

基于多尺度功能脑网络融合特征的抑郁症分类算法

付常洋,王瑜,肖洪兵,邢素霞

北京工商大学计算机与信息工程学院食品安全大数据技术北京市重点实验室,北京 100048

【摘要】提出一种多尺度功能脑网络融合特征的抑郁症分类方法,具体思想包括:首先通过精细化脑区,建立4种不同尺度的脑网络;然后对每种尺度的脑网络分别提取局部特征和全局特征,并将多种尺度脑网络的特征进行有效融合并降维;最后使用支持向量机对患者脑部功能磁共振影像进行分类。试验结果表明,分别提取局部特征和全局特征,并进行有效融合,可以提升识别效果;空间尺度减小会得到更多有效特征,进而能够有效提升分类结果;多尺度特征融合也可以在很大程度上对分类结果起到积极作用。与传统单一大尺度脑网络方法相比,本研究提出的方法获得了更加优秀的试验结果,识别率可达88.67%,充分验证了本研究提出方法的有效性和可行性,并为抑郁症患者的临床诊断与治疗提供生物学依据。

【关键词】抑郁症;功能脑网络;多尺度;特征融合;支持向量机

【中图分类号】R318;TP181

【文献标志码】A

【文章编号】1005-202X(2020)04-0439-06

Classification of depression using fusion features based on multi-scale functional brain network

FU Changyang, WANG Yu, XIAO Hongbing, XING Suxia

Beijing Key Laboratory of Big Data Technology for Food Safety, School of Computer and Information Engineering, Beijing Technology and Business University, Beijing 100048, China

Abstract: A novel method for the classification of depression is proposed based on a multi-scale functional brain network and fusion features. After 4 different scales of brain networks are established by refining the brain region, the local and global features are extracted from each scale of brain network, and the features of multi-scale brain networks are effectively fused and the dimensionality is reduced. Finally, support vector machine is used to classify the functional magnetic resonance images of the brain. The experimental results show that it is effective to improve the recognition effect by the fusion of separately extracted local and global features. More effective features can be obtained by reducing the spatial scale, which can remarkably improve the classification results. Multi-scale feature fusion can also greatly promote the accuracy and recall rate of classification. Compared with the traditional method with single large-scale brain networks, the proposed method achieves better performances. The classification accuracy by the proposed method reaches 88.67%, which fully verifies the effectiveness and feasibility of the proposed method, and also provides a biological basis for the clinical diagnosis and treatment of depression.

Keywords: depression; functional brain network; multi-scale; feature fusion; support vector machine

前言

抑郁症又称抑郁障碍,是一种以显著而持久的

心境低落为主要临床特征的精神类疾病,随着当今社会生活节奏日益加快,竞争压力不断增大,越来越多人罹患抑郁症。据世界卫生组织统计,目前全球有超3亿人患有抑郁症,并预计在2020年,抑郁症将有可能成为人类的第2大疾病,仅次于心脑血管疾病^[1]。抑郁症患者的自残、自杀等行为更是危害巨大,其对患者及家属造成的痛苦、对社会造成的损失是其他疾病所无法比拟的。

目前,抑郁症的临床诊断主要依据病史、症状、病程及体格检查和试验室检查获得,缺乏定量的生理指标,常见的诊断标准有《国际疾病分类》第10版

【收稿日期】2019-12-08

【基金项目】国家自然科学基金(61671028);国家重大科技研发子课题(ZLJC6 03-5-1);北京工商大学校级两科培育基金项目(19008001270)

【作者简介】付常洋,在读研究生,主要从事图像处理、机器学习方面的研究, E-mail: fcy112@outlook.com

【通信作者】王瑜,博士,教授,主要从事图像处理与模式识别的研究, E-mail: wangyu@btbu.edu.cn

(ICD-10)^[2]和美国《精神障碍诊断与统计手册》第4版(DSM-IV)^[3],但这种方式过于依赖医生的主观判断,临床诊断方式识别率低,从而延误了最佳治疗时间,导致病情迁延或加重。

