

基于线性化核标签融合的脑 MR 图像分割方法

刘悦¹ 魏颖^{1,2} 贾晓甜¹ 王楚媛¹

摘要 深层脑结构的形态变化和神经退行性疾病相关,对脑 MR 图像中的深层脑结构分割有助于分析各结构的形态变化.多图融合方法利用图谱图像中的先验信息,为脑结构分割提供了一种有效的方法.大部分现有多图谱融合方法仅以灰度值作为特征,然而深层脑结构灰度分布之间重叠的部分较多,且边缘不明显.为克服上述问题,本文提出一种基于线性化核多图融合的脑 MR 图像分割方法.首先,结合纹理与灰度双重特征,形成增强特征用于更好地表达脑结构信息.其次,引入核方法,通过高维映射捕获原始空间中特征的非线性结构,增强数据间的判别性和线性相似性.最后,利用 Nyström 方法,对高维核矩阵进行估计,通过特征值分解计算虚样本,并在核标签融合过程中利用虚样本替代高维样本,大大降低了核标签融合的计算复杂度.在三个公开数据集上的实验结果表明,本文方法在较少的时间消耗内,提高了分割精度.

关键词 脑结构分割,核标签融合,增强特征, Nyström 方法,虚样本

引用格式 刘悦,魏颖,贾晓甜,王楚媛.基于线性化核标签融合的脑 MR 图像分割方法.自动化学报,2020,46(12):2593–2606

DOI 10.16383/j.aas.c180407

Linearized Kernel-Based Label Fusion Method for Brain MR Image Segmentation

LIU Yue¹ WEI Ying^{1,2} JIA Xiao-Tian¹ WANG Chu-Yuan¹

Abstract Morphological changes in subcortical brain structures are related to different neurodegenerative disorders. Therefore, subcortical brain segmentation in MRI contribute to analyses of morphological changes in various structures. Multi atlas-based method provides an effective way for subcortical brain segmentation by using prior information in atlas. Most of the existing multi atlas-based methods only use intensities as features, while the distribution of gray value overlaps more and the edges of structures are not obvious. In order to solve above problems, a brain magnetic resonance image (MRI) segmentation method based on linearized kernel-based label fusion method is proposed in this paper. First, augmented features are formed by concatenating texture features and intensity features to obtain better representation. Then, kernel method is introduced to capture the nonlinear structure of features in the original space and enhance discriminability and linear similarity between features using high dimensional mapping. Finally, the Nyström method is used to estimate high dimensional kernel matrices and virtual samples are calculated by eigenvalue decomposition. Mapped samples are replaced by virtual samples in label fusion methods, which can greatly reduce the computational complexity of kernel-based label fusion methods. Experimental results on three public datasets show that the proposed method improves the segmentation accuracy with less time consumption.

Key words Subcortical brain segmentation, kernel-based label fusion method, augmented feature, Nyström method, virtual sample

Citation Liu Yue, Wei Ying, Jia Xiao-Tian, Wang Chu-Yuan. Linearized kernel-based label fusion method for brain MR image segmentation. *Acta Automatica Sinica*, 2020, 46(12): 2593–2606

人类的大脑是包含很多解剖结构的复杂神经系统,位于大脑半球内部的重要深层结构包括丘脑、壳核、尾状核、苍白球、海马和杏仁核等.神经退行性

疾病的发生会引起深层脑结构一系列的变化^[1],如:抑郁症病人的尾状核体积减小^[2],海马体积测量可以为阿尔兹海默症的早期诊断提供可靠依据^[3].磁共振成像可以对脑和神经系统等软组织进行高分辨率成像,是对大脑结构分析的有效临床方法,因此,对脑磁共振图像(Magnetic resonance image, MRI)中深层结构的精准分割是后续图像分析和疾病辅助诊断的基础.然而,专家手动分割 MRI 十分耗时,且分割结果受到各类因素影响.目前,很多脑结构自动分割软件,如 FreeSurfer^[4]和 FIRST^[5],减轻了手动分割带来的负担,但其精度仍需改善.

近年来,脑结构的自动分割受到了广泛的关

收稿日期 2018-06-08 录用日期 2019-01-09
Manuscript received June 8 2018; accepted January 9, 2019
国家自然科学基金(61871106)资助
Support by National Natural Science Foundation of China (61871106)

本文责任编辑 张道强

Recommended by Associate Editor ZHANG Dao-Qiang

1. 东北大学信息科学与工程学院 沈阳 110819 2. 东北大学医学影像计算教育部重点实验室 沈阳 110179

1. School of Information Science and Engineering, Northeastern University, Shenyang 110819 2. Key Laboratory of Medical Imaging Calculation of the Ministry of Education, Northeastern University, Shenyang 110179

注^[6-13]. 其中基于多图谱融合的分割方法是目前研究比较广泛的一类方法^[14-15]. 该方法的主要思想是: 利用图谱原图与目标图像的相关性和图谱标签中的先验信息, 将加权投票的结果或者重构误差作为标签融合的依据, 判断目标像素的类别. 基于多图谱融合的分割方法分为图像配准和标签融合 (Label fusion, LF) 两步, 其中标签融合是最重要的一步, 有两种常见的方法, 一是基于非局部图像块的融合方法 (Nonlocal patch-based method, PB)^[16-18], 二是基于重构的融合方法^[19-21]. 基于非局部图像块的方法 (PB) 在估计标签时, 仅考虑目标像素邻域内的像素, 通过计算图谱图像块之间的相似性来估计目标的标签. Coupé 等^[16] 提出了基于 PB 方法的海马和心室分割方法. Rousseau 等^[17] 将 PB 方法应用于脑组织 (脑白质、脑灰质和脑脊液) 和深层脑结构 (丘脑、尾状核、壳核和苍白球等) 的分割. 基于重构的典型方法包括稀疏表示 (Sparse representation classifier, SRC)^[20] 和字典学习 (Dictionary learning, DL)^[21]. 文献 [20] 首先将 SRC 用于多模态的脑部肿瘤分割. Tong 等^[21] 改进了判别性字典学习方法 (Discriminative dictionary learning, DDL), 离线学习字典, 在线分割海马. 多图谱融合方法在脑 MRI 分割领域取得了较好的结果.

人类的视觉系统对于图像的灰度值敏感, 在基于多图谱融合的分割方法中, 灰度值是最常用的图像特征. 然而, 深层脑结构灰度分布之间重叠部分较多, 且边缘不明显, 因此, 脑结构的分割不能仅仅依赖于灰度值. 已有研究在心脏图像分割问题上将梯度特征和上下文特征拼接在一起, 并取得不错效果^[22]. 借助该思想, 本文将灰度和纹理特征相融合, 形成增强特征向量, 用于表示脑 MRI 中的像素信息, 在第 2 节有详细说明. 然而, 针对 MRI 中的深层脑结构所构建的特征向量不具有很好的线性相关性, 考虑到数据的非线性结构, 可以将相关特征映射到高维特征空间中, 使分类或回归结果更加准确^[23-24]. 核方法 (Kernel method) 将高维特征数据的内积运算替换成核函数运算, 有效解决了映射形式未知的难题. 近年来, 核方法广泛应用于多图谱融合方法中, 如核稀疏表示 (Kernel SRC, KSRC)^[25-26] 和核字典学习 (Kernel DL, KDL)^[27-28]. Nguyen 等^[27] 用核方法扩展字典学习算法, 如 MOD (Method of optimal directions) 和 KSVD (K singular value decomposition) 算法, 并在脑肿瘤分割上得到初步应用^[29].

然而, 将核方法引入多图谱融合方法时, 有两点问题: 一是在学习算法中需要已知数据的内积形式, 而构造内积有时较困难, 二是核矩阵的维度和样本

数目相关, 学习算法的每次迭代都涉及到核矩阵的运算, 当样本集较大时, 耗费计算时间和存储空间. 在深层脑结构分割问题中, 减少算法的时间消耗十分必要. 本文针对上述两点问题, 提出了一种基于线性化核标签融合 (Linearized kernel-based label fusion method, LK + LF) 的脑结构分割方法. 先计算虚样本, 再用虚样本替代标签融合方法中的原始样本, 避免每次迭代中的核矩阵计算. 虚样本的计算分为两步, 第 1 步的目的是得到核矩阵的近似估计, 用 Nyström 方法^[19,30], 通过输入数据的子集对高维核矩阵进行低秩估计. 第 2 步对低秩矩阵进行特征值分解, 计算得到虚样本. 虚样本包含了隐式高维映射所包含的数据的非线性结构, 保证了核方法的准确率. 线性化核方法只需要在计算虚样本的时候计算高维核矩阵, 与每次迭代都需要计算核矩阵相比, 节省了计算时间. 具体方法细节在第 2.2 节和第 2.3 节描述.

