

基于联合对比学习的图融合AD分类网络

胡梓俊, 谢勤岚*

(中南民族大学 生物医学工程学院, 武汉 430074)

摘要 图神经网络在阿尔茨海默症早期诊断中取得了显著进展,但多数方法存在图构建质量不足的问题,导致在含噪样本条件下难以准确建模节点间的拓扑关系,影响分类准确度.为了解决这一问题,提出了分类网络GFGCN-SP,它将单一图构建替换为多图融合构建,以提高图的质量;并在自注意力图池化中引入对比学习机制,从而实现有效的层次化表示学习.通过在ADNI数据集上进行的三组分类实验(AD-CN、MCI-CN和EMCI-LMCI)显示:所提方法显著优于现有主流基线模型,平均分类准确率分别达到了92.64%、86.85%、79.04%,验证了所提方法在阿尔茨海默症早期识别任务中的有效性.

关键词 阿尔茨海默症;多图融合;图池化;对比学习

中图分类号 TP391.4 **文献标志码** A **文章编号** 1672-4321(2026)03-0364-09

doi:10.20056/j.cnki.ZNMDZK.20250857

The graph fusion AD classification network based on joint contrastive learning

HU Zijun, XIE Qinlan*

(College of Biomedical Engineering, South-Central Minzu University, Wuhan 430074, China)

Abstract Graph neural networks have achieved remarkable progress in the early diagnosis of Alzheimer's disease (AD). However, most existing methods suffer from low-quality graph construction, making it difficult to accurately model the topological relationships between nodes under noisy samples condition, which in turn affects classification performance. To address this issue, a classification network named GFGCN-SP is proposed. Instead of relying on the single graph construction strategy, GFGCN-SP employs the multi-graph fusion approach to enhance the quality of the graph structure. Additionally, a contrastive learning mechanism is introduced to guide graph pooling, enabling effective hierarchical representation learning. Extensive experiments conducted on the ADNI dataset across three classification tasks (AD-CN, MCI-CN, and EMCI-LMCI) demonstrate that the proposed method significantly outperforms existing state-of-the-art baselines, achieving average classification accuracies of 92.64%, 86.85%, and 79.04%, respectively, thereby validating its effectiveness in early-stage AD identification.

Keywords Alzheimer's disease; multi-graph fusion; graph pooling; contrastive learning

阿尔茨海默症(Alzheimer's Disease, AD)是老年人常见的慢性神经退行性疾病,它是造成痴呆症的主要原因^[1].在21世纪,AD已经成为死亡率最高和负担最严重的疾病之一^[2].因此,AD的早期诊断在阻止AD的发生以及发展方面具有实际意义^[3].

静息态功能磁共振成像(resting-state functional Magnetic Resonance Imaging, rs-fMRI)是一种非侵入性成像技术,可以捕获大脑的结构变化,因此已经广泛用于AD诊断领域.在利用rs-fMRI进行脑网络分析时,将脑建模为由一组节点(例如感兴趣的脑

收稿日期 2025-05-22

*通信作者 谢勤岚(1968-),男,教授,研究方向:医学图像处理, E-mail: xieqinlan@126.com

基金项目 湖北省自然科学基金资助项目(2016CFB489);2024年中南民族大学研究生教研资助项目("人工智能时代生物医学工程类专业学位硕士培养改革研究")

区 (Region of Interest, ROI)^[4]和衡量节点间功能连接的连接矩阵^[5]组成的网络,以此来增加对人脑功能结构的理解.脑网络节点则根据解剖脑谱图、脑功能分区或者脑功能分解来定义,这些节点通过其局部形状、功能一致性或局部连接度量来表征^[6],脑网络节点之间的功能连接通过其 rs-fMRI 时间序列间的时间相关性来衡量.如何使用 rs-fMRI 进行准确诊断仍是当前研究的重要挑战^[7].

在整图分类任务中,图的构建质量对模型的分类型性能具有关键影响.然而,密集图结构容易受到过度平滑的影响^[8].一些研究人员提出了构建稀疏脑网络拓扑的方法.例如,LI 等通过保留前 10% 的高相关连接定义稀疏图边,从而捕捉最显著的连接特征^[9];YAO 等首先计算大脑区域间的 Pearson 相关性^[10],然后基于每个节点的前 k 个最近邻 (k -Nearest Neighbors, Nearest NeighborskNN) 构建边,将统一的 kNN 拓扑应用于所有受试者进行分析.尽管上述方法在一定程度上提升了图构建的有效性,但仅使用单一脑图往往难以反映神经退行性疾病引发的细微脑部变化^[11].另外,注意力机制在深度学习领域的广泛应用,提高了表示学习的效果.这种机制能够将更多的注意力集中在关键特征上,同时弱化对次要特征的关注.特别是,自注意力(也称内部注意力)能够利用输入特征本身来决定注意力的分配.LEE 等^[12]首次提出了自注意力图池化 (Self-attention Graph Pooling, SAGPool),它基于图卷积网络 (Graph Convolutional Network, GCN) 框架,通过自动更新节点得分并按照 top- k 筛选标准对节点进行

选择,为图池化引入了一种基于梯度下降的创新方法.然而,由于节点得分的获取仅基于单一角度,细微的扰动就可能对图的拓扑结构发生较大变化^[13].

为了解决以上问题,本文提出的网络模型,首先构建一个密集图以捕捉全局脑信息同时保留所有连接;其次,使用 kNN 方法生成多个稀疏图,描述脑区域之间的局部关系和相互作用,并根据 LI 等提出的方法,在谱嵌入空间中学习两种图之间的高阶一致性并生成一个融合的稀疏图^[14],从而优化图的结构;同时在 SAGPool 的基础上提出了一种结合对比学习的增强池化方法,以提升图池化的性能.

