

个性化教育资源推荐综述

席鹏晖, 吴夏祯, 蒋文聪, 方良达, 贺超波, 官全龙

引用本文

席鹏晖, 吴夏祯, 蒋文聪, 方良达, 贺超波, 官全龙. [个性化教育资源推荐综述](#)[J]. 计算机科学, 2026, 53(2): 1-15.

Xi Penghui, Wu Xiaozhen, Jiang Wencong, Fang Liangda, He Chaobo, Guan Quanlong. [Review of Personalized Educational Resource Recommendations](#) [J]. Computer Science, 2026, 53(2): 1-15.

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)

[基于背景结构感知的小样本知识图谱补全](#)

Background Structure-aware Few-shot Knowledge Graph Completion

计算机科学, 2026, 53(2): 331-341. <https://doi.org/10.11896/jsjcx.250100107>

[知识图谱的复杂逻辑查询方法研究综述](#)

Survey on Complex Logical Query Methods in Knowledge Graphs

计算机科学, 2026, 53(2): 273-288. <https://doi.org/10.11896/jsjcx.250400033>

[聚焦边界和多尺度特征融合的脑卒中病灶分割](#)

Boundary-focused Multi-scale Feature Fusion Network for Stroke Lesion Segmentation

计算机科学, 2026, 53(2): 264-272. <https://doi.org/10.11896/jsjcx.250300137>

[多模态水声图像目标视觉检测](#)

Multimodal Visual Detection for Underwater Sonar Target Images

计算机科学, 2026, 53(2): 227-235. <https://doi.org/10.11896/jsjcx.241200082>

[基于方向感知孪生网络的知识概念先序关系预测方法](#)

Direction-aware Siamese Network for Knowledge Concept Prerequisite Relation Prediction

计算机科学, 2026, 53(2): 39-47. <https://doi.org/10.11896/jsjcx.250600005>

个性化教育资源推荐综述

席鹏晖^{1,2} 吴夏桢^{1,2} 蒋文聪^{1,2} 方良达^{1,2} 贺超波³ 官全龙^{1,2}

1 暨南大学信息科学技术学院 广州 510632

2 暨南大学广东智慧教育研究院 广州 510632

3 华南师范大学计算机学院 广州 510631

(xiphms@stu2024.jnu.edu.cn)

摘要 在“双减”政策和教育数字化转型的背景下,个性化教育资源推荐系统(Educational Recommender Systems,ERS)成为智慧教育的重要支撑技术。ERS通过建模学生的知识水平、学习兴趣与行为特征,能够实现因材施教并提升学习效率。对此,系统梳理了该领域的研究进展,围绕课程推荐、习题推荐和学习路径推荐三大典型任务展开。课程推荐从传统的协同过滤与矩阵分解逐步演进到基于图神经网络与强化学习的方法,显著提升了推荐的精准性与适应性。习题推荐则从静态标签匹配转向动态知识追踪与深度学习建模,能够更好地刻画学习者与习题之间的复杂关系。学习路径推荐需要兼顾知识依赖、能力演化与多目标约束,近年来融合了图模型、强化学习和进化算法,实现了个性化路径优化。此外,还对主流数据集与实验结果进行了对比分析,总结了不同方法的优势与不足。最后指出未来研究的方向应聚焦于动态知识演化感知,跨场景泛化能力,自适应学习策略设计,以及高可解释性与教育可用性,以推动教育推荐系统由静态、封闭的“黑箱”模型向动态、透明、以人为本的教育生态系统转变。

关键词:教育数据挖掘;推荐系统;深度学习;知识图谱;个性化教育

中图分类号 G434

Review of Personalized Educational Resource Recommendations

XI Penghui^{1,2}, WU Xiazhen^{1,2}, JIANG Wencong^{1,2}, FANG Liangda^{1,2}, HE Chaobo³ and GUAN Quanlong^{1,2}

1 College of Information Science and Technology, Jinan University, Guangzhou 510632, China

2 Guangdong Institute of Smart Education, Jinan University, Guangzhou 510632, China

3 School of Computer Science, South China Normal University, Guangzhou 510631, China

Abstract Under the background of the “Double Reduction” policy and the ongoing digital transformation of education, personalized educational recommender systems (ERSs) have become a key enabler of smart education. By modelling learners’ knowledge mastery, interests, and behavioural patterns, ERS supports personalised instruction and improves learning efficiency. This paper provides a systematic review of research progress in three core tasks: course recommendation, exercise recommendation, and learning path recommendation. Course recommendation has evolved from traditional collaborative filtering and matrix factorisation to graph neural networks and reinforcement learning, enhancing accuracy and adaptability. Exercise recommendation has shifted from static tag matching to dynamic knowledge tracing and deep learning models, capturing complex learner-item interactions. Learning path recommendation must balance knowledge dependency, learner ability evolution, and multi-objective constraints. Recent approaches integrate graph-based modelling, reinforcement learning, and evolutionary algorithms to optimise personalised paths. The paper also reviews mainstream datasets and performance comparisons, summarising the strengths and limitations of different methods. Finally, it highlights future directions: dynamic knowledge evolution modelling, cross-scenario generalisation, adaptive strategy design, and enhanced interpretability and usability, aiming to transform ERS from static and opaque “black-box” models into dynamic, transparent, and human-centred educational ecosystems.

Keywords Educational data mining, Recommender systems, Deep learning, Knowledge graphs, Personalised education

到稿日期:2025-07-30 返修日期:2025-10-27

基金项目:国家重点研发计划(2022YFC3303603);国家自然科学基金(62377028);中央高校基本科研业务费专项资金(21625102)

This work was supported by the National Key R&D Program of China (2022YFC3303603), National Natural Science Foundation of China (62377028) and Fundamental Research Funds for the Central Universities(21625102).

通信作者:官全龙(gql@jnu.edu.cn)

1 引言

智慧教育是线下课堂的延伸,数字化教育已成为关键发展方向。在此背景下,在线教育平台(如 MOOCs)与智慧教育系统的快速演进推动着教育资源呈爆炸式增长,却也导致学习者陷入“信息过载”与“资源迷航”困境^[1]——面对海量课程时,其往往难以精准筛选适配内容,既降低了学习效率,更可能错失个性化学习路径。因此,如何根据学生的个性化需求、学习目标、知识掌握程度以及动态行为推荐合适的课程或者学习资源,成为数字教育时代下教育技术领域的重要研究方向^[2]。

教育推荐系统(ERS)结合教育学理论、学习者行为分析以及机器学习技术,为学习者提供个性化的学习资源推荐,从而有效提升学习效率、降低辍学率,并优化学习路径。这一系统通过实时分析学习者的行为数据,结合教学理论和人工智能,帮助学习者根据其需求和能力选择最适合的学习内容^[3]。其应用场景涵盖高校课程推荐、MOOCs 平台、习题推荐、学习路径推荐等,在现实应用中,可以覆盖中小学学习、高校教育,以及职业培训系统,具有显著的研究价值和社会意义^[4]。鼓励学习者之间的社交互动可以有效提高课程完成率。以 Coursera 为例,其 2023 年发布的《个性化学习体验年度报告》显示,平台通过引入基于用户行为数据的协同过滤推荐算法(结合课程难度、学习历史、兴趣标签等多维度特征),针对“机器学习基础”类课程进行了 A/B 测试:实验组(接收个性化推荐)的课程完成率较对照组(无推荐或通用推荐)提升了 18.7%(从 32% 提升至 38%),且学习者的知识掌握度(通过结课测试平均分衡量)提高了 12.3% ($p < 0.05$)。这一结果验证了推荐技术在 MOOCs 场景中对用户粘性 with 学习效果的显著促进作用。在国内平台中,学堂在线与中国大学 MOOC 合作开展的“智能推荐系统优化项目”(2024)提供了更具本土化的参考:通过对高校学生群体的学习行为建模(如碎片化学习时长、章节跳转频率、讨论区互动热度),平台将推荐准确率从 61% 提升至 78%,并带动试点课程(如“Python 程序设计”)的平均完课率从 25% 提升至 34%(较行业均值高 5 个百分点)。这一成果已被纳入教育部《在线教育技术应用白皮书(2024)》,印证了推荐技术在我国 MOOCs 规模化应用中的可行性。

随着教育数字化转型的推进,个性化学习已成为提升教学效果的关键路径^[5]。教育推荐系统与电商或社交推荐系统存在显著不同,例如推荐目标不同。具体来说,教育推荐系统不仅需要根据学习者的兴趣进行个性化推荐,更重要的是需要考虑学习目标的达成度、认知发展规律以及学习者的积极性。这使得教育推荐系统在设计时必须兼顾学术性、长期性和自适应性^[6]。因此,与传统的推荐系统相比,教育推荐系统不仅需要考虑学习者的学习目标和知识掌握情况,还需兼顾学习者的认知水平、学习风格 and 行为习惯等多维度因素。而这类系统不仅需要解决信息过载的问题,更要通过精准的教学资源推荐,实现针对不同学习者的自适应学习^[7]。教育推荐系统的创新之处在于结合了教育心理学理论与人工智能

技术。其通过教育心理学的理论框架,能够更精准地理解学习者的认知过程,而人工智能技术则为系统提供了实时数据分析和动态优化能力。这一交叉领域的研究推动了个性化教育教学的发展^[8]。

当前教育推荐系统呈现出多模态融合的发展趋势,这意味着系统不仅结合了学习者的行为数据,还引入了视觉、文本等多种数据模态,以全面建模学习者的需求和兴趣^[9]。研究者在课程适配度建模^[10]、知识掌握程度追踪^[11]、路径动态规划^[12]等核心环节取得了系列突破。在习题推荐领域中,基于深度知识追踪的习题推荐系统可以通过时间序列建模捕捉知识掌握程度的隐形演化规律^[13]。在课程推荐领域中,基于图神经网络的课程推荐框架实现了跨平台课程元数据的异构信息融合^[14]。在学习路径推荐领域中,基于认知诊断的学习路径推荐系统可以通过学习者知识状态的估计与教学理论编码,逐步解决个性化路径生成的适配性难题^[15]。尽管知识追踪和认知诊断可以提升教育资源推荐的适配性,但其实效性仍然受限于两大瓶颈:其一,诊断模型和追踪模型依赖高质量标注数据(如专家标注的 Q 矩阵),而真实教育场景中常面临标注噪声与知识概念漂移问题(如课程大纲更新导致知识点关系变化);其二,现有路径优化多基于短期学习目标(如单元测试通过率),缺乏对终身学习能力培养的长期规划(如跨学科知识迁移能力)^[11,16]。

为了突破上述限制,在教育推荐领域中,知识图谱^[17]与深度强化学习^[18]的创新性注入正在推动自适应学习的范式变革。具体而言,研究者通过 TransE, RotatE 等图谱嵌入算法^[19]编码不同实体之间的依赖关系,例如编码学习者对于知识点的遗忘程度等。另外,引入强化学习框架可以将知识掌握程度增益为奖励函数,来实现推荐过程的优化^[20]。尽管知识图谱和强化学习可以有效地提升教育资源推荐的性能,但是依然存在 3 方面的瓶颈:其一,知识依赖关系的静态编码难以应对课程大纲动态调整引发的概念漂移;其二,强化学习的黑箱特性与教育场景的可解释性需求存在本质冲突;其三,跨文化教育差异,如中美数学课程的知识结构差异,导致算法在不同教育体系中的泛化能力受限,需设计具有跨文化适应性的推荐算法。

