

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



基于图的知识追踪方法研究

序列数据处理

数据挖掘

博士研究生 周瑾洁

2023年05月07日

- 背景简介
 - 知识追踪回顾
- 基本概念
 - 基于图的知识追踪
 - 对比学习
- 算法原理
 - KSGKT
 - Bi-CLKT
- 总结
- 前沿发展
- 参考文献

- 预期收获
 - 了解知识追踪的基本概念
 - 熟悉知识追踪的分类及应用场景
 - 理解基于图的知识追踪方法原理
 - 了解知识追踪算法的未来发展

- 因材施教

- **2 Sigma** 问题：寻找与一对一辅导一样有效的小组教学方法

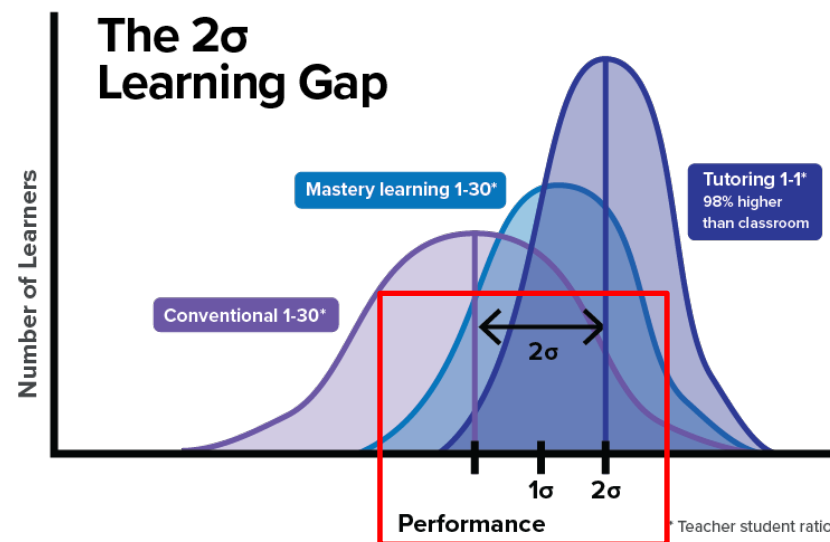
- Bloom (1984)

- 2030 年，全世界需要 **6900** 万名教师才能普及基础教育

- 联合国教科文组织总干事 (2022)

World Teachers' Day: UNESCO sounds alarm on global teacher shortage crisis

On World Teachers' Day, Audrey Azoulay, Director-general of UNESCO, called on governments around the world to step up their support for teachers, warning that the profession is struggling to retain its workforce and attract new talent. Worldwide, 69 million teachers are needed to reach universal basic education by 2030. The largest deficit is in sub-Saharan Africa.

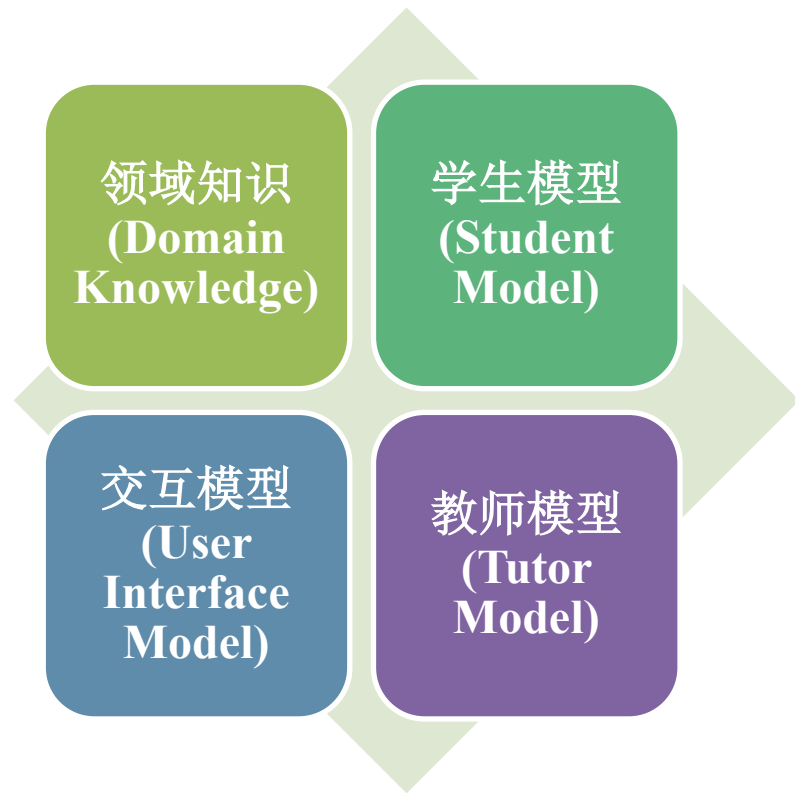


如何有效地解决2 Sigma 问题?

- 智能教学系统 (Intelligent Tutoring System, ITS)

- 学生交互数据充足
- 深度学习、机器学习技术发展迅速

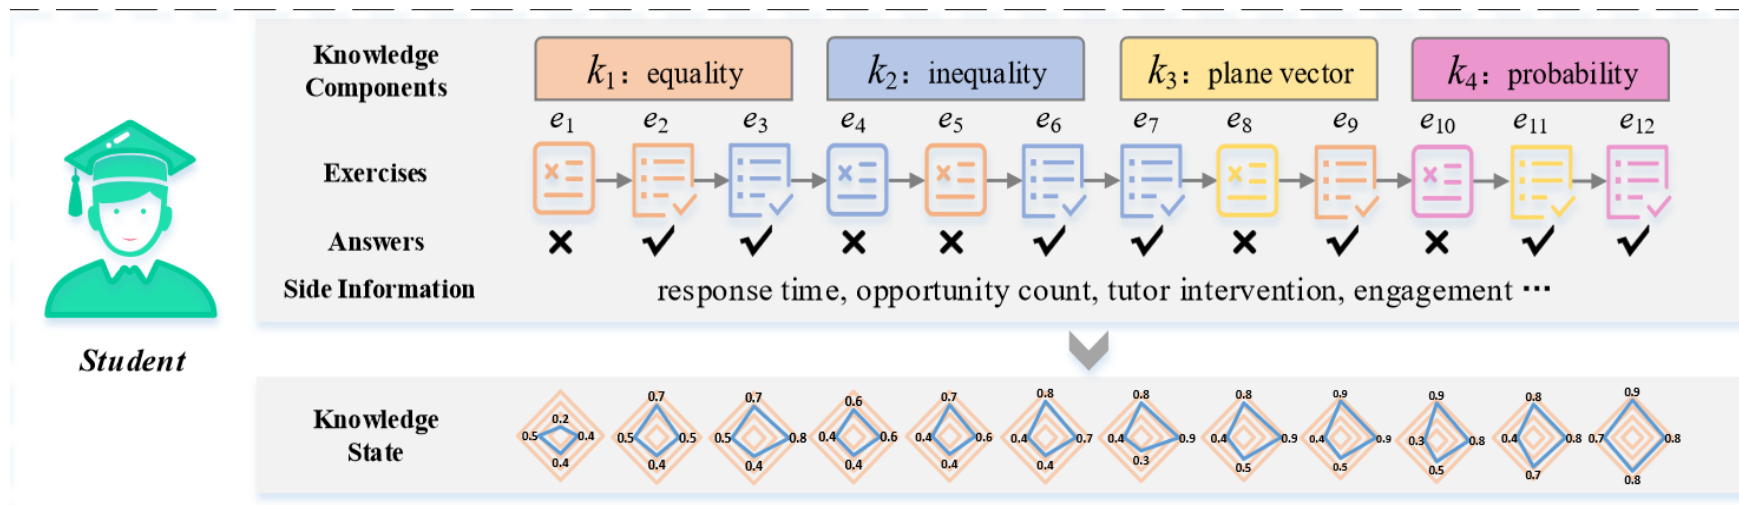
Dataset	#Questions	#Students	#Interactions	#KCs	Public available
ASSISTments2009	26,688	4,217	346,860	123	Yes
ASSISTments2012	179,999	46,674	6,123,270	265	Yes
ASSISTments2015	100	19,917	708,631	-	Yes
ASSISTChall	3,162	1,709	942,816	102	Yes
STATICS2011	1,224	335	361,092	85	No
Junyi Academy	722	247,606	25,925,992	41	Yes
Simulated-5 (Synthetic)	50	4,000	200,000	5	Yes
Algebra 2005-2006	1,084	575	813,661	112	Yes
Algebra 2006-2007	90,831	1,840	2,289,726	523	Yes
Bridge to Algebra	19,258	1,146	3,686,871	493	Yes
EdNet-KT1	13,169	784,309	95,293,926	188	Yes
EdNet-KT2	13,169	297,444	56,360,602	188	Yes
EdNet-KT3	13,169	297,915	89,270,654	293	Yes
EdNet-KT4	13,169	297,915	131,441,538	293	Yes



