

应试心理状态增强的学生表现预测模型

张维, 宋玲玲*, 曾鑫耀, 胡森

(华中师范大学人工智能教育学部, 湖北武汉 430079)

摘要: 准确预测学生答题表现是智能导学系统为学生提供个性化学习服务的先决条件。认知诊断和知识追踪作为主流的学生表现预测方法, 均将学生表现仅归因于知识状态, 而忽视了学生答题过程中的应试心理状态, 限制了模型预测精准性的进一步提升。为此, 本文将学生的应试心理状态融入以知识为中心的学生表现预测模型中, 并结合认知诊断可解释与知识追踪动态预测的互补优势, 提出了一种应试心理状态增强的学生表现预测模型 (Test-taking psychological state enhanced Student Performance Prediction model, TSPP)。该模型通过捕捉习题与学生答题行为之间的复杂高阶关系, 对学生应试心理状态进行建模; 同时通过提取异构知识图中丰富的节点间关系对学生动态知识状态进行建模; 最后设计了一种渐进式融合门, 其采用可解释渐进式的方式融合应试心理状态与知识状态, 得到可解释的预测结果。在3个真实世界数据集上的大量实验结果表明, TSPP模型在AUC (Area Under the Curve) 和ACC (Accuracy) 2项指标上, 相较于9种对比模型的平均表现, 分别提升了6.05%和7.27%, 在RMSE (Root Mean Square Error) 指标上降低了6.76%。此外, 通过对TSPP中的应试心理状态和知识状态进行可视化分析, 并探究其可解释性参数的优势, 本文进一步验证了TSPP的可解释性。

关键词: 学生表现预测; 认知诊断; 知识追踪; 应试心理状态; 多头注意力机制

基金项目: 国家自然科学基金 (No.62377024)

中图分类号: TP391

文献标识码: A

文章编号: 0372-2112(2025)08-2864-15

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250299

Test-taking Psychological State Enhanced Student Performance Prediction Model

ZHANG Wei, SONG Ling-ling*, ZENG Xin-yao, HU Sen

(Faculty of Artificial Intelligence in Education, Central China Normal University, Wuhan, Hubei 430079, China)

Abstract: Accurately predicting student performance is a prerequisite for intelligent tutoring systems to provide students with personalized learning services. As mainstream methods for student performance prediction, both cognitive diagnosis and knowledge tracing attribute student performance solely to knowledge states, neglecting students' test-taking psychological states during the answering process, thereby limiting further improvements in prediction accuracy. To this end, this paper proposes a test-taking psychological state enhanced student performance prediction model (TSPP), which integrates students' test-taking psychological states into the knowledge-centered student performance prediction model and combines the complementary advantages of the interpretability of cognitive diagnosis with dynamic prediction capability of knowledge tracing. The model models students' test-taking psychological states by capturing complex high-order relations between exercises and their answering behaviors. Meanwhile, it models students' dynamic knowledge states by extracting rich inter-node relations in heterogeneous knowledge graphs. Finally, we design a progressive fusion gate that employs an interpretable progressive approach to integrate test-taking psychological states and knowledge states to obtain interpretable prediction results. Extensive experimental results on three real-world datasets demonstrate that the TSPP model achieves 6.05% and 7.27% improvements in AUC (Area Under the Curve) and ACC (Accuracy), respectively, and a 6.76% reduction in RMSE (Root Mean Square Error), compared to the average performance of nine baseline models. Additionally, we further validate the explainability of TSPP by visually analyzing the test-taking psychological state and knowledge state in TSPP, and by investigating the advantages of the explainability parameters designed in the model.

Key words: student performance prediction; cognitive diagnosis; knowledge tracing; test-taking psychological state; multi-head attention mechanism

Foundation Item(s): National Natural Science Foundation of China (No. 62377024)

1 引言

学生表现预测作为支持智能导学系统(Intelligent Tutoring Systems, ITS)提供个性化学习服务的关键技术,旨在基于学生历史学习表现建模其知识状态(即对各知识点的掌握程度),以预测学生在未来习题上的答题表现^[1]. ITS通过学生表现预测技术,不仅能针对学生的知识薄弱环节提供个性化反馈,还能为其定制学习方案,从而有效提升学生的学习效率与体验^[2]. 此外,学生表现预测作为学习路径规划、学习资源推荐以及自适应测评等智能教育服务的实现基础,一直是个性化学习领域的研究重点.

当前学生表现预测方法主要分为认知诊断和知识追踪^[3]. 认知诊断假定学生知识状态在一定时间内保持不变,并根据学生历史交互数据评估出其静态知识状态^[4];相比之下,知识追踪主张学生知识状态随学习过程不断演变,其通过分析学生历史交互序列追踪学生动态知识状态^[5,6]. 图1展示了认知诊断和知识追踪的示例,其中学生1和学生2分别与一组习题进行交互,得到相应的答题结果. 认知诊断刻画学生1在整个答题过程中的静态知识状态,以预测她在未来习题上的答题表现;而知识追踪则通过持续更新学生2在不同时刻的动态知识状态,以预测他在下一时刻习题上作答正确的概率.

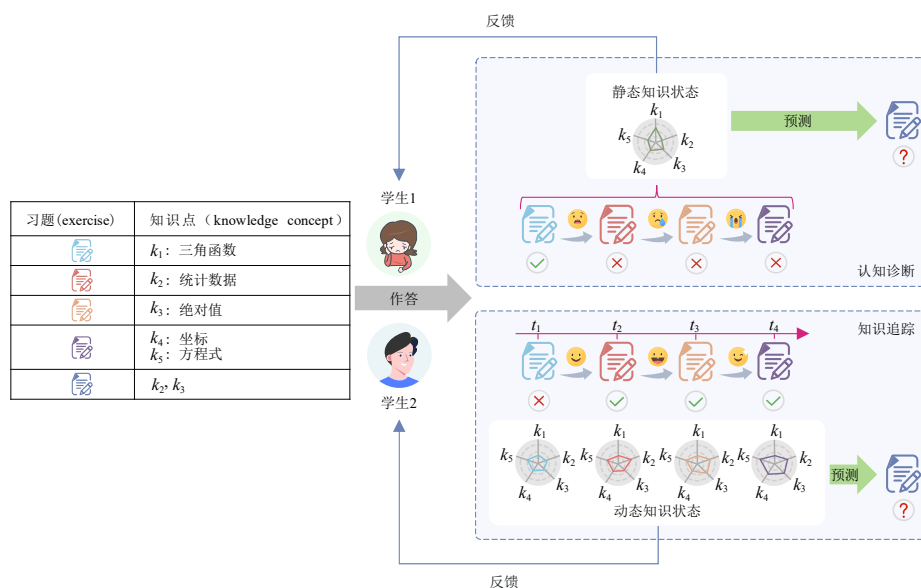


图1 认知诊断和知识追踪的示例

尽管认知诊断模型(Cognitive Diagnosis Models, CDMs)和知识追踪模型(Knowledge Tracing Models, KTM)在ITS中发挥着关键作用,但两者存在共同不足:均将学生答题表现仅归因于知识状态,而忽视了学生答题过程中心理状态的潜在影响. 心理学自我效能理论强调,个体的心理状态能影响其态度、情绪和行为,进而对个体问题解决能力产生显著影响^[7]. 在问题解决理论中,知识掌握程度和心理状态被视为影响学生问题解决结果的2个主要因素^[8]. 如同运动员比赛时的心理状态决定其竞技结果,学生答题过程中的心理状态同样显著影响其答题表现. 例如,图1中的学生2在答题过程中始终保持专注且自信,这种积极的心理

状态不仅能提高他的投入度,还促使其超常发挥;而学生1因过度紧张焦虑,导致发挥失常. 结合这一可视化示例可以得出,学生答题过程中的心理状态是影响其表现的关键因素. 本文将学生在特定答题环境下的心理状态称为“应试心理状态”,涵盖专注力、焦虑以及紧张等心理因素. 然而,未考虑学生应试心理状态的CDMs和KTM仅以知识状态为中心,无法识别和利用学生心理信息,在一定程度上造成模型性能瓶颈^[9]. 因此,为有效提升学生表现预测的精准性,应在建模过程中同时考虑学生的知识状态和应试心理状态.

