

面向公平的个性化支持：基于学习分析探索生成式 AI 赋能自我调节学习的人机协同路径

Towards Equity-Focused Personalization: A Learning Analytics Perspective on Human-AI Collaboration for Self-Regulated Learning with Generative AI

肖可欣¹, 许修玲², 彭萧宜³

¹²³北京师范大学未来教育学院

xkxin0217@163.com

【摘要】 随着GenAI与自我调节学习（SRL）的发展，如何借助GenAI实现个性化支持成为焦点。基于学习分析视角，本研究梳理GenAI支持SRL的理论与应用，反思其个性化实践中的公平性挑战。研究表明，GenAI可促进认知、元认知与动机调节，但其效果受学习者特征影响，算法偏见可能固化差距、削弱能动性。为此，本文构建面向公平的人机协同框架，提出可操作的系统原型、含交互、成效、能动与情感公平四维度的评估指标，及教师作为“公平调节者”的角色模型。未来应融合多模态学习分析与可解释AI，服务所有学习者的公平发展。

【关键词】 生成式人工智能；自我调节学习；学习分析；个性化学习；教育公平

Abstract: With the development of Generative AI (GenAI) and Self-Regulated Learning (SRL), leveraging GenAI for personalized support has become a research focus. From a learning analytics perspective, this study reviews the theory and applications of GenAI-supported SRL and reflects on equity challenges in personalized practice. Research shows that GenAI can promote cognitive, metacognitive, and motivational regulation, yet its effects are influenced by learner characteristics, and algorithmic bias may reinforce disparities and undermine agency. To address these issues, this study constructs an equity-focused human-AI collaboration framework, proposing an actionable system prototype, a four-dimensional evaluation framework encompassing interaction, outcome, agency, and affective equity, and a teacher role model as “equity mediators”. Future efforts should integrate multimodal learning analytics with explainable AI to serve the equitable development of all learners.

Keywords: generative AI, self-regulated learning, learning analytics, personalized learning, educational equity

1. 背景与意义

自我调节学习（SRL）强调学习者通过目标设定、策略运用、过程监控和结果反思来掌控自己的学习，其核心机制依赖于元认知监控与调节过程（Flavell, 1979），是“学会学习”的核心能力。在信息化教育背景下，利用人工智能促进个性化学习已成为明确政策导向。人工智能在教育中的应用经历了从规则驱动到数据驱动的演变过程（Roll & Wylie, 2016）。生成式人工智能（如 ChatGPT）的突破性在于其强大的“理解-生成-互动”能力，为动态、对话式的学习支持提供了可能。是追问“对谁有效、在何种条件下有效、以及其潜在的社会伦理影响为何”。这要求我们超越工具有效性讨论，深入至个性化支持的微观机制、学习者特征的差异影响，以及其中蕴含的公平性议题。因此，本文旨在系统探讨：GenAI 如何能在学习分析的理论支持与方法支持下，实现真正以学习者为中心、兼具效能与公平的 SRL 赋能。

2. GenAI 赋能 SRL 的理论基础、应用场景与学习分析视角

理论基础与学习者建模

现有研究主要基于社会认知理论、元认知理论与自我决定理论来构建 GenAI 支持 SRL 的模型。然而，要实现有效的个性化，必须对学习者特征进行动态识别与建模。这恰是学习分析的关键贡献。学习分析（Learning Analytics）关注通过数据分析理解与优化学习过程（Siemens & Baker, 2012）。学习分析通过整合多源数据构建动态的“学习者画像”，其核心价值在于将 SRL 理论中的抽象构念转化为可测量的指标体系，从而为个性化干预提供实证基础。然而，已有研究也指出，学习分析在实际教育情境中的转化影响仍然有限，存在从研究到实践落地的断层问题（Dawson et al., 2019）。其核心价值在于将 SRL 理论中的抽象构念转化为可测量的指标体系，从而为个性化干预提供实证基础。本研究基于 Zimmerman 的 SRL 三阶段模型（Forethought-Performance-Reflection），并结合公平性视角，提出了面向人机协同场景的学习者画像指标体系（见表 1）。该体系从三个维度刻画学习者特征：

