

HMGNet: 基于层次化多维特征图卷积网络的孤独症谱系障碍诊断

李祖达 于 淼 陈尊凡 王 哲 杨啸林 徐 涛

(中国医学科学院基础医学研究所 北京 100005)

〔摘要〕 **目的/意义** 探讨基于静息态功能磁共振成像的脑功能连接在预测孤独症谱系障碍中的应用潜力,旨在解决神经精神疾病诊断中生物标志物难以确定的问题。**方法/过程** 提出层次化多维特征图卷积网络模型 HMGNet,通过设计时间序列编码器提取具有长期依赖性的时序相关特征,并强化功能连接矩阵特征建模。引入图注意力机制实现动态权重调整以识别关键脑区间的互动,利用残差学习构建具有更深层级的图神经网络架构,提升模型对复杂脑功能连接的建模性能。**结果/结论** 实证结果显示,在两种类型的 ABIDE 数据集上,HMGNet 实现了 74.4% 的准确率,优于多数方法。所揭示的生物标志物与现有权威医学知识高度吻合,为孤独症谱系障碍的临床诊断提供了可行的新路径。

〔关键词〕 功能磁共振成像;孤独症谱系障碍诊断;注意力模型

〔中图分类号〕 R-058 **〔文献标识码〕** A **〔DOI〕** 10.3969/j.issn.1673-6036.2025.09.002

HMGNet: Diagnosis of Autism Spectrum Disorder Based on Hierarchical Multi-dimensional Graph Convolutional Network

Li Zuda, Yu Miao, CHEN Zunfan, WANG Zhe, YANG Xiaolin, XU Tao

Institute of Basic Medical Sciences, Chinese Academy of Medical Sciences, Beijing 100005, China

〔Abstract〕 **Purpose/Significance** To explore the potential of rs-fMRI-based functional connectivity (FC) as a predictive biomarker for autism spectrum disorder (ASD), so as to address the challenge of identifying reliable biological markers in the diagnosis of neuropsychiatric disorders. **Method/Process** A hierarchical multi-dimensional graph convolutional network (HMGNet) is proposed, which incorporates a time-series encoder to extract temporal features with long-term dependencies and enhance FC matrix modeling. The model integrates a graph attention mechanism to dynamically adjust edge weights, enabling the identification of critical inter-regional brain interactions. Additionally, residual learning is employed to construct a deeper graph neural network architecture, thereby improving the modeling performance for complex brain functional connectivity. **Result/Conclusion** Empirical results demonstrate that HMGNet achieves a classification accuracy of 74.4% on two variants of the ABIDE dataset, outperforming most existing approaches. The neuroimaging biomarkers identified by the model show strong concordance with established medical knowledge, offering a promising and clinically viable pathway for the diagnosis of ASD.

〔Keywords〕 functional magnetic resonance imaging (fMRI); diagnosis of autism spectrum disorder (ASD); attention model

〔修回日期〕 2025-08-15

〔作者简介〕 李祖达,硕士研究生;通信作者:杨啸林,徐涛。

〔基金项目〕 中国医学科学院医学与健康科技创新工程项目(项目编号:2021-I2M-1-057);北京协和医学院研究生课程信息化项目(项目编号:2021YXX009)。

1 引言

孤独症谱系障碍 (autism spectrum disorder, ASD) 是一种复杂的神经发育障碍, 临床诊断依赖主观行为评估, 急需客观生物标志物以提升诊断准确性^[1]。功能磁共振成像 (functional magnetic resonance imaging, fMRI) 通过血氧水平依赖 (blood oxygen level dependent, BOLD) 信号揭示大脑功能连接 (functional connectivity, FC) 动态, 为 ASD 神经机制研究提供了重要工具^[2]。现有研究多基于皮尔逊相关 (pearson correlation, PC) 构建 FC 矩阵, 并结合机器学习进行分类, 但其线性假设难以捕捉 BOLD 信号的非线性动态特性, 且传统模型在复杂脑网络建模与可解释性方面存在局限。深度学习和图神经网络 (graph convolutional network, GCN) 已初步应用于 ASD 识别, 但仍面临动态特征建模不足、拓扑结构表达不充分、训练稳定性差及生物标志物解释性弱等挑战。