此外,CDMs和KTM在ITS中具有不同的优劣势. 众所周知,学习是一个持续且动态的知识获取过程,受

多种因素的相互影响。学生的知识状态时刻发生变化,因学习巩固而增强,随时间遗忘而减弱^[10]。CDMs 主要适用于单次测验场景下的静态评估,而无法对 ITS 中学生持续变化的知识状态进行动态建模^[3]。相反,KTMs 属于动态预测,更适用于知识状态不断演变的学习场景。然而,KTMs 大多基于神经网络,因其“黑盒”属性导致模型可解释性较差,使得学生和教师难以信任 ITS 提供的智能教育服务^[11]。相比之下,CDMs 基于心理测量学理论,通常具备解释性较强的参数(如习题难度、区分度以及猜测度等)来提升 ITS 决策过程的透明度和可解释性。因此,为获取准确且更具可解释性的预测结果,应结合 CDMs 良好的可解释性和 KTMs 动态预测的互补优势。

基于上述分析,本文从知识状态和应试心理状态的双视角切入,将应试心理状态融入以知识状态为核心的学生表现预测模型中,并结合认知诊断与知识追踪的互补优势,以提升学生表现预测的准确性和可解释性。为此,本文提出了一种应试心理状态增强的学生表现预测模型(Test-taking psychological state enhanced Student Performance Prediction model, TSPP)。首先,在行为主义学习理论^[12]的指导下,通过捕捉习题与学生答题行为之间的复杂高阶关系来建模学生应试心理状态;其次,构建异构知识图(Heterogeneous Knowledge Graph, HKG)以表征学生、习题以及知识点之间丰富的异构关系,并利用门控循环单元(Gated Recurrent Unit, GRU)^[13]从 HKG 中动态建模学生知识状态;最后,提出基于多维项目反应理论(Multidimensional Item Response Theory, MIRT)^[14]的渐进式融合门,其通过融合应试心理状态和知识状态来共同预测学生表现。本文主要贡献如下:

(1)首次将学生表现归因于知识状态与应试心理状态,弥补了现有学生表现预测模型对应试心理状态的忽视。为此,基于行为主义学习理论,通过捕捉习题与学生答题行为之间的高阶关系,精细化建模应试心理状态。

(2)设计了基于 MIRT 的渐进式融合门,以可解释渐进式的方式融合学生应试心理状态与知识状态,充分结合了认知诊断良好的可解释性和知识追踪动态预测的互补优势。

(3)在 3 个公开数据集上开展广泛实验,以系统性评估 TSPP 的有效性。实验结果表明,TSPP 在预测性能与可解释性方面均显著优于对比模型。

2 相关工作

本节首先概述学生心理效应,其次从 2 个方面回顾学生表现预测的相关研究:(1)基于统计学方法的

CDMs,源自心理测量学领域,因其较强的可解释性而备受关注;(2)基于深度学习的 KTMs,通过神经网络动态建模学生知识状态。

2.1 心理效应

学生心理状态对其答题表现的显著影响已得到心理学领域的广泛认可。自我效能理论和问题解决理论指出,学生答题表现不仅取决于所掌握的知识,还受到学生对任务的信念及其心理状态的影响,这些因素共同决定了学生应对问题的方式和最终解决结果。具体而言,高自我效能感(即相信自己会成功)促使学生积极面对困难与挑战,并采取有效策略解决问题;而低自我效能感则可能导致学生在遇到困难时选择逃避或放弃^[15]。因此,学生的应试心理状态对其答题表现具有重要影响。然而,应试心理状态作为一种受多种内外因素影响的隐性变量,难以直接观测与评估。对此,心理学行为主义学习理论提出了一种通过观察学生外显行为来推测其内在心理状态的方法。行为主义学习理论认为,个体的行为是对外界刺激的直接反应,而学习是通过建立刺激与反应之间的联系而实现的^[12]。在这一理论框架指导下,学生在答题过程中所表现出的答题行为(如响应时长、尝试次数以及请求提示次数等)可被视为其对特定刺激(即习题)的反应,从而间接反映出学生的应试心理状态^[16,17]。例如,较长的响应时长和频繁请求提示可能表明学生在答题过程中遇到困难,处于焦虑或紧张的应试心理状态。

2.2 基于统计学方法的 CDMs

基于统计学方法的 CDMs 是心理测量学领域对学生能力进行诊断评估的产物,根据学生能力的表征形式可主要分为连续模型和离散模型^[18]。项目反应理论(Item Response Theory, IRT)^[19]作为经典的连续模型,将学生潜在能力建模为连续变量,并评估习题的难度、区分度和猜测度。IRT 因复杂度低而被广泛应用,但其只能评估出学生整体知识掌握情况,而无法解释具体知识点上的掌握程度^[20]。为弥补这一不足,研究人员将 IRT 扩展至 MIRT。MIRT 通过多维连续向量而非 IRT 中的标量来刻画学生知识状态,有效增强了模型的可解释性^[14]。确定输入噪音与门模型(Deterministic Inputs, Noisy And gate model, DINA)^[21]是典型的离散模型,该模型采用二进制向量表示学生是否掌握习题所涉及的知识点,并引入猜测度和失误度等参数对知识状态进行解释。基于不同的模型假设,研究人员后续提出多种 CDMs,如 HO-DINA^[22]、DINO^[23]以及 Fuzzy CDM^[24]等。总体而言,基于统计学方法的 CDMs 因其参数在解释学生知识状态上具有明确的教育学含义,能有效提升师生对 ITS 智能决策的信任度。然而,CDMs 缺乏动态建模学生知识状态的能力,因此难以应用于学生知识状

态持续变化的长期学习场景中。

2.3 基于深度学习的KTM s

基于深度学习的KTM s主要利用深度学习强大的表征能力建模学生随时间变化的知识状态,按其网络结构可进一步细分为基于循环神经网络(Recurrent Neural Network, RNN)^[25]、记忆增强神经网络(Memory-Augmented Neural Networks, MANNs)^[26]、注意力网络^[27]以及图神经网络(Graph Neural Network, GNN)^[28]的模型。深度知识追踪(Deep Knowledge Tracing, DKT)^[29]作为基于RNN的代表性模型,首次将深度学习引入知识追踪任务中。相较于以贝叶斯知识追踪(Bayesian Knowledge Tracing)^[30]为代表的传统知识追踪模型,DKT在不依赖专家标注知识的同时,显著提升了模型预测准确性。然而,DKT将RNN的隐藏状态直接视为学生知识状态,导致模型可解释性较差^[31,32]。动态键值记忆网络(Dynamic Key-Value Memory Networks, DKVMN)^[33]是典型的基于MANNs的知识追踪模型,其采用动态键-值记忆结构,能随学习过程不断更新学生知识状态。自注意力知识追踪(Self-Attentive Knowledge Tracing, SAKT)^[34]是经典的基于注意力网络的知识追踪模型,其利用自注意力机制有效缓解了数据稀疏性问题。基于图的知识追踪(Graph-based Knowledge Tracing, GKT)^[35]是首个基于GNN的知识追踪模型,其将知识追踪任务转化为GNN中的时间序列节点分类问题,旨在通过图结构来捕获更多信息。研究人员后续对这些模型进行了扩展,包括添加学习和遗忘特征^[10]、增强习题表征^[36]以及改进损失函数^[37]等。总体而言,基于深度学习的KTM s能充分学习时序信息,建模学生不断演变的知识状态。然而,神经网络内部结构的复杂性和不透明性,导致这类模型可解释性较差,使得ITS提供的智能教育服务因缺乏解释能力和归因分析而受到限制和质疑。

3 问题定义

本节首先介绍学生表现预测所涉及的核心概念,其次定义应试心理状态和知识状态的表示,最后给出学生表现预测的任务。

在ITS中,假定有学生集合 $S=\{s_1, s_2, \dots, s_i, \dots, s_N\}$,习题集合 $E=\{e_1, e_2, \dots, e_j, \dots, e_J\}$ 以及知识点集合 $K=\{k_1, k_2, \dots, k_m, \dots, k_M\}$ 。矩阵 $Q=(q_{j,m}) \in \mathbb{R}^{J \times M}$ 表示习题与知识点之间的包含关系。若习题 e_j 包含知识点 k_m ,则 $q_{j,m}=1$,否则 $q_{j,m}=0$ 。

定义1 时序交互单元。学生的交互行为是按时间顺序发生的。因此,学生 s_i 的每一次交互被视为一个时序交互单元,由三元组 (e_t, r_t, F_t) 表示。 $e_t \in E$ 表示 s_i 在 t 时刻作答的习题。 $r_t \in \{0, 1\}$ 表示 s_i 在 e_t 上的答题结果,

即 $r_t=1$ 表示作答正确, $r_t=0$ 表示作答错误。 $F_t=\{f_t^1, f_t^2, \dots, f_t^l, \dots, f_t^L\}$ 为 s_i 作答 e_t 时的答题行为特征集合,其中 f_t^l 表示某一具体的答题行为特征,例如响应时长、尝试次数或提示次数等。

定义2 交互序列。学生交互序列由一系列时序交互单元沿时间轴构成。学生 s_i 的交互序列为 $X_i=\{(e_1, r_1, F_1), (e_2, r_2, F_2), \dots, (e_t, r_t, F_t), \dots, (e_T, r_T, F_T)\}$,其中 T 为交互序列的长度。

定义3 应试心理状态。 $\alpha=[\alpha_1, \alpha_2, \dots, \alpha_t, \dots, \alpha_T]$ 表示学生 s_i 的应试心理状态向量,其中 $\alpha_t(0 \leq \alpha_t \leq 1)$ 为 s_i 在习题 e_t 上的应试心理水平。

定义4 知识状态。 $\beta_t=[\beta_t^1, \beta_t^2, \dots, \beta_t^m, \dots, \beta_t^M]$ 表示学生 s_i 在 t 时刻的知识状态向量,其中 $\beta_t^m(0 \leq \beta_t^m \leq 1)$ 为 s_i 在习题 e_t 上对知识点 k_m 的掌握程度。学生的知识状态与知识点明确关联,这种表示有助于增加模型的可解释性。

给定学生 s_i 的交互序列 X_i 以及 Q 矩阵,学生表现预测的任务如下:(1)建模 s_i 在 t 时刻的应试心理水平 α_t 和知识状态 β_t ;(2)基于 α_t 和 β_t ,预测 s_i 在下一时刻习题 e_{t+1} 上正确作答的概率 $y_{t+1}(r_{t+1}=1|e_{t+1}, \alpha_t, \beta_t)$ 。

