

# 基于子图相似性的多动症患者脑网络分析

汪鑫欣<sup>1</sup>, 宋笑影<sup>1</sup>, 柴利<sup>2</sup>

(1. 武汉科技大学冶金自动化与检测技术教育部工程中心, 武汉 430081; 2. 浙江大学控制科学与工程学院, 杭州 310058)

**摘要:** 多动症会严重影响儿童发育, 对多动症患者的有效诊断受到广泛关注。该文结合脑网络的拓扑结构信息和图上的信号, 提出一种基于稀疏表示的图相似性计算方法, 从微观到宏观分析脑区之间的差异。该方法使用 Pearson 相关系数构建全连通脑网络, 基于稀疏表示从底层结构中提取节点子网络, 根据图核函数计算子网络相似性, 最后给出了脑网络相似性的全局指标。以受试者间的相似性作为特征在公共数据集 ADHD-200 上的分类实验结果表明, 该方法能够以 93.1% 的准确度区分多动症患者和健康对照者, 分类性能明显优于其他已有算法。此外, 结果表明多动症患者在中央前回、丘脑、海马和脑岛等脑区之间有更强的连接。

**关键词:** 多动症; 功能磁共振成像; 图相似性; 子网络

**中图分类号:** TN911.7      **文献标志码:** A

## Brain Network Analysis of Patients with ADHD Based on Subnetwork Similarity

WANG Xinxin<sup>1</sup>, SONG Xiaoying<sup>1</sup>, CHAI Li<sup>2</sup>

(1. Engineering Research Center of Metallurgical Automation and Measurement Technology, Wuhan University of Science and Technology, Wuhan 430081, China; 2. College of Control Science and Engineering, Zhejiang University, Hangzhou 310058, China)

**Abstract:** Attention deficit hyperactivity disorder (ADHD) seriously affects children's development, so extensive attention has been paid to its effective diagnosis. A new method for calculating graph similarity is proposed, which combines the topological information of brain networks with signals on the network. The Pearson correlation coefficient is used to construct the fully connected brain network. Based on the sparse representation, the node subnetwork is extracted from the underlying structure, and the similarity of the subnetwork is calculated according to the graph kernel function. Finally, the global index of brain network similarity is given. Experimental results of classifying ADHD-200 in the public dataset characterized by similarity between subjects show that the proposed method can distinguish ADHD patients and healthy people with 93.1% accuracy, and the classification performance is significantly superior than other existing methods. In addition, it is found that ADHD patients have stronger connections in brain regions, such as anterior central gyrus, thalamus, hippocampus and insula.

**Key words:** attention deficit hyperactivity disorder (ADHD); functional magnetic resonance imaging (fMRI); graph similarity; subnetwork

## 引言

注意缺陷多动障碍(Attention deficit hyperactivity disorder, ADHD),又称多动症,是一种神经发育障碍疾病,其症状主要表现为注意力不集中、注意力持续时间短暂、活动过多和情绪不集中,在全球儿童中的总患病率超过5%<sup>[1-2]</sup>。ADHD会严重影响患者在社会、情感和认知领域的发展,并与其一生的精神疾病相关联<sup>[3]</sup>。目前,ADHD的致病原因还没有明确的定论,遗传因素、家庭因素、中毒因素及脑组织损伤因素<sup>[4]</sup>等都可能导致ADHD的产生。本文试图从拓扑结构的角度量化受试者的脑网络,给出脑网络相似性的计算方法,并进一步探索ADHD患者的异常脑区。

神经影像技术<sup>[5]</sup>为大脑疾病的诊断提供了新思路,使研究者能够从生物医学和信息技术角度对大脑疾病进行分析。功能磁共振成像(Functional magnetic resonance imaging, fMRI)作为最重要的神经影像技术之一,在脑网络研究中起着关键作用<sup>[6]</sup>。fMRI技术以无创的方式获取大脑的功能连接信息<sup>[7]</sup>,根据血液动力学变化间接测量大脑神经元之间的交流,使用血氧水平依赖(Blood oxygen level dependent, BOLD)信号表征大脑神经元的电活动<sup>[8]</sup>,是研究脑网络的有力工具。

fMRI大数据的采集允许研究者们使用图论<sup>[9]</sup>和机器学习<sup>[10]</sup>等方法探索大脑内部的连接,根据不同的功能大脑可被划分为多个区域,不同的大脑区域之间存在一定的联系,图模型可以从拓扑结构方面抽象地体现大脑不同区域之间复杂的交互<sup>[11]</sup>。目前,已有许多工作从图论的角度分析ADHD患者的脑网络,如文献[12]对脑网络中与执行功能相关的子网络进行研究,发现ADHD患者的连接密度和网络效率显著降低,表明ADHD患者大脑的功能网络不太完整,这可能是该疾病执行功能障碍的根本原因;文献[13]使用图度量来描述大脑之间的连接模式,发现ADHD患者的脑网络在局部结构上更加模块化,而且在整个大脑中远程通信更少,表明ADHD患者在局部脑区之间的通信减少;文献[14]使用fMRI信号构建脑网络,与健康对照者相比,ADHD患者的拓扑特征发生改变,包括整体效率和局部效率减小以及路径长度增长。