为此, 本文提出层次化多维特征图卷积网络 (hierarchical multi-dimensional graph convolutional network, HMGNet), 旨在从静息态 fMRI 数据中高效识别 ASD 相关功能标记。主要贡献包括: 设计时间序列编码器 (time-series encoder, TE), 深入挖掘 BOLD 信号的动态非线性特征; 提出特征强化 FC

建模机制, 增强对脑区间隐含拓扑关系的表达能力; 融合图注意力 (graph attention network, GAT) 与残差学习 (residual network, ResNet), 实现连接权重自适应学习, 并缓解梯度消失, 提升深层模型判别性能; 结合可视化与医学验证, 识别出下小脑、上小脑及蚓部等关键异常区域, 结果与现有神经科学发现高度一致。本研究为 ASD 的精准诊断提供了可解释的深度神经网络框架与潜在神经影像标记。

2 方法

2.1 模型结构

HMGNet 模型包含 3 个核心模块: 时间序列编码器、特征强化的 FC 矩阵生成和残差图注意力卷积, 见图 1。时间序列编码器通过多头注意力机制提取 BOLD 信号的时间序列特征, 捕捉长期依赖性。特征强化的 FC 矩阵生成通过非线性变换和元素间乘积, 增强脑区间的交互特征。残差图注意力卷积结合图注意力机制和残差学习, 能够动态调整脑区间的连接权重, 并有效缓解深层网络训练中的梯度消失问题。这些模块的结合使 HMGNet 能够更准确地识别 ASD 相关的脑网络特征。最后, 将 FC 矩阵和节点特征输入消息扩散和感兴趣区域 (region of interest, ROI) 筛选流程, 通过多层感知机 (multi-layer perceptron, MLP) 完成 ASD 诊断。




图 1 HMGNet 模型结构

2.2 时间序列编码器

传统方法如 ICA 和 PCA^[3] 忽略 BOLD 信号的时间顺序且局限于线性建模, 难以支持图神经网络。近年来, Transformer 架构凭借其强大的非线性特征学习能力和多头注意力机制, 在捕捉长距离依赖方面表现出色。本研究设计 TE, 用于挖掘 BOLD 信号序列的复杂动态特性。TE 不仅继承了多头注意力的

并行处理优势, 还引入了特征增强注意力 (feature augmented attention, FAA), 以增强对关键脑区连接的识别能力。

首先通过多头自注意力并行处理输入序列, 对于每个头 h , 定义查询 $Q^{(h)}$ 、键 $K^{(h)}$ 和值 $V^{(h)}$ 。其中, $W^{Q(h)}$ 、 $W^{K(h)}$ 和 $W^{V(h)}$ 是可学习的线性变换权重矩阵。

$$Q^{(h)} = X W^{Q(h)} \quad (1)$$

$$K^{(h)} = X W^{K(h)} \quad (2)$$

$$V^{(h)} = X W^{V(h)} \quad (3)$$

随后,通过缩放点积注意力机制计算该头的输出,其中 $K^{(h)T}$ 为 $K^{(h)}$ 的转置矩阵, d_k 用于数值稳定性缩放。

$$A^{(h)} = \text{softmax}\left(\frac{Q^{(h)} K^{(h)T}}{\sqrt{d_k}}\right) V^{(h)} \quad (4)$$

然后,将所有头的输出进行拼接和线性变换,以生成最终的多头注意力输出。

$$A^{(mha)} = W^O \cdot \text{Concatenate}(A^{(1)}, \dots, A^{(h)}) \quad (5)$$

为进一步增强特征表示能力,在每头输出上引入特征增强操作,再进行一次独立融合。其中, $W^{O'}$ 是新的可学习参数,而 *Enhance* 函数表示特征增强。

$$A^{(faa)} = W^{O'} \cdot \text{Concatenate}(\text{Enhance}(A^{(1)}), \dots, \text{Enhance}(A^{(h)})) \quad (6)$$

