

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



增强认知诊断结果的可解释性

硕士研究生 邢倚康

2024年10月13日

- 相关内容
 - 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
 - QCCDM
 - ORCDF
- 特点总结与未来展望
- 参考文献

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

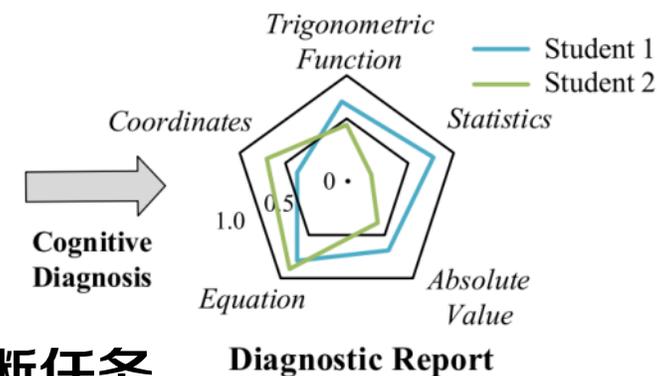
• 内涵解析

- **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)
- **认知诊断结果的可解释性**: 不同学生对不同知识概念的熟练程度应符合实际情况
 - 存在**前提关系**的一对概念, 其熟练程度应具有**正相关性**
 - 不同学生对于知识概念的熟练程度应具有一定**差异性**



Student	Exercise	e ₁	e ₂	e ₃	e ₄
Student 1	Exercise				
Student 1	Response	✓	✓	✗	✓
Student 2	Exercise	e ₂	e ₃	e ₄	e ₅
Student 2	Response	✗	✓	✓	✗

Response Logs



• 研究目标

- 以**学习者建模**为研究对象, 面向智能教育系统中的认知诊断任务
- 结合**深度学习、图神经网络**等技术
- 深入分析学习者的**认知状态**, 增强其**可解释性**, 为教学设计、个性化学习路径推荐等下游任务提供更准确的支持和指导

- 研究背景

- 传统教学模式下，由于**时间**和**空间**的限制，教师无法为每一个学生都制定**个性化**学习方案
- **智能教育系统**广泛应用，通过分析大量的在线数据帮助学生找准知识上的**薄弱点**，提供个性化学习方案
- 越来越多的学生通过在线学习的方式来提升自己的知识水平，我国在线教育用户规模已达**4.23**亿，规模空前

- 研究意义

- 深入分析学习者的**认知状态**，为教学设计、个性化学习路径推荐等下游任务提供更准确的支持和指导
- 深化智能教学系统，致力于**优化**学习者的**个性化学习体验**，具有重要的**理论意义**



研究历史与现状



Frederic提出了**IRT**模型，综合考虑学生能力、练习难度、练习区分度以及猜测度因素，评估学生的能力水平并预测答题情况

Reckase提出了**MIRT**，将学习者的能力水平由单个维度扩展到多个维度，每个维度都可以独立地影响个体在项目上的表现

Wang等提出了**CDGK**，运用神经网络捕捉练习特征、学习者分数和学习者对概念熟练程度之间的相互作用，并将概念转换为图结构来聚合概念

Wang等提出了**KaNCD**，采用基于表示的方法对知识关联进行隐式建模，有效解决认知诊断中的知识覆盖问题

Qian等提出了**ORCDF**，即抗过度平滑的认知诊断框架

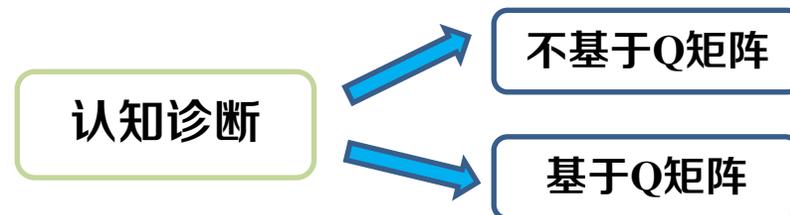
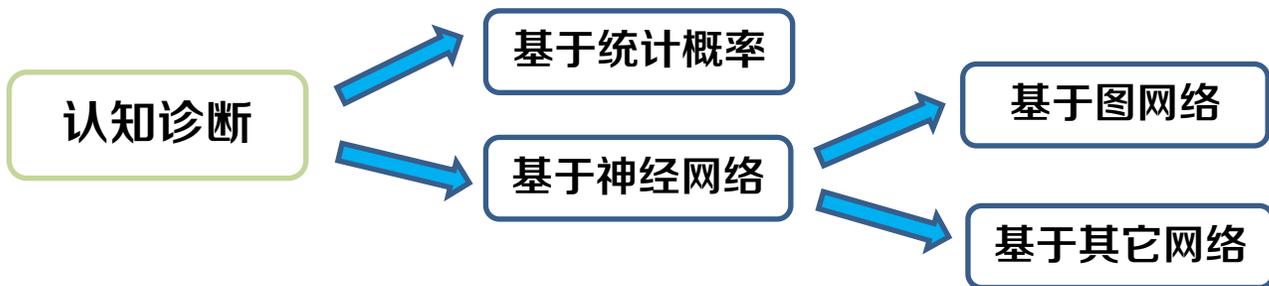


Junker提出了**DINA**模型，使用人工标注Q矩阵表示练习和概念之间的相关性，并考虑学习者在回答练习时的**猜测**和**失误**因素

Wang等提出神经认知诊断框架NeuralCDM，**首次通过神经网络**来学习学习者与练习之间复杂的交互，使用单调性假设来确保模型可解释性

Su等提出了**GCDM**，通过异构认知图传播学生的认知状态，并选择性地聚合来自相邻图节点的消息

Liu等提出了**QCCDM**，即Q矩阵增强因果认知诊断模型



• 认知诊断

– 挖掘学习者**行为、心理和认知**之间的关系，利用学习者的**学习数据**，对其**认知状态**进行综合评估和诊断

- 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：学生对于**知识概念的熟练程度**

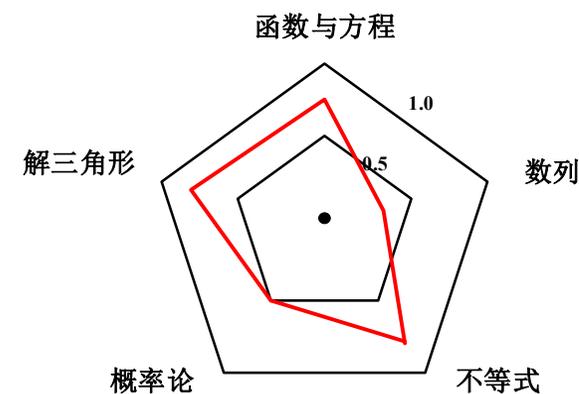
– 元素定义

- 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： $K = \{k_1, k_2, k_3, \dots, k_K\}$
- 响应日志： $R = \{(s, e, r) | s \in S, e \in E, r \in \{0, 1\}\}$
- Q矩阵： $Q = \{Q_{i,j} \in \{0, 1\}\}_{M \times K}$



Exercise	e ₁	e ₂	e ₃	e ₄
Response				

	k ₁	k ₂	k ₃	k ₄	k ₅
e ₁	1	0	0	0	0
e ₂	0	1	0	1	0
e ₃	0	0	1	0	0
e ₄	0	0	1	0	1



- 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 of the IRT model:

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

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

- 多维项目反应理论 (MIRT)
 - 假设个体的能力不是单一维度的，而是由多个维度（如数学能力、语言能力、推理能力等）组成
 - 由单个维度扩展到多个维度，每个维度都可以独立地影响个体在测试项目上的表现



