



计算机科学

COMPUTER SCIENCE

基于轻量级教育大模型的个性化实践学习资料动态推荐

翟洁, 李艳豪, 陈乐旋, 郭卫斌

引用本文

翟洁, 李艳豪, 陈乐旋, 郭卫斌. [基于轻量级教育大模型的个性化实践学习资料动态推荐](#)[J]. 计算机科学, 2026, 53(2): 48-56.

ZHAI Jie, LI Yanhao, CHEN Lexuan, GUO Weibin. [Dynamic Recommendation of Personalized Hands-on Learning Materials Based on Lightweight Educational LLMs](#) [J]. Computer Science, 2026, 53(2): 48-56.

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)

[低轨卫星网络中基于深度强化学习的航空器任务卸载策略](#)

Deep Reinforcement Learning-based Aircraft Task Offloading in Low Earth Orbit Satellite Networks
计算机科学, 2026, 53(2): 406-415. <https://doi.org/10.11896/jsjcx.250200092>

[基于拓扑虚拟结构洞节点的分布式多智能体快速共识寻求](#)

Fast Consensus Seeking in Distributed Multi-agent System Using Topology Virtual Structural Hole Node
计算机科学, 2026, 53(2): 358-366. <https://doi.org/10.11896/jsjcx.241200109>

[基于图神经网络的学业表现预测方法研究综述](#)

Survey on Graph Neural Network-based Methods for Academic Performance Prediction
计算机科学, 2026, 53(2): 16-30. <https://doi.org/10.11896/jsjcx.250800001>

[攻击图辅助下基于深度强化学习的服务功能链攻击恢复方法](#)

Attack Graph-assisted Deep Reinforcement Learning-based Service Function Chain Attack Recovery Method
计算机科学, 2026, 53(1): 371-381. <https://doi.org/10.11896/jsjcx.250300076>

[基于协作语义融合的多智能体行为决策方法](#)

Collaborative Semantics Fusion for Multi-agent Behavior Decision-making
计算机科学, 2026, 53(1): 252-261. <https://doi.org/10.11896/jsjcx.250300145>

基于轻量级教育大模型的个性化实践学习资料动态推荐

翟洁 李艳豪 陈乐旋 郭卫斌

华东理工大学信息科学与工程学院 上海 200023

(zjbzj@ecust.edu.cn)

摘要 人工智能技术在教育领域的深度应用,已成为国家教育数字化转型的核心战略。在计算机实践教学领域,实践学习资料的精准推荐是提升学生学习效能与质量的重要途径。针对高校教育规模化与学生需求多元化之间的矛盾,提出一种基于轻量级教育大模型的个性化实践学习资料推荐模型 LightPLRec(Lightweight Personalized Learning Recommender for Dynamic Practice Materials),旨在依据学生个体特征的动态变化智能推荐个性化的实践学习资料。基于低算力需求的轻量级大模型,通过指令微调和强化学习方法构建了面向个性化实践学习资料推荐的教育大模型 SPIR(Student Profile & Interest-based Recommender)。通过整合多源异构数据,深度融入课程知识体系、学科前沿动态、产业发展趋势、国家战略导向,构建了跨学科、多模态的实践学习资料库,并设计了图转主题文本方法 graph2topic。依托于 SPIR 大模型的强大赋能和多源资料库的坚实支撑,提出了基于智能工作流的资料推荐方法。设计主题分析方法从学生能力评估结果中提取学生的能力特征,应用图卷积网络算法 GCN 从学生学习行为数据中挖掘学生的兴趣特征,创建了“能力-推荐智能体”和“兴趣-推荐智能体”,构建了双智能体协同驱动的智能流程体系,实现了从学生个性化画像智能生成到实践学习资料动态推荐的系列工作流任务;并且构建了个性化资料推荐数据集,在该数据集上验证了所提模型的性能显著优于基线模型。其中,以 Qwen2.5-3.0B 为基模型训练的 LightPL-Rec 模型,在能力推荐与兴趣推荐这两项任务中展现出卓越性能,准确率分别高达 0.947 和 0.939,其表现均优于 DeepSeek-V3 在同一数据集上的测评结果。该研究为教育大模型的垂直场景应用提供了技术范式,同时通过创建个性化实践学习资料动态推荐模型,为践行“因材施教”理念和培育高素质计算机实践人才提供了创新路径。

关键词: 轻量级教育大模型;个性化推荐;GCN 算法;智能工作流;智能体;强化学习

中图分类号 G434

Dynamic Recommendation of Personalized Hands-on Learning Materials Based on Lightweight Educational LLMs

ZHAI Jie, LI Yanhao, CHEN Lexuan and GUO Weibin

School of Information Science and Engineering, East China University of Science and Technology, Shanghai 200023, China

Abstract The deep integration of artificial intelligence(AI) technology in the education sector has become a core strategy for national educational digital transformation. Within the domain of computer practice teaching, the precise recommendation of practical learning resources serves as a vital pathway to enhance student learning efficacy and quality. Confronting the tension between the scale of higher education and the diversification of student needs, this study proposes a lightweight educational large model-based personalized practice learning resource recommendation framework, named LightPLRec(Lightweight Personalized Learning Recommender for Dynamic Practice Materials). The model is designed to intelligently recommend tailored practical learning materials in response to the dynamic changes in individual student characteristics. Leveraging a lightweight large model with low computational demands, it constructs the SPIR(Student Profile & Interest-based Recommender) educational large model for personalized practical learning resource recommendation through instruction fine-tuning and reinforcement learning methods. By integrating multi-source heterogeneous data and deeply incorporating the curriculum knowledge system, disciplinary frontiers, industrial development trends, and national strategic orientations, it establishes a cross-disciplinary, multimodal practical learning resource

到稿日期:2025-08-01 返修日期:2025-10-25

基金项目:上海高校市级一流课程建设项目(沪教委高[2025]5号);2024年度教育部产学研合作协同育人项目;2024年度教育部-华为“智能基座”产教融合协同育人基地一流课程建设项目;国家自然科学基金青年科学基金(62306112)

This work was supported by the Shanghai Municipal First-Class Undergraduate Course Construction Project(Shanghai Municipal Education Commission Higher Education [2025] No. 5), 2024 Ministry of Education Industry-University Cooperative Education Program, 2024 Ministry of Education-Huawei “Intelligent Base” Industry-Education Integration Collaborative Education Project; First-Class Course Construction and Young Scientists Fund of the National Natural Science Foundation of China(62306112).