（1）认知与元认知维度：通过分析学生与 GenAI 的对话文本（如提问类型、追问深度）和交互日志（如代码运行次数、调试行为），识别其元认知策略的运用水平。具体指标包括：策略性提问占比（如“为什么这段代码会报错”vs“如何修改这个错误”）、问题分解行为（是否主动将复杂任务拆解为子问题）、自我监控频次（如运行代码后是否主动检查输出）。

（2）动机与情感维度：通过分析对话中的情感表达（如语气、情绪词）、交互时长与求助频率的变化趋势，推断其动机状态和情感投入。这一过程可以从自我决定理论的视角理解，即学习者的自主性、能力感与关系感需求在与 GenAI 互动中得到不同程度的满足，从而影响其学习动机（Deci & Ryan, 2000）。这一关系受到需求满足的中介作用（Xia et al., 2023）。具体指标包括：求助主动性（主动向 GenAI 提问的次数 vs 被动接受提示）、任务坚持度（面对错误时是否持续尝试）、情绪波动指数（通过文本情感分析识别学习过程中的挫败感或信心变化）。

（3）行为与策略维度：通过分析操作序列（如点击流、代码修改轨迹），刻画其学习策略的选择与调整模式。具体指标包括：策略多样性（在规划、执行、调试等环节使用的策略种类）、策略切换效率（从错误到修正的时间间隔）、资源利用模式（对 GenAI 提供的不同类型支架（如问题分解提示、错误解释）的调用频率）。

这一指标体系的设计不仅回应了学习分析领域对“细粒度建模”的呼吁（Baker & Inventado, 2014），也为后续公平性评估提供了可量化的基础——例如，通过对比不同学习特征群体（如语言背景、能力起点）在上述指标上的分布差异，可以识别潜在的算法偏见或支持效能的异质性。

教育应用场景中的个性化实践与潜在差异

个性化教育的实践与挑战，在不同教育阶段呈现出鲜明差异。

在中小学阶段，实践侧重于基础能力培养与适应性互动。GenAI 的应用强调“具象化、互动化”，例如在数学教学中生成动画情境题，或在语文阅读中提供多角度提问清单。此阶段，学习分析的核心价值在于，通过记录学生与 AI 互动的时长、尝试次数、求助频率等行为轨迹，帮助教师精准识别哪些学生在“任务规划”或“反思”环节存在困难，从而提供更具针对性的线下干预，最终实现人机协同的分层支持。

进入高等教育阶段，重心转向高阶能力发展与批判性思维引导。GenAI 通常用于辅助学术写作框架梳理或复杂编程任务拆解，其带来的个性化挑战也更为深刻。学习分析可以追踪学生从接受 AI 建议到自主修改的迭代过程，借此评估其高阶自我调节学习策略（如综合评估、自我调试）的发展轨迹。然而，研究也警示我们，元认知能力强的学生更能从开放性提示中受益，而能力较弱者则可能因信息过载而效率低下（Fan et al., 2024, preprint）。可能导致学习效果的分化，形成不同的学习参与模式（Kizilcec et al., 2013），这凸显了“一刀切”式的 AI 交互可能潜藏并加剧教育不平等。

在课外自主探究场景中，GenAI 则扮演着“全天候学习伙伴”的角色，核心目标是促进学习者能动性培养。在此，学习分析的延伸价值得以显现：通过分析学生在自主探究中提出的问

题质量、使用的资源类型及反思深度，可以评估其课外自我调节学习的真实质量。这些分析结果为设计那些鼓励深度探索而非简单索取答案的 AI 提示语提供了关键依据，其根本宗旨在于增强而非替代学习者的内在求知能动性。