• 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

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

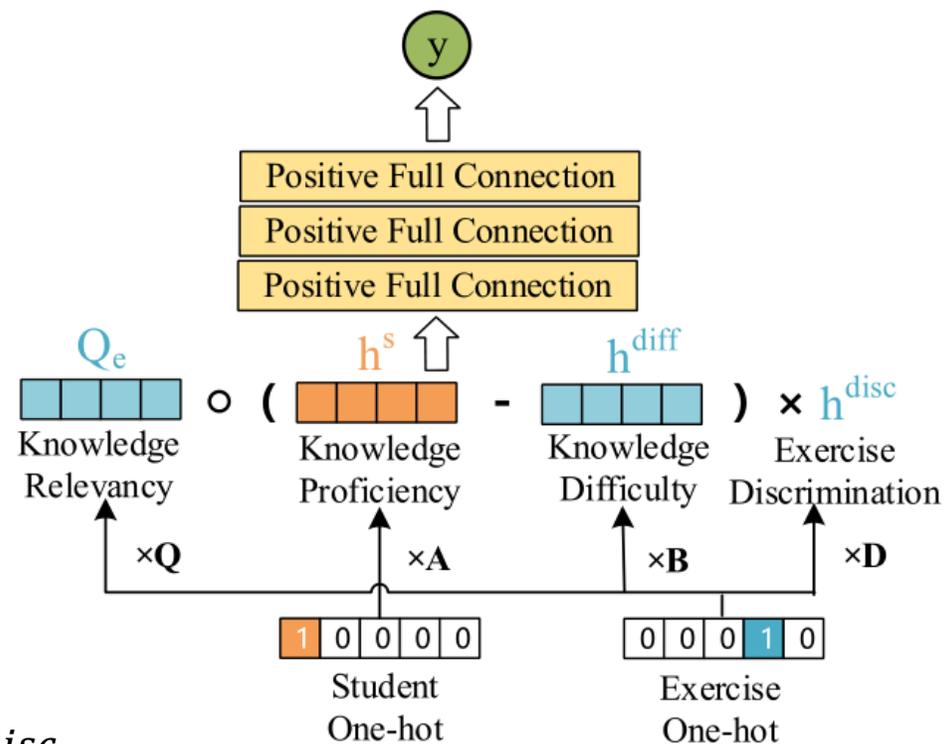
• 练习区分度向量

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

– 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
 - 由于学生对于知识概念的掌握程度难以准确衡量，因此一般通过**学生回答练习的结果预测**是否正确来评估认知诊断方法的准确率
 - 从分类和回归的角度采用不同的衡量指标
 - 从**分类**的角度来看，学生回答错误或正确可以分别表示为0和1
 - 预测准确率**ACC**
 - ROC曲线下面积**AUC**
 - **F1值**：综合评估精确率与召回率
 - 从**回归**的角度来看，量化预测分数（范围从0到1）与实际分数之间的距离
 - 均方根误差**RMSE**



- 可解释性评价指标

- 一致性度量 (DOA)

- 如果学生 s_u 在回答与知识概念 C_k 相关的问题时比学生 s_v 有更高的准确性，那么 s_u 掌握概念 C_k 的概率应该高于 s_v

- 如果 $Mas_{uk} > Mas_{vk}$ ，那么响应日志中对于都包含概念 k 且两人都做过并且回答不同

- 的练习，应该有 $\frac{s_u \text{ 答对而 } s_v \text{ 答错的练习数量}}{s_u \text{ 和 } s_v \text{ 回答不同的练习数量}} = 1$

$$DOA_k = \frac{\sum_{u,v \in S} \delta(Mas_{uk}, Mas_{vk}) \frac{\sum_{j=1}^L q_{jk} \wedge J(j, u, v) \wedge \delta(y_{uj}, y_{vj})}{\sum_{j=1}^L q_{jk} \wedge J(j, u, v) \wedge I(y_{uj} \neq y_{vj})}}{\sum_{u,v \in S} \delta(Mas_{uk}, Mas_{vk}) I(\sum_{j=1}^L q_{jk} \wedge J(j, u, v) \wedge I(y_{uj} \neq y_{vj}) > 0)}$$

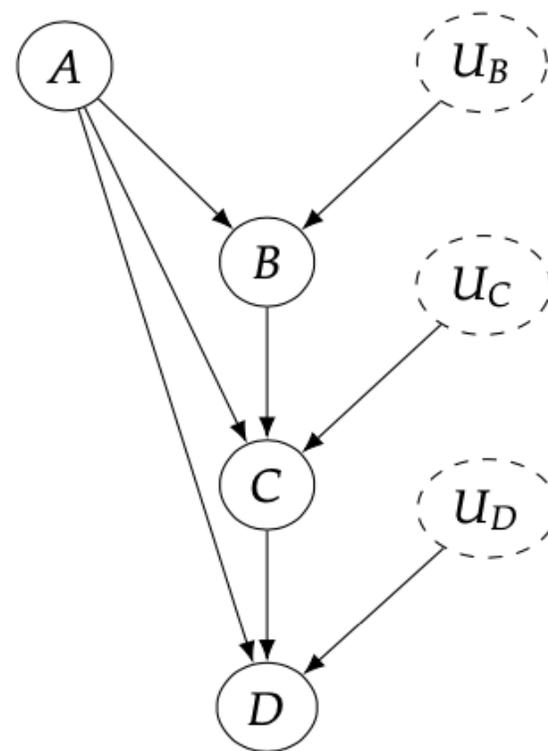
if $Mas_{uk} > Mas_{vk}$, $\delta(Mas_{uk}, Mas_{vk}) = 1$; otherwise, $\delta(Mas_{uk}, Mas_{vk}) = 0$

- 结构因果模型 (SCM)

- **因果关系**: 一个变量 (因) 的变化会导致另一个变量 (果) 的变化, SCM旨在明确地表示这种关系, 而不仅仅是变量之间的相关性
- 结构因果模型强调**单向**的因果关系
- 结构方程

$$Y = f(X_1, X_2, \dots, X_k, \sigma)$$

- Y 表示**结果变量**
- X_1, X_2, \dots, X_k 表示直接影响 Y 的**原因变量**
- σ 表示未观察到因素的**随机扰动**
- 因果图
 - 有向无环图
 - 严格按照箭头方向推理





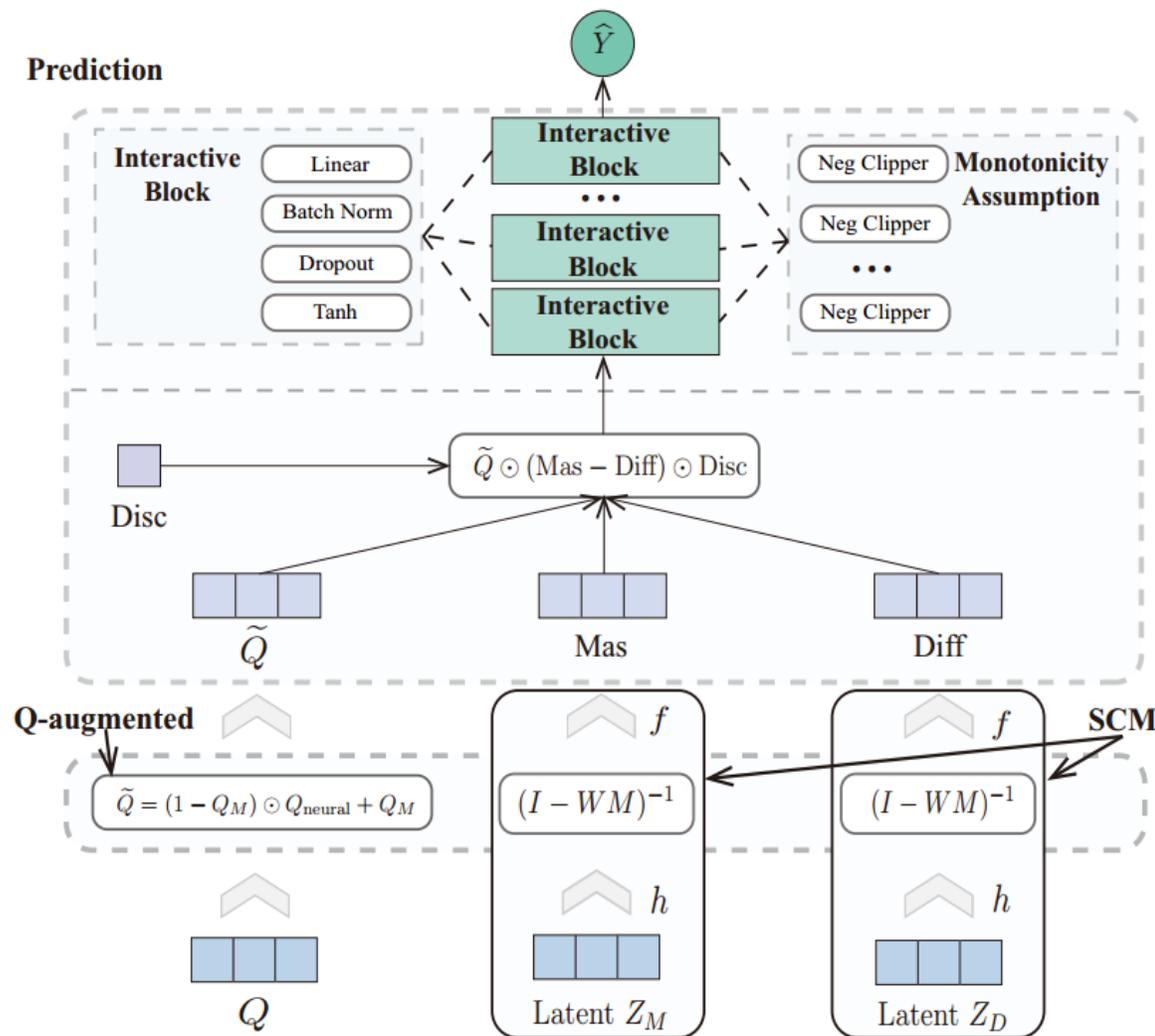
QCCDM: A Q-Augmented Causal Cognitive Diagnosis Model for Student Learning