综上所述,学术界与工业界在个性化教育资源推荐领域已开展了广泛而深入的研究,涌现出深度知识追踪、图神经网络与强化学习融合等新理论与新方法,显著推动了教育资源推荐技术的发展。然而,该领域仍面临诸多关键挑战,包括冷启动问题、数据稀疏性、模型可解释性不足、跨场景泛化能力有限,以及对知识动态演化的适应能力不足等。为系统梳理现有技术脉络,厘清核心难点与瓶颈,并前瞻未来的发展方向,为构建更加智能、精准、以人为本的教育推荐生态系统提供坚实的理论支撑与实践指导,有必要对个性化教育资源推荐的研究进展进行全面而深入的综述。本文正是基于这一目标,旨在为教育技术领域的研究者与实践者提供有价值的参考与启示。

与已有的系统综述文章^[1-3]相比,本文的独特贡献主要体现在以下几个方面:

首先,在研究范围上,本文不仅系统梳理了课程推荐、习题推荐与学习路径推荐三大模块,还覆盖了多种前沿方法(如图神经网络、强化学习、混合模型),形成了更全面的框架。

其次,在分析深度上,本文在方法分类的基础上,进一步进行了“优劣对比”与案例对照,并结合实际教育平台的可部署性与性能进行了总结,从而增强了综述的实用价值,为读者提供了便于检索和应用的参考工具。这些方面均是已有综述未能充分覆盖的,也是本文的特色贡献。

此外,本文特别强调了未来研究趋势与教育实践之间的结合,力求推动教育推荐系统从理论探索走向实际落地,为智慧教育的长期发展提供更加坚实的支撑。

2 分类与相关术语

本文基于图1所示的分类体系,将个性化教育资源推荐划分为课程推荐、习题推荐与学习路径推荐三大方向。其中,课程推荐侧重于基于行为表征的资源匹配,关注兴趣建模与动态偏好演化;习题推荐依托认知状态估计与强化学习策略,旨在实现精准干预与能力提升;学习路径推荐则面向教育规律建模与路径规划,强调知识依赖关系与教学目标驱动的个性化引导。这三类方法在目标与技术上各具侧重,但通过协同优化,正推动教育推荐系统从单点式资源匹配迈向全流程学习伴随。本文以此为主线,构建“技术演进-数据支撑-前瞻探索”的论述框架,系统梳理该领域的研究进展与未来趋势。

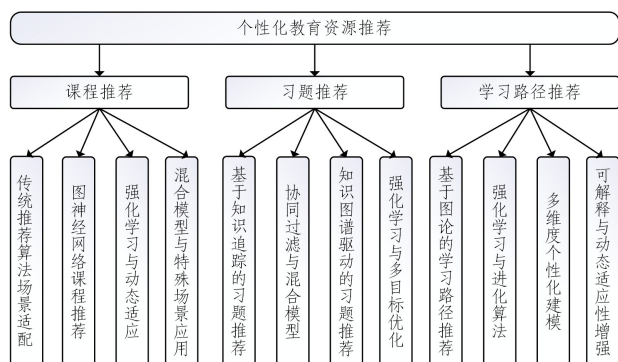


图1 分类框架图

Fig.1 Diagram of classification framework

本文所使用到的相关术语如下。1)知识状态:一般指学习者对所有已学知识的整体掌握情况。2)知识点掌握情况:学习者对某一特定知识点的掌握程度,是知识状态的具体体现。3)学习路径:指学习者按照知识点依赖关系和难度设置的学习顺序,便于提高学习者的知识状态。4)知识追踪:建模学习者知识状态演变的过程,预测其对未来知识点的掌握情况。5)协同过滤:通过挖掘学习者与习题间的潜在相似性进行推荐。6)图神经网络:通过图结构建模和学习节点间关系的神经网络方法,常用于复杂数据结构的学习和推理。7)知识图谱:通过结构化表示知识点之间关系的图形结构,能够提供知识的语义支持。8)强化学习:通过与环境交互,依赖奖励反馈来训练代理,最终优化决策策略的机器学习方法。

3 课程推荐

大规模开放在线课程(MOOCs)的兴起极大地扩展了教

育资源的可及性,但也带来了显著挑战。例如 Coursera,edX 等 MOOCs 平台课程数量激增,学习者由于可选课程数量过多,容易产生选择困难,无法有效找到适合自己的课程,从而降低学习效率。课程完成率低(平均不足 10%)的原因主要在于学习者兴趣的变化、课程设计缺乏互动性和个性化学习路径等^[21]。MOOC 场景的特殊性在于:1)学习者背景高度异构,包括不同年龄段、职业背景和知识水平,导致学习需求和学习方式产生巨大差异;2)学习行为碎片化,需实时捕捉动态兴趣;3)课程间依赖关系复杂(如先修知识、技能衔接);4)高辍学风险要求推荐系统在提高学习效果的同时,还必须确保学员的参与度和学习动力,避免缺乏个性化推荐导致学习失去兴趣。MOOC 推荐系统面临的挑战促使传统推荐算法的改进,并推动了新兴技术的探索^[22]。

3.1 传统推荐算法的场景适配

传统的协同过滤(CF)和内容过滤(CB)方法在教育推荐系统中有一定应用,但它们分别存在数据稀疏性问题和无法处理动态需求变化的局限。混合方法虽可缓解这些问题,但仍存在计算复杂度较高的问题。Parameswaran 等^[23]提出的优化框架通过将课程的时间冲突、先修条件等硬性约束纳入推荐系统,确保推荐结果的合理性。然而,该方法过于依赖人工规则,灵活性和适应性不足。Aher 与 Lobo 结合 K-means 聚类与关联规则挖掘,利用历史数据预测课程选择。这些方法通常忽视了学习者的兴趣随时间变化的动态特性,例如,学习者对某一课程的兴趣可能因外部因素(如考试临近)而发生变化,导致原本精准的推荐失效^[24]。为解决冷启动问题,Jing 等^[25]通过社交网络数据扩展用户画像,利用社交网络中已有的用户兴趣和行为数据,帮助新用户生成初步的偏好模型。而 Chang 等^[26]融合协同过滤与免疫算法来提升稀疏数据下的鲁棒性,Elbadrawy 等^[27]通过领域感知的成绩预测优化推荐,Vedavathi 等^[28]利用情感分析改进 E-learning 推荐。尽管传统方法具有可解释性优势,但仍面临数据稀疏性、动态适应性不足等挑战^[29]。

3.2 图神经网络课程推荐

为捕捉课程间的语义关系与高阶交互,知识图谱(KG)与图神经网络(GNN)凭借在复杂关系建模和数据结构化方面的显著优势,成为教育推荐系统领域研究的热点技术。Jung 等^[30]通过构建课程-知识点图谱(KPCR),有效地将课程内容与知识点关联,从而增强了推荐系统的逻辑可解释性,帮助学习者更好地理解推荐背后的原因。Yang 等^[31]提出的双边知识图谱(课程-技能-职业)通过将课程、技能与职业进行关联,支持职业导向的个性化课程推荐,帮助学习者选择符合职业发展需求的课程。超图技术通过引入超边来表示多个课程组合之间的关系,突破了传统图模型的限制,使得复杂的课程依赖关系能够得到更好的表达。Wang 等^[14]设计的 HGNN 模型通过超边表示多个课程组合模式,能够捕捉课程之间的复杂关系,增强课程推荐系统的多样性和准确性。Li 等^[32]开发的 EduGraph 通过学习路径超图建模,能够动态地根据学习者的知识进展优化推荐路径,从而实现个性化的学习路线规划。在知识动态更新方面,Deng 等^[33]提出的知识感知序列

模型通过实时更新课程和知识点的关联性,使推荐系统能够更好地适应学习者的知识进展和课程内容的变化。Sun等^[34]融合课程先验知识优化图神经网络。通过结合知识图谱和超图模型,这些方法能够基于学习者的长期目标和知识依赖关系,制定个性化的学习路线。然而,这些方法的效果高度依赖于高质量、实时更新的知识图谱^[35-36]。

3.3 强化学习与动态适应

针对学习目标漂移与实时反馈需求,强化学习(RL)在MOOC推荐系统中的应用通常将推荐任务视为一个序贯决策问题,通过反馈奖励来调整推荐策略,从而优化长期学习效果。Zhang等^[37]设计分层RL框架分离目标规划与课程选择, Lin等^[38]引入动态递归机制处理兴趣漂移。上下文感知方面, Wang等^[39]结合学习情境(设备、时段)设计在线推荐策略, Tian等^[40]通过能力追踪动态调整课程难度, Jiang等^[41]提出多通道超图神经网络增强RL的状态表征, Lin等^[42]开发自适应机制应对MOOCs开放环境, Pardos等^[43]创新性地引入“意外性”设计,平衡目标导向与探索性推荐。尽管RL方法擅长处理动态优化问题,但其在训练过程中需要大量交互数据,且计算复杂度较高,使得其在大规模在线教育平台的实际部署面临一定挑战^[44-45]。

3.4 混合模型与特殊场景应用

单一方法的局限性催生了多技术融合趋势。Ban等^[46]

通过多任务学习框架将推荐与效果预测任务联合优化,不仅提高了推荐准确度,还使得系统能够同时关注学习者的长期学习目标和短期需求; Hao等^[47]提出的元关系框架通过学习不同平台间的共享知识表示,使得推荐系统能够跨平台迁移学习,提升了模型在不同教育平台上的适应性; Zhu等^[48]结合张量分解技术,通过整合课程的文本描述和视频内容构建多模态推荐模型,有效提高了推荐系统在不同学习模式下的适应性。特殊场景中, Ma等^[49]针对高校学分约束设计课程依赖图模型, Wang等^[50]建立职业发展感知推荐系统, George等^[51]提出语义网驱动的个性化高等教育推荐。

通过对比不同的教育推荐方法,可以看到它们各自的优缺点,如表1所列。传统推荐算法,如协同过滤方法,因其简单易实现且适合大规模数据处理而被广泛应用,但数据稀疏性和冷启动问题导致其适用范围受限。图神经网络作为一种新兴的推荐技术,凭借其强大的语义建模能力,能够有效提高推荐系统的准确性和多样性,尤其适用于复杂的教育场景。然而,图神经网络在计算上较为昂贵,并且高度依赖高质量的知识图谱。强化学习则能更好地应对动态变化的学习需求,通过与学习者的实时交互不断优化推荐策略,但它的训练过程需要大量的数据和计算资源,且缺乏足够的可解释性。因此,选择适合的推荐方法应根据具体的应用场景、数据特性以及资源限制来决定。

表1 课程推荐方法总结

Table 1 Summary of course recommendation methods

方法	优点	缺点	支持在线学习	支持认知理论	实验平台	适用场景
传统推荐算法的场景适配	简单易实现;适合大规模数据分析;良好的推荐准确性	数据稀疏性严重;冷启动问题;无法处理动态需求变化	否	否	MOOC平台	学校教育,在线学习
图神经网络课程推荐	捕捉复杂的语义关系;提升推荐的准确性和多样性	对图谱质量依赖大;计算复杂度高	是	是	高校平台、MOOC平台	学校教育、企业培训
强化学习与动态适应	能动态优化推荐;适应学习者需求变化;能提升学习效果	训练数据需求大;计算资源消耗高;缺乏可解释性	是	否	企业培训、MOOC平台	个性化学习路径推荐
混合模型与特殊场景应用	克服单一推荐方法的局限性,并针对特定的教育需求提供定制化解决方案	计算资源需求较高,训练过程中需要较多的参数调优	是	否	MOOC平台、K12教育系统	企业培训、学校教育