为了辅助医生进行抑郁症的临床诊断,利用功能磁共振成像(functional Magnetic Resonance Imaging, fMRI)^[4]数据构建脑网络进行分类研究成为相关领域的研究热点,并广泛应用于抑郁症等脑疾病的研究中^[5-7]。脑网络的构建过程中,节点的定义至关重要,不同的定义方式会得到不同尺度的脑网络。现有研究中往往将fMRI数据在单一的大尺度脑网络中进行特征提取,少数多尺度脑网络方法也没有用于抑郁症的研究^[8-11]。Jing等^[12]仅从两个尺度对抑郁症fMRI数据进行脑网络构建和分类研究,但没有探讨更多尺度脑网络的特征融合问题。

针对上述问题,本研究在传统的脑分割模板定义基础上,构建多尺度脑网络,提取脑网络的局部特征和全局特征,分析不同尺度网络特征之间的潜在关系,利用多尺度特征融合的方法进一步提高特征显著度,并将此方法应用于抑郁症fMRI数据的分类研究中,辅助医生对抑郁症进行诊断、治疗和预后,提高诊断效率。本文的主要贡献包括:(1)利用抑郁症和健康被试的fMRI数据构建多尺度加权脑网络;(2)分别提取每种尺度脑网络的局部和全局网络特征;(3)有效融合多尺度局部和全局脑网络特征。试验结果表明,与传统单一大尺度脑网络方法相比,本研究提出的方法获得了更高的准确率,可以有效用于抑郁症的辅助诊断。

1 试验准备

1.1 被试者

本研究共包含174例被试,其中99例重症抑郁症患者(抑郁症患者组)和75例在年龄、性别、受教育程度匹配的健康对照者(健康对照组)。重症抑郁症患者是从首都医科大学附属安定医院招募的,健康对照组是从报纸广告上招募的。所有重症抑郁症患者都达到了DSM-IV对抑郁症的诊断标准,所有正常人都通过了DSM-IV的非病人版结构化临床访谈面试,在试验前,所有被试者都签署了知情同意书。两组被试者的临床统计学分析结果如表1所示。

1.2 fMRI数据采集

所有fMRI图像都由一台第三代特斯拉磁共振扫描仪(西门子公司,德国埃尔根)在北京师范大学认知神经科学和学习国家重点实验室扫描所得,扫描参数如下:射频重复时间(TR)=2 000 ms,回波时间(TE)=30 ms,

翻转角度(FA)=90°,矩阵大小=64×64,成像视野(FOV)=220 mm×220 mm,共240个时间点,层厚为3.5 mm,切片数为46。所有被试者在fMRI扫描过程中都保持安静、不动、闭眼、不睡觉,没有系统的思维活动。

表1 被试统计学分析结果
Tab.1 Statistical analysis of the clinical information of subjects

| 临床资料 | 抑郁症患者组 | 健康对照组 | P值 |
|---------|-------------|-------------|-------|
| 性别(男/女) | 43/56 | 33/42 | 0.941 |
| 年龄/岁 | 34.57±12.18 | 35.65±12.63 | 0.570 |
| 受教育程度/年 | 13.75±3.01 | 12.93±2.40 | 0.610 |
| 年龄范围/岁 | 18~65 | 19~60 | - |
| 病程/年 | 7.88±7.87 | - | - |
| 抑郁症发病次数 | 2.63±1.26 | - | - |
| HAMD | 21.44±3.97 | - | - |
| HAMA | 16.00±9.61 | - | - |

HAMD:汉密尔顿忧郁量表;HAMA:汉密尔顿焦虑量表

1.3 数据预处理

fMRI数据预处理工作使用基于Matlab的SPM8工具包实现^[13]。首先,前10个时间点由于信号稳定性与被试者对扫描器噪声的适应程度差而被丢弃;随后进行时间层校正和头动矫正;接下来将每个被试数据空间标准化为3 mm体素的MNI标准空间,并进行平滑;最后,消除所有受试者fMRI时间序列的线性趋势,过滤掉不在0.01~0.08 Hz带宽的样本,以减小高频干扰。