1 方法

1.1 总体框架

GFGCN-SP 框架如图 1 所示,此框架用于基于 rs-fMRI 数据的功能连接网络分析的流程图:(1)通过皮尔逊相关性分析构建原始的功能连接网络 (Functional Connectivity Networks, FCNs),并为每位受试者分别构建多重 FCN(即:构建一个密集图和使用 kNN 方法生成多个稀疏图);(2)使用所提出的多图融合方法,用于提取融合特征;(3)将构造的图数据输入到 3 层 GCN 中,依次进行图结构特征提取,每一层 GCN 后连接一个对比学习增强的自注意力池化模块 (Pooling1-Pooling3),用于压缩图结构、提取关键节点特征.最后通过 Readout 操作提取全局表示;(4)将 3 层的 Readout 特征拼接后输入至多层感知机 (MLP) 进行最终分类,输出为两个类别 (Class1 和 Class2).

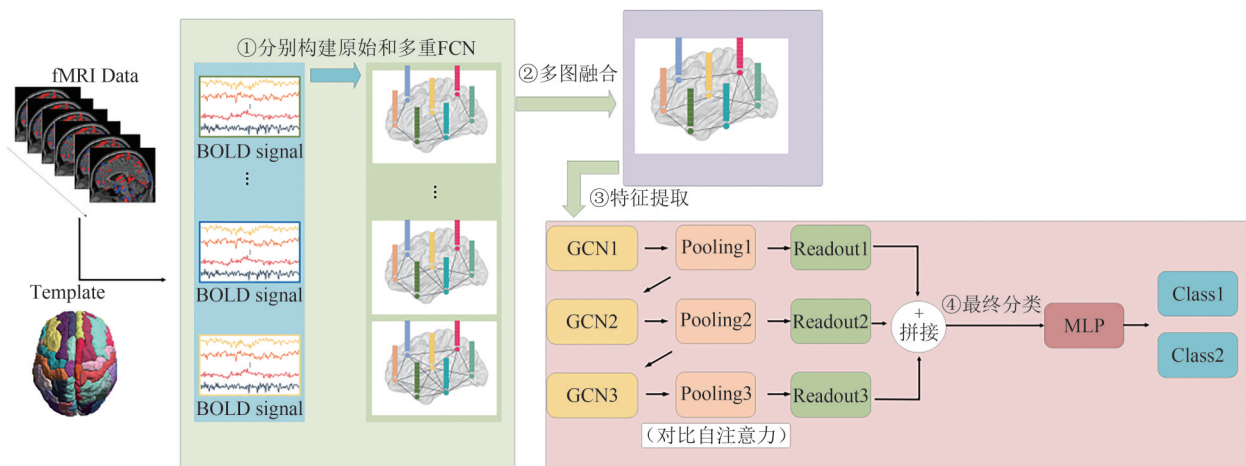


图 1 GFGCN-SP 框架图

Fig. 1 GFGCN-SP framework diagram

在图 1 中的粉色背景框中, Pooling 为提出的对比学习增强的自注意力池化模块,每个 Pooling 的输

出包括一个正图和一个负图.正图通过两个路径进行处理:(1)作为下一层 GCN-pooling 块的输入,进行

更深层次的特征学习;(2)通过 Readout 模块生成当前层的正向分层表示.而负图则仅通过 Readout 模块生成对应的负向分层表示.最终,所有正负分层表示被统一输入到 MLP 中完成分类.3 个 GCN 层计算公式如下:

$$H^0 = \text{ReLU}(A^0 \cdot X \cdot W_0), \quad (1)$$

$$H^1 = \text{ReLU}(A^1 \cdot H^0 \cdot W_1), \quad (2)$$

$$H^2 = \text{ReLU}(A^2 \cdot H^1 \cdot W_2), \quad (3)$$

其中 H^0, H^1, H^2 和 W_0, W_1, W_2 分别是 3 个 GCN 层的卷积嵌入和可学习的谱核. A^0 和 X 分别表示原始图的邻接矩阵和顶点嵌入集. A^1 和 A^2 分别是粗化图 1 和粗化图 2 的邻接矩阵. 每个 GCN 都连接到一个池化层, 该层给出掩码邻接矩阵与上层图的表示的乘积.

对于读出模块, 它充当第 i 个粗化图中均值池和最大池的连接部分, 公式如下:

$$r_i = \text{CONCAT}\left(\frac{1}{N} \sum_{n=1}^N H_n^i, \max H_n^i\right), \quad (4)$$

其中 r_i 是第 i 个粗化图的生成表示, N 是顶点的数量, H_n^i 表示第 n 个顶点在第 i 个粗化图中的嵌入. 不同粗化级别生成的图则进一步输入到 MLP 中, MLP 由 3 个完全连接的层组成, 最后一层通过 softmax 激活. 其中根据参数更新计算而得的基于交叉熵的分类损失, 表示为:

$$L_{\text{cls}} = - \sum_{j=1}^N \sum_{c=1}^c p_j \log q_j, \quad (5)$$

其中 N_j 为样本数量; c 为标签空间; p_j 表示第 j 个样本的真实值, q_j 表示第 j 个样本属于 c 类的概率.

1.2 自注意力图池化

图可以由符号表示为 $G = (V, E, A)$, 其中 V 是顶点集合, 顶点数量为 N ; E 是边的集合, 表示节点之间的连接关系; 邻接矩阵 $A \in \mathbb{R}^{N \times N}$, 用于描述节点之间的连接强度. 根据邻接矩阵可以构建图的对称归一化拉普拉斯矩阵 $L = I_n - D^{-\frac{1}{2}} A D^{-\frac{1}{2}}$ (其中 D 是图的度矩阵, 为对角矩阵, 其第 i 个对角元素为节点 i 的度, 即 $D_{i,i} = \sum_{j=1, j \neq i}^n A_{i,j}$). 拉普拉斯矩阵 L 的特征值集合记为 $\Lambda = \{\lambda_i\}_{i=0}^{n-1}$, 用于刻画图的普特性. 图池化是 GCN 中获取图级表示的重要技术^[15]. 通过图池化, 可以获得不同级别的粗化图, 以找到有意义的节点分配和分层表示^[16]. 由 LEE 等提出的 SAGPool^[12], 它的原理是计算每个节点的自注意力分数, 并通过图卷积模块获得注意力掩码. SAGPool 的机制可以表示如下:

$$\begin{cases} Z = \sigma(D^{-\frac{1}{2}} A D^{-\frac{1}{2}} X \Theta_{\text{att}}) \\ \text{idx} = \text{top} - \text{rank}(Z, kn), \\ Z_{\text{mask}} = Z_{\text{idx}} \end{cases}, \quad (6)$$