4 TSPP 模型

4.1 模型框架

如图2所示,TSPP模型由3个主要功能模块构成:(1)基于多头注意力机制的应试心理状态建模,通过捕捉习题与学生答题行为之间的复杂高阶关系,以建模学生应试心理状态;(2)基于HKG的知识状态建模,构建基于异构知识图的知识追踪模块以追踪学生动态知识状态;(3)基于渐进式融合门的学生表现预测,通过渐进式融合门以可解释渐进式的方式融合学生应试心理状态与知识状态,以共同预测学生表现。

4.2 基于多头注意力机制的应试心理状态建模

在行为主义学习理论的视角下,学生隐性应试心理状态可通过其外显的答题行为进行间接评估。因此,本文将学生在特定习题上所展现的多种答题行为特征视为其在该习题上应试心理状态的外在表现。基于此,本小节在行为主义学习理论的指导下,通过分析习题与答题行为特征之间的复杂高阶关系来建模学生应试心理状态。具体而言,首先利用皮尔逊相关系数^[38]筛选出与学生习题答题结果密切相关的答题行为特征,其次将选取的特征映射至低维空间以提取特征的深层次语义,最后通过多头注意力机制捕捉习题与答题行为特征之间的高阶关系。

4.2.1 答题行为特征选择

皮尔逊相关系数能衡量2个变量之间的线性相关

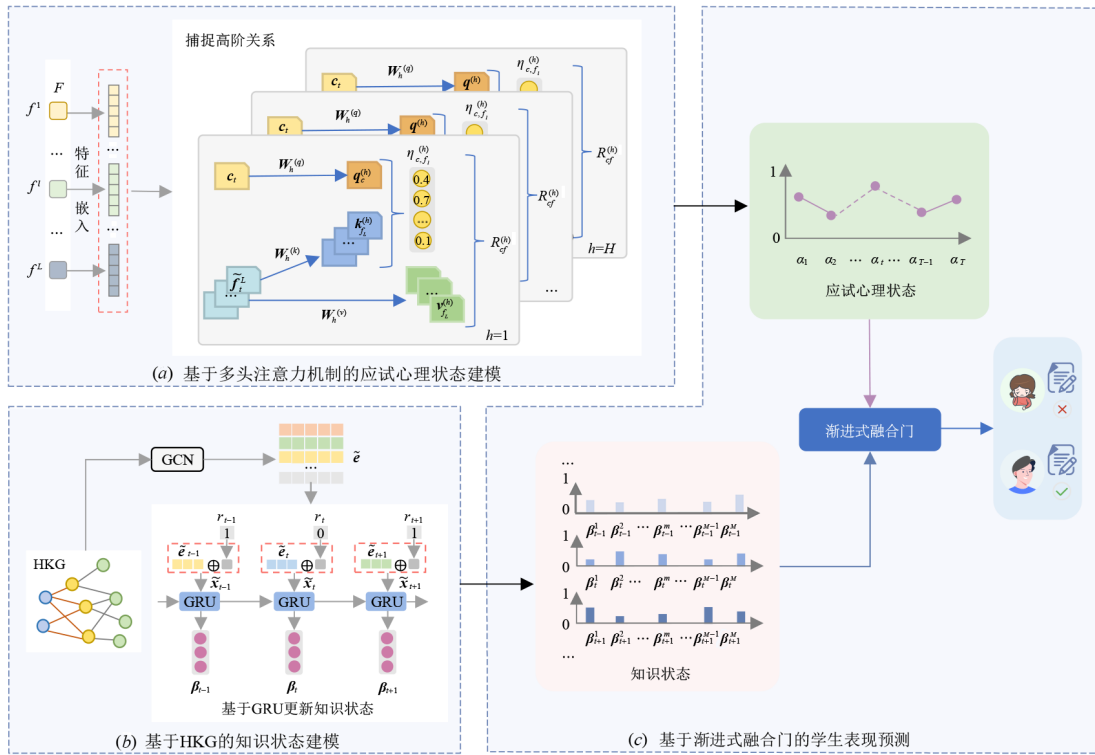


图2 TSPP模型框架

程度,其值介于-1和1之间,绝对值越大表示变量间的相关性越强。基于此,本文通过皮尔逊相关系数计算学生答题行为特征与答题结果 r 之间的相关性。皮尔逊相关系数计算公式如下:

$$P(X, Y) = \frac{\sum_{i=1}^n [(x_i - \bar{x})(y_i - \bar{y})]}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

其中, $P(X, Y)$ 表示变量 X 和 Y 的相关系数, \bar{x} 和 \bar{y} 分别为 X 和 Y 的均值。通过式(1)计算出与 r 相关性最强的前 L 个答题行为特征作为模型的输入数据。

4.2.2 特征嵌入

将学生 s_i 在习题 e_i 上的答题行为特征集合 $F_i = \{f_i^1, f_i^2, \dots, f_i^l, \dots, f_i^L\}$ 中的特征表示为向量,进一步得到特征 f_i^l 的嵌入表示 \tilde{f}_i^l 。为避免向量稀疏且高维造成模型过拟合,将 \tilde{f}_i^l 映射到低维连续空间中,得到低维特征向量 \tilde{f}_i^l :

$$\tilde{f}_i^l = W_l f_i^l \quad (2)$$

其中, $W_l \in \mathbb{R}^{d \times d_l}$ 为 f_i^l 的嵌入矩阵, d_l 为 f_i^l 的维度, d 为低维特征向量的维度。

此外,将习题 e_i 进行嵌入表示得到 e_i 。为捕捉学生对知识点的掌握信息,将 e_i 所包含的知识点 k_m 的嵌入表示 k_m 和 e_i 进行结合:

$$c_i = W_e^T (e_i \oplus k_m) + b_e \quad (3)$$

其中, $c_i \in \mathbb{R}^d$ 为 e_i 的增强向量, \oplus 为拼接操作, $W_e \in \mathbb{R}^{(d_e + d_k) \times d}$ 和 $b_e \in \mathbb{R}^d$ 为训练参数。

4.2.3 捕捉高阶关系

多头注意力机制^[39]在提升模型对输入数据的理解与表征能力方面表现出显著优势,已被广泛应用于自然语言处理、计算机视觉和推荐系统等领域。在处理序列数据时,该机制能在多个注意力子空间中并行捕捉信息,使模型同时关注输入数据的不同方面,从而有效挖掘数据中潜在的复杂结构关系和高阶依赖关系。因此,本文使用多头注意力机制来识别答题行为中更能反映学生内在应试心理状态的关键特征,并进一步建模习题与答题行为特征之间所蕴含的高阶语义关系。通过这种方式,模型能在数据驱动过程中学习和捕捉到答题行为特征背后所隐含的应试心理状态。

在多头注意力机制中,习题 e_i 的增强向量 c_i 用于构建查询向量 q ,使模型更好地聚焦于当前习题信息。同时,答题行为特征向量 \tilde{f}_i^l 被用于构建键向量 k 和值向量 v 。这是因为答题行为能反映学生的应试心理状态。具体而言, q 与 k 匹配,帮助模型捕捉习题与答题行为特征之间的关系,而 v 则提供答题行为特征的具体语义信息。如式(4)所示,分别获取注意力头 h 下相应的查询向量 $q_c^{(h)}$ 、键向量 $k_{f_i}^{(h)}$ 以及值向量 $v_{f_i}^{(h)}$:

$$q_c^{(h)} = W_h^{(q)} c_i, k_{f_i}^{(h)} = W_h^{(k)} \tilde{f}_i^l, v_{f_i}^{(h)} = W_h^{(v)} \tilde{f}_i^l \quad (4)$$

其中, $W_h^{(q)}$ 、 $W_h^{(k)}$ 以及 $W_h^{(v)} \in \mathbb{R}^{d' \times d}$ 分别为在注意力头 h 下

的投影矩阵,用于将原始向量投影到对应的子空间.

随后,计算在注意力头 h 下, \mathbf{c}_i 和 $\tilde{\mathbf{f}}_i'$ 之间相似度占比 $\eta_{c_i, f_i}^{(h)}$:

$$\eta_{c_i, f_i}^{(h)} = \frac{\exp\left(\frac{\langle \mathbf{q}_c^{(h)}, \mathbf{k}_{f_i}^{(h)} \rangle}{\sqrt{d'}}\right)}{\sum_{i=1}^L \exp\left(\frac{\langle \mathbf{q}_c^{(h)}, \mathbf{k}_{f_i}^{(h)} \rangle}{\sqrt{d'}}\right)} \quad (5)$$

其中, $\langle \mathbf{q}_c^{(h)}, \mathbf{k}_{f_i}^{(h)} \rangle$ 表示通过内积来计算在注意力头 h 下 \mathbf{c}_i 和 $\tilde{\mathbf{f}}_i'$ 的相似度.

通过组合与习题 e_i 相关的所有答题行为特征来表示注意力头 h 下习题与答题行为特征之间的关系 $R_{cf}^{(h)}$:

$$R_{cf}^{(h)} = \sum_{i=1}^L \eta_{c_i, f_i}^{(h)} \mathbf{v}_{f_i}^{(h)} \quad (6)$$

其中, $\eta_{c_i, f_i}^{(h)}$ 表示在注意力头 h 下赋予答题行为特征 f_i' 的注意力权重,它反映了不同答题行为特征对关系 $R_{cf}^{(h)}$ 的相对贡献.

