中图法分类号:TP391　　**文献标识码**: A　　**文章编号**: 1006-8961(XXXX)XX-0001-18

论文引用格式:Peng Wen, Cui Xinyue, Cheng Shumeng. Prior-guided region-community hierarchical graph network for assisted diagnosis of autism spectrum disorder[J/OL]. Journal of Image and Graphics, XXXX:1-18. DOI: 10.11834/jig.260274. (彭文, 崔馨悦, 程淑梦. 先验引导下脑区-社区分层图网络的自闭症辅助诊断方法[J/OL]. 中国图象图形学报, XXXX:1-18. DOI: 10.11834/jig.260274.)[DOI:10.11834/jig.260274]

先验引导下脑区–社区分层图网络的自闭症辅助诊断方法

彭文*,崔馨悦,程淑梦

华北电力大学　控制与计算机工程学院,北京　102206

摘　要:**目的**　现有基于功能脑网络的自闭症谱系障碍(autism spectrum disorder,ASD)辅助诊断方法通常依赖预定义统计度量构建脑区间连接,并将大脑建模为缺乏层次结构的扁平图,既难以学习与诊断任务相关的功能连接模式,也无法刻画脑区与功能社区之间的层级交互异常。针对上述问题,本文提出一种先验引导下脑区-社区分层图网络(prior-guided region-community hierarchical graph network,PGRC-HGN)。**方法**　PGRC-HGN首先构建关键时间感知图构造器(salient temporal-aware graph constructor,STAGC),通过多尺度时序编码与关键时间点筛选学习任务相关邻接矩阵,以捕捉更具诊断判别力的脑区功能连接模式。其次,设计先验引导分层图网络(prior-guided hierarchical graph network,PG-HGN),在功能社区先验约束下动态估计脑区到社区的归属关系,并通过跨层交互实现脑区层与社区层的联合表征。**结果**　在自闭症脑成像数据交换I(Autism Brain Imaging Data Exchange I,ABIDE I)数据集上的实验结果表明,PGRC-HGN的准确率(accuracy,ACC)、受试者工作特征曲线下面积(area under the receiver operating characteristic curve,AUC)、灵敏度(sensitivity,SEN)和特异度(specificity,SPE)分别达到75.27%、79.63%、75.06%和76.62%。与综合性能最优的对比方法DHGFormer相比,所提方法在上述四项指标上分别提升2.76、2.88、3.47和3.28个百分点。**结论**　PGRC-HGN通过关键时间感知的任务相关邻接矩阵构建和先验引导的脑区-社区分层建模,刻画ASD相关的多层级功能连接异常,可为临床ASD辅助诊断提供参考。

关键词:自闭症谱系障碍;静息态功能磁共振成像;图神经网络;功能连接;时间卷积网络

Prior-guided region-community hierarchical graph network for assisted diagnosis of autism spectrum disorder

Peng Wen*, Cui Xinyue, Cheng Shumeng

School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China

Abstract: **Objective** Existing functional brain network-based methods for the auxiliary diagnosis of autism spectrum disorder (ASD) commonly rely on predefined statistical measures to construct inter-regional adjacency matrices and often model the brain as a flat, non-hierarchical graph, which limits their ability to learn diagnosis-relevant connectivity patterns and characterize multi-level abnormalities across brain regions and functional communities. **Methods** To address these limitations, this study proposes a prior-guided region-community hierarchical graph network (PGRC-HGN) for ASD auxiliary diagnosis using resting-state functional magnetic resonance imaging (rs-fMRI). The proposed framework consists of two major components: a salient temporal-aware graph constructor (STAGC) and a prior-guided hierarchical graph network

收稿日期:2026-05-14;**修回日期**:2026-10-26

* **通信作者**:彭文 pengwen@ncepu.edu.cn

© 中国图象图形学报版权所有

(PG-HGN). Given blood-oxygen-level-dependent (BOLD) signals extracted from predefined regions of interest (ROIs), STAGC first adopts multi-scale temporal convolutional networks to encode regional time-series features under different temporal receptive fields, thereby capturing temporal dependencies at multiple scales. A shared temporal self-attention mechanism is then employed to estimate the diagnostic importance of each time point and select key temporal segments that are more closely associated with ASD-related functional abnormalities. Based on these key-time features, a spatial attention module learns a task-relevant adjacency matrix to describe functional interactions between ROIs. In this way, the graph construction process is no longer solely dependent on predefined correlation measures, but is optimized under the supervision of the downstream classification objective. Meanwhile, the Pearson correlation coefficient (PCC) matrix computed from the original BOLD time series is used as the initial node feature representation rather than as a fixed adjacency structure, allowing the model to preserve useful functional connectivity information while learning a more discriminative graph topology. The learned brain graph is subsequently fed into PG-HGN for hierarchical graph representation learning and classification. Unlike conventional graph neural network (GNN)-based brain network models that mainly perform message passing at the ROI level, PG-HGN jointly models brain functional interactions at both the ROI level and the functional community level. Specifically, functional community priors are introduced to provide biologically meaningful constraints for community-level representation learning. In this study, the CC200 atlas is used for ROI parcellation, and the community prior is derived by mapping ROIs to large-scale functional systems based on canonical functional network organization, including the default mode network (DMN), frontoparietal network (FPN), limbic network (LN), ventral attention network (VAN), dorsal attention network (DAN), somatomotor network (SMN), visual network (VN), and cerebellar and subcortical structures (CB&SC). Instead of assigning each ROI to a single fixed community, PG-HGN employs a learnable prototype-based attention mechanism to dynamically estimate the affiliation probabilities between ROIs and functional communities. This design enables each ROI to participate in multiple communities with different weights, thereby improving the model's ability to characterize individual variability and overlapping community organization while maintaining the semantic constraints provided by functional community priors. At the ROI level, graph convolution is used to learn local functional interaction representations among brain regions. At the community level, the dynamically estimated ROI-to-community affiliation matrix is used to aggregate regional features into community-level representations. A cross-level interaction mechanism is then introduced to enable information exchange between the ROI layer and the community layer. Specifically, community-level reasoning is performed to model interactions among large-scale functional systems, and the refined community representations are further propagated back to the ROI layer, allowing local regional features to be updated with global community-level contextual information. Finally, the ROI-level and community-level representations are fused to form a graph-level feature representation, which is fed into a multilayer perceptron for ASD classification. Through this design, PGRC-HGN integrates key-time-aware task-driven graph structure learning with prior-guided hierarchical community modeling, enabling joint characterization of local ROI-level abnormalities and system-level community coordination disruptions. **Results** Experiments were conducted on the preprocessed Autism Brain Imaging Data Exchange I (ABIDE I) dataset. Subjects with fewer than 100 time points were excluded, and all remaining rs-fMRI sequences were truncated to the first 100 frames to ensure consistent temporal length. A total of 1,009 subjects, including 493 individuals with ASD and 516 typical controls, were used for evaluation. The CC200 atlas was adopted to parcellate the brain into 200 ROIs. Five-fold cross-validation was employed to assess the classification performance of the proposed model. Experimental results show that PGRC-HGN achieved an accuracy (ACC) of 75.27%, an area under the receiver operating characteristic curve (AUC) of 79.63%, a sensitivity (SEN) of 75.06%, and a specificity (SPE) of 76.62%. Compared with representative competing methods, including BrainGNN, BrainNetTF, Com-BTF, FBNetGen, RGTNet, and DHGFormer, the proposed method achieved superior overall diagnostic performance. In particular, compared with DHGFormer, the best-performing baseline method in terms of comprehensive performance, PGRC-HGN improved ACC, AUC, SEN, and SPE by 2.76, 2.88, 3.47, and 3.28 percentage points, respectively. These results indicate that the proposed method can more effectively learn discriminative functional connectivity patterns from rs-fMRI data and improve ASD classification performance. **Conclusions** The proposed PGRC-HGN combines task-driven graph structure learning with prior-guided region-community hierarchical modeling for ASD auxiliary diagnosis. By explicitly selecting diagnostically informative time

© 中国图象图形学报版权所有

points, STAGC reduces the interference of irrelevant temporal segments and enhances the learning of task-relevant dynamic functional connectivity patterns. By introducing functional community priors and dynamically estimating ROI-to-community affiliations, PG-HGN balances biological interpretability and individual-specific flexibility in hierarchical brain network modeling. The experimental results on ABIDE I demonstrate that PGRC-HGN achieves superior classification performance and provides more interpretable hierarchical representations of ASD-related functional abnormalities. Therefore, the proposed method may provide useful imaging-based support for ASD auxiliary diagnosis and contribute to the analysis of abnormal functional organization in ASD.

Key words: autism spectrum disorder; resting-state functional magnetic resonance imaging; graph neural network; functional connectivity; temporal convolutional network

论文引用格式:【DOI:10. 11834/jig. 260274】

0 引 言

自闭症谱系障碍(autism spectrum disorder, ASD)是一类以社交沟通能力受损与重复刻板行为为核心特征的神经发育障碍(Karten 和 Hirsch, 2015)。目前,ASD的临床诊断主要依赖行为量表评估和医师的临床观察,缺乏客观、可量化的生物标志物,这在很大程度上限制了诊断的准确性与一致性(Lord 等,2020)。静息态功能磁共振成像(resting-state functional magnetic resonance imaging, rs-fMRI)通过记录血氧水平依赖(blood oxygen level-dependent, BOLD)信号来反映大脑的自发神经活动,已成为探究ASD脑功能异常机制和挖掘潜在生物标志物的重要工具(Kunda 等,2023)。已有研究表明,ASD的脑功能异常不仅体现在局部脑区活动强度的改变,更体现于不同脑区间功能交互模式的紊乱(Hull 等,2017)。这种跨脑区的功能交互模式通常可以通过功能性脑网络建模进行量化分析。在建模中,通常将功能性脑网络抽象为图结构:脑区作为图的节点,脑区间的功能连接关系作为边,连接强度以边权表示,从而将脑功能交互转化为可计算、可分析的图结构数据。

由于脑网络属于典型的非欧几里得图结构数据,传统的卷积神经网络(convolutional neural network, CNN)或序列建模方法难以有效捕捉其固有的拓扑依赖关系。近年来,图神经网络(graph neural network, GNN)凭借其在图结构数据上邻域信息聚合与节点特征学习能力,已逐渐成为脑疾病辅助诊断领域的核心技术手段(Luo 等,2024; Long 等,2024; Lei 等,2026)。现有基于GNN的脑网络方法大多通过皮尔逊相关系数(Pearson correlation coefficient, PCC)等预定义统计度量来构造图,再基于该图利用图卷积网络(graph convolutional network, GCN)等经典GNN模型完成ASD与健康对照组的诊断任务(Tong 等,2023)。此类方法实现简便,实验效果稳定,可复现性强,因此在ASD脑网络分析中得到了广泛应用。

