Iranian Agricultural Extension and Education Journal 21 (2026) 1-23

Online ISSN: 2980-8561

Iranian Agricultural Extension and Education Journal

Journal Homepage: http://www. https://www.iaeej.ir/

Research Paper

Analysis of AI Tool Usage Behavior Among Agricultural Students: An Integrated Approach of Structural Equation Modeling (SEM) and Artificial Neural Network (ANN)

Omid Jamshidi [a,*] , **Seyed Mohammad Javad Sobhani**[b]

[a] Department of Agricultural Extension and Education, Faculty of Crop Sciences, Sari Agricultural and Natural Resourses University, Sari, Iran
[b] Department of Agricultural Extension and Education, Faculty of Agricultural Engineering and Rural Development, Agricultural Sciences and Natural Resources University of Khuzestan, Mollasani, Iran

ARTICLE INFO

Article history:
Received: 27 Auguast 2025
Revised: 20 November 2025
Accepted: 29 November 2025

Keywords:
Artificial Intelligenc
Agricultural higher education
Artificial neural network
Structural equation modeling
Technology adoption

ABSTRACT

Given the rapid expansion of artificial intelligence (AI) technologies across various domains, identifying the factors that influence students' adoption and use of these tools has become increasingly important. This study aimed to analyze the usage behavior of AI tools among agricultural students using an integrated approach that combines Structural Equation Modeling (SEM) and Artificial Neural Network (ANN). The research employed a descriptive-survey method, and the study population consisted of students from Sari University of Agricultural Sciences and Natural Resources who had participated in AI-related courses during the 2022–2023 academic years. Using Krejcie and Morgan's table, a sample size of 176 was determined, and data were collected through stratified random sampling with proportional allocation. The main research instrument was a questionnaire, whose validity and reliability were confirmed. Data analysis was conducted using SEM with SmartPLS3 software and ANN analysis to incorporate complementary linear and nonlinear perspectives in explaining user behavior. The findings revealed that all examined variables—social norms, self-efficacy, perceived usefulness, perceived ease of use, and technology access—had a significant positive effect on the usage behavior of AI tools. Among these factors, social norms played the most substantial role in the SEM analysis, indicating that support from peers, instructors, and the university environment were the primary drivers of technology adoption. In contrast, the ANN analysis highlighted the critical importance of self-efficacy, suggesting that students' belief in their individual capability to use technology is a latent yet highly influential factor. Additionally, the results underscored that without adequate access to technological infrastructure, other motivational factors would be ineffective. Based on the findings, facilitating the adoption and utilization of AI tools in agricultural higher education can be achieved by strengthening a technology-oriented culture within academic environments, enhancing students' digital self-efficacy, developing technological infrastructure, designing user-friendly tools tailored to the needs of agricultural disciplines, and providing continuous and up-to-date training in AI.

1. Introduction

In the current era, the digital revolution and the emergence of novel technologies, including artificial intelligence (AI), have transformed all scientific and professional fields, including agriculture. Although the extensive applications and potential benefits of AI tools in agriculture are well documented, there remains a significant gap in understanding the factors influencing users' intentions and actual behaviors regarding these technologies within agricultural higher education systems. Meanwhile, advancements in AI represent one of the key developments capable of revolutionizing education and learning. Despite these advancements, a fundamental challenge in effectively leveraging AI technologies lies in the level of readiness, awareness, and attitudes of the academic community toward these technologies. Various studies have shown that users' attitudes and levels of knowledge regarding new technologies are key predictors of their acceptance or resistance. This significance has led to numerous studies on AI usage behavior among users, particularly in academic settings, identifying various influential factors. A general review of existing research indicates that most studies have

* Corresponding author: Assistant Professor, Department of Agricultural Extension and Education, Faculty of Crop Sciences, Sari Agricultural Sciences and Natural Resourses University, Sari, Iran
E-mail address: O.jamshidi@sanru.ac.ir
https://doi.org/10.22034/iaeej.2026.543688.1870

either focused solely on technology-centered examinations of AI or approached it from a purely technical and engineering perspective, with limited attention given to analyzing the factors influencing students' behavior in agricultural disciplines. Furthermore, field studies employing rigorous psychometric tools and structural analyses such as structural equation modeling (SEM) are scarce in this context. Therefore, the present study aims to fill this research gap by conducting a comprehensive and systematic assessment of the factors affecting AI usage, the results of which can significantly contribute to the design of technology-enhanced educational programs, the improvement of digital literacy, and the alignment of higher education systems with global developments. Given the existing research gap at the national and regional levels, this study was conducted to analyze the usage behavior of AI tools among agricultural students.

2. Methodology

This study is applied in purpose and quantitative in paradigm. Data were collected through a survey. The statistical population consisted of students at Sari University of Agricultural Sciences and Natural Resources (N = 310) who had participated in at least one AI-related training course during 2023 and 2024. Stratified random sampling with proportional allocation was employed, in which strata were defined based on educational level, and the sample size for each stratum was determined according to its proportion within the population. Using Krejcie and Morgan's table, the sample size was estimated at 172; however, data from 176 questionnaires were analyzed to enhance reliability. The data collection instrument was a researcher-developed questionnaire based on theoretical literature and previous studies, consisting of two sections: demographic information (major, educational level, gender, and AI usage experience) and research model components (items measured on a Likert scale ranging from "not at all" to "very much"). The validity of the research instrument was confirmed through feedback from experts in the field of education and professors of agricultural extension and education. To assess reliability, Cronbach's alpha and composite reliability indices were calculated. To comprehensively examine the linear and nonlinear relationships between exogenous and endogenous constructs, this study employed a hybrid methodology integrating SEM and ANN. In the first stage, partial least squares structural equation modeling (PLS-SEM) was conducted using SmartPLS version 3 to examine the linear relationships between constructs. In the second stage, to address the limitations of SEM in capturing nonlinear relationships, a multilayer perceptron (MLP) artificial neural network (ANN) analysis was applied. The implemented MLP framework in this study consisted of three main components: an input layer, one or more hidden layers, and an output layer. In the ANN model, the input layer represented the independent variables (social norms, self-efficacy, perceived usefulness, perceived ease of use, and access), while the hidden layers facilitated nonlinear processing and feature extraction. The output layer enabled the prediction of the dependent variable, AI tool usage behavior. Both the hidden and output layers used the sigmoid activation function, a common choice in classification-based research.

3. Findings

The findings revealed that all examined variables, including social norms, self-efficacy, perceived usefulness, perceived ease of use, and access to technology, had a positive and significant effect on AI tool usage behavior. Among these factors, social norms played the most prominent role in the SEM analysis, indicating that support from peers, professors, and the academic environment was the most critical driver of using these technologies. In contrast, the ANN analysis highlighted the distinctive importance of self-efficacy, demonstrating that students' belief in their individual ability to use technology may be a latent yet highly influential factor. The results also indicated that without adequate access to technological infrastructure, other motivational factors would not achieve the necessary level of effectiveness.

4. Discussion

This study, by employing a novel hybrid approach (SEM-ANN), provides a multi-layered and deeper understanding of the factors determining AI acceptance among agricultural students. While the SEM analysis confirmed the prominent and linear role of social norms as the strongest predictor, the key and distinctive finding of this research was the identification of the nonlinear and complex roles of self-efficacy and access to technology through ANN analysis. This suggests that the impact of these variables may not be simple or direct but may vary in intensity at different levels, thereby influencing user behavior in different ways—a phenomenon that traditional linear models are unable to detect. These findings enrich the existing theoretical discussion by demonstrating that integrating theory-based models (such as TAM and TPB) with data-driven methods (such as ANN) can better explain the complexity of human behavior when interacting with new technologies. From a practical perspective, these results emphasize that educational policies aimed at promoting AI acceptance must adopt a multifaceted strategy rather than merely focusing on usefulness and ease of use. Such a strategy should include fostering a supportive organizational culture to normalize AI use, implementing training programs to enhance students' self-confidence, and, most importantly, ensuring equitable and barrier-free access to the necessary infrastructure and tools for all students in order to prevent the widening of the digital divide.

5. Conclusion

In conclusion, this research emphasizes that AI acceptance among agricultural students is a multidimensional phenomenon primarily shaped by five key factors: social norms (as the strongest predictor), access to technology, perceived ease of use, perceived usefulness, and self-efficacy. The findings particularly highlight the pivotal role of the social environment and academic culture, suggesting that normalizing AI use can serve as a primary driver of its acceptance. Additionally, the identification of the nonlinear and complex role of self-efficacy through ANN analysis indicates that enhancing students' self-confidence through practical training can significantly influence usage behavior. Alongside these factors, the decisive influence of infrastructure and equitable access is emphasized as a fundamental prerequisite. Ultimately, these results call on educational policymakers to adopt a comprehensive approach in which organizational culture-building, infrastructure development, skill-based training, and the design of user-friendly tools relevant to the specialized field are pursued simultaneously to achieve widespread and meaningful AI acceptance in agricultural higher education.