本文在如下两方面对现有标签融合方法进行改进: 1) 将灰度和纹理特征相结合作为像素的特征表示, 得到增强特征 (Augmented feature, AF) 向量, 将 AF 应用于基于标签融合的脑结构分割方法中. 2) 将核方法用于基于原始特征空间的标签融合中, 并且针对核标签融合的两点问题, 引入 Nyström 方法, 对核矩阵进行低秩估计, 用虚样本替代高维特征空间中的未知样本, 减少核矩阵的计算时间.

本文结构安排如下: 第 1 节简要介绍多图谱融合分割方法基础; 第 2 节阐述本文方法的实现细节和计算复杂度; 第 3 节通过实验验证本文方法的有效性; 第 4 节进行了讨论; 第 5 节对本文的研究内容进行总结.

1 基于多图谱融合的脑 MRI 分割基础

基于多图谱融合的分割方法将分割问题看作是像素分类问题, 预测每一个像素的类别标签. 多图谱方法分为两个阶段, 分别是图像配准和标签融合, 图像配准的方法包括 B 样条法^[31] 和余弦基函数法^[32] 等, 本文采用 B 样条的配准方法. 前文所述方法: PB, SRC 和 DL 是不同的标签融合策略.

1.1 基于非局部图像块的融合方法

PB 分割方法^[16] 将待分类的目标特征向量和图谱特征向量的相似性作为权重, 对目标像素加权预测. 权重计算方法为

$$w(x_i, x_{s,j}) = \exp \frac{-\|P(x_i) - P(x_{s,j})\|_2^2}{h} \quad (1)$$

其中, $P(x_i) \in \mathbf{R}^m$ 代表目标像素 x_i 的特征向量, m 为特征向量维度, $P(x_{s,j}) \in \mathbf{R}^m$ 表示第 s 个图谱中的第 j 个像素的特征向量, h 为衰变参数. 利用上述

权重 w 对图谱标签进行加权, 得到目标像素标签的加权融合结果为

$$v(x_i) = \frac{\sum_{s=1}^N \sum_{j \in V_i} w(x_i, x_{s,j}) y_{s,j}}{\sum_{s=1}^N \sum_{j \in V_i} w(x_i, x_{s,j})} \quad (2)$$

其中, $y_{s,j}$ 为像素 $x_{s,j}$ 的标签. 目标像素标签 y 的最终计算方法为

$$y = L(x_i) = \begin{cases} 1, & v(x_i) \geq 0.5 \\ 0, & v(x_i) < 0.5 \end{cases} \quad (3)$$

1.2 基于重构的融合方法

根据像素之间的相似性通常无法得到最优的融合结果^[33], 故 PB 方法在很多情况下, 效果差于重构的方法. SRC^[19] 通过重构目标向量的方式计算权重, 通过预定义字典 $P_L = [P(x_{1,1}), \dots, P(x_{s,j}), \dots] \in \mathbf{R}^{m \times n}$, 对目标特征向量 $P(x_i)$ 进行线性重构:

$$\hat{A} = \arg \min_A \|P(x_i) - P_L A\|_2^2 \quad \text{s.t.} \quad \|A\|_0 \leq T \quad (4)$$

其中, T 表示稀疏度, 限制 A 中非 0 元素个数不能大于 T . n 是图谱特征向量个数, m 是特征向量的维度, $A = [a_{1,1}, \dots, a_{s,j}, \dots]^T \in \mathbf{R}^n$ 代表稀疏系数, n 的取值和搜索邻域有关. 以二维图像为例来说明搜索邻域的选取, 如图 1 所示, 圆点表示和目标像素对应的图谱像素, 虚线方框圈定搜索邻域, 实线方框提取搜索邻域内每一个点的图像块, 将图像块拉成列向量, 构成中心像素的特征向量, 维度为 m . n 的取值为所有图谱图像的搜索邻域内的像素点数目总数. 和文献 [16] 不同的是, 本文将所有搜索邻域内的像素都用于表示目标. 实验结果表明, 本文的方式取得了较好的效果, 在第 3.2 节有详细说明.




图 1 搜索邻域示意图. 图示为某一图谱 MRI 的搜索邻域, 对于每个图谱, 都以同样的方法选择搜索邻域内的图像块, 所有图像块集成预定义字典

Fig. 1 Diagram of search volume. For each atlas, the same strategy is used to extract image patches in search volume. All patches form predefined dictionary

本文用正交匹配追踪法 (Orthogonal matching pursuit, OMP) 求解系数 A . 对于目标像素点, 选择重构误差最小的类别为目标类别, 重构误差表示为

$$r_l(x_i) = \|P(x_i) - P_L a^l\|_2^2 \quad (5)$$

其中, a^l 表示第 l 类图谱特征向量的稀疏系数, $r_l(x_i)$ 是对目标像素 x_i 属于第 l 类的重构误差, x_i 的标签 L 为

$$L = \arg \min_l (r_l(x_i)), \quad l = 1, \dots, C \quad (6)$$

稀疏表示直接将图谱特征向量组成预定义的字典, 来重构目标向量, 预定义字典维度大, 导致计算负担重, 而且预定义字典 P_L 中的特征向量之间冗余信息较多, 不利于重构目标向量. 为克服以上缺点, 字典学习方法研究广泛, 其中判别性字典学习^[24] 的优化问题为

$$\begin{aligned} \langle D, W, Z \rangle = \arg \min_{D, W, Z} & \|P_L - DZ\|_2^2 + \\ & \lambda_1 \|H - WZ\|_2^2 \\ \text{s.t.} & \|Z\|_0 \leq T \end{aligned} \quad (7)$$

本文用在线字典学习算法^[34] 进行字典更新. 其中, $D = [d_1, d_2, \dots, d_k] \in \mathbf{R}^{m \times k}$ 为学习后的字典, k 是字典原子数, $Z \in \mathbf{R}^k$ 代表预定义字典的系数, z_i 是 Z 中的第 i 列, T 表示稀疏度, 限制 z_i 中非 0 元素个数不能大于 T . 在二分类任务中, $H \in \mathbf{R}^{2 \times n}$ 的列对应每个图谱像素的标签向量, 每个列向量是由 0 和 1 元素组成, 类别对应位置上的元素为 1, 其余为 0. W 是和 H 维度相同的分类器, 字典 D 更新的同时更新 W , 再用更新的字典 D 对目标特征向量进行线性重构, 目标函数为

$$A = \arg \min_A \|P(x_i) - DA\|_2^2 + \lambda_2 \|A\|_1 \quad (8)$$

其中, $A \in \mathbf{R}^n$ 为 $P(x_i)$ 的稀疏系数, 再通过线性分类器 W 求目标像素 x_i 的标签 L

$$\begin{cases} h = WA \\ L = \arg \max_l h(l) \end{cases} \quad (9)$$

2 线性化核标签融合方法

本节阐述线性化核标签融合方法的步骤, 第 2.1 节描述增强特征向量的像素表达方法, 第 2.2 节阐述虚样本的计算过程, 第 2.3 节将虚样本和各种标签融合方法相结合.

2.1 基于增强特征的像素表示

灰度值是最常用的医学图像信息描述方法,然而在脑 MRI 中,各个深层脑结构的灰度值对比度很低,挖掘更多的图像特征可以对像素进行更有判别性的表示,有利于对图像信息进一步的理解.局部二值模式 (Local binary pattern, LBP)^[35] 是一种十分常用的纹理特征描述方法,广泛应用于人脸识别、图像分类等领域^[36]. 本文用 LBP 描述符计算脑 MRI 的纹理特征,简记为 LBP 特征. LBP 对脑结构边缘区域的微小灰度变化较敏感.