知识追踪

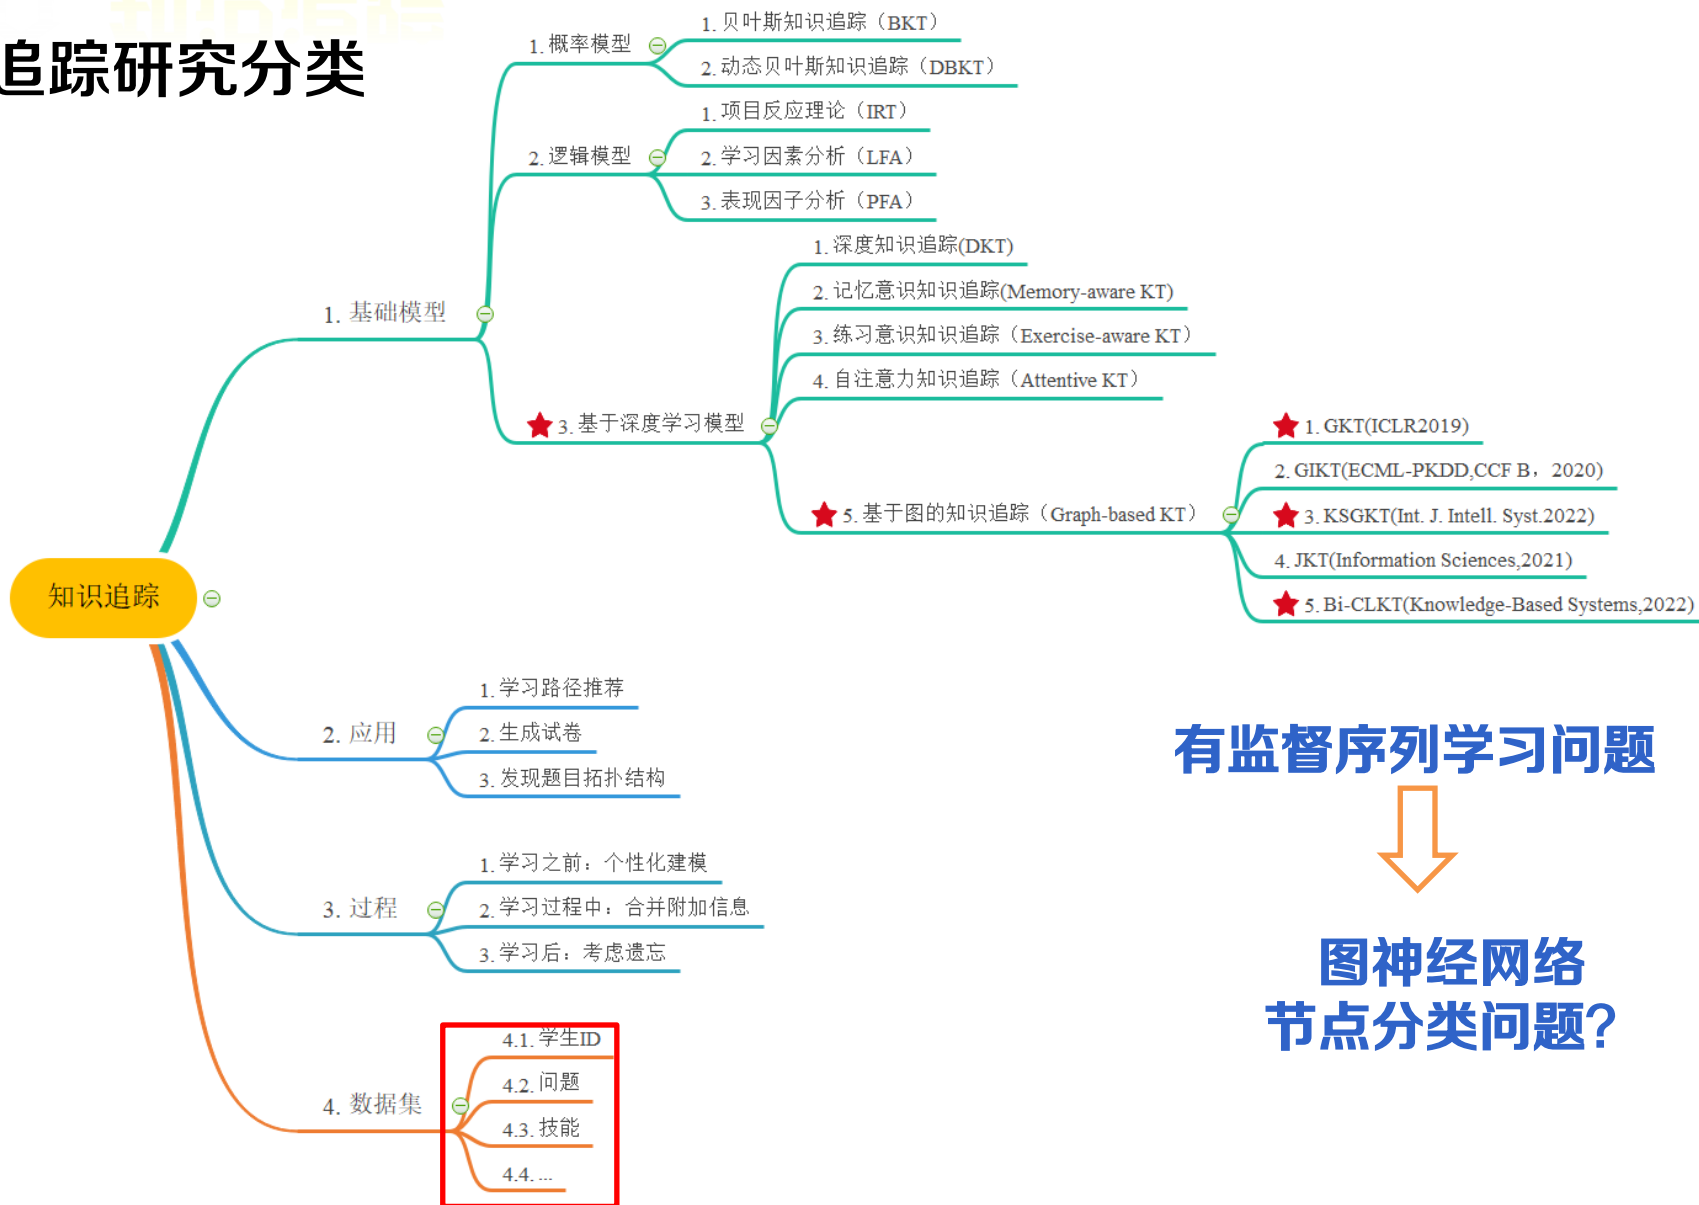
知识追踪

- 基于**学生行为序列**进行建模，预测学生对**知识掌握程度**。
- 学生交互记录 $X_t = \{x_1, x_2, \dots, x_t\}$ ，预设模型提取学生隐式知识状态，并跟踪其变化
- 学生交互：一个题目-答案的元组 $x_t = (q_t, a_t)$ ，学生在时刻 t 回答了 q_t ，情况为 a_t
- 使模型**预测**下一个题目答对的概率 $P(a_{t+1} = correct | q_{t+1}, X_t)$





知识追踪研究分类



有监督序列学习问题



图神经网络
节点分类问题?