Acknowledgments

This article is derived from the results of a research project entitled "Analysis of the Attitudinal and Knowledge Structures Influencing the Application of Artificial Intelligence Technologies Among Students at Sari University of Agricultural Sciences and Natural Resources" (Contract No. 01-1404-07) supported by the Sari Agricultural Sciences and Natural Resourses University, Sari, Iran. The authors extend their gratitude for the material and intellectual support of Reasearch Deputy of Vice-Chancellor of the university

نوع مقاله: پژوهشی

DOI: 10.22034/iaeej.2026.543688.1870

تحلیل رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان کشاورزی: رویکرد تلفیقی مدل‌سازی معادلات ساختاری (SEM) و شبکه عصبی مصنوعی (ANN)

امید جمشیدی[1]* و سید محمدجواد سبحانی[2]

(دریافت: ۱۴۰۴/۰۶/۰۵؛ پذیرش: ۱۴۰۴/۰۹/۰۸)

چکیده

با توجه به گسترش پرشتاب فناوری‌های هوش مصنوعی در عرصه‌های گوناگون، شناسایی عوامل مؤثر بر پذیرش و به‌کارگیری این ابزارها توسط دانشجویان اهمیتی روزافزون یافته است. هدف این پژوهش، تحلیل رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان کشاورزی با رویکرد تلفیقی مدل‌سازی معادلات ساختاری و شبکه عصبی مصنوعی بود. این پژوهش از نظر هدف کاربردی و از نظر روش توصیفی-پیمایش بود. جامعه آماری پژوهش شامل دانشجویان دانشگاه علوم کشاورزی و منابع طبیعی ساری بود که در دوره‌های آموزشی مرتبط با هوش مصنوعی شرکت کرده بودند. با استفاده از جدول کرجسی و مورگان حجم نمونه ۱۷۶ نفر تعیین و داده‌ها با روش نمونه‌گیری تصادفی طبقه‌ای با انتساب متناسب جمع‌آوری شدند. ابزار اصلی پژوهش پرسشنامه بود که روایی و پایایی آن مورد تأیید قرار گرفت. در این مطالعه برای تحلیل داده‌ها از مدل‌سازی معادلات ساختاری (SEM) با نرم‌افزار پی‌ال‌اس نسخه ۳ (Smart PLS3) و نیز تحلیل شبکه عصبی مصنوعی (ANN) استفاده شد تا دیدگاه‌های مکمل خطی و غیر خطی در تبیین رفتار کاربران مورد بررسی قرار گیرد. یافته‌ها نشان داد که تمامی متغیرهای مورد بررسی شامل هنجار اجتماعی، خودکارآمدی، سودمندی درک‌شده، سهولت درک‌شده و دسترسی به فناوری اثر مثبت و معناداری بر رفتار استفاده از ابزارهای هوش مصنوعی دارند. در میان این عوامل، هنجار اجتماعی بیشترین نقش را در تحلیل SEM ایفا کرد؛ به‌گونه‌ای که حمایت همسالان، اساتید و فضای دانشگاهی مهم‌ترین محرک استفاده از این فناوری‌ها تلقی شد. در مقابل، تحلیل ANN اهمیت ویژه‌ای برای خودکارآمدی قائل شد و نشان داد که باور دانشجویان به توانایی فردی برای استفاده از فناوری می‌تواند عاملی پنهان، اما بسیار تأثیرگذار باشد. همچنین نتایج نشان داد که بدون دسترسی کافی به زیرساخت‌های فناوری، سایر عوامل انگیزشی کارایی لازم را نخواهند داشت. بر اساس نتایج، تقویت فرهنگ استفاده از فناوری در محیط دانشگاهی، ارتقای خودکارآمدی دیجیتال دانشجویان، توسعه زیرساخت‌های فناورانه، طراحی ابزارهای کاربرپسند متناسب با نیازهای رشته کشاورزی و ارائه آموزش‌های مداوم و به‌روز در حوزه هوش مصنوعی می‌تواند پذیرش و بهره‌برداری از این ابزارها را در آموزش عالی کشاورزی تسهیل کند.

واژه‌های کلیدی: آموزش عالی کشاورزی، پذیرش فناوری، شبکه عصبی مصنوعی، مدل‌سازی معادلات ساختاری، هوش مصنوعی.

[1] استادیار گروه ترویج و آموزش کشاورزی، دانشکده علوم زراعی، دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران.

[2] استادیار گروه ترویج و آموزش کشاورزی، دانشکده مهندسی زراعی و عمران روستایی، دانشگاه علوم کشاورزی و منابع طبیعی خوزستان، ملاثانی، ایران.

* نویسنده‌ی مسئول، پست الکترونیک: O.jamshidi@sanru.ac.ir

مقدمه

در عصر حاضر، انقلاب دیجیتال و ظهور فناوری‌های نوین، ماهیت تمامی عرصه‌های علمی و حرفه‌ای، از جمله کشاورزی را دگرگون ساخته است (Pallottino *et al.*, 2025). هوش مصنوعی ((Artificial Intelligence (AI) به عنوان یکی از پیشرفته‌ترین فناوری‌ها، با ارائه ابزارهایی برای پردازش داده‌های کلان، پیش‌بینی، مدل‌سازی و اتوماسیون، پتانسیل عظیمی برای مواجهه با چالش‌های پیچیده حوزه کشاورزی، مانند امنیت غذایی، تغییرات اقلیمی و مدیریت منابع پایه ایجاد کرده است (Rane *et al.*, 2024; Spanaki *et al.*, 2022). اگرچه کاربردهای گسترده و مزایای بالقوه ابزارهای هوش مصنوعی در کشاورزی به خوبی مستند شده است، اما شکاف قابل توجهی در درک عوامل مؤثر بر تمایل و رفتار واقعی کاربران این فناوری در نظام‌های آموزش عالی کشاورزی وجود دارد (Bampasidou *et al.*, 2023). پیشرفت‌های هوش مصنوعی یکی از حوزه‌هایی است که می‌تواند انقلابی در عرصه آموزش و یادگیری ایجاد کند. کاربردهای هوش مصنوعی از سیستم‌های یادگیری هوشمند، ارزیابی خودکار، تولید محتوای شخصی‌سازی‌شده تا طراحی محیط‌های یادگیری تطبیقی گسترده شده است (Zawacki-Richter *et al.*, 2019). این فناوری نه‌تنها می‌تواند فرآیند یادگیری را تسهیل و تسریع کند، بلکه به افزایش انگیزش، خودتنظیمی و مشارکت دانشجویان نیز کمک می‌کند (Holmes *et al.*, 2021).

این تحول فرصت‌هایی همچون افزایش دسترسی به آموزش، تنوع در روش‌های یادگیری و ارتقای عدالت آموزشی را به همراه داشته است (Luckin *et al.*, 2016; OECD, 2023). با این حال، چالش‌هایی از جمله شکاف دیجیتال میان اقشار مختلف دانشجویان، ضعف یا کمبود در زیرساخت‌ها، نبود آموزش کافی برای بهره‌برداری بهینه از فناوری و کاهش تعاملات انسانی در فرایند یادگیری در پی این تحولات ایجاد شده‌اند (Salmon, 2019). علاوه بر این، برخی از فناوری‌های نوین اگر بدون آمادگی ذهنی و دانشی لازم توسط کاربران مورد استفاده قرار گیرند، نه‌تنها به بهبود کیفیت آموزش کمک نمی‌کنند، بلکه ممکن است منجر به تضعیف درک مفهومی و سطحی‌گرایی شوند (Jin, 2025). بر این اساس، نحوه مواجهه نظام آموزش عالی کشاورزی، به‌ویژه دانشجویان، با فناوری‌های نوین، موضوعی است که نیازمند واکاوی دقیق و علمی است (Spanaki *et al.*, 2022). دانشجویان کشاورزی به عنوان آینده‌سازان و مجریان این تحول، نقشی محوری ایفا می‌کنند. میزان پذیرش، نحوه استفاده و عوامل مؤثر بر رفتار آنان در به‌کارگیری ابزارهای هوش مصنوعی، تعیین‌کننده سرعت و موفقیت ادغام این فناوری در چرخه تولید کشاورزی خواهد بود (Bampasidou *et al.*, 2023). به همین دلیل، بررسی رفتار کاربرد هوش مصنوعی دانشجویان نسبت به این فناوری، پیش‌نیازی مهم برای سیاست‌گذاری آموزشی در عصر دیجیتال به شمار می‌آید (دلجو و همکاران، ۱۴۰۳).

