

基于 AI 问答内容的学生认知能力评价方法

邹青宇^{1,2,*}, 余水龙¹

¹ 北华大学电气与信息工程学院, 吉林吉林, 中国

² 北华大学计算机控制技术研究, 吉林吉林, 中国

【摘要】针对传统认知能力评价方法主要依赖考试成绩、问卷调查和教师观察, 难以反映学生学习过程和高阶认知能力的问题, 本文提出了一种基于 AI 问答内容的学生认知能力评价方法。该方法以学生完成教学项目过程中与 AI 的全过程交互记录为基础, 构建了包含理解能力、推理能力、批判性思维、创造力和元认知能力五个维度的认知能力评价指标体系, 通过大语言模型对学生与 AI 的多轮对话进行认知证据提取, 并结合证据驱动的评价策略生成学生认知能力画像, 实现对学生学习过程的动态评价。以关键线路识别教学项目为案例, 采集 20 名学生完成项目过程中与 AI 的全部交互记录, 对学生认知能力进行了量化评价, 并结合案例学习前后的能力增值结果对评价方法进行了验证。实验结果表明, 该方法能够有效识别学生在不同认知维度上的个体差异, 认知能力评价结果与学生学习能力增值具有较好的一致性, 能够较真实地反映学生的认知水平及学习效果。研究表明, 本文提出的方法通过学习结果评价向学习过程评价的转变, 从而为人工智能赋能教育评价、形成性评价以及个性化学习支持提供了一种新的技术路径。

【关键词】生成式人工智能; 学习过程评价; 元认知能力; 项目式学习; 教育评价

【基金项目】吉林省教育科学“十四五”规划 2024 年度课题“生成式技术驱动的高校个性化化学伴设计与应用研究”(GH24446)

1. 引言

认知能力是反映学生知识理解、逻辑推理、问题解决和创新思维水平的重要指标, 也是衡量教学质量和学习效果的重要依据。传统的学生认知能力评价主要依赖考试成绩、课堂表现、教师观察以及问卷调查等方式。这些评价方法虽然能够在一定程度上反映学生的知识掌握情况, 但大多属于结果性评价, 关注的是学习结果, 而难以全面反映学生在学习过程中的思维活动、认知发展和能力形成过程[1,2]。随着项目式学习和形成性评价的广泛应用, 教育评价逐渐由以结果导向向以过程导向的方向转变, 如何利用学习过程中产生的数据实现学生认知能力的动态评价已成为教育研究的重要方向[3]。

近年来, 以 ChatGPT、Claude、Gemini 等为代表的生成式人工智能快速发展, 并逐渐应用于智能辅导、个性化学习、课程设计和学习评价等多个教育场景[4,5]。与传统智能教学系统相比, 大语言模型具有较强的自然语言理解与生成能力, 能够与学生开展多轮对话, 在问题分析、知识解释、程序设计和学习指导等方面提供实时支持。学生在完成学习任务过程中与 AI 产生的大量连续交互数据, 不仅完整

的记录知识获取一系列过程, 还包含了更重要一些学生认知能力的信息, 如, 问题提出、推理分析、方案修正、知识迁移以及学习反思等, 为学习过程评价提供了新的数据来源[6]。

目前, 关于人工智能辅助教育评价的研究主要集中于自动阅卷、作文评分、知识掌握情况分析以及学习行为预测等方面[7-9]。部分研究利用学习日志、在线学习行为或课堂交互数据建立学习者画像, 实现学习状态分析和学习效果预测[10-11]。近年来, 也有研究尝试利用大语言模型分析学生文本或学习对话, 对学生的问题解决能力、批判性思维和学习策略进行评价[12,13]。然而, 现有研究仍存在以下不足:

(1) 多数研究仍以最终学习结果或单次作业作为评价对象, 缺乏对学生全过程学习行为的持续分析;

(2) 已有研究主要关注知识掌握程度, 对理解能力、推理能力、批判性思维、创造力以及元认知能力等高阶认知能力缺乏系统评价;