综上所述,现有研究大多侧重于分析ADHD患者脑网络在拓扑结构上的定性差异,而很少关注脑网络之间的定量比较<sup>[15]</sup>。与传统可以用特征空间直接表示的数据不同<sup>[16]</sup>,对图进行定量表示需借助于图相似性,即采用图相似性定量分析不同受试者脑网络之间的结构差异。现有研究主要从以下两个角度来定义图的相似性:(1)图论方法,从全局、局部、节点和边切入,通过计算图度量来比较两个图的拓扑结构;(2)基于距离的方法,如图和子图同构<sup>[17]</sup>、图编辑距离<sup>[18]</sup>和核方法<sup>[19]</sup>等。

在众多计算图相似性方法中,核方法为相似性计算提供了便利,其中基于图构造的核函数被证明是最有效的,并已广泛应用于大脑网络<sup>[16]</sup>、社交网络<sup>[20]</sup>和网络异常检测<sup>[21]</sup>等。文献[22]提出了使用多种核函数分别计算阿尔兹海默症患者和健康对照组核相关性的方法,并通过计算全局特征来比较两组之间的核相关性,发现核相关性在组间表现出显著差异;文献[23]提出基于主成分分析(Principal components analysis, PCA)核的方法来判别阿尔兹海默症和ADHD患者,使用PCA核从重建的脑网络中提取拓扑特征,并将脑网络特征映射到另一个空间中,对重建前后脑网络的拓扑结构进行量化。上述采用核函数对大脑网络的分析都是基于网络的底层结构构建阈值网络,使得部分信息丢失,此外在计算相似性的过程中只用到了大脑的拓扑结构信息,而没有考虑图上的信号,即脑区上的BOLD信号。

针对上述问题,本文同时考虑脑网络的拓扑结构信息和节点上的BOLD信号,提出了一种新的图相似性计算方法,基于BOLD信号之间的Pearson相关系数构建大脑底层网络,采用稀疏表示从底层网络中提取节点子网络,根据节点子网络的相似性给出脑网络相似性的计算方法,定量分析ADHD患者脑网络的改变。在公共数据集ADHD-200上的实验结果表明,本文方法能够以93.1%的准确度区分ADHD患者和健康对照者,性能明显优于其他已有的算法。

## 1 本文方法

基于图模型的脑网络可以使用三元组表示为  $G=(V, E, W)$ , 其中  $V$  为节点(脑区)的集合,  $|V|=N$  为图的大小(节点数量),  $E \subseteq V \times V$  为边的集合,  $|E|$  为图  $G$  中边的数量,  $W \in \mathbb{R}^{N \times N}$  为  $G$  的加权邻接矩阵,  $w_{ij}$  为节点  $i$  和节点  $j$  间连接的权重。定义  $x_i \in \mathbb{R}^T$  为第  $i$  个节点上的 BOLD 信号, 所有节点的 BOLD 时间序列构成  $G$  上的信号矩阵  $X=[x_1, x_2, \dots, x_N] \in \mathbb{R}^{T \times N}$ 。

图 1 显示了本文方法的流程图。根据脑图模板从 fMRI 数据中提取受试者的 BOLD 信号矩阵  $X$ , 基于受试者的 BOLD 信号使用稀疏表示的方法, 将脑网络中的一个节点用其余节点进行表示, 选取较大系数对应的节点。根据 BOLD 信号之间的 Pearson 相关系数构造受试者的全连通矩阵  $W$ , 提取稀疏表示得到的节点之间的权重, 选取权重最大的前 4 个节点, 即连接最密切的脑区, 结合全连通矩阵  $W$  和选取的节点, 构建每个节点的子网络。将子网络映射到  $q$  阶 Krylov 子空间<sup>[24]</sup> 中, 采用其协方差矩阵描述该子网络的内部连接。计算每个子网络的相似性, 基于此定义受试者的脑网络相似性, 以相似性为特征采用支持向量机(Support vector machine, SVM)方法对受试者进行分类。接下来具体介绍本文方法的主要步骤。