基本概念

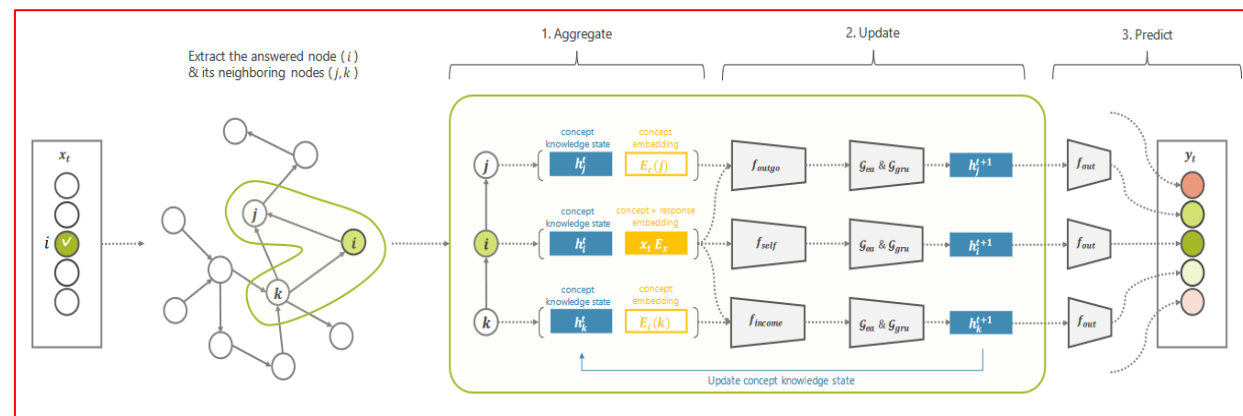
• 基于图的知识追踪——GKT

– $G = (V, E, A)$

- 节点: $V = \{v_1, \dots, v_N\}$, 概念
- 边: $E \subseteq V \times V$, 概念共享的依赖关系, 依赖度由A邻接矩阵定义

– 实施步骤

- 聚合
 - 集合了所回答的概念及其邻近概念的隐藏状态和嵌入
- 更新
 - 已聚合的特征和知识图架构来更新整个知识的结构图
- 预测




KT Model	Graph		Assumption
	Node	Edge	
GKT [78]	KC	KC-KC relation	One KC per question
GIKT [120]	Question or KC	Question-KC relation	Many KC per question
SKT [108]	KC	KC-KC multiple relations	One KC per question

仅代表概念或练习，没有很好整合二者
忽略问题本身和问题之间的联系

- 对比学习——自监督学习方法

- 核心思想：代理任务+目标函数

- 代理任务作用阶段 → 特征提取编码器 → MLP层 → 目标函数作用阶段



- 设计模型结构和对比损失，使正样例的表示在表示空间更接近，负样例更远

- 图像：空间/几何扰动和外观/色彩扰动

- NLP：词级别（token-level）{句子剪裁（crop）、删除词/词块（span）、换序、同义词替换} 和表示级别（embedding-level）{高斯噪声、dropout}



算法原理

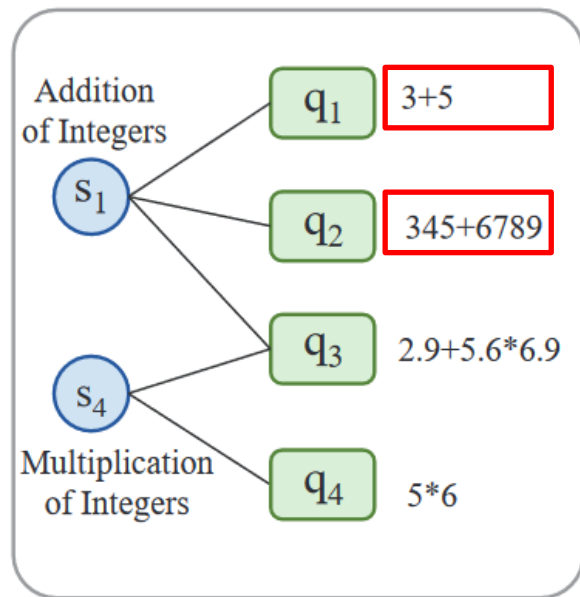
K2BKJ

T	目标	深度 知识追踪 ，精准预测学生对知识的掌握程度
I	输入	学生行为序列数据（答题数、题目编号、答题结果）
P	处理	<ol style="list-style-type: none"> 1.提取潜在KS 2.知识点题目矩阵 3.使用KS增强后异质图进行向量嵌入 4.卷积进行信息融合 5.计算注意力分数 6.LSTM预测学生的回答
O	输出	预测下一时刻学生回答问题结果

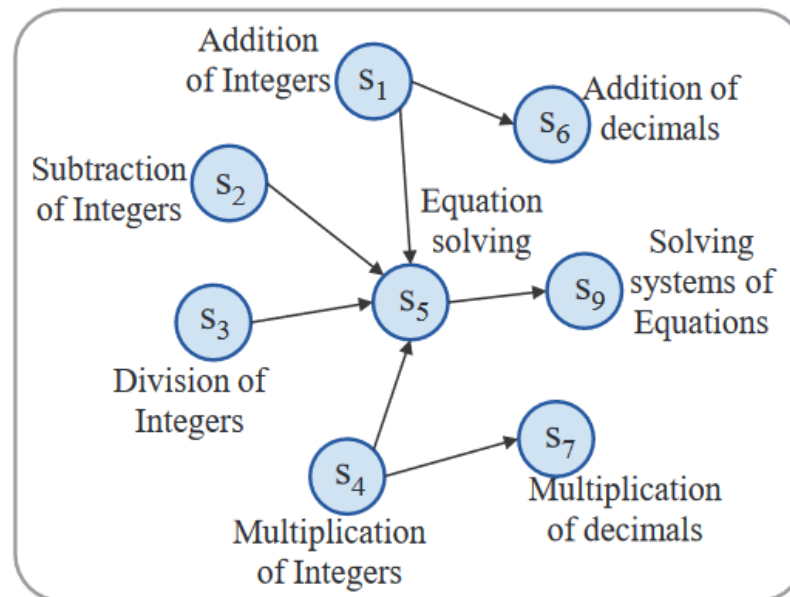
P	问题	学习者交互稀疏，现有方法忽略问题与问题间的相关性
C	条件	基于数据集计算知识架构（KS）
D	难点	知识架构提取及多种信息融合
L	水平	International Journal of Intelligent Systems, (SCI一区) 2022

- KSGKT：用于注意力知识追踪的知识结构增强图表示学习模型

- 数据集存在**数据稀疏**：练习数量远远大于技能数量且学习者只尝试了部分练习
- 现有研究主要致力于概念级KT，忽略**问题难度**及**知识结构**(概念间的关系)



问题技能关系图



知识结构图 (KS)