در دهه‌های اخیر، تحولات فناوری‌های دیجیتال به‌ویژه در حوزه هوش مصنوعی، به‌سرعت ساختارهای مختلف آموزش عالی را متحول ساخته است. هوش مصنوعی، با قابلیت‌هایی همچون تحلیل پیشرفته داده‌ها، یادگیری ماشینی (machine learning)، پردازش زبان طبیعی و تولید محتوای خودکار، نقش‌های جدیدی در آموزش و یادگیری ایفا کرده است. دانشگاه‌ها و مؤسسات آموزشی، به‌ویژه در دوران پساکرونا، به سمت استفاده از این فناوری‌ها در آموزش مجازی، مشاوره تحصیلی، ارزیابی یادگیری، شخصی‌سازی محتوا و حتی مدیریت امور اداری گام برداشته‌اند (Shabanian *et al.*, 2025)، اما در کنار این پیشرفت‌ها، یکی از چالش‌های اساسی در بهره‌گیری مؤثر از فناوری‌های هوش مصنوعی، سطح آمادگی، آگاهی و نگرش جامعه دانشگاهی نسبت به این فناوری‌هاست. در میان اعضای این جامعه، دانشجویان به عنوان کاربران نهایی و اصلی این فناوری‌ها، نقش محوری در موفقیت یا شکست سیاست‌های فناورانه آموزشی ایفا می‌کنند (Adhikari & Gope, 2025). بررسی‌های مختلف نشان داده‌اند که نگرش و سطح دانش کاربران نسبت به فناوری‌های نوین، یکی از پیش‌بینی‌کننده‌های کلیدی در پذیرش یا مقاومت نسبت به آن‌ها محسوب می‌شود (Sergeeva *et al.*, 2025). در بسیاری از پژوهش‌های بین‌المللی، به‌ویژه در کشورهای در حال توسعه، مشاهده شده است که اگرچه دانشجویان ممکن است نگرش مثبتی نسبت به هوش مصنوعی داشته باشند، اما درک آن‌ها از ماهیت، کاربرد و محدودیت‌های آن اغلب سطحی و گاه متناقض است. به‌عبارت دیگر، «شکاف نگرشی–دانشی» نسبت به فناوری‌های هوش مصنوعی، پدیده‌ای رایج و قابل توجه در محیط‌های دانشگاهی محسوب می‌شود (Yasin, 2022; Li *et al.*, 2025).

این شکاف دانشی می‌تواند پیامدهای متعددی از جمله استفاده غیر مؤثر از ابزارهای هوش مصنوعی، بروز اضطراب تکنولوژیک (Technophobia) و حتی سوءاستفاده‌های تحصیلی مانند استفاده نادرست از ابزارهای تولید خودکار متن را داشته باشد. افزون

بر این، شواهد نشان می‌دهد که سطح سواد دیجیتال و آشنایی قبلی با فناوری، نقش مهمی در شکل‌گیری نگرش نسبت به هوش مصنوعی دارد (Salameh *et al*., 2025). در همین راستا، تحلیل عوامل مؤثر بر رفتار کاربرد هوش مصنوعی در میان دانشجویان، ضروریتی اساسی برای سیاست‌گذاری هوشمندانه و مبتنی بر شواهد در زمینه آموزش و فناوری محسوب می‌شود (دلجو و همکاران، ۱۴۰۳).

دانشگاه علوم کشاورزی و منابع طبیعی ساری، به عنوان یکی از مراکز علمی فعال در حوزه علوم تخصصی، تاکنون تجربه‌هایی در زمینه ورود فناوری‌های نوین به آموزش داشته است، اما پژوهش‌های نظام‌مندی در خصوص بررسی عوامل مؤثر بر رفتار دانشجویان این دانشگاه نسبت به فناوری‌های هوش مصنوعی انجام نشده است. از سوی دیگر، ورود فناوری‌های هوش مصنوعی به حوزه‌هایی چون کشاورزی هوشمند، منابع طبیعی دیجیتال و تحلیل داده‌های محیط‌زیستی، خود گواهی بر ضرورت تجهیز نسل آینده متخصصان این حوزه‌ها به دانش و بینش فناورانه است (Bampasidou *et al*., 2023; Waqas *et al*., 2025; Pallottino *et al*., 2025). در این میان، استفاده از ابزارهای تحلیل ساختاری مانند مدل‌سازی ساختاری و یا شبکه عصبی مصنوعی می‌تواند به فهم دقیق‌تر از روابط میان متغیرهای نگرشی و دانشی کمک کند. این نوع تحلیل‌ها می‌توانند علاوه بر شناسایی سطوح مختلف آگاهی و نگرش، به طراحی راهبردهای آموزشی متناسب برای ارتقای مهارت‌های فناورانه دانشجویان بیانجامد (Sergeeva *et al*., 2025). با توجه به اهمیت موضوع، تاکنون پژوهش‌های محدودی در خصوص مسائل مرتبط با رفتار کاربرد هوش مصنوعی انجام شده است که در ادامه به برخی از آن‌ها اشاره می‌شود. در پژوهشی، پیش‌بینی‌کننده‌های کلیدی قصد رفتاری و رفتار استفاده از فناوری هوش مصنوعی مورد بررسی قرار گرفت. ویژگی متمایز این پژوهش ترکیب جنبه‌های مدل توسعه‌یافته نظریه یکپارچه پذیرش و استفاده از فناوری (UTAUT2) با جنبه‌های فناوری، سازمانی و محیطی (TOE) بود. نتایج نشان داد عملکرد مورد انتظار و تأثیرات اجتماعی، مهم‌ترین عوامل مثبت تعیین‌کننده قصد رفتاری افراد برای پذیرش فناوری هوش مصنوعی هستند (ثانی‌حیدری و صفری، ۱۴۰۴). در مطالعه دیگری که به رتبه‌بندی عوامل مؤثر بر کارکرد هوش مصنوعی در بهبود آموزش ضمن خدمت معلمان اختصاص داشت، از پارادایم پیمایشی برای جمع‌آوری اطلاعات استفاده شد. نتایج نشان داد که داده‌های آموزشی، شخصی‌سازی آموزش و تعامل و همکاری مجازی از مهم‌ترین عوامل مؤثر بر کارکرد هوش مصنوعی در بهبود آموزش ضمن خدمت معلمان هستند (فتحعلی‌بیگی و همکاران، ۱۴۰۳). در پژوهشی وضعیت سواد، کاربست و عوامل مؤثر بر پذیرش هوش مصنوعی در بین اعضای هیئت علمی بررسی شد. نتایج نشان داد که نیت رفتاری، سهولت ادراک شده، سودمندی ادراک شده، ارتباط شغلی، هنجار ذهنی، شرایط تسهیل کننده و نگرش نسبت به استفاده بر پذیرش هوش مصنوعی مؤثر است (حاجی‌انوری و رمضانی، ۱۴۰۳). در مطالعه‌ای مشخص شد که سهولت ادراک شده و سودمندی ادراک شده بیشترین تأثیر را بر قصد رفتاری پاسخگویان برای استفاده از ابزارهای آموزشی مبتنی بر هوش مصنوعی دارند. همچنین اعتماد ادراک‌شده به این فناوری نقش مهمی در پذیرش آن ایفا می‌کند؛ به‌گونه‌ای که افرادی با اعتماد بیشتر به قابلیت‌ها و امنیت این ابزارها، تمایل بیشتری به استفاده از آن نشان می‌دهند (عسکر، ۱۴۰۴). همچنین در نظام آموزش عالی کشاورزی، نتایج پژوهش سبحانی و تاکی (۱۴۰۴) نشان داد که سازه‌های انتظار عملکرد، انتظار تلاش، نفوذ اجتماعی، شرایط تسهیل‌گر و تمایل رفتاری بر استفاده واقعی از ابزارهای هوش مصنوعی در میان دانشجویان موثر بودند.