最终,编码器的输出为两者加权组合。这里, λ 是一个可学习的缩放参数,用于平衡两种输出的贡献。

$$A^{(out)} = A^{(mha)} + \lambda \cdot A^{(faa)} \quad (7)$$

2.3 特征强化的 FC 矩阵生成

FC 矩阵在脑网络建模中具有核心作用,用于刻画脑区之间的成对交互关系。传统方法通常基于 ICA 或 PCA 提取特征后计算皮尔逊相关系数,但该方法存在两个主要缺陷:一是生成的矩阵包含负权重,GCN 不兼容;二是难以准确建模大脑复杂的非线性连接模式^[4]。

为此,提出一种端到端可学习的 FC 构建机制。该方法基于时间序列编码器输出的特征矩阵 $X \in R^{n \times d}$, 其中 n 为脑区数量, d 为特征维度。首先,通过幂次变换增强特征的非线性表示。其中, i, j 分别表示第 i 个和第 j 个脑区, p 是预设参数,用于放大关键区域间的相互作用。

$$X_{ij}^p = (X_{ij})^p \quad (8)$$

其次计算特征乘积,构建相似性矩阵 M 。该乘积操作进一步增强特征强化效果,使脑区间的交互更加显著,其中 k 遍历所有特征维度 ($k = 1, 2, \dots, d$)。

$$M_{ij} = \sum_{k=1}^d X_{ik}^p \cdot X_{jk}^p \quad (9)$$

最后,对每一行应用 *Softmax* 函数,将 M 映射

为概率形式的 FC 矩阵 A , 其元素值介于 0 和 1 之间,满足图神经网络输入要求。

$$A_{ij} = \text{Softmax}(M_{ij}) = \frac{e^{M_{ij}}}{\sum_{k=1}^n e^{M_{ik}}} \quad (10)$$

该方法增强了模型对大脑网络复杂性的建模能力及解释性,能够识别出与 ASD 相关的重要脑区连接。

2.4 残差图注意力卷积

给定邻接矩阵 $A \in R^{n \times n}$ 和节点特征矩阵 $O \in R^{n \times d}$, 构建融合图注意力机制与残差学习的图神经网络,用于提取并增强大脑功能网络中的高级语义特征。

2.4.1 图卷积 图卷积层通过邻域聚合更新节点。 A 是 $n \times n$ 的邻接矩阵,描述脑区间的连接强度; x_{k-1} 是前一层的节点特征; w_k 是可学习的权重矩阵;而 x_k 是经过图卷积后的节点特征。该过程使模型能够逐层捕捉局部连接模式。

$$x_k = \text{ReLU}(A_{x_{k-1}} w_k) \quad (11)$$

2.4.2 图注意力 为克服传统图卷积中固定连接权重的局限性,引入图注意力机制。 Wh 是经过线性变换的节点特征; a 是可学习的注意力参数; *Attention* 函数负责生成基于这些参数的加权节点更新。该机制增强了模型对关键脑区连接的关注能力,提高了对 ASD 相关异常的敏感性。

$$h' = \text{Attention}(Wh, a) \quad (12)$$

2.4.3 残差学习 为进一步缓解深度模型训练中的梯度消失问题^[5],在每层图卷积中引入残差学习模块。 x_k 是第 k 层的输出, A 是邻接矩阵, $\tau(x_{k-1})$ 是经过归一化处理的第 $k-1$ 层的特征, W_k 是第 k 层的权重矩阵。

$$x_k = \sigma(A\sigma(\tau(x_{k-1}))W_k) + x_{k-1} \quad (13)$$

2.5 损失函数

本任务中的基本预测损失是交叉熵项:

$$L_{ce} = -\frac{1}{b} \sum_{m=1}^b \sum_{c=1}^C y_{m,c} \log(\hat{y}_{m,c}) \quad (14)$$