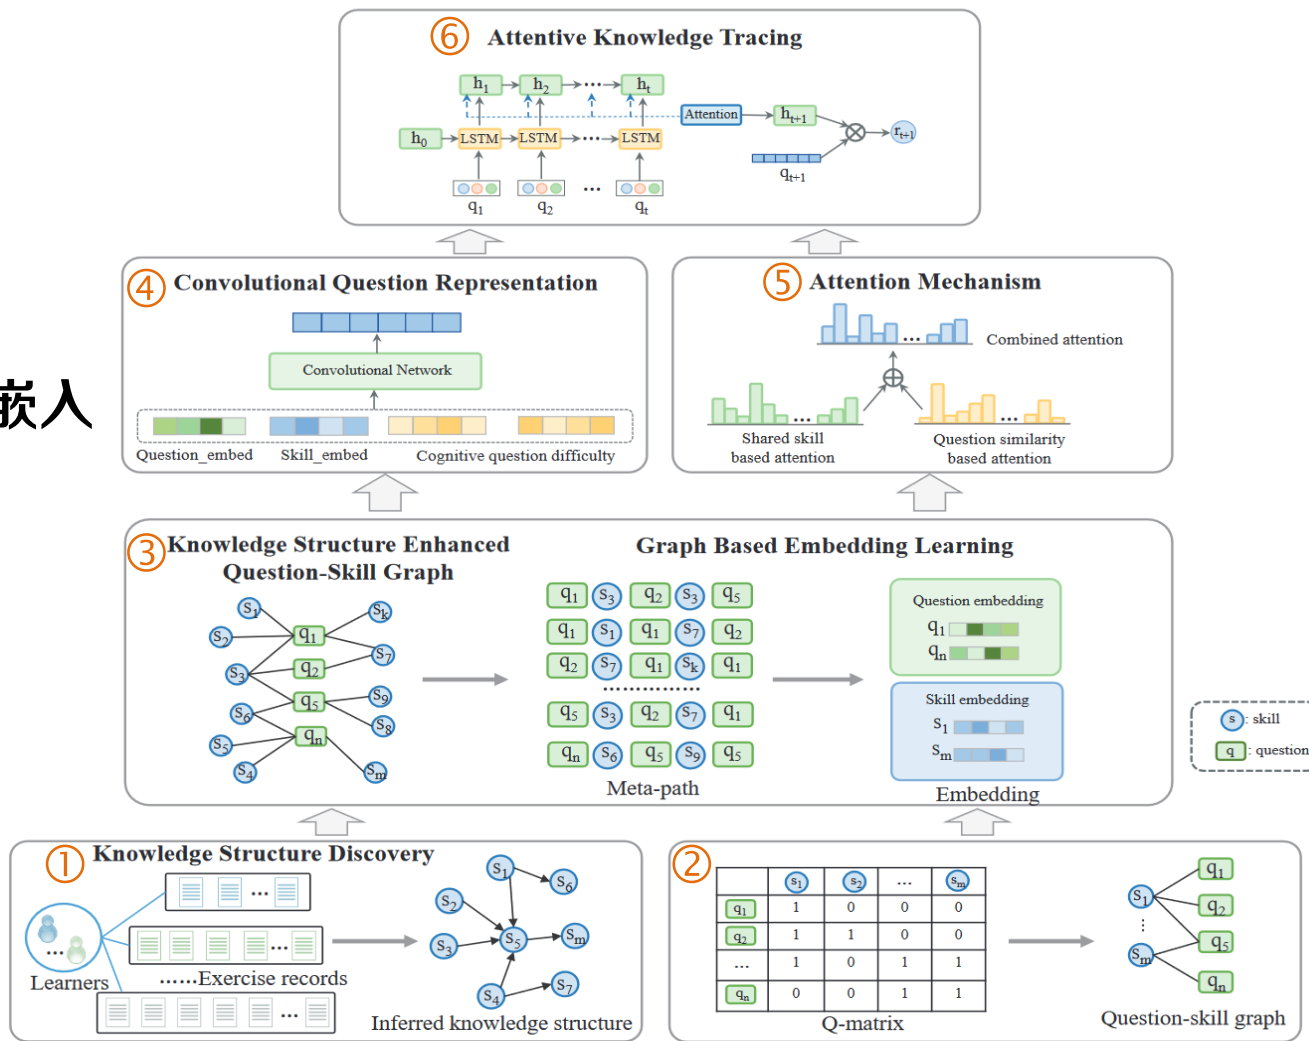
• KSGKT

– 整体流程

- 提取潜在KS
- 知识点题目矩阵
- KS增强后的异质图进行向量嵌入
- 卷积进行信息融合
- 计算注意力分数
- LSTM预测学生的回答

– 核心思想

- 知识结构提取
- 认知问题难度
- 多重注意力计算



问题陈述:

– 假设在学习系统中，二进制Q矩阵 O ， $O_{j,k} \in \{0,1\}$ 表示练习都与解决该问题所需的一种或多种技能关系，表示**第j个练习是否与第k个概念相关**

	s_1	s_2	...	s_m
q_1	1	0	0	0
q_2	1	1	0	0
...	1	0	1	1
q_n	0	0	1	1

Q-matrix

– 当学习者在时间 t 尝试练习时，生成对应练习记录五元组

$$n_t = (u_i, q_t, s_k, e_{tt}, r_t)$$


• 学习者ID: $u_i \in \{u_1, u_2, \dots, u_l\}$ ，练习ID: $q_t \in \{q_1, q_2, \dots, q_j\}$ ，基础技能: $s_k \in \{s_1, s_2, \dots, s_K\}$ ，回答练习 q_t 所花费的时间 e_{tt} ，在时间 t 下回答练习的正确性 $r_t \in \{0,1\}$

– 学习者历史练习序列 $X = \{n_1, n_2, \dots, n_T\}$ 和新练习 q_{t+1} ，预测答对 q_{t+1} 的概率

$$p(r_{t+1} = 1 | X, q_{t+1})$$

练习-技能图:

- Q矩阵→为 $G = \{Q, S, L\}$, $L = [O_{jk}] \in \{0,1\}$, 问题 q_j 和技能节点 s_k 是否有边相连



知识结构KS

- KS以技能为节点的有向图: $KS = \{S, \vec{L}\}$, \vec{L} 图中两个技能节点之间的先决关系

认知问题难度

- 在动态学习过程中模拟**面向学习者的问题难度**

$$\Psi_{v,t|v=\{q,s\}} \begin{cases} \frac{|\{l_v == 0\}|_{0:t}}{|N_v|_{0:t}} * (c - 1), \text{ if } |N_v|_{0:t} \geq 5 & \text{先前尝试同一问题或技能的结果} \\ c, & \text{otherwise} \end{cases}$$

学习者在时间 t 之前尝试的一组问题或技能

• $\Psi_{q,t}$ 和 $\Psi_{s,t}$ 表示学习者 t 时刻问题和技能水平的认知难度, 难度量化为 $c + 1$ 级



• 知识结构KS

- 技能为节点的有向图, $KS = \{S, \vec{L}\}$, \vec{L} : 节点间先决关系
- 8种KS: 技能关系矩阵 R^W , $W \in \{SK, Kappa, Kappa', Phi, Yule, Ochiai, Sokal, Jaccard\}$

- SK技能转换: $R_{i,j}^{sk} = \frac{n_{i,j}}{\sum_{K=1}^{|K|} n_{i,k}}$

- 7个评价指标: 一对技能之间先决条件关系的一致性

$$\begin{cases} R_{i,j}^W = \max(R_{i,j}^W, R_{j,i}^W), R_{j,i}^W = 0, \text{ if } R_{i,j}^W > R_{j,i}^W \\ R_{j,i}^W = \max(R_{i,j}^W, R_{j,i}^W), R_{i,j}^W = 0, \text{ otherwise} \end{cases}$$

$$R_{i,j}^W = \begin{cases} 1, & \text{if } R_{i,j}^W \geq \text{threshold} \\ 0, & \text{otherwise} \end{cases}$$