$R_{cf}^{(h)} \in \mathbb{R}^{d'}$ 是 e_i 与所有答题行为特征(在注意力头 h 下)的高阶组合,代表了模型学习到习题与答题行为特征之间的高阶关系. 为捕捉来自不同注意力头的综合信息,进一步收集在所有子空间下学习到的高阶关系 R_{cf} :

$$R_{cf} = R_{cf}^{(1)} \oplus R_{cf}^{(2)} \oplus \dots \oplus R_{cf}^{(H)} \quad (7)$$

式(7)中, H 为注意力头数. 为保留原始向量 \mathbf{c}_i 的信息,通过残差连接将 \mathbf{c}_i 再次添加到网络中:

$$\tilde{R}_{cf} = \text{ReLU}(R_{cf} + \mathbf{W}_c \mathbf{c}_i) \quad (8)$$

其中, ReLU 为非线性激活函数, $\mathbf{W}_c \in \mathbb{R}^{d' \times d}$ 为投影矩阵.

最后,通过非线性映射将高阶语义表示映射为学生在当前习题 e_i 上的应试心理水平 α_i :

$$\alpha_i = \sigma(\mathbf{w}_R^T \tilde{R}_{cf} + b_R) \quad (9)$$

其中, σ 为 sigmoid 激活函数, $\mathbf{w}_R \in \mathbb{R}^{d'H}$ 为投影向量, b_R 为调整最终输出的偏差项.

4.3 基于 HKG 的知识状态建模

建模学生知识状态 β_i 主要涉及以下因素:(1)学生 s_i ; (2) s_i 所做习题 e_i ; (3) e_i 所包含的知识点 k_m ; (4) s_i 对 e_i 的答题结果 $r_i^{[3]}$. 为充分挖掘不同实体(学生、习题、知识点)以及实体间关系(学生-习题的作答关系、习题-知识点的包含关系)中蕴含的丰富信息以构建 β_i , 本文首先构建异构知识图 HKG 以表示不同实体间关系,其次通过图卷积网络(Graph Convolutional Network, GCN)^[40]生成 HKG 中由学生、习题以及知识点所构成的习题节点嵌入表示,最后使用 GRU 动态更新 β_i .

4.3.1 异构知识图 HKG

在学生历史交互数据中,学生、习题与知识点可构

成 HKG, 如图 3(a) 所示. $\text{HKG} = \{\mathbb{V}; \mathbb{E}\}$ 由节点集 \mathbb{V} 和关系边集 \mathbb{E} 组成. \mathbb{V} 是由不同实体(学生、习题以及知识点)组成的集合. $\mathbb{E} = \{r_{s-e}, r_{e-k}\}$ 是由不同实体间关系组成的边集,其中 r_{s-e} 表示学生-习题作答关系, r_{e-k} 表示习题-知识点的包含关系.




图 3 异构知识图 HKG 与元路径

与仅使用单一类型节点和边的同质图或简单图不同, HKG 通过融合多样化的实体以及实体间丰富的异构关系,使其能全面捕捉学生学习过程中的多维交互信息. 为进一步挖掘 HKG 中丰富的语义信息和异构关系,本文在 HKG 中定义 2 条元路径: $e-s-e$ 和 $e-k-e$, 如图 3(b) 所示. 根据以下规则构建元路径:(1) $e-s-e$, 习题的邻居节点是同一学生作答的习题;(2) $e-k-e$, 习题的邻居节点还可以是包含同一知识点的习题. 定义元路径有助于模型深入挖掘节点间复杂关系并指导邻居节点选择,从而丰富习题嵌入表示.

4.3.2 基于元路径的 HKG 节点嵌入

基于提出的 2 条元路径,本文利用 GCN 对 HKG 中的习题节点进行嵌入学习,以融合学生作答以及知识点包含信息,得到习题嵌入表示 $\tilde{\mathbf{e}}$. GCN 每个图卷积层中节点嵌入表示是通过将节点特征向量与其邻居节点的嵌入表示进行加权求和. 将 HKG 中第 i 个节点表示为 n_i , 其邻居节点表示为 N_i . GCN 第 l 层节点 n_i 表示如下:

$$n_i^l = \text{ReLU}\left(\frac{1}{N_i} \sum_{j \in \{i\} \cup N_i} \mathbf{c}^l n_j^{l-1} + \mathbf{b}^l\right) \quad (10)$$

其中, \mathbf{c}^l 和 \mathbf{b}^l 为训练参数,分别表示第 l 层中的聚合权重以及偏差. 通过 GCN 嵌入传播后得到习题嵌入表示 $\tilde{\mathbf{e}}$.

4.3.3 基于 GRU 更新知识状态

将 $\tilde{\mathbf{e}}$ 结合习题答题结果 r 作为 GRU 的输入,以动态建模学生知识状态. 首先将学生交互元组 $x_i = \{\tilde{\mathbf{e}}, r_i\}$ 转换为低维稠密实值向量 $\tilde{\mathbf{x}}_i$, 其次将 $\tilde{\mathbf{x}}_i$ 作为 GRU 的输入向量. 由于 GRU 不仅能捕捉当前时刻的信息,还能集成相邻时刻的上下文信息,因此本文采用 GRU 对学生知识状态 β_i 进行动态更新:

$$z_t = \sigma(\mathbf{W}_z \tilde{\mathbf{x}}_t + \mathbf{U}_z \mathbf{h}_{t-1}) \quad (11)$$

$$\tilde{r}_t = \sigma(\mathbf{W}_r \tilde{\mathbf{x}}_t + \mathbf{U}_r \mathbf{h}_{t-1}) \quad (12)$$

$$\tilde{\mathbf{h}}_t = \tanh(\mathbf{W}_h \tilde{\mathbf{x}}_t + \mathbf{U}_h (\tilde{r}_t \odot \mathbf{h}_{t-1})) \quad (13)$$

$$\mathbf{h}_t = (1 - z_t) \odot \mathbf{h}_{t-1} + z_t \odot \tilde{\mathbf{h}}_t \quad (14)$$

$$\boldsymbol{\beta}_t = \sigma(\mathbf{W}_\beta \mathbf{h}_t + \mathbf{b}_\beta) \quad (15)$$

其中, \odot 表示逐元素乘积, \mathbf{W}_z 、 \mathbf{W}_r 、 \mathbf{W}_h 、 \mathbf{U}_z 、 \mathbf{U}_r 、 \mathbf{U}_h 以及 \mathbf{W}_β 为权重矩阵, \mathbf{b}_β 为偏差项, \mathbf{h}_t 为 s_i 在 t 时刻的隐藏状态.

4.4 基于渐进式融合门的学生表现预测

为增强 TSPP 的可解释性, 本文设计了基于 MIRT 的渐进式融合门来融合学生应试心理状态和知识状态, 得到可解释的预测结果. 如图 4 所示, 渐进式融合门采用可解释渐进式的方式, 结合了认知诊断良好的可解释性与知识追踪动态预测的互补优势. 具体而言, 首先将学生答题过程划分为“知识状态—习题掌握程度—答题表现”递进式认知推理三阶段, 以辅助 TSPP 更合理地建模学生从抽象思维能力到具体作答表现的答题过程; 其次受 MIRT 的启发, 引入具有教育意义的可解释性参数, 有助于 TSPP 有效建模“知识状态—习题掌握程度—答题表现”这三个阶段之间的复杂关系.

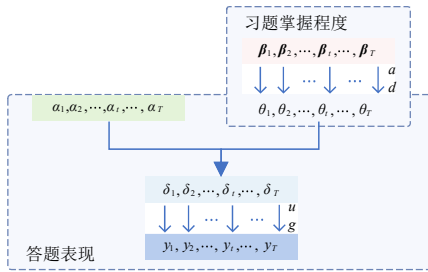


图4 渐进式融合门结构

4.4.1 习题掌握程度

学生对习题 e_t 的掌握程度不仅取决于当前知识状态 $\boldsymbol{\beta}_t$, 还与习题本身的特性密切相关, 如习题的区分度、难度等^[41]. 鉴于 MIRT 能通过多个可解释性参数刻画习题特征, 本文对 MIRT 进行改进以预测学生 s_i 在 $\boldsymbol{\beta}_t$ 下对 e_t 的掌握程度 θ_t :

$$\theta_t = \frac{1}{1 + e^{\left(-D a_t \left(\sum_{m=1}^M q_{t,m} (\beta_t^m - d_{t,m})\right)\right)}} \quad (16)$$

其中, β_t^m 为 s_i 在 t 时刻时对 k_m 的掌握程度, $d_{t,m}$ 为 k_m 的难度, a_t 为 e_t 的区分度. $d_{t,m}$ 和 a_t 为训练中学习到的参数. 若 e_t 包含 k_m , 则 $q_{t,m} = 1$, 否则 $q_{t,m} = 0$. D 为常数 1.7^[14].

4.4.2 答题表现

学生答题表现由应试心理状态和知识状态共同决定. 本文预测 s_i 在 e_t 上由 α_t 和 θ_t 共同决定的理想答题表现 δ_t :

$$\delta_t = \lambda \left(\frac{1}{1 + e^{\left(-D \left(\alpha_t - \sum_{m=1}^M q_{t,m} d_{t,m}\right)\right)}} \right) + (1 - \lambda) \theta_t \quad (17)$$

其中, α_t 为 s_i 在 e_t 上的应试心理水平, $\sum_{m=1}^M q_{t,m} d_{t,m}$ 代表 e_t 的难度. λ ($0 \leq \lambda \leq 1$) 表示应试心理状态 $\boldsymbol{\alpha}$ 在学生表现预测中的重要性权重, 为超参数. 后续实验部分将重点讨论 λ .