T	目标	诊断学生对特定 知识概念 的熟练程度
I	输入	学生与练习的响应日志（Junyi 408k, Math1 63k, Math2 58k）、练习与概念对应关系的Q矩阵（Junyi 734-734, Math1 15-11, Math2 16-16），专家标注的概念间前提关系（Junyi 927, Math1 21, Math2 36）
P	处理	<ol style="list-style-type: none"> 1. 建立结构因果模型（SCM）捕获概念间的因果关系及潜在因素影响，构建学生能力向量、练习难度向量、练习区分度向量 2. 捕获练习与潜在概念之间的联系，得到增强Q矩阵 3. 认知交互过程模拟
O	输出	练习回答结果（正、误）、特定知识概念的熟练程度（范围从0到1）
P	问题	<ol style="list-style-type: none"> 1. 现有方法存在知识覆盖问题，对于弱概念熟练程度的推断效果较差 2. 现有方法忽视了练习与潜在概念之间的关系
C	条件	需要有专家标注的概念间前提关系
D	难点	<ol style="list-style-type: none"> 1. 如何对弱概念的熟练程度进行合理推断，增强其可解释性 2. 如何充分挖掘练习与潜在概念之间的关系
L	水平	2023 CCF B类

• 算法原理图

- 根据概念间的前提关系构建因果图，并建立**结构因果模型 (SCM)**，构建学生能力向量、练习难度向量、练习区分度向量
- 构建**增强Q矩阵**，添加正则化项作为约束
- 认知交互过程模拟

关键向量学习
交互模拟



- 现有方法存在问题

- **知识覆盖问题**: 在实际做题的过程中, 学生做的题目数量有限, 不可能涉及到所有知识概念的现象, 未涉及到或涉及极少的概念称为**弱概念**
- 根本原因: Q矩阵粒度细化带来的稀疏性

- KaNCD的解决方法

- **假设所有的知识概念都是相互关联的**, 即都存在某种隐性关系, 通过神经网络训练来推断弱概念的掌握程度
- 存在问题:
 - 所有知识概念之间都存在联系是不合理的, 如三角函数与三变量线性方程
 - 过多的隐性关系会导致推断效果下降

数学、物理、化学
数列、方程、不等式
等差数列、等比数列



- 解决方法

- 因果属性层次：概念间的前提关系，如单变量微积分和多变量微积分

- 结构因果模型 (SCM)

- 概念间的前提关系构建因果图（有向无环图，父节点与子节点）

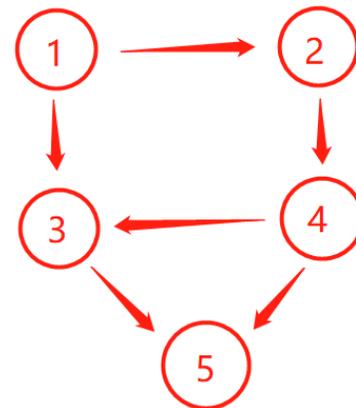
- 利用无系数的因果图作为先验，并捕获知识概念的掌握程度与潜在因素（如勤奋、学习策略和学习环境）之间的关系

$$Mas_{i,a_c} = \sum_{a_j \in Pa(a_c)} Mas_{i,a_j} \varepsilon_{j_c} + Z_{i,a_c}$$

$Pa(a_c)$ 表示概念 a_c 节点的父节点集合

ε_{j_c} 表示节点之间边的权重

Z 表示潜在因素



- 现有方法存在问题

- Q矩阵由专家标注，但练习与概念之间存在一些潜在关系，难以被专家标注，例如：

$$\cos(x) = \frac{\sqrt{5} - 1}{2}, 0 \leq x \leq 0.5\pi, \text{ 求 } \sin(x) \quad \text{三角函数}$$

- Q矩阵粒度细化，增加了专家标注的难度

- 解决方法

- **增强Q矩阵**：表示练习与知识概念之间的关系，包括显式关系和潜在关系

$$\tilde{Q}: \tilde{Q}_{ij} = 1, \text{ if } Q_{ij} = 1$$
$$\tilde{Q}_{ij} = \epsilon \in [0,1], \text{ if } Q_{ij} = 0$$

- 解决方法

- 增强Q矩阵：表示练习与知识概念之间的关系，包括显式关系和潜在关系

$$\tilde{Q}: \tilde{Q}_{ij} = 1, \text{ if } Q_{ij} = 1$$

$$\tilde{Q}_{ij} = \epsilon \in [0,1], \text{ if } Q_{ij} = 0$$

- 在训练过程中保证专家标注的**显式关系不被模糊**

专家标注Q矩阵

矩阵逐元素相乘

$$\tilde{Q} = (1 - Q_M) \cdot Q_{neural} + Q_M$$

可训练Q矩阵

- 防止学习到的Q矩阵**过于密集**，避免被不存在的潜在关系误导，添加正则化项

$$\vartheta(\tilde{Q}) = \frac{\|(1 - Q_M) \cdot Q_{neural}\|_{1,1}}{L \times K}$$

其中， L 为练习数量， K 为概念数量， $\|C\|_{1,1} = \sum_i \sum_j |C_{ij}|$ ，即矩阵中各元素的绝对值之和

- 数据集

数据集名称	Junyi	Math1	Math2
学生数量	10000	4209	3911
练习数量	734	15	16
概念数量	734	11	16
响应日志数量	408057	63135	58665
概念间 前提关系数量	927	21	36
Q矩阵稀疏性	1	3.2	3.25

- 评价指标

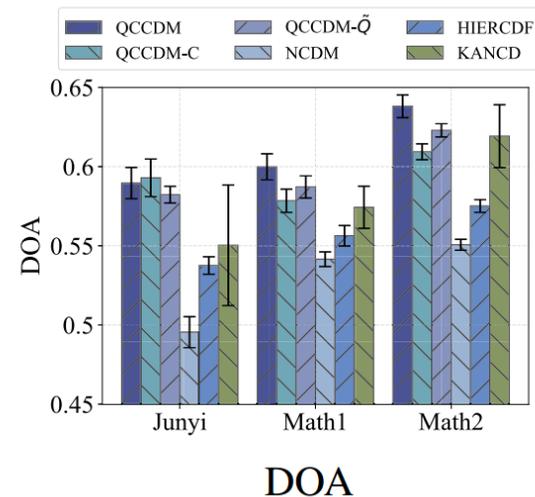
- 正确性: ACC, AUC, RMSE, F1
- 可解释性: DOA
- Spearman等级相关系数

