

融合多维度学习行为特征的轻量化知识追踪模型构建与验证

Construction and Validation of a Lightweight Knowledge Tracing Model Integrating Multi-Dimensional Learning Behavioral Features

陈嘉裕^{1*} 周悦欣¹ 周琮笑¹ 郑嘉琪¹ 陈佳坤¹

华南师范大学教育信息技术学院

* 2567103204@qq.com

【摘要】 为实现在线教育的精准过程性评估，本文针对现有知识追踪模型过度依赖答题正误、忽略元认知与时间行为的问题，提出一种轻量化多特征融合模型 LKT-HR。该模型整合认知结果、提示求助（元认知）与响应时间（认知负荷）三类行为特征，基于 LSTM 实现动态知识状态追踪。在 ASSISTments2009 与 2017 数据集上的实验表明，LKT-HR 在 AUC 与 ACC 上均显著优于 BKT、DKT 及 DKT-DE 等基线，消融实验验证了多维度特征的有效性与互补性。本研究拓展了知识追踪的特征体系，其轻量化设计为智能教育系统实现实时、精准且可解释的学习状态评估提供了可行方案。

【关键词】 知识追踪；智慧教育；个性化学习；多维度学习行为特征；可解释性

Abstract: To achieve precise process evaluation in online education, this paper proposes a lightweight multi-feature fusion model, LKT-HR, to address the issue of existing knowledge tracing models overly relying on correct/incorrect answers while neglecting metacognition and time-based behavior. The model integrates three behavioral features: cognitive results, hint usage, and response time, with dynamic knowledge state tracking based on LSTM. Experiments on ASSISTments2009 and 2017 datasets demonstrate that LKT-HR outperforms baseline models like BKT, DKT, and DKT-DE in terms of AUC and ACC, while ablation studies confirm the effectiveness and complementarity of multi-dimensional features. This research expands the feature system of knowledge tracing and offers a feasible solution for real-time, precise, and interpretable learning state assessment in intelligent education systems.

Keywords: Knowledge Tracing, Smart Education, Personalized Learning, Multidimensional Learning Behavioral Features, Interpretability

1. 问题的提出

人工智能、大数据等技术的飞速发展，正驱动教育范式向精准化、个性化的智慧教育深刻转型（教育部等九部门，2025）。智慧教育的核心理念在于实现对学生认知状态的精细化感知与过程化调控，从而提供真正适配个体需求的指导（祝智庭 & 贺斌，2012）。知识追踪（Knowledge Tracing, KT）作为智能教育系统的核心使能技术，承担着通过分析学生历史交互数据来动态评估其知识掌握状态、并预测未来表现的核心任务，是连接学习行为与个性化干预的桥梁（Shen et al., 2021）。

然而,当前主流的 KT 模型在应对真实、复杂教育场景时,仍面临两大显著局限。首先,在建模维度上存在“结果导向”。大多数模型,从经典的贝叶斯知识追踪 (BKT) (Corbett & Anderson, 1994) 到深度知识追踪 (DKT) (Piech et al., 2015),其输入主要依赖于“答题正误”这一认知结果的单维信号。这忽视了学习过程中蕴含丰富认知与元认知信息的行为特征。学生在遇到困难时寻求提示的行为,直接反映了其元认知策略与自我调节能力 (Piech et al., 2015);而学生解答问题所花费的响应时间,则是衡量其认知负荷与解题策略稳定性的关键指标 (翟羽佳, 2022)。这些过程性特征对于区分“猜测正确”与“真正掌握”“因困惑而慢”与“因深思而慢”具有不可替代的价值。其次,在模型效能上存在“效率瓶颈”。以 DKT 为代表的深度模型虽提升了预测性能,但其复杂的网络结构导致计算成本高昂,对海量数据处理的适应性不足,在需要实时反馈的实际教学系统中面临部署难题 (葛志强, 2025)。反之,结构简单的传统模型又难以捕捉学习过程中的复杂模式。因此,如何构建一个既能够充分融合多维度学习过程特征,又能保持高效计算特性,从而适用于大规模真实教育数据场景的知识追踪模型?