(3) 大语言模型更多作为智能教学工具, 而利用 AI 全过程交互数据开展认知能力评价的研究仍相对较少, 其评价依据和可解释性仍有待进一步完善。

针对上述问题,本文提出一种基于 AI 问答内容的学生认知能力评价方法。该方法以学生完成教学项目过程中与 AI 的全过程交互记录为评价对象,构建包含理解能力、推理能力、批判性思维、创造力和元认知能力五个维度的认知能力评价指标体系,通过大语言模型自动提取认知证据,生成学生认知能力画像,实现学生学习过程的动态评价。以《电网分析》课程中的关键线路识别教学项目为案例,对 20 名学生完成项目过程中与 AI 的全部交互数据进行分析,并结合案例学习前后的能力增值结果,对所提出方法进行了验证。实验结果表明,该方法能够有效反映学生认知能力的个体差异,其评价结果与学习能力增值具有较好的一致性,可为人工智能赋能教育评价、形成性评价以及个性化学习支持提供新的技术路径。

本文的主要贡献包括:

(1)提出了一种基于 AI 全过程问答内容的学生认知能力评价框架,实现了由学习结果评价向学习过程评价的转变;

(2)构建了包含理解能力、推理能力、批判性思维、创造力和元认知能力五个维度的认知能力评价指标体系,并利用大语言模型完成认知证据自动提取;

(3)以电网分析教学项目为案例,对所提出方法进行了实验验证,证明了认知能力评价结果与学习能力增值之间具有较好的一致性,为 AI 辅助教学中的学生能力评价提供了一种可解释、可推广的新方法。

2.材料与方法

2.1 基于 AI 全过程对话的学生认知能力评价方法

本文方法主要包括数据采集、认知证据提取、能力评价和认知画像生成四个阶段。首先,在项目实施过程中,系统自动记录学生与 AI 之间的全部交互信息,包括学生提出的问题、AI 生成的回答、学生后续追问、修改意见以及交互时间等,形成完整的人机对话日志。由于整个项目通常持续数天甚至数周,因此这些连续的交互记录能够真实反映学生认知发展的动态过程,而不仅仅是某一次回答的结果。随后,对全部对话进行语义分析和行为分析,从对话中提取能够反映学生认知活动的证据。其中,语义分析主要关注学生的问题类型、推理过程、知识迁移以及创新表达等语言特征;行为分析则重点关注学生的提问频率、追问深度、修改行为、自主探索程度以及 AI 依赖程度等学习行为特征。在此基础上,依据预先建

立的认知能力评价指标体系,对学生不同维度的认知能力进行综合评价,并最终形成学生的认知画像,为教师提供具有可解释性的学习评价结果。

2.1.1 数据采集

全过程对话数据是认知评价的基础。本文将学生完成项目期间与 AI 发生的每一次交互作为一个基本分析单元,每条记录包含以下信息:

学生提出的问题 (Question);

AI 生成的回答 (Response);

学生后续追问或反馈 (Follow-up Question);

项目所属阶段 (Project Stage);

交互时间 (Timestamp);

学生是否根据 AI 建议进行了修改 (Revision)。

与传统评价只分析最终答案不同,本文更加关注学生认知过程中的动态变化,因此整个数据集完整保留了学生从问题提出、知识获取到问题解决的全过程。

2.1.2 认知能力评价指标体系

依据教育心理学关于高阶认知能力的相关理论,本文构建了包含五个一级指标的认知能力评价体系,包括理解能力 (Understanding)、推理能力 (Reasoning)、批判性思维 (Critical Thinking)、创造力 (Creativity) 以及元认知能力 (Metacognition)。

① 理解能力 (Understanding)

理解能力主要评价学生对知识概念的理解程度及迁移应用能力。评价过程中重点关注以下几个方面:

(1) 是否主动询问基本概念;

(2) 是否要求 AI 进行实例说明;

(3) 是否能够利用自己的语言重新总结知识;

(4) 是否能够将知识迁移至新的问题情境。

上述行为反映了学生从知识获取到知识内化的全过程,因此能够较为准确地评价学生的理解水平。

② 推理能力 (Reasoning)

推理能力主要评价学生构建逻辑关系和解决问题的能力。本文主要分析学生在对话中的推理链长度、逻辑一致性以及推理方式。

其中,推理链长度用于衡量学生完成问题分析所经历的逻辑层次;逻辑一致性用于评价前后推理是否存在矛盾;推理方式则包括演绎推理、归纳推理、类比推理、因果推理以及反

事实推理等不同类型。

通过上述指标,可以全面评价学生解决复杂问题时的逻辑思维能力。

③ 批判性思维 (Critical Thinking)

批判性思维强调学生对 AI 回答保持理性质疑和独立判断,而不是被动接受 AI 生成内容。本文主要考察学生是否表现出以下行为:

