

基于知识图谱的高校个性化学习系统研究

李梦琳¹, 夏 巍^{2*}

¹湖北师范大学文理学院, 湖北 黄石

²湖北师范大学人工智能与计算机学院, 湖北 黄石

收稿日期: 2026年7月2日; 录用日期: 2026年8月17日; 发布日期: 2026年8月26日

摘 要

随着国家教育数字化战略持续推进, 人工智能、大数据、知识图谱等技术正在深刻改变高校教学组织方式。高校数字化学习平台虽然积累了大量课程资源和学习数据, 但仍存在资源匹配不精准、学习诊断不深入、教学工具协同不足、评价偏重结果等问题。知识图谱具有语义关联、结构化表达和知识推理能力, 能够将课程知识点、学习资源、学习任务、评价标准和学生学习行为进行系统整合。本文围绕高校个性化学习需求, 提出基于知识图谱的高校个性化学习系统框架, 从学习资源重组、课程知识建模、D-KG-AI技术基座、学习者画像、学习诊断、路径推荐、教学应用场景和数据伦理保障等方面展开分析。研究认为, 基于知识图谱的个性化学习系统能够推动高校教学从统一化、经验化向精准化、动态化和智能化转型, 为高等教育数字化改革提供新的技术路径和实践思路。同时, 本文进一步分析该系统在技术可靠性、算法偏见、数据隐私、教师技术能力和学生自主探索等方面可能面临的挑战与局限。

关键词

知识图谱, 高校教育, 个性化学习, 学习诊断, 人工智能, 教育数字化

Research on a Personalized Learning System for Higher Education Based on Knowledge Graphs

Menglin Li¹, Wei Xia^{2*}

¹College of Arts and Science of Hubei Normal University, Huangshi Hubei

²School of Artificial Intelligence and Computer Science, Hubei Normal University, Huangshi Hubei

Received: July 2, 2026; accepted: August 17, 2026; published: August 26, 2026

Abstract

With the continuous advancement of the national education digitalization strategy, technologies

*通讯作者。

文章引用: 李梦琳, 夏巍. 基于知识图谱的高校个性化学习系统研究[J]. 创新教育研究, 2026, 14(8): 424-434.

DOI: 10.12677/ces.2026.148621

such as artificial intelligence, big data, and knowledge graphs are profoundly transforming the organization of teaching in higher education. Although digital learning platforms in universities have accumulated abundant course resources and learning data, they still face several problems, including inaccurate resource matching, insufficient learning diagnosis, weak coordination among teaching tools, and an overemphasis on outcome-based evaluation. Knowledge graphs, with their capabilities of semantic association, structured representation, and knowledge reasoning, can systematically integrate course knowledge points, learning resources, learning tasks, assessment standards, and students' learning behaviors. Focusing on the needs of personalized learning in higher education, this paper proposes a knowledge graph-based framework for personalized learning systems in universities. It analyzes the system from the perspectives of learning resource reorganization, course knowledge modeling, the D-KG-AI technological foundation, learner profiling, learning diagnosis, learning path recommendation, application scenarios, and data ethics safeguards. The study argues that a knowledge graph-based personalized learning system can promote the transformation of higher education from standardized and experience-based teaching toward precise, dynamic, and intelligent teaching, providing a new technical pathway and practical approach for the digital reform of higher education. The paper also examines the challenges and limitations that may arise during implementation, including technical reliability, algorithmic bias, data privacy, teachers' digital competence, and the possible weakening of students' autonomous exploration.

Keywords

Knowledge Graph, Higher Education, Personalized Learning, Learning Diagnosis, Artificial Intelligence, Education Digitalization

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

1.1. 研究背景

近年来,教育数字化已成为我国建设教育强国的重要战略方向。国家持续推进教育数字化战略行动,强调以数字技术重塑教育资源供给方式、教学组织方式和学习支持方式,推动教育公平与教育质量同步提升。《教育强国建设规划纲要(2024—2035年)》提出,要深入实施国家教育数字化战略,促进人工智能助力教育变革[1]。在这一背景下,高等教育作为人才培养、科学研究和社会服务的重要领域,正面临从传统课堂教学向数字化、智能化、个性化教学转型的迫切任务。

人工智能技术的发展进一步推动了“人工智能 + 高等教育”的深入融合。生成式人工智能、智能推荐、学习分析、知识图谱和智能问答等技术,使高校教学不再局限于教师统一讲授、学生被动接受的单一路径,而是逐渐转向以学生为中心、以数据为基础、以智能技术为支撑的新型教学形态。高校学生的学习基础、认知能力、兴趣方向、学习节奏和发展目标具有明显差异,传统统一化、标准化教学模式难以充分满足学生差异化成长需求。因此,如何利用智能技术实现学习资源精准供给、学习过程动态诊断和学习路径个性化推荐,成为高校教学改革的重要议题[2]。