نتایج پژوهشی دیگر نشان داد که تجربه پیشین کار با فناوری، نقش مهمی در شکل‌گیری اعتماد به هوش مصنوعی دارد و دانشجویانی که آشنایی و درک بیشتری از این فناوری داشتند، سطح پذیرش بالاتری نیز نشان دادند (Jin, 2025). در مطالعه‌ای مقدماتی، تفاوت درک و نگرش نسبت به آموزش هوش مصنوعی میان دو گروه از دانشجویان علوم کامپیوتر (CS) و دانشجویان غیر کامپیوتری (Non-CS) بررسی شد. نتایج نشان داد که دانشجویان CS نگرش مثبت‌تر، سطح آگاهی بالاتر و اعتماد بیشتری نسبت به هوش مصنوعی دارند. افزون بر این، تجربه عملی با ابزارهای هوش مصنوعی و محتوای آموزشی مرتبط با حوزه‌های غیرفنی می‌تواند نقش مؤثری در کاهش اضطراب و افزایش مشارکت در یادگیری هوش مصنوعی ایفا کند (Shabanian *et al*., 2025). در پژوهش لی و همکاران (Li *et al*., 2025)، نگرش و سواد هوش مصنوعی به عنوان میانجی بین خودکارآمدی شغلی و اضطراب جستجوی شغل بررسی شد. نتایج حاکی از آن بود که سواد هوش مصنوعی (AI literacy) نقشی اساسی در کاهش اضطراب و افزایش اعتماد به نفس ایفا می‌کند. در مطالعه‌ای کیفی-پیمایشی، محققان ترجیحات و ادراکات دانشجویان در مورد کاربرد هوش مصنوعی در آموزش عالی را بررسی کردند. این پژوهش نشان داد که کاربرد هوش مصنوعی در آموزش، گامی جدید

برای نسل آلفا است. امروزه، دانش‌آموزان از ابزارهای هوش مصنوعی متعددی استفاده می‌کنند؛ ابزارهایی که از جمله پرکاربردترین آن‌ها می‌توان به ChatGPT (تولید دیالوگ توسط هوش مصنوعی متن‌باز)، Grammarly (بررسی املا، دستور زبان و علائم نگارشی، تشخیص سرقت ادبی و غیره)، Tutor AI (ارتباط دانش‌آموزان با معلمان واجد شرایط)، QuillBot (پلتفرم نوشتاری آنلاین)، Duolingo (اپلیکیشن یادگیری زبان)، Education Copilot (پلتفرمی برای طرح درس، نکات نوشتاری، گزارش‌های دانش‌آموزان و طرح کلی پروژه)، Curipod (ابزار ارائه تعاملی برای ساخت درس) اشاره کرد. یافته‌ها نشان داد که گرچه بسیاری از دانشجویان نسبت به هوش مصنوعی کنجکاو و خوش‌بین هستند، اما شکاف اطلاعاتی قابل توجهی درباره عملکرد آن وجود دارد (Adhikari & Gope, 2025). مطالعه‌ای دیگر نشان داد که سواد رسانه‌ای دیجیتال تأثیر مستقیمی بر نگرش و پذیرش هوش مصنوعی دارد، به‌گونه‌ای که درک عمیق‌تر از رسانه‌های دیجیتال، نگرش مثبت‌تری نسبت به هوش مصنوعی در میان دانشجویان ایجاد می‌کند (Sergeeva *et al*., 2025). مطالعه دیگری نشان داد که اکثریت قابل توجهی از شرکت‌کنندگان با هوش مصنوعی آشنا بودند. همچنین ارتباط معناداری بین سطح دانش و عوامل اجتماعی-جمعیتی مانند سن، جنس، منبع اطلاعات مرتبط با هوش مصنوعی و رتبه‌بندی دانش وجود داشت (Kharroubi *et al*., 2024). در پژوهشی با تمرکز بر دانشجویان و اعضای هیئت‌علمی، وضعیت فعلی آگاهی و آمادگی آنان برای استفاده از فناوری‌های هوش مصنوعی مورد بررسی قرار گرفت. نتایج نشان داد که نگرش کلی به هوش مصنوعی مثبت است و همبستگی معناداری میان دانش و نگرش نسبت به این فناوری وجود دارد، به‌گونه‌ای که افزایش آگاهی ساختاریافته می‌تواند نگرش‌ها را تقویت و پذیرش فناوری را تسهیل کند (Hasan *et al*., 2024). مطالعه دیگری با تمرکز بر دانشجویان علوم انسانی و اجتماعی، نشان می‌دهد که با وجود آشنایی عملی نسبی جوانان با فناوری‌های دیجیتال، درک مفهومی و شناخت آن‌ها از ماهیت هوش مصنوعی بسیار سطحی باقی مانده است (Yasin, 2022).

در نهایت، سان و همکاران (Son *et al*., 2025) نشان دادند که پذیرش و بهره‌برداری از فناوری‌های نوین آموزشی در میان دانشجویان به ترکیبی از عوامل اجتماعی، روان‌شناختی، فنی و زیرساختی وابسته است. یافته‌های این پژوهش بر نقش محوری هنجار اجتماعی، خودکارآمدی و دسترسی به فناوری در تعیین رفتار کاربران تأکید دارد و سودمندی و سهولت استفاده را به عنوان پیش‌نیازهای اصلی پذیرش فناوری معرفی می‌کند. افزون بر این، یک مرور نظام‌مند بر بیش از ۱۰۰ مقاله در حوزه کاربردهای هوش مصنوعی در آموزش عالی نشان داد که تمرکز اغلب مطالعات بر جنبه‌های فناورانه بوده و ادراکات کاربران نهایی، به‌ویژه دانشجویان، کمتر مورد توجه قرار گرفته است. این تحقیق بر ضرورت اتخاذ رویکردی میان‌رشته‌ای تأکید می‌کند که در کنار بهره‌گیری از ظرفیت‌های فناورانه، به ابعاد تربیتی، اخلاقی و فرهنگی نیز توجه ویژه داشته باشد (Zawacki-Richter *et al*., 2019).

بررسی کلی پژوهش‌های انجام شده نشان می‌دهد بیشتر مطالعات موجود یا صرفاً به بررسی فناوری‌محور هوش مصنوعی پرداخته‌اند یا تنها از جنبه فنی و مهندسی به آن نگاه کرده‌اند و کمتر به تحلیل عوامل موثر بر رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان در رشته‌های کشاورزی یا دانشگاه‌های تخصصی (مانند کشاورزی و منابع طبیعی) توجه شده است. همچنین، بررسی‌های میدانی مبتنی بر ابزارهای روان‌سنجی دقیق و تحلیل‌های ساختاری مانند مدل‌سازی معادلات ساختاری، در این حوزه بسیار محدود است. پژوهش حاضر با هدف پر کردن این خلأ، به سنجش عمیق و نظام‌مند نگرش و آگاهی دانشجویان نسبت به هوش مصنوعی پرداخته است. یافته‌های این مطالعه می‌تواند در طراحی برنامه‌های آموزشی فناورانه، ارتقای سواد دیجیتال و همسوسازی نظام آموزش عالی با تحولات جهانی نقشی مؤثر ایفا کند. بر همین اساس، پژوهش پیشِ‌رو با هدف تحلیل رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان کشاورزی انجام شده است. مدل‌های پذیرش فناوری سنتی، اگرچه بینش‌های ارزشمندی ارائه می‌دهند، اما اغلب در تبیین پیچیدگی‌های رفتار انسانی و روابط غیر خطی بین متغیرها دارای محدودیت هستند. ازاین‌رو، بهره‌گیری از روش‌های تحلیلی پیشرفته‌تر که قادر به مدل‌سازی این پیچیدگی‌ها باشند، ضروری به نظر می‌رسد. تلفیق مدل‌سازی معادلات ساختاری (SEM) که توانایی آزمون روابط علی بین متغیرهای پنهان را دارد، با شبکه عصبی مصنوعی (ANN) که قدرت پیش‌بینی غیر خطی و شناسایی الگوهای پیچیده را داراست، می‌تواند رویکردی جامع و قدرتمند برای تحلیل و پیش‌بینی رفتار استفاده از هوش مصنوعی فراهم آورد. بنابراین، مساله علمی این پژوهش، فقدان یک مدل پیش‌بینی‌کننده قوی و جامع برای تحلیل رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان کشاورزی است. این پژوهش به‌طور خاص به این پرسش‌ها می‌پردازد:

۱. مهم‌ترین عوامل علی تأثیرگذار بر رفتار استفاده دانشجویان کشاورزی از ابزارهای هوش مصنوعی کدامند؟
۲. سهم و قدرت پیش‌بینی‌کنندگی هر یک از این عوامل در مدل نهایی به چه میزان است؟
۳. چگونه می‌توان با ترکیب SEM و ANN، قدرت پیش‌بینی مدل را افزایش داد و روابط غیر خطی پنهان‌بین متغیرها را شناسایی کرد؟

درک این روابط پیچیده به سیاست‌گذاران آموزشی، طراحان برنامه درسی و توسعه‌دهندگان ابزارهای هوش مصنوعی کمک خواهد کرد تا استراتژی‌های هدفمندتری برای افزایش پذیرش و استفاده مؤثر از این فناوری حیاتی در نسل آینده متخصصان کشاورزی طراحی کنند. بر اساس نگاره ۱ و در راستای پاسخگویی به سؤالات مطرح شده در پژوهش، فرضیه‌های زیر در نظر گرفته شد:

- فرضیه ۱: هنجار اجتماعی تأثیر مثبت و معناداری بر رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان کشاورزی دارد.
- فرضیه ۲: خودکارآمدی تأثیر مثبت و معناداری بر رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان کشاورزی دارد.
- فرضیه ۳: سودمندی درک شده تأثیر مثبت و معناداری بر رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان کشاورزی دارد.
- فرضیه ۴: سهولت درک شده تأثیر مثبت و معناداری بر رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان کشاورزی دارد.
- فرضیه ۵: دسترسی به فناوری تأثیر مثبت و معناداری بر رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان کشاورزی دارد.