- (1) 主动质疑 AI 回答的正确性;
- (2) 要求提供理论依据或参考文献;
- (3) 提出反例验证 AI 观点;
- (4) 比较不同解决方案的优劣;
- (5) 主动发现 AI 回答中的错误或逻辑漏洞。

上述行为均能够反映学生是否具有独立思考能力以及信息甄别能力。

④ 创造力 (Creativity)

创造力主要评价学生提出创新观点和解决方案的能力。评价指标包括:

- (1) 提出新的问题或新的研究思路;
- (2) 跨领域知识融合能力;
- (3) 方案优化能力;
- (4) 开放性探索能力;
- (5) 原创性解决方案设计能力。

相较于简单重复 AI 回答,上述行为更能体现学生自主创新能力。

⑤ 元认知能力 (Metacognition)

元认知能力反映学生对自身学习过程的监控与调节能力。本文主要评价学生是否能够:

- (1) 主动发现自身理解错误;
- (2) 根据学习效果调整学习策略;
- (3) 不断修正已有方案;
- (4) 完成学习总结与反思;
- (5) 形成自主学习闭环。

元认知能力能够反映学生持续学习能力,也是高水平学习者的重要特征

2.1.3 认知证据提取

为了提高评价结果的客观性与可解释性,

本文采用"认知证据提取—能力评分"两阶段评价策略。

第一阶段利用大语言模型对全过程对话进行分析,从学生交互内容中自动识别能够体现各项认知能力的关键证据,并建立认知证据集合。例如,学生主动要求验证 AI 结论可作为批判性思维证据;学生主动总结知识可作为理解能力证据;学生提出新的解决方案则可作为创造力证据。通过证据提取,可以保证后续评分具有明确依据,提高评价结果的可解释性。

2.1.4 认知能力综合评价

在获得认知证据之后,依据各维度评价规则计算学生在不同认知能力上的得分,并形成综合评价结果。设学生五项认知能力评分分别为:

$$U, R, C, I, M$$

分别表示理解能力、推理能力、批判性思维、创造力和元认知能力,则学生总体认知能力评分可表示为:

$$S = w_1 U + w_2 R + w_3 C + w_4 I + w_5 M \quad (1)$$

其中, w_i 为各能力维度的权重,满足

$$\sum_{i=1}^5 w_i = 1. \quad (2)$$

2.1.5 电网分析教学案例

该案例分为构建电力网络图模型、图模型基本属性分析、关键线路识别三个部分,每一个部分都需要学生与 AI 沟通,在 AI 的辅助下完成。

① 构建电力网络图模型

根据电力网络工程图抽象出合适的节点和链接,将电力网络表达为图模型,并将图模型以稀疏矩阵的数据结构进行存储。电力网络即可以抽象为无权无向图,也可以抽象为有向图和权值图。不同的图模型关键线路的识别算法不同。以 IEEE 标准 118 节点电网算例进行分析,图 1 为算例电气示意图,将母线作为节点,母线间的连接线路作为边,构建了 IEEE 30 节点算例的网络模型,如图 2 所示。




图 1.IEEE 标准 118 节点算例网络




图 2.IEEE-118 节点电网数学模型

②图模型基本属性分析

对抽象出的电网图模型基本拓扑结构属性进行分析，包括节点数量、边数量、度值、介数值、接近度、聚类系数等属性的计算,如表 1 所示。学生需根据各自的图模型特征修改程序参数，准确计算相关属性。

表 1.IEEE 118 节点算例网络拓扑结构特征

网络结构属性	数量值
节点数量	118
边数量	179
密度	0.026
度均值	3.033
节点介数均值	0.466
平均接近度	0.163
全局聚类系数	0.165

③关键线路识别

设计电网图模型关键线路识别算法，该算法能够识别出对电网影响最大的线路。该方法面向有向带权的电力网络，旨在通过网络科学指标识别关键节点与传输路径。它首先根据节点的加权入度与出度评估其在网络中的控制力与影响力，从中筛选高权重节点作为关键候选。接着，提取这些节点之间的连接关系，构建关键子图，并计算其中边的介数中心性，以挖掘在功率传输路径中具有“枢纽”作用的关键线路。该方法不仅考虑了方向性和权重特征，还具备良好的可视化能力，有助于支持电网结构分析、教学演示与智能调度策略设计。