- 对比方法

- KANCD (2023)
- HIERCDF (2022)
- RCD (2021)
- NCDM (2020)
- MIRT (2009)
- DINA (2001)

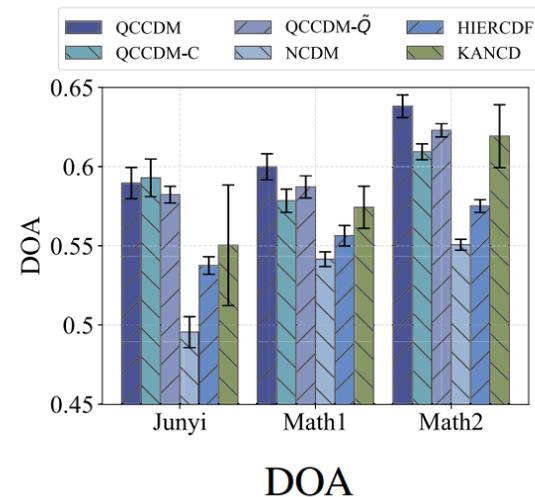
Q矩阵稀疏性是指
每个练习涉及概
念数量的平均值

- 评估QCCDM在不同数据集上的表现
 - QCCDM在不同数据集中**正确性**几乎都优于对比方法，但效果提升较小
 - QCCDM在不同数据集中**可解释性**都优于对比方法，效果提升较大



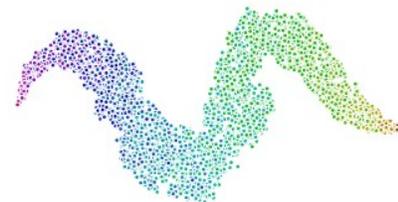
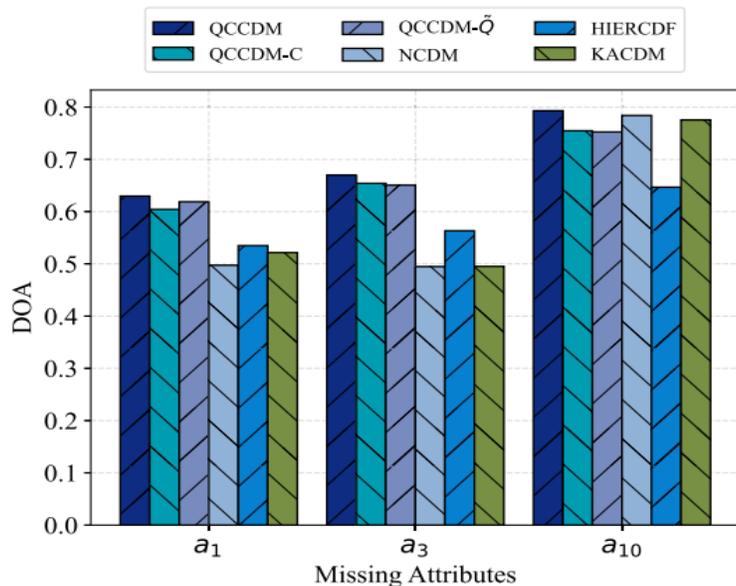
Algo.	Junyi				Math1				Math2			
	AUC	ACC	RMSE	F1	AUC	ACC	RMSE	F1	AUC	ACC	RMSE	F1
DINA	0.6353●	0.5002●	0.5263●	0.5786●	0.6795●	0.4744●	0.5456●	0.2501●	0.6831●	0.5076●	0.5390●	0.1934●
MIRT	0.7949●	0.7626●	0.4057●	0.8354●	0.7438●	0.6784●	0.4565●	0.7179	0.7683●	0.6962●	0.4495●	0.6916
NCDM	0.7839●	0.7485●	0.4106●	0.8254●	0.7450●	0.6774	0.4536●	0.7164●	0.7708●	0.6949●	0.4443●	0.6874 ●
HIERCDF	0.7848●	0.7516●	0.4098●	0.8292●	0.7426●	0.6727●	0.4528	0.7373○	0.7689●	0.6897●	0.4522●	0.6941
KANCD	0.7992●	0.7610●	0.4034●	0.8346●	0.7514	0.6835	0.4456	0.7330	0.7798	0.7005	0.4380	0.7001
RCD	0.8145●	0.7716●	0.3963	0.8348●	0.7410●	0.6779●	0.4497	0.7412○	0.7740●	0.6967●	0.4484	0.7011
QCCDM	0.8171	0.7762	0.3928	0.8445	0.7553	0.6856	0.4446	0.7232	0.7815	0.7013	0.4401	0.7020

- 评估QCCDM的不同模块在不同数据集上的表现
 - QCCDM-C: 仅使用结构因果模型 (SCM)
 - QCCDM-Q: 仅使用增强Q矩阵
 - QCCDM的两个模块在正确性及可解释性上均发挥了作用, 但F1值的效果评估并不理想

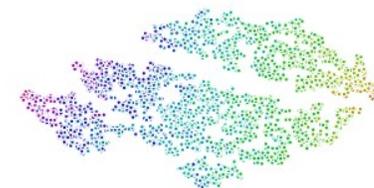


Algo.	Junyi				Math1				Math2			
	AUC	ACC	RMSE	F1	AUC	ACC	RMSE	F1	AUC	ACC	RMSE	F1
QCCDM-C	0.8060●	0.7673●	0.4013●	0.8406●	0.7462●	0.6821	0.4512	0.7425○	0.7702●	0.6912●	0.4554●	0.7140
QCCDM- \tilde{Q}	0.8165●	0.7736●	0.3949	0.8439	0.7478●	0.6831	0.4504●	0.7304●	0.7762	0.6987●	0.4440	0.7042
QCCDM	0.8171	0.7762	0.3928	0.8445	0.7553	0.6856	0.4446	0.7232	0.7815	0.7013	0.4401	0.7020

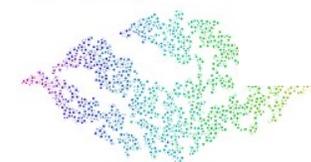
- 利用t-SNE验证QCCDM的可解释性
 - 聚类效果明显：从左到右形成了明显的纹路
 - 中等成绩学生表现出更高的离散性
- 验证弱概念的可解释性
 - 手动划分训练集与测试集形成弱概念
 - 计算弱概念的DOA



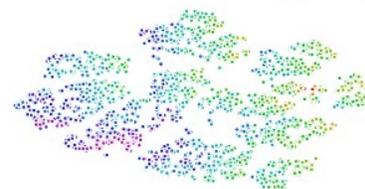
(a) t-SNE of QCCDM- \tilde{Q}



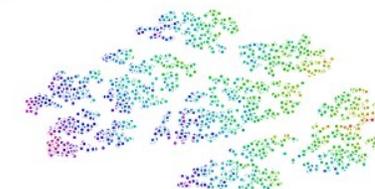
(b) t-SNE of QCCDM-C



(c) t-SNE of QCCDM



(d) t-SNE of NCDM



(e) t-SNE of HIERCDF

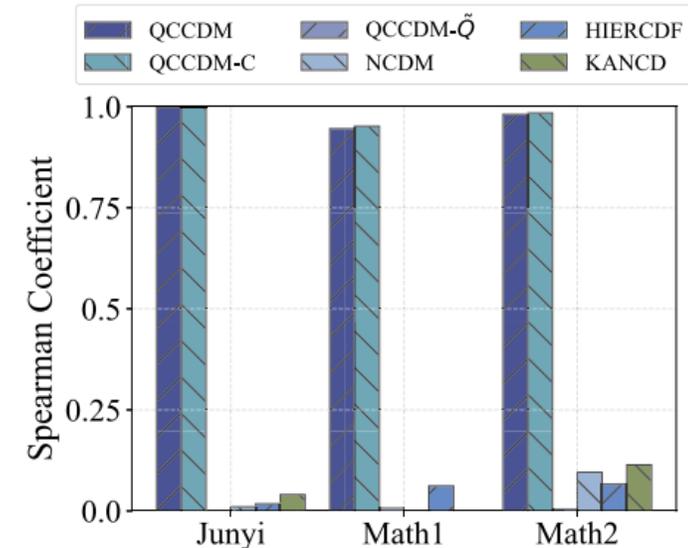
- 利用Spearman等级相关系数验证结构因果模型（SCM）的效果
 - 衡量两个变量之间的单调关系强度，通过比较数据的排名来计算相关性
 - 存在前提关系的一对概念，其熟练程度应具有相关性

