

doi:10.3969/j.issn.1001-4616.2024.03.016

# 可解释孪生图对比学习及其在脑疾病诊断中的应用

徐如婷<sup>1</sup>, 朱旗<sup>1</sup>, 孙凯<sup>2</sup>, 朱敏<sup>3</sup>, 邵伟<sup>1</sup>, 张道强<sup>1</sup>

(1.南京航空航天大学计算机科学与技术学院, 江苏 南京, 211106)

(2.深圳市华赛瑞飞智能科技有限公司, 广东 深圳 518063)

(3.南京航空航天大学公共实验教学部, 江苏 南京 211106)

**[摘要]** 近年来,许多研究采用静息态磁共振成像(rs-fMRI)构建动态功能连接网络,并将其应用于癫痫、精神分裂症等脑部疾病的诊断。研究表明,图卷积网络可以有效保存图结构,提取脑网络的高阶特征。然而,现有的利用GCN模型对脑疾病进行诊断的模型通常在训练的过程中不进行图结构的更新,因此模型效果常常受到输入图质量的约束。另外由于GCN模型缺乏可解释性的特点,也限制了模型在疾病诊断上的广泛应用。在本文中,我们提出了一个可解释的孪生图对比网络用于提取大脑的时空信息。具体而言,可解释模块通过图生成网络结合脑区之间的相关性信息,动态调整输入模型图结构。图对比模块学习脑网络全局和局部的信息提高特征表达的鉴别性。孪生网络模块将成对的样本图作为模型输入,从而缓解数据样本量少的问题。所有模块联合优化,在个体层面提取大脑网络时域和空域上的特征并进行可靠的疾病诊断。实验结果表明,该方法在癫痫数据集上具有较好的诊断性能,并为疾病诊断提供可解释性。

**[关键词]** 脑网络研究,可解释,图生成网络,图对比学习,孪生网络

**[中图分类号]** TP399 **[文献标志码]** A **[文章编号]** 1001-4616(2024)03-0129-09

## Interpretable Siamese Graph Contrastive Networks for Brain Disease Diagnosis

Xu Ruting<sup>1</sup>, Zhu Qi<sup>1</sup>, Sun Kai<sup>2</sup>, Zhu Min<sup>3</sup>, Shao Wei<sup>1</sup>, Zhang Daoqiang<sup>1</sup>

(1.School of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

(2.Shenzhen Huasai Ruifei Intelligent Technology Co., Ltd, Shenzhen 518063, China)

(3.Public Experiment Teaching Department of Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

**Abstract:** In recent years, many studies have used rs-fMRI to construct dynamic functional connectivity network and applied it to the diagnosis of brain diseases such as epilepsy and schizophrenia. The results show that graph convolution network(GCN) can effectively preserve graph structure and extract higher-order features of brain network. However, the existing models using GCN model to diagnose brain diseases usually do not update the graph structure during the training process, so the model effect is often constrained by the quality of the input graph. In addition, the lack of explainability limits the wide application of GCN model in disease diagnosis. In this paper, we propose an interpretable Siamese graph contrastive network to extract spatio-temporal information from the brain network. Specifically, the interpretable module dynamically adjusts the graph structure of the input model by combining the correlation information between brain regions through graph generation network. The graph contrast module learns global and local information of brain network to obtain discriminative feature embedding. Siamese network module takes paired subject graph as model input to alleviate the problem of small data subject size. All modules in our method are optimized together to extract temporal and spatial features of brain networks at the individual level for reliable disease diagnosis. Experimental results show that the proposed method achieves promising diagnostic performance on epilepsy datasets and provides explainable results.

**Key words:** brain network research, interpretable, graph generation network, graph contrastive learning, siamese networks

应用于神经成像数据的网络分析技术能够揭示大脑的底层结构或功能。其中脑网络技术提供了脑区域间相互作用模式的强大表征,在研究癫痫、精神分裂症、阿尔茨海默病等多种脑部疾病的机制方面受到

收稿日期:2022-09-20.

基金项目:江苏省自然科学基金项目(BK20231438)、江苏省重点研发项目(BE202282)、国家自然科学基金项目(62076129、62371234)。

通讯作者:朱旗,博士,副教授,研究方向:机器学习,模式识别和脑疾病诊断。E-mail:zhuqinuaa@163.com

了广泛关注.

脑网络由节点和边构成,其中节点代表由生理模板定义的大脑区域,边通常是利用皮尔逊相关系数计算的脑区之间的相互作用. 目前对于脑网络的分析分为两个方面:(1)静态功能连接网络;(2)动态功能连接网络. 静态功能性连接网络将大脑区域之间的连接视为常数. 然而,大脑本质上是一个动态系统,在执行任务的过程中,随着时间的推移,大脑网络不断重构<sup>[1]</sup>. 因此,能够有效挖掘脑网络的时空信息对于脑疾病诊断来说至关重要. 为了获得脑网络的动态特征,最常见的方法就是通过滑动时间窗口划分不同的时域,之后去捕获不同时域之间脑区的信息传递. 例如 Jie 等<sup>[2]</sup>利用非重叠时间窗方法,从 rs-fMRI 时间序列中构建每个受试者的动态连接网络,之后通过计算特定脑区功能序列的相关性来表征动态功能连接网络的空间变异性. Wang 等<sup>[3]</sup>在 rs-fMRI 上划分滑动时间窗口,之后在阿兹海默病数据集上利用端到端时空卷积神经网络提取脑网络时间与空间的特征信息.

