

# 智能教育领域的知识追踪模型综述<sup>①</sup>

赵 娅, 托晋宽, 单可欣, 贾 迪

(东北石油大学 计算机与信息技术学院, 大庆 163318)

通信作者: 赵 娅, E-mail: [lindaya11@163.com](mailto:lindaya11@163.com)



**摘要:** 知识追踪技术可以对学生题目作答序列等数据进行分析, 从而准确预测学生的知识点掌握状况, 以帮助教育管理者更精确地对学生进行教学干预, 提升学生的学习效果。随着时间的推移, 知识追踪技术已经成为实现智能教育目标的重要辅助手段, 并在智能教育领域得到了广泛应用。本综述主要研究智能教育领域的知识追踪技术发展现状。首先, 本综述对知识追踪技术进行了概念界定; 随后, 分析了两类智能教育领域的知识追踪模型及其存在的问题, 同步总结了国内外研究者对这些问题的应对策略; 接下来, 探讨了智能教育领域知识追踪模型的实际应用场景; 最后, 明确指出了智能教育领域的知识追踪模型面临的各种挑战, 并对其未来发展进行了展望。

**关键词:** 知识追踪; 智能教育; 深度学习; 贝叶斯网络

引用格式: 赵娅, 托晋宽, 单可欣, 贾迪. 智能教育领域的知识追踪模型综述. 计算机系统应用, 2025, 34(6):1-11. <http://www.c-s-a.org.cn/1003-3254/9903.html>

## Review of Knowledge Tracing Models in Intelligent Education Field

ZHAO Ya, TUO Jin-Kuan, SHAN Ke-Xin, JIA Di

(School of Computer and Information Technology, Northeast Petroleum University, Daqing 163318, China)

**Abstract:** Knowledge tracing technology analyzes data, such as students' response sequences to questions, to accurately predict their mastery of knowledge points. This allows for more precise educational interventions and improves students' learning outcomes. Over time, knowledge tracing technology has become a vital tool in achieving intelligent education goals and is widely applied in this field. This review examines the current development of knowledge tracing technology in intelligent education. First, the concept of knowledge tracing technology is defined. Next, two types of knowledge tracing models and their associated issues are analyzed, and the strategies proposed by researchers to address these challenges are summarized. The review then explores the practical application scenarios of knowledge tracing models in intelligent education. Finally, various challenges faced by knowledge tracing models in this field are outlined, and future development prospects are discussed.

**Key words:** knowledge tracing; intelligent education; deep learning; Bayesian network

随着物联网、云计算、大数据、泛在网络、人工智能、深度学习等新技术的快速发展, 我国教育快速步入智能时代<sup>[1]</sup>。2018年, 教育部印发的《教育信息化2.0行动计划》<sup>[2]</sup>强调要推动智能教育环境的建设, 教育信息化2.0新阶段的目标就是发展智能教育。智

能教育作为人工智能时代教育教学的必然趋势, 是我国教育研究和实践的重要内容, 也是我国教育数字化转型的重要组成部分<sup>[3]</sup>。其本质在于, 利用信息技术与人工智能技术等前沿技术, 实现提升学习效果、个性化学习、智能化教学等目标。要实现智能教育的目标,

① 基金项目: 国家人文社会科学基金(22BTJ046); 黑龙江省哲学社会科学规划项目(22EDE389)

收稿时间: 2024-11-26; 修改时间: 2025-01-24; 采用时间: 2025-02-18; csa 在线出版时间: 2025-04-30

CNKI 网络首发时间: 2025-05-06

阐释学习者的学习特征是其中的重要一环。根据学习者的学习特征，可以对其进行有针对性的学习干预，以提升其学习效果。知识掌握状态是学习者的一个重要的学习特征，因此，在智能教育领域，如何有效地对学习者的知识掌握状态进行诊断成为一个备受关注的问题。

知识追踪是一种可以对学习者知识掌握状态进行诊断的技术<sup>[4]</sup>。其不仅能够对学习者的知识状态进行建模，以诊断学习者对每一个知识点的掌握情况，及时识别那些在特定知识点的学习上遇到困难的学习者。此外，它还能协助教师和教学辅助系统为学习者提供针对性的学习建议和个性化的学习帮助，帮助学习者规划学习路径，为学习者推荐与其当前知识水平相匹配的学习资源，从而实现智能教育的目标，提高学习者的学习效果。因此，从这一点来看，知识追踪是智能教育领域一种有效的辅助工具。

本文聚焦于智能教育领域的知识追踪技术，将探讨并尝试解答如下问题，为今后相关领域的研究人员提供指导：(1) 知识追踪的概念如何界定？(2) 目前两类智能教育领域的知识追踪模型存在哪些问题？(3) 国

内外学者是如何解决这些问题的？(4) 目前，智能教育领域的知识追踪模型具体有哪些应用场景？(5) 在未来，智能教育领域的知识追踪模型还将面临哪些挑战？将来的发展方向会是怎样的？

## 1 知识追踪的概念界定

1994年，卡内基梅隆大学的Corbett等人<sup>[5]</sup>将知识追踪技术引入智能教育领域。知识追踪技术即借助计算机技术与数据分析技术，对学习者的知识状态进行动态建模，其可以根据学习者的题目作答序列，包括作答题目与作答结果，预测学习者的知识点掌握状态与下一次答题正确的概率<sup>[6]</sup>。

知识追踪如图1所示，其过程可以形式化为：给定一个学习者的题目作答序列  $X = \{x_1, x_2, \dots, x_{t-1}, x_t\}$ ，序列中每个  $x_t$  代表一个元组  $\{q_t, r_t\}$ ， $q_t$  表示题目的编号， $r_t$  表示题目的作答结果， $r_t$  为0代表学习者答错了题目，为1代表学习者答对了题目。知识追踪可以利用学习者的题目作答序列对其知识状态进行建模，进而预测学习者正确回答每一道问题的概率即  $Pt(r_t=1|q_t, X)$ ，与学习者的知识点掌握状况。

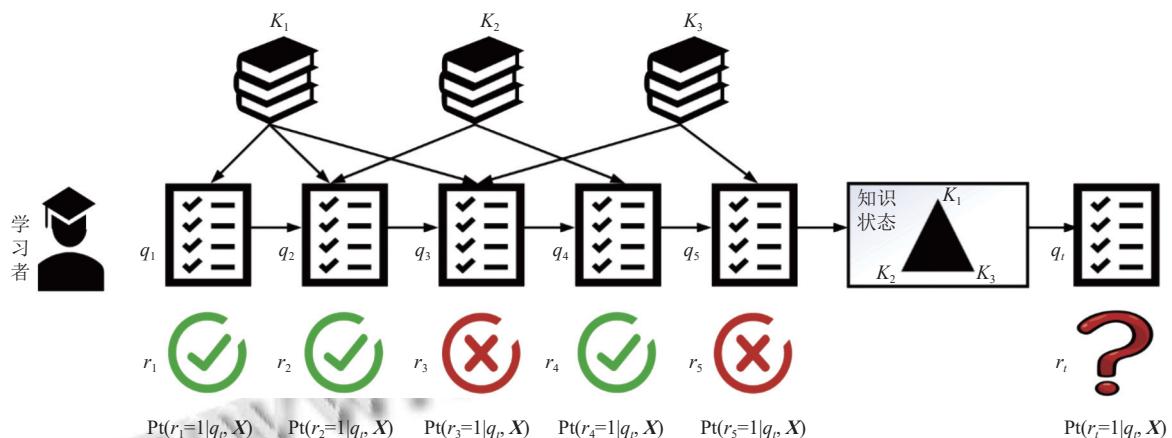


图1 知识追踪过程

目前，智能教育领域的知识追踪技术主要包含两类知识追踪模型，一类是基于机器学习的贝叶斯知识追踪模型，另一类是基于深度学习的知识追踪模型。接下来，本文将对这两类智能教育领域的知识追踪模型的当前研究状况进行整理。

