

یادگیری، تربیت و آموزش مدارس در هزاره سوم، دوره دوم، شماره چهارم، سال ۱۴۰۴

تاریخ پذیرش: ۲۳ بهمن ۱۴۰۴

تاریخ بازنگری: ۱۸ بهمن ۱۴۰۴

تاریخ ارسال: ۱۹ آذر ۱۴۰۴

تاریخ چاپ: ۱ اسفند ۱۴۰۴

© ۱۴۰۴ 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.

طراحی چارچوب مفهومی برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی با تأکید بر تحلیل داده‌های یادگیری و تفاوت‌های فردی دانش‌آموزان: مطالعه آمیخته اکتشافی

شیوه استناددهی: رادمهر، علی. (۱۴۰۴). طراحی چارچوب مفهومی برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی با تأکید بر تحلیل داده‌های یادگیری و تفاوت‌های فردی دانش‌آموزان: مطالعه آمیخته اکتشافی، *تربیت و آموزش مدارس در هزاره سوم*، ۲ (۴)، ۲۶-۱.

مشخصات نویسندگان:

۱. علی رادمهر*: هیئت علمی، دانشگاه پیام نور، واحد شهر بابک، کرمان، ایران

*پست الکترونیکی نویسنده مسئول: radmehr@pnu.ac.ir

چکیده

هدف پژوهش حاضر طراحی و اعتبارسنجی چارچوب مفهومی برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی با تأکید بر تحلیل داده‌های یادگیری و تفاوت‌های فردی دانش‌آموزان بود. این پژوهش با رویکرد آمیخته اکتشافی متوالی انجام شد. در مرحله کیفی، ۲۰ نفر از متخصصان برنامه‌ریزی درسی، تکنولوژی آموزشی، هوش مصنوعی در آموزش، سنجش و اندازه‌گیری و تحلیل داده‌های یادگیری در تهران با روش نمونه‌گیری هدفمند انتخاب شدند و داده‌ها از طریق مصاحبه‌های نیمه‌ساختاریافته گردآوری و با روش تحلیل مضمون بررسی شدند. بر اساس یافته‌های کیفی، پرسشنامه محقق‌ساخته تدوین و پس از بررسی روایی صوری و محتوایی، در مرحله کمی روی ۴۰۰ دانش‌آموز دوره دوم متوسطه شهر تهران که با روش نمونه‌گیری خوشه‌ای چندمرحله‌ای انتخاب شده بودند، اجرا شد. تحلیل داده‌های کمی شامل بررسی پایایی درونی، پایایی ترکیبی، میانگین واریانس استخراج‌شده و تحلیل عاملی تأییدی بود و برازش مدل با استفاده از شاخص‌های χ^2/df، GFI، AGFI، CFI، TLI، NFI، IFI، RMSEA و SRMR ارزیابی شد. تحلیل کیفی به شناسایی ۱۰ مؤلفه اصلی شامل زیرساخت داده‌محور برنامه درسی، تحلیل داده‌های یادگیری، شناسایی تفاوت‌های فردی، مدل‌سازی پروفایل یادگیرنده، انطباق اهداف و محتوای آموزشی، انطباق راهبردهای تدریس و فعالیت‌های یادگیری، ارزشیابی هوشمند و بازخورد مستمر، تصمیم‌گیری مبتنی بر هوش مصنوعی، نقش معلم و الزامات اخلاقی، امنیتی و حمایتی منجر شد. در مرحله کمی، بارهای عاملی استانداردشده بین ۰.۶۷ تا ۰.۹۱ و ضرایب آلفای کرونباخ بین ۰.۸۶ تا ۰.۹۲ بود. پایایی ترکیبی بین ۰.۸۹ تا ۰.۹۴ و میانگین واریانس استخراج‌شده بین ۰.۶۱ تا ۰.۷۱ به دست آمد. شاخص‌های برازش نیز مناسب بودند: χ^2/df=۲.۱۹، GFI=۰.۹۱، CFI=۰.۹۵، TLI=۰.۹۴، NFI=۰.۹۲، IFI=۰.۹۵، RMSEA=۰.۰۵۵ و SRMR=۰.۰۴۶. یافته‌ها نشان داد که برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی ساختاری چندبعدی، داده‌محور و پویا دارد که در آن تحلیل داده‌های یادگیری و شناسایی تفاوت‌های فردی، مبنای شکل‌گیری پروفایل پویا و تصمیم‌گیری هوشمند برای انطباق عناصر برنامه درسی قرار می‌گیرند و نقش معلم و الزامات اخلاقی به‌عنوان سازوکارهای کنترلی و حمایتی عمل می‌کنند. برازش مناسب مدل نیز قابلیت استفاده از چارچوب پیشنهادی را به‌عنوان مبنایی برای طراحی و توسعه سامانه‌های برنامه‌ریزی درسی هوشمند تأیید کرد.

واژگان کلیدی: برنامه‌ریزی درسی انطباقی، هوش مصنوعی، تحلیل داده‌های یادگیری، تفاوت‌های فردی، یادگیری شخصی‌سازی‌شده، برنامه درسی هوشمند، مطالعه آمیخته اکتشافی

Learning, Training, and Education in Schools in the Third Millennium, Vol. 2, No. 4, Year 2025

Submit Date: 10 December 2025
Revise Date: 07 February 2026
Accept Date: 12 February 2026
Publish Date: 20 February 2026



© 2025 the authors. This is an open access article under the terms of the CC BY-NC 4.0 License.

Designing a Conceptual Framework for AI-Based Adaptive Curriculum Planning with Emphasis on Learning Analytics and Students' Individual Differences: An Exploratory Mixed-Methods Study

How to cite: Radmehr, A. (2025). Designing a Conceptual Framework for AI-Based Adaptive Curriculum Planning with Emphasis on Learning Analytics and Students' Individual Differences: An Exploratory Mixed-Methods Study. *Learning, Training, and Education in Schools in the Third Millennium, 2*(4), 1-26.

Authors' Information:

1. Ali Radmehr*: Faculty Member, Payame Noor University, Shahr-E-Babak Branch, Kerman, Iran

Corresponding author's email: radmehr@pnu.ac.ir

Abstract

This study aimed to design and validate a conceptual framework for AI-based adaptive curriculum planning with emphasis on learning analytics and students' individual differences. An exploratory sequential mixed-methods design was employed. In the qualitative phase, 20 experts in curriculum planning, educational technology, artificial intelligence in education, educational measurement and assessment, and learning analytics in Tehran were selected through purposive sampling. Data were collected through semi-structured interviews and analyzed using thematic analysis. Based on the qualitative findings, a researcher-developed questionnaire was constructed and its face and content validity were examined. In the quantitative phase, the questionnaire was administered to 400 upper-secondary students in Tehran selected through multistage cluster sampling. Quantitative analyses included internal consistency reliability, composite reliability, average variance extracted, and confirmatory factor analysis. Model fit was assessed using χ^2/df, GFI, AGFI, CFI, TLI, NFI, IFI, RMSEA, and SRMR. The qualitative analysis identified 10 major components: data-driven curriculum infrastructure, learning analytics, identification of individual differences, learner-profile modeling, adaptation of learning objectives and instructional content, adaptation of teaching strategies and learning activities, intelligent assessment and continuous feedback, AI-based decision-making, teacher supervision, and ethical, security, and supportive requirements. In the quantitative phase, standardized factor loadings ranged from 0.67 to 0.91 and Cronbach's alpha coefficients ranged from 0.86 to 0.92. Composite reliability values ranged from 0.89 to 0.94, while average variance extracted ranged from 0.61 to 0.71. Model-fit indices indicated satisfactory fit: χ^2/df=2.19, GFI=0.91, CFI=0.95, TLI=0.94, NFI=0.92, IFI=0.95, RMSEA=0.055, and SRMR=0.046. The findings demonstrated that AI-based adaptive curriculum planning is a multidimensional, dynamic, and data-driven system in which learning analytics and individual differences provide the basis for dynamic learner profiling and intelligent adaptation of curriculum components. Teacher supervision and ethical safeguards function as essential regulatory mechanisms. The acceptable psychometric properties and model-fit indices support the proposed framework as a valid foundation for the development of intelligent and personalized curriculum-planning systems.

Keywords: *Adaptive Curriculum Planning, Artificial Intelligence, Learning Analytics, Individual Differences, Personalized Learning, Intelligent Curriculum, Exploratory Mixed-Methods Study*

مقدمه

تحولات شتابان فناوری‌های دیجیتال در دهه اخیر، به‌ویژه گسترش هوش مصنوعی، یادگیری ماشین، تحلیل داده‌های آموزشی و سامانه‌های هوشمند یادگیری، الگوهای سنتی آموزش و برنامه‌ریزی درسی را با تغییرات بنیادین مواجه ساخته است. در الگوهای کلاسیک برنامه‌ریزی درسی، اهداف، محتوا، روش‌های تدریس و شیوه‌های ارزشیابی عموماً برای گروه‌های نسبتاً همگن از دانش‌آموزان طراحی می‌شوند و تفاوت‌های فردی یادگیرندگان تنها در سطح محدودی مورد توجه قرار می‌گیرد. در مقابل، رویکردهای نوین مبتنی بر هوش مصنوعی امکان آن را فراهم کرده‌اند که فرایندهای آموزشی بر اساس داده‌های واقعی حاصل از عملکرد، تعامل، رفتار و پیشرفت هر دانش‌آموز به‌طور مستمر بازتنظیم شوند. در چنین بستری، برنامه درسی از یک ساختار ایستا و از پیش‌تعیین‌شده به نظامی پویا، داده‌محور، پاسخ‌گو و قابل انطباق تبدیل می‌شود که می‌تواند مسیرهای یادگیری متفاوتی را برای دانش‌آموزان با ویژگی‌های متفاوت فراهم سازد. ادبیات هوش مصنوعی در آموزش نیز نشان می‌دهد که استفاده از سامانه‌های هوشمند، ابزارهای تصمیم‌یار، فناوری‌های یادگیری ماشین و محیط‌های یادگیری شخصی‌سازی‌شده می‌تواند شیوه طراحی، اجرا و ارزیابی فرایند آموزشی را به نحو قابل توجهی دگرگون کند (Boulay et al., 2023; Nguyen et al., 2023; Ojha et al., 2023; Yildirim & Celepcikay, 2021).

یکی از مهم‌ترین پیامدهای ورود هوش مصنوعی به حوزه آموزش، حرکت از رویکردهای یکسان‌ساز به سمت یادگیری شخصی‌سازی‌شده و انطباقی است. در یادگیری انطباقی، سامانه آموزشی به‌جای ارائه یک مسیر ثابت برای همه یادگیرندگان، اطلاعات مربوط به سطح دانش، میزان تسلط، سرعت یادگیری، الگوی خطا، علایق، ترجیحات و نیازهای حمایتی هر فرد را تحلیل می‌کند و بر اساس آن، محتوا، سطح دشواری، توالی فعالیت‌ها و نوع بازخورد را تنظیم می‌نماید. این ظرفیت موجب شده است که هوش مصنوعی به‌عنوان ابزاری مؤثر برای کاهش شکاف میان تنوع فردی دانش‌آموزان و ساختارهای استانداردشده برنامه درسی مطرح شود. مطالعات مرتبط با یادگیری شخصی‌سازی‌شده و آموزش مبتنی بر هوش مصنوعی نشان داده‌اند که سامانه‌های تطبیقی می‌توانند با شناسایی سطح واقعی یادگیرنده، منابع متناسب با نیاز او را ارائه دهند و مسیر یادگیری را به‌طور پویا تغییر دهند (Alvarez et al., 2024; Galaup, 2023; Ivanova, 2023). همچنین، توسعه مدل‌های چندعاملی، سامانه‌های هوشمند آموزشی و ساختارهای مبتنی بر مدل دانش یادگیرنده، زمینه را برای ایجاد محیط‌هایی فراهم کرده است که قادرند تصمیم‌های آموزشی را متناسب با ویژگی‌های فردی به‌صورت مستمر بازتنظیم کنند (Elhaimeur & Chrisochoides, 2026; Ivanova, 2026).

در این میان، تحلیل داده‌های یادگیری یکی از ارکان اساسی برنامه‌ریزی درسی انطباقی محسوب می‌شود. سامانه‌های دیجیتال آموزشی حجم گسترده‌ای از داده‌ها را درباره مدت زمان حضور در فعالیت‌ها، الگوی پاسخ‌دهی، دفعات خطا، میزان مشارکت، سرعت پیشرفت، توالی انتخاب منابع، تعامل با تکالیف و عملکرد در ارزشیابی‌ها تولید می‌کنند. تحلیل نظام‌مند این داده‌ها امکان شناسایی الگوهای یادگیری، پیش‌بینی مشکلات احتمالی، تشخیص نیازهای آموزشی و ارائه مداخلات هدفمند را فراهم می‌سازد. در واقع، ارزش اصلی هوش مصنوعی در برنامه‌ریزی

درسی زمانی آشکار می‌شود که داده‌های خام آموزشی به اطلاعات قابل تفسیر برای تصمیم‌گیری تبدیل شوند. رویکردهای تحلیلی جدید از تحلیل توصیفی فراتر رفته و به تحلیل‌های تشخیصی، پیش‌بینانه و تجویزی گسترش یافته‌اند؛ به‌گونه‌ای که سامانه نه‌تنها وضعیت گذشته و حال یادگیرنده را توصیف می‌کند، بلکه می‌تواند احتمال موفقیت یا شکست او را پیش‌بینی کرده و گزینه‌های مداخله‌ای مناسب را نیز پیشنهاد دهد (Georgiou, 2026; Mon et al., 2023; Peralta & Martínez, 2024). کاربرد این ظرفیت‌ها در طراحی برنامه درسی می‌تواند تصمیم‌گیری درباره محتوا، زمان‌بندی، سطح پیچیدگی و شیوه حمایت آموزشی را از حالت شهودی به تصمیم‌گیری مبتنی بر شواهد تبدیل کند.

هوش مصنوعی همچنین ظرفیت مهمی برای بازتعریف مفهوم طراحی برنامه درسی دارد. برنامه‌ریزی درسی سنتی معمولاً در سطح کلان و پیش از شروع فرایند تدریس انجام می‌شود، در حالی که محیط‌های هوشمند امکان طراحی مداوم و بازطراحی برنامه درسی در حین اجرا را فراهم می‌کنند. در چنین چارچوبی، برنامه درسی می‌تواند به‌صورت یک نظام باز در نظر گرفته شود که به‌طور مستمر اطلاعات جدید دریافت می‌کند و بر اساس آنها تغییر می‌یابد. پژوهش‌های مرتبط با کاربرد یادگیری ماشین در طراحی برنامه درسی نشان داده‌اند که الگوریتم‌های هوشمند قادرند الگوهای عملکرد دانشجویان یا دانش‌آموزان را تحلیل کرده و از این اطلاعات برای اصلاح توالی موضوعات، پیشنهاد منابع تکمیلی و تنظیم فعالیت‌های یادگیری استفاده کنند (Deng, 2024). همچنین، توسعه نظام‌های طراحی برنامه درسی مبتنی بر تحلیل‌های پیشرفته و مدل‌های زبانی بزرگ، چشم‌انداز جدیدی برای تدوین برنامه‌های درسی انعطاف‌پذیر و شخصی‌سازی‌شده ایجاد کرده است (Wang et al., 2025). از این منظر، برنامه‌ریزی درسی انطباقی را می‌توان فرایندی دانست که در آن طراحی، اجرا، پایش و اصلاح برنامه درسی به‌طور همزمان و در تعامل با داده‌های یادگیری انجام می‌شوند.

