大语言模型赋能OBE人工智能导论课程教学设计*

郑华 文成**

广州软件学院软件与人工智能学院，广州 510990 西安电子科技大学广州研究院，广州 510555

摘 要 针对大语言模型进入人工智能导论课堂后课程目标、学习任务与评价证据难以保持一致，以及学生真实贡献和风险意识难以识别的问题，本文以 OBE 与建构性对齐为理论基础，借鉴教育设计研究的设计逻辑，构建证据导向的教学设计方案。围绕“目标如何可观察化、任务如何生成可核验的学习证据、评价如何区分人机协同中的真实达成”三个问题，提出“目标对齐—智能支架—证据评价—反馈改进”的课程设计框架。该框架借助 ABCD 方法将课程目标表述为可观察、可评价的学习成果，并据此设计表现性任务和达成判据；以分层实验、案例研讨、知识库问答和综合项目组织学习；以提示词版本、资料来源、模型输出、人工核验、实验日志、答辩追问和反思记录构成多源证据链；依据多源评价证据开展目标达成分析，并支持后续教学调整。本文的贡献在于将大语言模型从单纯的内容更新或作业工具，重新定位为服务目标对齐、过程留痕与风险治理的学习支架，并给出可供后续实证检验的数据采集与分析方案。

关键字 大语言模型；OBE；建构性对齐；人工智能导论；过程性评价；教学设计

An Evidence-Oriented OBE Design for Introduction to Artificial Intelligence with Large Language Models

Hua Zheng

School of Software and Artificial Intelligence,
Guangzhou University of Software,
Guangzhou 510990, China;
zhengh@mail.gzus.edu.cn

Cheng Wen

Guangzhou Institute of Technology,
Xidian University,
Guangzhou 510555, China
wencheng@xidian.edu.cn

Abstract—The integration of large language models (LLMs) into introductory artificial intelligence courses challenges the alignment of course outcomes, learning tasks, and assessment evidence, while making students' genuine contributions and risk awareness more difficult to identify. Grounded in outcome-based education (OBE) and constructive alignment, and drawing on educational design research, this paper proposes an evidence-oriented instructional design. It addresses three questions: how to formulate observable learning outcomes, generate verifiable evidence through learning tasks, and assess genuine attainment in human–AI collaboration. Accordingly, a four-component framework is developed, comprising outcome alignment, intelligent scaffolding, evidence-based assessment, and feedback-driven improvement. The ABCD method is used to formulate observable and assessable outcomes and to guide the design of performance tasks and attainment criteria. Learning is organized through layered experiments, case discussions, knowledge-base question answering, and comprehensive projects. A multi-source evidence chain integrates prompt versions, information sources, model outputs, human verification, experiment logs, oral defenses, and reflection records to support outcome assessment and instructional improvement. The main contribution is to reposition LLMs from content or assignment tools to learning scaffolds for outcome alignment, process traceability, and risk governance, while providing a data collection and analysis scheme for subsequent empirical validation.

Keywords—Large language models, Outcome-based education, Constructive alignment, Introduction to Artificial Intelligence, Process assessment, Course design

1 引 言

大语言模型正在改变学生获取资料、解释概念、编写代码和组织表达的方式，也使课程评价面临“成果可生成、过程难辨识”的新挑战。国际组织和相关研究均提示，生成式人工智能在教育中的使用应同时关注学习支持、事实核验、数据与隐私、偏见以及学术诚信等问题[1-4]。因此，人工智能导论课程的改革不

*基金资助：本文得到国家自然科学基金（62302375）资助

**通讯作者：文成 wencheng@xidian.edu.cn。

能仅增加模型原理或工具演示，更需要重建目标、活动、评价和风险治理之间的可追溯关系。

人工智能导论承担基础认知、算法思维、实践训练与伦理启蒙的任务。现有研究已从案例驱动、多元实践、学习动机与大模型辅助教学等角度提出有益探索[5-8]，但高质量教改研究通常还应说明改革解决的具体学习问题、理论依据、设计要素、证据来源和验证路径。相较于这一要求，当前相关课程改革中仍常见目标表述笼统、任务与评价脱节、AI 使用留痕不足、仅凭最终作品判断学习效果等问题。