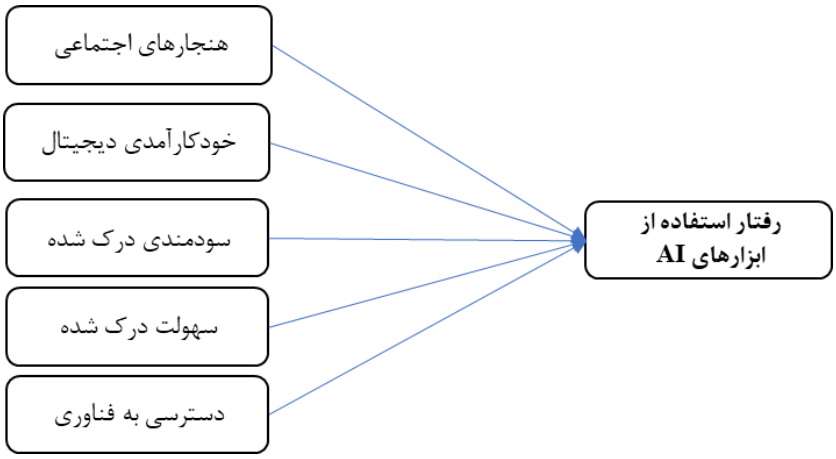

نگاره ۱- چارچوب نظری پژوهش

مواد و روش‌ها

این پژوهش از نظر هدف، کاربردی و از نظر پارادایم، کمی است. گردآوری داده‌ها نیز به صورت پیمایشی انجام شد. هدف اصلی این پژوهش، بررسی کمی و مدل‌سازی عوامل مؤثر بر رفتار استفاده دانشجویان از فناوری‌های هوش مصنوعی در محیط دانشگاهی است. جامعه آماری پژوهش شامل دانشجویان دانشگاه علوم کشاورزی و منابع طبیعی ساری (N=310) بود که طی سال‌های تحصیلی ۱۴۰۲ و ۱۴۰۳ در حداقل یک دوره آموزشی مرتبط با هوش مصنوعی شرکت کرده بودند. این افراد در مقاطع مختلف کارشناسی، کارشناسی ارشد و دکتری و در رشته‌های مرتبط با حوزه کشاورزی و منابع طبیعی مشغول به تحصیل بودند. روش نمونه‌گیری به صورت تصادفی طبقه‌ای با انتساب متناسب بود که در آن، طبقات بر اساس مقطع تحصیلی تفکیک شدند و حجم نمونه هر طبقه با توجه به نسبت جمعیتی آن تعیین گردید. با استفاده از جدول کرجسی و مورگان، حجم نمونه ۱۷۲ نفر برآورد شد، اما برای اطمینان و افزایش دقت، پرسشنامه‌ها بین ۱۸۰ نفر توزیع گردید. از این تعداد، ۴ پرسشنامه به دلیل نقص کنار گذاشته شد و در نهایت ۱۷۶ پرسشنامه برای تحلیل مورد استفاده قرار گرفت.

پژوهش حاضر فاقد طرح آزمایشی مداخله‌ای است و از نوع طرح غیرآزمایشی (Ex Post Facto) محسوب می‌شود. گردآوری داده‌ها در مقطع زمانی سال تحصیلی ۱۴۰۴-۱۴۰۳ و به صورت پیمایشی انجام پذیرفت. ابزار گردآوری داده‌ها، پرسشنامه محقق‌ساخته بود که بر پایه ادبیات نظری و پژوهش‌های پیشین طراحی و شامل دو بخش مشخصات جمعیت‌شناختی (رشته، مقطع، جنسیت، سابقه استفاده از هوش مصنوعی) و مؤلفه‌های مدل پژوهش (گویه‌هایی در قالب طیف لیکرت، از اصلاً تا بسیار زیاد) بود (جدول ۱).

جدول ۱- سازه‌های تشکیل‌دهنده مدل پژوهش و منبع استخراج آن‌ها

سازه	گویه	منبع
هنجار اجتماعی	همکلاسی‌های من معتقدند که استفاده از هوش مصنوعی برای انجام کارها مفید است.	دلجو و همکاران (۱۴۰۳)؛ حاجی‌انوری و رمضانی (۱۴۰۳)؛ عسکر (۱۴۰۴) Zawacki-Richter *et al.* (2019); Holmes *et al.* (2021); Yasin (2022); OECD (2023); Hasan *et al.* (2024); Kharroubi *et al.* (2024); Adhikari & Gope (2025); Salameh *et al.* (2025)
	اساتید و مربیان من به استفاده از ابزارهای هوش مصنوعی در یادگیری تشویق می‌کنند.	
	در جامعه دانشگاهی، استفاده از هوش مصنوعی به عنوان یک فعالیت معمول و پسندیده شناخته می‌شود.	
	من احساس می‌کنم که بیشتر دانشجویان باید از هوش مصنوعی برای تسهیل کارهای روزمره خود استفاده کنند.	
	اگر استفاده از هوش مصنوعی توسط افراد مهم در اطراف من توصیه شود، من نیز متمایل به استفاده از آن خواهم بود.	
خودکارآمدی	به توانایی خود در یادگیری و استفاده از هوش مصنوعی اطمینان دارم.	حاجی‌انوری و رمضانی (۱۴۰۳)؛ دلجو و همکاران (۱۴۰۳)؛ ثانی‌حیدری و صفری (۱۴۰۴) Yasin (2022); Hasan *et al.* (2024); Adhikari & Gope (2025); Li *et al.* (2025); Salameh et al. (2025); Sergeeva *et al.* (2025); Shabanian *et al.* (2025)
	فکر می‌کنم می‌توانم ابزارهای هوش مصنوعی را به خوبی مدیریت کنم.	
	حتی بدون کمک دیگران می‌توانم مشکلات مربوط به استفاده از هوش مصنوعی را حل کنم.	
	احساس می‌کنم مهارت کافی برای کار با فناوری‌های هوش مصنوعی دارم.	
سودمندی درک شده	استفاده از هوش مصنوعی می‌تواند بهره‌وری من را افزایش دهد.	فتحعلی‌بیگی و همکاران (۱۴۰۳)؛ ثانی‌حیدری و صفری (۱۴۰۴) Luckin *et al.* (2016); Zawacki-Richter *et al.* (2019); Yasin (2022); OECD (2023); Hasan *et al.* (2024); Adhikari & Gope (2025); Waqas *et al.* (2025); Son *et al.* (2025)
	فکر می‌کنم هوش مصنوعی در بهبود عملکرد تحصیلی من مفید است.	
	هوش مصنوعی می‌تواند به ساده‌تر شدن وظایف روزمره کمک کند.	
	استفاده از هوش مصنوعی در رسیدن به اهداف حرفه‌ای من مفید است.	
سهولت درک شده	یادگیری کار با ابزارهای هوش مصنوعی برای من آسان است.	حاجی‌انوری و رمضانی (۱۴۰۳)؛ فتحعلی‌بیگی و همکاران (۱۴۰۳)؛ ثانی‌حیدری و صفری (۱۴۰۴) Yasin (2022); Shabanian *et al.* (2025); Li *et al.* (2025); Adhikari & Gope (2025); Salameh *et al.* (2025)
	ابزارهای هوش مصنوعی کاربرپسند طراحی شده‌اند.	
	فکر می‌کنم کار با هوش مصنوعی نیاز به مهارت‌های پیچیده ندارد.	
	می‌توانم به سرعت با فناوری‌های جدید هوش مصنوعی سازگار شوم.	
دسترسی به فناوری	به ابزارها و نرم‌افزارهای هوش مصنوعی دسترسی کافی دارم.	حاجی‌انوری و رمضانی (۱۴۰۳)؛ دلجو و همکاران (۱۴۰۳)؛ ثانی‌حیدری و صفری (۱۴۰۴) Salmon (2019); OECD (2023); Hasan *et al.* (2024); Kharroubi *et al.* (2024); Sergeeva *et al.* (2025); Shabanian *et al.* (2025); Son *et al.* (2025)
	زیرساخت‌های لازم برای استفاده از هوش مصنوعی برای من فراهم است.	
	منابع آموزشی مرتبط با هوش مصنوعی به‌راحتی در دسترس من قرار دارند.	
	دانشگاه یا محیط کاری من امکانات مناسبی برای استفاده از هوش مصنوعی ارائه می‌دهد.	
رفتار استفاده از ابزارهای AI	از ابزارهای هوش مصنوعی در زندگی روزمره خود استفاده می‌کنم.	دلجو و همکاران (۱۴۰۳)؛ عسکر (۱۴۰۴)؛ ثانی‌حیدری و صفری (۱۴۰۴) Zawacki- Richter *et al.* (2019); Yasin (2022); Hasan *et al.* (2024); Kharroubi *et al.* (2024); Salameh *et al.* (2025); Sergeeva *et al.* (2025)
	در محیط تحصیلی از فناوری هوش مصنوعی بهره می‌برم.	
	تاکنون از هوش مصنوعی برای حل مشکلات واقعی استفاده کرده‌ام.	
	به صورت عملی تجربه کار با ابزارهای پیشرفته هوش مصنوعی را دارم.	

