

基于多尺度残差融合图卷积网络的脑疾病诊断研究

郝小可, 何子龙, 卢欣楚, 马明明, 刘时宇

(河北工业大学人工智能与数据科学学院, 天津 300401)

摘要: 近年来, 功能性脑网络已被用于自闭症谱系障碍 (Autism spectrum disorder, ASD) 等脑部疾病的诊断。现有研究表明, 将静息态功能磁共振成像 (Resting-state functional magnetic resonance imaging, rs-fMRI) 数据以及非影像信息结合起来构成人口图, 然后采用图神经网络 (Graph neural network, GNN) 进行学习和分类的方法对 ASD 的诊断十分有效。然而, 大多数研究仍然面临两个挑战: 一是仅使用皮尔森相关系数等方法构建功能连接矩阵无法有效地识别和分析与疾病相关的局部脑区和生物标志物; 二是无法在 GNN 上有效地学习人口图中节点特征的多尺度信息。为解决这些问题, 提出了一种基于注意力机制的多尺度残差融合图卷积网络 (Multi-scale residual fusion graph convolutional networks, MSRF-GCN)。该算法通过设计一个功能连接生成器来提取具有远程依赖关系的时间相关特征, 从而有效地定位和识别对诊断有益的脑区。同时, 通过设计多尺度残差融合算法, 学习人口图中的多尺度信息。此外, 还引入了 Edge Sparse 策略, 通过随机丢弃初始人口图中的边, 以增加节点连接的稀疏性, 进而减少训练期间过拟合的风险。通过在自闭症脑影像数据交换项目 (Autism brain imaging data exchange, ABIDE) 上进行实验的结果证明了 MSRF-GCN 在 ASD 诊断方面的有效性。

关键词: 自闭症谱系障碍; 功能连接; 注意力机制; 人口图; 图神经网络

中图分类号: TP391 **文献标志码:** A

Diagnosis of Brain Diseases Based on Multi-scale Residual Fusion Graph Convolutional Networks

HAO Xiaoke, HE Zilong, LU Xinchu, MA Mingming, LIU Shiyu

(School of Artificial Intelligence, Hebei University of Technology, Tianjin 300401, China)

Abstract: In recent years, functional brain networks have been used in the diagnosis of brain disorders such as autism spectrum disorder (ASD). Existing studies have shown that combining resting-state functional magnetic resonance imaging (rs-fMRI) data as well as non-imaging information to form a population graph, and then learning and classifying the data by using graph neural network (GNN) is very effective in the diagnosis of ASD. However, most studies still face two challenges: First, the construction of functional connectivity matrices using methods such as Pearson correlation coefficient cannot effectively identify and analyze localized brain regions and biomarkers associated with diseases; second, it is difficult to efficiently learn multi-scale information about node features in population graphs on GNN. To solve

基金项目: 国家自然科学基金 (62276088); 河北省自然科学基金 (F2023202072, H2023202901)。

收稿日期: 2024-06-09; **修订日期:** 2024-07-10

these problems, a multi-scale residual fusion graph convolutional networks (MSRF-GCN) based on the attention mechanism is proposed. The algorithm efficiently localizes and identifies brain regions useful for diagnosis by designing a functional connection generator to extract temporally relevant features with remote dependencies. Meanwhile, the multi-scale information in the population graph is learned by designing a multi-scale residual fusion algorithm. The Edge Sparse strategy is also introduced to increase the sparsity of node connections by randomly discarding edges in the initial population graph, which in turn reduces the risk of overfitting during training. The effectiveness of MSRF-GCN in the diagnosis of ASD is demonstrated by the results of experiments performed on the autism brain imaging data exchange (ABIDE) program.

Key words: autism spectrum disorder (ASD); functional connection; attention mechanism; population graph; graph neural network (GNN)

引言

自闭症谱系障碍(Autism spectrum disorder, ASD)是一种神经发育障碍,一般以重复的刻板行为和社交困难为主要特征,早期诊断和干预有利于提高该疾病的治疗效果^[1]。此外,ASD是一种终身性的发育障碍疾病,它影响了人们与外界的交流和互动。随着医学研究的不断进步,ASD的治疗方法得到了很大的改善。然而,目前ASD的诊断技术主要依赖于问卷调查或临床观察^[2],具有很大的主观性和敏感性,并可能导致误导性的结果。因此,迫切需要客观地探索病理生物标志物以进行早期干预。

静息态功能磁共振成像(Resting-state functional magnetic resonance imaging, rs-fMRI)是一种非侵入性的成像技术,它可以量化脑区的活动,并已被广泛应用于脑疾病的研究^[3]。在功能磁共振成像(Functional magnetic resonance imaging, fMRI)研究中,一般都使用血氧水平依赖性(Blood oxygen level dependent, BOLD)来评估功能性大脑活动,并揭示大脑网络中可能导致神经功能障碍的新模式。通过这种技术,人脑活动的模式不仅可以通过人脑网络的功能或结构连接来描述,还可以用图的形式进行表示^[4]。

随着现代医疗以及人工智能技术的快速发展,基于深度学习的方法已广泛应用于疾病预测任务并取得了优异的效果。Heinsfeld等^[5]使用自编码器来学习全脑功能连接(Functional connection, FC)特征,通过构建一个深度神经网络,并使用迁移学习的方法成功地对ABIDE数据集中1 035名受试者进行了分类。李习之等^[6]提出了一种基于低秩表示和域适应的方法,通过将数据表示、数据重构和分类损失整合到一个统一的框架中,成功地学习到具有判别性的数据表示,有效地解决了多中心自闭症诊断中的数据分布差异问题。Eslami等^[7]通过构建由自编码器和一个单层感知机(Single layer perceptron, SLP)组成的混合网络进行联合学习来提取rs-fMRI数据中的特征,并利用数据增强,优化了参数并提高了提取特征的质量。郝小可等^[8]提出了一种联邦加权域自适应方法,通过提高属于互逆最近邻与属于同一数据样本的窗口样本间伪标签的一致性,充分利用了ABIDE数据集中无标注站点上的数据,解决了缺乏标注数据的站点的局部阻塞问题。深度学习方法有助于融合多模态数据来诊断精神障碍。然而,基于非图的深度学习方法不利于多模态数据的建模,通常只支持使用单模态数据,这限制了模型的性能。

近年来,GNN已被广泛用于解决医学fMRI图像表示学习的医学问题。GNN通过显式捕获大脑网络的拓扑信息,将深度神经网络与图表示学习相结合,因此非常适合分析各个大脑区域之间的关系。Wen等^[9]提出了一种多视图图卷积网络(Graph convolutional networks, GCN),它将图结构学习与多任

务图嵌入学习相结合,以提高脑部疾病的分类性能并识别 rs-fMRI 中潜在的功能子网络。Hao 等^[10]提出了一种加权超图卷积网络,利用不同时间点数据之间的内部相关性和受试者之间的高阶关系来进行阿尔茨海默病诊断。然而,如果要尽可能多地捕捉疾病的各个方面,进一步提高诊断准确性,就需要充分利用复杂的医学多模态以及多尺度的数据提取其中隐藏的有效信息。这些数据通常包括医学成像和相应的非成像表型测量(例如受试者的年龄、性别、采集地点以及受教育程度)。Yao 等^[11]提出了一种相互多尺度三元组 GCN,用于根据功能和结构连接对脑部疾病进行分类。Jiang 等^[12]提出了一种分层 GCN 框架来学习图特征嵌入,同时考虑网络拓扑信息和受试者关联。图对比学习利用丰富图结构信息的能力,通过自监督和对抗训练等方式,提高了模型的鲁棒性和泛化能力,这些优势使其在脑疾病分类领域得到了广泛应用。Zhang 等^[13]提出了一种名为对抗图对比学习方法,通过创建稀疏连接图作为对比学习中的正样本来提取图表示,使得其能够更好地聚合现有 GNN 模型中的邻居节点特征。Zhu 等^[14]提出了一种新颖的多视图对比学习方法,该方法结合了受试者的 FC 和高阶 FC 特征,通过对比学习准则整合了两种视图的一致表示。

