

Beijing Forest Studio
北京理工大学信息系统及安全对抗实验中心



群体认知诊断方法研究

硕士研究生 吴廷瑞

2025年10月9日

- 相关内容
 - 2024.10.13 邢倚康《增强**认知诊断**可解释性》
 - 2024.04.21 周瑾洁《**认知诊断**前沿探索—精准学习状态建模》
 - 2024.04.14 杨晓楠《**个性化学习**路径推荐—量身打造专属于你的学习Plan》
 - 2023.09.03 杨晓楠《**认知诊断**技术及其研究》

- 预期收获
- 内涵解析与研究目标
- 研究背景与意义
- 研究历史与现状
- 知识基础
- 算法原理
 - DGCD
 - RDGT
- 特点总结与未来展望
- 参考文献

- 预期收获
 - 掌握群体认知诊断技术的基本概念与研究方法
 - 理解群体认知诊断技术的应用原理
 - 了解群体认知诊断的发展前景



- 内涵解析

- 认知诊断：研究学习者某一时间段学习行为，分析挖掘基于这些行为的认知状态（如对知识概念的熟练程度）
- 群体认知诊断：统计分析某群体内所有成员的认知状态来获取群体层面的整体认知状态表现

- 研究分析群体-个体之间的关系
- 群体内部成员之间交互关系

- 研究目标

- 以学习者认知状态为研究对象
- 结合深度学习、图神经网络等技术
- 深入分析群体及内部成员的关联关系，增强群体对其成员认知状态的表征能力，为教学设计、个性化学习路径推荐等任务提供更准确的支持和指导



- 研究背景

- 传统教学模式下，教师以**班级为单位**统一教学，个体认知诊断难以适应**实际教学需求**
- **智能教育系统**广泛应用，通过分析在线数据帮助学生找准知识上的**薄弱点**
- 我国在线教育用户规模已达**4.23**亿，越来越多的学生通过在线学习的方式来提升自己



- 研究意义


- 为智能教学平台提供**群体画像**，挖掘**共性需求**
- 揭示学习群体中存在的**普遍性**知识盲区和**学习瓶颈**，为**课程整体优化**提供有力参考



Wang提出NeuralCD模型，**首次通过神经网络**来学习学习者与练习之间复杂的交互。建模练习与知识概念之间以及概念之间的复杂关系

Ma 等提出了知识感知认知诊断（KSCD）框架，从学生响应日志中**学习知识概念的内在关系**。并设计了一个新函数来更好地模拟学生-练习交互

RDGT模型通过构建双侧关系图，**从群体-学生-练习异构交互数据中建模学生与练习之间的关联**。使用混合损失函数优化小组和学生的表现预测



• 群体认知诊断

- 挖掘群体内个体行为、心理和认知之间的关系，利用个体学习数据，对其认知状态进行诊断，并基于群体与个体之间的关系，对群体认知状态进行综合评估

- 学习数据：学生与练习的响应日志、练习与概念对应关系的Q矩阵、专家标注的概念间关系
- 认知状态：对于知识概念的熟练程度


– 元素定义

- 群体集合： $G = \{g_1, g_2, g_3, \dots, g_O\}$
- 学生集合： $S = \{s_1, s_2, s_3, \dots, s_N\}$
- 练习集合： $E = \{e_1, e_2, e_3, \dots, e_M\}$
- 概念集合： $C = \{c_1, c_2, c_3, \dots, c_K\}$
- 响应日志： $R^S = \{(s, e, r) | s \in S, e \in E, r \in \{0, 1\}\}$

Interaction	Response
(o_1, s_1, e_1)	✓
(o_1, s_2, e_1)	✓
(o_1, s_1, e_2)	✗
(o_1, s_2, e_2)	✗
(o_2, s_3, e_3)	✗
(o_2, s_4, e_3)	✓
(o_1, s_2, e_3)	✓

Interaction Logs

Cognitive Diagnosis Processes



- 项目反应理论（IRT） 认知水平研究范式

- 强调理解个体内部微观层次的认知加工过程
- 模拟交互函数

$$P(X_{ij} = 1 | \theta_i, \alpha_j, \beta_j, c_j) = c_j + (1 - c_j) \frac{e^{D\alpha_j(\theta_i - \beta_j)}}{1 + e^{D\alpha_j(\theta_i - \beta_j)}}$$

