

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



强化学生个性的知识追踪

硕士研究生 吴松凌

2023年12月17日

- 相关内容

- 2023.09.03 杨晓楠 《认知诊断技术及其研究》
- 2023.05.07 周瑾洁 《基于图的知识追踪方法研究》
- 2022.09.18 周瑾洁 《从赋能学习到知识追踪》

- 预期收获
- 内涵解析
- 背景简介
- 知识基础
- 算法原理
 - DGMN
 - PGN
- 特点总结与工作展望
- 参考文献


- 预期收获
 - 了解知识追踪的基本概念
 - 熟悉知识追踪的历史现状、分类及应用场景
 - 理解强化学生个性的知识追踪方法原理
 - 明确知识追踪算法的应用领域和发展方向

- 内涵解析

- 知识追踪：基于学生的**学习历史**，预测学生答对新问题的**概率**
- 强化学生个性：使知识追踪模型能更好地适应学生个人发展和个体差异
 - **个人发展**：学习经历和年龄增长引起认知发展，相同学生在不同时间完成相同练习会产生不同的知识状态变化
 - **个体差异**：不同文化和教育背景等学习特征导致不同学生在完成相同的练习后知识状态发生不同的变化
 - 知识状态：学生对概念的掌握程度

- 研究目标

- 利用学生的学习历史记录数据
- 结合深度神经网络、**突触可塑性**等理论
- 实现对学生回答问题情况的准确预测




- 研究背景

- 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）
- **智慧教育系统**凭借时空约束少、便捷程度高和个性化定制学习的优势快速发展
- 机器学习、深度学习**技术发展迅速**，通过知识追踪分析智慧教育系统中的海量学习数据，为学生提供个性化学习方案
- 提高知识追踪的**个性化分析水平**一直是研究的重点

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.



- 研究意义

- 细粒度**追踪报告**


- 一份全面的追踪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**

- 从学生的学习历史中推断出问题的认知难度，可以跳过或延迟与学生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**

- 合理安排学习内容的顺序，生成定义明确的学习路径



Corbett提出了贝叶斯知识追踪方法。该方法的核心为**贝叶斯公式**，可解释性强；但模型过于简单，忽略遗忘效应

Piech等人**率先**将深度学习用于知识追踪，提出了深度知识追踪方法，该方法是最经典的深度学习知识追踪方法

Nakagawa等人提出了图知识追踪方法。该方法建模了**概念依赖**关系，但忽略了问题本身及问题之间的关系

Huo等人提出了**动态学生分类**知识追踪，通过根据学生最近的回答表现定期对学生进行分类，实现个性化预测

Li等人提出了塑性门控网络，通过采用**塑性权重**来使模型能够开发出特定于时间和个体的参数，以适应学习者的个人发展和个体差异




- 提取额外个性化特征
 - 代表学生个性化信息的特征
 - 个性化先验知识
 - 个性化学习速度
 - 动态学生分类
 - 个性化概念表示
 - 往往需要进行额外的数据收集工作，且难以覆盖实际中的所有特征
- 动态模型参数
 - 根据突触可塑性理论，在神经元的连接中引入塑性权重，在模型训练完成后仍能根据输入输出不断演变，以此适应学生个人发展和个体差异
 - 往往会造成成倍的计算资源占用



知识追踪

- 基于**学生学习历史**进行建模，预测学生答对新问题的**概率**
- 学生学习历史——**问答序列** $X_t = \{x_1, x_2, \dots, x_t\}$ ，预设模型提取学生隐式知识状态，并跟踪其变化
- 问答：一个问题-回答的元组 $x_t = (q_t, a_t)$ ，学生在时刻 t 回答了 q_t ，情况为 a_t （0或1）
- 让模型**预测**下一个问题被答对的概率 $P(a_{t+1} = \text{correct} | q_{t+1}, X_t)$



• Hebbian理论

– 基本原理：当神经元A的轴突**重复参与**神经元B的放电时，代谢变化将**增强**从A到B的突触连接

– 数学表述

• $e^{post} = \sum_{i=1}^n w_i e_i^{pre}$ 表示前后层神经元的连接， w_i 为突触强度

• $\Delta w_i = \alpha e_i^{pre} e^{post}$ 表示突触强度 w_i 的变化量

– 理论问题：若 e_i^{pre} 与 e^{post} 初始均大于0，则突触强度**只能增强**

• BCM理论


– 解决方案：引入阈值 $\theta(m)$ ，允许突触**增强和减弱**

$$\Delta w_i = \frac{\alpha e^{post} (e^{post} - \theta(m)) e_i^{pre}}{\theta(m)}$$