然而,上述方法使用预定义统计度量计算脑区间的边权,以此构建邻接矩阵。这一做法存在两个明显的局限。首先,边的构建过程与下游诊断任务相互解耦,由PCC等预定义统计度量得到的邻接矩阵并未考虑任务关联性,导致预先确定的脑区连接模式可能与ASD诊断任务无关,难以针对下游任务优化GNN中的消息传播路径。其次,相关系数生成的邻接矩阵通常包含正负边权,分别反映脑区间正相关与负相关的功能连接模式,但多数GNN方法仅支持在非负邻接矩阵上执行信息聚合。现有研究中常用的取绝对值等处理方式会直接丢弃正负功能连接携带的潜在生物学信息,从而影响模型的生物学合理性(Wen 等,2022)。为解决上述问题,一些研究引入了图结构学习(graph structure learning, GSL)方法,尝试从rs-fMRI数据中学习与任务相关的邻接矩阵,使边权能够在下游诊断目标的监督下进行优化,从而捕捉更具判别性的脑区连接模式(Mahmood 等,2021; Kan 等,2022a; Wang 等,2024)。尽管这类方法实现了邻接矩阵的任务驱动学习,但仍主要依赖完整rs-fMRI时间序列来估计脑区间连接关系。考虑到BOLD信号具有显著的非平稳性和高度时间变异性,脑区间功能连接会随时间动态波动。如果图结构学习过程缺乏对关键时间点的显式选择机制,模型将难以聚焦于与ASD病理状态潜在相关的判别性时刻,进而忽略脑疾病状态下具有诊断价值的

© 中国图象图形学报版权所有

瞬时功能异常,最终限制诊断性能(Damaraju 等,2014)。

此外,现有基于GNN的脑网络方法通常将大脑视为无层次的扁平图结构,忽视了大脑功能组织的固有层级特性。相关神经科学研究证实,大脑的功能组织并非局限于脑区间的简单交互,更依赖于不同功能社区之间的协同来实现复杂的认知与行为功能(Sporns 和 Betzel,2016)。针对这一特点,现有基于“脑区-社区”分层结构的脑网络方法大致分为两类:一类依赖功能社区先验构建固定的社区划分,为“脑区-社区”层级建模提供清晰且可解释的结构约束。另外一类采用数据驱动的软划分机制,动态学习脑区到社区的归属关系,使脑区能够以不同权重参与多个功能社区,以提升模型对个体差异和社区重叠关系的刻画能力。前者虽然具有清晰的社区语义约束,但默认所有个体共享一致的社区边界,并将每个脑区固定归属于单一社区,难以适应个体间功能连接模式与社区组织方式的异质性。后者虽然更灵活,却往往缺乏明确的功能社区先验约束,可能导致学习到的社区语义不够稳定,甚至在不同个体之间难以保持一致的对应关系。因此,构建一种既能引入功能社区先验约束,又能通过数据驱动机制动态调整脑区到社区归属关系的分层建模框架,对于提升 ASD 诊断的准确性与生物学合理性具有重要的理论与实践意义。

尽管现有研究分别沿着任务驱动的图结构学习与“脑区—社区”分层建模两条路径提升了 ASD 辅助诊断性能,但前者尚未充分利用具有诊断价值的时序信息,后者则难以兼顾社区归属的个体适应性与生物学语义稳定性。针对上述问题,本文提出一种先验引导下脑区-社区分层图网络(prior-guided region-community hierarchical graph network, PGRC-HGN),用于 ASD 的辅助诊断。所提模型将关键时间感知的任务驱动图构建与功能社区先验引导的动态分层建模整合在一个统一框架中,以联合刻画脑区级功能交互异常与社区级协同异常。具体而言,在构图阶段,本文设计了关键时间感知图构造器(salient temporal-aware graph constructor, STAGC)。该图构造器从 rs-fMRI 数据的多尺度时序特征中识别与 ASD 诊断相关的关键时间点,并基于这些时间点捕捉脑区间的任务相关复杂连接模式,从而使图结构学习过程聚焦于具有诊断价值的功能交互,减少无关时间信息对邻接矩阵估计的干扰。进一步,在分层表征学习阶段,本文设计了先验引导分层图网络(prior-guided hierarchical graph network, PG-HGN)。该模块在功能社区先验的约束下,动态估计每个脑区到各功能社区的归属关系,并在脑区与社区两个层级进行脑功能特征的联合建模。这一设计有助于增强模型对社区层功能交互异常的刻画能力,提升层级表征的生物学合理性,并进一步提高诊断性能。

1 相关工作

1.1 基于预定义邻接矩阵的脑网络方法

现有基于 rs-fMRI 的 ASD 诊断方法通常采用 PCC 等统计度量,对脑区时间序列进行两两关联并构建矩阵,再将其作为特征表示输入诊断模型(Khosla 等,2019)。随着 GNN 的发展,越来越多的研究将统计度量构建的矩阵视为图的邻接矩阵,并结合 GCN、图注意力网络(graph attention network, GAT)等模型开展图表示学习。例如,Li 等(2021)将基于偏相关系数构建的邻接矩阵与由 PCC 矩阵构成的节点特征共同输入 BrainGNN 网络,该网络采用同构的聚类图卷积,以学习更具判别性的脑网络特征。Yin 等(2021)利用 PCC 矩阵构建邻接矩阵,并进一步结合图注意力机制,对脑网络中邻域节点的重要性关系进行建模,从而实现 ASD 诊断。尽管此类方法具有较好的稳定性与实用性,但其邻接矩阵通常由 PCC、偏相关系数等预定义统计量预先确定,边的构建过程与下游诊断任务相互分离,难以根据诊断目标优化脑区之间的连接关系。同时,多数基于 GNN 的模型无法直接兼容预定义邻接矩阵中固有的正负边权,采用绝对值处理会丢失具有神经生物学意义的正负功能连接信息。

1.2 基于图结构学习的脑网络方法

为解决基于预定义邻接矩阵的脑网络方法的局限性,部分研究引入 GSL 方法,从数据中自动发现潜在的脑区连接模式(Zhu 等,2021)。Mahmood 等通过一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)提取脑区的时域特征,并借助自注意力机制在诊断任务中学习节点间的邻接关系,再将脑区时域特征与学习到的邻接矩阵共同输入 GNN。Kan 等提出的 FBNetGen 模型采用 1D-CNN

© 中国图象图形学报版权所有

与双向门控循环单元(bidirectional gated recurrent unit,bi-GRU)编码时序特征,经过归一化后以内积相似度生成任务驱动的邻接矩阵。Wang等提出的RGTNet模型通过基于Transformer编码器建模脑区之间的关系,并利用转置自乘运算生成对称的邻接矩阵,再将其与PCC构建的节点特征输入残差GCN进行疾病诊断。然而,上述GSL方法的邻接矩阵学习过程通常建立在完整时间序列之上,未能显式识别BOLD信号中与疾病状态潜在相关的关键时间点。已有研究表明,fMRI功能连接并非在整个扫描过程中保持不变,其动态变化中包含有助于脑疾病分类的判别信息(Wang等,2017)。因此,如何在邻接矩阵学习过程中筛选对诊断任务具有较高判别贡献的时间点,降低无关时间信息对连接模式估计的干扰,是现有GSL方法仍需解决的问题。

1.3 基于“脑区–社区”分层结构的脑网络方法

神经影像学研究表明,大脑功能组织具有显著的层次性,疾病相关异常不仅表现为局部脑区活动紊乱,还体现为不同社区之间协同关系的失衡(Bertolero等,2015)。目前,基于“脑区-社区”分层结构的脑网络方法大多利用功能社区先验获得固定的社区划分,在脑区层特征的基础上进一步引入社区层特征,以建模社区内部及社区之间的交互关系。这种硬划分方法通常根据既有社区标签将脑区映射到预设社区,再通过分层特征聚合、跨层信息传递或社区重组等机制增强对异常模式的刻画能力(Bannadabhavi等,2023;Shehzad等,2024;Xue等,2025)。硬划分方法的优势在于能够引入清晰的社区结构约束,提升社区层表示的可解释性。然而,由于其社区边界和脑区归属关系通常在所有个体之间保持固定,难以适应个体间功能连接模式和社区组织方式的差异,也难以描述部分脑区在多个功能社区中的重叠参与关系,因此对个体化社区组织和多社区参与模式的表征能力仍然有限。不同于硬划分,一些方法尝试从数据中自动学习功能社区结构,通过软分配、聚类或层次融合等机制动态估计脑区到社区的归属关系,以获得更具任务相关性的社区层特征(Zhu等,2023;Kan等,2022b)。这种软划分方法允许脑区以不同权重参与多个功能社区,因而能够更灵活地刻画个体差异和社区重叠关系。但由于软划分方法通常缺乏明确的功能社区先验约束,学习得到的社区结构可能存在语义不清晰、跨个体对应关系不稳定等问题,从而影响社区层表示的生物学可解释性与稳健性。综上所述,现有分层方法虽提升了对社区层交互关系的刻画能力,但如何在社区特征的灵活性与生物学可解释性之间取得平衡,仍是ASD诊断领域的一个关键问题。

2 方 法

2.1 模型总体框架概述

本文提出的先验引导下脑区-社区分层图网络(PGRC-HGN)主要由两个关键组成部分构成:1)关键时间感知图构造器;2)先验引导分层图网络。整体框架如图1所示,对于给定受试者的原始rs-fMRI,本文基于CC200脑图谱划分脑区,并对每个脑区内体素信号取均值,得到脑区平均BOLD时间序列$\boldsymbol{X}\in\mathbf{R}^{N\times T}$,其中$N$为脑区数量,$T$为时间序列长度。模型首先将$\boldsymbol{X}$输入关键时间感知图构造器,得到任务相关邻接矩阵$\boldsymbol{A}\in\mathbf{R}^{N\times N}$。同时,由$\boldsymbol{X}$计算PCC矩阵$\boldsymbol{F}\in\mathbf{R}^{N\times N}$,并将其作为图的初始节点特征。最后,将$\boldsymbol{A}$和$\boldsymbol{F}$构造的非对称图输入先验引导分层图网络中,在脑区层与社区层进行联合建模,输出最终诊断结果。

从整体功能上看,PGRC-HGN中各模块围绕ASD脑功能异常的多层级表征依次展开。STAGC用于从时间维度学习任务相关邻接矩阵,增强邻接矩阵与诊断任务的相关性,并突出诊断相关的关键时序信息。PG-HGN中的双视角图卷积(bidirectional graph convolution,Bi-GCN)在保留非对称任务相关邻接矩阵的基础上,分别从正向与反向两个视角聚合脑区邻域信息。社区动态归属模块在功能社区先验约束下将脑区层表示聚合为个体化社区层表示,缓解固定社区划分难以描述个体差异的问题。社区层Transformer进一步建模功能社区之间的全局交互关系,跨层信息交互则将社区层全局上下文回传至脑区层,并与脑区层局部特征进行融合。通过上述设计,各模块沿任务相关构图—脑区信息传播—社区归属—社区间推理—跨层融合的信息链路依次衔接,共同构成从脑区局部连接到功能社区协同异常的层级建模框架。