为了解决上述问题,本研究提出了一种基于多维度学习行为特征的轻量化知识追踪模型 LKT-HR。该模型融合认知结果 (答题正误)、元认知策略 (提示求助) 和时间投入 (响应时间) 等多种学习行为特征,旨在确保计算效率的基础上提升评估准确性,从而实现对知识状态的更加全面和精准的检测。这一研究不仅丰富了知识追踪领域的理论框架,也为个性化学习评估技术的发展提供了新的思路和实践依据。

2. 相关工作

2.1. 知识追踪模型

知识追踪 (Knowledge Tracing, KT) 的核心任务是通过学生历史交互序列动态评估其知识状态,其发展遵循从概率图模型到深度学习模型,再到融合领域知识的深度学习模型这一演进路径 (周楚雄等, 2025)。早期的贝叶斯知识追踪 (BKT) 模型基于隐马尔可夫模型,将知识掌握状态视为隐变量,通过答题正误这一观测变量进行更新 (刘雯蔚等, 2025)。BKT 结构简洁、计算高效,但其二值知识状态、忽视遗忘机制以及假设知识点独立等强假设,限制了模型对真实学习中渐进掌握过程、记忆衰减及知识点间关联性的刻画能力 (Corbett & Anderson, 1995)。

随着深度学习的发展,深度知识追踪 (DKT) 模型利用循环神经网络 (RNN) 对连续、高维的知识状态进行建模,能够捕捉学习序列中的长期依赖关系,并支持对多知识点间复杂交互的建模,从而显著提升了预测性能 (杨文阳 & 杨益慧, 2024)。DKT 的这一突破也推动了知识追踪研究进一步融合多维度教育特征。DKT-DE 模型显示引入习题难度与作答经验特征,以增强模型的判别能力 (Piech et al., 2015);基于记忆网络的 MFKT 等模型则尝试整合学习与遗忘的动态过程 (梁祥等, 2023)。这一系列工作标志着 KT 研究从“通用序列建模”向“领域知识增强建模”的重要转变。

然而,特征与模型的不断复杂化也带来了新的挑战:模型计算开销剧增,可解释性下降,在需要实时反馈的大规模真实场景中面临部署瓶颈。因此,如何在引入丰富特征以保证模型性能的同时,设计计算高效、结构轻量的 KT 模型,已成为当前一个重要的研究内容。

2.2. 学习行为特征的研究

学习行为特征作为反映学生认知过程的外在表征,是提升 KT 模型精细度的关键。随着教育数据挖掘研究的深入,学习过程中的行为特征对精准评估知识状态的价值日益凸显。

传统 KT 模型主要依赖答题正误这一认知结果特征，它虽是衡量掌握程度的直接信号，但无法区分答案背后的认知过程，是学生牢固掌握知识点后的流畅输出还是学生猜测所致（贺步贵等，2024）。为此，研究者致力于挖掘能够揭示学生内在认知与元认知过程的行为指标。提示求助行为是一种典型的元认知策略特征，学生在遇到困难时是否寻求提示、寻求多少次提示，直接反映了其对自身知识漏洞的监控意识和自我调节的策略选择（翟羽佳，2022；葛志强，2025）。研究表明，提示的使用模式与知识掌握深度紧密相关，能够有效区分深思熟虑后的求助与盲目依赖（Powers et al., 2011）。

另一方面，响应时间则是一种关键的认知负荷与时间投入特征，它不仅间接反映知识的熟练度，更蕴含着解题时的认知努力程度、遇到的内部困难以及策略的谨慎性（Wise & Kong, 2005）。较长的响应时间可能意味着高认知负荷下的知识检索或复杂推理，而异常短的响应时间则可能暗示猜测行为（石君太，2023）。因此，提示次数与响应时间从“策略选择”与“心智投入”两个关键维度，提供了独立于最终答案的、连续的过程性证据。通过融合这两类特征，模型有望更细腻地解读“答对但频繁求助”与“答错但经长时间思考”等复杂学习场景，从而实现从对结果的追踪到对过程的诊断的跨越。