学生在实际答题过程中可能出现失误和猜测的情况. 即使学生完全掌握了与习题相关的所有知识点, 他们也可能给出错误的答案, 这称为失误. s_i 在 e_t 上的失误度表示为 u_t ($0 \leq u_t \leq 1$). 即使学生没有掌握与习题相关的所有知识点, 他们也可能正确猜测出习题的答案, 这称为猜测. s_i 在 e_t 上的猜测度表示为 g_t ($0 \leq g_t \leq 1$). 在学生答题过程中, u_t 和 g_t 可能同时存在.

进一步考虑 u_t 和 g_t , 计算学生答题表现 y_t :

$$y_t = (1 - u_t) \delta_t + g_t (1 - \delta_t) \quad (18)$$

$$u_t = \frac{1}{1 + e^{(-\hat{u}_t)}}, g_t = \frac{1}{1 + e^{(-\hat{g}_t)}} \quad (19)$$

参考 Qi 等人^[42]的工作, 通过引入可学习参数 $\hat{\mathbf{u}} \in \mathbb{R}^{1 \times T}$ 和 $\hat{\mathbf{g}} \in \mathbb{R}^{1 \times T}$ 来分别迭代计算 u_t 和 g_t . 其中, \hat{u}_t 为 $\hat{\mathbf{u}}$ 中的元素, \hat{g}_t 为 $\hat{\mathbf{g}}$ 中的元素. 初始化时, \hat{u}_t 和 \hat{g}_t 为经验常数 -2.

4.4.3 目标函数

将 TSPP 预测 s_i 在 e_t 上的答题表现 y_t 和实际答题结果 r_t 之间的交叉熵作为模型损失, 则 s_i 在所有作答习题上的模型损失函数表示为

$$\text{Loss} = - \sum_{t=1}^T \left(r_t \log y_t + (1 - r_t) \log (1 - y_t) \right) \quad (20)$$

为优化上述目标函数, 本文采用 Adam^[43] 优化器对模型参数进行更新. Adam 因其收敛快、稳定性强等优点, 被广泛应用于深度学习模型的训练中.

5 实验

为评估 TSPP 模型在学生表现预测任务上的有效性, 本文在 3 个真实世界数据集上开展大量实验, 旨在回答以下关键研究问题 (Research Question, RQ):

RQ1: 与多种 CDMs 和 KTM 相比, TSPP 在学生表现预测任务上的性能如何?

RQ2: 融入应试心理状态是否有利于提升 TSPP 的预测性能?

RQ3: TSPP 提出的渐进式融合门是否有效提升了模型的预测性能?

RQ4: 应试心理状态在学生表现预测任务上的重要性权重 λ 对 TSPP 性能表现有何影响?

RQ5: TSPP 的预测结果是否具有可解释性?

本节内容组织如下: 首先描述实验所使用的数据集, 其次依次介绍对比模型、评价指标以及实验设置, 最后对上述 RQ1~RQ5 进行实验分析与讨论.

5.1 数据集

本文在学生表现预测领域广泛使用的3个公开数据集上进行实验,即 ASSIST09^①、ASSIST17^②以及 Junyi^③。选择这3个数据集的原因在于它们不仅包含丰富的答题行为特征,还具有较高的代表性,涵盖了不同的学习场景和知识点类型,有助于对模型性能进行全面评估。ASSIST09和ASSIST17分别为ASSISTments在线教育平台于2009—2010学年和2017—2018学年收集的学生详细答题记录。Junyi由Junyi Academy教育平台提供,包括了2012年10月至2015年1月这期间

表1 数据集统计

数据集	ASSIST09	ASSIST17	Junyi
学生总数	4 151	1 709	29 865
习题总数	17 751	3 162	25 630
知识点总数	123	102	1 326
交互总数	325 637	942 816	14 660 217
学生平均交互数量	78.45	551.68	490.88

5.2 对比模型与评价指标

为全面验证TSPP的有效性,本文从以下2个方面选择对比模型:(1)最经典和最先进的CDMs(MIRT、DINA、NeuralCD^[44]、ICD、ACD^[45]),旨在验证TSPP建模学生知识状态的准确性;(2)最经典和最先进的KTMs(DKT、DKVMN、SAKT、HiTSKT^[46]),旨在验证TSPP在动态预测方面的优越性。对比模型简介如下:

MIRT^[14]:使用多维能力向量对学生知识状态进行建模。

DINA^[21]:引入学生在习题中的猜测和失误参数,并采用二进制向量对知识状态进行诊断。

NeuralCD^[44]:基于深度学习的认知诊断模型,通过神经网络建模学生和习题之间非线性交互关系,以获得准确且可解释的诊断结果。

ICD^[42]:使用神经网络对知识点间的相互作用以及习题-知识点间的定量关系进行建模,并引入猜测度和失误度提升模型的可解释性。

ACD^[45]:在认知诊断框架中融入学生情感状态建模,解决现有CDMs未考虑学生情感状态对其表现影响的问题。

DKT^[29]:首次将深度学习引入知识追踪任务中。

DKVMN^[33]:使用动态键值记忆网络存储并更新学生知识状态。

SAKT^[34]:利用自注意力机制对学生交互数据进行高效建模。

HiTSKT^[46]:通过提取学生历史交互数据中的会话

信息来解决知识追踪问题。

为全面评估TSPP及各对比模型在数据集上的预测性能,本文从分类和回归2个角度选取多个常用评价指标。从分类的角度,选择ROC曲线下面积(Area Under the Curve, AUC)以及准确率(ACCuracy, ACC)来评价模型预测性能。AUC和ACC值越大,表示模型预测性能越好;从回归的角度,采用均方根误差(Root Mean Square Error, RMSE)量化预测表现和实际表现之间的差值以评价模型预测性能。RMSE值越小,表示模型预测性能越好。

5.3 实验设置

本文实验环境:在PyTorch框架下实现TSPP模型,并在一台配置CPU为Intel i9 13900K(24核),GPU为NVIDIA GeForce RTX 4090的服务器上进行模型训练与测试。每个数据集随机选取80%的数据用于模型训练,剩余20%用于测试。每个模型在数据集上重复运行10次,并取其平均值作为最终实验结果。为简化模型设计,TSPP中的维度参数,包括 d_i 、 d_e 以及 d_k 等,统一设置为128。学生交互序列长度设置为100,训练批次大小为32,学习率为0.001。应试心理状态建模中答题行为特征个数 L 为3。参考王炼红等人^[31]的工作,多头注意力机制中注意力头数 H 设置为3。值得注意的是,重要性权重 λ 的设置是通过参数敏感度分析实验(5.4.3节)确定的。

5.4 实验结果与分析

为全面评估TSPP的性能,本文从以下5个方面展开实验:(1)将TSPP与9种对比模型进行比较以验证TSPP的预测性能(RQ1);(2)对TSPP进行消融实验以验证TSPP中融入应试心理状态的重要性以及提出的渐进式融合门的有效性(RQ2和RQ3);(3)探究TSPP中重要性权重 λ 的影响(RQ4);(4)探究TSPP的计算效率;(5)对TSPP进行可解释性分析(RQ5)。

5.4.1 对比实验(RQ1)

将TSPP与9种对比模型进行比较,以解决RQ1。表2展示了所有模型在3个数据集上的预测结果。结果表明,TSPP在ASSIST17和Junyi数据集上的个别指标略低于ACD,其他情况均优于所有对比模型,表现出显著的优越性。以ASSIST09数据集为例,在分类性能方面,TSPP实现了最高的AUC和ACC值(即0.809和0.762),与所有对比模型的均值相比分别提高了7.72%和

① <https://sites.google.com/site/assistmentsdata/home/2009-2010-assistment-data/skill-builder-data-2009-2010>.

② <https://sites.google.com/view/assistmentsdatamining/data-mining-competition-2017>.

③ <https://pslcdatashop.web.cmu.edu/DatasetInfo?datasetId=1198>.

6.57%;在回归性能方面,TSPP达到了最低的RMSE值(即0.401),与所有对比模型的均值相比降低了8.24%。

表2 3个数据集上学生表现预测结果

模型	ASSIST09			ASSIST17			Junyi		
	AUC↑	ACC↑	RMSE↓	AUC↑	ACC↑	RMSE↓	AUC↑	ACC↑	RMSE↓
MIRT	0.716	0.707	0.461	0.678	0.668	0.461	0.799	0.751	0.412
DINA	0.712	0.686	0.471	0.654	0.613	0.519	0.707	0.692	0.439
NeuralCD	0.752	0.731	0.430	0.710	0.694	0.453	0.791	0.744	0.417
ICD	<u>0.784</u>	<u>0.746</u>	<u>0.415</u>	0.719	0.696	0.451	0.803	<u>0.802</u>	<u>0.383</u>
ACD	—	—	—	0.785	0.717	0.432	0.827	0.774	0.397
DKT	0.746	0.669	0.439	0.681	0.698	0.454	0.767	0.623	0.422
DKVMN	0.769	0.726	0.426	0.702	0.678	0.454	0.814	0.714	0.391
SAKT	0.778	0.742	0.420	0.673	0.674	0.461	0.819	0.728	0.386
HiTSKT	—	—	—	0.750	0.692	0.443	0.793	0.756	0.406
TSPP	0.809	0.762	0.401	<u>0.751</u>	<u>0.716</u>	0.432	<u>0.823</u>	0.806	0.381