LBP 的计算方法如下,定义局部区域纹理特征为

$$T = t(g_c, g_0, \dots, g_{P-1}) \quad (10)$$

其中, g_c 为中心像素点的灰度值, g_p ($p = 0, \dots, P-1$) 是 g_c 邻域内的 P 个像素点,为了更好地捕获边缘信息,以及保证旋转不变性,将 T 写成如下形式:

$$T \approx t(s(g_0 - g_c), s(g_1 - g_c), \dots, s(g_{P-1} - g_c)) \quad (11)$$

其中, $s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$. 将式 (11) 转化成用于表达局部图像纹理的 LBP 值,即

$$LBP = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (12)$$

图 2 所示为对某一像素 g_c 求其 LBP 值的过程示意图,设 g_c 的坐标是 (0,0),则 g_p 的坐标是 $(-r \sin(2\pi p/P), r \cos(2\pi p/P))$,在 g_c 的邻域中,用

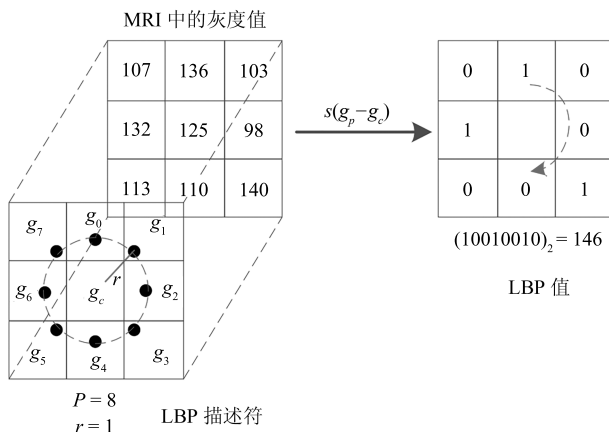


图 2 纹理特征计算过程. 用 LBP 算子遍历整幅 MRI, 计算每个像素的 LBP 值, 得到 MRI 对应的 LBP 图像
Fig. 2 Calculation of texture feature. Use LBP operator to traverse the entire MRI and calculate the LBP value for each pixel. Then, the corresponding LBP image is obtained

插值的方法计算没有落到像素中心的邻域点灰度值.

本文方法首先计算整幅脑 MRI 对应的 LBP 图像,然后针对感兴趣的像素点提取其周围邻域内的图像块,形成向量,作为该像素点的 LBP 特征. 增强特征向量计算方法如图 3 所示,针对某一目标像素点,分别在原 MRI 和 LBP 图像上取其邻域图像块,并排列成列向量,分别记为 F_{gray} 和 F_{LBP} ,将两种特征拼接在一起,得到目标像素点的特征向量,记为 $AF = \begin{bmatrix} F_{gray} \\ F_{LBP} \end{bmatrix}$,则将标签融合中的预定义字典和目标向量分别重新表示为 AF_L 和 AF_i ,分别对应于 P_L 和 $P(x_i)$,从而得到基于增强特征的标签融合方法,记为 $LF + AF$.

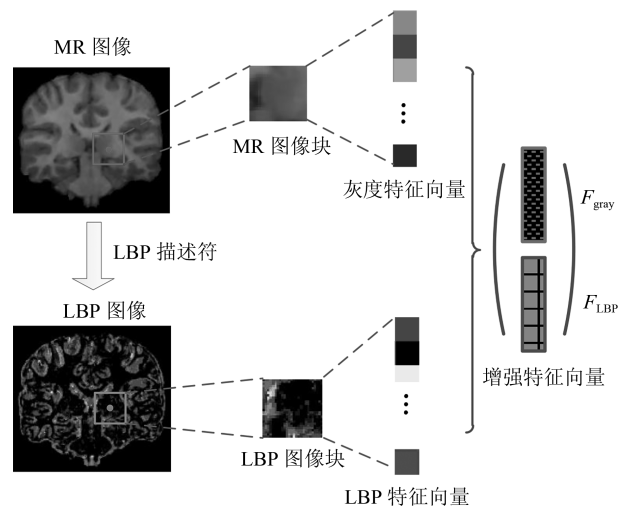


图 3 增强特征计算过程示意图. 取 MR 图像和 LBP 图像同一位置的图像块, 拼接成增强特征向量
Fig. 3 Calculation of augmented feature. Image patches with the same coordinate in MRI and LBP image concatenate together to form AF vector

2.2 基于 Nyström 方法的虚样本计算过程


在理想情况下,特征值相同的像素属于同一类别,具有相同的标签. 由于脑 MRI 和自然图像相比,分辨率较低,且各个深层脑结构之间对比度低,脑结构边界模糊且不连续. 因此,在脑 MRI 中,特征值和标签没有相应的联系,各像素之间具有非线性相似性. 将特征向量经过非线性映射,转换到高维特征空间中,可以更好地表示数据. 映射前后数据的相似性如图 4 所示,图 4(a) 为丘脑区域中的任意两个像素特征向量之间的线性相关性 $\langle AF_i, AF_j \rangle$,可以看出,即使特征值相差很大,像素仍具有相关性,不利于分割. 图 4(b) 为通过高斯函数计算之后,得到的像素的非线性相关性 $\langle \phi(AF_i), \phi(AF_j) \rangle$,可以看出,只有特征值相近的像素才具有相关性,有利于数据

的线性稀疏表示. 由于映射之后的数据维度很大, 且映射形式是隐式的, 基于高维特征空间的分类方法无法用常规方法求解, 故可以借助核技巧进行求解.


以 KSRC 为例, 核化后的正交匹配追踪法 (Kernel orthogonal matching pursuit, KOMP)^[36] 是 KSRC 的系数求解方法, 解得的系数为

$$x = K(AF_L, AF_L)^{-1}K(AF_i, AF_L)^T \quad (13)$$

其中, $K \in \mathbf{R}^{n \times n}$ 是核矩阵, $K_{a,b} = k(AF_{L_a}, AF_{L_b})$ 是 K 中第 a 行第 b 列的元素. K 的维度是由输入样本数目决定的, 而且在 KOMP 的每一次迭代中, 都涉及到核矩阵的计算, 当样本数目很多时, 核方法的计算消耗很大.



(a) $\langle AF_i, AF_j \rangle$



(b) $\langle \phi(AF_i), \phi(AF_j) \rangle$

图4 特征的相似性 (a) 原始特征的线性相似度; (b) 高维特征的线性相似度. 映射后的特征具有较好的相似性

Fig. 4 Similarity of features. (a) Similarity between original features; (b) Similarity between high dimensional features. Mapped data have better similarities

为了避免构造未知高维样本的内积形式和对核矩阵的频繁计算, 将高维数据替换成可计算的虚样本, 直接用原始标签融合方法来处理虚样本. 本节重点阐述计算虚样本的方法. 虚样本 F 可以通过对核

矩阵 K 的分解求得

$$K = F^T F = \phi(AF_L)^T \phi(AF_L) \quad (14)$$

由于 $K \in \mathbf{R}^{n \times n}$ 是半正定矩阵, 特征值可以分解为 $K = Q\Lambda Q^T$, 其中 $Q \in \mathbf{R}^{n \times k}$, $\Lambda \in \mathbf{R}^{k \times k}$ 是包含 K 的 k 个特征值的对角阵, 虚样本具体可以写成如下形式:

$$F = \Lambda^{\frac{1}{2}} Q^T = \Lambda^{-\frac{1}{2}} Q^T K \quad (15)$$

对核矩阵 K 进行特征值分解的时间复杂度是 $O(n^2 k)$, 空间复杂度是 $O(n^2)$, $Q^T K$ 的时间复杂度是 $O(n^2 k)$, 复杂度高, 因此需要借助 Nyström 方法^[30] 来对 K 进行估计, 对估计后的 K 再分解.