2 研究方法

2.1 脑网络的构建

如果将人脑定义为一个网络系统,那么它将是现实世界中最为复杂的网络系统之一,一个复杂网络的构建基于图论理论,包含节点和边的定义^[14]。本研究对每个被试进行脑网络构建,以探寻抑郁症患者与正常对照组的网络拓扑属性差异。

2.1.1 节点的定义 目前传统的研究方法中,脑网络节点的定义往往空间尺度较大,即根据某一特定的先验脑模板将全脑进行脑区划分,随后将每个脑区定义为一个节点,再将每个脑区中全部体素的算术平均值作为该节点时间序列中的值,使用最广泛的是自动解剖标记模板(Automated Anatomical Labeling, AAL)^[15]。本研究针对这一局限,将空间尺度不断缩小,共使用4种不同尺度下的脑区模板,首先使用AAL模板将全脑分为116个脑区,随后在

AAL 模板的基础上应用随机种子点方法^[16], 分别将 AAL 模板细化为包含 264、625、1 024 个脑区的模板, 如图 1 所示, 即建立了节点数量分别为 116、264、625、1 024 的 4 种尺度的脑网络, 试图探寻不同尺度下脑网络的拓扑属性对抑郁症 fMRI 数据分析的影响。




图1 4种尺度下定义的脑区模板

Fig.1 Brain templates defined at 4 scales

2.1.2 边的定义 边即节点间的连接, 定义为通过不同节点间功能性信号时间序列的相关性获得的功能连接, 本研究使用广泛应用于脑网络研究中的皮尔逊相关系数来定义该相关性。皮尔逊相关系数计算公式如下:

$$\rho_{X,Y} = \frac{\text{cov}(X,Y)}{\sigma_X \sigma_Y} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - (EX)^2} \sqrt{E(Y^2) - (EY)^2}} \quad (1)$$

其中, X 、 Y 分别为两个节点的时间序列向量, E 表示期望, 其值介于 -1 到 1 之间, 正数表示正相关, 负数表示负相关, 绝对值越大表示相关性越强。

由此可得到每个被试的关联矩阵, 包含 n 个节点的脑网络对应的关联矩阵规模即为 $n \times n$, 矩阵中的数值即为对应的皮尔逊相关系数。

2.1.3 阈值的选择 得到每个被试的关联矩阵之后, 需要对每个矩阵进行稀疏化, 目前大多数研究中的做法是将关联矩阵二值化, 即根据一个阈值来确定两节点间是否存在连接, 若矩阵中元素大于阈值, 则对应元素值设为 1, 否则设为 0。这样做虽然降低了计算复杂度, 便于分析, 但二值化过程导致部分信息损失。为了保留更多的细节信息, 本研究采取加权网络, 即关联矩阵中大于阈值的数值保留其原始值, 小于阈值的数值设为 0。

阈值的选择直接决定网络中边的密度, 从而对网络的结构和拓扑属性产生重要影响, 阈值的选择在现有研究中并没有一个公认的方式或者最优经验值。本研究采用稀疏度来确定阈值, 稀疏度定义为网络中实际存在的边数与网络中可能存在的最大边数的比值。研究表明, 当脑网络的稀疏度大于 0.5 时, 脑网络将会退化为随机网络^[17]。因此, 本研究设置稀疏度在 0.05 到 0.50 之间, 步长为 0.05, 数量为 10, 求出每个原始关联矩阵在每个稀疏度下的加权关联矩阵, 从而得到最终的脑网络, 如图 2 所示。