• DKT

- 预处理：对概念ID与学生回答的one-hot编码进行**嵌入表示**，作为输入 x_t
- 知识状态表示：使用LSTM循环更新学生的知识状态表示 h_t
 - h_{t-1} 与 x_t 作为LSTM单元的输入，输出 h_t ； h_t 将被用于预测 $t + 1$ 时刻的问题回答
- 预测：使用 h_t 预测所有问题的回答正确**概率**，乘以 $t + 1$ 时刻问题的概念ID的one-hot编码，得到该问题的回答预测 $\hat{r}_{t+1}$
 - $y_t = \sigma(W_s h_t + b_s)$
 - $\hat{r}_{t+1} = \delta(c_{t+1}) y_t$
 - δ 表示one-hot编码
- 模型优化：二元交叉熵损失函数



• DKVMN

– 获取**相关向量** w_t

- $w_t(i) = \text{Softmax}(k_t^T M^k(i))$, k_t^T 是问题嵌入表示的转置

– 读取**知识状态**并预测

- $r_t = \sum_{i=1}^N w_t(i) M_t^v(i)$, **读取向量**, 代表概念知识状态

- $f_t = \text{Tanh}(W_1[r_t, k_t] + b_1)$, **摘要向量**

- $p_t = \sigma(W_2 f_t + b_2)$


– 擦除—写入机制

- $e_t = \sigma(W_e v_t + b_e)$, **擦除向量**, v_t 是问题与回答的嵌入表示

- $a_t = \text{Tanh}(W_a v_t + b_a)$, **写入向量**

- $M_t^v(i) = M_{t-1}^v(i)[1 - w_t(i)e_t] + w_t(i)a_t$

– 模型优化：二元交叉熵损失函数





Deep Graph Memory Networks for Forgetting-Robust Knowledge Tracing



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	学生问答序列（问题编号+答题结果）*n，教育数据集*4
P	处理	1.动态键值记忆网络动态捕获学生对概念的知识状态 2. 潜在概念图 生成动态概念表示 3. 遗忘门控 机制结合学生的遗忘效应和知识状态 4.预测学生回答 5.根据 问题排序 改进模型优化函数
O	输出	预测下一时刻学生正确回答问题的概率（范围(0,1)）

P	问题	无法捕捉学生对概念的掌握程度及其随时间的变化
C	条件	只有学生的问答序列可用， 概念的总数已知
D	难点	动态学习概念之间关系，生成 特定于学生的动态 概念表示
L	水平	IEEE Transactions on Knowledge and Data Engineering （2023 SCI 二区）

• 算法原理

- 以DKVMN为基础，学习概念的嵌入表示，并动态捕获学生对概念的知识状态
- 潜在概念图动态学习潜在概念之间关系，生成**特定于学生的动态**概念表示 z_t^g
- 遗忘门控将2个**遗忘特征**与学生的知识状态结合，生成组合记忆向量 z_t^m
- 根据**问题排序**优化损失函数


$\odot$: 激活函数

f_t : 遗忘特征的向量表示

$\odot$: 逐元素相乘

$\oplus$: 向量拼接

-1 : 向量元素乘负一



潜在概念图构造


- M^k 中每1行对应1个概念的嵌入表示，作为图的**节点特征**，每个节点对应1个概念
- 根据 M_t^v 的N行向量表示的N个概念知识状态，计算两两之间的余弦相似度，构建**邻接矩阵A**，并将其中小于阈值0.25的元素置零

个性化概念表示生成

- 将 M^k 和A作为GCN的输入，进行2层卷积后输出H——**所有概念的个性化表示**
- 使用H与问题和概念的相关向量 w_t 生成当前问题的概念表示，该表示**特定于不同学生并随时间发展变化**

$$z_t^g = \text{Tanh}\left(W \left(\sum_{i=1}^N w_t(i) H(i) \right)^T + b\right)$$

Latent Concept Graph




遗忘门控

遗忘特征

- **空窗期**: 问答序列中最后一次回答 c_i 相关问题的时间间隔
- **练习总次数**: 问答序列中回答 c_i 相关问题的总次数
- 将所有概念的2个遗忘特征的联合嵌入表示 f_t 与相关向量 w_t 逐元素相乘, 得到 f_{s_t}