4 习题推荐

习题推荐系统在教育推荐领域发挥着重要作用,它能够根据学习者的知识掌握情况、学习目标等信息,动态推荐适配的练习资源,有效提升学习效率^[51]。该任务旨在通过分析学习者的知识水平、学习行为(如作答时间、频率)、认知偏好(如题型选择倾向)等多维特征和习题的语义属性(如知识点关联、难度系数、题型),为学习者推荐适当的习题并调整难度,帮助他们在合适的时间点复习薄弱知识,提升学习效率^[52]。其输入主要包括两类数据:学习者侧数据包括学习者的历史答题记录、知识点掌握情况、学习目标和行为日志;习题侧数据则包括每道习题的知识点标签、难度等级、题型及文本描述。系统根据学习者的学习目标(如知识点补全、能力提升、兴趣匹配),生成个性化的习题序列或优先级排序,并通过实时调整推荐来确保目标的实现。例如, Wu等^[53]通过基于历史答题数据的知识点掌握状态预测,结合个性化模型推荐学

习者当前薄弱的知识点习题;而 Gao等^[54]结合学生的学习风格画像(如视觉型、听觉型)和习题的认知复杂度画像(如题目难度、涉及的知识点深度),生成多维度适配的推荐结果,确保习题推荐既符合学生的学习习惯,也满足其知识掌握需求。推荐系统的核心挑战源于学习者与习题间动态关系的复杂性:一方面,学习者对习题的反馈(如答题正确与否)、习题难度的适应性调整、学习者题型兴趣的变化需实时捕捉;另一方面,这些动态因素的相互干扰(如短期错题反馈可能掩盖长期兴趣倾向)会直接影响推荐决策的精准性,导致系统难以兼顾短期学习效果的提升与长期知识积累的系统性。

4.1 基于知识追踪的习题推荐

基于知识追踪(Knowledge Tracing, KT)的方法通过建模学习者的知识状态,即对当前已学知识的掌握程度,预测其对未来知识点的掌握情况,从而推荐适合的习题,为习题推荐提供动态决策依据^[11]。此类模型通常以学习者的历史答题序列为输入,输出知识点掌握概率,并据此推荐薄弱环节的习

题^[51]。例如,Wu等^[54]提出的基于LSTM的模型通过序列数据建模学习者的答题历史,捕捉其长期的知识掌握状态,为知识点预测和习题推荐提供依据;Huo等^[55]引入上下文感知表示,通过分析习题文本的语义信息(如题干关键词)和知识点层级关系,优化LSTM的时序建模能力,提升推荐精度;Ai等^[56]提出的C-DKT模型通过显式建模知识点间的依赖关系(如“三角函数”依赖“代数运算”),结合图卷积网络(GCN),提升了知识点掌握状态预测的可解释性;Gong等^[57]提出的深度练习推荐模型(DERM)结合了卷积神经网络(CNN)和注意力机制,能够动态捕捉学习者的兴趣漂移(如从基础题转向综合题),并据此生成适应性习题推荐。然而,此类模型高度依赖标注完整的知识点体系,且对冷启动问题(如新用户无历史数据)的鲁棒性不足。Huo等^[58]尝试通过班级上下文因素(如教学进度、平均成绩)缓解冷启动问题,但跨班级泛化能力仍需提升。

4.2 协同过滤与混合推荐模型

协同过滤(Collaborative Filtering, CF)通过挖掘学习者与习题间的潜在相似性生成推荐,其主要缺点是受限于数据稀疏性和冷启动问题^[59]。Li等^[60]提出基于改进协同过滤的算法,引入知识点权重(如核心知识点优先级)和遗忘曲线(模拟知识衰退)优化相似度计算,使推荐结果更贴合学习者的实时需求。Zheng等^[61]利用知识结构树构建学习者画像,将知识点掌握度映射为树状层级,增强CF的可解释性。为进一步融合多源信息,Guan等^[62]提出KG4Ex框架,将知识图谱(KG)与协同过滤结合:通过知识三元组(如“习题A考察知识点B”“学习者C掌握知识点B”)建模语义关联,并利用神经网络生成可解释的推荐路径(如“因未掌握知识点D,推荐习题E”)。Zhu等^[63]扩展了这一思路,构建增强型知识图谱,通过计算项目之间的语义相似度,将项目本身的语义信息纳入协作过滤推荐中。该算法弥补了协同过滤推荐算法不考虑项目本身知识信息的缺陷,增强了协同过滤推荐在语义层面的效果。Cheng等^[64]通过序列增强模块提升非活跃学生表示,并利用神经重排优化推荐多样性和相关性,旨在解决在线教育平台中学生高辍学率和多样化学习需求的问题。此类混合方法虽能有效整合异构数据,但模型复杂度较高,可能影响实时响应速度。

4.3 知识图谱驱动的习题推荐

知识图谱(Knowledge Graph, KG)通过结构化表示知识点间的逻辑关系,如先修关系(如“代数”是“几何”的前提)、并列关系(如“几何”和“代数”并列),以及因果关系(如“基础运算”是“解方程”的前提),为习题推荐提供语义支撑和路径规划能力。Yan等^[65]提出的基于知识图谱的推荐框架,首先使用图嵌入技术(如TransE)将知识点和习题映射为低维向量,从而捕捉知识点之间的潜在关系。然后,利用路径搜索算法,生成符合学习者认知规律的学习路径,如“先学习基础概念,再进行高级应用”。Lyu等^[66]设计了加权知识图谱,通过为知识点之间的边赋予动态权重,如难度系数和关联强度,反映知识点的不同重要性。结合强化学习优化路径选择策略,系统能够在不同学习阶段动态调整推荐内容,优先推荐对学习者最有价值的习题。Zheng等^[61]基于知识结构树构建了

层次化推荐逻辑,通过层次化的方式将知识点划分为不同层次,确保推荐的习题覆盖知识体系的广度与深度。该方法通过从基础知识点到高级知识点的逐步推荐,帮助学习者系统性地掌握知识。在可解释性方面,Guan等^[63,67]的KG4Ex框架通过可视化知识路径(如“用户因未掌握知识点X,需优先练习习题Y”)增强推荐透明度;Liu等^[68]进一步提出P-G-V评估框架(实用性-泛化性-多样性),从多维度验证知识图谱驱动推荐效果。然而,知识图谱的构建涉及大量的人工标注和领域专家的参与,知识图谱的维护需要持续更新,以反映新知识点和学习者的动态需求,尤其是在新增知识点时,往往依赖人工干预,这使得其构建和维护的成本较高,并限制了其在大规模应用中的普及。

4.4 强化学习与多目标优化

强化学习(Reinforcement Learning, RL)通过模拟学习者在学习过程中不断调整其行为和策略,优化长期的学习目标(如期末成绩提升)。具体来说,RL通过试错过程使学习者逐步调整学习策略,以达到最优的学习效果^[16]。在教育推荐中,“探索”指的是推荐新的题型或知识点,帮助学习者拓展知识面;“利用”指的是根据学习者的已掌握知识推荐相应的巩固题目,以提高学习效率。Wu等^[69]通过强化学习框架,自动平衡探索与利用的比例,确保推荐系统在学习过程中既能让学习者接触新的知识,又能巩固已学知识。Liu等^[20]的Meta多智能体框架引入课程博弈机制,协调多个推荐代理(如难度适配代理和知识点覆盖代理),使得不同代理在推荐过程中既能合作,又能竞争,最终为学习者提供个性化的学习路径。该框架通过多个代理的协同工作,使推荐策略在难度调整和知识点覆盖之间达到最优平衡。Huang等^[70]提出的多目标建模方法,通过帕累托最优搜索算法同时优化学习者的知识掌握度、学习效率和兴趣匹配度。而Ren等^[71]则设计了双层自注意力网络(MulOER-SAN),动态调整不同学习目标的权重,确保在不同时间点(如考前或日常学习中)适当侧重效率或深度。两者的研究在目标优化方面互为补充,能够进一步提升教育推荐系统的个性化水平。这些方法能够有效应对复杂的教育场景,例如处理学习者兴趣变化、应对课程难度动态变化等。然而,这些方法的训练过程依赖大量交互数据,且为了模拟真实的学习环境,通常需要构建高保真仿真环境(如学生行为模拟器),这使得实际部署难度较高。

在习题推荐方法中,通过表2可以发现,基于知识追踪的方法能够动态建模学习者的知识掌握程度,并提供个性化练习推荐,但过于依赖完整知识点体系,且冷启动鲁棒性不足。协同过滤与混合推荐模型通过相似性与多源信息融合提升了推荐效果,但依然受到数据稀疏和复杂度的限制。知识图谱驱动的方法在可解释性与认知规律匹配方面具有突出优势,能够为习题推荐提供清晰的逻辑路径,但其构建与维护成本高,应用范围受限。强化学习与多目标优化则更适合应对复杂动态教育场景,可同时优化学习者的掌握度、效率与兴趣匹配度,但数据需求与仿真环境限制了其在大规模平台的部署。综上,不同方法各有优缺点,研究者和实践者应根据应用场景选择合适的方案,并结合多种技术融合以发挥最大优势。

表2 习题推荐方法总结

Table 2 Summary of exercise recommendation methods

方法	优点	缺点	支持在线学习	支持认知理论	实验平台	适用场景
基于知识追踪(KT)	动态建模学习者知识掌握程度;能预测未来掌握情况;适合个性化适配	依赖完整知识点标注体系;冷启动鲁棒性不足	是	是	在线评测、学校教育	动态知识掌握程度监测、薄弱环节诊断
协同过滤与混合推荐模型	能利用相似性发现潜在需求;结合多源数据可提升精度;增强可解释性	易受数据稀疏性与冷启动影响;模型复杂度高,影响实时性	是	否	MOOC平台、在线评测	学习者群体相似性、异构数据融合
知识图谱驱动	能显式建模先修/因果关系;生成符合认知规律的路径;可解释性较好	构建图结构和维护成本高;需依赖领域专家持续更新	是	是	高校平台、MOOC平台、职业培训	系统化知识掌握、路径规划
强化学习与多目标优化	可动态平衡探索与利用;能同时优化掌握度、效率、兴趣等多目标;个性化强	数据需求量大;需高保真仿真环境;计算复杂度高,部署难度大	是	否	学校教育、在线评测	长期学习目标优化、复杂教育场景

5 学习路径推荐

学习路径推荐是教育推荐系统的核心任务之一,旨在根据学习者的知识水平、学习目标、兴趣偏好及行为模式,动态规划最优的学习资源序列(如课程、知识点、习题等),以解决传统“一刀切”教学模式中效率低下、个性化不足的问题^[52,72]。其核心挑战在于平衡知识点的逻辑依赖关系(如先修后学)、学习者的认知差异(如知识遗忘、能力波动)以及多目标约束(如时间成本、难度梯度)。现有系统主要基于知识图谱、图论、进化算法、深度学习与强化学习等技术,结合多维特征建模(如知识状态、交互行为、社交影响)和动态反馈机制(如实时学习分析、路径调整)。通过集成学习者的学习历史和反馈,系统能够根据学习者的进度和需求动态调整推荐内容。MOOC平台和编程学习社区等在线教育平台可以利用这一功能为学习者提供个性化的学习路径,从而提高学习者的学习参与度和完成率。