توجه به تفاوت‌های فردی، بخش دیگری از منطق بنیادین این نوع برنامه‌ریزی است. دانش‌آموزان از نظر دانش پیشین، استعداد، سرعت پردازش اطلاعات، علایق، انگیزش، میزان خودتنظیمی، سبک تعامل با محتوا و نیازهای حمایتی با یکدیگر تفاوت دارند. نادیده گرفتن این تفاوت‌ها می‌تواند به کاهش مشارکت، افت انگیزش و فاصله گرفتن برخی یادگیرندگان از اهداف آموزشی منجر شود. سامانه‌های هوشمند می‌توانند با ایجاد پروفایل پویا برای هر دانش‌آموز، این تفاوت‌ها را در فرایند تصمیم‌گیری آموزشی لحاظ کنند. چنین پروفایلی می‌تواند شامل داده‌های شناختی، رفتاری، عملکردی و حتی الگوهای تعامل دیجیتال باشد و به‌صورت مستمر بر اساس داده‌های جدید به‌روزرسانی شود. تجربه‌های مربوط به نرم‌افزارهای آموزشی مبتنی بر هوش مصنوعی نشان داده‌اند که شخصی‌سازی محتوا و بازخورد زمانی اثربخش‌تر است که بر داده‌های واقعی و مستمر یادگیرنده استوار باشد (Annuš, 2024; Soviak & Antoniv, 2023). در همین راستا، استفاده از فناوری‌های هوشمند در آموزش‌های تخصصی و محیط‌های یادگیری جدید نیز بر ضرورت بازشناسی ویژگی‌های متفاوت یادگیرندگان و طراحی مسیرهای آموزشی متناسب تأکید کرده است (Sun, 2023; Suvendu & S, 2024).

یکی دیگر از ابعاد مهم برنامه‌ریزی درسی انطباقی، قابلیت بازتنظیم عناصر مختلف برنامه درسی است. انطباق نباید تنها به تغییر محتوای آموزشی محدود شود، بلکه می‌تواند اهداف، سطح دشواری، فعالیت‌ها، شیوه ارائه، مدت زمان یادگیری، نوع بازخورد و روش ارزشیابی را نیز

دربرگیرد. به بیان دیگر، یک نظام انطباقی کامل باید بتواند در پاسخ به داده‌های هر دانش‌آموز، مجموعه‌ای از تصمیم‌های هماهنگ درباره اجزای برنامه درسی اتخاذ کند. برای مثال، دانش‌آموزی که در یک مفهوم بنیادی ضعف دارد ممکن است به محتوای جبرانی، فعالیت‌های ساده‌تر و بازخورد فوری نیاز داشته باشد، در حالی که دانش‌آموزی با سطح تسلط بالا می‌تواند به فعالیت‌های پیچیده‌تر و مسیر سریع‌تر هدایت شود. بررسی کاربردهای هوش مصنوعی در تدریس و محیط‌های یادگیری نشان داده است که فناوری‌های هوشمند امکان چنین انعطافی را در مقیاس‌هایی فراهم می‌کنند که در نظام‌های سنتی به دشواری قابل دستیابی است (Alashwal, 2024; Chhatwal et al., 2023; Chopra, 2023).

در عین حال، استفاده از هوش مصنوعی در برنامه‌ریزی درسی تنها یک مسئله فنی نیست و مستلزم بازاندیشی در نقش معلم است. برخلاف دیدگاهی که هوش مصنوعی را جایگزین تصمیم‌گیری انسانی تلقی می‌کند، رویکردهای جدید بر مفهوم «هوش تقویت‌شده» و همکاری میان انسان و سامانه تأکید دارند. در این رویکرد، سامانه هوشمند داده‌ها را پردازش و پیشنهادهای آموزشی تولید می‌کند، اما معلم همچنان نقش اصلی را در تفسیر زمینه آموزشی، شناخت شرایط اجتماعی و عاطفی دانش‌آموز، داوری درباره مناسب بودن پیشنهادها و اصلاح تصمیم‌های الگوریتمی ایفا می‌کند. بنابراین، برنامه‌ریزی درسی انطباقی زمانی می‌تواند از نظر تربیتی معتبر باشد که سازوکارهای نظارت انسانی در آن به‌طور صریح طراحی شده باشند. پژوهش‌های مربوط به طراحی نظام‌های آموزشی مبتنی بر هوش مصنوعی نیز بر ضرورت آماده‌سازی معلمان، توسعه شایستگی‌های دیجیتال و ایجاد ساختارهای نهادی پایدار برای ادغام هوش مصنوعی در آموزش تأکید کرده‌اند (Kesgin, 2025; Yokuş, 2025). همچنین، تجربه طراحی پلتفرم‌های آموزشی هوشمند نشان می‌دهد که اثربخشی فناوری زمانی افزایش می‌یابد که طراحی فنی آن با اصول طراحی آموزشی و نیازهای واقعی یادگیرندگان هماهنگ باشد (Aliyu et al., 2026).

گسترش هوش مصنوعی در آموزش همچنین فرصت‌هایی برای افزایش دسترسی، عدالت و کیفیت آموزشی ایجاد کرده است. در شرایطی که منابع آموزشی و امکان دسترسی به معلمان متخصص به‌طور برابر توزیع نشده‌اند، سامانه‌های هوشمند می‌توانند بخشی از خدمات آموزشی را در مقیاس وسیع‌تری ارائه کنند و امکان دسترسی به محتوای متناسب با نیاز فردی را افزایش دهند. این موضوع به‌ویژه برای نظام‌های آموزشی در اقتصادهای نوظهور اهمیت دارد، زیرا شخصی‌سازی یادگیری می‌تواند بخشی از نابرابری‌های ناشی از تفاوت در منابع، موقعیت جغرافیایی و امکانات آموزشی را کاهش دهد (Mbithi & Maina, 2025). در مقابل، تحقق چنین ظرفیتی نیازمند زیرساخت دیجیتال مناسب، دسترسی عادلانه به فناوری و طراحی سامانه‌هایی است که خود به بازتولید نابرابری منجر نشوند. مطالعات انجام‌شده در زمینه پیامدهای هوش مصنوعی در آموزش عالی نیز نشان می‌دهد که فرصت‌های ناشی از افزایش کارایی، دسترسی و انعطاف‌پذیری همزمان با چالش‌هایی مانند شکاف دیجیتال، آمادگی نهادی و ظرفیت حرفه‌ای کاربران همراه است (Patel & Ragolane, 2024; Wang’ang’a, 2024).

در کنار فرصت‌ها، ملاحظات اخلاقی و امنیتی از اساسی‌ترین چالش‌های برنامه‌ریزی درسی مبتنی بر هوش مصنوعی به شمار می‌روند. سیستم‌های انطباقی برای عملکرد مؤثر به حجم قابل توجهی از داده‌های فردی نیاز دارند و این امر مسائل مهمی درباره حریم خصوصی، مالکیت داده، رضایت آگاهانه، امنیت اطلاعات و حدود دسترسی به داده‌های دانش‌آموزان ایجاد می‌کند. علاوه بر آن، الگوریتم‌هایی که برای توصیه

مسیر یادگیری یا پیش‌بینی عملکرد به کار می‌روند ممکن است تحت تأثیر داده‌های سوگیرانه قرار گرفته و به تصمیم‌هایی منجر شوند که برای برخی گروه‌های دانش‌آموزان ناعادلانه باشد. از این رو، طراحی نظام‌های هوشمند آموزشی باید با اصول شفافیت، قابلیت توضیح، عدالت، پاسخ‌گویی و امکان مداخله انسانی همراه باشد. ادبیات مربوط به عامل‌های آموزشی مبتنی بر هوش مصنوعی بر این نکته تأکید دارد که نوآوری آموزشی بدون توجه به چالش‌های اخلاقی می‌تواند پیامدهای ناخواسته‌ای برای دانش‌آموزان و نهادهای آموزشی ایجاد کند (Córdova-Esparza, 2025). همچنین، توسعه چارچوب‌های انسان‌محور برای سامانه‌های آموزش هوشمند نشان می‌دهد که پایداری، شمول، مسئولیت‌پذیری و رفاه یادگیرندگان باید در کنار عملکرد فنی سامانه مورد توجه قرار گیرد (Triantafyllou, 2026).

از منظر نظام آموزشی، استفاده از هوش مصنوعی مستلزم تغییراتی فراتر از سطح کلاس است. ورود سامانه‌های هوشمند می‌تواند فرایندهای برنامه‌ریزی، مدیریت آموزشی، ارزشیابی، تخصیص منابع و حتی تعریف نقش‌های حرفه‌ای را تحت تأثیر قرار دهد. بنابراین، هوش مصنوعی باید به‌عنوان بخشی از یک اکوسیستم آموزشی در نظر گرفته شود، نه صرفاً یک ابزار منفرد. بررسی پیامدهای تحول‌آفرین هوش مصنوعی برای نظام‌های آموزشی نشان داده است که این فناوری می‌تواند ساختارها، روش‌های تدریس و مدل‌های تصمیم‌گیری را به‌طور همزمان دگرگون کند (Huong, 2024; Іванишко et al., 2024). مطالعات جدیدتر نیز بر این نکته تأکید دارند که طراحی محیط‌های آموزشی هوشمند باید با رویکردی سیستمی انجام شود تا زیرساخت فناوری، اهداف یادگیری، برنامه درسی، سنجش و توسعه حرفه‌ای معلمان در یک چارچوب منسجم قرار گیرند (Xu & Zhang, 2026; Ye et al., 2026).

کاربردهای هوش مصنوعی در حوزه‌های آموزشی تخصصی نیز نشان داده‌اند که اثربخشی این فناوری به میزان هماهنگی آن با منطق رشته، اهداف یادگیری و طراحی آموزشی بستگی دارد. در آموزش زبان، برای نمونه، هوش مصنوعی فرصت‌هایی برای بازخورد سریع، تمرین شخصی‌سازی‌شده و حمایت از یادگیری مستقل فراهم کرده است، اما در عین حال چالش‌هایی در زمینه کیفیت تعامل، وابستگی به فناوری و ملاحظات تربیتی ایجاد می‌کند (Elmadani, 2026). در حوزه‌های دیگری مانند علوم، ریاضیات و آموزش‌های حرفه‌ای نیز سامانه‌های هوشمند توانسته‌اند امکان ایجاد مسیرهای یادگیری متناسب و بازخورد مستمر را فراهم کنند (Alvarez et al., 2024; Kesgin, 2025). این یافته‌ها نشان می‌دهد که برنامه‌ریزی درسی انطباقی نمی‌تواند الگویی یکسان برای همه حوزه‌ها داشته باشد و باید قابلیت انطباق نه‌تنها با تفاوت‌های فردی، بلکه با ویژگی‌های محتوایی و اهداف هر حوزه را نیز دارا باشد.

در سطح فنی، پیشرفت الگوریتم‌های یادگیری ماشین و مدل‌های ترکیبی دانش، ظرفیت سیستم‌های آموزشی را برای تحلیل روابط پیچیده میان متغیرهای یادگیری افزایش داده است. الگوریتم‌های پیش‌بینی می‌توانند احتمال افت یا موفقیت را بر اساس الگوهای رفتاری برآورد کنند و الگوریتم‌های تجویزی می‌توانند بر اساس این پیش‌بینی‌ها، نوع مداخله مناسب را پیشنهاد دهند (Georgiou, 2026). رویکردهای مبتنی بر یادگیری تقویتی نیز این امکان را فراهم می‌کنند که سیستم از پیامدهای تصمیم‌های قبلی بیاموزد و به‌تدریج سیاست‌های آموزشی مؤثرتری را توسعه دهد (Mon et al., 2023). افزون بر این، مدل‌های دانش مبتنی بر هستی‌شناسی و معماری‌های ترکیبی هوش مصنوعی می‌توانند اطلاعات مربوط به مفاهیم آموزشی، ارتباط میان موضوعات و وضعیت دانش هر یادگیرنده را به شکل ساخت‌یافته بازنمایی کنند (Ivanova,

2026). این قابلیت‌ها زمینه شکل‌گیری برنامه‌های درسی واقعاً پویا را فراهم می‌کنند، زیرا تصمیم‌های آموزشی می‌توانند بر پایه ترکیبی از داده‌های عملکردی، ساختار دانش و اهداف برنامه درسی اتخاذ شوند.

با این حال، یکی از چالش‌های مهم در ادبیات موجود، پراکندگی مطالعات میان حوزه‌های مختلف هوش مصنوعی، یادگیری انطباقی، تحلیل یادگیری، سیستم‌های توصیه‌گر و طراحی برنامه درسی است. بسیاری از پژوهش‌ها بر اثربخشی یک ابزار، یک الگوریتم یا یک محیط آموزشی خاص تمرکز کرده‌اند، در حالی که ارتباط نظام‌مند میان داده‌های یادگیری، تفاوت‌های فردی و تصمیم‌های برنامه درسی کمتر در قالب یک چارچوب یکپارچه مورد توجه قرار گرفته است. برای نمونه، برخی مطالعات بر کاربردهای عمومی هوش مصنوعی در آموزش تمرکز دارند (Chembe et al., 2023; Chhatwal et al., 2023)، برخی بر سامانه‌های هوشمند یا معماری‌های شخصی‌سازی متمرکز هستند (Ivanova, 2023; Soviak & Antoniv, 2023) و گروهی دیگر بر تحلیل داده و طراحی یادگیری انطباقی تأکید دارند (Peralta & Martínez, 2024; Wang et al., 2025). در نتیجه، هنوز نیاز به چارچوبی وجود دارد که این حوزه‌ها را در قالب یک منطق منسجم برنامه‌ریزی درسی با یکدیگر پیوند دهد.

از سوی دیگر، یکی از الزامات اساسی چنین چارچوبی، توجه همزمان به کارایی فنی و اعتبار تربیتی است. اگر طراحی برنامه درسی صرفاً بر پیش‌بینی الگوریتمی استوار شود، احتمال دارد عناصر انسانی، زمینه‌ای و ارزشی آموزش نادیده گرفته شوند. برعکس، اگر تصمیم‌گیری صرفاً بر قضاوت انسانی تکیه کند، بخش مهمی از ظرفیت داده‌های گسترده آموزشی مورد استفاده قرار نخواهد گرفت. بنابراین، رویکرد مطلوب باید نوعی تلفیق میان تحلیل هوشمند و قضاوت حرفه‌ای ایجاد کند. مطالعات مربوط به کلاس‌های هوشمند و نظام‌های آموزشی مبتنی بر فناوری نیز نشان داده‌اند که نقش معلم، کیفیت طراحی آموزشی و زمینه نهادی همچنان در تعیین موفقیت یا شکست نوآوری‌های مبتنی بر هوش مصنوعی نقش اساسی دارند (Alashwal, 2024; Chopra, 2023). این موضوع ضرورت طراحی چارچوبی را تقویت می‌کند که هوش مصنوعی را نه جایگزین معلم، بلکه بخشی از یک نظام پشتیبان تصمیم در نظر بگیرد.