利用脑网络分析对脑疾病进行诊断是一个复杂的问题,这是由于医学样本数据量少,并且脑结构复杂. 近年来,人们提出了一些图神经网络(GCN)方法来学习复杂的具有非线性结构的脑网络. 作为一种强大的图数据表示方式,GCN 可以有效地整合网络的节点特征和图的拓扑结构,非常适合研究脑网络这种非线性结构数据. 例如 Yu 等<sup>[4]</sup>设计了一个多尺度增强 GCN 框架,融合了静息态磁共振成像和扩散张量成像的功能信息和结构信息,用于早期轻度认知障碍的诊断并获得了很好的诊断效果. Zhang 等<sup>[5]</sup>利用了多视图 GCN 和成对匹配策略,融合大脑的多种影像信息用于帕金森病的预测. 该模型与传统的单模态模型相比,诊断精准度大大提高. 然而,当前的用于脑疾病研究的 GCN 模型通常忽略了以下三个问题. 第一,GCN 的性能高度依赖于输入邻接矩阵的质量. 然而,目前的模型通常使用的是固定的邻接矩阵图,没有动态考虑训练数据的结构特点,以至于容易在个性化诊断中输出次优性能. 第二,与其他深度网络对比,GCN 不能输出可解释性的诊断结果<sup>[6]</sup>. 第三,利用 GCN 来作图分类的时候,通常是整图嵌入为一个特征,但是这样的方法只能保留住图的全局特征,失去了图的局部特征,因此降低了诊断的准确率.

针对以上的问题,在本文中,我们提出了一个可解释的孪生图对比网络用于提取大脑的时空信息. 整体框架展示在图 1 中. 具体来说,我们提取静息态磁共振图像中的感兴趣脑区(ROI)上的时间序列,再利用固定大小的滑动时间窗口将时间序列分成多个重叠的块. 然后,利用堆叠的 LSTM 单元来捕获时间窗口间脑区之间的时间信息. 我们将皮尔逊相关系数计算出的脑网络视为图的邻接矩阵,而将脑区之间的时间信息作为节点的特征矩阵,为每一个样本构建一张图. 之后,我们构建孪生结构将成对的样本图作为模型输入,目的是缓解数据样本量少的问题. 通过对 ROI 之间的相关性学习,我们动态调整输入孪生网络的图结构,使得模型能够输出更具有解释性的结果. 在动态学习图结构的基础上,我们进一步对样本嵌入的特征施加图对比学习约束来获取每一个 FCN 的局部属性和全局属性,从而增强了样本的特征表示. 在癫痫数据上的实验结果表明,

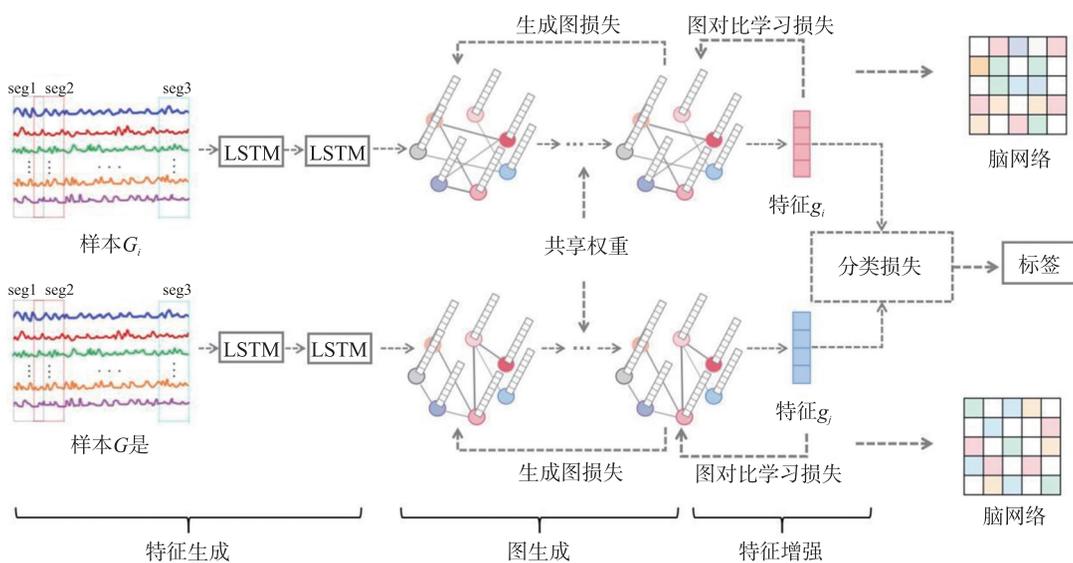


图 1 框架提出流程图

Fig. 1 The overview of the proposed method

所提出的方法相比于其他先进的脑疾病诊断方法,能够达到更好的可信的诊断效果.

总之,本文提出的方法具有以下几点优势:

(1)我们使用孪生网络结构,利用大脑网络的两两相似学习来指导学习过程,从而缓解样本稀缺问题.

(2)利用图生成网络,动态调整输入模型的图结构,使得模型生成可解释的脑网络.

