

脑-HGCN：一种用于大脑功能网络分析的双曲图卷积网络

Junhao Jia¹, Yunyou Liu¹, Cheng Yang¹, Yifei Sun², Feiwei Qin^{1,*}, Changmiao Wang³, Yong Peng¹

¹ Hangzhou Dianzi University, Hangzhou, China

² Zhejiang University, Hangzhou, China

³ Shenzhen Research Institute of Big Data, Shenzhen, China

* Corresponding author: qinfeiwei@hdu.edu.cn

ABSTRACT

功能性磁共振成像 (fMRI) 通过生成复杂的功能网络提供了一个强大的非侵入性窗口，用以观察大脑的功能组织，这些网络通常被建模为图。这些脑网络表现出一种分层拓扑结构，这对于认知处理至关重要。然而，由于内在的空间限制，标准的欧几里得 GNN 难以在不产生高失真情况下表示这种分层结构，这限制了它们的临床性能。为了应对这一局限性，我们提出了 Brain-HGCN，这是一个基于双曲几何的几何深度学习框架，它利用负曲率空间的内在属性以高度保真的方式建模大脑网络层次结构。基于 Lorentz 模型，我们的模型采用了一种新颖的带有符号聚合机制的双曲图注意力层，用以区分处理兴奋性和抑制性连接，并通过几何上合理的 Fréchet 平均进行图级读出学习稳健的图级表示。在两个大规模 fMRI 数据集上的精神病分类实验表明，我们的方法显著超越了广泛的最先进的欧几里得基线模型。这项工作开创了一种用于 fMRI 分析的新几何深度学习范式，突显了双曲 GNN 在计算精神病学领域中的巨大潜力。

Index Terms— 双曲学习，洛伦兹模型，脑功能网络，计算精神病学

1. 介绍

精神和神经发育障碍在全球范围内造成了重大负担，然而它们的神经基础仍然知之甚少 [1, 2]。功能磁共振成像 (fMRI) 因其非侵入性和高时空分辨率，已成为研究这些状况的关键工具，这使得测量 BOLD 信号和构建脑功能网络 [3, 4] 成为可能。由分布的脑区及其同步活动组成，这些网络表现出高度有序的层级组织，这对于大脑高效处理和整合信息的能力至关重要 [5, 6]。

然而，主流方法 [7, 8, 9] 依赖于假设数据空间为平坦的欧几里得几何框架，这一假设与分层脑网络固有的非线性拓扑特征 [10] 不一致。这使得检测各种神经发育障碍特有的细微层级异常变得困难，最终阻碍了基于网络的生物标志物的发展，从而影响临床诊断和预后。

为了解决这一方法论瓶颈，双曲几何因其独特的指数扩张特性，自然地成为建模分层系统的一个解决方案 [11, 12]。与欧几里得空间不同，双曲空间能够通过其距离中心点的度量尺度呈指数级扩展来高效表示低维度中的层级结构 [13]，这与大脑网络的核心集中外围发散拓扑结构相一致 [14]。在此基础上，我们提出了一种新颖的大脑功能网络建模双曲学习框架，该框




Fig. 1: (a) 大脑功能网络内在的层次拓扑结构。(b) 欧氏嵌入通过压缩层次距离导致高失真。(c) 双曲嵌入以高保真度保留这些层次关系。

架将功能连接数据嵌入到双曲空间中，利用其指数扩张特性自然地编码层级关系，如图 1 所示。我们的主要贡献是：

- (1) 我们开创了 Brain-HGCN，这是一种几何范式，将大脑的分层拓扑结构嵌入到洛伦兹双曲面以克服欧几里得表示限制。
- (2) 我们构建了一个双曲注意力机制，其带符号的聚合方案能够实现几何原理上的消息传递，从而区分兴奋性和抑制性路径。
- (3) 我们提出了一个曲率感知读出策略，该策略采用弗雷歇平均值在双曲线空间内直接导出无失真且符合流形本性的的大脑表示。

2. 预备知识

双曲几何提供了一个强大的框架，用于建模分层数据，因为它具有内在的恒定负曲率。这一特性使其能够以最小的扭曲嵌入树状结构。为了在神经网络中利用这种几何属性，本节介绍了基于洛伦兹模型的核心计算工具，这些工具为我们在工作中提出的方法奠定了基础。

洛伦兹模型。 Lorentz 模型将双曲空间实现为嵌入闵可夫斯基空间中的双曲面 $\mathbb{R}^{n+1}$ ：

$$\langle \mathbf{x}, \mathbf{y} \rangle_{\mathcal{L}} = -x_0 y_0 + \sum_{i=1}^n x_i y_i, \quad (1)$$