知识图谱作为人工智能领域的重要知识组织技术,能够通过实体、关系和属性构建结构化知识网络,实现知识之间的语义连接和可解释推理[3]。将知识图谱应用于高校个性化学习系统,可以突破传统学习平台以课程章节或资源目录为中心的组织方式,将知识点、资源、任务、能力目标和评价标准联系起来,为学生提供更加精准、连续和可解释的学习支持[4]。

1.2. 研究问题

当前, 高校数字化学习平台建设已取得显著进展, 大量课程资源、在线教学平台、学习管理系统和智慧教室系统被广泛应用。然而, 从实际教学效果看, 现有平台仍存在若干突出问题。

第一, 资源丰富但匹配不足。高校平台中积累了大量教材、课件、视频、案例、论文、题库和实验任务, 但这些资源多以课程、章节或文件形式存储, 缺乏对知识点、能力目标和学生需求的细粒度关联。学生面对海量资源时, 往往不知道应先学什么、重点学什么以及如何选择适合自己的资源。

第二, 数据较多但诊断不深。数字化平台可以记录学生登录次数、学习时长、作业成绩、测验结果和资源浏览记录, 但这些数据如果缺少知识结构支撑, 通常只能反映表层学习行为, 难以解释学生成绩背后的原因。例如, 学生某次测验成绩较低, 平台可以判断其“结果不好”, 但未必能够准确识别其薄弱知识点、前置知识缺陷或能力短板。

第三, 工具分散但协同不强。高校教学中常见的学习管理系统、在线课程平台、课堂互动工具、作业系统、考试系统和资源库往往相互分离, 数据标准不统一, 教学过程难以形成完整闭环。教师需要在不同平台之间切换, 学生也容易出现学习路径断裂和认知负担增加的问题。

第四, 评价偏重结果而忽视过程。传统教学评价主要依据期末考试、阶段测验和作业分数, 难以全面反映学生在学习过程中的投入程度、思维发展、协作表现和持续进步情况。随着高校人才培养目标从知识传授转向能力培养, 单一结果性评价已难以满足个性化培养要求。

1.3. 研究价值

基于知识图谱构建高校个性化学习系统, 具有重要的理论价值和实践意义。从理论层面看, 该研究将知识图谱、学习分析和人工智能推荐机制引入高校教学场景, 有助于丰富智慧教育和个性化学习理论。知识图谱不仅能够描述知识点之间的逻辑关系, 还能够将学习资源、学习任务、评价标准和学习行为纳入统一结构, 为理解学生学习过程提供新的分析框架。

从实践层面看, 基于知识图谱的个性化学习系统能够实现知识建模、学习诊断、资源推荐和智能反馈的有机融合。一方面, 系统可以帮助教师更准确地掌握学生学情, 发现学生学习困难的具体来源; 另一方面, 系统可以帮助学生获得适合自身基础和目标的学习资源与学习路径, 从而提高学习效率和学习体验。同时, 该系统还可以促进高校教学管理从经验判断转向数据驱动, 从统一教学转向精准支持, 为高校课程改革、教学评价改革和人才培养模式创新提供技术支撑。

2. 基于知识图谱的高校个性化学习系统构建逻辑

2.1. 图谱赋能高校学习资源重组

高校课程资源类型丰富, 包括教材文本、教学课件、课堂视频、案例材料、学术论文、题库资源、实验任务、项目材料和拓展阅读等。传统数字化平台通常按照课程名称、章节目录或文件类型存储资源, 这种组织方式便于资源上传和管理, 但难以满足个性化学习需求。因为学生在学习过程中真正需要的并不是简单的“资源集合”, 而是与其当前知识基础、学习目标和能力短板相匹配的学习支持。

知识图谱能够对高校学习资源进行语义标注和结构化重组。具体而言, 系统可以将课程中的核心知识点作为图谱节点, 将视频、课件、案例、题目、实验任务等资源与相应知识点建立关联, 并进一步标注资源难度、适用对象、学习目标、使用场景和评价方式。通过这种方式, 学习资源不再是孤立文件, 而是嵌入课程知识网络中的学习对象。

例如, 在“数据结构”课程中, “链表”这一知识点可以关联基础讲解视频、代码示例、课堂课件、典型习题、实验任务和综合项目; 同时, 它还可以与“指针”“数组”“栈”“队列”等知识点建立前

置、并列或应用关系。学生如果在链表实验中出现错误, 系统便可以根据图谱追溯其是否存在指针基础薄弱、动态内存理解不足或算法复杂度分析能力欠缺等问题。

因此, 知识图谱赋能学习资源重组的关键意义在于, 使资源从静态存储转向智能组织, 从统一供给转向精准匹配, 从文件管理转向知识服务。通过建立“知识点-资源-任务-评价”之间的关联关系, 系统能够为个性化学习提供更加细致、可解释和可持续的资源基础[5]。