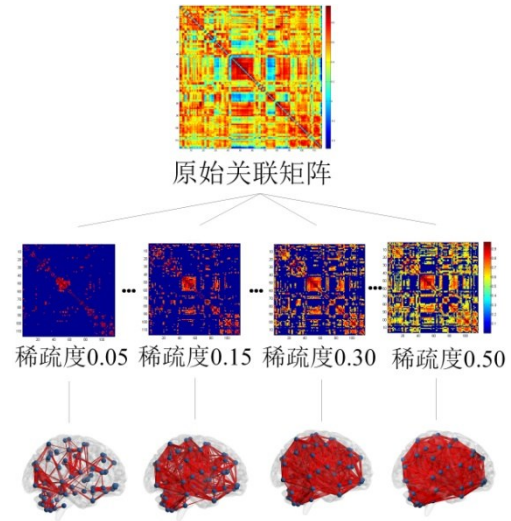


图2 不同稀疏度下脑网络的构建

Fig.2 Construction of brain networks with different sparsities

2.2 网络特征的计算

每个被试按照上述过程构建脑网络后, 利用脑网络的关联矩阵, 可以计算不同种类的网络特征。目前, 网络特征种类繁多, 本研究使用局部特征和全局特征两种网络特征, 局部特征包括度中心性、中介中心等, 全局特征包括全局效率、聚合系数。

2.2.1 局部特征 局部特征体现节点属性, 本文对每个节点计算 3 个局部特征。

(1) 度中心性:

$$k_i = \sum_{j \in G} w_{ij} \quad (i \neq j) \quad (2)$$

其中, k_i 为第 i 个节点的度中心性, $\sum_{j \in G} w_{ij} \quad (i \neq j)$ 用于计算节点 i 与其他节点之间的边 w_{ij} 的加权总和, G 表示整个网络。

(2) 中介中心性:

$$b_i = \sum_{m \neq i \neq n \in G} \frac{\sigma_{mn}(i)}{\sigma_{mn}} \quad (3)$$

其中, σ_{mn} 是从节点 m 到节点 n 最短路径的数量, $\sigma_{mn}(i)$ 是从节点 m 到节点 n 的最短路径经过节点 i 的数量。

(3) 节点效率:

$$e_i = \frac{1}{N-1} \sum_{j \neq i \in G} \frac{1}{d_{ij}} \quad (4)$$

其中, N 表示所有节点的数量, d_{ij} 表示节点 i 和节点 j 间的最短路径长度。

2.2.2 全局特征 全局特征体现全脑属性, 本研究对每个脑网络计算 2 个全局特征。

(1) 全局效率:

$$E_{\text{global}} = \frac{1}{N(N-1)} \sum_{j \neq i \in G} \frac{1}{d_{ij}} \quad (5)$$

其中, N 表示所有节点的数量, d_{ij} 表示节点 i 和节点 j 间的最短路径长度。

(2)聚合系数:

$$c_i = \frac{2}{k_i(k_i - 1)} \sum_{j,k} (w_{ij}w_{jk}w_{ki})^{1/3} \quad (6)$$

其中, k_i 表示节点 i 的度中心性, w_{ij} 、 w_{jk} 、 w_{ki} 表示加权边的值。

2.2.3 曲线下面积 (Area Under Curve, AUC) 由于不同尺度下的每个被试都有 10 个稀疏度下的关联矩阵, 经过特征计算后, 每个尺度下每个被试的每个属性都有对应的 10 个稀疏度下的值, 为了更好地表征属性在连续稀疏度上的整体特征, 本研究采取计算每个属性的方法, 以稀疏度为横轴, 特征值为纵轴构建坐标系, 用对应的 10 个稀疏度下的特征值做曲线, 计算每个属性的 AUC 值, 作为最终的特征值。

因此, 经过 AUC 计算后, 不同尺度下每个被试的特征向量的维数为 $(n \times 3 + 2)$ 个 (n 为脑网络节点数, 3 种局部特征, 2 种全局特征), 例如节点数量为 264 个脑网络的特征维数为 $(625 \times 3 + 2) = 1\,877$ 个, 节点数量为 1\,024 个的脑网络的特征维数为 $(1\,024 \times 3 + 2) = 3\,074$ 个。