其中, $y_{m,c}$ 表示标签, $\hat{y}_{m,c}$ 是模型输出, b 和 C 分别表示实例数量和类别数量。为进一步提升模型的

判别性与泛化能力，引入 3 项正则化损失。

2.5.1 组内损失 基于临床观察中同类个体功能连接模式趋于一致的假设，引入组内损失。给定类别 $c \in C$ ，设其对应的样本集合为 $S_c = \{i | Y_i, c = 1\}$ ，该组的 FC 均值为 μ_c ，方差为 σ_c^2 ，组内损失定义如下。通过最小化类内方差，该损失增强了模型对共享特征的捕捉能力。

$$L_{intra} = \sum_{c \in C} \sum_{i \in S_c} \|A_i - \mu_c\|^2 = \sum_{c \in C} \frac{|S_c|}{|S_c|} \sigma_c^2 \quad (15)$$

2.5.2 组间损失 认知科学研究表明，不同性别的功能性大脑网络之间存在显著差异^[6]。因此，引入组间损失，旨在最大化不同类别 FC 矩阵之间的差异。对于任意两个类别 a 和 b ，组间损失通过扩大均值 μ_a 和 μ_b 计算：

$$L_{inter} = - \sum_{a, b \in C} \|\mu_a - \mu_b\|^2 \quad (16)$$

2.5.3 稀疏性损失 为抑制非特异性高幅连接、突出关键通路，引入 FC 矩阵均值正则：

$$L_{sparsity} = \frac{1}{b} \sum_{m=1}^b \frac{1}{v^2} \sum_{i=1}^v \sum_{j=1}^v A_{ij} = \frac{1}{b} \sum_{m=1}^b \mu_{m,A} \quad (17)$$

综上，最终损失函数组装如下。 α, β, γ 是平衡每个正则化器贡献的超参数。

$$L = L_{ce} + \alpha L_{intra} + \beta L_{inter} + \gamma L_{sparsity} \quad (18)$$

3 实验

3.1 数据

孤独症脑成像交换数据库（autism brain imaging data exchange, ABIDE）整合了来自全球 17 个研究中心的静息态功能磁共振成像（resting-state functional magnetic resonance imaging, rs-fMRI）数据。本研究纳入 ABIDE 中所有可获取的有效 rs-fMRI 数据集共 1 112 例，包括 539 名 ASD 患者和 573 名正常对照（negative control, NC）个体。

3.2 数据预处理

使用来自 ABIDE 的预处理连接组项目数据。其预处理步骤包括体素强度归一化、运动校正、切片时间校正等。随后提取每个受试者在特定 ROI 内的平均时间序列信号。由于数据来源多样，各中心采

集的时间点长度不一。为统一输入格式，保留每个样本前 100 个时间点，排除时间点不足 100 的样本。最终筛选后获得 1 009 个带有完整表型信息的样本，其中包括 516 名 ASD 患者和 493 名 NC 个体。在构建脑网络时，采用基于非重叠 ROI 的种子像素方法，使用 7 个不同解剖图谱定义脑区。实验主要采用 Craddock 200（CC200）和自动解剖学标签（automated anatomical labeling, AAL）图谱，分别将大脑划分为 200 和 116 个功能区域，以评估模型在不同尺度下的泛化能力。

3.3 实验设置

在配备 12GB GPU 内存、NVIDIA GeForce RTX 3060 显卡的设备上进行实验。软件平台采用 Python 环境中的 Pytorch2.2。采用 5 折交叉验证策略评估所有竞争方法的性能，整个数据集被平均分成 5 份，每次使用其中 1 份作为验证集，其余 4 份作为训练集，该过程重复 5 次，每次轮换验证集，没有独立的测试集，最终的性能指标是基于 5 次验证结果的平均值。实验中所有预设超参数，见表 1。使用灵敏度、特异度、受试者工作特征（receiver operating characteristic, ROC）曲线下面积（area under curve, AUC）和准确度作为评价指标。

表 1 超参数设置

超参数	值
Epoch	500
Batch size	32
Optimizer	Adam
Learning rate	0.000 1
Dropout rate	0.5
Step size	200
Weight decay	0.000 1
Pool ratio	0.7
α	0.01
β	0.01
γ	0.001