然而，现有研究在融合这些多维特征时，多面临模型复杂度过高、难以兼顾性能与轻量化部署的挑战，尤其缺乏对“提示—响应”特征间交互效应的系统建模。为此，本研究提出 LKT-HR 模型，其核心在于构建一个面向“提示—响应”双过程的轻量化融合架构，旨在高效协同这两类关键特征，实现更精细、更实用的学习过程动态追踪。

3. 模型构建

3.1. 问题形式化

知识追踪问题的目标是通过学生的历史作答数据，动态地评估其对知识点的掌握情况，并预测学生在未来任务中的表现。该过程可建模为时序任务：在每个时间步 t ，学生作答习题 q_t ，得到答题结果 $r_t \in \{0,1\}$ 。模型的输入包括历史交互序列： $X_t = \{(q_1, r_1), (q_2, r_2), \dots, (q_t, r_t)\}$ ，及其对应的潜在知识状态 S_t 。核心任务是利用 X_t 推断当前知识状态 S_t ，并预测下一题答对的概率 $P(T_{t+1}=1 | q_{t+1}, S_t)$ 。

3.2. 特征工程

为了准确地评估学生的知识状态并提高模型的预测能力，我们在特征工程阶段从学生的历史作答数据中提取了多种特征。这些特征分为两类：基础特征和过程性特征。

基础特征包括习题 ID (skill_id) 与答题正误 (correct)。习题 ID 经嵌入层转化为稠密向量，以捕捉习题间的语义与难度关系；答题正误以二值形式 (0/1) 直接输入，作为评估知识掌握程度的直接依据。核心过程特征包括提示次数 (hint_count) 与首次响应时间 (ms_first_response)，分别从元认知策略与认知负荷维度补充传统答题正误信息的不足。提示次数直接反映学生遇到困难时的求助倾向与元认知调节能力。为消除学生个体差异与习题难度的影响，我们采用最大最小值归一化将其映射至统一区间。首次响应时间表征学生对题目的理解速度与认知负荷，其分布通常右偏。我们依次进行自然对数变换与 Z-score 标准化，以降低极端值影响并使其符合标准正态分布。经上述处理，两类过程特征与基础特征（习题 ID、答题正误）共同构成模型的输入向量，实现“结果—过程”融合的知识状态表征。

为了使模型能够利用所有的学习行为特征，我们将提取的特征进行融合。将习题 ID 嵌入得到的向量，与答题正误、归一化后的提示次数和标准化后的响应时间等数值特征进行拼接，融合为综合特征向量 X_t ，作为 LSTM 网络的输入，从而实现多维度学习行为的统一表征与动

态知识状态评估。

3.3. LKT-HR 模型结构

3.3.1. LKT-HR 模型架构

LKT-HR 模型的输入层接收经预处理的特征向量 x_t ，该向量整合了学生在当前时间步的习题 ID、答题正误、提示次数及响应时间等多维度学习行为信息；模型核心采用 LSTM 网络对序列进行建模，通过其隐藏状态捕捉学习过程中的长期依赖关系，动态表征学生的潜在知识状态；最后，输出层基于 LSTM 隐藏状态，经由 Sigmoid 函数输出学生答对下一道习题 q_{t+1} 的概率为： $P(r_{t+1}=1|q_{t+1}, S_t)$ ，从而反映其知识掌握程度。

3.3.2. 损失函数

损失函数采用二元交叉熵损失 (binary cross-entropy loss)，其计算公式为：

$$\text{Loss} = -\sum_{i=1}^N (y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i))$$

，其中， y_i 为实际的答题结果， $\hat{y}_i$ 为模型预测的概率

值， N 为样本数量。该损失函数用于衡量模型在预测学生知识掌握情况时的误差。

4. 实验设计与分析

本部分旨在设计实验以评估提出的 LKT-HR 模型，并与传统模型进行对比。通过实验设计、模型评估和结果分析，验证了 LKT-HR 模型在知识追踪任务中的优势，并评估了各特征对模型性能的影响。