注:最优性能加粗标识,次优性能由下划线标识,“—”符号表示模型不适用于相应的数据集。

与同样关注学生心理因素建模的ACD相比,TSPP除了在ASSIST17数据集上的AUC低于ACD外,在其他指标上差距较小或表现出更优的预测性能。ACD的优势在于首次引入学生情感状态,弥补了现有CDMs对学生主观情绪的忽视。然而,ACD对情感状态的建模仅依赖于习题难度以及缺乏语义可解释的学生情感特质向量,导致模型难以对学生情感状态进行行为溯源与解释。与之不同,TSPP基于心理学行为主义学习理论,通过学生在答题过程中的外显行为来评估其内在应试心理状态,实现了更具理论支持与行为依据的心理建模。这一特性使TSPP相较于ACD在实际教育场景中展现出更优的学生行为理解能力与可解释性,提升了模型在教学干预与个性化指导中的应用价值。

TSPP相较于多种CDMs和KTM所展现出的性能优势,可归因于以下2点核心设计。

(1)TSPP同时建模了学生应试心理状态与知识状态,这不仅增强了模型的数据拟合能力,还提升了模型决策合理性。例如,学生在面对简单习题时可能因焦虑而表现不佳。通过引入应试心理状态,TSPP能有效捕捉这些心理因素对学生表现的影响,从而使模型预测结果更加准确,也更符合学生实际的答题过程。

(2)TSPP结合认知诊断的解释能力和知识追踪的动态建模能力,突破了传统模型在可解释性和知识状态动态演变方面的局限性。值得注意的是,TSPP从细

粒度层面捕捉学生知识掌握程度,并动态更新其随时间变化的知识状态,能更真实地反映学生的学习轨迹。相比之下,对比模型考虑比较片面,削弱了模型的建模能力,从而阻碍了它们在学生表现预测任务上的性能。

上述实验分析表明,TSPP在学生表现预测任务上的有效性得到了充分验证,可以回答RQ1。

5.4.2 消融实验(RQ2和RQ3)

为评估TSPP中融入应试心理状态以及渐进式融合门对模型预测性能的影响,本文依据TSPP的3个功能模块设计了相应的变体模型。具体而言,TSPP-t表示移除应试心理状态建模模块,仅基于知识状态预测学生表现,目的是评估应试心理状态对TSPP的影响;TSPP-k表示移除知识状态建模模块,仅基于应试心理状态预测学生表现,目的是评估知识状态对TSPP的影响;TSPP-p表示不包含渐进式融合门,而对应试心理状态和知识状态进行简单融合,目的是评估渐进式融合门对TSPP的影响。

表3展示了各变体模型在ASSIST09和ASSIST17数据集上的实验结果。为进一步直观显示TSPP与不同变体模型之间的性能差异,本文绘制了图5。从图5中可以得出以下观察结果:

(1)将应试心理状态引入TSPP能有效提升学生表现预测的准确性。TSPP-t与TSPP相比,在2个数据集上AUC和ACC平均降低了0.021和0.0055, RMSE平均提

表3 消融实验结果

模型	应试心理状态	知识状态	渐进式融合门	ASSIST09			ASSIST17		
				AUC↑	ACC↑	RMSE↓	AUC↑	ACC↑	RMSE↓
TSPP-t	×	√	√	0.780	0.758	0.426	0.738	0.709	0.443
TSPP-k	√	×	√	0.781	0.741	0.432	0.736	0.695	0.435
TSPP-p	√	√	×	0.796	0.760	0.407	0.749	0.714	0.436
TSPP	√	√	√	0.809	0.762	0.401	0.751	0.716	0.432

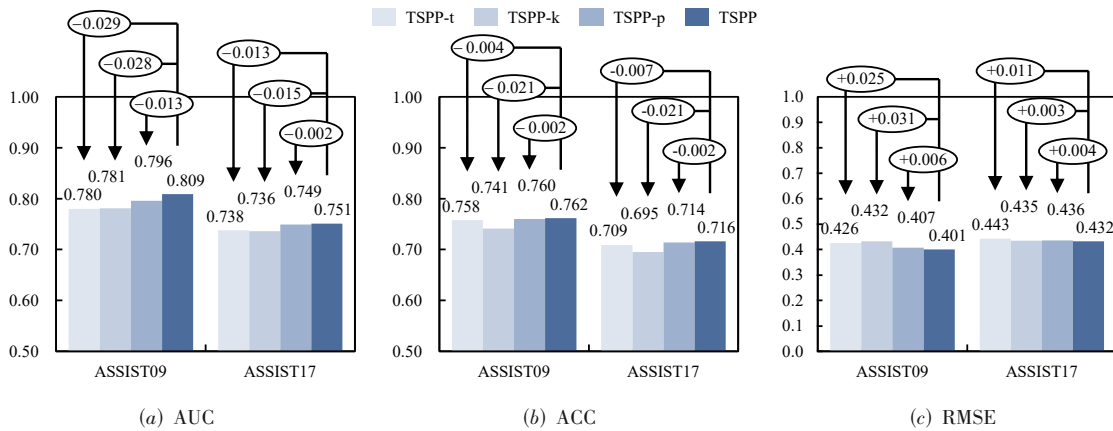


图5 TSPP与各变体模型的预测结果比较

高了0.018. 这一结果表明,将应试心理状态引入以知识状态为核心的学生表现预测模型中能显著提升模型预测性能,可以回答RQ2. 此外,可以观察到TSPP-k与TSPP相比,在2个数据集上AUC和ACC平均降低了0.021 5和0.021, RMSE平均提高了0.017. 比较TSPP-t和TSPP-k,不难发现应试心理状态与知识状态对模型的重要性几乎同等重要,验证了将学生表现归因于应试心理状态和知识状态的重要性.

(2)渐进式融合门相较于一般的融合方法,效果更好. TSPP-p与TSPP相比,在2个数据集上AUC和ACC平均降低了0.007 5和0.002, RMSE平均提高了0.005. 这表明,渐进式融合门相较于一般的融合方法,在提升模型性能方面展现出更显著的优势. 因为渐进式融合门采用可解释渐进式的方式,引导模型更合理地建模学生从抽象思维能力到具体作答表现的答题过程,从而增强了模型预测的合理性与拟合精度. 此外,渐进式

融合门引入具有教育意义的可解释性参数,能显著提升模型预测结果的可解释性,这一大优势是一般融合方法所不具备的. 因此可以有效回答RQ3.

5.4.3 参数敏感度分析(RQ4)

为探究TSPP中应试心理状态的重要性权重 λ 对模型预测性能的影响,本文在3个数据集上开展参数敏感度分析实验. 具体而言,将 λ 分别设置为0、0.2、0.4、0.6、0.8、1,并以AUC作为评价指标,实验结果如图6所示. 可以观察到当 λ 为0.4时,TSPP在3个数据集上均取得最佳性能. 先升后降的性能趋势表明,当 λ 为较小值时,不足以完全发挥出应试心理状态在学生表现预测任务上的作用,而当 λ 为较大值时,会迫使模型过度关注应试心理状态而忽视知识状态,导致模型性能降低,可以回答RQ4. 这一结果进一步验证了将学生表现归因于应试心理状态和知识状态的必要性. 因此,在TSPP的实现中将 λ 设置为0.4,以获得最佳模型性能.




图6 参数敏感度分析结果

5.4.4 模型计算效率分析

考虑到学生表现预测在实际应用中对实时性的要求,本文详细比较TSPP与其他模型的计算时间,以验证其计算效率和实际可行性. 表4展示了在相同实验条件下,DKT、TSPP以及当前最先进的HiTSKT在ASSIST09和ASSIST17数据集上的计算时间. 结果表

明,TSPP具有较高的计算效率. DKT作为早期提出的模型,因其结构简单,计算时间最短;而TSPP虽引入了多头注意力机制和GRU以建模学生应试心理状态和动态知识状态,导致计算时间略有增加,但仍保持较高的计算效率;相比之下,HiTSKT因采用更为复杂的会话建模机制,其计算时间为三者中最长. 总体而言,TSPP

的计算时间虽高于 DKT,但远低于 HiTSKT. 这充分证明了 TSPP 保证模型预测性能与可解释性的同时,兼具较强的计算效率,有力支撑了其在实际应用中的可行性.

表 4 模型计算时间

数据集	计算时间	DKT	TSPP	HiTSKT
ASSIST09	训练时间(s/每轮迭代)	8.32	32.74	—
	预测时间/s	0.46	2.77	—
ASSIST17	训练时间(s/每轮迭代)	13.50	69.79	195.36
	预测时间/s	0.81	4.34	15.99

5.4.5 可解释性分析(RQ5)

为验证 TSPP 中预测结果的可解释性,本文从 3 个方面开展模型的可解释性分析. 首先,可视化应试心理状态和知识状态,以探究两者对学生表现的影响;其次,可视化应试心理状态建模过程,以实现应试心理状态生成过程的透明化和可追溯性;最后,可视化渐进式融合门中的可解释性参数,以分析可解释性参数带来的优势.

(1)可视化应试心理状态和知识状态

本文从 ASSIST09 数据集中随机选出一名学生对某一特定知识点的交互序列作为分析对象. DKT 和 TSPP 预测结果如图 7 所示. 从图 7 可以观察到,TSPP 所建模的应试心理状态和知识状态均与学生实际答题结果较为契合. 以习题 e_7 为例,DKT 将学生知识掌握程度从 0.529 陡降至 0.371,以此解释学生的错误作答. 然而,TSPP 认为学生在 e_7 上知识掌握程度处于中等水平(0.531),但其较低的应试心理水平(0.242)才导致答题错误. 这是因为即使学生具备部分解决特定习题所需的知识,但较差的应试心理状态仍可能影响其答题表现. 值得注意的是,TSPP 中的知识状态曲线相对稳定且直观可读,能揭示学生知识掌握程度随时间的稳定变化趋势. 相比之下,DKT 在处理学生答题结果频繁交替的交互序列时,通过急剧上升或下降的知识掌握程度来拟合学生表现. 然而,这种处理方法并不符合知识状态演化原理,因为学生对知识点的掌握程度在短期内倾向于表现出相对稳定且发生方向性的变化. 综上所述,TSPP 引入学生应试心理状态并对知识状态进行有效建模,使得模型在学生表现解释层面具有更高的可信度.