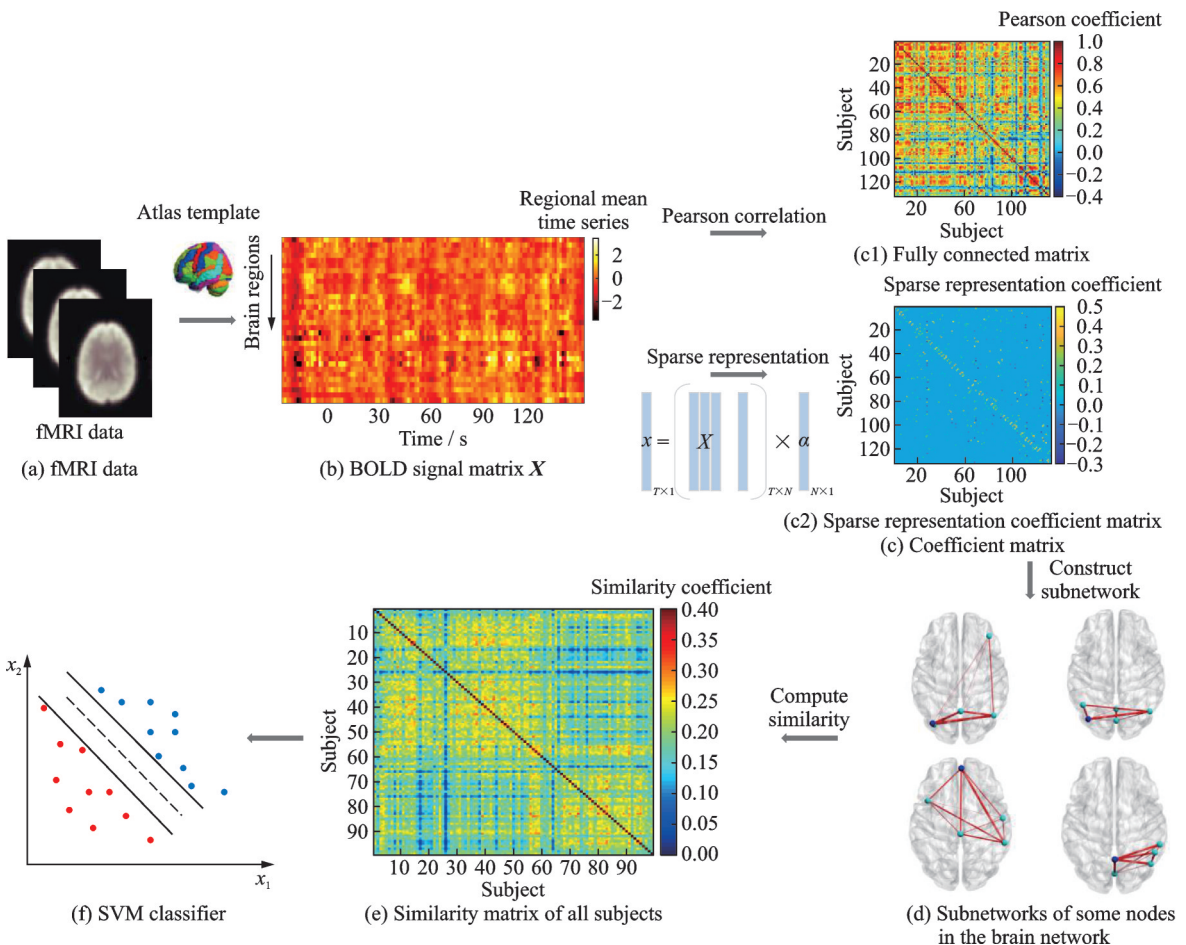


图 1 本文方法流程图

Fig.1 Flow chart of the proposed method

### 1.1 子网络构建

本文提出一种基于稀疏表示构建网络中节点子网络的方法,节点子网络可以从局部反映网络的多层次结构。对于具有  $N$  个节点的脑网络,定义  $X_i = [x_1, x_2, \dots, x_{i-1}, 0, x_{i+1}, \dots, x_N] \in \mathbf{R}^{T \times N}$ , 采用稀疏表示算法用脑网络中其他  $(N-1)$  个节点上的 BOLD 信号表示当前节点  $v_i$  上的 BOLD 信号,即

$$x_i = X_i \alpha_i + \text{error} \quad (1)$$

式中:  $\alpha_i \in \mathbf{R}^N$ , error 为误差项。稀疏表示可以被视为一个标准的  $l_1$  范数正则化优化问题,其目标函数为

$$\min_{\alpha} \|x_i - X_i \alpha_i\|_2^2 + \lambda \|\alpha_i\|_1 \quad (2)$$

式中:  $\lambda$  为正则化参数,控制模型的稀疏性。 $\lambda$  越大,模型越稀疏。

选取稀疏表示系数  $\alpha_i$  中前  $m$  个最大系数所对应的节点以及中心节点  $v_i$  构成节点  $v_i$  子网络的节点集合  $V_{v_i}$ ,  $V_{v_i}$  中节点在底层结构中对应的边构成节点  $v_i$  子网络的边集合  $E_{v_i}$ 。结合  $V_{v_i}$  和  $E_{v_i}$ ,可以得到节点  $v_i$  的子网络  $G_{v_i} = (V_{v_i}, E_{v_i}, W_{v_i})$ , 其中,  $v_i \in V_{v_i}$ ,  $|V_{v_i}| = m + 1$ ,  $W_{v_i} \in \mathbf{R}^{(m+1) \times (m+1)}$ 。