## 2 贝叶斯知识追踪模型

### 2.1 贝叶斯知识追踪模型的工作原理

贝叶斯知识追踪模型 (Bayesian knowledge tracing,

BKT) 将学习过程建模为学习者从未掌握知识点到掌握知识点的动态变化，将学习者的知识状态建模为掌握和未掌握知识点的二进制变量。BKT 模型作为一种传统的知识追踪模型，自 1995 年起，被引入到智能教育领域中。

在 BKT 模型中，学生的知识掌握概率受学习者在学习前对知识的掌握概率  $P(L)$ 、学生从未掌握知识到掌握知识的概率  $P(T)$ 、学生未掌握知识点但答对习题的概率即猜测概率  $P(S)$ 、学生掌握知识点但答错习题

的概率即失误概率  $P(G)$  这 4 个参数影响。该模型的输入是学习者题目作答序列，输出则是学习者已经掌握和尚未掌握知识的二分状态（若学习者已经掌握知识，输出 1，未掌握知识，输出 0），具体模型结构图如图 2 所示。

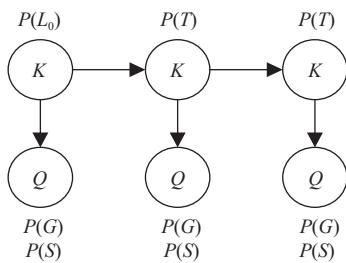


图 2 BKT 知识追踪模型结构图

标准的 BKT 模型实现了对学习者知识状态的建模，模型结构简单并且具有较强的可解释性。然而，BKT 模型没有考虑学习者在学习过程中会有遗忘知识点的情况发生，也没有考虑学习者之间的差异，并且不能面向多个知识点进行建模。这些问题在很大程度上影响了 BKT 模型在智能教育领域中的应用。因此，鉴于这些问题，国内外的研究者对 BKT 模型进行了优化。主要有如下 3 个分类。

## 2.2 融入遗忘因素的贝叶斯知识追踪模型

在学习的过程中，学习者往往会遗忘某些知识点，并且不同的学习者的知识点遗忘情况也有所不同。BKT 模型在设计时忽略了学习者的遗忘因素，这与实际的学习过程并不吻合，从而导致了模型预测的结果与学习者真实的学习情况之间出现了某种程度的偏差。因此，众多学者对融入遗忘因素的 BKT 模型进行了研究。

如 2015 年，Nedungadi 等人<sup>[7]</sup>在 BKT 模型中加入了时间衰减函数，不仅解决了 BKT 模型的遗忘问题，还提高了模型的预测精度。2021 年，黄诗雯等人<sup>[8]</sup>提出了一种融合学习者的行为和遗忘因素的贝叶斯知识追踪模型 BF-BKT。BF-BKT 在传统的 BKT 模型中融入了遗忘参数。遗忘参数将与其他 4 个参数共同作用，计算和更新学习者对各个知识点的掌握水平。

综上，融入了遗忘因素的 BKT 模型更符合学习者的学习情况，可以更好地面向智能教育领域。并且与传统的 BKT 模型相比，融入了遗忘因素的 BKT 模型具有更高的预测精度。

## 2.3 融入学习者差异特征的贝叶斯知识追踪模型

BKT 模型没有考虑到学习者之间的个性化差异特征，这种特征同样会对知识追踪的结果产生影响，因此

一些学者提出了一些融合了学习者差异特征的知识追踪模型。

2010 年，Pardos 等人<sup>[9]</sup>在将每位学习者的先验知识差异参数  $P(L[S])$  融入 BKT 知识追踪模型中，从而成功构建了一个名为 PPS 的学习者先验知识追踪模型。由于每位学习者所拥有的先验知识参数各不相同，这使得该模型的预测结果相较于传统 BKT 模型更加准确。

2016 年，Yudelson 等人<sup>[10]</sup>在 BKT 模型中考虑了学习者间的个体差异，在 BKT 模型中加入了学习者参数来表示学习者的个体差异，提出了一种名为 IBKT 的个性化知识追踪模型。这个模型充分考虑了学习者之间的差异，并且，由于该模型的参数经过了正则化处理，其能够较好地拟合数据，有效地防止了过拟合现象的发生。

综上，在融入了学习者差异特征后，模型的预测结果更加能反映出学习者个性化差异，更能满足智能教育的需求，模型的表现也得到了进一步的增强。

## 2.4 多知识点方面的贝叶斯知识追踪模型

BKT 模型对知识点进行了独立建模，其假设每一个习题仅涉及一个知识点，因此其无法对包含多个知识点的习题进行分析。但在真实的智能教育情境中，知识点并不是孤立存在的。一个问题可能涵盖多个不同的知识点，并且这些知识点之间存在明确的层次结构。基于此局限性，众多学者在多知识点方面对模型进行了优化。

如 2017 年，Käser 等人<sup>[11]</sup>提出的动态贝叶斯知识追踪模型。该模型采用了动态贝叶斯网络 DBN 来对学习者的知识状态进行建模，它能够在模型中同时联合表示多个知识点，并且充分考虑了这些知识点之间的层次联系和依赖关系，克服了传统 BKT 模型在处理多知识点建模上的局限性。

2018 年，徐墨客等人<sup>[12]</sup>为了解决传统 BKT 模型无法分析涉及多个知识点的习题的局限性，采用了 Logistic 回归方法将猜对概率、犯错概率、题目难度、观测参数和状态转移参数等作为模型的特征，从而提出了 3 种面向多知识点的 BKT 改进模型：KTLR-GS 模型、KTLR-LFID 模型和 KTLR-FP 模型，这 3 个模型都具有比 BKT 模型更为出色的分析能力。

综上，多知识点方面的 BKT 模型有效地解决了传统 BKT 模型在多知识点处理方面存在的缺陷，从而增

强了模型的预测分析能力,可以更好地适应智能教育的环境.

## 2.5 总结

虽然上文提到的3类优化方法取得了显著的效果,但BKT模型却存在固有的局限性. BKT模型将学习者的知识状态划分为已掌握和未掌握两种状态,但这两种状态并不能完全反映学习者知识状态的演变过程,学习者可能处于已掌握和未掌握知识点的过渡状态.并且BKT模型不能实现习题和知识点之间的一一对应关系.此外,在数据处理过程中BKT模型可能会丢失关键的数据信息.因此,BKT模型在智能教育实践中推广较为困难.