Diagram illustrating the parameters in the IRT equation:

- θ_i : 学生能力 (Student Ability)
- α_j : 练习区分度 (Item Discrimination)
- β_j : 练习难度 (Item Difficulty)
- c_j : 猜测度 (Guessing)

没有用到Q矩阵，学生能力水平无法与知识概念的熟练程度匹配

交互函数由人工设计，函数模拟能力有限

- 群体项目反应理论（GIRT）

- 假设被试群体并不是同质的，而是由多个不同的子群体（如性别群体、地区群体、语言群体等）组成
- 由单一总体扩展到多个群体，每个群体都可能在题目参数（如难度、区分度）上表现出差异，反映不同群体在潜在特质上的差异性与不平衡性

• 基于神经网络的认知诊断框架 NCD

– 学生建模：学生知识概念熟练度向量： $h^s = \text{sigmoid}(x^s \times A)$

– 练习建模

• 知识点相关度向量

$$Q_e = x^e \times Q$$

• 练习难度向量

$$h^{diff} = \text{sigmoid}(x^e \times B)$$


• 练习区分度向量

$$h^{disc} = \text{sigmoid}(x^e \times D)$$

– 交互函数预测

$$f_0 = Q^e \circ (h^s - h^{diff}) \times h^{disc}$$

$$y^* = \text{sigmoid}(W_n \times f_{n-1} + b_n)$$



关键向量学习

交互模拟

- 正确性评价指标

- 由于难以直接获取群体知识水平的精确值，因此通常通过预测的群体认知状态与实际观测结果之间的差异来评估诊断方法的准确性。

- 从回归的角度来看，量化预测分数（范围从0到1）

- 均方根误差RMSE

- 反映预测结果与真实结果之间的整体偏差程度

- $$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}$$

- 平均绝对误差MAE

- 反映预测偏差的平均水平

- $$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$






DGCD: An Adaptive Denoising GNN for Group-level Cognitive Diagnosis

T	目标	诊断群体和学生对特定 知识概念 的熟练程度
I	输入	群体-学生关系记录、学生练习交互记录(答题情况、练习编号、概念编号) 教育数据集*4: SLP-Bio (56万交互) SLP-Math (92万交互) ASSIST-2012 (270万交互) NIPS_Edu (320万交互)
P	处理	1. 建立 小组-学生-练习 (GSE) 图, 捕捉三者之间的 高阶连接 2. 对学生-练习边的 可靠性分布 进行建模, 去除可靠性低的噪声边 3. 构建熵权平衡模块, 减轻GSE图中 关系不平衡 可能带来的偏差 4. 认知状态诊断
O	输出	学生和群体的认知状态结果(用连续变量表示, 范围从0到1)

P	问题	1. 现有方法使用图神经网络构建小组、学生与练习的互动时存在 噪声 2. GSE图中的 关系不平衡 可能会在消息传递过程中引入偏差
C	条件	群体-学生关系记录、学生练习交互记录、练习-概念映射Q矩阵
D	难点	1. 如何降低关系图中存在的噪声 2. 如何减低关系图中的不平衡带来的偏差
L	水平	2024 CCF A类

• 算法原理图

- 构建群体-学生-练习(GSE)关系图，计算学生-练习边的**边可靠性**实现GSE图**去噪**
- 构建**熵加权平衡**模块，根据节点聚合的**信息熵**进行加权
- 进行群体认知诊断模块，评估群体潜在认知状态



- 现有方法存在问题

- GSE图噪声明显：“学生-练习”边代表一次作答（对/错）但在实际做题的过程中，学生可能临时发挥或失误，导致作答结果不能完全代表其真实水平，反应在图中即边存在一定不可靠性导致图学习存在噪声
- 根本原因：数据无法反映偶然性

- 解决方法

- 确定学生-练习边的信息是否可信，计算边的可靠性
 - 高斯分布建模可靠性
 - 重参数化采样
 - 松散Bernoulli分布计算保留概论
 - 构造“去噪视图”的邻接矩阵