2.2 关键时间感知图构造器

关键时间感知图构造器(STAGC)以平均BOLD时间序列$\boldsymbol{X}$为输入,用于构造非对称图。考虑到关

© 中国图象图形学报版权所有

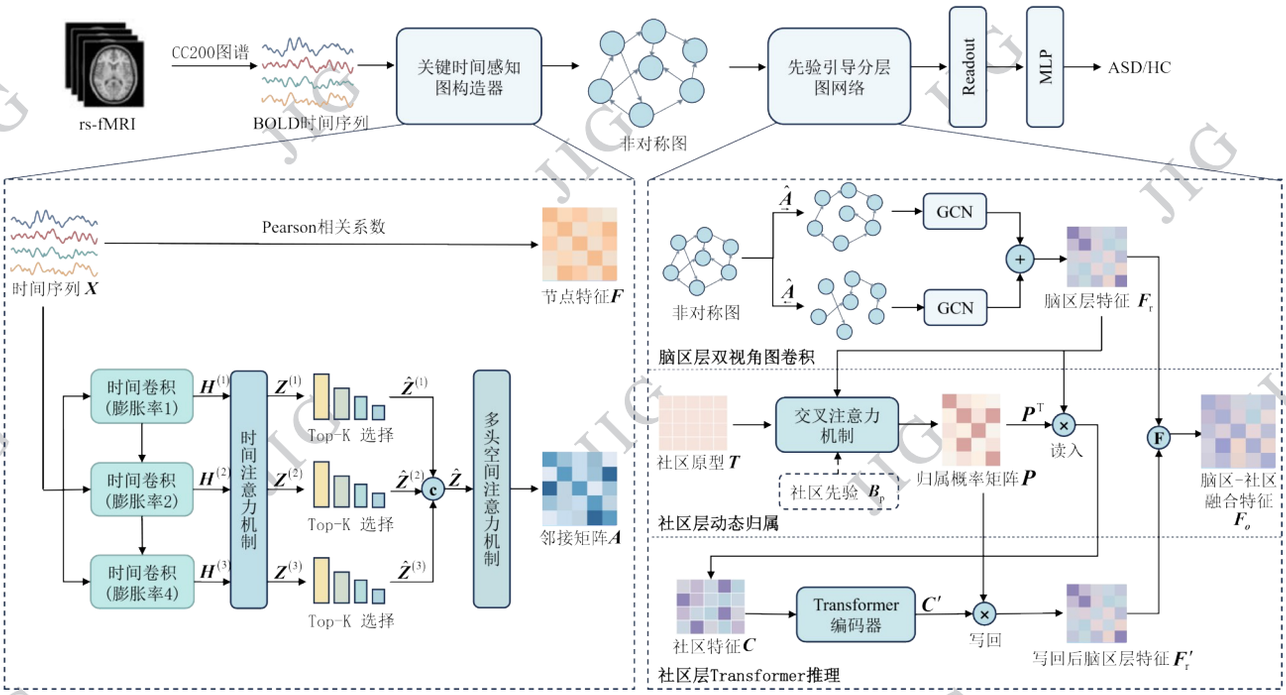


图1　PGRC-HGN的总体架构

Fig. 1　Overall architecture of PGRC-HGN

键时间信息对于刻画脑功能交互模式的重要性，本文受Thapaliya等(2025)提出的DSAM启发，引入多尺度时间卷积与时间注意力机制，来识别对诊断任务更具判别力的关键时间点。具体而言，STAGC首先利用多尺度时间卷积编码不同时间感受野下的脑区时序特征，随后通过时间注意力机制估计时间点的重要性并筛选关键时间点，最后基于多尺度关键时间特征，利用空间注意力机制学习任务相关邻接矩阵。

与FBNetGen、RGTNet等现有GSL方法基于完整时间序列直接估计脑区连接关系的做法不同，STAGC将关键时间点选择置于邻接矩阵学习之前，并基于筛选后的多尺度关键时间特征学习图结构，使所学习的连接关系更多地反映诊断相关时刻的脑区功能交互，从而降低无关时间信息对邻接矩阵估计的干扰。此外，不同于DSAM仍基于时间注意力机制输出的关键时间点特征或原始时间序列计算PCC以构建邻接矩阵，本文进一步将关键时间点选择与任务驱动的图结构学习相结合，通过空间注意力直接基于关键时间特征学习邻接矩阵。同时，本文直接保留所学习邻接矩阵的非对称性，避免强制对称化带来的信息损失。

2.2.1　多尺度时间编码

为提取不同时间感受野下的时序信息，本文引入多尺度时间编码器，以刻画脑区BOLD信号中的短时局部变化、中程时序依赖和长程动态趋势。输入给定受试者的BOLD时间序列矩阵$\boldsymbol{X}$，其编码过程可表示为

$$\boldsymbol{H}^{(1)},\boldsymbol{H}^{(2)},\boldsymbol{H}^{(3)} = Encoder(\boldsymbol{X}) \tag{1}$$

式中，$\boldsymbol{H}^{(1)},\boldsymbol{H}^{(2)},\boldsymbol{H}^{(3)} \in \mathbf{R}^{N\times T}$分别表示3个时间尺度下的时序特征矩阵，其维度均为$N \times T$；Encoder表示多尺度时间编码器。

该时间编码器由三个级联的二维因果时间卷积块组成，膨胀率采用1、2和4的渐进式设置，使首个卷积块保持对局部连续时序模式的提取能力，后续卷积块则在不增加卷积参数量的情况下逐级扩大时间感受野，从而形成由局部到较长时间范围的多尺度时序表示。不同膨胀率组合的对比结果将在第3.5.3节中进一步分析。卷积操作仅沿时间维展开，而不在脑区维混合信息，从而避免在时间编码阶段引入跨脑区干扰。每个卷积块均包含两层因果卷积，逐层扩大时间感受野并增强时序模式建模能力。最终得到的多尺度时序特征为后续关键时间点选择提供输入。

© 中国图象图形学报版权所有

2.2.2　关键时间点选择机制

为克服传统基于图结构学习的脑网络方法中缺乏对关键时间点显式选择机制的局限，本文在多尺度时间编码器输出的时序特征$\boldsymbol{H}^{(1)},\boldsymbol{H}^{(2)},\boldsymbol{H}^{(3)}$上引入时间注意力机制。该机制对每个尺度的时序特征分别进行时间注意力计算，以估计各时间点的重要性。尺度之间共享注意力权重，从而使不同尺度选择一组相似的时间点。

对第s个尺度特征$\boldsymbol{H}^{(s)}$，首先利用时间注意力机制进行建模：

$$\boldsymbol{Q}^{(s)}=\boldsymbol{H}^{(s)}\boldsymbol{W}_{\mathrm{Q}},\boldsymbol{K}^{(s)}=\boldsymbol{H}^{(s)}\boldsymbol{W}_{\mathrm{K}},\boldsymbol{V}^{(s)}=\boldsymbol{H}^{(s)}\boldsymbol{W}_{\mathrm{V}} \tag{2}$$

$$\boldsymbol{Z}^{(s)}=LayerNorm\left(Softmax\left(\frac{\boldsymbol{Q}^{(s)}\boldsymbol{K}^{(s)\mathrm{T}}}{\sqrt{d}}\right)\boldsymbol{V}^{(s)}+\boldsymbol{H}^{(s)}\right) \tag{3}$$

式中，s表示时间尺度索引，$\boldsymbol{Q}^{(s)},\boldsymbol{K}^{(s)},\boldsymbol{V}^{(s)}$分别表示第$s$个尺度的查询矩阵、键矩阵和值矩阵；$\boldsymbol{H}^{(s)}$表示该尺度的时序特征矩阵；$\boldsymbol{W}_{\mathrm{Q}},\boldsymbol{W}_{\mathrm{K}},\boldsymbol{W}_{\mathrm{V}}$分别表示对应的可学习线性映射矩阵，$\boldsymbol{Z}^{(s)}$表示第$s$个尺度的时间注意力输出特征矩阵；$d$表示注意力计算中的特征维度；Softmax表示归一化指数函数，LayerNorm表示层归一化操作。

随后，将注意力输出进行聚合，得到时间重要性得分向量$\boldsymbol{u}^{(s)}\in\mathbf{R}^{T}$：

$$u_j^{(s)}=sigmoid\left(\sum_{i=1}^{N}\left|\boldsymbol{Z}_{ij}^{(s)}\right|\right),j=1,2,...,T \tag{4}$$

式中，$u_j^{(s)}$表示第s个尺度下第j个时间点的重要性得分；i为脑区索引，j为时间点索引；sigmoid表示Sigmoid激活函数。

设关键时间选择比例为$\alpha\in(0,1)$，则每个尺度选取$K=\lfloor\alpha T\rfloor$个关键时间点，其索引集合为：

$$\boldsymbol{I}^{(s)}=TopK\left(\boldsymbol{u}^{(s)},K\right) \tag{5}$$

式中，$\boldsymbol{I}^{(s)}$表示第s个尺度下选取的关键时间点索引集合；$\boldsymbol{u}^{(s)}$表示对应尺度的时间重要性得分向量；TopK表示选取重要性得分最高的K个时间点的操作。

并据此从对应尺度特征中提取关键时间点特征$\hat{\boldsymbol{Z}}^{(s)}\in\mathbf{R}^{N\times K}$：

$$\hat{\boldsymbol{Z}}^{(s)}=\boldsymbol{H}^{(s)}_{:,I^{(s)}} \tag{6}$$

式中，$\hat{\boldsymbol{Z}}^{(s)}$表示第$s$个尺度筛选出的关键时间点特征矩阵；下标中的冒号表示保留全部脑区。

最后，将三个尺度下的关键时间点特征拼接，得到多尺度关键时间点特征$\hat{\boldsymbol{Z}}\in\mathbf{R}^{N\times 3K}$：

$$\hat{\boldsymbol{Z}}=Concat\left(\hat{\boldsymbol{Z}}^{(1)},\hat{\boldsymbol{Z}}^{(2)},\hat{\boldsymbol{Z}}^{(3)}\right) \tag{7}$$

式中，$\hat{\boldsymbol{Z}}$表示拼接得到的多尺度关键时间点特征矩阵；Concat表示沿时间特征维度进行拼接的操作。该特征能够突出对下游诊断任务具有判别力的时间模式。

2.2.3　非对称图的构造

在获得多尺度关键时间点特征$\hat{\boldsymbol{Z}}$后，本文进一步学习脑区之间的空间关系，以构造非对称图。具体而言，本文采用多头空间注意力机制对脑区间的两两依赖关系进行建模。设第h个注意力头的查询矩阵和键矩阵分别为：

$$\boldsymbol{Q}^{(h)}=\hat{\boldsymbol{Z}}^{(h)}\boldsymbol{W}_{\mathrm{Q}},\boldsymbol{K}^{(h)}=\hat{\boldsymbol{Z}}^{(h)}\boldsymbol{W}_{\mathrm{K}} \tag{8}$$