## 3 基于深度学习的知识追踪模型

### 3.1 深度知识追踪模型

由于贝叶斯知识追踪模型具有局限性,难以在智能教育领域推广.而近年来深度学习以其强大的特征提取能力,以及无需人工标记数据信息的优点,引起了学者的广泛关注<sup>[13]</sup>.

2015年,斯坦福大学的Piech等人<sup>[14]</sup>将深度学习技术应用到知识追踪领域,提出了深度知识追踪模型

(deep knowledge tracing, DKT). DKT将知识追踪问题建模为时间序列预测问题,利用循环神经网络RNN,将学习者的答题序列作为输入,输出为学习者的答题表现.

DKT模型分为输入层、隐藏层与输出层.输出层将学习者题目作答序列 $\{x_1, x_2, \dots, x_t\}$ 输入到模型中<sup>[15]</sup>.输出层即输出学习者习题的作答表现 $\{y_1, y_2, \dots, y_t\}$ ,表示学习者每一时刻正确作答习题的概率.在输入层与输出层之间的隐藏层,存储着学习者每一时刻的知识状态 $\{h_1, h_2, \dots, h_t\}$ .模型的具体结构图如图3所示.

从图3可以看出,模型的隐藏层是由上一时刻的知识状态和当前时刻模型的输入决定的,而模型的输出层是由当前时刻的知识状态决定的.

与BKT模型的二分状态不同,DKT模型中的知识点掌握状态是用0-1的数字来表示的,代表了学习者知识点的掌握概率. DKT模型的知识点掌握状态表示方法可以更准确地反映学习者的知识掌握水平和他们持续的知识变化情况.因此,DKT模型可以更好地利用学习者历史的答题序列来预测学习者的表现.表1为贝叶斯知识追踪模型BKT与深度知识追踪模型DKT的对比.

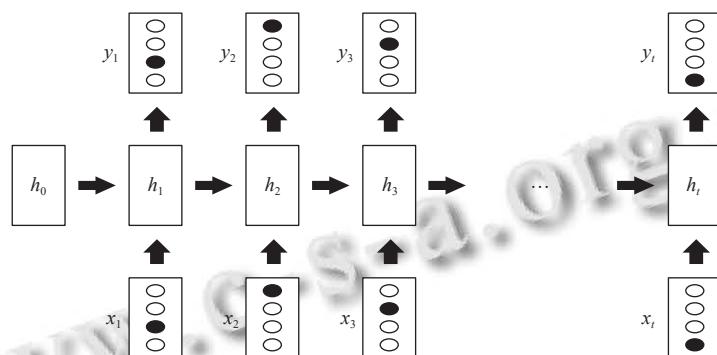


图3 DKT知识追踪模型结构图

表1 DKT与BKT模型对比

类别	BKT	DKT
工作原理	基于一阶马尔可夫模型,利用贝叶斯概率公式来计算学习者对知识点的掌握概率.	基于神经网络模型,将知识追踪问题建模为时间序列预测问题.
输出	若学习者已经掌握知识,输出1,未掌握知识,输出0.	学习者习题的答题表现 $\{y_1, y_2, \dots, y_t\}$ , $y_i$ 用0-1的数字来表示,代表了学习者知识点的掌握概率.
优点	模型结构简单并且具有较强的可解释性.	可以更准确地反映学习者的知识掌握水平和他们持续的知识变化情况,准确性较好,扩展性良好,易于改进.
存在的主要问题	不能准确反映学习者知识状态,可扩展性有限.	缺乏可解释性、缺少学习行为特征.

然而,DKT模型具有可解释性差、缺少学习特征、缺少习题特征等缺陷,极大地限制了DKT模型在

智能教育领域中的应用<sup>[16]</sup>. DKT模型因其缺乏可解释性,不能直接从隐藏层中提取学习者的真实知识状况,

这构成了 DKT 模型的一个显著短板。并且 DKT 模型缺少学习者学习行为特征与问题特征, 不能很好地模拟学习者真实的学习过程。

因此, 大量的学者陆续探索了如何对基于深度学习的知识追踪模型进行优化, 使基于深度学习的知识追踪模型能更好地面向于智能教育领域。经过学者们的不懈努力, 目前主要出现了 4 类基于深度学习的知识追踪模型的改进方向。

### 3.2 改进网络模型的知识追踪模型

由于 DKT 模型具有可解释性差的问题, 无法从模型的隐藏层中获取学习者的知识状态, 因此, 一些学者利用新的神经网络模型来完成知识追踪任务, 例如动态键值记忆网络以及图神经网络。

#### (1) 基于动态键值记忆网络的知识追踪模型

2017 年, Zhang 等人<sup>[17]</sup>提出了基于动态键值记忆网络的知识追踪模型 (dynamic key-value memory networks for knowledge tracing, DKVMN)。DKVMN 模型拥有一个被称为键矩阵的静态矩阵  $M^K$ , 大小为  $Q \times dk$ , 用于储存知识点, 以及一个被称为值矩阵的动态矩阵  $M^V_t$ , 用于储存和更新学习者对知识点的掌握状态 ( $Q$  代表输入指标集中题目所涉及知识点的数量,  $dk$ 、 $dv$  代表矩阵的维数)。DKVMN 可以通过值矩阵直接地输出学习者知识点的掌握状态。DKVMN 的工作过程分为读过程与写过程, 在读过程中, 习题的相关知识点被储存在  $M^K$  里, 而学习者对知识点的掌握状态则被保存在  $M^V_t$  里, 通过读取学生答题结果  $q_t$  与键矩阵, 模型可以预测学习者的答题表现, 输出序列  $\{p_1, p_2, \dots, p_t\}$ , 代表学生每一时刻作答正确的概率; 在写过程时, 模型可以利用学习者的答题结果来更新值矩阵  $M^V_t$ , 具体过程为: 模型要先使用擦除加法机制计算出擦除矢量  $e_t$ , 然后计算出添加矢量  $a_t$ ,  $e_t$ 、 $a_t$  将用于更新知识状态矩阵<sup>[18]</sup>。

图 4 为 DKVMN 知识追踪模型结构图。

综上, DKVMN 模型不仅打破了 DKT 模型隐藏状

态的限制, 可以显示地输出学习者每个知识点的掌握状态, 并且 DKVMN 模型通过增加读写过程来控制记忆状态更新, 使其具有比 RNN 和 LSTM 更强的记忆建模能力<sup>[19]</sup>。DKVMN 模型由于其独特的优点, 在智能教育领域得到了广泛的应用。

