Psychology of Motivation, Behavior, and Health, Volume 2, Issue 3, PP 1-22

Design and Validation of a Generative AI-Based Personalized Learning Model and Its Effects on Students' Self-Regulated Learning and Academic Achievement

1. Hamid Maleki*: Associate Professor, Department of Educational Management, Payame Noor University, Tehran, Iran

*Corresponding Author's Email: dr.maleki@pnu.ac.ir

Received: 2024-08-01 Revised: 2024-11-05 Accepted: 2024-11-13 Published: 2024-11-21



How to Cite: Maleki, H. (2024). Design and Validation of a Generative AI-Based Personalized Learning Model and Its Effects on Students' Self-Regulated Learning and Academic Achievement. *Psychology of Motivation, Behavior, and Health*, 2(3), 1-22.

Abstract

Introduction and Aim: The rapid development of generative artificial intelligence has created new opportunities for adapting educational content, providing targeted feedback, and supporting students' independent learning processes. This study aimed to design and validate a generative AI-based personalized learning model and examine its relationships with students' self-regulated learning and academic achievement.

Methodology: This applied study employed a sequential exploratory mixed-methods design. In the qualitative phase, data were collected through semi-structured interviews with experts in educational sciences, educational technology, artificial intelligence, and educational psychology and analyzed using thematic analysis. Based on the qualitative findings, the conceptual model and corresponding measurement instrument were developed. In the quantitative phase, 420 upper-secondary school students in Tehran participated in the study. After examining the psychometric properties of the measurement instrument, the relationships among generative AI-based personalized learning, self-regulated learning, and academic achievement were tested using structural equation modeling.

Findings: Structural model results indicated that generative AI-based personalized learning was positively and significantly associated with self-regulated learning ($\beta=0.62$, test statistic=10.40, $p<0.001$). Self-regulated learning was also positively and significantly related to academic achievement ($\beta=0.38$, test statistic=6.70, $p<0.001$). Moreover, the direct path from generative AI-based personalized learning to academic achievement was positive and statistically significant ($\beta=0.21$, test statistic=3.50, $p=0.001$). The estimated indirect effect of personalized learning on academic achievement through self-regulated learning was 0.236, while the total effect was 0.446.

Conclusion: The findings indicate that generative AI-based personalized learning is associated with higher levels of self-regulated learning and academic achievement. Accordingly, intelligent learning environments incorporating adaptive content, targeted feedback, opportunities for self-assessment, and appropriate teacher supervision may provide an effective framework for supporting independent learning and academic performance. Nevertheless, given the non-experimental nature of the quantitative data, the findings should be interpreted as statistical relationships rather than definitive causal effects.

Keywords: Generative artificial intelligence; personalized learning; self-regulated learning; academic achievement; structural equation modeling.

Copyright: © 2024 by the authors. Published under the terms and conditions of Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) License.

Extended Abstract

Introduction and Aim

The rapid expansion of digital technologies has accelerated a fundamental transition from uniform, teacher-centered models of instruction toward learning environments capable of responding to individual differences in prior knowledge, learning pace, cognitive abilities, motivation, interests, and learning strategies. Personalized learning has emerged as one of the most important manifestations of this transition because it seeks to adapt educational content, task difficulty, learning pathways, pace of progression, instructional activities, and feedback to the characteristics and needs of individual learners. A systematic review of 25 years of research on digital personalized learning in primary and secondary education demonstrated substantial conceptual and methodological diversity in the field, emphasizing the need for coherent models that clearly specify the components and mechanisms through which personalization is expected to improve learning (Van Schoors et al., 2021). Meta-analytic evidence has also suggested that technology-supported personalized learning can contribute positively to educational outcomes, particularly when instructional activities are genuinely aligned with learners' levels of mastery and individual needs (Major et al., 2021). Recent developments in artificial intelligence have considerably expanded the technical possibilities for such personalization. AI-based systems can analyze learner performance, identify patterns of error, estimate levels of mastery, and recommend or generate educational activities that are more closely matched to individual learning profiles (Hashim et al., 2022). Contemporary approaches to AI-driven adaptive learning similarly emphasize the capacity of intelligent systems to construct individualized learning pathways and continuously modify instructional support according to learners' progress (Hernandez-Herrera et al., 2026; Rezaei et al., 2025). Deep learning techniques have further increased the capacity to model complex learner patterns and support data-driven personalization (Qiang, 2025), while recent discussions of personalized learning experiences underscore the importance of using AI not merely to automate instruction but to create flexible and learner-responsive educational experiences (Sa-ad et al., 2025). Within the Iranian educational context, the potential role of artificial intelligence in transforming personalized learning has likewise received increasing attention (Sargazi et al., 2025).

The emergence of generative artificial intelligence represents a particularly important development because generative systems can produce new explanations, examples, exercises, questions, summaries, problem-solving scenarios, and feedback in response to individual learner requests. Consequently, the interaction between learners and instructional technology can become more dynamic and dialogic than in conventional adaptive systems based primarily on selecting pre-existing resources. Generative AI has been identified as a potentially transformative educational technology capable of supporting content generation, instructional interaction, differentiated explanation, and individualized learning activities (Bahroun et al., 2023; Yu & Guo, 2023). Systematic evidence concerning ChatGPT and related technologies similarly indicates opportunities for individualized support, rapid access to explanations, interactive learning, and instructional assistance, although the educational value of such tools depends on the quality of pedagogical implementation (Montenegro-Rueda et al., 2023). One particularly relevant mechanism is intelligent feedback. Automated feedback can provide learners with timely information about errors, reasoning processes, and possible next steps, but its effectiveness depends on accuracy, specificity, timing, and instructional relevance (Cavalcanti et al., 2021). AI may also support teachers in planning, diagnosing learner needs, implementing instruction, and evaluating student progress, although effective implementation requires teachers to retain an active professional role in reviewing and contextualizing AI-generated outputs (Celik et al., 2022). At the same time, the use of AI in school settings raises concerns regarding privacy, algorithmic bias, transparency, data protection, equity of access, and accountability (Akgun & Greenhow, 2022). Human-centered implementation, age appropriateness, protection of learner data, and critical evaluation of generated content are therefore essential requirements for educational applications of generative AI (Miao & Holmes, 2023). Reviews of the broader AI-in-education literature similarly caution that technological novelty should not automatically be equated with educational effectiveness (Crompton & Burke, 2023).

An important theoretical mechanism through which personalized learning may be associated with improved educational outcomes is self-regulated learning. Self-regulated learning involves learners' active participation in goal setting, planning, selection of cognitive and metacognitive strategies, time management, performance monitoring, self-

evaluation, and modification of learning strategies when difficulties arise. Meta-analytic evidence has demonstrated significant associations between different phases and strategies of self-regulation and academic performance (Li et al., 2018). Interventions designed to improve self-regulated learning in online and blended educational environments have also been associated with enhanced academic achievement (Xu et al., 2023). Furthermore, evidence suggests that self-regulated learning may partially account for the relationship between educational interventions and academic achievement, indicating that instructional environments may influence outcomes partly by strengthening learners' ability to manage their own learning processes (Jansen et al., 2019). This mechanism is particularly relevant to generative AI because immediate access to explanations and answers may either strengthen learner autonomy or, if poorly designed, encourage passive dependence on technology. Therefore, generative AI-based personalized learning should ideally support students in setting goals, evaluating their understanding, requesting appropriate assistance, monitoring progress, and reflecting on their own performance rather than simply providing final answers. Evidence concerning AI and computational technologies also indicates potential positive associations with student performance, although outcomes depend substantially on instructional design and implementation conditions (García-Martínez et al., 2023). Accordingly, an integrated framework is needed to connect personalization, generative AI, self-regulated learning, academic achievement, and responsible implementation. The present study therefore aimed to design and validate a generative AI-based personalized learning model and examine its relationships with self-regulated learning and academic achievement among upper-secondary school students.

Methodology

The study was applied in purpose and employed a sequential exploratory mixed-methods design consisting of qualitative and quantitative phases. In the qualitative phase, the dimensions, components, and indicators of a generative AI-based personalized learning model were identified through semi-structured interviews with experts in educational sciences, educational technology, artificial intelligence, and educational psychology. Interview data were transcribed, coded, and analyzed using thematic analysis. The qualitative findings were subsequently organized into an integrated conceptual framework and used to define the principal constructs of the proposed model and develop the corresponding measurement instrument. The identified framework incorporated personalized and adaptive instruction, intelligent interaction and learning feedback, support for self-regulated learning, support for academic achievement, and responsible governance and implementation requirements. In the quantitative phase, the proposed relationships among generative AI-based personalized learning, self-regulated learning, and academic achievement were evaluated using survey data collected from 420 upper-secondary school students in Tehran. Generative AI-based personalized learning was specified as the predictor construct, self-regulated learning as an intermediate construct, and academic achievement as the outcome construct. Responsible implementation requirements, including content accuracy, data protection, educational equity, and teacher supervision, were considered essential criteria for model design and implementation. Following evaluation of the measurement properties of the instrument, structural equation modeling was used to assess model fit and estimate the structural relationships among the study variables. Direct, indirect, and total effects were calculated to determine the relative contribution of the proposed pathways linking personalized learning, self-regulated learning, and academic achievement.

Findings

The quantitative analysis indicated that the measurement model demonstrated acceptable reliability and convergent validity and that the proposed structural model provided an adequate representation of the observed data. Structural path analysis showed that generative AI-based personalized learning was positively and significantly associated with self-regulated learning. The standardized coefficient for this path was $\beta=0.62$, with a test statistic of 10.40 and $p<0.001$, making it the strongest structural relationship observed in the model. This result indicated that higher levels of adaptive content, intelligent interaction, individualized feedback, and personalized learning support were associated with higher levels of students' goal setting, planning, monitoring, time management, and self-evaluation.

Self-regulated learning was also positively and significantly associated with academic achievement. The standardized path coefficient was $\beta=0.38$, the test statistic was 6.70, and the significance level was $p<0.001$. Thus, students reporting stronger self-regulatory learning processes also demonstrated

higher academic achievement within the structural model. In addition, generative AI-based personalized learning had a positive and statistically significant direct relationship with academic achievement. The standardized coefficient for this direct pathway was β=0.21, with a test statistic of 3.50 and p=0.001. Accordingly, the relationship between personalized learning and academic achievement was not limited to the pathway involving self-regulated learning.

The estimated indirect effect of generative AI-based personalized learning on academic achievement through self-regulated learning was 0.236. The total effect, calculated by combining the direct and indirect effects, was 0.446. Numerically, the estimated indirect effect was slightly greater than the direct effect of 0.210, suggesting that the pathway involving self-regulated learning accounted for a substantial portion of the overall relationship between personalized learning and academic achievement. Nevertheless, because a bootstrap confidence interval for the indirect effect was not reported, this pattern should be regarded as consistent with an indirect mechanism rather than definitive statistical confirmation of mediation.

Discussion and Conclusion

The findings provide support for an integrated interpretation of generative AI-based personalized learning in which educational technology is valuable not simply because it produces content rapidly but because it can create conditions that encourage students to manage their own learning more effectively. The strongest path in the model connected personalized learning with self-regulated learning. This finding suggests that personalization may be particularly important when it provides students with meaningful opportunities to establish goals, select appropriate activities, monitor their understanding, receive targeted feedback, identify errors, and evaluate their own progress. Generative AI can potentially support each of these processes by varying explanations, generating additional examples, proposing practice activities, offering step-by-step guidance, and responding dynamically to learner questions. However, these functions become educationally meaningful only when they are structured to preserve learner agency rather than replace students' cognitive effort.

The positive relationship between self-regulated learning and academic achievement further indicates that learner characteristics and learning-management processes remain central even in technologically advanced instructional environments. Access to intelligent tools alone cannot guarantee improved academic outcomes. Students must be capable of using available support strategically, recognizing when assistance is needed, evaluating the quality of responses, and modifying ineffective learning strategies. Consequently, the findings reinforce the importance of designing AI-supported environments in ways that simultaneously promote technological personalization and student autonomy.

The significant direct relationship between generative AI-based personalized learning and academic achievement indicates that personalization may also contribute to academic performance through mechanisms that are not fully explained by self-regulation. Adaptive levels of difficulty, individualized examples, rapid correction of misconceptions, targeted practice, and timely feedback may directly improve students' opportunities to understand instructional material and achieve learning objectives. At the same time, the indirect effect through self-regulated learning was slightly larger than the direct effect, suggesting that the educational value of personalized learning may be particularly substantial when personalization contributes to students' capacity to regulate their own learning.

The results therefore support a broader conception of generative AI-based personalized learning as an educational ecosystem rather than merely a technological tool. Effective implementation should integrate adaptive content, intelligent interaction, formative feedback, self-monitoring opportunities, teacher supervision, content verification, privacy protection, and equitable access. Teachers should retain a central role in determining instructional goals, evaluating AI-generated outputs, identifying situations in which students require human support, and ensuring that technological assistance does not replace independent reasoning. Likewise, students should be encouraged to question generated responses, explain their reasoning, compare alternative solutions, monitor their own understanding, and use AI as a learning scaffold rather than as a substitute for learning.