با استفاده از نظرات متخصصان حوزه آموزش و اساتید ترویج و آموزش کشاورزی روایی ابزار پژوهش مورد تأیید قرار گرفت. به منظور تعیین پایایی نیز از شاخص‌های آلفای کرونباخ (Cronbach's alpha) و پایایی ترکیبی (CR) استفاده شد.

برای بررسی جامع روابط خطی و غیر خطی بین سازه‌های برون‌زا و درون‌زا، این مطالعه از یک روش‌شناسی ترکیبی تلفیق‌کننده SEM و ANN بهره گرفته است. این رویکرد تلفیقی، درک ظریف‌تری از پویایی‌های پیچیده مؤثر بر رفتار استفاده از ابزارهای هوش مصنوعی را فراهم می‌کند و محدودیت‌های مدل‌سازی تک‌متغیره را مرتفع می‌سازد. مطالعه حاضر در دو مرحله مجزا اما مکمل ساختاریافته شد. در مرحله اول، مدل‌سازی معادلات ساختاری کمترین مربعات جزئی (PLS-SEM) با استفاده از نرم‌افزار اسمارت پی‌ال‌اس نسخه ۳ (Smart PLS$_3$)، برای بررسی روابط خطی بین سازه‌ها استفاده شد. این رویکرد به‌طور ویژه برای پژوهش‌های مبتنی بر مدل‌های نظری نوپا بسیار مناسب است (Hair *et al*., 2019). فرآیند مدل‌سازی معادلات ساختاری در گام مرحله اول بر ارزیابی مدل اندازه‌گیری متمرکز بود تا از پایایی و روایی سازه اطمینان حاصل شود. این مرحله شامل محاسبه آلفای کرونباخ، پایایی ترکیبی (CR) و میانگین واریانس استخراج شده (AVE) برای سنجش ثبات درونی و روایی همگرا بود. روایی تشخیصی نیز بیشتر با استفاده از معیار فورنل-لارکر (Fornell-Larcker) و نسبت روایی یگانه-دوگانه (HTMT) مورد بررسی قرار گرفت. در گام دوم، جهت آزمون معناداری روابط علّی مدل پیشنهادی، از رویه‌های بوت‌استرپینگ (Bootstrapping) با ۵۰۰ و ۵۰۰۰ نمونه استفاده شد. علاوه بر این، در تحلیل روابط متقابل بین سازه‌ها، شاخص‌های برازش کلیدی مانند R^2 و Q^2 برای سنجش قدرت تبیین و پیش‌بینی مدل با استفاده از تکنیک‌های بلایندفولدینگ (Blindfolding) محاسبه شد. در نهایت، ماتریس اهمیت-عملکرد مقایسه وزن و اعتبار سازه‌ها را در مدل به تصویر کشید. علی‌رغم مزایای آن، PLS-SEM محدودیت‌های شناخته‌شده‌ای در مدل‌سازی تعاملات غیر خطی و کشف الگوهای پیچیده درون مجموعه داده‌های با ابعاد بالا دارد. این محدودیت‌ها باعث شد تا از روش جایگزینی استفاده شود که بتواند این پیچیدگی‌ها را تحلیل کند.

در مرحله‌ی دوم، برای مقابله با محدودیت‌های SEM در ثبت روابط غیر خطی، از تحلیل شبکه عصبی مصنوعی (ANN) و مدل عصبی پرسپترون چندلایه (MLP) استفاده شد. MLP به عنوان یکی از پرکاربردترین معماری‌ها در مدل‌سازی ANN، به‌طور ویژه در شناسایی تعاملات پیچیده و غیر جبرانی بین متغیرها، حتی زمانی که داده‌ها با فرضیه‌های نرمال بودن مطابقت ندارند، مؤثر است. چارچوب MLP پیاده شده در این مطالعه شامل سه جزء اصلی یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی بود. در مدل شبکه عصبی مصنوعی، لایه ورودی نشان‌دهنده متغیرهای مستقل (هنجار اجتماعی، خودکارآمدی، سودمندی درک شده، سهولت درک شده و دسترسی به فناوری) بود، در حالی که لایه‌های پنهان، پردازش غیرخطی و استخراج ویژگی را تسهیل می‌کردند. لایه خروجی نیز امکان پیش‌بینی متغیر وابسته، رفتار استفاده از ابزارهای هوش مصنوعی را فراهم آورد. هر دو لایه پنهان و خروجی از تابع فعال‌سازی سیگموئید (Sigmoid) استفاده کردند که انتخابی رایج در زمینه‌های پژوهشی مبتنی بر طبقه‌بندی است (Elareshi *et al*., 2022; Xu *et al*., 2024).

یافته‌ها و بحث

ویژگی‌های فردی و حرفه‌ای پاسخگویان

یافته‌های حاصل از تحلیل داده‌های جمع‌آوری‌شده از پاسخگویان (جدول ۲) نشان می‌دهد که اکثریت دانشجویان زن (۵۷ درصد) بودند. میانگین سنی دانشجویان حدود ۲۳ سال محاسبه شد. بخش عمده‌ای از آنها (۸۰/۷ درصد) در مقطع کارشناسی، ۱۴/۲ درصد در مقطع ارشد و تنها ۵/۱ درصد در مقطع دکتری مشغول به تحصیل بودند. بیشترین ابزار هوش مصنوعی مورد استفاده توسط پاسخگویان ChatGPT بود. معدل دانشجویان حدود ۱۶ برآورد شد. بر اساس نتایج میانگین استفاده دانشجویان از اینترنت در روز حدود ۶/۵ ساعت و میانگین استفاده از هوش مصنوعی حدود ۱ ساعت محاسبه گردید.

جدول ۲- ویژگی‌های جمعیت‌شناختی پاسخگویان

ویژگی‌های پاسخگویان		فراوانی	درصد	توضیحات
جنسیت	مرد	۷۶	۴۳	نما: زن
	زن	۱۰۰	۵۷	
سن	۲۰ سال و کمتر	۵۰	۲۸/۴	میانگین: ۲۳/۴۳
	۲۱ تا ۳۰ سال	۱۰۶	۶۰/۲	انحراف معیار: ۵/۲۰
	۳۱ و بالاتر	۲۰	۱۱/۴	
مقطع تحصیلی	کارشناسی	۱۴۲	۸۰/۷	نما: کارشناسی
	ارشد	۲۵	۱۴/۲	
	دکتری	۹	۵/۱	
استفاده از ابزارهای هوش مصنوعی	ChatGPT	۹۷	۵۵/۱	نما: ChatGPT
	Bing	۴	۲/۳	
	Gemini	۱۵	۸/۵	
	تلفیقی از ابزارها	۴۴	۲۵	
	سایر	۱۶	۹/۱	
معدل	میانگین: ۱۵/۹۷	انحراف معیار: ۱/۵۴	کمترین: ۱۲	بیشترین: ۲۰
میزان استفاده از اینترنت در روز (ساعت)	میانگین: ۶/۵۴	انحراف معیار: ۴/۱۹	کمترین: ۰	بیشترین: ۱۶
میزان استفاده از ابزارهای هوش مصنوعی	عدم استفاده در روز	۴۳	۲۴/۴	میانگین: ۱/۱۰
	کمتر از ۱ ساعت در روز	۸۵	۴۸/۳	انحراف معیار: ۱/۲۱
	۲ تا ۳ ساعت در روز	۴۰	۲۲/۷	
	بیش از ۳ ساعت در روز	۸	۴/۶	

ارزیابی مدل اندازه‌گیری

همان‌گونه که در جدول ۳ نشان داده شده است، در ارزیابی اعتبار مدل اندازه‌گیری تمامی گویه‌ها دارای بارهای عاملی بالاتر از آستانه ۰/۷ بودند که نشان‌دهنده تبیین‌پذیری مناسب و عملکرد مطلوب گویه‌ها در سطح عوامل زیربنایی است. برای ارزیابی جامع قابلیت روایی و پایایی سازه‌های مدل مطابق با رویکردهای پیشنهادی توسط هیر و همکاران (Hair *et al.*, 2019)، از سه شاخص کلیدی آلفای کرونباخ، پایایی ترکیبی (CR) و میانگین واریانس استخراج‌شده (AVE) استفاده شد. ضرایب آلفای کرونباخ برای تمام سازه‌ها بالاتر از ۰/۷ محاسبه شد که نشان‌دهنده سازگاری درونی مطلوب و پایایی قابل قبول مقیاس‌هاست. همچنین، مقادیر پایایی ترکیبی (CR) نیز از آستانه ۰/۷ فراتر رفت که تأییدکننده پایایی بالای سازه‌های مکنون در مدل است. از سوی دیگر، شاخص AVE برای تمام سازه‌ها از حداقل ۰/۵بالاتر بود که حاکی از وجود اعتبار همگرای بوده و نشان می‌دهد بخش قابل توجهی از واریانس متغیرهای مشاهده‌شده به سازه‌های پنهان اختصاص یافته است.