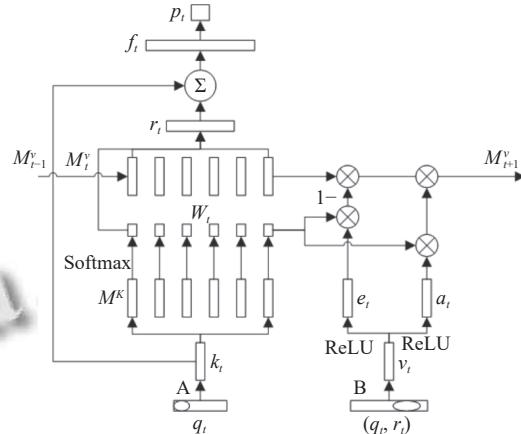


图 4 DKVMN 知识追踪模型结构图

#### (2) 图神经网络知识追踪模型

图神经网络知识追踪模型 (graph-based knowledge tracing, GKT) 由 Nakagawa 等人<sup>[20]</sup>于 2019 年提出, 图神经网络知识追踪模型将学习者的知识结构建模为一个图, 图的节点表示知识点的概念, 而图的边表示知识点的依赖关系, 图的邻接矩阵则表示知识点的依赖程度, 基于此, 图神经网络知识追踪模型能够对多个知识点间的复杂关系进行建模。值得强调的是, 当学习者解答了有关知识点  $i$  的习题后, GKT 模型不仅要更新知识点  $i$  的知识状态, 还需更新与知识点  $i$  相对应的节点的邻接节点的知识状态。并且, GKT 模型能够借助图的边信息, 从每个知识点节点以及其邻接节点中获取学习者的隐藏知识状态, 并据此预测并输出学习者在下一时刻正确回答每个知识点的概率, 也就是学习者对每个知识点的掌握状态。

图 5 为 GKT 知识追踪模型结构图。

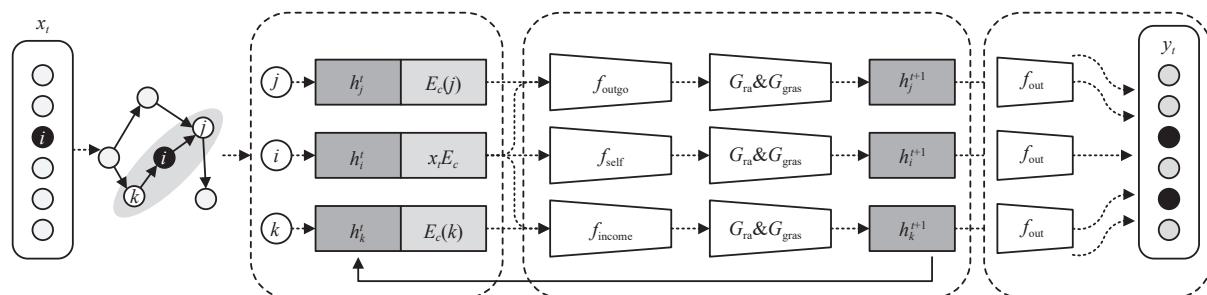


图 5 GKT 知识追踪模型结构图

综上,正是因为图神经网络知识追踪模型的结构特点,其可以预测并显示地输出学生的知识状态,有效地提升了知识追踪模型的可解释性。此外,该模型还能很好地识别知识点与习题之间的依赖关系。通过应用GKT模型,教师和教学辅助系统能够更准确地识别学习者的知识状态,并据此推动个性化学习的实施,实现智能教育的目标。因此,GKT模型在智能教育领域展现出了巨大的应用前景。

### (3) 其他改进

除了动态键值记忆网络与图神经网络,其他网络也可以实现知识追踪任务。如图卷积神经网络。

图卷积神经网络(GCN)的核心思想为将卷积操作扩展到图结构上,通过对每个节点及其相邻节点的信息进行聚合和转换,能够自动学习节点的表示,从而捕捉图结构中的局部和全局特征。应用图卷积神经网络的知识追踪模型如2024年,Dao等人<sup>[21]</sup>提出的GCKT知识追踪模型,该模型利用图卷积神经网络增强知识点的局部特征,提高了模型效果,并降低了过拟合的风险。2024年,Hu等人<sup>[22]</sup>提出了一种基于动态广度图卷积网络(DBGN)的知识追踪模型,将图卷积网络模型的变体引入知识追踪领域。该模型可以从动态构建的拓扑图中高效地获取问题和知识点的表示,可以更好地捕捉学生知识状态的动态变化。

也有的学者对网络模型的注意力机制进行了改进。如2019年,Pandey等人<sup>[23]</sup>提出的SAKT知识追踪模型,该模型使用自注意力机制,通过识别学生过去所有题目作答数据交互之间的相关性,更好地应对数据稀疏的问题,更准确地预测学生学习表现。2024年,Xu等人<sup>[24]</sup>将多频带注意力机制融入知识追踪模型,通过使用不同的衰减率计算注意力权重,自适应地捕捉不同知识概念的长期和短期交互对知识状态的影响,以获取更加准确的知识追踪结果。2025年,王聪等人<sup>[25]</sup>提出了RAKT知识追踪模型,该模型使用Transform编码-解码器追踪学生的知识掌握水平变化,并融入了学生的知识水平与遗忘行为,具有良好的知识追踪的准确性。

综上所述,随着深度学习的发展,越来越多的新机制、新网络被广泛应用于知识追踪任务,进一步提升了知识追踪模型的性能。在这一趋势的推动下,智慧教育领域的知识追踪模型将迎来更加蓬勃的发展。

### 3.3 改进可解释性的知识追踪模型

由于DKT模型可解释性较差,限制了其在智能教

育中的应用。鉴于此,部分学者对知识追踪模型的可解释性进行了优化。

2019年,Yeung等人<sup>[26]</sup>提出了Deep-IRT模型。该模型结合项目反应理论(IRT),在知识模型中加入学习者能力网络和项目难度网络,通过分析学习者的答题记录,可以估算出学习者的能力与项目难度,使知识追踪方法更具有可解释性。2019年,Hu等人<sup>[27]</sup>在深度知识追踪中引入了评估不确定性的概念,为每一次预测都提供了不确定性的评分,并进一步采用了正则化损失函数,将这种不确定性整合到深度知识追踪中,减少了预测学习者知识状态时的不确定性问题,增强了模型的可解释性。2021年,刘坤佳等人<sup>[28]</sup>提出了可解释深度知识追踪模型IDKT,该模型引入了习题的上下文信息来挖掘习题与知识点间的隐含关系,可以得到更有表征能力的习题与知识点表示,以缓解数据稀疏的问题,并利用RNN模型预测学习者的知识点掌握状态,并基于学习者的知识状态的注意力权重,生成一条推理路径来解释预测结果,以提高模型的可解释性。2023年,陈成等人<sup>[29]</sup>提出了适用于KT事后可解释性的Shapley Value和ISP算法以及可解释性评价指标和谐度,以DKT模型为例计算了历史交互与预测结果之间的相关性分数,解释了DKT的预测结果,提高了知识追踪模型的可解释性。