Overall, the proposed model demonstrated empirical support for the relationships among generative AI-based personalized learning, self-regulated learning, and academic achievement. Personalized learning showed a strong positive relationship with self-regulated learning and a smaller but significant direct relationship with academic achievement, while self-regulated learning was positively related to academic

achievement. The combined direct and indirect pathways produced a meaningful total relationship between personalized learning and academic achievement. These findings suggest that generative AI may have its greatest educational value when personalized technological support is deliberately designed to strengthen learners' active management of their learning processes. Nevertheless, because the quantitative phase was non-experimental and cross-sectional, the reported structural relationships should not be interpreted as definitive causal effects. Future experimental and longitudinal validation is required to determine whether implementation of the proposed model produces sustained improvements in self-regulation and academic performance. Within these limitations, the study provides an integrated framework for designing intelligent, flexible, learner-centered, and responsibly governed learning environments in which generative AI supports rather than replaces the intellectual and regulatory activity of students.

طراحی و اعتباریابی مدل یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد و تأثیر آن بر خودتنظیمی یادگیری و پیشرفت تحصیلی دانش‌آموزان

۱. حمید ملکی*: دانشیار، گروه مدیریت آموزشی، دانشگاه پیام نور، تهران، ایران

*ایمیل نویسنده مسئول: dr.maleki@pnu.ac.ir

دریافت: ۱۴۰۳/۰۵/۱۱ بازنگری: ۱۴۰۳/۰۸/۱۵ پذیرش: ۱۴۰۳/۰۸/۲۳ انتشار اولیه: ۱۴۰۳/۰۹/۰۱



نحوه استناددهی: ملکی، حمید. (۱۴۰۳). طراحی و اعتباریابی مدل یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد و تأثیر آن بر خودتنظیمی یادگیری و پیشرفت تحصیلی دانش‌آموزان. *روان‌شناسی انگیزش، رفتار و سلامت*، ۲(۳)، ۲۲-۱.

چکیده

مقدمه و هدف: گسترش هوش مصنوعی مولد، ظرفیت‌های جدیدی برای انطباق محتوا، ارائه بازخورد هدفمند و حمایت از فرایندهای یادگیری مستقل دانش‌آموزان فراهم کرده است. پژوهش حاضر با هدف طراحی و اعتباریابی مدل یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد و بررسی روابط آن با خودتنظیمی یادگیری و پیشرفت تحصیلی دانش‌آموزان انجام شد.

روش‌شناسی: پژوهش از نظر هدف کاربردی و از نظر روش‌شناسی دارای طرح آمیخته اکتشافی متوالی بود. در مرحله کیفی، داده‌ها از طریق مصاحبه‌های نیمه‌ساختاریافته با متخصصان علوم تربیتی، فناوری آموزشی، هوش مصنوعی و روان‌شناسی تربیتی گردآوری و با روش تحلیل مضمون تجزیه‌وتحلیل شدند. بر مبنای نتایج این مرحله، مدل مفهومی و ابزار اندازه‌گیری تدوین شد. در مرحله کمی، ۴۲۰ دانش‌آموز دوره متوسطه دوم شهر تهران در مطالعه شرکت کردند. پس از بررسی ویژگی‌های روان‌سنجی ابزار، روابط میان یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد، خودتنظیمی یادگیری و پیشرفت تحصیلی با استفاده از مدل‌سازی معادلات ساختاری آزمون شدند.

یافته‌ها: نتایج مدل ساختاری نشان داد یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد رابطه مثبت و معناداری با خودتنظیمی یادگیری داشت (β=۰.۶۲، آماره آزمون=۱۰.۴۰، $p<0.001$). خودتنظیمی یادگیری نیز به‌طور مثبت و معنادار با پیشرفت تحصیلی مرتبط بود (β=۰.۳۸، آماره آزمون=۶.۷۰، $p<0.001$). همچنین، مسیر مستقیم یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد به پیشرفت تحصیلی مثبت و معنادار بود (β=۰.۲۱، آماره آزمون=۳.۵۰، $p=0.001$). اثر غیرمستقیم برآوردشده یادگیری شخصی‌سازی‌شده بر پیشرفت تحصیلی از طریق خودتنظیمی یادگیری برابر با ۰.۲۳۶ و اثر کل برابر با ۰.۴۴۶ بود.

نتیجه‌گیری: یافته‌ها نشان می‌دهند یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد می‌تواند با خودتنظیمی بیشتر و پیشرفت تحصیلی بالاتر دانش‌آموزان همراه باشد. بنابراین، طراحی محیط‌های یادگیری هوشمند با محتوای سازگار، بازخورد هدفمند، فرصت‌های خودارزیابی و حفظ نقش نظارتی معلم می‌تواند چارچوب مناسبی برای حمایت از یادگیری مستقل و عملکرد تحصیلی فراهم کند؛ بااین‌حال، به دلیل ماهیت غیرآزمایشی داده‌های کمی، نتایج باید در چارچوب روابط آماری تفسیر شوند.

کلیدواژگان: هوش مصنوعی مولد؛ یادگیری شخصی‌سازی‌شده؛ خودتنظیمی یادگیری؛ پیشرفت تحصیلی؛ مدل‌سازی معادلات ساختاری.

مجوز و حق نشر: © ۱۴۰۳ تمامی حقوق انتشار این مقاله متعلق به نویسنده است. انتشار این مقاله به‌صورت دسترسی آزاد مطابق با گواهی (CC BY-NC 4.0) صورت گرفته است.

مقدمه

تحول دیجیتال در آموزش طی دو دهه اخیر، نگاه به فرایند یاددهی—یادگیری را از الگوهای یکسان، خطی و معلم‌محور به سوی رویکردهایی سوق داده است که در آن تفاوت‌های فردی یادگیرندگان، مسیرهای متفاوت یادگیری، نیازهای شناختی و انگیزشی و قابلیت انطباق محیط آموزشی با ویژگی‌های هر دانش‌آموز اهمیت بیشتری یافته‌اند. یکی از مهم‌ترین نمودهای این تحول، «یادگیری شخصی‌سازی‌شده» است؛ رویکردی که بر تنظیم محتوا، سطح دشواری، سرعت پیشرفت، نوع فعالیت، بازخورد و مسیر یادگیری بر اساس وضعیت، نیازها و توانایی‌های هر یادگیرنده تأکید می‌کند. در چنین رویکردی، هدف صرفاً ارائه محتوای متفاوت به افراد نیست، بلکه طراحی تجربه‌ای پویا از یادگیری است که بتواند بر اساس داده‌های حاصل از عملکرد یادگیرنده به‌طور مستمر بازتنظیم شود. مرور پژوهش‌های ۲۵ ساله در حوزه یادگیری شخصی‌سازی‌شده دیجیتال در آموزش ابتدایی و متوسطه نشان می‌دهد که این حوزه از نظر مفهومی، روش‌شناختی و شیوه‌های اجرای عملی تنوع گسترده‌ای دارد و هنوز تعریف عملیاتی واحدی برای همه اشکال شخصی‌سازی وجود ندارد؛ ازاین‌رو، طراحی مدل‌های منسجم و قابل‌اعتباریابی برای استفاده از این رویکرد در نظام آموزشی اهمیت بنیادی دارد (Van Schoors et al., 2021). شواهد فراتحلیلی نیز نشان داده‌اند که شخصی‌سازی آموزشیِ پشتیبانی‌شده با فناوری، در صورت برخورداری از طراحی آموزشی مناسب و انطباق واقعی فعالیت‌ها با سطح یادگیرندگان، می‌تواند پیامدهای مثبتی برای یادگیری ایجاد کند (Major et al., 2021). در مطالعات جدیدتر نیز تأکید شده است که ترکیب هوش مصنوعی با سامانه‌های یادگیری تطبیقی می‌تواند امکان شناسایی دقیق‌تر نیازهای یادگیرندگان و طراحی مسیرهای یادگیری متناسب با تفاوت‌های فردی را گسترش دهد (Hernandez-Herrera et al., 2026).

ظهور هوش مصنوعی، به‌ویژه طی سال‌های اخیر، ظرفیت‌های یادگیری شخصی‌سازی‌شده را به‌طور چشمگیری توسعه داده است. سامانه‌های مبتنی بر هوش مصنوعی می‌توانند حجم زیادی از داده‌های مربوط به عملکرد، الگوهای خطا، سرعت یادگیری، ترجیحات و میزان تسلط دانش‌آموزان را تحلیل کنند و بر اساس این داده‌ها محتوای آموزشی، فعالیت‌ها و بازخوردهای متناسب‌تری ارائه دهند. مرور نظام‌مند روندهای فناوری و هوش مصنوعی در یادگیری شخصی‌سازی‌شده نشان داده است که فناوری‌های هوشمند می‌توانند در انطباق محتوا، روش تدریس، سطح دشواری فعالیت‌ها، ارزیابی و ارائه بازخورد با ویژگی‌های یادگیرندگان نقش داشته باشند (Hashim et al., 2022). همچنین، رویکردهای جدید مبتنی بر یادگیری عمیق، امکان مدل‌سازی دقیق‌تر الگوهای رفتاری و عملکردی یادگیرندگان و پیش‌بینی نیازهای آموزشی بعدی آنان را فراهم ساخته‌اند؛ موضوعی که می‌تواند زیرساخت فنی یادگیری شخصی‌سازی‌شده را تقویت کند (Qiang, 2025). در چارچوب‌های نوظهور آموزشی، از جمله محیط‌های فراگیر و متاورسی، هوش مصنوعی نیز به‌عنوان ابزار اصلی برای طراحی مسیرهای یادگیری متناسب با سطح، عملکرد و ترجیحات یادگیرندگان معرفی شده است (Rezaei et al., 2025). از منظر کاربردی، پژوهش‌های جدید درباره تجربه‌های یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی نشان می‌دهند که مزیت اصلی این فناوری نه صرفاً در خودکارسازی فرایندها، بلکه در توانایی آن برای تنظیم حمایت آموزشی متناسب با نیاز فرد و ارائه تجربه‌ای انعطاف‌پذیرتر از یادگیری نهفته است (Sa-ad et al., 2025). در نظام آموزشی ایران نیز توجه به ظرفیت هوش مصنوعی برای تحول در شیوه‌های یادگیری شخصی‌سازی‌شده افزایش یافته و بر ضرورت تدوین الگوهایی متناسب با بافت آموزشی، امکانات فناورانه و نیازهای دانش‌آموزان تأکید شده است (Sargazi et al., 2025).

در میان فناوری‌های نوین هوش مصنوعی، ظهور هوش مصنوعی مولد نقطه عطف مهم‌تری در تحول محیط‌های آموزشی ایجاد کرده است. برخلاف بسیاری از سامانه‌های سنتی هوش مصنوعی آموزشی که عمدتاً بر انتخاب، طبقه‌بندی یا پیشنهاد محتوای از پیش موجود متکی بودند، مدل‌های مولد قادرند به‌صورت پویا توضیحات، مثال‌ها، تمرین‌ها، پرسش‌ها، خلاصه‌ها، سناریوهای حل مسئله و بازخوردهای متنی تازه تولید کنند. این ویژگی، تعامل یادگیرنده با فناوری را از دریافت منفعل محتوا به یک فرایند گفت‌وگویی و انعطاف‌پذیر تبدیل می‌کند که در آن دانش‌آموز می‌تواند درباره یک مفهوم پرسش کند، توضیحی ساده‌تر یا پیشرفته‌تر درخواست کند، مثال‌های بیشتری دریافت نماید یا برای ارزیابی میزان تسلط خود، تمرین‌های

متناسب با سطحش تولید کند. بررسی‌های انجام‌شده درباره نقش هوش مصنوعی مولد در اصلاح نظام‌های آموزشی نشان می‌دهد که این فناوری ظرفیت قابل‌توجهی برای تولید محتوا، پشتیبانی از تدریس، تسهیل دسترسی به توضیحات و بازطراحی تجربه یادگیری دارد، اما تحقق این ظرفیت به نحوه طراحی آموزشی و استفاده هدفمند از ابزار وابسته است (Yu & Guo, 2023). تحلیل کتاب‌سنجی و محتوایی پژوهش‌های مربوط به هوش مصنوعی مولد در محیط‌های آموزشی نیز نشان داده است که شخصی‌سازی، تولید محتوای آموزشی، ارزیابی، بازخورد و پشتیبانی از یادگیری از مهم‌ترین حوزه‌های کاربرد این فناوری محسوب می‌شوند (Bahroun et al., 2023). همچنین، مرور نظام‌مند مطالعات مربوط به اجرای ChatGPT در آموزش نشان داده است که این فناوری می‌تواند فرصت‌هایی برای دسترسی سریع به اطلاعات، حمایت از فعالیت‌های یادگیری، تعامل آموزشی و تولید محتوای متناسب فراهم سازد، هرچند کیفیت پاسخ‌ها و شیوه استفاده از آن باید به‌طور جدی مورد نظارت قرار گیرد (Montenegro-Rueda et al., 2023).