همچنین، استفاده از هوش مصنوعی در برنامه‌ریزی درسی باید با ارزیابی مستمر و چرخه بازخورد همراه باشد. انطباق واقعی زمانی رخ می‌دهد که آثار یک تصمیم آموزشی مجدداً اندازه‌گیری و به‌عنوان داده جدید وارد فرایند تصمیم‌گیری شود. در این صورت، سامانه می‌تواند بررسی کند که آیا تغییر محتوا، سطح دشواری یا روش تدریس موجب بهبود یادگیری شده است یا خیر و در صورت نیاز، مسیر را اصلاح کند. این ویژگی، برنامه‌ریزی درسی انطباقی را به یک نظام خوداصلاح‌گر تبدیل می‌کند. تجربه توسعه محیط‌های یادگیری هوشمند و اکوسیستم‌های انطباقی نیز نشان می‌دهد که چرخه مستمر داده، تحلیل، تصمیم، مداخله و بازخورد از عناصر اساسی پایداری چنین سامانه‌هایی است (Elhaimeur & Chrisochoides, 2026; Galaup, 2023). در همین راستا، رویکردهای جدید طراحی سامانه‌های آموزشی تأکید می‌کنند که تحلیل مستمر عملکرد و بازخورد فوری باید در قلب معماری سیستم قرار گیرد، نه آنکه صرفاً به‌عنوان مرحله نهایی ارزشیابی در نظر گرفته شود (Aliyu et al., 2026).

در مجموع، شواهد موجود نشان می‌دهد که هوش مصنوعی ظرفیت قابل توجهی برای تحول در برنامه‌ریزی درسی از طریق شخصی‌سازی، تحلیل داده، پیش‌بینی، بازخورد و تصمیم‌گیری انطباقی دارد؛ با این حال، بهره‌گیری مؤثر از این ظرفیت مستلزم ایجاد چارچوبی است که همزمان داده‌های یادگیری، تفاوت‌های فردی، عناصر برنامه درسی، نقش معلم، سازوکارهای تصمیم‌گیری هوشمند و الزامات اخلاقی و امنیتی را در یک ساختار یکپارچه قرار دهد. تحولات اخیر در حوزه سامانه‌های هوشمند، یادگیری ماشین و طراحی محیط‌های آموزشی نیز نشان می‌دهد که حرکت به سمت چنین الگوهایی نه صرفاً یک انتخاب فناورانه، بلکه بخشی از گذار گسترده‌تر نظام‌های آموزشی به سمت یادگیری انعطاف‌پذیر، داده‌محور و شخصی‌سازی‌شده است (Triantafyllou, 2026; Xu & Zhang, 2026; Ye et al., 2026). از این رو، خلأ اصلی در ادبیات را می‌توان در فقدان یک چارچوب مفهومی جامع دانست که بتواند این عناصر را به‌صورت منسجم و مبتنی بر شواهد در سطح برنامه‌ریزی درسی مدارس تلفیق کند.

هدف پژوهش حاضر طراحی و اعتبارسنجی چارچوب مفهومی برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی با تأکید بر تحلیل داده‌های یادگیری و تفاوت‌های فردی دانش‌آموزان بود.

روش‌شناسی

پژوهش حاضر با هدف طراحی چارچوب مفهومی برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی با تأکید بر تحلیل داده‌های یادگیری و تفاوت‌های فردی دانش‌آموزان، با رویکرد آمیخته اکتشافی متوالی انجام شد. در این طرح، ابتدا مرحله کیفی با هدف شناسایی مؤلفه‌ها، ابعاد، شاخص‌ها و روابط مفهومی مرتبط با برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی اجرا شد و سپس، یافته‌های حاصل از این مرحله در بخش کمی مورد بررسی و اعتبارسنجی قرار گرفت. منطق استفاده از طرح آمیخته اکتشافی آن بود که موضوع برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی، به‌ویژه از منظر تلفیق تحلیل داده‌های یادگیری، ویژگی‌های فردی دانش‌آموزان، تصمیم‌گیری آموزشی و سازوکارهای انطباق برنامه درسی، دارای ماهیتی چندبعدی و نسبتاً نوظهور است و تدوین یک چارچوب مفهومی جامع برای آن مستلزم اکتشاف اولیه مفاهیم و سپس آزمون تجربی ساختار حاصل است. جامعه مشارکت‌کنندگان در مرحله کیفی شامل اعضای هیئت علمی و متخصصان حوزه‌های برنامه‌ریزی درسی، تکنولوژی آموزشی، هوش مصنوعی در آموزش، سنجش و اندازه‌گیری آموزشی و تحلیل داده‌های یادگیری در شهر تهران بود. مشارکت‌کنندگان این مرحله با استفاده از روش نمونه‌گیری هدفمند و بر اساس معیار برخورداری از دانش تخصصی و تجربه علمی یا اجرایی مرتبط با موضوع پژوهش انتخاب شدند. معیارهای ورود شامل داشتن حداقل مدرک دکتری در یکی از حوزه‌های مرتبط یا برخورداری از سابقه حرفه‌ای قابل توجه در طراحی و اجرای سامانه‌های یادگیری هوشمند، داشتن حداقل پنج سال سابقه آموزشی، پژوهشی یا اجرایی مرتبط و تمایل به مشارکت در مصاحبه بود. فرایند نمونه‌گیری تا دستیابی به اشباع نظری ادامه یافت و در نهایت ۲۰ نفر در مرحله کیفی پژوهش مشارکت کردند. پس از انجام مصاحبه هجدهم، داده‌های جدید موجب شکل‌گیری مقوله اساسی تازه‌ای نشد؛ با این حال، دو مصاحبه تکمیلی نیز به‌منظور اطمینان از کفایت داده‌ها و تثبیت اشباع نظری انجام شد.

در مرحله کمی، جامعه آماری شامل دانش‌آموزان دوره دوم متوسطه مدارس شهر تهران در سال تحصیلی مورد بررسی بود. با توجه به ضرورت برخورداری از حجم نمونه مناسب برای بررسی ساختار عاملی و اعتبارسنجی مدل مفهومی حاصل از مرحله کیفی، ۴۰۰ دانش‌آموز به‌عنوان نمونه نهایی انتخاب شدند. نمونه‌گیری در این مرحله به روش خوشه‌ای چندمرحله‌ای انجام شد؛ به این صورت که ابتدا مناطق آموزشی تهران با هدف پوشش تنوع جغرافیایی و اجتماعی به چند خوشه تقسیم شدند، سپس تعدادی از مناطق از بخش‌های شمال، جنوب، شرق، غرب و مرکز شهر انتخاب شد و در ادامه، از میان مدارس دولتی و غیردولتی هر منطقه تعدادی مدرسه به‌صورت تصادفی انتخاب گردید. در مرحله بعد، کلاس‌های واجد شرایط به‌عنوان واحدهای نمونه‌گیری انتخاب و دانش‌آموزان حاضر در کلاس‌ها برای مشارکت در پژوهش دعوت شدند. معیارهای ورود به مرحله کمی شامل اشتغال به تحصیل در دوره دوم متوسطه، برخورداری از تجربه استفاده از محیط‌های یادگیری دیجیتال یا سامانه‌های آموزشی الکترونیکی، رضایت آگاهانه برای شرکت در پژوهش و تکمیل کامل ابزار پژوهش بود. پرسشنامه‌هایی که بیش از ۱۰ درصد گویه‌های آنها بدون پاسخ باقی مانده بود از تحلیل کنار گذاشته شدند. انتخاب حجم نمونه ۴۰۰ نفر ضمن تأمین کفایت آماری برای تحلیل عاملی تأییدی و مدل‌سازی روابط میان سازه‌ها، امکان دستیابی به برآوردهای نسبتاً پایدار از پارامترهای مدل پیشنهادی را فراهم کرد. در تمامی مراحل پژوهش، اصول اخلاقی شامل مشارکت داوطلبانه، توضیح اهداف مطالعه، محرمانه ماندن اطلاعات، ناشناس بودن پاسخ‌ها و امکان انصراف از پژوهش در هر زمان برای مشارکت‌کنندگان رعایت شد.

در مرحله کیفی، داده‌ها از طریق مصاحبه نیمه‌ساختاریافته عمیق گردآوری شد. راهنمای اولیه مصاحبه بر اساس هدف پژوهش و مرور مبانی نظری مرتبط با برنامه‌ریزی درسی انطباقی، هوش مصنوعی در آموزش، تحلیل یادگیری، شخصی‌سازی آموزشی و تفاوت‌های فردی دانش‌آموزان تدوین شد. پرسش‌های مصاحبه به‌گونه‌ای طراحی شدند که دیدگاه مشارکت‌کنندگان را درباره مؤلفه‌های ضروری یک نظام برنامه‌ریزی درسی انطباقی، انواع داده‌های مورد نیاز برای شناخت وضعیت یادگیرنده، نقش هوش مصنوعی در تحلیل و تصمیم‌گیری آموزشی، شیوه شناسایی و بازنمایی تفاوت‌های فردی، سازوکارهای انطباق اهداف، محتوا، فعالیت‌های یادگیری، راهبردهای تدریس و ارزشیابی و همچنین الزامات فنی، آموزشی، اخلاقی و مدیریتی چنین نظامی آشکار سازند. علاوه بر پرسش‌های اصلی، از پرسش‌های کاوشگر نظیر «چگونه»، «چرا»، «در چه شرایطی» و «چه عواملی می‌توانند این فرایند را تسهیل یا محدود کنند» برای دستیابی به توضیحات عمیق‌تر استفاده شد. مصاحبه‌ها به‌صورت حضوری یا برخط، بر اساس شرایط مشارکت‌کنندگان، انجام شد و هر مصاحبه به‌طور میانگین بین ۴۵ تا ۷۰ دقیقه به طول انجامید. با کسب رضایت مشارکت‌کنندگان، مصاحبه‌ها ضبط و سپس به‌صورت کلمه‌به‌کلمه پیاده‌سازی شدند. برای افزایش اعتبار داده‌های کیفی، متن مصاحبه‌ها چندین بار مرور شد و در موارد ضروری، برداشت‌های پژوهشگر با برخی از مشارکت‌کنندگان در میان گذاشته شد تا میزان انطباق تفسیرها با دیدگاه آنان بررسی شود.

در مرحله کمی، ابزار اصلی گردآوری داده‌ها پرسشنامه محقق‌ساخته‌ای بود که مستقیماً بر اساس مضامین، مقوله‌ها و شاخص‌های استخراج‌شده از مرحله کیفی تدوین شد. بدین منظور، کدهای نهایی حاصل از تحلیل مصاحبه‌ها ابتدا به مجموعه‌ای از گزاره‌های قابل سنجش تبدیل شدند و پس از حذف موارد مشابه و ادغام گویه‌های دارای همپوشانی مفهومی، نسخه اولیه پرسشنامه تهیه شد. گویه‌ها بر اساس طیف پنج‌درجه‌ای

لیکرت از «کاملاً مخالفم» تا «کاملاً موافقم» تنظیم شدند. محتوای پرسشنامه ابعادی نظیر زیرساخت داده‌محور برنامه درسی، تحلیل مستمر داده‌های یادگیری، شناسایی ویژگی‌ها و تفاوت‌های فردی دانش‌آموزان، مدل‌سازی پروفایل یادگیرنده، انطباق اهداف و محتوای آموزشی، انطباق راهبردهای تدریس و فعالیت‌های یادگیری، ارزشیابی هوشمند و بازخورد مستمر، تصمیم‌گیری الگوریتمی، نقش معلم در فرایند انطباق و الزامات اخلاقی و حمایتی استفاده از هوش مصنوعی را پوشش می‌داد. برای بررسی روایی صوری و محتوایی، نسخه اولیه پرسشنامه در اختیار ۱۰ نفر از متخصصان برنامه‌ریزی درسی، تکنولوژی آموزشی، هوش مصنوعی و سنجش آموزشی قرار گرفت و از آنان خواسته شد میزان تناسب، شفافیت، ضرورت و ارتباط هر گویه با سازه مورد سنجش را ارزیابی کنند. اصلاحات پیشنهادی متخصصان در زمینه حذف ابهام‌های مفهومی، ساده‌سازی برخی عبارات و کاهش همپوشانی میان گویه‌ها در نسخه نهایی اعمال شد. همچنین، برای ارزیابی اولیه قابلیت فهم گویه‌ها، پرسشنامه به‌صورت آزمایشی در گروهی از دانش‌آموزان مشابه جامعه اصلی اجرا شد و بر اساس بازخورد آنان، اصلاحات زبانی لازم صورت گرفت. پایایی ابزار در مرحله اصلی از طریق ضریب آلفای کرونباخ و پایایی ترکیبی برای سازه‌های مختلف مورد بررسی قرار گرفت و مقادیر ۰٫۷۰ و بالاتر به‌عنوان نشان‌دهنده پایایی قابل قبول در نظر گرفته شد.

تحلیل داده‌ها متناسب با منطق طرح آمیخته اکتشافی در دو مرحله کیفی و کمی انجام گرفت و در پایان، یافته‌های دو مرحله برای تدوین چارچوب نهایی با یکدیگر ادغام شدند. در مرحله کیفی، متن کامل مصاحبه‌ها پس از پیاده‌سازی، چندین بار مطالعه شد تا پژوهشگر درک جامعی از محتوای داده‌ها به دست آورد. سپس تحلیل داده‌ها با استفاده از روش تحلیل مضمون انجام شد. در مرحله نخست، واحدهای معنایی مرتبط با موضوع پژوهش شناسایی و کدهای اولیه استخراج شدند. کدهای مشابه یا دارای قرابت معنایی در قالب زیرمقوله‌ها دسته‌بندی شدند و از طریق مقایسه مستمر میان داده‌ها، روابط میان کدها و مقوله‌ها مورد بررسی قرار گرفت. در ادامه، زیرمقوله‌های مرتبط در قالب مضامین اصلی سازمان‌دهی شدند و ساختار اولیه چارچوب برنامه‌ریزی درسی انطباقی شکل گرفت. فرایند تحلیل به‌صورت رفت‌وبرگشتی انجام شد؛ به این معنا که پژوهشگر به‌طور مکرر میان متن خام مصاحبه‌ها، کدهای اولیه، زیرمقوله‌ها و مضامین اصلی رفت‌وآمد کرد تا اطمینان حاصل شود مضامین استخراج‌شده بازنمایی مناسبی از داده‌های اصلی دارند. برای افزایش قابلیت اعتماد تحلیل کیفی، از راهبردهایی نظیر بازبینی مکرر داده‌ها، مقایسه مستمر کدها، بررسی همتایان، بازبینی مشارکت‌کنندگان و ثبت فرایند تصمیم‌گیری تحلیلی استفاده شد. همچنین، بخشی از داده‌ها توسط یک پژوهشگر آشنا با روش‌های تحلیل کیفی به‌صورت مستقل کدگذاری شد و موارد اختلاف از طریق بحث و بررسی تا دستیابی به توافق مفهومی مورد بازنگری قرار گرفت.