其中第一个坐标带有负号。具有曲率 $-1/K < 0$ 的 n 维双曲空间表示为：

$$\mathbb{H}_K^n = \{\mathbf{x} \in \mathbb{R}^{n+1} : \langle \mathbf{x}, \mathbf{x} \rangle_{\mathcal{L}} = -K, x_0 > 0\}, \quad (2)$$

This work was supported in part by the ‘Pioneer’ and ‘Leading Goose’ R&D Program of Zhejiang (No.2025C04001), Fundamental Research Funds for the Provincial Universities of Zhejiang (No. GK259909299001-006), Anhui Provincial Joint Construction Key Laboratory of Intelligent Education Equipment and Technology (No. IEEET202401), and National Undergraduate Training Program for Innovation and Entrepreneurship (No.202510336076).

这对应于两片双曲面中的上一片。这种嵌入提供了一个常数负曲率的光滑黎曼流形 $-1/K$ 。两点 $\mathbf{x}, \mathbf{y} \in \mathbb{H}_K^n$ 之间的测地线距离是：

$$d_K(\mathbf{x}, \mathbf{y}) = \text{arcosh}\left(-\frac{\langle \mathbf{x}, \mathbf{y} \rangle_{\mathcal{L}}}{K}\right). \quad (3)$$

这个距离反映了双曲空间的指数扩张特性，使其适合于编码层次关系。

切空间。在每个点 $\mathbf{x} \in \mathbb{H}_K^n$ ，切空间是与 $\mathbf{x}$ 在洛伦兹乘积下正交的线性空间：

$$T_{\mathbf{x}}\mathbb{H}_K^n = \{\mathbf{v} \in \mathbb{R}^{n+1} : \langle \mathbf{v}, \mathbf{x} \rangle_{\mathcal{L}} = 0\}. \quad (4)$$

切空间提供了一个局部平坦化的流形近似，使我们能够以一致的方式执行神经操作，如线性变换和聚合。

指数映射和对数映射。指数映射将切向量重新投影回流形。对于 $\mathbf{v} \in T_{\mathbf{x}}\mathbb{H}_K^n$ ，

$$\exp_{\mathbf{x}}^K(\mathbf{v}) = \cosh\left(\frac{\|\mathbf{v}\|_{\mathcal{L}}}{\sqrt{K}}\right)\mathbf{x} + \sqrt{K} \sinh\left(\frac{\|\mathbf{v}\|_{\mathcal{L}}}{\sqrt{K}}\right) \frac{\mathbf{v}}{\|\mathbf{v}\|_{\mathcal{L}}}, \quad (5)$$

其中 $\|\mathbf{v}\|_{\mathcal{L}} = \sqrt{\langle \mathbf{v}, \mathbf{v} \rangle_{\mathcal{L}}}$ 。直观上， $\exp_{\mathbf{x}}^K$ 沿着从 $\mathbf{x}$ 出发的方向为 $\mathbf{v}$ 的测地线移动了距离 $\|\mathbf{v}\|_{\mathcal{L}}/\sqrt{K}$ 。

对数映射是逆映射，将点 $\mathbf{y} \in \mathbb{H}_K^n$ 映回 $\mathbf{x}$ 处的切空间：

$$\log_{\mathbf{x}}^K(\mathbf{y}) = \frac{\text{arcosh}\left(-\frac{\langle \mathbf{x}, \mathbf{y} \rangle_{\mathcal{L}}}{K}\right)}{\sqrt{\left(-\frac{\langle \mathbf{x}, \mathbf{y} \rangle_{\mathcal{L}}}{K}\right)^2 - 1}} \left(\mathbf{y} + \frac{\langle \mathbf{x}, \mathbf{y} \rangle_{\mathcal{L}}}{K} \mathbf{x}\right). \quad (6)$$

此操作返回指向 $\mathbf{y}$ 的 $\mathbf{x}$ 处的切向量，其洛伦兹范数满足 $\|\log_{\mathbf{x}}^K(\mathbf{y})\|_{\mathcal{L}} = \sqrt{K} d_K(\mathbf{x}, \mathbf{y})$ 。