尽管上述方法取得了良好的效果,但仍然存在一些问题:(1)传统生成 FC 的方法(比如计算皮尔森相关系数)生成的 FC 忽略了时间顺序,仅捕获脑区之间的线性相关性,因此可能不适合描述连续时间序列中大脑复杂的 BOLD 变化;(2)由于 GCN 过度平滑的问题,现有应用于医学诊断的 GCN 模型大多仅基于浅层结构,无法从多模态数据中学习潜在的多尺度信息,这影响了疾病分类的准确性;(3)针对输入到 GCN 的人口图缺少一种降维策略,使得模型在训练期间可能会出现计算复杂度高、过拟合风险大的问题从而影响分类结果。

针对上述问题,本文提出了基于注意力机制的多尺度残差融合图卷积网络(Multi-scale residual fusion GCN, MSRF-GCN),来进行 ASD 的诊断。通过引入功能连接生成器(Functional connection generator, FC Generator)来解决线性生成 FC 矩阵的局限性。具体而言,使用了基于多头自注意力(Multi-head self-attention, MSA)的编码器进行特征提取,从而有效地捕获时间序列中的长距离依赖,使模型能够捕获大脑节点之间复杂的活动模式。在非成像数据的处理上,通过引入特定的编码器,利用非图像数据之间的关联来计算人口图中边的权重。为了学习输入数据的多尺度信息,在 MSRF-GCN 模块中,引入多尺度残差融合块来聚合不同图卷积层的输出特征,进而捕获多尺度的节点特征嵌入。此外,通过引入残差连接来解决 GCN 架构训练过程中存在梯度消失或爆炸等问题。最后,引入了边稀疏化的操作,从已经构建好的人口图中按照一定的比例随机丢弃一部分边,以减少训练期间过拟合的风险并增加图的稀疏性。

本文工作的主要贡献如下:

(1)提出了 MSRF-GCN 框架,通过引入残差连接来解决由于 GCN 层数增加而产生过渡平滑、梯度消失或爆炸的问题。通过设计多尺度残差融合块来将所有卷积块的输出特征进行聚合,从而学习输入人口图的多尺度信息并且降低训练过程中过拟合的风险。

(2)引入了 FC Generator,通过基于多头自注意力的编码器进行特征提取,使其能够从时间序列信号中提取具有远程依赖性的丰富特征。这有效解决了传统 FC 生成的方法仅能捕获脑区之间的线性相关性的问题,从而使模型能够捕获大脑节点之间复杂的活动模式。

(3)引入了 Edge Sparse 策略,在训练开始之前,按一定比例从构建好的人口图中随机删除一部分边使得训练图更稀疏。这减少了输入图中某些节点对其相邻节点的过度依赖,进而降低了 GCN 过渡平滑的速度。Edge Sparse 策略增强了输入数据的随机性和多样性,提高了模型整体泛化性能。

1 相关方法

本文提出的算法框架如图 1 所示。样本数据采用人口图的结构来表示,将诊断任务建模为节点分

类任务。模型主要围绕3个关键部分:(1)使用FC Generator构建FC矩阵;(2)构建人口图;(3)MSRF-GCN模块。首先按照预定义的图集将大脑进行分区,将划分脑区后感兴趣区域(Region of interest, ROI)的BOLD信号表示为 $T \in \mathbf{R}^{n \times t}$,其中 n 表示ROI的数量, t 表示时间信号序列长度。接下来,将BOLD信号输入到FC Generator中得到对应样本的FC矩阵。将影像信息经过处理得到的FC矩阵与经处理得到的非影像数据相结合生成人口图,其中FC网络用于定义图中的节点特征,不同受试者的表型信息(采集地点、年龄、性别等)的相似性用来定义图的边。通过Edge Sparse操作将完成后的人口图进行稀疏化处理,接着输入到MSRF-GCN,通过引入残差连接以及多尺度残差融合块,来学习输入人口图的多尺度信息进而得到每个节点更深层次的特征表示。最后使用多层感知机(Multilayer perceptron, MLP)来完成最终的分类。

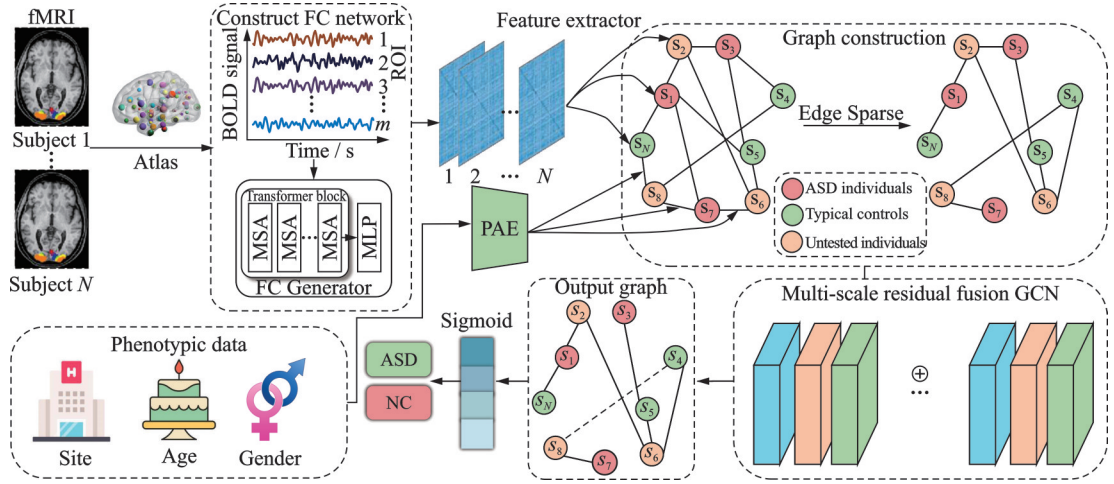


图1 MSRF-GCN的总体结构图

Fig.1 Overview of the MSRF-GCN structure

1.1 生成FC网络

为了从时间序列信号 T 中提取具有远程依赖性的丰富特征,本文通过设计FC Generator来实现。FC Generator主要由 L 层MSA操作构成的Transformer块以及一层MLP组成。通过注意力机制模拟节点间的交互,旨在最大程度上捕捉时间序列数据中的两个时间点之间长距离的相关性。这样的设计允许模型辨识出大脑中更广泛的模式和相互作用,从而深化人们对大脑复杂FC模式的理解。

Transformer块的详细操作过程如下。针对第 l 层MSA块中每个头的输入 $T^{l-1} \in \mathbf{R}^{n \times t}$,三元组 (Q, K, V) 通过以下方式计算

$$\begin{cases} Q = T^{(l-1)}W^q \\ K = T^{(l-1)}W^k \\ V = T^{(l-1)}W^v \end{cases} \quad (1)$$

式中: $W^q, W^k, W^v \in \mathbf{R}^{t \times d}$, d 表示三元组的通道维度, $T^{(0)} = T$ 。单头注意力表示为