(2)可视化应试心理状态建模

为更直观展示应试心理状态的建模过程,本文对图 7 中学生在习题 e_7 上的应试心理水平(0.242)的建模过程进行可视化分析. 该学生在 e_7 上的答题行为特征如下:hint_count=3(请求提示次数为 3)、first_action=0(首次操作是尝试作答)、attempt_count=3(尝试答题次数为 3). 这些答题行为特征从不同维度间接揭示了学

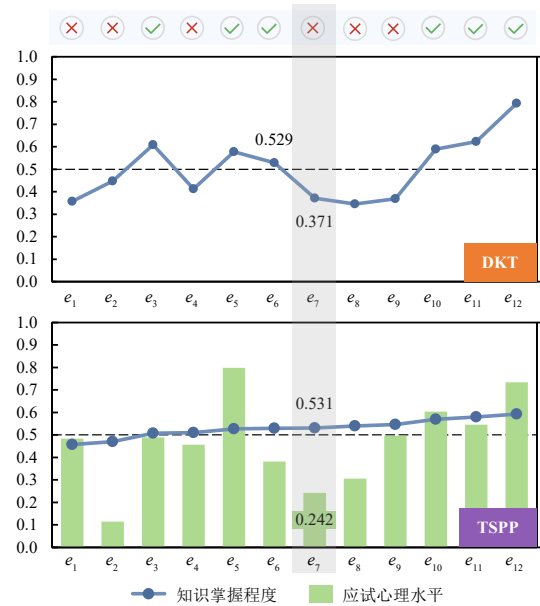


图 7 DKT 和 TSPP 对知识状态和应试心理状态的可视化

生在该习题上的应试心理状态:hint_count 较高通常表明学生缺乏解题把握或依赖提示;first_action 反映其初始作答时的信心与主动性;attempt_count 则揭示其在面对困难时的心理波动和坚持程度. 如图 8 所示,TSPP 通过三头注意力机制建模上述答题行为特征与习题 e_7 间的高阶关系.

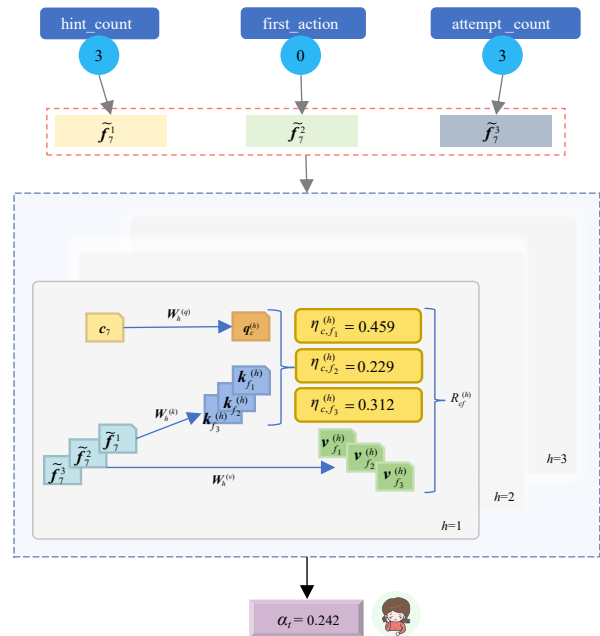


图 8 TSPP 中应试心理状态建模可视化示例

在第一个注意力头下, hint_count、first_action 与 attempt_count 的注意力权重分别为 0.458 9、0.229 3 与 0.311 6. 模型赋予 hint_count 最高权重,说明其是推测

该学生应试心理状态的主要参考依据。随后,模型将多个注意力头的结果进行融合,并通过非线性映射计算出该学生在 e_7 上的应试心理水平为0.242。从可视化数值分析中可以得出:学生一开始选择直接作答,表明其对知识点具备一定的信心,但实际掌握程度不充分,导致答题过程中多次请求提示,最终仍答错。这一过程反映出学生在答题时的心理波动,综合表现为较低的应试心理水平。该算例不仅揭示了答题行为特征与应试心理状态之间的潜在关联,也验证了TSPP在刻画学生应试心理状态方面的合理性、行为可追溯性以及预测结果可解释性。

(3)可视化渐进式融合门中的可解释性参数

在ASSIST17数据集中,本文随机选取一名学生对某一特定知识点的交互序列作为分析对象。DKT和TSPP预测结果如图9所示。

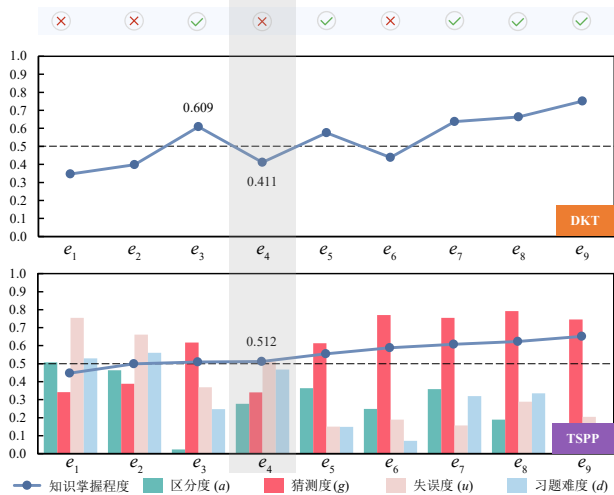


图9 DKT和TSPP的可解释性比较

从图9中可以看出,与DKT相比,TSPP基于渐进式融合门,引入了丰富的可解释性参数来详细刻画学生答题过程,有助于学生和教师归因溯源。具体而言,TSPP为每次预测提供了当前习题的区分度(a)、猜测度(g)、失误度(u)以及难度(d)。这些参数显著增强了模型预测结果的可解释性。以习题 e_4 为例,DKT通过学生知识掌握程度从0.609到0.411的陡降来解释学生的错误作答结果,而TSPP将学生的错误作答主要归因于学生在这道习题上的高失误率以及习题的高难度。同时,能观察到TSPP中的学生知识状态曲线较为平稳,这表明TSPP刻画的知识状态曲线更符合教育实际,对学生答题表现的解释也更为合理。此外,图9中TSPP在习题 e_5 之后呈现高猜测度,本文认为该学生在答题后期进入认知疲劳状态或注意力下降阶段,导致出现较多基于直觉或随机的作答行为,因而被模型归因为猜测性作答。同时,模型在 e_1 、 e_2 以及 e_4 中给出的较高失误

度,对应了学生在中等知识掌握程度下出现答题错误的行为特征;在 $e_5 \sim e_9$ 上的失误度显著低于之前习题,符合学生知识掌握程度稳步提升、习题难度下降的趋势。整个序列中,习题区分度与难度参数分布平稳,且区分度随习题难度逐渐降低而有所下降,符合“易题通常区分能力较低”的教育测评规律。

上述实验分析表明,TSPP的预测更贴合实际且具备优异的可解释性,因此可以回答RQ5。

6 总结与展望

本文提出了一种应试心理状态增强的学生表现预测模型TSPP,其核心思想在于将学生表现归因于应试心理状态和知识状态,并结合认知诊断良好的可解释性与知识追踪动态预测的互补优势。TSPP通过2个并行模块分别建模学生应试心理状态与知识状态,并设计渐进式融合门,采用可解释渐进式的方式融合这2种状态以共同预测学生表现。在多个公开数据集上进行了一系列针对性实验,结果表明TSPP与对比模型相比,在学生表现预测任务上具有更优的预测性能和可解释性。

未来将探索应试心理状态在学生表现预测中的长期效应,重点关注应试心理状态的动态演变对学生知识积累与学习效率的潜在作用。通过上述拓展,期望进一步深化TSPP的理论深度与应用广度,使其在教育研究与实践中发挥更为广泛而深远的影响。

参考文献

- [1] 王炼红, 罗志辉, 刘畅. 面向慕课学习者评估的认知反应模型[J]. 电子学报, 2023, 51(1): 18-25.
- [2] WANG L H, LUO Z H, LIU C. Cognitive and response model for evaluation of MOOC learners[J]. Acta Electronica Sinica, 2023, 51(1): 18-25. (in Chinese)
- [3] 刘铁园, 陈威, 常亮, 等. 基于深度学习的知识追踪研究进展[J]. 计算机研究与发展, 2022, 59(1): 81-104.
- [4] LIU T Y, CHEN W, CHANG L, et al. Research advances in the knowledge tracing based on deep learning[J]. Journal of Computer Research and Development, 2022, 59(1): 81-104. (in Chinese)
- [5] SU Y, SHEN S H, ZHU L B, et al. Global and local neural cognitive modeling for student performance prediction[J]. Expert Systems with Applications, 2024, 237: 121637.
- [6] LI X Y, GUO S Y, WU J, et al. An interpretable polytomous cognitive diagnosis framework for predicting examinee performance[J]. Information Processing & Management, 2025, 62(1): 103913.
- [7] 贾瑞, 董永权, 刘源, 等. 知识点相关性与遗忘程度融合