3. 方法论

如图 2 所示，我们提出了 Brain-HGCN 框架，该框架将 fMRI 数据嵌入双曲空间，并利用此空间内在的指数扩张自然地捕捉和编码大脑的层次组织原则。

3.1. 基于主题的脑网络构建

对于每个主题，我们构建一个加权的、无向的、有符号的图 $\mathcal{G} = (\mathcal{V}, \mathcal{E}, \mathbf{A}^{(+)}, \mathbf{A}^{(-)})$ 。节点 $\mathcal{V}$ 表示来自 AAL-116 理论的兴趣区域 (ROI)。每个节点 v_i 的初始特征是其对应的 ROI 平均时间序列， $\mathbf{x}_i^{0,E} \in \mathbb{R}^T$ ，其中 T 是时间点的数量。边 $\mathcal{E}$ 的权重由节点时间序列之间的皮尔逊相关性 C_{ij} 决定。为了保持有符号的耦合，我们通过保留每个节点的前 k 个正负连接来构建一个稀疏的对称图：

$$A_{ij}^{(+)} = \max(C_{ij}, 0), \quad A_{ij}^{(-)} = \max(-C_{ij}, 0). \quad (7)$$

3.2. 双曲神经网络原语

我们在具有常数负曲率 $-1/K < 0$ 的双曲面 $\mathbb{H}_K^d$ 上实例化该模型。每一层学习其自身的曲率 $K_{\ell} > 0$ 。令 $\mathbf{o} = (\sqrt{K_0}, 0, \dots, 0)$ 表示原点。我们使用指数/对数映射 $\exp^K(\cdot)(\cdot)$ 和 $\log^K(\cdot)(\cdot)$ 。上标 E/H 区分欧几里得量和双曲量。

输入提升。欧几里得节点特征通过原点的指数映射提升到流形上：

$$\mathbf{x}_i^{0,H} = \exp_{\mathbf{o}}^{K_0}((0, \mathbf{x}_i^{0,E})). \quad (8)$$

双曲线性变换和偏置。设 $\mathbf{W}_{\ell}$ 是在原点切空间作用的权重矩阵。我们定义双曲矩阵向量乘积和偏置加法为：

$$\begin{aligned} \mathbf{W}_{\ell} \otimes_{K_{\ell-1}} \mathbf{x}_i^{\ell-1,H} &= \exp_{\mathbf{o}}^{K_{\ell-1}}\left(\mathbf{W}_{\ell} \log_{\mathbf{o}}^{K_{\ell-1}}(\mathbf{x}_i^{\ell-1,H})\right), \\ \mathbf{x} \oplus_K \mathbf{b} &= \exp_{\mathbf{x}}^K\left(\text{PT}_{\mathbf{o} \rightarrow \mathbf{x}}^K(\mathbf{b})\right). \end{aligned} \quad (9)$$

其中 $\mathbf{b}_{\ell} \in T_{\mathbf{o}}\mathbb{H}_{K_{\ell-1}}^d$ 是原切线空间中的偏差，而 $\text{PT}_{\mathbf{o} \rightarrow \mathbf{x}}^K$ 表示平行传输到中心点的切线空间。变换后的表示为：

$$\mathbf{h}_i^{\ell,H} = (\mathbf{W}_{\ell} \otimes_{K_{\ell-1}} \mathbf{x}_i^{\ell-1,H}) \oplus_{K_{\ell-1}} \mathbf{b}_{\ell}. \quad (10)$$

3.3. 双曲注意力机制与带符号聚合

我们引入了一种针对大脑网络符号拓扑结构的双曲注意力层。设 $\mathbf{x}_i^{\ell-1,H}$ 是来自上一层的节点 i 的特征。首先，我们应用一个双曲线性变换并加上偏置以获得中间表示：

$$\mathbf{h}_i^{\ell,H} = (\mathbf{W}_{\ell} \otimes_{K_{\ell-1}} \mathbf{x}_i^{\ell-1,H}) \oplus_{K_{\ell-1}} \mathbf{b}_{\ell}. \quad (11)$$

洛伦兹注意力机制。我们将多头注意力机制适应到洛伦兹模型中。对于每个头 m ，查询 ($\mathbf{q}$)、键 ($\mathbf{k}$) 和值 ($\mathbf{v}$) 是通过线性映射生成的，并使用洛伦兹内积 $\langle \cdot, \cdot \rangle_{\mathcal{L}}$ 计算注意力分数，该内积自然来源于洛伦兹模型的几何：

$$s_{ij}^{(m)} = \frac{\langle \mathbf{q}_i^{(m)}, \mathbf{k}_j^{(m)} \rangle_{\mathcal{L}}}{\sqrt{d} \tau_{\ell}}, \quad \text{where } \tau_{\ell} = \tau_0 / \sqrt{K_{\ell-1}}. \quad (12)$$