5.1 基于图论的学习路径推荐

基于图的学习路径推荐方法通过将学习内容和知识点建模为图结构,显式表示其间的依赖关系、层级和关联,利用图算法(如最短路径算法、图遍历等)生成符合知识逻辑的最优学习路径。此类方法可分为静态知识图谱与动态图模型两类。

5.1.1 静态知识图谱

早期研究侧重于利用预定义的知识图谱解决路径规划问题。例如,Shi等^[73]提出多维知识图谱框架,整合知识层级、难度标签和学习目标生成路径,通过图遍历算法(如广度优先搜索或最短路径算法)筛选符合知识依赖关系和学习目标的最优路径,确保推荐的学习顺序符合逻辑和学习效率;Zhu等^[74]进一步引入时间、认知负荷等约束条件,提出多约束路径优化算法,确保路径在满足知识依赖的同时适应学习者的时间限制。静态知识图谱依赖于人工构建的知识结构,通常包括知识点的层次结构和知识点间的固定关系。然而,这些图谱缺乏动态更新能力,无法实时适应学习者的学习进度和行为变化,从而影响推荐系统的灵活性和实时性。

5.1.2 动态图模型与图神经网络

近年来,研究者尝试结合动态知识图谱与深度学习提升推荐灵活性。Zhang等^[75]提出的基于图卷积网络(GCN)的动态知识图谱模型通过在图中传播知识点的嵌入表示,来捕

捉知识点之间的潜在语义关联。该方法能够动态调整推荐路径,以适应学习者的当前知识掌握情况和学习需求。Chen等^[76]针对MOOC场景设计增量更新的知识图谱,利用学习者的实时交互数据(如答题记录、视频观看时长)动态修正知识点权重。此外,Fiqri等^[77]提出的基于图的领域自适应模型,通过图嵌入技术将来自不同教育领域的知识迁移至目标学习场景,以应对跨学科或跨文化的知识差异,优化推荐效果。然而,动态图谱的计算复杂度较高,原因主要在于图中节点和边的动态更新,尤其是当涉及大规模学习者数据时,计算图的更新和路径搜索会增加大量的计算成本^[78],且对数据质量敏感,动态图谱的构建和更新依赖大规模的标注数据,特别是在知识点间关系的推理过程中,需要大量经过标注的真实数据集来训练模型,以确保推荐的准确性和可解释性^[79]。

5.1.3 混合图模型

部分研究探索图模型与其他技术的结合。例如,Tang等^[80]提出概念地图工具ConceptGuide,将知识图谱与视频学习场景结合,通过可视化交互增强路径可解释性;Li等^[32]设计的超图神经网络EduGraph,通过多层超边连接MOOC课程之间的复杂关系,能够捕捉不同课程、学习者和知识点之间的多跳关联,优化学习路径推荐。此类方法在编程教育^[81]、开源项目学习^[79]等垂直领域展现出潜力。尽管这些方法在某些特定领域(如编程教育)表现出良好的效果,但由于学习环境和教育需求的差异,现有方法的通用性仍有待验证,尤其是在不同学科和教育平台中的适应性。

5.2 基于强化学习与进化算法的路径优化

强化学习(RL)通过模拟学习者的动态决策过程,优化学习路径;进化算法则通过模拟生物进化过程,优化路径的全局规划^[82-83]。RL方法通过将学习路径推荐建模为序贯决策问题,使学习者通过不断的反馈调整推荐路径,通过奖励函数引导智能体探索最优策略。例如,学习者在每一步学习后,系统根据其表现调整推荐的学习资源。Cai^[84]等提出的基于深度知识追踪(DKT)的RL模型通过分析学习者的历史答题记录,预测其知识状态,从而推荐适合的习题,并通过奖励函数优化知识点覆盖率与学习效率。Yun等^[85]提出的双重约束离线RL方法通过引入行为克隆和策略正则化,克服数据稀疏性问题,并增强推荐系统的稳定性和适应性。针对多目标优化场景,Li等^[86]设计分层强化学习框架,将宏观学习目标

(如通过考试)分解为子任务(如掌握特定知识点),支持细粒度路径生成。

进化算法通过模拟生物进化过程(如交叉、变异、选择)实现路径全局优化。Dwivedi 等^[87]提出改进变长遗传算法(MVLGA),动态调整染色体长度以处理路径长度不确定性;Zheng 等^[88]结合蚁群算法与知识图谱,设计多粒度路径推荐框架,通过信息素更新机制平衡探索与开发效率;Bian 等^[89]提出的免疫算法通过模拟免疫系统的克隆选择与抗体浓度机制,有效避免了算法的早熟收敛问题,优化了多目标路径推荐过程。然而,由于进化算法需要模拟大量的个体并进行多代演化,计算资源需求大^[90],因此计算成本较高,并且其需预设适应度函数,可能忽略学习者的动态行为特征^[91]。

部分研究尝试融合 RL 与进化算法。例如,Ma 等^[92]提出级联深度 Q 网络(CDQN),将遗传算法的种群初始化策略与 RL 的在线决策结合,提升路径多样性;Zhang 等^[93]设计基于过程挖掘的强化学习框架,利用进化算法生成初始路径,再通过 RL 进行动态调整。此类方法在职业课程学习^[78]等场景中表现优异,但对超参数敏感,需复杂调优。

5.3 多维度个性化建模

多维度个性化建模通过整合学习者的知识状态、行为偏好、社交影响等异构特征,利用机器学习算法提升推荐系统的精准度,并通过动态调整满足不同场景的需求。多源特征融合的核心在于构建学习者画像并量化多维度特征。Hidasi 等^[94]提出的基于会话的推荐算法,在 GRU 网络处理之前,对会话进行单串编码和嵌入,并返回每个项目被推荐的概率。Ma 等^[95]提出的多算法融合框架将协同过滤、知识图谱和遗传算法结合,通过捕捉学习者兴趣相似性、建模知识依赖关系以及优化路径长度,提供个性化且精准的学习路径推荐;Raj 等^[96]通过实时学习分析(如眼动追踪、点击流数据)动态捕捉学习者的实时行为,更新学习者画像,并据此调整学习路径的推荐,确保推荐的内容适应学习者当前的需求。针对社交学习场景,Zhang 等^[93]提出的多上下文感知模型通过结合社交学习场景中的同伴影响和资源流行度,利用知识图谱嵌入技术捕捉学习者在学习社区中的互动,从而优化学习路径推荐。

学习者的长期行为演化对路径推荐至关重要。Chang 等^[91]使用传统的分类算法 KNN,认为每个样本可以用它最近的 K 个相邻值来表示。在学习路径推荐的任务中,使用学习路径之间的余弦相似度来衡量两个学习资源之间的相似度并推荐相似的学习资源。Zhang 等^[97]进一步引入项目难度感知机制,根据学习者的实时表现(如答题正确率)动态调整路径难度梯度。此类方法需处理数据稀疏性与噪声问题^[98],

且对计算资源要求较高^[96]。部分研究针对特定场景设计个性化策略。例如,Chen 等^[99]提出集合到序列排序框架,解决开放学习环境中概念组合的灵活推荐问题;Tang 等^[80]在视频学习场景中结合概念地图与协同过滤,提升路径可解释性。然而,多维度数据融合可能引发特征冗余与过拟合风险^[100],需设计高效的特征选择机制。

5.4 可解释性与动态适应性增强

可解释性与动态适应性是学习路径推荐系统能够被广泛应用并得到用户信任的关键因素。用户需要理解推荐的依据,而系统需要根据实时数据调整推荐策略。近年的研究从可视化、反馈机制与终身学习等角度提出解决方案。

为增强用户信任,研究者探索基于规则与可视化技术的解释方法。Tang 等^[80]开发的概念地图工具 ConceptGuide 通过交互式可视化界面,展示学习路径中各知识点的逻辑关系以及推荐的依据,帮助学习者理解推荐背后的决策过程;Frej 等^[100]提出的 MOOC 推荐系统通过生成自然语言描述,解释每条推荐路径的合理性(例如“推荐此路径因其覆盖你的薄弱知识点”),使学习者能够清晰了解推荐的依据。此外,Zhang 等^[101]提出基于过程挖掘的路径解释框架,通过日志分析揭示推荐策略与学习目标的一致性。

实时反馈机制通过实时监测学习者的表现(如答题情况),根据学习进度动态调整推荐路径,确保学习者得到最适合的学习资源。Luo 等^[102]提出高自适应模型 HA-LPR,集成在线学习算法与滑动窗口机制,根据学习者的实时表现(如单元测试成绩)调整后续路径。Raj 等^[96]设计轻量级实时分析引擎,支持秒级响应与路径重规划。针对长期学习需求,Yun 等^[85]则利用离线 RL 存储历史策略,避免出现数据分布偏移导致的性能下降问题。

学习路径推荐方法从早期的静态知识图谱逐渐发展到动态图模型与图神经网络,再到混合模型与多目标优化框架,呈现出越来越强的动态适应性与个性化趋势,如表 3 所列。静态知识图谱能够提供逻辑清晰的路径规划,但难以适应学习者实时变化的需求;动态图模型与图神经网络在灵活性上显著提升,但需要较高的计算与数据资源支持。强化学习与进化算法能够在复杂场景下实现全局与多目标优化,但在实际部署时仍受限于数据量和计算成本。多维度个性化建模和可解释性增强方法则更关注学习者行为、兴趣和信任机制,为大规模应用与推广提供了新的可能。整体而言,不同方法各具优势,未来的发展趋势在于结合图模型、强化学习与个性化建模,构建既高效又可解释的学习路径推荐系统。本文所涉及的文献分类如表 4 所列。

表 3 学习路径推荐方法总结

Table 3 Summary of learning path recommendation methods

方法	优点	缺点	支持在线学习	支持认知理论	实验平台	适用场景
基于图论的方法	能显式建模知识点依赖关系;逻辑清晰,可解释性强;动态图可适应学习者实时进度;混合模型增强灵活性	静态图谱缺乏动态更新;动态图计算复杂度高、需大量标注数据;混合模型跨领域通用性不足	是	是	MOOC 平台、学校教育图谱	动态学习环境、跨学科/跨平台推荐、特定领域学习
强化学习与进化算法	动态优化学习路径;可实现全局搜索与多目标优化;适应复杂教育场景	数据需求量大;需仿真环境;计算开销高,调参复杂	是	否	在线教育实验平台	长期目标优化、复杂路径全局规划

(续表)

方法	优点	缺点	支持在线学习	支持认知理论	实验平台	适用场景
多维度个性化建模	综合学习者画像、社交影响和实时行为;提升精度与适应性	易引发特征冗余与过拟合;计算资源需求大	是	是	社交学习平台、MOOC平台	个性化路径推荐、社交学习场景
可解释性和动态适应性增强	增强用户信任(规则、可视化、自然语言解释);支持实时反馈与路径重规划	实现复杂;部分方法依赖人工规则或额外计算资源	是	是	MOOC平台、智慧课堂	适时调整、用户信任增强