式中，h表示注意力头索引；$\boldsymbol{Q}^{(h)}$和$\boldsymbol{K}^{(h)}$分别表示第h个注意力头的查询矩阵和键矩阵；$\hat{\boldsymbol{Z}}^{(h)}$表示输入该注意力头的特征矩阵；$\boldsymbol{W}_{\mathrm{Q}},\boldsymbol{W}_{\mathrm{K}}$分别表示查询矩阵和键矩阵对应的可学习线性映射矩阵。

$$\boldsymbol{A}^{(h)}=Sigmoid\left(\frac{\boldsymbol{Q}^{(h)}\boldsymbol{K}^{(h)\mathrm{T}}}{\sqrt{d_h}}\right) \tag{9}$$

式中，$\boldsymbol{A}^{(h)}$表示第h个注意力头学习得到的邻接矩阵；d_h表示第h个注意力头的特征维度；上标T表示矩阵转置。最后，对多个注意力头的结果取平均，得到最终的非对称矩阵$\boldsymbol{A}\in\mathbf{R}^{N\times N}$。

为了避免传统基于图结构学习的脑网络方法中，对学习得到的非对称矩阵使用自乘等对称化操作带来的信息损失，本文将$\boldsymbol{A}$直接作为图的任务相关邻接矩阵。同时，本文由原始BOLD时间序列$\boldsymbol{X}$计算PCC矩阵$\boldsymbol{F}$，并将其作为图的初始节点特征输入。由此，邻接矩阵$\boldsymbol{A}$与节点特征$\boldsymbol{F}$共同构成图，输入后续的先验引导分层图网络。

2.3　先验引导分层图网络

相关神经科学表明，大脑的信息处理遵循自然的层级模式：信息首先在单个脑区之间进行基础交互，随后逐步整合为具有特定功能的社区，通过这些功能社区之间的动态协同，完成复杂的神经信息整合与处理。ASD的脑功能异常，往往集中体现在这些功能社区之间的协同关系失衡上（Meunier等，2010）。为了捕捉这种异常，本文设计了先验引导分层图网络（PG-HGN），PG-HGN以STAGC输出的非对称图为输入，在脑区层与社区层对脑网络进行联

© 中国图象图形学报版权所有

合建模。具体而言，PG-HGN首先通过脑区层双视角图卷积聚合邻域信息，得到脑区层特征。随后，在功能先验约束下动态估计每个脑区到各功能社区的归属概率，最后，基于该归属关系进行跨层信息交互，实现脑区层特征与社区层特征的联合更新，从而提升模型对系统级异常模式的表征能力与生物学合理性。

2.3.1 脑区层双视角图卷积

由于STAGC输出的任务相关邻接矩阵为非对称矩阵，若直接采用传统GCN难以充分利用非对称拓扑结构中源节点与目标节点的差异化特征。为此，本文采用双视角图卷积（Bi-GCN），在保留非对称任务相关邻接矩阵的基础上，分别从正向传播与反向传播两个视角对节点表示进行聚合，从而综合捕捉不同视角下的邻域信息。

首先在任务相关邻接矩阵上加入自环得到$\hat{\boldsymbol{A}}=\boldsymbol{A}+\boldsymbol{I}$，其中$\boldsymbol{I}$为单位阵。随后，分别沿正向与反向传播路径进行聚合：

$$\underset{\rightarrow}{\boldsymbol{F}}^{(l)}=\sigma\left(\xrightarrow[\hat{\boldsymbol{A}}]{}\boldsymbol{F}^{(l-1)}\underset{\rightarrow}{\boldsymbol{W}}^{(l)}\right),\underset{\leftarrow}{\boldsymbol{F}}^{(l)}=\sigma\left(\xleftarrow[\hat{\boldsymbol{A}}]{}\boldsymbol{F}^{(l-1)}\underset{\leftarrow}{\boldsymbol{W}}^{(l)}\right)\tag{10}$$

式中，$\underset{\rightarrow}{\boldsymbol{F}}^{(l)}$，$\underset{\leftarrow}{\boldsymbol{F}}^{(l)}$分别表示正向与反向节点特征矩阵；$\xrightarrow[\hat{\boldsymbol{A}}]{}$，$\xleftarrow[\hat{\boldsymbol{A}}]{}$分别表示正向与反向归一化任务相关邻接矩阵；$\underset{\rightarrow}{\boldsymbol{W}}^{(l)}$，$\underset{\leftarrow}{\boldsymbol{W}}^{(l)}$分别表示正向与反向可学习参数；$l$表示图卷积层索引；$\sigma(\cdot)$表示非线性激活函数。

最后，将两个方向的聚合结果取均值进行融合得到更新后的节点特征$\boldsymbol{F}^{(l)}\in\mathbf{R}^{N\times d}$。该设计能够在保留非对称图结构的同时，从两个视角综合建模脑区间的信息传递过程，为后续社区层建模提供更充分的脑区层特征。

2.3.2 社区层动态归属与Transformer推理

脑网络分析方法中，如何平衡特征学习的灵活性与生物学可解释性是一个核心挑战。仅依赖固定社区标签进行硬划分虽具有高度的生物学可解释性，但容易掩盖与疾病相关的个体化差异。而完全数据驱动的无约束软聚类虽灵活，容易导致学习得到的功能社区含义模糊且不稳定。

为此，本文引入K个可学习的社区原型$\boldsymbol{T}\in\mathrm{R}^{K\times d}$，并构建脑区到社区的先验偏置矩阵$\boldsymbol{B}_{\mathrm{p}}\in\mathbf{R}^{N\times K}$。其中，若第$i$个脑区属于第$k$个先验社区，则对应偏置为0，否则赋予负偏置惩罚$-\gamma$，即

$$\boldsymbol{b}_{ik}^{\mathrm{p}}=\begin{cases}0, & \text{若脑区}i\text{属于社区}k\\ -\gamma, & \text{否则}\end{cases}\tag{11}$$

式中，$\boldsymbol{b}_{ik}^{\mathrm{p}}$表示先验偏置矩阵中第$i$行、第$k$列的元素；$i$和$k$分别表示脑区索引和社区索引；$\gamma>0$为先验惩罚系数。

随后，将脑区层双视角图卷积得到的脑区层特征$\boldsymbol{F}_{\mathrm{r}}\in\mathbf{R}^{N\times d}$与社区原型$\boldsymbol{T}$计算动态归属概率矩阵$\boldsymbol{P}\in\boldsymbol{R}^{N\times K}$：

$$\boldsymbol{P}=Softmax\left(\frac{\left(\boldsymbol{F}_{\mathrm{r}}\boldsymbol{W}_{\mathrm{Q}}\right)\left(\boldsymbol{T}\boldsymbol{W}_{\mathrm{K}}\right)^{\mathrm{T}}}{\sqrt{d}}+\boldsymbol{B}_{\mathrm{p}}\right)\tag{12}$$

式中，$\boldsymbol{P}$表示脑区到社区的动态归属概率矩阵；$\boldsymbol{W}_{\mathrm{Q}}$，$\boldsymbol{W}_{\mathrm{K}}$分别表示查询和键对应的可学习映射矩阵。

先验偏置矩阵$\boldsymbol{B}_{\mathrm{p}}$根据脑区与预定义功能社区之间的先验归属关系构造，作为偏置项加入到动态归属概率矩阵$\boldsymbol{P}$的计算中，以引导概率矩阵$\boldsymbol{P}$的学习。概率矩阵$\boldsymbol{P}$刻画每个脑区对不同功能社区的归属权重，使脑区能够在保留先验功能社区语义的同时，以不同权重参与多个社区。因此，模型能够在功能社区先验的约束下，根据个体脑区层特征动态调整脑区到各功能社区的归属关系，在保持社区语义稳定性的同时，增强对个体差异和社区重叠关系的刻画能力。

在此基础上，本文采用读入—推理—写回的跨层交互方式进行社区层建模。首先，利用归属概率矩阵$\boldsymbol{P}$将脑区层特征聚合为社区层特征：$\boldsymbol{C}=\boldsymbol{P}^{\mathrm{T}}\boldsymbol{F}_{\mathrm{r}}$。随后，在社区层利用Transformer编码器对$\boldsymbol{C}$进行全局交互推理，得到更新后的社区层特征$\boldsymbol{C}'=\mathrm{Transformer}(\boldsymbol{C})$，最后利用同一归属概率矩阵将社区信息写回脑区层：$\boldsymbol{F}_{\mathrm{r}}'=\boldsymbol{P}\boldsymbol{C}'$，将社区层写回的特征与原始脑区层特征进行融合，得到最终的“脑区-社区”融合特征$\boldsymbol{F}_{\mathrm{o}}$。该过程能够在功能社区先验约束下实现社区归属的动态调整，并通过脑区层与社区层的联合建模增强模型对系统级异常模式的刻画能力。

2.3.3 图级读出与分类输出

在得到最终“脑区-社区”融合特征$\boldsymbol{F}_{\mathrm{o}}$后，本文通过线性映射将节点特征投影至低维空间并形成图级向量表示，随后输入多层感知机（multilayer perceptron，MLP）输出二分类结果。设节点投影为$\boldsymbol{Y}=\phi\left(\boldsymbol{F}_{\mathrm{o}}\boldsymbol{W}_{\mathrm{o}}\right)$，式中$\boldsymbol{W}_{\mathrm{o}}$表示输出投影的可学习权重矩

© 中国图象图形学报版权所有

阵，ϕ表示激活函数；将$\boldsymbol{Y}$展平得到受试者级表示$\boldsymbol{V}$，最终分类为

$$\hat{\boldsymbol{V}} = Softmax\left(MLP\left(\boldsymbol{V}\right)\right) \tag{13}$$

式中，$\boldsymbol{V}$表示受试者级图表示向量；MLP表示多层感知机；$\hat{\boldsymbol{V}}$表示模型输出的分类预测结果。训练阶段采用交叉熵损失进行监督学习，端到端联合优化。

3 结　果

3.1 受试者信息与数据集

本文采用自闭症脑成像数据交换Ⅰ(Autism Brain Imaging Data Exchange Ⅰ, ABIDE Ⅰ)公开数据集开展自闭症谱系障碍(ASD)辅助诊断研究(Craddock等，2013)。ABIDE Ⅰ汇集来自17个研究中心的多中心静息态功能磁共振(rs-fMRI)数据，包含ASD与健康对照组(healthy controls, HC)两类受试者。鉴于多中心数据在扫描设备、采集参数与受试者构成方面存在显著差异，中心间异质性可能对模型训练与泛化评估产生干扰，本文直接使用预处理连接组项目(Preprocessed Connectomes Project, PCP)提供的标准化预处理数据作为输入。

PCP预处理流程主要包括时间校正、头动校正、空间配准与标准化、白质和脑脊液等非神经信号回归、低频漂移去除以及带通滤波。预处理完成后，基于CC200脑图谱将全脑划分为200个脑区，并对每个脑区内体素信号取均值，得到脑区平均BOLD时间序列。

为引入具有生物学意义的社区先验，本文参考Yeo 7-network atlas(Yeo等，2011)将脑区划分为8个功能社区，分别为默认模式网络(default mode network, DMN)、额顶网络(frontoparietal network, FPN)、边缘网络(limbic network, LN)、腹侧注意网络(ventral attention network, VAN)、背侧注意网络(dorsal attention network, DAN)、躯体运动网络(somatomotor network, SMN)、视觉网络(visual network, VN)以及小脑与皮层下结构(cerebellar and subcortical structures, CB&SC)。