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d}}\right)V \quad (2)$$

接着,将所有头的输出进行合并,并通过一个由两个线性投影层组成的MLP将其映射为特征表示。MSA在这里发挥了关键作用,因为MSA在同时增强多个注意力头的效能方面非常有效,能够以并行方式利用具有远程依赖关系的多种特征。该过程可以表示为

$$\text{MultiHead}\left(T^{(\ell-1)}\right)=\text{Concat}\left(\text{head}_1, \text{head}_2, \dots, \text{head}_h\right)W_{\text{MLP}}$$

$$\text{where head}_i=\text{Attention}\left(T^{(\ell-1)}W_i^q, T^{(\ell-1)}W_i^k, T^{(\ell-1)}W_i^v\right) \quad (3)$$

式中: $W_i^q, W_i^k, W_i^v \in \mathbf{R}^{t \times d}$, $W_{\text{MLP}} \in \mathbf{R}^{hd \times t}$, h 表示注意力头的个数。经过多头注意力操作得到添加了远程依赖关系的新序列 $T_{\text{final}} \in \mathbf{R}^{n \times t}$ 。将 T_{final} 送入 MLP 中进行投影从而得到特征表示 $H \in \mathbf{R}^{n \times p}$, p 为经 MLP 操作后得到的特征维度。最后,通过对节点之间的交互进行建模得到最终的特征表示 $X \in \mathbf{R}^{n \times n}$, 该过程可以表示为

$$X = \text{Sigmoid}\left(HH^T\right) \quad (4)$$

由式(4)计算得到的 X 即为经过 FC Generator 操作得到的 FC 矩阵。本文对 H 使用转置运算进行自乘处理,然后使用 Sigmoid 激活函数,最终计算得到 FC 矩阵中的值是非负的,因此得到 FC 矩阵的操作适用于 GNN。

1.2 构建人口图

将 N 个受试者的信息纳入将要构建的人口图中,将要构建的人口图 $G=(V, E, W)$ 以无向加权图的形式体现。其中 V 为图中节点的集合, $E \subseteq V \times V$ 表示节点之间的边, W 表示边权重,即受试者之间的关联程度。 G 中的节点 V 表示受试者从影像数据中提取的特征,该特征信息已经由 FC Generator 模块对 BOLD 信号进行处理,并转化成了 FC 矩阵。接着将 FC 矩阵转化成向量的形式,然后嵌入人口图中。在将矩阵向量化以生成用于分类的特征向量时,高维度的特征向量可能导致模型发生过拟合,从而影响模型的性能。为了降低特征向量的维度,本文采用岭回归作为递归特征消除 (Recursive feature elimination, RFE)^[15] 的基础模型,使用固定数量的 2 000 个特征进行 RFE 操作。

针对表型数据,选取了每个受试者的采集地点、年龄以及性别 3 种信息。对每个受试者的采集地点、年龄以及性别分别构建字典。其中性别用 (0, 1) 表示,所采集的 17 个站点依次编码为 (0, 1, 2, ..., 16), 年龄取值范围为 (6, 64), 然后将站点和年龄标准化至 (0, 1) 之间。将表型信息进一步整合为矩阵的形式。采用 Huang 等^[16] 提出的成对关联编码器 (Pairwise association encoder, PAE) 进一步对两个受试者之间的非影像信息进行关联计算,最终得到受试者 i 与受试者 j 之间的关联程度 $W_{i,j}$ 。

对于两个不同受试者的表型信息 x_i 和 x_j , 将其归一化并重新缩放为两个单位向量 \tilde{x}_i 和 \tilde{x}_j 。将归一化后的两个向量依次放入 PAE 的两个权重共享的投影网络中,经过两个全连接层、ReLU 激活层、批归一化层以及 dropout 层之后得到两个公共潜在空间中的隐藏特征向量 v_i 和 v_j 。接着通过式(5)计算两个潜在特征向量的余弦相似度。

$$W_{i,j} = \frac{v_i^T v_j}{2 \|v_i\| \|v_j\|} + 0.5 \quad (5)$$

1.3 Edge Sparse 策略

GCN 在训练过程中,容易受网络深度、模型参数过多等影响而产生过度平滑以及过拟合的问题导致模型的表达能力受限,影响最后的分类结果。因此,提出了 Edge Sparse 策略来解决这两个问题。受到 Rong 等^[17] 在 GCN 训练过程中对图数据进行改进的启发,Edge Sparse 策略在训练开始之前,从已经构建好的人口图中按照一定的比例随机丢弃一部分边。具体来说,对于人口图的邻接矩阵 A ,按一定的比例 q 随机选取 A 中的 Eq 个非零元素并将其设置为零,其中 E 为原始人口图中边的总数。经过边稀疏操作,得到了一个新的邻接矩阵,将该邻接矩阵作为 MSRF-GCN 最终的输入。

通过以一定的比例随机丢弃图中的边而不是丢弃节点来尽可能地保留人口图的整体结构,维持数据的完整性。同时 Edge Sparse 策略也可被视为一种数据增强机制,通过每次训练输入不同的子图,模

型能够学习到更健壮的代表,在增强了输入数据的随机性和多样性的同时提高了模型整体的泛化性能,缓解了过拟合的问题。由于GCN中相邻节点之间的消息传递通过边来实现,通过随机删除一些边,使得节点之间的连接变得更加稀疏,这在一定程度上有助于缓解由于GCN层数增加等因素带来的过度平滑问题。

1.4 MSRF-GCN

由于浅层GCN只能通过有限数量的邻居传播信息,导致其特征提取能力较弱,难以捕捉到复杂图结构中的高阶特征,但随着GCN层数的增加,如果采用简单堆叠的方式很容易产生过渡平滑、梯度消失或爆炸的问题。为了解决上述问题,提出了MSRF-GCN框架,该算法通过多尺度架构中的GCN对图的层次结构和上下文信息进行建模,从而提供了更强大的表示和分类能力。MSRF-GCN框架如图2所示。

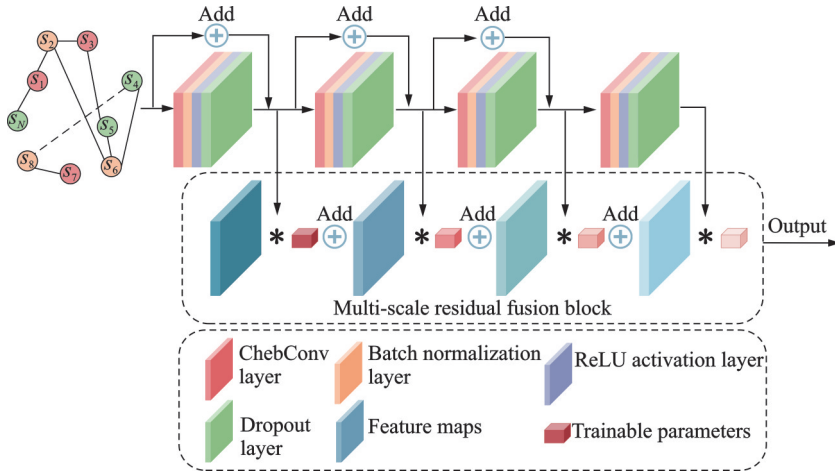


图2 MSRF-GCN的图卷积模块

Fig.2 Convolution module of MSRF-GCN

MSRF-GCN由4个图卷积层以及多尺度残差融合模块(Multi-scale residual fusion block, MRFB)组成。本文采用切比雪夫卷积(Chebyshev convolution, ChebConv)^[18]作为卷积算子。ChebConv是谱图卷积的有效近似,在局部滤波方面表现出色,并且在处理不规则加权图时具有较小的计算成本。每个卷积块中输入特征依次经过ChebConv层、批归一化层、ReLU激活层以及dropout层。受He等^[19]的启发,本文在卷积层之间使用残差连接来增强特征表示,并且防止产生梯度消失或爆炸的问题。

