

基于张量子空间的半脑对称度特征与癫痫识别

姜慧研¹, 刘若楠², 高菲菲², 苗宇¹
(1. 东北大学 软件学院, 辽宁 沈阳 110169; 2. 东北大学 中荷生物医学与信息工程学院, 辽宁 沈阳 110169)

摘 要: 结合脑 PET 图像信息, 提出了一种基于张量子空间的半脑对称度特征的识别方法用于识别 PET 图像中癫痫病灶. 首先计算全部脑 PET 图像中所有体素的 SUV, 并基于 SUV 建立三阶张量; 然后提取半脑对称度特征, 建立半脑对称度张量模型; 其次利用多线性主成分分析(MPCA)方法对半脑对称度张量模型进行特征选择; 最后基于支持向量机(SVM)分类器进行癫痫识别. 实验结果表明: 提出的算法能够有效地识别脑 PET 图像中的癫痫病灶, 可以作为计算机辅助诊断方式帮助医生进行癫痫疾病的诊断.

关 键 词: 癫痫; 张量; PET; 多线性主成分分析; 支持向量机

中图分类号: TP 391.4 文献标志码: A 文章编号: 1005-3026(2017)07-0923-05

Hemisphere Symmetry Feature Based on Tensor Space and Recognition of Epilepsy

JIANG Hui-yan¹, LIU Ruo-nan², GAO Fei-fei², MIAO Yu¹
(1. School of Software, Northeastern University, Shenyang 110169, China; 2. School of Sino-Dutch Biomedical and Information Engineering, Northeastern University, Shenyang 110169, China. Corresponding author: JIANG Hui-yan, E-mail: hyjiang@mail.neu.edu.cn)

Abstract: With brain PET (positron emission tomography) image information, a recognition method based on hemisphere symmetry feature of tensor space was proposed to identify the epilepsy lesions of PET (positron emission tomography) images. Firstly, the SUV (standard uptake value) of each voxel in brain PET images was calculated and the third order tensor based on SUV was constructed. Then, the hemisphere symmetry feature was extracted and the hemisphere symmetry tensor model was built. Next, a multi linear principal component analysis (MPCA) algorithm was used for feature selection of hemisphere symmetry tensor model. Lastly, the support vector machine (SVM) was used to identify the epilepsy. The results show that the epilepsy lesions of the brain PET images can be effectively identified by the proposed algorithm, which can be used as a computer aided diagnosis way to help doctors with epilepsy disease diagnosis.

Key words: epilepsy; tensor; PET (positron emission tomography); multi-linear principal component analysis; support vector machine

¹⁸F-氟代脱氧葡萄糖(¹⁸F-FDG) PET (positron emission tomography) 图像是通过在体内静脉注入¹⁸F-FDG 后获得脑细胞的葡萄糖代谢的功能图像(FDG-PET), 能够比血流更直接地反映脑神经活动, 在脑神经疾病“癫痫”的临床检查中受到医生的青睐.

临床判定 PET 图像癫痫病灶的主要方法包括目测法和半定量分析^[1]. 医生通过勾画来设定感兴趣区域(ROI), 然后测定 ROI 的 SUV (standard uptake value)^[1]来对图像进行诊断. 其中 SUV 是反映葡萄糖代谢状态的半定量指标, 表示局部组织摄取的显像剂的放射性活度. 但是设定 ROI 区域需要大量的工作, 并且受主观性影响导致诊断结果的不确定性. 相反, 全脑数据的研究不需要预先选择空间体素, 这就使其具有更高的准确性和更低的偏差^[2]. 近年来许多基于全脑的

分类研究都得到了较为理想的结果^[3-4]. Song 等^[5]提出了一种对全脑 fMRI 图像基于张量特征学习进行词汇反应的分类,得到了很好的效果.