表4 相关文献分类

Table 4 Classification of relevant literature

方法	关键文献	特点
传统方法	[23-28]	主要依赖协同过滤、内容过滤及混合技术,但面临数据稀疏性和动态适应性不足的局限
课程推荐	图神经网络方法 [14,30-34]	利用知识图谱和超图技术捕捉课程间语义关系,显著提升可解释性和多样性,但高度依赖高质量知识图谱的实时更新
	强化学习方法 [37-43]	将推荐视为序贯决策问题,通过分层框架或上下文感知处理动态兴趣,但训练需大量数据且计算复杂度高
	混合模型与特殊场景 [46-51]	融合多技术(如多任务学习、张量分解)或针对特定场景(如学分约束、职业发展),增强了跨平台适应性和实用性,但模型复杂度可能影响实时响应
基于知识追踪的习题推荐	[11,54,56-59]	通过时序模型(如LSTM/RNN)分析历史答题序列,预测知识点掌握概率并推荐薄弱环节习题,实现个性化动态适配,但依赖完整标注体系且冷启动鲁棒性不足
习题推荐	协同过滤与混合模型 [55,58,60-64]	挖掘学习者与习题之间的相似性,借助协同过滤模型进行推荐,但受限于数据稀疏性和冷启动问题
	知识图谱驱动 [62-63,65-68]	利用图嵌入结构化表示知识点逻辑关系(先修/因果),生成符合认知规律的学习路径(如“基础→高级”),但图谱构建依赖人工维护成本高
强化学习与多目标优化	[18,20,69-71]	通过模拟学习者在学习过程中不断调整其行为和策略,以求达到最优的学习效果,但需高保真仿真环境导致部署困难
学习路径推荐	基于图结构的学习路径推荐 [32,73-81]	将知识体系建模为节点与边的图结构,显式编码逻辑约束(如先修关系、层级关联),为路径生成提供可计算框架,但具有高计算复杂度并且受限于跨领域迁移能力不足
	基于强化学习与进化算法的路径优化 [78,82,84-93]	将路径规划建模为马尔可夫决策过程,通过奖励函数优化长期收益(如考试通过率);进化算法则模拟生物选择机制全局搜索帕累托最优解,但需要高计算开销并且依赖于高保真的仿真环境
	多维度个性化建模 [80,91,93-99]	整合知识状态、行为偏好、社交影响等异构特征,构建动态学习者画像,然而特征冗余易造成过拟合风险,并且数据稀疏性将会降低冷启动效果
	可解释性与动态适应性增强 [80,85,96,100-102]	可解释性通过可视化工具(概念地图)与自然语言生成揭示推荐逻辑;动态适应性依赖实时反馈环(滑动窗口机制)调整策略

6 数据集介绍

在个性化教育推荐中,数据的重要性不容忽视。通过捕获有关学习者行为、偏好、属性和表现的信息,个性化学习系统可以深入了解每个学习者的不同需求,从而促进更有针对性和更有效的学习支持。这种数据驱动的建模机制不仅为个性化资源推荐提供了科学依据,更能通过时序行为分析预测学习者的潜在需求,实现前瞻性的学习路径规划。

ASSISTMents¹⁾:该数据集来源于著名的在线辅导系统——ASSISTment Tutoring System,主要包括ASSIST-Ment09-10,ASSISTMent12-13,ASSISTMent15等,每个数据集都是不同时间收集的。数据集包含学生ID、问题ID、相关知识点和每个问题所花费的时间等详细信息,如表5所列。

Junyi²⁾:该数据集来源于Junyi Academy在线学习平台。数据集呈现出分层结构,从区域到主题再到习题。在习题中,每个习题都涉及多个概念,相反,一个概念与多个习题相关联。该数据集的特点是包含习题之间的先决条件关系,因此经常用于研究智慧教育相关的工作,详细信息如表5所列。

KDDcup³⁾:该数据集来源于KDDcup2010教育数据挖掘挑战赛,主要包含了学习者对于代数问题的回答。其主要包括Algebra05-06,Algebra06-07和Bridge to Algebra 3个子集,详细信息如表5所列。

STATICS2011:该数据集来源于卡内基梅隆大学的工程静力学课程的相关问题互动,包含361092个交互记录,335名学习者,1224个问题,详细信息如表5所列。

¹⁾ <https://www.assistments.org>

²⁾ <https://pslcdatashop.web.cmu.edu>

³⁾ <https://pslcdatashop.web.cmu.edu/KDDCup>

XueTangX¹⁾:该数据集来源于 XueTangX,涵盖了1302门课程,其中包含 82 535 个注册用户信息和 458 453 个用户与课程的交互。数据集包含学生 ID、注册时间、课程 ID 和课程名称等数据信息,详细信息如表 5 所列。

MOOCCube²⁾:该数据集来源于 XueTangX 平台,包含了 55 203 名注册用户、706 门课程、38 181 个教学视频和 114 563 个概念,用户与课程之间的互动总数为 354 541 次。MOOC-Cube 关注概念、课程和学生行为 3 个主要维度。它包含大量数据,包括实体文件(课程、概念、用户等),关系文件(课程概念、用户课程等),详细信息如表 6 所列。

表 5 数据信息统计

Table 5 Data information statistics

数据集名称	问题/ 课程个数	学习者 个数	交互 个数	知识点 个数
ASSIST09	26 688	4 217	34 860	123
ASSIST12	179 999	46 674	6 123 270	265
ASSIST15	100	19 917	708 631	—
Statics2011	1 224	335	361 092	80
Junyi	722	247 606	25 925 992	5
MOOC	1 302	82 535	458 453	—
Algebra05	1 084	575	813 661	112
Algebra06	90 831	1 840	2 289 726	523
Bridgeto Algebra	19 258	1 146	3 686 871	493

表 6 MOOCCube 数据集详细信息

Table 6 MOOCCube dataset details

实体	数量	链接	数量
概念	7 507	概念-课程	21 507
		概念-视频	11 732
用户	3 111 637	用户-课程	15 045 219
		用户-视频	53 481 869
课程	7 327	课程-概念	69 012
		课程-视频	811 841
		课程-用户	167 248 752
		视频-课程	147 433
视频	62 191	视频-概念	11 732
		视频-用户	53 971 707
总计	3 183 682	—	140 096 904

尽管现有的数据集已涵盖了教育推荐中的基础应用场景(如课程推荐和习题推荐),但近年来出现的新兴学习场景,尤其是开源项目学习和编程教育的数据集,尚未得到充分关注。例如,GitHub 等平台上的开源项目学习数据集能够为编程教育中的推荐系统提供更加丰富的数据支持,但这类数据集目前较为稀缺,且大多未公开用于学术研究。未来,针对这类新场景的数据集将成为研究的重要方向。

然而,现有数据集也存在一些不足。首先,数据集由于标注噪声和数据不完整性的问题,可能会影响推荐系统的训练效果。例如,ASSISTment Tutoring System 虽然涵盖了学生与习题之间的交互,但缺乏学生的上课信息、作业提交情况以及学生的学习行为历史,这些信息对于全面评估学生的学习状态和兴趣至关重要。因此,单一依赖于交互数据的推荐系统可能会忽视学生个性化学习路径和动态学习需求,从而影响推荐的准确性和个性化水平。而 MOOC 项目数据集尽管

在教育教学中得到了广泛应用,提供了丰富的学习者行为数据,但学习者的行为具有高度异质性,还是导致了数据稀疏性问题的发生。具体而言,不同学习者在平台上的参与度、学习习惯和学习路径差异较大,造成了大量用户对某些课程或习题的参与数据缺失。这种稀疏性使得传统的推荐算法在处理用户个性化需求时面临挑战,尤其是在冷启动问题和模型训练的有效性方面。此外,异质性还可能导致推荐系统无法充分捕捉学习者的动态兴趣变化,从而影响推荐的准确性和系统的适应能力。

此外,数据隐私和标注噪声是影响推荐系统性能的重要因素^[82]。随着数据保护法规和隐私保护技术的发展,如何在确保数据隐私的情况下训练有效的模型,将是未来研究的关键方向。

7 性能比较

尽管当前研究在动态知识演化感知和跨场景迁移等领域有一定理论基础,但这些技术在实际应用中的验证仍然较少。为弥补这一空白,未来的研究需要在 MOOC 平台、K12 教育平台等多场景环境中进行实验对比,验证这些技术的实际应用效果。

现有的强化学习方法虽然在个性化推荐方面具有显著优势,但其“黑箱”问题和计算复杂度较高的问题依然是制约其应用的瓶颈。与此相比,基于图神经网络的推荐方法能够更好地捕捉知识之间的复杂关系,并提高推荐系统的准确性,但其训练时间较长,计算开销较大。传统的协同过滤方法虽然在数据量庞大且用户兴趣稳定的场景下表现良好,但在冷启动和动态需求适应性方面存在局限。

接下来本文将会对课程推荐、习题推荐和学习路径推荐三大类研究中的代表性方法进行比较分析。

1) 课程推荐性能比较

根据表 7 中提供的数据,可以对不同课程推荐方法在 MOOC 场景下的性能进行对比分析。评估指标包括 HR@K 和 NDCG@K,分别衡量推荐结果的准确性和排序质量,K 值分别为 5,10 和 20。

表 7 课程推荐方法性能对比

Table 7 Performance comparison of course recommendation methods

方法	HR@K			NDCG@K		
	K=5	K=10	K=20	K=5	K=10	K=20
FISM	53.12	65.89	80.50	40.63	45.13	48.82
SRL-RNN	55.89	69.36	81.91	43.24	47.59	51.06
KPCR	56.12	70.65	82.33	43.18	48.02	51.31
HRL	59.84	75.00	84.59	44.50	50.95	52.67
MCRRec	59.86	75.12	84.93	44.69	51.15	52.83
DARL	63.12	77.63	87.71	48.53	53.25	55.30
EduGraph	64.32	78.12	88.71	49.46	54.25	56.89

在 MOOC 场景下,课程推荐系统的性能在不同方法之间存在显著差异。根据表 7 中的评估结果可知,EduGraph 在 HR@K 和 NDCG@K 指标上表现最为突出,在 K 值为 5,10 和 20 时,分别取得了 64.32,78.12 和 88.71 的 HR@K 以及

¹⁾ <http://www.xuetangx.com>

²⁾ <http://moocdata.cn/data/MOCCube>

49.46, 54.25 和 56.89 的 NDCG@K 的优异成绩。这表明, EduGraph 在课程推荐的准确性和排序质量上均优于其他方法, 能够较好地捕捉课程之间的语义关联和学习者的个性化需求。

相比之下, 其他推荐方法, 如 DARL, MRCRec 和 HRL 虽然在多个评估指标中也取得了较为良好的结果, 但仍然略逊一筹。例如, DARL 在 HR@K 指标上表现不错, $K=5$ 时的值为 63.12, $K=20$ 时为 87.71, 但在 NDCG@K 指标上的表现相对较低, 说明其在推荐结果的排序质量上与本文方法还存在一定差距。FISM 则在整体表现上处于下游, 尤其是在 NDCG@K 指标上的较低分数反映出该方法在排序推荐的准确性上存在一定的不足。

综合来看, EduGraph 凭借其知识图谱的有效利用, 展现了较强的课程推荐能力, 能够在不同的 K 值下稳定提供高质量的推荐。虽然其他方法也在准确性和排序质量上取得了一定的成绩, 但从表 7 中数据来看, EduGraph 在 MOOC 推荐系统中具有明显的优势, 尤其是在处理复杂的课程关系和学习者多样化需求方面。