假设采样率是 c/n , 从 K 中根据不同的采样方法, 采样出 c 列形成降维矩阵 $C \in \mathbf{R}^{n \times c}$, $C = \begin{bmatrix} W \\ S \end{bmatrix}$, 其中 $W \in \mathbf{R}^{c \times c}$ 表示从 C 中随机抽取 c 行组成的矩阵, S 是 C 中剩余 $n - c$ 行组成的矩阵. K 可以被拆分为: $K = \begin{bmatrix} W & S^T \\ S & B \end{bmatrix}$, 其中, $B \in \mathbf{R}^{(n-c) \times (n-c)}$ 是 K 中剩余 $n - c$ 行和 $n - c$ 列组成的矩阵. Nyström 方法将高维矩阵 K 分解成 W 和 C

$$K \approx CW^\dagger C^T \quad (16)$$

其中, $(\cdot)^\dagger$ 表示伪逆. 进一步将 W 特征值分解为 $W = V\Sigma V^T$, 则 $W^\dagger = V\Sigma^\dagger V^T$. 则虚样本的内积形式如下:

$$K = F^T F = CW^\dagger C = CV\Sigma^\dagger V^T C^T \quad (17)$$

故维数为 k 的虚样本可以表示为

$$F_k = (\Sigma_k^\dagger)^{\frac{1}{2}} V_k^T C^T \quad (18)$$

其中, $\Sigma_k \in \mathbf{R}^{k \times k}$ 包含 K 的前 k 个特征值, $V_k \in \mathbf{R}^{c \times k}$ 是特征值对应的特征向量. 计算虚样本的步骤总结如下:

- 1) 对 AF_L 进行采样, 得到 $AF_R = [AF_{R_1}, \dots, AF_{R_c}] \in \mathbf{R}^{m \times c}$;
- 2) 通过 AF_L 和 AF_R 计算得到 $C_{\text{atlas}} = K(AF_L, AF_R)$;
- 3) 通过 AF_i 和 AF_R 计算得到 $C_{\text{target}} = K(AF_i, AF_R)$;
- 4) 通过 AF_R 计算得到 $W = K(AF_R, AF_R)$, 并对 W 进行特征值分解得 $W = V\Sigma V^T$;
- 5) 计算得 $F_{\text{atlas}} = (\Sigma_k^\dagger)^{1/2} V_k^T C_{\text{atlas}}^T$ 和 $F_{\text{target}} = (\Sigma_k^\dagger)^{1/2} V_k^T C_{\text{target}}^T$.

Nyström 方法的时间复杂度是 $O(nck + c^2k)$, 其中 $V_k^T C^T$ 的复杂度是 $O(nck)$, $O(c^2k)$ 是特征值分解的复杂度. 应当注意, 在所提方法中虚样本计算是唯一需要计算核矩阵的部分 (详见第 2.3 节), 相比于传统核方法在每次迭代中都计算核矩阵, 本文设计虚样本的处理方式减少了计算量.

2.3 虚样本和标签融合的结合方法

在第 2.2 节中计算得到的虚样本 F 包含了隐式高维映射所包含的数据的非线性结构, 因此, 可以直接用 F_{atlas} 代替 $\phi(AF_L)$, 用 F_{target} 代替 $\phi(AF_i)$, 将核标签融合方法中的高维样本替换为虚样本, 得到线性化核标签融合方法, 记为 LK + LF + AF.

在 LK + PB + AF 方法中, 权重计算公式可以写为

$$w(x_i, x_{s,j}) = \exp \frac{-\|F(x_i) - F(x_{s,j})\|_2^2}{h} \quad (19)$$

其中, $F(x_i)$ 和 $F(x_{s,j})$ 分别表示像素 x_i 和 $x_{s,j}$ 对应的虚样本. LK + SRC + AF 的目标函数可以写为

$$\hat{A} = \arg \min_A \frac{1}{2} \|F_{\text{target}} - F_{\text{atlas}}A\|_2^2 + \lambda_1 \|A\|_1 + \frac{\lambda_2}{2} \|A\|_2^2 \quad (20)$$

其中, F_{target} 和 $F_{\text{atlas}} \in \mathbf{R}^{k \times n}$ 分别代表特征空间中的目标虚样本和图谱虚样本集, 类似地, 适合于分割任务的 LK + DDL + AF 的优化目标可以改写为式 (21), 改写后的目标函数仍可以用原始优化方法, 如 OMP 和在线字典学习方法求解系数和字典.

$$\langle F_D, W, X \rangle = \arg \min_{F_D, W, X} \|F_{\text{atlas}} - F_D X\|_2^2 +$$

$$\lambda_1 \|H - WX\|_2^2 \quad \text{s.t.} \quad \|X\|_0 \leq T \quad (21)$$

上述结合策略的优点: 在线性化核方法中, 计算得到虚样本可以直接替代高维样本, 无需在优化算法中构造内积, 这一特点使其能够快速应用于不同的标签融合方法中. 由于避免了每次迭代中的核矩阵计算, 算法复杂度减少. 本文方法的流程如图 5 所示.

3 实验结果与分析

3.1 数据集和预处理

为了验证本文方法对脑 MRI 中的深层脑结构的分割效果, 使用 IBSR, Hammers67n20 和 SATA MICCAI 2013 Challenge Dataset 这三种数据集进行验证, 各数据集的基本信息如表 1 所示.

本文方法用于分割 6 种深层脑结构, 包括丘脑、壳核、尾状核、苍白球、海马和杏仁核, 如图 6 所示 (以 IBSR 中的第 2 组图像为例). 每种脑结构分为左右两个区域, 分别位于大脑的左右半球.

本文用 3D slicer 通过仿射变换进行图像配准. 在成像过程中有可能产生相同脑结构的灰度不一致现象, 灰度规范化能够减少灰度不一致性, 保留具有诊断意义的灰度差别. 故在图像配准之后, 首先进行灰度规范化, 规范化范围为 $[0, 255]$, 计算方法为

$$y = \frac{(x - x_{\min}) \times 255}{x_{\max} - x_{\min}}$$

其中, x 表示规范化前的像素值, x_{\min} 和 x_{\max} 分别表示规范化前图像的最小和最大像素值, 表示规范化后得到的像素值. 本文分割准确性的评价指标使用 Dice 系数, 定义为

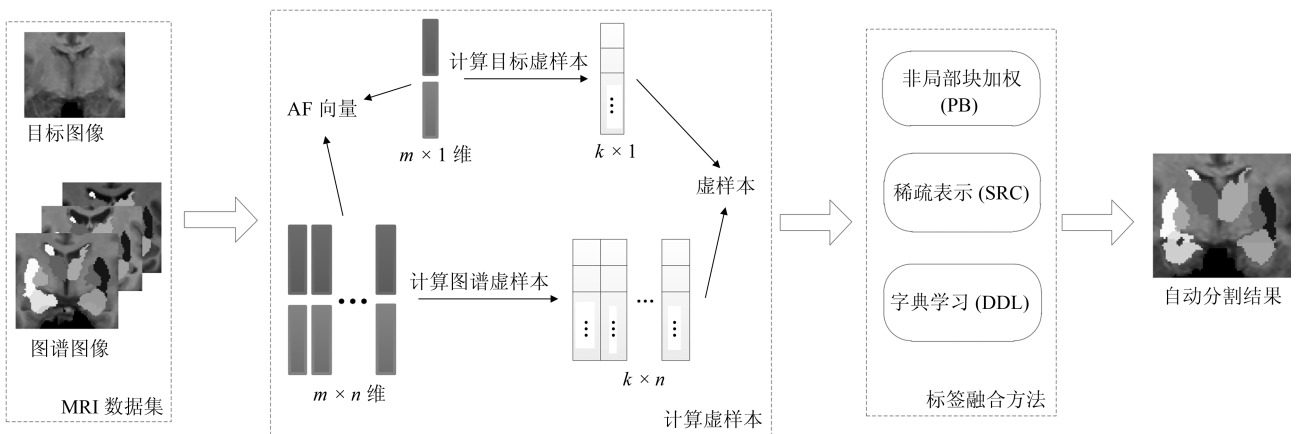


图 5 线性化核标签融合算法的整体流程

Fig. 5 Process of linearized kernel-based label fusion method

表 1 数据集基本信息
Table 1 Information of each dataset

数据集	个体数	年龄	类别数	尺寸	分辨率 (mm)
IBSR	18	7~71	32	256 × 256 × 128	0.94 × 0.94 × 1.5 和 0.84 × 0.84 × 1.5
Hammers67n	20	20~54	67	192 × 256 × 124	0.937 × 0.937 × 1.5
SATA	35	—	14	256 × 256 × 287	1.0 × 1.0 × 1.0




图 6 IBSR 中的六种脑结构 (以第 2 组为例)
Fig. 6 Six structures in IBSR dataset
(The second subject)

$$Dice = \frac{2 \times V(S \cap G)}{V(S) + V(G)}$$

其中, S 为手动分割结果, G 为自动分割结果, 即方法分割结果, $V(\cdot)$ 代表像素点数目.