为了处理带符号的边，我们在兴奋性 (+) 和抑制性 (-) 邻域中分别对分数进行标准化：

$$\begin{aligned} w_{ij}^{(m,+)} &= \text{softmax}_{j \in \mathcal{N}_i^{(+)}}(s_{ij}^{(m)}), \\ w_{ij}^{(m,-)} &= \text{softmax}_{j \in \mathcal{N}_i^{(-)}}(s_{ij}^{(m)}). \end{aligned} \quad (13)$$

签名聚合与更新。聚合在中心节点的切空间中进行 $\mathbf{h}_i^{\ell,H}$ 。我们从正邻居拉取并从负邻居推离：

$$\begin{aligned} \Delta_i^{(m)} &= \sum_{j \in \mathcal{N}_i^{(+)}} w_{ij}^{(m,+)} \log_{\mathbf{h}_i^{\ell,H}}^{K_{\ell-1}}(\mathbf{v}_j^{(m)}) \\ &\quad - \sum_{j \in \mathcal{N}_i^{(-)}} w_{ij}^{(m,-)} \log_{\mathbf{h}_i^{\ell,H}}^{K_{\ell-1}}(\mathbf{v}_j^{(m)}). \end{aligned} \quad (14)$$

输出被平均化并投影回流形：

$$\mathbf{y}_i^{\ell,H} = \exp_{\mathbf{h}_i^{\ell,H}}^{K_{\ell-1}}\left(\frac{1}{H} \sum_{m=1}^H \Delta_i^{(m)}\right). \quad (15)$$

最后，我们在原点的切空间中应用一个欧几里得非线性 σ ，并将结果映射回到具有新层曲率 K_{ℓ} 的流形上以获得该层最终节点表示：

$$\mathbf{x}_i^{\ell,H} = \exp_{\mathbf{o}}^{K_{\ell}}\left(\sigma\left(\log_{\mathbf{o}}^{K_{\ell-1}}(\mathbf{y}_i^{\ell,H})\right)\right). \quad (16)$$

3.4. 内在图读出与分类

最终的双曲层生成节点嵌入 $\{\mathbf{x}_i^{L,H}\}_{i=1}^N$ 。对于图级分类，我们的内在读出计算弗雷歇平均值并在其切线空间中进行池化。

Fréchet 平均作为几何中心。Fréchet 均值， $\mu_{\mathcal{G}}$ 将欧几里得质心推广到黎曼流形，定义为最小化到所有节点的测地距离平方和的点：

$$\mu_{\mathcal{G}} = \arg \min_{\mathbf{x} \in \mathbb{H}_{K_L}^d} \frac{1}{N} \sum_{i=1}^N d_{K_L}(\mathbf{x}, \mathbf{x}_i^{L,H})^2. \quad (17)$$




Fig. 2: 我们提出的 Brain-HGCN 框架的概述。(a) 展示了从 fMRI 数据构建有符号功能图进行端到端分类的过程。(b) Brain-HGCN 训练和分类的核心模型，其特点是带有有符号聚合的消息传递的 Lorentzian 注意力，以及用于内图池化和分类的 Fréchet 平均读出。

在 Hadamard 流形上，这个均值是唯一的，并且可以通过 Karcher 流找到：

$$\begin{aligned} \mathbf{v}^{(t)} &= \frac{1}{N} \sum_{i=1}^N \log_{\mu^{(t)}}^{K_L}(\mathbf{x}_i^{L,H}), \\ \mu^{(t+1)} &= \exp_{\mu^{(t)}}^{K_L}(\eta \mathbf{v}^{(t)}). \end{aligned} \quad (18)$$

池化和分类。以 μ_G 为基准，我们将节点映射到 T_{μ_G} 并进行平均：

$$\mathbf{z}_G = \frac{1}{N} \sum_{i=1}^N \log_{\mu_G}^{K_L}(\mathbf{x}_i^{L,H}). \quad (19)$$

将欧几里得向量 $\mathbf{z}_G$ 输入分类器，并使用交叉熵损失进行端到端训练。

4. 实验

4.1. 实验设置

我们在 ADHD-200[15] 和 ABIDE[16] 数据集上评估了 Brain-HGCN。使用官方的预处理和质量控制，ADHD-200 得到了 776 名受试者，其中 285 名 ADHD 患者和 491 名对照组；ABIDE 得到了 871 名受试者，其中 403 名 ASD 患者和 468 名对照组。