علاوه بر این، نتایج مندرج در جدول ۵ نشان داد که در ارزیابی روایی تشخیصی مبتنی بر شاخص HTMT، تمامی مقادیر به دست آمده کمتر از آستانه توصیه شده ۰/۸۵ بودند. این یافته‌ها تأیید می‌کنند که سازه‌های مدل به خوبی از لحاظ مفهومی متمایز شده‌اند و همپوشانی نامطلوبی بین آن‌ها وجود ندارد.

جدول ۳- نتایج ارزیابی مدل اندازه‌گیری

سازه	نماد	بار عاملی	عامل تورم واریانس (VIF)	آلفای کرونباخ Cronbach's) (alpha	پایایی ترکیبی (CR)	میانگین واریانس استخراج شده (AVE)
هنجار اجتماعی	B1	۰/۷۲۴	۱/۳۶۴	۰/۷۹۵	۰/۸۵۸	۰/۵۴۸
	B2	۰/۷۳۵	۱/۷۷۴			
	B3	۰/۷۴۴	۱/۸۲۸			
	B4	۰/۷۷۵	۱/۶۵۳			
	B5	۰/۷۲۰	۱/۵۱۲			
خودکارآمدی	B6	۰/۸۰۵	۱/۹۱۵	۰/۸۵۹	۰/۹۰۵	۰/۷۰۴
	B7	۰/۸۶۸	۲/۳۳۳			
	B8	۰/۸۵۶	۲/۳۴۵			
	B9	۰/۸۲۶	۲/۰۹۴			
سودمندی درک شده	B10	۰/۸۱۴	۱/۹۱۴	۰/۸۷۰	۰/۹۱۱	۰/۷۱۹
	B11	۰/۸۷۹	۲/۴۷۴			
	B12	۰/۸۶۳	۲/۲۹۱			
	B13	۰/۸۳۵	۲/۰۴۶			
سهولت درک شده	B14	۰/۸۴۲	۲/۰۳۶	۰/۸۶۲	۰/۹۰۶	۰/۷۰۷
	B15	۰/۸۲۱	۱/۹۳۹			
	B16	۰/۸۴۶	۲/۰۰۱			
	B17	۰/۸۵۵	۲/۲۳۴			
دسترسی به فناوری	B18	۰/۸۶۰	۱/۹۷۲	۰/۸۴۰	۰/۸۹۰	۰/۶۷۳
	B19	۰/۸۵۶	۲/۰۸۳			
	B20	۰/۸۹۰	۲/۴۷۱			
	B21	۰/۶۵۴	۱/۵۰۱			
رفتار استفاده از ابزارهای AI	B22	۰/۸۴۲	۲/۲۵۸	۰/۸۶۰	۰/۹۰۵	۰/۷۰۵
	B23	۰/۸۵۷	۲/۱۷۳			
	B24	۰/۸۷۱	۲/۴۱۳			
	B25	۰/۷۸۵	۱/۶۶۹			

در این پژوهش، به‌منظور ارزیابی روایی تشخیصی مدل، از دو رویکرد مکمل شامل معیار فورنل و لارکر و شاخص HTMT، مبتنی بر پیشنهاد هنسلر و همکاران (Henseler *et al.*, 2015) استفاده شد. بر اساس نتایج ارائه شده در جدول ۴، ریشه دوم AVE هر سازه بزرگ‌تر از بیشترین مقدار همبستگی آن با سایر سازه‌ها بود که شرط اساسی معیار فورنل و لارکر را برآورده می‌سازد و بیانگر تمایز مناسب سازه‌ها از یکدیگر است.

جدول ۴- ارزیابی ریشه دوم میانگین واریانس استخراج‌شده (AVE) با همبستگی سازه‌ها (معیار فورنل لارکر)

سازه‌ها	هنجار اجتماعی	خودکارآمدی	سودمندی درک شده	سهولت درک شده	دسترسی به فناوری	رفتار استفاده از ابزارهای AI
هنجار اجتماعی	**۰/۷۴۰***					
خودکارآمدی	۰/۴۵۵	**۰/۸۳۹**				
سودمندی درک شده	۰/۵۴۲	۰/۶۱۲	**۰/۸۴۸**			
سهولت درک شده	۰/۵۰۳	۰/۷۶۶	۰/۷۰۵	**۰/۸۴۱**		
دسترسی به فناوری	۰/۲۶۰	۰/۵۳۵	۰/۳۲۷	۰/۴۶۰	**۰/۸۲۰**	
رفتار استفاده از ابزارهای AI	۰/۶۰۰	۰/۶۹۴	۰/۶۶۱	۰/۷۱۲	۰/۵۳۸	**۰/۸۴۰**

* در خانه‌های قطر جدول، مقادیر جذر میانگین واریانس هر مؤلفه به صورت پررنگ و همبستگی بین مؤلفه و سایر متغیرها در زیر سلول‌های مورب درج شده است.

علاوه بر این، نتایج مندرج در جدول ۵ نشان داد که در ارزیابی روایی تشخیصی مبتنی بر شاخص HTMT، تمامی مقادیر به دست آمده کمتر از آستانه توصیه شده ۰/۸۵ بودند. این یافته‌ها تأیید می‌کنند که سازه‌های مدل به خوبی از لحاظ مفهومی متمایز شده‌اند و همپوشانی نامطلوبی بین آن‌ها وجود ندارد.

جدول ۵- شاخص یگانه-دوگانه (HTMT) برای سنجش میزان روایی

سازه‌ها	هنجار اجتماعی	خودکارآمدی	سودمندی درک شده	سهولت درک شده	دسترسی به فناوری	رفتار استفاده از ابزارهای AI
هنجار اجتماعی						
خودکارآمدی	۰/۵۴۷					
سودمندی درک شده	۰/۶۳۹	۰/۷۰۹				
سهولت درک شده	۰/۶۰۲	۰/۸۲۱	۰/۸۱۶			
دسترسی به فناوری	۰/۳۲۵	۰/۵۸۸	۰/۳۴۳	۰/۵۲۰		
رفتار استفاده از ابزارهای AI	۰/۷۱۴	۰/۸۰۶	۰/۷۶۴	۰/۸۲۵	۰/۵۹۸	

* مقادیر بالای ۰/۹۰ یا ۰/۸۵ (در رویکردهای سخت‌گیرانه‌تر) نشان‌دهنده عدم تشخیص روایی مطلوب بین سازه‌هاست. به‌بیان دیگر، وقتی HTMT از این محدوده فراتر رود، یعنی دو سازه چنان همبستگی بالایی دارند که از نظر تجربی قابل تفکیک از یکدیگر نیستند و احتمالاً معرف یک مفهوم واحد هستند.

تحلیل مدل ساختاری

در مرحله تحلیل مدل ساختاری با استفاده از روش حداقل مربعات جزئی (PLS-SEM)، فرآیند برآورد با حداکثر ۵۰۰ تکرار و با استفاده از وزن‌های اولیه پیش‌فرض انجام شد. به منظور افزایش استحکام و قابلیت تعمیم نتایج، از روش بوت‌استرپینگ غیرپارامتریک (Nonparametric Bootstrapping) با ۵۰۰۰ نمونه‌گیری مجدد استفاده شد. این روش علاوه بر بهبود پایداری برآوردها، امکان محاسبه آماره‌های معنادار (t-values) و فواصل اطمینان را در سطح معناداری ۵ درصد فراهم کرد که از این طریق، معناداری روابط بین سازه‌ها به طور قابل‌اعتماد تأیید شد. عملکرد مدل ساختاری نیز از طریق ضریب تعیین (R^2) ارزیابی شد که نشان دهنده قدرت تبیینی مدل در پیش‌بینی متغیر وابسته است. بر اساس طبقه‌بندی هیر و همکاران (Hair *et al.*, 2022)، مقادیر R^2 به‌ترتیب به عنوان ضعیف (۰/۲۵)، متوسط (۰/۵۰) و قوی (۰/۷۵) تفسیر می‌شوند. در مدل حاضر، مقدار R^2 برای متغیر رفتار استفاده دانشجویان از ابزارهای هوش مصنوعی برابر با ۰/۶۷۱ به دست آمد که نشان‌دهنده توان تبیینی مناسب و بالاتر از حد متوسط این مدل است. در ادامه، تأثیر عوامل مختلف بر این رفتار مطابق با فرضیه‌های پژوهش مورد بررسی قرار گرفت و نتایج آن در جدول ۶ ارائه شده است.