2.2. 课程知识结构的细粒度建模

知识图谱的核心作用在于揭示知识之间的内在关系。高校课程知识具有较强的系统性和层级性, 知识点之间不仅存在章节顺序关系, 还存在前置关系、包含关系、拓展关系、应用关系和评价关系。传统课程大纲通常能够说明课程内容安排, 但对知识点之间的复杂依赖关系表达不足, 难以直接支撑智能诊断和路径推荐。

构建课程知识图谱, 首先需要对课程目标、教学大纲、教材章节、课堂内容和评价标准进行系统分析, 提取课程中的核心概念、原理、方法、技能和应用场景。其次, 需要明确不同知识点之间的关系类型。例如, “线性代数”课程中, “矩阵运算”是“线性方程组求解”的前置知识, “特征值与特征向量”又是理解“矩阵对角化”和“主成分分析”的基础。通过关系建模, 系统可以形成清晰的知识依赖网络。

课程知识结构的细粒度建模还应关注能力目标和学习任务之间的关系。高校课程不仅要求学生掌握概念和公式, 更强调分析问题、解决问题和创新应用能力。因此, 课程知识图谱应将知识点与认知层级、实践任务和评价指标相连接。例如, 某一知识点可以对应“理解概念”“完成计算”“解决案例”“开展项目设计”等不同层次任务, 从而体现知识学习到能力形成的过程。

通过细粒度课程知识建模, 系统可以明确学生学习某一知识点所需的前置基础、对应资源、训练任务和评价标准。这不仅为学生提供清晰的学习路线, 也为教师开展精准教学和分层辅导提供依据。更重要的是, 知识图谱具有较强的可解释性, 能够说明系统为什么推荐某一资源、为什么判断某一知识点薄弱以及为什么建议学生调整学习路径[6]。

2.3. D-KG-AI 技术基座的系统支撑作用

高校个性化学习系统不能只依赖单一技术, 而应形成“数据-知识-智能”融合架构, 即 D-KG-AI 技术基座。其中, D 代表数据, KG 代表知识图谱, AI 代表人工智能模型。三者分别承担数据采集、知识组织和智能决策功能, 共同支撑个性化学习系统运行。其系统支撑架构如图 1 所示。

数据层主要负责采集学生学习行为和教学过程数据, 包括学生基本信息、课程学习记录、资源访问行为、课堂互动、在线讨论、作业提交、测验成绩、实验表现和学习反馈等。数据层的价值在于为系统提供动态感知能力, 使系统能够及时了解学生学习状态和教学过程变化。

知识层以课程知识图谱为核心, 对课程知识、学习资源、教学任务和评价标准进行结构化组织。与单纯数据存储不同, 知识层强调语义关系和教育逻辑。它不仅回答“学生做了什么”, 还帮助系统理解“学生的行为与哪些知识点有关”“某一错误可能指向哪些前置知识缺陷”“某一资源适合解决哪类学习困难”。

智能层则利用人工智能模型实现学习诊断、资源推荐、路径优化和智能反馈。系统可以结合知识追踪、推荐算法、自然语言处理和生成式人工智能等方法, 对学生学习状态进行分析, 并生成个性化学习建议。需要强调的是, AI 模型不应脱离教育知识结构独立运行, 而应受到知识图谱约束和教师专业判断校正, 以提升推荐结果的准确性、可解释性和教育适切性。

D-KG-AI 技术基座的优势在于实现数据、知识和智能的闭环融合。数据层提供学习过程证据，知识层提供结构化解释框架，智能层提供个性化决策能力[7]。三者协同作用，可以增强系统的动态感知、智能分析和持续优化能力，推动高校个性化学习系统从简单信息平台升级为智能教学支持系统。