Brain-HGCN 包含 3 个注意力层 ($d = 64$)，每层具有可学习的曲率 K_ℓ (初始值为 1.0) 和 4 个注意力头。我们构建了稀疏图 ($k = 10$)，并在 5 次迭代 ($\eta = 0.1$) 上计算 Fréchet 平均。该模型使用 AdamW 训练了 100 个周期 (学习率 $= 10^{-3}$ ，权重衰减 $= 5 \times 10^{-4}$ ，批量大小 $= 32$)。

4.2. 与 SOTA 方法的比较

如表 1 所示，我们将 Brain-HGCN 与 CNN、Transformer 和 GNN 类别的十三种先进基线进行比较。

在 ADHD-200 数据集上，Brain-HGCN 达到了 83.6% 的准确率和 90.7% 的 AUC 值，分别比 MM-GTUNets 高出 1.9

个百分点和 2.0 个百分点 (MM-GTUNets 分别为 81.7% 和 88.7%)，灵敏度为 80.8%，特异度为 85.8%，形成了最佳组合。在 ABIDE 数据集上，Brain-HGCN 达到了 88.3% 的准确率和 91.4% 的 AUC 值，其中 AUC 值比 MM-GTUNets 高出 4.0 个百分点 (MM-GTUNets 为 87.4%)，准确率比 RTGMFF 高出 1.9 个百分点 (RTGMFF 为 86.4%)；灵敏度 87.1%，特异度 89.7%，均为整体最高。在各个数据集上，Brain-HGCN 在核心指标上领先，并显示出更强的跨站点稳健性和区分能力。

4.3. 消融研究

我们的消融研究 (表 2) 量化了每个模块的贡献，并证实了其在两个数据集上的跨队列鲁棒性。

双曲几何。移除双曲几何并替换为欧式几何会导致最大的性能下降，证明了它在以低失真建模分层脑网络中的关键作用。

Fréchet 平均读出。移除固有的 Fréchet 平均值并在固定基点处进行平均会一致地降低性能，这表明在固有均值处的切线空间池化消除了基点偏差并稳定了图级别的表示。

洛伦茨注意力。切换到欧氏点积或移除注意力机制会导致进一步下降，突显了几何一致相似度量度的价值。

签名聚合。移除带符号的聚合机制会降低准确性，这证实了区分兴奋性和抑制性通路的重要性。

总体而言，结论在各个数据集上一致，各组成部分互为补充，并且完整模型在其几何和结构设计的驱动下，在关键指标上取得了最佳结果。

5. 结论

在这项研究中，我们介绍了用于脑功能网络分析的双曲图卷积网络 Brain-HGCN。Brain-HGCN 利用几何一致运算的 Lorentz 模型来减少层次失真，结合带有符号聚合的 Lorentz 多头注意力以区别地建模正负耦合，并采用内在 Fréchet 平均读出以实现无偏的图级别池化。在 ADHD-200 和 ABIDE 上的对比实验显示其性能优于强大基线，并具有稳定训练和跨站点鲁棒性，表明其适合大规模计算精神病学研究。未来工作将扩展 Brain-HGCN 至动态功能连接和多模态整合，探索站点调谐

Table 1: ADHD-200 和 ABIDE 数据集上的性能比较。所有结果均报告为 10 折交叉验证的平均值 $\pm$ 标准差。每列中的前三名结果分别用 第一、第二 和 第三 的颜色突出显示。