4.1. 数据集与预处理

本研究选用 ASSISTments2009 与 ASSISTments2017 两个公开数据集，均来源于在线数学辅导平台 ASSISTments。ASSISTments2009 包含 401756 条交互记录、30 维特征；ASSISTments2017 包含 942,816 条记录、82 维特征，涵盖更细粒度的元认知与行为信息。二者共同用于验证模型在不同规模与特征复杂度下的性能。

4.2. 模型训练

本研究采用深度学习框架 PyTorch 实现 LKT-HR 模型的训练与评估。训练总体目标为最小化二元交叉熵损失，并采用以下设置确保训练效果：首先，数据集按学生 ID 以 7:1:2 的比例划分为训练集、验证集和测试集，以保持学习序列的完整性。训练过程中，模型采用 Adam 优化器，经调优确定学习率、批量大小等超参数。LSTM 隐藏层与技能嵌入维度分别设为 128 和 64，以充分建模时序依赖与语义信息。训练中使用了梯度裁剪、Dropout 及早停机制，以防止梯度爆炸与过拟合。

4.3. 评估指标

为全面、客观地评估模型性能，本研究采用三类常用指标进行综合评测。本研究采用 AUC (ROC 曲线下面积) 作为核心评估指标 (Pelánek, R., 2017)，并辅以准确率 (ACC) 和 F1 分数进行综合性能分析 (Hastie et al., 2009)。AUC 能有效衡量模型对答题结果的排序能力，且对类别不平衡不敏感；ACC 反映整体预测正确率；F1 分数综合平衡精确率与召回率，以全面评估模型在教育场景中的实用性。

4.4. 实验结果与分析

4.4.1. 对比实验

为验证所提出的 LKT-HR 模型在知识追踪任务上的有效性，本研究在 ASSISTments2009 与 ASSISTments2017 两个公开数据集上，将 LKT-HR 模型与三个经典基线模型进行了对比实验。基线模型包括：基于隐马尔可夫的贝叶斯知识追踪模型（BKT）、经典的深度知识追踪模型（DKT）以及融合习题难度与作答经验的深度知识追踪模型（DKT-DE）。实验旨在评估融合多维度学习行为特征（答题正误、提示求助、响应时间）的 LKT-HR 模型，相较于传统及现有改进模型是否具有更优的预测性能。各模型的平均性能对比如表 1 所示。

表 1 各模型在测试集上的性能对比

数据集	ASSISTments2009		ASSISTments2017	
	AUC	ACC	AUC	ACC
BKT	0.5990	0.6946	0.5752	0.4077
DKT	0.7127	0.6104	0.5852	0.6366
DKT-DE	0.6961	0.5801	0.5647	0.6388
LKT-HR	0.8057	0.7631	0.7172	0.6739

根据表 1 结果可得出以下结论：首先，基于深度学习的 DKT、DKT-DE 及 LKT-HR 在 AUC 上均显著优于传统 BKT，表明深度建模能更有效捕捉学习中的复杂模式。其次，LKT-HR 在两个数据集上的 AUC 与 ACC 均全面领先；在 ASSISTments2009 上 AUC 达 0.8057，较 DKT 提升约 13.0%；在 ASSISTments2017 上 AUC 为 0.7172，提升约 22.5%，证实多特征融合能更全面刻画学习过程。此外，LKT-HR 也显著优于引入习题难度与作答经验的 DKT-DE，说明实时交互行为特征比静态聚合特征对即时预测更具价值。综上，融合提示与响应时间等多维特征的 LKT-HR 能更精准追踪知识状态，性能优于现有模型。

4.4.2. 消融实验设计

为探究答题正误（基础特征）、提示求助行为与首次响应时间等多维度学习行为对知识追踪模型性能的影响，本文在 ASSISTments2009 与 ASSISTments2017 数据集上进行了系统的消融实验。实验设置了四种模型变体：①仅使用基础特征（习题 ID 与答题正误）的 LKT-Base 模型，作为特征贡献分析的基准；②在 LKT-Base 基础上单独引入提示次数特征，得到 LKT-H 模型；③单独引入首次响应时间特征，得到 LKT-R 模型；④融合全部三类特征构成完整的 LKT-HR 模型。

