



计算机科学

COMPUTER SCIENCE

Agent4Stu:基于大语言模型的学生作答行为高效模拟智能体

刘苏熠, 刘淇, 高维博

引用本文

刘苏熠, 刘淇, 高维博. [Agent4Stu:基于大语言模型的学生作答行为高效模拟智能体](#)[J]. 计算机科学, 2026, 53(4): 347-355.

LIU Suyi, LIU Qi, GAO Weibo. [Agent4Stu:Efficient LLM-based Student Answer Behavior Simulation](#) [Agent](#) [J]. Computer Science, 2026, 53(4): 347-355.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于循环一致性约束的LLM增强型语言模型训练框架](#)

LLM-augmented Training Framework with Cycle-Consistency Constraints
计算机科学, 2026, 53(4): 377-383. <https://doi.org/10.11896/jsjcx.250600032>

[大模型驱动的形式化定理证明:综述与展望](#)

Formal Theorem Proving Empowered by Large Language Model:Survey and Perspectives
计算机科学, 2026, 53(4): 1-23. <https://doi.org/10.11896/jsjcx.251000067>

[大语言模型驱动的言语障碍评估方法综述](#)

Review of Speech Disorder Assessment Methods Driven by Large Language Models
计算机科学, 2026, 53(3): 307-320. <https://doi.org/10.11896/jsjcx.250300125>

[表格问答研究综述](#)

Survey of Table Question Answering Research
计算机科学, 2026, 53(3): 295-306. <https://doi.org/10.11896/jsjcx.250900006>

[SQL-MARS:面向用户模糊需求的 Text2SQL 结构化数据推荐系统](#)

SQL-MARS:Text-to-SQL Structured Data Recommendation System for Ambiguous UserRequirements
计算机科学, 2026, 53(3): 52-63. <https://doi.org/10.11896/jsjcx.250700096>

Agent4Stu: 基于大语言模型的学生作答行为高效模拟智能体

刘苏熠 刘 淇 高维博

中国科学技术大学人工智能与数据科学学院 合肥 230027

(slyiulsy@163.com)

摘要 个性化学习已成为教育数字化转型的核心方向,其关键在于对学生作答数据进行精准理解与建模。然而,受限于学习行为的稀缺性、学习状态的动态演化以及隐私合规等因素,真实教育场景中普遍存在行为数据不足及离线数据与在线学习行为存在分布偏移的问题,严重制约了智能教育系统的建模能力与泛化水平。为缓解上述困境,已有研究尝试通过模拟学生作答行为来扩展数据规模并提升模型性能,然而现有方法难以同时兼顾数据的生成质量、效率与资源成本。为此,提出一种融合大语言模型与检索增强生成技术的学生作答行为模拟智能体框架 Agent4Stu,实现低成本、高效率、强泛化能力的个性化作答行为生成。其核心包括预置检索库及检索策略,以及基于大语言模型的智能体。其中,以学生作答行为构建检索库,并设计了两类检索策略,即相似学生协同检索与相关事实检索,同时结合学生个体短期记忆动态生成高相关性的提示信息。智能体内部融合画像、记忆与动作 3 个核心模块,分别用于刻画学生的学习特征与认知能力,整合历史经验与检索库知识,并基于画像、记忆和知识掌握程度模拟学生针对具体题目的作答行为。与现有学生智能体相比,Agent4Stu 的记忆容量更小,动作推理更简化,依托面向学习行为的结构化检索库提供辅助信息,从而实现了低成本、高效率、强泛化能力的个性化作答行为生成。基于两个真实作答数据集开展的定量与定性实验,验证了 Agent4Stu 在学生作答行为模拟方面的有效性和优越性。

关键词: 数据合成; 大语言模型; 检索增强生成; 智能体; 人类行为模拟; 冷启动; 智能教育

中图分类号 TP391.1

Agent4Stu: Efficient LLM-based Student Answer Behavior Simulation Agent

LIU Suyi, LIU Qi and GAO Weibo

School of Artificial Intelligence and Data Science, University of Science and Technology of China, Hefei 230027, China

Abstract Personalized learning has become a core focus of the digital transformation in education, with its success hinging on the precise understanding and modeling of student response data. However, real-world educational scenarios often face challenges such as sparse learning behaviors, dynamic evolution of learning states, and privacy compliance constraints. Additionally, discrepancies between offline data and online learning behaviors result in insufficient behavioral data and distribution shifts, significantly limiting the modeling capabilities and generalization performance of intelligent education systems. To alleviate these dilemmas, previous studies have attempted to simulate student response behaviors to expand data scale and improve model performance. However, existing methods struggle to simultaneously balance generation quality, efficiency, and resource costs. To overcome these limitations, this paper proposes Agent4Stu, a student response behavior simulation framework that integrates large language models (LLMs) with retrieval-augmented generation (RAG) techniques, enabling low-cost, efficient, and highly generalizable personalized response generation. The framework comprises a pre-built retrieval database with retrieval strategies and an LLM-based agent. The retrieval database is constructed from student response behaviors, and two retrieval strategies are designed: similar-student collaborative retrieval and relevant-fact retrieval. These are combined with each student's short-term memory to dynamically generate highly relevant prompts. Internally, the agent integrates three core modules, profile, memory, and action, which are responsible for modeling students' learning characteristics and cognitive abilities, integrating historical experiences with knowledge from the retrieval database, and simulating students' responses on specific items based on their profile, memory, and knowledge mastery. Compared with existing LLM-based student agents, Agent4Stu has a smaller memory footprint and simplified action reasoning, while leveraging a behavior-oriented structured retrieval database to provide auxiliary information. This design enables low-cost, efficient, and highly generalizable personalized response generation. Quantitative and qualitative experiments on two real-world learning datasets demonstrate the effectiveness and superiority of Agent4Stu in simulating student learning response behaviors.

Keywords Data synthesis, Large language models, Retrieval-augmented generation, Agents, Human behavior simulation, Cold-start, Intelligent education

到稿日期:2025-08-04 返修日期:2025-11-07

基金项目:国家重点研发计划(2024YFC3308200);国家自然科学基金(62337001);中央高校基本科研业务费专项资金

This work was supported by the National Key Research and Development Program of China(2024YFC3308200), National Natural Science Foundation of China(62337001) and Fundamental Research Funds for the Central Universities.