为回应上述不足，本文以 OBE 理论[9]和建构性对齐理论[10]为基础，并借鉴教育设计研究强调“理论主张—设计要素—课堂证据”相互验证的思路[11]，提出三个研究问题：**RQ1**，如何将人工智能导论课程目标转化为可观察、可评价的学习成果？**RQ2**，如何设计大语言模型参与的学习任务，使学生形成可核验的人机协同过程证据？**RQ3**，如何构建兼顾学习达成、真实贡献与风险治理的过程性评价闭环？本文的贡献是提出一套可实施、可审计、可后续验证的课程设计框架，而非预先宣称未经证实的教学效果。

2 理论基础与研究设计

2．1 OBE 与建构性对齐的设计要求

人工智能导论具有基础性、交叉性和前沿性，内容应服务于学生理解智能系统、选择适当方法、完成小型应用并评估技术影响。课程设计不应按算法或热点简单罗列，而应以毕业要求、课程定位和学时约束为边界，将内容、活动和评价组织为能够支持学习成果达成的整体。

依据 RQ1，课程目标可归纳为四类：解释人工智能核心概念、典型方法与应用场景；围绕给定问题选择算法或模型工具并完成实验分析；规范使用大语言模型开展学习、编程、调研和结果核验；识别幻觉、偏见、隐私、版权与学术诚信风险。每类目标均需进一步写明学习者、可观察行为、完成条件和表现程度。

课程设计遵循三项原则：其一，目标—活动—评价一致，任何任务均应能回溯到具体目标与达成判据；其二，人机协同可追溯，学生应保留提示词、资料来源、模型输出、人工取舍与验证过程；其三，风险治理嵌入任务，数据合法性、隐私保护、事实核验和学术诚信不是附加说明，而是评价对象。

如图 1 所示，ABCD 目标表述方法[12]从学习者（Audience）、行为（Behavior）、条件（Condition）和表现程度（Degree）四个方面细化学习目标，有助于将抽象能力转化为可观察、可评价的学习表现，并在设计之初明确评价标准。大语言模型可辅助检查目标表述和生成任务样例，但课程团队仍应依据学生基础、资源条件与课程定位进行人工审核，避免以工具建议替代专业判断。



图 1 基于 ABCD 要素的 OBE 课程目标表述示意图

通过 ABCD 目标表述，可将“了解提示词工程”改写为“在给定应用场景和资料来源条件下，设计提示词并核验模型输出，形成含证据说明的解决方案”。这一改写使课程目标能够与任务产出、评价量规和后续改进建立明确对应关系。

2．2 研究问题与证据导向设计框架

围绕 RQ1—RQ3，本文构建“目标对齐—智能支架—证据评价—反馈改进”框架。目标对齐以毕业要求和课程定位为起点，明确成果、任务和评价的对应关系；智能支架以分层案例、解释、诊断与方案比较支持学习；证据评价以过程留痕、作品核验和答辩追问识别真实达成；反馈改进依据目标达成情况和多源评价证据调整课程内容、任务与评价量规。该逻辑与建构性对齐和教育设计研究强调的理论—设计—证据关系相一致[10-11]。

在学习活动中，大语言模型作为辅助性学习支架，可用于生成练习变式、解释概念、定位错误、比较方案和整理过程记录，但不能替代教师的目标判断、学生的事实核验与最终评价。任何模型输出进入作业、报告或项目之前，都应留下来源、版本、验证和人工修改的证据。表 1 呈现了核心问题、设计回应及可检验证据，作为课程实施和后续实证研究的共同依据。

表 1 OBE 人工智能导论课程的证据导向教学设计框架

核心问题	设计回应	可检验证据
目标表述宽泛、活动与评价脱节	以ABCD细化目标，建立目标—任务—判据映射	课程目标、任务单、评分量规与映射表
模型支持易遮蔽学生真实理解	设置分层任务、过程留痕和现场追问	提示词版本、模型输出、人工修改、答辩记录
风险治理与持续改进不足	将事实核验、数据合规和失败案例纳入评价	核验记录、风险说明、反思日志与改进台账

该框架将课程目标、学习活动、大模型使用过程和评价反馈纳入统一的证据链，使模型介入能够回溯到具体学习成果，并受到证据要求和风险边界的共同约束。其关注重点不是模型使用频率，而是模型介入能否形成可核验、可追溯的学习证据。