令  $G = (V, E, W)$  和  $G' = (V, E', W')$  分别表示两个受试者的脑网络,由于使用同一脑图模板,所有受试者脑网络的节点集合完全相同。在图  $G$  和  $G'$  中,为每个节点  $v_i$  构造子网络,由局部节点子网络描述受试者的全局脑网络,得到

$$\begin{aligned} G &= \{G_{v_1}, G_{v_2}, \dots, G_{v_N}\} = \{(V_{v_1}, E_{v_1}, W_{v_1}), (V_{v_2}, E_{v_2}, W_{v_2}), \dots, (V_{v_N}, E_{v_N}, W_{v_N})\} \\ G' &= \{G'_{v_1}, G'_{v_2}, \dots, G'_{v_N}\} = \{(V'_{v_1}, E'_{v_1}, W'_{v_1}), (V'_{v_2}, E'_{v_2}, W'_{v_2}), \dots, (V'_{v_N}, E'_{v_N}, W'_{v_N})\} \end{aligned} \quad (3)$$

### 1.2 协方差矩阵

为更简便而有效地表示子网络  $G_{v_i}$  的连接,引入对称半正定协方差矩阵  $C^{G_{v_i}} \in \mathbf{R}^{q \times q}$  [24]

$$C_{a,b}^{G_{v_i}} = \text{cov} \left( \frac{NW_{v_i}^a e}{\|W_{v_i}^a e\|_1}, \frac{NW_{v_i}^b e}{\|W_{v_i}^b e\|_1} \right) \quad (4)$$

式中: cov 为两个向量之间的协方差,  $q$  为幂迭代的最大次数 ( $q < m$ ),  $a, b \in \{1, 2, \dots, q\}$  为协方差矩阵的索引,  $e \in \mathbf{R}^N$ ,  $W_{v_i}^a e \in \mathbf{R}^N$  为  $W_{v_i}$  在向量  $e$  上的第  $a$  次幂迭代,  $\|\cdot\|_1$  为计算向量的  $l_1$  范数。

对于幂迭代序列  $\{e, We, W^2e, \dots, W^q e\}$  所张成的  $q$  阶 Krylov 子空间,给定合适的  $q$ , 加权邻接矩阵  $W$  可以用包含足够信息的 Krylov 子空间表示为半正定协方差矩阵  $C \in \mathbf{R}^{q \times q}$ 。该映射方法可以很好地捕捉图的底层结构,同时具有图不变性的特点。

### 1.3 子网络相似性

基于以下核函数算法计算两个受试者相同节点对应子网络  $G_{v_i}$  和  $G'_{v_i}$  间的相似性 [16]

$$s(G_{v_i}, G'_{v_i}) = \exp \left( -\frac{1}{2} \lg \left( \frac{|S_{v_i}|}{\sqrt{|C^{G_{v_i}}| |C^{G'_{v_i}}|}} \right) \right) \quad (5)$$

式中:  $C^{G_{v_i}} \in \mathbf{R}^{q \times q}$  和  $C^{G'_{v_i}} \in \mathbf{R}^{q \times q}$  分别为子网络  $G_{v_i}$  和  $G'_{v_i}$  的协方差矩阵,  $S_{v_i} = (C^{G_{v_i}} + C^{G'_{v_i}})/2$ ,  $|\cdot|$  表示行列式计算。该算法定义了子网络  $G_{v_i}$  和  $G'_{v_i}$  基于巴氏距离 [25] 的相似性。

通过计算图  $G$  和  $G'$  所有节点对应子网络的相似性,给出以下定量比较图  $G$  和  $G'$  相似性的指标

$$k(G, G') = \frac{1}{N} \sum_{i=1}^N s(G_{v_i}, G'_{v_i}) \quad (6)$$



## 2 实验结果及分析

### 2.1 实验数据及预处理

所用数据来自公共数据集 ADHD-200 ([http://fcon\\_1000.projects.nitrc.org/indi/adhd200/](http://fcon_1000.projects.nitrc.org/indi/adhd200/)), 99名实验受试者包括44名健康对照者和55名ADHD患者。从各个方面考虑受试者的身体信息, 包括诊断状态、年龄、性别、多种ADHD症状测量、智商和药物使用情况。所有的fMRI数据均通过3T Siemens Tim Trio全身扫描仪获取, 扫描参数为: TR=2 500 ms, TE=15 ms, Flip=90°, 每名受试者BOLD信号时间序列长度 $T=123$ 。受试者的具体信息如表1所示。