通信作者:高维博(weibogao@mail.ustc.edu.cn)

1 引言

智能教育^[1]作为新时代教育发展的核心驱动力,极大地影响着人才培养模式及国家创新能力的提升。依托在线教育平台(如 Coursera 和 LeetCode)丰富的学习资源与行为数据,智能教育系统通过“感知-分析-决策”闭环机制,精准建模学生知识状态与学习偏好,动态生成个性化学习路径,推动教育模式由“千人一面”向“千人千面”转变。该转变不仅显著提升了教育资源的利用效率,也促进了因材施教的深入实践,推动着创新型和个性化人才的培养,成为教育现代化和社会进步的重要推动力。

尽管智能教育展现出广阔的前景,但其核心能力高度依赖于对学生作答数据的深度建模与持续更新,当前发展仍面临两个关键挑战。其一,由于学习活动本身具有周期长、频率低、受主观动机影响大等特点,学生在线学习行为具有明显的碎片化和间歇性特征,导致平台采集到的有效作答数据十分有限,从而形成了严重的数据稀缺问题。例如,在典型的学习平台 ASSISTment 中,单个用户平均仅产生 83 次有效作答交互^[2],远不足以支撑复杂的个性化建模需求。其二,在面向学校教学等正式教育场景中,通常受到严格的隐私保护政策约束,对学生作答数据、行为日志及个人信息等敏感数据的采集和使用存在显著限制。这些制度性因素进一步加剧了数据获取的难度,使得智能教育系统在模型训练、动态评估与个性化推荐等关键环节中面临“数据不足”与“泛化能力弱”的双重瓶颈。

为缓解在线作答数据稀缺的问题,现有研究尝试模拟学生在答题过程中的行为,通过生成具备一定语义和行为特征的虚拟作答数据,来扩充训练样本并辅助模型学习。这些方法主要分为两类。一类基于传统监督模型^[3](如规则引擎和知识追踪等),其能够利用已有作答数据有效预测学生在未答题目上的表现(如是否答对),在一定程度上提升了个性化建模的准确性。但此类方法难以动态建模学习者解答问题的过程(例如,如何思考、分析、修改习题),且在数据稀缺的冷启动场景下泛化能力有限。另一类依托大语言模型强大的生成能力和泛化能力,构建学习者作答行为模拟智能体,更丰富地模拟学生的响应和认知过程^[4],其在冷启动场景中表现出较好的泛化能力。此类方法虽然在一定程度上弥补了传统监督方法的不足,但由于依赖复杂的工作流推理和高昂的计算资源,构建和运行成本较高,效率较低,难以满足大规模、低成本的个性化模拟需求。简化智能体推理结构虽然可以降低成本,但可能因缺少中间信息而损失准确性。因此,亟需一种高效、低成本且具备良好泛化能力的学生行为模拟方法,以支撑真实教育场景中的个性化系统的应用与落地。

为此,本文将结合大型语言模型与检索增强生成(Retrieval-Augmented Generation, RAG)技术设计学生智能体,以弥补上述两类方法的不足。一方面,大语言模型具备丰富的通用知识和强大的上下文推理能力,能够在数据稀缺的冷启动场景中生成语义合理、行为一致的学习响应,具备良好的跨任务、跨学科泛化能力;另一方面,RAG 技术通过检索与任务高度相关的辅助信息或历史学习记录的示例,动态增强生成上下文,从而缓解智能体结构简化所导致的知识感知不足,

提升其在学习模式理解与行为建模上的表现。

基于上述动机,本文提出 Agent4Stu——一种基于大语言模型的学生作答行为高效模拟智能体,结合预置检索库,旨在实现低成本、高效率、强泛化能力的个性化作答生成。其核心设计包括两方面。

1)预置检索库及合适的信息检索策略构成 Agent4Stu 的基础。检索库包含学生的量化特征表示与部分历史作答记录,通过合适的检索策略可生成高效、可用的增强信息。具体而言,本文设计两类检索策略。(1)协同检索:基于行为与能力相似性,从相似学生的作答记录中获取协同信号,为目标学生提供跨个体的行为参考。(2)相关事实检索:提取目标学生在检索库中与当前习题知识点相关的作答数据,并将其作为事实记忆以强化模型推理并减少生成干扰。

2)Agent4Stu 的智能体架构由 3 个模块组成。(1)画像模块:构建学生的个性化学习状态,涵盖显性练习风格与隐性认知因素。(2)记忆模块:记录并组织学生的短期记忆,融合检索结果以实现知识增强,并引入反思机制总结学习过程,修正潜在的推理偏差。(3)动作模块:基于画像、记忆等信息推理学生的行为模式,最终生成一致、可靠且可解释的作答行为。

与现有的大语言模型智能体相比,Agent4Stu 在结构设计上更为轻量,其记忆模块简洁,动作模块推理链路更短,在降低生成开销的同时能显著提升响应效率。与此同时,Agent4Stu 通过引入预置检索库,并融合其中的协同知识信号与相似作答记忆,有效增强了模拟能力,保持了较高的行为生成质量与一致性。表 1 详细对比了 Agent4Stu 与现有基于大语言模型的学生智能体的记忆模块容量与推理步骤。可以看出,Agent4Stu 的记忆模块容量更小,整体推理步骤更加简洁。由于推理开销通常与动作复杂性和记忆容量正相关,Agent4Stu 在保证生成质量的同时实现了最低的推理成本。

表 1 技术细节对比

Table 1 Comparison of technical details

智能体	记忆模块容量	动作推理流畅
EduAgent ^[5]	(1)学习行为 (2)短期记忆 (3)经验总结记忆	(1)理解习题 (2)解答习题 (3)作答表现模拟
Agent4Edu ^[4]	(1)短期记忆 (2)强化记忆(推理 token 长) (3)知识掌握演变 (4)经验总结记忆(反思,推理 token 长)	(1)选择习题 (2)理解习题(反思) (3)分析习题 (4)解答习题 (5)作答表现模拟(反思)
Agent4Stu	(1)短期记忆 (2)检索记忆 (3)经验总结记忆(反思,推理 token 短)	(1)学习情况理解 (2)理解习题 (3)作答表现模拟(反思)

本文的主要贡献包括以下几点:

1)从方法论上将检索增强生成机制引入教育智能体构建任务中,打破了传统智能体对复杂结构和高计算资源的依赖,提出了一种结构简洁、推理高效的作答行为模拟方案,为大规模、低成本且可泛化的教育系统落地应用提供了新范式。

2)提出 Agent4Stu 框架,融合画像、记忆与动作三大模块,并结合两类基于检索的增强机制(协同信号与相关事实记忆),实现了更加精准的学生行为模拟。

3)基于两个真实学习数据,在多个评估维度上系统验证

了 Agent4Stu 的性能,包括行为模拟精度、模拟效率和大模型商用 API 服务的经济开销、消融实验、参数影响以及冷启动场景下的泛化能力。实验结果表明,所提方法在准确率、稳定性及构建成本方面均优于传统有监督模型与主流教育智能体,展现出较强的实用潜力与研究价值。

2 相关工作

2.1 基于数据驱动的学生作答数据模拟

学生作答数据模拟在智能教育系统中具有重要价值,尤其在缓解高质量个性化练习数据稀缺问题方面发挥了关键作用。近年来,国内外研究者围绕如何有效生成具有行为特征与语义一致性的虚拟作答数据提出了多种方法,取得了初步进展。

早期研究主要采用基于规则的策略进行学生行为建模。Reddy 等^[6]提出基于记忆机制的学生模拟方法,利用人工设定的规则推测学生的作答与记忆行为。该类方法实现简单,成本低,但在面对复杂交互行为时表达能力有限,泛化能力较弱。随后,神经网络模型被广泛引入学生模拟任务。Su 等^[7]提出的 EERNN 以及 Liu 等^[8]提出的 KES 分别基于循环神经网络架构,能够从历史作答中学习学生的行为模式,在一定程度上提升了模拟的动态性与预测准确性。然而,该类方法对训练数据依赖程度较高,难以适应训练数据受限的冷启动环境。近年来,强化学习范式在学习者模拟中也逐渐受到关注。Zhao 等^[9]提出的 DAISim 模型将学生作答过程建模为马尔可夫决策过程,并联合建模了学习者的短期与长期行为,提升了模拟的一致性与个体差异性。但总体而言,无论是基于规则、神经网络还是强化学习的方法,仍普遍存在结构简化、个体差异捕捉不充分以及零样本场景泛化能力不足等问题。