实验结果如下表所示。整体上，完整模型 LKT-HR 在两个数据集的所有评估指标上均表现最佳，验证了多特征融合的有效性。与基础模型相比，引入提示特征（LKT-H）或响应时间特征（LKT-R）均能带来性能提升，其中提示特征的贡献更为显著。此外，特征间存在一定的交互协同效应，完整模型的性能提升超过各特征独立贡献之和，说明多维度特征在建模学习过程中具有互补作用。

表 2 消融实验结果对比

模型	2009-ACC	2009-AUC	2017-ACC	2017-AUC
LKT-HR（完整模型）	0.7631	0.8057	0.6739	0.7172
LKT-H（仅提示特征）	0.7312	0.7756	0.6456	0.6891
LKT-R（仅时间特征）	0.7218	0.7689	0.6321	0.6712

LKT-Base (基础特征)

0.7123

0.7512

0.6214

0.6589

4.5. 知识追踪可视化

为直观展示 LKT-HR 对学生知识状态的动态追踪能力, 本研究对测试集中学生交互序列进行了可视化分析, 主要包括知识状态演变热力图与习题相似性聚类两部分。

4.5.1. 知识状态演变热力图

以 ASSISTments2009 数据集中一名随机抽取的学生为例, 该学生共完成 42 次交互, 涵盖 5 个知识点 (k_1 至 k_5)。通过 LKT-HR 模型提取其每个时间步的知识掌握向量, 并将其按时间顺序绘制为热力图, 如图 1 所示。横轴为时间步 (交互顺序), 纵轴为知识点名称, 颜色深浅表示掌握程度 (0~1, 越深表示掌握越好)。

图中可见, 学生在第 12、18、25 时刻正确回答涉及知识点 k_3 的题目后, 该知识点掌握程度显著上升 (图中红色箭头标记的“Correct k_3 ”区域); 而在第 8、20 时刻回答错误后

(“Wrong k_1 ”和“Correct k_2 ”), 掌握程度有所下降。同时, 知识点 k_1 在第 6 至第 14 时刻未被再次练习, 其掌握程度随时间逐渐衰减, 表明模型能捕捉到因遗忘导致的掌握程度下降。这些变化符合“学习—遗忘”的教育心理学规律, 验证了 LKT-HR 模型在动态追踪学生知识状态方面的合理性与有效性。




图 1 学生知识状态动态演变热力图

4.5.2. 习题相似性聚类可视化

为进一步验证模型对习题潜在语义与难度结构的理解能力, 本研究基于 LKT-HR 模型中习题嵌入向量进行了聚类可视化。使用 t-SNE 降维技术将高维嵌入向量投影至二维平面, 并依据习题所属知识点进行着色标注, 结果如图 2 所示。相同知识点习题在二维空间中呈现聚集趋势, 表明 LKT-HR 能有效区分不同知识点并捕捉其间语义与难度关联, 为习题推荐与知识关联分析提供依据。




图 2 基于习题嵌入向量的知识点聚类可视化

5. 讨论

本研究提出并验证了融合多维度学习行为特征的轻量化知识追踪模型 LKT-HR。实验结果表明,该模型在 ASSISTments2009 与 2017 数据集上均显著优于 BKT、DKT 及 DKT-DE 等基线模型。这一核心发现验证了研究的基本假设:在学习行为表征中,从单一的答题正误(认知结果)扩展到融合提示求助(元认知策略)与响应时间(认知负荷)等多维过程性特征,能够实现对学习者知识状态更为精准和全面的动态描绘。

5.1. 与已有研究的对比与实践启示

本研究在特征融合与模型轻量化两个关键方向上,与近期相关研究形成了有意义的对话与推进。

在特征融合方面,本研究与李振等人(2022)提出的 DKT-FF 模型有一定相似之处,二者均强调融合多维度特征以提升预测性能。不同之处在于,DKT-FF 模型侧重于通过决策树选择测评行为特征,并利用知识传播机制融入知识结构,其特征工程更为复杂,且未突出过程性行为的独立价值。而 LKT-HR 则明确聚焦于提示求助与响应时间这两类更具解释性的过程特征,并通过简洁的归一化与标准化实现高效融合,使模型更贴近学习认知机理,也为融入更复杂的多模态信号提供了清晰接口。