3 学习成果导向的课程内容与学习支架设计

3．1 面向学习成果的课程内容组织

在 OBE 框架下，课程内容的取舍依据不是技术的新旧，而是其对预期学习成果的支撑程度。搜索与优化支撑问题建模和策略比较，知识表示支撑检索增强与知识库任务，机器学习与神经网络支撑模型训练和评价，生成式人工智能与智能体则支撑前沿应用和责任治理相关学习成果。由此，传统内容和大模型专题不再形成简单的新旧分层，而按照学习成果重新建立关联。

围绕预期学习成果，课程基础内容可归纳为三个主要模块：一是问题表示与求解，包括状态空间、启发式搜索、约束满足和优化方法；二是数据驱动与模型学习，包括机器学习、深度学习、训练验证和评价指标；三是智能系统与社会影响，包括智能体、生成式 AI、可信安全和伦理治理。

通过上述安排，学生能够在使用大语言模型时保持必要的原理意识。例如，理解搜索和优化有助于比较模型生成规划与传统启发式策略，理解概率和评估有助于判断输出可信度，理解知识表示有助于认识检索增强生成的优势与局限。

3．2 大语言模型介入点与学习支架

在课程内容层面，大语言模型既是需要理解的前沿对象，也是可受约束使用的学习支架。课程可将 Transformer、预训练、对齐、检索增强生成、工具调用、多模态交互和智能体工作流嵌入经典模块，并同步讨论其能力边界、错误模式与社会影响。

这些专题不宜以热点堆叠方式进入课堂，而应与基础模块相互嵌入：工具调用可联系搜索与智能体，检索增强可联系知识表示和信息检索，模型评估可联系机器学习实验，多模态模型可联系视觉与自然语言处理，AI 治理可联系课程思政和工程伦理。

在学习支持层面，模型可提供分层解释、案例迁移、错误定位和方案比较，但必须设置可核验的使用边界：学生提交的不是模型回答本身，而是包含提示词版本、资料来源、输出核验、人工修改和失败案例分析的学习档案。该要求与人本、可信和负责任使用生成式人工智能的原则一致[1,13]。

3．3 大语言模型专题的知识体系嵌入

为避免将大语言模型相关内容作为附加专题简单叠加，课程按照不同内容对学习成果的支撑作用重新组织教学内容。搜索、优化、机器学习等基础方法承担原理支撑功能，生成式人工智能、检索增强、智能体和多模态内容用于拓展应用情境，可信、安全与伦理治理要求则贯穿知识学习和实践任务全过程。通过这种组织方式，传统内容、大模型专题与责任治理能够围绕具体学习成果形成关联。

表 2 课程内容单元与大语言模型介入方式

课程模块	前沿专题融入	能力培养目标
人工智能概论与智能体	引入大语言模型智能体、工具调用和人机协同工作流	形成智能系统观
搜索、优化与问题求解	比较传统启发式策略、模型生成规划和提示优化案例	提升问题建模与策略比较能力
知识表示与自然语言处理	融入检索增强生成、知识库问答、提示词设计和事实核验	培养知识组织与输出核验能力
机器学习与深度学习	结合Transformer、预训练、对齐、多模态学习和模型评估	提升算法理解和实验分析能力
生成式AI伦理与治理	讨论幻觉、偏见、隐私、版权、诚信和安全对齐案例	强化责任意识与风险识别能力

课程内容不再以知识点覆盖为唯一组织依据，而以可评价学习成果作为教学单元的组织核心。每个单元同时明确所需概念、模型介入方式、学生应提交的过程证据以及相应的风险检查要求，从而建立内容学习与成果判定之间的对应关系。

上述设计明确了学习成果与课程内容及大语言模型专题之间的衔接关系。在此基础上，还需要进一步回答大语言模型参与学习任务时，学生的学习过程如何形成可核验的证据，即 RQ2 所关注的问题。

4 人机协同学习的可核验证据设计

RQ2 关注的核心不是“学生是否使用大语言模型”，而是“学生能否借助工具完成可解释、可核验的问题解决”。因此，实践任务应以表现性成果为载体，并同时要求提交过程证据。课程可按基础实验、案例研讨、知识库问答和综合项目递进组织，在任务设计中同步考虑学习目标、工具边界、任务产出与证据要求，并在后续评价环节明确相应判据。