2.2 基于大语言模型的学习者模拟智能体

近年来,大型语言模型(Large Language Models, LLMs)凭借类人推理能力与丰富的通用知识,展现出对复杂行为逻辑与决策模式的强大建模能力。LLMs 不仅能够生成语义合理且行为一致的响应,还具备卓越的上下文学习能力,在缺乏充足监督的冷启动场景中能够通过少量示例快速适应任务需求,有效突破了传统数据驱动方法的局限。得益于这些优势,基于 LLM 的生成式智能体在模拟人类行为方面展现出显著潜力^[10-11],被广泛应用于用户社交行为模拟、科学研究辅助实验设计,以及教育场景中的学生答题行为建模等任务中^[12]。

面向教育场景,Xu 等^[5]提出的 EduAgent 通过模拟学生对多媒体资源的学习过程,预测其未来的答题表现。但该方法仍存在局限性,其依赖专家标注的认知因素初始化智能体,构建成本较高,且忽略了对习题的理解与分析,只能模拟答题表现。Gao 等^[4]提出的 Agent4Edu 实现了更全面和细致的模拟,它在记忆模块中运用工具追踪知识掌握度的演化,以实现连贯的观测行为,监测知识掌握度的演化,强化记忆并模拟人类遗忘现象。

总之,基于大语言模型的学习者模拟智能体为智能教育中的学生行为建模提供了新的可能,但现有方法依赖于复杂的结构和 workflow,推理效率低下,仍需在构建效率、成本等方

面持续探索,以推动其在真实教育场景中的落地应用。

2.3 检索增强生成技术

RAG^[13-14]是一种将信息检索机制与生成式语言模型相结合的技术框架,近年来被广泛应用于自然语言处理、对话系统及知识密集型任务。其核心思想是:在生成过程中,模型不仅依赖参数中的固有知识,还可动态检索外部文档,以增强输入信息,从而生成更为准确、一致且知识支撑充分的内容。

将 RAG 引入生成式智能体,为解决智能体结构复杂、效率低下的问题提供了新路径。传统智能体往往依赖多层规划器或大规模记忆模块以保障生成质量,带来了显著的计算与部署成本。RAG 通过引入与任务上下文高度相关的信息(如题目标签与相似作答记录),提升了模型的感知能力,使得在结构简洁的前提下仍可实现高质量的行为模拟,显著缓解了智能体在精度与效率之间的矛盾。

本研究在学生作答行为模拟任务中引入 RAG,构建由作答历史与题目语义表示组成的检索库,用于辅助 LLM 智能体动态获取相关行为片段与题目信息,从而提升生成行为的合理性与连贯性,有效支持大规模、低成本的个性化模拟。

3 Agent4Stu

3.1 符号记法及问题定义

在智能教育系统中,设有学生集合 U 和习题集 E ,其中 $|U|$ 表示学生总数, $|E|$ 表示习题总数。对于任意学生 $u \in U$,其 n 次作答的历史行为可表示为一个按时间顺序排列的四元组序列:

$$l_u = \{(e_1, c_1, t_1, y_{u,e_1}), \dots, (e_n, c_n, t_n, y_{u,e_n})\} \quad (1)$$

其中, $e_i \in E$ 表示学生 u 在第 i 步作答的题目; c_i 表示练习 e_i 的内容信息,如题干文本、知识点标签、选项结构与难度等; t_i 为作答耗时; $y_{u,e_i} \in \{0, 1\}$ 表示学生 u 对练习 e_i 的作答表现,1 表示正确,0 表示错误。此外,针对每位学生 u ,将依据其历史作答数据 l_u 提取与学习相关的关键行为特征和认知层面的学习能力状态因素,并进行多维向量化编码,构造特征向量 p_u ,作为其个体表征输入模型(详见 3.4.1 节“学生画像模块”部分)。

本文方法依赖于从作答数据中检索可用信息,因此将学生的早期历史作答记录及其对应的特征向量统一构建为可查询的检索库 D^{store} ,即 $D^{\text{store}} = \{l_u, p_u\}_{u \in U}$,并设计多种检索策略,以从原始数据中挖掘除目标学生自身历史以外的辅助信息,支持个性化行为生成。该检索库的构建与使用过程无须依赖专家标注或额外的外部资源,完全基于系统中原生可获得的数据,具有良好的可扩展性与实际部署适应性。此外,检索数据的选取方式并非唯一,例如也可选择部分学生作为锚点;本文将学生的部分作答数据划分为检索数据的方式仅作为一种初步探索。

在此设定下,Agent4Stu 的核心目标是:从检索库 D^{store} 中检索待模拟的目标学生 u 的协同信号和相关事实记忆(详见第 3.3 节),并结合其短期记忆、经验总结和画像信息,准确提炼其个体的学习模式。在此基础上,系统通过缜密推理,模拟学生在未作答习题上的作答表现。

3.2 方法概述

如图 1 所示,Agent4Stu 的核心包括两方面:一是构建以作答行为为核心的检索库和两种检索策略,动态获取与当前

任务高度相关的协同学生行为及相关事实记忆,结合学生的短期记忆、经验总结和画像信息,实现对学生认知状态的精准感知;二是在智能体内部设计画像、记忆与动作三大模块,分别负责刻画学生学习特征与能力,整合历史经验与外部知识,

并基于综合认知状态模拟学生在具体题目上的作答行为。该设计兼顾模拟精度与推理效率,旨在构建一个高效、低成本且具备强泛化能力的学生行为生成框架,为智能教育系统的个性化应用提供坚实支撑。