表1 受试者相关信息

Table 1 Subject related information

受试者	人数	性别(男/女)	惯用手(左/右)
健康对照者	44	27/17	7/37
ADHD患者	55	37/18	1/54

使用CONN工具箱<sup>[26]</sup>对fMRI数据进行预处理, 预处理流程包括: 功能校正和切片时间校正, 用于校正不同切片之间功能性数据的时间失调; 异常值识别, 根据观察到的全局BOLD信号和扫描仪中的对象运动量来识别潜在的异常扫描; 直接分割、归一化和功能平滑, 将解剖数据在蒙特利尔坐标系中进行标准化, 并使用统计参数映射工具箱进行统一分割和标准化程序分割。

根据CONN工具箱中的Atlas模板, 将受试者的大脑空间划分为132个感兴趣区域(Region of interest, ROI), 即 $N=132$ 。对于每个单独的ROI, 将所有体素的fMRI BOLD时间序列进行平均得到该ROI上的时间序列。以ROI为节点, 以ROI上BOLD信号之间的Pearson相关系数为连通权值, 为每个受试者构建全连通脑网络。

### 2.2 实验设置

使用SVM算法进行分类, 采用留一法进行交叉验证, 基于LIBSVM库<sup>[27]</sup>(默认参数)实现SVM算法。依据准确度、敏感性、特异性和接收机工作特性(Receiver operating characteristic, ROC)曲线下面积(Area under curve, AUC)评价算法的分类性能, 并与其他已有流行算法进行比较。具体而言, 准确度衡量所有受试者中正确预测的受试者比例, 敏感性表示正确预测的阳性比例, 特异性表示正确预测的阴性比例, ROC曲线是反映敏感性和特异性连续变量的综合指标。

### 2.3 分类性能

本文基于稀疏表示和全连通矩阵构建所有节点子网络, 通过计算节点子网络相似性, 得到任意两名受试者的相似性, 以相似性矩阵作为特征进行分类。在同一数据集ADHD-200上, 对ADHD患者和健康对照者进行分类, 表2显示了不同方法的分类性能。现有方法分类的最高准确度为82.76%, 敏感性为93.30%, 特异性为83.45%, AUC为0.9356; 使用本文方法分类的准确度为93.10%, 敏感性为93.33%, 特异性为92.86%, AUC为0.9810。由实验结果可知, 本文所提方法的准确度、敏感性和特异

表2 不同方法分类性能比较

Table 2 Comparison of classification performance of different methods

方法	准确度/%	AUC	敏感性/%	特异性/%
Shortest path <sup>[28]</sup>	68.96	0.695 2	73.33	64.28
Pyramid match <sup>[29]</sup>	62.06	0.742 9	80.00	42.86
Random walk <sup>[30]</sup>	80.31	0.890 5	93.30	64.28
MST kernel <sup>[23]</sup>	82.76	0.935 6	80.64	83.45
本文方法	93.10	0.981 0	93.33	92.86

性都明显优于其他方法,说明本文所提子图相似性方法能够充分捕捉受试者的信息,并在分类任务中表现出良好的分类性能。图2显示了不同方法的ROC曲线,根据ROC曲线也可以看出本文方法具有更好的分类性能。

在本文方法中,使用 Pearson 相关系数构建脑网络,得到全连通矩阵,保留脑网络的全部结构信息,并在此基础上基于稀疏表示提取节点的子网络。大脑是一个非常复杂的系统,细小的差异可能导致巨大的变化,传统构建阈值网络的思想没有充分考虑脑网络的结构信息,阈值的设置会在一定程度上影响分类性能。本文方法兼顾脑网络的拓扑结构信息和节点上的BOLD信号,因此可以得到更好的分类性能。

## 2.4 异常脑区分析

根据式(5)可以得到两组受试者在同一脑区上子网络的相似性。为了探索具有统计学意义的异常脑区,对两组受试者在同一脑区上的相似性进行  $t$  检验,将  $p$  值最小的10个脑区视为异常脑区。实验所发现的异常脑区及对应的  $p$  值如表3所示,包括脑岛皮层、肾上腺素皮层、海马和丘脑等脑区。根据两组受试者的平均连通网络,图3显示了上述得到的10个脑区分别在健康对照组和ADHD患者组中的连接。观察图3发现,相较于健康对照者,ADHD患者脑区之间的连接更多,表示ADHD患者脑部活动更活跃,这与ADHD患者注意力不集中和执行功能障碍密切相关。

表3 异常脑区及对应的  $p$  值

Table 3 Abnormal brain regions and corresponding  $p$  values

ROI 标号	ROI名称	$p$ 值
4	脑岛皮层左侧	$6.83 \times 10^{-13}$
48	肾上腺素内皮层左侧	$1.36 \times 10^{-11}$
101	海马左侧	$1.08 \times 10^{-10}$
3	脑岛皮层右侧	$2.96 \times 10^{-9}$
93	丘脑左侧	$8.30 \times 10^{-9}$
106	脑干	$8.86 \times 10^{-9}$
1	右额极	$2.49 \times 10^{-8}$
92	丘脑右侧	$2.51 \times 10^{-8}$
13	中央前回右侧	$1.88 \times 10^{-7}$
51	补充运动皮层左侧	$1.96 \times 10^{-7}$