3.2 标签融合方法基本参数设置

本节主要分析: 标签融合中常见的参数对分割结果的影响, 包括图谱数目、图像块大小和搜索邻域大小, 从而确定后续实验中的固定参数. 本节采用留一法, 将 IBSR 数据集中的 18 组图像分为图谱集和目标, 随机选择 1 组图像作为目标图像, 剩下的 17 组作为图谱图像, 不重复选取 17 次, 平均 Dice 最高时的参数取值为最优值. 以 IBSR 为例, 图 7 所示为图谱数目对分割结果的影响, 由于图谱数目小于 3 时, 分割结果较差, 因此本文研究的图谱数目为 3~17 个. 本文将图谱图像和目标图像按照文献 [8] 中的平方差和 (Sum of the squared difference, SSD) 方法计算相似性, 按照相似性从高到低依次排列, 选前 k ($k = 1, \dots, 17$) 个图谱用于分割.

由图 7 可知, 当图谱数目是 9~12 时, 每种脑结构的 Dice 值均较高且稳定. 当图谱数目少时, 有限的样本中只包括一小部分的信息, 很难对目标进行准确的重构, 而图谱数目较多时, 图谱特征向量库中的信息冗余, 不能很好地重构目标. 故当图谱数目为 9~12 时, 分割效果最好.

下面考虑搜索邻域对分割准确率的影响, 以苍白球为例, 搜索邻域对 LK + SRC 的影响如图 8 所示, 文献 [8] 在计算权重之前, 先对搜索邻域内的图谱像素依据相似性进行选择. 本文尝试了两种策略,

选择或者不选择相似图谱向量. 实线表示未在搜索邻域内选择和目标向量相似的图谱向量的情况, 虚线表示在搜索邻域内选择和目标向量相似的图谱向量的情况. 最优搜索邻域大小和解剖结构上的变化有关, 解剖结构变化明显, 则应选择较大的搜索邻域. 由于苍白球体积小, 解剖结构变化不明显, 所以在搜索邻域较小, 取 $3 \times 3 \times 3$ 时有最高的分割准确率. 不选择相似图谱向量时, Dice 值较高, 原因在于, 对于 LK + SRC 算法, 预定义字典中的样本最好来自于不同的类别, 这样才能得到比较准确的表示结果, 但是耗时较长. 而选择相似的图谱向量会导致预定义字典中的样本类别不平衡, 使其表示能力降低, 但由于样本少, 所以计算速度快. 本文采用不选择相




图 7 各脑结构分割准确率随图谱数目变化趋势
Fig. 7 Dice value of each structure with different atlas numbers

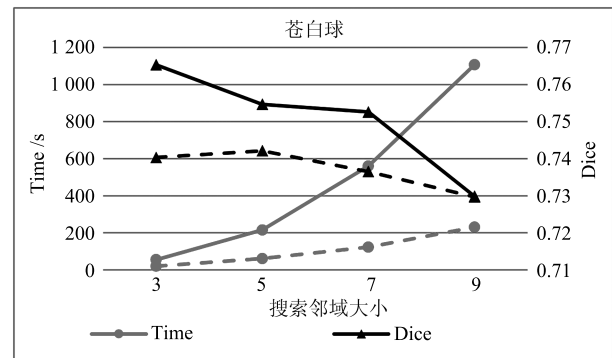


图 8 搜索邻域大小对 LK + SRC 的影响
Fig. 8 Impact of search volume size on LK + SRC

似图谱向量的策略.

下面以壳核为例, 分析图像块大小对分割结果的影响, 如图 9 所示. 图像块大小与解剖结构的复杂度相关, 当灰度值的判别性较差的时候, 应选择较大的图像块尺寸. 由图 6 可知, 壳核灰度判别性较好, 所以图像块大小为 $13 \times 13 \times 13$ 时, 分割结果最好. 综合考虑方法执行时间和准确率, 本文后续实验的搜索邻域选择为 $3 \times 3 \times 3$, 图像块大小为 $5 \times 5 \times 5$, 图谱数目选择 9.




图 9 图像块大小对 LK + SRC 的影响

Fig. 9 Impact of image patch size on LK + SRC

3.3 核方法的参数设置


本文通过 Nyström 方法对核矩阵进行低秩估计, Nyström 方法中的采样率和采样方法对分割结果均有影响. 本文尝试了多种采样方法, 包括: Uniform^[30], Kmeans^[37], Coreset^[38], Colnorm^[28], Diagonal^[39]. 由图 10 可以得知, 在采样率固定不变时, 不同采样方法对分割结果有一定的影响, Kmeans 采样方法效果最好. 由图 10(b) 所示, 对于 LK + SRC 来说, 随着采样率的变化, 分割准确率提高不超过 3%, 变化不明显. 导致这一结果的原因在于, 图谱特征向量数目较多而其包含的信息较单一.

核函数的选择对分割同样有一定的影响, 不同的核函数表示不同的特征映射方法和不同的相似度计算方法. 常用的核函数包括高斯核函数: $k(x, y) = e^{(-\|x-y\|^2/2\sigma^2)}$, 多项式核函数: $k(x, y) = (\langle x, y \rangle + R)^d$. 图 11 所示为不同参数和不同核函数对脑结构分割的影响, 以 LK + SRC 为例. 固定 R 为 0, 分析 σ 和 d 的影响, d 越大, 分割结果越好, σ 趋势相反. 从实验结果中可以得出结论, 当 σ 取 0.3 时, Dice 值最高.

3.4 增强特征对分割结果的影响

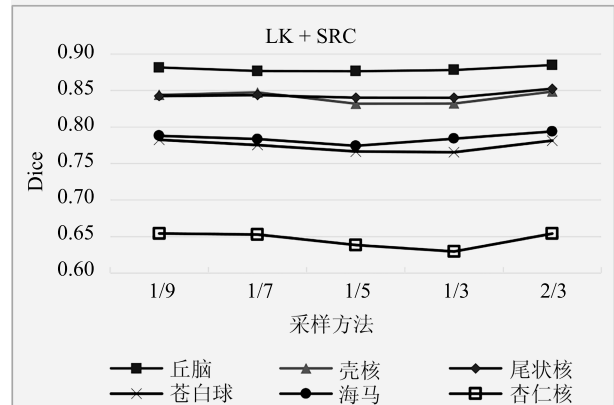
本节实验验证了基于增强特征的标签融合方法 (LF + AF) 的优势, 图 12 所示为灰度特征, LBP 特征和 AF 对 SRC 方法的影响. 可以看出, 针对 SRC,

除丘脑外, LBP 特征和 AF 均优于灰度特征.



(a) 不同采样方法的影响

(a) Impact of sample method size on LK + SRC



(b) 不同采样率的影响


(b) Impact of sample ratio size on LK + SRC

图 10 采样对 LK + SRC 的影响


Fig. 10 Impact of sample on LK + SRC

3.5 线性化核标签融合方法结果

本节用多个数据集来验证本文方法 (LK + LF + AF) 的有效性, 用于对比的基准方法为基于增强特征的标签融合分割方法 (LF + AF), 包括: PB + AF、SRC + AF 和 DDL + AF. 表 2 所示为 LK + LF + AF 方法在 IBSR 数据集和不同多图谱方法上的分割准确率. 加粗标记的 Dice 值为同一多图谱融合方法框架下的最高准确率. 对于 IBSR 数据集, LK + PB + AF 提高了 0.5% ~ 9.1%. LK + SRC + AF 提高了 3.4% ~ 10.4%. LK + DDL + AF 提高了 0.1% ~ 0.9%, 在杏仁核上略有下降. 本文所提的 LK 方法在 PB + AF 和 SRC + AF 上有较明显的提高, 原因在于映射后形成的虚样本捕获了像素灰度值的非线性结构, 增强了样本的判别性, 使得 PB + AF 中的相似度计算和 SRC + AF 中的线性表示更加准确. 而 LK 方法对 DDL + AF 的 Dice 值提高有限, 因为 DDL + AF 方法同时更新字