受文献[5]的启发,本文将全脑体素的 PET 数据用 3 阶张量进行表示,计算每个体素 SUV, 用 SUV 代替 PET 全脑体素并表示为张量形式^[6],解决了 ROI 设定的问题. 由于癫痫病灶通常具有不对称性,本文定义了一种新的半脑对称度特征,然后利用多线性主成分分析(MPCA)方法对半脑对称度张量模型进行特征选择,最后基于支持向量机(SVM)分类器进行癫痫识别.

1 PET - SUV 图像的张量表示

PET 图像本身是一种多维结构数据,张量是对这类数据自然而本质的表达方式. 与传统图像数据向量化的处理方式相比,张量这种数据表示方式可以更好地保留高维数据的内部结构和信息^[7]. 为了解决 PET 图像中 ROI 设定的问题,本文将左、右脑所有体素的 SUV 表示成张量形式^[8]. 即首先计算 PET 图像的所有体素的 SUV, 然后将 PET - SUV 图像按照对应体素的位置表示成 3 阶张量形式 $X_1, X_2, \dots, X_M \in \mathbf{R}^{I_1 \times I_2 \times I_3}$, 其中 M 是脑数据样本个数, I_1 是每一个样本 PET 图像的断层个数, I_2, I_3 分别是每个断层图像的水平、垂直分辨率.

2 癫痫特征的提取

2.1 半脑对称度特征的定义

比较癫痫患者与正常人的 PET 图像中的脑对称区域发现:癫痫患者位于癫痫病灶一侧的大脑半球的葡萄糖代谢通常存在异常,如图 1 的箭头所示^[1]. 在 PET 图像中,可以利用 SUV 的差异性表现葡萄糖代谢异常.

为了描述位于病灶一侧的大脑半球的葡萄糖代谢异常,本文在 PET - SUV 的断层图像上定义对称模板,并利用这个对称模板分别遍历每个断层图像上的左、右半脑对称区域,基于对称区域的 SUV 定义了半脑对称度特征.

构造对称模板及计算半脑对称度特征的方法如下:

①首先将 PET - SUV 的每个断层图像均匀划分成左区域(左脑区)和右区域(右脑区). 在左脑区及其中轴对称位置的右脑区分别设置 $n \times n$ 大小的模板,左、右脑对称模板如图 1 上方的 2 个

灰色框所示.

②使这两个对称模板(左脑模板、右脑模板)分别从 PET - SUV 图像的左上角和右上角出发,按照从外向内、从上到下的顺序进行遍历.

③在每个遍历位置 (i, j) 计算半脑对称度特征.

本文提出了一种半脑对称度特征,其计算公式为

$$S_{i,j} = \frac{|V_{L_{\max}} - V_{R_{\max}}| \bar{V}_{\text{all}}}{\bar{V}_{L+R}} \times 100\% . \quad (1)$$

其中: $S_{i,j}$ 是半脑对称度; i 与 j 分别为像素的横纵坐标, $i = 1, \dots, M, j = 1, \dots, (N/2 - n + 1), M \times N$ 为 PET - SUV 图像的大小, n 为模板的大小; $V_{L_{\max}}$ 与 $V_{R_{\max}}$ 分别是左、右脑模板内 SUV 的最大值; \bar{V}_{L+R} 是左、右脑模板两个区域内 SUV 的平均值; \bar{V}_{all} 是整个 PET - SUV 图像内 SUV 的平均值.




图 1 FDG - PET 图像颞叶代谢异常示意图
Fig. 1 Schematic diagram of FDG-PET temporal lobe metabolic abnormalities

2.2 基于 MPCA 的特征降维

由于是对全脑 PET 图像进行研究,需要对整个大脑的所有体像素的 SUV 进行计算. 计算得到的半脑对称度特征数量远远超过样本个数,将导致过拟合现象^[7],因此需要通过降低特征维数来选择适量的特征用于分类器分类.