如图 2 所示，实践任务设计以课程目标为起点，将评价要求前置，再组织案例、工具、协作和展示活动，使每项任务都对应明确产出。

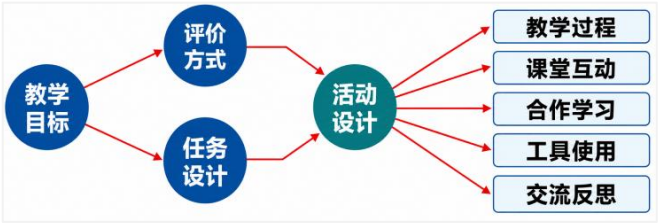


图 2 OBE 导向的实践任务组织路径

4．1 实验任务中的过程证据

在搜索、优化、机器学习和模型评价等基础单元中，学生通过可运行实验检验相关概念与算法，并对实验现象、参数变化和错误原因作出解释。大语言模型可以参与代码解释、报错定位和参数调试，但其建议必须经过学生验证并保留相应记录。

概念诊断用于发现基础理解偏差。教师可借助模型生成概念辨析题、案例判断题和反例构造题，学生则需说明判断依据。例如，比较广度优先搜索、A*算法和模型生成规划在路径问题中的差异，或解释过拟合、欠拟合和数据泄漏的实验表现。

该类任务的评价重点由“会运行”转向“能解释、能核验、能修正”。教师可通过过程记录和现场追问识别学生是否理解实验机制，并将模型建议转化为经过验证的个人判断。

4．2 开放任务中的核验与修订证据

案例研讨连接理论与应用。课程可围绕智能客服、校园知识助手、交通预测、图像分类和智能数据分析等场景，引导学生明确问题背景、数据来源、方法选择、评价指标和应用边界。案例不追求复杂系统，而强调学生能说明为什么选择某种算法或模型工具。

课程知识库问答适合展示大语言模型与人工智能基础知识的衔接。学生以小组形式围绕课程资料或指定文档构建小型知识库，完成资料清洗、文本切分、向量检索、提示模板设计、回答生成和事实核验。除呈现成功结果外，还应报告检索失败、回答偏差、归因分析和改进记录。

在案例与知识库任务中，教师应明确数据合法性、隐私保护、引用标注和输出核验要求。学生需要保留检索失败、回答偏差和改进记录，使人机协同过程可解释。

4．3 综合任务中的证据链组织

综合项目以完整的问题解决过程为组织单位，成果既可以表现为轻量级智能应用，也可以形成基于数据和证据的分析报告。选题可涉及课程问答、检索增强资料服务、实验数据分析、多模态理解和校园服务智能体等场景。

展示环节不以成果演示为终点，学生还需解释问题如何界定、方案为何如此选择、大语言模型在哪些环节参与、结果经过何种验证，并说明失败情形、人工修订和仍然存在的局限。表 3 据此概括任务及其证据要求。

表 3 大语言模型赋能的实践任务设计

任务模块	主要学习活动	组织方式	核心证据
基础实验与概念诊断	完成小型实验并解释现象、订正错因	个人完成	代码、测试、结果解释、错因订正
案例研讨与模型核验	选择方法并核验模型输出与资料来源	小组研讨	案例报告、来源清单、人工判断
课程知识库问答	构建检索问答流程并分析失败案例	小组合作	知识库文档、问答样例、失败归因
综合项目与课堂展示	完成问题定义、验证、展示与答辩	小组合作	项目报告、AI 使用说明、答辩记录

通过上述设计，课程实践从知识复现转向目标牵引下的问题解决。学生在完成任务的同时积累实验记录、模型交互、结果核验和展示反馈，为后续评价提供依据。这些过程记录不作为独立的达成证据，而需与实验结果、资料核验和现场答辩相互印证，以提高学习证据的可信度。

5 面向真实达成的评价与风险治理

RQ3 旨在解决大语言模型环境下“最终成果无法单独代表学生能力”的评价效度问题。课程应将课堂诊断、基础实验、AI 协作记录、综合项目、口头答辩和反思档案共同纳入评价，以多源证据而非单一文本或代码判断学习成果。

5．1 学习成果真实性判别

如表 4 所示，评价不按单一作业成果判断学生表现，而是从不同来源的学习证据中识别其概念理解、方法运用、人机协同、综合问题解决以及表达反思等方面的达成情况。评价设计应同时明确评价主体、证据来源、判据和反馈用途；对可能由模型直接生成的内容，应增加过程留痕、交叉核验与答辩追问。

评价材料不只包括结果文件，还包括问题分析、提示词版本、资料来源、模型回答、人工核验、实验日志和反思报告。教师据此判断学生是否理解任务、如何判断输出可信、哪些地方存在风险以及如何继续完善。