یکی از عناصر محوری در اثربخشی یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد، کیفیت بازخورد آموزشی است. بازخورد زمانی می‌تواند به یادگیری عمیق کمک کند که تنها درست یا نادرست بودن پاسخ را اعلام نکند، بلکه اطلاعاتی درباره ماهیت خطا، منطق اصلاح آن، راهبرد مناسب و گام بعدی یادگیری در اختیار دانش‌آموز قرار دهد. مرور نظام‌مند پژوهش‌های بازخورد خودکار در محیط‌های یادگیری برخط نشان داده است که سامانه‌های هوشمند می‌توانند با ارائه بازخورد سریع و متناسب، فرایند یادگیری و تنظیم فعالیت‌های آموزشی را پشتیبانی کنند، اما اثربخشی این بازخورد به دقت، تناسب، زمان‌بندی و کیفیت طراحی آن وابسته است (Cavalcanti et al., 2021). از سوی دیگر، نقش معلم در چنین محیط‌هایی نه‌تنها حذف نمی‌شود، بلکه از انتقال صرف اطلاعات به سوی هدایت، نظارت، تفسیر داده‌ها و ارزیابی کیفیت تعامل دانش‌آموز با سامانه تغییر می‌کند. مرور پژوهش‌ها درباره وعده‌ها و چالش‌های هوش مصنوعی برای معلمان نشان داده است که این فناوری می‌تواند در برنامه‌ریزی، اجرا، ارزیابی و شناسایی نیازهای یادگیرندگان نقش پشتیبان داشته باشد، اما استفاده اثربخش از آن به شایستگی‌های فناورانه و تربیتی معلم و توانایی او در ارزیابی انتقادی خروجی‌های سامانه وابسته است (Celik et al., 2022). ازاین‌رو، مدل‌های آموزشی مبتنی بر هوش مصنوعی مولد باید رابطه میان نقش معلم، قابلیت‌های هوشمند سامانه و فعالیت مستقل یادگیرنده را به‌گونه‌ای متوازن طراحی کنند.

در کنار مزایای بالقوه، استفاده آموزشی از هوش مصنوعی مولد با مجموعه‌ای از چالش‌های اخلاقی، شناختی و اجرایی همراه است که نمی‌توان آن‌ها را از طراحی یک مدل یادگیری شخصی‌سازی‌شده جدا کرد. خروجی‌های سامانه‌های مولد ممکن است نادرست، ناقص یا نامتناسب با سطح رشد و دانش دانش‌آموز باشند؛ همچنین، گردآوری و تحلیل داده‌های فردی می‌تواند نگرانی‌هایی در زمینه حریم خصوصی، مالکیت داده، امنیت اطلاعات و شفافیت تصمیم‌های الگوریتمی ایجاد کند. در محیط‌های مدرسه‌ای، این چالش‌ها اهمیت بیشتری دارند، زیرا دانش‌آموزان از نظر سنی و شناختی در موقعیتی قرار دارند که نیازمند حمایت و نظارت بیشتر است. بررسی مسائل اخلاقی هوش مصنوعی در محیط‌های K–12، موضوعاتی مانند سوگیری الگوریتمی، شفافیت، حریم خصوصی، عدالت، نظارت و مسئولیت‌پذیری را از چالش‌های اساسی این حوزه معرفی کرده است (Akgun & Greenhow, 2022). راهنمای یونسکو برای هوش مصنوعی مولد در آموزش و پژوهش نیز بر رویکرد انسان‌محور، حفاظت از داده‌ها، تناسب سنی، اعتبارسنجی محتوای تولیدشده و حفظ عاملیت انسان در تصمیم‌گیری‌های آموزشی تأکید دارد (Miao & Holmes, 2023). افزون بر این، مرور وضعیت هوش مصنوعی در آموزش عالی نشان می‌دهد که گرچه دامنه کاربردهای آموزشی این فناوری به سرعت در حال گسترش است، شواهد تجربی درباره اثربخشی برخی کاربردها هنوز محدود و ناهمگون است و لازم است میان جذابیت فناورانه ابزارها و اثربخشی واقعی آموزشی آن‌ها تمایز قائل شد (Crompton & Burke, 2023). بنابراین، هر مدل پیشنهادی باید علاوه بر قابلیت‌های فنی، الزامات اخلاقی، آموزشی و اجرایی استفاده مسئولانه از فناوری را نیز در ساختار خود جای دهد.

بااین‌حال، صرف دسترسی دانش‌آموز به محتوای تطبیقی یا بازخورد هوشمند تضمین‌کننده یادگیری مؤثر نیست؛ زیرا کیفیت یادگیری تا حد زیادی به توانایی یادگیرنده در مدیریت و هدایت فعالیت‌های

خود وابسته است. در این زمینه، خودتنظیمی یادگیری به‌عنوان یکی از سازه‌های کلیدی مطرح می‌شود که شامل هدف‌گذاری، برنامه‌ریزی، انتخاب و اجرای راهبردهای شناختی، مدیریت زمان و منابع، پایش درک و عملکرد، خودارزیابی و اصلاح راهبردهای یادگیری است. دانش‌آموز خودتنظیم صرفاً دریافت‌کننده اطلاعات نیست، بلکه در فرایند یادگیری نقش فعال دارد و بر اساس ارزیابی مستمر از وضعیت خود، تصمیم‌های لازم را درباره ادامه مسیر اتخاذ می‌کند. فراتحلیل دو دهه پژوهش درباره خودتنظیمی و عملکرد تحصیلی نشان داده است که مراحل و راهبردهای مختلف خودتنظیمی، از جمله خودکارآمدی، راهبردهای انجام تکلیف، خودارزیابی و تنظیم فعالیت‌ها، با عملکرد تحصیلی دانش‌آموزان رابطه معناداری دارند (Li et al., 2018). در محیط‌های برخط و ترکیبی نیز شواهد فراتحلیلی نشان داده‌اند که مداخلات خودتنظیمی می‌توانند به بهبود پیشرفت تحصیلی کمک کنند و بنابراین، تقویت این مهارت‌ها باید به‌عنوان بخشی از طراحی محیط‌های آموزشی دیجیتال مورد توجه قرار گیرد (Xu et al., 2023). این مسئله برای محیط‌های مبتنی بر هوش مصنوعی مولد اهمیتی دوچندان دارد، زیرا دسترسی فراوان و سریع به پاسخ‌ها، در صورت طراحی نامناسب، می‌تواند از تلاش شناختی و استقلال یادگیرنده بکاهد، درحالی‌که استفاده از راهنمایی تدریجی، پرسش‌های تأملی، فعالیت‌های خودارزیابی و بازخورد مرحله‌ای می‌تواند ظرفیت خودتنظیمی را تقویت کند.

پیوند میان یادگیری شخصی‌سازی‌شده، خودتنظیمی و پیشرفت تحصیلی از نظر نظری نیز اهمیت ویژه‌ای دارد. شخصی‌سازی می‌تواند با فراهم کردن فعالیت‌های متناسب با سطح یادگیرنده، کاهش فاصله میان دشواری تکلیف و توانایی فرد، ارائه بازخورد مناسب و ایجاد فرصت برای تصمیم‌گیری درباره مسیر یادگیری، زمینه مشارکت فعال‌تر دانش‌آموز را فراهم کند. در چنین شرایطی، دانش‌آموز فرصت بیشتری برای هدف‌گذاری، پایش عملکرد، اصلاح خطاها و ارزیابی پیشرفت خود خواهد داشت؛ فرایندهایی که هسته اصلی خودتنظیمی را تشکیل می‌دهند. از سوی دیگر، خودتنظیمی می‌تواند بخشی از سازوکار ارتباط میان کیفیت تجربه آموزشی و عملکرد تحصیلی را توضیح دهد. فراتحلیل مداخلات خودتنظیمی نشان داده است که خودتنظیمی یادگیری می‌تواند بخشی از اثر مداخلات آموزشی بر پیشرفت تحصیلی را میانجی‌گری کند، هرچند این نقش میانجی کامل نیست و سایر عوامل شناختی، انگیزشی و محیطی نیز در عملکرد تحصیلی دخالت دارند (Jansen et al., 2019). بنابراین، بررسی هم‌زمان مسیر مستقیم یادگیری شخصی‌سازی‌شده به پیشرفت تحصیلی و مسیر غیرمستقیم آن از طریق خودتنظیمی می‌تواند تصویر دقیق‌تری از چگونگی ارتباط این متغیرها فراهم سازد.

پیشرفت تحصیلی به‌عنوان یکی از مهم‌ترین پیامدهای نظام آموزشی، بیانگر میزان دستیابی دانش‌آموز به اهداف، دانش و مهارت‌های مورد انتظار است و می‌تواند شاخصی اساسی برای ارزیابی کارآمدی فناوری‌های آموزشی محسوب شود. بااین‌حال، استفاده از هوش مصنوعی زمانی ارزش آموزشی دارد که بتواند به یادگیری واقعی و پایدار منجر شود، نه صرفاً عملکرد لحظه‌ای دانش‌آموز را در حضور ابزار ارتقا دهد. مرور نظام‌مند و فراتحلیل پژوهش‌های مربوط به هوش مصنوعی و علوم محاسباتی نشان داده است که استفاده از این فناوری‌ها می‌تواند با بهبود برخی شاخص‌های عملکرد دانش‌آموزان همراه باشد، اما اندازه و پایداری اثر به نوع فناوری، شیوه اجرا، طراحی آموزشی و ویژگی‌های جمعیت مورد مطالعه وابسته است (García-Martínez et al., 2023). به همین دلیل، در ارزیابی مدل‌های مبتنی بر هوش مصنوعی مولد باید بررسی شود که آیا شخصی‌سازی و بازخورد هوشمند صرفاً سهولت انجام تکالیف را افزایش می‌دهند یا واقعاً با افزایش ظرفیت یادگیری مستقل و پیشرفت تحصیلی مرتبط هستند. این تمایز به‌ویژه در محیط مدرسه اهمیت دارد، زیرا رشد مهارت‌های شناختی و فراشناختی بلندمدت دانش‌آموزان باید بر سرعت دستیابی به پاسخ ترجیح داده شود.

علاوه بر مبانی نظری یادشده، طراحی مدل‌های پیچیده آموزشی نیازمند رویکردی روش‌شناختی است که ابتدا ابعاد و مؤلفه‌های پدیده را در بستر مورد مطالعه شناسایی کند و سپس روابط میان سازه‌های استخراج‌شده را به‌صورت تجربی مورد آزمون قرار دهد. استفاده از طرح‌های آمیخته و حرکت از مرحله کیفی برای شناسایی مؤلفه‌ها به مرحله کمی برای آزمون و اعتباریابی مدل، در پژوهش‌های مدل‌سازی سازمانی و رفتاری به‌عنوان رویکردی مناسب برای تبدیل داده‌های کیفی به سازه‌های قابل‌سنجش مورد استفاده قرار گرفته

است (Kermanian et al., 2023). چنین منطقی در مطالعه حاضر نیز اهمیت دارد، زیرا یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد پدیده‌ای چندبعدی است که عناصر فناورانه، آموزشی، شناختی، اخلاقی و اجرایی را به‌طور هم‌زمان دربر می‌گیرد و تقلیل آن به یک شاخص فنی نمی‌تواند پیچیدگی واقعی آن را منعکس کند. بنابراین، شناسایی ابعاد مدل از دیدگاه متخصصان و سپس آزمون تجربی روابط میان سازه‌های اصلی می‌تواند به تدوین الگویی با انسجام مفهومی و قابلیت کاربرد بیشتر کمک کند.

با وجود افزایش سریع پژوهش‌ها درباره هوش مصنوعی در آموزش، چند خلأ مهم همچنان قابل مشاهده است. نخست آنکه بخش قابل‌توجهی از مطالعات موجود به بررسی کلی کاربردهای هوش مصنوعی یا هوش مصنوعی مولد پرداخته‌اند و مدل‌های یکپارچه‌ای که شخصی‌سازی آموزشی، تعامل و بازخورد، خودتنظیمی و پیشرفت تحصیلی را در یک ساختار واحد بررسی کنند، هنوز محدود هستند. دوم آنکه مطالعات مربوط به ChatGPT و دیگر ابزارهای مولد غالباً بر آموزش عالی متمرکز بوده‌اند، درحالی‌که ویژگی‌های رشدی، نیازهای نظارتی و ساختار آموزشی دانش‌آموزان مدارس با دانشجویان تفاوت دارد (Crompton & Burke, 2023; Montenegro-Rueda et al., 2023). سوم آنکه شواهد مربوط به شخصی‌سازی فناورانه نشان می‌دهد اثربخشی این رویکرد به زمینه اجرای آن وابسته است و انتقال مستقیم نتایج میان نظام‌های آموزشی مختلف بدون توجه به شرایط فرهنگی، فناورانه و نهادی مناسب نیست (Major et al., 2021). چهارم آنکه گسترش سریع قابلیت‌های هوش مصنوعی مولد نیازمند مدل‌هایی است که نه‌تنها مزایای آموزشی، بلکه صحت محتوا، حفظ حریم خصوصی، عدالت در دسترسی و نظارت معلم را نیز در نظر گیرند (Akgun & Greenhow, 2022; Miao & Holmes, 2023). سرانجام، با وجود شواهد روشن درباره رابطه خودتنظیمی با پیشرفت تحصیلی، چگونگی قرار گرفتن این سازه در مسیر ارتباط میان تجربه‌های شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد و عملکرد تحصیلی دانش‌آموزان هنوز نیازمند بررسی تجربی بیشتری است (Jansen et al., 2019; Xu et al., 2023).