门控机制

$$gw_t = \sigma(W_1 \cdot o_t + W_2 \cdot f_{s_t}) \quad z_t^m = gw_t \odot o_t + (1 - gw_t) \odot f_{s_t}$$



问题排序

- 问题的排序计算为 $r(q_j) = \sum_{i=1}^N w_j(i) D(i, i)$, 其中 D 为邻接矩阵 A 的度矩阵
- 对问题排序集合 $S = \{r(q_j) | q_j \in \hat{D}^{train}\}$ 进行**归一化**
- 损失函数优化为 $L = \frac{1}{|\hat{D}^{train}|} \sum_{i=1}^{|\hat{D}^{train}|} \bar{r}(q_i) \cdot l_i$, $\bar{r}(q_i)$ 为归一化值, $\hat{D}^{train}$ 是当前训练的 mini-batch, l_i 是问题 i 的实际和预测回答的二元交叉熵损失

- 数据资源

- 教育数据集*4

- 对比方法

- SAINT+: 结合transformer与遗忘效应
 - SAKT: 使用注意力机制衡量历史问题的重要性
 - AKT: 指数衰减的注意力机制, 考虑遗忘效应
 - HawkesKT: 使用 Hawkes 过程来计算学生的遗忘行为

- 实验设置

- 30%作为测试集, 剩下70%进行5折交叉验证 (80%训练, 20%验证)

- 评价指标

- ROC曲线下面积AUC

数据集	记录总数	学生数	概念数	问题数
Statics2011	190,923	335	85	1,362
ASSISTments2009	325,637	4,151	110	110
Synthenic-5	200,000	4,000	5	50
Kddcup2010	607,026	575	112	436

实验结果

- 在所有数据集上，DGMN在AUC上都**表现最好**
- 大部分算法在Kddcup2010上均获得最低的AUC值，这是因为该数据集拥有**最多**的记录总数和潜在概念，增加了知识追踪任务的复杂性
- 与GKT仅图网络、DKT+forget仅遗忘效应、DKVMN仅键值记忆相比，能一定程度上凸显DGMN的潜在概念图与遗忘门控的性能优势

Model	Forget	Graph	Rank	Knowledge Representation Model	Dataset			
					ASSISTments2009	Statics2011	Synthetic-5	Kddcup2010
GKT [16]	×	✓	×	GNN	72.3 ± 0.02	73.4 ± 0.03	74.2 ± 0.01	76.9 ± 0.01
DKT+forget [11]	✓	×	×	RNN	73.2 ± 0.02	74.5 ± 0.01	75.1 ± 0.03	79.0 ± 0.01
DKVMN [6]	×	×	×	Key-value memory	81.6 ± 0.03	82.8 ± 0.02	82.7 ± 0.01	79.8 ± 0.02
SAKT [22]	×	×	×	Attention mechanism	83.7 ± 0.02	84.2 ± 0.01	81.9 ± 0.03	80.4 ± 0.02
HawkesKT [23]	✓	×	×	Factorization machines	83.9 ± 0.04	83.8 ± 0.05	82.2 ± 0.05	79.5 ± 0.03
AKT [8]	✓	×	×	Attention mechanism	84.1 ± 0.03	85.0 ± 0.02	83.6 ± 0.03	81.5 ± 0.02
SAINT+ [24]	✓	×	×	Attention mechanism	84.4 ± 0.04	85.1 ± 0.03	83.8 ± 0.03	81.6 ± 0.05
DGMN (ours)	✓	✓	✓	Key-value memory	86.1 ± 0.01	86.4 ± 0.02	85.9 ± 0.03	83.4 ± 0.01

实验结果

- **潜在概念图**：比较DGMN-Basic和DGMN-NoForget，0.9%、1.0%、0.9%、0.7%
- **静态概念图**（直接从数据集获取图结构数据，缺乏根据**不同学生**的知识状态**随时****间变化**的适应性）：比较DGMN-StaticGraph和DGMN-NoForget，7.4%、7.8%、8.1%、2.4%
- **遗忘门控**：比较DGMN-Basic和DGMN-NoGraph，3.3%、2.6%、1.8%、2.4%
- **问题排序**：比较DGMN-NoRank和DGMN，0.4%、0.5%、0.8%、0.7%
- **记忆结构**：比较DGMN-RNN和DGMN-Basic，9.1%、9.0%、9.3%、3.8%