考虑到不同受试者的时间序列长度并不一致，本文进一步剔除时间点数少于100的样本，并将其余样本统一截取为前100个时间点，最终形成用于实验分析的1009个受试者集合(统计信息见表1)。为评估模型在不同样本划分下的稳健性与泛化能力，本文采用交叉验证方案，具体参数见实验环境设置与评价指标部分。

表1　受试者信息

Table 1　Subject information

指标	ASD	HC	总计
受试者数量	493	516	1009
年龄/岁	17.2±8.6	17.0±7.5	17.1±8.0
性别(男/女)	431/62	421/95	852/157
FD/mm	0.159±0.190	0.103±0.099	0.130±0.153
采集站点数量	16	16	16

注：年龄和平均帧间位移(framewise displacement, FD)以均值±标准差表示。

3.2 实验环境设置与评价指标

本文模型的构建与训练基于PyTorch框架实现，实验运行环境为配备24GB显存的NVIDIA GeForce RTX 3090 GPU。训练过程中，批处理大小设置为16，训练轮数设为100，初始学习率设为1×10^-4。为更全面地评估模型的泛化能力与结果稳定性，本文采用五折交叉验证策略，并将各折实验结果的平均值作为最终性能报告。考虑到本文主要目标是在统一条件下，对本文方法与多种公开基线方法进行比较，因此实验划分遵循现有基线方法常用的五折交叉验证评估协议，未额外引入类别—站点联合分层约束，以避免由于划分策略变化造成不同方法之间的比较偏差。分类性能评价方面，本文选取准确率(accuracy, ACC)、灵敏度(sensitivity, SEN)、特异度(specificity, SPE)和受试者工作特征曲线下面积(area under the receiver operating characteristic curve, AUC)作为评价指标，从多个角度对模型进行综合评估。

3.3 对比实验结果与分析

为验证本文提出模型的有效性，将PGRC-HGN与多种代表性方法进行对比，包括基于GNN的脑网络方法BrainGNN(Li等，2021)，基于“脑区-社区”分层结构的脑网络方法BrainNetTF(Kan等，2022b)、Com-BTF (Bannadabhavi 等，2023) 和 DHGFormer (Xue等，2025)，其中BrainNetTF属于软划分分层方法，Com-BTF和DHGFormer属于硬划分分层方法，以及基于图结构学习的脑网络方法FBNetGen(Kan

© 中国图象图形学报版权所有

等,2022a)和RGTNet(Wang等,2024)。

各模型在ABIDE I数据集上的分类结果如表2所示。为提高不同方法之间的可比性,表2中所有对比方法的结果均由本文作者基于公开代码重新复现获得。所有方法均采用相同的数据集、相同的样本筛选标准、相同的PCP预处理流程和CC200脑图谱,并统一采用ACC、AUC、SEN和SPE作为评价指标。对于能够直接适配统一数据接口的对比方法,本文进一步使用相同的数据划分进行训练和测试;对于部分具有独立数据读取流程的公开代码,本文在保持其官方模型结构和主要超参数设置不变的基础上,对输入数据和评价指标进行统一适配。上述设置尽可能减少了数据来源、预处理流程和评价指标差异对实验结果的影响,从而尽可能减少非模型因素对实验结果的影响。

表2 不同模型的分类效果

Table 2 Classification effects of different models

模型	ACC/%	AUC/%	SEN/%	SPE/%
BrainGNN	63.84±3.08	65.53±3.67	58.55±6.81	69.00±4.76
BrainNetTF	70.44±2.07	77.54±2.38	68.08±2.50	74.13±6.50
Com-BTF	70.15±2.97	77.64±3.36	67.49±5.79	75.10±5.65
FBNetGen	68.87±2.67	75.63±3.01	66.43±3.35	71.70±4.02
RGTNet	70.15±3.77	72.03±4.84	69.88±4.41	70.50±3.94
DHGFormer	72.51±1.89	76.75±3.31	71.59±1.88	73.34±3.18
PGRC-HGN	**75.27 2.16**	**79.63 2.54**	**75.06 6.03**	**76.62 3.58**

注:各指标均以均值±标准差表示;加粗数据表示对应指标的最优结果。

由表2可知,PGRC-HGN在ACC、AUC、SEN和SPE四项指标上均取得最优结果,分别达到75.27±2.16%、79.63±2.54% 、75.06±6.03% 和 76.62±3.58%。相较于性能综合最优的已有方法DHGFormer,PGRC-HGN在ACC、AUC、SEN、SPE上分别提升2.76、2.88、3.47、3.28个百分点。需要指出的是,DHGFormer同样属于基于图结构学习的"脑区-社区"分层结构的脑网络方法,这一结果表明,在相近的方法范式下,PGRC-HGN所采用的建模策略能够进一步提升对ASD相关异常模式的表征能力。综合来看,本文方法在ABIDE I数据集上表现出更优的整体判别性能,说明其能够学习到更具区分性的脑网络表征,从而为ASD辅助诊断提供更有效的方法支撑。

为进一步验证PGRC-HGN相较于最强基线方法性能提升的统计显著性,本文针对PGRC-HGN与DHGFormer进行了补充显著性检验。具体而言,本文采用10次重复的5折交叉验证,并对两种方法在对应划分上的性能差异进行Wilcoxon符号秩检验(显著性水平设为$p<0.05$)。同时,本文报告对应划分上性能差值的95%置信区间,以评估性能提升的稳定性。统计结果如表3所示。

由表3可知,PGRC-HGN相较于DHGFormer在ACC和AUC上的性能提升均达到统计显著水平,且对应性能差值的95%置信区间均大于0,说明本文方法相较于最强基线方法的性能提升具有较好的稳定性。

表3 PGRC-HGN相较于DHGFormer的统计学显著性

Table 3 Statistical significance of PGRC-HGN compared with DHGFormer

指标	95%置信区间/百分点	*P*-值
ACC	[0.45,1.79]	8.52e-4*
AUC	[0.98,2.60]	3.30e-5*

注:"*"表示差异具有统计学显著性($p<0.05$)。

3.4 消融实验结果与分析

为验证PGRC-HGN中各核心模块对ASD辅助诊断性能的贡献,本文设计了多组消融实验,结果如表4所示。实验涉及图构造器(graph constructor,GC)和分层图网络(hierarchical graph network,HGN)等模块,具体模块设置及其差异将在下文进一步说明。完整模型PGRC-HGN在ACC、AUC、SEN和SPE

© 中国图象图形学报版权所有

四项指标上均取得最优结果，分别为75.27%、79.63%、75.06%和76.62%，说明关键时间感知图构造器（STAGC）与先验引导分层图网络（PG-HGN）能够在图结构学习和层级特征建模两个方面形成互补，从而提升模型对ASD异常脑功能模式的判别能力。

表4 消融实验结果

Table 4 Ablation study results

方法	ACC/%	AUC/%	SEN/%	SPE/%
PCC+PG-HGN	70.05±1.53	73.94±0.57	69.08±2.50	70.82±2.97
GC+PG-HGN	71.03±1.61	74.29±2.34	73.55±3.25	69.50±4.09
STAGC+GCN	68.87±2.64	71.54±2.86	66.92±5.85	70.98±4.60
STAGC+Bi-GCN	69.56±2.13	72.15±2.58	70.43±7.35	69.22±2.40
STAGC+HGN	73.20±3.11	77.16±3.40	74.51±4.24	72.10±3.19
PGRC-HGN	**75.27 2.16**	**79.63 2.54**	**75.06 6.03**	**76.62 3.58**

注：各指标均以均值±标准差表示；加粗数据表示对应指标的最优结果。

首先，从图结构构造方式来看，PCC+PG-HGN使用PCC构建的预定义邻接矩阵替代STAGC学习到的任务相关邻接矩阵，四项指标较完整模型分别下降5.22%、5.69%、5.98%和5.80%。这一结果表明，尽管PCC能够刻画脑区时间序列之间的线性相关关系，但其连接结构在模型训练前已经固定，无法针对诊断任务优化传播路径，难以充分捕捉与任务相关的功能连接模式。相比之下，STAGC在监督信号约束下学习邻接关系，使图结构具有更强的任务相关性和判别性。

其次，为验证关键时间点选择机制的作用，本文设置GC+PG-HGN作为对照模型。该模型去除STAGC中的关键时间点选择机制，直接基于完整时间特征学习图结构。实验结果显示，其ACC和AUC较完整模型分别下降4.24%和5.34%，SPE下降更为明显（由76.62%降至69.50%）。这说明仅依赖完整rs-fMRI时间序列进行连接关系估计，容易受到大量诊断无关时间片段的干扰，从而削弱邻接矩阵对ASD功能交互模式的表达能力。STAGC通过从多尺度时序特征中选择与诊断任务更相关的关键时间点，使图结构学习过程能够聚焦于更具判别性的瞬时功能交互，减少冗余时间信息的影响。

再次，从脑网络表征结构来看，STAGC+GCN在保留STAGC的基础上，将PG-HGN替换为传统GCN。该模型的ACC和AUC分别为68.87%和71.54%，是所有消融模型中性能最低的结果。这表明，即使图结构能够通过STAGC学习到较强的任务相关连接模式，若后续特征传播仍局限于扁平的脑区层图卷积，模型仍难以描述脑区之间以及社区之间的多层级功能交互关系。

进一步地，为验证非对称任务相关邻接矩阵及其双向传播机制的作用，本文设置STAGC+Bi-GCN作为对照模型。该模型在保留STAGC所学习邻接矩阵的基础上，仅采用脑区层双向图卷积，不引入社区层动态归属与分层推理。与STAGC+GCN相比，STAGC+Bi-GCN的ACC、AUC和SEN分别提升至69.56%、72.15%和70.43%，说明相比传统GCN，双向图卷积能够更充分地利用STAGC学习得到的非对称邻接结构，在一定程度上保留脑区间潜在的非对称功能交互信息，避免对学习邻接矩阵进行强制对称化所造成的信息损失。然而，STAGC+Bi-GCN的整体性能仍明显低于完整模型，这表明，仅在脑区层利用非对称连接进行双向信息传播，仍难以充分刻画ASD相关异常在社区层面的组织模式。

最后，为考察功能社区先验约束的作用，本文比较了STAGC+HGN与完整模型PGRC-HGN。STAGC+HGN去除了功能社区先验，仅采用数据驱动的软划分方式学习脑区到社区的归属关系。该模型性能优于STAGC+GCN和STAGC+Bi-GCN，说明数据驱动的分层结构本身能够有效提升模型对社区层交互关系的建模能力。然而，与完整模型相比，STAGC+HGN的ACC、AUC和SPE分别下降2.07%、2.47%和4.52%。这表明，如果缺乏功能社区先验约束，软划分机制虽然具有较强灵活性，但学习得到