猜题？粗心大意？



• 解决方法

– 确定学生-练习边的信息是否可信，计算边的可靠性

• 高斯分布建模可靠性

– 为学生-练习边引入“可靠性”变量 z_{jk}

$$\mu_{jk} = W_{\mu}[s_j^0, e_k^0], \quad \log \sigma_{jk}^2 = W_{\sigma}[s_j^0, e_k^0]$$


$$q(z_{jk}|s_j, e_k) = N(\mu_{jk}, \sigma_{jk}^2)$$

– s_j^0, e_k^0 表示学生 j 和练习 e 经线性变换后的嵌入表示

• 重参数化采样

– 重参数化采样高斯分布，实现端到端的可微分优化

$$w_{jk} = \mu_{jk} + \epsilon \odot \sigma_{jk}^2, \quad \epsilon \sim N(0,1)$$



• 解决方法

– 确定学生-练习边的信息是否可信，计算边的可靠性



- 高斯分布建模可靠性
- 重参数化采样
- 松散Bernoulli分布计算保留概率

$$p_{jk} = \sigma \left(\frac{1}{t} \left(\log \frac{\rho(w_{jk})}{1-\rho(w_{jk})} + \log \frac{\mu}{1-\mu} \right) \right), \quad \mu \sim \text{Unif}[0,1]$$

• 构造“去噪视图”的邻接矩阵

– 得到去噪后的正确/错误邻接矩阵 A_t^d, A_f^d ，用于后续模块

$$\begin{cases} a_{jk}^t = p_{jk} \text{ if } s_j \text{ 答对 } e_k \\ a_{jk}^f = p_{jk} \text{ if } s_j \text{ 答错 } e_k \end{cases}$$



- 现有方法存在问题

- 消息传递 (Message Passing) 时, 存在不平衡现象, 例如:

- 一个学生节点连接一个群组节点
 - 一个学生节点连接数十个练习节点

- 学生的表示更新存在偏差

- 来自练习的消息被“放大”
 - 群体的信息被“稀释”



- 解决方法

- 平衡消息聚合时关系权重: 按信息量分配权重, 高价值关系贡献更大

- 邻居聚合与归一化
 - 信息熵计算
 - 熵加权
 - 加权消息传递



• 解决方法

– 平衡消息聚合时关系权重：按信息量分配权重，高价值关系贡献更大

• 邻居聚合与归一化(以学生从答对练习邻居聚合的信息为例)

学生 s_j 在第 l 层从“答对练习”邻居得到的聚合向量

$$h_{st}^{j,l} = \sum_{k \in N_j^t} \frac{a_{jk}^t}{d_j^t d_j^k} W_{r2}^{l-1} e_k^{l-1}$$

去噪后的边权

• 信息熵计算

– 计算聚合向量 h 信息熵

练习节点嵌入

$$F H(h) = -\frac{1}{\sqrt{d}} \sum_i h_i \log_2 h_i \quad H_{st}^{j,l} = F H(h_{st}^{j,l}), H_{sf}^{j,l}, H_{sg}^{j,l} \dots$$

• 解决方法

– 平衡消息聚合时关系权重：按信息量分配权重，高价值关系贡献更大

• 熵加权

– 用熵值分配关系权重，例如对学生节点：

$$\lambda_{st}^{j,l} = \frac{H_{st}^{j,l}}{H_{st}^{j,l} + H_{sf}^{j,l} + H_{sg}^{j,l}}$$

• 加权消息传递

– 以学生节点更新为例，群体-学生、答对-学生、答错-学生三类信息按熵权重平衡聚合

$$s_j^l = W_s^{l-1} s_j^{l-1} + \lambda_{st}^{j,l} \sum_{k \in N_j^t} \frac{a_{jk}^t}{d_j^t d_j^k} W_{r2}^{l-1} e_k^{l-1} + \lambda_{sf}^{j,l} \sum_{k \in N_j^f} \frac{a_{jk}^f}{d_j^t d_j^k} W_{r3}^{l-1} e_h^{l-1} + \lambda_{sg}^{j,l} \frac{1}{|N_i^s|} W_{r1}^{l-1} g_i^{l-1}$$

数据集

数据集名称	ASSIST12	NIPS_Edu	SLP-Bio	SLP-Math
学生数量	1,802	2,113	3,922	4,152
群组数量	114	150	145	153
练习数量	707	688	120	138
概念数量	122	77	21	39
平均组大小	19.16	14.78	27.05	27.14
单组回答平均次数	7.48	31.96	70.49	72.56