其中 $\Theta_{\text{att}} \in \mathbb{R}^{d \times 1}$ 是 SAGPool 中唯一可学习的参数; $X \in \mathbb{R}^{n \times d}$ 是节点嵌入矩阵 (d 是每个节点的维度嵌入); $Z \in \mathbb{R}^{n \times 1}$ 是计算出的自注意力分数; $k \in [0, 1]$ 是决定要保留节点数的超参数, $\text{top-rank}(\cdot)$ 是返回 $\text{top}[kn]$ 节点索引 idx 的函数; $(\cdot)_{\text{idx}}$ 是索引操作, 它返回特征注意力掩码 Z_{mask} . 然后, 可以按如下方式池化输入图:

$$\begin{cases} X' = X_{\text{idx},:} \\ X_{\text{out}} = X' \otimes Z_{\text{mask}}, \\ A_{\text{out}} = A_{\text{idx}, \text{idx}} \end{cases}, \quad (7)$$

其中 $X \in \mathbb{R}^{kn, d}$ 是索引特征矩阵; \otimes 是广播的元素乘积; $A_{\text{idx}, \text{idx}} \in \mathbb{R}^{kn, kn}$ 是索引邻接矩阵; X_{out} 和 A_{out} 分别是新的特征矩阵和相应的邻接矩阵.

1.3 图融合

对于第 m 个被试, 初步构造多个邻接矩阵 $B_m^v \in \mathbb{R}^{N \times N}$ ($v = 1, \dots, V$), 其中 V 为子图的数量, 通过多图融合为每个被试学习到一个稀疏的邻接矩阵 A_m . 本文为每位被试构建两类脑图, 包括基于 ROI 相关性生成的全连接脑图和基于 kNN 的稀疏脑图. 结合 LI 等^[14]的方法, 引入多个脑图间的相似性图及加权张量核范数约束, 以捕提高阶一致性信息, 并统一训练阶段与测试阶段的数据处理流程, 从而有效提升模型的鲁棒性和性能.

将 B_m^v 进行谱嵌入获得谱嵌入矩阵 X , 如公式 (8) 所示:

$$\max_{X^{(v)}} \text{Tr}(X^{(v)\top} B^{(v)} X^{(v)}), \quad \text{s.t. } X^{(v)} X^{(v)\top} = I_c, \quad (8)$$

其中 I_c 表示尺寸为 $c \times c$ 的单位矩阵, 用于保证特征矩阵 $X^{(v)}$ 的正交性与范数一致. 给定所有的谱嵌入矩阵后, 通过求解式 (9) 来获得融合图 A , 使得该图与融合前的脑图之间具有最大的相似度.

$$\begin{cases} \min_A \sum_{v=1}^V \sum_{i=1}^n \sum_{j=1}^n \|\bar{x}_i^v - \bar{x}_j^v\|_2^2 A_{ij} + \gamma \|A\|_F^2, \\ \text{s.t. } A_{ij} \geq 0, A_i \mathbf{1}_n = 1, \end{cases}, \quad (9)$$

其中 $\|\cdot\|_F$ 表示 Frobenius 范数, γ 是一个平衡参数, 其中 \bar{x}_i^v, \bar{x}_j^v 为通过式 (10) 归一化后的谱嵌入矩阵 \bar{x} 的第 i 和第 j 行.

$$\bar{x}_i^v = \frac{x_i^v}{\sqrt{x_i^{v\top} x_i^v}}, \quad (10)$$

通过式 (8) 获得谱嵌入矩阵时不能考虑到多个脑图之间的相关性, 缺乏全局一致性. 因此将目标

公式优化为:

$$\begin{cases} \min_{X^v, \mathcal{T}} -\lambda \sum_{v=1}^r \text{Tr}(X^{v\top} B^v X^v) + \frac{1}{2} \|\mathcal{Z} - \mathcal{T}\|_F^2 + \|\mathcal{T}\|_{w,*}, & (11) \\ \text{s.t. } X^{v\top} X^v = I_v, \end{cases}$$

其中 $\mathcal{Z} \in \mathbb{R}^{N \times V \times N}$ 是由 $\{\bar{x}^v \bar{x}^v\}_1^V$ 重新排列而成的一个三阶张量, \mathcal{T} 为通过算法 1 将其进行奇异值分解获得的张量, $\|\mathcal{T}\|_{w,*}$ 为一个加权张量核范数.

$$\|\mathcal{T}\|_{w,*} = \sum_{i=1}^r \sum_{j=1}^n w_i^{(j)} \bar{S}(i, i, j), \quad (12)$$

算法 1 中的 \bar{S} 可通过式 (13) 获得,

$$\bar{S}(i, i, j) = \begin{cases} 0, & \text{if } c_2 < 0 \\ \frac{c_1 + \sqrt{c_2}}{2}, & \text{if } c_2 \geq 0 \end{cases}, \quad (13)$$

其中 $c_1 = \bar{S}(i, i, j) - \epsilon$, $c_2 = (\bar{S}(i, i, j) + \epsilon)^2 - 4C$, ϵ 是一个足够小的正数, 使得不等式 $\epsilon < \min\left(\sqrt{\gamma}, \frac{\gamma}{S(i, i, j)}\right)$

成立, γ 是一个正则化参数.