通信作者:李艳豪(2814058178@qq.com)

repository and designs the graph2topic method for converting knowledge graphs into thematic text. Empowered by the robust capabilities of the SPIR large model and supported by the multi-source resource repository, it proposes an intelligent workflow-based recommendation method. Specifically, it designs a thematic analysis method to extract student competency features from assessment results, applies the GCN(Graph Convolutional Network) algorithm to mine student interest features from learning behavior data, and creates dual intelligent agents: a “Competency-Recommender Agent” and an “Interest-Recommender Agent”. This constructs a dual-agent collaboratively driven intelligent workflow system, enabling a series of tasks from the intelligent generation of personalized student profiles to the dynamic recommendation of practical learning resources. Furthermore, a personalized resource recommendation dataset is constructed, on which the proposed model demonstrates significantly superior performance compared to baseline models. Specifically, the LightPLRec model trained on the Qwen2.5-3.0B base model demonstrates outstanding performance in both the capability recommendation and interest recommendation tasks, achieving accuracies of 0.947 and 0.939 respectively, surpassing the evaluation results of DeepSeek-V3 on the same dataset. This research provides a technical paradigm for the vertical application of educational large models in specific scenarios. Simultaneously, by creating a dynamic personalized practical learning resource recommendation model, it offers an innovative pathway to implement the principle of “teaching students according to their aptitude” and cultivate high-quality computer practice talents.

Keywords Lightweight educational large model, Personalized recommendation, Graph convolutional network algorithm, Intelligent workflow, Intelligent agent, Reinforcement learning

1 引言

近年来,人工智能技术在教育领域的深度应用,已成为国家教育数字化转型的核心战略。《教育强国建设规划纲要(2024—2035年)》明确提出“探索数字赋能大规模因材施教、创新性教学的有效途径”。在此背景下,AI赋能的个性化学生培养方式成为应对教育规模化与学生多元需求矛盾的关键解决方案。而如何构建高效、可解释的个性化学习推荐框架,已成为当前个性化教育技术研究的重要方向。

在个性化学习推荐技术领域,研究者围绕学习者特质精准建模及教育资源智能匹配机制等展开深入探索,有效推动了教育技术的创新发展。但这些研究依旧存在以下问题:1)现有推荐模式往往按照学生能力的不同层次按类推荐相应的资料,难以有效契合学生个体差异化的学习需求;2)个性化推荐机制未充分融合学习者能力与兴趣的协同价值,亦难以动态适配二者随时间演变的需求,导致推荐资料更新不及时。

针对上述挑战,面向计算机实践教学领域,提出了基于轻量级大模型的个性化实践学习资源动态推荐模型。以Qwen2.5-3.0B等为代表的轻量级通用大模型在具备较低资源占用优势的同时,展现了强大的知识融合与逻辑推理能力,但缺乏教育领域的垂直知识体系,难以满足个性化实践学习资源推荐的深度需求。本文构建了教育场景下的大模型SPIR,结合智能工作流(Agentic Workflows)等技术,创建了个性化资源动态推荐模型。本文主要贡献点如下:

1)提出了基于轻量级大模型的个性化实践资料动态推荐模型LightPLRec,依据学生的能力特征和兴趣特征的动态变化,实时且精准地推送跨学科、多模态的个性化学习资料包。

2)提出了基于PP-OCR(Post-processing Optical Character Recognition)和LLM(Large Language Model)的图转主题文本方法graph2topic,将图资料转换为适合不同类型学生学习的主题文本资料;并设计了基于图卷积网络算法GCN

(Graph Convolutional Network)的兴趣特征挖掘方法,依据学生行为的历史数据,精准挖掘其动态演化的兴趣偏好。

3)创建了基于能力或兴趣特征推荐资料的数据集,基于微调优化和强化学习策略构建了SPIR大模型,其可应用于计算机实践学习资料的个性化推荐领域;提出了基于智能工作流的个性化实践学习资料生成方法,依托于SPIR大模型创建了能力-推荐agent和兴趣-推荐agent,构建了双智能体协同驱动的智能流程体系。

相关实验结果表明,所提模型较基线模型展现出显著的性能优势,为践行“因材施教”理念、培育高素质计算机实践人才提供了创新路径。

2 相关工作

2.1 轻量级大模型

轻量级大模型^[1]以精简架构实现高效运算,兼具低算力消耗与快响应速度。其模块化设计适配多元场景,在终端设备流畅运行,既保障了隐私安全,又降低了部署门槛,为实时交互与普惠AI提供了轻量化的解决方案。

在模型设计方面,近年来也涌现出一系列小参数量但性能优异的大语言模型。LLaMA^[2]系列模型在保持较小参数量规模的同时,展现出优异的性能,适用于多种自然语言处理任务。Phi^[3]系列模型通过高质量的数据集和精心设计的模型架构,在数学推理和编程任务中表现出色。Qwen^[4]系列模型则在中文语言处理任务中展现出良好的语言理解和生成能力。MiniCPM^[5]系列模型通过优化模型结构和训练策略,实现了在移动设备上的高效运行。相比传统方法,这些工作为轻量级大模型的实用化提供了新的技术路径。

另外,CONEG框架^[6]通过层次化建模与LLM增强过滤机制生成高质量混淆负样本,有效提升了关系预测等性能,为多模态、跨学科教育资料库的构建与负样本设计提供了方法论支持。

2.2 智能体构建

随着大模型在自然语言处理任务中取得显著进展,研究者逐渐将其视为构建智能体(Agent)的核心组件。智能体^[7]被定义为能够感知环境、进行推理、规划并执行任务的自主系统。在构建大模型智能体的过程中,研究者提出了多种架构和方法。Yao等^[8]提出的 ReAct 框架将推理和行动结合起来,使得智能体在处理任务时能够进行自我推理,并根据推理结果采取相应的行动。Wang等^[9]提出的 DEPS 方法通过将视觉输入转换为语言描述,使得大模型能够理解和规划复杂的任务,从而提升其在多模态环境中的表现。Xiang等^[10]提出的世界模型方法使得智能体能够基于历史经验预测未来的状态,从而进行有效的规划和决策。

值得注意的是,工作流机制正成为提升智能体任务执行效率的关键新方向。这一机制旨在通过结构化、自动化的任务流程编排,高效管理复杂任务的执行过程。例如,微软^[11]提出的 AutoGen 框架通过动态任务分解与多智能体对话机制(如 UserProxyAgent 与 AssistantAgent 的协作循环),实现了代码生成、调试与反馈的自动化工作流执行。A2A 协议^[12](Agent2Agent Protocol)作为首个智能体间通信的开放标准,通过智能体名片和任务生命周期管理机制,为跨组织智能体协作提供了标准化接口规范,显著降低了多智能体系统集成门槛。此外,神州问学团队提出的 Routine 框架^[13]创新性地将企业任务拆解为结构化子步骤,通过规划模块与执行模块的协同优化,大幅提升了工具调用准确率。这些研究工作凸显了工作流机制在提升智能体系统执行效率、处理复杂性和促进协作方面的重要价值。