(3)结合图对比学习使得学习到的特征具有脑网络全局和局部的信息,使得获取的特征更具有鉴别性,从而提高疾病诊断准确率.

## 1 可解释的孪生图对比网络

我们提出的框架分为3部分:(1)使用 LSTM 来捕获大脑网络的动态时间特征;(2)利用一个孪生的图学习架构来生成特征嵌入和可解释的大脑网络;(3)图对比学习使得嵌入的特征具有大脑网络的全局和局部特征.接下来,我们分块对模型进行阐述.

### 1.1 时间卷积层

我们假设受试者的 rs-fMRI 时间序列数据为  $X=(x_1, \dots, x_N)^T \in R^{N \times M}$ ,其中第  $n$  个向量  $x_n \in R^M$  包含在连续  $M$  个时间点 ROI 的血氧水平相关测量值.研究发现,即使在静止状态下,脑功能网络也表现出显著的时间变异性,而这种时间变异性包含了大量的信息,可以更好地描述 DFCNs<sup>[7]</sup>.因此为了获得跨时间域脑区之间的动态交互信息,我们将所有 rs-fMRI 时间序列分割为  $L$  长度恒定的  $T$  重叠窗口,并在时间窗口之间使用两层叠加的 LSTM 模块.通过 LSTM 层,我们为每个 ROI 生成包含时间信息的特征  $F_n \in R^l$ ,用于后续的图构造.

### 1.2 孪生图生成网络

本文采用孪生结构的图生成网络,利用脑网络的两两相似度学习来指导学习过程.图神经网络能有效地结合拓扑结构和节点特征,能很好地学习非欧数据的特征.在图卷积网络中,脑功能连接网络被视为图的邻接矩阵,跨时域间脑区的动态交互信息被视为图的特征矩阵.对于每个样本,我们可以构造图  $G_i$  为  $G_i=(F_i, A_i)$ ,其中  $F_i$  为特征矩阵,  $A_i$  为邻接矩阵.因此 GCN 的计算公式为:

$$Z_i = \text{ReLu}(D^{-\frac{1}{2}} A_i D^{-\frac{1}{2}} F_i W), \quad (1)$$

式中,  $D$  为  $N \times N$  的度矩阵.我们将最后一层输出嵌入表示为  $Z_i$ .

为了缓解数据样本稀缺问题,我们引入了孪生网络来指导大脑网络的学习.孪生网络将一对样本作为网络的输入,并输出样本之间的相似性<sup>[8]</sup>.图神经网络之间共享相同的权值,从而保证每个输入图都能被孪生网络以相同的方式处理.在本文中,我们设计损失函数以使来自同一类别的两个输入样本之间的欧氏距离最小化,而来自不同类别的两个输入样本之间的距离最大化.孪生网络的损失函数可以表示为:

$$L_s = \frac{y}{2} \| Z_i - Z_j \|_2^2 + (1-y) * \frac{1}{2} \{ \max(0, m - \| Z_i - Z_j \|_2) \}^2, \quad (2)$$

式中,  $Z_i$  和  $Z_j$  为样本  $i$  和样本  $j$  经过 GCN 获得的图嵌入,  $m$  是大于 0 的边际值.如果两个被试来自同一个类别,  $y$  等于 1, 否则  $y$  等于 0.

对于 GCN 来说,邻接矩阵和特征矩阵是最重要的两个输入,它们的质量影响着模型分类的性能.但在大多数情况下,GCN 输入的图结构是基于先验知识的,通常包含冗余信息,且与学习任务无关,容易产生次优结果<sup>[9]</sup>.此外,GCN 不能产生可解释的诊断结果.因此,如何动态调整图结构,输入更具识别力的脑网络是提高诊断性能的关键.因此,我们结合可解释特征学习模块和 GCN 模块进行动态图学习,生成可解释脑网络.具体来说,我们在 GCN 学习的过程中增加了正则化项用于图学习,如图 2 所示.损失正则化项  $L_{CL}$  可以定义为:

$$L_{CL} = \min_A \frac{1}{N^2} \sum_{i,j=1}^N \exp(A_{ij} + \alpha \| f_i - f_j \|_2^2) + \beta \| A \|_F^2, \quad (3)$$

式中,  $\| \cdot \|_F$  为  $F$  范数.目标函数中的第一项惩罚了节点  $i$  和节点  $j$  之间的相似性.具体来说,如果两个 ROI 高度相似,应增强其强连通性,否则抑制其弱连通性,该过程可以防止图卷积聚集噪声节点信息<sup>[10]</sup>. $\alpha$  是控制图节点重要性的一个参数.第二项用于控制邻域矩阵  $A$  的稀疏性.总的来说,通过图学习模块,我们可以学习到更多高质量的可解释的脑网络表示.