2.3 特征选择及融合

因为特征数据的维数巨大, 导致特征向量不紧致, 同时增加运算成本, 不利于后期的分类研究, 因此需进行特征选择和降维, 防止后期分类模型训练过程中的过拟合, 增强模型泛化能力。

2.3.1 特征选择 特征选择和降维的方法很多, 本研究使用主成分分析 (Principal Components Analysis, PCA) 方法^[18]。PCA 的基本思想是将原来的样本数据映射到一个新的低维空间中, 通过坐标转换后, 在新的坐标系下, 只需要原来样本的一个最大线性无关组特征值对应的空间坐标, 即可表示原样本。映射过程中需要计算特征向量的贡献率, 用来确定最终降维后的特征数目 m , 贡献率即按大小排序后前 m 个特征值包含的信息占样本信息的比重, 本研究设置贡献率下限为 90%, 即降维后的数据包含 90% 以上原始数据的信息, m 的值可由如下公式求得:

$$\frac{\frac{1}{m} \sum_{i=1}^m \|x^{(i)} - x_{\text{approx}}^{(i)}\|^2}{\frac{1}{m} \sum_{i=1}^m \|x^{(i)}\|^2} \leq 0.1 \quad (7)$$

其中, $x^{(i)}$ 为第 i 个样本数据初始的空间坐标, $x_{\text{approx}}^{(i)}$ 为其映射到低维空间后的空间坐标, m 为原始数据经过降维后的维数。

需要指出的是, 在使用 PCA 对特征数据进行降维之前, 需先对其进行标准化处理, 以使得所有特征

的大小都在相同的范围内, 防止过分捕捉某些数值过大的特征。本研究采用 Z-Score 标准化方法, 如式 (8) 所示:

$$x_i^* = \frac{x_i - \frac{1}{n} \sum_{j=1}^n x_j}{\sqrt{\frac{1}{n} \sum_{j=1}^n (x_j - \frac{1}{n} \sum_{j=1}^n x_j)^2}} \quad (8)$$

其中, x_i^* 表示标准化后第 i 个样本的特征向量, x_i 表示第 i 个样本的原始特征向量, n 表示样本数量。

2.3.2 特征融合 在得到 4 个尺度的脑网络局部和全局特征后, 通过融合多尺度脑网络特征, 实现综合利用所有尺度脑网络的信息, 最终提高分类效果的目的。在进行特征融合时, 本研究使用串联融合的策略^[19], 即将每个被试数据在 4 种空间尺度下的脑网络特征向量首尾相连, 获得融合特征, 如式 (9) 所示:

$$S_{\text{fusion}} = [S_1, S_2, S_3, S_4] \quad (9)$$

其中, S_{fusion} 为融合后的特征向量, S_1 、 S_2 、 S_3 、 S_4 分别为 4 个尺度下的脑网络特征向量。

2.4 分类器

得到不同尺度下每个被试的特征向量后, 对特征数据进行分类研究, 在分类器选择方面, 本研究选取在 fMRI 数据分析领域应用广泛, 且非线性映射能力优秀的带有径向基核函数 (Radial Basis Function, RBF) 的支持向量机 (Support Vector Machine, SVM)^[20], 采用基于 python 语言的机器学习模块 Scikit-learn^[21] 辅助完成 SVM 算法的实现, 在训练和测试分类器的过程中进行五折交叉验证, 并在每次训练时尝试一定范围内各种可能的 RBF 核参数 C 、 g 的组合值 (C 取值: $10^3 \sim 10^5$, g 取值: $10^{-4} \sim 10^{-1}$), 找出使交叉验证精确度最高的 C 、 g 组合值, 确定最终的 SVM 分类模型。