综上,改进可解释性的知识追踪模型成功地解决了DKT模型在预测过程中存在的不可解释性问题,并更为有效地应对了知识交互等解释性问题。

### 3.4 融入习题特征的知识追踪模型

每一个习题都具有其独特的特征,而传统的基于深度学习的知识追踪模型不仅忽视了学习者的学习特征,也忽视了题目本身的特性,例如题目的难度、题目的文本信息以及题目和知识点之间的关系等。如果能在知识追踪模型中整合这些特征,那么模型的预测精度都将得到显著提升。

例如,2021年,Liu等人<sup>[30]</sup>提出了一种练习感知知识追踪模型EKT,该模型将文本信息整合到知识追踪模型中,通过有效地利用问题文本的内容,显著提升了知识追踪的准确性能。2020年,Liu等人<sup>[31]</sup>提出了一种以二分图为基础的预训练嵌入知识追踪方法PEBG,这种方法利用问题的难度和问题与知识概念之间的关系作为辅助信息来进行预训练嵌入,接着利用这种嵌入训练DKT与DKVMN模型,显著地提升了这两种模

型的预测性能。2024年,许智宏等人<sup>[32]</sup>利用图卷积神经网络技术对问题和知识点的相关特性进行了建模,并据此提出了一个名为QFEKT的基于问题特征增强的知识追踪模型,该模型利用问题匹配模块和学习者知识状态表征模块来进一步强化问题的特性,同时,学习者问题表征模块将双向长短期记忆网络与注意力机制相结合,以增强问题特征来建模学习者的知识状态。在2023年,梁祥等人<sup>[33]</sup>通过分析答题序列来评估习题的难度和学习者的答题经验,并将评估结果融入模型的输入层中,提出了一种融合习题难度和答题经验的深度知识追踪模型DKT-DE,该模型不仅有效针对了现有的知识追踪模型缺乏对习题和学习者特征信息综合考虑的问题,而且还显著提升了模型的预测性能。2023年,Chen等人<sup>[34]</sup>结合练习题的特征,改进了包含相同概念的练习题的差异化表示,并描述了两种传播知识点状态的方式:单向和双向,分别用于更新当前知识点及其相关知识点的状态。

综上,近年来,融入习题特征的知识追踪模型数量日益增多,并取得了良好的效果,在智能教育领域具有广阔的应用前景。

### 3.5 融入学习者特征的知识追踪模型

DKT模型、DKVMN模型、GKT模型都忽略了学习者在学习过程中的学习特征,如:学习者作答习题的时间、习题作答次数、学习者能力等,这些学习特征反映了学习者之间的差异。另外,遗忘因素也是重要的学习者特征。如果能将这些学习特征融入知识追踪模型,必能提升模型的预测性能,使知识追踪模型更好地面向智能教育领域。因此,许多学者对知识追踪模型进行了改进,提出了融入学习者特征的知识追踪模型。

如2019年,Ai等人<sup>[35]</sup>对DKVMN模型进行了改进,将学习者的作答结果和练习时间融入了DKVMN模型,提出了DKVMN-CA模型,利用学习者的作答结果和练习时间来更新学习者的知识状态,提升了模型预测的准确性。2021年,王斌等人<sup>[36]</sup>提出了一种融合多种特征的知识追踪模型DKTwMF,这个模型通过利用邻域信息和随机森林来选择学习者特征,并对这些特征数据进行编码,并利用深度学习技术自动识别出数据集中的关键特征,并将这些特征融入知识追踪模型来更精确地评估学习者的知识状态。2022年,Sun等人<sup>[37]</sup>提出一种结合学习者能力的知识追踪模型DKVMN-LA,此算法根据学习者的历史答题记录,分析出学习者的学习能力,并将学习者分为3个不同的组,可以更

加方便地指导个性化学习。2021年,杨尚辉<sup>[38]</sup>综合考虑了学习者的知识水平、学习能力和遗忘行为等与学习行为有关的多个因素,从学习者的历史做题序列数据中提取了这4个关键特征,并将这些特征组合起来作为模型输入,并基于这些特征,设计了一个2D卷积网络来处理这些特征,提出了一个名为C2DKT的基于2D卷积神经网络的知识追踪模型。2022年,王璨等人<sup>[39]</sup>提出了融合学习者个人先验基础和遗忘因素的时间卷积知识追踪模型TCN-KT,该模型首先利用RNN网络计算得出学习者的先验基础,接着利用TCN时间卷积网络预测学习者作答下一习题的正确率,最后在模型中融入了学习者的先验基础与遗忘因素。2022年,李浩君等人<sup>[40]</sup>利用BORUTA特征选择模型挖掘了在线学习过程中的多维特征,在DKVMN模型基础上构造多维特征网络,设计了融合学习过程特征的知识追踪模型,提出了深度知识追踪优化方法DKVMN-BORUTA。2024年,李子杰等人<sup>[41]</sup>提出了一种名为SLKT的知识追踪模型,该模型将序列特征与学习过程相结合,有效地解决了传统基于知识状态建模方法在考虑学习者近期学习状态方面的局限性,同时,他们还引入了一种带有约束条件的动态Q矩阵,用以描述练习与知识点之间的相互关系,从而更精确地进行学习者学习过程的建模。这不仅确保了模型具有良好的可解释性,还有效地提高了模型的准确性。2023年,孙浩等人<sup>[42]</sup>提出了一种基于序列中遗忘行为的动态键值记忆网络DKVMN-F,在这个网络中,重复的时间间隔被视为遗忘的因素,而过去的答题次数则被视为学习的因素,通过在DKVMN的预测层中应用门控机制,整合了遗忘和学习两个因素,从而实现了对知识的有效追踪。2024年,贺步贵等人<sup>[43]</sup>提出了一种名为多行为特征嵌入记忆网络的知识追踪模型MFKT。这个模型综合考虑了学习过程中的两种行为:学习和遗忘,模型首先从交互记录中提取了学习和遗忘这两个主要特征,然后通过标量交叉的方式将这些特征嵌入到记忆网络中,同时,遗忘特征也通过向量组合的方式被嵌入,以增强模型对学习者答题序列的学习能力。2024年,Shou等人<sup>[44]</sup>利用学生座位关系、学生间互动、抬头或低头状态等特征,建立学生参与度模型,并利用学生参与度模型与学生答题结果数据共同预测学生知识状态。

综上,融入学习者特征的知识追踪模型可以更好地模拟学习者的学习过程,进而更准确地评估学习者的知识状态,提升了模型的性能与可解释性,使模型的

预测结果能更好地应用于智能教育实践中。

## 4 智能教育领域的知识追踪模型应用场景

### 4.1 学习资源推荐

学习资源推荐是知识追踪模型在智能教育领域的重要应用场景。学习资源推荐指的是教师与教学辅助系统根据学习者的个体差异，智能地为他们推荐合适且有效的学习资源，从而提升其学习效果。推荐给学习者的学习资源包括习题、学习视频和文章等多种形式的学习资料。