基于谱图卷积可以定义为图信号 $x \in \mathbf{R}^N$ 与滤波器 $g_\theta = \text{diag}(\theta)$ 的乘积

$$g_\theta \star x = U g_\theta U^T x \quad (6)$$

式中 \star 为图上的卷积算子, $U^T x$ 为 x 的图傅里叶变换, U 为由拉普拉斯矩阵 $L = I_N - D^{-1/2} W D^{1/2}$ 的特征向量构造的矩阵, I 为单位矩阵, D 为度矩阵。由于执行上述谱卷积的计算成本很高,本文通过使用 K 阶切比雪夫多项式来简化计算,表示为

$$g_\theta \star x \approx \sum_{k=0}^{K-1} T_k(\tilde{L}) \theta_k x \quad (7)$$

式中 \tilde{L} 为重新缩放的图拉普拉斯算子, $T_k(\tilde{L}) = 2\tilde{L}T_{k-1}(\tilde{L}) - T_{k-2}(\tilde{L})$ 为用 $T_0(\tilde{L}) = 1$ 和 $T_1(\tilde{L}) = \tilde{L}$ 递归定义的切比雪夫多项式, θ_k 为滤波器参数。

在这项工作中,给定输入人口图的节点特征 \mathbf{X} ,将第 l 层ChebConv的输出特征定义为

$$\mathbf{X}^{(l+1)} = \sum_{k=0}^{K-1} T_k(\tilde{L}) \theta_k^{(l)} \mathbf{X}^{(l)} \quad (8)$$

本文将每个卷积块输出的特征与神经网络学习到的权重进行融合来学习输入节点特征的多尺度信息。所有卷积块生成的节点嵌入 $\{\mathbf{X}^{(0)}, \mathbf{X}^{(1)}, \mathbf{X}^{(2)}, \mathbf{X}^{(3)}\}$ 在多尺度残差融合块中与神经网络学习到的权重相乘然后聚合得到最终的节点嵌入 Z ,整个过程表示为

$$Z = \sum_l w^{(l)} \odot \mathbf{X}^{(l)} \quad (9)$$

式中: $w^{(l)} (l \in \{0, 1, 2, 3\})$ 通过随机初始化的可学习权重 $r^{(l)}$ 经Softmax操作计算得到,表示为

$$w^{(l)} = \frac{\exp(r^{(l)})}{\sum_l \exp(r^{(l)})} \quad (10)$$

在MRFB中,通过引入可学习的权重,将所有卷积块的输出特征进行聚合。MRFB有效地利用了每个卷积块的特征图,从而获得多尺度的节点特征嵌入。这不仅提高了模型的性能和泛化能力,还减轻了过度平滑的问题。

1.5 损失函数

采用交叉熵损失在训练时约束MSRF-GCN

$$\mathcal{L}_{CE} = \frac{1}{N} \sum_i -[q_i \cdot \log(p_i) + (1 - q_i) \cdot \log(1 - p_i)] \quad (11)$$

式中: p_i 代表针对受试者 i 的预测结果, q_i 代表受试者 i 真实的标签, N 为样本总数。

2 实验分析与结果

2.1 数据集

本文在ABIDE^[20]数据集上评估模型的性能。ABIDE汇总了来自17个不同采集站点的数据,并公开共享1112名受试者的rs-fMRI数据和对应的表型数据(例如年龄、性别和采集地点)。使用哈佛-牛津(Harvard-Oxford, HO)皮质结构图谱^[21]来定义大脑区域以生成不同的FC矩阵。HO图集使用最近邻插值将处理后的皮质和皮质下ROI结合起来,以分割功能分辨率,产生111个ROI。通过提取每个受试者的平均ROI时间序列,将其用于后续构建FC网络。

选择通过可配置的连接体分析管道(Configurable pipeline for the analysis of connectomes, CPAC)预处理后的数据。预处理主要步骤^[22]如下:(1)切片时间校正;(2)运动校正;(3)颅骨剥离;(4)体素强度归一化;(5)干扰信号回归,包括24个运动参数、白质、脑脊液、线性和平方趋势以及全局信号回归;(6)带通滤波(0.01~0.1 Hz)。预处理后,选择871张带有表型信息的高质量MRI图像,其中包括在17个不同地点采集的403名ASD患者和468名正常个体。

2.2 实验设置

通过在ABIDE数据集上使用10折交叉验证来评估模型的性能。将数据集经过重新打乱划分后分为10组,在每次迭代中使用9组进行训练,剩下的1组进行测试,确保ASD患者与不患病的受试者均匀分配在所有组。整个过程重复10次,最后将10次测试的结果平均以得到模型的最终性能评估。每折的测试集仅用于评估模型的性能,不参与调整模型参数或特征选择,这有效避免了模型在10折交叉验证中性能过高但泛化能力较弱的问题。将经FC Generator对BOLD信号进行处理后生成的FC矩阵执

行RFE操作来提取代表受试者FC的2000维特征向量。选择非图像数据的年龄、性别和采集地点3种信息来学习图的边权重。使用Adam优化器训练了一个基于图的500次迭代模型,将学习率设置为0.001,dropout值设置为0.2,将MSRF-GCN的层数设置为4。对于Edge Sparse策略,将去除边的比率 q 设置为0.3。所有模型均使用开源机器学习库PyTorch开发,并在GeForce GTX 3060的GPU上进行实验。

2.3 评价指标

采用分类准确度(Accuracy, ACC)、敏感度(Sensitivity, SEN)、特异性(Specificity, SPE)、曲线下面积(Area under the curve, AUC)、 F_1 分数(F_1 -score)这5个常用的评价指标来评估模型性能。AUC是通过计算ROC曲线下的面积获得的, F_1 分数是精确率(Precision, Prec)和召回率(Recall)的平均值之和。在二分类任务中,定义以下4种分类结果的样本来计算以上评价指标:(1)真正类(True positive, TP),某一样本为正类,且被预测为正类;(2)假负类(False negative, FN),某一样本为正类,但被模型划分为负类;(3)假正类(False positive, FP),某一样本为负类,但被模型划分为正类;(4)真负类(True negative, TN),某一样本为负类,且被模型划分为负类。这些评价指标定义如下

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (12)$$

$$SEN = Recall = \frac{TP}{TP + FN} \quad (13)$$

$$SPE = \frac{TN}{TN + FP} \quad (14)$$

$$Prec = \frac{TP}{TP + FP} \quad (15)$$

$$F_1 = \frac{2 \times Prec \times Recall}{Prec + Recall} \quad (16)$$

ACC是一个常用的分类指标,表示正确预测样本的比例;SEN表示所有正类样本被正确分类的比例,衡量分类器识别正类样本的能力;SPE表示所有负类样本被正确分类的比例;精确率和召回率是两个相互制约的指标,通常,当精确率较高时,召回率可能较低;为了平衡精确率和召回率之间的冲突,使用了 F_1 ,它综合了这两者,提供了一个模型在精度和召回率上的调和平均;AUC则通过随机评估正样本和负本来衡量模型的泛化性能,即分类效果,AUC越接近1,表明模型的性能越好,真实性越高。

2.4 对比实验

为了验证MSRF-GCN模型的性能并确保结果具有可比性,进一步将MSRF-GCN与多个基础模型以及当前最先进的模型进行了比较。将对比方法大致分为3类:传统方法、基于非图数据的方法以及基于GCN的方法。所有可比较的方法都在相同比例的数据集上进行训练和测试。

2.4.1 传统方法

(1)SVM。支持向量机(Support vector machine, SVM)^[23]是一种用于二元分类的模型,旨在找到特征空间中最大化分类间隔的线性边界。通过核函数,SVM还能处理非线性分类问题,利用支持向量优化决策边界。