2) 习题推荐性能比较

在 Assist09 数据集上, 不同的习题推荐方法在 Accuracy, Novelty 和 Diversity 这 3 个评估指标上展现了不同的性能特点, 如表 8 所列。综合来看, KGEB-CF 方法在 Accuracy 上表现优异, 达到了 0.879, 表明该方法能够较为准确地预测学习者的兴趣, 并推荐相关习题。然而, 其在 Novelty 指标上的得分较低(0.524), 表明该方法在推荐过程中可能过于依赖已有的热门习题, 缺乏足够的创新性, 未能有效地引入新的或多样化的学习内容。

表 8 习题推荐方法性能对比

Table 8 Performance comparison of exercise recommendation methods

方法	ASSIST09		
	Accuracy	Novelty	Diversity
KGEB-CF	0.879	0.524	0.912
HB-DeepCF	0.823	0.914	0.758
KCP-ER	0.895	0.952	0.765
PERP	0.897	0.959	0.781
KG4EX	0.897	0.961	0.782
KG4EER	0.936	0.892	0.776
MuOER-SAN	0.925	0.972	0.816

与此相对, HB-DeepCF 方法在 Novelty 上取得了显著的提升, 得分为 0.914, 这意味着该方法能够提供更多新颖的推荐, 增强了学习者的探索性。然而, 这一优势的获得是以牺牲 Accuracy 为代价, 其 Accuracy 分数为 0.823, 相较之下较低, 这表明该方法虽然在推荐的新颖性方面表现突出, 但在准确度上仍有待提高。Diversity 指标上, HB-DeepCF 的表现也不尽如人意, 其得分为 0.758, 显示出该方法在推荐多样性方面的潜力不足, 可能导致学习者接收到的推荐结果较为集中。

其他方法中, KCP-ER 和 PERP 在 Accuracy 上表现接近, 分别为 0.895 和 0.897, 并且在 Novelty 和 Diversity 指标上均显示出较强的优势。特别是 KCP-ER 在 Novelty 上的表现尤为突出, 得分为 0.952, 表明该方法能够有效提高推荐内容的多样性和新颖性。与此同时, PERP 在 Diversity 上表现

较好, 得分为 0.781, 但其在 Novelty 上的提升相对有限(为 0.959), 显示了其在平衡新颖性和多样性方面的潜力。KG4EX 和 KG4EER 方法通过引入知识图谱, 在 Accuracy 和 Novelty 上均表现出色。尤其是 KG4EX, 其在 Novelty 上的得分达到 0.961, 表明该方法能够较好地捕捉到知识点之间的关系, 从而推荐更多新颖且有意义的习题。然而, 这两种方法在 Diversity 上的得分相对较低, 分别为 0.782 和 0.776, 显示了它们在推荐内容多样性方面的不足, 可能限制了其在一些需要多样化内容的学习场景中的应用。

最后, MuOER-SAN 方法在所有 3 个指标上均表现出色, 尤其是在 Novelty 和 Accuracy 上的平衡性较好, 分别达到了 0.972 和 0.925, 同时也在 Diversity 上展现了较强的能力, 得分为 0.816。这一结果表明, MuOER-SAN 在精准推荐和创新推荐的平衡方面具有较为突出的优势, 能够较好地满足学习者的个性化需求和多样化探索需求。

综上所述, 各方法在 Assist09 数据集上的表现存在一定差异, 显示出不同推荐系统在特定指标上的优势和局限性。MuOER-SAN 的综合表现最为优异, 能够平衡准确性、新颖性和多样性, 为习题推荐系统提供了较为全面的解决方案。然而, 其他方法, 如 KG4EX, KG4EER 和 KCP-ER, 则在某些指标上具备优势, 适用于特定的教育场景和学习需求。

3) 学习路径推荐性能比较

如表 9 所列, 在 junyi 和 ASSIST09 数据集上, 不同学习路径推荐方法的表现有所不同, 尤其在 $Step=5$, $Step=10$ 和 $Step=20$ 这几个不同的评估阶段下, 呈现出一定的性能差异。具体来说, DLPR 在两个数据集中的表现均优于其他方法, 在所有 Step 的评估中, 特别是在 ASSIST09 数据集上, 表现最为突出。在 $Step=5$, $Step=10$ 和 $Step=20$ 下, DLPR 分别取得了 0.2049, 0.3835 和 0.6124 的得分, 显示出该方法在学习路径推荐任务中具有较强的性能优势, 尤其是在长时间步($Step=20$)下, 其得分最高, 说明该方法在更复杂的学习任务中能够保持较好的性能。

与之相比, GEHRL 也表现优异, 在 junyi 和 ASSIST09 数据集中的 Step 评估中均获得了较高的得分。相比之下, CSEAL 方法在 junyi 数据集上取得了较为均衡的结果, 尤其是在 $Step=10$ 和 $Step=20$ 下表现良好。但是其在 ASSIST09 数据集上的表现相对较弱, 显示出其在某些场景下的局限性。其他方法, 如 Actor-Critic 和 CB 的表现较为稳定, 尤其是 Actor-Critic 在 junyi 数据集上的表现较好, 特别是在 $Step=10$ (0.1671) 和 $Step=20$ (0.1916) 时得分较高, 表明其能够较好地适应中长周期的推荐需求。而 KNN 和 GRU4Rec 的性能相对较弱, 尤其是在 ASSIST09 数据集上, 前者在 $Step=5$ 和 $Step=10$ 下出现了负值, 后者在所有步骤中均未能实现显著的正向提升, 表明它们在特定学习路径推荐任务中的适用性较差。

总结来看, DLPR 和 GEHRL 在这两个数据集上的表现均优于其他方法, 尤其在较长步长下, 能够有效提升学习路径推荐的质量。CSEAL 和 Actor-Critic 等方法虽然在某些场景下表现较好, 但在 ASSIST09 数据集上的效果相对较弱, 揭示了它们在不同数据集和学习场景下的适用性差异。未来的

研究可以进一步优化这些方法,以提高其在多样化学习环境中的适应能力和表现。

表9 学习路径推荐方法对比

Table 9 Comparison of learning path recommendation methods

方法	junyi			ASSIST09		
	Step=5	Step=10	Step=20	Step=5	Step=10	Step=20
KNN	-0.0902	-0.1455	0.1343	-0.0549	-0.0731	-0.0932
GRU4Rec	-0.0047	-0.0721	0.0993	-0.0536	-0.1003	-0.1344
DQN	0.0299	-0.1058	0.1536	-0.0495	-0.0934	-0.0267
ActorCritic	0.1004	0.1671	0.1916	-0.0004	-0.0327	0.0676
CB	0.0666	0.1451	0.2098	-0.0563	-0.1294	0.0038
RLTutor	-0.0007	-0.0379	-0.1034	-0.0611	-0.1096	0.0784
CSEAL	0.0975	0.2021	0.2505	0.0482	0.0637	0.1009
GEHRL	0.1198	0.2278	0.4206	0.0751	0.0918	0.1971
DLPR	0.2049	0.3835	0.6124	0.0807	0.1544	0.3283

8 挑战与未来方向

1) 动态知识演化感知

当前教育推荐系统大多依赖静态知识图谱对知识点关系进行建模,难以应对课程大纲调整、知识体系扩展等引发的概念漂移与结构演化^[105]。未来研究应探索动态知识图谱(Dynamic Knowledge Graph, DKG)与在线学习机制的深度融合,实时捕捉学习者的交互行为(如答题路径、视频观看序列)与外部知识更新(如课程内容修订),动态调整知识点间的关联权重与拓扑结构,从而提升系统对知识演化的适应能力。

2) 增强系统的跨场景泛化和迁移能力

现有推荐算法在不同教育平台、文化语境或领域任务中往往难以保持性能稳定,泛化能力受限。未来可通过引入元学习(Meta-Learning)机制提升模型对小样本、高噪声数据的鲁棒性,并结合多语言知识图谱与对比学习技术实现跨文化特征对齐与通用表示建模。同时,通过课程语义增强、多任务学习与知识蒸馏等手段,推动从源领域(如MOOC)向目标场景(如企业培训或K12教育)的策略迁移,构建具有跨域适应性的推荐生态系统。

3) 构建更智能的自适应学习策略

现有教育推荐系统缺乏对个体学习节奏、长期目标与短期反馈之间的动态权衡机制,难以提供真正个性化的干预策略。未来研究应融合强化学习中的探索-利用机制,设计可动态调整的奖励函数,综合考虑学习成效提升(如知识掌握增益)、学习负荷控制(如疲劳度)等多维指标,精细化调节推荐频次与内容难度,实现因人而异的个性化学习路径优化。

4) 结合教育理论与提升教育可用性

当前教育推荐系统高度依赖学习行为、认知状态,甚至情感交互等敏感数据,普遍面临“采集-存储-共享”全链路的隐私泄露风险^[83]。一方面,传统明文集中存储模式易成为攻击目标;另一方面,跨平台数据合作(如MOOC与中小学学籍系统对接)进一步放大泄露面,导致家长、学校及监管机构对系统采纳持谨慎态度。未来研究需将“隐私保护”与“教育可用性”同步纳入设计目标,形成“可用不可见”的推荐范式。

5) 冷启动问题与可解释性问题

冷启动问题与可解释性问题是推荐系统面临的两大核心挑战。在教育资源推荐系统中,该挑战严重影响到用户的体验。冷启动问题主要发生在新用户或新项目缺乏足够历史

数据的情况下,传统的基于协同过滤和内容过滤的方法通常难以提供准确推荐。为了应对这一挑战,研究者提出了多种方法。首先,基于内容的推荐通过分析项目的特征(如课程描述、标签等)与用户的偏好来进行推荐,虽然不依赖历史数据,但其推荐精度常常受到特征表达的限制。其次,社交网络扩展方法通过引入社交媒体数据(如朋友关系、社交活动等)来推测用户兴趣,缓解新用户冷启动问题^[25]。然而,这些方法也存在隐私问题和数据稀疏性等挑战。近年来,因果推断推荐模型成为冷启动问题的一个重要解决方案,通过基于因果推断的模型,研究者可以在缺少历史行为数据的情况下推测用户可能感兴趣的内容。例如,因果推断模型通过建立“用户-项目-行为”的因果关系图,能够从少量的数据中推断出用户潜在的偏好,进而实现精确的冷启动推荐。

在可解释性问题方面,推荐系统的“黑箱”特性使得用户难以理解推荐的依据,影响了系统的可信度和用户接受度^[103-104]。为了解决这一问题,研究者提出了几种方法。基于规则的推荐系统通过定义一组明确的规则来生成推荐,并将推荐理由直接呈现给用户,简单且易于理解。然而,这种方法缺乏灵活性,难以适应复杂的推荐场景。可视化推荐系统通过图表或交互界面展示推荐路径和决策依据,增强了透明度和用户对推荐过程的理解。例如,Tang等^[80]提出的概念地图工具ConceptGuide,通过可视化展示学习路径中各知识点的关系,帮助学习者理解推荐背后的决策过程。近年来,因果推断模型在提高推荐系统可解释性方面也取得了进展,通过建模因果关系,推荐系统能够为每个推荐提供明确的因果推理依据。例如,当推荐某个课程时,系统可以解释推荐的原因是“用户对某个先修知识点具有较强兴趣,因此推荐了与其相关的课程”。

尽管现有方法在一定程度上缓解了冷启动和可解释性问题,但仍然面临挑战。未来的研究需要进一步优化这些方法,尤其是在因果推断推荐模型的应用上,以进一步提高其在实时数据和大规模平台中的可应用性。具体来说,如何结合因果推断与其他推荐算法(如协同过滤、深度学习等),以实现更精准的冷启动推荐和更高的可解释性,仍是未来的重要研究方向。