在为学习者推荐学习资源时，可能会出现因难以理解学习者的知识状况而导致无法准确为他们推荐最合适的学习资源的问题。为了应对这种问题，知识追踪模型被应用于智能教育领域的学习资源推荐中。利用知识追踪模型，能够评估学习者的知识状态。基于学习者的知识状态，教师、在线学习平台或智能教学系统可以向学习者推荐与其知识状态相匹配的学习资源，以提高学习者的知识水平。如2020年，Wu等人<sup>[45]</sup>提出了一种基于知识追踪模型的个性化习题推荐算法：首先采用向量来描述每个题目的知识点涵盖情况，并利用RNN神经网络来预测每个习题应涵盖的知识点，同时采用深度知识追踪模型来预估学习者对这些知识点的掌握水平，最后根据学习者对各种知识点的掌握水平，为他们推荐包含其尚未掌握的知识点并且难度适中的习题。2020年，马晓睿等人<sup>[46]</sup>提出了一种结合深度知识追踪模型与协同过滤算法的个性化习题推荐方法，此方法采用深度知识追踪模型对学习者的知识状态进行建模，并与协同过滤技术相结合，计算出学习者正确回答习题的概率，并根据这个概率，为学习者推荐在一定难度范围内的习题。2023年，郑佩芸<sup>[47]</sup>提出了一个基于深度学习的大学英语自适应学习系统，该系统利用深度知识追踪技术来分析学习者的英语知识状态，并构建了一个学习者知识状态与知识结构的模型，然后根据此模型，个性化地推送给学习者与其知识水平相匹配的英语学习资料。

### 4.2 个性化学习干预实施

个性化学习干预同样是知识追踪模型在智能教育领域的重要应用。知识追踪技术是一种能够诊断学习者知识点掌握状态的学习分析方法。这种技术可以帮助教师与教学辅助系统及时识别出在某个知识点的学习上存在困难的学习者，并对存在学习困难的学

习者实施个性化学习干预，如对学习者进行个性化的学习辅导，为学习者提供学习建议，以提升其学习效果。

在2019年与2022年张明心<sup>[48]</sup>、褚钰<sup>[49]</sup>分别成功地将贝叶斯知识追踪模型应用到小学数学与初中物理的教学中，准确地评估了学习者的知识点掌握水平，并据此生成了个性化的认知诊断报告，依据认知诊断报告，教师可以对学习者进行个性化的学习帮助，从而更好地提升学习者的学习效果。2022年，张俊楷<sup>[50]</sup>提出了基于深度知识追踪的个性化教学模型，此模型利用知识追踪技术生成知识状态追踪结果报告，可以动态反映学习者在学习过程中知识状态的变化，让教师与教学辅助系统能够根据学习者的知识状态实施个性化学习干预，促进学习者的知识水平的提升。2023年，赵亚歌<sup>[51]</sup>构建了基于BKT的个性化学习模型，该模型中包含了个性化补救学习阶段，有效地提升了学生的知识掌握水平与学习效果。

### 4.3 学习路径推荐

学习路径的推荐一般指通过探寻学习者的特征，根据所构建的学习者模型自适应地调整学习资源和活动序列，以形成适合每个学习者的学习路径，从而实现精准的学习过程引导<sup>[52]</sup>。学习者的知识状态是一种重要的个性特征，因此，同样地，知识追踪模型也可以应用于智能教育领域的学习路径的推荐中。

2023年，夏瑞玲等人<sup>[53]</sup>结合了知识图谱技术、深度知识追踪模型和蚁群算法，提出了一种基于改进蚁群算法的学习路径推荐方法，首先，使用抽象的课程知识点图谱作为学习路径的基础，然后，采用深度知识追踪模型对处于不同知识状态的学习者进行分类，最终，使用蚁群算法来规划学习路径，从而找到了一条高效的学习路径。2023年，王剑等人<sup>[54]</sup>提出了一种结合多维偏好和知识追踪的学习路径推荐方法，此方法构建了一个融合多维学习偏好和动态知识追踪的学习者画像模型，并在此模型的指导下，提出了一个基于知识单元有向图的学习路径和路径优化流程，旨在为学习者推荐最适合其学习需求的学习路径。2024年，孙小琪等人<sup>[55]</sup>基于图嵌入与注意力机制的知识追踪技术，设计了一种学习路径推荐模型，实现了更加个性化的学习路径推荐。2024年，Zhang等人<sup>[56]</sup>利用深度知识追踪来建模学习者的知识状态，并运用过程挖掘技术实现了个性化流程型的学习路径推荐。

## 5 当下面临的问题与展望

### 5.1 智能教育领域的知识追踪模型面临的问题

目前的智能教育领域的知识追踪模型仍然存在一些亟待解决的难题。

#### 5.1.1 知识追踪的跨学科问题

知识追踪模型最初是为了建模学习者在数学领域的知识状态而诞生的。目前，知识追踪模型主要应用于数学、物理等知识点分布明确、逻辑严密且知识层次清晰的学科。然而，如果将知识追踪模型用于英语、语文等知识点较为模糊的学科，那么知识追踪模型所能达到的效果可能并不如人意。由此可见，在一些学科的智能教育中，知识追踪模型面临着跨学科的挑战。因此，跨学科的问题将成为智能教育领域的知识追踪模型所要应对的主要问题之一。

#### 5.1.2 知识追踪的体系标准问题

至今，知识追踪领域还没有建立起统一的体系标准。例如，目前还没有一个可靠的标准来明确知识追踪所需的样本和数据范围，也没有统一的标准来对知识追踪模型预测的学习者知识状态进行等级划分，更没有一个明确的知识追踪模型构建标准。缺乏这些体系标准也会妨碍知识追踪模型在智能教育中的应用。

#### 5.1.3 主观题的知识追踪问题

现有的知识追踪模型主要使用二元变量来描述学习者的题目作答结果，客观题由于其独特性，更适合用二元变量来描述其答题结果，因此在知识追踪的数据集中，问题都属于客观题。然而，在真实的智能教育环境下，习题不仅涵盖了客观题，还包括了大量的主观题。主观题的答案呈现出了丰富的多样性，仅用二元变量来描述主观题的答案显然是不足够的。因此，如何有效地实现对主观题的知识追踪成为智能教育领域的知识追踪模型一个亟待解决的难题。

#### 5.1.4 知识追踪的数据集问题

当前，知识追踪模型拥有大量可利用的数据集，这些数据集包含的学习者的题目作答序列，已经可以满足现有知识追踪模型的各种需求。然而目前的知识追踪模型已经开始整合学习者的学习特征和习题的特征，但关于可以融入知识追踪模型的学习者特征和习题特征的数据集仍然很少。并且，目前大部分的数据集主要记录了学习者数学和物理学科学习者的习题作答结果，而其他学科的数据集则相对较少。因此，本文希望更多

学习者学习行为特征的数据集、更多习题特征的数据集、更多学科的数据集的出现，并希望这些数据集能被应用到智能教育领域的知识追踪模型中。

#### 5.1.5 知识追踪的应用环境问题

智能教育环境不仅包括了在线的学习环境，还涵盖了线下的学习环境。在线下学习环境下，知识追踪模型的运用主要是教师依据学习者当前的知识水平，为他们提供学习干预方案。在线上教学环境下，收集学习者的学习数据较为便捷，并且数据类型与数量较为广泛，但在线下的教学环境下，收集学习者的学习数据较为困难，且数据类型与数量比较有限。因此，目前的智能教育领域的知识追踪模型主要是在自适应学习系统和在线学习平台中得到应用，而在线下学习环境的应用则相对较少。