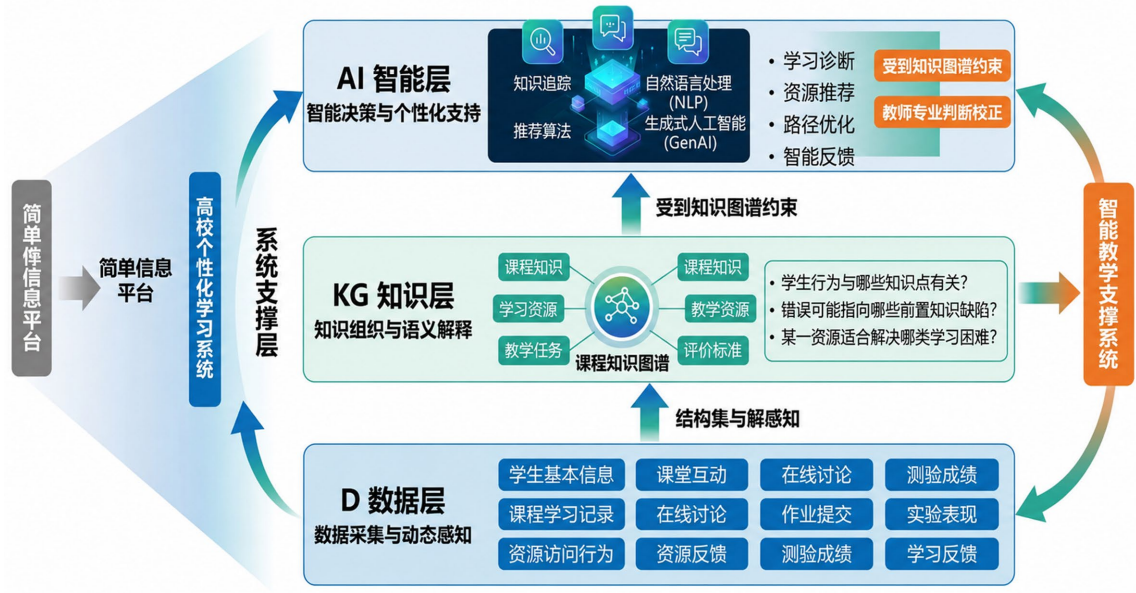


Figure 1. D-KG-AI technology base: supporting architecture of the university personalized learning system
图 1. D-KG-AI 技术基座：高校个性化学习系统支撑架构

3. 基于知识图谱的个性化学习实现机制

知识图谱的个性化学习实现机制的结构框图，如图 2 所示。




Figure 2. Architecture of the university personalized learning realization mechanism based on knowledge graph
图 2. 基于知识图谱的高校个性化学习实现机制架构

3.1. 动态学习者画像生成机制

个性化学习的前提是准确理解学习者。高校学生在知识基础、学习动机、专业兴趣、学习习惯、认知风格和发展目标方面存在明显差异,因此系统需要构建动态学习者画像,以全面描述学生的学习状态和成长需求。

动态学习者画像的数据来源应具有多元性。系统可以采集学生的基本信息、专业背景、课程成绩、学习行为、测验结果、作业表现、课堂互动、资源浏览、讨论参与、实验记录和发展目标等数据。其中,学习行为数据能够反映学生是否持续投入,测验和作业数据能够反映知识掌握情况,课堂互动和讨论数据能够反映学生参与度和思维活跃度,发展目标数据则有助于系统提供更符合学生长期成长方向的学习建议。

学习者画像应包括知识掌握水平、学习兴趣、学习偏好、学习投入度、学习风险、能力短板和成长目标等内容。例如,系统可以判断某学生在理论概念理解方面较强,但在实践应用任务中表现不足;也可以识别某学生偏好视频讲解,或更适合通过案例学习和项目任务进行知识巩固。对于学习投入不足、连续测验下降或作业延迟提交的学生,系统还可以标注学习风险并提醒教师及时干预。

需要注意的是,学习者画像不是静态标签,而是随学习过程持续更新的动态模型。学生在学习不同阶段的学习表现可能发生变化,系统应根据新的行为数据和评价结果不断修正画像,避免一次性判断造成刻板化评价。动态画像的价值不在于简单给学生分类,而在于帮助教师 and 系统持续理解学生变化,为学习诊断和路径推荐提供基础[8]。

3.2. 基于知识图谱的学习诊断机制

学习诊断是个性化学习系统的核心环节。传统学习诊断往往依据考试成绩或作业得分判断学生学习效果,但这种方式容易停留在结果层面,难以解释学生为什么出现错误、错误与哪些知识点相关以及如何补救。基于知识图谱的学习诊断机制则能够将学生学习表现与课程知识结构进行关联分析,实现从“成绩判断”向“原因诊断”的转变。

系统可以将测验题目、作业任务、实验项目和课堂问题与相应知识点进行绑定。当学生在某一题目或任务中表现不佳时,系统不仅记录其得分,还可以识别该任务涉及哪些知识点、能力要求和前置基础。例如,学生在高阶综合任务中表现较差,系统可以通过知识图谱追溯其前置知识链条,判断问题是来自核心概念理解不足、基本方法掌握不牢,还是迁移应用能力欠缺。

这种诊断机制具有较强的解释性。以“机器学习”课程为例,如果学生在模型评估任务中出现错误,系统可以追溯其是否掌握混淆矩阵、准确率、召回率、过拟合、交叉验证等相关知识点。如果发现学生在“过拟合”概念上掌握薄弱,系统就可以进一步推荐基础讲解、案例分析和针对性练习,而不是简单要求学生重复完成整章内容。

基于知识图谱的学习诊断还有助于教师精准了解学生学习困难的来源。教师可以通过班级知识掌握热力图、知识点错误分布图和学生个体诊断报告,发现共性问题 and 个体差异。对于班级普遍薄弱的知识点,教师可以在课堂上重新讲解;对于少数学生存在的问题,则可以通过个别辅导或系统推荐进行补救。由此,教学干预更加及时、精准和有依据[9]。

3.3. 个性化学习路径推荐机制

在学习者画像和知识诊断结果的基础上,系统可以为不同类型学生生成差异化学习路径。个性化学习路径推荐并不是简单地推送资源,而是根据学生当前知识状态、学习目标、能力水平和学习偏好,规划适合其发展的学习顺序、学习资源和训练任务。