(2)Ridge Classifier。岭分类器(Ridge classifier)^[24]是一种用于二元分类的模型,通过在损失函数中加入 L_2 正则化项来防止过拟合。它在优化过程中利用岭回归技术,确保模型在处理高维数据时具备良好的泛化能力。

2.4.2 基于非图数据的方法

(1)ASD-DiagNet。ASD-DiagNet^[7]将自编码器与SLP相结合进行联合学习来提取rs-fMRI数据中的特征,同时采用数据增强方法来提高提取特征的质量和分类性能。

(2)DNN。深度神经网络(Deep neural network, DNN)^[25]由两个自编码器和一个MLP组成。DNN通过多个隐藏层的设计,从数据中提取复杂特征,适合处理图像、文本等复杂的高维数据。

2.4.3 基于GCN的方法

(1)GCN。GCN^[26]是一种用于处理图数据的神经网络模型,其作用类似于卷积神经网络(Convolutional neural networks, CNN)的特征提取器,但适用于图结构数据。GCN是一种设计巧妙的算法,用于从图数据中提取特征,特别适用于处理非欧几里得数据。

(2)BrainGNN。BrainGNN^[27]是一种基于端到端GNN的fMRI预测框架,可联合学习ROI聚类 and 下游全脑fMRI分类。

(3)MVS-GCN。一种采用先验大脑结构学习引导的多视图GCN^[9],它将图结构学习和多任务图嵌入学习相结合,以提高分类性能并识别潜在的功能子网络。

(4)RGNet。一种使用图编码器以及图稀疏拟合和加权聚合方法的深度残差GNN^[28],通过引入残差技巧以及图稀疏拟合算法在降低整体图维度的同时提取数据中更高级别特征。

(5)Hi-GCN。采用分层视角进行图嵌入学习^[12],同时考虑个体大脑网络的结构和全局人口图中受试者的相关性,从而捕获最本质的嵌入特征。

(6)EV-GCN。一种使用自定义编码器结合谱图卷积网络从非成像表型数据获取节点之间关联的模式^[16]。

为了公平比较,所有模型都使用已发布的源代码并在相同的环境中运行。此外,为了确保其具有最佳性能,按照原始文献的建议设置所有超参数,然后在实验中进行微调。使用10折交叉验证将本文提出的算法与以上模型在ABIDE数据集上进行对比。实验结果对比如表1所示,其中最佳结果以粗体显示。

表1 不同模型实验对比

Table 1 Experimental comparison of different models

Model	ACC	AUC	SEN	SPE	F_1	%
SVM	65.73±0.23	67.87±0.39	70.69±1.27	64.87±0.39	69.65±0.61	
Ridge Classifier	64.51±0.39	68.42±0.76	65.14±0.26	68.25±0.39	65.63±0.71	
ASD-DiagNet	67.79±0.28	68.53±0.49	63.67±0.71	64.31±0.63	68.81±0.82	
DNN	67.25±0.23	67.43±0.72	71.26±0.69	63.70±0.88	68.12±0.73	
GCN	67.81±1.57	65.95±0.46	71.39±0.64	72.31±0.45	70.98±0.27	
BrainGNN	54.44±0.35	62.17±0.32	60.13±0.25	53.79±0.21	61.57±0.31	
MVS-GCN	68.15±2.08	69.38±1.32	68.39±0.57	65.13±0.72	69.37±0.91	
RGNet	71.29±1.79	68.80±2.12	61.66±2.67	68.76±2.98	65.90±1.78	
Hi-GCN	72.81±0.41	77.38±1.35	72.04±0.75	73.85±1.27	75.68±0.89	
EV-GCN	75.83±0.53	72.94±0.98	77.83±1.31	82.73±1.41	79.42±0.21	
Proposed	78.14±0.43	78.44±1.78	82.81±0.73	80.56±2.27	80.41±0.82	

由表1可以得出以下结论:

(1)在传统方法中,SVM的性能通常优于Ridge分类器。然而,由于模型架构简单,传统机器学习方法的性能通常不如大多数深度学习方法。深度学习凭借其强大的非线性特征提取能力,使得模型从基于知识的方式向数据驱动的方式转变,从而显著提升了模型性能。

(2)基于GCN的方法通常优于基于非图数据的方法。可以看到ASD-DiagNet除了SEN之外,其余指标都高于DNN模型,这说明数据增强算法对于模型性能的提升有一定的影响。BrainGNN是一种在不同层之间采取TopK池化技巧的GCN,可以发现BrainGNN在表现ABIDE数据集的分类任务上比传统和非图方法都要差,因此认为TopK技巧可能不会像CNN池化操作那样广泛适用。其余采用图数据的方法效果普遍比采用非图数据好,可以体现出图学习方法在脑部疾病诊断中更有优势,可以更充分地利用复杂的脑网络结构。

(3)采用多模态数据的方法普遍优于采用单模态数据的方法。Hi-GCN和EV-GCN都利用了非图像数据,在分类任务中的表现显著优于仅采用fMRI数据的方法。这表明融合多模态输入能够提供更多特征信息,相比单模态输入更加有效。这一结论与临床实践相一致,临床医生在诊断时不仅需要考虑放射学数据,还需综合考虑年龄、性别等其他患者信息,以提高诊断的可靠性。

(4)MSRF-GCN在ABIDE数据集上总体实现了最佳性能,除了SPE略低于EV-GCN外,其余指标均优于其他模型。虽然RGTNet采用注意力机制对FC矩阵进行了处理,但本文利用非图像数据重新构建了人口图并且引入MRFB提取输入数据的多尺度信息,使得MSRF-GCN的性能显著优于RGTNet。MVS-GCN充分利用了多个视图之间的互补信息提供了更丰富的特征信息,然而,MVS-GCN需要学习更多的参数,使得模型难以收敛,并且可能导致泛化能力较弱。与其他基于图的模型相比,EV-GCN取得了更好的性能,然而其缺陷在于仅通过线性方法生成了FC矩阵,无法捕获大脑节点之间复杂的活动模式。本文还引入Edge Sparse策略和GCN残差连接来避免产生过度平滑以及过拟合的问题。

图3展示了MSRF-GCN的详细性能指标。图3(a)为MSRF-GCN在10折交叉验证下的ACC、SEN、SPE和 F_1 的箱线图,其中虚线代表平均值。MSRF-GCN平均精度为78.14%,表明模型具有较高的置信度。图3(b)显示了10折交叉验证下测试集上的ROC曲线变化。可以看出,模型的AUC值较高,表1中平均AUC为78.44%,表明该模型具有较高的稳健性。此外,MSRF-GCN的真阳性率在ROC曲线开始处增加较快,表明该模型对ASD具有更高的诊断率和更低的误诊率。这使得在临床应用中提供准确可靠的结果成为可能。