表 4 面向真实学习达成的多源证据评价设计

评价环节	评价主体	关键证据与判据	反馈用途
课堂诊断	教师	概念测验、案例判断与理由说明；概念判断准确、理由能够对应课程原理	发现共性误区并调整教学
基础实验	教师	算法实现、测试与过程记录；结果可复现，能够解释主要实验现象与错误原因	评价方法应用与错误修正
AI协作记录	教师	提示词、来源、模型输出与人工修改；关键结论有核验依据，能够说明模型贡献与人工判断	识别工具边界和真实贡献
综合项目	教师	问题定义、技术路线、验证与风险说明；方案与问题匹配，实验结果有证据支持并能说明主要局限	评价综合问题解决能力
课堂报告与反馈	教师+学生	展示答辩、互评与反思记录；表达逻辑清晰，能够回应追问并根据反馈说明改进方向	促进表达、追问与持续反馈

5．2 多源证据的综合判定

对综合项目的判断以问题解决链条是否完整为中心，而不以作品规模或呈现形式作为主要依据。教师重点考察问题界定、目标对应、方案选择、模型介入、实验验证、结果解释与伦理风险说明之间是否形成一致且可核验的证据关系。

具体而言，问题定义应说明应用场景、数据来源和评价指标；技术路线应说明算法、检索增强或智能体方案的选择理由；AI 协作应说明提示词迭代、输出核验和人工贡献；结果解释应呈现可复现性、失败案例和改进依据。

通过答辩追问，教师可以区分模型生成内容与学生真实理解，避免评价停留在文本完整度或界面效果上。

5．3 模型使用边界与责任治理

大语言模型进入课程评价后，必须配套 AI 使用规范。学生应说明使用的模型或工具、版本和具体用途，标注引用或改写内容，说明外部资料的核验情况，并保存代码、图表和报告的人工修改依据。涉及个人信息、受限数据或外部平台时，应遵循隐私保护、数据治理和授权使用等相关要求[1,13]。

课堂展示同时承担同伴审阅和教师核验两项功能。学生依据目标匹配、技术选择、证据充分性、表达清晰度和风险意识等方面对其他小组提供反馈；教师则通过现场追问重点核查实验结果是否可信、模型使用边界是否清楚，以及项目结论能否得到已有证据支持。

评价不把最终作品直接等同于学习成果，而是综合问题解释、模型交互记录、独立核验、现场追问和反思修订等证据，判断学生是否真正达到预定学习目标。不同证据之间能否相互印证，构成判断人机协同条件下真实学习达成的重要依据。

6 课程实施方案、研究验证与持续改进

6．1 实施流程与边界条件

课程实施可采用“课前目标导学—课中问题驱动—课后证据沉淀—阶段反馈改进”的流程。教师在实施前公布目标、任务、允许和禁止的 AI 使用方式以及评价量规；实施中组织案例、实验和同伴讨论；实施后收集学习档案并依据目标达成情况调整后续教学。模型选择、访问方式、版本、提示规范和数据处理规则应在课程开始前明确。

如图 3 所示，闭环实施遵循“逆向设计、正向实施、反馈改进”的逻辑：先明确学习成果和评价要求，再组织学习活动与过程评价，最后依据达成情况改进内容、任务和量规。

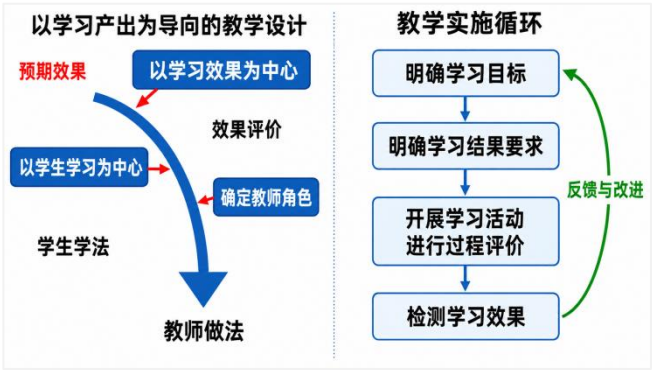


图 3 OBE 导向的课程实施与持续改进闭环

大语言模型的使用宜分阶段推进：初期用于目标诊断、概念解释和示例生成；中期用于案例分析、代码调试、资料检索和结果比较；后期用于项目论证、报告修改、证据整理和答辩准备。每一阶段均应设置人工复核与禁止性边界，例如不得将未经核验的生成内容直接作为结论，不得将敏感数据输入外部平台。