设置阈值
控制KS稀疏性

	s_j master	s_j not master	total
s_i master	a	b	a+b
s_j not master	c	d	c+d
total	a+c	b+d	a+b+c+d

Cohen's Kappa	$R_{i,j}^{Kappa} = 2(ad - bc) / \{(a+b)(b+d) + (a+c)(c+d)\}$
Adjusted Kappa	$R_{i,j}^{Kappa'} = 2(ad - bc) / \{(a+c)(c+d)\}$
Phi coefficient	$R_{i,j}^{Phi} = (ad - bc) / \sqrt{(a+b)(b+d)(a+c)(c+d)}$
Yule coefficient	$R_{i,j}^{Yule} = (ad - bc) / (ad + bc)$
Ochiai coefficient	$R_{i,j}^{Ochiai} = a / \sqrt{(a+b)(a+c)}$
Sokal coefficient	$R_{i,j}^{Sokal} = (a+d) / (a+b+c+d)$
Jaccard coefficient	$R_{i,j}^{Jaccard} = a / (a+b+c)$

- KS增强的问题—技能图，嵌入学习

- KS和问题技能图融合提取嵌入，当前问题技能的先决条件矩阵 \hat{R}

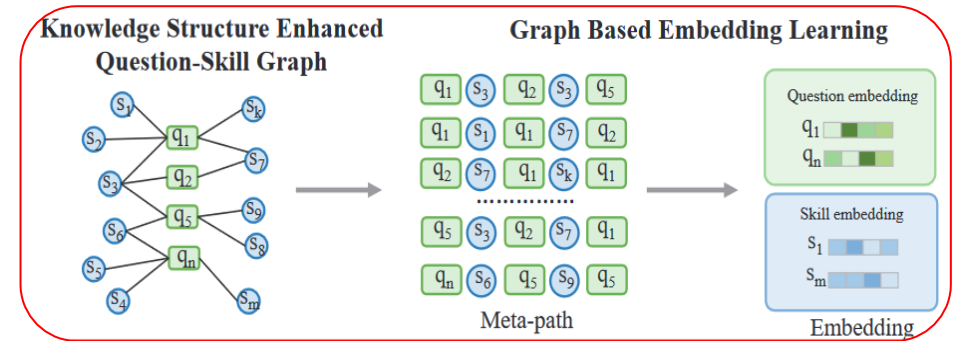
$$R^W \in \mathbb{R}^{|S| \times |S|} \text{ “+” } O \in \mathbb{R}^{|Q| \times |S|} \rightarrow \hat{R} \in \mathbb{R}^{|Q| \times |S|}, \hat{R} = O(R^W)^T$$

$$\hat{R}_{i,j} = \begin{cases} 1, & \text{if } \hat{R}_{i,j} \geq 1 \\ 0, & \text{otherwise} \end{cases}$$

包含问题与技能多跳关系和技能间先决条件

- Metapath2Vec方法获得异构网络嵌入

- 元路径生成
- 基于skip-gram的嵌入学习



$$\operatorname{argmax}_{\theta} \sum_{v \in V} \sum_{\text{type} \in \{Q, S\}} \sum_{c_t \in N_t(v_t)} \log(c_t | v_t, \theta)$$

卷积进行信息融合——技能嵌入及难度信息

– 通过特征交互和卷积操作学习高阶潜在模式

- 每个问题在练习和技能水平连续嵌入向量：

$$d_q = \Psi_{q,t}D, d_s = \Psi_{s,t}D$$

- 包含多项技能的问题，平均技能嵌入：

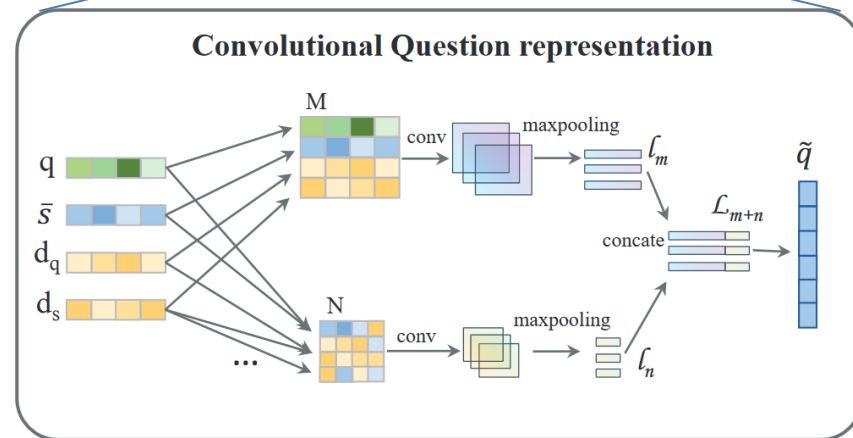
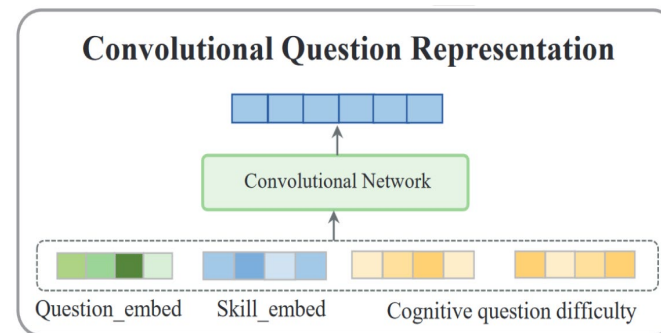
$$\bar{s} = \frac{1}{|s_q|} \sum_{s_i \in s_q} s_i$$

$$M = [q, \bar{s}, d_q, d_s] \in \mathbb{R}^{4 \times d}$$

$$N = [\langle M_i | M_j \rangle] \in \mathbb{R}^{4 \times 4}$$

- 8 个大小为 2×2 的二维卷积运算，最大池化

$$\tilde{q} = \text{Concat}(l_{m+n}^1, \dots, l_{m+n}^8)W^0$$



• 学习者知识状态演化

– 学习者练习顺序输入至注意力KT模型中进行预测

- 输入: $x_t = \text{Concat}(\tilde{q}, t_t, r_t)$
- 序列数据建模
 - LSTM
- 考虑遗忘因子: $\text{corre}_{i,t+1} = \exp(-\theta |t_{t+1} - t_i|) g(\tilde{q}_i, \tilde{q}_{t+1})$
- 考虑三种注意力, 计算分数

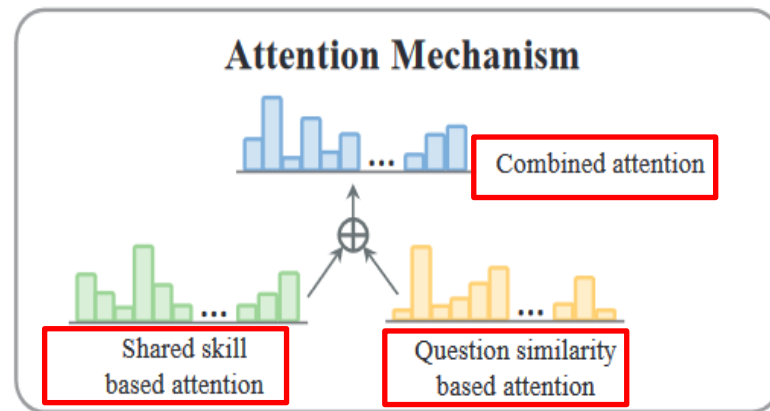
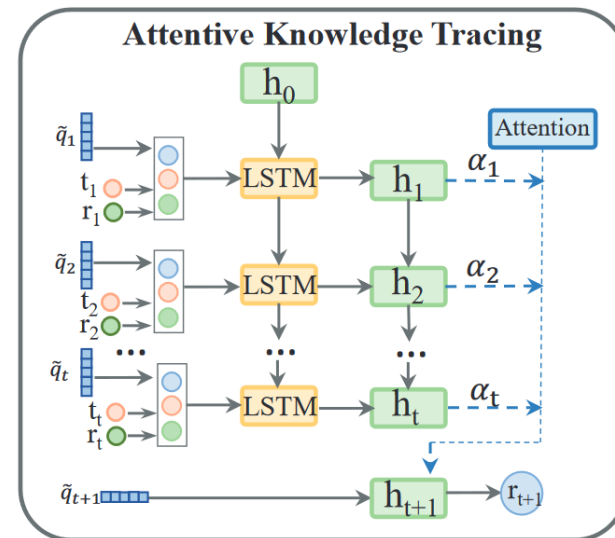
– 基于**共享技能**的注意力: $g(\tilde{q}_i, \tilde{q}_{t+1}) = \frac{n}{|s_{q_{t+1}}|}$