(a) 高斯函数参数对分割的影响
(a) Impact of Gaussian function on LK + SRC



(b) 多项式函数参数对分割的影响
(b) Impact of polynomial function on LK + SRC

图 11 核函数参数对分割结果的影响
Fig. 11 Impact of kernel on LK + SRC

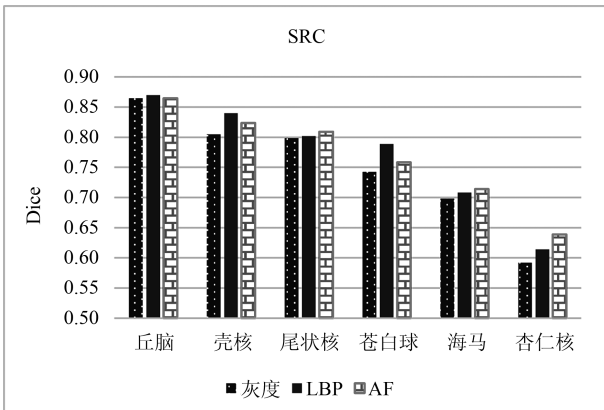


图 12 不同图像特征对分割结果的影响 (AF 为本文所提的增强特征方法)
Fig. 12 Impact of different features on segmentation result. AF is the proposed method

典 D 和分类器 W , W 中的参数适应于字典元素. 当分别用 AF 和虚样本表示像素时, 学习到不同的分类器, 在 DDL + AF 中, 分类器决定分类结果, 如式 (9). 虽然依赖于原始特征无法学到判别性强的

字典, 但是分类器在一定程度上弥补了字典的弱判别性, 所以 DDL + AF 方法对样本判别信息的依赖比 SRC + AF 和 PB + AF 小, 虚样本和增强特征虽然所含信息不同, 但其对 DDL + AF 的影响不明显, 故 LK 方法在 DDL + AF 上提高有限. 然而 LK + DDL + AF 方法同样取得了很高的 Dice 值, 且易于实现, 说明通过 LK 方法计算得到的虚样本可以适用于多种标签融合方法. 表 3 所示为 LK + LF + AF 方法在 Hammers67n20 数据集上的分割结果. LK + PB + AF 方法分割尾状核的 Dice 提高了 5.1%. 图 13 所示为 IBSR 数据集中三维脑 MRI 中的第 67 层, 图 13 (a) 为第 16 组的原脑 MRI 和 6 种脑结构的标签图像, 图 13 (b) 第 1 行是 PB 方法, 第 2 行是 DDL 方法, 图 13 (c) 第 1 行是 LK + PB 方法, 第 2 行是 LK + DDL 方法, 图 13 (d) 第 1 行是 PB + AF 方法, 第 2 行是 DDL + AF 方法, 图 13 (e) 第 1 行是 LK + PB + AF 方法, 第 2 行是 LK + DDL + AF 方法. PB 方法对脑结构的分割结果有不连续的现象, 比如结构内部出现空洞, 且分割出的脑结构形态和体积与标签图像有一定差距. 而应用核方法之后的脑结构分割结果在形态上和标签图像相似, LK + LF + AF 方法分割结果不仅形态上与标签图像相似, 而且结构内部不存在空洞, 分割结果连续. 图 14 所示为各个脑结构的三维分割结果, 以 SRC 为例, 作为比较基准的 SRC 方法, 其脑结构分割结果在边界处, 与 LK + SRC 方法相比更加粗糙. LK + SRC + AF 方法的分割结果在边界处比较平滑, 和标签图像相似. 图 15 所示为用 AF 表示像素时, 线性化核标签融合的分割准确率. 对不同脑结构进行分割的实验结果表明, 在固定像素表示方法时, LK + LF 方法和原始的标签融合 (LF) 方法相比, Dice 值有所提高. 虚线是加核前后的 Dice 差值, 从图中可以看出各方法对 Dice 值的提高程度, LK 方法针对 PB + AF 和 SRC + AF 有较明显的提高.

接下来分析 LF、kernel + LF 和 LK + LF + AF 方法的计算时间. 图 16 所示为标签融合、核标签融合和线性化核标签融合方法在计算时间上的对比. 结合第 2.2 节中的分析, LF 方法计算速度最快, 因为无需计算核矩阵, LK + LF 方法只需要在计算虚样本的时候计算一次核矩阵, 所以计算时间和 LF 相比, 略有增加, 而核标签融合方法在每次迭代更新系数时, 都涉及到核矩阵的计算, 所消耗的计算时间最长. 故本文所提 LK + LF + AF 方法和传统核方法比, 提高了计算速度.

3.6 和现有方法对比

近年来, 深度学习方法在脑 MRI 分割中取得了

表 2 LK 方法在 IBSR 上的 Dice 值, 加粗的 Dice 值为同种 LF + AF 方法中的最高值

Table 2 Dice value of LK method on IBSR. Blue bolds show the maximum in the same LF + AF method

	方法	丘脑	壳核	尾状核	苍白球	海马	杏仁核	平均
PB + AF	无 LK	0.885	0.802	0.807	0.746	0.811	0.688	0.790
	有 LK	0.899	0.881	0.886	0.837	0.816	0.743	0.844
SRC + AF	无 LK	0.864	0.823	0.809	0.758	0.714	0.639	0.768
	有 LK	0.898	0.883	0.866	0.831	0.818	0.678	0.829
DDL + AF	无 LK	0.902	0.892	0.882	0.851	0.830	0.695	0.842
	有 LK	0.905	0.898	0.883	0.854	0.839	0.678	0.843

表 3 LK 方法在 Hammers67n20 上的 Dice 值, 加粗的 Dice 值为每种 LF + AF 方法中的最高值

Table 3 Dice value of LK method on Hammers67n20. Blue bolds show the maximum in the same LF + AF method

	方法	丘脑	壳核	尾状核	苍白球	海马	杏仁核	平均
PB + AF	无 LK	0.844	0.849	0.838	0.762	0.799	0.825	0.820
	有 LK	0.879	0.890	0.889	0.811	0.831	0.868	0.861
SRC + AF	无 LK	0.862	0.859	0.852	0.748	0.793	0.802	0.819
	有 LK	0.887	0.885	0.893	0.792	0.842	0.839	0.856
DDL + AF	无 LK	0.875	0.882	0.870	0.789	0.812	0.860	0.848
	有 LK	0.892	0.891	0.875	0.802	0.830	0.857	0.858




图 13 深层脑结构分割二维结果 (黑色加粗的方法为本文所提方法)

Fig. 13 2D results of subcortical brain structures (Black bolds show the proposed method)

较好的应用, 针对 IBSR 数据集, 将本文方法和深度学习方法进行比较, 对比方法包括: MS-CNN^[6]、BrainSegNet^[7]、FCNN^[8]、M-net^[9] 和 Dolz 提出的 3D FCNN^[10]. 在相关文献中, FCNN 和 Dolz 提出的 3D FCNN 方法只针对较大的结构

进行分割, 没有海马和杏仁核的分割结果, 因此本文没有进行对比. 另外本文所提方法也和常用的分割软件, 如 FIRST 和 FreeSurfer 进行了比较. 表 4 所示为各方法的 Dice 值, 本文方法的平均 Dice 值为 0.844, 与 FIRST、FreeSurfer 相比较, FreeSurfer




图 14 深层脑结构分割三维结果 (其中, (e) 为本文所提方法)
Fig. 14 3D results of subcortical brain structures ((e) show the proposed method)

在大部分脑结构上表现较差, 而 FIRST 和本文方法相差不多. 本文方法在各个脑结构的 Dice 值上都高于 MS-CNN 和 FCNN 方法, BrainSegNet 方法的平均 Dice 值为 0.842, M-net 的平均 Dice 值为 0.84, 和本文方法比较相近, 但是 BrainSegNet 和 M-net 在除了壳核以外的其他结构上的 Dice 值均低于本文方法. Dolz 提出的 3D FCNN 方法在 4 种脑结构上的分割 Dice 值为 0.89, 本文方法在同样的 4 种结构上的平均 Dice 值为 0.885. 可以看出, 本文所提方法与深度学习相比具有竞争力, 虽然在精度上 (平均 Dice 值) 3D FCNN 略高于本文所提方法, 但应注意到, 该方法只能有效分割 4 种脑结构, 而本

文方法在 6 种结构上都可达到满意的分割效果, 且对硬件计算资源要求远低于深度学习方法.

4 讨论

像素的纹理特征和灰度特征相结合形成增强特征. 为了使特征线性相关, 将核方法引入标签融合中, 将原始特征映射到高维空间中. 然而, 将核方法应用于标签融合方法会产生较大的计算负担. 考虑核方法的时间消耗和较困难的内积构造过程, 本文引入 Nyström 方法对核矩阵进行估计后再分解, 形成虚样本, 将虚样本和标签融合方法相结合, 提出线性化核标签融合方法.