3.4 方法对比

为全面评估所提方法的有效性，对比两类主流

模型：传统机器学习与深度学习模型。其中，传统机器学习模型包括 Auto – ASD – Network（AAN）^[7]及随机森林（random forest，RF）^[8]。均以向量形式的 FC 矩阵作为输入，其维度为 n ，即 ROI 总数。深度学习模型方面，根据是否基于 GCN 进行分类评估。非 GCN 模型包括 DiagNet^[9]、BoIT^[10]、DAE^[6]、CA – CNN^[11]、AD – CNN^[12]、MC – NFE^[13]和 MDANN^[14]模型。GCN 类模型则涵盖 sGCN^[15]、MVS – GCN^[8]、BrainGNN^[16]和 FBNETGEN^[17]。

3.5 结果

不同模型在 AAL 和 CC200 图谱上的性能对比，见表 2—表 3。HMGNet 在所有实验中采用统一超参数设置，以评估其对不同脑区划分方式的适应性。结果显示，HMGNet 在多数评估指标上均优于对比方法，展现出优越的泛化能力。值得注意的是，基于 CC200 图谱的性能普遍优于基于 AAL 图谱的结果。这一现象与预期一致：CC200 包含 200 个脑区，显著多于 AAL 的 116 个区域，能够提供更细粒度的大脑功能描述，有助于提升模型判别能力。

表 2 各模型在 AAL 图谱上的预测性能比较（%）

模型类型	模型	灵敏度	特异度	AUC	准确度
传统机器	AAN ^[7]	68.5	64.7	66.3	66.2
学习模型	RF ^[8]	70.2	59.6	60.9	64.6
非 GCN 模型	DiagNet ^[9]	62.8	64.9	65.2	68.8
	BoIT ^[10]	67.9	69.6	70.1	69.1
	DAE ^[6]	69.5	68.2	68.9	65.3
	CA – CNN ^[11]	70.8	69.1	69.5	70.8
	AD – CNN ^[12]	63.1	63.9	66.2	66.9
	MC – NFE ^[13]	70.9	64.5	69.1	69.9
	MDANN ^[14]	65.6	67.2	66.3	67.0
	sGCN ^[15]	64.5	60.5	62.9	63.7
GCN 类模型	MVS – GCN ^[8]	67.8	68.9	68.3	70.0
	BrainGNN ^[16]	65.5	62.3	63.4	68.5
	FBNETGEN ^[17]	71.5	72.5	71.8	72.6
	HMGNet	73.8	75.0	76.9	74.4

表 3 各模型在 CC200 图谱上的预测性能比较（%）

模型类型	模型	灵敏度	特异度	AUC	准确度
传统机器	AAN ^[7]	65.5	66.2	67.9	68.3
学习模型	RF ^[8]	62.8	61.5	63.2	64.8
非 GCN 模型	DiagNet ^[9]	69.1	73.2	73.5	71.2
	BoIT ^[10]	73.5	72.9	72.2	70.9
	DAE ^[6]	74.6	55.3	60.8	68.5
	CA – CNN ^[11]	68.6	71.9	69.8	69.5
	AD – CNN ^[12]	65.3	68.9	67.7	68.7
	MC – NFE ^[13]	70.7	71.2	70.6	72.5
	MDANN ^[14]	67.6	68.8	67.9	70.0
	sGCN ^[15]	66.8	63.2	64.2	68.3
GCN 类模型	MVS – GCN ^[8]	71.2	68.3	70.4	70.4
	BrainGNN ^[16]	65.4	65.8	66.6	64.9
	FBNETGEN ^[17]	74.8	74.3	76.8	74.7
	HMGNet	77.8	76.9	79.4	77.3

在基于 GCN 的方法中，FBNETGEN 在各项指标上均排名第 2 位。其采用门控循环单元（gated recurrent unit，GRU）作为时间序列编码器，但由于递归特性易受梯度爆炸影响，性能逊色于 HMGNet，在 AAL 和 CC200 图谱上的准确度差距分别为 1.8 和 2.6 个百分点。尽管 BrainGNN 和 MVS – GCN 也利用图网络模拟大脑结构，但因缺乏特征升华机制，表现欠佳。