– 基于**问题相似性**的注意力

– **联合**注意力

• 迭代优化

– $\mathcal{L} = \sum_t (r_{t+1} \log p_{t+1} + (1 - r_{t+1}) / \log(1 - p_{t+1}))$



K2BKJ

• 问题

- 1. KSGKT 预测学习者在**新问题上的表现**有多好?
- 2. **KS 增强图**上的嵌入学习如何影响所提出模型的性能?
- 3. 在图上学习的问题嵌入是否提供了**有意义的信息**?
- 4. 八种方法从数据中推断 KS 的效果如何? 推断的 KS 是否可以解释?
- 5. KT 任务的卷积问题表示效果如何?
- 6. 所提出方法中的**注意力机制**有多有效? 改变注意力计算方法有什么影响?



- 预测学习者在新问题上的表现

- 评价指标: AUC

- KSGKT在所有数据集上都优于基线，分别比基线高出 **3.97%**、**1.39%** 和 **2.25%**

Dataset	Assist0910	Assist1213	Ednet
# of learners	3,002	22,339	5,000
# of questions	17,705	52,825	12,372
# of skills	123	265	188
# of interaction records	277,540	2,672,532	347,864
# skills per item	1.20	1.00	2.28
# questions per skill	172.33	199.34	149.78
# of attempted items per learner	92.45	119.64	69.57
# of attempted items per learner	92.45	119.64	69.57

	Model	ASSIST0910	ASSIST1213	EdNet
Skill-based Model	BKT	0.6571	0.6204	0.6027
	DKT	0.7412	0.7256	0.6889
	DKVMN	0.7559	0.7247	0.6921
Question-based Model	KTM	0.7582	0.7212	0.6899
	DKT-Q	0.7306	0.7158	0.6812
	DKT-Q&S	0.7616	0.7389	0.7235
	DKT-CQE	0.7998	0.7686	0.7523
	GIKT	0.7845	0.7712	0.7529
	DAS3H	0.789	0.741	0.731
	RKTM	0.7650	0.7690	-
	AKT	0.8152	0.7720	0.7658
	CoKT	0.7928	0.7802	0.7464
	IEKT	0.7720	0.7341	0.7305
	KSGKT	0.8242*	0.7851*	0.7754*

• 嵌入学习对图的影响

– 评价指标: AUC


– 消融实验

- KSGKT-Q: 嵌入模块换为one-hot问题嵌入
- KSGKT-S: 嵌入模块换为one-hot技能嵌入
- KSGKT-Q&S: 连接了问题和技能嵌入
- KSGKT-CQE: 重命名KSGKT


– 在图上学习的问题嵌入的可视化

- 随机选择了 50 个技能及其相应的问题
- 将嵌入分散在使用 Metapath2Vec 学习的嵌入
- t-SNE实现

Methods	ASSIST0910	ASSIST1213	EdNet
DKT	0.7412	0.7256	0.6889
DKT-Q	0.7306	0.7158	0.6812
DKT-Q&S	0.7616	0.7389	0.7235
DKT-CQE	0.7998	0.7686	0.7523
GIKT	0.7845	0.7712	0.7529
KSGKT-Q	0.7409	0.7277	0.6987
KSGKT-S	0.7523	0.7399	0.7043
KSGKT-Q&S	0.7682	0.7464	0.7293
KSGKT-CQE	0.8242*	0.7851*	0.7754*



原始

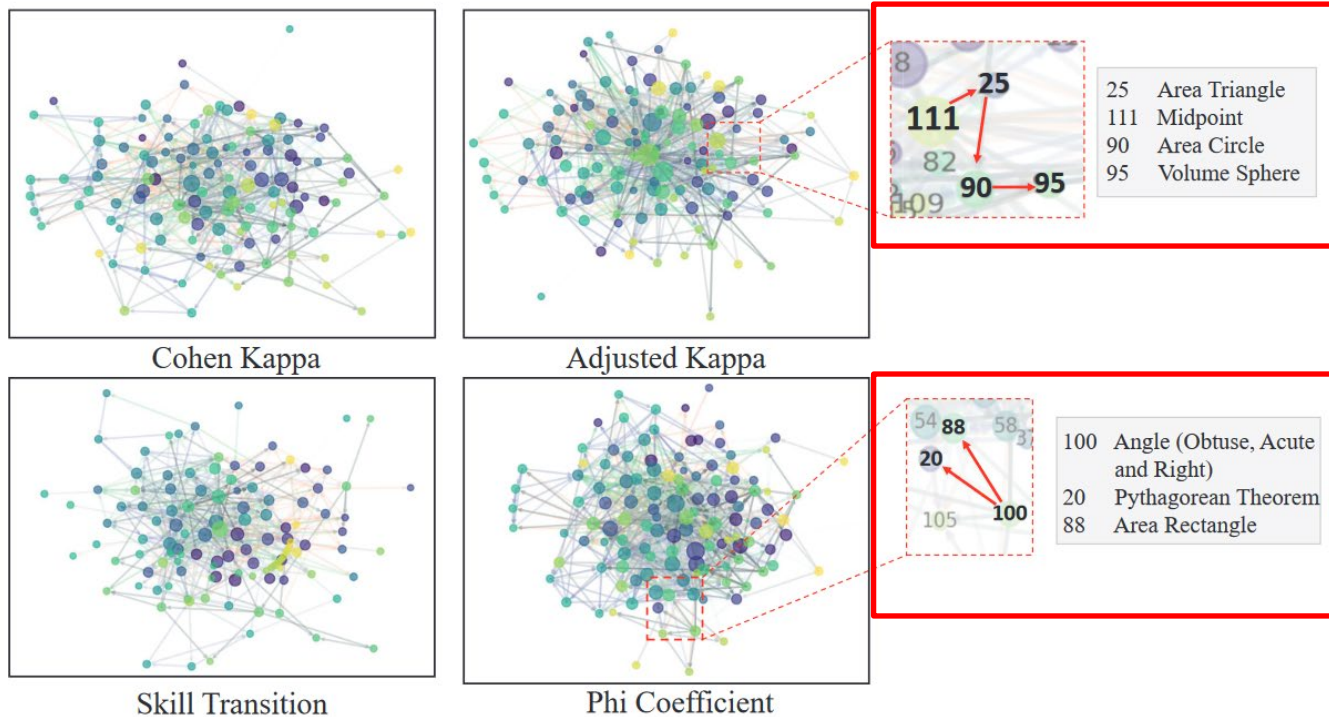


提出方法

• 八种方法从数据中推断 KS 的效果

– 生成有向KS图

- Adjust-Kappa: 四个节点在局部相互连接，并揭示了**完美排序**（先决条件和后决关系）
- Phi 系数图中的局部连接也呈现了三种技能之间的**合理关系**