Model	Component				Dataset			
	Forget	Graph	Rank	Memory	ASSISTments2009	Statics2011	Synthetic-5	Kddcup2010
DGMN	✓	Dynamic	✓	Key-Value	86.1 ± 0.01	86.4 ± 0.02	85.9 ± 0.03	83.4 ± 0.01
DGMN-NoForget	×	Dynamic	×	Key-Value	82.8 ± 0.01	83.9 ± 0.03	83.8 ± 0.04	80.7 ± 0.03
DGMN-NoGraph	✓	×	×	Key-Value	85.2 ± 0.02	85.5 ± 0.01	84.7 ± 0.02	82.4 ± 0.01
DGMN-NoRank	✓	Dynamic	×	Key-Value	85.7 ± 0.02	85.9 ± 0.01	85.1 ± 0.02	82.7 ± 0.03
DGMN-Basic	×	×	×	Key-Value	81.9 ± 0.01	82.9 ± 0.03	82.9 ± 0.01	80.0 ± 0.02
DGMN-RNN	×	×	×	RNN	72.8 ± 0.08	73.9 ± 0.07	73.6 ± 0.04	76.2 ± 0.03
DGMN-StaticGraph	×	Static	×	Key-Value	75.4 ± 0.09	76.1 ± 0.08	75.7 ± 0.05	78.3 ± 0.05



Plastic gating network: Adapting to personal development and individual differences in knowledge tracing





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	学生问答序列（问题编号+答题结果）*n，教育数据集*4
P	处理	1.序列数据嵌入表示 2.塑性门控网络建模学生的知识状态 3.预测学生回答 4.模型优化
O	输出	预测下一时刻学生正确回答问题的概率（范围(0,1)）

P	问题	模型参数固定，难以适应学生的个人发展和个体差异
C	条件	缺少学生个性化信息，BCM理论
D	难点	使模型具有特定于时间和学生个体的参数
L	水平	Information Science（2023 SCI 一区）

• 算法原理图

- 预处理：使用问题ID、概念ID和学生回答的**嵌入表示**之和作为输入 x_t
- 知识状态表示：使用**塑性门控网络**代替LSTM循环更新学生的知识状态表示 h_t
- 预测：使用 h_t 预测所有问题的回答正确**概率**，提取下一个问题对应的一项
- 模型优化：二元交叉熵损失函数



• 网络结构

- 上层隐藏状态 h_{t-1} 和下层遗忘门 f_t^p 、输入门 i_t^p 、输出门 o_t^p 以及单元输入 $\tilde{c}_t$ 之间的连接由传统连接权重 W^s 和加权的塑性权重 αW^p 组成

$$f_t^p = \sigma(W_f e_t + (W_f^s + \alpha_f W_f^p) h_{t-1} + b_f) \quad i_t^p = \sigma(W_i e_t + (W_i^s + \alpha_i W_i^p) h_{t-1} + b_i)$$

$$o_t^p = \sigma(W_o e_t + (W_o^s + \alpha_o W_o^p) h_{t-1} + b_o) \quad \tilde{c}_t = \text{Tanh}(W_c e_t + (W_c^s + \alpha_c W_c^p) h_{t-1} + b_c)$$

• 塑性权重


- 更新规则——BCM理论

$$W_{i,j}^p = W_{i,j}^p + \eta e_j (e_j - \theta(m)) e_i / \theta(m)$$

- 更新速率 η (标量)

$$\eta = \sigma(W_{\eta f} f_t^p + W_{\eta i} i_t^p + W_{\eta o} o_t^p + W_{\eta c} \tilde{c}_t + b_{\eta})$$

- 阈值 $\theta(m)$ ——下层神经元的平均平方值



- 数据资源

- 教育数据集*4

- 对比方法

- 传统RNN类、注意力类方法
 - DKT、DKVMN、SAKT等
 - 基于Hebbian理论的塑性方法——PLSTM

- 实验设置

- 20%作为测试集，剩下80%进行5折交叉验证（80%训练，20%验证）


- 评价指标

- ROC曲线下面积AUC、准确率ACC、均方根误差RMSE
 - AUC——预测概率根据阈值0.5分为正确和错误，从而转化为二分类问题进行评价

数据集	记录总数	学生	概念	问题	记录/学生
Statics2011	189,297	333	1,223	-	568.5
ASSISTments2015	683,801	19,840	100	-	34.5
ASSISTments2017	942,816	1,709	102	3,162	551.7
SLP	324,866	2,868	181	4,884	113.3