在非 GCN 模型中，DiagNet 多数情况下表现最佳，甚至优于多数基于 GCN 的方法（如 BrainGNN 和 sGCN），再次表明后者在模拟真实大脑结构方面的局限性。在 CC200 图谱上，DAE 虽在灵敏度方面领先，但在特异度方面表现最差，显示出模型稳定性存在问题。这些结果说明建模应充分考虑空间位置信息和显著性。

特别需要指出的是，以 CC200 图谱为例，HMGNet 相比其他代表性模型（如 AAN、DiagNet 和 FBNETGEN）的准确度实现了平均 9%、6.1% 和 2.6% 的性能提升。最终 HMGNet 达到了准确度 77.3% 和 AUC 79.4% 的优异成绩，展示了其在 ASD 诊断中的前沿水平。

3.6 可解释性分析

3.6.1 FC 矩阵可视化对比 FC 矩阵对模型性能具有关键影响，其可解释性在临床诊断中同样至关重要。HMGNet 生成的 FC 热图与皮尔逊相关在结构上有一定相似性，但其在多个感应区域表现出显著增强的连接响应。相比之下，皮尔逊相关产生的热图分布更为均匀，难以突出对 ASD 预测具有决定性的 ROI。此外，较弱的连接强度可能削弱后续信息传播的有效性，并放大噪声连接的影响。这与其线性建模方式难以捕捉复杂非线性特征密切相关。

为进一步探索潜在的 ASD 临床预测脑区，分别在 ASD 和 NC 样本上可视化 FC 热图，见图 2。在 ASD 样本中显著增强的部分功能连接在 NC 样本中明显减弱。结合 AAL 图谱定位，这些区域主要集中在下小脑、上小脑及蚓部，提示其可能在 ASD 的神经机制中扮演重要角色，值得临床进一步关注。




图 2 FC 矩阵热图

注：a 为 HMGNet 得出的 ASD 的 FC 矩阵；b 为 HMGNet 得出的 NC 的 FC 矩阵；c 为皮尔逊相关得出的 ASD 的 FC 矩阵；d 为皮尔逊相关得出的 NC 的 FC 矩阵。

3.6.2 医学文献一致性验证 HMGNet 发现的关键脑区与既有研究具有一定的一致性。蚓部^[18]在孤独症患者中的发育速度显著快于对照组。下小脑皮层^[19]被证实与孤独症密切相关，其发育不全的个体常表现出刻板行为、工作记忆障碍和社会线索理解困难等孤独症样症状。

3.7 消融实验

通过消融实验进一步探究 HMGNet 核心子组件及图注意力的实际贡献，见表 4。

表 4 消融实验结果

图谱	TE	强化 FC	ResNet	GAT	灵敏度（%）	特异度（%）	AUC（%）	准确度（%）
AAL		√	√	√	69.8	72.0	75.7	70.6
	√		√	√	71.0	72.6	75.9	71.4
	√	√	√		70.6	72.2	75.4	69.9
	√	√		√	70.8	72.1	75.7	70.6
CC200		√	√	√	72.9	74.3	78.2	72.7
	√		√	√	74.6	73.6	77.9	73.8
	√	√	√		74.1	73.8	77.4	72.3
	√	√		√	74.3	73.6	77.7	73.1

3.7.1 时间序列编码器的影响 为弥补皮尔逊相关在 FC 建模中的局限性，引入时间序列编码器。为验证其实际贡献，将模型降级为使用 PC 生成 FC，并比较其性能差异。替换组件后，在 AAL 和 CC200 两个图谱上，准确度、灵敏度等关键指标均出现明显下降。完整的 HMGNet 模型准确度分别提升 3.8 和 4.6 个百分点，灵敏度分别提升 4.0 和 4.9 个百分点，特异度分别提升 3.0 和 2.6 个百分点，AUC 均提升 1.2 个百分点。BOLD 信号中包含

复杂的非线性关系与长程依赖特性，借助 TE，HMGNet 能够更精确建模 FC 矩阵从而显著增强 ASD 诊断的准确性。

3.7.2 特征强化 FC 矩阵生成的影响 为弥补传统方法在 FC 建模中忽略复杂脑网络特征的问题，在 HMGNet 中引入特征强化机制。为评估其贡献，将该模块替换为线性处理方式，即将幂次操作改为恒等映射，不进行任何增强操作。在 AAL 和 CC200 图谱上，移除特征强化后模型性能显著下降。具体