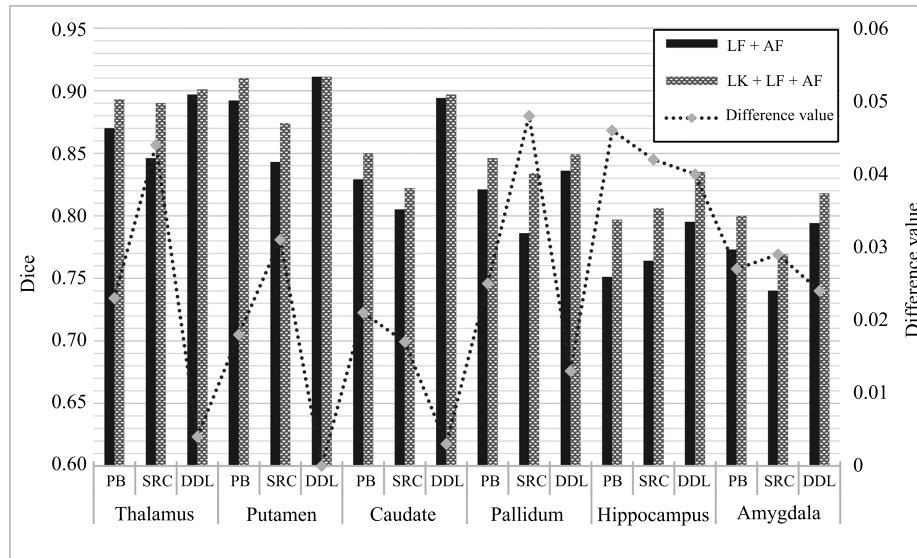


图 15 线性化核标签融合方法在 SATA 数据集上的分割准确率

Fig. 15 Dice value of linearized kernel-based label fusion method on SATA dataset

表 4 本文方法和现有脑结构分割方法在 IBSR 数据集上的结果, 评价指标 Dice

Table 4 Results compared with existing brain structure segmentation method, measured with Dice

	FIRST	FreeSurfer	MS-CNN	BrainSegNet	FCNN	M-net	Dolz	本文方法
丘脑	0.889	0.840	0.889	0.89	0.87	0.90	0.92	0.905
壳核	0.875	0.809	0.875	0.91	0.83	0.90	0.90	0.898
尾状核	0.827	0.803	0.849	0.87	0.78	0.87	0.91	0.886
苍白球	0.810	0.703	0.787	0.82	0.75	0.82	0.83	0.854
海马	0.811	0.764	0.788	0.82	—	0.82	—	0.839
杏仁核	0.750	0.589	0.654	0.74	—	0.73	—	0.743
平均	0.827	0.751	0.807	0.842	0.808	0.84	0.89	0.844

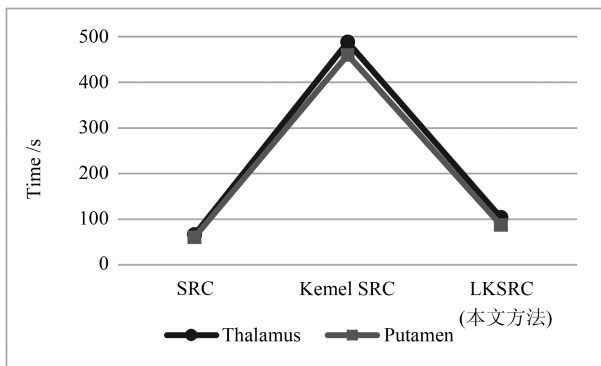


图 16 各方法消耗时间对比

Fig. 16 Computational complexity

虽然本文所提线性化核标签融合方法在深层脑结构分割上取得了很好的效果, 但是仍存在几点需要注意的问题: 1) 第 3.4 节对增强特征的作用进行了讨论, 实验结果表明, 对于 PB 方法, LBP 和灰

度特征的效果不稳定, 原因在于脑 MRI 中各个脑结构的灰度特性有所不同, LBP 图像无法很好地表示解剖结构变化不明显的区域. 在 PB 方法中, 单纯使用灰度特征或 LBP 特征得到的分割结果不稳定, 而 AF 的结果均优于灰度特征, 因此本文将两者结合形成增强特征, 用于保证结果的稳定. 而其他特征也可以用于本文算法, 探索其他更加有效的图像特征也是今后值得研究的问题; 2) 第 3.5 节实验结果表明, LK + PB + AF、LK + SRC + AF 和 LK + DDL + AF 方法均取得了较高的准确率, 可以得出, LK 方法中的虚样本可以用于各种标签融合方法, 推测 LK 方法也可以适用于其他学习算法, LK 方法的更多适用范围是今后可以探索的工作; 3) 第 3.2 节所讨论的搜索邻域和图像块大小对 LK + SRC 方法有比较明显的影响, 搜索邻域大小和结构的解剖变化相关, 对于解剖结构变化不明显且体积较小的结构来说, 适合较小的搜索邻域. 图像块大小和解剖结

构的复杂性相关, 针对灰度值判别性小的结构来说, 应该选取较大的图像块, 较大的图像块能够捕获到局部的几何结构, 若选择较小的图像块, 则会使分割结果中产生空洞. 针对不同结构, 最优的搜索邻域和图像块大小不同, 需要依据经验和已有知识进行参数设置. 标签融合方法本身对参数有一定的依赖, 本文分析了参数选择的规律, 然而如何使分割结果较少的依赖于参数的选取, 是未来可以研究的问题; 4) 本文方法和传统标签融合方法相比, 除了第 3.2 节分析的三个基本参数, 还另外涉及到核方法中的参数, 包括: 核函数, 核函数参数, Nyström 方法中涉及到的采样方法和采样率. 在基本参数取值相同时, 不同的核参数影响 LK + LF + AF 方法的分割准确率, 故影响方法准确性的因素较多, 导致方法在不同数据集上的稳定性不如传统多图谱方法. 分析各个参数取值的规律是未来需要研究的问题.


5 结束语

本文引入增强特征对像素进行表示, 并提出了基于线性化核标签融合的深层脑结构分割方法. 实验结果表明, 增强特征和灰度特征相比, 可以提高标签融合方法的分割准确率. 本文分析了图谱数目、搜索邻域、图像块大小、不同核函数、核函数参数、Nyström 方法中涉及到的采样方法和采样率的取值对所提方法的影响. 在三个数据集上的 6 种深层脑结构的分割结果表明了本文所提方法的有效性. LK + LF + AF 方法不仅可以提高原始标签融合方法的分割准确率, 和传统核方法相比, 还减少了计算时间, 和深度学习方法相比, 本文方法也有较好的结果. MRI 中的一些目标区域对比度低, 可通过对原始特征进行映射的方法区分各个像素, 故本文所提 LK + LF + AF 方法可以应用于其他 MRI 分割问题上, 如脑组织分割、脑皮层结构分割、肿瘤分割等, 还可以应用于其他类型的医学图像分割.