方法	注意力缺陷多动障碍-200 (注意缺陷多动障碍)[15]				遵守 (ASD)[16]			
	ACC (%)	SEN (%)	SPE (%)	AUC (%)	ACC (%)	SEN (%)	SPE (%)	AUC (%)
基于 CNN 的方法								
VGG16 (ICLR'15)[17]	64.6 $\pm$ 3.8	59.7 $\pm$ 5.3	70.3 $\pm$ 3.1	65.0 $\pm$ 3.1	71.3 $\pm$ 3.2	73.0 $\pm$ 4.2	69.1 $\pm$ 3.9	71.0 $\pm$ 2.9
ResNet-50 (CVPR'16)[18]	68.5 $\pm$ 3.4	57.7 $\pm$ 4.8	78.1 $\pm$ 3.6	67.9 $\pm$ 3.0	72.2 $\pm$ 2.9	68.0 $\pm$ 3.3	75.6 $\pm$ 2.6	71.8 $\pm$ 2.1
BrainNetCNN (Neuro'17)[7]	68.0 $\pm$ 3.3	65.8 $\pm$ 8.3	70.4 $\pm$ 5.3	68.1 $\pm$ 4.9	67.3 $\pm$ 2.6	63.3 $\pm$ 9.4	70.5 $\pm$ 8.7	66.9 $\pm$ 6.4
MMAFN (DLCV'25)[19]	77.6 $\pm$ 2.1	75.2 $\pm$ 2.7	73.5 $\pm$ 2.1	77.4 $\pm$ 2.3	80.4 $\pm$ 1.6	79.2 $\pm$ 2.4	77.5 $\pm$ 2.1	80.1 $\pm$ 1.4
基于变压器的方法								
BNT (NeurIPS'22)[8]	72.8 $\pm$ 2.9	70.9 $\pm$ 4.3	73.9 $\pm$ 3.6	72.4 $\pm$ 2.8	75.9 $\pm$ 1.6	72.9 $\pm$ 5.3	69.8 $\pm$ 6.6	71.3 $\pm$ 4.2
MCPATS (JBHI'24)[20]	74.0 $\pm$ 3.3	64.3 $\pm$ 4.7	80.4 $\pm$ 2.9	72.3 $\pm$ 3.8	76.0 $\pm$ 2.6	73.2 $\pm$ 3.6	78.7 $\pm$ 2.9	76.0 $\pm$ 2.3
GBT (MICCAI'24)[21]	70.4 $\pm$ 3.6	68.1 $\pm$ 4.3	71.5 $\pm$ 3.9	69.8 $\pm$ 2.9	78.0 $\pm$ 6.6	79.5 $\pm$ 9.5	77.3 $\pm$ 4.0	78.4 $\pm$ 5.2
RTGMFF (arXiv'25)[22]	80.7 $\pm$ 2.5	79.5 $\pm$ 3.0	81.3 $\pm$ 2.8	80.4 $\pm$ 2.1	86.4 $\pm$ 1.9	84.5 $\pm$ 2.7	87.5 $\pm$ 2.3	86.0 $\pm$ 1.8
基于 GNN 的方法								
BrainGNN (MIA'21)[9]	64.7 $\pm$ 3.8	67.9 $\pm$ 3.5	62.7 $\pm$ 4.1	65.3 $\pm$ 2.7	69.3 $\pm$ 3.9	66.8 $\pm$ 3.3	72.7 $\pm$ 3.4	69.8 $\pm$ 2.4
BrainGB (TMI'22)[23]	65.8 $\pm$ 2.6	61.3 $\pm$ 4.9	70.3 $\pm$ 3.8	65.8 $\pm$ 3.1	63.2 $\pm$ 2.0	63.8 $\pm$ 8.1	60.1 $\pm$ 6.9	62.0 $\pm$ 5.3
A-GCL (MIA'23)[24]	77.8 $\pm$ 4.4	76.4 $\pm$ 4.7	79.4 $\pm$ 5.3	77.9 $\pm$ 3.5	82.9 $\pm$ 2.1	82.4 $\pm$ 2.6	83.7 $\pm$ 1.9	83.1 $\pm$ 1.6
KMGCN (MIA'25)[25]	75.2 $\pm$ 2.6	72.8 $\pm$ 3.9	77.0 $\pm$ 2.6	74.2 $\pm$ 3.9	84.7 $\pm$ 1.3	83.6 $\pm$ 1.7	81.3 $\pm$ 1.4	82.4 $\pm$ 1.1
MM-GTUNets (TMI'25)[26]	81.7 $\pm$ 1.6	78.8 $\pm$ 2.9	81.1 $\pm$ 1.9	88.7 $\pm$ 1.5	83.1 $\pm$ 1.7	84.6 $\pm$ 2.1	82.3 $\pm$ 1.6	87.4 $\pm$ 1.5
脑-HGCN (我们的工作)	83.6 $\pm$ 1.3	80.8 $\pm$ 2.7	85.8 $\pm$ 1.6	90.7 $\pm$ 1.2	88.3 $\pm$ 1.1	87.1 $\pm$ 1.2	89.7 $\pm$ 0.9	91.4 $\pm$ 0.7

Table 2: ADHD-200 和 ABIDE 数据集上的消融研究。所有结果均报告为在 10 折交叉验证下的平均值 $\pm$ 标准差。每一列中的前三名结果分别用 第一、第二 和 第三 色标突出显示。