$$r_s(Mas_{\blacksquare, a_p}, Mas_{\blacksquare, a_c}) = 1 - \frac{6 \sum_{i=1}^N d_i^2}{N(N^2-1)}, \quad d_i = rank(Mas_{a_p}) - rank(Mas_{a_c})$$

其中， p 表示父概念， c 表示子概念， N 表示样本数，系数 $r_s \in [-1, 1]$

学生	Mas_{a_p}	Mas_{a_c}	$rank(a_p)$	$rank(a_c)$	d_i	d_i^2
A	0.9	0.1	1	5	-4	16
B	0.8	0.3	2	3	-1	1
C	0.7	0.2	3	4	-1	1
D	0.6	0.4	4	2	2	4
F	0.5	0.5	5	1	4	16

系数为 -0.9，负相关性



- 算法贡献
 - **建立结构因果模型 (SCM)**：根据概念间的前提关系构建因果图，利用无系数的因果图作为先验，并捕获知识概念的掌握程度与潜在因素之间的关系
 - 有效缓解了知识覆盖问题，增强了对于弱概念诊断效果的正确性以及可解释性
 - **提出增强Q矩阵**：捕获练习与潜在概念之间的关系
 - 增强了诊断结果的正确性与可解释性
- 算法不足
 - 概念间存在大量且复杂的关系，除了前提关系外，还包括**相似关系**等，这些关系未得到充分利用
 - 需要**专家标注**的概念间关系，耗费大量的时间、人力资源等





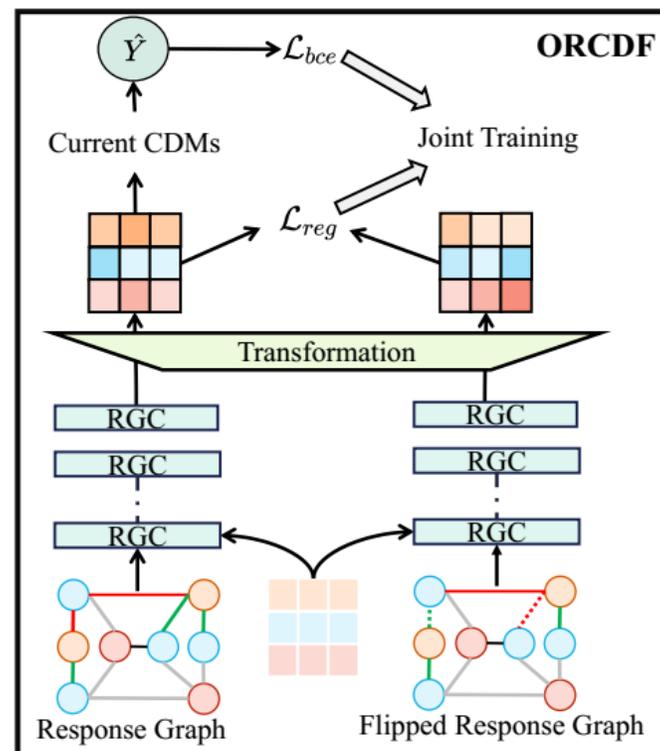
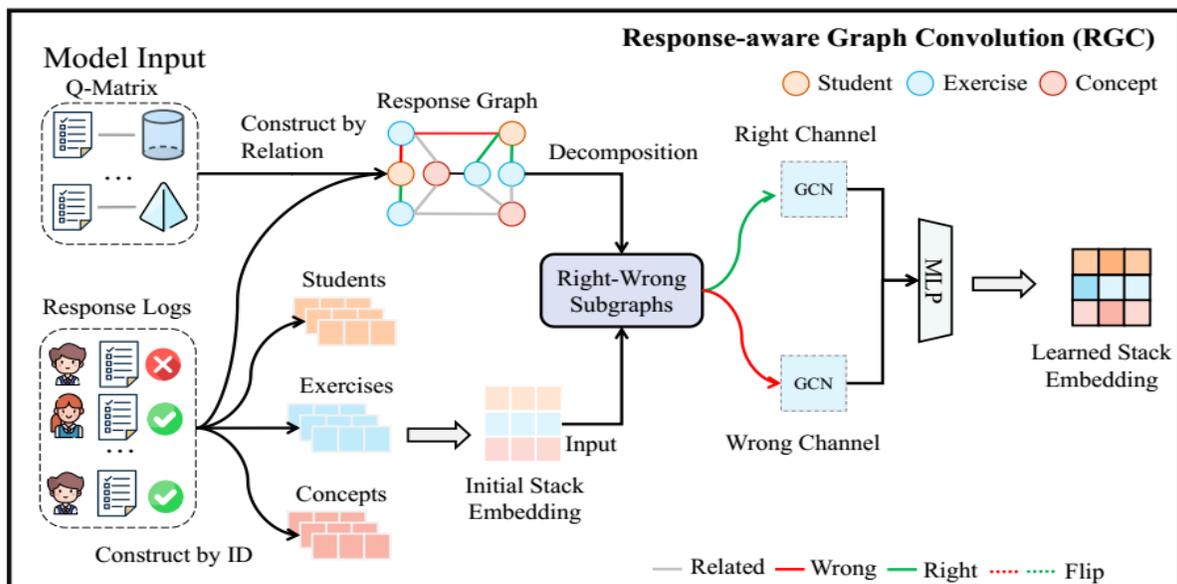
**An Oversmoothing-Resistant Cognitive Diagnosis
Framework for Student Learning in Online Education Systems**

T	目标	诊断学生对特定 知识概念 的熟练程度
I	输入	学生与练习的响应日志（ Assist 390k, EdNet 616k, Junyi 408k, XES3G5M 1174k ）、练习与概念对应关系的Q矩阵（ Assist 3162-102, EdNet 11925-189, Junyi 734-734, XES3G5M 7191-832 ）
P	处理	<ol style="list-style-type: none"> 构建响应感知图并进行正误子图分解，利用卷积操作学习学生、练习、概念的嵌入表示 以一定的比例随机翻转响应感知图中的学生练习边，并构建损失函数确保在存在不同噪声的情况下学习的一致性 认知交互过程模拟
O	输出	练习回答结果（正、误）、特定知识概念的熟练程度（范围从0到1）

P	问题	<ol style="list-style-type: none"> 现有方法未充分利用响应日志，存在过平滑问题 由于猜测、失误等因素影响，学生答题结果会发生变化，产生噪声干扰
C	条件	需要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	<ol style="list-style-type: none"> 如何缓解认知诊断中的过平滑问题 如何缓解由于猜测、失误等因素造成的噪声干扰
L	水平	2024 CCFA类

• 算法原理图

- 构建响应感知图并进行正误子图分解，利用卷积操作学习学生、练习、概念的嵌入表示
- 以一定的比例随机翻转响应感知图中的学生练习边，并构建损失函数确保在存在不同噪声的情况下学习的一致性
- 认知交互过程模拟