表现为：准确度分别降低 3.0 和 3.5 个百分点，灵敏度分别下降 2.8 和 3.2 个百分点，特异度分别下降 2.4 和 3.3 个百分点，AUC 分别下降 1.0 和 1.5 个百分点。这些结果充分说明，特征强化机制通过增强关键脑区间的交互响应，有效提升了模型的判别能力。

3.7.3 残差学习和图注意力的影响 为应对传统图卷积方法在深层网络训练中的局限性，在 HMGNet 中引入残差学习机制。为进一步验证其作用，将残差连接移除，仅保留传统的图卷积操作，即每一层仅通过邻接矩阵聚合信息，而不引入原始特征的恒等映射。同时，为评估图注意力机制的效果，将其替换为固定权重的传统图卷积层，从而取消节点间连接权重的动态调整能力。当移除残差学习后，模型性能在多个关键指标上均显著下降。在 AAL 和 CC200 图谱上，准确度分别下降 3.8 和 4.2 个百分点，灵敏度分别下降 3.0 和 3.5 个百分点，特异度分别下降 2.9 与 3.3 个百分点，AUC 分别下降 1.2 和 1.7 个百分点。这些结果表明，残差学习在提升深层图神经网络的稳定性与判别能力方面具有关键作用。同样地，图注意力机制的去除也导致性能下降：在 AAL 和 CC200 上，准确度分别下降 4.5 和 5.0 个百分点，灵敏度分别下降 3.2 和 3.7 个百分点，特异度分别下降 2.8 和 3.1 个百分点，AUC 分别下降 1.5 和 2.0 个百分点。这一结果进一步验证了图注意力机制在建模脑区间复杂交互关系中的重要价值。

4 结语

本研究提出了一种端到端的多维特征层次增强图卷积网络——HMGNet，旨在利用 rs-fMRI 数据实现对 ASD 的准确识别。HMGNet 通过时间序列编码器提取 BOLD 信号中的动态交互特征，并结合特征强化策略优化 FC 矩阵建模。同时，模型引入了图注意力机制与残差学习模块，能够动态调整脑区间连接权重并提升信息传播效率，从而有效提升了特征表示能力和分类诊断精度。最终，通过 MLP 完成分类任务，在 ABIDE 数据库上取得了优异的性能

表现。

实验结果表明，HMGNet 在多个评估指标上均优于现有方法。更重要的是，模型识别出多个与已有医学研究一致的脑区，如下小脑、上小脑和蚓部区域，为 ASD 相关的神经机制研究提供了有力的影像学支持。

尽管 HMGNet 在 ASD 诊断中展现出良好的性能，但仍存在一些局限值得进一步改进。首先，当前模型主要基于线性变换建模脑网络拓扑结构，未来可探索更具表达能力的非线性方法，以更全面地捕捉复杂的脑区交互模式；其次，融合临床变量（如年龄、性别、行为评分等）可能揭示更多潜在生物标志物，并有助于提升模型的泛化能力；最后，模型在不同 ROI 划分图谱下的鲁棒性仍有待进一步验证，以增强其在多中心、多站点数据中的适用性和稳定性。

HMGNet 为基于神经影像的 ASD 自动识别提供了有效的深度学习框架，也为后续脑疾病相关人工智能辅助诊断研究提供了有益参考。

作者贡献：李祖达、于森负责数据整理、建模与代码编写、论文撰写；陈尊凡、王哲负责协助建模与代码编写；杨啸林、徐涛负责研究设计、论文审核与修订。

利益声明：所有作者均声明不存在利益冲突。

参考文献

- 1 JANOUSCHEK H, CHASE H W, SHARKEY R J, et al. The functional neural architecture of dysfunctional reward processing in autism [J]. *NeuroImage: clinical*, 2021, 31 (5): 102700.
- 2 WANG C, XIAO Z, WU J. Functional connectivity - based classification of autism and control using SVM - RFECV on rs-fMRI data [J]. *Physica medica*, 2019, 65 (9): 99 - 105.
- 3 INGALHALIKAR M, SHINDE S, KARMARKAR A, et al. Functional connectivity - based prediction of autism on site harmonized ABIDE dataset [J]. *IEEE transactions on biomedical engineering*, 2021, 68 (12): 3628 - 3637.
- 4 WANG Y, LONG H, ZHOU Q, et al. PLSNet: position - aware GCN - based autism spectrum disorder diagnosis via FC learning and ROIs sifting [J]. *Computers in biology and*