2.5 模型评价指标

本研究分类问题为二分类问题, 也就是将样本分成抑郁症患者组和健康对照组两类, 规定抑郁症患者为正类 (positive), 健康对照者为负类 (negative), 分类算法对测试数据集的预测有正确或错误之分, 具体包括将正类预测为正类数 TP (True Positive)、将正类预测为负类数 FN (False Negative)、将负类预测为正类数 FP (False Positive)、将负类预测为负类数 TN (True Negative) 4 种情况。

针对研究课题的特殊性, 本研究选取正确率和召回率两个指标来评价模型的分类性能。正确率定义为: $\text{Accuracy} = (TP + TN) / (TP + FN + FP + TN)$, 反映分类器对所有样本的判定能力; 召回率定义为: $\text{Recall} = TP / (TP + FN)$, 反映被正确判定的抑郁症患者占抑郁症患者总数的比重。

2.6 算法流程

综上所述,本研究提出算法的具体步骤如下:步骤1,根据多尺度脑分区模板和式(1)定义脑网络的节点和边,并利用稀疏度对脑网络进行稀疏化;步骤2,根据式(2)~式(6)对不同尺度下每个脑网络进行特征计算,并求出不同稀疏度下每个特征的Auc,建立每个被试在每个尺度下的特征向量;步骤3,根据式(9)对每个被试在4个尺度下的特征向量进行串联融合;步骤4,根据式(7)和式(8)对特征向量进行降维;步骤5,将融合后的特征数据输入SVM分类器进行五折交叉验证,调节参数,获得分类结果。

3 实验结果与分析

为了验证本研究提出方法的有效性,精心设计了一系列试验,探讨不同尺度脑网络局部特征和全局特征对分类精度的影响,同时验证融合思想的有效性,即将4种尺度脑网络特征进行串联融合,以期获得更高的识别结果。

3.1 多尺度脑网络特征维度的确定

经过PCA降维,保留贡献率大于90%的特征数据,每种尺度脑网络的有效特征数量降维前后的具体数据如表2所示。从表2中的数据可以看出,降维

前后特征数目有很大变化,例如尺度4脑网络下,特征数目由3 074个降低到了112个,为后期分类提供有效且紧凑的特征数据,降低算法的计算成本。

表2 降维前后特征维数变化
Tab.2 Number of feature dimensions before and after dimensionality reduction

| 节点数量/个 | 降维前的特征维数 | 降维后的特征维数 |
|--------|----------|----------|
| 116 | 350 | 64 |
| 264 | 794 | 84 |
| 625 | 1 877 | 90 |
| 1 024 | 3 074 | 112 |

3.2 多尺度脑网络的分类结果

对两组被试每种尺度的脑网络特征(局部特征,全局特征,局部特征+全局特征)利用SVM进行分类,获得分类结果,为了验证特征选择和降维的有效性,本研究对局部特征和全局特征的串联融合特征利用PCA进行特征选择和降维,然后利用SVM进行分类,SVM采用RBF核函数,五折交叉验证,分类准确率和召回率如表3所示。

表3 不同尺度脑网络下的分类效果对比
Tab.3 Classification results at different scales of brain networks

| 节点数量/个 | 准确率/% | | | | 召回率/% | | | |
|--------|-------|-------|---------|-------|-------|-------|---------|-------|
| | 局部特征 | 全局特征 | 局部+全局特征 | | 局部特征 | 全局特征 | 局部+全局特征 | |
| | | | 降维前 | 降维后 | | | 降维前 | 降维后 |
| 116 | 65.67 | 55.33 | 67.00 | 72.67 | 68.67 | 62.33 | 70.00 | 77.33 |
| 264 | 68.67 | 59.33 | 70.67 | 75.33 | 77.33 | 68.67 | 79.33 | 84.00 |
| 625 | 75.33 | 62.67 | 76.33 | 84.67 | 84.00 | 72.33 | 84.67 | 90.67 |
| 1 024 | 79.33 | 67.00 | 79.67 | 85.33 | 83.67 | 77.33 | 86.67 | 92.00 |