1.4 增强自注意力池化

如图 2 所示, 两个并行的 GCN 构成了增强框架. 正

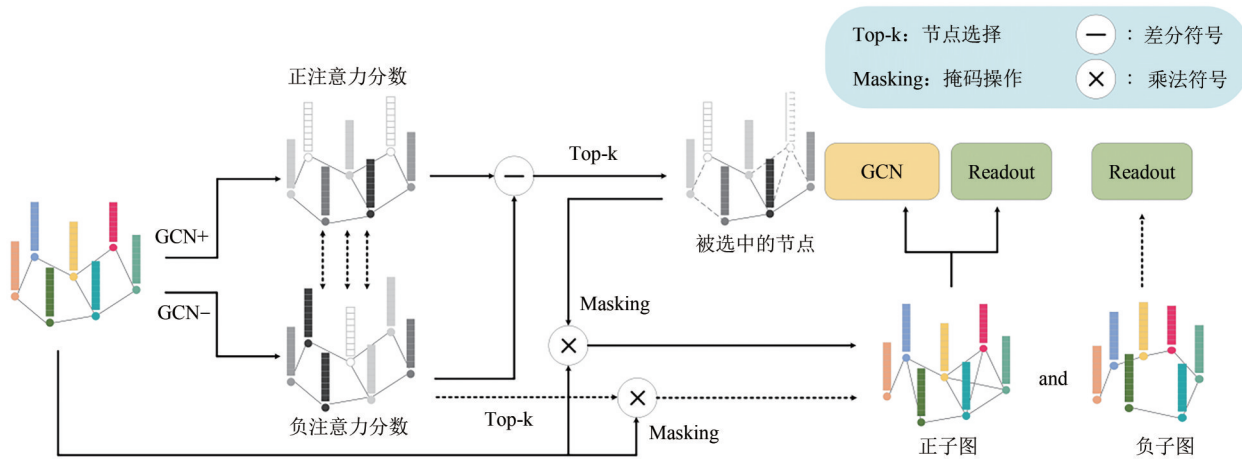


图 2 对比增强自注意力池化图

Fig. 2 Compared enhanced self-attention pooling diagram

对比增强自注意力池化方法分为 3 个步骤:

(1) 注意力分数计算.

注意力分数的计算方式如下:

$$\begin{cases} S_+^{l+1} = \sigma(\text{GCN}_+^l(H^l, A^l)) \\ S_-^{l+1} = \sigma(\sigma(\text{GCN}_-^l(H^l, A^l)) - S_+^{l+1}) \end{cases}, \quad (14)$$

其中 σ 是 sigmoid 函数. $S_+^{l+1} \in R^{N \times 1}$ 和 $S_-^{l+1} \in R^{N \times 1}$ 是 G^l 的学习到的顶点分数. H^l 是第 l 个 GCN 层之后的卷积顶点嵌入; A^l 是第 l 个 GCN 层之后的相同图结构的邻接矩阵. S_+^{l+1} 是 GCN_+ 和 GCN_- 学习到的分数之间的 sigmoid 激活差异.

算法 1 张量奇异值分解

输入: $\mathcal{Z} \in \mathbb{R}^{N \times V \times N}$
 输出: Tensor $\mathcal{T} \in \mathbb{R}^{N \times V \times N}$
 Compute $\bar{\mathcal{T}} = \text{fft}(\mathcal{Z})$
 for $i = 1, \dots, N$ do
 $[\bar{U}^i, \bar{S}^i, \bar{V}^i] = \text{SVD}(\bar{\mathcal{T}}^i)$
 通过式 (13) 获得 \bar{S}
 $\bar{\mathcal{T}}^i = \bar{U}^i \times \bar{S}^i \times \bar{V}^i$
 end
 $\mathcal{T} = \text{ifft}(\bar{\mathcal{T}})$

分支 GCN_+ 旨在学习注意力分数 $S_+ = \{S_+^1, S_+^2, \dots, S_+^n\}$, 以选择一组正顶点, 这些顶点在第 1 层最大程度地表示图 G^l 并获得真正的粗化图 G_+^{l+1} ; 而负分支 GCN_- 旨在学习用于选择负顶点的注意力分数 $S_- = \{S_-^1, S_-^2, \dots, S_-^n\}$, 从而腐蚀 G^l 并获得无效粗化图 G_-^{l+1} . 由于 GCN_+ 旨在对重要顶点分配较高的分数, 对平凡顶点分配较低的分数, 而 GCN_- 则执行相反的操作, 因此 G_+^{l+1} 和 G_-^{l+1} 可以作为一对对比样本. 本文的目标是最大化该对的差异, 并最大限度地分散正顶点和负顶点的得分, 以获得更稳健的图粗化表示.

(2) 顶点选择.

基于 S_+^{l+1} 和 S_-^{l+1} , 使用 top-k 方法从 G^l 中选择 k 个最大的顶点值:

$$\begin{cases} \text{idx}_+^{l+1} = \text{top-}k(S_+^{l+1}, k = \lfloor N \times \text{ratio}_{\text{pool}} \rfloor) \\ \text{idx}_-^{l+1} = \text{top-}k(S_-^{l+1}, k = \lfloor N \times \text{ratio}_{\text{pool}} \rfloor) \end{cases}, \quad (15)$$

其中 idx_+^{l+1} 和 idx_-^{l+1} 是排序后的顶点索引, 用于构造图 G_+^{l+1} 和 G_-^{l+1} . 这两个向量分别包含排名前 k 的顶点索引, 且用于区分对比学习中的正样本子图和负样本子图.

(3) 顶点删除.