بر این اساس، ضرورت پژوهش حاضر از نیاز به ارائه چارچوبی یکپارچه ناشی می‌شود که قابلیت‌های تولیدی و تعاملی هوش مصنوعی مولد را با اصول یادگیری شخصی‌سازی‌شده، سازوکارهای خودتنظیمی یادگیری و پیامدهای تحصیلی پیوند دهد و در عین حال، ملاحظات مربوط به اجرای مسئولانه فناوری را نادیده نگیرد. چنین مدلی می‌تواند از یک سو مبنایی نظری برای تبیین نحوه ارتباط فناوری مولد با فرایندهای یادگیری فراهم کند و از سوی دیگر، برای طراحان آموزشی، معلمان و مدیران مدرسه مشخص سازد که استفاده مؤثر از هوش مصنوعی نباید به ارائه پاسخ‌های سریع یا تولید خودکار محتوا محدود شود، بلکه لازم است در قالب چرخه‌ای شامل تشخیص نیاز، انطباق محتوا، تعامل آموزشی، بازخورد هدفمند، فعالیت مستقل، پایش و خودارزیابی سازمان‌دهی شود. همچنین، توجه به پژوهش‌های جدید درباره یادگیری تطبیقی و شخصی‌سازی مبتنی بر هوش مصنوعی نشان می‌دهد که توسعه مدل‌های آینده باید علاوه بر ظرفیت‌های فنی الگوریتم‌ها، بر عاملیت یادگیرنده، کیفیت طراحی آموزشی و هماهنگی میان فناوری و نقش حرفه‌ای معلم استوار باشد (Hernandez-Herrera et al., 2026; Sa-ad et al., 2025). بنابراین، هدف پژوهش حاضر طراحی و اعتباریابی مدل یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد و بررسی رابطه آن با خودتنظیمی یادگیری و پیشرفت تحصیلی دانش‌آموزان دوره متوسطه دوم شهر تهران است.

روش‌شناسی

پژوهش حاضر از نظر هدف، کاربردی و از نظر رویکرد، آمیخته اکتشافی متوالی بود که در دو مرحله کیفی و کمی انجام شد. در مرحله کیفی، به‌منظور شناسایی ابعاد، مؤلفه‌ها و شاخص‌های مدل یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد، از روش تحلیل مضمون استفاده شد. داده‌های این مرحله از طریق مصاحبه‌های نیمه‌ساختاریافته با متخصصان حوزه علوم تربیتی، فناوری آموزشی، هوش مصنوعی و روان‌شناسی تربیتی گردآوری شدند و پس از پیاده‌سازی، کدگذاری و تحلیل شدند. بر اساس یافته‌های کیفی، مدل مفهومی پژوهش تدوین و ابزار اندازه‌گیری متناسب با سازه‌های شناسایی‌شده طراحی شد. در مرحله کمی، به‌منظور اعتباریابی مدل پیشنهادی و بررسی روابط میان یادگیری شخصی‌سازی‌شده مبتنی بر

هوش مصنوعی مولد، خودتنظیمی یادگیری و پیشرفت تحصیلی، از روش پیمایشی و مدل‌سازی معادلات ساختاری استفاده شد. جامعه آماری این مرحله را دانش‌آموزان دوره متوسطه دوم شهر تهران تشکیل دادند. حجم نمونه پژوهش ۴۲۰ دانش‌آموز از دوره متوسطه دوم شهر تهران در نظر گرفته شد و توزیع فرضی دانش‌آموزان بر اساس جنسیت و پایه تحصیلی در جدول ۳ ارائه شد. داده‌های کمی پس از بررسی روایی و پایایی ابزار پژوهش، با استفاده از روش مدل‌سازی معادلات ساختاری تحلیل شدند تا برازش مدل، ضرایب مسیر و میزان تأثیر متغیرهای پژوهش بر یکدیگر ارزیابی شوند.

یافته‌ها

در این بخش، یافته‌های حاصل از تحلیل داده‌های کیفی با هدف شناسایی ابعاد، مؤلفه‌ها و شاخص‌های مدل یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد ارائه می‌شود . داده‌های حاصل از مصاحبه‌های نیمه‌ساختاریافته با متخصصان حوزه علوم تربیتی، فناوری آموزشی، هوش مصنوعی و روان‌شناسی تربیتی، پس از پیاده‌سازی و بررسی، از طریق فرایند کدگذاری و تحلیل مضمون مورد تجزیه‌وتحلیل قرار گرفتند .هدف از این فرایند، شناسایی الگوهای معنایی مشترک در دیدگاه مشارکت‌کنندگان و سازمان‌دهی آن‌ها در قالب مضامین اصلی، مضامین فرعی و شاخص‌های مفهومی بود تا زمینه لازم برای تدوین یک مدل منسجم و متناسب با الزامات یادگیری شخصی‌سازی‌شده در محیط‌های آموزشی فراهم شود.

نتایج تحلیل مضمون در جدول ۱ ارائه شده است .بر اساس ساختار مفهومی استخراج‌شده، پنج مضمون اصلی شامل شخصی‌سازی و سازگاری آموزشی، تعامل هوشمند و بازخورد یادگیری، تقویت خودتنظیمی یادگیری، پشتیبانی از پیشرفت تحصیلی و حکمرانی مسئولانه و الزامات اجرایی شناسایی شدند .هر یک از این مضامین، مجموعه‌ای از مضامین فرعی و شاخص‌های مفهومی مرتبط را دربر می‌گیرند که ابعاد مختلف طراحی، پیاده‌سازی و بهره‌برداری آموزشی از هوش مصنوعی مولد را تبیین می‌کنند.

جدول ۱. مضامین اصلی، مضامین فرعی و شاخص‌های مدل یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد

مضامین اصلی	مضامین فرعی	شاخص‌های مفهومی
شخصی‌سازی و سازگاری آموزشی	تشخیص سطح یادگیری، انطباق محتوا، انعطاف‌پذیری مسیر یادگیری	تنظیم دشواری محتوا، ارائه مثال‌های متناسب، طراحی مسیرهای متفاوت یادگیری
تعامل هوشمند و بازخورد یادگیری	گفت‌وگوی آموزشی، بازخورد تکوینی، توضیح گام‌به‌گام	پاسخ‌گویی متناسب با پرسش دانش‌آموز، شناسایی خطاها، ارائه راهنمایی اصلاحی
تقویت خودتنظیمی یادگیری	هدف‌گذاری، برنامه‌ریزی، پایش و خودارزیابی	تعیین اهداف یادگیری، مدیریت زمان، پیگیری پیشرفت و بازاندیشی درباره عملکرد
پشتیبانی از پیشرفت تحصیلی	تسلط مفهومی، حل مسئله، تمرین هدفمند	رفع بدفهمی‌ها، تمرین متناسب با نیاز، بهبود عملکرد در ارزشیابی
حکمرانی مسئولانه و الزامات اجرایی	صحت محتوا، حریم خصوصی، عدالت آموزشی و نقش معلم	بررسی صحت پاسخ‌ها، حفاظت از اطلاعات، دسترس‌پذیری و نظارت آموزشی

بر اساس یافته‌های جدول ۱، مضمون شخصی‌سازی و سازگاری آموزشی بر ضرورت انطباق محتوای آموزشی، سطح دشواری و مسیر یادگیری با ویژگی‌ها و نیازهای فردی دانش‌آموزان تأکید دارد .این مضمون نشان می‌دهد که کارکرد آموزشی هوش مصنوعی مولد صرفاً به تولید محتوا محدود نیست، بلکه توانایی ارائه توضیحات متناسب، تنظیم سطح دشواری و پیشنهاد مسیرهای متفاوت یادگیری نیز در طراحی محیط‌های یادگیری شخصی‌سازی‌شده اهمیت دارد . همچنین، مضمون تعامل هوشمند و بازخورد یادگیری بر نقش گفت‌وگوی آموزشی، بازخورد تکوینی و راهنمایی گام‌به‌گام در شناسایی خطاها و اصلاح فرایند یادگیری دلالت دارد؛ به‌گونه‌ای که دانش‌آموز بتواند در مواجهه با مسائل و مفاهیم دشوار، راهنمایی متناسب با نیاز خود دریافت کند.

مضمون تقویت خودتنظیمی یادگیری نیز بر نقش محیط یادگیری مبتنی بر هوش مصنوعی مولد در حمایت از هدف‌گذاری، برنامه‌ریزی، مدیریت زمان، پایش عملکرد و خودارزیابی تأکید می‌کند .اهمیت این مضمون از آن جهت است که اثربخشی یادگیری شخصی‌سازی‌شده صرفاً به کیفیت محتوای ارائه‌شده وابسته نیست، بلکه به میزان مشارکت فعال دانش‌آموز در مدیریت و هدایت فرایند

یادگیری نیز ارتباط دارد .در همین راستا، مضمون پشتیبانی از پیشرفت تحصیلی بر تقویت تسلط مفهومی، توسعه توانایی حل مسئله، ارائه تمرین‌های هدفمند و بهبود عملکرد دانش‌آموز در ارزشیابی‌های آموزشی تمرکز دارد .در نهایت، مضمون حکمرانی مسئولانه و الزامات اجرایی، ضرورت توجه به صحت محتوای تولیدشده، حفاظت از حریم خصوصی، رعایت عدالت آموزشی و حفظ نقش نظارتی و هدایت‌گر معلم را برجسته می‌سازد.

در مجموع، یافته‌های کیفی بیانگر آن است که طراحی مدل یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد مستلزم توجه هم‌زمان به ابعاد فناورانه، آموزشی، شناختی و اخلاقی است .بر این اساس، مدل پیشنهادی باید از یک سو امکان انطباق و تعامل آموزشی متناسب با نیازهای دانش‌آموز را فراهم کند و از سوی دیگر، زمینه تقویت خودتنظیمی یادگیری و بهبود پیشرفت تحصیلی را در چارچوب استفاده مسئولانه از فناوری ایجاد کند .این یافته‌ها مبنای تدوین مدل مفهومی پژوهش و تعیین سازه‌های مورد بررسی در مرحله کمی قرار گرفتند.

پس از شناسایی مضامین اصلی، مضامین فرعی و شاخص‌های مفهومی در مرحله کیفی، در گام بعدی، یافته‌های حاصل از تحلیل مضمون در قالب یک چارچوب مفهومی سازمان‌دهی شدند .هدف از این مرحله، تبدیل نتایج کیفی به سازه‌هایی مشخص و قابل سنجش بود تا امکان بررسی تجربی روابط میان یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد، خودتنظیمی یادگیری و پیشرفت تحصیلی دانش‌آموزان فراهم شود .در این فرایند، ضمن توجه به پیوند مفهومی میان مضامین استخراج‌شده، تعریف عملیاتی هر سازه و جایگاه آن در ساختار پیشنهادی پژوهش مشخص شد .همچنین، الزامات مسئولانه اجرا به‌عنوان مجموعه‌ای از ملاحظات ناظر بر طراحی و به‌کارگیری مدل در نظر گرفته شد تا ابعاد اخلاقی، آموزشی و اجرایی استفاده از هوش مصنوعی مولد در محیط مدرسه نیز مورد توجه قرار گیرد.

جدول ۲. سازه‌ها و تعریف عملیاتی آن‌ها در مدل پیشنهادی

سازه	تعریف عملیاتی	جایگاه در مدل
یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد	میزان انطباق محتوا، تعامل و بازخورد هوشمند با نیازهای یادگیری دانش‌آموز	متغیر پیش‌بین
خودتنظیمی یادگیری	توانایی هدف‌گذاری، برنامه‌ریزی، مدیریت زمان، پایش و خودارزیابی یادگیری	متغیر میانجی
پیشرفت تحصیلی	میزان دستیابی دانش‌آموز به اهداف آموزشی بر اساس نمرات یا آزمون معتبر	متغیر پیامد
الزامات مسئولانه اجرا	صحت محتوا، حفاظت از داده‌ها، عدالت آموزشی و نظارت معلم	معیار طراحی و اجرا

مطابق جدول ۲، یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد به‌عنوان متغیر پیش‌بین در نظر گرفته شده است .این سازه میزان انطباق محتوای آموزشی، تعاملات و بازخوردهای هوشمند با نیازها و ویژگی‌های یادگیری دانش‌آموز را منعکس می‌کند .انتظار می‌رود برخورداری از محتوای متناسب، بازخورد هدفمند و راهنمایی آموزشی سازگار با سطح یادگیری، شرایط مساعدتری را برای مشارکت فعال دانش‌آموز در فرایند یادگیری فراهم آورد .در این چارچوب، خودتنظیمی یادگیری به‌عنوان متغیر میانجی تعریف شده است که توانایی دانش‌آموز در هدف‌گذاری، برنامه‌ریزی، مدیریت زمان، پایش عملکرد و خودارزیابی را دربر می‌گیرد .جایگاه این سازه در مدل نشان‌دهنده اهمیت بررسی این موضوع است که آیا یادگیری شخصی‌سازی‌شده می‌تواند از طریق تقویت توانایی دانش‌آموز در مدیریت فرایند یادگیری، با بهبود پیامدهای آموزشی همراه شود یا خیر.

همچنین، پیشرفت تحصیلی به‌عنوان متغیر پیامد مدل در نظر گرفته شده و میزان دستیابی دانش‌آموز به اهداف آموزشی را بر اساس نمرات تحصیلی یا نتایج یک آزمون معتبر نشان می‌دهد .بر این اساس، چارچوب پیشنهادی امکان بررسی رابطه مستقیم یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد با پیشرفت تحصیلی و نیز رابطه غیرمستقیم آن از طریق خودتنظیمی یادگیری را فراهم می‌کند .در کنار این سازه‌ها، الزامات مسئولانه اجرا شامل صحت محتوای تولیدشده، حفاظت از داده‌های دانش‌آموزان، عدالت آموزشی و نظارت معلم، به‌عنوان معیارهایی برای طراحی و اجرای مناسب مدل مشخص شده‌اند .این الزامات در مرحله طراحی و

پیاده‌سازی مدل اهمیت اساسی دارند و باید در تفسیر قابلیت کاربرد آن در محیط‌های آموزشی مورد توجه قرار گیرند.