در مرحله کمی، داده‌های حاصل از پرسشنامه پس از بررسی اولیه، پاک‌سازی و کدگذاری شدند و ابتدا شاخص‌های آمار توصیفی شامل فراوانی، درصد، میانگین و انحراف معیار برای مشخصات جمعیت‌شناختی و گویه‌های پژوهش محاسبه شد. پیش از انجام تحلیل‌های اصلی، وضعیت داده‌های مفقود، داده‌های پرت و مفروضه‌های لازم برای تحلیل چندمتغیره مورد بررسی قرار گرفت. نرمال بودن توزیع داده‌ها با استفاده از شاخص‌های چولگی و کشیدگی و بررسی توزیع متغیرها ارزیابی شد. همچنین، به‌منظور اطمینان از نبود هم‌خطی شدید میان سازه‌ها، ضرایب همبستگی و شاخص‌های تشخیصی مربوط بررسی شدند. پس از آن، برای ارزیابی ساختار اندازه‌گیری و بررسی میزان انطباق داده‌های تجربی

با ابعاد استخراج‌شده از مرحله کیفی، تحلیل عاملی تأییدی انجام گرفت. در این مرحله، بارهای عاملی گویه‌ها، پایایی ترکیبی، میانگین واریانس استخراج‌شده و روایی همگرا و واگرا مورد ارزیابی قرار گرفتند. گویه‌هایی که از بار عاملی کافی برخوردار نبودند یا موجب کاهش انسجام مفهومی سازه می‌شدند، با در نظر گرفتن مبانی نظری و محتوایی مورد بازنگری قرار گرفتند. برای بررسی برازش مدل اندازه‌گیری و چارچوب مفهومی پیشنهادی از شاخص‌هایی نظیر نسبت کای‌دو به درجه آزادی، شاخص برازش تطبیقی، شاخص تاکر–لوئیس و ریشه میانگین مربعات خطای تقریب استفاده شد. مقادیر کمتر از ۳ برای نسبت کای‌دو به درجه آزادی، مقادیر نزدیک یا بالاتر از ۰٫۹۰ برای شاخص‌های برازش تطبیقی و تاکر–لوئیس و مقادیر کمتر از ۰٫۰۸ برای ریشه میانگین مربعات خطای تقریب به‌عنوان شواهدی از برازش قابل قبول مدل در نظر گرفته شدند. در مرحله تلفیق، نتایج حاصل از تحلیل کیفی و کمی در کنار یکدیگر قرار گرفتند. مضامین و روابط مفهومی استخراج‌شده از مصاحبه‌ها، ساختار اولیه چارچوب را تشکیل دادند و شواهد حاصل از تحلیل کمی برای تأیید، اصلاح یا حذف برخی مؤلفه‌ها و روابط مورد استفاده قرار گرفتند. بر این اساس، چارچوب نهایی پژوهش نه صرفاً بر پایه دیدگاه خبرگان و نه تنها بر اساس روابط آماری، بلکه از طریق ادغام نظام‌مند شواهد کیفی و کمی تدوین شد. در مدل نهایی، تحلیل مستمر داده‌های یادگیری و شناسایی تفاوت‌های فردی دانش‌آموزان به‌عنوان ورودی‌های اصلی نظام انطباقی در نظر گرفته شدند و سازوکارهای مبتنی بر هوش مصنوعی نقش تبدیل این داده‌ها به تصمیم‌های برنامه درسی را بر عهده داشتند؛ تصمیم‌هایی که می‌توانند به انطباق پویای اهداف، محتوا، فعالیت‌های یادگیری، روش‌های تدریس، سطح دشواری، سرعت پیشرفت و شیوه‌های ارزشیابی با نیازهای هر یادگیرنده منجر شوند. سطح معناداری آزمون‌های آماری ۰٫۰۵ در نظر گرفته شد و تحلیل داده‌های کمی با استفاده از نرم‌افزارهای آماری مناسب برای تحلیل‌های چندمتغیره و مدل‌سازی ساختاری انجام گرفت.

یافته‌ها

در مرحله کیفی پژوهش، ۲۰ نفر از متخصصان حوزه‌های برنامه‌ریزی درسی، تکنولوژی آموزشی، هوش مصنوعی در آموزش، سنجش و اندازه‌گیری و تحلیل داده‌های یادگیری مشارکت داشتند. از مجموع مشارکت‌کنندگان، ۱۲ نفر مرد و ۸ نفر زن بودند. دامنه سنی مشارکت‌کنندگان بین ۳۷ تا ۶۱ سال قرار داشت و میانگین سنی آنان ۴۷.۸۵ سال با انحراف معیار ۶.۴۲ بود. از نظر مرتبه علمی و موقعیت حرفه‌ای، ۶ نفر استاد دانشگاه، ۸ نفر دانشیار، ۴ نفر استادیار و ۲ نفر متخصص حرفه‌ای فعال در حوزه طراحی سامانه‌های یادگیری هوشمند و تحلیل داده‌های آموزشی بودند. سابقه فعالیت تخصصی مشارکت‌کنندگان بین ۸ تا ۲۹ سال متغیر بود و میانگین سابقه حرفه‌ای آنان ۱۶.۷۰ سال با انحراف معیار ۵.۶۱ به دست آمد. از نظر حوزه تخصصی اصلی، ۷ نفر در برنامه‌ریزی درسی، ۵ نفر در تکنولوژی آموزشی، ۳ نفر در هوش مصنوعی و یادگیری هوشمند، ۳ نفر در سنجش و اندازه‌گیری آموزشی و ۲ نفر در تحلیل داده‌های یادگیری تخصص اصلی داشتند. فرایند مصاحبه تا مصاحبه هجدهم به مرحله‌ای رسید که کد یا مقوله مفهومی جدیدی با ظرفیت ایجاد تغییر اساسی در ساختار تحلیل ظاهر نشد و دو مصاحبه بعدی برای اطمینان از تثبیت اشباع نظری انجام گرفت. در مرحله کمی نیز ۴۰۰ دانش‌آموز دوره دوم متوسطه شهر تهران در پژوهش شرکت کردند. از این تعداد، ۲۰۶ نفر معادل ۵۱.۵۰ درصد دختر و ۱۹۴ نفر معادل ۴۸.۵۰ درصد پسر بودند. میانگین سنی دانش‌آموزان

۱۶.۴۷ سال با انحراف معیار ۰.۹۱ بود. از نظر پایه تحصیلی، ۱۳۸ دانش‌آموز معادل ۳۴.۵۰ درصد در پایه دهم، ۱۳۴ نفر معادل ۳۳.۵۰ درصد در پایه یازدهم و ۱۲۸ نفر معادل ۳۲.۰۰ درصد در پایه دوازدهم تحصیل می‌کردند. همچنین، ۲۹۶ نفر معادل ۷۴.۰۰ درصد در مدارس دولتی و ۱۰۴ نفر معادل ۲۶.۰۰ درصد در مدارس غیردولتی تحصیل داشتند. تمامی دانش‌آموزان مورد بررسی سابقه استفاده از حداقل یک نوع محیط یادگیری دیجیتال، سامانه مدیریت یادگیری، محتوای آموزشی برخط یا نرم‌افزار آموزشی را گزارش کردند؛ از این رو، نمونه کمی از حداقل تجربه لازم برای ارزیابی مؤلفه‌های مرتبط با برنامه‌ریزی درسی انطباقی برخوردار بود.

جدول ۱. مضامین اصلی، زیرمؤلفه‌ها و شاخص‌های استخراج‌شده از تحلیل کیفی

مضمون اصلی	زیرمؤلفه‌ها	نمونه شاخص‌های مفهومی	تعداد کدهای نهایی	فراوانی ارجاع در مصاحبه‌ها
زیرساخت داده‌محور برنامه درسی	گردآوری داده، یکپارچه‌سازی داده، کیفیت داده، دسترس‌پذیری داده	ثبت تعاملات یادگیری، تجمیع داده‌های عملکردی، داده‌های رفتاری و آموزشی، به‌روزرسانی مستمر اطلاعات	۱۸	۹۴
تحلیل داده‌های یادگیری	تحلیل توصیفی، تشخیصی، پیش‌بینانه و تجویزی	تشخیص الگوی یادگیری، پیش‌بینی افت تحصیلی، شناسایی نقاط ضعف و قوت، پیشنهاد مسیر یادگیری	۲۱	۱۱۸
شناسایی تفاوت‌های فردی	توانایی شناختی، سبک و سرعت یادگیری، علایق، انگیزش، دانش پیشین	تشخیص سطح آمادگی، ترجیحات یادگیری، میزان پیشرفت، نیازهای حمایتی و تفاوت در سرعت یادگیری	۲۴	۱۲۶
مدل‌سازی پروفایل یادگیرنده	ایجاد پروفایل پویا، به‌روزرسانی پروفایل، دسته‌بندی ویژگی‌های یادگیرنده	نمایه توانایی‌ها، سابقه عملکرد، الگوی تعامل، اهداف شخصی و نیازهای آموزشی	۱۷	۸۹
انطباق اهداف و محتوای آموزشی	تنظیم سطح هدف، انتخاب محتوا، توالی محتوا، تنوع منابع	تعدیل سطح دشواری، ارائه محتوای جایگزین، توالی شخصی‌سازی‌شده و پیشنهاد منابع مکمل	۲۲	۱۱۴
انطباق راهبردهای تدریس و فعالیت‌های یادگیری	شخصی‌سازی فعالیت، انتخاب راهبرد، زمان‌بندی و حمایت آموزشی	فعالیت‌های متناسب با توانایی، انتخاب روش ارائه، تنظیم سرعت و میزان راهنمایی	۲۰	۱۰۷
ارزشیابی هوشمند و بازخورد مستمر	ارزشیابی تکوینی، بازخورد فوری، ارزیابی تطبیقی، پایش پیشرفت	سؤال‌های متناسب با سطح، بازخورد شخصی، تشخیص خطا، اصلاح مسیر یادگیری	۱۹	۱۰۳
تصمیم‌گیری مبتنی بر هوش مصنوعی	موتور توصیه‌گر، قواعد تصمیم، یادگیری ماشین، پشتیبانی تصمیم	پیشنهاد مسیر آموزشی، اولویت‌بندی محتوا، شناسایی نیاز به مداخله و پیشنهاد اقدام اصلاحی	۲۳	۱۲۱
نقش معلم در کنترل و هدایت فرایند	نظارت حرفه‌ای، تأیید تصمیمات، مداخله انسانی و تفسیر داده‌ها	کنترل توصیه‌های الگوریتمی، اصلاح تصمیم، توجه به زمینه کلاس و تعامل انسانی	۱۶	۸۷
الزامات اخلاقی، امنیتی و حمایتی	حریم خصوصی، شفافیت، عدالت الگوریتمی، امنیت داده، مسئولیت‌پذیری	حفاظت از داده، جلوگیری از سوگیری، توضیح‌پذیری تصمیم، رضایت آگاهانه و پاسخ‌گویی	۲۰	۱۱۱

نتایج تحلیل مضمون مصاحبه‌ها نشان داد که چارچوب مفهومی برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی دارای ساختاری چندلایه و متشکل از ۱۰ مضمون اصلی است. در مجموع، پس از حذف کدهای تکراری، ادغام مفاهیم همپوشان و بازنگری در روابط میان مقوله‌ها، ۲۰۰ کد نهایی در ساختار تحلیلی باقی ماند. بیشترین تعداد کد به مضمون «شناسایی تفاوت‌های فردی» با ۲۴ کد و پس از آن به «تصمیم‌گیری مبتنی بر هوش مصنوعی» با ۲۳ کد، «انطباق اهداف و محتوای آموزشی» با ۲۲ کد و «تحلیل داده‌های یادگیری» با ۲۱ کد اختصاص داشت. همچنین، از نظر فراوانی ارجاع در مصاحبه‌ها، شناسایی تفاوت‌های فردی با ۱۲۶ ارجاع، تصمیم‌گیری مبتنی بر هوش مصنوعی با ۱۲۱ ارجاع

و تحلیل داده‌های یادگیری با ۱۱۸ ارجاع بیشترین تأکید را در دیدگاه خبرگان به خود اختصاص دادند. این الگو نشان داد که از دیدگاه مشارکت‌کنندگان، برنامه‌ریزی درسی انطباقی صرفاً به معنای استفاده از فناوری برای ارائه محتوای متفاوت نیست، بلکه مبتنی بر چرخه‌ای است که از گردآوری مستمر داده‌های یادگیری آغاز می‌شود، با شناخت دقیق ویژگی‌های فردی و مدل‌سازی پروفایل یادگیرنده ادامه می‌یابد و در نهایت از طریق سازوکارهای تصمیم‌گیری هوشمند به تعدیل اهداف، محتوا، راهبردهای تدریس، فعالیت‌های یادگیری و شیوه‌های ارزشیابی منتهی می‌شود. افزون بر این، قرار گرفتن «نقش معلم» و «الزامات اخلاقی، امنیتی و حمایتی» به‌عنوان دو مضمون مستقل نشان داد که خبرگان، چارچوب پیشنهادی را به‌عنوان یک نظام کاملاً خودکار و مستقل از عامل انسانی در نظر نمی‌گیرند؛ بلکه هوش مصنوعی را به‌عنوان سامانه پشتیبان تصمیم تلقی می‌کنند که تصمیمات آن باید در چارچوب نظارت حرفه‌ای معلم، حفاظت از حریم خصوصی، شفافیت الگوریتمی و رعایت عدالت آموزشی به کار گرفته شود.