在模型轻量化与效率考量方面,叶艳伟等人(2019)的研究指出,贝叶斯知识追踪扩展模型在使用学习者部分近期数据时,可能获得与全量数据相当甚至更优的预测精度,这源于遗忘效应使得远期数据对当前状态预测的贡献减弱。本研究通过使用单层 LSTM 模型结构与高效特征融合来降低计算开销,呼应这一观点。与徐墨客等人(2018)提出的多知识点 Logistic 回归扩展模型(KTLR 系列)相比,LKT-HR 避免了因引入大量题目难度、知识点组合参数而导致的模型复杂化,更适合大规模、高并发的实时教育场景。同时,本研究结果也间接支持了王志锋等人(2021)的观点:面向智慧教育的知识追踪模型应在性能与可部署性(轻量化)之间寻求平衡,而非一味追求预测精度的边际提升。

在研究框架与趋势响应方面,卢宇等人(2021)指出当前 KT 模型存在可解释性弱、迁移能力差等挑战。LKT-HR 可视为对该挑战的回应:通过选用具有明确教育心理学含义的过程特征,增强了模型的可解释性;轻量化设计则有助于跨场景迁移部署。此外,戴静等人(2022)对认知诊断与知识追踪的辨析,凸显了 KT 在时序动态建模方面的核心价值。LKT-HR 通过 LSTM 对过程特征序列的建模,正强化了这一动态追踪能力,使其不仅能判断“是否掌握”,也能部分揭示“如何学习”。

在实践层面,LKT-HR 模型的应用有望在多个方面赋能智慧教育。对于教师与管理者,模型输出的动态知识状态图谱可作为精准学情分析的仪表盘,帮助识别班级整体的知识薄弱环节与个体的异常学习轨迹(如长期依赖提示、响应时间异常波动),从而实施有针对性的群体教学或个别辅导。对于学习系统开发者,轻量化的模型特性便于集成到各类在线学习平台、自适应学习工具乃至移动学习应用中,实现实时、低延迟的知识状态追踪与预测,为动态调整学习路径、推送适应性习题或学习内容提供核心驱动。对于学习者自身,基于过程特征的评估反馈(例如,提示使用效率分析、时间分配建议)或许能间接促进其元认知能力的发展,引导其成为更善于自我监控与调节的自主学习者。

5.2. 局限性与未来工作

尽管本研究取得了积极的结果,但仍存在若干局限性。第一,数据与场景的局限性。模型仅在数学学科的 ASSISTments 数据集上进行了验证。不同学科的学习行为模式、提示的设计与作用、响应时间的意义可能存在差异,未来研究需要在更广泛的学科领域和在线学习平台数据上检验模型的泛化能力。第二,特征覆盖的局限性。当前模型主要利用了结构化日

志中的显性行为特征,尚未充分挖掘自由文本作答、社交交互、眼动等多模态非结构化数据,融合此类复杂数据是提升模型感知深度的重要方向。第三,模型机理的局限性。LSTM虽能有效处理序列,但对知识点间复杂的先验知识结构的建模能力有限。未来可探索引入图神经网络显式编码知识图谱,以支持知识迁移建模;也可尝试Transformer线性变体等轻量架构,以处理更长学习序列。第四,实证验证的缺失。本研究主要进行了计算实验验证尚未在真实课堂环境中验证模型对学习效率、学业成绩等的实际影响。未来应开展教育干预实验,完成从“算法有效”到“教学有效”的闭环验证。