对于基础薄弱学生, 系统应优先推荐基础讲解、概念梳理、典型例题和补救练习, 帮助其弥补前置知识缺陷。此类学生不宜直接进入高阶综合任务, 否则容易因认知负荷过大而产生挫败感。知识图谱可以帮助系统识别其薄弱知识链条, 并按照前置关系安排补救路径。

对于中等水平学生, 系统可以推荐巩固训练、阶段测评和应用型任务, 帮助其从知识理解走向稳定掌握。这类学生通常具备一定基础, 但知识迁移和综合应用能力仍需加强。系统可以根据其错题类型和学习表现, 推送不同难度的练习与案例, 促进其能力提升。

对于能力较强学生, 系统可以推荐拓展阅读、综合案例、研究性任务和跨学科项目, 引导其进行更高层次的探究学习。高校教学不仅要帮助学生达到课程基本要求, 还应支持优秀学生开展深度学习和创新实践。知识图谱可以将课程知识与学术论文、产业案例、科研项目和竞赛任务相连接, 为学生提供更广阔的发展空间。

同时, 个性化学习路径应具有动态调整能力。学生完成推荐任务后, 系统应根据其新的表现更新学习者画像和知识掌握状态, 并进一步调整后续推荐策略。如果学生补救效果明显, 可以逐步提高任务难度; 如果学生仍然存在理解障碍, 则应继续降低难度或更换资源类型。通过持续反馈和迭代优化, 系统能够形成“诊断-推荐-学习-评价-再推荐”的闭环机制[10]。

4. 高校个性化学习系统的应用场景与保障机制

4.1. “师-生-机”三元协同教学场景

基于知识图谱的高校个性化学习系统应贯穿课前、课中、课后三个阶段, 形成教师、学生和智能系统共同参与的“师-生-机”三元协同教学模式。该模式并不是用智能系统替代教师, 而是通过智能技术增强教师教学决策能力和学生自主学习能力。

课前阶段, 系统可以根据学生预习情况、资源浏览记录和预习测验结果生成学情报告。教师能够据此了解学生对即将学习内容的准备程度, 判断哪些前置知识需要补充, 哪些内容可以快速推进, 哪些学生需要重点关注。与传统教师依靠经验备课不同, 智能系统能够为教师提供更具体的数据支持, 使课堂教学重点更加明确。

课中阶段, 系统可以支持即时问答、课堂互动分析和分层任务推送。学生在课堂上提出的问题可以与知识图谱中的知识点关联, 系统辅助教师判断问题集中在哪些概念或方法上。对于不同学习水平的学生, 系统还可以推送不同难度的课堂练习, 使课堂教学兼顾整体进度和个体差异。教师则根据系统反馈及时调整讲解方式、案例选择和课堂节奏。

课后阶段, 系统可以提供个性化复习、作业反馈和学习计划建议。学生完成作业或测验后, 系统根据其错误情况生成知识点诊断报告, 并推荐相应复习资源和补救任务。教师可以通过系统查看班级整体掌握情况, 安排下一阶段教学内容。由此, 课前、课中、课后不再是相互割裂的教学环节, 而是通过数据和知识图谱连接起来的连续学习过程。

“师-生-机”三元协同模式的关键在于明确角色分工。教师负责教学设计、价值引导和专业判断; 学生负责主动学习、反思改进和目标规划; 智能系统负责数据分析、知识关联和个性化支持。三者协同作用, 能够提升高校教学的精准性、互动性和发展性。

4.2. 智能化教学评价与反馈机制

传统教学评价主要依赖考试成绩和作业评分, 虽然具有一定客观性和可操作性, 但难以全面反映学生学习过程。高校个性化学习系统应构建过程性、发展性和智能化评价机制, 将学习结果评价与学习过程评价结合起来。

系统可以综合学习成绩、学习行为、课堂互动、作品质量、协作表现和反思记录,生成多维度学习诊断报告。例如,某学生考试成绩较高,但课堂参与度低、合作任务表现不足,说明其学习发展并不完全均衡;另一名学生虽然初始成绩不高,但学习投入持续增加、知识掌握曲线逐步上升,也应在发展性评价中得到体现。

基于知识图谱的评价机制还可以将评价结果细化到具体知识点和能力目标。系统不仅说明学生总成绩是多少,还可以指出其在哪些知识点上掌握较好,在哪些能力目标上仍需加强。这种评价方式能够为学生提供明确改进方向,也能够帮助教师优化教学设计。

智能化反馈应强调及时性和可操作性。学生完成测验或任务后,系统应及时提供错误原因分析、相关知识点解释和后续学习建议,而不是只给出分数。对于教师而言,系统可以提供班级整体知识掌握图谱、学生风险预警和教学改进建议,帮助教师更有效地开展教学干预。

不过,AI评价结果不能完全替代教师判断。教育评价涉及学生发展、课程目标、情感态度和价值引导等复杂因素,单纯依赖算法可能造成片面化。因此,教师应对AI生成的评价结果进行审核和修正,确保评价符合教育目标和学生发展需要。智能系统应作为教师评价的辅助工具,而不是最终裁判[11]。