评价指标

- 正确性: RMSE, MAE

基于认知诊断对比方法

- IRT (1958)
- MIRT (2009)
- NCD (2020)
- MGCD (2021)
- ReliCD (2023)

基于图的对比方法


- RGCN (2018)
- GATv2 (2021)
- SGL (2021)
- RocSE (2023)

- 评估DGCD在不同数据集上的表现
 - DGCD在不同数据集中**RMSE**和**MAE**都优于对比方法，但效果提升较小

Model	ASSIST2012		NIPS_Edu		SLPbio		SLPmath	
	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
IRT	0.3214 ± 0.0029	0.2772 ± 0.0035	0.2414 ± 0.0011	0.1919 ± 0.0012	0.1336 ± 0.0035	0.1016 ± 0.0024	0.1316 ± 0.0067	0.0953 ± 0.0059
MIRT	0.2304 ± 0.0012	0.1827 ± 0.0009	0.2145 ± 0.0020	0.1674 ± 0.0016	0.1250 ± 0.0002	0.0953 ± 0.0003	0.1261 ± 0.0002	0.0911 ± 0.0002
NCD	0.2074 ± 0.0012	0.1531 ± 0.0009	0.2036 ± 0.0004	0.1568 ± 0.0011	0.1264 ± 0.0008	0.0955 ± 0.0007	0.1320 ± 0.0010	0.0936 ± 0.0004
ReliCD	0.2088 ± 0.0011	0.1561 ± 0.0019	0.1997 ± 0.0005	0.1548 ± 0.0007	0.1278 ± 0.0007	0.0959 ± 0.0006	0.1308 ± 0.0006	0.0919 ± 0.0006
MGCD	0.2061 ± 0.0012	0.1524 ± 0.0016	0.2022 ± 0.0017	0.1554 ± 0.0022	0.1212 ± 0.0012	0.0927 ± 0.0006	0.1192 ± 0.0013	0.0856 ± 0.0007
RGCN	0.2145 ± 0.0005	0.1622 ± 0.0027	0.2035 ± 0.0011	0.1565 ± 0.0011	0.1260 ± 0.0011	0.0957 ± 0.0010	0.1242 ± 0.0005	0.0893 ± 0.0006
GATv2	0.2123 ± 0.0046	0.1594 ± 0.0018	0.2026 ± 0.0018	0.1542 ± 0.0014	0.1236 ± 0.0026	0.0940 ± 0.0023	0.1153 ± 0.0005	0.0829 ± 0.0014
SGL	0.2072 ± 0.0011	0.1578 ± 0.0021	0.2092 ± 0.0006	0.1582 ± 0.0008	0.1320 ± 0.0006	0.1004 ± 0.0004	0.1384 ± 0.0011	0.0992 ± 0.0009
RocSE	0.2076 ± 0.0012	0.1543 ± 0.0016	0.2066 ± 0.0005	0.1555 ± 0.0008	0.1312 ± 0.0009	0.1005 ± 0.0007	0.1342 ± 0.0005	0.0959 ± 0.0004
DGCD	0.1977 ± 0.0023	0.1437 ± 0.0022	0.1929 ± 0.0009	0.1495 ± 0.0014	0.1127 ± 0.0007	0.0859 ± 0.0005	0.1072 ± 0.0010	0.0762 ± 0.0010


- 评估DGCD的**不同模块**在不同数据集上的表现

- w/o AD : 仅使用熵加权平衡模块
- w/o EB : 仅使用自适应去噪模块
- DGCD的两个模块在正确性上均发挥了作用



- 评估DGCD的**不同训练参数**在不同数据集上的表现

- λ_{kl} : 学生-练习边可靠性建模中 $\mathcal{L}_{kl}$ 权重
- t : 松散Bernoulli采样过程的温度参数
- 当 $t = 0.67$ 时, 在ASSIT12上实现最佳性能
- 当 λ_{kl} 设置为 $1e-3$ 时, 在ASSIST12上观察到最佳性能



- 算法贡献

- 建立自适应图去噪模块：建模学生-练习边的可靠性，根据可靠性概论去除存在噪声的学生-练习边
 - 有效缓解了GSE图存在的噪声问题，减小了对诊断结果的影响
- 提出熵加权平衡方法：在消息传递过程中计算不同关系聚合的信息熵，并计算不同关系信息熵之间的权重
 - 缓解消息传递中关系不平衡导致的信息偏差