结束语 本文系统总结了教育资源推荐系统(ERS)的工作(课程推荐、习题推荐、学习路径推荐),并且对不同类型的

教育资源推荐进行了明确的定义。在课程推荐中,图神经网络与知识图谱的融合显著提升了跨平台课程元数据的语义关联建模能力;习题推荐通过深度知识追踪与强化学习的协同优化,实现了知识点状态动态诊断与个性化习题序列生成;学习路径推荐则借助动态知识图谱与进化算法,解决了知识依赖约束与多目标优化的平衡问题。本文进一步指出,现有技术的瓶颈主要集中于静态知识表征的僵化性、模型可解释性不足以及跨文化场景适配能力有限。

未来,教育资源推荐系统(ERS)将在职业教育和 K12 教育等领域发挥重要作用。例如,在职业教育领域,ERS 可以结合学习者的职业发展需求与实际工作场景,动态推荐与职业发展相关的课程和习题,帮助学习者定制个性化的职业成长路径。在 K12 教育领域,ERS 可以根据学习者的认知发展阶段、学习进度与兴趣变化,推荐合适的学习资源和练习题,促进个性化学习的实现。此外,结合教育心理学的理论框架,未来的系统设计还可以通过情感分析和学习者反馈机制来进一步优化推荐策略,提升学习体验。

未来研究需突破动态知识图谱的实时更新机制、教育心理学理论的结构化编码,以及跨场景知识迁移技术,以构建透明、自适应、可持续演化的教育推荐生态系统。这些突破将推动 ERS 从工具性辅助向智能化教育伴侣转型,为终身学习提供核心支撑。

参考文献

- [1] URDANETA-PONTE M C, MENDEZ-ZORRILLA A, OLEA-GORDIA-RUIZ I. Recommendation systems for education: Systematic review[J]. *Electronics*, 2021, 10(14):1611.
- [2] CHIU T K F, XIA Q, ZHOU X, et al. Systematic literature review on opportunities, challenges, and future research recommendations of artificial intelligence in education[J]. *Computers and Education: Artificial Intelligence*, 2023, 4:100118.
- [3] KUNDU S S, SARKAR D, JANA P, et al. Personalization in education using recommendation system: an overview [M] // *Computational Intelligence in Digital Pedagogy*. 2020:85-111.
- [4] BENHAMDI S, BABOURI A, CHIKY R. Personalized recommender system for e-Learning environment[J]. *Education and Information Technologies*, 2017, 22:1455-1477.
- [5] YANG K, RAKOVIĆ M, LI Y, et al. Unveiling the tapestry of automated essay scoring: A comprehensive investigation of accuracy, fairness, and generalizability [C] // *Proceedings of the AAAI Conference on Artificial Intelligence*. 2024:22466-22474.
- [6] LABARTHE H, BACHELET R, BOUCHET F, et al. Increasing MOOC completion rates through social interactions: a recommendation system[C] // *EMOOCs 2016 Conference, Fourth European MOOCs Stakeholders Summit*. 2016:471-480.
- [7] ZHANG T, YUAN B. Visualizing MOOC user behaviors: A case study on XuetangX[C] // *International Conference on Intelligent Data Engineering and Automated Learning*. Cham: Springer, 2016:89-98.
- [8] WEI X, SUN S, WU D, et al. Personalized online learning resource recommendation based on artificial intelligence and educational psychology [J]. *Frontiers in psychology*, 2021, 12: 767837.
- [9] DUAN X, TAN D, FANG L, et al. Reason-and-execute prompting: Enhancing multi-modal large language models for solving geometry questions[C] // *Proceedings of the 32nd ACM International Conference on Multimedia*. 2024:6959-6968.
- [10] ALYOUSSEF I Y. Massive open online course (MOOCs) acceptance: The role of task-technology fit (TTF) for higher education sustainability[J]. *Sustainability*, 2021, 13(13):7374.
- [11] ABDELRAHMAN G, WANG Q, NUNES B. Knowledge tracing: A survey[J]. *ACM Computing Surveys*, 2023, 55(11):1-37.
- [12] ZHAO J, MAO H, MAO P, et al. Learning path planning methods based on learning path variability and ant colony optimization[J]. *Systems and Soft Computing*, 2024, 6:200091.
- [13] TAKAMI K, FLANAGAN B. Toward educational explainable recommender system: explanation generation based on Bayesian knowledge tracing parameters[C] // *International Conference on Computers in Education*. 2021.
- [14] WANG X, MA W, GUO L, et al. HGNN: Hyperedge-based graph neural network for MOOC course recommendation[J]. *Information Processing & Management*, 2022, 59(3):102938.
- [15] BI H, CHEN E, HE W, et al. BETA-CD: A Bayesian meta-learned cognitive diagnosis framework for personalized learning[C] // *Proceedings of the AAAI Conference on Artificial Intelligence*. 2023:5018-5026.
- [16] WANG F, GAO W, LIU Q, et al. A survey of models for cognitive diagnosis: New developments and future directions[J]. *arXiv*:2407.05458, 2024.
- [17] HOGAN A, BLOMQVIST E, COCHEZ M, et al. Knowledge graphs[J]. *ACM Computing Surveys*, 2021, 54(4):1-37.
- [18] CANESE L, CARDARILLI G C, DI NUNZIO L, et al. Multi-agent reinforcement learning: A review of challenges and applications[J]. *Applied Sciences*, 2021, 11(11):4948.
- [19] CAO J, FANG J, MENG Z, et al. Knowledge graph embedding: A survey from the perspective of representation spaces [J]. *ACM Computing Surveys*, 2024, 56(6):1-42.
- [20] LIU F, HU X, LIU S, et al. Meta multi-agent exercise recommendation: A game application perspective[C] // *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. 2023:1441-1452.
- [21] YU P, LIU X, CHENG H, et al. A review of online course recommendation systems[J]. *Computer Engineering and Applications*, 2023, 59(22):1-14.
- [22] JIANG L, LIU K, WANG Y, et al. Reinforced explainable knowledge concept recommendation in MOOCs [J]. *ACM Transactions on Intelligent Systems and Technology*, 2023, 14(3):1-20.
- [23] PARAMESWARAN A, VENETIS P, GARCIA-MOLINA H. Recommendation systems with complex constraints: A course recommendation perspective[J]. *ACM Transactions on Information Systems*, 2011, 29(4):1-33.
- [24] AHER S B, LOBO L. Combination of machine learning algorithms for recommendation of courses in E-Learning System based on historical data[J]. *Knowledge-Based Systems*, 2013,

- 51:1-14.
- [25] JING X, TANG J. Guess you like: course recommendation in MOOCs[C] // Proceedings of the International Conference on Web Intelligence. 2017:783-789.
- [26] CHANG P C, LIN C H, CHEN M H. A hybrid course recommendation system by integrating collaborative filtering and artificial immune systems[J]. Algorithms, 2016, 9(3):47.
- [27] ELBADRAWY A, KARYPIS G. Domain-aware grade prediction and top-n course recommendation[C] // Proceedings of the 10th ACM Conference on Recommender Systems. 2016:183-190.
- [28] VEDAVATHI N, KM A K. E-learning course recommendation based on sentiment analysis using hybrid Elman similarity[J]. Knowledge-Based Systems, 2023, 259:110086.
- [29] KABBUR S, NING X, KARYPIS G. Fism: factored item similarity models for top-n recommender systems[C] // Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2013:659-667.
- [30] JUNG H, JANG Y, KIM S, et al. KPCR: Knowledge graph enhanced personalized course recommendation[C] // Australasian Joint Conference on Artificial Intelligence. Cham: Springer, 2022:739-750.
- [31] YANG S, CAI X. Bilateral knowledge graph enhanced online course recommendation [J]. Information Systems, 2022, 107: 102000.
- [32] LI M, LI Z, HUANG C, et al. Edugraph: Learning path-based hypergraph neural networks for mooc course recommendation [J]. IEEE Transactions on Big Data, 2024, 10(6):706-719.
- [33] DENG W, ZHU P, CHEN H, et al. Knowledge-aware sequence modelling with deep learning for online course recommendation [J]. Information Processing & Management, 2023, 60(4): 103377.
- [34] SUN J, MEI S, YUAN K, et al. Prerequisite-enhanced category-aware graph neural networks for course recommendation[J]. ACM Transactions on Knowledge Discovery from Data, 2024, 18(5):1-21.
- [35] ZHANG Y, YU M, SUN J, et al. Mg-cr: factor memory network and graph neural network based personalized course recommendation[C] // International Conference on Database Systems for Advanced Applications. Cham: Springer, 2023:547-562.
- [36] YANG Y, ZHANG C, SONG X, et al. Contextualized knowledge graph embedding for explainable talent training course recommendation [J]. ACM Transactions on Information Systems, 2023, 42(2):1-27.
- [37] ZHANG J, HAO B, CHEN B, et al. Hierarchical reinforcement learning for course recommendation in MOOCs[C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2019: 435-442.
- [38] LIN Y, LIN F, ZENG W, et al. Hierarchical reinforcement learning with dynamic recurrent mechanism for course recommendation[J]. Knowledge-Based Systems, 2022, 244:108546.
- [39] WANG L, ZHANG W, HE X, et al. Supervised reinforcement learning with recurrent neural network for dynamic treatment recommendation[C] // Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2018:2447-2456.
- [40] TIAN X, LIU F. Capacity tracing-enhanced course recommendation in MOOCs[J]. IEEE Transactions on Learning Technologies, 2021, 14(3):313-321.
- [41] JIANG L, XIAO Y, ZHAO X, et al. Hierarchical reinforcement learning on multi-channel hypergraph neural network for course recommendation[C] // Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence (IJCAI-24). 2024.
- [42] LIN Y, FENG S, LIN F, et al. Adaptive course recommendation in MOOCs[J]. Knowledge-Based Systems, 2021, 224:107085.
- [43] PARDOS Z A, JIANG W. Designing for serendipity in a university course recommendation system[C] // Proceedings of the Tenth International Conference on Learning Analytics & Knowledge. 2020:350-359.
- [44] RAO S, SALOMATIN K, POLATKAN G, et al. Learning to be relevant: evolution of a course recommendation system[C] // Proceedings of the 28th ACM International Conference on Information and Knowledge Management. 2019:2625-2633.
- [45] LI S, ZHAO Y, GUO L, et al. Quantification and prediction of engagement: Applied to personalized course recommendation to reduce dropout in MOOCs[J]. Information Processing & Management, 2024, 61(1):103536.
- [46] BAN Q, WU W, HU W, et al. Knowledge-enhanced multi-task learning for course recommendation[C] // International Conference on Database Systems for Advanced Applications. Cham: Springer, 2022:85-101.
- [47] HAO P, LI Y, BAI C. Meta-relationship for course recommendation in MOOCs[J]. Multimedia Systems, 2023, 29(1):235-246.
- [48] ZHU Y, LU H, QIU P, et al. Heterogeneous teaching evaluation network based offline course recommendation with graph learning and tensor factorization[J]. Neurocomputing, 2020, 415: 84-95.
- [49] MA B, TANIGUCHI Y, KONOMI S. Course Recommendation for University Environments[C] // Proceedings of the 13th International Educational Data Mining. 2020:460-466.
- [50] WANG C, ZHU H, ZHU C, et al. Personalized employee training course recommendation with career development awareness [C] // Proceedings of the Web Conference 2020. 2020:1648-1659.
- [51] GEORGE G, LAL A M. A personalized approach to course recommendation in higher education[J]. International Journal on Semantic Web and Information Systems, 2021, 17(2):100-114.
- [52] XIONG Z, LI H, LIU Z, et al. A review of data mining in personalized education: Current trends and future prospects[J]. Frontiers of Digital Education, 2024, 1(1):26-50.
- [53] WU Z, LI M, TANG Y, et al. Exercise recommendation based on knowledge concept prediction[J]. Knowledge-Based Systems, 2020, 210:106481.
- [54] GAO W W, MA H F, ZHAO Y, et al. Enhancing personalized exercise recommendation with student and exercise portraits [J]. Journal of Electronic Science and Technology, 2024, 22(2): 100262.
- [55] HUO Y, WONG D F, NI L M, et al. Knowledge modeling via