从表3中的数据可以看出,在多尺度脑网络中,随着脑网络的节点数量增加,分类效果有了显著提升,这表明细化脑区分割后增加的特征中有大量有效特征,能够对分类器的训练起到积极影响,提高分类器的泛化能力;在融合局部和全局特征后,分类效果也有一定提升,这说明将局部和全局特征进行融合对分类结果有积极作用;经过降维处理后,不仅可以提取出有效信息,摒弃冗余信息,同时特征向量结构更加紧致,有利于最终识别结果的提升,例如,在第4个尺度下,降维后的分类准确率从79.67%提升

到85.33%;随着空间尺度的减小,网络节点数量增加,有效特征的数量也在增加,这表明细化脑分区模板能够提供更多有效的信息,例如,同样为降维后的分类正确率,空间尺度更小的第3个尺度下的分类正确率相较第2个空间尺度从75.33%提升到84.67%。

3.3 多尺度脑网络融合特征的分类结果

为了探究多尺度脑网络的融合特征对分类效果的影响,本研究在融合4种尺度脑网络的特征后,将融合后的特征使用PCA进行特征选择和降维,为了试验的可比性,控制融合特征降维后的数量分别与

融合特征前4个尺度下的特征数量相同,再应用RBF核函数的SVM分类器进行五折交叉验证,得到分类准确率和召回率,具体试验结果如表4所示。

表4 融合多尺度特征前后的分类效果对比
Tab.4 Comparison of classification results before
and after multi-scale feature fusion

| 特征数量/个 | 准确率/% | | 召回率/% | |
|--------|-------|-------|-------|-------|
| | 降维前 | 降维后 | 降维前 | 降维后 |
| 64 | 72.67 | 75.33 | 77.33 | 81.33 |
| 84 | 75.33 | 77.33 | 84.00 | 86.67 |
| 90 | 84.67 | 85.33 | 90.67 | 92.00 |
| 112 | 85.33 | 88.67 | 92.00 | 94.67 |

通过对表4数据的观察可以看出,在相同特征数量的情况下,融合多尺度脑网络特征后的分类正确率相比单独空间尺度下的脑网络分类正确率有所提升,这说明单纯地减小空间尺度、增加节点数量后求得特征并不是完全优于相对较大尺度脑网络的特征,不同空间尺度下的脑网络特征都有其重要意义,通过融合多尺度脑网络特征后,再对特征进行筛选,才能更好地利用多尺度脑网络信息,以提升模型泛化能力,提升分类效果。

4 结 论

在抑郁症fMRI数据分析领域中,本研究在传统脑网络研究中节点定义的基础上,增加脑网络节点的数量,构建4种不同尺度下的脑网络,并融合多尺度脑网络的特征,进行分类研究,以比较空间尺度变化和特征融合对分类效果的影响。试验结果表明,随着节点数量的增加,有效特征数量有所增多,进而分类效果也有显著提升,说明细化脑区模板对分类结果的重要性;而融合多尺度脑网络特征之后,在控制特征数量不变的情况下,融合特征后的分类效果明显优于单个尺度脑网络的分类效果,进一步说明每个空间尺度下的脑网络特征都有其重要意义,通过融合多尺度脑网络特征才能更好地分析抑郁症fMRI数据,提升分类效果。

【参考文献】

- [1] World Health Organization. World health organization depression fact sheet[EB/OL]. [2017-9-30/2019-3-22]. <https://www.who.int/zh/news-room/fact-sheets/detail/depression>.
- [2] BRANDT W A, LOEW T, VON H F, et al. How does the ICD-10 symptom rating (ISR) with four items assess depression compared to

the BDI-II? A validation study[J]. J Affect Disorders, 2015, 173(2): 143-145.