- medicine, 2023, 163 (9): 107184.
- 5 QU G, HU W, XIAO L, et al. Brain functional connectivity analysis via graphical deep learning [J]. IEEE transactions on biomedical engineering, 2022, 69 (5): 1696 – 1706.
- 6 WANG Y, LONG H, BO T, et al. Residual graph transformer for autism spectrum disorder prediction [J]. Computational methods and programs in biomedicine, 2024, 247 (4): 108065.
- 7 ESLAMI T, SADEED F. Auto – ASD – Network: a technique based on deep learning and support vector machines for diagnosing autism spectrum disorder using fMRI data [C]. Washington, DC: 10th ACM International Conference on Bioinformatics, Computational Biology and Health Informatics, 2019.
- 8 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 (3): 105239.
- 9 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 (11): 70.
- 10 BEDEL H A, SIVGIN I, DALMAZ O, et al. BoT: fused window transformers for fMRI time series analysis [J]. Medical image analysis, 2023, 88 (8): 102841.
- 11 SHRIVASTAVA S, MISHRA U, SINGH N, et al. Control or autism – classification using convolutional neural networks on functional MRI [C]. Kharagpur: 2020 11th International Conference on Computing, Communication and Networking Technologies (ICCCNT), 2020.
- 12 LOHAR M, CHORAGE S. Automatic classification of autism spectrum disorder (ASD) from brain MR images based on feature optimization and machine learning [C]. Pune: 2021 International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON), 2021.
- 13 WANG N, YAO D, MA L, et al. Multi – site clustering and nested feature extraction for identifying autism spectrum disorder with resting – state fMRI [J]. Medical image analysis, 2022, 75 (1): 102279.
- 14 NIU K, GUO J Y, PAN Y J, et al. Multichannel deep attention neural networks for the classification of autism spectrum disorder using neuroimaging and personal characteristic data [J]. Complexity, 2020, 2020 (1): 1357853.
- 15 KTEA S I, PARISOT S, FERRANTE E, et al. Metric learning with spectral graph convolutions on brain connectivity networks [J]. NeuroImage, 2018, 169 (4): 431 – 442.
- 16 LI X, ZHOU Y, DVORNEK N, et al. BrainGNN: interpretable brain graph neural network for fMRI analysis [J]. Medical image analysis, 2021, 74 (12): 102233.
- 17 KAN X, CUI H, LUKEMIRE J, et al. FBNetGen: task – aware GNN – based fMRI analysis via functional brain network generation [J]. Proceedings of machine learning research, 2022, 172 (7): 618 – 637.
- 18 KELLY E, MENG F, FUJITA H, et al. Regulation of autism – relevant behaviors by cerebellar – prefrontal cortical circuits [J]. Nature neuroscience, 2020, 23 (9): 1102 – 1110.
- 19 PERSICHETTI A S, SHAO J, GOTTS S J, et al. A functional parcellation of the whole brain in high – functioning individuals with autism spectrum disorder reveals atypical patterns of network organization [J]. Molecular psychiatry, 2025, 30 (4): 1518 – 1528.

《医学信息学杂志》开通微信公众号

《医学信息学杂志》微信公众号现已开通，作者可通过该平台查阅稿件状态；读者可浏览当期最新内容、过刊等；同时提供国内外最新医学信息研究动态、发展前沿等，搭建编者、作者、读者之间沟通、交流的平台。可在微信添加中找到公众号，输入“医学信息学杂志”进行确认，也可扫描右侧二维码添加，敬请关注！



《医学信息学杂志》编辑部