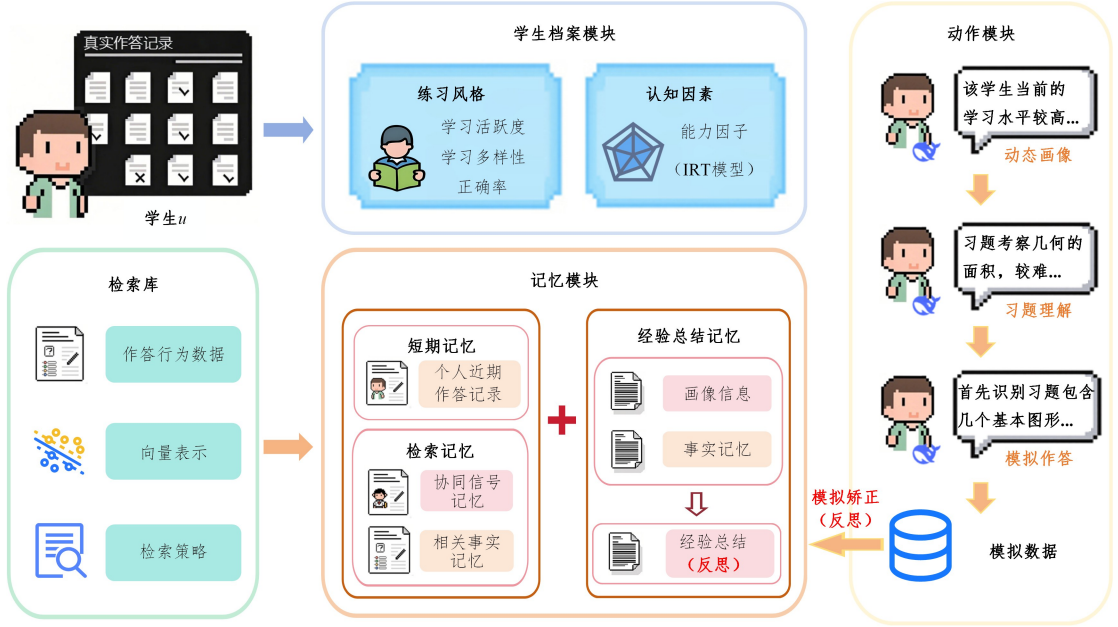


图1 Agent4Stu 结构

Fig. 1 Structure of Agent4Stu

Agent4Stu 通过各个模块的协调运作来模拟学生的作答行为,其生成提示词的过程如算法 1 所示。

算法 1 Agent4Stu 提示词生成

输入:目标学生(u),待模拟题目(e_i),检索库(D^{store}),学生画像(P),学生历史作答记忆(l_u),学生知识点掌握情况(Proficiency $_{e_i}^u$)
输出:提示词文本(Prompt $_{u,e_i}$)

1. for each u, e_i do:
2. $[P_{act}^u, P_{div}^u, P_{suc}^u, P_{ab}^u] = \text{Query}(P, u)$ // 检索该学生画像信息
3. $\text{Profile}_u = \text{GenPersona}(P_{act}^u, P_{div}^u, P_{suc}^u, P_{ab}^u)$ // 生成画像文本
4. $M_{short}^u = \text{Slice}(l_u, m)$ // 生成用户短期记忆
5. $KC_{e_i} = \text{Query}(E, e_i, \text{knowledge_id})$ // 检索题目关联知识点
6. $R_{e_i} = \text{Match}(E, e_i, KC_{e_i})$ // 根据知识点的关联获取相似题目
7. $M_{que_sim} = \text{Query}(R_{e_i}, D^{store}, l_u)$ // 检索相关事实记忆
8. $C_{e_i} = \text{Query}(\text{Content}_{e_i}, \text{Concept}_{e_i}, \text{Proficiency}_{e_i}^u)$ // 检索题目详情以及该学生对知识点的掌握
9. $\{p_u\} = \text{Load}(D^{store}, u)$ // 加载学生特征向量
10. $\text{sim}_{u,i} = \cos(p_u, p_{U_{i,j}})$ // 计算相似度
11. $N_k(u) = \text{TopK}(\text{sim}_{u,i}, k, s)$ // 筛选相似学生
12. $M_{stu_sim} = \text{Query}(D^{store}, N_k(u), e_i)$ // 检索协同信号
13. $\text{Prompt}_{u,e_i} = \text{Concat}(\text{Profile}_u, M_{short}^u, M_{que_sim}, M_{summary}, C_{e_i}, M_{stu_sim}, M_{task})$ // 生成检索文本,用于智能体模拟
14. return Prompt $_{u,e_i}$

3.3 检索库及检索策略的设计

本文所构建的检索库由所有学生的历史作答行为数据及其对应的向量化表示组成,形式化表示为 $D^{store} = \{l_u, p_u\}_{u=1}^{|U|}$ 。该检索库以作答数据为主体,具有低成本采集且无需专家标注的优势。向量化表示的构建将在 3.4.1 节“学生画像模块”部分详述。为了从检索库中获取有价值的信息以辅助模拟,

设计能增强作答模拟效果的检索策略至关重要。假设待模拟的目标学生为 u ,模拟其针对习题 e_i 的表现。检索库中可利用其唯一标识符作为检索入口,获取与其相关的行为数据。为提升模拟效果,本文从协同信号与相关事实记忆两个视角出发,设计了两种检索策略,以充分挖掘不同维度的信息,支持行为生成。

1) 协同信号检索:根据协同学习理论,具有相似学习经历和个体能力状态的学生在未来作答表现上存在较大的相似性。基于此,协同检索策略旨在从与学生 u 学习行为和能力相似的其他学生中获取辅助信息,来作为模拟的参考依据。在推断学生 u 对习题 e_i 的作答表现时,可参考其他已经作答过 e_i 且与 u 相似的学生们的行为,从而提升预测的准确性。

具体实现中,通过学生特征向量集合 $\{p_u\}_{u=1}^{|U|}$ 计算学生间的相似度。该特征向量融合了行为特征与能力状态,其具体计算方法详见第 3.4.1 节“学生画像模块”部分。给定待模拟的目标学生 u 与候选学生 $u_i \in U \setminus \{u\}$,其相似性定义为余弦相似度: $\text{sim}_{u,i} = \cos(p_u, p_{u_i})$ 。根据相似度对检索库中的所有学生排序,选择相似度最高且大于预设阈值 s 的前 k 名学生作为相似学习者,进而从检索库中检索其作答习题 e_i 的数据作为协同信号。令 l_{u_i,e_i} 表示学生 u_i 作答习题 e_i 的行为记录,则协同检索的输出被表示为:

$$M_{u,e_i,ret_stu_sim} = \{l_{u_i,e_i} \mid \text{sim}_{u,i} \geq s, u_i \in N_k(u)\} \quad (2)$$

其中, $N_k(u)$ 表示与学生 u 最相似的前 k 名学生的集合。

2) 相关事实记忆检索:原始作答记录往往以文本形式提供给模型作为提示输入。然而,当这类文本较长且结构冗余时,容易引入无关噪声,干扰模型对关键信息的识别与理解,进而影响行为生成的准确性。为此,传统智能体方法常依赖多阶段总结、反思机制,或构建类人记忆结构,以提炼高质量

的上下文信息。但这类方案结构复杂,推理链路长,难以满足高效部署的需求。为了在结构轻量化前提下提升信息利用率,本文还引入相关事实检索策略,以从学生 u 的历史行为中提取与当前待模拟习题最相关的行为事实供参考。

具体而言,在模拟学生 u 作答目标问题 e_i 的过程中,首先从检索库中提取 e_i 所对应的知识概念及其相关联知识点,并据此识别出所有包含相同或相关知识概念的问题,将其记为相关问题集合 $R_{e_i} = \{e_{i_s}\}$ 。随后,在检索库中查询学生 u 在作答 e_i 之前,是否曾作答过这些相似问题 e_{i_s} ,若存在有效记录,则将其提取作为相关事实记忆信号,以增强当前模拟任务的知识关注与行为推理能力,表示为:

$$M_{u,e_i,ret_que_sim} = \{l_{u,e_{i_s}} \mid e_{i_s} \in R_{e_i}\} \quad (3)$$

3.4 基于 LLM 的学生模拟智能体 Agent4Stu

Agent4Stu 以大型语言模型(如 DeepSeek 和 GPT 等)为核心推理引擎,融合画像、记忆与动作三大模块,按照预设推理流程系统性地模拟学习者的作答行为。相比现有智能体,Agent4Stu 在保持模拟精度的同时,记忆模块结构更为简洁,动作模块推理链条更短。在前文所述的 3 种检索策略的辅助下,Agent4Stu 实现了高效且精准的学生作答行为模拟。下文将详细介绍 Agent4Stu 的三大核心模块及其与检索库的交互机制。