جدول ۲. شاخص‌های توصیفی، پایایی و روایی همگرای سازه‌های چارچوب مفهومی

سازه	تعداد گویه	میانگین	انحراف معیار	آلفای کرونباخ	پایایی ترکیبی	میانگین واریانس استخراج‌شده
زیرساخت داده‌محور برنامه درسی	۵	۴.۰۱	۰.۶۳	۰.۸۶	۰.۸۹	۰.۶۲
تحلیل داده‌های یادگیری	۶	۴.۱۲	۰.۵۸	۰.۸۹	۰.۹۱	۰.۶۵
شناسایی تفاوت‌های فردی	۶	۴.۱۸	۰.۵۶	۰.۹۱	۰.۹۳	۰.۶۸
مدل‌سازی پروفایل یادگیرنده	۵	۴.۰۷	۰.۶۱	۰.۸۷	۰.۹۰	۰.۶۴
انطباق اهداف و محتوای آموزشی	۶	۴.۱۵	۰.۵۷	۰.۹۰	۰.۹۲	۰.۶۶
انطباق راهبردهای تدریس و فعالیت‌ها	۶	۴.۱۰	۰.۶۰	۰.۸۹	۰.۹۱	۰.۶۴
ارزشیابی هوشمند و بازخورد مستمر	۵	۴.۲۱	۰.۵۵	۰.۸۸	۰.۹۱	۰.۶۷
تصمیم‌گیری مبتنی بر هوش مصنوعی	۶	۴.۰۹	۰.۵۹	۰.۹۱	۰.۹۳	۰.۶۹
نقش معلم در کنترل و هدایت فرایند	۵	۴.۲۵	۰.۵۴	۰.۸۶	۰.۸۹	۰.۶۱
الزامات اخلاقی، امنیتی و حمایتی	۶	۴.۲۹	۰.۵۲	۰.۹۲	۰.۹۴	۰.۷۱

نتایج جدول ۲ نشان داد که میانگین تمام سازه‌های چارچوب در سطحی بالاتر از نقطه میانی مقیاس قرار داشت و دامنه میانگین‌ها از ۴.۰۱ برای «زیرساخت داده‌محور برنامه درسی» تا ۴.۲۹ برای «الزامات اخلاقی، امنیتی و حمایتی» متغیر بود. این یافته بیانگر آن است که دانش‌آموزان، مؤلفه‌های استخراج‌شده از مرحله کیفی را به میزان بالایی با الزامات یک نظام برنامه‌ریزی درسی انطباقی مرتبط ارزیابی کردند. بالاترین میانگین‌ها به‌ترتیب برای الزامات اخلاقی، امنیتی و حمایتی، نقش معلم در کنترل و هدایت فرایند و ارزشیابی هوشمند و بازخورد مستمر مشاهده شد که نشان می‌دهد از دیدگاه پاسخ‌دهندگان، کاربرد هوش مصنوعی در برنامه درسی باید علاوه بر قابلیت شخصی‌سازی، با کنترل انسانی، امنیت داده و بازخورد قابل فهم همراه باشد. از نظر پایایی، ضرایب آلفای کرونباخ در تمام سازه‌ها بالاتر از ۰.۸۵ بود و از ۰.۸۶ تا ۰.۹۲ متغیر بود. پایایی ترکیبی نیز بین ۰.۸۹ و ۰.۹۴ قرار داشت و در تمام موارد از مقدار معیار ۰.۷۰ بیشتر بود. علاوه بر این، میانگین واریانس استخراج‌شده برای همه سازه‌ها بیشتر از ۰.۵۰ بود و بین ۰.۶۱ تا ۰.۷۱ قرار داشت. بنابراین، مجموعه گویه‌های مربوط به هر سازه از انسجام درونی مطلوب برخوردار بود و میزان واریانس تبیین‌شده توسط سازه نهفته در مقایسه با واریانس خطای اندازه‌گیری در سطح قابل

قبولی قرار داشت. ترکیب ضرایب پایایی بالا و مقادیر مناسب میانگین واریانس استخراج‌شده، شواهد کافی برای تأیید پایایی و روایی همگرای ابزار محقق‌ساخته و حفظ تمامی ۱۰ سازه در مدل اندازه‌گیری فراهم کرد.

جدول ۳. بارهای عاملی استانداردشده و شاخص‌های معنی‌داری تحلیل عاملی تأییدی

سازه	دامنه بارهای عاملی استانداردشده	کمترین مقدار t	بیشترین مقدار t	وضعیت تأیید
زیرساخت داده‌محور برنامه درسی	۰.۶۸ تا ۰.۸۴	۱۲.۷۶	۱۸.۴۳	تأیید شد
تحلیل داده‌های یادگیری	۰.۷۱ تا ۰.۸۷	۱۴.۱۱	۲۱.۳۷	تأیید شد
شناسایی تفاوت‌های فردی	۰.۷۳ تا ۰.۸۹	۱۵.۰۸	۲۲.۶۵	تأیید شد
مدل‌سازی پروفایل یادگیرنده	۰.۶۹ تا ۰.۸۶	۱۳.۲۴	۲۰.۱۸	تأیید شد
انطباق اهداف و محتوای آموزشی	۰.۷۲ تا ۰.۸۸	۱۴.۷۶	۲۱.۹۴	تأیید شد
انطباق راهبردهای تدریس و فعالیت‌ها	۰.۷۰ تا ۰.۸۶	۱۳.۸۹	۲۰.۷۳	تأیید شد
ارزشیابی هوشمند و بازخورد مستمر	۰.۷۴ تا ۰.۸۸	۱۵.۲۱	۲۱.۸۲	تأیید شد
تصمیم‌گیری مبتنی بر هوش مصنوعی	۰.۷۵ تا ۰.۹۰	۱۵.۶۳	۲۳.۴۸	تأیید شد
نقش معلم در کنترل و هدایت فرایند	۰.۶۷ تا ۰.۸۳	۱۲.۴۴	۱۷.۹۶	تأیید شد
الزامات اخلاقی، امنیتی و حمایتی	۰.۷۶ تا ۰.۹۱	۱۶.۳۱	۲۴.۱۲	تأیید شد

بر اساس نتایج تحلیل عاملی تأییدی، تمام گویه‌های باقی‌مانده در مدل اندازه‌گیری دارای بار عاملی استانداردشده بالاتر از ۰.۶۰ بودند و هیچ‌یک از گویه‌ها به دلیل بار عاملی ضعیف از مدل نهایی حذف نشدند. دامنه کلی بارهای عاملی از ۰.۶۷ تا ۰.۹۱ متغیر بود. بالاترین بار عاملی در سازه الزامات اخلاقی، امنیتی و حمایتی مشاهده شد که حداکثر آن به ۰.۹۱ رسید و پس از آن سازه تصمیم‌گیری مبتنی بر هوش مصنوعی با بیشینه بار ۰.۹۰ قرار گرفت. مقادیر آماره t نیز در تمامی موارد به‌طور قابل توجهی بالاتر از مقدار بحرانی ۱.۹۶ بود و کمترین مقدار آن ۱۲.۴۴ و بیشترین مقدار ۲۴.۱۲ به دست آمد. بنابراین، تمامی روابط میان گویه‌ها و سازه‌های متناظر در سطح ۰.۰۰۱ معنی‌دار بودند. این یافته‌ها علاوه بر تأیید ساختار ده‌بعدی استخراج‌شده از بخش کیفی، نشان دادند که هر یک از سازه‌ها توسط مجموعه‌ای نسبتاً همگن از شاخص‌های مشاهده‌پذیر اندازه‌گیری شده‌اند. به‌ویژه، بارهای عاملی بالاتر در ابعاد شناسایی تفاوت‌های فردی، تصمیم‌گیری مبتنی بر هوش مصنوعی و الزامات اخلاقی نشان داد که این سازه‌ها در ادراک پاسخ‌دهندگان از هویت مفهومی روشن و انسجام اندازه‌گیری بالایی برخوردار هستند. همچنین، پایین‌ترین بارهای مشاهده‌شده نیز از آستانه قابل قبول فراتر بودند؛ از این رو، ساختار اندازه‌گیری چارچوب بدون حذف هیچ‌یک از سازه‌های اصلی مرحله کیفی مورد تأیید قرار گرفت.

جدول ۴. شاخص‌های برازش مدل نهایی چارچوب مفهومی

شاخص برازش	مقدار به‌دست‌آمده	معیار قابل قبول	ارزیابی
χ^2	۱۱۲۴.۳۶	—	—
درجه آزادی	۵۱۴	—	—
χ^2/df	۲.۱۹	کمتر از ۳.۰۰	مطلوب
GFI	۰.۹۱	۰.۹۰و بالاتر	مطلوب
AGFI	۰.۸۹	نزدیک به ۰.۹۰ و بالاتر	قابل قبول
CFI	۰.۹۵	۰.۹۰و بالاتر	مطلوب

TLI	۰.۹۴	۰.۹۰و بالاتر	مطلوب
NFI	۰.۹۲	۰.۹۰و بالاتر	مطلوب
IFI	۰.۹۵	۰.۹۰و بالاتر	مطلوب
RMSEA	۰.۰۵۵	کمتر از ۰.۰۸	مطلوب
SRMR	۰.۰۴۶	کمتر از ۰.۰۸	مطلوب

نتایج ارزیابی برازش مدل نهایی نشان داد که ساختار مفهومی استخراج‌شده از مرحله کیفی با داده‌های تجربی مرحله کمی انطباق مطلوبی دارد. نسبت کای‌دو به درجه آزادی برابر با ۲.۱۹ به دست آمد که پایین‌تر از مقدار ۳.۰۰ بود و برازش مناسب مدل را نشان داد. شاخص برازش تطبیقی برابر با ۰.۹۵، شاخص تاکر–لوئیس برابر با ۰.۹۴، شاخص برازش افزایشی برابر با ۰.۹۵ و شاخص برازش هنجارشده برابر با ۰.۹۲ بود که تمامی آنها از حداقل معیار ۰.۹۰ فراتر رفتند. شاخص GFI نیز برابر با ۰.۹۱ بود و در سطح مطلوب قرار گرفت. مقدار AGFI برابر با ۰.۸۹ به دست آمد که بسیار نزدیک به معیار ۰.۹۰ بود و با توجه به سایر شاخص‌های برازش، قابل قبول ارزیابی شد. همچنین، مقدار RMSEA برابر با ۰.۰۵۵ و مقدار SRMR برابر با ۰.۰۴۶ بود که هر دو به‌طور محسوسی پایین‌تر از حد ۰.۰۸ قرار داشتند. برآیند این شاخص‌ها نشان داد که مدل اندازه‌گیری و ساختار کلی چارچوب پیشنهادی از برازش کافی برخوردار است و تفاوت میان ماتریس کوواریانس مشاهده‌شده و ماتریس کوواریانس بازتولیدشده توسط مدل در سطح قابل قبول قرار دارد. بنابراین، داده‌های کمی از ساختار مفهومی حاصل از مرحله کیفی حمایت کردند و شواهد لازم برای پذیرش مدل نهایی فراهم شد.



شکل ۱. چارچوب مفهومی نهایی برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی با تأکید بر تحلیل داده‌های یادگیری و تفاوت‌های فردی دانش‌آموزان

چارچوب نهایی پژوهش نشان داد که برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی از یک فرایند چرخه‌ای و پویا تشکیل شده است که در آن «زیرساخت داده‌محور برنامه درسی» نقطه آغاز فرایند محسوب می‌شود. داده‌های حاصل از عملکرد تحصیلی، تعاملات دانش‌آموز با محیط یادگیری، الگوی پاسخ‌دهی، سرعت انجام تکالیف، میزان مشارکت، خطاهای متداول، سابقه ارزشیابی و سایر شاخص‌های رفتاری و آموزشی در این زیرساخت گردآوری و یکپارچه می‌شوند. در مرحله بعد، این داده‌ها از طریق سازوکارهای تحلیل داده‌های یادگیری پردازش می‌شوند تا الگوهای عملکردی و نیازهای احتمالی دانش‌آموزان شناسایی شود. همزمان، داده‌های تحلیل‌شده برای شناسایی تفاوت‌های فردی از نظر دانش پیشین، سطح توانایی، سرعت یادگیری، علایق، انگیزش، نیازهای حمایتی و نحوه پاسخ به فعالیت‌های آموزشی مورد استفاده قرار می‌گیرند. حاصل این فرایند، ایجاد و به‌روزرسانی مستمر یک پروفایل پویا برای هر یادگیرنده است. پروفایل یادگیرنده سپس به موتور تصمیم‌گیری مبتنی بر هوش مصنوعی منتقل می‌شود و سامانه بر اساس قواعد آموزشی، الگوریتم‌های توصیه‌گر و الگوهای استخراج‌شده از داده‌ها، پیشنهادهایی برای انطباق عناصر مختلف برنامه درسی تولید می‌کند. این انطباق شامل تعدیل اهداف یادگیری، انتخاب و توالی محتوا، تعیین سطح دشواری، تنظیم سرعت پیشرفت، انتخاب فعالیت‌های مناسب، پیشنهاد راهبردهای تدریس و تنظیم روش‌های ارزشیابی است. ارزشیابی هوشمند و بازخورد مستمر نیز در انتهای فرایند قرار نمی‌گیرد، بلکه به‌عنوان بخشی از یک چرخه بازخوردی، اطلاعات جدیدی درباره وضعیت یادگیری تولید می‌کند و این اطلاعات مجدداً وارد زیرساخت داده می‌شود. در نتیجه، چارچوب پیشنهادی ماهیتی خوداصلاح‌گر و پویا دارد و تصمیم‌های مربوط به برنامه درسی بر اساس تغییر وضعیت یادگیرنده به‌صورت مستمر به‌روزرسانی می‌شوند. با این حال، نقش معلم در تمام مراحل به‌عنوان سازوکار نظارت انسانی و تفسیر حرفه‌ای داده‌ها حفظ می‌شود؛ به این معنا که پیشنهادهای الگوریتمی جایگزین قضاوت تربیتی معلم نمی‌شوند، بلکه برای پشتیبانی از تصمیم‌گیری وی مورد استفاده قرار می‌گیرند. همچنین، الزامات اخلاقی، امنیتی و حمایتی شامل حفاظت از داده‌ها، شفافیت الگوریتمی، جلوگیری از سوگیری، عدالت در دسترسی، قابلیت توضیح تصمیم‌ها و رعایت حریم خصوصی، به‌صورت یک لایه فراگیر تمام اجزای مدل را پوشش می‌دهند.

در مجموع، تلفیق یافته‌های کیفی و کمی نشان داد که برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی را نمی‌توان به کاربرد یک الگوریتم توصیه‌گر یا صرفاً تغییر سطح دشواری محتوا تقلیل داد، بلکه این مفهوم بیانگر یک نظام تصمیم‌گیری آموزشی چندبعدی است که از تعامل مستمر میان داده، تحلیل، شناخت فردی، تصمیم‌گیری هوشمند، مداخله برنامه درسی، بازخورد و نظارت انسانی شکل می‌گیرد. یافته‌های مرحله کیفی ساختار اولیه این نظام را در قالب ۱۰ مضمون اصلی مشخص کرد و یافته‌های مرحله کمی نیز پایایی، روایی و برازش مناسب این ساختار را نشان داد. در چارچوب نهایی، تحلیل داده‌های یادگیری و شناسایی تفاوت‌های فردی نقش حلقه واسط میان داده خام و تصمیم برنامه درسی را ایفا می‌کنند؛ به این معنا که داده تنها زمانی ارزش برنامه‌ریزی پیدا می‌کند که به شناختی قابل استفاده از وضعیت هر دانش‌آموز تبدیل شود. از سوی دیگر، هوش مصنوعی نیز در این چارچوب نه به‌عنوان هدف، بلکه به‌عنوان سازوکار پردازش، پیش‌بینی و پشتیبانی از تصمیم‌های انطباقی تعریف می‌شود. بر این اساس، برنامه درسی از یک ساختار ثابت و یکسان برای همه دانش‌آموزان به یک نظام پویا تبدیل می‌شود که می‌تواند با حفظ اهداف کلان آموزشی، مسیرهای متفاوتی برای تحقق یادگیری متناسب با ویژگی‌های هر دانش‌آموز فراهم کند.