实验结果


– 与其他方法相比，PGN方法在三种评价指标下几乎均优于其他算法



- 实验目的
 - 为验证PGN能更好适应学生的**个人发展**
- 实验设置
 - 时间顺序 ≤ 100 和 > 100 的记录分别分为前期和后期2个阶段
 - 评价指标——AUC、ACC、RMSE
 - **塑性性能增益**：具有塑性权重的模型（PGN和PLSTM）相较于非塑性等效模型（DKT）之间的性能差异
 - **阶段性能增益**：模型自身在后期相较于前期的性能差异
- 验证原理
 - **塑性性能增益**在后期比前期更好，表明塑性模型更能适应学生个人发展
 - **阶段性能增益**更好，表明该模型对学生个人发展的适应能力更有效


实验结果

— 塑性性能增益——塑性模型比非塑性模型更能适应学生个人发展



• 实验结果


— 阶段性能增益——PGN对学生个人发展的适应能力比PLSTM更有效



- 实验目的
 - 为验证PGN能更好适应学生的个体差异
- 实验设置
 - 使用验证集（在5折交叉验证的每个折包含20%的个体）代替训练集（每个折包含80%的个体）训练模型
 - 从原始训练集中随机选取等数量的个体作为新的验证集
 - 测试集保持与之前相同
 - 评价指标——AUC、ACC、RMSE
- 验证原理
 - 训练数据少，模型在测试时将面对更多没有学习过的具有不同认知和能力的学生
 - 性能高，表明模型对上述学生具有更强的泛化能力，即更能适应学生的个体差异



实验结果

- 在适应学生个体差异方面，PGN优于PLSTM，优于非塑性方法DKT



- 实验目的
 - 为验证PGN中塑性权重的有效性——是否仅起到了帮助训练的作用
- 实验结果
 - 启用/禁用训练好的PGN模型中的塑性权重
 - 评价指标更好直接证明了有效性
 - 前后期对比证明了塑性权重对学生个人发展适应的有效性

	Dataset	BCM-e	BCM-d
AUC	Statics2011	0.8334	0.8296
	ASSISTments2015	0.7306	0.7301
	ASSISTments2017	0.7831	0.7786
	SLP	0.8150	0.8106
ACC	Statics	0.8139	0.8125
	ASSISTments2015	0.7514	0.7513
	ASSISTments2017	0.7249	0.7219
	SLP	0.7398	0.7368
RMSE	Statics	0.3582	0.3604
	ASSISTments2015	0.4122	0.4124
	ASSISTments2017	0.4246	0.4265
	SLP	0.4175	0.4194





特点总结与未来展望

- DGMN
 - 使用潜在概念图生成**特定于学生的动态**概念表示，更好预测学生学习表现
 - 概念的总数必须**事先已知**；忽略了现实中概念间可能存在的**先决条件关系**
- PGN
 - 塑性门控网络通过**不断更新其参数**来不断适应学习者的个人发展和个体差异
 - 在**较短序列**数据上表现不够出彩；计算**资源开销**较大
- 未来发展
 - 利用**超图**学习更高阶的学生-问题-概念信息
 - 动态参数和额外学生特征结合
 - 塑性权重理念可**迁移**到面临个人发展和个体差异挑战的其他任务，如自动论文评分系统和推荐系统等

- [1] Li Z, Yu S, Lu Y, et al. Plastic Gating Network: Adapting to Personal Development and Individual Differences in Knowledge Tracing[J]. Information Sciences, 2023, 624(1): 761-776.**
- [2] Abdelrahman G, Wang Q. Deep graph memory networks for forgetting-robust knowledge tracing[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(8): 7844-7855.**
- [3] Piech C, Bassen J, Huang J, et al. Deep knowledge tracing[J]. Advances in neural information processing systems, 2015, 28(1): 505-513.**
- [4] Zhang J, Shi X, King I, et al. Dynamic key-value memory networks for knowledge tracing: Proceedings of the 26th international conference on World Wide Web[C]. Geneva: International World Wide Web Conferences Steering Committee, 2017: 765-774.**

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！