در مجموع، مدل مفهومی تدوین‌شده بر این فرض استوار است که یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد می‌تواند از طریق انطباق آموزشی و ارائه تعامل و بازخورد متناسب، زمینه تقویت خودتنظیمی یادگیری را فراهم سازد و از این مسیر و همچنین به‌صورت مستقیم، با پیشرفت تحصیلی دانش‌آموزان ارتباط داشته باشد .با این حال، تعیین جهت و شدت روابط و همچنین تأیید نقش میانجی خودتنظیمی یادگیری، مستلزم آزمون تجربی مدل در مرحله کمی است .ازاین‌رو، در مرحله بعد، سازه‌های تعریف‌شده و روابط مفروض میان آن‌ها با استفاده از داده‌های گردآوری‌شده از دانش‌آموزان دوره متوسطه دوم شهر تهران و به‌کارگیری روش مدل‌سازی معادلات ساختاری بررسی می‌شوند تا شواهد لازم برای ارزیابی اعتبار مدل پیشنهادی فراهم شود.

نکته روش‌شناختی مهم :با توجه به عنوان پژوهش که بر »تأثیر «مدل بر خودتنظیمی یادگیری و پیشرفت تحصیلی تأکید دارد، اگر داده‌های مرحله کمی صرفاً از طریق پرسش‌نامه و در یک مقطع زمانی گردآوری شوند، نتایج عمدتاً بیانگر روابط و اثرات آماری برآوردشده خواهند بود و برای اثبات تأثیر علّی، شواهد کافی فراهم نمی‌کنند .همچنین، اگر هدف پژوهش اعتباریابی مدل آموزشی و بررسی تأثیر واقعی آن بر پیامدهای یادگیری باشد، بهتر است اجرای مداخله آموزشی و سنجش پیشرفت تحصیلی و خودتنظیمی یادگیری پیش و پس از مداخله نیز در طراحی پژوهش مدنظر قرار گیرد.

به‌منظور توصیف ویژگی‌های جمعیت‌شناختی شرکت‌کنندگان در بخش کمی پژوهش، توزیع فراوانی و درصد دانش‌آموزان بر حسب جنسیت و پایه تحصیلی بررسی شد .در این مرحله، داده‌های مربوط به ۴۲۰ دانش‌آموز دوره متوسطه دوم شهر تهران مبنای تحلیل قرار گرفتند .بررسی ویژگی‌های جمعیت‌شناختی نمونه، علاوه بر ارائه تصویری کلی از ترکیب پاسخ‌دهندگان، زمینه لازم را برای شناخت توزیع نمونه در طبقات مختلف و تفسیر مناسب‌تر نتایج حاصل از تحلیل‌های آماری فراهم می‌کند.

جدول ۳. توزیع جمعیت‌شناختی نمونه

متغیر	طبقه	فراوانی	درصد
جنسیت	دختر	۲۲۶	۵۳/۸
جنسیت	پسر	۱۹۴	۴۶/۲
پایه تحصیلی	دهم	۱۴۲	۳۳/۸
پایه تحصیلی	یازدهم	۱۴۱	۳۳/۶
پایه تحصیلی	دوازدهم	۱۳۷	۳۲/۶
مجموع		۴۲۰	۱۰۰

مطابق نتایج جدول ۳، از مجموع ۴۲۰ دانش‌آموز شرکت‌کننده در پژوهش، ۲۲۶ نفر معادل ۵۳/۸ درصد دختر و ۱۹۴ نفر معادل ۴۶/۲ درصد پسر بودند .بنابراین، سهم دانش‌آموزان دختر در نمونه اندکی بیشتر از دانش‌آموزان پسر بود .از نظر پایه تحصیلی نیز، ۱۴۲ نفر معادل ۳۳/۸ درصد در پایه دهم، ۱۴۱ نفر معادل ۳۳/۶ درصد در پایه یازدهم و ۱۳۷ نفر معادل ۳۲/۶ درصد در پایه دوازدهم تحصیل می‌کردند .توزیع نسبتاً نزدیک فراوانی‌ها در سه پایه تحصیلی نشان می‌دهد که نمونه پژوهش از نظر این ویژگی، از پراکندگی مناسبی برخوردار بوده است .در مجموع، ترکیب جمعیت‌شناختی نمونه امکان بررسی مدل پیشنهادی را در میان دانش‌آموزان هر سه پایه دوره متوسطه دوم فراهم می‌کند؛ هرچند تعمیم نتایج به کل جامعه آماری، علاوه بر ترکیب نمونه، به روش نمونه‌گیری و میزان نمایندگی آن نیز وابسته است.

به‌منظور توصیف وضعیت متغیرهای اصلی پژوهش، شاخص‌های آمار توصیفی شامل میانگین و انحراف معیار برای سه سازه یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد، خودتنظیمی یادگیری و پیشرفت تحصیلی محاسبه شد .میانگین، سطح کلی مقادیر مشاهده‌شده برای هر سازه را نشان می‌دهد و انحراف معیار بیانگر میزان پراکندگی پاسخ‌ها پیرامون میانگین است .نتایج این تحلیل، تصویری اولیه از وضعیت متغیرهای پژوهش پیش از بررسی روابط ساختاری میان آن‌ها ارائه می‌کند.

جدول ۴. آمار توصیفی سازه‌های پژوهش

سازه	میانگین	انحراف معیار
یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد	۳/۷۲	۰/۷۱
خودتنظیمی یادگیری	۳/۵۸	۰/۶۸
پیشرفت تحصیلی	۳/۶۴	۰/۷۵

بر اساس نتایج جدول ۴، میانگین یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد برابر با ۳/۷۲ و انحراف معیار آن ۰/۷۱ بود .در میان سازه‌های بررسی‌شده، این متغیر بالاترین میانگین را به خود اختصاص داد .میانگین خودتنظیمی یادگیری برابر با ۳/۵۸ و انحراف معیار آن ۰/۶۸ به دست آمد .همچنین، میانگین پیشرفت تحصیلی ۳/۶۴ و انحراف معیار آن ۰/۷۵ گزارش شد .این نتایج نشان می‌دهد که میانگین مقادیر مشاهده‌شده برای هر سه سازه به یکدیگر نزدیک است و بیشترین پراکندگی پاسخ‌ها به سازه پیشرفت تحصیلی مربوط می‌شود.

با توجه به نزدیکی میانگین‌های گزارش‌شده، می‌توان گفت که از نظر توصیفی تفاوت چشمگیری میان مقادیر مرکزی سه سازه مشاهده نمی‌شود .بااین‌حال، تفسیر سطح میانگین‌ها به دامنه و مقیاس اندازه‌گیری ابزار بستگی دارد و برای تعیین بالا یا پایین بودن قطعی آن‌ها، باید مقیاس پاسخ‌گویی و نقاط برش معتبر مشخص باشند .

همچنین، آمار توصیفی به‌تنهایی درباره معناداری روابط یا تأثیر یک سازه بر سازه دیگر داوری نمی‌کند؛ ازاین‌رو، بررسی کیفیت ابزار اندازه‌گیری و آزمون روابط ساختاری در مراحل بعدی ضروری است.

به‌منظور ارزیابی کیفیت ابزار اندازه‌گیری و اطمینان از مناسب بودن سازه‌های پژوهش برای ورود به مرحله تحلیل مدل ساختاری، شاخص‌های پایایی و روایی همگرای متغیرها بررسی شدند .برای سنجش پایایی، آلفای کرونباخ و پایایی ترکیبی و برای ارزیابی روایی همگرا، میانگین واریانس استخراج‌شده محاسبه شد .آلفای کرونباخ و پایایی ترکیبی میزان هماهنگی درونی گویه‌های مرتبط با هر سازه را ارزیابی می‌کنند؛ درحالی‌که میانگین واریانس استخراج‌شده نشان می‌دهد چه میزان از واریانس گویه‌های هر سازه به‌وسیله همان سازه تبیین می‌شود.

جدول ۵. شاخص‌های پایایی و روایی همگرای سازه‌ها

سازه	آلفای کرونباخ	پایایی ترکیبی	میانگین واریانس استخراج‌شده
یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد	۰/۸۹	۰/۹۲	۰/۶۶
خودتنظیمی یادگیری	۰/۸۷	۰/۹۰	۰/۶۴
پیشرفت تحصیلی	۰/۸۴	۰/۸۸	۰/۶۱

نتایج جدول ۵ نشان می‌دهد که آلفای کرونباخ برای سازه یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد برابر با ۰/۸۹، برای خودتنظیمی یادگیری برابر با ۰/۸۷ و برای پیشرفت تحصیلی برابر با ۰/۸۴ است .همچنین، مقادیر پایایی ترکیبی به‌ترتیب ۰/۹۲، ۰/۹۰ و ۰/۸۸ گزارش شده‌اند .ازآنجاکه تمامی مقادیر آلفای کرونباخ و پایایی ترکیبی از آستانه متعارف ۰/۷۰ بیشتر هستند، نتایج اولیه حاکی از برخورداری هر سه سازه از پایایی درونی قابل‌قبول است.

از نظر روایی همگرا نیز، مقادیر میانگین واریانس استخراج‌شده برای یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد، خودتنظیمی یادگیری و پیشرفت تحصیلی به‌ترتیب برابر با ۰/۶۶، ۰/۶۴ و ۰/۶۱ به دست آمده‌اند .با توجه به اینکه همه این مقادیر از حد پیشنهادی ۰/۵۰ بیشتر هستند، می‌توان نتیجه گرفت که سازه‌ها از روایی همگرای قابل‌قبولی برخوردارند؛ به این معنا که هر سازه توانسته است بخش مناسبی از واریانس گویه‌های مربوط به خود را تبیین کند.

در مجموع، شاخص‌های گزارش‌شده شواهد اولیه مناسبی از پایایی و روایی همگرای ابزار اندازه‌گیری فراهم می‌کنند .بااین‌حال، برای تأیید کامل کیفیت مدل اندازه‌گیری، بررسی بارهای عاملی گویه‌ها و روایی واگرا نیز ضروری است .پس از بررسی این شاخص‌ها، می‌توان برازش مدل و روابط میان سازه‌های پژوهش را با اطمینان بیشتری ارزیابی کرد.

پس از بررسی شاخص‌های پایایی و روایی سازه‌ها، برازش مدل پیشنهادی مورد ارزیابی قرار گرفت تا میزان انطباق ساختار نظری پژوهش با داده‌های گردآوری‌شده مشخص شود .در این مرحله، شاخص‌های مختلف برازش شامل نسبت کای‌دو به درجه آزادی، شاخص برازش تطبیقی، شاخص تاکر ـ لوئیس، ریشه میانگین مربعات خطای برآورد و ریشه میانگین مربعات باقیمانده استانداردشده بررسی شدند .استفاده هم‌زمان از این شاخص‌ها امکان ارزیابی مدل از جنبه‌های مختلف را فراهم می‌کند و از اتکای نتیجه‌گیری به یک شاخص منفرد جلوگیری می‌کند.

جدول ۶. شاخص‌های برازش مدل ساختاری

شاخص	مقدار
کای‌دو به درجه آزادی	۲/۱۸
شاخص برازش تطبیقی	۰/۹۵
شاخص تاکر ـ لوئیس	۰/۹۴
ریشه میانگین مربعات خطای برآورد	۰/۰۵۳
ریشه میانگین مربعات باقیمانده استانداردشده	۰/۰۴۱

مطابق نتایج جدول ۶، نسبت کای‌دو به درجه آزادی برابر با ۲/۱۸ گزارش شده است که در محدوده قابل‌قبول متعارف قرار دارد . شاخص برازش تطبیقی (CFI)برابر با ۰/۹۵ و شاخص تاکر ـ لوئیس (TLI)برابر با ۰/۹۴ به دست آمده‌اند .این مقادیر نشان می‌دهند که مدل از برازش تطبیقی مطلوبی برخوردار است؛ به‌ویژه آنکه مقدار CFIبه آستانه ۰/۹۵ رسیده و مقدار TLIنیز به این سطح نزدیک است .همچنین، مقدار ریشه میانگین مربعات خطای برآورد (RMSEA)برابر با ۰/۰۵۳ است که بیانگر خطای تقریبی پایین و برازش قابل‌قبول مدل است .مقدار ریشه میانگین مربعات باقیمانده استانداردشده (SRMR)نیز برابر با ۰/۰۴۱ گزارش شده که از حد متعارف ۰/۰۸ کمتر است و با برازش مناسب مدل سازگاری دارد.

در مجموع، الگوی مقادیر شاخص‌های گزارش‌شده حاکی از آن است که مدل پیشنهادی از برازش کلی قابل‌قبولی برخوردار است و ساختار مفروض آن با داده‌های مشاهده‌شده سازگاری مناسبی دارد . بر این اساس، بررسی ضرایب مسیر و روابط میان متغیرهای پژوهش در مرحله بعد قابل انجام است .البته، تأیید برازش کلی به‌تنهایی به معنای تأیید همه فرضیه‌ها یا اثبات روابط علّی نیست؛ بلکه لازم است معناداری ضرایب مسیر، جهت روابط و اندازه اثرهای مستقیم و غیرمستقیم نیز به‌صورت جداگانه بررسی شوند.

به‌منظور آزمون روابط مفروض در مدل مفهومی پژوهش، ضرایب مسیر استانداردشده و شاخص‌های معناداری آماری مربوط به روابط میان یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد، خودتنظیمی یادگیری و پیشرفت تحصیلی بررسی شدند .در این مرحله، سه مسیر ساختاری شامل رابطه یادگیری شخصی‌سازی‌شده با خودتنظیمی یادگیری، رابطه خودتنظیمی یادگیری با پیشرفت تحصیلی و رابطه مستقیم یادگیری شخصی‌سازی‌شده با پیشرفت تحصیلی مورد آزمون قرار گرفتند .ضرایب استانداردشده، جهت و شدت نسبی روابط را نشان می‌دهند و آماره آزمون و سطح معناداری برای ارزیابی شواهد آماری مربوط به هر مسیر به کار می‌روند.