نتایج مدل کمی نیز تأیید کرد که ابعاد شناسایی تفاوت‌های فردی، تصمیم‌گیری مبتنی بر هوش مصنوعی، انطباق عناصر برنامه درسی، ارزشیابی هوشمند، نقش معلم و الزامات اخلاقی همگی اجزای ضروری و مکمل این ساختار هستند و حذف هر یک از آنها می‌تواند انسجام نظری و عملی چارچوب را کاهش دهد.

بحث و نتیجه‌گیری

پژوهش حاضر با هدف طراحی و اعتبارسنجی چارچوب مفهومی برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی با تأکید بر تحلیل داده‌های یادگیری و تفاوت‌های فردی دانش‌آموزان انجام شد. یافته‌های مرحله کیفی نشان داد که چارچوب پیشنهادی از ۱۰ مضمون اصلی شامل زیرساخت داده‌محور برنامه درسی، تحلیل داده‌های یادگیری، شناسایی تفاوت‌های فردی، مدل‌سازی پروفایل یادگیرنده، انطباق اهداف و محتوای آموزشی، انطباق راهبردهای تدریس و فعالیت‌های یادگیری، ارزشیابی هوشمند و بازخورد مستمر، تصمیم‌گیری مبتنی بر هوش مصنوعی، نقش معلم در کنترل و هدایت فرایند و الزامات اخلاقی، امنیتی و حمایتی تشکیل می‌شود. در مرحله کمی نیز ساختار استخراج‌شده از داده‌های کیفی مورد تأیید قرار گرفت و نتایج تحلیل عاملی تأییدی، ضرایب پایایی و شاخص‌های برازش مدل نشان داد که سازه‌های پیشنهادی از انسجام درونی، روایی همگرا و برازش مطلوب برخوردارند. این یافته‌ها نشان می‌دهد که برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی را نمی‌توان صرفاً به استفاده از یک فناوری، الگوریتم یا سامانه توصیه‌گر تقلیل داد، بلکه باید آن را به‌عنوان یک نظام چندلایه، داده‌محور و پویا در نظر گرفت که میان تحلیل مستمر داده، شناخت دقیق یادگیرنده، تصمیم‌گیری هوشمند، بازطراحی عناصر برنامه درسی، ارزشیابی و بازخورد مستمر ارتباط برقرار می‌کند. چنین برداشتی با رویکردهای جدید در حوزه هوش مصنوعی در آموزش همسو است که بر حرکت از کاربردهای منفرد فناوری به سمت طراحی اکوسیستم‌های یکپارچه یادگیری تأکید می‌کنند (Boulay et al., 2023; Huong, 2024; Nguyen et al., 2023).

یکی از مهم‌ترین یافته‌های پژوهش، جایگاه محوری «زیرساخت داده‌محور برنامه درسی» در چارچوب نهایی بود. این نتیجه نشان می‌دهد که هرگونه انطباق واقعی در سطح برنامه درسی، در درجه نخست به دسترسی به داده‌های معتبر، مستمر و قابل تحلیل وابسته است. داده‌های مربوط به عملکرد تحصیلی، میزان مشارکت، سرعت انجام فعالیت‌ها، نوع خطاها، الگوی پاسخ‌دهی، سابقه ارزشیابی و نحوه تعامل با منابع آموزشی، مبنای تصمیم‌گیری هوشمند را شکل می‌دهند. از این منظر، داده نه یک محصول جانبی سامانه آموزشی، بلکه جزء بنیادین معماری برنامه درسی انطباقی است. این نتیجه با مطالعاتی همسو است که بر نقش تحلیل‌های آموزشی و داده‌های رفتاری در بهبود تصمیم‌گیری آموزشی تأکید کرده‌اند (Georgiou, 2026; Peralta & Martínez, 2024). همچنین، پژوهش‌های مرتبط با طراحی سامانه‌های آموزشی هوشمند نشان داده‌اند که کیفیت توصیه‌ها و تصمیم‌های الگوریتمی به کیفیت و جامعیت داده‌های ورودی وابسته است و هرگونه نقصان در ثبت، یکپارچه‌سازی یا تفسیر داده‌ها می‌تواند دقت تصمیم‌گیری را کاهش دهد (Ivanova, 2026; Ye et al., 2026). بنابراین، نتایج

پژوهش حاضر تأیید می‌کند که توسعه برنامه‌ریزی درسی هوشمند، پیش از هر چیز، مستلزم ایجاد زیرساختی برای جمع‌آوری، ذخیره‌سازی، ادغام و تحلیل داده‌های یادگیری است.

یافته دیگر پژوهش به اهمیت «تحلیل داده‌های یادگیری» به‌عنوان حلقه واسط میان داده خام و تصمیم برنامه درسی مربوط می‌شود. در چارچوب نهایی، تحلیل داده تنها به توصیف عملکرد گذشته محدود نمی‌شود، بلکه شامل تحلیل‌های تشخیصی، پیش‌بینانه و تجویزی است. این بدان معناست که سامانه باید قادر باشد نه‌تنها مشخص کند دانش‌آموز چه عملکردی داشته است، بلکه دلایل احتمالی مشکلات یادگیری را شناسایی کند، احتمال بروز افت یا موفقیت را پیش‌بینی نماید و در نهایت، مداخله آموزشی مناسب را پیشنهاد دهد. چنین برداشتی با ادبیات جدید یادگیری ماشین در آموزش سازگار است؛ زیرا الگوریتم‌های یادگیری ماشین امکان استخراج الگوهای پیچیده از داده‌های آموزشی و تبدیل آنها به تصمیم‌های کاربردی را فراهم می‌کنند (Deng, 2024; Georgiou, 2026). علاوه بر این، یادگیری تقویتی نیز ظرفیت ایجاد سیستم‌هایی را فراهم کرده است که از پیامد تصمیم‌های قبلی یاد می‌گیرند و به‌تدریج سیاست‌های آموزشی خود را اصلاح می‌کنند (Mon et al., 2023). از این رو، یافته حاضر نشان می‌دهد که برنامه‌ریزی درسی انطباقی زمانی از سطح شخصی‌سازی ساده فراتر می‌رود که داده‌ها در یک چرخه مستمر تحلیل، پیش‌بینی، مداخله و بازخورد قرار گیرند.

نتایج پژوهش همچنین نشان داد که «شناسایی تفاوت‌های فردی» یکی از پرتکرارترین و مهم‌ترین مضامین استخراج‌شده از مصاحبه‌ها بوده است. این یافته بیانگر آن است که کارشناسان، انطباق را بدون شناخت ویژگی‌های فردی دانش‌آموزان ممکن نمی‌دانند. در چارچوب نهایی، تفاوت‌های فردی تنها به سطح دانش یا عملکرد تحصیلی محدود نشده، بلکه ابعادی مانند سرعت یادگیری، علایق، انگیزش، نیازهای حمایتی و نحوه تعامل با فعالیت‌های آموزشی را نیز دربرمی‌گیرد. این نتیجه با منطق یادگیری شخصی‌سازی‌شده و سامانه‌های آموزش تطبیقی همسو است. مطالعات انجام‌شده در زمینه تدریس خصوصی مبتنی بر هوش مصنوعی و یادگیری شخصی‌سازی‌شده نشان داده‌اند که استفاده از اطلاعات مربوط به وضعیت واقعی یادگیرنده می‌تواند امکان ارائه مسیرهای متفاوت یادگیری را فراهم کند (Alvarez et al., 2024; Ivanova, 2023). همچنین، تجربه‌های مرتبط با نرم‌افزارهای آموزشی مبتنی بر هوش مصنوعی نشان داده‌اند که دانش‌آموزان زمانی از محیط‌های هوشمند بهره بیشتری می‌برند که سامانه بتواند محتوا، سطح دشواری و نوع بازخورد را با نیازهای آنان هماهنگ کند (Annuš, 2024). بنابراین، یافته‌های پژوهش حاضر این دیدگاه را تقویت می‌کند که نقطه آغاز انطباق، شناخت تفاوت است و هر نظام انطباقی باید دارای سازوکاری برای بازنمایی مستمر تفاوت‌های میان یادگیرندگان باشد.

در همین راستا، «مدل‌سازی پروفایل پویا برای هر یادگیرنده» به‌عنوان یکی از اجزای واسط چارچوب شناسایی شد. اهمیت این مؤلفه در آن است که اطلاعات پراکنده مربوط به هر دانش‌آموز را در قالب یک مدل منسجم و قابل به‌روزرسانی سازمان می‌دهد. برخلاف پروفایل‌های ثابت که تنها بر اطلاعات اولیه یا نتایج یک آزمون متکی هستند، پروفایل پویا با ورود داده‌های جدید اصلاح می‌شود و می‌تواند تغییرات تدریجی در سطح دانش، عملکرد و نیازهای آموزشی را بازتاب دهد. این نتیجه با مدل‌های چندعاملی و معماری‌های دانش‌محور در یادگیری شخصی‌سازی‌شده سازگار است (Ivanova, 2023, 2026). چنین مدل‌هایی تلاش می‌کنند وضعیت یادگیرنده را به‌صورت ساخت‌یافته

بازنمایی کنند و از آن برای انتخاب مسیر آموزشی مناسب بهره بگیرند. از این منظر، پروفایل یادگیرنده را می‌توان هسته شناختی سامانه انطباقی دانست؛ زیرا تصمیم‌های مرتبط با محتوا، فعالیت، سرعت و ارزشیابی تنها زمانی می‌توانند شخصی‌سازی شوند که سیستم تصویری نسبتاً دقیق و به‌روز از وضعیت هر دانش‌آموز در اختیار داشته باشد.

یکی دیگر از یافته‌های مهم پژوهش، تأیید نقش «تصمیم‌گیری مبتنی بر هوش مصنوعی» به‌عنوان مرکز پردازش و تبدیل اطلاعات به اقدام برنامه درسی بود. در مدل نهایی، هوش مصنوعی وظیفه دارد اطلاعات حاصل از تحلیل داده‌ها و پروفایل یادگیرنده را به پیشنهادهایی برای تغییر در عناصر برنامه درسی تبدیل کند. این یافته با مطالعات اخیر در زمینه طراحی برنامه درسی شخصی‌سازی‌شده و سیستم‌های مبتنی بر تحلیل‌های هوشمند همسو است (Deng, 2024; Wang et al., 2025). همچنین، مطالعات مربوط به طراحی و توسعه پلتفرم‌های آموزشی مبتنی بر هوش مصنوعی نشان داده‌اند که ترکیب اصول طراحی آموزشی با قابلیت‌های الگوریتمی می‌تواند به بهبود کیفیت تصمیم‌گیری درباره فعالیت‌ها و مسیرهای یادگیری منجر شود (Aliyu et al., 2026). با این حال، یافته پژوهش حاضر نشان می‌دهد که تصمیم‌گیری مبتنی بر هوش مصنوعی نباید به‌عنوان تصمیم‌گیری کاملاً مستقل و خودمختار تفسیر شود، بلکه باید درون یک معماری آموزشی تعریف شود که در آن قواعد تربیتی، اهداف برنامه درسی و قضاوت حرفه‌ای معلم نیز نقش تعیین‌کننده دارند.

نتایج همچنین نشان داد که انطباق باید به مجموعه‌ای از عناصر برنامه درسی گسترش یابد و تنها در سطح محتوا باقی نماند. در چارچوب نهایی، انطباق اهداف یادگیری، محتوای آموزشی، راهبردهای تدریس، فعالیت‌های یادگیری و روش‌های ارزشیابی به‌عنوان ابعاد مجزای فرایند در نظر گرفته شدند. این یافته از آن جهت اهمیت دارد که بسیاری از کاربردهای اولیه هوش مصنوعی در آموزش عمدتاً بر پیشنهاد محتوا یا تغییر سطح دشواری تمرکز داشتند، در حالی که برنامه‌ریزی درسی انطباقی نیازمند هماهنگی میان عناصر متعدد است. مطالعات مرتبط با کلاس‌های هوشمند، آموزش شخصی‌سازی‌شده و طراحی آموزشی مبتنی بر هوش مصنوعی نیز نشان داده‌اند که اثربخشی زمانی افزایش می‌یابد که فناوری تنها به ارائه محتوا محدود نباشد و در سازمان‌دهی فعالیت‌ها، انتخاب روش تدریس و نحوه ارزشیابی نیز مشارکت داشته باشد (Alashwal, 2024; Chopra, 2023; Suvendu & S, 2024). همچنین، تجربه طراحی دوره‌های هوشمند و ترکیبی نشان داده است که هماهنگی میان اهداف، فعالیت‌ها، فناوری و ارزشیابی از شروط اصلی موفقیت در محیط‌های آموزشی هوشمند است (Xu & Zhang, 2026). در نتیجه، یافته پژوهش حاضر بر ضرورت نگاه کل‌نگر به انطباق تأکید دارد.

«ارزشیابی هوشمند و بازخورد مستمر» نیز یکی از مؤلفه‌های اساسی چارچوب نهایی بود. در مدل پیشنهادی، ارزشیابی یک مرحله پایانی نیست، بلکه بخشی از چرخه یادگیری محسوب می‌شود که اطلاعات جدید تولید می‌کند و آنها را دوباره وارد فرایند تصمیم‌گیری می‌سازد. این ساختار موجب می‌شود برنامه درسی قابلیت خوداصلاحی پیدا کند؛ زیرا پیامد هر تصمیم آموزشی مورد ارزیابی قرار می‌گیرد و در صورت ناکافی بودن، مسیر یادگیری اصلاح می‌شود. این نتیجه با دیدگاه‌های مربوط به اکوسیستم‌های یادگیری انطباقی همسو است که بر چرخه مستمر داده، تحلیل، مداخله و بازخورد تأکید دارند (Galaup, 2023). همچنین، سامانه‌های تدریس هوشمند و محیط‌های یادگیری مبتنی بر هوش مصنوعی زمانی اثربخش‌تر هستند که بتوانند بازخورد سریع و مستمر فراهم کنند (Alvarez et al., 2024; Elhaimeur &

Chrisochoides, 2026). بنابراین، ارزشیابی در برنامه‌ریزی درسی انطباقی نه صرفاً ابزار سنجش نتیجه، بلکه مکانیسم تنظیم و هدایت مستمر یادگیری است.

از دیگر یافته‌های مهم، جایگاه مستقل «نقش معلم در کنترل و هدایت فرایند» بود. این نتیجه نشان داد که چارچوب مطلوب برنامه‌ریزی درسی انطباقی نباید بر حذف یا حاشیه‌راندن معلم استوار باشد. معلم همچنان مسئول تفسیر زمینه آموزشی، ارزیابی مناسب بودن توصیه‌های الگوریتمی، توجه به عوامل عاطفی و اجتماعی و اصلاح تصمیم‌های سیستم است. این یافته با مطالعاتی همسو است که بر ضرورت توانمندسازی معلمان برای کار با هوش مصنوعی و توسعه شایستگی‌های جدید حرفه‌ای تأکید دارند (Kesgin, 2025; Yokuş, 2025). همچنین، مطالعات مربوط به کلاس‌های هوشمند نشان داده‌اند که فناوری در صورت نبود هدایت حرفه‌ای معلم ممکن است نتواند پیچیدگی‌های واقعی یادگیری را به‌درستی مدیریت کند (Chopra, 2023). بنابراین، رابطه میان معلم و هوش مصنوعی در چارچوب حاضر از جنس جایگزینی نیست، بلکه از جنس همکاری، کنترل و تکمیل متقابل است.