4.3. 数据治理与伦理保障机制

高校个性化学习系统涉及大量学生学习数据,因此必须高度重视数据治理与伦理保障。只有在安全、透明、可控的前提下,智能教育系统才能获得师生信任,并实现可持续应用。

首先,学校应明确学生数据采集边界。系统采集数据应遵循最小必要原则,只采集与教学改进和学习支持直接相关的数据,避免过度收集学生个人隐私信息。对于学习行为、成绩记录和互动数据,应提前告知学生数据用途、使用范围和保护方式。

其次,应建立数据脱敏、权限管理和安全审计机制。不同角色应拥有不同数据访问权限,教师只能查看与教学相关的学生学习数据,管理人员只能查看经过汇总和脱敏处理的数据。系统还应记录数据访问和使用过程,防止数据泄露、滥用或未经授权传播。

再次,应重视算法透明和公平问题。个性化推荐和学习诊断可能影响学生学习机会和教师评价判断,因此系统应尽可能提供可解释结果,让教师和学生理解推荐依据与诊断逻辑。如果系统长期将某些学生固定标注为“低水平”或“高风险”,可能造成标签化和自我实现效应。因此,系统应保持动态更新机制,并允许教师和学生对系统判断提出修正。

最后,应规范生成式人工智能在学习中的使用。高校既不能简单禁止AI工具,也不能放任学生过度依赖AI替代独立思考。学校应制定明确的AI使用规范,引导学生将AI作为辅助学习、资料整理和思维启发工具,而不是直接生成作业或论文的替代工具。同时,课程评价也更加关注学生的问题意识、思考过程和原创表达,维护学术诚信与教育公平[12]。

5. 系统实施面临的挑战与局限性

尽管基于知识图谱的高校个性化学习系统能够提升学习诊断和资源推荐的精准性,但其技术输出并非天然客观,也不具备脱离具体课程与组织环境的普适性。系统实施会同时受到数据质量、算法机制、平台条件、教师能力和学生使用方式的制约。因此,有必要明确系统的适用边界,将风险识别、人类监督和持续评估纳入设计与运行全过程。

5.1. 技术可靠性与系统适用边界

首先,知识图谱的质量直接决定后续诊断与推荐的可靠程度。课程概念划分不一致、实体对齐错误、

关系标注遗漏、学习行为数据稀疏或噪声过大, 都可能沿着“图谱建模-状态估计-路径推荐”的链条被放大。对于新生、新课程或新建专业, 系统还可能面临数据不足的冷启动问题, 导致学习者画像不稳定、推荐结果缺乏代表性。与此同时, 课程内容、教学要求和学生群体持续变化, 若图谱与模型不能及时更新, 就可能出现知识关系失效和模型漂移。

其次, 高校现有学习管理系统、教务系统、资源平台和实验平台的数据标准往往不一致, 跨平台接口、身份标识和数据语义难以统一。系统部署还需要持续的算力、存储、运维和安全投入, 存在建设成本较高、维护周期较长以及对特定技术供应商形成依赖等问题。因此, 平台应采用开放数据标准和模块化架构, 建立图谱版本管理、异常监测、置信度呈现、人工复核和结果回滚机制。系统给出的诊断与推荐应被视为具有不确定性的辅助判断, 而不能被直接等同于对学生能力和发展潜力的确定性结论。

5.2. 算法偏见与数据隐私风险

算法偏见是个性化学习系统面临的重要伦理风险。训练数据和历史评价结果可能包含由课程资源差异、学习机会不均、教师评分习惯以及群体样本失衡造成的结构性偏差。若系统直接依据这些数据识别“薄弱学生”或生成风险等级, 可能对部分群体产生更高的误判率, 并通过低难度任务的持续推荐限制其接触高阶学习机会, 进一步形成标签固化和自我实现效应。已有研究表明, 教育算法偏见可能出现在数据采集、特征选择、模型训练、结果解释和实际干预等多个环节[13]。因此, 高校应定期比较不同群体的推荐覆盖率、误报率、漏报率和学习收益, 开展公平性审计, 并为学生提供解释、申诉和人工纠正渠道。

数据隐私风险则贯穿数据采集、关联、存储、共享和删除的完整生命周期。学习者画像不仅包含成绩与资源访问记录, 还可能通过知识图谱的关系推断间接揭示学习困难、行为习惯、心理压力或发展倾向等敏感信息。数据一旦被超范围使用、长期保存或向第三方平台传输, 可能引发隐私泄露、用途扩张和商业化利用风险[14]。为此, 系统应遵循最小必要、知情同意、目的限定和期限管理原则, 采用去标识化、加密存储、分级授权和访问审计, 并上线前开展数据保护影响评估。学生应能够查询系统掌握的数据、了解推断依据, 并在合理范围内申请更正、撤回授权或删除相关记录。