2.3 图机器学习方法

图机器学习(Graph Machine Learning)^[14]是处理图结构数据的核心方法,旨在从节点、边及图整体中提取有效特征并完成各类下游任务。图神经网络(Graph Neural Network, GNN)作为该领域的代表性技术,通过融合图拓扑与节点特征,实现了对复杂关系的高效建模。现有研究通常将 GNN 分为谱域 GNN^[15]和空间域 GNN^[16]两类。谱域 GNN 基于图信号处理理论,通过谱图滤波实现特征传播。例如, ChebNet 利用切比雪夫多项式逼近图拉普拉斯矩阵的谱滤波器; BernNet 引入伯恩斯坦基函数,可灵活逼近任意谱滤波器; Wang 等证明线性 GNN 在特定条件下能够生成任意图信号。这类方法在节点分类和图回归任务中表现出色,但受限于谱分解的计算复杂度,难以扩展到大规模图数据。空间域 GNN^[17]基于消息传递机制,通过局部邻域聚合更新节点表示。典型模型包括 GCN, GAT(Graph Attention Network)和 GIN(Graph Isomorphism Network)。因此,无论是谱域方法通过频域滤波器建模全局结构^[18],还是空间域方法借助局部邻域消息传递聚焦拓扑关系,两者均展现出对图结构与节点特征的高效融合与表达能力^[19]。

2.4 个性化学习推荐

通过融合大模型的语义理解能力、智能体的动态决策机制或图机器学习的复杂关系建模^[20],个性化学习推荐模型对用户多维度需求的捕捉精度得到显著提升。在实际应用中,

个性化学习推荐存在多种场景。图机器学习技术与个性化推荐算法^[21]能够根据学生的实时答题数据与历史学习轨迹,智能推荐最适合其当前能力水平的学习内容,并自动调节题目难度与知识密度,确保学生在匹配自身认知节奏的环境中稳步提升学习效率。例如, DyGKT 模型^[22]构建了一个连续时间动态问答图以处理不断增长的学生答题行为,并利用双时间编码器区分长短期时间间隔的语义差异,显著提升了对学生知识状态动态建模的准确性。在大模型驱动的个性化方案领域,融合决策树与大模型构建学生能力评估模型^[23],并开发个性化推荐工具,依据评估结果精准推送学习资料或实验任务,可以有效解决传统计算机实验教学难以满足个性化需求的问题,提升了教学效率与学生实践创新能力。此外, PKSD 框架^[24]将学习者的实际知识状态作为特权信息引入强化学习训练过程,并借助知识状态适配器在推理阶段模拟该状态,显著提升了对多源异构学生特征的适应能力。未来,随着图机器学习在跨学科知识关联建模中的深入应用,以及教育智能体在沉浸式环境中的决策优化,个性化推荐系统有望进一步打破学习边界,构建真正以学习者为中心的智慧教育。

3 基于轻量级大模型的个性化实践学习资料动态推荐模型

多模态数据资料库及轻量化大模型 SPIR,为个性化实践资料的动态推荐模型奠定了坚实基础。LightPLRec 模型从学生数据中智能提取学生的能力特征、兴趣特征,分别应用能力-推荐智能体和兴趣-推荐智能体生成动态的个性化实践学习资料。

3.1 模型的整体流程

为助力学生在筑牢课程基础知识的同时,实时把握计算机领域的科研动态、产业趋势与国家战略方向,整合了课程教学、学科研究、产教融合等多平台优质资料。此外,聚焦跨学科复合型人才培养目标,计算机实践项目深度融入多学科知识体系。因此,构建了涵盖课程知识体系、科研前沿探索、产业发展趋势及国家战略需求的跨学科、多模态实践学习资料库。

面向教育场景下的个性化学习推荐需求,创建了适配性强的资料推荐数据集,并以此数据集为基础对轻量级大模型开展精细化微调,同时引入 GRPO(Generalized Reward Policy Optimization)优化策略显著提升微调结果的正确性和规范化效果,成功构建了轻量化大模型 SPIR。

基于 LLM 技术,针对学生能力评估结果开展主题化分析,以提炼学生能力特征。同时,应用图卷积网络算法 GCN 从学生学习行为数据中挖掘学生的兴趣特征。

依托能力特征画像及计算机实践项目相关的核心必修知识点与拓展选修知识点,借助能力-推荐智能体自动生成个性化的知识清单。依据学生相关的知识清单和知识、行为兴趣特征,通过兴趣-推荐智能体生成适合学生个体的实践学习资料。

本文模型的整体流程如图 1 所示。

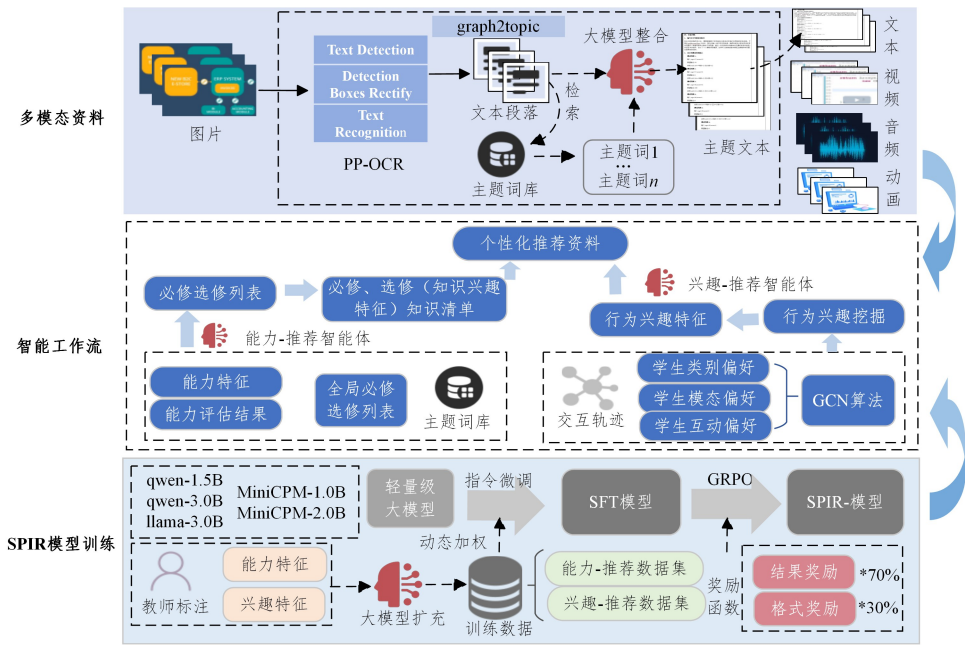


图1 模型整体流程图

Fig. 1 Overall flowchart of the proposed model

3.2 轻量级大模型 SPIR 的构建

轻量级大模型 SPIR 的构建流程为:首先构建融合学生知识掌握能力、行为兴趣特征的个性化资料推荐数据集,然后基于面向数据不平衡问题的动态加权采样策略对轻量级大模型进行微调,最终基于强化学习算法 GRPO 对微调的结果进行优化。