- 算法不足

- 概念间存在大量且复杂的关系，GSE图并未充分利用这些关系





RDGT: Enhancing Group Cognitive Diagnosis With Relation-Guided Dual-Side Graph Transformer




T	目标	诊断群体和学生对特定知识概念的熟练程度
I	输入	群体-学生关系记录、学生练习交互记录(答题情况、练习编号、概念编号) 教育数据集*5: SLP-Bio (56万交互) SLP-Math (92万交互) ASSIST-2012 (270万交互) NIPS_Edu (320万交互) SLP-Physics (75万交互)
P	处理	1. 构建学生测和练习测双侧关系图，根据学生-练习交互相似性调整边权重 2. 引入两个关系引导图转换器，整合群体信息到关系图中学习学生的相似性 3. 认知交互过程模拟
O	输出	学生和群体的认知状态结果(用连续变量表示，范围从0到1)

P	问题	1. 现有方法未充分利用响应日志，难以有效建模群体能力 2. 不同小组之间学生可能存在跨组相似性，这些“跨组信息”未被充分利用
C	条件	学生与练习的响应日志、练习与概念对应关系的Q矩阵
D	难点	1. 如何弥补群体-习题交互的稀疏性，更全面地捕捉群体认知特征 2. 如何获取学生间的跨组相似性并加以利用
L	水平	2024 CCF A类

- 算法原理图

- 构建学生测和练习测**双侧关系图**，根据学生-练习交互相似性调整边权重
- 引入两个**关系引导图转换器**，整合群体信息到关系图中学习学生的相似性
- 认知交互过程模拟



- 现有方法存在问题
 - 数据稀疏：小组-习题交互往往数量有限，难以学习可靠的群体表示
 - 潜在关系未利用：学生之间、习题之间存在潜在相似性，没有充分利用
- 解决思路
 - 从“学生侧”和“习题侧”分别构建关系图，让模型能显式学习学生-学生关系和习题-习题关系
 - 学生侧关系图构建
 - 对于两个学生 u 和 v ，如果他们在一组习题上的作答行为相似，他们可能存在协同学习或认知水平上的相关性
 - 练习侧关系图构建
 - 对于两个练习 i 和 j ，如果它们对应的学生作答行为相似，两者之间可能存在“隐性关系”

• 解决方法

– 学生侧关系图构建

- 定义学生 u 和 v 的共同邻居集合

$$N_{u,v} = \{t | t \text{ 是学生 } u, v \text{ 共同作答过的习题}\}$$

- 学生 u, v 在习题 t 上的特征表示为

$$m_u = [m_{u,t_1}, m_{u,t_2}, \dots, m_{u,t_{|N_{u,v}|}}]$$

$$m_v = [m_{v,t_1}, m_{v,t_2}, \dots, m_{v,t_{|N_{u,v}|}}]$$

- 计算二者的作答相似度


$$d_{u,v} = \text{sim}(m_u, m_v)$$

余弦相似度函数

- 以 $d_{u,v}$ 为边权重，构建关系图

$$G^S = (X^S, Z^S)$$

X^S 为学生节点特征矩阵
 Z^S 为边权重矩阵



• 解决方法

– 练习侧关系图构建

- 定义学生 i 和 j 的共同邻居集合

$$N_{i,j} = \{t | t \text{ 是作答过这两道题的学生}\}$$

- 习题 i, j 在学生 t 上的特征表示为

$$n_i = [n_{i,t_1}, n_{i,t_2}, \dots, n_{i,t_{|N_{i,j}|}}]$$

$$n_j = [n_{j,t_1}, n_{j,t_2}, \dots, n_{j,t_{|N_{i,j}|}}]$$

- 计算二者的作答相似度


$$d_{i,j} = \text{sim}(n_i, n_j)$$

余弦相似度函数

- 以 $d_{i,j}$ 为边权重，构建关系图


$$G^E = (X^E, Z^E)$$

X^E 为练习节点特征矩阵
 Z^E 为边权重矩阵



- 现有方法存在问题
 - 图学习存在误差：传统Transformer计算关注度时，依赖节点的特征向量相似性，没有考虑图结构中的边信息，无法捕捉学生与习题的复杂耦合关系