主成分分析(principal component analysis, PCA)是最常用的线性特征降维的方法^[9]. 主成分分析的目的是将高维数据投影到较低维空间从而将一个多变量的复杂问题简化为低维空间的简单问题. 为了将 PCA 应用到全脑特征的降维,需要将所有特征集中在一个超高维的向量里,不适合处理小样本问题. 多线性主成分分析(multilinear principal component analysis, MPCA)^[10]是 PCA 在高维的延伸. 本文利用 MPCA 将张量(tensor)投影到向量,使运算在较低维子空间进行,因此处理高维数据时有低运算量的优势. 另外, MPCA 是一种无监督学习方法^[10],将高维空

间映射到低维空间并舍弃不重要的特征向量缩减维度。

将 3 阶张量 $\boldsymbol{X}_1, \boldsymbol{X}_2, \cdots, \boldsymbol{X}_M \in \mathbf{R}^{I_1 \times I_2 \times I_3}$ 作为 MPCA 的输入, M 是数据样本个数. 通过 3 个 ($n=3$) 投影矩阵 $\boldsymbol{U}^{(n)} \in \mathbf{R}^{I_n \times P_n}, n=1, 2, 3$ 提取出低维张量特征 $\boldsymbol{Y}_m = \boldsymbol{X}_m \times \boldsymbol{U}^{(1)\text{T}} \times \boldsymbol{U}^{(2)\text{T}} \times \boldsymbol{U}^{(3)\text{T}}, P_n < I_n$, 使张量的维数从 $I_1 \times I_2 \times I_3$ 减少到 $P_1 \times P_2 \times P_3$.

投影矩阵的计算方法为

$$\{\boldsymbol{U}^{(n)} \in \mathbf{R}^{I_n \times P_n}\}_{n=1}^N = \underset{\boldsymbol{U}^{(1)}, \cdots, \boldsymbol{U}^{(N)}}{\operatorname{argmax}} \psi_Y. \quad (2)$$

其中, $\psi_Y = \sum_{m=1}^M \|\boldsymbol{Y}_m - \bar{\boldsymbol{Y}}\|_F^2, \bar{\boldsymbol{Y}} = (1/M) \sum_{m=1}^M \boldsymbol{Y}_m$.

MPCA 将高维张量投影到低维张量, 且保持同样的顺序. 在实际应用中, 低维张量展开到对应向量中 $\boldsymbol{Y} \rightarrow \boldsymbol{y}$, 其中 $\{\boldsymbol{Y} \in \mathbf{R}^{P_1 \times P_2 \times P_3}, \boldsymbol{y} \in \mathbf{R}^{p_1 p_2 p_3}\}$ 中的元素根据方差进行排序^[9]. MPCA 实验的参数设置同文献[5].

3 癫痫分类模型的建立

首先基于 MPCA 对张量表示的 PET 图像的半脑对称度特征进行降维, 然后将其作为支持向量机 (support vector machine, SVM)^[11-12] 分类器的输入进行癫痫的分类, 步骤如下:

1) 输入 PET 图像, 计算所有体素的 SUV 并将其表示为 3 阶 PET 张量 $\boldsymbol{X}_1, \boldsymbol{X}_2, \cdots, \boldsymbol{X}_M \in \mathbf{R}^{I_1 \times I_2 \times I_3}, M$ 是训练样本个数.

2) 提取半脑对称度特征, 将其表示为张量形式 $\boldsymbol{X}_1^I, \boldsymbol{X}_2^I, \cdots, \boldsymbol{X}_M^I \in \mathbf{R}^{I_1^I \times I_2^I \times I_3^I}$, 其中 $I_3^I = I_3/2 - n + 1, n$ 为提取半脑对称度特征时所用模板大小.

3) 基于 MPCA 对张量 $\boldsymbol{X}_1^I, \boldsymbol{X}_2^I, \cdots, \boldsymbol{X}_M^I \in \mathbf{R}^{I_1^I \times I_2^I \times I_3^I}$ 进行降维, 得到特征向量组 $\{\boldsymbol{y}_1, \cdots, \boldsymbol{y}_m\}$.

4) 将 $\{\boldsymbol{y}_1, \cdots, \boldsymbol{y}_m\}$ 作为 SVM 分类器的输入, 建立癫痫分类模型, 并采用 3-fold 交叉验证进行分类, 输出识别准确率.