- [3] MASKE U E, HAPKE U, RIEDELHELLER S G, et al. Respondents' report of a clinician-diagnosed depression in health surveys: comparison with DSM-IV mental disorders in the general adult population in Germany[J]. BMC Psychiat, 2017, 17(1): 39.
- [4] FRISTON K J, HOLMES A P, POLINE J B, et al. Analysis of fMRI time-series revisited[J]. Neuroimage, 1995, 2(1): 173-181.
- [5] NIXON N L, LIDDLE P F, NIXON E, et al. Biological vulnerability to depression: linked structural and functional brain network findings[J]. Br J Psychiat, 2013, 204(4): 283-289.
- [6] KOBELEVA X, FIRBANK M, PERAZA L, et al. Divergent functional connectivity during attentional processing in Lewy body dementia and Alzheimer's disease[J]. Cortex, 2017, 92: 8-18.
- [7] JOSEPH K, LANA K I, CARLOS C, et al. Aberrant functional whole-brain network architecture in patients with schizophrenia: a Meta-analysis[J]. Schizophr Bull, 2016, 42(Suppl 1): s13-s21.
- [8] XIN W, YANSHUANG R, WENSHENG Z. Depression disorder classification of fMRI data using sparse low-rank functional brain network and graph-based features[J]. Comput Math Method Med, 2017, 4(2): 1-11.
- [9] ROSA M J, PORTUGAL L, SHAW-TAYLOR J, et al. Sparse network-based models for patient classification using fMRI[J]. Neuroimage, 2015, 105(3): 493-506.
- [10] HADLEY J A, KRAGULJAC N V, WHITE D M, et al. Change in brain network topology as a function of treatment response in schizophrenia: a longitudinal resting-state fMRI study using graph theory[J]. Npj Schizophr, 2016, 2: 16014.
- [11] KHAZAEI A, EBRAHIMZADEH A, BABAJANI-FEREMI A. Application of advanced machine learning methods on resting-state fMRI network for identification of mild cognitive impairment and Alzheimer's disease[J]. Brain Imaging Behav, 2016, 10(3): 799-817.
- [12] JING B, LONG Z, LIU H, et al. Identifying current and remitted major depressive disorder with the Hurst exponent: a comparative study on two automated anatomical labeling atlases[J]. Oncotarget, 2017, 8(52): 90452-90464.
- [13] FRISTON K J. Statistical parametric mapping[J]. Hum Brain Funct, 1994, 4(6): 350-355.
- [14] DIESTEL R. Graph theory[J]. Math Gaz, 2000, 173(502): 67-128.
- [15] ROLLS E T, JOLIOT M, TZOURIO-MAZOYER N. Implementation of a new parcellation of the orbitofrontal cortex in the automated anatomical labeling atlas[J]. Neuroimage, 2015, 122: 1-5.
- [16] CHEN H, ZHEN X, GU X, et al. SPARSE: seed point auto-generation for random walks segmentation enhancement in medical inhomogeneous targets delineation of morphological MR and CT images[J]. J Appl Clin Med Phys, 2015, 16(2): 387-402.
- [17] BULLMORE E T, BASSETT D S. Brain graphs: graphical models of the human brain connectome[J]. Annu Rev Clin Psycho, 2011, 7(7): 113.
- [18] VIVIANI R, GRÖN G, SPITZER M. Functional principal component analysis of fMRI data[J]. Hum Brain Mapp, 2010, 24(2): 109.
- [19] YANG J, YANG J Y, ZHANG D, et al. Feature fusion: parallel strategy vs. serial strategy[J]. Pattern Recogn, 2003, 36(6): 1369-1381.
- [20] ADANKON M M, CHERIET M. Support vector machine[J]. Comput Sci, 2002, 1(4): 1-28.
- [21] PEDREGOSA F, GRAMFORT A, MICHEL V, et al. Scikit-learn: machine learning in Python[J]. J Mach Learn Res, 2013, 12(10): 2825-2830.

(编辑:陈丽霞)