根据排序后的顶点索引,可以通过矩阵掩码删除顶点,并根据以下定义构造图 G_+^{l+1} 和 G_-^{l+1} :

$$\begin{cases} A_+^{l+1} = A^l(\text{id}x_+^{l+1}, \text{id}x_+^{l+1}) \\ H_+^{l+1} = H^l(\text{id}x_+^{l+1}, :) \end{cases}, \quad (16)$$

$$\begin{cases} A_-^{l+1} = A^l(\text{id}x_-^{l+1}, \text{id}x_-^{l+1}) \\ H_-^{l+1} = H^l(\text{id}x_-^{l+1}, :) \end{cases}, \quad (17)$$

其中 $A_+^{l+1} \in R^{[N_l \times \text{ratio}_{\text{pool}}] \times [N_l \times \text{ratio}_{\text{pool}}]}$, $A_-^{l+1} \in R^{[N_l \times \text{ratio}_{\text{pool}}] \times [N_l \times \text{ratio}_{\text{pool}}]}$ 分别表示根据前一层图 G^l 中筛选的顶点索引 ($\text{id}x_+^{l+1}$ 和 $\text{id}x_-^{l+1}$) 所构造的正/负对比子图的邻接矩阵. 对应地, $H_+^{l+1} \in R^{[N_l \times \text{ratio}_{\text{pool}}] \times 512}$ 与 $H_-^{l+1} \in R^{[N_l \times \text{ratio}_{\text{pool}}] \times 512}$ 分别表示从原始 $A_l \in R^{N_l \times N_l}$ 和 $H_l \in R^{N_l \times 512}$ 中抽取所得的正/负子图的邻接矩阵与节点评嵌入.

定义的 G_+^{l+1} 旨简化原图 G^l 并保留对分类有用的信息,而 G_-^{l+1} 则相反. 为了使 G_+^{l+1} 和 G_-^{l+1} 分别学习有意义的顶点评分 S_+^{l+1} 和 S_-^{l+1} , 引入了一种“腐蚀损失”(corrosion loss, L_{cor}). 该损失旨在放大 S_+^{l+1} 和 S_-^{l+1} 之间的差异,同时诱导 G_-^{l+1} 出现更多的错误分类. 腐蚀损失 L_{cor} 的定义如下:

$$L_{\text{cor}} = \sum_{i=1}^{N_i} \sum_{l=l_1, l_2, l_3} \cos(S_{+,i}^{l+1}, S_{-,i}^{l+1}) + \sum_{i=1}^{N_i} \cos(q_{+,i}, q_{-,i}), \quad (18)$$

其中 l_1, l_2 和 l_3 是用于构造粗化子图的层级编号. $\cos(\cdot)$ 表示余弦相似度运算. $q_{+,i}$ 和 $q_{-,i}$ 分别表示基于 G_+^{l+1} 和 G_-^{l+1} 的表示对第 i 个样本的预测概率.

分类损失(5)和腐蚀损失(18)限制了图对的对比性质,并且式(14)计算的注意力得分扩大了对比之间的差异. 与从单一角度计算的得分相比,本文所提方法将图池化转换为二类近似问题,充分利用了正/负粗化图固有的矛盾性质. 可以给出鲁棒的图池化操作来动态更新图拓扑并获得分层表示,从而提高诊断性能.

2 实验与结果

2.1 数据集以及数据预处理

2.1.1 实验数据

本实验使用的数据来自阿尔茨海默症神经影像学计划(Alzheimer's Disease Neuroimaging Initiative, ADNI). 在 ADNI 数据库中,轻度认知障碍(Mild Cognitive Impairment, MCI)根据认知损伤程度常被细分为3类:(1)早期轻度认知功能障碍(Early Mild Cognitive Impairment, EMCI),指在记忆测试中表现轻微下降;(2)晚期轻度认知功能障碍(Late Mild

Cognitive Impairment, LMCI),记忆及其他认知功能损伤更明显,更接近痴呆状态;(3)以及未分类的轻度认知障碍. 本实验收集了包含 666 名受试者的数据集,其中包含 117 名 AD 患者,281 名 MCI 患者(其中 126 名 EMCI 患者,103 名为 LMCI 患者,52 名未分类的 MCI 患者)以及 268 名认知正常者(Cognitively Normal, CN)作为对照组. 受试者的详细信息如表 1 所示.

表 1 ADNI 数据集受试者详细信息

类别	AD	CN	MCI	EMCI	LMCI
被试	117	268	281	126	103
性别(女/男)	56/61	175/93	131/150	68/58	41/62
年龄(均值±标准差)	74.7±7.8	72.5±7.2	72.9±7.8	72.4±7.6	72.2±7.5
女性年龄(均值±标准差)	73±9.6	71.5±7	71.9±8.2	69.9±8.5	74.3±6.6
男性年龄(均值±标准差)	76.3±5.2	74.5±7.1	73.8±7.4	75.5±5.1	70.9±7.8

2.1.2 数据预处理

在处理数据库中的数据时,使用静息状态 fMRI 数据处理助手(Data Processing Assistant for Resting-State fMRI)^[17]进行预处理. 为了保证稳定的纵向磁化并适应固有的扫描仪噪声,本文去除前 10 个时间点的数据. 剩余图像按以下步骤依次处理:(1)校正切片采集时间差异和头部运动;(2)去除每个体素时间序列内的线性趋势;(3)对于干扰信号(白质、脑脊液信号、刚体校正计算的头部运动参数)和尖峰回归量进行回归剔除;(4)时序带通滤波(0.01~0.08 Hz),减少低频漂移,滤除高频噪声;(5)使用包含 116 个 ROI 的自动解剖标注(Automated Anatomical Labeling, AAL)从每个被试者影像数据上提取 ROI 的平均时间序列.

在分类任务中,存在一些类别分布不均衡的情况. 原始数据集存在样本数量的差异,为了解决这一问题,本文使用了数据增强策略,来满足各个任务的需求. 这种方法已被证明有效^[18]. 通过对 AAL 的每个脑区进行随机采样 1/3 体素,重复 10 次得到 10 个重采样模板,再将这些模板应用于被试影像数据,具体采样次数见表 2.