2.2 基于度分布的关键节点识别

度是复杂网络中节点的一个重要的结构属性。节点的度是与该节点直接相连接的所有其他节点的数量，在定向复杂网络中，节点的度分为出度和入度两种，出度是指从这个节点直接指向其他节点的连接数量，而入度是指从其他节点直接指向该节点的数量。也就是说，在邻接矩阵为 $A(n \times n)$ 的网络中，如果存在一条由节点 i 指向节点 j 的边则 $A_{ij}=1$ ，那么节点的出度 k_{out} 和入度 k_{in} 分别为：

$$k_i^{out} = \sum_{j=1}^n A_{ij} \tag{3}$$

$$k_{j-1}^{in} = \sum_{j=1}^n A_{ij} \tag{4}$$

如表 1 所示

关键节点（度前 23）：[69, 65, 68, 49, 80, 100, 17, 37, 89, 5, 25, 64, 77, 59, 92, 30, 61, 66, 12, 15, 70, 75, 85]

2.3 基于介数中心性的关键边识别

介数是评价节点在网络中传递信息能力的物理量，定义为某个节点/边作为网络中路径节点/边的频率。从理论讲，介数越大的节点或边，得到的信息就越多，那么其对这个网络的稳定性影响就越大，因此在复杂网络中介数越大的节点或边就更加重要。

边介数 $C_B(e)$ 定义为

$$C_B(e) = \sum_{i \neq j} \frac{\sigma_{ij(e)}}{\sigma_{ij}} \tag{5}$$

式中， σ_{ij} 为节点 i 与节点 j 之间最短路径的数量， $\sigma_{ij(e)}$ 为节点 i 与 j 之间所有通过边 e 的最短路径的数量。

将计算得到的边介数值从高到低排序，识别出边介数显著高的边集合，这些被视为关键传输线路或网络脆弱边。可进一步结合边容量（如电网中变压器容量、输电线载流量）以及实际数据（如负荷流量、历史故障记录），综合判断这些边在电网中的结构重要性与业务重要性。如表 2 所示。

表 2.关键传输线路与边介数

关键传输路线	边介数
(69,77)	0.0910
(49,69)	0.0892
(77, 80)	0.0548
(85, 89)	0.0316
(65, 68)	0.0233

识别出的关键线路如图 3 所示。图中，黄色的节点为关键节点，红色的线路为关键线路。




图 3.关键线路识别结果

3.结果与讨论

3.1 学生认知能力评价

为了验证本文提出的基于 AI 全过程对话

的学生认知能力评价方法的有效性,本文选取"电网关键线路识别"教学案例作为实验对象,共采集20名学生在完成整个项目过程中与AI的全部交互记录。系统自动保存了学生提出的问题、AI回答内容、学生追问、修改过程及交互时间等信息,并依据本文建立的认知能力评价指标体系,对学生的理解能力、推理能力、批判性思维、创造力以及元认知能力进行了综合评价。




图4.认知能力量化评价结果

图4给出了20名学生五个认知维度的评价结果。从整体结果可以看出,不同学生在五项认知能力上的表现具有较大的个体差异。其中,大多数学生在理解能力和推理能力方面得分相对较高,说明学生能够借助AI较好地理解电网图模型构建、网络拓扑分析以及关键线路识别等相关知识,并能够依据AI提供的信息逐步完成问题求解过程。

相比之下,批判性思维和创造力两个维度的评分离散程度较大。部分学生在与AI交互过程中主要表现为直接接受AI生成结果,缺少进一步验证、比较和质疑,因此批判性思维得分相对较低;而部分学生能够主动提出新的解决思路,对AI生成方案进行修改和优化,甚至尝试采用不同算法进行比较,因此创造力评价得分明显较高。

元认知能力的评价结果表明,不同学生在学习策略调整方面存在明显差异。一些学生能够根据AI反馈不断修正自己的程序设计方案,并主动总结错误原因,形成较完整的问题解决闭环;而部分学生则倾向于重复询问相似问题,表现出较高度度的AI依赖,其元认知能力评价相对较低。

上述结果说明,本文提出的方法不仅能够评价学生知识掌握情况,而且能够进一步揭示学生学习过程中的思维特点,为教师提供传统考试无法获得的学习过程信息。

进一步分析学生全过程对话发现,不同认知能力对应着不同的人机交互模式。例如,高理解能力学生通常表现出"概念理解—实例验

证—知识迁移"的连续学习过程;高推理能力学生能够形成较长的逻辑推理链;高批判性思维学生更倾向于要求AI提供依据、验证结论以及比较不同算法;而高创造力学生则能够提出新的模型构建方法或优化方案。这说明本文提出的认知证据提取方法能够有效捕获学生在学习过程中的不同认知行为,为后续认知能力评价提供可靠依据。