جدول ۷. ضرایب مسیر مدل ساختاری

مسیر ساختاری	ضریب استانداردشده	آماره آزمون	سطح معناداری
یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد به خودتنظیمی یادگیری	۰/۶۲	۱۰/۴۰	کمتر از ۰/۰۰۱
خودتنظیمی یادگیری به پیشرفت تحصیلی	۰/۳۸	۶/۷۰	کمتر از ۰/۰۰۱
یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد به پیشرفت تحصیلی	۰/۲۱	۳/۵۰	۰/۰۰۱

بر اساس نتایج جدول ۷، ضریب مسیر یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد به خودتنظیمی یادگیری برابر با ۰/۶۲ و آماره آزمون آن برابر با ۱۰/۴۰ است .سطح معناداری این رابطه کمتر از ۰/۰۰۱ گزارش شده است؛ بنابراین، رابطه مثبت و معناداری میان این دو سازه مشاهده می‌شود .این نتیجه نشان می‌دهد که با افزایش نمره یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد، نمره

خودتنظیمی یادگیری نیز، در چارچوب مدل برآوردشده، افزایش می‌یابد .در میان مسیرهای بررسی‌شده، این رابطه بالاترین ضریب استانداردشده را به خود اختصاص داده است.

همچنین، ضریب مسیر خودتنظیمی یادگیری به پیشرفت تحصیلی برابر با ۰/۳۸ و آماره آزمون آن برابر با ۶/۷۰ به دست آمده است .با توجه به سطح معناداری کمتر از ۰/۰۰۱، این رابطه نیز مثبت و از نظر آماری معنادار است .این یافته بیانگر آن است که خودتنظیمی یادگیری با پیشرفت تحصیلی رابطه مثبت دارد؛ به این معنا که سطوح بالاتر هدف‌گذاری، برنامه‌ریزی، پایش و خودارزیابی یادگیری با مقادیر بالاتر پیشرفت تحصیلی در مدل همراه هستند.

افزون بر این، ضریب مسیر مستقیم یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد به پیشرفت تحصیلی برابر با ۰/۲۱ و آماره آزمون آن برابر با ۳/۵۰ گزارش شده است .سطح معناداری این مسیر ۰/۰۰۱ است؛ بنابراین، رابطه مستقیم میان دو سازه نیز از نظر آماری معنادار و مثبت است .این نتیجه نشان می‌دهد که ارتباط یادگیری شخصی‌سازی‌شده با پیشرفت تحصیلی صرفاً به مسیر مرتبط با خودتنظیمی یادگیری محدود نیست و در مدل ساختاری، یک مسیر مستقیم نیز میان این دو متغیر وجود دارد.

جدول ۸. اثرات مستقیم، غیرمستقیم و کل در مدل ساختاری

نوع اثر	مسیر	مقدار
اثر مستقیم	یادگیری شخصی‌سازی‌شده به پیشرفت تحصیلی	۰/۲۱۰
اثر غیرمستقیم	یادگیری شخصی‌سازی‌شده از طریق خودتنظیمی یادگیری به پیشرفت تحصیلی	۰/۲۳۶
اثر کل	مجموع اثر مستقیم و غیرمستقیم	۰/۴۴۶

مطابق نتایج جدول ۸، اثر مستقیم یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد بر پیشرفت تحصیلی برابر با ۰/۲۱۰ گزارش شده است .این مقدار نشان‌دهنده وجود رابطه مستقیم مثبت میان این دو سازه، با کنترل مسیر میانجی در مدل، است .همچنین، اثر غیرمستقیم یادگیری شخصی‌سازی‌شده بر پیشرفت تحصیلی از طریق خودتنظیمی یادگیری برابر با ۰/۲۳۶ به دست آمده است .مثبت بودن این مقدار نشان می‌دهد که مسیر غیرمستقیم مفروض با جهت روابط برآوردشده در مدل سازگار است؛ به این معنا که یادگیری شخصی‌سازی‌شده با خودتنظیمی یادگیری رابطه مثبت دارد و خودتنظیمی یادگیری نیز با پیشرفت تحصیلی مرتبط است.

در مجموع، هر سه مسیر ساختاری بررسی‌شده مثبت و معنادار هستند . یافته‌ها از نقش یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد در تبیین خودتنظیمی یادگیری و پیشرفت تحصیلی حمایت می‌کنند و هم‌زمان، اهمیت خودتنظیمی یادگیری را در تبیین پیشرفت تحصیلی نشان می‌دهند .بااین‌حال، برای تعیین اینکه خودتنظیمی یادگیری تا چه اندازه رابطه میان یادگیری شخصی‌سازی‌شده و پیشرفت تحصیلی را توضیح می‌دهد، لازم است اثر غیرمستقیم و اثر کل نیز بررسی شود.

به‌منظور بررسی نقش خودتنظیمی یادگیری در رابطه میان یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد و پیشرفت تحصیلی، اثر مستقیم، اثر غیرمستقیم و اثر کل در مدل ساختاری محاسبه شد .اثر مستقیم نشان‌دهنده رابطه یادگیری شخصی‌سازی‌شده با پیشرفت تحصیلی، مستقل از مسیر میانجی در مدل است .اثر غیرمستقیم از حاصل‌ضرب ضریب مسیر یادگیری شخصی‌سازی‌شده به خودتنظیمی یادگیری در ضریب مسیر خودتنظیمی یادگیری به پیشرفت تحصیلی به دست می‌آید .اثر کل نیز از مجموع اثر مستقیم و غیرمستقیم تشکیل می‌شود و میزان کلی رابطه برآوردشده میان متغیر پیش‌بین و متغیر پیامد را نشان می‌دهد.

اثر کل یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد بر پیشرفت تحصیلی برابر با ۰/۴۴۶ گزارش شده است که از مجموع اثر مستقیم و غیرمستقیم حاصل می‌شود .مقایسه مقادیر نشان می‌دهد که اثر غیرمستقیم برآوردشده، از نظر عددی، اندکی بیشتر از اثر مستقیم است .این الگو بیانگر آن است که مسیر مرتبط با خودتنظیمی یادگیری سهم قابل‌توجهی در رابطه کلی میان یادگیری شخصی‌سازی‌شده و پیشرفت تحصیلی دارد .بنابراین، توجه به سازوکارهای تقویت خودتنظیمی یادگیری می‌تواند در طراحی و اجرای محیط‌های یادگیری مبتنی بر هوش مصنوعی مولد از اهمیت نظری و کاربردی برخوردار باشد.

در مجموع، نتایج اثرهای مستقیم، غیرمستقیم و کل با این تبیین سازگار هستند که یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد می‌تواند هم به‌صورت مستقیم و هم از مسیر خودتنظیمی یادگیری با پیشرفت تحصیلی ارتباط داشته باشد . بااین‌حال، برای نتیجه‌گیری قطعی درباره معناداری اثر میانجی، لازم است معناداری اثر غیرمستقیم به‌طور مستقل، ترجیحاً با استفاده از روش بوت‌استرپ و فاصله اطمینان آن، آزمون شود .صرف مثبت بودن اثر غیرمستقیم یا بزرگ‌تر بودن عددی آن از اثر مستقیم، به‌تنهایی برای تأیید معناداری میانجی‌گری کافی نیست.

مجموع نتایج بخش کمی نشان می‌دهد که ابزار اندازه‌گیری پژوهش، بر اساس شاخص‌های گزارش‌شده، از پایایی و روایی همگرای قابل‌قبولی برخوردار است و شاخص‌های برازش نیز از سازگاری مناسب مدل پیشنهادی با داده‌های مشاهده‌شده حکایت دارند .افزون بر این، هر سه مسیر ساختاری مورد بررسی، شامل رابطه یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد با خودتنظیمی یادگیری، رابطه خودتنظیمی یادگیری با پیشرفت تحصیلی و رابطه مستقیم یادگیری شخصی‌سازی‌شده با پیشرفت تحصیلی، مثبت و از نظر آماری معنادار گزارش شده‌اند .همچنین، اثر غیرمستقیم برآوردشده نشان می‌دهد که خودتنظیمی یادگیری می‌تواند یکی از مسیرهای توضیح‌دهنده رابطه میان یادگیری شخصی‌سازی‌شده و پیشرفت تحصیلی باشد؛ هرچند تأیید آماری نقش میانجی مستلزم آزمون مستقل اثر غیرمستقیم است.

بر این اساس، یافته‌های کمی از مدل پیشنهادی در سطح روابط آماری حمایت می‌کنند و بر اهمیت توجه هم‌زمان به قابلیت‌های شخصی‌سازی آموزشی و فرایندهای خودتنظیمی یادگیری تأکید دارند .بااین‌حال، تفسیر نتایج باید با توجه به روش نمونه‌گیری، شیوه عملیاتی‌سازی پیشرفت تحصیلی و طرح گردآوری داده‌ها انجام شود . چنانچه پژوهش با طرح پیمایشی و بدون مداخله آزمایشی اجرا شده باشد، نتایج بیانگر روابط ساختاری برآوردشده هستند و نباید به‌عنوان اثبات قطعی رابطه علّی یا تأثیر تجربی هوش مصنوعی مولد تفسیر شوند.

بحث و نتیجه‌گیری

پژوهش حاضر با هدف طراحی و اعتباریابی مدل یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد و بررسی رابطه آن با خودتنظیمی یادگیری و پیشرفت تحصیلی دانش‌آموزان انجام شد. نتایج مدل ساختاری نشان داد که یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد با خودتنظیمی یادگیری رابطه مثبت و معناداری دارد و ضریب استانداردشده این مسیر برابر با ۰.۶۲ بود؛ این مقدار در مقایسه با سایر مسیرهای ساختاری مدل، بیشترین ضریب را به خود اختصاص داد. همچنین، خودتنظیمی یادگیری با پیشرفت تحصیلی رابطه مثبت و معناداری داشت و ضریب مسیر آن برابر با ۰.۳۸ بود. افزون بر این، یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد به‌طور مستقیم نیز با پیشرفت تحصیلی رابطه مثبت و معناداری نشان داد و ضریب این مسیر ۰.۲۱ به دست آمد. اثر غیرمستقیم برآوردشده یادگیری شخصی‌سازی‌شده بر پیشرفت تحصیلی از مسیر خودتنظیمی یادگیری برابر با ۰.۲۳۶ و اثر کل برابر با ۰.۴۴۶ بود. این الگو نشان می‌دهد که بخش قابل‌توجهی از رابطه کلی میان یادگیری شخصی‌سازی‌شده و پیشرفت تحصیلی می‌تواند از طریق فرایندهای مرتبط با خودتنظیمی توضیح داده شود، هرچند با توجه به ماهیت غیرآزمایشی داده‌های مرحله کمی، نتایج باید در چارچوب روابط ساختاری و آماری تفسیر شوند و برای تأیید قطعی نقش میانجی، بررسی معناداری اثر غیرمستقیم با روش‌هایی نظیر بوت‌استرپ ضروری است.

نخستین یافته اصلی نشان داد که یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد با خودتنظیمی یادگیری رابطه مثبت و نسبتاً قوی دارد. این نتیجه از نظر نظری قابل انتظار است، زیرا یکی از ویژگی‌های اساسی محیط‌های یادگیری شخصی‌سازی‌شده، فراهم‌کردن امکان هدف‌گذاری، انتخاب مسیر، تنظیم سرعت یادگیری، دریافت بازخورد متناسب و پایش مستمر پیشرفت است؛ یعنی همان فرایندهایی که در قلب خودتنظیمی یادگیری قرار دارند. وقتی دانش‌آموز در محیطی فعالیت می‌کند که محتوا، تمرین، بازخورد و سطح دشواری بر اساس نیازها و عملکرد او تنظیم می‌شوند، فرصت بیشتری برای مقایسه وضعیت فعلی خود با اهداف یادگیری، شناسایی نقاط ضعف، اصلاح راهبردها و تصمیم‌گیری

درباره گام بعدی پیدا می‌کند. در چنین بستری، هوش مصنوعی مولد می‌تواند از یک ابزار صرفاً پاسخ‌گو فراتر رود و به‌عنوان پشتیبان تنظیم فرایند یادگیری عمل کند. این تفسیر با یافته‌های مطالعاتی هماهنگ است که نشان داده‌اند سامانه‌های هوشمند می‌توانند محتوای آموزشی و فعالیت‌ها را با سطح و نیاز یادگیرنده تطبیق دهند و از این طریق زمینه مشارکت فعال‌تر و مدیریت بهتر فرایند یادگیری را فراهم کنند (Hashim et al., 2022; Van Schoors et al., 2021). همچنین، در پژوهش‌های جدیدتر بر این موضوع تأکید شده است که استفاده از هوش مصنوعی در یادگیری تطبیقی می‌تواند از طریق تنظیم پویا و شخصی‌سازی مسیرهای یادگیری، نقش مهمی در افزایش عاملیت و استقلال یادگیرنده داشته باشد (Hernandez-Herrera et al., 2026; Rezaei et al., 2025).