本文使用 AAL 模板来对脑部区域进行划分,同时提取时间序列. 在进行时间序列的提取之后,通过使用皮尔逊相关系数(Pearson Correlation Coefficient, PCC)来计算这些脑区之间的相关性. 得到一组相关性系数来表示脑区之间的功能连接强度. 这些相关性系

表2 不同任务采样次数

Tab. 2 Number of sampling times for different tasks

对比组别	AD-CN		MCI-CN		EMCI-LMCI	
原始样本数	117	268	281	268	126	103
采样次数	10	4	5	5	8	10
最终样本数	1170	1072	1405	1340	1008	1030

数整合为一个矩阵,即功能连接网络,通过功能连接网络来生成脑图。

2.2 评价指标

为了全面评估本文模型的性能,采用了6个常用分类指标:准确度(ACC)衡量整体预测的正确率;灵敏度(SEN)评估模型识别正类样本的能力;特异性(SPE)反映模型识别负类样本的能力;精度(PRE)表示被预测为正类中实际为正的样本比例;F1值(F1)综合考虑了精度和灵敏度;而ROC曲线下面积(AUC)用于衡量模型对正负样本的区分能力,AUC值越高代表模型性能越优.这些指标的计算公式如下:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}, \quad (19)$$

$$SEN = \frac{TP}{TP + FN}, \quad (20)$$

$$SPE = \frac{TN}{TN + FP}, \quad (21)$$

$$PRE = \frac{TP}{TP + FP}, \quad (22)$$

$$F1 = 2 \frac{PRE \cdot SEN}{PRE + SEN}. \quad (23)$$

2.3 实验设置

所提出的方法以及基线均使用Pytorch平台进行.所有训练和测试均在两个NVIDIA RTX 2080Ti GPU上进行.本文的模型使用Adam优化器,权重衰减参数为0.0005,学习率为0.01,每训练50轮学习率衰减0.5.此外,使用10倍交叉验证来评估性能并重复10次,以减少随机梯度下降引起的估计不确定性.将数据集分成10个子集,其中一个子集作为测试集,其余按8:1的比例分为训练集和验证集.重复该过程10次,每次选取不同子集作为测试集,其余子集作为训练集和验证集.

2.4 实验结果对比

本文将GFGCN-SP与其他4种方法进行了比较,包括GAT^[19],GCN^[20],GraphSAGE^[21]和BrainGNN^[9].GCN通过多层卷积来逐步融合提取节点的特征信息;GAT在学习过程中自动学习各个节点与其邻居节点的关系;GraphSAGE在大规模图的计算效率上居优;BrainGNN是专为脑连接网络设计的模型。

2.4.1 AD-CN任务上的实验结果

表3展示了在AD-CN任务上的定量结果(最优结果用蓝色字体标出,次优结果用下划线表示).GFGCN-SP分类精度达到了92.64%,较GAT模型提高了0.55%,较GCN模型提高了1.41%,较GrapsSAGE模型提高了0.96%,较BrainGNN提高了0.76%.其AUC和SEN分别为92.66%和93.61%也优于其他方法,这表明其分类的可靠性和泛化能力均较强。

表3 AD-CN任务上对比实验结果 %

Tab. 3 Comparison results on the AD-CN task %

类别	Method	ACC	SEN	SPE	PRE	F1	AUC
AD-CN	GFGCN-SP	92.64	93.61	<u>91.71</u>	<u>91.82</u>	<u>92.38</u>	<u>92.66</u>
	GAT	<u>92.09</u>	91.02	92.96	93.03	91.6	<u>91.99</u>
	GCN	91.23	91.57	90.87	91.06	90.9	91.22
	GraphSAGE	91.68	91.93	91.36	91.43	91.39	91.64
	BrainGNN	91.88	<u>92.87</u>	90.85	90.96	<u>91.69</u>	91.86

2.4.2 MCI-CN任务上的实验结果

表4展示了在MCI-CN任务上的定量结果(最优结果用蓝色字体标出,次优结果用下划线表示).GFGCN-SP分类精度达到了86.85%为最高,较GAT模型提高了2.36%,较GCN模型提高了2.59%,较GrapsSAGE模型提高了2.11%,较BrainGNN提高了1.74%.同时其SEN高于其他方法,说明其对MCI患者的识别能力更强.BrainGNN以85.11%的ACC和85.12%的AUC次之。

表4 MCI-CN任务上对比实验结果 %

Tab. 4 Comparison results on the MCI-CN task %

类别	Method	ACC	SEN	SPE	PRE	F1	AUC
MCI-CN	GFGCN-SP	86.85	88.70	<u>85.06</u>	<u>85.36</u>	<u>86.73</u>	<u>86.88</u>
	GAT	84.49	84.61	84.38	84.1	84.02	84.50
	GCN	84.26	84.81	83.78	83.39	83.76	84.30
	GraphSAGE	84.74	85.00	84.51	83.98	84.39	84.75
	BrainGNN	<u>85.11</u>	<u>85.68</u>	<u>84.56</u>	<u>84.55</u>	<u>84.65</u>	<u>85.12</u>

2.4.3 EMCI-LMCI任务上的实验结果

表5展示了在EMCI-LMCI任务上的定量结果.GFGCN-SP的表现最优,分类精度达到了79.04%,在SPE和PRE上也表现突出,表明其对复杂分类任务的适应能力.BrainGNN的表现次之,但其SPE明显低于GFGCN-SP,表明在对早期病例的识别上仍存在不足。

GFGCN-SP在所有分类任务上均优于其他对比方法,在关键指标(ACC、AUC)上优势明显.这种优势得益于其在特征提取与信息聚合方面的高效机制:(1)图融合模块通过结合密集图与kNN稀疏图的多视图信息,增强了对脑网络复杂结构的识别能

表5 EMCI-LMCI对比实验结果
Tab. 5 Comparison results on the EMCI-LMCI task

类别	Method	ACC	SEN	SPE	PRE	F1	AUC
EMCI-LMCI	GFGCN-SP	79.04	75.83	82.31	84.25	78.92	79.07
	GAT	77.10	72.63	81.5	83.17	75.57	77.06
	GCN	78.41	80.4	76.36	79.05	78.80	78.38
	GraphSAGE	76.17	78.24	73.94	76.27	76.68	76.09
	BrainGNN	78.76	76.28	81.20	82.16	78.34	78.74

力;(2)对比增强自注意力池化模块通过对比学习与自注意力机制,有效筛选判别性节点并提升图下采样的质量.尽管BrainGNN在部分任务中表现不错,但与GFGCN-SP仍有一定差距,尤其是在复杂任务EMCI-LMCI分类的灵敏度和精确性方面.