方法	注意力缺陷多动障碍-200 (ADHD)[15]				遵守 (ASD)[16]			
	ACC (%)	SEN (%)	SPE (%)	AUC (%)	ACC (%)	SEN (%)	SPE (%)	AUC (%)
w/o Hyperbolic Geometry	78.5 $\pm$ 2.1	75.1 $\pm$ 3.5	80.3 $\pm$ 2.8	84.1 $\pm$ 1.9	82.1 $\pm$ 1.8	83.2 $\pm$ 2.5	80.5 $\pm$ 2.1	85.3 $\pm$ 1.5
w/o Fréchet Mean Readout	82.0 $\pm$ 1.5	78.9 $\pm$ 2.9	84.1 $\pm$ 1.9	88.5 $\pm$ 1.4	85.9 $\pm$ 1.3	87.5 $\pm$ 1.8	83.1 $\pm$ 1.2	89.8 $\pm$ 1.0
w/o Lorentzian Attention	81.3 $\pm$ 1.8	78.2 $\pm$ 3.1	83.5 $\pm$ 2.2	87.9 $\pm$ 1.6	85.2 $\pm$ 1.5	86.9 $\pm$ 2.0	82.8 $\pm$ 1.4	89.1 $\pm$ 1.2
w/o Signed Aggregation	80.2 $\pm$ 1.9	76.9 $\pm$ 3.3	82.8 $\pm$ 2.5	86.5 $\pm$ 1.8	84.5 $\pm$ 1.6	85.1 $\pm$ 2.2	83.7 $\pm$ 1.3	88.2 $\pm$ 1.3
脑-HGCN (我们的)	83.6 $\pm$ 1.3	80.8 $\pm$ 2.7	85.8 $\pm$ 1.6	90.7 $\pm$ 1.2	87.3 $\pm$ 1.1	89.6 $\pm$ 1.2	84.3 $\pm$ 0.9	91.4 $\pm$ 0.7

与领域泛化，并开发曲率感知、可解释的生物标志物以促进临床转化。

6. REFERENCES

- [1] Thomas R Insel and Bruce N Cuthbert, "Brain disorders? precisely," *Science*, vol. 348, no. 6234, pp. 499–500, 2015.
- [2] GBD 2019 Mental Disorders Collaborators et al., "Global, regional, and national burden of 12 mental disorders in 204 countries and territories, 1990–2019: a systematic analysis for the global burden of disease study 2019," *The Lancet Psychiatry*, vol. 9, no. 2, pp. 137–150, 2022.
- [3] Seiji Ogawa, Tso-Ming Lee, Alan R Kay, and David W Tank, "Brain magnetic resonance imaging with contrast dependent on blood oxygenation.," *Proceedings of the National Academy of Sciences*, vol. 87, no. 24, pp. 9868–9872, 1990.
- [4] Michael D Fox and Michael Greicius, "Clinical applications of resting state functional connectivity," *Frontiers in Systems Neuroscience*, vol. 4, pp. 1443, 2010.
- [5] David Meunier, Renaud Lambiotte, Alex Fornito, Karen Ersche, and Edward T Bullmore, "Hierarchical modularity in human brain functional networks," *Frontiers in Neuroinformatics*, vol. 3, pp. 571, 2009.
- [6] Danielle S Bassett and Michael S Gazzaniga, "Understanding complexity in the human brain," *Trends in Cognitive Sciences*, vol. 15, no. 5, pp. 200–209, 2011.
- [7] Jeremy Kawahara, Colin J Brown, Steven P Miller, Brian G Booth, Vann Chau, Ruth E Grunau, Jill G Zwicker, and Ghassan Hamarneh, "BrainNetCNN: Convolutional neural networks for brain networks; towards predicting neurodevelopment," *NeuroImage*, vol. 146, pp. 1038–1049, 2017.