در کنار این مؤلفه‌ها، «الزامات اخلاقی، امنیتی و حمایتی» به‌عنوان یک لایه فراگیر در چارچوب نهایی ظاهر شد. اهمیت بالای این مؤلفه با توجه به حجم داده‌های فردی مورد نیاز برای شخصی‌سازی قابل انتظار است. حفاظت از حریم خصوصی، جلوگیری از سوگیری الگوریتمی، شفافیت تصمیم‌ها، امنیت داده، عدالت در دسترسی و قابلیت توضیح توصیه‌های سامانه از جمله الزامات اساسی شناسایی‌شده بودند. این نتیجه با مطالعاتی که درباره چالش‌های اخلاقی عامل‌های آموزشی هوشمند انجام شده‌اند همسو است (Córdova-Esparza, 2025). همچنین، رویکردهای انسان‌محور در طراحی سامانه‌های تدریس هوشمند بر ضرورت شمول، پایداری، پاسخ‌گویی و حفاظت از رفاه یادگیرندگان تأکید کرده‌اند (Triantafyllou, 2026). مطالعات دیگر نیز هشدار داده‌اند که استفاده از هوش مصنوعی بدون ملاحظات اخلاقی و حکمرانی مناسب می‌تواند به تقویت نابرابری یا ایجاد وابستگی بیش از حد به تصمیم‌های الگوریتمی منجر شود (Chembe et al., 2023; Patel & Ragolane, 2024). بنابراین، یافته‌های حاضر نشان می‌دهد که اخلاق و امنیت نباید به‌عنوان ملاحظات جانبی پس از طراحی سیستم مورد توجه قرار گیرند، بلکه باید از ابتدا در معماری برنامه درسی انطباقی تعبیه شوند.

نتایج کمی پژوهش نیز اعتبار ساختار مفهومی حاصل از مرحله کیفی را تأیید کرد. ضرایب آلفای کرونباخ و پایایی ترکیبی برای تمامی سازه‌ها در سطح مطلوب قرار داشت و مقادیر میانگین واریانس استخراج‌شده نیز شواهد کافی برای روایی همگرا فراهم کرد. همچنین، بارهای عاملی استانداردشده در دامنه قابل قبول قرار داشتند و شاخص‌های برازش مدل شامل CFI، TLI، RMSEA و SRMR نشان دادند که ساختار ده‌بعدی با داده‌های تجربی هماهنگ است. این نتیجه از اهمیت روش‌شناختی برخوردار است؛ زیرا نشان می‌دهد مضامین استخراج‌شده از دیدگاه خبرگان، تنها توصیف‌های نظری نیستند و در مرحله کمی نیز به‌صورت سازه‌های قابل اندازه‌گیری و متمایز قابل تأیید بوده‌اند. این یافته با جهت‌گیری پژوهش‌های جدیدی همسو است که بر ضرورت حرکت از بحث‌های نظری درباره هوش مصنوعی در آموزش به سمت مدل‌های قابل سنجش، اعتبارسنجی‌شده و قابل استفاده در محیط واقعی تأکید دارند (Wang’ang’a, 2024; Іванашко et al., 2024). همچنین،

شواهد مربوط به توسعه سامانه‌های آموزشی هوشمند در حوزه‌های مختلف نشان می‌دهد که موفقیت عملی چنین مدل‌هایی به انسجام مفهومی و اعتبار تجربی مؤلفه‌های آنها وابسته است (Elmadani, 2026; Sun, 2023).

در مجموع، یافته‌های پژوهش حاضر برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی را به‌عنوان یک چرخه پویا و چندسطحی معرفی می‌کند که در آن داده‌های یادگیری به شناخت تفاوت‌های فردی منجر می‌شوند، این شناخت در قالب پروفایل پویا سازمان می‌یابد، هوش مصنوعی از آن برای تولید توصیه‌های برنامه درسی استفاده می‌کند و نتایج تصمیم‌ها از طریق ارزشیابی و بازخورد مجدداً به چرخه داده بازمی‌گردند. نقش معلم و الزامات اخلاقی نیز به‌صورت دو سازوکار کنترل‌کننده و تنظیم‌گر در سراسر این چرخه عمل می‌کنند. این برداشت با روند کلی ادبیات معاصر همسو است که هوش مصنوعی را نه صرفاً ابزار اتوماسیون، بلکه زیرساختی برای بازطراحی یادگیری، برنامه درسی و تصمیم‌گیری آموزشی می‌داند (Mbithi & Maina, 2025; Ojha et al., 2023; Wang et al., 2023). ارزش افزوده پژوهش حاضر در این است که مؤلفه‌هایی که در مطالعات پیشین عمدتاً به‌صورت پراکنده بررسی شده‌اند، در قالب یک چارچوب یکپارچه و مبتنی بر شواهد کیفی و کمی در سطح برنامه‌ریزی درسی سازمان یافته‌اند.

یکی از محدودیت‌های پژوهش حاضر آن بود که بخش کیفی بر دیدگاه متخصصان مستقر در شهر تهران و بخش کمی بر دانش‌آموزان دوره دوم متوسطه این شهر متمرکز بود؛ بنابراین، تعمیم نتایج به سایر مناطق جغرافیایی، مقاطع تحصیلی و نظام‌های آموزشی باید با احتیاط انجام شود. علاوه بر این، داده‌های کمی عمدتاً بر پاسخ‌های پرسشنامه‌ای استوار بود و امکان بررسی مستقیم عملکرد واقعی دانش‌آموزان در یک سامانه کامل برنامه‌ریزی درسی انطباقی فراهم نبود. همچنین، چارچوب پیشنهادی در سطح مفهومی و اندازه‌گیری اعتبارسنجی شد و در یک محیط واقعی مبتنی بر هوش مصنوعی به‌صورت طولی مورد آزمون قرار نگرفت. سرعت بالای تحول فناوری‌های هوش مصنوعی نیز محدودیت دیگری محسوب می‌شود؛ زیرا برخی قابلیت‌ها، مدل‌ها و الزامات فنی ممکن است در آینده نزدیک تغییر کنند و نیاز به بازنگری در اجزای چارچوب ایجاد شود.

پیشنهاد می‌شود پژوهش‌های آینده چارچوب حاضر را در مقاطع ابتدایی، متوسطه اول، آموزش عالی و آموزش‌های فنی و حرفه‌ای مورد بررسی قرار دهند و تفاوت‌های احتمالی میان گروه‌های سنی و محیط‌های آموزشی مختلف را تحلیل کنند. اجرای مطالعات طولی و آزمایشی برای بررسی تأثیر واقعی استفاده از چارچوب بر پیشرفت تحصیلی، انگیزش، درگیری تحصیلی و خودتنظیمی یادگیرندگان نیز ضروری است. همچنین، توسعه نمونه اولیه یک سامانه مبتنی بر این چارچوب و مقایسه نتایج آن با برنامه‌های درسی غیرانطباقی می‌تواند شواهد تجربی قوی‌تری فراهم سازد. بررسی نقش متغیرهایی مانند سواد هوش مصنوعی معلمان، پذیرش فناوری، آمادگی زیرساختی مدارس، عدالت الگوریتمی، قابلیت توضیح تصمیم‌های هوشمند و تفاوت‌های اجتماعی و اقتصادی دانش‌آموزان نیز می‌تواند به تکمیل مدل کمک کند. پژوهش‌های آینده همچنین می‌توانند از روش‌های تحلیل داده‌های واقعی یادگیری، داده‌کاوی آموزشی و مدل‌سازی طولی برای ارزیابی پویایی پروفایل یادگیرنده استفاده کنند.

از نظر کاربردی، پیشنهاد می‌شود سیاست‌گذاران و مدیران آموزشی توسعه برنامه‌ریزی درسی انطباقی را به‌صورت یک پروژه صرفاً فناورانه در نظر نگیرند و همزمان بر زیرساخت داده، طراحی آموزشی، آموزش معلمان و سازوکارهای اخلاقی سرمایه‌گذاری کنند. مدارس و نهادهای آموزشی می‌توانند سامانه‌هایی را به‌تدریج توسعه دهند که ابتدا داده‌های معتبر عملکرد و تعامل دانش‌آموزان را ثبت و تحلیل کنند و سپس از این داده‌ها برای ارائه پیشنهادهای آموزشی به معلمان بهره بگیرند. ضروری است اختیار نهایی تصمیم‌های مهم آموزشی در اختیار معلم باقی بماند و سامانه هوشمند نقش پشتیبان تصمیم را ایفا کند. همچنین، طراحی دستورالعمل‌های روشن درباره حریم خصوصی، دسترسی به داده‌ها، نحوه استفاده از پروفایل دانش‌آموزان، جلوگیری از سوگیری و امکان اعتراض یا اصلاح تصمیم‌های الگوریتمی باید پیش از اجرای گسترده چنین سیستم‌هایی انجام شود. در نهایت، اجرای آزمایشی چارچوب در تعداد محدودی از مدارس، ارزیابی مستمر نتایج و اصلاح تدریجی آن می‌تواند مسیر ایمن‌تر و اثربخش‌تری برای استقرار برنامه‌ریزی درسی انطباقی مبتنی بر هوش مصنوعی فراهم سازد.

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

تعارض منافع

در انجام مطالعه حاضر، هیچ‌گونه تضاد منافعی وجود ندارد.

موازین اخلاقی

در تمامی مراحل پژوهش حاضر اصول اخلاقی مرتبط با نشر و انجام پژوهش رعایت گردیده است.

تشکر و قدردانی

از تمامی کسانی که در انجام این پژوهش ما را همراهی کردند تشکر و قدردانی به عمل می‌آید.

EXTENDED SUMMARY

Introduction

The rapid advancement of artificial intelligence (AI), machine learning, learning analytics, intelligent tutoring systems, and educational data mining has created new possibilities for transforming curriculum planning from a predominantly standardized and static process into a dynamic, evidence-based, and learner-responsive system. Traditional curriculum planning generally assumes relatively homogeneous groups of learners and often determines objectives, content, instructional activities, and assessment procedures before instruction begins. Although such approaches provide curricular coherence and organizational stability, they may insufficiently address differences in students' prior knowledge, learning pace, motivation, interests, cognitive characteristics, patterns of engagement, and support needs. The emergence of AI in education has challenged this assumption by enabling educational systems to continuously collect and process learner-generated data and use these data to support increasingly individualized instructional decisions (Boulay et al., 2023; Nguyen et al., 2023; Ojha et al., 2023; Yildirim & Celepcikay, 2021).

A central development associated with AI-supported education is the transition from uniform instruction toward personalized and adaptive learning. Adaptive learning environments can adjust educational content, difficulty levels, sequencing, feedback, learning activities, and instructional support according to an evolving representation of each learner. AI-powered tutors and personalized learning systems have demonstrated the potential to identify learning gaps, tailor learning pathways, and provide

differentiated instructional experiences according to student performance and needs (Alvarez et al., 2024; Galaup, 2023; Ivanova, 2023). More recent AI-driven knowledge models further suggest that adaptive educational environments can integrate learner data, domain knowledge, and pedagogical rules to produce more sophisticated forms of personalization (Ivanova, 2026). Accordingly, adaptation should not be understood merely as changing the difficulty of instructional materials; rather, it can be conceptualized as a continuous process of aligning curriculum components with the changing characteristics of individual learners.

Learning analytics represents one of the most important foundations of such adaptation. Digital educational environments generate substantial amounts of data concerning academic performance, response patterns, time on task, participation, error frequency, learning progression, resource use, and interaction with assessment activities. When analyzed systematically, these data can support descriptive, diagnostic, predictive, and prescriptive decision-making. Machine-learning methods increasingly allow educational systems to detect complex patterns in learner behavior and convert those patterns into actionable information for instructional planning (Deng, 2024; Georgiou, 2026). Reinforcement-learning approaches further extend this capacity by enabling systems to learn from the consequences of previous educational decisions and progressively improve their recommendations (Mon et al., 2023). Thus, learning data become meaningful for curriculum planning when they are transformed into interpretable evidence about learner status and used to inform subsequent educational actions.

The consideration of individual differences is equally fundamental. Students differ not only in academic achievement but also in prior knowledge, rate of learning, motivation, interests, engagement, patterns of error, and the type and intensity of instructional support they require. AI-enabled educational software has increasingly been designed to capture these differences and respond to them through personalized feedback and instructional recommendations (Annuš, 2024). Adaptive curriculum planning therefore requires a dynamic learner profile that can be continuously updated as new data become available. Such a profile can function as an intermediary representation linking learning analytics to instructional decision-making. Rather than assigning learners to fixed categories, a dynamic model can represent changes in performance and learning needs over time, thereby enabling curricular decisions to remain responsive to emerging evidence.

At the same time, the integration of AI into curriculum planning raises pedagogical and ethical concerns. AI-generated recommendations cannot adequately account for every contextual, emotional, social, and educational factor affecting a learner. Consequently, the teacher remains essential as a professional decision-maker who interprets data, evaluates algorithmic suggestions, recognizes contextual circumstances, and modifies recommendations when necessary. Recent work on AI-supported teacher education and classroom integration emphasizes that sustainable adoption requires teachers to develop both technological competencies and the professional capacity to critically evaluate AI-supported decisions (Kesgin, 2025; Yokuş, 2025). Furthermore, the extensive use of student data introduces concerns related to privacy, algorithmic bias, transparency, explainability, data security, accountability, and equitable access. Human-centered approaches to intelligent educational systems therefore emphasize that technological effectiveness must be accompanied by ethical safeguards, inclusion, and meaningful human oversight (Córdova-Esparza, 2025; Triantafyllou, 2026).

Although previous studies have separately examined AI-based tutoring, learning analytics, machine learning, personalized learning, educational software, and intelligent curriculum design, these areas are often treated as distinct lines of inquiry. There remains a need for an integrated framework explaining how learning data, individual learner differences, dynamic learner modeling, AI-based decision-making, curriculum adaptation, continuous assessment, teacher supervision, and ethical safeguards can function together as components of a coherent curriculum-planning system. Recent developments in AI-powered curriculum design and smart educational environments reinforce the importance of developing such integrated models (Wang et al., 2025; Xu & Zhang, 2026). Therefore, the present study aimed to design and validate a conceptual framework for AI-based adaptive curriculum planning with emphasis on learning analytics and students' individual differences.