2.5 消融分析

为了研究不同模块的影响,本文设计了3个消融实验:GF、SP和GF-SP,它们分别代表在原始框架上不使用多图融合方法、去掉对比增强自注意力池化方法、同时不使用这两种方法.通过分别与完整模型GFGCN-SP以及GFGCN-SP的变体进行对比,评估各模块对性能的影响,实验结果如表6所示.不同模块的消融实验在AD-CN、MCI-CN和EMCI-LMCI这三类分类任务中的性能比较如图3所示.

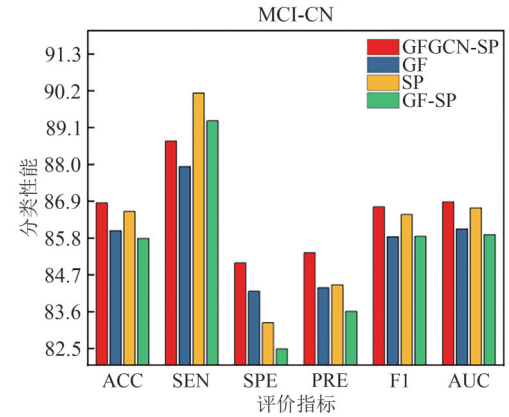
表6 消融实验结果
Tab. 6 Ablation experiment results

任务	Method	ACC	SEN	SPE	PRE	F1	AUC
AD-CN	GFGCN-SP	92.64	93.61	91.71	91.82	92.38	92.66
	GF	91.88	92.87	90.85	90.96	91.69	91.86
	SP	91.41	91.66	91.08	91.01	91.08	91.37
	GF-SP	90.44	90.81	89.90	90.80	90.31	90.36
MCI-CN	GFGCN-SP	86.85	88.70	85.06	85.36	86.73	86.88
	GF	86.02	87.94	84.21	84.32	85.84	86.07
	SP	86.59	90.13	83.27	84.40	86.50	86.70
EMCI-LMCI	GF-SP	85.79	89.30	82.49	83.61	85.85	85.90
	GFGCN-SP	79.04	75.83	82.31	84.25	78.92	79.07
	GF	78.29	76.32	80.38	80.82	77.59	78.35
	SP	78.26	75.19	81.41	82.28	77.66	78.30
	GF-SP	77.90	75.38	80.49	80.39	77.25	77.94

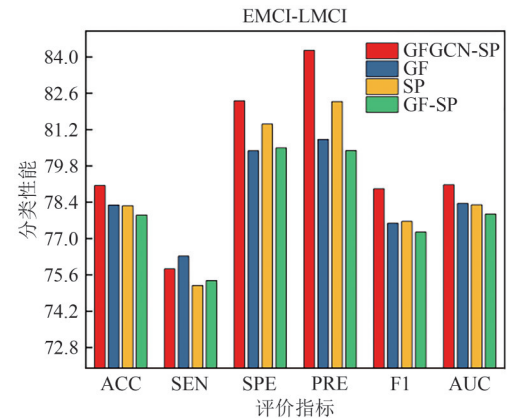
在AD-CN分类任务中,GFGCN-SP的准确率显著高于其他变体.不使用多图融合方法后,ACC和AUC分别下降了0.76%和0.80%,这说明图融合有助于捕获复杂脑网络特征;移除对比增强自注意力池化的影响更大,ACC下降1.23%,AUC下降1.29%,说明对比增强自注意力池化层在提取关键特征方面起到了核心作用;同时移除图融合和对比增强自注意力池化时的性能最差,验证了两个模块联合的重要性.



(a) AD-CN 分类任务下各模型变体的性能表现



(b) MCI-CN 分类任务下各模型变体的性能表现



(c) EMCI-LMCI 分类任务下各模型变体的性能表现

图3 不同模块消融实验在3类分类任务中的性能比较
Fig. 3 Performance comparison of different modules ablation experiments across three classification tasks

在MCI-CN分类任务中,GFGCN-SP表现最佳.移除图融合后,ACC和AUC分别下降0.83%和0.81%,说明多图融合在区分MCI与CN方面贡献显著;移除对比增强自注意力池化后,虽然SEN提升到90.13%,但SPE和AUC有所下降,对比增强自注意力池化对整体分类性能的提升至关重要;同时移除两个模块后,性能降幅明显,进一步验证了两个模块协同作用的重要性.

在EMCI-LMCI分类任务中,GFGCN-SP在所有指标上均优于其他变体,特别是在准确率和特异性上表现突出.移除图融合后,ACC下降至78.29%,AUC下降至78.35%;移除对比增强自注意力池化时,AUC进一步下降至78.30%,表明这两个模块对于区分早期和晚期轻度认知障碍的脑网络特征具有重要作用;完全移除两个模块后的性能最低,说明两模块在复杂任务中的协同效应更加显著.

消融实验结果表明,图融合和对比增强自注意力池化模块均具有提升模型分类准确度的作用:(1)多图融合通过融合多张脑网络图,提升了模型对复杂脑连接模式的捕捉能力,使得分类更全面精准;(2)对比增强自注意力池化模块通过对比增强和自注意力机制进一步优化了特征表示与分类性能.两者的协同作用使得GFGCN-SP在所有分类任务中均表现出卓越的性能,特别是在EMCI-LMCI分类中展现出强大的泛化能力和实际应用潜力.这一结果验证了图融合和对比增强自注意力池化模块设计的有效性,为认知障碍分类提供了更全面和准确的技术支持.