- 解决方法
 - 构建关系引导的图学习：引入关系编码，基于边的相似度构建引导偏置
 - 关系编码建立
 - 跨组信息增强



• 解决方法

– 构建关系引导的图学习：引入关系编码，基于边的相似度构建引导偏置

• 关系编码建立

– 学生侧：根据边相似度矩阵 Z^S 计算关系注意力分数

$z_{u,v}^S$ 为学生 u 和 v 的边权重

$$b_{u,v}^S = \sigma \left((z_{u,v}^S h_1^S + b_1^S)^T h_2^S + b_2^S \right)$$

$$A_{l,k}^S = \text{softmax} \left(\frac{Q_{l,k}^S (K_{l,k}^S)^T}{\sqrt{d_h}} + B^S \right)$$

$B^S = \{b_{u,v}^S\}$, 是关系注意力矩阵

– 练习侧：根据边相似度矩阵 Z^E 计算关系注意力分数

$$b_{i,j}^E = \sigma \left((z_{i,j}^E h_1^S + b_1^S)^T h_2^S + b_2^S \right) \quad A_{l,k}^E = \text{softmax} \left(\frac{Q_{l,k}^E (K_{l,k}^E)^T}{\sqrt{d_h}} + B^E \right)$$

• 跨组信息增强

- 解决方法

- 构建关系引导的图学习：引入关系编码，基于边的相似度构建引导偏置

- 关系编码建立

- 组级信息增强

- 利用群组节点连接组内学生节点，实现组内信息的传播

λ_j 是学生对群体能力的贡献权重

$$x_g^G = \sum_j \lambda_j x_j^S$$

x_g^S 是虚拟群体节点表示

$$\lambda_j = \frac{\exp(\tilde{\lambda}_j)}{\sum_j \exp(\tilde{\lambda}_j)}, \quad \tilde{\lambda}_j = \text{ReLU} \left((x_j^S)^T W_k + x_g^S W_q \right) h$$

给每个学生开了一扇“看向全局”的窗

数据集

数据集名称	ASSIST12	NIPS_Edu	SLP-Bio	SLP-Math	SLP-Physics
学生数量	1,078	2,415	3,052	4,173	4,314
群组数量	111	177	111	172	170
练习数量	11,564	921	120	226	115
概念数量	182	86	22	40	37
平均组大小	14.31	14.54	27.49	24.26	25.37
单组回答平均次数	9.57	35.81	55.32	73.77	81.44

评价指标

- 正确性: RMSE, MAE

基于认知诊断对比方法

- IRT (2013)
- MIRT (2009)
- MF (2010)
- NCD (2020)
- MGCD (2021)

基于图的对比方法


- RGCN (2018)
- SignedGCN (2018)
- HGT (2020)
- GATv2 (2021)
- GraphTrans (2021)

- 评估RDGT在不同数据集上的表现
 - RDGT在不同数据集中**RMSE**和**MAE**都优于对比方法

Datasets	ASSISTment12		NIPS-Edu		SLP-math		SLP-biology		SLP-physics	
Metrics	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE
IRT	0.2514	0.1996	0.2346	0.1875	0.1989	0.1504	0.2278	0.1714	0.2047	0.1616
MIRT	0.2297	0.1970	0.2442	0.1973	0.2495	0.1992	0.2183	0.1662	0.2256	0.1738
MF	0.2360	0.1768	0.2111	0.1706	0.1822	0.1456	0.2247	0.1695	0.1982	0.1526
NCD	0.2221	0.1694	0.2107	0.1654	0.1774	0.1154	0.1963	0.1461	0.1869	0.1481
MGCD	0.2124	0.1598	0.1955	0.1507	0.1789	0.1167	0.1879	0.1371	0.1815	0.1403
RGCN	0.1984	0.1603	0.2253	0.1742	0.2015	0.1538	0.2059	0.1584	0.1907	0.1494
SignedGCN	0.1896	<u>0.1346</u>	0.2038	0.1569	0.1847	0.1423	0.1967	0.1473	0.1838	0.1432
HGT	0.1911	0.1556	0.1988	0.1603	0.1826	0.1501	0.1943	0.1366	0.1896	0.1453
GraphTrans	0.1845	0.1349	0.1931	<u>0.1474</u>	0.1719	0.1114	0.1855	0.1382	0.1769	<u>0.1345</u>
GATv2	<u>0.1836</u>	0.1401	0.1939	0.1485	0.1689	<u>0.1001</u>	<u>0.1837</u>	<u>0.1353</u>	0.1799	0.1389
RDGT-Int	0.1969	0.1411	<u>0.1924</u>	0.1476	<u>0.1670</u>	0.1064	0.1866	0.1378	<u>0.1758</u>	0.1366
RDGT	0.1747	0.1266	0.1819	0.1371	0.1566	0.0954	0.1738	0.1297	0.1643	0.1128