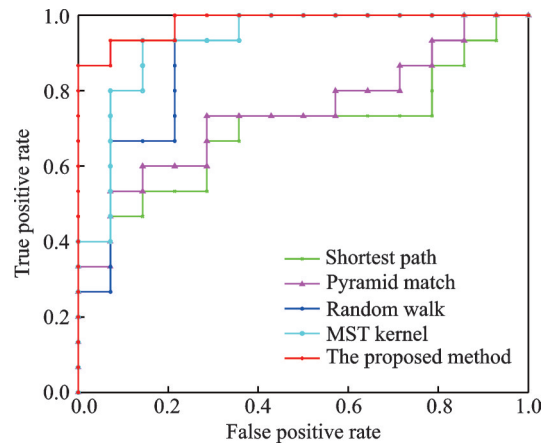


图2 不同方法的ROC曲线

Fig.2 ROC curves for different methods

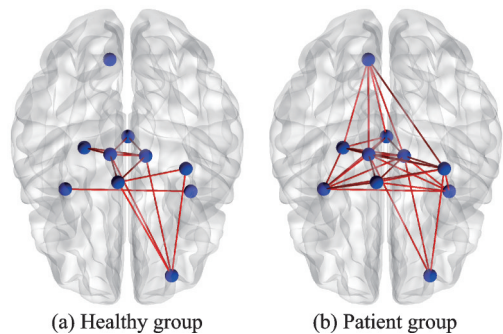


图3 健康组和患者组异常脑区连接对比

Fig.3 Comparison of abnormal brain area connectivity between healthy group and patient group

根据本文实验得到的异常脑区结果与已有的工作是一致的,包括文献[31]采用Meta技术发现,中央前回与注意力不集中、多动且易冲动的表现有关;文献[32]发现在肾上腺素内皮层中,ADHD患者在不同的年龄段有不同的脑活动模式,该脑区异常会导致注意力不集中,同时发现ADHD患者在丘脑和补充运动皮层表现出很强的活动性,这与ADHD患者的运动控制和执行功能障碍有关;文献[33]的研究表明,脑岛和海马是ADHD发展早期最先遭受损伤的脑区,可以通过对这两个脑区的检测对ADHD

进行诊断。

在大脑完成各种任务时,不同的脑区之间分工合作。中央前回主要参与注意力转移和眼球运动<sup>[33]</sup>;脑岛通常被认为与意识有关,并在感知、运动控制、自我意识、语言、认知功能、情绪和人际关系体验中发挥重要作用<sup>[34]</sup>;海马在空间记忆和从短期记忆到长期记忆的信息整合中起着重要作用<sup>[35]</sup>。研究者们发现,ADHD患者的异常脑区涉及中央前回、丘脑、海马和脑岛等脑区,这些脑区的病变可能是ADHD产生的主要原因。

## 2.5 参数分析

本文所提出的相似性方法涉及两个参数  $m$  和  $q$  的设置,其中  $m$  控制子网络的大小, $q$  控制子网络映射为协方差矩阵时的迭代次数。为了分析不同参数设置对分类结果的影响,使  $m$  和  $q$  的取值范围分别为  $\{4, 5, 6, 7\}$  和  $\{2, 3, 4\}$ ,图4显示了  $m$  和  $q$  取不同值时分类的准确度和AUC。从图4可以看出, $m$  和  $q$  取不同的值时,得到的分类结果差别不明显。在本文实验中,选择  $m=5, q=3$ 。

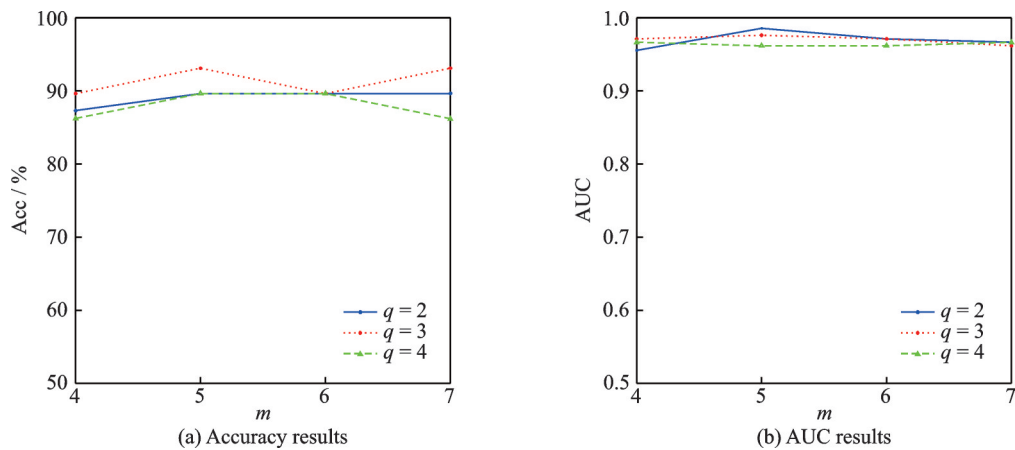


图4 参数  $m$  和  $q$  取不同值的分类结果

Fig.4 Classification results of taking different values for parameters  $m$  and  $q$