### 5.2 智能教育领域的知识追踪模型总结与未来展望

知识追踪模型具有对学习者知识掌握状态进行诊断的能力，其已被广泛应用于智能教育领域的多个方面，包括学习资源的推荐、个性化学习干预的实施、学习路径的推荐以及学生知识画像构建等。

虽然传统的知识追踪模型在可解释性和整合学生行为与习题特征方面存在不足，但国内外研究者提出的优化模型已经在很大程度上解决了这些问题。尽管智能教育领域的知识追踪模型仍存在一些亟待解决的难题，但近年来，在线学习平台在教育领域的广泛应用已经成功地追踪和记录了学习者在学习过程中积累的大量数据，为知识追踪技术提供了坚实的数据基础，并且随着机器学习、深度学习等人工智能技术的不断进步，知识追踪技术得到了强大的技术支持。未来的智能教育领域的知识追踪模型必将会展现出更为丰富的发展趋势，它将整合更多学习者的学习特征（如学生的情感和态度），并适应多种学习模式（如团队合作学习），更加适应智能教育发展的要求。

由此可见，智能教育领域的知识追踪模型展现出了巨大的发展潜力，预计在未来，其将得到广泛的应用。

### 参考文献

- 1 杨现民, 张昊, 郭利明, 等. 教育人工智能的发展难题与突破路径. 现代远程教育研究, 2018(3): 30–38. [doi: 10.3969/j.issn.1009-5195.2018.03.004]
- 2 中华人民共和国教育部. 教育部关于印发《教育信息化2.0行动计划》的通知. <http://www.moe.gov.cn/srcsite/A16/>

- s3342/201804/t20180425\_334188.html. (2018-04-13).
- 3 祝智庭, 卢琳萌, 王馨怡, 等. 智慧教育理论与实践在中国的发展: 十年回顾与近未来展望. 中国远程教育, 2023, 43(12): 21–33, 45.
- 4 吴伟康. 基于知识点拓扑关系的知识追踪模型研究 [硕士学位论文]. 武汉: 华中师范大学, 2021.
- 5 Corbett AT, Anderson JR. Knowledge tracing: Modeling the acquisition of procedural knowledge. *User Modeling and User-adapted Interaction*, 1994, 4(4): 253–278.
- 6 戴静, 顾小清, 江波. 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, 2022, 32(4): 88–98. [doi: [10.3969/j.issn.1009-8097.2022.04.010](https://doi.org/10.3969/j.issn.1009-8097.2022.04.010)]
- 7 Nedungadi P, Remya MS. Incorporating forgetting in the personalized, clustered, Bayesian knowledge tracing (PC-BKT) model. Proceedings of the 2015 International Conference on Cognitive Computing and Information Processing. Noida: IEEE, 2015. 1–5.
- 8 黄诗雯, 刘朝晖, 罗凌云, 等. 融合行为和遗忘因素的贝叶斯知识追踪模型研究. 计算机应用研究, 2021, 38(7): 1993–1997.
- 9 Pardos ZA, Heffernan NT. Modeling individualization in a Bayesian networks implementation of knowledge tracing. Proceedings of the 18th International Conference on User Modeling, Adaptation, and Personalization. Big Island: Springer, 2010. 255–266.
- 10 Yudelson M. Regularizing student parameters of individualized Bayesian knowledge tracing model. Proceedings of the 9th International Conference on Educational Data Mining. Raleigh: EDM, 2016.
- 11 Käser T, Klingler S, Schwing AG, et al. Dynamic Bayesian networks for student modeling. *IEEE Transactions on Learning Technologies*, 2017, 10(4): 450–462. [doi: [10.1109/TLT.2017.2689017](https://doi.org/10.1109/TLT.2017.2689017)]
- 12 徐墨客, 吴文峻, 周萱, 等. 多知识点知识追踪模型与可视化研究. 电化教育研究, 2018, 39(10): 53–59.
- 13 王丹萍, 王忠, 梁宏涛. 基于深度学习的知识追踪研究综述. 计算机测量与控制, 2022, 30(12): 1–10.
- 14 Piech C, Bassen J, Huang J, et al. Deep knowledge tracing. Proceedings of the 29th International Conference on Neural Information Processing Systems. Montreal: ACM, 2015. 505–513.
- 15 Tian Y, Niu ZD, Liu DL. Learning strategy based on deep knowledge tracing. Proceedings of the 3rd International Conference on Computer Science and Technologies in Education (CSTE). Beijing: IEEE, 2021. 75–79.
- 16 Buckman J, Roy A, Raffel C, et al. Thermometer encoding: One hot way to resist adversarial examples. Proceedings of the 6th International Conference on Learning Representations. Vancouver: OpenReview.net, 2018.
- 17 Zhang JN, Shi XJ, King I, et al. Dynamic key-value memory networks for knowledge tracing. Proceedings of the 26th International Conference on World Wide Web. Perth: ACM, 2017. 765–774.
- 18 赵旭. 基于动态键值记忆网络的知识追踪算法研究 [硕士学位论文]. 西安: 西北大学, 2020.
- 19 Ha H, Hwang U, Hong YJ, et al. Memory-augmented neural networks for knowledge tracing from the perspective of learning and forgetting. arXiv:1805.10768, 2018.
- 20 Nakagawa H, Iwasawa Y, Matsuo Y. Graph-based knowledge tracing: Modeling student proficiency using graph neural network. Proceedings of the 2019 IEEE/WIC/ACM International Conference on Web Intelligence. Thessaloniki: IEEE, 2019. 156–163.
- 21 Dao JW, Hong L. Graph convolutional neural network knowledge tracking based on response time feature. *Journal of Electronics and Information Science*, 2024, 9(1): 7–12.
- 22 Hu P, Li ZF, Zhang P, et al. DBGCN: A knowledge tracing model based on dynamic breadth graph convolutional networks. *International Journal of Web-based Learning and Teaching Technologies*, 2024, 19(1): 1–20.
- 23 Pandey S, Karypis G. A self-attentive model for knowledge tracing. arXiv:1907.06837, 2019.
- 24 Xu JZ, Hu WT. An enhanced deep knowledge tracing model via multiband attention and quantized question embedding. *Applied Sciences*, 2024, 14(8): 3425. [doi: [10.3390/app14083425](https://doi.org/10.3390/app14083425)]
- 25 王聪, 万聪, 陈倩倩. 基于自注意力机制的个性化学生知识追踪模型. 软件导刊, 2025, 24(2): 76–82. [doi: [10.11907/rjdc.241690](https://doi.org/10.11907/rjdc.241690)]
- 26 Yeung CK. Deep-IRT: Make deep learning based knowledge tracing explainable using item response theory. Proceedings of the 12th International Conference on Educational Data Mining. Montréal: EDM, 2019.
- 27 Hu Q, Rangwala H. Reliable deep grade prediction with uncertainty estimation. Proceedings of the 9th International Conference on Learning Analytics & Knowledge. Tempe: ACM, 2019. 76–85.
- 28 刘坤佳, 李欣奕, 唐九阳, 等. 可解释深度知识追踪模型. 计算机研究与发展, 2021, 58(12): 2618–2629. [doi: [10.7544/issn1000-1239.2021.20211021](https://doi.org/10.7544/issn1000-1239.2021.20211021)]
- 29 陈成, 董永权, 贾瑞, 等. 基于交互序列特征相关性的可解