3.4.1 学生画像模块

学生档案模块旨在刻画学生的整体学习特征,这些特征通常较为稳定,反映其长期的学习经验。本文基于学生 u 的历史学习行为数据,对其代理智能体 $agent_u$ 进行个性化配置。每个智能体的初始画像包含两个维度:显性的练习风格与隐性的认知因素。

练习风格通过对学生 u 的练习记录集合 l_u 进行统计分析获得,主要包括学习活跃度、多样性和正确率等指标。学习活跃度反映学生对知识探索的积极性,是模拟其学习行为的重要线索。例如,活跃度较高的学生通常在学业表现上更为优异。数学上,学生 u 的活跃度定义为 $P_{act}^u = \frac{|l_u|}{|E|}$,其中, $|l_u|$ 为学生 u 的作答次数, $|E|$ 为练习总数。多样性衡量学生覆盖知识点的广度,定义为 $P_{div}^u = \frac{|K_u|}{|K|}$,其中, $|K_u|$ 表示学生 u 曾经作答过的知识概念的数量, $|K|$ 为知识点全集规模。正确率表示学生回答问题的准确性,其数学表达为 $P_{suc}^u = \frac{\sum_{y_{u,e_i} \in l_u} y_{u,e_i}}{|l_u|}$,即学生 u 在所有作答中正确的比例。

认知因素属于反映学生学习状态的隐性特征,已被心理测量学广泛研究。其中,解题能力是应用最广泛的认知因素,心理学研究普遍认为能力水平与学生未来作答的正确概率呈正相关。因此,能力因子作为关键指标,对于精准刻画学生认知水平和预测学习表现至关重要。由于能力为隐式特征,难以直接观测或计算,本文采用心理测量学经典的 IRT 模型^[15],通过拟合学生历史作答数据,以数据驱动的方式间接学习其能力参数 P_{ab}^u (取值范围为 0 至 1,数值越大表示能力越强)。

此外,为了更好地支持基于向量表示的协同检索(详见“检索策略”部分),基于 4 类画像指标为每位学习者 u 构建特

征向量 p_u ,其中每一维对应一个特定学习特征,并将其离散化映射为二元表示形式,以增强相似性度量的判别能力。最终,将特征向量与其对应的行为数据共同存入检索库,用于支持后续的个性化行为模拟与知识增强。

综上,学生画像模块结合行为练习风格与心理认知因素两大维度,既显性反映学生的学习活跃度及练习风格,又隐性揭示其内在学习能力,实现对真实学生的全面刻画。为引导大型语言模型更准确地区分不同学生的认知状态,将相关指标根据数值大小划分为 3 个等级(高、中、低),以支持更具辨识度的个性化画像构建。

3.4.2 记忆模块

记忆模块赋予基于大语言模型的智能体 $agent_u$ 持续观察并逐步总结其对应学生 u 历史作答经验的能力。该模块采用三重记忆架构。1)短期记忆:通过目标学生近期真实作答记录的构建,反映其最新学习状态。2)检索记忆:通过预置的固定检索库获取多源辅助信息,支持跨学生的行为参考与个人相关事实增强。3)经验总结记忆:引入反思机制,从画像和短期记忆中提取关键认知信息,形成经验总结,用于支撑智能体对未作答习题的模拟与推理。具体而言,在模拟学生 u 作答目标习题 e_i (即第 i 次作答)时,系统首先获取其短期记忆,随后触发两种检索策略,进一步生成多类事实记忆以辅助模拟。

1)短期记忆

首先是短期记忆,用于模拟人类近期的瞬时记忆。本文采用学生 u 最近 m 次的作答行为作为其当前短期记忆,表示为:

$$M_{u,e_i,short} = l_u[i-m:i] \quad (4)$$

其中,当 $i-m < 1$ 时,自动截断至第 1 条记录,以保证索引有效。

2)检索记忆

检索记忆包括协同信号记忆和相关事实记忆。其中,协同信号记忆通过协同检索策略获取,筛选与目标学生 u 学习特征相似且已作答过习题 e_i 的其他学生的作答行为,构成跨学生维度的参考依据,记为 M_{u,e_i,ret_stu_sim} 。

相关事实记忆用于捕捉学生 u 过去在与当前习题 e_i 包含相同或相关知识的问题上的作答表现,借此增强模型对当前任务的知识语境理解,记为 M_{u,e_i,ret_que_sim} 。

综上所述,针对每一次模拟任务,即学生 u 对习题 e_i 的作答行为预测,检索记忆将提供以下两类记忆信息作为输入支持:

$$M_{u,e_i,retrieval} = \{M_{u,e_i,ret_stu_sim}, M_{u,e_i,ret_que_sim}\} \quad (5)$$

3)经验总结记忆

除了包含详细行为信息的事实记忆,Agent4Stu 还依托内嵌的 LLM 引擎,引入反思机制对学习过程进行总结,以提取更具全局性的长期认知特征。该机制有助于提升智能体对学生知识状态的理解深度,并增强模拟行为的一致性与可解释性。

具体而言,智能体在获取最新事实记忆后触发总结,将短期记忆和学习者画像信息进行整合与升华,形成系统且连贯的学习状态描述,表示为 $M_{u,e_i,sum}$ 。该机制有助于梳理学生的学习轨迹与发展演变,捕捉潜在的学习趋势,从而为未来作答行为的准确预测提供认知支撑。

3.4.3 动作模块

在具备学生画像与记忆模块功能的基础上,为使智能体能够展现类人的问题解决行为并生成高质量响应,为 Agent4Stu 设计了动作模块,用于驱动学习者作答行为的全过程模拟。该模块集成了对学生学习状态的感知、习题理解及行为决策,其核心流程包括以下步骤。

首先,系统整合学生画像模块与记忆模块中的阶段性总结信息,全面理解当前模拟学生 u 的学习情况和能力状态。

其次,对待模拟习题 e_i 进行语义理解。受 Agent4Edu^[4] 启发,系统利用预训练的 NeuralCD 模型获取学生对习题涉及知识点的掌握水平,并将题目难度与学生的知识状态进行匹配,以辅助预测其潜在解题路径和认知负荷。

随后,系统引导智能体根据学习者的学习画像、三类记忆以及知识掌握水平进行推理,模拟学生对该题目的作答表现,模拟结果 $\hat{y}_{u,e_i} \in \{0,1\}$ 。

最后,在模拟行为完成后,系统将模拟结果 \hat{y}_{u,e_i} 与真实作答结果 y_{u,e_i} 进行比对,以判断模拟行为与真实行为是否存在偏差。若 $\hat{y}_{u,e_i} \neq y_{u,e_i}$,即存在模拟偏差,则引导智能体对模拟失败的原因进行自我诊断,识别其在知识理解、信息提取或策略迁移中的不足之处,并将此类诊断性总结纳入经验总结记忆 $M_{u,e_i,summary}$ 中,有效弥合模型推理与真实行为之间的偏差,以提升未来模拟的鲁棒性与自适应能力。

4 实验

本章旨在系统评估所提出的 Agent4Stu 智能体的模拟效果与效率,并围绕以下研究问题(Research Questions, RQ)展开实证分析。

RQ1:相较于传统有监督方法和基于大型语言模型的教育智能体,Agent4Stu 在模拟学生作答行为的准确性方面表现如何?