3.2.1 个性化资料推荐数据集的构建

目前尚不存在能够全面兼顾学生能力水平以及兴趣特征的公开可用数据集。为适配教育推荐场景并支撑模型微调,构建了基于能力或兴趣特征推荐资料的数据集。相关数据源自融入课程知识体系、学科前沿动态、产业发展趋势、国家战略导向的数字化云平台,采集了不同年级学生参与学科交叉类、软件工程类、程序设计类实践课程时所产生的历史数据,并借鉴了开源数据集的数据。首先,分别采用 3.3.1 节和 3.3.2 节所述方法,获取学生的学习能力特征、兴趣偏好特征。接着,教师依据能力特征标注出可以推荐给该生的必修与选修知识列表,并根据行为兴趣特征、知识清单标注出对应的推荐资料,得到原始数据。最后,利用大模型的语义理解与生成能力,基于已经人工标注完成的数据进行多样化改写与转换,扩充了特征规模并覆盖了更丰富的表达形式。最终构建的数据集如下所述。

1)能力-推荐数据集:数据形式为(能力特征 1,全局必修列表与选修列表;所推荐的必修列表:[课程知识点 1, …],选修列表:[科研知识点 1,企业知识点 1,国家战略知识点 1, …])。必修和选修知识含义见 3.3.3 节。

2)兴趣-推荐数据集:数据形式为(必修知识清单+基于知识兴趣特征的选修知识清单,学生在资料类别、资料模态、学习方式这 3 个维度的行为兴趣特征,个性化推荐资料)。

3.2.2 基于动态加权采样策略的指令微调

基于教育推荐任务特性及部署资源受限的原因,选取了

参数量在 4×10^9 以下的轻量级开源大模型作为基础模型进行指令微调 SFT(Supervised Fine-Tuning)。微调过程旨在使轻量级模型精准理解并执行能力-推荐、兴趣-推荐两阶段推荐指令。同时,面对数据集中存在的显著不平衡问题,提出了一种面向不平衡数据的动态加权采样策略:在训练过程中,根据每个批次内不同任务样本的分布比例,动态调整其采样权重与损失函数权重,给予稀疏任务样本更高的关注度,从而缓解模型在少数样本上的预测偏差。

3.2.3 基于强化学习算法 GRPO 的效果优化

经指令微调优化后的模型虽已初步具备执行学习资料推荐任务的基础能力,但少数测试用例存在输出格式不符合规范要求或多次的输出结果不一致等情况,因此在输出内容的格式规范性及结果稳定性方面仍存在一定的改进空间。为了提升模型输出结果的规范性和稳定性,基于强化学习算法 GRPO 对微调后的轻量级模型进行了训练。具体而言,设计了一套基于规则的、面向两阶段推荐任务的奖励函数机制,包括结果奖励和格式奖励。结果奖励专注于评估结果内容的准确性,其计算基于模型生成的推荐列表实体与标准答案之间是否达成精确匹配。格式奖励则强制执行严格的格式约束,输出必须采用结构化的、规范的列表形式呈现最终结果。

3.2.4 graph2topic 方法

在构建实践学习资料库时,蕴含丰富文本信息的图像未被有效利用。OCR 技术尽管能够提取图像中的文字,但缺乏清晰的段落划分和主题聚焦。针对上述问题,提出 graph2topic 方法,旨在将图像中提取的文字信息重组为结构化、主题明确的文本。首先,利用 PP-OCR 引擎精准识别图像中的文字内容,获取原始的、非结构化的文本序列。随后,从实践项目相关的主题词库对 OCR 识别结果进行主题匹配,检索出文本中涉及的核心主题词。最后,应用 LLM 执行智能

重组任务,输出一系列主题明确、语义连贯的“主题文本”单元,每个单元代表一个逻辑清晰的段落,共同构成结构化的高质量、可供不同需求学生学习的文本资料。

3.3 基于智能工作流的个性化资料生成

个性化资料生成过程中,既在知识层面兼顾学生能力、兴

趣特征的协同,又在行为层面精准考量学生对资料类别、呈现模态、学习方式的偏好。工作流任务流程包含能力特征生成模块、兴趣特征生成模块、基于能力-推荐智能体的知识清单生成模块、基于兴趣-推荐智能体的个性化资料生成模块。流程示例如图2所示。

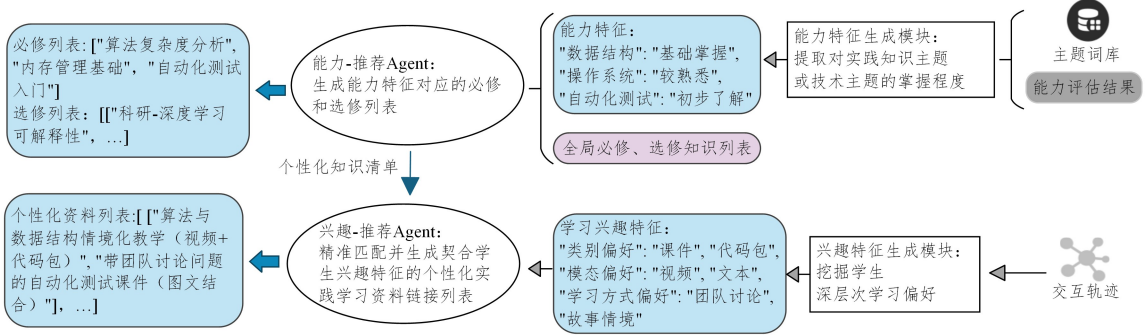


图2 智能工作流示例图

Fig. 2 Example diagram of intelligent workflow

3.3.1 能力特征生成模块

基于大模型从实践项目决策树提取主题词,并将其存入主题词库。依托能力评估结果和项目相关的主题词,应用大模型技术提取关于各主题的能力特征,即对实践知识主题或技术主题的掌握程度。以“自动化测试系统”为例,能力特征生成的示例如表1所列。

表1 能力特征生成示例

Table 1 Example of ability characteristics generation

能力评估结果	决策树	能力特征
学生主题1未有过相关代码实践,在主题2上完成了3个在线实验,.....	{“** 实验决策树”{“主题1”: {“评估方式”:“*****”},“对在主题2上完成了3个在线实验,.....”}“主题2”: {“评估方式”:“*****”}.....}}	[主题1: 仅掌握基本概念;主题2: 非常熟悉];.....