• 卷积、注意力的有效性

– 卷积消融

- KSGKT with only QE: 不用卷积, 输入**问题嵌入**
- KSGKT with only SE: 不用卷积, 输入**技能嵌入**
- KSGKT with QE&SE: 不用卷积, 输入**问题&技能嵌入**
- KSGKT with CQE: 重命名**KSGKT**

– 注意力消融

- 注意力机制有利于 KT 任务

Methods	ASSIST09	ASSIST12	EdNet
KSGKT with only QE	0.8005	0.7636	0.7489
KSGKT with only SE	0.8047	0.7569	0.7543
KSGKT with QE&SE	0.8132	0.7764	0.7603
KSGKT with CQE	0.8242*	0.7851*	0.7754*

Methods	ASSIST0910	ASSIST1213	EdNet
Without attention	0.7998	0.7686	0.7523
shared skill-based attention	0.8229	0.7784	0.7729
question similarity-based attention	0.8233	0.7839	0.7727
combined attention	0.8242*	0.7851*	0.7754*



Bi-CLKT

BI-CLKT

T	目标	深度 知识追踪 ，精准预测学生对知识的掌握程度
I	输入	学生行为序列数据（答题数、题目编号、答题结果）
P	处理	<ol style="list-style-type: none"> 1.根据“练习到练习”交互记录，构建练习影响子图 2.图数据增强 3.基于 GCN 的编码器 4.预测头（Projection head） 5.联合对比损失函数
O	输出	预测下一时刻学生回答问题结果

P	问题	学习者交互稀疏，现有方法未考虑高级语义信息；难以有效地建立节点的空间关联和复杂结构；仅代表概念或练习，没有很好整合二者
C	条件	图对比学习架构
D	难点	有效构建影响子图并联合对比训练局部和全局图
L	水平	KBS（SCI二区），2022

- 核心思想

- 自监督对比学习

- 两层对比学习框架

- 全局和局部级别执行“练习到练习”（E2E）和“概念到概念”（C2C）的关系信息

- 整体流程

- 根据“练习到练习”交互记录，构建练习影响子图

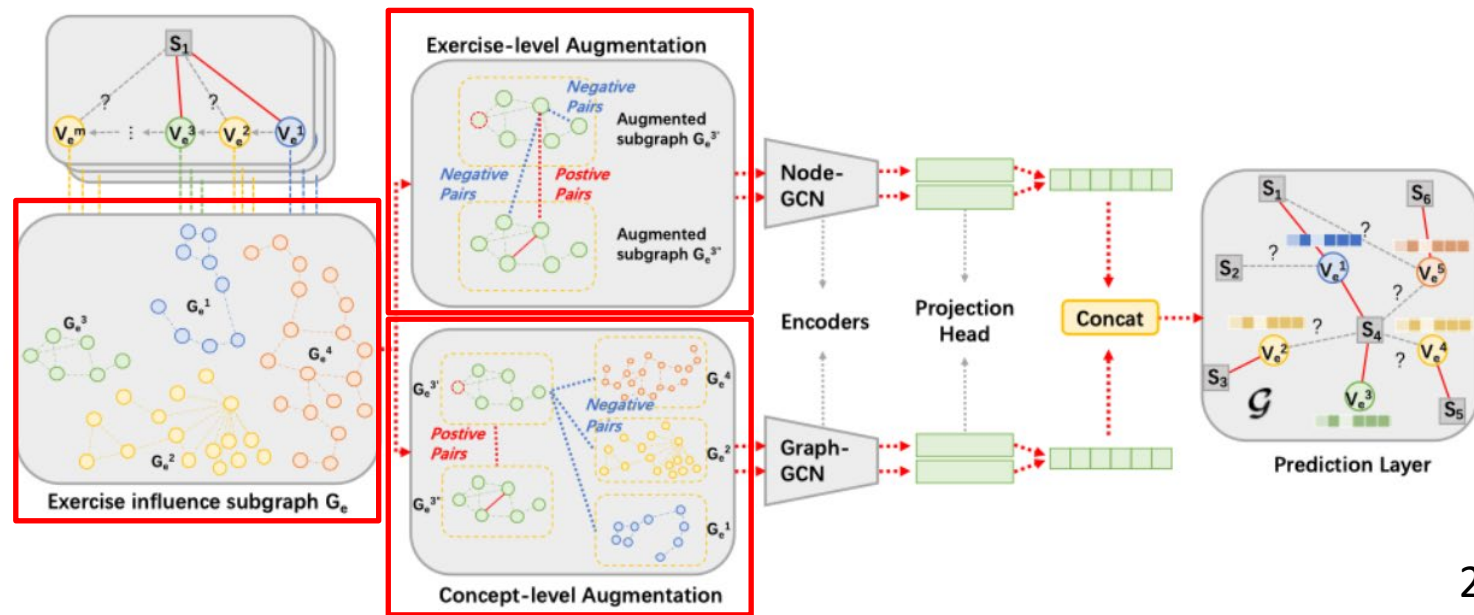
- 双图对比学习模型构建

- 图数据增强

- 基于 GCN 编码器

- 预测头

- 联合对比损失函数

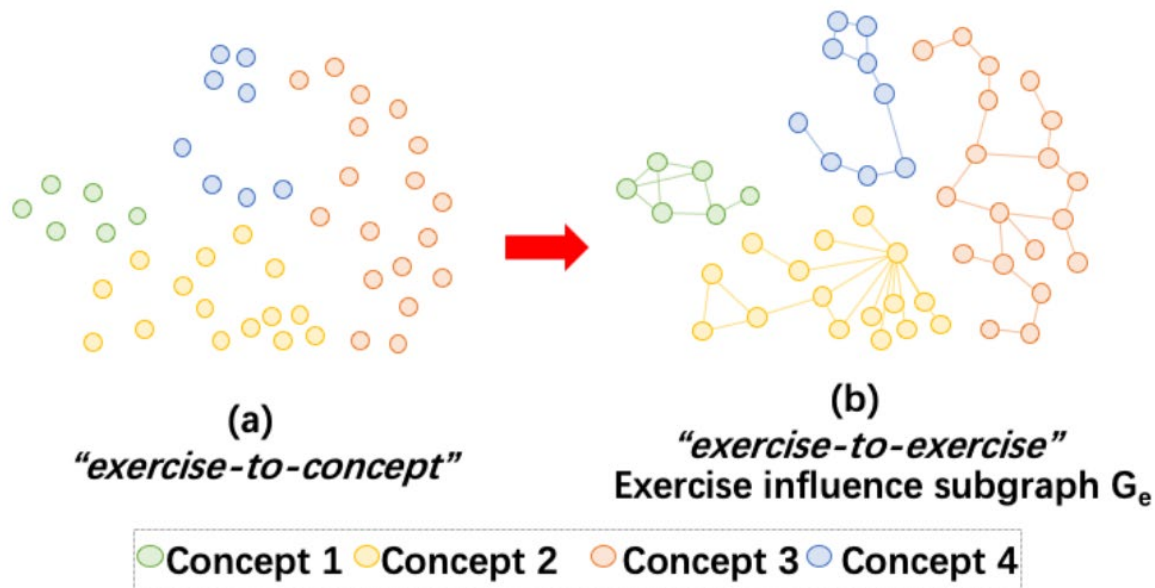


- 练习影响子图构建

- 子图 $\mathcal{G}_e(v_e, \varepsilon_e)$, 边权重 Q_e^{ij} ($i, j \in \mathbb{N}, i, j \leq m$)

$$Q_e^{ij} = \frac{f^c(v_e^i, v_e^j)}{\sum_m f^o(v_e^i, v_e^m)}$$

- Q_e^{ij} 涉及所有 v_e^i 已回答的**共现练习**中 v_e^j 和 v_e^i 的**正确率**, f^c f^o 共同正确和共现的计数



• 图数据增强

- Exercise level: 通过随机选择边或节点进行删除得到新的节点集和边集，从而形成不同的子图，概率定义：

$$P_E\{(u, v) \in \tilde{\mathcal{E}}\} = 1 - p_{uv}^e \quad \text{消除边的概率}$$

$$P_{V_e}\{(u, v) \in \tilde{v}_e\} = 1 - p_v^e \quad \text{消除节点的概率}$$

- Concept-level: 计算概率，反映边和节点的重要性，通过结合PageRank算法进行边和点的选择，从而形成新的子图：

$$p_i^f = \min\left(\frac{s_{max}^f - s_i^f}{s_{max}^f - u_i^f}\right) \cdot p_f, p_\tau \quad p_f \text{ 是 } p_{uv}^e \text{ 和 } p_v^e \text{ 联合概率}$$