Methods and Materials

This study employed an exploratory sequential mixed-methods design consisting of qualitative exploration followed by quantitative validation. In the qualitative phase, the study population included faculty members and specialists in curriculum planning, educational technology, artificial intelligence in education, educational measurement and assessment, and learning analytics in Tehran. Participants were selected through purposive sampling according to their academic expertise, professional experience, and direct relevance to the research topic. Inclusion criteria consisted of possessing a doctoral degree in a relevant field or substantial professional expertise in intelligent learning systems, having at least five years of relevant academic or professional experience, and willingness to participate in an in-depth interview. Sampling continued until theoretical saturation was achieved. A total of 20 experts participated in this phase. Saturation was substantially reached after the eighteenth interview, and two additional interviews were conducted to ensure conceptual adequacy.

Qualitative data were collected using semi-structured interviews lasting approximately 45 to 70 minutes. The interviews explored the essential components of adaptive curriculum planning, types of learner data required for adaptation, mechanisms

for identifying individual differences, AI-supported decision-making, adaptation of curriculum objectives and content, instructional strategies, learning activities, intelligent assessment, teacher supervision, and ethical and technical requirements. Interviews were transcribed verbatim and analyzed through thematic analysis. Initial codes were generated from meaningful units of text, conceptually similar codes were grouped into subcategories, and related subcategories were progressively organized into broader themes. The analysis involved repeated comparison between raw interview data, codes, subcategories, and final themes.

In the quantitative phase, the statistical population consisted of upper-secondary students in Tehran. A final sample of 400 students was selected through multistage cluster sampling. A researcher-developed questionnaire was constructed directly from the qualitative findings. Items represented the themes and indicators identified during the interview phase and were scored using a five-point Likert scale. Content and face validity were assessed by a panel of experts, and the instrument was pilot-tested for clarity before administration. Quantitative data analysis included descriptive statistics, assessment of missing values and distributional assumptions, internal consistency reliability, composite reliability, average variance extracted, and confirmatory factor analysis. Model fit was evaluated using the chi-square to degrees-of-freedom ratio, GFI, AGFI, CFI, TLI, NFI, IFI, RMSEA, and SRMR.

Findings

The qualitative phase included 20 experts, of whom 12 were men and 8 were women. Their mean age was 47.85 years with a standard deviation of 6.42, and their professional experience averaged 16.70 years with a standard deviation of 5.61. The quantitative sample consisted of 400 upper-secondary students, including 206 girls and 194 boys. Their mean age was 16.47 years with a standard deviation of 0.91. Of the students, 138 were in Grade 10, 134 in Grade 11, and 128 in Grade 12.

Thematic analysis resulted in 10 major components of AI-based adaptive curriculum planning: data-driven curriculum infrastructure, learning analytics, identification of individual differences, dynamic learner-profile modeling, adaptation of learning objectives and instructional content, adaptation of teaching strategies and learning activities, intelligent assessment and continuous feedback, AI-based decision-making, teacher supervision and process guidance, and ethical, security, and supportive requirements. After merging overlapping codes and removing redundancies, 200 final qualitative codes remained. Identification of individual differences generated the largest number of final codes, followed by AI-based decision-making, adaptation of objectives and content, and learning analytics. The greatest interview-reference frequencies were also observed for identification of individual differences, AI-based decision-making, and learning analytics, indicating the centrality of these components within the proposed framework.

Quantitative findings supported the reliability and validity of the extracted structure. Mean scores for the 10 constructs ranged from 4.01 to 4.29. The highest mean was observed for ethical, security, and supportive requirements, followed by teacher supervision and intelligent assessment with continuous feedback. Cronbach's alpha coefficients ranged from 0.86 to 0.92, while composite reliability coefficients ranged from 0.89 to 0.94. Average variance extracted ranged from 0.61 to 0.71, exceeding the acceptable threshold for all constructs and providing evidence of convergent validity.

Confirmatory factor analysis further supported the proposed measurement model. Standardized factor loadings ranged from 0.67 to 0.91, and all associated t-values were statistically significant. The lowest t-value was 12.44 and the highest was 24.12, indicating that all observed indicators contributed significantly to their intended latent constructs. Model-fit analysis yielded $\chi^2 = 1124.36$ with 514 degrees of freedom and $\chi^2/df = 2.19$. Additional indices were GFI = 0.91, AGFI = 0.89, CFI = 0.95, TLI = 0.94, NFI = 0.92, IFI = 0.95, RMSEA = 0.055, and SRMR = 0.046. Collectively, these values indicated an acceptable to strong fit between the conceptual structure derived from the qualitative phase and the empirical data obtained from students.

Discussion and Conclusion

The findings indicate that AI-based adaptive curriculum planning is best understood as an interconnected and cyclical educational system rather than as the application of a single intelligent technology. The proposed framework begins with a data-driven curriculum infrastructure through which academic, behavioral, and interaction data are continuously collected. These data are processed through learning analytics and interpreted in relation to students' individual differences. The resulting information is then organized into a dynamic learner profile that represents the learner's current knowledge, performance, pace, interests, motivation, and support requirements.

This profile provides the informational basis for AI-supported decision-making. The AI component does not function as an autonomous replacement for professional educational judgment; rather, it transforms analyzed learner information into recommendations concerning learning objectives, instructional content, teaching strategies, learning activities, difficulty levels, pacing, and assessment. Intelligent assessment subsequently measures the consequences of these adaptations and generates new data, thereby returning information to the beginning of the cycle. The framework is therefore self-correcting: curriculum decisions are continuously revised according to evidence produced through learner interaction and assessment.

A particularly important contribution of the framework is its treatment of teacher supervision as an integral rather than external component. Adaptive systems may identify patterns and generate recommendations at a scale that is difficult for teachers to

achieve manually, but educational decisions remain context-sensitive. Teachers are needed to interpret recommendations, consider emotional and social circumstances, recognize exceptional cases, and approve or revise algorithmic decisions. The model therefore positions AI as a decision-support mechanism operating under professional human oversight.

The findings also demonstrate that ethical, security, and supportive requirements should not be treated as supplementary considerations. Because adaptive curriculum planning depends heavily on individualized learner data, privacy protection, data security, algorithmic transparency, fairness, explainability, and accountability must operate across all components of the system. The high quantitative evaluation of this dimension suggests that effective implementation requires technical and pedagogical innovation to proceed alongside governance mechanisms designed to protect students.

Overall, the mixed-methods findings support a 10-component conceptual framework in which learning analytics and individual differences form the primary bridge between educational data and adaptive curriculum decisions. The framework expands personalization beyond content recommendation by incorporating objectives, instructional strategies, activities, assessment, feedback, teacher oversight, and ethical governance. Its empirical validation suggests that the proposed structure possesses sufficient conceptual coherence, reliability, and construct validity to serve as a foundation for future development and implementation of AI-supported adaptive curriculum systems. In conclusion, the study provides an integrated model for transforming curriculum planning from a predominantly static and uniform process into a dynamic, data-driven, learner-sensitive, continuously evaluated, and human-supervised system capable of responding to the changing educational needs of individual students.

References

Alashwal, M. (2024). Empowering Education Through Ai: Potential Benefits and Future Implications for Instructional Pedagogy. 201-212. https://doi.org/10.20319/ictel.2024.201212

Aliyu, A. M., Gambari, A. I., Bello, I. i. M., & Folorunso, T. A. (2026). Development and Validation of AI Instructional Platform Using ADDIE Model for Enhancing Pre-Service Biology Teachers Learning Outcomes in Collaborative Learning Settings in North-East, Nigeria. https://doi.org/10.21203/rs.3.rs-10795144/v1

Alvarez, J. I., Cortez, A. O., & Alberto, M. Z. (2024). Personalized Learning in Action: Utilizing AI-powered Tutors to Bridge the Gap in Mathematics. *International Journal of Research Studies in Education*, *13*(8). https://doi.org/10.5861/ijrse.2024.24074

Annuš, N. (2024). Educational Software and Artificial Intelligence: Students' Experiences and Innovative Solutions. *Information Technologies and Learning Tools*, *101*(3), 200-226. https://doi.org/10.33407/itlt.v101i3.5479

Boulay, B. d., Mitrović, A., & Yacef, K. (2023). Introduction to the Handbook of Artificial Intelligence in Education. 2-9. https://doi.org/10.4337/9781800375413.00009

Chembe, C., Nasilele, N. B., & M'sendo, R. (2023). The Fuss About Artificial Intelligence in Education Sector: Should We Worry? *Zambia Ict Journal*, *7*(2), 30-35. https://doi.org/10.33260/zictjournal.v7i2.269

Chhatwal, M., Garg, V., & Rajput, N. (2023). Role of AI in the Education Sector. *Lloyd Business Review*, 1-7. https://doi.org/10.56595/lbr.v2i1.11

Chopra, D. (2023). Smart Classrooms, Smarter Teachers: A Deep Dive Into AI-Driven Educational Enhancement. https://doi.org/10.52783/jier.v3i2.479

Córdova-Esparza, D. M. (2025). AI-Powered Educational Agents: Opportunities, Innovations, and Ethical Challenges. *Information*, *16*(6), 469. https://doi.org/10.3390/info16060469

Deng, Y. (2024). A Systematic Review of Application of Machine Learning in Curriculum Design Among Higher Education. *Journal of Emerging Computer Technologies*, *4*(1), 15-24. https://doi.org/10.57020/ject.1475566

Elhaimeur, I., & Chrisochoides, N. (2026). From Prototype to Classroom: An Intelligent Tutoring System for Quantum Education. https://doi.org/10.48550/arxiv.2604.24807

Elmadani, A. (2026). Artificial Intelligence in English Language Teaching for Undergraduate University Students Opportunities Challenges and Pedagogical Implications. https://doi.org/10.21203/rs.3.rs-10886848/v1

Galaup, M. (2023). Reflection on the Construction and Impact of an Adaptive Learning Ecosystem. *Revue Internationale Des Technologies en Pédagogie Universitaire*, *20*(2), 125-138. https://doi.org/10.18162/ritpu-2023-v20n2-10

Georgiou, G. P. (2026). Machine Learning in Education. *Algorithms*, *19*(6), 441. https://doi.org/10.3390/a19060441

Huong, X. V. (2024). The Implications of Artificial Intelligence for Educational Systems: Challenges, Opportunities, and Transformative Potential. *The American Journal of Social Science and Education Innovations*, *06*(03), 101-111. https://doi.org/10.37547/tajssei/volume06issue03-17

Ivanova, T. (2023). A Multi-Agent Architecture for Learning Paths-Based Personalized E-Learning Systems. *International Journal on Information Technologies and Security*, *15*(4), 49-60. https://doi.org/10.59035/qeza3869

Ivanova, T. (2026). Ontology-Based Layered Hybrid AI-Driven Knowledge Model for Personalized E-Learning. *Mathematics*, *14*(5), 808. https://doi.org/10.3390/math14050808

Kesgin, K. (2025). Mapping and Modeling the Role of Artificial Intelligence in Science Education: From Bibliometrics to Classroom Integration. https://doi.org/10.21203/rs.3.rs-6542160/v1

Mbithi, A., & Maina, L. (2025). Artificial Intelligence (AI) Promise for Equitable Education in Emerging Economies. https://doi.org/10.21203/rs.3.rs-7216045/v1

Mon, B. F., Wasfi, A., Hayajneh, M., & Ali, N. A. (2023). Reinforcement Learning in Education: A Literature Review. *Informatics*, *10*(3), 74. https://doi.org/10.3390/informatics10030074

Nguyen, T., Nguyễn, M. T., & Tran, H. T. (2023). Artificial Intelligent Based Teaching and Learning Approaches: A Comprehensive Review. *International Journal of Evaluation and Research in Education (Ijere)*, *12*(4), 2387. https://doi.org/10.11591/ijere.v12i4.26623

Ojha, S., Mohapatra, S., & Misra, I. (2023). From Robots to Books-an Introduction to Smart Applications of AI in Education (AIEd). https://doi.org/10.36227/techrxiv.21836610.v1

Patel, S., & Ragolane, M. (2024). The Implementation of Artificial Intelligence in South African Higher Education Institutions: Opportunities and Challenges. *Technium Education and Humanities*, *9*, 51-65. https://doi.org/10.47577/teh.v9i.11452

Peralta, M. A. C., & Martínez, J. L. V. (2024). Application of Academic Analytical Models in Education Management. *Journal of Educational and Social Research*, *14*(6), 274. https://doi.org/10.36941/jesr-2024-0171

Soviak, R., & Antoniv, V. (2023). Processes of Development of Intellectual Systems in Education. *Visnyk of the Lviv University Series Economics*(63). https://doi.org/10.30970/ves.2022.63.0.6320

Sun, R. (2023). Innovations of Music and Aesthetic Education Courses Using Intelligent Technologies. *Education and Information Technologies*, *28*(10), 13665-13688. https://doi.org/10.1007/s10639-023-11624-9

Suvendu, R., & S, D. P. (2024). AI-Driven Flipped Classroom: Revolutionizing Education Through Digital Pedagogy. *British Journal of Education Learning and Development Psychology*, *7*(2), 169-179. https://doi.org/10.52589/bjeldp-ltdjflih

Triantafyllou, S. A. (2026). Sustainable Intelligent Tutoring Systems for Social Well-Being: A Human-Centered Framework for Inclusive, Ethical, and Resilient Learning. *Sustainability*, *18*(17), 8946. https://doi.org/10.3390/su18178946

Wang, J., Nong, R., Liu, J.-N., & Evans, L. (2025). Adaptive Learning Systems: Personalized Curriculum Design Using LLM-Powered Analytics. https://doi.org/10.21203/rs.3.rs-7210109/v1

Wang, X., He, X., Wei, J., Liu, J., Li, Y., & Liu, X. (2023). Application of Artificial Intelligence to the Public Health Education. *Frontiers in Public Health*, *10*. https://doi.org/10.3389/fpubh.2022.1087174

Wang'ang'a, A. W. (2024). Consequences of Artificial Intelligence on Teaching and Learning in Higher Education in Kenya: Literature Review. *East African Journal of Education Studies*, *7*(1), 202-215. https://doi.org/10.37284/eajes.7.1.1718

Xu, X., & Zhang, B. (2026). Construction and Practice of a Blended Smart Course for Environmental Microbiology Under OBE Principles. *Applied Sciences*, *16*(17), 8564. https://doi.org/10.3390/app16178564

Ye, C., Fang, F., Zhang, N., Wang, L., & Wan, H. (2026). System Design of Intelligent Logistics Training Base Based on Information Technology Integration. *Journal of Cases on Information Technology*, *28*(1), 1-24. https://doi.org/10.4018/jcit.398563

Yildirim, Y., & Celepcikay, A. (2021). Artificial Intelligence and Machine Learning Applications in Education. *Eurasian Journal of Higher Education*, *2*(4), 1-11. https://doi.org/10.31039/ejohe.2021.4.49

Yokuş, G. (2025). A Multi-Stakeholder Vision for Designing AI-Empowered Teacher Education: Exploring Key Components for Sustainable Institutional Change. *Sustainability*, *17*(21), 9815. https://doi.org/10.3390/su17219815

Іванашко, О., Козак, А., Knysh, T., & Honchar, K. (2024). The Role of Artificial Intelligence in Shaping the Future of Education: Opportunities and Challenges. *Futurity Education*, 126-146. https://doi.org/10.57125/fed.2024.03.25.08