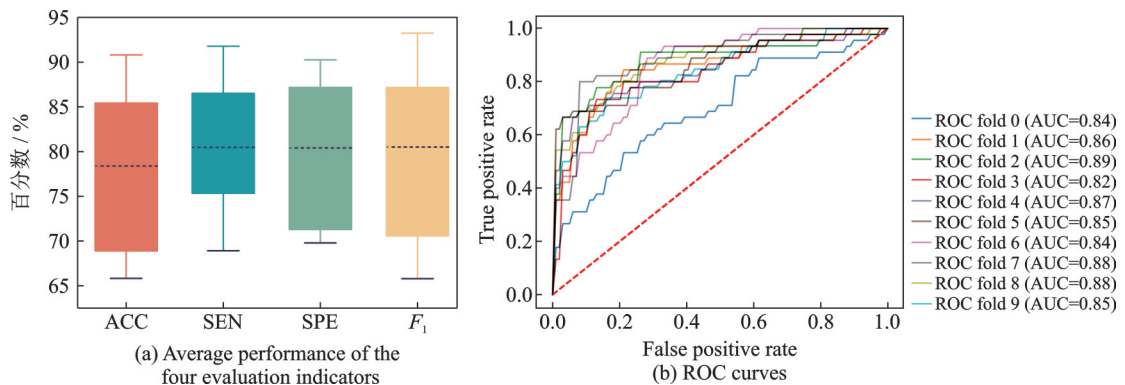


图3 MSRF-GCN在10折交叉验证下的平均性能

Fig.3 Average performance of MSRF-GCN under 10-fold cross-validation

2.5 消融实验

MSRF-GCN的整体性能已通过与其他模型的比较得到验证。本节尝试探讨几个核心子组件的实际作用,包括FC Generator、GNN算子、Edge Sparse策略、网络层数、连接方式以及表型信息。为此,依次对这些部分进行消融实验。

2.5.1 不同生成FC矩阵的方式对分类性能的影响

采用Pearson相关系数线性生成FC矩阵的方法并不适合描述连续时间序列中大脑复杂的BOLD信号变化。为了更好地捕捉这些时序信息,提出了基于注意力机制的FC Generator。为了验证FC Generator对最终诊断结果的影响,在不改变其他组件的前提下,采用Pearson相关系数生成FC矩阵,并将结果与使用FC Generator的算法进行对比,如表2所示。

表2 采用Pearson以及FC Generator生成FC矩阵的性能对比

Table 2 Performance comparison of FC matrix generation using Pearson and FC Generator

Model	ACC	AUC	SEN	SPE	F_1
Pearson	72.25±0.97	69.86±1.15	78.06±1.70	69.56±3.26	70.72±0.96
FC Generator	78.14±0.43	78.44±1.78	82.81±0.73	80.56±2.27	80.41±0.82

从表2可以看出,仅采用Pearson相关系数生成的FC矩阵在5个指标上均低于使用FC Generator生成的矩阵。因此,认为基于非线性学习方法的FC Generator在构建FC矩阵方面更有效。

2.5.2 不同图卷积算子对分类性能的影响

为了评估MSRF-GCN中ChebConv算子的有效性,将其替换成其他图卷积算子,包括GCNConv^[26]、GATConv^[29]、ARMAConv^[30]、SAGEConv^[31]和GraphConv^[32]。除图卷积算子外,其他实验设置均保持不变。如表3所示,所提出的MSRF-GCN在ABIDE数据集上的所有指标均实现了最佳分类性能。这些结果证明了ChebConv能够更好地捕捉图结构中的复杂关系,从而提升分类模型的整体表现。

为了证明MRFB的有效性,将最后一个图卷积块的输出直接作为最终MLP的输入,从而避免使用MRFB模块。结果如表3所示,使用MRFB模块的方案在分类精度等各项指标上显著优于不使用

表3 在MSRF-GCN上使用不同的图卷积算子的性能对比

Table 3 Performance comparison using different graph convolution operators on MSRF-GCN

Model	ACC	AUC	SEN	SPE	F_1
GCNConv	72.25±0.97	69.86±1.15	78.06±1.70	69.56±3.26	70.72±0.96
GATConv	76.41±1.47	72.37±3.64	76.72±1.12	78.48±0.43	79.18±1.29
ARMAConv	75.53±0.94	76.02±1.93	77.12±0.73	78.10±0.87	77.54±1.32
SAGEConv	76.67±0.47	76.71±0.37	78.29±0.42	76.86±0.96	77.25±0.55
SGConv	77.31±0.49	78.14±1.75	77.84±0.77	77.53±1.58	78.27±0.41
GraphConv	76.63±0.74	77.66±0.49	78.82±0.75	75.65±1.94	77.07±0.88
Proposed w/o MRFB	75.42±0.79	72.21±0.65	76.53±1.57	80.42±1.28	79.41±0.29
Proposed	78.14±0.43	78.44±1.78	82.81±0.73	80.56±2.27	80.41±0.82

MRFB模块的方案。这表明,MRFB模块通过捕捉人口图中的多尺度信息,对ASD诊断任务有显著的提升作用。

2.5.3 不同网络结构对分类性能的影响

通过设置不同GCN的层数来探究GCN深度对分类性能的影响。在训练中设置层数依次为2、4、6、8、10。同时,为了评估Edge Sparse策略的有效性,在相同实验条件下对模型中不采用Edge Sparse策略的情况进行了实验。在10折交叉验证的情况下网络不同的深度以及Edge Sparse策略对ACC和 F_1 的影响。

如图4所示,随着网络层数的加深,分别采用两种策略的模型性能均在第四层达到了峰值然后逐层下降。结合不同网络结构的性能指标,可以看出具有4个卷积层和Edge Sparse策略的MSRF-GCN具有最佳的分类性能。在实验中加入Edge Sparse策略后,分类准确率具有一定程度的提升。这表明Edge Sparse策略通过随机丢弃一些边来增加数据的多样性和随机性,可以缓解模型训练过程中出现的过拟合和过平滑问题。

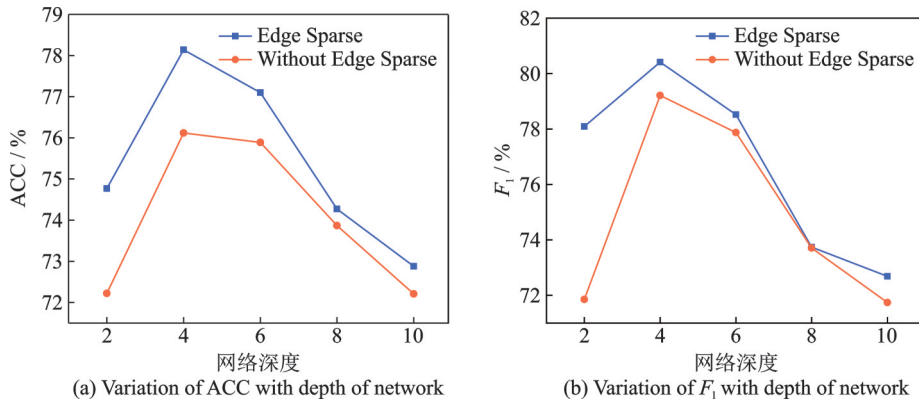


图4 MSRF-GCN在不同的网络深度以及是否使用Edge Sparse策略下的性能对比

Fig.4 Performance comparison of MSRF-GCN with different network depths and with or without Edge Sparse strategy

2.5.4 GCN连接方式对分类性能的影响

MSRF-GCN采用了GCN残差连接的方式缓解模型在训练过程中可能产生的梯度消失和梯度爆炸问题。Huang等^[16]在EV-GCN中引入跳跃连接来融合卷积层的特征。本文将MSRF-GCN在4层和6层两个表现较好的架构下分别进行不采用额外连接、跳跃连接和GCN残差连接的实验,以验证GCN残差连接的有效性。结果分别如图5和表4所示。

在图5中,橙色部分代表使用GCN残差连接,其结果显著优于其余两种连接情况。跳跃连接在分类任务中的表现也优于不采用额外连接的方式,这是因为跳跃连接允许特征信息从前面层直接传递到后面层,缓解了由于卷积操作而导致的信息丢失情况。