参考文献

- 中华人民共和国教育部、中央网络安全和信息化委员会办公室、国家发展和改革委员会 等九部门.(2025). 教育部等九部门关于加快推进教育数字化的意见 (教办〔2025〕3号).
- 王志锋,熊莎莎,左明章,闵秋莎 & 叶俊民.(2021).智慧教育视域下的知识追踪:现状、框架及趋势.远程教育杂志, 39(05), 45-54.
- 石君太.(2023).基于多特征融合和记忆感知的深度知识追踪模型研究(硕士学位论文,兰州大学).
- 叶艳伟,李菲茗,刘倩倩 & 林丽娟.(2019).知识追踪模型融入遗忘和数据量因素对预测精度的影响.中国远程教育, (08), 20-26.
- 卢宇,王德亮,章志,陈鹏鹤 & 余胜泉.(2021).智能导学系统中的知识追踪建模综述.现代教育技术, 31(11),87-95.
- 刘雯蔚,余敦辉 & 吕志闯.SMKT: 融合结构感知与多粒度认知建模的知识追踪方法.计算机科学,1-17.
- 李振 & 周东岱.(2022).人工智能支持下基于特征融合的深度知识追踪模型研究.电化教育研究,43(04),47-54.
- 杨文阳 & 杨益慧.(2024).聚焦可解释性:知识追踪模型综述与展望.现代教育技术,34(05),53-63.
- 李菲茗,叶艳伟,李晓菲 & 史丹丹.(2019).知识追踪模型在教育领域的应用:2008—2017年相关研究的综述.中国远程教育,(07),86-91.
- 周楚雄,张丽萍,闫盛,李娜 & 王东奇.基于图神经网络的深度知识追踪方法综述.计算机工程与应用,1-27.
- 贺步贵,董永权,贾瑞 & 金家永.(2024).基于多行为特征嵌入记忆网络的知识追踪模型.太原理工大学学报, 55(01), 184-194.
- 徐墨客,吴文峻,周莹 & 蒲彦均.(2018).多知识点知识追踪模型与可视化研究.电化教育研究,39(10),53-59.
- 梁祥,刘梦赤,胡婕 & 冯嘉美.(2023).融合习题难度和作答经验的深度知识追踪模型.华南师范大学学报(自然科学版),55(04),81-86.
- 葛志强.(2025).基于知识追踪的情感支持元认知自我调节学习模型构建研究(硕士学位论文,江西师范大学).
- 翟羽佳. 基于自我评估学习对元认知能力优化影响的后期追踪访谈研究[J]. 教育进展, 2022, 12(11): 4798-4806.
- 戴静,顾小清 & 江波.(2022).殊途同归:认知诊断与知识追踪——两种主流学习者知识状态建模方法的比较.现代教育技术,32(04),88-98.
- Wise, S. L., & Kong, X. (2005). Response time effort: A new measure of examinee motivation in computer-based tests. *Applied Measurement in Education*, 18(2), 163–183.
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37–63.
- Feng, M., Heffernan, N., & Koedinger, K. (2009). Addressing the assessment challenge in an online system that tutors as it assesses. *User Modeling and User-Adapted Interaction*, 19(3), 243–266.
- Feng, M., Heffernan, N., & Heffernan, C. (2018). Towards an evidence-driven educational data mining: A curated collection of the ASSISTments online learning dataset 2017. *Journal of Educational Data Mining*, 10(2), 1–10.
- Pelánek, R. (2017). Bayesian knowledge tracing, logistic models, and beyond: An overview of learner modeling techniques. *User Modeling and User-Adapted Interaction*, *27*(3–5), 313–350.

- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.
- Shen, S., Liu, Q., Huang, Z., Zheng, Y., Yin, M., Wang, M., & Chen, E. (2021). A survey of knowledge tracing: Models, variants, and applications. *arXiv*.
- Corbett, A. T., & Anderson, J. R. (1994). Knowledge tracing: Modeling the acquisition of procedural knowledge. *User Modeling and User-Adapted Interaction*, 4*(4), 253–278.
- Piech, C., Bassen, J., Huang, J., Ganguli, S., Sahami, M., Guibas, L., & Sohl-Dickstein, J. (2015). Deep knowledge tracing. In C. Cortes, N. Lawrence, D. Lee, M. Sugiyama, & R. Garnett (Eds.), *Advances in neural information processing systems 28* (pp. 505–513). Neural Information Processing Systems Foundation.