6．2 证据采集与分析方案

为进一步检验上述教学设计的可行性与有效性，后续实施应至少报告课程对象、样本规模、学时与教学情境、模型与工具版本、数据来源、评分量规、教师角色和实施周期。建议同时采集目标达成数据、过程档案、答辩记录、学生反思与访谈材料；定量部分报告前后测或对照比较、效应量和缺失值处理，定性部分报告编码框架、双人编码一致性及与量化结果的三角互证。相关学习档案、模型交互记录和访谈材料

用于教学研究时，应明确数据用途，并做好知情说明、匿名化处理与访问控制。

实施中需要特别警惕新奇效应、教师干预差异、学生数字能力差异、工具版本变化和样本自选择等威胁。若尚无可比课程或基线数据，应将研究表述限定为课程设计与可行性探索，而不应将学生满意度、作品质量或个别案例直接解释为教学因果效果。

持续改进可聚焦三方面：完善 AI 使用边界、示范案例与失败案例库；细化“目标—任务—证据—判据”量规并检验其评分一致性；以课程运行数据识别薄弱目标和高风险环节，迭代预习材料、任务难度、教师支持和项目约束。

7 结束语

本文提出了大语言模型赋能 OBE 人工智能导论课程的证据导向教学设计：以目标对齐界定学习成果，以智能支架支持分层任务，以过程档案、核验记录与答辩追问识别真实达成，并依据目标达成情况支持课程持续改进。相较于将大语言模型视为新增知识点或作业工具的做法，该设计强调工具使用必须服务于可观察目标、可核验证据和负责任治理。需要说明的是，本文目前提供的是课程设计框架和验证方案，尚未报告真实课堂的比较数据、量规信效度或学习成效因果证据。后续研究应在明确教学情境和伦理要求的前提下开展多轮实施与混合方法验证。

参 考 文 献

[1] UNESCO. Guidance for generative AI in education and research[R/OL]. 2023[2026-05-28]. https://www.unesco.org/en/articles/guidance-generative-ai-education-and-research.

[2] Kasneci E, Sessler K, Küchemann S, et al. ChatGPT for good? On opportunities and challenges of large language models for education[J]. Learning and Individual Differences, 2023, 103: 102274. DOI:10.1016/j.lindif.2023.102274.

[3] Tlili A, Shehata B, Adarkwah M A, et al. What if the devil is my guardian angel: ChatGPT as a case study of using chatbots in education[J]. Smart Learning Environments, 2023, 10(1): 15. DOI:10.1186/s40561-023-00237-x.

[4] Meyer J G, Urbanowicz R J, Martin P C N, et al. ChatGPT and large language models in academia: opportunities and challenges[J]. BioData Mining, 2023, 16: 20. DOI:10.1186/s13040-023-00339-9.

[5] 朱艳,李香菊,朱林,等.基于 OBE 与案例驱动的人工智能课程教学改革研究[J].软件导刊,2024,23(11):206-211.

[6] 许莹,钟雄虎,周旭,等.面向学生能力培养的人工智能课程多元实践教学体系[J].计算机教育,2021(11):77-79.

[7] 李国庆,辛宇,严迪群,等.基于 ARCS 动机模型的人工智能导论课程教学设计[J].计算机教育,2025(08):145-149.

[8] 王兆静,胡新荣,李丽,等.大语言模型辅助下数据挖掘类课程教学内容与模式改革研究[J].计算机教育,2025(11):74-79.

[9] Spady W G. Outcome-based education: Critical issues and answers[M]. American Association of School Administrators, 1994.

[10] Biggs J. Enhancing teaching through constructive alignment[J]. Higher Education, 1996, 32(3): 347-364. DOI:10.1007/BF00138871.

[11] The Design-Based Research Collective. Design-based research: An emerging paradigm for educational inquiry[J]. Educational Researcher, 2003, 32(1): 5-8. DOI:10.3102/0013189X032001005.

[12] Heinich R, Molenda M, Russell J D, Smaldino S E. Instructional Media and Technologies for Learning[M]. 5th ed. Englewood Cliffs, NJ: Merrill, 1996.

[13] Tabassi E. Artificial Intelligence Risk Management Framework (AI RMF 1.0)[R]. Gaithersburg: National Institute of Standards and Technology, 2023. DOI:10.6028/NIST.AI.100-1.