从图5和表4可以看出,在两种不同深度的MSRF-GCN中,采用残差连接相较于跳跃连接在各项评价指标上均有显著提升:在4层深度时,ACC提升了2.96%,AUC提升了2.02%,SEN提升了4.27%,SPE提升了2.7%, F_1 提升了3.02%;在深度为6层时,分类精度也提升了2.59%。这表明残差连接能够更好地保持信息完整性,减少信息丢失,避免梯度爆炸和梯度消失,也证明了MSRF-GCN具有鲁棒性。

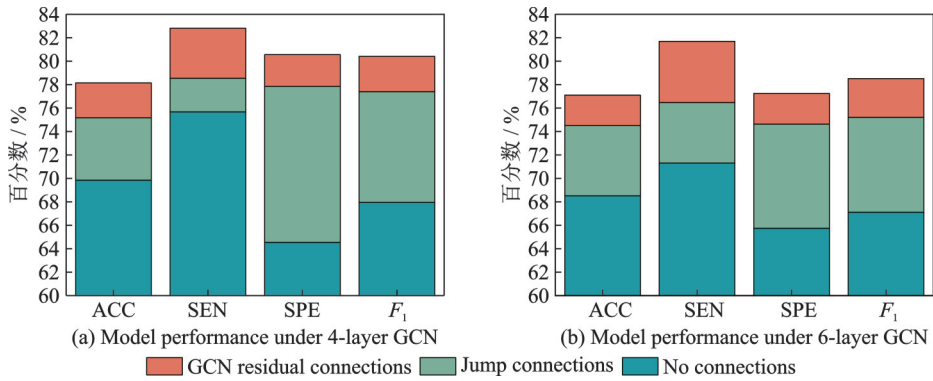


图5 MSRF-GCN 分别使用3种不同连接方式的性能对比

Fig.5 Performance comparison of MSRF-GCN using three different connections separately

表4 MSRF-GCN 分别使用3种不同连接方式的 AUC 值

Table 4 AUC values for MSRF-GCN using three different connections separately

Connection pattern	AUC under 4-layer	AUC under 6-layer
No connection	73.57±1.21	72.63±1.52
Jump connection	76.42±1.64	73.95±1.10
GCN residual connection	78.44±1.78	76.13±1.49

2.5.5 表型信息对分类性能的影响

MSRF-GCN通过引入不同的非影像信息来构建脑图。实验采用的性别、站点以及年龄这3个非影像信息对最终分类结果的影响。如表5所示,实验以性别+站点、性别+年龄以及站点+年龄的方式分开进行讨论。使用站点信息的实验结果明显高于使用性别+年龄组合的实验结果,这是因为 ABIDE 数据集具有高度异质性,其数据是使用不同的成像协议和扫描仪在不同站点获取的,所以站点信息是影响分类效果最重要的因素。另外,综合使用站点、性别以及年龄的实验结果优于使用站点+年龄以及性别+站点的结果,这表明性别以及年龄信息均有助于 ASD 分类。

表5 3种表型信息对性能的影响

Table 5 Effect of three types of phenotypic information on performance

Phenotypic information	ACC	AUC	SEN	SPE	F ₁
Site+Gender	76.27±0.51	76.21±0.78	80.63±1.39	78.33±2.89	78.32±0.90
Gender+Age	67.33±0.78	66.81±0.35	70.11±2.10	71.57±3.71	69.92±1.45
Site+Age	75.06±0.59	74.57±1.86	81.06±1.45	74.24±1.53	76.29±1.39
Site+Age+Gender	78.14±0.43	78.44±1.78	82.81±0.73	80.56±2.27	80.41±0.82

2.6 生物标志物检测

提取与 ASD 相关的、具有生物学意义的生物标记物非常重要,这样做也可以验证模型的有效性。

因此,本文展示了在HO模板上,由MSRF-GCN选出的对ASD分类影响最大的前10个脑区。图6显示了MSRF-GCN识别出的对ASD分类最重要的10个脑区,这些脑区通过BrainNet Viewer工具箱生成^[33]。对于ASD分类,权重最大的10个脑区主要是额下回、额盖皮层、中央前回、海马旁回、额眶皮层和中央盖皮层等,这些脑区与社交沟通、感知和执行等神经功能密切相关^[34]。

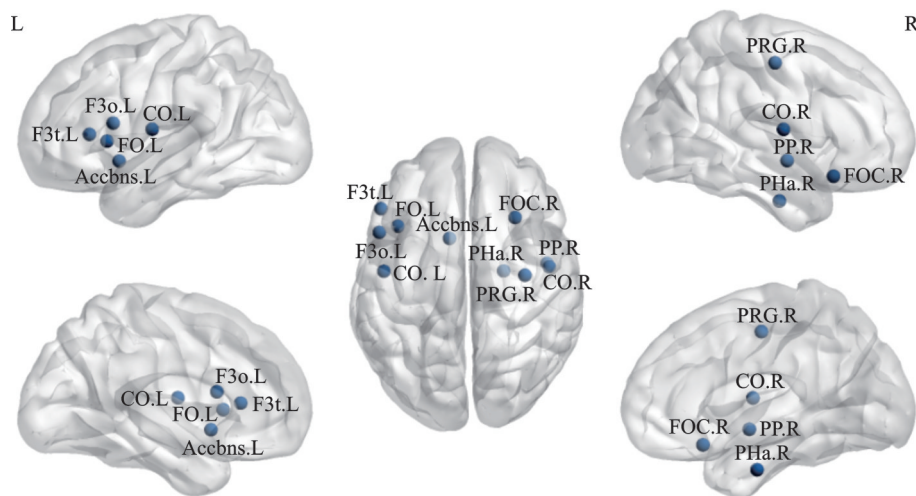


图6 对ASD分类最重要的10个脑区

Fig.6 The ten most important brain regions for ASD classification

3 结束语

本文提出了一个名为MSRF-GCN的模型来诊断ASD。具体来说,为了克服皮尔森相关系数等传统生成FC网络的方法忽略了时间顺序,仅捕获脑区之间的线性相关性的问题,本文提出FC Generator,以深入研究大脑节点之间复杂的活动模式。将通过FC Generator生成的FC网络与表型信息结合生成人口图,以充分利用两种模态之间的信息。为了避免梯度消失和梯度爆炸问题,本文提出GCN残差连接来融合潜在特征,并引入Edge Sparse策略来缓解模型训练过程中可能产生的过拟合和过度平滑问题,从而提高了模型的鲁棒性。为了获得输入数据的多尺度信息,提出了多尺度残差融合块,通过引入可学习的权重,将所有卷积块的输出特征进行聚合,充分利用每个卷积块生成的特征图,从而获得多尺度的节点特征嵌入。在ABIDE数据集上的实验结果表明,与现有模型相比,MSRF-GCN在预测ASD方面表现出卓越的性能。此外,本文还选出了对自闭症诊断影响最大的前10个脑区,并对其进行了可视化。综合实验表明,本文提出的模型对于ASD诊断是有效的。MSRF-GCN是一种基于人口图的方法。然而,现有的基于人口图的GNN算法在学习和分析每个受试者局部脑区的特征嵌入以及脑区之间的关联方面存在一定的局限性。如何在保持基于人口图的GNN能够利用非影像信息来学习受试者之间的关联基础上,有效地学习和分析每个受试者局部脑区的特征将是下一步需要继续研究的重点。

参考文献:

- [1] 尚宇夫,王月华,杜冠华. 自闭症发病机制及治疗药物研究进展[J]. 中国药学杂志, 2023, 58(11): 949-953.
SHANG Yufu, WANG Yuehua, DU Guanhua. Research progress in the pathogenesis and therapeutic drugs of autism[J]. Chinese Pharmaceutical Journal, 2023, 58(11): 949-953.
- [2] WANG Z, LIU J, ZHANG W, et al. Diagnosis and intervention for children with autism spectrum disorder: A survey[J].