References

- Goodro M, Sameti M, Patenaude B, Fein G. Age effect on subcortical structures in healthy adults. *Psychiatry Research: Neuroimaging*, 2012, **203**(1): 38–45
- Kim M J, Hamilton J P, Gotlib I H. Reduced caudate gray matter volume in women with major depressive disorder. *Psychiatry Research: Neuroimaging*, 2008, **164**(2): 114–122
- Rangini M, Jiji G W. Detection of Alzheimer's disease through automated hippocampal segmentation. In: Proceedings of the 2013 Automation, Computing, Communication, Control and Compressed Sensing. Kottayam, India: IEEE, 2013. 144–149
- Fischl B. FreeSurfer. *Neuroimage*, 2012, **62**(2): 774–781
- Patenaude B, Smith S M, Kennedy D N, Jenkinson M. A Bayesian model of shape and appearance for subcortical brain segmentation. *Neuroimage*, 2011, **56**(3): 907–922
- Bao S Q, Chung A C S. Multi-scale structured CNN with label consistency for brain MR image segmentation. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging and Visualization*, 2018, **6**(1): 113–117
- Mehta R, Majumdar A, Sivaswamy J. BrainSegNet: a convolutional neural network architecture for automated segmentation of human brain structures. *Journal of Medical Imaging*, 2017, **4**(2): 024003
- Shakeri M, Tsogkas S, Ferrante E. Sub-cortical brain structure segmentation using F-CNN's. In: Processings of the 13th International Symposium on Biomedical Imaging. Prague, Czech Republic: IEEE, 2016. 269–272
- Mehta R, Sivaswamy J. M-net: a convolutional neural network for deep brain structure segmentation. In: Processings of the 14th International Symposium on Biomedical Imaging. Melbourne, Australia: IEEE, 2017. 437–440
- Dolz J, Desrosiers C, Ayed I B. 3D fully convolutional networks for subcortical segmentation in MRI: a large-scale study. *NeuroImage*, 2017, **170**(2018): 456–470
- Shen D G, Moffat S, Resnick S M, Davatzikos C. Measuring size and shape of the hippocampus in MR images using a deformable shape model. *NeuroImage*, 2002, **15**(2): 422–434
- Wu G R, Kim M, Sanroma G, Wang Q, Munsell B C, Shen D G. Hierarchical multi-atlas label fusion with multi-scale feature representation and label-specific patch partition. *NeuroImage*, 2017, **170**(2018): 456–470
- Tian Juan-Xiu, Liu Guo-Cai, Gu Shan-Shan, Jv Zhong-Jian, Liu Jin-Guang, Gu Dong-Dong. Deep learning in medical image analysis and its challenges. *Acta Automatica Sinica*, 2018, **44**(3): 401–424
(田娟秀, 刘国才, 谷珊珊, 鞠忠建, 刘劲光, 顾冬冬. 医学图像分析深度学习方法研究与挑战. *自动化学报*, 2018, **44**(3): 401–424)
- Babalola K O, Patenaude B, Aljabar P, Schnabel J, Kennedy D, Crum W. An evaluation of four automatic methods of segmenting the subcortical structures in the brain. *Neuroimage*, 2009, **47**(4): 1435–1447
- González-Villám S, Oliver A, Valverde S, Wang L P, Zwigelaar R, Lladó X. A review on brain structures segmentation in magnetic resonance imaging. *Artificial Intelligence in Medicine*, 2016, **73**(2016): 45–69
- Coupé P, Manjón J V, Fonov V, Pruessner J, Robles M, Collins D L. Patch-based segmentation using expert priors: application to hippocampus and ventricle segmentation. *Neuroimage*, 2011, **54**(2): 940–954
- Rousseau F, Habas P A, Studholme C. A supervised patch-based approach for human brain labeling. *IEEE Transactions on Medical Imaging*, 2011, **30**(10): 1852–1862
- Eskildsen S F, Coupé P, Fonov V, Manjón J V, Leung K K, Guizard N. BEaST: brain extraction based on nonlocal segmentation technique. *Neuroimage*, 2012, **59**(3): 2362–2373
- Golts A, Elad M. Linearized kernel dictionary learning. *IEEE Journal of Selected Topics in Signal Processing*, 2016, **10**(4): 726–739.
- Li Y H, Jia F C, Qin J. Brain tumor segmentation from multimodal magnetic resonance images via sparse representation. *Artificial Intelligence in Medicine*, 2016, **73**(2016): 1–13

- 21 Tong T, Wolz R, Coupé P, Hajnal J V, Rueckert D. Segmentation of MR images via discriminative dictionary learning and sparse coding: application to hippocampus labeling. *Neuroimage*, 2013, **76**(1): 11–23
- 22 Bai W J, Shi W Z, Ledig C, Rueckert D. Multi-atlas segmentation with augmented features for cardiac MR images. *Medical Image Analysis*, 2015, **19**(1): 98–109
- 23 Vapnik V N. The nature of statistical learning theory. *Technometrics*, 1997, **38**(4): 409–409
- 24 Smola A J. Kernel principal component analysis. In: *Processings of the 1997 International Conference on Artificial Neural Networks*. Springer-Verlag, 1997: 583–588
- 25 Vincent P, Bengio Y. Kernel matching pursuit. *Machine Learning*, 2002, **48**(1–3): 165–187
- 26 Guigue V, Rakotomamonjy A, Canu S. Kernel basis pursuit. In: *Processings of the 2005 European Conference on Machine Learning*. Berlin, Heidelberg, Germany: Springer, 2005. 146–157
- 27 Nguyen H V, Patel V M, Nasrabadi N M, Chellappa R. Kernel dictionary learning. In: *Processings of the 2012 International Conference on Acoustics, Speech, and Signal Processing*. Kyoto, Japan: IEEE, 2012. 2021–2024
- 28 Drineas P, Kannan R, Mahoney M W. Fast Monte Carlo algorithms for matrices I: approximating matrix multiplication. *SIAM Journal on Computing*, 2006, **36**(1): 132–157
- 29 Lee J, Kim S J, Chen R, Herskovits E H. Brain tumor image segmentation using kernel dictionary learning. In: *Processings of the 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Milan, Italy: IEEE, 2015. 658–661
- 30 Williams C K I, Seeger M. Using the Nyström method to speed up kernel machines. In: *Processings of the 2001 Advances in Neural Information Processing Systems*. 2001. 682–688
- 31 Schnabel J A, Rueckert D, Quist M, Blackall J M, Castellano-Smith A D, Hartkens T. Design of non-linear discriminative dictionaries for image classification. In: *Processings of the 2001 International Conference on Medical Image Computing and Computer-Assisted Intervention*. Berlin, Heidelberg, Germany: Springer, 2001. 573–581
- 32 Ashburner J, Friston K J. Nonlinear spatial normalization using basis functions. *Human Brain Mapping*, 2015, **7**(4): 254–266
- 33 Wang H Z, Yushkevich P A. Dependency prior for multi-atlas label fusion. In: *Processings of the 9th IEEE International Symposium on Biomedical Imaging*. Barcelona, Spain: IEEE, 2012. 892–895
- 34 Mairal J, Bach F, Ponce J. Online dictionary learning for sparse coding. In: *Processings of the 2009 International Conference on Machine Learning*. Montreal, Canada: IEEE, 2009. 689–696
- 35 Ojala T, Pietikäinen M, Mäenpää T. Gray scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, **24**(7): 971–987
- 36 Ghorbani M, Targhi A T, Dehshibi M M. HOG and LBP: towards a robust face recognition system. In: *Processings of the 10th International Conference on Digital Information Management*. Jeju, Korea: IEEE, 2016. 138–141
- 37 Zhang K, Tsang I W, Kwok J T. Improved Nyström low-rank approximation and error analysis. In: *Processings of the 25th International Conference on Machine Learning*. Helsinki, Finland: ACM, 2008. 1232–1239
- 38 Feldman D, Feigin M, Sochen N. Learning big (image) data via coresets for dictionaries. *Journal of Mathematical Imaging and Vision*, 2013, **46**(3): 276–291
- 39 Drineas P, Mahoney M W. On the Nyström method for approximating a gram matrix for improved kernel-based learning. *Journal of Machine Learning Research*, 2005, **6**(12): 2153–2175



刘悦 东北大学信息科学与工程学院博士研究生. 主要研究方向为图像处理, 计算机视觉与模式识别.
E-mail: 18512478164@163.com
(LIU Yue Ph.D. candidate at the College of Information Science and Engineering, Northeastern University. Her research interest covers image processing, computer vision, and pattern recognition.)



魏颖 东北大学信息科学与工程学院教授. 主要研究方向为图像处理与模式识别, 医学影像计算与分析, 计算机辅助诊断, 计算机视觉. 本文通信作者.
E-mail: weiying@ise.neu.edu.cn
(WEI Ying Professor at the College of Information Science and Engineering, Northeastern University. Her research interest covers image processing and pattern recognition, medical image computation and analysis, computer-aided diagnosis, and computer vision. Corresponding author of this paper.)



贾晓甜 东北大学信息科学与工程学院模式识别与智能系统专业硕士研究生. 主要研究方向为模式识别与图像处理.
E-mail: jxt.neu@163.com
(JIA Xiao-Tian Master student of science in pattern recognition and intelligent systems at the College of Information Science and Engineering, Northeastern University. Her research interest covers pattern recognition and image processing.)



王楚媛 东北大学信息科学与工程学院模式识别与智能系统专业硕士研究生. 主要研究方向为模式识别与图像处理.
E-mail: wangchuyuan0718@163.com
(WANG Chu-Yuan Master student of Science in Pattern Recognition and Intelligent Systems at the College of Information Science and Engineering, Northeastern University. Her research interest covers pattern recognition and image processing.)