© 中国图象图形学报版权所有

的社区归属关系可能存在语义不稳定或跨个体对应关系不一致的问题。PGRC-HGN通过在先验功能社区约束下动态调整脑区到社区的归属权重，在保持社区语义一致性的同时兼顾个体差异，从而获得更稳定、更具生物学合理性的层级脑网络表示。

为进一步验证核心模块带来的性能提升是否具有统计学显著性，本文针对完整模型PGRC-HGN与关键消融模型进行了补充显著性检验。具体而言，本文采用10次重复的5折交叉验证，并对完整模型与消融模型在对应划分上的性能差异进行Wilcoxon符号秩检验（显著性水平设为$p<0.05$）。同时，本文报告对应划分上性能差值的95%置信区间，以评估性能提升的稳定性。考虑到STAGC和PG-HGN是本文方法的两个核心组成部分，本文分别选取PCC+PG-HGN和STAGC+GCN作为关键消融对照模型，以验证STAGC和PG-HGN对模型性能提升的贡献。统计结果如表5所示。

表5　PGRC-HGN相较于核心消融模型的统计学显著性

Table 5　Statistical significance of PGRC-HGN compared with Ablation Model on Core Components

方法	指标	95%置信区间/百分点	*P*-值
PCC+PG-HGN	ACC	[0.16,0.90]	5.53e-3*
PCC+PG-HGN	AUC	[0.08,0.80]	1.45e-2*
STAGC+GCN	ACC	[0.49,1.79]	1.03e-3*
STAGC+GCN	AUC	[0.32,1.70]	9.96e-3*

注："*"表示差异具有统计学显著性（p<0.05）。

由表5可知，PGRC-HGN相较于PCC+PG-HGN在ACC和AUC上的性能提升均达到统计显著水平，说明STAGC学习得到的任务相关邻接矩阵相较于PCC预定义邻接矩阵能够带来稳定的性能增益。PGRC-HGN相较于STAGC+GCN在ACC和AUC上的提升同样达到统计显著水平。

综上，消融实验验证了各核心模块的有效性：STAGC学习任务相关的脑区连接结构，关键时间点选择机制使模型聚焦于判别性时刻，PG-HGN结合功能社区先验与动态软划分实现多层异常交互建模。各模块协同使完整模型在所有评价指标上均优于消融模型，且关键模块带来的ACC和AUC提升在统计学检验中达到显著水平，证实了本文方法在ASD辅助诊断任务中的合理性与有效性。

3.5　超参数对模型性能的影响

3.5.1　关键时间点选择比例对模型性能的影响

为分析关键时间点选择比例对模型性能的影响，本文在10%、20%、30%、40%、60%和80%共六种比例设置下分别进行实验，结果如图2所示。

从实验结果来看，模型性能随关键时间点选择比例的变化呈现先升后降的趋势。当选择比例为10%时，筛选条件过于严格，丢失了部分具有判别价值的时序信息，导致分类性能显著下降。当选择比例提升至20%时，模型在信息保留与噪声抑制之间达到最佳平衡，取得最优性能，ACC和AUC分别达到75.27%和79.63%。当比例增至30%和40%时，模型虽仍保留较多判别信息，但冗余时间点逐渐增多，性能略有下降，整体仍维持较高水平。当选择比例进一步增至60%和80%时，关键时间点选择机制的作用被大幅削弱，模型输入趋近于全时序信号，性能因此进一步下降。

综上所述，过低的关键时间点保留比例会导致有效信息丢失，而过高的保留比例则会引入冗余噪声，从而削弱关键点选择机制对判别性时间模式的聚焦能力。

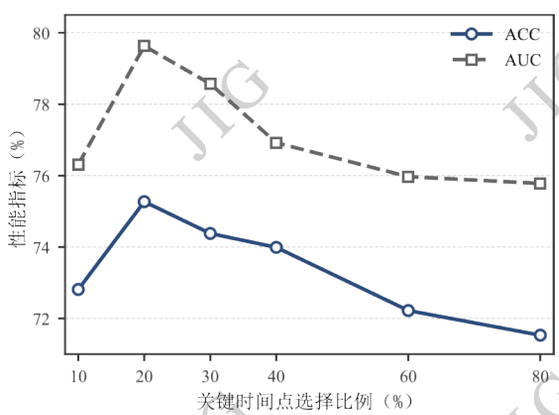


图2　关键时间点选择比例对模型性能的影响

Fig. 2　Effect of the key time-point selection ratio on model performance

3.5.2　先验惩罚系数对社区归属与模型性能的影响

为分析社区层动态归属与Transformer推理中先验惩罚系数γ对社区归属及模型性能的影响，本文设置不同γ取值进行实验。该系数用于调节社区归属学习过程中模型对功能社区先验的依赖程度。γ越大，模型越倾向于将各脑区分配到先验社区中。

© 中国图象图形学报版权所有

除分类指标外，本文进一步利用归属概率矩阵$\boldsymbol{P}$统计分配熵（assignment entropy，AE）、平均最大归属概率（mean maximum assignment probability，MPM）和先验一致率（prior matching rate，PMR）三项指标。其中，AE由每个脑区对各社区归属概率分布的信息熵取平均得到，用于衡量社区分配的不确定性。MPM表示每个脑区在所有社区中最大归属概率的平均值，用于刻画模型对主导社区归属的确定程度。PMR表示模型预测的社区标签与预定义先验社区标签一致的比例，用于衡量分配结果与功能社区先验的一致性。

因此，AE、MPM和PMR分别从归属概率分散程度、主导社区归属确定程度以及主导归属与功能社区先验的一致程度三个角度，评价模型是否在先验语义保持、多社区重叠参与和数据驱动调整之间取得平衡，从而为动态社区归属结果的生物学合理性提供间接的定量支持。实验结果如表6和图3所示。

表6　先验惩罚系数对社区归属的影响

Table 6　Effect of the prior penalty coefficient on community assignment

γ	ACC/%	AUC/%	AE	MPM/%	PMR/%
0	73.20	77.16	1.63	43.85	15.10
3	**75.27**	**79.63**	1.17	64.64	88.81
5	72.41	75.64	0.34	93.60	100

注：加粗数据表示对应分类性能指标的最优结果。

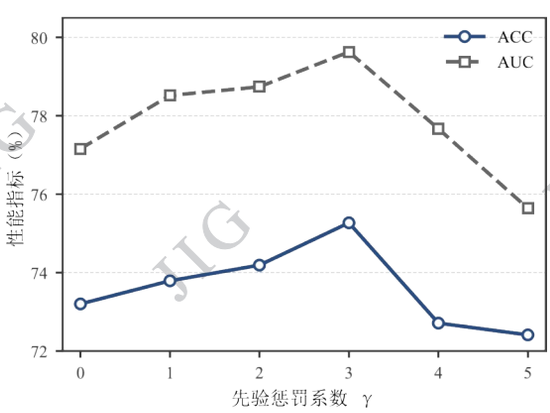


图3　先验惩罚系数对模型性能的影响

Fig. 3　Effect of the prior penalty coefficient on model performance

从图3可以看出，随着γ从0增大到3模型的ACC和AUC整体呈上升趋势，并在γ=3时达到最优，分别为75.27%和79.63%。这说明适度增强先验约束有助于提升模型性能。结合表6可见，当γ=0时，模型未受到显式先验约束，ACC和AUC分别为73.20%和77.16%；此时AE为1.63，MPM和PMR分别为43.85%和15.10%，表明社区归属较为分散，且与社区先验缺少稳定对齐。相比之下，当γ=3时，AE降至1.17，MPM和PMR分别提升至64.64%和88.81%，说明适度先验约束能够降低社区分配的不确定性，使社区归属结果更加稳定，同时仍保留一定的数据驱动调整空间。

当γ继续增大时，模型性能开始下降。尤其在γ=5时，ACC和AUC分别降至72.41%和75.64%，低于γ=3的结果。此时AE进一步下降至0.34，MPM提升至93.60%，PMR达到100.00%，说明社区归属几乎完全服从社区先验，软划分机制趋近于固定硬划分。虽然较大的γ能够提高先验一致性，但过强的先验约束会削弱模型根据个体rs-fMRI数据动态调整社区归属的能力，使其难以刻画个体间功能组织差异及疾病相关的社区重组模式，进而导致分类性能下降。

从社区归属结果的生物学含义来看，动态归属概率矩阵$\boldsymbol{P}$可理解为脑区到功能社区的软归属关系。其意义并不在于完全改变已有功能社区划分，而是在功能社区先验约束下，使脑区归属能够根据个体功能连接特征进行适度调整。结合表6可见，当γ=0时，模型缺乏先验社区标签约束，AE较高且PMR仅为15.10%，说明脑区归属较为分散，学习到的主导社区归属与先验功能社区的对应关系较弱。当γ=5时，PMR达到100.00%，说明脑区归属几乎完全服从预定义社区标签，虽然社区语义最稳定，但软划分机制趋近于固定硬划分，限制了模型依据个体功能连接特征调整社区归属的空间。相比之下，当γ=3时，PMR为88.81%，MPM为64.64%，AE降至1.17，说明模型在大部分脑区上保持了与功能社区先验的一致性，同时没有完全复制先验，仍保留一定的数据驱动调整空间。该结果表明，适度先验约束下的动态社区归属能够在功能社区语义稳定性和个体化灵活性之间取得较好平衡，从而增强社区层表示的生物学合理性。

3.5.3　不同膨胀率组合对模型性能的影响

为验证多尺度时间编码器中膨胀率设置的合理

© 中国图象图形学报版权所有

性,本文在保持卷积块数量、卷积核大小及其他实验设置不变的条件下,选取(1,1,1)、(1,2,4)和(1,4,8)三种具有代表性的膨胀率组合进行对比实验。三种组合分别对应不进行膨胀扩展、适度渐进扩展和较大跨度扩展,用于考察时间感受野扩展程度及时间采样密度对模型性能的影响。实验结果如图4所示。

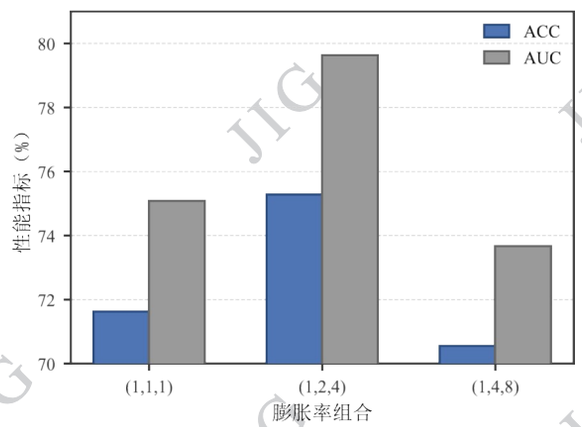


图4 不同膨胀率组合对模型性能的影响

Fig. 4 Effect of different dilation-rate combinations on model performance

从图4可以看出,在所比较的三种膨胀率设置中,(1,2,4)组合取得了最优性能,其ACC和AUC分别达到75.27%和79.63%,均高于(1,1,1)和(1,4,8)组合,说明膨胀率配置会明显影响模型对BOLD信号时序特征的提取效果。