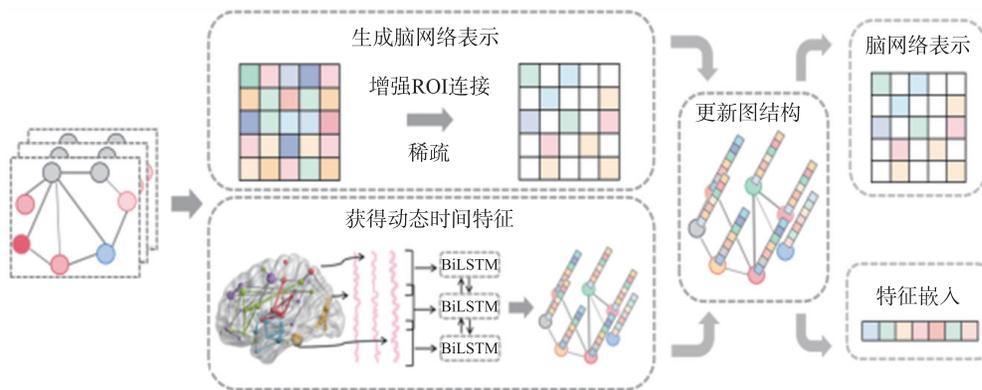


图 2 利用图生成网络更新图结构  
Fig. 2 Update graph structure by graph generate network

### 1.3 对比学习模块

利用 GCN 进行图分类时,每个被试的特征表示只具有脑网络的全局特征,常常丢失了局部信息.受近年来图对比学习<sup>[11-12]</sup>的启发,我们在图和特征表示之间应用对比约束,使互信息最大化,从而使输出特征表示包括了脑网络的全局和局部信息.针对  $(G_i, Z_i)$  的损失函数可以计算为:

$$L_{\text{contrastive-}i} = \frac{1}{2S} \left( \frac{1}{N} \sum_{j=1}^N I(G_i; Z_j^i) + I(Z_i; G_i^j) \right). \tag{4}$$

为了有效优化,我们使用 Jason-Shannon Divergence (JSD) 来估计式(4)中  $I(X; Y)$  的互信息:

$$I(Z_i^j; G_i^j) = -sp(-d(Z_i^j; G_i^j)) - \frac{1}{N-1} \sum_{n_j \in N \setminus \{n_i\}} sp(d(Z_i^j; G_i^j)), \tag{5}$$

式中,  $sp(x) = \log(1+e^x)$ ,  $d$  是一个带有 sigmoid 激活的内积函数.由于孪生网络的输入是一对样本,因此两个样本特征的损失记为  $L_{\text{contra}}$ :

$$L_{\text{contra}} = L_{\text{contrastive-}i} + L_{\text{contrastive-}j}. \tag{6}$$

### 1.4 优化目标函数

输出嵌入  $Z$  经过线性变换和 softmax 函数得到预测的标签.我们将所有主题的图分类的交叉熵损失表示为  $L_c$ .总体来说,我们模型的输出包括两部分:获取分类标签和生成判别脑网络.因此,总体目标函数包括四个部分:生成可解释的脑网络表示  $L_{\text{GL}}$ ,图对比学习损失  $L_{\text{contra}}$ ,孪生网络学习损失  $L_s$  以及分类损失  $L_c$ .总体可以计算为:

$$L = L_{\text{GL}} + L_{\text{contra}} + L_s + L_c. \tag{7}$$

之后,我们在标记数据的指导下,利用反向传播对模型进行优化,学习图的嵌入进行分类.

## 2 实验

### 2.1 实验设置

在本研究中,我们以金陵医院的癫痫数据集为样本,采用 10 折交叉验证的方法对所提出的方法进行评价.四种二分类任务被用来评估我们的模型性能,包括:NC vs. TLE&FLE(ILL)、NC vs. TLE、NC vs. FLE 和 TLE vs. FLE.每个任务的表现都通过三个指标来衡量,即准确性(ACC)、F1 得分和 AUC.

### 2.2 对比方法

为了验证我们提出的方法的有效性,我们将其在四个分类任务下的分类性能与最先进的模型方法进行比较.对比方法包括:dFCN\_LSTM<sup>[13]</sup>,Dfuse<sup>[14]</sup>,BrainNetCNN<sup>[15]</sup>,SCP-GCN<sup>[16]</sup>,GCNeuro<sup>[17]</sup>.实验结果展示在表 1 中.结果表明,我们提出的方法在癫痫数据集的四个分类任务上都取得了最好的效果.所提出的方法之所以能取得很好的效果是因为我们通过图对比学习有效地挖掘了大脑网络的时空信息,并引入了孪生结构网络的结构,缓解了样本稀缺的问题.并且相比于其他直接使用堆叠 GCN 的方法,例如 GCNeuro 和 SCP-GCN,我们利用图生成网络,通过调整所有 ROI 中的相似关联和不同关联来动态更新图结构,使模型能够输出可解释性的诊断结果.

表 1 所提出的方法和对比方法的性能比较

Table 1 Performance comparison of the proposed and competing methods

Method	NC vs. TLE&FLE			NC vs. TLE		
	ACC	F1	AUC	ACC	F1	AUC
dFCN_LSTM	66.72	56.90	66.35	62.64	65.02	62.63
Dfuse	70.98	59.68	72.59	68.90	72.59	69.48
BrainNetCNN	73.77	78.95	71.07	72.73	66.67	68.34
SCP-GCN	77.41	74.07	73.11	75.75	70.64	68.33
GCNeuro	67.98	72.36	56.09	67.40	55.86	66.53
ours	80.73	85.08	74.85	76.93	71.69	69.49