3.3.2 兴趣特征生成模块

兴趣特征可细分为知识型兴趣与行为型兴趣。其中,知识型兴趣借助智能对话交互模式,精准捕捉学生在知识拓展领域的关注焦点;而行为型兴趣则聚焦于对学生实际行为为好的深度洞察。资料类别、模态形式、学习方式如表2所列,其中论文包含课程论文、学术论文等,报告包含学术会议报告、企业专家报告和国家战略报告等,项目案例包含科研前沿成果案例、企业创新实践案例和往届学生优秀案例等。

表2 资料类别、呈现模态、学习方式形式

Table 2 Data category, modality type and learning mode

资料类别	资料模态	学习方式
课件、论文、报告、代码包、电子书、习题集、项目案例、企业云平台资源等	文本、图片、视频、音频、动画等	教师讲授、学生提问、团队讨论、故事情境、动手实践、游戏模拟等

从学习平台采集近期每位学生学习行为方面的历史数据,设计了一种基于GCN的学生兴趣特征提取方法,该方法通过端到端的图学习框架挖掘资料类别、模态方面的深层次学习偏好。如图3所示,该算法包含3个核心阶段。1)二部图构建:将学生和资源建模为异构图节点,学生访问不同学习资料的次数、时长等历史交互行为作为带权边,资源节点携带

类别和模态的嵌入特征;2)多层图卷积:通过堆叠的GCN层实现特征传播,每层包含邻居聚合、特征变换和非线性激活;3)兴趣解耦:最终的学生节点嵌入被分离为类别偏好分布和模态偏好分布。

另外,鉴于云平台未收集到学生对不同主题内容的学习方式偏好信息,引入了开源的Education Dialogue Dataset数据集^[25]。此数据集涵盖了教师所讲授的特定主题以及与之对应的学生学习方式偏好情况。本文据此参考了该公开数据集中相近主题下的学习方式偏好相关数据。

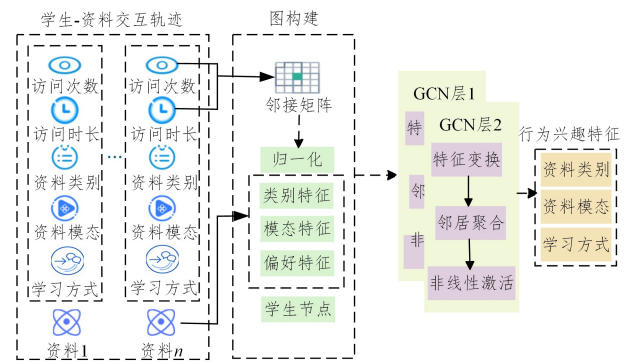


图3 学生兴趣特征提取方法

Fig. 3 Student interest feature extraction method

3.3.3 基于能力-推荐智能体的知识清单生成模块

计算机实践教学涉及多样化的实践项目,各项目关联多个知识或技术主题。本文为所有主题设置了相应的必修知识点和选修知识点,并将其系统整合为必修知识列表和选修知识列表。必修知识点紧密围绕实践课程的核心知识体系与关键技术要点进行设置;而选修知识点则以科研前沿探索、企业实践场景以及国家战略发展为导向广泛取材,既重视基础知识的夯实,又注重拓展知识的延伸。依托于轻量级大模型SPIR,基于能力-推荐智能体生成能力特征对应的知识清单,该智能体的设计信息如表3所列。此外,依据学生的知识兴趣特征,从候选清单中选取学生希望深入探究的知识点,并与必修知识点进行有机融合,最终形成专属的个性化知识清单。

表3 能力-推荐智能体的设计信息

Table 3 Design information for capability-recommender agents

名称	内容
输入信息	学生的能力特征、全局的必修知识列表和选修知识列表
输出信息	学生能力特征对应的必修+选修知识清单
角色设置	你是一个善于推荐最符合学生能力特征的知识清单的老师
任务定义	基于所给的学生能力特征,从所给全局选修知识列表和必修知识列表中,推荐给最适合学生的知识
输出格式	必修列表:[课程知识点1,...],选修列表:[科研知识点1,企业知识点1,国家战略知识点1,...]

3.3.4 基于兴趣-推荐智能体的个性化资料生成模块

依托个性化知识清单和行为兴趣特征,借助轻量级大模型 SPIR 的生成能力,基于兴趣-推荐智能体精准匹配并生成契合学生兴趣特征的个性化实践学习资料链接列表。该智能体的设计信息如表 4 所列。依据个性化的资料链接列表,为学生精心设计了契合学生个体特征的专属推荐页面,其中涵盖教师代理虚拟形象、计算机实践项目名称、教师和学生名称、可解释性的推荐依据、精选学习资料链接列表。个性化的推荐页面示例如图 4 所示。

表4 兴趣-推荐智能体的设计信息

Table 4 Design information for interest-based recommendation agents

名称	内容
输入信息	个性化知识清单、行为兴趣特征
输出信息	契合学生兴趣特征的个性化实践学习资源
角色设置	你是一个善于推荐最符合学生兴趣特征资料的老师
任务定义	基于所给的学生兴趣特征,从所给个性化知识清单当中,推荐给最适合学生的个性化实践学习资源
输出格式	个性化资料列表:[必修(课程知识点1,资料类别,呈现模式,学习方式,资源链接),……,选修(科研知识点1,资料类别,呈现模式,学习方式,资源链接),……]

构建方法(见 3.2.1 节),依据学生行为的历史数据以及公开数据集,分别创建了能力-推荐数据集和兴趣-推荐数据集。数据集按 7:3 划分训练集和测试集(数据信息见表 5),确保评估可靠性。每条能力特征数据皆围绕一个计算机实验相关主题展开,且每个实验所涉主题数量介于 3 至 10 个之间。每条行为兴趣特征数据涵盖 3 个维度,于各维度内选取排名靠前的 2 个兴趣候选项,整体构成含 6 项内容的集合。同时,构建了 5000 余条跨学科、多模态资料数据,以有力支撑个性化推荐系统的高效运行。

表5 数据集数据信息

Table 5 Dataset data information

数据集	数据量	训练	测试
能力-推荐数据集	1014	714	300
兴趣-推荐数据集	2488	1738	750

4.2 实验设置

训练阶段使用 2 张 NVIDIA A800(80GB) GPU 进行分布式训练,模型采用 5 个轻量级参数大语言模型,分别进行 LoRA 训练。训练时启用动态 FlashAttention 优化机制,共训练 2 个 epoch。优化器采用 AdamW,设置全局批量大小为 32(每卡 16),配合余弦学习率衰减策略和 0.01 的权重衰减率。推理阶段通过 vLLM 框架执行,每 GPU 批量大小为 16,生成时采用极低温度系数(0.01)保证输出的确定性。