当膨胀率设置为(1,1,1)时,三个卷积块均采用普通因果卷积,时间感受野仅随网络层数逐步扩大,不同层级之间的时间尺度差异相对有限,导致所提取时序特征的互补性不足,难以充分描述BOLD信号中的中程和较长范围动态依赖。采用(1,4,8)组合时,虽然模型能够覆盖更长范围的时间信息,但后续卷积块中较大的膨胀率增大了相邻采样位置之间的间隔,可能削弱对局部连续动态变化的捕捉,进而影响关键时间点筛选及任务相关邻接矩阵的学习。

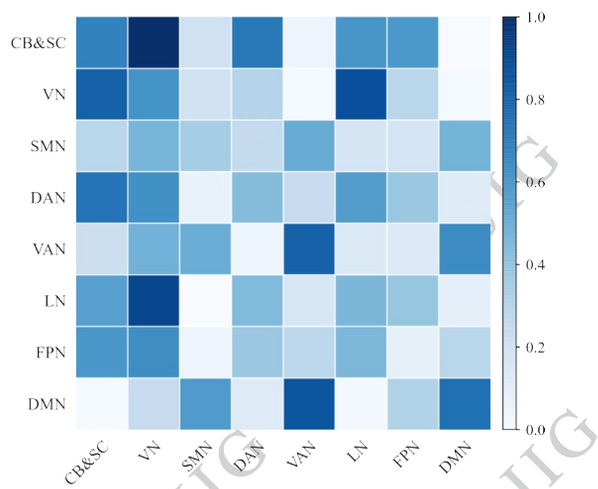
相比之下,(1,2,4)组合通过逐级增大的膨胀率形成由局部到较长时间范围的层次化感受野,在保留局部时间连续性的同时增强了对不同时间范围动态依赖的建模能力。实验结果还表明,模型性能并不会随膨胀率增大而持续提升,适当的时间尺度差异和采样密度对于获得互补的多尺度时序特征更为重要。因此,本文采用(1,2,4)作为多尺度因果时间卷积的默认膨胀率组合。

3.6 可解释性分析

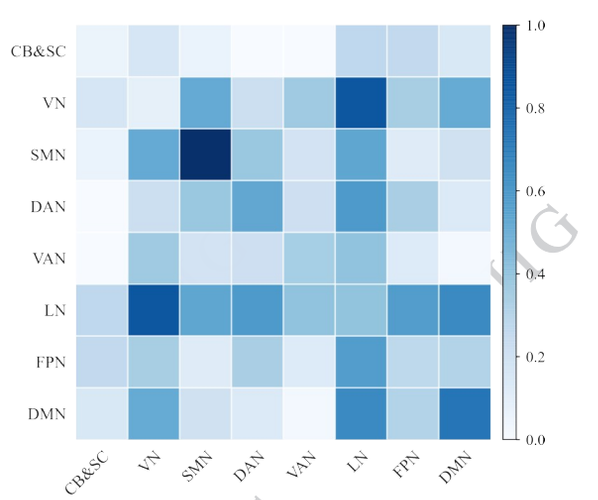
3.6.1 任务相关连接模式的可解释性分析

为考察所提模型在连接模式层面的可解释性,本文在测试集上进一步分析了学习得到的任务相关邻接矩阵的组间差异,并将其与基于皮尔逊相关系数(PCC)构建的预定义邻接矩阵进行对比。

为直观展示社区间交互模式,本文根据动态归属概率矩阵按各脑区的最大归属概率将其分配至唯一社区,随后将脑区级连接按社区聚合。实验结果如图5所示,其中图5(a)与图5(b)分别呈现了任务相关邻接矩阵及预定义邻接矩阵的组间差异分布。



(a) 任务相关邻接矩阵组间差异



(b) 预定义邻接矩阵的组间差异

((a)Inter-group differences in task-driven adjacency matrix; (b) Inter-group differences in predefined adjacency matrix)

图5 组间差异可视化结果

Fig. 5 Visualization results of inter-group differences

© 中国图象图形学报版权所有

分析表明，二者所呈现的差异模式存在明显区别。预定义邻接矩阵所体现的组间差异较为局限，主要集中于特定网络的模块内连接。本文方法学习得到的任务相关邻接矩阵不仅保留了局部差异性表达，更揭示了更为广泛的跨社区异常连接模式。尤其在默认模式网络（DMN）、小脑与皮层下结构（CB&SC）、视觉网络（VN）以及额顶网络（FPN）相关区域中表现出更明显的组间差异。这表明，相比于基于PCC的预定义邻接矩阵，任务相关邻接矩阵能够更充分地呈现ASD相关功能社区之间的差异性连接模式。

为进一步定量分析图5中的组间差异，本文基于bootstrap重采样计算每条边在ASD-HC组间差异方向上的一致性，并筛选一致性不低于0.8的稳定差异连接。本文利用动态归属概率矩阵按各脑区的最大归属概率将其分配至唯一社区，并据此将脑区级稳定差异边聚合为有向社区连接，得到社区层稳定差异连接的统计与排序。其中，稳定边数量表示对应有向社区连接中满足一致性阈值的脑区级边数量，差异总强度表示稳定差异边的组间差异绝对值之和，平均差异强度表示差异总强度与稳定边数量的比值，平均一致性表示稳定差异边在bootstrap重采样中差异方向保持一致的平均比例。统计结果如表7所示。

表7　任务相关邻接矩阵中稳定差异有向社区连接统计（Top 15）

Table 7　Top 15 stable differential directed community connections in the task-related adjacency matrix

排名	有向社区连接	稳定边数量	差异总强度	平均差异强度	平均一致性
1	DMN→DMN	931	28.7044	0.0308	0.9124
2	CB&SC→CB&SC	906	23.1609	0.0256	0.9079
3	CB&SC →VN	732	21.7497	0.0297	0.9229
4	DMN→CB&SC	827	20.8041	0.0252	0.8993
5	CB&SC→DMN	837	20.3580	0.0243	0.8968
6	VN→CB&SC	654	18.7424	0.0287	0.9198
7	DMN →VN	617	16.7335	0.0271	0.9055
8	VN→DMN	607	16.4181	0.0270	0.9051
9	CB&SC→FPN	509	13.7848	0.0271	0.9085
10	DMN→FPN	483	13.5234	0.0280	0.9035
11	FPN→CB&SC	477	13.4706	0.0282	0.9122
12	FPN→DMN	469	13.0155	0.0278	0.9070
13	DMN→VAN	448	12.8610	0.0287	0.9071
14	DMN→SMN	461	11.9810	0.0260	0.9018
15	CB&SC→DAN	439	11.9644	0.0273	0.9089

由表7可见，任务相关邻接矩阵中的稳定差异连接主要集中于DMN、CB&SC、VN、FPN及注意网络相关通路。其中，DMN→DMN排名第1，稳定边数量和差异总强度均较高，提示默认模式网络内部连接差异在模型学习到的判别性连接中占据重要位置。同时，DMN相关跨社区连接也较为明显，主要涉及DMN与CB&SC、VN、FPN、VAN和SMN等功能社区之间的有向连接。已有研究表明，DMN与自我参照、社会认知和内在心理活动等功能密切相关，ASD患者常表现出DMN功能失调及其与其他网络之间连接模式改变（Padmanabhan等，2017）。因此，本文模型识别出的DMN内部及其与其他功能社区之间的稳定差异连接，与ASD神经影像学研究中关于默认模式网络异常和跨网络连通性改变的发现具有一致性。

此外，表7中CB&SC等相关跨社区连接也位于前列，说明任务相关邻接矩阵所揭示的稳定差异连接并不局限于单一功能社区，而是涉及多个功能系

© 中国图象图形学报版权所有

统之间的连接变化。结合图5可视化结果可以看出,本文方法学习得到的任务相关邻接矩阵在社区层面呈现出更明显的跨社区差异模式,进一步补充了仅依赖热图观察所得出的定性结论。

综上,本文方法不仅提升了诊断性能,也提供了具有一定可解释性的社区层差异表征,从而增强了模型结果的可信度。

3.6.2 关键时间点选择的可解释性分析

为考察STAGC中关键时间点选择机制的可解释性,本文汇总五折交叉验证中各折测试集的关键时间点选择结果,分别统计ASD组和HC组受试者在各时间点被选为关键时间点的频率,并计算两组选择频率之差。差值为正表示ASD组在该时间点具有更高的关键时间点选择频率,差值为负则表示HC组具有更高的选择频率。

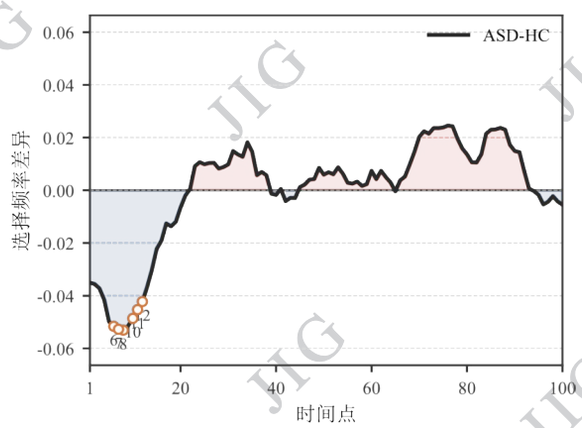


图6 ASD组与HC组关键时间点选择频率差异

Fig. 6 Difference in key time-point selection frequency between ASD and HC groups

图6展示了ASD组与HC组关键时间点选择频率的平均差异(ASD-HC),其中红色区域表示ASD组选择频率较高,蓝色区域表示HC组选择频率较高,黄色标记点表示选择频率差异绝对值较大的时间点。实验结果表明,第5—12个时间点附近的选择频率差异主要为负,说明HC组在该时间区间具有相对较高的选择频率;第25—38个时间点和第70—90个时间点附近的差异主要为正,说明ASD组在这些时间区间表现出相对较高的选择倾向。

上述选择频率差异在若干连续时间区间内呈现一致的变化方向,表明ASD组与HC组的关键时间点选择具有一定的类别相关分布特征。不同时间区间内差异方向的变化进一步体现了模型对多个时间区间进行差异化关注的能力,说明关键时间点选择能够根据受试者的时序特征形成相应的选择倾向。该结果从诊断类别角度为STAGC的时间选择机制提供了解释,表明模型能够聚焦与诊断类别相关的时序信息,并为后续任务相关邻接矩阵学习提供更具区分度的时序特征。

4 结 论

本文提出了一个面向自闭症谱系障碍辅助诊断的先验引导下脑区-社区分层图网络,其中关键时间感知图构造器能够从rs-fMRI数据中识别与ASD诊断相关的关键时间点,并基于这些判别性时间片段学习脑区间的任务相关连接模式。先验引导分层图网络则在功能社区先验约束下动态建模脑区到社区的归属关系,并实现脑区层与社区层的联合表示学习。在ABIDE I数据集上的实验结果表明,相较于综合性能最优的已有方法DHGFormer,本文提出的PGRC-HGN在ACC、AUC、SEN、SPE上分别提升2.76、2.88、3.47、3.28个百分点。