为了评价模型的性能, 基于式(3), 式(4), 式(5)分别计算样本的分类准确率 R_{AC} , 敏感性 R_{SP} 和特异性 R_{SE} .

$$R_{AC} = (\alpha_t + \beta_t) / (\alpha + \beta). \quad (3)$$

$$R_{SP} = \alpha_t / (\alpha_t + \beta_f). \quad (4)$$

$$R_{SE} = \beta_t / (\alpha_f + \beta_t). \quad (5)$$

其中: α 是测试集中正常脑样本个数; β 是癫痫脑样本个数; α_t 是正确识别正常脑样本个数; α_f 是错误识别正常脑样本个数; β_t 是正确识别癫痫脑样本个数; β_f 是错误识别癫痫脑样本个数.

4 实验结果与分析

为了验证本文方法的有效性, 分别选取 11 例癫痫、12 例正常脑 PET 图像作为实验数据. 患者进行 PET 扫描之前禁食 6 h 以上, 于安静状态下静脉注射¹⁸F-FDG. 安静平躺半小时后开始进行图像采集工作. 然后对采集到的 FDG-PET 图像进行标准化和高斯平滑处理, 得到 $128 \times 128 \times 35$ 的图像. 本文软件平台为 MATLAB 2014b.

实验中以 2×2 模板提取的半脑对称度特征为研究对象, 分别将基于 MPCA 与 PCA 降维后的特征输入 SVM 及 KNN (K -nearest neighbor)^[13] 分类器. 根据不同的特征选择方法以及不同的分类器构造出 4 种不同的分类模型, 即 MPCA-KNN, MPCA-SVM, PCA-KNN, PCA-SVM, 分别进行癫痫分类实验. 分类结果如表 1 所示.

表 1 PCA 及 MPCA 分类模型的癫痫分类准确率
Table 1 Epilepsy classification accuracy rate of PCA classification model and MPCA classification model %

| PCA | | MPCA | |
|------|-----|------|------|
| KNN | SVM | KNN | SVM |
| 72.3 | 80 | 91.3 | 96.5 |

从表 1 可以看出, MPCA-KNN 分类准确率为 91.3%, MPCA-SVM 分类准确率为 96.5%, PCA-KNN 分类准确率为 72.3%, PCA-SVM 分类准确率为 80%. 无论利用何种分类器, 基于 MPCA 的特征降维方法均优于 PCA 降维方法.

为了研究模板大小对分类准确率的影响, 本文分别利用 $2 \times 2, 3 \times 3, 4 \times 4$ 大小的模板提取半脑对称度特征进行实验. 通过 MPCA 降维后, 再利用 SVM, KNN 分类器分类, 模板大小对分类结果的影响如表 2 所示.

表 2 模板大小对分类结果的影响
Table 2 Effect of template size on the results of classification %

| 模板大小 | MPCA-SVM | | | MPCA-KNN | | |
|--------------|----------|------|------|----------|------|------|
| | 准确率 | 特异性 | 敏感性 | 准确率 | 特异性 | 敏感性 |
| 4×4 | 88.7 | 87.5 | 92.9 | 86.9 | 83.3 | 90.9 |
| 3×3 | 88.5 | 83.4 | 92.9 | 86.9 | 75 | 100 |
| 2×2 | 96.5 | 92.9 | 100 | 91.3 | 91.7 | 90.9 |

从表 2 可以看出, 基于 MPCA-KNN 的分类准确率最高为 91.3% (2×2 模板), 而基于

MPCA - SVM 分类准确率高达 96.5% (2×2 模板). 显然利用 SVM 分类器对于脑 PET 图像的癫痫识别具有很好的分类效果. 对于半脑对称度特征提取过程中模板的选用, 无论利用 SVM 还是 KNN, 2×2 模板的分类准确率均为最高, 同时其敏感性和特异性的综合性能最优.

不同特征维数对分类准确率的影响也不同, 如图 2 所示.