4.3 实验分析

本节为了验证轻量级教育大模型 SPIR 的构建方法以及基于能力-推荐智能体的知识清单生成模块、基于兴趣-推荐智能体的个性化资料生成模块的有效性,设计了系列实验,采用自主构建的能力-推荐数据集和兴趣-推荐数据集。基线模型包含超大规模大模型 DeepSeek-V3 及 5 个经典的轻量级大模型(Qwen2.5-1.5B/3.0B, Llama3-3.0B, MiniCPM-1.0B/2.0B)。

所有实验的核心指标如下:

- 1) Accuracy: 衡量推荐结果与标准清单的一致性。
- 2) Precision@3: 前 3 个推荐结果中正确项的比例。
- 3) Recall@3: 真实目标被前 3 个推荐覆盖的比例。
- 4) F1@3: Precision 与 Recall 的调和均值。
- 5) NDCG@3: 关注正确结果在推荐列表中的顺序,越靠前权重越大,越接近用户的实际体验。
- 6) Compliance Rate: 模型输出格式符合规定格式要求的比例。

4.3.1 节和 4.3.2 节均为面向两个阶段性任务的实验,任务信息如表 6 所列。4.3.3 节面向基于大模型 SPIR 的个性化资料生成的整体任务进行实验。

表6 阶段任务信息

Table 6 Phase task information

阶段任务名称	数据集	对应的智能体
基于能力特征的知识清单生成任务(简称能力推荐任务)	能力-推荐数据集	能力-推荐智能体
基于兴趣特征的个性化资料生成任务(简称兴趣推荐任务)	兴趣-推荐数据集	兴趣-推荐智能体

4.3.1 对比实验

面向两阶段任务,分别从 Zero-shot, COT 和 SFT+Agent

个性化学习资源推荐

基于你的学习表现和偏好,为你定制了以下学习资料

李*同学,您好!

因为您目前对 WebDriver 知识掌握不牢固,特为您定制推荐。这组必修资料推荐您 WebDriver 教师提供 PPT (含课程讨论模块),选修资料则边学边看于企业资料。

推荐原因

为了助力你高效推进计算机实践项目“”的实践,指导教师“依据以下因素为你定制了推荐资料:

- 您在数据分析中表现出对 WebDriver 知识的理解不足
- 您尚未完成任何 WebDriver 相关的实践项目
- 您的学习偏好分析表明您更倾向于:

企业资料
代码类资源
文本资料
团队讨论

推荐学习资料

必修资料

文本

WebDriver 教师提供 PPT (团队讨论)

[ecust.webdriverurl1](#)

系统学习 WebDriver 核心概念与 API 使用方法,包含团队讨论模块

选修资料

文本

企业云平台 WebDriver 实操代码 (团队讨论)

[ecust.webdriverurl2](#)

企业级 WebDriver 应用案例与最佳实践

图4 个性化的推荐页面示例

Fig. 4 Example of personalized recommendation page

4 实验及结果分析

4.1 实验数据集

目前网上没有公开的专门针对学生能力特征或兴趣特征进行关联推荐的数据集,因此采用自建数据集。基于数据集

三方面进行了大模型之间的对比实验。Zero-shot: 基于大模型直接生成结果。COT: 通过分步推理提示激发大模型的逻辑能力生成结果。SFT+Agent: 采用 LoRA 对轻量级大模型进行适配性微调, 并结合对应的智能体 Agent 生成结果。本研究聚焦于低资源消耗的轻量化大模型的性能优化, 鉴于超大规模模型 DeepSeek-V3 的高算力需求特性, 暂未开展针对该模型的微调工作。

对比实验结果一如表 7 所列。可以看出, DeepSeek-V3 在 Zero-shot 和 COT 设置下展现出显著的基础性能优势, 尤其在兴趣推荐任务上达到了 0.920 的准确率, 显著优于经典的轻量级大模型。然而, 基于 SFT 微调和智能体 Agent 的轻

量级大模型性能提升明显。5 个轻量级大模型在能力推荐任务、兴趣推荐任务方面, SFT+Agent 方法的正确率分别较 Zero-shot 方法的正确率平均提升了 395% 和 291%。同时, 部分改进后的轻量级大模型在特定任务上的性能优于超大规模模型 DeepSeek-V3, 如 Qwen2.5-3.0B 在能力推荐任务上达到了 0.947 的准确率, 在兴趣推荐任务上达到了 0.939 的准确率, 均优于 DeepSeek-V3。实验结果表明, 虽然模型参数规模堪称衡量基础能力的关键要素, 但借助精准高效的微调策略以及智能体的协同赋能, 轻量级大模型在参数规模受限的条件下, 能够在个性化资料推荐任务上展现出可与超大规模模型相似乃至更优的性能表现。

表 7 对比实验结果一

Table 7 Comparative experimental results I

模型	Zero-shot Accuracy		COT Accuracy		SFT+Agent Accuracy	
	能力-推荐 数据集	兴趣-推荐 数据集	能力-推荐 数据集	兴趣-推荐 数据集	数据集	兴趣-推荐 数据集
Qwen2.5-1.5B	0.170	0.272	0.247	0.323	0.800	0.811
Qwen2.5-3.0B	0.230	0.503	0.323	0.539	0.947	0.939
Llama3-3.0B	0.160	0.473	0.253	0.523	0.880	0.836
MiniCPM-1.0B	0.113	0.231	0.207	0.272	0.670	0.710
MiniCPM-2.0B	0.183	0.472	0.283	0.496	0.827	0.841
DeepSeek-V3	0.383	0.775	0.690	0.920	—	—

为强化实验设计的对照效果, 特意引入了协同过滤 (Collaborative Filtering, CF) 及关联推荐 (Association Rule Learning, AR) 这两种经典的推荐算法来与本文 LightPLRec 推荐模型展开对比研究。对比实验结果二如表 8 所列。可以看出, CF 在 Recall@3 上具有一定优势 (能力推荐为 0.842, 兴趣推荐为 0.854), 但其 Precision@3 仅为 0.772/0.791, NDCG@3 为 0.817/0.828, 说明推荐结果虽覆盖率高但排序合理性不足。AR 的表现与 CF 接近,

但在 Recall@3 上略低, Precision@3 和 NDCG@3 也维持在 0.756~0.817 的区间。相较之下, LightPLRec 框架下的不同轻量级大模型均表现出明显优势, 其中 Qwen2.5-3.0B 的 Precision@3 达到 0.958/0.951, Recall@3 达到 0.971/0.963, NDCG@3 最高可至 0.973/0.965, 全面超越了传统方法。整体来看, LightPLRec 在准确率、覆盖率与排序相关性三方面均展现了领先优势, 并在规模与性能之间取得了良好平衡。