3 讨论与总结

3.1 讨论

本文提出的GFGCN-SP模型通过使用多图融合方法以及在注意力图池化层中加入对比学习的方法,有效解决了图构建质量不足的问题,同时在含噪样本条件下准确建模节点间的拓扑关系,提升了分类准确性.实验结果表明,GFGCN-SP在不同阶段的阿尔茨海默症识别任务中有着较高的分类精度.特别是在AD-CN任务中,分类精度达到了92.64%,优于传统网络.但是,在MCI-CN和EMCI-LMCI任务上的分类精度较AD-CN任务上要差,这可能是由于MCI与CN之间以及EMCI与LMCI之间的神经影像学特征差异较为微弱,导致MCI-CN和EMCI-LMCI任务分类要求更高.经过实验分析,该框架的良好性能可能来源于以下因素:(1)对比增强自注意力池化层通过对比机制,能够增强对不同类别样本的判别性,同时抑制类内冗余信息,有助于突出细微但有区分度的特征信息;(2)通过kNN稀疏图和密集图的融合,既保留了局部判别特征,又涵盖了全面的节点连接,以此加强了图的质量,提升了分类性能.尽管本研究取得了良好的分类性能,但是

仍然存在一些值得进一步探索的地方.特别是在MCI-CN和EMCI-LMCI分类任务中,需要更进一步提取它们之间更为细微的特征信息.在未来的研究中,计划从多模态角度入手,融合结构、功能等多种特征信息,进一步探索更高难度的多分类任务(如AD、CN、EMCI和LMCI)以提升模型的可行性和泛化能力.

3.2 结语

本文提出了基于对比学习和图融合的GFGCN-SP模型,能够有效地提取医学图像中的特征信息.通过在ADNI数据集上的实验验证,GFGCN-SP在分类性能上优于传统的GAT、GCN、GraphSAGE和BrainGNN方法.未来的研究将致力于进一步提升模型的特征提取能力,并探索更为稳健的多分类方法,以应对如AD、CN、EMCI和LMCI等类别间特征差异微小的复杂分类任务.

参 考 文 献

- [1] SIMON R P, AMINOFF M J, GREENBERG D A. Clinical neurology[M]. New York: Lange Medical Books/McGraw-Hill, 2009.
- [2] SHARMA P, SRIVASTAVA P, SETH A, et al. Comprehensive review of mechanisms of pathogenesis involved in Alzheimer's disease and potential therapeutic strategies[J]. Progress in Neurobiology, 2019, 174: 53-89.
- [3] SCHELTENS P, DE STROOPER B, KIVIPELTO M, et al. Alzheimer's disease [J]. The Lancet, 2021, 397 (10284): 1577-1590.
- [4] ZHOU Z, WANG Q, AN X, et al. A novel graph neural network method for Alzheimer's disease classification [J]. Computers in Biology and Medicine, 2024, 180: 108869.
- [5] DECO G, KRINGELBACH M L. Great expectations: Using whole-brain computational connectomics for understanding neuropsychiatric disorders [J]. Neuron, 2014, 84(5): 892-905.
- [6] BLUMENSATH T, JBABDI S, GLASSER M F, et al. Spatially constrained hierarchical parcellation of the brain with resting-state fMRI [J]. NeuroImage, 2013, 76: 313-324.
- [7] SMITH S M, MILLER K L, SALIMI-KHORSHIDI G, et al. Network modelling methods for FMRI [J]. NeuroImage, 2011, 54(2): 875-891.
- [8] OONO K, SUZUKI T. Graph neural networks exponentially lose expressive power for node classification [C]// 8th International Conference on Learning Representations. Addis Ababa: ICLR, 2020: 26-30.

- [9] LI X, ZHOU Y, DVORNEK N, et al. BrainGNN: Interpretable brain graph neural network for fMRI analysis [J]. *Medical Image Analysis*, 2021, 74: 102233.
- [10] YAO D, SUI J, YANG E, et al. Temporal-adaptive graph convolutional network for automated identification of major depressive disorder using resting-state fMRI [C]// *Machine Learning in Medical Imaging*. Cham: Springer, 2020: 1-10.
- [11] GAN J, PENG Z, ZHU X, et al. Brain functional connectivity analysis based on multi-graph fusion [J]. *Medical Image Analysis*, 2021, 71: 102057.
- [12] LEE J, LEE I, KANG J. Self-attention graph pooling [C]// *International Conference on Machine Learning*. Long Beach: PMLR, 2019: 3734-3743.
- [13] RANJAN E, SANYAL S, TALUKDAR P. ASAP: Adaptive structure aware pooling for learning hierarchical graph representations [J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34 (4): 5470-5477.
- [14] LI Z, TANG C, LIU X, et al. Consensus graph learning for multi-view clustering [J]. *IEEE Transactions on Multimedia*, 2021, 24: 2461-2472.
- [15] ZHAO Q, ZHANG H, HE M, et al. Graph pooling via dual-view multi-level infomax [J]. *Knowledge-Based Systems*, 2023, 260: 110089.
- [16] XIE Y, YAO C, GONG M, et al. Graph convolutional networks with multi-level coarsening for graph classification [J]. *Knowledge-Based Systems*, 2020, 194: 105578.
- [17] YAN C G, WANG X D, ZUO X N, et al. DPABI: Data processing & analysis for (resting-state) brain imaging [J]. *Neuroinformatics*, 2016, 14(3): 339-351.
- [18] DVORNEK N C, YANG D, VENTOLA P, et al. Learning generalizable recurrent neural networks from small task-fMRI datasets [C]// *Medical Image Computing and Computer Assisted Intervention*. Cham: Springer, 2018: 329-337.
- [19] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks [J]. *arXiv preprint. arXiv: 2017,1710.10903*.
- [20] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks [J]. *arXiv: 2016, 1609.02907*.
- [21] HAMILTON W, YING Z, LESKOVEC J. Inductive representation learning on large graphs [J]// *arXiv: 2017, 1706.02216*.

(责编 曹东,校对 雷建云)