3.2 案例学习后能力增值分析

为了进一步验证本文提出认知能力评价方法的有效性,我们采用学生自评方式对案例学习前后的能力变化进行调查。评价内容包括数学建模能力、算法思维与实现能力、跨学科整合能力以及自主学习与反思能力四个方面,每项能力采用5分制进行评价。




图5.能力增值结果

图5展示了学生完成案例学习前后的能力变化情况。结果表明,四项能力均呈现不同程度的提升。其中,算法思维与实现能力提升最为明显。这主要是因为学生需要在AI辅助下完成电网图模型建立、网络属性分析以及关键线路识别算法设计,在不断调试程序和验证结果的过程中,加深了对图算法及复杂网络分析方法的理

解。数学建模能力也获得了较明显提升。在案例学习过程中,学生需要将实际电网结构抽象为复杂网络模型,并根据具体问题选择不同类型的图结构进行表示。这一过程促进了学生从工程问题向数学模型转换能力的发展,提高了其建模意识。

跨学科整合能力同样得到改善。该案例涉及电力系统、图论、复杂网络分析以及Python程序设计等多个学科知识,学生需要综合运用不同领域知识完成项目任务。在与AI持续交互过程中,学生不断建立不同知识之间的联系,增强了跨学科知识融合能力。

此外,自主学习与反思能力也表现出明显提升。AI能够为学生提供实时反馈,使学生能够及时发现程序错误、修正建模思路,并不断优化解决方案。这种持续"提问—反馈—修

改—验证"的学习模式，有助于形成完整的自主学习闭环，提高学生的学习主动性。

3.3 认知能力评价结果与学习能力增值的一致性分析

为了进一步验证本文提出的认知能力评价方法的有效性，本文将学生全过程 AI 交互得到的认知能力综合评价结果，与案例学习后的能力增值结果进行了对比分析。认知能力评价采用本文提出的方法计算得到学生的综合认知能力得分，而学习能力增值则采用学生完成案例学习前后的能力变化值进行表示，包括数学建模能力、算法思维与实现能力、跨学科整合能力以及自主学习与反思能力四个维度，各维度能力增值取学习后评分减去学习前评分。

为了进一步验证这种一致性，可采用 Pearson 相关系数对认知能力综合得分与学习能力平均增值进行相关性分析，其计算公式如下：

$$r = \frac{\sum_{i=1}^n (C_i - \bar{C})(G_i - \bar{G})}{\sqrt{\sum_{i=1}^n (C_i - \bar{C})^2} \sqrt{\sum_{i=1}^n (G_i - \bar{G})^2}} \quad (6)$$

其中， C_i 表示第*i*名学生的综合认知能力得分， G_i 表示对应的学习能力增值， n 为学生人数。当相关系数 r 接近 1 时，说明两者具有较强的正相关关系，即认知能力评价结果能够较好地预测学生的学习效果；当 r 接近 0 时，则说明两者相关性较弱。

图 6 给出了 20 名学生认知能力综合得分与学习能力平均增值之间的关系。从整体趋势可以看出，两者呈现出较明显的正相关关系。认知能力评价得分较高的学生，其案例学习后的能力提升幅度普遍较大；而认知能力评价较低的学生，其学习能力增值相对较小。这说明学生在 AI 辅助学习过程中表现出的理解能力、推理能力、批判性思维、创造力以及元认知能力，与最终学习效果之间具有较强的一致性。

实验结果表明，认知能力综合评价与学习能力增值之间具有较好的相关性（图 6），说明基于 AI 全过程对话所提取的认知证据能够较真实地反映学生在项目学习中的认知水平。相比传统考试主要评价学习结果，本文方法更加关注学生解决问题过程中的认知表现，因此不仅能够反映学生当前的知识掌握情况，还能够预测学生在项目学习中的成长潜力。

进一步分析发现，认知能力得分较高的学生通常具有以下共同特征：能够主动向 AI 提出具有探索性的问题；在获得 AI 回答后能够继续追问并验证结果；能够根据 AI 反馈不断

修改程序和优化模型；在项目完成后能够主动总结学习过程并反思存在的问题。这些行为正是高阶认知能力的重要表现，也是学生获得较大学习能力提升的重要原因。




图 6.一致性分析

综上所述，认知能力评价结果与案例学习能力增值之间表现出较好的一致性，验证了本文提出方法的有效性和可靠性。该方法能够利用学生与 AI 的全过程交互数据实现学习过程评价，为项目式教学中的学生能力评估提供了一种客观、可解释且具有预测能力的新方法。