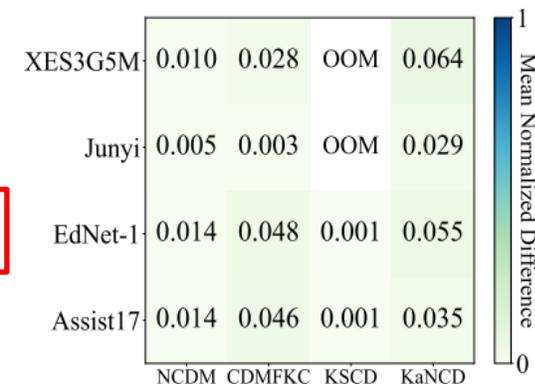




• 现有方法存在问题

- **过平滑问题**: 学生对于知识概念的掌握程度过于相似, 可解释性下降, 无法为下游任务提供有力的指导
- **过平滑程度度量**: 均值归一化差 (MND)

MND值越大, 差异越大

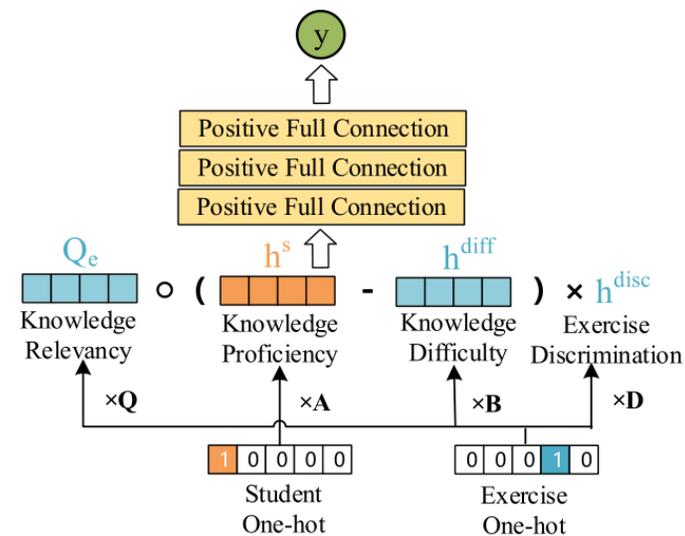


$$MND = \frac{1}{|S|} \frac{1}{|S| - 1} \sum_{S_u \in S} \sum_{S_v \in S} \frac{\|Mas_{S_u} - Mas_{S_v}\|_2^2}{|C|}$$

学生集合

概念集合

- 图表示学习中的过平滑问题: 层数加深, 节点的代表越来越平滑
- 认知诊断中的过平滑问题: 在学习部分很少利用响应日志, 而在交互部分只将其作为标签



• 解决方法

– 响应感知图卷积 (RGC)

- 构建响应感知图
- 正误子图分解
- 利用卷积操作学习嵌入表示

规范化作用，平衡不同度数的节点在传递中的权重

$$H^{(l)} = \hat{A}H^{(l-1)}, \hat{A} = \left(D^{-\frac{1}{2}} \hat{A} D^{-\frac{1}{2}} \right)$$

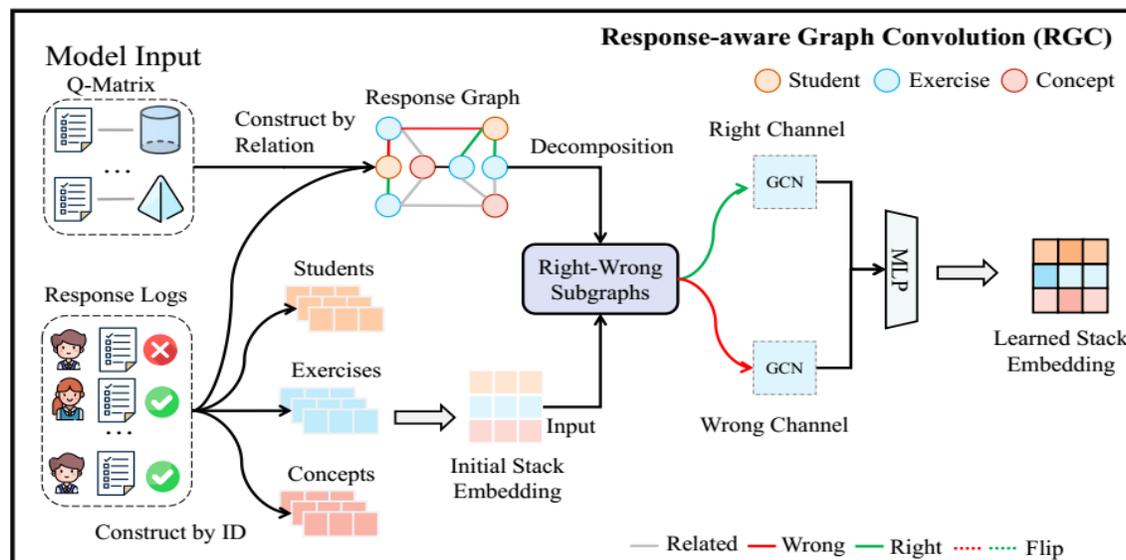
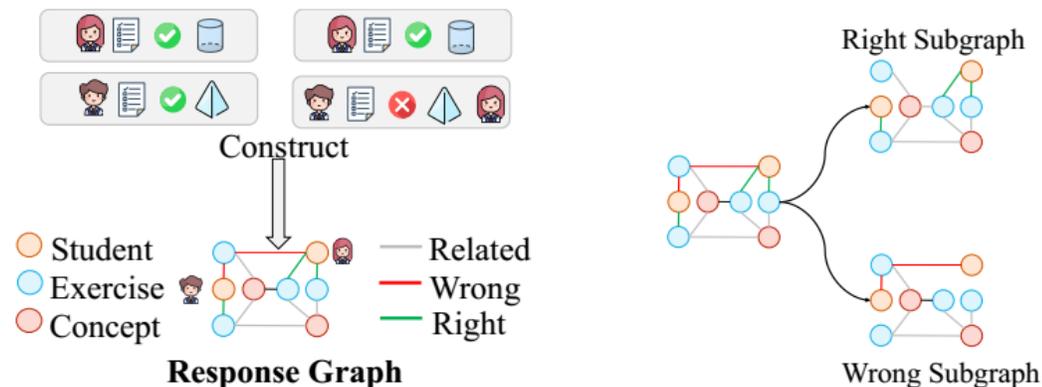
\hat{A} : 带有自环的邻接矩阵

D : 对角矩阵，表示节点的度数

$$H_F^{(l)} = \varphi \left(H_R^{(l)} W_{rc} + H_W^{(l)} W_{wc} \right)$$

$$H = \frac{1}{1 + L} \left(H_F^{(0)} + H_F^{(1)} + \dots + H_F^{(L)} \right)$$

取每层RGC的结果进行平均池化操作



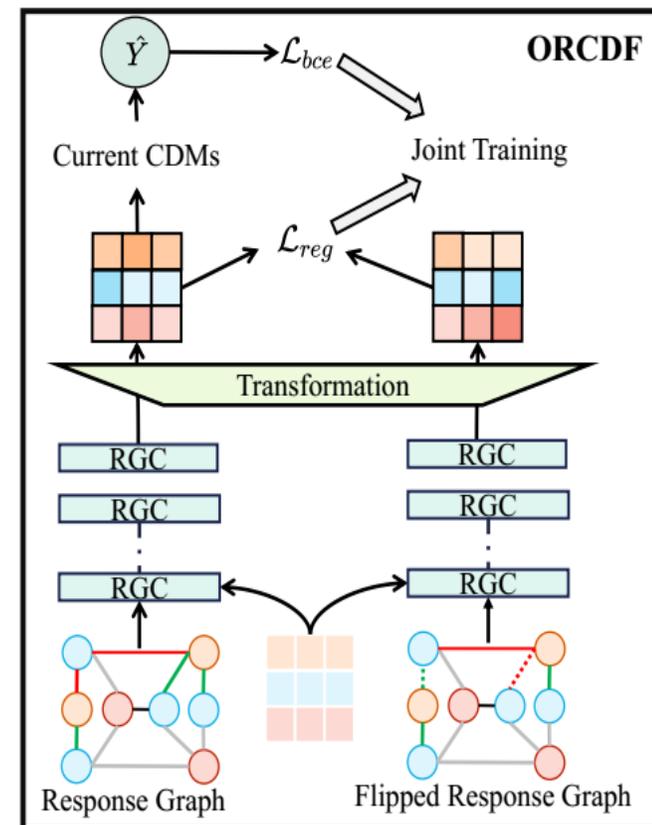
- 现有方法存在问题

- 猜测、失误等因素造成的噪声干扰：学生可能通过猜测来答对自己并没有掌握的题目，也可能因为粗心答错自己掌握的题目，产生了噪声干扰
- 在学习过程中利用响应日志加剧了噪声的干扰