5.3. 教师技术与组织实施条件

该系统对教师的数字胜任力提出了更高要求。教师不仅需要理解课程知识结构, 还需要具备基本的数据素养、图谱建模意识、算法结果解读能力和伦理判断能力。如果教师缺乏相关能力, 可能出现两种相反风险: 一是过度信任系统输出, 将推荐结果机械地用于分层和评价; 二是因难以理解系统逻辑而拒绝使用, 导致平台与真实教学脱节。此外, 知识点拆分、资源标注、关系审核、异常修正和推荐复核都会增加教师的前期与持续工作负担。

因此, 系统实施不能仅依靠一次性技术培训, 而应建立长期的教师发展与组织支持机制。高校可由学科教师、教育技术人员、数据工程师和伦理治理人员组成跨专业团队, 为教师提供可复用的知识图谱模板、可解释报告和现场技术支持; 同时, 应将数据治理、资源维护和系统审核计入合理工作量, 避免把新增任务完全转嫁给任课教师。不同高校在经费、基础设施和技术人员配置方面存在明显差异, 系统推广还应坚持小范围试点、分阶段评估和可持续投入, 防止形成新的数字鸿沟。

5.4. 对学生自主探索能力的潜在影响

个性化推荐虽然能够降低资源选择成本, 但过度依赖预设路径也可能削弱学生的自主探索。系统持续推送“最适合”的内容, 尽可能缩小学生接触陌生主题、跨学科资源和偶然发现的机会, 使其逐渐形

成对算法提示的依赖。若学生把系统建议视为唯一正确答案, 还可能减少主动提问、试错、比较方案和反思失败的过程。生成式人工智能带来的即时答案与文本生成能力, 也可能诱发直接复制、表层完成任务和学术诚信风险[15]。

为保护学生主体性, 平台应把推荐设计为“可解释、可选择、可退出”的学习建议, 而不是强制性路径。系统除给出推荐内容外, 还应呈现推荐依据、备选路线和可能遗漏, 使学生能够自行调整目标与顺序。课程中应保留开放探索区、学生自选任务和不依赖系统完成的实践活动, 并要求学生提交选择理由、证据比较和反思记录。随着学生能力提升, 系统应逐步减少直接提示, 转向线索、追问和自我解释要求, 使智能支持发挥支架作用而不是替代学生的判断与责任。

5.5. 研究局限与后续验证方向

本研究主要采用理论分析与框架构建方法, 尚未基于完整原型系统开展跨课程、跨专业和长期追踪的实证检验, 因此目前不能直接推断该系统对学习成绩、能力发展和教学效率的因果影响。文中提出的知识结构、画像指标和推荐机制还具有较强的课程情境依赖性, 在人文学科、工程实践课程和大规模公共基础课程中的适用程度可能存在差异。此外, 系统建设成本、教师工作量、不同学生群体的公平收益以及长期使用对学习自主性的影响, 也需要真实数据验证。

后续研究可采用多校、多学科的混合研究设计, 通过准实验或随机对照、学习日志分析、访谈和课堂观察, 综合评估学习效果、推荐公平性、隐私风险、学生自主性、教师负担、用户信任和成本效益。研究还应开展分群体误差分析和长期模型漂移监测, 并比较“完全个性化推荐”“教师审核后推荐”和“学生自主选择”等不同机制的效果。只有经过持续的技术审计、伦理评估和教育有效性验证, 系统才能从概念框架转化为可信、可控和可持续的高校教学基础设施。

6. 结论

本文围绕高校个性化学习需求, 提出了基于知识图谱的高校个性化学习系统框架。研究认为, 在国家教育数字化战略行动和“人工智能 + 高等教育”持续推进的背景下, 高校教学正从统一化、标准化向个性化、智能化转型。传统数字化学习平台虽然在资源建设和数据积累方面取得进展, 但仍存在资源匹配不足、学习诊断不深、工具协同不强和评价偏重结果等问题。知识图谱凭借其语义建模、结构化表达和可解释推理能力, 为解决上述问题提供了新的技术路径。

从系统构建逻辑看, 知识图谱能够有效整合课程知识、学习资源、学习任务和评价标准, 使学习资源从静态存储转向智能组织。通过课程知识结构的细粒度建模, 系统可以明确知识点之间的前置关系、包含关系、拓展关系、应用关系和评价关系, 为学习诊断和路径推荐提供知识基础。D-KG-AI 技术基座则进一步实现数据、知识和智能的融合, 使系统具备动态感知、智能分析和持续优化能力。

从实现机制看, 动态学习者画像是个性化学习的前提, 能够从知识掌握、学习兴趣、学习偏好、学习投入、风险预警和成长目标等方面描述学生学习状态。基于知识图谱的学习诊断机制可以将学生表现与课程知识结构关联起来, 实现从“成绩判断”到“原因诊断”的转变。个性化学习路径推荐机制则能够根据学生差异提供基础补救、巩固训练或拓展研究等不同学习路径, 并根据后续表现持续调整。