این یافته همچنین با ادبیات مربوط به نقش هوش مصنوعی مولد در تحول آموزش همسو است. هوش مصنوعی مولد به دلیل توانایی در تولید توضیحات جایگزین، مثال‌های متناسب، تمرین‌های هدفمند، پرسش‌های تأملی و بازخورد مرحله‌ای، می‌تواند محیطی فراهم کند که در آن دانش‌آموز تنها مصرف‌کننده محتوا نباشد، بلکه به‌طور فعال درباره نحوه یادگیری خود تصمیم بگیرد. پژوهش‌های موجود نشان داده‌اند که ظرفیت اصلی هوش مصنوعی مولد در آموزش، صرفاً در تولید سریع محتوا خلاصه نمی‌شود، بلکه در ایجاد تعامل انعطاف‌پذیر، پشتیبانی از فرایندهای یادگیری و فراهم‌کردن پاسخ‌های متناسب با نیازهای لحظه‌ای یادگیرنده نیز نمود می‌یابد (Bahroun et al., 2023; Yu & Guo, 2023). بررسی نظام‌مند کاربرد ChatGPT در آموزش نیز نشان داده است که این فناوری می‌تواند در ارائه توضیحات، حمایت از فعالیت‌های یادگیری، تسهیل تعامل آموزشی و پاسخ‌گویی به نیازهای فردی مفید باشد، مشروط بر اینکه استفاده از آن در چارچوب طراحی آموزشی هدفمند صورت گیرد (Montenegro-Rueda et al., 2023). ازاین‌رو، ضریب نسبتاً بالای ۰.۶۲ در مسیر یادگیری شخصی‌سازی‌شده به خودتنظیمی را می‌توان نشانه‌ای از اهمیت پیوند میان قابلیت‌های تطبیقی و تعاملی هوش مصنوعی مولد با توانایی دانش‌آموز برای مدیریت مستقل فرایند یادگیری دانست.

یافته دوم پژوهش نشان داد که خودتنظیمی یادگیری با پیشرفت تحصیلی رابطه مثبت و معناداری دارد. این نتیجه با بدنه گسترده‌ای از شواهد نظری و تجربی سازگار است. دانش‌آموزانی که قادرند اهداف واقع‌بینانه تعیین کنند، برای یادگیری برنامه‌ریزی کنند، راهبردهای مناسب را انتخاب و اجرا نمایند، بر میزان درک خود نظارت داشته باشند و عملکرد خود را ارزیابی کنند، معمولاً بهتر می‌توانند از منابع آموزشی استفاده کنند و در مواجهه با دشواری‌ها، راهبردهای جایگزین به کار گیرند. فراتحلیل انجام‌شده درباره مراحل و راهبردهای خودتنظیمی نشان داد که مؤلفه‌های مختلف این سازه با عملکرد تحصیلی دانش‌آموزان ارتباط معناداری دارند و به‌ویژه خودکارآمدی، راهبردهای انجام تکلیف، پایش و خودارزیابی از عوامل مهم مرتبط با پیشرفت تحصیلی محسوب می‌شوند (Li et al., 2018). افزون بر این، شواهد حاصل از مداخلات خودتنظیمی در محیط‌های برخط و ترکیبی نشان داده‌اند که تقویت این مهارت‌ها می‌تواند به بهبود عملکرد تحصیلی در گروه‌های مختلف یادگیرندگان منجر شود (Xu et al., 2023). بنابراین، ضریب ۰.۳۸ مشاهده‌شده در پژوهش حاضر نشان می‌دهد که حتی در محیط‌های یادگیری مجهز به فناوری هوش مصنوعی، نقش فعال دانش‌آموز در تنظیم فرایند یادگیری همچنان یک عامل اساسی در تبیین عملکرد تحصیلی است.

اهمیت این یافته از آن جهت است که استفاده از هوش مصنوعی مولد لزوماً به‌صورت خودکار به یادگیری بهتر منجر نمی‌شود. اگر دانش‌آموز فاقد مهارت‌های خودتنظیمی باشد، ممکن است از ابزار هوشمند بیشتر برای دریافت پاسخ‌های فوری استفاده کند تا برای فهم عمیق، بازاندیشی یا اصلاح راهبردهای یادگیری. در مقابل، دانش‌آموزی که از توانایی هدف‌گذاری، پایش و خودارزیابی برخوردار است، می‌تواند از هوش مصنوعی به‌عنوان منبعی برای بازخورد، تمرین، توضیح تکمیلی و بررسی میزان تسلط خود استفاده کند. این تبیین با نتایج فراتحلیل Jansen و همکاران همسو است که نشان داد خودتنظیمی یادگیری می‌تواند بخشی از اثر مداخلات آموزشی بر پیشرفت تحصیلی را توضیح دهد و نقش واسطه‌ای مهمی در تبدیل فرصت‌های آموزشی به پیامدهای عملکردی ایفا کند (Jansen et al., 2019). به بیان دیگر، کیفیت فناوری تنها بخشی از معادله است و توانایی یادگیرنده در بهره‌برداری فعال و هدفمند از

فناوری بخش دیگری از آن را تشکیل می‌دهد. در نتیجه، یافته حاضر بر این دیدگاه تأکید دارد که کارآمدی هوش مصنوعی مولد در آموزش زمانی افزایش می‌یابد که طراحی محیط یادگیری به تقویت خودتنظیمی منجر شود، نه اینکه تصمیم‌گیری و تفکر را به‌طور کامل از دانش‌آموز سلب کند.

یافته سوم نشان داد که یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد به‌طور مستقیم نیز با پیشرفت تحصیلی رابطه مثبت و معناداری دارد. اگرچه ضریب این مسیر نسبت به مسیر یادگیری شخصی‌سازی‌شده به خودتنظیمی کمتر بود، مقدار ۰.۲۱ نشان می‌دهد که شخصی‌سازی می‌تواند مستقل از مسیر خودتنظیمی نیز با بهبود عملکرد تحصیلی همراه باشد. این رابطه مستقیم را می‌توان از چند سازوکار توضیح داد. نخست، تنظیم سطح دشواری محتوا می‌تواند از ارائه تکالیفی که بیش از حد آسان یا بیش از حد دشوار هستند جلوگیری کند و دانش‌آموز را در سطح مناسبی از چالش شناختی قرار دهد. دوم، تشخیص سریع خطاها و ارائه توضیح متناسب می‌تواند زمان باقی‌ماندن بدفهمی‌ها را کاهش دهد. سوم، فراهم‌کردن تمرین‌های متعدد و متناسب با نیاز دانش‌آموز می‌تواند فرصت تسلط بر مفاهیم را افزایش دهد. چهارم، دریافت بازخورد سریع می‌تواند به اصلاح فوری پاسخ‌ها و کاهش تکرار خطا منجر شود. نتایج فراتحلیل یادگیری شخصی‌سازی‌شده پشتیبانی‌شده با فناوری نیز نشان داده است که این نوع مداخلات می‌توانند به بهبود پیامدهای یادگیری کمک کنند، به‌ویژه زمانی که فعالیت‌ها بر اساس سطح تسلط و نیازهای واقعی یادگیرنده تنظیم شوند (Major et al., 2021). همچنین، مرور و فراتحلیل پژوهش‌های هوش مصنوعی و علوم محاسباتی در آموزش، شواهدی از ارتباط مثبت این فناوری‌ها با عملکرد دانش‌آموزان گزارش کرده است (García-Martínez et al., 2023).

هم‌راستا با این نتیجه، مطالعات جدید در زمینه یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی نیز بر نقش طراحی مسیرهای آموزشی متناسب با تفاوت‌های فردی در بهبود کیفیت تجربه یادگیری تأکید کرده‌اند (Sa-ad et al., 2025). مدل‌های پیشرفته‌تر مبتنی بر یادگیری عمیق نیز این قابلیت را دارند که الگوهای عملکردی دانش‌آموزان را تحلیل کرده و بر اساس داده‌های موجود، محتوا و مسیر مناسب‌تری برای ادامه یادگیری پیشنهاد کنند (Qiang, 2025). در بافت نظام آموزشی ایران نیز بر ظرفیت هوش مصنوعی برای تحول در شیوه‌های شخصی‌سازی یادگیری و پاسخ‌گویی بهتر به تفاوت‌های فردی دانش‌آموزان تأکید شده است (Sargazi et al., 2025). بر این اساس، مسیر مستقیم مشاهده‌شده در مطالعه حاضر را می‌توان بازتابی از مجموعه‌ای از سازوکارهای شناختی و آموزشی دانست که از طریق آن‌ها انطباق محتوا، سطح دشواری، نوع بازخورد و تعامل آموزشی می‌توانند بدون وابستگی کامل به خودتنظیمی، با عملکرد تحصیلی بهتر همراه شوند.

یافته مربوط به اثر غیرمستقیم نیز از اهمیت ویژه‌ای برخوردار است. اثر غیرمستقیم یادگیری شخصی‌سازی‌شده بر پیشرفت تحصیلی از طریق خودتنظیمی برابر با ۰.۲۳۶ بود که از نظر عددی اندکی بزرگ‌تر از اثر مستقیم ۰.۲۱ بود. این الگو نشان می‌دهد که مسیر مرتبط با خودتنظیمی سهم قابل‌توجهی در ارتباط کلی میان یادگیری شخصی‌سازی‌شده و پیشرفت تحصیلی دارد. به عبارت دیگر، بخشی از فایده بالقوه یک محیط شخصی‌سازی‌شده ممکن است نه صرفاً به دلیل ارائه محتوای بهتر، بلکه به این دلیل باشد که چنین محیطی دانش‌آموز را به برنامه‌ریزی، پایش، خودارزیابی و مدیریت فعال یادگیری تشویق می‌کند. این تفسیر با شواهد فراتحلیلی درباره نقش خودتنظیمی در پیوند میان مداخلات آموزشی و پیشرفت تحصیلی هم‌راستا است (Jansen et al., 2019). همچنین، مطالعات خودتنظیمی نشان می‌دهند که وقتی محیط‌های آموزشی فرصت تمرین، بازخورد و کنترل بیشتر بر فرایند یادگیری را فراهم می‌کنند، احتمال رشد مهارت‌های خودتنظیمی و انتقال این مهارت‌ها به عملکرد تحصیلی افزایش می‌یابد (Li et al., 2018; Xu et al., 2023). بااین‌حال، از آنجا که معناداری اثر غیرمستقیم در مطالعه حاضر با بوت‌استرپ گزارش نشده است، این نتیجه باید به‌عنوان شواهدی سازگار با یک مسیر میانجی تفسیر شود و نه تأیید قطعی میانجی‌گری آماری.

اثر کل ۰.۴۴۶ نیز نشان می‌دهد که یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد، با در نظر گرفتن مسیر مستقیم و مسیر مرتبط با خودتنظیمی، ارتباط قابل‌توجهی با پیشرفت تحصیلی دارد. این یافته بر ضرورت نگاه سیستمی به کاربرد هوش مصنوعی در آموزش

تأکید می‌کند. اگر استفاده از هوش مصنوعی تنها به تولید سریع پاسخ یا ارائه محتوای بیشتر محدود شود، ممکن است بخشی از ظرفیت آموزشی آن بالفعل نشود. در مقابل، زمانی که فناوری در چارچوبی طراحی شود که تشخیص نیاز، انطباق محتوا، تعامل، بازخورد، تمرین، خودارزیابی و تصمیم‌گیری مستقل را به هم پیوند دهد، امکان دستیابی به پیامدهای آموزشی مطلوب‌تر افزایش می‌یابد. پژوهش‌های مربوط به بازخورد خودکار نیز نشان داده‌اند که ارزش آموزشی فناوری بیش از آنکه به سرعت پاسخ‌گویی وابسته باشد، به کیفیت اطلاعات ارائه‌شده برای اصلاح عملکرد و هدایت گام بعدی یادگیری مرتبط است (Cavalcanti et al., 2021). همچنین، بررسی نقش هوش مصنوعی برای معلمان نشان می‌دهد که استفاده از فناوری زمانی اثربخش‌تر است که در خدمت تصمیم‌های آموزشی معلم، شناسایی نیازهای یادگیرنده و طراحی فعالیت‌های هدفمند قرار گیرد (Celik et al., 2022).

در عین حال، نتایج پژوهش نباید به معنای جایگزینی معلم یا واگذاری کامل فرایند یادگیری به هوش مصنوعی تفسیر شوند. شخصی‌سازی مؤثر نیازمند نظارت آموزشی، بررسی صحت محتوا و هدایت دانش‌آموز در استفاده انتقادی از فناوری است. پژوهش‌های حوزه اخلاق هوش مصنوعی در مدارس نشان داده‌اند که سوگیری، حریم خصوصی، شفافیت، نابرابری دسترسی و مسئولیت‌پذیری از مسائل اساسی استفاده از این فناوری در محیط‌های K–12 هستند (Akgun & Greenhow, 2022). راهنمای یونسکو نیز بر حفظ رویکرد انسان‌محور، تناسب سنی، حفاظت از داده‌های یادگیرندگان و اعتبارسنجی خروجی‌های تولیدشده تأکید دارد (Miao & Holmes, 2023). از سوی دیگر، مرور وضعیت هوش مصنوعی در آموزش نشان می‌دهد که با وجود گسترش سریع ابزارها، کیفیت شواهد تجربی هنوز در همه زمینه‌ها یکسان نیست و نباید صرف جذابیت یا نوآوری فناوری را معادل اثربخشی آموزشی دانست (Crompton & Burke, 2023). بنابراین، نتیجه پژوهش حاضر بیش از آنکه تأییدی بر استفاده نامحدود از هوش مصنوعی مولد باشد، از طراحی هدفمند، نظارت‌شده و مبتنی بر اصول آموزشی حمایت می‌کند.