Method	NC vs. FLE			TLE vs. FLE		
	ACC	F1	AUC	ACC	F1	AUC
dFCN_LSTM	64.01	70.97	68.40	60.47	66.98	59.50
Dfuse	61.18	62.37	65.75	76.05	69.11	70.38
BrainNetCNN	67.50	71.11	67.04	66.67	57.14	65.00
SCP-GCN	78.57	71.43	74.55	71.05	66.67	69.34
GCNeuro	70.87	43.33	59.54	66.79	41.04	58.79
ours	79.19	75.73	87.36	77.05	71.68	73.47

表 2 癫痫数据集上 4 个分类任务的消融实验结果

Table 2 Ablation experiments of four classification tasks on an epileptic dataset

Method	NC vs. TLE&FLE			NC vs. TLE		
	ACC	F1	AUC	ACC	F1	AUC
SCG-s	79.08	83.22	74.25	74.63	69.34	67.60
SCG-g	72.19	80.76	63.78	71.40	67.90	66.65
SCG-c	80.43	84.91	72.01	76.01	71.24	69.46
ours	80.73	85.08	74.85	76.93	71.69	69.49

Method	NC vs. FLE			TLE vs. FLE		
	ACC	F1	AUC	ACC	F1	AUC
SCG-s	75.33	72.33	84.98	74.45	69.57	69.95
SCG-g	71.95	53.14	67.65	76.66	70.99	71.25
SCG-c	73.95	69.47	84.09	71.95	53.14	67.64
ours	79.19	75.73	87.36	77.05	71.68	73.47

### 2.3 消融实验

为了验证孪生网络结构、可解释的图生成网络模块和图对比学习模块的有效性,我们进行了三组消融实验. 实验结果展示在表 2 中. 具体来说,SCG-s 移除了孪生网络的结构,使用单个样本作为图生成网络的输入并施压图对比学习约束来获得样本更具有鉴别性的特征. SCG-g 移除了动态更新图结构的模块,即将图生成网络模块替换为 GCN 模块,输入的邻接矩阵始终为皮尔逊相关系数构建的脑网络. SCG-c 移除了图对比学习模块,仅仅利用 embedding 后的全局特征诊断. 从表 2 中,我们可以发现所提出的方法在癫痫数据集的四个分类任务下均优于 SCG-s, SCG-g, SCG-c. 这证明了我们所提出了可解释的孪生图生成网络是有效的,能够挖掘出脑网络中具有鉴别性的时空特征.

## 3 讨论

### 3.1 滑动时间窗口的有效性

我们划分滑动时间窗口来捕捉脑功能网络的动态特性. 为了进一步研究滑动窗口大小对模型分类性能的影响,我们进行了不同滑动窗口大小的实验. 实验结果展示在图 3 中. 显然,当滑动窗口大小

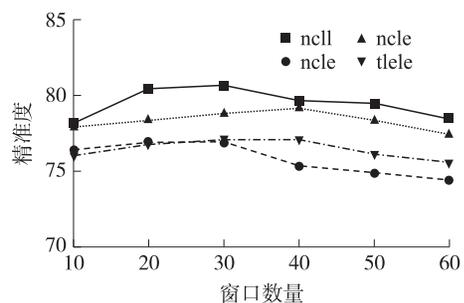


图 3 窗口划分数量对模型性能的影响

Fig. 3 The influence of number of window partitions on model performance

较大(如 60)或较小(如 10)时,我们的方法分类精度较差. 我们认为这种现象是合理的,因为窗口数量过少,不同时间窗口下 ROI 之间的信息交互会丢失,信息的丢失会导致分类精度低. 当时间窗划分过多时,可能包含过多的冗余信息,也会降低分类精度.

### 3.2 参数敏感性讨论

我们所提出的模型一共涉及在公式(3)中的两个参数  $\alpha$  和  $\beta$ . 其中  $\alpha$  控制图中节点的重要度,如果两个 ROI 高度相似,应增强其强连通性,否则抑制其弱连通性. 参数  $\beta$  控制学习到脑网络表示的系数性. 我们使用网格搜索法并设置  $\alpha \in [0.1, 0.2, 0.3, \dots, 1.0]$ ,  $\beta \in [0.1, 0.2, 0.3, \dots, 1.0]$ . 在癫痫数据集上的四个分类任务上的分类结果展示在图 4 中. 从结果上看,当  $\alpha$  和  $\beta$  取值在 0.5 附近的时候,在四个任务下都能取得最好的诊断结果. 但是不论  $\alpha$  和  $\beta$  取值为多少,实验分类的精度都是稳定的,证明了所提公式的鲁棒性.