- 的深度知识追踪模型[J]. 计算机研究与发展, 2025, 62(2): 364-373.
- JIA R, DONG Y Q, LIU Y, et al. Deep knowledge tracing model with the integration of skills relation and forgetting degree[J]. Journal of Computer Research and Development, 2025, 62(2): 364-373. (in Chinese)
- [6] 闫秋艳, 司雨晴, 袁冠, 等. 基于学生-问题关联的异构图知识追踪模型[J]. 电子学报, 2023, 51(12): 3549-3556.
- YAN Q Y, SI Y Q, YUAN G, et al. Student-problem association based heterogeneous graph knowledge tracing model[J]. Acta Electronica Sinica, 2023, 51(12): 3549-3556. (in Chinese)
- [7] SCHUNK D H, DIBENEDETTO M K. Self-efficacy theory in education[M]//Handbook of Motivation at School. New York: Routledge, 2016: 34-54.
- [8] SLAVIN R E. Educational Psychology: Theory and Practice[M]. 12th ed. New York: Pearson, 2018.
- [9] LIU S, YU J W, LI Q, et al. Ability boosted knowledge tracing[J]. Information Sciences, 2022, 596: 567-587.
- [10] ZHAO W Z, XIA J, JIANG X P, et al. A novel framework for deep knowledge tracing via gating-controlled forgetting and learning mechanisms[J]. Information Processing & Management, 2023, 60(1): 103114.
- [11] 孙建文, 周建鹏, 刘三女牙, 等. 基于多层注意力网络的可解释认知追踪方法[J]. 计算机研究与发展, 2021, 58(12): 2630-2644.
- SUN J W, ZHOU J P, LIU S N Y, et al. Hierarchical attention network based interpretable knowledge tracing[J]. Journal of Computer Research and Development, 2021, 58(12): 2630-2644. (in Chinese)
- [12] CLARK K R. Learning theories: Behaviorism[J]. Radiologic Technology, 2018, 90(2): 172-175.
- [13] CHUNG J, GULCEHRE C, CHO K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[EB/OL]. (2024-12-11) [2025-03-19]. <https://arXiv.org/abs/1412.3555>.
- [14] ACKERMAN T A, GIERL M J, WALKER C M. Using multidimensional item response theory to evaluate educational and psychological tests[J]. Educational Measurement: Issues and Practice, 2003, 22(3): 37-51.
- [15] BANDURA A. Self-Efficacy: The Exercise of Control[M]. New York: PWorth Publishers, 1997.
- [16] ZHAN P D, JIAO H, LIAO D D. Cognitive diagnosis modelling incorporating item response times[J]. British Journal of Mathematical and Statistical Psychology, 2018, 71(2): 262-286.
- [17] HUANG T, HU S Z, YANG H L, et al. Response speed enhanced fine-grained knowledge tracing: A multi-task learning perspective[J]. Expert Systems with Applications, 2024, 238: 122107.
- [18] LIU Z C, WANG S Y, ZHANG S M, et al. A Mixture Fluency model using responses and response times with cognitive diagnosis model framework[J]. Behavior Research Methods, 2024, 56(4): 3396-3451.
- [19] HAMBLETON R K, SWAMINATHAN H, ROGERS H J. Fundamentals of Item Response Theory[M]. California: Sage, 1991.
- [20] SONG L Y, HE M T, SHANG X Q, et al. A deep cross-modal neural cognitive diagnosis framework for modeling student performance[J]. Expert Systems with Applications, 2023, 230: 120675.
- [21] DE LA TORRE J. DINA model and parameter estimation: A didactic[J]. Journal of Educational and Behavioral Statistics, 2009, 34(1): 115-130.
- [22] DE LA TORRE J, DOUGLAS J A. Higher-order latent trait models for cognitive diagnosis[J]. Psychometrika, 2004, 69(3): 333-353.
- [23] TEMPLIN J L, HENSON R A. Measurement of psychological disorders using cognitive diagnosis models[J]. Psychological Methods, 2006, 11(3): 287-305.
- [24] LIU Q, WU R Z, CHEN E H, et al. Fuzzy cognitive diagnosis for modelling examinee performance[J]. ACM Transactions on Intelligent Systems and Technology, 2018, 9(4): 1-26.
- [25] MEDSKER L, JAIN L C. Recurrent Neural Networks: Design and Applications[M]. Boca Raton: CRC Press, 1999.
- [26] SANTORO A, BARTUNOV S, BOTVINICK M, et al. Meta-learning with memory-augmented neural networks[C]//International Conference on Machine Learning. Cambridge: PMLR, 2016: 1842-1850.
- [27] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach: ACM, 2017: 6000-6010.
- [28] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2009, 20(1): 61-80.
- [29] PIECH C, BASSEN J, HUANG J, et al. Deep knowledge tracing[J]. Advances in Neural Information Processing Systems, 2015, 28: 05908.
- [30] CORBETT A T, ANDERSON J R. Knowledge tracing: Modeling the acquisition of procedural knowledge[J]. Us-

er Modeling and User-Adapted Interaction, 1994, 4(4): 253-278.

- [31] 王炼红, 罗志辉, 林飞鹏, 等. 采用多头注意力机制的 C&RM-MAKT 预测算法[J]. 电子学报, 2023, 51(5): 1215-1222.

WANG L H, LUO Z H, LIN F P, et al. C & RM-MAKT prediction algorithm using multi-head attention mechanism[J]. Acta Electronica Sinica, 2023, 51(5): 1215-1222. (in Chinese)

- [32] 张峰, 姜婷婷. DKVMN-PLC: 一种融合学习者个性化学习特征的动态键值记忆网络知识追踪模型[J]. 小型微型计算机系统, 2024, 45(5): 1272-1280.

ZHANG F, JIANG T T. DKVMN-PLC: A dynamic key-value memory networks with personalized learning characteristics of learners for knowledge tracking[J]. Journal of Chinese Computer Systems, 2024, 45(5): 1272-1280. (in Chinese)

- [33] ZHANG J N, SHI X J, KING I, et al. Dynamic key-value memory networks for knowledge tracing[C]//Proceedings of the 26th International Conference on World Wide Web. International World Wide Web Conferences Steering Committee, 2017: 765-774.

- [34] PANDEY S, KARYPIS G. A self-attentive model for knowledge tracing[EB/OL]. (2019-07-16) [2025-03-19]. <https://arXiv.org/abs/1907.06837>.

- [35] NAKAGAWA H, IWASAWA Y, MATSUO Y. Graph-based knowledge tracing: Modeling student proficiency using graph neural network[C]//IEEE/WIC/ACM International Conference on Web Intelligence. New York: ACM, 2019: 156-163.

- [36] WANG W T, MA H F, ZHAO Y, et al. SEEP: Semantic-enhanced question embeddings pre-training for improving knowledge tracing[J]. Information Sciences, 2022, 614: 153-169.

- [37] ZHAO Y, MA H F, WANG J, et al. Question-response

representation with dual-level contrastive learning for improving knowledge tracing[J]. Information Sciences, 2024, 658: 120032.

- [38] SEDGWICK P M. Pearson's correlation coefficient[J]. British Medical Journal, 2012, 345: e4483.

- [39] SUBAKAN C, RAVANELLI M, CORNELL S, et al. Attention is all you need in speech separation[C]//ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE, 2021: 21-25.

- [40] KIPF T N, WELLMING M. Semi-supervised classification with graph convolutional networks[EB/OL]. (2017-02-22)[2025-03-19]. <https://arXiv.org/abs/1609.02907>.

- [41] CHEN J H, LIU Z T, HUANG S Y, et al. Improving interpretability of deep sequential knowledge tracing models with question-centric cognitive representations[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(12): 14196-14204.

- [42] QI T L, REN M R, GUO L J, et al. ICD: A new interpretable cognitive diagnosis model for intelligent tutor systems[J]. Expert Systems with Applications, 2023, 215: 119309.

- [43] KINGMA D P, BA J. Adam: A method for stochastic optimization[EB/OL]. (2017-01-30) [2025-03-19]. <https://arXiv.org/abs/1412.6980>.

- [44] WANG F, LIU Q, CHEN E H, et al. NeuralCD: A general framework for cognitive diagnosis[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(8): 8312-8327.


- [45] WANG S S, ZENG Z, YANG X, et al. Boosting neural cognitive diagnosis with student's affective state modeling[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2024, 38(1): 620-627.

- [46] KE F C, WANG W Q, TAN W C, et al. HiTSKT: A hierarchical transformer model for session-aware knowledge tracing[J]. Knowledge-Based Systems, 2024, 284: 111300.

作者简介



张 维 男, 1975年出生于湖北省仙桃市. 博士. 现为华中师范大学人工智能教育学部教授、博士生导师. 主要研究方向为教育数据挖掘、智能教育评估、大数据分析等.
E-mail: zwcnu@ccnu.edu.cn



宋玲玲 女, 1994年出生于湖北省天门市. 现为华中师范大学人工智能教育学部博士研究生. 主要研究方向为知识追踪、认知诊断.
E-mail: linglingsong@mails.ccnu.edu.cn



曾鑫耀 男,1998年出生于湖北省仙桃市.
现为华中师范大学人工智能教育学部博士研究生. 主要研究方向为知识追踪、推荐算法.
E-mail: zengxy_98@mails.cnu.edu.cn



胡 森 男,1997年出生于湖北省仙桃市.
硕士. 主要研究方向为知识追踪.
E-mail: hsen@mails.cnu.edu.cn