از منظر روش‌شناختی نیز پژوهش حاضر با استفاده از طرح آمیخته اکتشافی متوالی تلاش کرد ابتدا مؤلفه‌های مدل را در مرحله کیفی شناسایی و سپس روابط میان سازه‌ها را در مرحله کمی آزمون کند. چنین رویکردی برای پدیده‌های چندبعدی مناسب است، زیرا امکان می‌دهد مدل تنها بر مفروضات نظری از پیش تعیین‌شده استوار نباشد و در عین حال، مؤلفه‌های شناسایی‌شده در مرحله بعد به‌صورت تجربی مورد ارزیابی قرار گیرند. استفاده از رویکردهای آمیخته برای طراحی و تبیین مدل‌های مفهومی در پژوهش‌های رفتاری و سازمانی پیش‌تر نیز به‌عنوان راهی برای پیوند میان اکتشاف کیفی و آزمون کمی به کار رفته است (Kermanian et al., 2023). در مجموع، نتایج مطالعه حاضر نشان می‌دهد که یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد می‌تواند با خودتنظیمی بیشتر و پیشرفت تحصیلی بالاتر همراه باشد و خودتنظیمی نیز به‌عنوان یکی از سازوکارهای مهم در این رابطه مطرح است. بنابراین، ارزش آموزشی هوش مصنوعی مولد را باید نه صرفاً در قدرت تولید محتوا، بلکه در ظرفیت آن برای ایجاد محیطی انعطاف‌پذیر، تعاملی و حمایت‌کننده از عاملیت یادگیرنده جست‌وجو کرد.

محدودیت‌های پژوهش حاضر باید در تفسیر یافته‌ها مورد توجه قرار گیرند. نخست، داده‌های مرحله کمی در یک مقطع زمانی گردآوری شده‌اند و بنابراین، با وجود استفاده از مدل‌سازی معادلات ساختاری، امکان استنباط علی قطعی درباره تأثیر یادگیری شخصی‌سازی‌شده مبتنی بر هوش مصنوعی مولد بر خودتنظیمی یا پیشرفت تحصیلی وجود ندارد. دوم، جامعه پژوهش به دانش‌آموزان دوره متوسطه دوم شهر تهران محدود بود و ازاین‌رو، تعمیم نتایج به سایر مقاطع تحصیلی، مناطق جغرافیایی یا بافت‌های آموزشی باید با احتیاط انجام شود. سوم، بخشی از متغیرهای پژوهش بر اساس ابزارهای خودگزارشی اندازه‌گیری شدند که ممکن است تحت تأثیر خطای پاسخ، تمایل به ارائه پاسخ اجتماعی مطلوب یا ادراک ذهنی دانش‌آموزان قرار گرفته باشند. چهارم، تفاوت در میزان آشنایی، دسترسی و تجربه قبلی دانش‌آموزان در استفاده از ابزارهای هوش مصنوعی ممکن است بر پاسخ‌های آنان اثر گذاشته باشد. پنجم، اگرچه اثر غیرمستقیم در مدل محاسبه شد، برای تأیید آماری کامل نقش میانجی خودتنظیمی لازم است فاصله اطمینان اثر غیرمستقیم از طریق بوت‌استرپ بررسی شود. همچنین، عواملی مانند انگیزش

تحصیلی، سواد دیجیتال، خودکارآمدی، حمایت معلم، وضعیت اقتصادی ـ اجتماعی و کیفیت دسترسی به فناوری در مدل حاضر وارد نشده‌اند و ممکن است بخشی از روابط مشاهده‌شده را توضیح دهند.

پیشنهاد می‌شود پژوهش‌های آینده با استفاده از طرح‌های آزمایشی و نیمه‌آزمایشی، مدل پیشنهادی را در قالب یک مداخله آموزشی واقعی اجرا و تغییرات خودتنظیمی و پیشرفت تحصیلی را در مراحل پیش‌آزمون، پس‌آزمون و پیگیری بررسی کنند. همچنین، مطالعه طولی می‌تواند برای تعیین جهت زمانی روابط میان استفاده از محیط‌های شخصی‌سازی‌شده، رشد خودتنظیمی و پیامدهای تحصیلی به کار رود. پیشنهاد می‌شود نقش میانجی خودتنظیمی با استفاده از بوت‌استرپ و فاصله اطمینان مستقیم آزمون شود و متغیرهای تعدیل‌کننده‌ای مانند جنسیت، پایه تحصیلی، میزان سواد دیجیتال، تجربه استفاده از هوش مصنوعی، سطح اولیه پیشرفت تحصیلی و نوع درس نیز مورد بررسی قرار گیرند. تکرار پژوهش در مقاطع ابتدایی، متوسطه اول، مدارس فنی و حرفه‌ای و مناطق مختلف کشور می‌تواند قابلیت تعمیم مدل را روشن‌تر سازد. علاوه بر این، مقایسه انواع ابزارهای هوش مصنوعی مولد، طراحی مطالعات چندگروهی و بررسی داده‌های عینی مانند لاگ‌های تعامل با سامانه، مدت استفاده، الگوهای پرسش‌گری و عملکرد در آزمون‌های استاندارد می‌تواند شواهد دقیق‌تری درباره سازوکارهای واقعی اثربخشی این فناوری فراهم کند.

از نظر کاربردی، پیشنهاد می‌شود مدارس و طراحان آموزشی استفاده از هوش مصنوعی مولد را در قالب یک چارچوب هدایت‌شده و آموزشی تعریف کنند و از تبدیل آن به ابزار صرف پاسخ‌دهی جلوگیری شود. فعالیت‌های مبتنی بر هوش مصنوعی باید به‌گونه‌ای طراحی شوند که دانش‌آموز را به هدف‌گذاری، برنامه‌ریزی، توضیح استدلال، ارزیابی پاسخ‌ها، اصلاح خطا و خودارزیابی وادار کنند. معلمان نیز لازم است برای طراحی دستورهای مناسب، ارزیابی صحت خروجی‌های تولیدشده، تشخیص سوگیری و استفاده از داده‌های حاصل از تعامل دانش‌آموزان آموزش ببینند. توصیه می‌شود سامانه‌های مورد استفاده در مدارس امکان تنظیم سطح دشواری، ارائه بازخورد مرحله‌ای، ثبت پیشرفت و پیشنهاد تمرین متناسب را فراهم کنند و هم‌زمان، کنترل حرفه‌ای معلم بر محتوای آموزشی حفظ شود. حفاظت از اطلاعات دانش‌آموزان، دسترسی عادلانه به فناوری و تدوین دستورالعمل‌های روشن برای استفاده مسئولانه نیز باید بخشی از اجرای مدل باشد. در نهایت، به جای تمرکز صرف بر سرعت دستیابی به پاسخ، معیار ارزیابی موفقیت چنین محیط‌هایی باید رشد استقلال یادگیرنده، کیفیت تفکر، توانایی خودتنظیمی و بهبود پایدار پیشرفت تحصیلی باشد.

تعارض منافع

بین نویسندگان هیچ تعارض منافعی وجود نداشت.

حامی مالی

این پژوهش بدون هیچ حمایت مالی و با هزینه شخصی انجام شد.

ملاحظات اخلاقی

در این مطالعه، اهمیت و ضرورت پژوهش برای نمونه‌ها تشریح و درباره رعایت ملاحظات اخلاقی مانند رازداری، محرمانگی، حفظ حریم نمونه‌ها، آزادی جهت شرکت در پژوهش و انصراف از آن و غیره به آنان اطمینان داده شد.

مشارکت نویسندگان

نویسندگان این مقاله با یکدیگر مشارکت داشتند.

تشکر و قدردانی

بدین وسیله از تمامی افرادی که در مراحل پژوهش همکاری و یاری نمودند تقدیر و تشکر می‌شود.

References

Akgun, S., & Greenhow, C. (2022). Artificial intelligence in education: Addressing ethical challenges in K–12 settings. *Ai and Ethics*, *2*(3), 431-440. https://doi.org/10.1007/s43681-021-00096-7

Bahroun, Z., Anane, C., Ahmed, V., & Zacca, A. (2023). Transforming education: A comprehensive review of generative artificial intelligence in educational settings through bibliometric and content analysis. *Sustainability*, *15*(17), 12983. https://doi.org/10.3390/su151712983

Cavalcanti, A. P., Barbosa, A., Carvalho, R., Freitas, F., Tsai, Y. S., Gašević, D., & Mello, R. F. (2021). Automatic feedback in online learning environments: A systematic literature review. *Computers and Education: Artificial Intelligence*, *2*, 100027. https://doi.org/10.1016/j.caeai.2021.100027

Celik, I., Dindar, M., Muukkonen, H., & Järvelä, S. (2022). The promises and challenges of artificial intelligence for teachers: A systematic review of research. *TechTrends*, *66*, 616-630. https://doi.org/10.1007/s11528-022-00715-y

Crompton, H., & Burke, D. (2023). Artificial intelligence in higher education: The state of the field. *International Journal*

of Educational Technology in Higher Education, *20*, 22. https://doi.org/10.1186/s41239-023-00392-8

García-Martínez, I., Fernández-Batanero, J. M., Fernández-Cerero, J., & León, S. P. (2023). Analysing the impact of artificial intelligence and computational sciences on student performance: Systematic review and meta-analysis. *Journal of New Approaches in Educational Research*, *12*, 171-197. https://doi.org/10.7821/naer.2023.1.1240

Hashim, S., Omar, M. K., Jalil, H. A., & Sharef, N. M. (2022). Trends on technologies and artificial intelligence in education for personalized learning: Systematic literature review. *International Journal of Academic Research in Progressive Education and Development*, *11*(1), 884-903. https://doi.org/10.6007/IJARPED/v11-i1/12230

Hernandez-Herrera, J. R., Ortiz-Bejar, J., & Ortiz-Bejar, J. (2026). Adaptive and Personalized Learning in Higher Education: An Artificial Intelligence-Based Approach. *Education Sciences*, *16*(1), 109. https://doi.org/10.3390/educsci16010109

Jansen, R. S., van Leeuwen, A., Janssen, J., Jak, S., & Kester, L. (2019). Self-regulated learning partially mediates the effect of self-regulated learning interventions on achievement in higher education: A meta-analysis. *Educational Research Review*, *28*, 100292. https://doi.org/10.1016/j.edurev.2019.100292

Kermanian, M., Mohajernia, M., Moghaddam, A., & Abniki, S. (2023). Presenting and explaining a model of healthcare staff turnover during the COVID-19 epidemic: Public hospitals in Tehran. *Public Administration Perspective*, *14*(2), 67-92. https://doi.org/10.48308/jpap.2023.103566

Li, J., Ye, H., Tang, Y., Zhou, Z., & Hu, X. (2018). What are the effects of self-regulation phases and strategies on Chinese students? A meta-analysis of two decades of research on the association between self-regulation and academic performance. *Frontiers in psychology*, *9*, 2434. https://doi.org/10.3389/fpsyg.2018.02434

Major, L., Francis, G. A., & Tsapali, M. (2021). The effectiveness of technology-supported personalised learning in low- and middle-income countries: A meta-analysis. *British Journal of Educational Technology*, *52*(5), 1935-1964. https://doi.org/10.1111/bjet.13116

Miao, F., & Holmes, W. (2023). *Guidance for generative AI in education and research*. https://doi.org/10.54675/EWZM9535

Montenegro-Rueda, M., Fernández-Cerero, J., Fernández-Batanero, J. M., & López-Meneses, E. (2023). Impact of the implementation of ChatGPT in education: A systematic review. *Computers*, *12*(8), 153. https://doi.org/10.3390/computers12080153

Qiang, S. (2025). Deep Learning-Based Modeling Methods in Personalized Education. *Artificial Intelligence Education Studies*, *1*(1), 23-47. https://doi.org/10.6914/aiese.010102

Rezaei, M., Karimi, A., & Sadeghi, H. (2025). Adaptive Learning in the Metaverse: Designing Personalized Learning Paths Using Artificial Intelligence. *Biannual Journal of Educational Measurement*.

Sa-ad, M. M., Abukari, A. M., Korda, D. R., & Owusu-Boateng, O. (2025). Personalized Learning Experiences With Artificial Intelligence. https://doi.org/10.70593/978-93-49307-53-7_2

Sargazi, A., Akati, M., Bolaqi, G., Fatemeh, & Kikha Jaleh, Z. (2025). *The Role of Artificial Intelligence in Transforming Personalized Learning Methods in Iran's Education System* Third International Conference on Smart Technologies in Educational Sciences, Psychology, and Counseling,

Van Schoors, R., Elen, J., Raes, A., & Depaepe, F. (2021). An overview of 25 years of research on digital personalised learning in primary and secondary education: A systematic review of conceptual and methodological trends. *British Journal of Educational Technology*, *52*(5), 1798-1822. https://doi.org/10.1111/bjet.13148

Xu, Z., Zhao, Y., Zhang, B., Liew, J., & Kogut, A. (2023). A meta-analysis of the efficacy of self-regulated learning interventions on academic achievement in online and blended environments in K–12 and higher education. *Behaviour & Information Technology*. https://doi.org/10.1080/0144929X.2022.2151935

Yu, H., & Guo, Y. (2023). Generative artificial intelligence empowers educational reform: Current status, issues, and prospects. *Frontiers in Education*, *8*, 1183162. https://doi.org/10.3389/feduc.2023.1183162