面向公平的人机协同框架：系统原型与核心机制

设计原则与理论依据

本框架以“人机协同”为核心设计原则（Molenaar, 2022），即在保留学习者主体地位的前提下，由 GenAI 提供情境化的策略支持。设计基于 Zimmerman（2000）的 SRL 三阶段模型（Forethought-Performance-Reflection），并融合可解释 AI（XAI）与开放学习者模型（Open Learner Model, OLM）技术：XAI 使 AI 的推荐透明化，OLM 赋予学习者审视、修正自身学习模型的权利（Bull & Kay, 2016），从技术层面回应算法偏见与能动性侵蚀的关切。

系统原型架构与核心模块

系统原型采用分层架构，包含三个核心模块：

（1）数据采集层：捕捉学习过程的细粒度特征，包括交互日志（提问时间、代码运行记录）、对话文本（完整交互内容）、行为痕迹（代码修改历史）。这些数据为后续分析提供原始材料。

（2）学习分析与建模层：将原始数据转化为学习者画像与动态状态。依据第 2.1 节提出的指标体系，运用自然语言处理（NLP）量化“策略性提问占比”，运用序列挖掘分析“策略切换效率”。同时，通过时序模型（如隐马尔可夫模型）实时识别学生所处的 SRL 阶段（规划、执行、监控、反思），这一过程涉及认知与元认知的协同调节（Winne, 2018）。该层内置公平性审计引擎，定期计算不同学生群体（如不同语言背景、能力起点）在各指标上的差异，并向教师端发出潜在偏见预警。

（3）动态干预与反馈层：以 GenAI 聊天机器人为核心，根据学习者画像与动态状态提供差异化支架。其核心机制是“因材施教”：对元认知能力较弱的学生：不直接给答案，生成引导性问题（如“你想用这个变量做什么？在代码中需要在哪里定义它？”）；对元认知能力较强的学生：提供开放性挑战或反事实推理（如“如果改变算法逻辑，结果会如何？”）这种差异化支持旨在为不同起点的学习者提供与其能力匹配的认知支架，从技术层面预防“马太效应”的加剧。

核心议题与公平性影响评估框架

个性化、学习者特征与公平性的张力

GenAI 在赋能 SRL 的过程中，个性化承诺与教育公平目标之间存在着内在张力，主要体现在三个方面：

（1）算法偏见：GenAI 模型可能隐含文化、语言或认知风格上的偏见，导致优势群体受益更多，弱势群体被边缘化，形成“马太效应”（Tsai et al., 2020）。

（2）能动性侵蚀：若 GenAI 过度主导或直接提供答案，可能削弱学习者的目标设定、策略尝试和持久思考的意愿，尤其对元认知技能初阶的学习者影响更为显著。

（3）数据伦理困境：学习过程数据的采集与使用涉及隐私、透明度与数据所有权问题，缺乏规范可能导致技术异化为“数据监控”，衍生新的数字鸿沟。

上述挑战表明，仅仅论证 GenAI 的“有效性”是不够的，必须追问“对谁有效、在何种条件下有效”。

公平性影响评估框架：方法与指标

本框架通过对比不同学习者群体（如语言背景、能力起点、性别）在关键指标上的表现差异，识别潜在的算法偏见或不公平效应。评估涵盖四个维度：

（1）交互公平性：关注不同群体在使用 GenAI 过程中的交互质量是否存在差异。具体指标包括对话轮次、响应时间、建议采纳率与追问深度。数据来源于系统交互日志，采用方差

分析(ANOVA)比较各组均值差异。若某群体建议采纳率显著低于其他群体,则提示可能存在交互层面的偏见。

(2) 成效公平性:关注不同群体在学习效果上的差异是否被 AI 系统缩小或放大。具体指标包括学习增益(前后测差值)、知识保留率与任务完成率。数据来源于前后测成绩与平台完成数据,采用异质性处理效应模型估计 AI 支持对不同子群体的因果效应差异。若低起点学生的学习增益显著低于高起点学生,则表明系统可能加剧了原有差距。