RQ2:Agent4Stu 智能体构建方案能否在保持模拟性能的前提下显著提升构建效率并降低系统开发成本?

RQ3:Agent4Stu 智能体的各个组件对于学生作答行为模拟任务是否有效?

RQ4:Agent4Stu 智能体的关键参数对学生作答行为模拟效果的影响如何?

RQ5:在学生作答数据稀缺的情况下,Agent4Stu 在模拟学生作答行为准确率方面的表现如何?

4.1 实验设置

4.1.1 数据集

选用 Dbe-kt22^[16] 和 EduData^[17] 作为实验验证的数据集。两者不仅包含学生的作答记录与题目文本信息,还提供知识概念关联信息,可用于刻画练习之间的语义或结构关联,从而支持更精准的相关事实记忆检索操作。两个数据集的统计信息如表 2 所列。

表 2 数据集描述

Table 2 Description of datasets

数据集	学生数量	习题数量	知识点数量	作答记录数量	正样本占比/%
Dbe-kt22	300	212	98	28785	64.43
EduData	480	2074	248	9133	74.40

4.1.2 数据集划分

在学生作答行为模拟任务中,学习交互过程具有强烈的时序依赖性,即后续行为需基于历史行为进行。为保证对比实验的合理性与严谨性,将每位学生的作答数据按时间顺序划分为训练集和测试集,比例为 9:1。

对于有监督基线模型,训练集用于模型训练,训练集末尾 20% 的数据作为验证集进行模型选择。对于 Agent4Stu,训练集进一步按 7:3 比例划分:前 70% 的数据用于构建固定检索库,不参与智能体优化;后 30% 的数据用于更新智能体的短期记忆和经验总结记忆。同时,Agent4Stu 使用所有检索库数据以及训练数据来构建学生画像。所有模型均在相同设置下重复运行 3 次,报告平均结果。

4.1.3 对比模型及评估指标

为系统评估 Agent4Stu 在学生作答行为模拟任务中的有效性,选取多种具有代表性的传统方法作为对比基线。首先,在学生模拟方向,引入经典有监督模拟器 DAISIM^[9],该方法已在先前研究中作为学生行为模拟器使用^[18]。此外,考虑到学生作答预测与模拟任务在本质上均涉及对学生未来表现的建模,进一步纳入主流知识追踪模型以提升对比的完整性:DKT^[19],EERN^[7],DKVMN^[20] 和 SAKT^[21]。其中,EE-RNN 同时考虑题目文本与学生历史作答数据来预测作答表现;而其他模型则基于作答行为序列进行预测。

在构建效率与成本方面,选取近期提出的两种基于 LLM 的教育智能体系统 EduAgent^[5] 和 Agent4Edu^[4] 作为对比方案,以验证 Agent4Stu 在实际应用中的高效性和低成本开销。

评估指标方面,在模拟精度上采用准确度(Accuracy)、F1 分数(F1-score)、精确率(Precision)、召回率(Recall)作为性能衡量标准;在效率与成本分析中,分别统计各模型构建智能体所需的总时间,以及在生成模拟数据过程中调用商用大模型 API 服务所产生的总经济成本。

4.1.4 实现设置

为构建实验所需的智能体,采用国产开源大语言模型 DeepSeek 提供的 API 服务作为核心推理引擎,具体选用其两个主力版本 DeepSeek-V3 与 DeepSeek-R1,以验证方法在不同模型基础上的适应性与稳定性。为消除生成过程中的随机性,统一将大模型的温度参数设置为 0。

在参数设定方面,在进行学生模拟的过程中,考虑到 API 的负载上限,设置并行学生处理数量为 50,学生相似性计算中的相似度阈值 s 设为 0.8,相似学生数量上限 k 设为 3,而短期记忆长度 m 设置为 5。所有实验均在笔记本电脑环境下完成,CPU 为 Intel Core i7-1165G7 @ 2.8GHz,4 核 8 线程,未使用 GPU 加速。

4.1.5 作答模拟输出形式

在实验中,监督式模拟方法输出学生对给定练习题作答正确的概率值。当该概率超过 0.5 时,预测结果被判定为“正确”;否则判定为“不正确”。相比之下,基于 LLM 的智能体方法则直接生成二分类作答结果,模拟学生在每道题目上的“正确”或“不正确”的二元状态,无需概率阈值转换。

4.2 实验结果

4.2.1 学生模拟评估(RQ1)

Agent4Stu 旨在生成与真实作答记录高度一致的学生作

答模拟数据。为验证其模拟效果,将 Agent4Stu 与多种传统监督式模拟方法及基于 LLM 的智能体方法进行对比。考虑到 API 响应时间的限制,在推理缓慢的 DeepSeek-R1 版本实验中仅对 50 名学生进行模拟,相关模型名称后缀标注为 50 (如 Agent4Stu₅₀)。实验结果如表 3 和表 4 所列。后续表格中,最佳结果以粗体标示;符号 \uparrow (\downarrow) 表示指标值越高(低),性能越优;标 * 的实验组为针对 50 名学生的基础探索性模拟。

表 3 不同模型之间对比实验(Dbe-kt22)

Table 3 Comparative experiment between different models (Dbe-kt22)

模型	准确度 \uparrow	F1 分数 \uparrow	精确率 \uparrow	召回率 \uparrow
DKT	0.5663	0.6528	0.5518	0.7990
DAISIM	0.6078	0.5842	0.6003	0.5690
EERNN	0.6351	0.6527	0.6246	0.6836
DKVMN	0.5355	0.5534	0.5423	0.5651
SAKT	0.6111	0.6196	0.6097	0.6298
EduAgent(DeepSeek-V3)	0.6696	0.6568	0.6908	0.6260
Agent4Edu(DeepSeek-V3)	0.6872	0.6849	0.6970	0.6732
Agent4Stu(DeepSeek-V3)	0.6965	0.6916	0.7102	0.6739
Agent4Stu ₅₀ (DeepSeek-R1)	0.7095*	0.6943*	0.7294*	0.6625*

表 4 不同模型之间对比实验(EduData)

Table 4 Comparative experiment between different models (EduData)

模型	准确度 \uparrow	F1 分数 \uparrow	精确率 \uparrow	召回率 \uparrow
DKT	0.7191	0.8142	0.7927	0.8369
DAISIM	0.6605	0.6776	0.6545	0.7023
EERNN	0.5711	0.5877	0.5594	0.6190
DKVMN	0.7092	0.8234	0.7410	0.9265
SAKT	0.7074	0.8277	0.7125	0.9873
EduAgent(DeepSeek-V3)	0.7375	0.8116	0.8390	0.7859
Agent4Edu(DeepSeek-V3)	0.7568	0.8241	0.8588	0.7920
Agent4Stu(DeepSeek-V3)	0.7760	0.8388	0.8695	0.8102
Agent4Stu ₅₀ (DeepSeek-R1)	0.7685*	0.8299*	0.9531*	0.7349*