从应用场景看, 基于知识图谱的高校个性化学习系统可以贯穿课前、课中和课后, 形成“师 - 生 - 机”三元协同教学模式。系统既能够辅助教师精准掌握学情、优化教学设计, 也能够帮助学生获得及时反馈和个性化学习支持。智能化教学评价机制可以突破单一结果性评价局限, 推动评价从分数判断走向过程诊断和发展支持。同时, 系统建设必须重视数据安全、隐私保护、算法透明和学术诚信, 确保技术应用符合教育伦理和学生发展需要。

同时, 研究表明, 该系统能否有效落地不仅取决于知识图谱和算法模型的精度, 还受到数据质量、算法偏见、隐私保护、教师数字胜任力和学生自主性的共同制约。高校应建立技术审计、伦理治理、教师培训和学生选择权保障机制, 在个性化效率与教育公平、数据利用与隐私保护、智能支持与自主探索之间保持动态平衡。

未来研究可进一步结合真实高校课程数据开展实证验证, 检验该系统对学生学习效果、教师教学效率和高校教学质量提升的实际作用。同时, 还可以探索跨课程、跨专业和跨平台的知识图谱融合机制, 推动高校个性化学习系统从单门课程应用走向专业培养方案和人才成长全过程支持。总体而言, 基于知识图谱的高校个性化学习系统不仅是一种技术方案, 更是高校教学模式创新的重要支撑, 对于推动高等教育数字化、智能化和高质量发展具有重要意义。

参考文献

- [1] 中共中央 国务院印发《教育强国建设规划纲要(2024—2035年)》[EB/OL]. https://www.gov.cn/gongbao/2025/issue_11846/202502/content_7002799.html, 2025-01-19.
- [2] 教育部等九部门关于加快推进教育数字化的意见[EB/OL]. http://www.moe.gov.cn/srcsite/A01/s7048/202504/t20250416_1187476.html, 2025-04-11.
- [3] 刘峤, 李杨, 段宏, 刘瑶, 秦志光. 知识图谱构建技术综述[J]. 计算机研究与发展, 2016, 53(3): 582-600.
- [4] Hogan, A., Blomqvist, E., Cochez, M., D'amato, C., Melo, G.D., Gutierrez, C., et al. (2021) Knowledge Graphs. *ACM Computing Surveys*, **54**, 1-37. <https://doi.org/10.1145/3447772>
- [5] 高茂, 张丽萍. 融合多模态资源的教育知识图谱的内涵、技术与应用研究[J]. 计算机应用研究, 2022, 39(8): 2257-2267.
- [6] 周东岱, 董晓晓, 顾恒年. 教育领域知识图谱研究新趋向: 学科教学图谱[J]. 电化教育研究, 2024, 45(2): 91-97, 120.
- [7] Abu-Rasheed, H., Dornhöfer, M., Weber, C., Kismihók, G., Buchmann, U. and Fathi, M. (2023) Building Contextual Knowledge Graphs for Personalized Learning Recommendations Using Text Mining and Semantic Graph Completion. 2023 *IEEE International Conference on Advanced Learning Technologies (ICALT)*, Orem, 10-13 July 2023, 36-40. <https://doi.org/10.1109/icalt58122.2023.00016>
- [8] Brusilovsky, P. and Millán, E. (2007) User Models for Adaptive Hypermedia and Adaptive Educational Systems. In: Brusilovsky, P., Kobsa, A. and Nejdl, W., Eds., *The Adaptive Web*, Springer, 3-53. https://doi.org/10.1007/978-3-540-72079-9_1
- [9] Corbett, A.T. and Anderson, J.R. (1995) Knowledge Tracing: Modeling the Acquisition of Procedural Knowledge. *User Modelling and User-Adapted Interaction*, **4**, 253-278. <https://doi.org/10.1007/bf01099821>
- [10] 熊余, 任朝辉, 吴超, 蔡婷, 秦新明. 基于知识图谱的可解释学习路径推荐[J]. 现代教育技术, 2024, 34(7): 131-141.
- [11] 谢幼如, 陆怡, 彭志扬, 邱艺, 李成军. 知识图谱赋能高校课程“教-学-评”一体化的探究[J]. 中国电化教育, 2024(12): 1-7.
- [12] 江波, 丁莹雯, 魏雨昂. 教育数字化转型的核心技术引擎: 可信教育人工智能[J]. 华东师范大学学报(教育科学版), 2023, 41(3): 52-61.
- [13] Baker, R.S. and Hawn, A. (2022) Algorithmic Bias in Education. *International Journal of Artificial Intelligence in Education*, **32**, 1052-1092. <https://doi.org/10.1007/s40593-021-00285-9>
- [14] UNESCO (2023) Guidance for Generative AI in Education and Research. UNESCO.
- [15] Kasneci, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., et al. (2023) ChatGPT for Good? On Opportunities and Challenges of Large Language Models for Education. *Learning and Individual Differences*, **103**, Article ID: 102274. <https://doi.org/10.1016/j.lindif.2023.102274>