- contextualized representations for LSTM-based personalized exercise recommendation[J]. *Information Sciences*, 2020, 523: 266-278.
- [56] AI F, CHEN Y, GUO Y, et al. Concept-aware deep knowledge tracing and exercise recommendation in an online learning system[C]//*Proceedings of the 12th International Educational Data Mining*. 2019:240-245.
- [57] GONG T, YAO X. Deep exercise recommendation model[J]. *International Journal of Modeling and Optimization*, 2019, 9(1): 18-23.
- [58] HUO Y, XIAO J, NI L M. Towards personalized learning through class contextual factors-based exercise recommendation [C]//*2018 IEEE 24th International Conference on Parallel and Distributed Systems(ICPADS)*. IEEE, 2018:85-92.
- [59] KOREN Y, RENDLE S, BELL R. Advances in collaborative filtering[M]//*Recommender Systems Handbook*. 2021:91-142.
- [60] LI Z, HU H, XIA Z, et al. Exercise recommendation method based on machine learning[C]//*2021 International Conference on Advanced Learning Technologies(ICALT)*. IEEE, 2021: 50-52.
- [61] ZHENG W, DU Q, FAN Y, et al. A personalized programming exercise recommendation algorithm based on knowledge structure tree[J]. *Journal of Intelligent & Fuzzy Systems*, 2022, 42(3):2169-2180.
- [62] GUAN Q, XIAO F, CHENG X, et al. Kg4ex: An explainable knowledge graph-based approach for exercise recommendation [C]//*Proceedings of the 32nd ACM International Conference on Information and Knowledge Management*. 2023:597-607.
- [63] ZHU M, ZHEN D, TAO R, et al. Top-N collaborative filtering recommendation algorithm based on knowledge graph embedding[C]//*International Conference on Knowledge Management in Organizations*. Cham: Springer, 2019:122-134.
- [64] CHENG X, ZHOU X, FANG L, et al. NR4DER: Neural Ranking for Diversified Exercise Recommendation[C]//*Proceedings of the 48th International ACM SIGIR Conference on Research and Development in Information Retrieval*. 2025: 1738-1747.
- [65] YAN Z, DU H, LIN Z, et al. Personalization exercise recommendation framework based on knowledge concept graph[J]. *Computer Science and Information Systems*, 2023, 20(2):857-878.
- [66] LYU P, WANG X, XU J, et al. Intelligent personalised exercise recommendation: A weighted knowledge graph-based approach [J]. *Computer Applications in Engineering Education*, 2021, 29(5):1403-1419.
- [67] GUAN Q, CHENG X, XIAO F, et al. Explainable exercise recommendation with knowledge graph[J]. *Neural Networks*, 2025, 183:106954.
- [68] LIU G, REN M, GUO L, et al. Comprehensive exercise recommendation with practicality, generalizability, and versatility in AI-driven education [J]. *Information Processing & Management*, 2025, 62(3): 104051.
- [69] WU S, WANG J, ZHANG W. Contrastive personalized exercise recommendation with reinforcement learning[J]. *IEEE Transactions on Learning Technologies*, 2023, 17:691-703.
- [70] 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.
- [71] REN Y, LIANG K, SHANG Y, et al. MuOER-SAN: 2-layer multi-objective framework for exercise recommendation with self-attention networks [J]. *Knowledge-Based Systems*, 2023, 260:110117.
- [72] THURMOND V, WAMBACH K. Understanding interactions in distance education: A review of the literature[J]. *International Journal of Instructional Technology and Distance Learning*, 2004, 1(1):9-26.
- [73] SHI D, WANG T, XING H, et al. A learning path recommendation model based on a multidimensional knowledge graph framework for e-learning[J]. *Knowledge-Based Systems*, 2020, 195: 105618.
- [74] ZHU H, TIAN F, WU K, et al. A multi-constraint learning path recommendation algorithm based on knowledge map[J]. *Knowledge-Based Systems*, 2018, 143:102-114.
- [75] ZHANG X, LIU S, WANG H. Personalized learning path recommendation for e-learning based on knowledge graph and graph convolutional network[J]. *International Journal of Software Engineering and Knowledge Engineering*, 2023, 33(1): 109-131.
- [76] CHEN H, YIN C, FAN X, et al. Learning path recommendation for MOOC platforms based on a knowledge graph[C]//*Knowledge Science, Engineering and Management: 14th International Conference, KSEM 2021*. 2021:600-611.
- [77] FIQRI M, NURJANAH D. Graph-based domain model for adaptive learning path recommendation[C]//*2017 IEEE Global Engineering Education Conference (EDUCON)*. IEEE, 2017: 375-380.
- [78] CHENG Y. A learning path recommendation method for knowledge graph of professional courses[C]//*2022 IEEE 22nd International Conference on Software Quality, Reliability, and Security Companion(QRS-C)*. IEEE, 2022:469-476.
- [79] YIN H, SUN Z, SUN Y, et al. Automatic learning path recommendation for open source projects using deep learning on knowledge graphs[C]//*2021 IEEE 45th Annual Computers, Software, and Applications Conference (COMPSAC)*. IEEE, 2021:824-833.
- [80] TANG C L, LIAO J, WANG H C, et al. Conceptguide: Supporting online video learning with concept map-based recommendation of learning path[C]//*Proceedings of the Web Conference 2021*. 2021:2757-2768.
- [81] TANG C L, LIAO J, WANG H C, et al. Supporting online video learning with concept map-based recommendation of learning path[C]//*Extended Abstracts of the 2020 CHI Conference on Human Factors in Computing Systems*. 2020:1-8.
- [82] LIU Z, CHEN B, ZHOU H, et al. Mapper: Multi-agent path planning with evolutionary reinforcement learning in mixed dynamic environments[C]//*2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2020: 11748-11754.

- [83] GUAN Q, YU Y, HUANG X, et al. Generating Privacy-preserving Educational Data Records with Diffusion Model[C]//Companion Proceedings of the ACM Web Conference 2024. 2024: 806-809.
- [84] CAI D, ZHANG Y, DAI B. Learning path recommendation based on knowledge tracing model and reinforcement learning [C]//2019 IEEE 5th International Conference on Computer and Communications(ICCC). IEEE, 2019:1881-1885.
- [85] YUN Y, DAI H, AN R, et al. Doubly constrained offline reinforcement learning for learning path recommendation [J]. Knowledge-Based Systems, 2024, 284:111242.
- [86] LI Q, XIA W, YIN L, et al. Graph enhanced hierarchical reinforcement learning for goal-oriented learning path recommendation[C]// Proceedings of the 32nd ACM International Conference on Information and Knowledge Management. 2023:1318-1327.
- [87] DWIVEDI P, KANT V, BHARADWAJ K K. Learning path recommendation based on modified variable length genetic algorithm[J]. Education and information technologies, 2018, 23:819-836.
- [88] ZHENG Y, WANG D, XU Y, et al. A Multigranularity Learning Path Recommendation Framework Based on Knowledge Graph and Improved Ant Colony Optimization Algorithm for E-Learning[J]. IEEE Transactions on Computational Social Systems, 2024, 12(2):586-607.
- [89] BIAN C L, WANG D L, LIU S Y, et al. Adaptive learning path recommendation based on graph theory and an improved immune algorithm[J]. KSII Transactions on Internet and Information Systems, 2019, 13(5):2277-2298.
- [90] NIKNAM M, THULASIRAMAN P. LPR: A bio-inspired intelligent learning path recommendation system based on meaningful learning theory[J]. Education and Information Technologies, 2020, 25(5):3797-3819.
- [91] CHANG H S, HSU H J, CHEN K T. Modeling exercise relationships in E-learning: A unified approach[C]// EDM. 2015: 532-535.
- [92] MA D, ZHU H, LIAO S, et al. Learning path recommendation with multi-behavior user modeling and cascading deep Q networks[J]. Knowledge-Based Systems, 2024, 294:111743.
- [93] ZHANG S, HUI N, ZHAI P, et al. A fine-grained and multi-context-aware learning path recommendation model over knowledge graphs for online learning communities[J]. Information Processing & Management, 2023, 60(5):103464.
- [94] HIDASI B, KARATZOGLOU A, BALTRUNAS L, et al. Session-based recommendations with recurrent neural networks [J]. arXiv:1511.06939, 2015.
- [95] MA Y, WANG L, ZHANG J, et al. A personalized learning path recommendation method incorporating multi-algorithm[J]. Applied Sciences, 2023, 13(10):5946.
- [96] RAJ N S, RENUMOL V G. An improved adaptive learning path recommendation model driven by real-time learning analytics [J]. Journal of Computers in Education, 2024, 11(1):121-148.
- [97] ZHANG H, SHEN S, XU B, et al. Item-Difficulty-Aware Learning Path Recommendation: From a Real Walking Perspective [C]//Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. 2024:4167-4178.
- [98] LIU H, LI X. Learning path combination recommendation based on the learning networks[J]. Soft Computing, 2020, 24(6):4427-4439.
- [99] CHEN X, SHEN J, XIA W, et al. Set-to-sequence ranking-based concept-aware learning path recommendation[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2023:5027-5035.
- [100] FREJ J, SHAH N, KNEZEVIC M, et al. Finding paths for explainable mooc recommendation: A learner perspective [C] // Proceedings of the 14th Learning Analytics and Knowledge Conference. 2024:426-437.
- [101] ZHANG F, FENG X, WANG Y. Personalized process-type learning path recommendation based on process mining and deep knowledge tracing [J]. Knowledge-Based Systems, 2024, 303:112431.
- [102] LUO G, GU H, DONG X, et al. HA-LPR: A highly adaptive learning path recommendation [J]. Education and Information Technologies, 2025, 30:14597-14627.
- [103] LI Y, SHAN Z, RAKOVIĆ M, et al. When AI explains in natural language: Unveiling the impact of generative AI explanations on educators' grading and feedback practices[EB/OL]. <https://doi.org/10.1007/s10639-025-13741-z>.
- [104] LI Y, RAKOVIĆ M, SRIVASTAVA N, et al. Can AI support human grading? Examining machine attention and confidence in short answer scoring[J]. Computers & Education, 2025, 228:105244.
- [105] LI L, SRIVASTAVA N, RONG J, et al. When and how biases seep in: Enhancing debiasing approaches for fair educational predictive analytics[J]. British Journal of Educational Technology, 2025, 56(6):2478-2501.



XI Penghui, born in 1996, Ph. D. His main research interests include intelligent education and graph neural network.



GUAN Quanlong, born in 1981, professor, Ph. D supervisor, is a member of CCF(No. 48326D). His main research interests include network security and intelligent education.