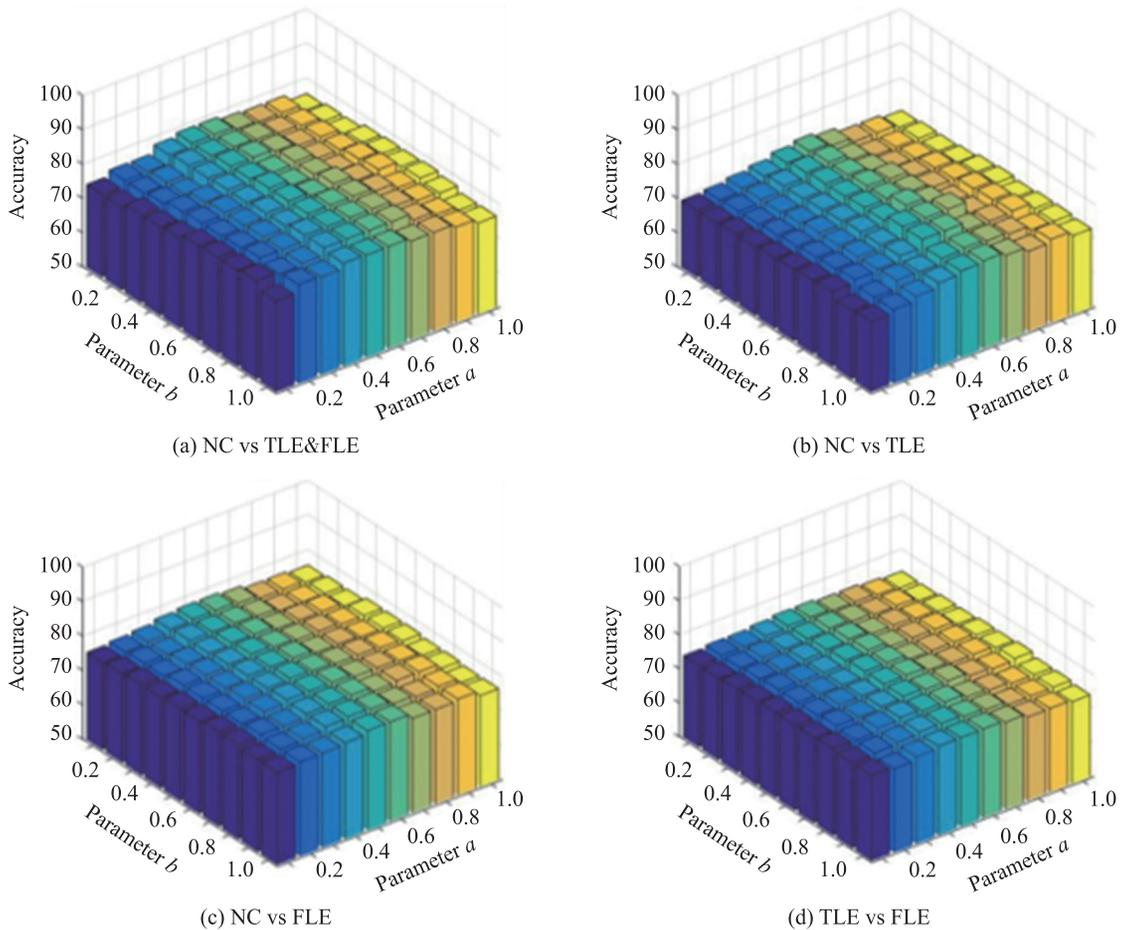


图 4 癫痫数据集 4 个任务下不同参数值模型分类性能

Fig. 4 Classification performance of models with different parameter values in four epilepsy tasks

### 3.3 脑网络可视化

我们所提出的方法的输出由两部分组成:生成可解释的脑网络矩阵表示和诊断结果. 我们随机选择了一个样本,在图 5 中展示利用皮尔逊相关系数构造的脑网络以及通过提出的模型生成的可解释性脑网络. 从图中我们可以看出,我们所提出的方法所表示的脑网络相比于皮尔逊构建的网络更加稀疏并且突出了一些与疾病相关的重要连接. 除此以外,我们利用提出的方法来找出能够诊断疾病的最具鉴别性脑区. 具体来说,我们分别在 NC vs. TLE&FLE(ILL), NC vs. TLE, NC vs. FLE 和 TLE vs. FLE 四个任务下,可视化了 10 个连接被最频繁增强的脑区并展示在图 6 中. 在 NC vs. ILL 任务中,具有鉴别性的脑区为苍白球、扣带回、额叶. 在 NC vs. TLE 任务中,与疾病最相关的脑区集中在海马旁回、嗅觉皮层和颞中回. 在 NC 和 FLE 任务中,关键区域包括额上回、颞中回和辅助运动区. 在 TLE 和 FLE 的任务中,颞中回和海马旁回相关的连接被明显的增强. 这些模型中发现的鉴别性的脑区,在以往研究中也证明和癫痫有关<sup>[18-22]</sup>.