(3) 能动性公平性:关注 AI 是否侵蚀了特定群体的学习主体性。具体指标包括策略性提问占比(区分“如何做”与“为何这样做”的提问)、原创内容比例与自主决策频率(主动调试 vs 被动求助)。数据来源于对话文本与操作序列,采用文本分析与序列模式挖掘进行量化。若某群体的策略性提问占比在使用 AI 后显著下降,则提示过度依赖风险。

(4) 情感与态度公平性:关注 AI 使用对不同群体心理体验的影响。具体指标包括自我效能感变化、技术接受度、焦虑水平与满意度。数据来源于问卷、访谈与情感计算,采用重复测量方差分析比较各组变化轨迹。若某群体的自我效能感在 AI 介入后不升反降,或焦虑水平显著上升,则提示系统设计存在情感层面的不公平。

未来方向:构建公平、透明、赋能的人机协同生态

教师角色:从知识传授者到公平调节者

在 GenAI 支持 SRL 的学习环境中,教师需承担“公平调节者”的新角色,教师需具备基本的 AI 素养,包括理解 AI 机制、解读数据结果与评估技术影响的能力(Ng et al.,2024)。这要求教师具备四种 AI 素养:(1) 数据解读能力:理解学习分析指标,识别风险信号;(2) AI 洞察能力:识别 GenAI 输出的潜在偏见;(3) 差异化干预能力:根据学生分组采取不同教学策略;(4) 伦理反思能力:评估 AI 应用对特定群体的影响。人机协同决策遵循“识别—判断—干预—反馈”闭环,确保教师在技术赋能中发挥核心调节作用。

未来研究方向

基于本研究的理论框架与评估体系,未来研究可从以下方向深入:

(1) 发展可解释且可审计的 GenAI-SRL 系统:整合可解释 AI 技术,使 AI 反馈透明可理解。同时建立公平性影响评估机制,定期审计系统对不同群体(如性别、语言背景、能力起点)的支持效果,确保个性化无偏见。

(2) 倡导参与式设计与学习者数据主权:鼓励学习者参与模型构建,让学生能够审视、修正甚至贡献于自己的学习者模型,将个性化从“系统对用户的单向适配”转变为“用户与系统协同建构”。

(3) 强化教师作为公平“关键词调节者”的角色:提升教师解读学习分析仪表盘、理解 AI 建议局限、进行差异化引导的能力。专业发展应聚焦培养教师利用“人机协同”数据进行公平教学决策的技能。

(4) 深化跨学科合作与批判理论视角:融合教育学、学习科学、人工智能、伦理学以及批判性数据研究视角,共同审视技术应用背后的权力结构与社会正义问题,确保技术进步服务于教育普惠的根本目标。

结语

本研究从学习分析视角出发,提出了一套面向公平的人机协同框架——包括可操作的系统原型、可测量的评估指标、可落地的教师角色模型。我们期待未来研究在实证验证、跨文化比较、纵向追踪等方向上继续推进,让技术真正服务于所有学习者的主体性成长与公平发展。

参考文献

- 倪闽景.从学习进化的视角看ChatGPT/生成式人工智能对学习的影响.华东师范大学学报(教育科学版),2023,41(7):151-161
- 唐赫.生成式人工智能教育应用的伦理风险及法治规避路径[J].法学,2023,11(6):6390-

6395.

余晖, & 朱俊华. (2023). 算法时代嵌入技术变革的教育权力关系重构. *教育研究*, 44(11), 29-41.

张鹏, 汪旻, & 尚俊杰. (2024). 生成式人工智能与教育变革: 价值、困难与策略. *现代教育技术*, 34(6), 14-24.

朱俊华, 许璐瑶, & 马近远. (2025). 生成式人工智能如何赋能学生学习——基于大学生自我调节学习行为的实证研究. *高等工程教育研究*(2), 66-72.