- [8] Xuan Kan, Wei Dai, Hejie Cui, Zilong Zhang, Ying Guo, and Carl Yang, "Brain Network Transformer," *Advances in Neural Information Processing Systems*, vol. 35, pp. 25586–25599, 2022.
- [9] Xiaoxiao Li, Yuan Zhou, Nicha Dvornek, Muhan Zhang, Siyuan Gao, Juntang Zhuang, Dustin Scheinost, Lawrence H Staib, Pamela Ventola, and James S Duncan, "BrainGNN: Interpretable brain graph neural network for fMRI analysis," *Medical Image Analysis*, vol. 74, pp. 102233, 2021.
- [10] Maximillian Nickel and Douwe Kiela, "Poincaré embeddings for learning hierarchical representations," *Advances in Neural Information Processing Systems*, vol. 30, 2017.
- [11] Dmitri Krioukov, Fragkiskos Papadopoulos, Maksim Kitsak, Amin Vahdat, and Marián Boguná, "Hyperbolic geometry of complex networks," *Physical Review E—Statistical, Nonlinear, and Soft Matter Physics*, vol. 82, no. 3, pp. 036106, 2010.
- [12] Cole Baker, Isabel Suárez-Méndez, Grace Smith, Elisabeth B Marsh, Michael Funke, John C Mosher, Fernando Maestú, Mengjia Xu, and Dimitrios Pantazis, "Hyperbolic graph embedding of meg brain networks to study brain alterations in individuals with subjective cognitive decline," *IEEE Journal of Biomedical and Health Informatics*, vol. 28, no. 12, pp. 7357–7368, 2024.
- [13] Octavian Ganea, Gary Bécigneul, and Thomas Hofmann, "Hyperbolic neural networks," *Advances in Neural Information Processing Systems*, vol. 31, 2018.
- [14] Martijn P Van Den Heuvel and Olaf Sporns, "Rich-club organization of the human connectome," *Journal of Neuroscience*, vol. 31, no. 44, pp. 15775–15786, 2011.
- [15] Pierre Bellec, Carlton Chu, Francois Chouinard-Decorte, Yassine Benhajali, Daniel S Margulies, and R Cameron Craddock, "The neuro bureau ADHD-200 preprocessed repository," *Neuroimage*, vol. 144, pp. 275–286, 2017.
- [16] Adriana Di Martino, Chao-Gan Yan, Qingyang Li, Erin Denio, Francisco X Castellanos, Kaat Alaerts, Jeffrey S Anderson, Michal Assaf, Susan Y Bookheimer, Mirella Dapretto, et al., "The autism brain imaging data exchange: towards a large-scale evaluation of the intrinsic brain architecture in autism," *Molecular Psychiatry*, vol. 19, no. 6, pp. 659–667, 2014.
- [17] Karen Simonyan and Andrew Zisserman, "Very deep convolutional networks for large-scale image recognition," *International Conference on Learning Representations*, 2015.
- [18] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016, pp. 770–778.
- [19] Junhao Jia, Ruoyu Liang, Yi Ding, Chi Zhang, Yangming Li, Changmiao Wang, Feiwei Qin, Guodao Zhang, Xinjun Miao, Ahmed Elazab, et al., "MMAFN: Multi-modal attention fusion network for attention-deficit hyperactivity disorder classification," in *2025 IEEE 2nd International Conference on Deep Learning and Computer Vision (DLCV)*. IEEE, 2025, pp. 1–5.
- [20] Ning Jiang, Gongshu Wang, Chuyang Ye, Tiantian Liu, and Tianyi Yan, "Multi-task collaborative pre-training and adaptive token selection: A unified framework for brain representation learning," *IEEE Journal of Biomedical and Health Informatics*, vol. 28, no. 9, pp. 5528–5539, 2024.
- [21] Zhihao Peng, Zhibin He, Yu Jiang, Pengyu Wang, and Yixuan Yuan, "GBT: Geometric-oriented brain Transformer for autism diagnosis," in *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer, 2024, pp. 142–152.
- [22] Junhao Jia, Yifei Sun, Yunyou Liu, Cheng Yang, Changmiao Wang, Feiwei Qin, Yong Peng, and Wenwen Min, "RTGMFF: Enhanced fmri-based brain disorder diagnosis via roi-driven text generation and multimodal feature fusion," *arXiv preprint arXiv:2509.03214*, 2025.
- [23] Hejie Cui, Wei Dai, Yanqiao Zhu, Xuan Kan, Antonio Aodong Chen Gu, Joshua Lukemire, Liang Zhan, Lifang He, Ying Guo, and Carl Yang, "BrainGB: a benchmark for brain network analysis with graph neural networks," *IEEE Transactions on Medical Imaging*, vol. 42, no. 2, pp. 493–506, 2022.
- [24] Shengjie Zhang, Xiang Chen, Xin Shen, Bohan Ren, Ziqi Yu, Haibo Yang, Xi Jiang, Dinggang Shen, Yuan Zhou, and Xiao-Yong Zhang, "A-GCL: Adversarial graph contrastive learning for fmri analysis to diagnose neurodevelopmental disorders," *Medical Image Analysis*, vol. 90, pp. 102932, 2023.
- [25] Xianhua Zeng, Jianhua Gong, Weisheng Li, and Zhuoya Yang, "Knowledge-driven multi-graph convolutional network for brain network analysis and potential biomarker discovery," *Medical Image Analysis*, vol. 99, pp. 103368, 2025.
- [26] Luhui Cai, Weiming Zeng, Hongyu Chen, Hua Zhang, Yueyang Li, Yu Feng, Hongjie Yan, Lingbin Bian, Wai Ting Siok, and Nizhuan Wang, "MM-GTUNets: Unified multi-modal graph deep learning for brain disorders prediction," *IEEE Transactions on Medical Imaging*, 2025.