- 生成两个损坏的图形视图 \tilde{g}_1, \tilde{g}_2

- 基于 GCN 的编码器

- 节点嵌入:

$$h_v = \text{CONCAT} \left(\left[x_v^{(k)} \right]_{k=1}^K \right) \mathbf{W}$$

- 结构嵌入:

$$h_{\text{graph}} = \text{READOUT}(H) = \sigma \left(\sum_{v=1}^{|V|} h_v \right)$$

- 预测头

- 通过投影头 $g(\cdot)$ 的非线性变换将增强的表示映射到均匀的潜空间中计算对比度损失

- 在图形对比学习中, 应用多层感知器 (MLP) 来获得映射 Z_i, \bar{Z}_j

- 联合对比损失函数

- 节点级GCN-局部对比学习

- 同一概念下练习影响图上随机抽取N小批节点

- 同一视图下的所有 1-hop 邻居点以及另一个视图的所有 1-hop 邻居都用作负对，唯一的正对是两个视图下的对应点

- 图级GCN-全局对比学习


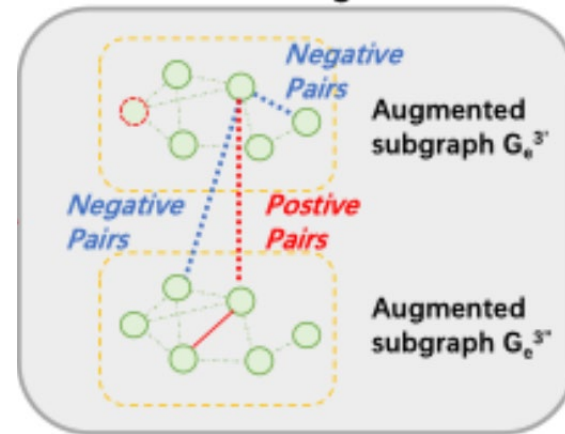
- 随机绘制 N 个小批量的练习影响图

- 2N个增强图作为正对，而其他所有图都作为它们的负对

- NT-Xent（归一化温度标度交叉熵损失），对比损失函数：

$$\ell_n = -\log \frac{\exp(\text{sim}(Z_{n,i}, \bar{Z}_{n,j})/\tau)}{\sum_{\acute{n}=1, \acute{n} \neq n}^N \exp(\text{sim}(Z_{n,i}, \bar{Z}_{\acute{n},j})/\tau)}$$

Exercise-level Augmentation



Concept-level Augmentation

- 预测学习者在新问题上的表现
 - Bi-CLKT 模型取得最佳性能
 - Bi-CLKT 模型比其他基线模型至少提高了 5%

	ASSISTment 2009		ASSISTment 2015		ASSISTment Chall		STATICS 2011	
	<i>AUC</i>	<i>ACC</i>	<i>AUC</i>	<i>ACC</i>	<i>AUC</i>	<i>ACC</i>	<i>AUC</i>	<i>ACC</i>
BKT [1]	0.648	0.594	0.616	0.592	0.562	0.555	0.719	0.698
DKT [2]	0.74	0.708	0.701	0.68	0.691	0.712	0.815	0.723
DKVMN [4]	0.739	0.618	0.705	0.68	0.689	0.614	0.814	0.722
SAKT [5]	0.735	0.679	0.721	0.647	0.701	0.657	0.803	0.797
EKT [36]	0.754	0.702	0.737	0.754	0.72	0.727	0.842	0.819
SAINT+ [37]	0.782	0.718	0.754	0.741	0.734	0.718	0.853	0.808
Bi-CLKT	0.857	0.802	0.765	0.757	0.775	0.764	0.865	0.835

- 消融实验

- 增强方法的影响

- 三种具有不同节点中心性度量：

Uniform、Degree、PageRank

Augmentation	ASSISTment 2009		ASSISTment 2015		ASSISTment Chall		STATICS 2011	
	AUC	ACC	AUC	ACC	AUC	ACC	AUC	ACC
Uniform	0.864	0.786	0.748	0.749	0.77	0.753	0.852	0.815
Degree	0.869	0.795	0.765	0.757	0.773	0.764	0.858	0.821
PageRank	0.875	0.802	0.757	0.752	0.775	0.764	0.865	0.835

- 不同嵌入方法的影响

- C2C、E2E、Concat

- 不同预测层的影响

- BiCLKT-M (Memory-augmented NN)
- Bi-CLKT-R (RNN)

Variants	Embedding	ASSISTment 2009		ASSISTment 2015		ASSISTment Chall		STATICS 2011	
		AUC	ACC	AUC	ACC	AUC	ACC	AUC	ACC
Bi-CLKT-M	C2C	0.838	0.768	0.762	0.746	0.733	0.752	0.802	0.777
	E2E	0.83	0.762	0.748	0.748	0.744	0.747	0.857	0.788
	Concat	0.862	0.795	0.764	0.752	0.769	0.751	0.859	0.833
Bi-CLKT-R	C2C	0.847	0.784	0.764	0.754	0.761	0.76	0.849	0.817
	E2E	0.859	0.795	0.765	0.755	0.761	0.761	0.864	0.828
	Concat	0.875	0.802	0.765	0.757	0.775	0.764	0.865	0.835



总结

- **KSGKT**
 - 优势
 - 注意力与图相结合，问题间关系，问题概念关系考虑全面
 - 知识结构纳入知识追踪模型
 - 劣势：非端对端，KS是从人为定义指标中计算出来的
- **Bi-CLKT**
 - 优势
 - 自监督**对比学习**
 - 考虑全局和局部级 E2E和C2C的关系信息
 - 劣势：未深入挖掘E2E和C2C的潜层关系信息

- 应用领域

- 细粒度**诊断报告**

- 一份全面的诊断报告将帮助教师确定整个班级和个别学生的知识水平

- 个性化**学习内容**

- 从学习者的交互历史中推断出问题的认知难度。可以跳过或延迟预测与学习者的知识水平不相容的内容（太简单或太难），有效地提高学生的学习速度，保持参与度

- 自适应学习**路径推荐**

- 推荐合理安排学习内容的顺序，生成定义明确的学习路径

- 发展方向

- 以端到端的方式将 KS 学习嵌入至模型，**自动学习KS**

- 深入挖掘E2E和C2C的**潜层关系信息**

- 利用**超图**学习更高阶语义信息

- [1] Song, X., Li, J., Lei, Q., Zhao, W., Chen, Y., & Mian, A. (2022). Bi-CLKT: Bi-graph contrastive learning based knowledge tracing. *Knowledge-Based Systems*, 241, 108274.
- [2] Gan W, Sun Y, Sun Y. Knowledge structure enhanced graph representation learning model for attentive knowledge tracing[J]. *International Journal of Intelligent Systems*, 2022, 37(3): 2012-2045.
- [3] Dong, Y., Chawla, N. V., & Swami, A. (2017, August). metapath2vec: Scalable representation learning for heterogeneous networks. In *Proceedings of the 23rd ACM SIGKDD international conference on knowledge discovery and data mining* (pp. 135-144).

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！

