的相似性大小,图谱间整体亮度不均一,但图谱内像素间的相似性变化较小,因此可以降低由图谱间亮度不均一造成的分割误差,从而提高海马体分割精度。

参考文献

- [1] TAN P Y, CHEN J H, LI P, et al. Improving Threshold Segmentation in 3D Reconstruction of Mandible CT Image [J]. 2015, 46(3): 458-462.
- [2] JIANG H, HE B, FANG D, et al. A region growing vessel segmentation algorithm based on spectrum information [J]. Comput Math Methods Med, 2013(6): 743870.
- [3] ASHRAF A B, GAVENONIS S, DAYE D, et al. A multichannel Markov random field approach for automated segmentation of breast cancer tumor in DCE-MRI data using kinetic observation model [J]. Med Image Comput Comput Assist Interv, 2011, 14 (pt3): 546-553.
- [4] MENDEZ C A, SUMMERS P, MENEGAZ G. Multiview Cluster Ensembles for Multimodal MRI Segmentation [J]. International Journal of Imaging Systems & Technology, 2015, 25(1): 56-67.
- [5] LI C, HUANG R, DING Z, et al. A level set method for image segmentation in the presence of intensity inhomogeneities with application to MRI [J]. IEEE Trans Image Process, 2011, 20 (7): 2007-2016.
- [6] PARK S H, GAO Y, SHEN D. Multi-atlas based segmentation editing with interaction-guided patch selection and label fusion [J]. IEEE Trans on Bio-medical Engineering, 2015, 63(6): 1208-1219.
- [7] TONG T, WOLZ R, WANG Z, et al. Discriminative dictionary learning for abdominal multi-organ segmentation [J]. Med Image Anal, 2015, 23(1): 92-104.
- [8] ALJABAR P, HECKEMANN R A, HAMMERS A, et al. Multi-atlas based segmentation of brain images; atlas selection and its effect on accuracy [J]. Neuroimage, 2009, 46(3): 726-738.
- [9] TONG T, WOLZ R, COUPE P, et al. Segmentation of MR images via discriminative dictionary learning and sparse coding; application to hippocampus labeling [J]. Neuroimage, 2013, 76: 11-23.
- [10] BAI W, SHI W, LEDIG C, et al. Multi-atlas segmentation with augmented features for cardiac MR images [J]. Med Image Anal, 2015, 19(1): 98-109.
- [11] ROY S, CARASS A, PRINCE J L, et al. Subject Specific Sparse Dictionary Learning for Atlas based Brain MRI Segmentation [C] // Machine Learning in Medical Image. Springer International Publishing, 2014.
- [12] GRAMFORT A, POUPON C, DESCOTEAUX M. Denoising and fast diffusion imaging with physically constrained sparse dictionary learning [J]. Med Image Anal, 2014, 18(1): 36-49.
- [13] DONOHO D L. Compressed sensing [J]. IEEE T Inform Theory, 2006, 52(4): 1289-1306.
- [14] LANGERAK T R, VAN DER HEIDE U A, et al. Label fusion in atlas-based segmentation using a selective and iterative method for performance level estimation (SIMPLE) [J]. IEEE Trans Med Imaging, 2010, 29(12): 2000-2008.
- [15] ASMAN A J, LANDMAN B A. Robust statistical label fusion through Consensus Level, Labeler Accuracy, and Truth Estimation (COLLATE) [J]. IEEE Trans Med Imaging, 2011, 30(10): 1779-1794.
- [16] JIA J, TANG C K. Tensor voting for image correction by global and local intensity alignment [J]. IEEE Trans Pattern Anal Mach Intell, 2005, 27(1): 36-50.
- [17] WARFIELD S K, ZOU K H, WELLS W M. Simultaneous truth and performance level estimation (STAPLE): an algorithm for the validation of image segmentation [J]. IEEE Trans Med Imaging, 2004, 23(7): 903-921.
- [18] OU Y, DAVATZIKOS C. DRAMMS: Deformable Registration via Attribute Matching and Mutual-Saliency Weighting [J]. Medical Image Analysis, 2009, 15(4): 622-639.
- [19] GIRAUD R, TA V T, PAPANASIK N, et al. An Optimized Patch Match for Multi-scale and Multi-feature Label Fusion [J]. Neuroimage, 2015, 124(Pt A): 770-782.
- [20] HAO Y, WANG T, ZHANG X, et al. Local label learning (LLL) for subcortical structure segmentation; application to hippocampus segmentation [J]. Hum Brain Mapp, 2014, 35(6): 2674-2697.
- [21] HEINRICH M P, JENKINSON M, BHUSHAN M, et al. M-IND: modality independent neighbourhood descriptor for multi-modal deformable registration [J]. Med Image Anal, 2012, 16 (7): 1423-1435.
- [22] LI X B, BURKOWSKI F. Generating conformational transitions using the euclidean distance matrix [J]. IEEE Trans Nanobioscience, 2015, 14(2): 203-209.
- [23] LIU W, HE J, CHANG S F. Large Graph Construction for Scalable Semi-Supervised Learning [C] // International Conference on Machine Learning. 2010: 679-686.
- [24] HUANG M, YANG W, JIANG J, et al. Brain extraction based on locally linear representation-based classification [J]. Neuroimage, 2014, 92: 322-339.
- [25] XIAO Y, FONOV V S, BERIAULTS S, et al. Patch-based label fusion segmentation of brainstem structures with dual-contrast MRI for Parkinson's disease [J]. Int Comput Assist Radiol Surg, 2015, 10(7): 1029-1041.
- [26] KLEMENCIC J, PLUIM J P W, VIERGEREV M A, et al. Non-rigid registration based active appearance models for 3D medical image segmentation [J]. Imaging Sci Techn, 2004, 48(2): 166-171.