- 解决方法

- 一致性损失函数构建：以一定的比例 p_f 随机翻转响应感知图中的学生练习边，并构建损失函数确保在存在不同噪声的情况下学习的一致性

$$L_{reg} = - \sum_{S_a \in S} \log \left(\exp(h'_{S_a} h_{S_a}^T / \tau) \right)$$



- 数据集

数据集名称	Assist 17	EdNet-1	Junyi	XES3G5M
学生数量	1709	1776	10000	4000
练习数量	3162	11925	734	7191
概念数量	102	189	734	832
响应日志数量	390311	616193	408057	1174514
平均正确率	0.815	0.662	0.687	0.799
Q矩阵稀疏性	1.22	2.25	1.0	1.16

- 评价指标

- 正确性: ACC, AUC
- 可解释性: DOA
- MND (均值归一化差, 衡量过平滑程度)

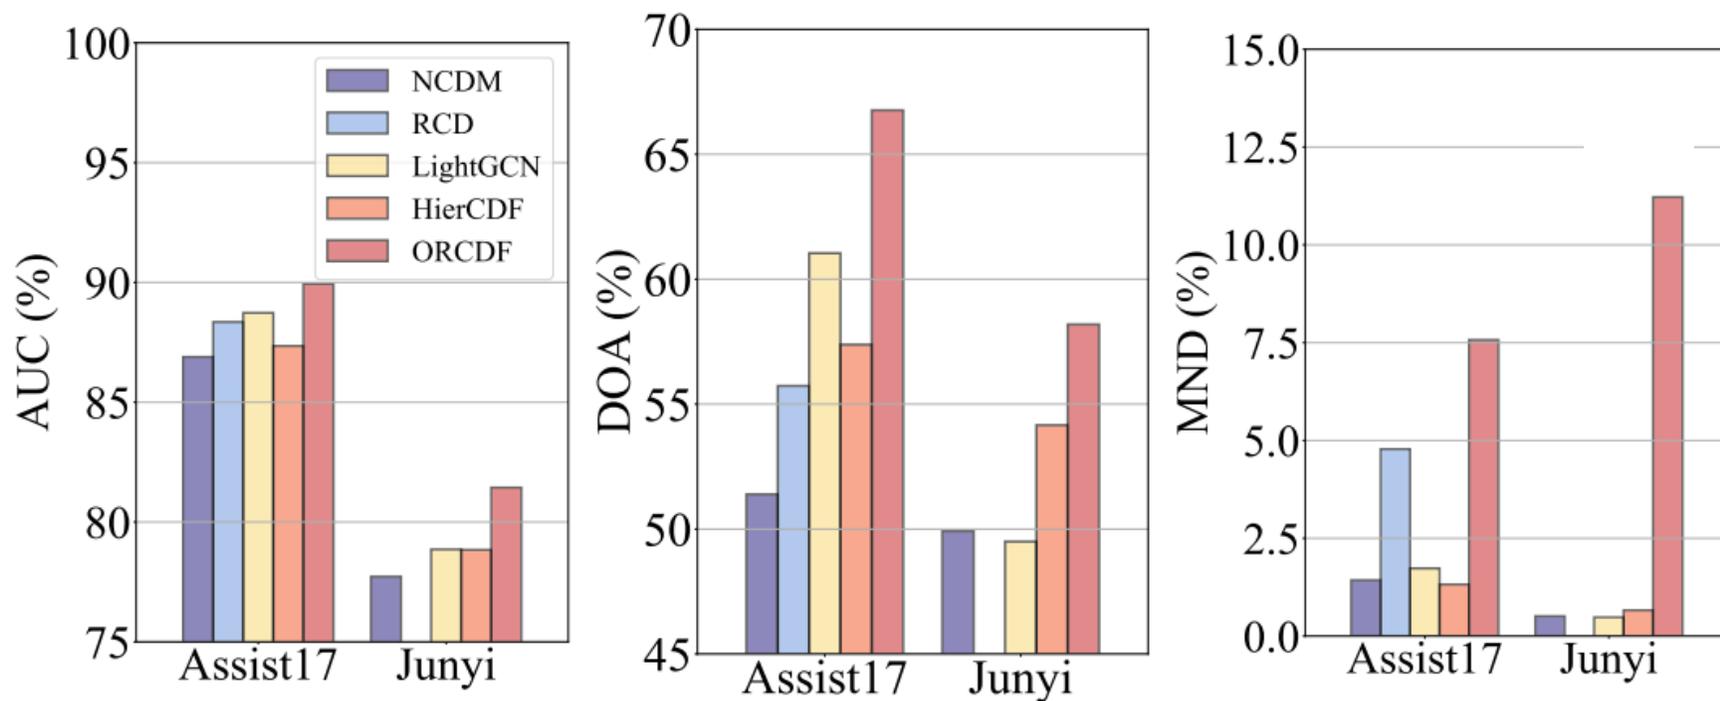
- 对比方法

- KANCD (2023)
- KSCD (2022)
- CDMFKC (2022)
- NCDM (2020)
- MIRT (2009)
- IRT (1952)
- 基于图神经网络
 - HierCDF (2022)
 - RCD (2021)
 - LightGCN (2020)

- 评估ORCDF在不同数据集上的表现
 - 不同模型中融入ORCDF，在不同数据集上**正确性与可解释性**都有较大提升
 - **有效缓解了过平滑问题**

Dataset	Metric (%)	IRT		MIRT		NCDM		CDMFKC		KSCD		KANCD	
		OL	OR	OL	OR	OL	OR	OL	OR	OL	OR	OL	OR
Assist17	AUC	88.95	89.60*	91.42	91.95*	86.89	89.94*	87.30	90.02*	88.56	89.68*	88.56	90.33*
	ACC	86.11	86.75*	88.15	88.51*	84.56	87.10*	85.15	87.2*	86.14	86.75*	86.06	87.56*
	DOA	-	-	-	-	51.39	66.76*	54.69	66.67*	65.86	68.05*	62.86	67.01*
	MND	-	-	-	-	1.43	7.57*	4.64	20.7*	0.05	2.21*	3.51	14.08*
EdNet-1	AUC	73.18	74.56*	74.41	74.68*	72.86	74.81*	73.05	74.85*	73.74	74.66*	74.42	75.11*
	ACC	70.89	71.85*	71.70	71.89*	70.68	71.98*	70.79	71.95*	71.42	71.85*	71.75	72.07*
	DOA	-	-	-	-	59.31	64.29*	60.45	64.01*	64.55	65.07*	63.02	65.47*
	MND	-	-	-	-	1.42	4.29*	0.82	4.05*	0.05	2.45*	5.48	7.12*
Junyi	AUC	80.35	81.46*	80.87	81.46*	77.72	81.44*	78.27	81.30*	OOM		79.12	81.72*
	ACC	76.65	77.52*	77.28	77.54*	74.49	77.59*	74.95	77.28*			75.57	77.71*
	DOA	-	-	-	-	49.92	58.19*	49.92	60.74*			53.59	60.85*
	MND	-	-	-	-	0.51	11.22*	0.34	17.18*			2.86	12.82*
XES3G5M	AUC	79.18	80.13*	80.43	80.66*	75.46	80.22*	74.15	79.98*	OOM		79.68	80.41*
	ACC	81.52	82.51*	82.31	82.52*	81.21	82.49*	80.17	82.28*			82.23	82.44*
	DOA	-	-	-	-	68.01	73.93*	69.03	73.89*			73.50	73.62*
	MND	-	-	-	-	1.04	19.37*	2.83	35.26*			6.43	16.67*