- 释知识追踪. 山东大学学报(工学版), 2024, 54(1): 100–108.
- 30 Liu Q, Huang ZY, Yin Y, et al. EKT: Exercise-aware knowledge tracing for student performance prediction. *IEEE Transactions on Knowledge and Data Engineering*, 2021, 33(1): 100–115. [doi: [10.1109/TKDE.2019.2924374](https://doi.org/10.1109/TKDE.2019.2924374)]
- 31 Liu YF, Yang Y, Chen XY, et al. Improving knowledge tracing via pre-training question embeddings. *Proceedings of the 29th International Conference on International Joint Conferences on Artificial Intelligence*. Yokohama: ACM, 2020. 219.
- 32 许智宏, 张惠斌, 董永峰, 等. 问题特征增强的知识追踪模型. *计算机科学与探索*, 2024, 18(9): 2466–2475. [doi: [10.3778/j.issn.1673-9418.2308086](https://doi.org/10.3778/j.issn.1673-9418.2308086)]
- 33 梁祥, 刘梦赤, 胡婕, 等. 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)*, 2023, 55(4): 81–86.
- 34 Chen LG, Liu XZ. Improvement of knowledge tracing by integrating exercise features and relationships of concepts. *Journal of Physics: Conference Series*, 2023, 2562(1): 012059.
- 35 Ai FZ, Chen YS, Guo YC, et al. Concept-aware deep knowledge tracing and exercise recommendation in an online learning system. *Proceedings of the 12th International Conference on Educational Data Mining*. Montréal: EDM, 2019.
- 36 王斌, 盛宇轩, 冀星昀. DKTwMF: 一种融合多特征的知识追踪模型. *计算机技术与发展*, 2021, 31(7): 35–41. [doi: [10.3969/j.issn.1673-629X.2021.07.006](https://doi.org/10.3969/j.issn.1673-629X.2021.07.006)]
- 37 Sun X, Zhao X, Li B, et al. Dynamic key-value memory networks with rich features for knowledge tracing. *IEEE Transactions on Cybernetics*, 2022, 52(8): 8239–8245. [doi: [10.1109/TCYB.2021.3051028](https://doi.org/10.1109/TCYB.2021.3051028)]
- 38 杨尚辉. 融合个体差异和学习曲线的累积知识追踪模型研究 [硕士学位论文]. 上海: 华东师范大学, 2021.
- 39 王璨, 刘朝晖, 王蓓, 等. TCN-KT: 个人基础与遗忘融合的时间累积知识追踪模型. *计算机应用研究*, 2022, 39(5): 1496–1500.
- 40 李浩君, 卢佳琪, 吴嘉铭. 融合学习过程特征的深度知识追踪方法. *浙江工业大学学报*, 2022, 50(3): 245–252. [doi: [10.3969/j.issn.1006-4303.2022.03.002](https://doi.org/10.3969/j.issn.1006-4303.2022.03.002)]
- 41 李子杰, 周菊香, 韩晓瑜, 等. 序列特征与学习过程融合的知识追踪模型. *计算机工程*, 2024, 50(6): 77–85.
- 42 孙浩, 洪青青, 魏李婷, 等. 基于序列遗忘行为的动态键值记忆网络. *扬州大学学报(自然科学版)*, 2023, 26(5): 58–63. [doi: [10.19411/j.1007-824x.2023.05.011](https://doi.org/10.19411/j.1007-824x.2023.05.011)]
- 43 贺步贵, 董永权, 贾瑞, 等. 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*, 2024, 55(1): 184–194.
- 44 Shou ZY, Li YH, Li DX, et al. Research on knowledge tracing-based classroom network characteristic learning engagement and temporal-spatial feature fusion. *Electronics*, 2024, 13(8): 1454. [doi: [10.3390/electronics13081454](https://doi.org/10.3390/electronics13081454)]
- 45 Wu ZY, He T, Mao CJ, et al. Exam paper generation based on performance prediction of student group. *Information Sciences*, 2020, 532: 72–90.
- 46 马晓睿, 徐圆, 朱群雄. 一种结合深度知识追踪的个性化习题推荐方法. *小型微型计算机系统*, 2020, 41(5): 990–995. [doi: [10.3969/j.issn.1000-1220.2020.05.015](https://doi.org/10.3969/j.issn.1000-1220.2020.05.015)]
- 47 郑佩芸. 基于深度知识追踪的大学英语智适应学习系统构建初探. *外语电化教学*, 2023(1): 53–56, 112.
- 48 张明心. 基于认知诊断的贝叶斯知识追踪模型改进与应用——以小学数学为例 [硕士学位论文]. 上海: 华东师范大学, 2019.
- 49 褚钰. 知识追踪模型的改进及在初中物理认知诊断评价中的应用研究 [硕士学位论文]. 上海: 华东师范大学, 2021.
- 50 张俊楷. 基于深度知识追踪的个性化教学模型构建及应用 [硕士学位论文]. 新乡: 河南师范大学, 2022.
- 51 赵亚歌. 基于贝叶斯知识追踪的个性化学习模型构建及应用 [硕士学位论文]. 新乡: 河南师范大学, 2023.
- 52 姜强, 赵蔚, 李松, 等. 大数据背景下的精准个性化学习路径挖掘研究——基于 AprioriAll 的群体行为分析. *电化教育研究*, 2018, 39(2): 45–52.
- 53 夏瑞玲, 李国平, 王国中, 等. 基于改进蚁群算法的个性化学习路径推荐. *上海大学学报(自然科学版)*, 2023, 29(1): 129–139.
- 54 王剑, 李易清, 石琦. 融合多维偏好与知识追踪的个性化学习路径推荐——以“系统建模”课程为例. *现代教育技术*, 2023, 33(11): 99–108. [doi: [10.3969/j.issn.1009-8097.2023.11.010](https://doi.org/10.3969/j.issn.1009-8097.2023.11.010)]
- 55 孙小琪, 袁媛. 深度学习支持下的自适应学习路径推荐——融合图嵌入与注意力机制的知识追踪模型. *软件导刊*, 2024, 23(11): 53–62. [doi: [10.11907/rjdk.241545](https://doi.org/10.11907/rjdk.241545)]
- 56 Zhang F, Feng XG, Wang YB. Personalized process-type learning path recommendation based on process mining and deep knowledge tracing. *Knowledge-based Systems*, 2024, 303: 112431. [doi: [10.1016/j.knosys.2024.112431](https://doi.org/10.1016/j.knosys.2024.112431)]

(校对责编: 张重毅)