实验结果表明:

1) Agent4Stu 在模拟学生作答行为的准确性方面显著优于传统监督式基线模型及现有基于 LLM 的教育智能体,其具备生成高质量仿真数据的能力。需要注意的是,由于部分基线模型受作答正负样本分布不均衡的影响(如 Dbe-kt33 和 EduData 的正样本占比分别约为 64% 和 74%),其召回率指标相对较高,但精确率明显偏低,说明这些方法未能有效区分正负样本,而是倾向于预测占比更多的正样本,其整体准确率几乎等同于正样本比例。这一现象进一步验证了 Agent4Stu 能够更准确地模拟学生作答行为,实现对正负样本的有效分类,从而在召回率、准确率和整体精确性上均表现优异。

2) 在 Dbe-kt22 数据集中,监督基线模型 EERNN 通过有效整合练习文本信息,取得了优于其他监督模型的性能;但在数据量较小的 EduData 数据集中,由于模型参数复杂且训练样本有限,会存在过拟合问题,其在该数据集上的效果明显下降。

3) 在智能体类别中,Agent4Edu 凭借其复杂的记忆更新机制,模拟准确率优于 EduAgent。

4) 基于 DeepSeek-R1 的 Agent4Stu 在有限学生样本的探索性模拟中,进一步验证了采用先进 LLM 构建智能体能够更精准地拟合真实作答数据的分布特征的潜力。

4.2.2 模拟效率及经济成本评估(RQ2)

与传统有监督方法相比,基于 LLM 的智能体在模拟学

生作答数据时通常面临更高的计算和资源成本。为验证 Agent4Stu 在实际部署中的优越性,在综合考虑模型代码开源等因素的基础上,将其与 EduAgent 和 Agent4Edu 进行了对比。表 5 和表 6 列出了基于 DeepSeek-V3 版本的 3 种智能体在完成初始化及在线推理过程中的总时间消耗与经济成本。

表 5 模拟效率及成本评估实验(Dbe-kt22)

Table 5 Simulation efficiency and cost assessment experiments (Dbe-kt22)

模型	时间 \downarrow /min	成本 \downarrow /¥
EduAgent(DeepSeek-V3)	92	63.43
Agent4Edu(DeepSeek-V3)	126	103.49
Agent4Stu(DeepSeek-V3)	39	26.01

表 6 模拟效率及成本评估实验(EduData)

Table 6 Simulation efficiency and cost assessment experiments (EduData)

模型	时间 \downarrow /min	成本 \downarrow /¥
EduAgent(DeepSeek-V3)	29	13.93
Agent4Edu(DeepSeek-V3)	44	20.74
Agent4Stu(DeepSeek-V3)	14	7.70

实验结果表明,传统智能体普遍存在记忆更新机制复杂及计算开销大等问题,导致整体构建效率偏低且成本显著上升。相比之下,Agent4Stu 通过简化记忆模块设计,结合外部检索库提供的两类检索信号辅助模拟,有效提升了构建效率,降低了构建成本,具备更强的部署适应性和实用价值。

4.2.3 消融实验(RQ3)

为评估基于 DeepSeek-v3 的智能体 Agent4Stu 中各个关键组件的作用,在 Dbe-kt22 数据集中开展了消融实验,通过移除短期记忆、经验总结记忆、画像模块、检索库记忆、协同信号记忆以及相关事实记忆,分析各组件对学习行为模拟效果的贡献,实验结果如图 2 所示。




图 2 消融实验

Fig. 2 Ablation experiment

实验结果表明,移除任一组件均会导致 Agent4Stu 模拟性能的下降,从而验证了每个关键组件在学生行为模拟中均具有实际贡献。

4.2.4 参数敏感度分析(RQ4)

为评估基于 DeepSeek-v3 的智能体 Agent4Stu 中关键参数对其模拟性能的影响,在 Dbe-kt22 数据集中开展了参数敏感性分析,通过改变学生相似性计算中的相似度阈值 s 以及相似学生数量上限 k 来评估这两个参数对模拟性能的影响。以准确率指标作为模拟性能影响的依据。在本次实验中,设置相似学生数量 k 分别为 1,3,5,相似度阈值 s 为 0.7,0.8 以及 0.95,实验结果如图 3 所示。




图3 参数敏感度实验

Fig. 3 Parameter sensitivity experiment

可以看出：

1) 随着 k 值的增加, 准确率先保持上升, 后又略微下降, 这表明适当的协同学生数量能帮助智能体更好地模拟当前学生的作答情况, 但超出一定范围后, 则会混淆智能体的判断。

2) 阈值 s 并不是越大越好, 且与协同学生数量 k 值相互影响。

4.2.5 冷启动场景模拟性能评估(RQ5)

冷启动场景下, 基于 Dbe-kt22 数据集在 RQ1 实验中分离出的训练数据, 针对单个学生随机选择 0%, 20% 及 50% 的数据用于训练监督模型并初始化 Agent4Stu, 构建了 3 种不同程度的数据稀缺情境。值得注意的是, 在完全缺乏当前模拟学生数据的极端情况下, 本文提出“平均水平学生”画像构建方法。具体而言, 利用 K-means 聚类算法对其余所有学生的画像特征进行聚类分析, 首先将学生群体划分为若干簇, 随

后筛选出包含学生数量最多的核心簇, 最终通过计算该簇内各项关键指标(如能力因子、准确率等)的均值, 生成代表该学生群体典型特征的平均水平学生画像, 用以替代当前学生的画像信息。实验结果如表 7 所列。

结果表明：

1) 在无任何历史作答数据的情况下, 有监督模型因无法训练而无结果(用“-”表示), 而 Agent4Stu 能够正常处理该情形。

2) 随着训练数据的减少, 有监督模型的性能表现波动明显且准确率较低, 而得益于 LLM 强大的泛化能力及丰富的预训练知识, Agent4Stu 表现更为稳定且准确率相对较高。

表7 冷启动场景下不同模型之间的性能对比

模型	训练数据分配			
	0% ↑	20% ↑	50% ↑	100% ↑
DKT	—	0.5336	0.5550	0.5663
DAISIM	—	0.5763	0.5927	0.6078
EERNN	—	0.5830	0.6042	0.6351
DKVMN	—	0.5199	0.5291	0.5355
SAKT	—	0.5802	0.5953	0.6111
Agent4Stu(DeepSeek-V3)	0.6590	0.6812	0.6905	0.6965