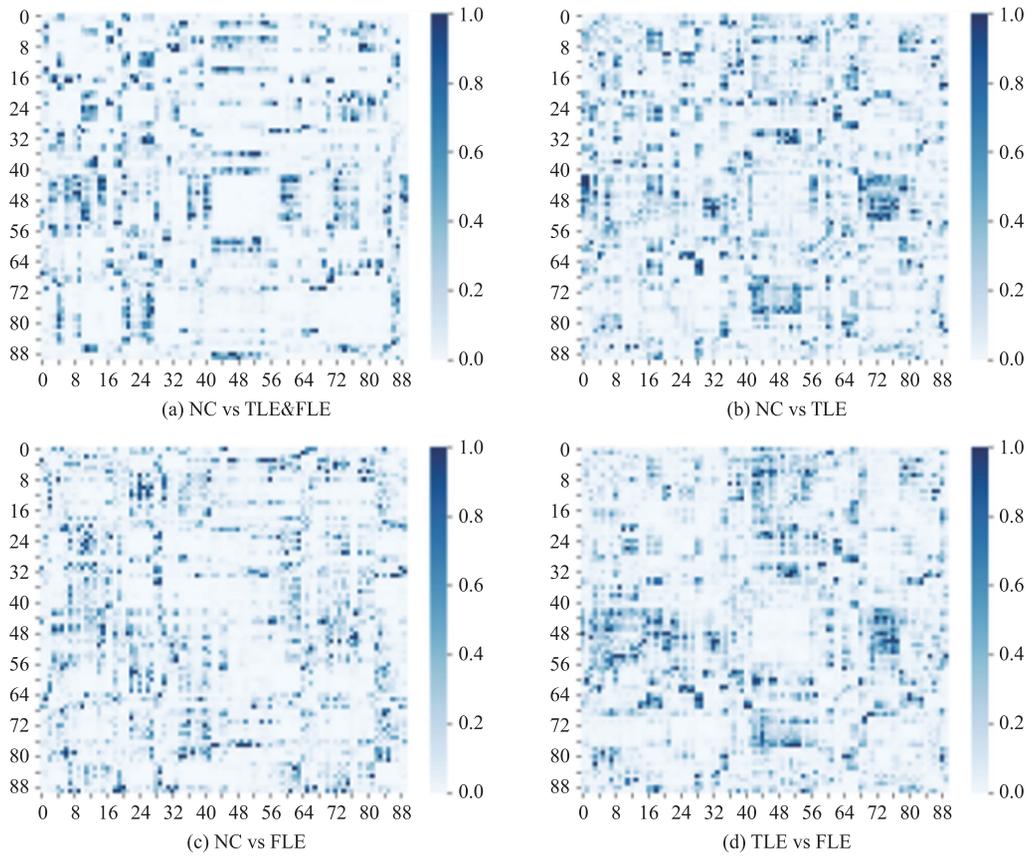


图 5 癫痫数据集 4 个分类任务下生成的脑网络表示

Fig. 5 Representation of brain networks generated under four classification tasks in epilepsy

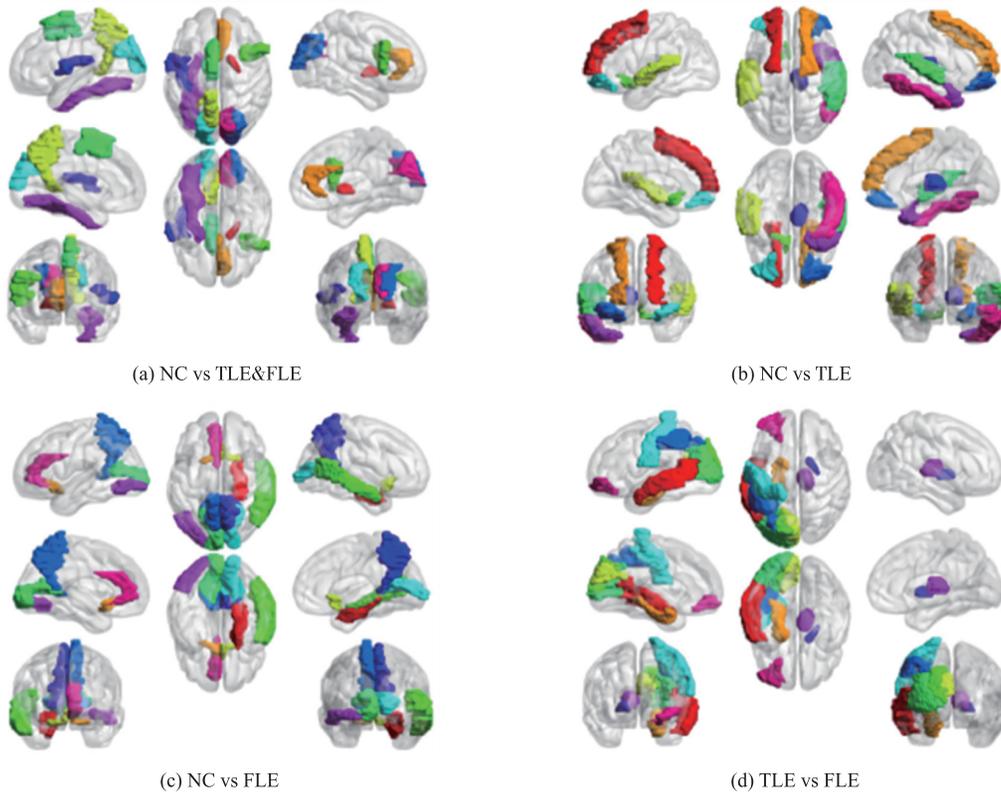


图 6 4 个分类任务下大脑中最具区分性的 10 个脑区的空间位置

Fig. 6 The spatial locations of the 10 most discriminating ROIs under four categorization tasks

## 4 结论

在本文中,我们提出了一个可解释的孪生图对比模型,能够有效挖掘出大脑时间和空间的信息用于脑疾病诊断. 具体来说,我们利用堆叠的 LSTM 来获得脑区跨时域之间的动态时间特征,并结合脑功能性连接网络为每个样本构造图. 之后,将成对的样本图作为模型输入从而缓解了样本数量少带来的问题. 在学习的过程中,我们根据脑区之间的相关性动态更新输入的图结构,生成可解释的脑网络. 为了使获得的嵌入特征更具有鉴别性,我们利用图对比学习挖掘出脑网络全局和局部的特征. 总而言之,所提出的模型不仅能够挖掘出原始脑网络结构中具有鉴别性的时空信息,还能生成可解释的脑网络表示. 在癫痫数据集上的实验结果表明,我们提出的模型在从健康者中识别癫痫患者方面取得了卓越的性能. 我们的工作有效结合了 FMRI 动态信息以及 DTI 模态信息,在未来工作中我们将考虑构建模型时引入更多非影像特征使标准脑网络特征更加精准.