尽管本文方法取得了较好的分类性能,但仍存在若干不足。首先,当前实验仅在ABIDE I数据集上进行验证。虽然ABIDE I包含多个采集站点,能够在一定程度上反映不同扫描设备、采集参数及受试者构成所带来的数据异质性,但本文采用的五折交叉验证未显式引入类别—站点联合分层约束,因此当前实验结果尚不足以全面说明模型在不同数据条件和应用任务下的泛化能力。后续研究将进一步开展类别—站点联合分层划分及跨站点训练与测试,以更加全面地评价模型在多中心数据上的稳定性;同时,将参考多数据集脑网络方法的实验设置,探索模型在阿尔茨海默病神经影像学计划(Alzheimer's Disease Neuroimaging Initiative,ADNI)、青少年大脑认知发展研究(Adolescent Brain Cognitive Development,ABCD)等公开脑影像数据集上的适配,将研究范围由ASD辅助诊断逐步扩展至更广泛的人群脑网络分析和脑疾病辅助诊断任务。其次,本文基于CC200脑图谱进行脑区划分,功能社区先验也依赖于该图谱对应的社区划分结果,不同脑图谱及功能社区先验对模型性能的影响仍有待进一步研究。最后,本文采用固定比例筛选关键时间点,尚未充分考虑不同受试者时序动态特征的个体差

© 中国图象图形学报版权所有

异。未来将进一步探索多图谱信息融合和自适应关键时间点选择机制，以提高模型在跨站点、跨任务和个体化诊断场景下的适用性与稳健性。

参考文献(References)

Bannadabhavi A, Lee S, Deng W, Ying R and Li X. 2023. Community-aware transformer for autism prediction in fMRI connectome//Medical Image Computing and Computer Assisted Intervention – MICCAI 2023. Lecture Notes in Computer Science, 14227: 287-297 [DOI: 10.1007/978-3-031-43993-3_28]

Bertolero M A, Yeo B T T and D'Esposito M. 2015. The modular and integrative functional architecture of the human brain. Proceedings of the National Academy of Sciences, 112(49): E6798-E6807 [DOI: 10.1073/pnas.1510619112]

Craddock C, Benhajali Y, Chu C, Chouinard F, Evans A, Jakab A, et al. 2013. The Neuro Bureau Preprocessing Initiative: open sharing of preprocessed neuroimaging data and derivatives//Frontiers in Neuroinformatics. Conference Abstract: Neuroinformatics 2013. Stockholm, Sweden, 27-29 August 2013 [DOI: 10.3389/conf.fninf.2013.09.00041]

Damaraju E, Allen E A, Belger A, Ford J M, McEwen S, Mathalon D H, et al. 2014. Dynamic functional connectivity analysis reveals transient states of dysconnectivity in schizophrenia. NeuroImage: Clinical, 5: 298-308 [DOI: 10.1016/j.nicl.2014.07.003]

Hull J V, Dokovna L B, Jacokes Z J, Torgerson C M, Irimia A and Van Horn J D. 2017. Resting-state functional connectivity in autism spectrum disorders: a review. Frontiers in Psychiatry, 7: 205 [DOI: 10.3389/fpsyt.2016.00205]

Kan X, Cui H, Lukemire J, Guo Y and Yang C. 2022a. FBNetGen: task-aware GNN-based fMRI analysis via functional brain network generation//Proceedings of the 5th International Conference on Medical Imaging with Deep Learning. Proceedings of Machine Learning Research, 172: 618-637.

Kan X, Dai W, Cui H, Zhang Z, Guo Y and Yang C. 2022b. Brain network transformer//Advances in Neural Information Processing Systems, 35: 25586-25599.

Karten A and Hirsch J. 2015. Brief report: anomalous neural deactivations and functional connectivity during receptive language in autism spectrum disorder: a functional MRI study. Journal of Autism and Developmental Disorders, 45(6): 1905-1914 [DOI: 10.1007/s10803-014-2344-y]

Khosla M, Jamison K, Kuceyeski A and Sabuncu M R. 2019. Ensemble learning with 3D convolutional neural networks for functional connectome-based prediction. NeuroImage, 199: 651-662 [DOI: 10.1016/j.neuroimage.2019.06.012]

Kunda M, Zhou S, Gong G and Lu H. 2023. Improving multi-site autism classification via site-dependence minimization and second-order functional connectivity. IEEE Transactions on Medical Imaging, 42(1): 55-65 [DOI: 10.1109/TMI.2022.3203899]

Lei M Q, Han X M, Li S Q and Gao Y. 2026. Brain structure-function coupling hypergraph neural network. Journal of Image and Graphics, 31(7): 2526-2537 (雷孟奇, 韩向敏, 李思奇和高跃. 2026. 脑结构—功能耦合超图神经网络. 中国图象图形学报, 31(7): 2526-2537) [DOI: 10.11834/jig.250535]

Li X, Zhou Y, Dvornek N, Zhang M, Gao S, Zhuang J, et al. 2021. BrainGNN: interpretable brain graph neural network for fMRI analysis. Medical Image Analysis, 74: 102233 [DOI: 10.1016/j.media.2021.102233]

Long D, Zhang M D, Ying R H, Chen F N, Shao L, Xie Q, et al. 2024. Intelligent diagnosis of depression by integrating genetic algorithm and graph neural network. Journal of Image and Graphics, 29(11): 3476-3486 (龙丹, 章梦达, 应仁辉, 陈丰农, 邵岚, 谢璩, 等. 2024. 融合遗传算法和图神经网络的抑郁症智能诊断. 中国图象图形学报, 29(11): 3476-3486) [DOI: 10.11834/jig.230337]

Lord C, Brugha T S, Charman T, Cusack J, Dumas G, Frazier T, et al. 2020. Autism spectrum disorder. Nature Reviews Disease Primers, 6(1): 5 [DOI: 10.1038/s41572-019-0138-4]

Luo X, Wu J, Yang J, Xue S, Beheshti A, Sheng Q Z, et al. 2024. Graph neural networks for brain graph learning: a survey [EB/OL]. (2024-06-01) [2026-10-15]. https://arxiv.org/abs/2406.02594 [DOI: 10.48550/arXiv.2406.02594]

Mahmood U, Fu Z, Calhoun V D and Plis S. 2021. A deep learning model for data-driven discovery of functional connectivity. Algorithms, 14(3): 75 [DOI: 10.3390/a14030075]

Meunier D, Lambiotte R and Bullmore E T. 2010. Modular and hierarchically modular organization of brain networks. Frontiers in Neuroscience, 4: 200 [DOI: 10.3389/fnins.2010.00200]

Padmanabhan A, Lynch C J, Schaer M and Menon V. 2017. The default mode network in autism. Biological Psychiatry: Cognitive Neuroscience and Neuroimaging, 2(6): 476-486 [DOI: 10.1016/j.bpsc.2017.04.004]

Shehzad A, Yu S, Zhang D, Abid S, Cheng X, Zhou J, et al. 2024. BrainGT: multifunctional brain graph transformer for brain disorder diagnosis [EB/OL]. (2024-08-31) [2026-10-15]. https://www.medrxiv.org/content/10.1101/2024.08.30.24312819v1 [DOI: 10.1101/2024.08.30.24312819]

Sporns O and Betzel R F. 2016. Modular brain networks. Annual Review of Psychology, 67(1): 613-640 [DOI: 10.1146/annurev-psych-122414-033634]

Thapaliya B, Miller R, Chen J, Wang Y P, Akbas E, Sapkota R, et al. 2025. DSAM: a deep learning framework for analyzing temporal and spatial dynamics in brain networks. Medical Image Analysis, 101: 103462 [DOI: 10.1016/j.media.2025.103462]

Tong W, Li Y X, Zhao X Y, Chen Q Q, Gao Y B and Li P. 2023. fMRI-based brain disease diagnosis: a graph network approach. IEEE

© 中国图象图形学报版权所有

Transactions on Medical Robotics and Bionics, 5(2): 312-322[DOI: 10.1109/TMRB.2023.3270481]

Wang X, Ren Y S and Zhang W S. 2017. Multi-task fused Lasso method for constructing dynamic functional brain network of resting-state fMRI. Journal of Image and Graphics, 22(7): 978-987 (王鑫, 任燕双, 张文生. 2017. 动态功能脑网络模型的多任务融合Lasso方法. 中国图象图形学报, 22(7): 978-987)[DOI: 10.11834/jig.170055]

Wang Y, Long H, Bo T and Zheng J. 2024. Residual graph transformer for autism spectrum disorder prediction. Computer Methods and Programs in Biomedicine, 247: 108065[DOI: 10.1016/j.cmpb.2024.108065]

Wen G, Cao P, Bao H, Yang W, Zheng T and Zaiane O. 2022. MVS-GCN: a prior brain structure learning-guided multi-view graph convolution network for autism spectrum disorder diagnosis. Computers in Biology and Medicine, 142: 105239[DOI: 10.1016/j.compbiomed.2022.105239]

Xue R, Hu H, Zhang Z, Han X, Wang J, Gao Y, et al. 2025. DHG-Former: dynamic hierarchical graph transformer for disorder brain disease diagnosis//Medical Image Computing and Computer Assisted Intervention – MICCAI 2025. Lecture Notes in Computer Science, 15971: 268-278[DOI: 10.1007/978-3-032-05162-2_26]

Yeo B T T, Krienen F M, Sepulcre J, Sabuncu M R, Lashkari D, Hollinshead M, et al. 2011. The organization of the human cerebral cortex estimated by intrinsic functional connectivity. Journal of Neurophysiology, 106(3): 1125-1165[DOI: 10.1152/jn.00338.2011]

Yin W, Li L and Wu F X. 2021. A graph attention neural network for diagnosing ASD with fMRI data//Proceedings of the 2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Houston: IEEE: 1131-1136[DOI: 10.1109/BIBM52615.2021.9669849]

Zhu Q, Yang J, Wang S, Zhang D and Zhang Z. 2023. Multi-modal non-euclidean brain network analysis with community detection and convolutional autoencoder. IEEE Transactions on Emerging Topics in Computational Intelligence, 7(2): 436-446[DOI: 10.1109/TETCI.2022.3171855]

Zhu Y, Xu W, Zhang J, Du Y, Zhang J, Liu Q, et al. 2021. A survey on graph structure learning: progress and opportunities[EB/OL]. (2021-03-04)[2026-10-15]. https://arxiv.org/abs/2103.03036[DOI: 10.48550/arXiv.2103.03036]

作者简介

彭文, 男, 副教授, 主要研究方向为医学影像分析与人工智能。E-mail: pengwen@ncepu.edu.cn

崔馨悦, 女, 硕士研究生, 主要研究方向为医学图像处理与人工智能。E-mail: 120242227085@ncepu.edu.cn

程淑梦, 女, 硕士研究生, 主要研究方向为医学图像处理与人工智能。E-mail: 16691517939@163.com

© 中国图象图形学报版权所有