4.结论

本文针对评价学生的认知能力时，传统手段主要依赖考试成绩、问卷调查和教师观察等方式存在难以反映学习过程、评价维度单一以及主观性较强等问题，提出了一种基于 AI 全过程问答内容的学生认知能力评价方法。该方法以学生完成项目过程中与 AI 的全部交互记录为基础，通过采集全过程对话数据，构建包含理解能力、推理能力、批判性思维、创造力和元认知能力五个维度的认知能力评价指标体系，利用大语言模型提取认知证据，并形成学生认知能力画像，实现了对学生学习过程的动态评价。

以关键线路识别教学案例为实验对象，对 20 名学生的 AI 全过程交互数据进行了分析。实验结果表明，本文方法能够有效识别学生在不同认知维度上的个体差异，较全面地反映学生在知识理解、问题推理、创新思维以及自主学习等方面的认知特点。同时，教学案例实施后的能力增值分析表明，学生在数学建模能力、算法思维与实现能力、跨学科整合能力以及自主学习与反思能力等方面均获得了明显提升。进一步将认知能力评价结果与学习能力增值进行对比分析发现，两者具有较好的一致性，认知能力评价较高的学生通常表现出更大的学习能力提升幅度，说明本文提出的评价方法能够较真实地反映学生的认知水平，并具有一

定的学习效果预测能力。

与传统结果导向的评价方式相比,本文方法充分利用学生与 AI 交互过程中产生的大量过程数据,实现了由学习结果评价向学习过程评价的转变,不仅能够输出学生综合认知能力评分,还能够提供具有可解释性的认知证据和认知画像,为教师开展形成性评价、精准教学和个性化学习指导提供了新的技术手段。

未来研究将进一步扩大实验样本规模,结合不同课程和不同专业开展跨场景验证,并引入多智能体协同评价、知识图谱和学习行为分析等技术,提高认知能力评价的稳定性、客观性和泛化能力。同时,将进一步研究认知能力的发展轨迹及其与学习成效之间的关系,为人工智能赋能教育评价提供更加完善的方法体系。

参考文献

- [1] Bloom B S. Taxonomy of Educational Objectives: The Classification of Educational Goals[M]. New York: Longmans, Green., 1956
- [2] Black P, Wiliam D. Assessment and Classroom Learning[J]. Assessment in Education, 1998, 5(1): 7-74.
- [3] Pellegrino J W. Assessment as a Positive Influence on 21st Century Teaching and Learning[J]. Educational Testing Service, 2014.
- [4] Kasneci E, et al. ChatGPT for Good? On Opportunities and Challenges of Large Language Models for Education[J]. Learning and Individual Differences, 2023, 103: 102274.
- [5] Zawacki-Richter O, Marín V I, Bond M, et al. Systematic Review of Research on Artificial Intelligence Applications in Higher Education[J]. International Journal of Educational Technology in Higher Education, 2019, 16: 39.
- [6] Rudolph, J, Tan S, Tan S. ChatGPT: Bullshit spewer or the end of traditional assessments?[J]. Journal of Applied Learning and Teaching, 2023, 6(1): 1-19.
- [7] Luckin R, Holmes W, Griffiths M, et al. Intelligence Unleashed: An Argument for AI in Education[M]. Pearson, 2016.
- [8] Holmes W, Bialik M, Fadel C. Artificial Intelligence in Education: Promises and Implications for Teaching and Learning[M]. Center for Curriculum Redesign, 2019.
- [9] Baker R S, Inventado P. Educational Data Mining and Learning Analytics[M]. Springer, 2014.
- [10] Siemens G, Long P. Penetrating the Fog: Analytics in Learning and Education[J]. EDUCAUSE Review, 2011.
- [11] Romero C, Ventura S. Educational Data Mining: A Review of the State of the Art[J]. IEEE Transactions on Systems, Man, and Cybernetics, 2010.
- [12] Yan L, et al. Practical and Ethical Challenges of Large Language Models in Education[J]. Computers and Education: Artificial Intelligence, 2024.
- [13] Shuting Z. Chatgpt Assisted Teachers in Improving Formative Assessment[J]. Journal of Education Humanities and Social Sciences, 2024, 40: 27-32.