- IEEE Transactions on Cognitive and Developmental Systems, 2022, 14(3): 819-832.
- [3] SPORNS O. From simple graphs to the connectome: Networks in neuroimaging[J]. NeuroImage, 2012, 62(2): 881-886.
- [4] BULLMORE E, SPORNS O. Complex brain networks: Graph theoretical analysis of structural and functional systems[J]. Nature Reviews Neuroscience, 2009, 10(3): 186-198.
- [5] HEINSFELD A S, FRANCO A R, CRADDOCK R C, et al. Identification of autism spectrum disorder using deep learning and the ABIDE dataset[J]. NeuroImage: Clinical, 2018, 17: 16-23.
- [6] 李习之, 朱灵瑶, 王明亮. 基于低秩表示判别域适应的多中心自闭症诊断[J]. 数据采集与处理, 2023, 38(4): 886-897.
LI Xizhi, ZHU Lingyao, WANG Mingliang. Discriminative domain adaptation via low-rank representation for multi-site autism spectrum disorder identification[J]. Journal of Data Acquisition and Processing, 2023, 38(4): 886-897.
- [7] ESLAMI T, MIRJALILI V, FONG A, et al. ASD-DiagNet: A hybrid learning approach for detection of autism spectrum disorder using fMRI data[J]. Frontiers in Neuroinformatics, 2019, 13: 70.
- [8] 郝小可, 甄时伟, 周超飞, 等. 基于联邦加权域自适应的多站点自闭症诊断[J]. 河北工业大学学报, 2024, 53(2): 54-63.
HAO Xiaoke, ZHEN Shiwei, ZHOU Chaofei, et al. Federated weighted domain adaptation for multi-site autism diagnosis[J]. Journal of Hebei University of Technology, 2024, 53(2): 54-63.
- [9] WEN G, CAO P, BAO H, et al. MVS-GCN: A prior brain structure learning-guided multi-view graph convolution network for autism spectrum disorder diagnosis[J]. Computers in Biology and Medicine, 2022, 142: 105239.
- [10] HAO X, LI J, MA M, et al. Hypergraph convolutional network for longitudinal data analysis in Alzheimer's disease[J]. Computers in Biology and Medicine, 2024, 168: 107765.
- [11] YAO D, SUI J, WANG M, et al. A mutual multi-scale triplet graph convolutional network for classification of brain disorders using functional or structural connectivity[J]. IEEE Transactions on Medical Imaging, 2021, 40(4): 1279-1289.
- [12] JIANG H, CAO P, XU M, et al. Hi-GCN: A hierarchical graph convolution network for graph embedding learning of brain network and brain disorders prediction[J]. Computers in Biology and Medicine, 2020, 127: 104096.
- [13] ZHANG S, CHEN X, SHEN X, et al. A-GCL: Adversarial graph contrastive learning for fMRI analysis to diagnose neurodevelopmental disorders[J]. Medical Image Analysis, 2023, 90: 102932.
- [14] ZHU H, WANG J, ZHAO Y P, et al. Contrastive multi-view composite graph convolutional networks based on contribution learning for autism spectrum disorder classification[J]. IEEE Transactions on Biomedical Engineering, 2023, 70(6): 1943-1954.
- [15] DING X, YANG F, MA F. An efficient model selection for linear discriminant function-based recursive feature elimination[J]. Journal of Biomedical Informatics, 2022, 129: 104070.
- [16] HUANG Y, CHUNG A C S. Disease prediction with edge-variational graph convolutional networks[J]. Medical Image Analysis, 2022, 77: 102375.
- [17] RONG Y, HUANG W, XU T, et al. DropEdge: Towards deep graph convolutional networks on node classification[C]// Proceedings of International Conference on Learning Representations. New Orleans: ICLR, 2019.
- [18] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering[C]// Proceedings of the 30th International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc, 2016: 3844-3852.
- [19] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 770-778.
- [20] DI MARTINO A, YAN C G, LI Q, et al. The autism brain imaging data exchange: Towards a large-scale evaluation of the intrinsic brain architecture in autism[J]. Molecular Psychiatry, 2014, 19(6): 659-667.
- [21] CRADDOCK R C, JAMES G A, HOLTZHEIMER P E, et al. A whole brain fMRI atlas generated via spatially constrained spectral clustering[J]. Human Brain Mapping, 2012, 33(8): 1914-1928.
- [22] CAMERON C, YASSINE B, CARLTON C, et al. The neuro bureau preprocessing initiative: Open sharing of preprocessed neuroimaging data and derivatives[J]. Frontiers in Neuroinformatics, 2013, 27: 1-5.
- [23] ZHAO L, SUN Y K, XUE S W, et al. Identifying boys with autism spectrum disorder based on whole-brain resting-state interregional functional connections using a boruta-based support vector machine approach[J]. Frontiers in Neuroinformatics, 2022, 16: 761942.

- [24] ABRAHAM A, MILHAM M P, DI MARTINO A, et al. Deriving reproducible biomarkers from multi-site resting-state data: An autism-based example[J]. *NeuroImage*, 2017, 147: 736-745.
- [25] ALMUQHIM F, SAEED F. ASD-SAENet: A sparse autoencoder, and deep-neural network model for detecting autism spectrum disorder (ASD) using fMRI data[J]. *Frontiers in Computational Neuroscience*, 2021, 15: 654315.
- [26] ZHANG S, TONG H, XU J, et al. Graph convolutional networks: A comprehensive review[J]. *Computational Social Networks*, 2019, 6(1): 1-11.
- [27] LI X, ZHOU Y, DVORNEK N, et al. BrainGNN: Interpretable brain graph neural network for fMRI analysis[J]. *Medical Image Analysis*, 2021, 74: 102233.
- [28] WANG Y, LONG H, BO T, et al. Residual graph transformer for autism spectrum disorder prediction[J]. *Computer Methods and Programs in Biomedicine*, 2024, 247: 108065.
- [29] YANG C, WANG P, TAN J, et al. Autism spectrum disorder diagnosis using graph attention network based on spatial-constrained sparse functional brain networks[J]. *Computers in Biology and Medicine*, 2021, 139: 104963.
- [30] BIANCHI F M, GRATAROLA D, LIVI L, et al. Graph neural networks with convolutional ARMA filters[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(7): 3496-3507.
- [31] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Red Hook: Curran Associates Inc, 2017: 1025-1035.
- [32] MORRIS C, RITZERT M, FEY M, et al. Weisfeiler and leman go neural: Higher-order graph neural networks[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. Honolulu: AAAI, 2019: 4602-4609.
- [33] XIA M, WANG J, HE Y. BrainNet viewer: A network visualization tool for human brain connectomics[J]. *PLoS ONE*, 2013, 8(7): 68910.
- [34] LI D, KARNATH H O, XU X. Candidate biomarkers in children with autism spectrum disorder: A review of MRI studies[J]. *Neuroscience Bulletin*, 2017, 33(2): 219-237.

作者简介:



郝小可(1985-),通信作者,男,教授,博士生导师,研究方向:机器学习、模式识别、医学图像分析,E-mail: haoxiaoke@hebut.edu.cn。



何子龙(2000-),男,硕士研究生,研究方向:医学图像分析、模式识别。



卢欣楚(2001-),女,硕士研究生,研究方向:医学图像分析、模式识别。



马明明(1999-),女,硕士研究生,研究方向:医学图像分析、模式识别。



刘时宇(2000-),男,硕士研究生,研究方向:医学图像分析、语义分割、域自适应。

(编辑:夏道家)