Baker, R. S., & Inventado, P. S. (2014). Educational data mining and learning analytics. In *Learning analytics* (pp. 61-75). Springer. https://doi.org/10.1007/978-1-4614-8823-8_4

Bull, S., & Kay, J. (2016). SMILI ©: A framework for interfaces to learning data in open learner models, learning analytics and related fields. *International Journal of Artificial Intelligence in Education*, 26(1), 293-331. <https://doi.org/10.1007/s40593-015-0090-8>

Dawson, S., Joksimovic, S., Poquet, O., & Siemens, G. (2019). Increasing the impact of learning analytics. In *Proceedings of the 9th International Conference on Learning Analytics & Knowledge* (pp. 446-455). <https://doi.org/10.1145/3303772.3303850>

Deci, E. L., & Ryan, R. M. (2000). The "what" and "why" of goal pursuits: Human needs and the self-determination of behavior. *Psychological Inquiry*, 11(4), 227-268.

https://doi.org/10.1207/S15327965PLI1104_01

Flavell, J. H. (1979). Metacognition and cognitive monitoring: A new area of cognitive-developmental inquiry. *American Psychologist*, 34(10), 906. <https://doi.org/10.1037/0003-066X.34.10.906>

Kizilcec, R. F., Piech, C., & Schneider, E. (2013). Deconstructing disengagement: analyzing learner subpopulations in massive open online courses. In *Proceedings of the third international conference on learning analytics and knowledge* (pp. 170-179).

<https://doi.org/10.1145/2460296.2460324>

Molenaar, I. (2022). The concept of hybrid human-AI regulation: Exemplifying how to support young learners' self-regulated learning. *Computers and Education: Artificial Intelligence*, 3, 100070. <https://doi.org/10.1016/j.caeai.2022.100070>

Ng, D. T. K., Leung, J. K. L., Chu, S. K. W., & Qiao, M. S. (2024). Conceptualizing AI literacy: An exploratory review. *Computers and Education: Artificial Intelligence*, 2, 100041. <https://doi.org/10.1016/j.caeai.2023.100041>

Roll, I., & Wylie, R. (2016). Evolution and revolution in artificial intelligence in education. *International Journal of Artificial Intelligence in Education*, 26(2), 582-599.

<https://doi.org/10.1007/s40593-016-0141-0>

Siemens, G., & Baker, R. S. (2012). Learning analytics and educational data mining. In *Proceedings of the 2nd International Conference on Learning Analytics and Knowledge* (pp. 252-254). <https://doi.org/10.1145/2330601.2330853>

Tsai, Y. S., Perrotta, C., & Gašević, D. (2020). Empowering learners with personalised learning approaches? Agency, equity and transparency in the context of learning analytics. *Assessment & Evaluation in Higher Education*, 45(4), 554-567.

<https://doi.org/10.1080/02602938.2019.1624346> Winne, P. H. (2018). Cognition and metacognition within self-regulated learning. In D. H. Schunk & J. A. Greene (Eds.), *Handbook of self-regulation of learning and performance* (2nd ed., pp.

36-48). Routledge. <https://doi.org/10.4324/9781315697045-3>

Fan, Y., Tang, L., Le, H., Shen, K., Tan, S., Zhao, Y., Shen, Y., Li, X., & Gašević, D. (2024). Beware of metacognitive laziness: Effects of generative artificial intelligence on learning motivation, processes, and performance (preprint). *arXiv*.

<https://doi.org/10.48550/arXiv.2412.09315>

Xia, Q., Chiu, T. K. F., Chai, C. S., & Xie, K. (2023). The mediating effects of needs satisfaction on the relationships between prior knowledge and self-regulated learning through artificial intelligence chatbot. *British Journal of Educational Technology*, 54(4),

967-986.<https://doi.org/10.1111/bjet.13271>

Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory Into Practice*, 41(2), 64-70. https://doi.org/10.1207/s15430421tip4102_4