- 评估RDGT的**不同模块**在不同数据集上的表现

- RDGT-S: 仅使用学生侧关系图进行建模
- RDGT-S+: 使用学生侧关系图和组信息进行建模
- RDGT-SE: 表示双侧关系图（学生侧和练习侧）的并发利用，同时丢弃组间信息
- **RDGT-S表现出最明显的下降趋势**





- 评估RDGT使用不同**注意力聚合群体表示**的表现


- 最大最小池化：性能出现明显下降
- **群体结构体现了丰富的信息，而特定的个体不能简单地取代群体表示**




- 缺失数据/有限抽样场景测试
 - 聚类每个小组的学生表示，分成若干子群（反映不同能力层次）
 - 从每个子群里挑出最“靠近中心”的代表性学生，再按比例抽取不同数量的学生来聚合成小组表示
 - 比较预测性能随着“代表性学生比例下降”的变化
 - RDGT能识别代表性学生，减少答题人数仍能维持高诊断精度



- 潜在协助关系挖掘实验
 - 提取最后一层Transformer中学生间的注意力权重，当作“学生间联系强度”
 - 权重大 = 学生之间可能有相似的答题模式或学习影响
 - 以学生为节点，注意力分数为边权重，聚类划分潜在的子群体
 - 一些学生之间的联系更强，说明他们可能形成“互相影响的小圈子”
 - 小组内多样化的子群，可能意味着更多的互补和交流，从而提升整体学习效果



(a)



(b)

- 算法贡献

- **建立双侧关系图**：构建学生侧与练习侧关系图，并根据节点相似度寻找作答情况相似的节点群
 - 充分挖掘学生-学生、练习-练习之间的**潜在关系**
- **构建关系引导式图学习**：引入关系编码，基于边的相似度构建引导偏置，在图学习时充分考虑图结构关系，并实现**跨组信息交互**
 - 有效捕捉学生与习题的复杂耦合关系

- 算法不足

- 构图和注意力计算的复杂度过高，**真实场景难以部署**
 - 学生侧和习题侧构建**完全图**，再叠加多头注意力和跨组增强
- 对相似度的依赖过强，容易**放大噪声**
 - 没有在机制上抑制噪声传播，对数据质量过于敏感





特点总结与未来展望

- 特点总结

- DGCD

- 考虑学生作答记录存在**偶然性**，建立自适应去噪机制，并提出熵关系平衡方法
 - 有效缓解了GSE图中的**噪声问题**，并实现不同节点间消息关系的**熵平衡**

- RDGT

- 考虑学生内部与练习之间存在**作答相似性**，建立关系引导的双侧图学习，并提出跨组信息交互增强
 - 有效捕捉群体-学生-习题之间的**深层关系**

- 未来发展

- 如何在GSE图的基础上引入更多更全面的异构关系
 - 如何在**无固定的节点相似度**的情况下构建自适应边权的关系图



- [1] Ma H, Song S, Qin C, et al. DGCD: An Adaptive Denoising GNN for Group-level Cognitive Diagnosis. Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence[C]. Jeju, South Korea: International Joint Conferences on Artificial Intelligence Organization, 2024: 2261-2269.**
- [2] Yu X, Qin C, Shen D, et al. RDGT: Enhancing Group Cognitive Diagnosis With Relation-Guided Dual-Side Graph Transformer[J]. IEEE Transactions on Knowledge and Data Engineering, 2024, 36(7): 3429-3442.**
- [3] Wang F, Liu Q, Chen E, et al. Neural cognitive diagnosis for intelligent education systems[C]. In Proceedings of the AAAI conference on artificial intelligence. 2020, 34: 6153–6161.**

知人者智，自知者明。胜人者有力，自胜者强。知足者富。强行者有志。不失其所者久。死而不亡者，寿。

谢谢！