4.3 模拟案例分析

图 4 详细展示了 Agent4Stu 模拟某一学生作答行为的案例。结果表明, 智能体能够整合学习者画像与记忆信息提炼学习状态的经验总结, 并结合学习者的知识掌握水平, 准确推理并生成合理的作答表现。

```

输入: 学生相关信息
# Profile #
{ You are a student engaging in online practice exercises. Your practice frequency is high, which indicates that your learning motivation is high. The diversity of the exercise categories you practice is high, which means you explore wide variety of knowledge categories. Your current accuracy in problem-solving is high, and you possess good analytical and problem-solving skills. } (学生画像信息)
# Short-term Memory # :
I will give you some of your most recent practice records(as Short-term Memory) below: { Record 1: You rightly answered the exercise and its information is depicted below: ** Textual Content * * ; Which technology is not used to enforce confidentiality of database security? ** Knowledge Concept * * ; Database Security } (短期个体记忆)
# Similar Question Record # :
Your question-answering record of answering similar questions is: { Record 1: You rightly answered the exercise and its information is depicted below: ** Textual Content * * ; R = { A, B, C } and Σ = { A → B, B → C }. The decomposition of R into R1 = { A, B } and R2 = { B, C } ** Knowledge Concept * * ; Lossless Join; Dependency preservation; Normalisation }
# Learning Status #
Your current * * Learning Status * * is summarized as: { -Reflection: I'll simulate this student by maintaining high accuracy in ...
. -Updated Learning Status; Expanding focus to include precise SQL... } (经验总结记忆)
# Action #
Currently, you start to answer the # Recommended Exercise # . Its content information is as follows: { ** Textual Content ** ; In SQL, which of the...
** Knowledge Concept * * ; Access Control; Discretionary access control(DAC); GRANT. } (当前作答题目信息)
Your current ** Knowledge Proficiency ** on the # Recommended Exercise # 's knowledge concept is: { Concept 'Access Control': 'high'. It means that you maintain a high mastery level of this concept. Concept... } (知识点掌握情况)
# Answer Statistics #
The record of students who have similar behavior to you answering # Recommended Exercise # : { Record 1; Student # 261, who behaves similarly to you has also done this question. His ability factor is 0.999 He correctly answered this question. } (协同信号记忆)
# Task #
Your task is to estimate whether you can correctly solve # Recommended Exercise # based on your # Profile # , # Short-term Memory # , # Similar Question Record # , # Learning Status # , ** Knowledge Proficiency ** , and # Answer Statistics # . For this recommended exercise If you think you can correctly solve this problem, answer Yes. If not, answer No. Do not output any other words (任务要求)
输出: 智能体预测结果
Yes
# 智能体认为该学生能正确回答问题

```

图4 案例研究

Fig. 4 Case study

结束语 本文针对智能教育中学生作答数据稀缺及传统模型泛化能力不足的问题,提出了一种结合大语言模型与检索增强生成技术的高效学生作答行为模拟智能体框架Agent4Stu。该框架通过多种检索策略动态获取辅助信息,智能体内部融合学生画像、记忆与行为模拟模块,综合利用历史经验与外部检索知识,生成符合学生实际学习状态的作答行为。该方法显著提升了模拟的准确性与效率,同时有效降低了构建成本。大量实验验证表明,Agent4Stu在模拟准确率、冷启动泛化能力及部署成本等方面均表现优异,展现出良好的应用价值与研究价值。尽管取得了较好的成效,但Agent4Stu在多样化行为模拟和检索策略灵活性方面仍有提升空间。未来工作将聚焦于优化检索机制,进一步提升模拟的精细度与适应性;同时,尝试基于学术模拟智能体构建可与智能教育算法交互的虚拟学生模型,以提供更可靠的个性化教学支持,推动智能教育的广泛应用与发展。

参考文献

- [1] HUANG H R, LIU J H, PAN J W, et al. Systematic transformation of education for the intelligent era: comprehensive education reform empowered by digitalization [J]. *E-education Research*, 2025, 46(4): 5-12.
- [2] FENG M, HEFFERNAN N, KOEDINGER K. Addressing the assessment challenge with an online system that tutors as it assesses [J]. *User Modeling and User-Adapted Interaction*, 2009, 19: 243-266.
- [3] 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*. 2019: 156-163.
- [4] GAO W, LIU Q, YUE L, et al. Agent4Edu: Generating Learner Response Data by Generative Agents for Intelligent Education Systems [J]. *arXiv:2501.10332*, 2025.
- [5] XU S, ZHANG X, QIN L. Eduagent: Generative student agents in learning [J]. *arXiv:2404.07963*, 2024.
- [6] REDDY S, LEVINE S, DRAGAN A. Accelerating human learning with deep reinforcement learning [C] // *NIPS Workshop: Teaching Machines, Robots, and Humans*. 2017: 5-9.
- [7] SU Y, LIU Q, LIU Q, et al. Exercise-enhanced sequential modeling for student performance prediction [C] // *Proceedings of the AAAI Conference on Artificial Intelligence*. 2018.
- [8] LIU Q, TONG S, LIU C, et al. Exploiting cognitive structure for adaptive learning [C] // *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. 2019: 627-635.
- [9] ZHAO G, HUANG Z, ZHUANG Y, et al. Simulating student interactions with two-stage imitation learning for intelligent educational systems [C] // *Proceeding of the 32nd ACM International Conference on Information and Knowledge Management*. 2023: 3423-3432.
- [10] PARK J S, O'BRIEN J, CAI C J, et al. Generative agents: Inter-

active simulacra of human behavior [C] // *Proceedings of the 36th Annual Acm Symposium on User Interface Software and Technology*. 2023: 1-22.

- [11] QIAN C, CONG X, YANG C, et al. Communicative agents for software development [J]. *arXiv:2307.07924*, 2023.
- [12] LIU J, HUANG Z, XIAO T, et al. SocraticLM: Exploring Socratic personalized teaching with large language models [J]. *Advances in Neural Information Processing Systems*. 2024, 37: 85693-85721.
- [13] RAM O, LEVINE Y, DALMEDIGOS I, et al. In-context retrieval-augmented language models [J]. *Transactions of the Association for Computational Linguistics*, 2023, 11: 1316-1331.
- [14] FENG Z, FENG X, ZHAO D, et al. Retrieval-generation synergy augmented large language models [C] // *ICASSP 2024 - 2024 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2024: 11661-11665.
- [15] BAKER F B. The basics of item response theory [M/OL]. <http://ericae.net/irt/baker>.
- [16] ABDELRAHMAN G, ABDELFATTAH S, WANG Q, et al. Dbe-kt22: A knowledge tracing dataset based on online student evaluation [J]. *arXiv:2208.12651*, 2022.
- [17] GAO W, LIU Q, YUE L, et al. Collaborative cognitive diagnosis with disentangled representation learning for learner modeling [J]. *Advances in Neural Information Processing Systems*, 2024, 37: 562-588.
- [18] HUANG Z, LIU Q, ZHAI C, et al. Exploring multi-objective exercise recommendations in online education systems [C] // *Proceedings of the 28th ACM International Conference on Information and Knowledge Management*. 2019: 1261-1270.
- [19] PIECH C, BASSEN J, HUANG J, et al. Deep knowledge tracing [C] // *Advances in Neural Information Processing Systems*. 2015.
- [20] ZHANG J, SHI X, KING I, et al. Dynamic key-value memory networks for knowledge tracing [C] // *Proceedings of the 26th International Conference on World Wide Web*. 2017: 765-774.
- [21] PANDEY S, KARYPIS G. A self-attentive model for knowledge tracing [J]. *arXiv:1907.06837*, 2019.



LIU Suyi, born in 2003, postgraduate. His main research interests include intelligent education and generative agents.



GAO Weibo, born in 1997, Ph. D. His main research interests include data mining and generative agents.