表 8 对比实验结果二

Table 8 Comparative experimental results II

方法	Precision@3		Recall@3		F1@3		NDCG@3	
	能力-推荐	兴趣-推荐	能力-推荐	兴趣-推荐	能力-推荐	兴趣-推荐	能力-推荐	兴趣-推荐
LightPLRec(Qwen2.5-1.5B)	0.842	0.856	0.861	0.873	0.851	0.864	0.865	0.879
LightPLRec(Qwen2.5-3.0B)	0.958	0.951	0.971	0.963	0.964	0.957	0.973	0.965
LightPLRec(Llama3-3.0B)	0.8924	0.854	0.905	0.867	0.898	0.860	0.912	0.874
LightPLRec(MiniCPM-1.0B)	0.761	0.772	0.776	0.784	0.769	0.778	0.784	0.790
LightPLRec(MiniCPM-2.0B)	0.839	0.852	0.855	0.866	0.847	0.859	0.861	0.872
DeepSeek-V3	0.944	0.956	0.953	0.964	0.948	0.960	0.957	0.968
协同过滤(CF)	0.772	0.791	0.842	0.854	0.806	0.822	0.817	0.828
关联推荐(AR)	0.756	0.773	0.826	0.841	0.789	0.806	0.801	0.817

4.3.2 消融实验

为进一步证明本文基于 GCN 的兴趣特征提取方法的有效性, 进行了消融实验一, 结果如表 9 所列。在缺失该方法时, 所有基线模型在准确性指标上均呈现出明显且趋于一致的性能下滑态势。具体来看, 模型的平均相对降幅在 Zero-shot 设置下约为 22.0%, 在 CoT 设置下约为 16.8%, 而在 LightPLRec 方法中仍下降约 9.0%。基于 GCN 提取资料类别、模态方面的兴趣特征后, 不仅能有效过滤掉用户行为轨迹中的冗余与噪声, 还能在表征中显式对齐学习者的真实偏好。相较于单纯依托学生的历史行为交互数据, 兴趣特征提取展现出独特的、无可取代的价值, 能够为采用不同规模架构及推

理策略的模型赋予统一且稳健的准确率提升效能。

为了进一步提升推荐结果的正确性和规范性, 基于强化学习算法 GRPO 对微调后的轻量级模型进行了训练, 设计双重奖励机制: 结果匹配奖励 (70% 权重, 强制推荐结果完全匹配标准答案) 与格式规范奖励 (30% 权重, 约束输出结构的规范化)。消融实验结果二如表 10 所列。面向两阶段任务, 对于 5 个轻量级大模型, SFT+GRPO+Agent 方法的性能均优于 SFT+Agent 方法, 其中 MiniCPM-1.0B 在能力推荐任务上的准确率提升达到 7.6%, MiniCPM-2.0B 在兴趣推荐任务上的准确率提升达到 9.2%, 验证了 GRPO 对推荐准确率的增强作用。

表9 消融实验结果一

Table 9 Ablation experiment results I

配置	Accuracy					
	Qwen2.5-1.5B	Qwen2.5-3.0B	Llama3-3.0B	MiniCPM-1.0B	MiniCPM-2.0B	DeepSeek-V3
Zero-shot	0.272	0.503	0.473	0.231	0.472	0.775
Zero-shot(w/o GCN 兴趣特征)	0.198	0.387	0.351	0.161	0.356	0.661
Δ (影响)	-0.074	-0.116	-0.122	-0.070	-0.116	-0.114
CoT	0.323	0.539	0.523	0.272	0.496	0.920
CoT(w/o GCN 兴趣特征)	0.258	0.441	0.417	0.213	0.400	0.822
Δ (影响)	-0.065	-0.098	-0.106	-0.059	-0.096	-0.098
LightPLRec	0.811	0.939	0.836	0.71	0.841	—
LightPLRec(w/o GCN 兴趣特征)	0.736	0.859	0.752	0.635	0.763	—
Δ (影响)	-0.075	-0.08	-0.084	-0.075	-0.078	—

表10 消融实验结果二

Table 10 Ablation experiment results II

	Accuracy				提升幅度/%	
	SFT+Agent		SFT+GPRO + Agent		能力-推荐 数据集	兴趣-推荐 数据集
	能力-推荐 数据集	兴趣-推荐 数据集	能力-推荐 数据集	兴趣-推荐 数据集		
Qwen2.5-1.5B	0.800	0.811	0.832	0.843	+4.0	+3.9
Qwen2.5-3.0B	0.947	0.939	0.965	0.958	+1.9	+2.0
Llama3-3.0B	0.880	0.836	0.912	0.867	+3.6	+3.7
MiniCPM-1.0B	0.670	0.710	0.721	0.762	+7.6	+7.3
MiniCPM-2.0B	0.827	0.841	0.879	0.912	+6.3	+9.2

为了验证 GRPO 设置双重奖励机制的有效性,针对 Qwen2.5-3.0B 大模型进行了相应的消融实验,消融实验结果三如表 11 所列。实验结果表明:移除结果奖励导致 Qwen2.5-3.0B 在能力/兴趣推荐任务上的准确率分别下降 6.6%(至 0.901)和 5.3%(至 0.907),证明结果奖励设置可以提升模型的推荐准确率;而移除格式奖励导致合规率从 99.1%下降至 82.3%,同时使准确率也有所下降,证明格式奖励设置主要提升模型的格式合规率。

表11 消融实验结果三

Table 11 Ablation experiment results III

实验方案	Accuracy		格式
	能力-推荐	兴趣-推荐	Compliance Rate/%
SFT+GRPO+Agent	0.965	0.958	99.1
w/o 结果奖励	0.901	0.907	98.8
w/o 格式奖励	0.912	0.932	82.3

4.3.3 面向个性化推荐模型的整体实验

本小节将能力-推荐数据集和兴趣-推荐数据集进行有机整合,形成学生画像-推荐数据集。实验任务为:输入可生成能力、兴趣特征的学生画像数据,将其处理为基于智能工作流的系列任务,输出为生成的个性化推荐资料。实验结果如图 5 所示。结果表明:若基模型选择 Qwen2.5-3.0B,基于优化

的教育轻量级大模型,所提出的个性化实践资料推荐模型性能显著优于 DeepSeek-V3,验证了所提模型的有效性。




图5 整体任务实验结果

Fig. 5 Overall task experimental results

另外,在不同硬件环境下对各模型的推理性能进行了测试,包括真实课堂环境下接口的每分钟可请求承载量(QPM)、每秒钟请求处理能力(QPS)、Token 生成吞吐量(TPM),以及 FP16 精度下的显存占用情况。实验选用常见的 GPU 平台 RTX 3090(24 GB VRAM),RTX 4090(24 GB VRAM)与 NVIDIA A800(80 GB VRAM),所有测试均基于相同的推理引擎与批处理策略进行,以保证不同模型的横向对比公平性。测试结果如表 12 所列。