### [参考文献]

- [1] FINC K, BONNA K, HE X, et al. Dynamic reconfiguration of functional brain networks during working memory training[J]. *Nature communications*, 2020, 11(1): 1–15.
- [2] JIE B, LIU M, SHEN D. Integration of temporal and spatial properties of dynamic connectivity networks for automatic diagnosis of brain disease[J]. *Medical image analysis*, 2018, 47: 81–94.
- [3] WANG M, LIAN C, YAO D, et al. Spatial-temporal dependency modeling and network hub detection for functional MRI analysis via convolutional-recurrent network[J]. *IEEE transaction on biomedical engineering*, 2019, 67(8): 2241–2252.
- [4] YU S, WANG S, XIAO X, et al. Multi-scale enhanced graph convolutional network for early mild cognitive impairment detection [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Vancouver, Canada: Springer, Cham, 2020: 228–237.
- [5] ZHANG X, HE L, CHEN K, et al. Multi-view graph convolutional network and its applications on neuroimage analysis for parkinson's disease[J]. *AMIA Annual Symposium Proceedings*, 2018, 2018: 1147–1156.
- [6] ZHU Y, MA J, YUAN C, et al. Interpretable learning based dynamic graph convolutional networks for alzheimer's disease analysis[J]. *Information fusion*, 2022, 77: 53–61.
- [7] CETIN M S, HOUCK J M, RASHID B, et al. Multimodal classification of schizophrenia patients with meg and fmri data using static and dynamic connectivity measures[J]. *Frontiers in neuroscience*, 2016, 10: 466, .
- [8] KOCH G, ZEMEL R, SALAKHUTDINOV R. Siamese neural networks for one-shot image recognition [C]//ICML Deep Learning Workshop. Lille, France: JMLR, 2015, 2(1): 1–30.
- [9] SHU H, WANG X, ZHU H T, D-CCA: A decomposition-based canonical correlation analysis for high-dimensional datasets[J]. *Journal of the American Statistical Association*, 2020, 115(529): 292–306.
- [10] YU R, ZHANG H, AN L, et al. Connectivity strength-weighted sparse group representation-based brain network construction form ci classification[J]. *Human brain mapping*, 2017, 38(5): 2370–2383.
- [11] ZHANG M, ZHU Y, WU S, et al. Deep contrastive learning for multi-view network embedding[J/OL]. arXiv preprint arXiv: 2108.08296, 2021.
- [12] HASSANI K, KHASAHMADI A H. Contrastive multi-view representation learning on graphs[C]//International Conference on Machine Learning (ICML). San Diego, CA: PMLR, 2020, 119(119): 4116–4126.
- [13] YAN W, ZHANG H, SUI J, et al. Deep chronnectome learning via full bidirectional long short-term memory networks for MCI diagnosis[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Granada, Spain: Springer, Cham, 2018, 11072: 249–257.
- [14] WANG Q, ZHAN L, THOMPSON P M, et al. Discriminative fusion of multiple brain networks for early mild cognitive impairment detection[C]//2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI). Prague, Czech Republic: IEEE, 2016: 568–572.
- [15] KAWAHARA J, BROWN C J, MILLER S P, et al. BrainNetCNN: convolutional neural networks for brain networks; towards predicting neurodevelopment[J]. *NeuroImage*, 2017, 146: 1038–1049.
- [16] LIU J, MA G, JIANG F, et al. Community-preserving graph convolutions for structural and functional joint embedding of brain

- networks[C]//2019 IEEE International Conference on Big Data(Big Data). Los angeles, CA:IEEE,2019:1163-1168.
- [17] MCDANIEL C, QUINN S. Developing a graph convolution-based analysis pipeline for multi-modal neuroimage data: an application to parkinson's disease[C]//Proceedings of the 18th Python in Science Conference(SciPy 2019). Austin TX:IEEE 2019:42-49.
- [18] HUANG J, ZHOU L, WANG L, et al. Attention-diffusion-bilinear neural network for brain network analysis [J]. IEEE transactions on medical imaging, 2020, 39(7) :2541-2552.
- [19] WAITES A B, BRIELLMANN R S, SALING M M, et al. Functional connectivity networks are disrupted in left temporal lobe epilepsy[J]. Annals of neurology, 2006, 59(2) :335-343.
- [20] Braakman H M, Vaessen M J, Jansen J F, et al. Frontal lobe connectivity and cognitive impairment in pediatric frontal lobe epilepsy[J]. Epilepsia, 2013, 54(3) :446-454.
- [21] STRUB R L. Frontal lobe syndrome in a patient with bilateral globus pallidus lesions[J]. Archives of neurology, 1989, 46(9) : 1024-1027.
- [22] GLOOR P, OLIVIER A, QUESNEY L F, et al. The role of the limbic system in experiential phenomena of temporal lobe epilepsy[J]. Annals of neurology, 1982, 12(2) :129-144.

[责任编辑:杜忆忱]