## 3 结束语

本文提出了一种基于稀疏表示构建子网络的相似性计算方法,并基于此采用SVM算法对ADHD患者和健康对照者进行分类。与现有的基于最短路径构造子网络的方法不同,本文使用基于稀疏表示的方法结合fMRI BOLD信号捕获网络从局部到全局的结构特征,得到更具鉴别力的子网络相似性作为分类特征。在公共数据集ADHD-200上的实验结果表明,与其他已有方法相比,本文方法能大幅度提高分类性能。同时,基于  $t$  检验,本文探索了导致疾病发生的异常脑区。

### 参考文献:

- [1] WEYANDT L, SWENTOSKY A, GUDMUNSDOTTIR B G. Neuroimaging and ADHD: fMRI, PET, DTI findings, and methodological limitations[J]. *Developmental Neuropsychology*, 2013, 38(4): 211-225.
- [2] CORTESE S, COMENCINI E, VINCENZI B, et al. Attention-deficit/hyperactivity disorder and impairment in executive functions: A barrier to weight loss in individuals with obesity[J]. *BMC Psychiatry*, 2013, 13(1): 2-4.
- [3] ABBAS A K, AZEMI G, AMIRI S, et al. Effective connectivity in brain networks estimated using EEG signals is altered in children with ADHD[J]. *Computers in Biology and Medicine*, 2021, 134: 104515.
- [4] CORTESE S, COGHILL D. Twenty years of research on attention-deficit/hyperactivity disorder (ADHD): Looking back,

- looking forward[J]. *Evidence-based Mental Health*, 2018, 21(4): 173-176.
- [5] SHARMA T. Insights and treatment options for psychiatric disorders guided by functional MRI[J]. *The Journal of Clinical Investigation*, 2003, 112(1): 10-18.
- [6] BUCKNER R L, ANDREWSHANNA J R, SCHACTER D L. The brain's default network: Anatomy, function, and relevance to disease[J]. *Annals of the New York Academy of Sciences*, 2008, 1124(1): 5-8.
- [7] HUANG W Y, BOLTON T A W, MEDAGLIA J D, et al. A graph signal processing perspective on functional brain imaging [J]. *Proceedings of the IEEE*, 2018, 106(5): 868-885.
- [8] GRIMM O, VAN ROOIJ D, HOOGMAN M, et al. Transdiagnostic neuroimaging of reward system phenotypes in ADHD and comorbid disorders[J]. *Neuroscience & Biobehavioral Reviews*, 2021, 128: 165-181.
- [9] SHUMAN D I, NARANG S K, FROSSARD P, et al. The emerging field of signal processing on graphs: Extending high-dimensional data analysis to networks and other irregular domains[J]. *IEEE Signal Processing Magazine*, 2013, 30(3): 83-98.
- [10] HU C H, SEPULCRE J, JOHNSON K A, et al. Matched signal detection on graphs: Theory and application to brain imaging data classification[J]. *NeuroImage*, 2016, 125(15): 587-600.
- [11] ORTEGA A, FROSSARD P, KOVACEVIC J, et al. Graph signal processing: Overview, challenges, and applications[J]. *Proceedings of the IEEE*, 2018, 106(5): 808-828.
- [12] TAO Jiejie, JIANG Xueyan, WANG Xin, et al. Disrupted control-related functional brain networks in drug-naive children with attention-deficit/hyperactivity disorder[J]. *Frontiers in Psychiatry*, 2017. DOI: 10.3389/fpsy.2017.00246.
- [13] BEARE R, ADAMSON C, BELLGROVE M A, et al. Altered structural connectivity in ADHD: A network based analysis [J]. *Brain Imaging and Behavior*, 2017, 11(3): 846-858.
- [14] CHEN Ying, HUANG Xiaoqi, WU Min, et al. Disrupted brain functional networks in drug-naive children with attention deficit hyperactivity disorder assessed using graph theory analysis[J]. *Human Brain Mapping*, 2019, 40(17): 4877-4887.
- [15] MHEICH A, WENDLING F, HASSAN M, et al. Brain network similarity: Methods and applications[J]. *Network Neuroscience*, 2020, 4(3): 507-527.
- [16] JIE BIAO, LIU Mingxia, ZHANG Daoqiang, et al. Sub-network kernels for measuring similarity of brain connectivity networks in disease diagnosis[J]. *IEEE Transactions on Image Processing*, 2018, 27(5): 2340-2353.
- [17] CORDELLA L P, FOGGIA P, SANSONE C, et al. A (sub) graph isomorphism algorithm for matching large graphs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004, 26(10): 1367-1372.
- [18] GAO Xinbo, XIAO Bing, TAO Dacheng, et al. A survey of graph edit distance[J]. *Pattern Analysis and Applications*, 2010, 13(1): 113-129.
- [19] SCHULZ T H, HORVÁTH T, WELKE P, et al. A generalized Weisfeiler-Lehman graph kernel[J]. (2021-01-20). <https://doi.org/10.48550/arXiv.2101.08104>.
- [20] MU Lin, JIN Peiquan, ZHAO Jie, et al. Detecting evolutionary stages of events on social media: A graph-kernel-based approach[J]. *Future Generation Computer Systems*, 2021, 123: 219-232.
- [21] LAGRAA S, AMROUCHE K, SEBA H. A simple graph embedding for anomaly detection in a stream of heterogeneous labeled graphs[J]. *Pattern Recognition*, 2021, 112: 107746.
- [22] AHMADI H, FATEMIZADEH E, MOTIENASRABADI A. fMRI functional connectivity analysis via kernel graph in Alzheimer's disease[J]. *Signal, Image and Video Processing*, 2021, 15(4): 715-723.
- [23] CUI Xiaohong, XIANG Jie, GUO Hao, et al. Classification of Alzheimer's disease, mild cognitive impairment, and normal controls with subnetwork selection and graph kernel principal component analysis based on minimum spanning tree brain functional network[J]. *Frontiers in Computational Neuroscience*, 2018, 12: 31.
- [24] SHRIVASTAVA A, LI P. A new space for comparing graphs[C]//*Proceedings of 2014 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining*. Beijing: IEEE, 2014: 62-71.
- [25] VAN MOLLE P, VERBELEN T, VANKEIRSBILCK B, et al. Leveraging the Bhattacharyya coefficient for uncertainty quantification in deep neural networks[J]. *Neural Computing and Applications*, 2021, 33(16): 10259-10275.
- [26] NIETOCASTANON A. *Handbook of functional connectivity magnetic resonance imaging methods in CONN*[M]. Boston: Hilbert Press, 2020: 3-9.