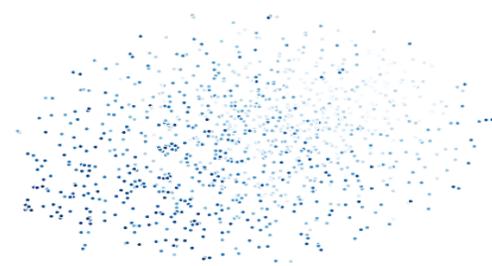
- 评估ORCDF在不同数据集上的表现
 - 在NCDM模型中融入ORCDF，在不同数据集上**正确性与可解释性**均优于对比方法
 - **有效缓解了过平滑问题**



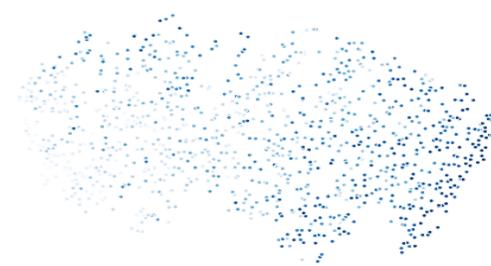
- 评估ORCDF的不同模块在不同数据集上的表现
 - OR-w/o-rgc: 没有使用响应感知图卷积, 而是对整个响应图进行卷积
 - OR-w/o-reg: 没有利用构建的一致性损失函数
 - ORCDF的两个模块在**正确性及可解释性**上均发挥了作用
 - ORCDF的两个模块都**有效缓解了过平滑问题**

Dataset	Metric	NCDM			
		OL	OR-w/o-rgc	OR-w/o-reg	OR
Assist17	AUC	86.89	88.73	89.91	89.94
	ACC	84.56	86.19	87.07	87.10
	DOA	51.39	63.74	65.26	66.76
	MND	1.43	2.53	6.90	7.57
EdNet-1	AUC	72.86	74.77	74.76	74.81
	ACC	70.86	71.94	71.86	71.98
	DOA	59.31	63.73	64.23	64.29
	MND	1.42	2.26	3.35	4.29
Junyi	AUC	77.72	80.23	81.14	81.44
	ACC	74.49	76.52	77.22	77.59
	DOA	49.92	57.96	58.14	58.19
	MND	0.51	4.96	7.96	11.22
XES3G5M	AUC	75.46	80.24	80.22	80.32
	ACC	81.21	82.46	82.46	82.49
	DOA	68.01	73.45	73.93	73.94
	MND	1.04	5.79	10.71	19.37

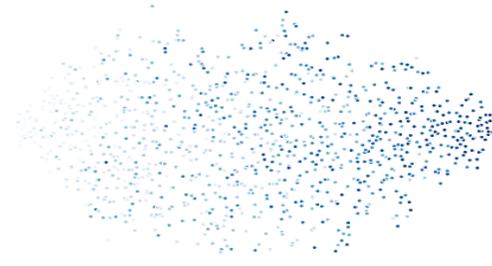
- 利用t-SNE验证ORCDF的可解释性
 - 聚类效果更加明显
- 响应感知图中学生练习边的随机翻转比例 p_f 超参数实验
 - 过高的翻转比例会带来更多的噪声，从而降低模型性能
 - 通常情况下， $p_f = 0.15$ 效果更好



(a) NCDM



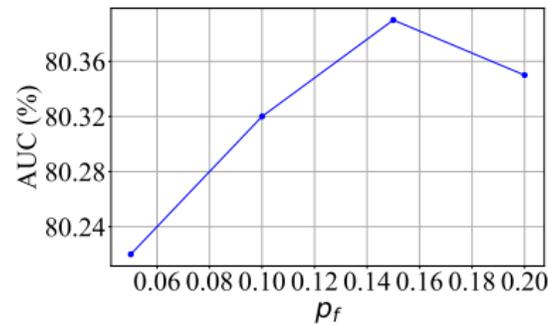
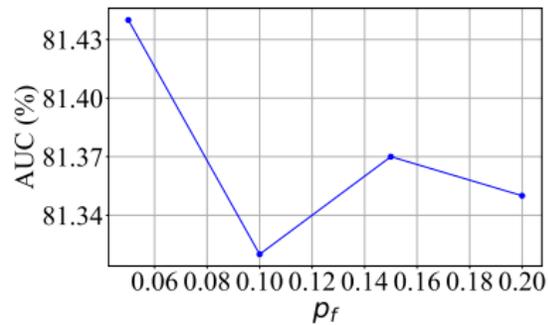
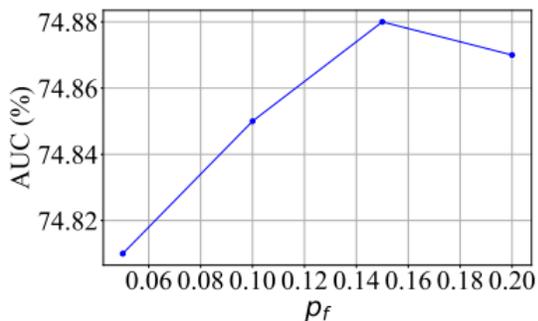
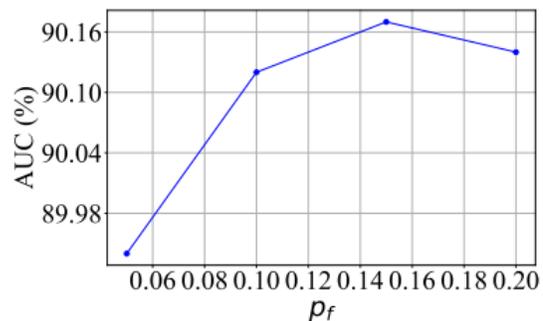
(b) OR-NCDM



(c) KaNCD



(d) OR-KaNCD



- 算法贡献
 - 建立响应感知图卷积 (RGC)：构建响应感知图，并进行正误子图分解，利用卷积操作学习嵌入表示
 - 在学习部分充分利用响应日志，有效缓解了过平滑问题
 - 构建一致性损失函数：以一定的比例随机翻转响应感知图中的学生练习边，并构建损失函数确保在存在不同噪声的情况下学习的一致性
 - 有效缓解了噪声干扰问题以及过平滑问题
- 算法不足
 - 采用随机翻转的方式并未从根本上解决噪声问题
 - 对于深层响应感知图卷积网络的研究不够深入，如何平衡正确率与过平滑问题





特点总结与未来展望

- 特点总结

- QCCDM

- 考虑**概念间存在的因果关系**，建立结构因果模型（SCM），并提出增强Q矩阵
 - 有效缓解了**知识覆盖问题**，并在认知诊断结果中体现了概念间的**因果关系**，增强了可解释性

- ORCDF

- 考虑不同学生对于知识概念的熟练程度应具有一定**差异性**，建立响应感知图卷积（RGC），并构建一致性损失函数
 - 有效缓解了**过平滑问题**，增强了结果的可解释性

- 未来发展

- 如何在**无专家标注概念间关系**的情况下构建关系图
 - 如何排除**猜测和失误因素**引起的噪声干扰，在学生练习响应图中**有效识别噪声边**



- [1] Liu S, Qian H, Li M, et al. QCCDM: A Q-Augmented Causal Cognitive Diagnosis Model for Student Learning[C]. ECAI 2023. 2023: 1536-1543.
- [2] Qian H, Liu S, Li M, et al. ORCDF: An Oversmoothing-Resistant Cognitive Diagnosis Framework for Student Learning in Online Education Systems[C]. Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2024:2455-2466.
- [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！