图 2 特征维数对分类准确率的影响
Fig. 2 Effect of different feature dimensions on classification accuracy

从图 2 可以看出, 对于 2×2 模板, 在特征维数为 135 时准确率最高值 96.5%; 对于 3×3 模板, 特征维数在 $[80, 180]$ 区间, 准确率基本保持稳定在 88.4%; 对于 4×4 模板, 只有在特征维数为 40 时准确率达到最大值 88.7%, 之后准确率随特征维数的增加呈递减趋势.

为了比较本文方法对癫痫识别的有效性, 对比了现有的两种癫痫识别的方法^[14-15], 如表 3 所示.

其中, Z 分数峰值分析法和多参数定量分析法主要是针对 PET 图像中 ROI 区域进行研究, 相比之下本文提出的方法在保证准确率的同时又省去了大量勾画 ROI 区域的工作, 具有一定的优越性.

| 表 3 几种癫痫识别方法的比较 Table 3 Comparison of several epilepsy recognition methods | |
|---|---------|
| 癫痫识别方法 | 识别准确率/% |
| Z 分数峰值分析法 ^[14] | 88.3 |
| 多参数定量分析法 ^[15] | 92.8 |
| 本文方法 | 96.5 |

从实验结果中可以看出, 利用张量结构表示 PET 图像并提取半脑对称度特征用于分类这种方法对癫痫的识别有着很好的效果. 对于 PET 等三维图像, 图像内部结构尤为重要, 传统的图像处理方式是将其转换为二维矩阵形式进行分析, 但这样做不利于保存数据内部结构信息. PET 脑图像数据通过张量表示可以减少图像内部信息的损

失. 对于癫痫的 PET 图像诊断, 主要是考虑大脑区域的 SUV 分布, 左右脑 SUV 分布不均则疑似存在癫痫病灶, 因此半脑对称度特征很大程度上代表了 SUV 的分布特点. 本实验中癫痫数据集为 11 例, 其中, 7 例为颞叶癫痫, 2 例为顶叶癫痫, 2 例为额叶癫痫, 不同病灶区的 SUV 分布对分类的准确率也存在一定影响. 本文研究了癫痫脑 PET 图像与正常脑 PET 图像的分类, 对于准确定位病灶区域以及识别出具体类型的病灶未来还具有很大的研究空间.

5 结 语

本文提出了一种基于张量子空间的半脑对称度特征并结合 SVM 识别癫痫的方法. 该方法克服了传统医学图像病灶识别中医生设定 ROI 带来的大工作量和主观性等问题. 将数据表示成张量形式可以很好地保存全局数据结构完整性信息. 实验结果表明, 本文提出的方法对全脑 PET 图像的癫痫识别具有很高的准确率, 可以辅助医生进行癫痫疾病的诊断. 本文方法虽然能够自动识别 PET 图像是否存在癫痫病灶, 但是还无法准确确定癫痫病灶的具体位置, 病灶的准确定位是下一步的研究方向. 本文的研究对阿茨海默症等神经疾病的研究也具有借鉴意义.

参考文献:

[1] Fougère C, Rominger A, Geisler J, et al. PET and SPECT in epilepsy: a critical review[J]. *Epilepsy & Behavior*, 2009, 15(1): 50-55.

[2] Batmanghelich N, Dong A, Taskar B. Regularized tensor factorization for multi-modality medical image classification[C]//International Conference on Medical Image Computing and Computer-assisted Intervention. Fichtinger; Springer, 2011: 17-24.

[3] Ryali S, Supekar K, Abrams D, et al. Sparse logistic regression for whole-brain classification of fMRI data[J]. *NeuroImage*, 2010, 51(2): 752-764.

[4] Ecker C, Johnston P, Murphy C, et al. Investigating the predictive value of whole-brain structural MR scans in autism: a pattern classification approach[J]. *NeuroImage*, 2010, 49(1): 44-56.

[5] Song X, Meng L, Shi Q, et al. Learning tensor-based features for whole-brain fMRI classification[C]//International Conference on Medical Image Computing and Computer-assisted Intervention. New York: Springer-Verlag, 2015: 613-620.