表12 各模型的推理性能测试


Table 12 Inference performance testing of various models

模型	显存占用/ GB	3090-24 GB	3090-24 GB	4090-24 GB	4090-24 GB	A800-80 GB	A800-80 GB
		QPM	TPM	QPM	TPM	QPM	TPM
Qwen2.5-1.5B	3.2+	60	17500	88	27000	172	52500
Qwen2.5-3.0B	6.5+	35	9800	52	15200	101	29500
Llama3-3.0B	6.5+	33	9200	49	14200	98	28600
MiniCPM-1.0B	2.5+	85	29000	129	42000	262	87500
MiniCPM-2.0B	4.2+	50	14500	76	22500	154	47000
DeepSeek-V3(官方,FP8)	700+	—	—	—	—	—	—

结束语 在计算机实践教学领域,面对高校教育规模化与学生需求多元化之间的矛盾,提出一种基于轻量级教育大模型的个性化实践学习资料推荐模型 LightPLRec。构建了面向个性化实践学习资料推荐的教育大模型 SPIR 和跨学科、多模态实践学习资料库,并创建了“能力-推荐智能体”和“兴趣-推荐智能体”协同驱动的智能流程体系。同时,自建了能力-推荐数据集和兴趣-推荐数据集,通过大量实验证明了所提模型的有效性。本研究为教育大模型的垂直场景应用提供了技术范式,同时通过创建个性化实践学习资料动态推荐模型,为践行“因材施教”理念、培育高素质计算机实践人才提供了创新路径。未来将扩展自建数据集,细化能力特征和兴趣特征,进一步提升所提模型的性能。

参 考 文 献

- [1] MURALIDHARAN S, TURUVEKERE SREENIVAS S, JOSHI R, et al. Compact language models via pruning and knowledge distillation[J]. *Advances in Neural Information Processing Systems*, 2024, 37: 41076-41102.
- [2] GRATTAFIORI A, DUBEY A, JAUHRI A, et al. The llama 3 herd of models[J]. *arXiv:2407.21783*, 2024.
- [3] GUNASEKAR S, ZHANG Y, ANEJA J, et al. Textbooks are all you need[J]. *arXiv:2306.11644*, 2023.
- [4] YANG A, YANG B, ZHANG B, et al. Qwen2.5 technical report [J]. *arXiv:2412.15115*, 2024.
- [5] HU S, TU Y, HAN X, et al. Minicpm: Unveiling the potential of small language models with scalable training strategies[J]. *arXiv:2404.06395*, 2024.
- [6] SHENG Y Q, ZENG W X, TANG J Y, et al. Confusing negative commonsense knowledge generation with hierarchy modeling and LLM-enhanced filtering[J]. *Information Processing & Management*, 2025, 62(3): 104060.
- [7] XIANG J, TAO T, GU Y, et al. Language models meet world models: Embodied experiences enhance language models[J]. *Advances in Neural Information Processing Systems*, 2023, 36: 75392-75412.
- [8] YAO S, ZHAO J, YU D, et al. React: Synergizing reasoning and acting in language models [C] // *International Conference on Learning Representations (ICLR)*. 2023.
- [9] WANG Z, CAI S, CHEN G, et al. Describe, explain, plan and select: Interactive planning with large language models enables open-world multi-task agents[J]. *arXiv:2302.01560*, 2023.
- [10] XIANG J, LIU G, GU Y, et al. Pandora: Towards general world model with natural language actions and video states[J]. *arXiv:2406.09455*, 2024.
- [11] WU Q, BANSAL G, ZHANG J, et al. Autogen: Enabling next-generation LLM applications via multi-agent conversations [C] // *First Conference on Language Modeling*. 2024.
- [12] HABLER I, HUANG K, NARAJALA V S, et al. Building a secure agentic AI application leveraging A2A protocol[J]. *arXiv:2504.16902*, 2025.
- [13] ZENG G, CHEN X, HU J, et al. Routine: A Structural Planning Framework for LLM Agent System in Enterprise [J]. *arXiv:2507.14447*, 2025.
- [14] CHEN C, WU Y, DAI Q, et al. A survey on graph neural networks and graph transformers in computer vision: A task-oriented perspective [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024(12): 46.
- [15] HITZLER P, SARKER M. Neuro-symbolic AI = neural + logical + probabilistic AI [J]. *Neuro-Symbolic Artificial Intelligence: The State of the Art*, 2022, 342: 173.
- [16] YU X, LIU Z, FANG Y, et al. Learning to count isomorphisms with graph neural networks [C] // *Proceedings of the AAAI Conference on Artificial Intelligence*. 2023: 4845-4853.
- [17] TAN F, ZHANG C, LIU L. DyAtGNN: Dynamic Attention Graph Neural Networks for dynamic graph [J]. *Knowledge-Based Systems*, 2025, 325: 113935.
- [18] BUTEREZ D, JANET J P, OGLIC D, et al. An end-to-end attention-based approach for learning on graphs [J]. *Nature Communications*, 2025, 16(1): 5244.
- [19] WU Y, HUANG H, SONG Y, et al. Soft-GNN: towards robust graph neural networks via self-adaptive data utilization [J]. *Frontiers of Computer Science*, 2025, 19(4): 194311.
- [20] ZHANG T, LIU Y, SHEN Z, et al. Learning from heterogeneity: A dynamic learning framework for hypergraphs [J]. *IEEE Transactions on Artificial Intelligence*, 2025, 6(6): 1513-1528.
- [21] XIE P Z, LI G J, LI T. Knowledge Tracing Model Based on Exercise-Knowledge Point Heterogeneous Graph and Multi-feature Fusion [J]. *Computer Science*, 2025, 52(3): 197-205.
- [22] CHENG K, PENG L, WANG P, et al. DyGKT: Dynamic Graph Learning for Knowledge Tracing [C] // *KDD'24: Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. 2024.
- [23] ZHAI J, LI Y H, MENG T X. Exploration and practice of personalized computer laboratory teaching based on decision trees and large models [J]. *Experimental Technology and Management*, 2023, 40(12): 8-15.
- [24] LI Q Y, XIA W, YIN L A, et al. Privileged Knowledge State Distillation for Reinforcement Learning-based Educational Path Recommendation [C] // *KDD'24: The 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. 2024.
- [25] Education Dialogue Dataset | 教育对话数据集 | 对话生成数据集 [DB/OL] (2024-10-29) [2025-08-23]. <https://www.selectdataset.com/dataset/f436a1b97fdc3c9cd38ed8294694b42d>.



ZHAI Jie, born in 1977, Ph.D, lecturer, master supervisor, is a member of CCF (No. K7876M). Her main research interests include large-scale models, teaching decision support and computer practice teaching.



LI Yanhao, born in 2002, postgraduate. His main research interests include lightweight large-scale model training and educational agents.