- [27] CHANG C C, LIN C J. LIBSVM: A library for support vector machines[J]. *ACM Transactions on Intelligent Systems and Technology*, 2011, 2(3): 5-11.
- [28] BORGWARDT K M, KRIEGEL H P. Shortest-path kernels on graphs[C]//*Proceedings of the Fifth IEEE International Conference on Data Mining*. Houston: IEEE, 2005.
- [29] NIKOLENTZOS G, MELADIANOS P, VAZIRGIANNIS M. Matching node embeddings for graph similarity[C]//*Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*. San Francisco: AAAI, 2017: 2429-2435.
- [30] VISHWANATHAN S V N, SCHRAUDOLPH N N, KONDOR R, et al. Graph kernels[J]. *Journal of Machine Learning Research*, 2010, 11: 1201-1242.
- [31] DICKSTEIN S G, BANNON K, XAVIER CASTELLANOS F, et al. The neural correlates of attention deficit hyperactivity disorder: An ALE meta-analysis [J]. *Journal of Child Psychology and Psychiatry*, 2006, 47(10): 1051-1062.
- [32] TANG Chao, WEI Yuqing, ZHAO Jiajia, et al. Abnormal brain activity in ADHD: A study of resting-state fMRI[C]//*Proceedings of International Conference on Brain Informatics*. Beijing: Springer, 2017: 181-189.
- [33] HUANG Z R, TARNAL V, VLISIDES P E, et al. Anterior insula regulates brain network transitions that gate conscious access[J]. *Cell Reports*, 2021, 35(5): 109081.
- [34] YANG Yue, PENG Gang, ZENG Hongwu, et al. Effects of the SNAP25 on integration ability of brain functions in children with ADHD[J]. *Journal of Attention Disorders*, 2022, 26(1): 88-100.
- [35] MAURER A P, NADEL L. The continuity of context: A role for the hippocampus[J]. *Trends in Cognitive Sciences*, 2021, 25(3): 187-199.

#### 作者简介:



汪鑫欣(1998-),女,硕士,研究方向:图信号处理,E-mail:2313990419@qq.com。



宋笑影(1990-),通信作者,女,副教授,博士生导师,研究方向:图信号处理、图学习,E-mail:xiaoying-811@wust.edu.cn。



柴利(1972-),男,教授,博士生导师,研究方向:图信号处理、分布式优化、滤波器组框架。

(编辑:王静)