جدول ۶- نتایج آزمون فرضیه‌ها

	فرضیه اثر مورد مطالعه	ضریب (β)	خطای استاندارد	آماره t	سطح معناداری	نتیجه
H1	هنجار اجتماعی ← رفتار	۰/۲۴۹	۰/۰۷۵	۳/۳۲۱	۰/۰۰۱	پذیرش
H2	خودکارآمدی ← رفتار	۰/۱۹۰	۰/۰۹۴	۲/۰۱۸	۰/۰۴۴	پذیرش
H3	سودمندی درک شده ← رفتار	۰/۱۹۴	۰/۰۷۹	۲/۴۵۶	۰/۰۱۴	پذیرش
H4	سهولت درک شده ← رفتار	۰/۲۱۵	۰/۱۰۱	۲/۰۴۲	۰/۰۴۲	پذیرش
H5	دسترسی به فناوری ←رفتار	۰/۲۱۳	۰/۰۶۷	۳/۲۰۱	۰/۰۰۱	پذیرش

بر اساس یافته‌های ارائه شده در جدول ۶، تمامی فرضیه‌های پژوهش در سطح معناداری ۰/۰۵تأیید شده‌اند. این نتایج نشان می‌دهد که متغیرهای پژوهش شامل هنجار اجتماعی، خودکارآمدی، سودمندی درک شده، سهولت درک شده و دسترسی به فناوری، همگی تأثیر مثبت و معناداری بر رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان رشته کشاورزی دارند. مدل ساختاری نهایی در نگاره ۲ ارائه شده است.

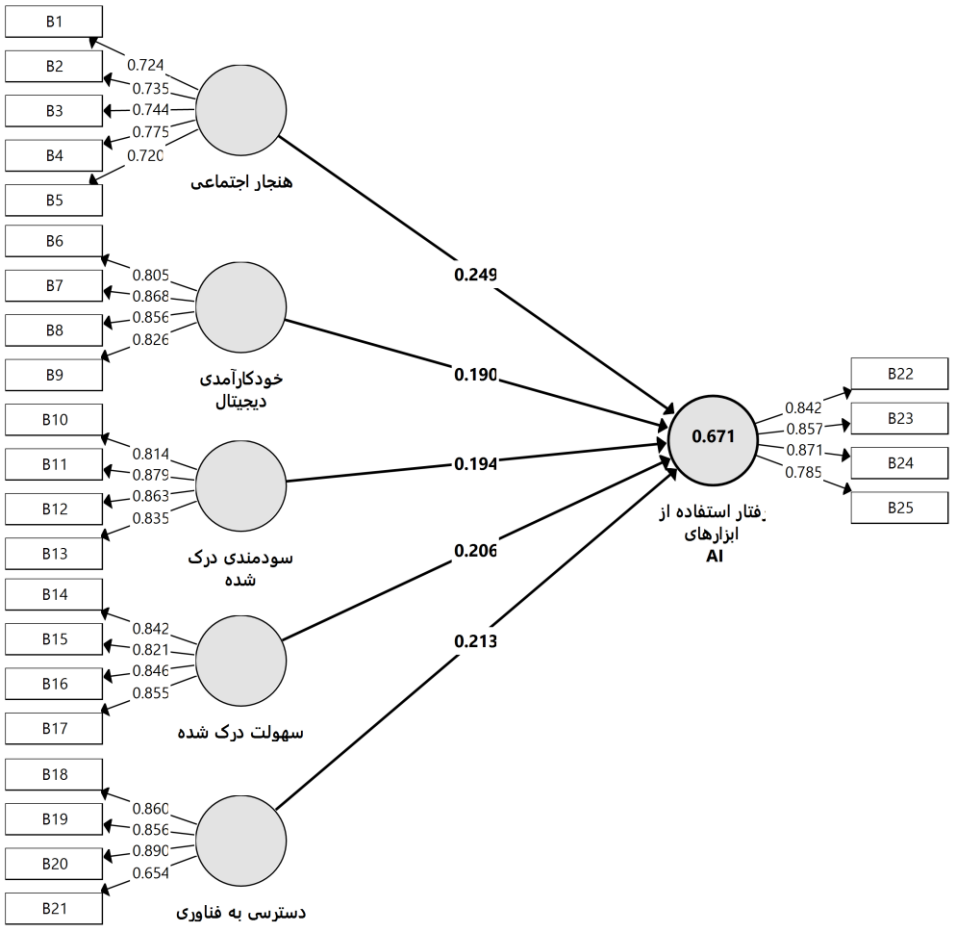

نگاره ۲- برازش مدل ساختاری پژوهش

تحلیل نقشه اهمیت-عملکرد (Importance-Performance Map Analysis - IPMA)

تحلیل نقشه اهمیت-عملکرد (IPMA) یک روش تکمیلی در جهت ارتقای درک نتایج مدل‌سازی معادلات ساختاری است که علاوه بر بررسی اثرات علی (ضریب مسیر استانداردشده، β)، عملکرد واقعی سازه‌ها (میانگین مقیاس‌های استاندارد نشده، بر اساس مقیاس لیکرت) را نیز ارزیابی می‌کند (Elareshi *et al*., 2022). این تحلیل به‌جای تأیید صرف ضرایب مسیر (مانند معیار اهمیت)، میانگین تعداد سازه‌های نهفته و شاخص‌های مربوط را نیز به‌عنوان معیار عملکرد به کار می‌گیرد (Ringle & Sarstedt, 2016). به عبارت دیگر، این تحلیل به شناسایی سازه‌هایی کمک می‌کند که اگرچه اهمیت بالایی در تبیین متغیر وابسته دارند، اما عملکرد آن سازه نسبت به سایر عوامل پایین بوده و نیازمند توجه ویژه و اقدامات بهبودی هستند.

همان‌طور که نگاره ۳ نشان می‌دهد، سازه «دسترسی به فناوری» با وجود اهمیت بالا، بعد از هنجار اجتماعی از ضعیف‌ترین عملکرد برخوردار است؛ بنابراین این یافته به عنوان اولویت اصلی بهبود تأکید دارد که بدون رفع محدودیت‌های دسترسی، تلاش‌های آموزشی

یا فرهنگی برای افزایش پذیرش هوش مصنوعی نمی‌توانند به‌طور کامل اثربخش باشد. در مقابل، هنجار اجتماعی به عنوان مهم‌ترین عامل تأثیرگذار، عملکرد مناسبی دارد و باید از طریق سیاست‌های فرهنگی و آموزشی تقویت و تثبیت شود. این تحلیل، تصویری جامع و عملیاتی از عوامل مؤثر بر رفتار دانشجویان ارائه می‌دهد و به سیاست‌گذاران و مدیران آموزشی کمک می‌کند تا منابع خود را به‌صورت استراتژیک و مبتنی بر داده تخصیص دهند.

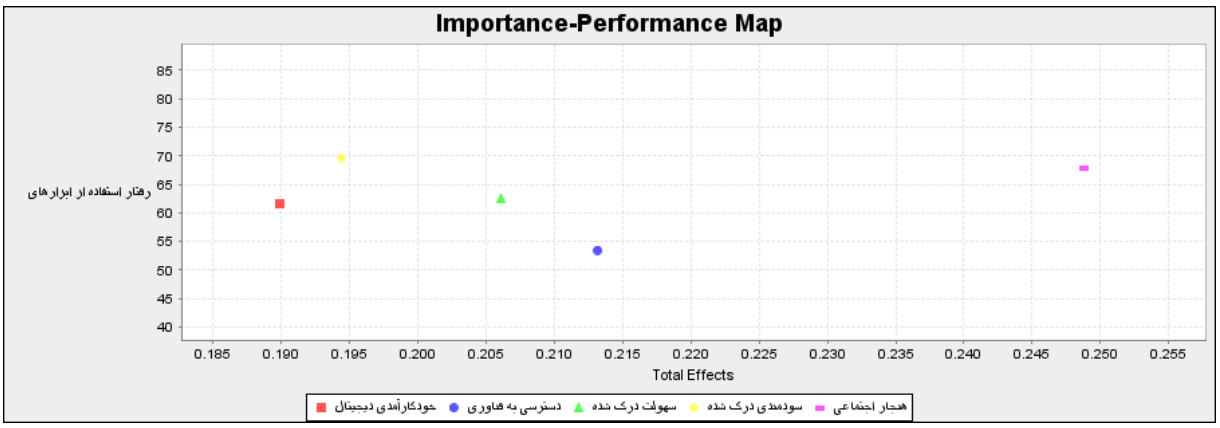

نگاره ۳- نتایج نقشه اهمیت-عملکرد

تحلیل شبکه عصبی مصنوعی (ANN)

در گام بعدی این مطالعه، با استفاده از نرم‌افزار SPSS نسخه ۲۲ و با استفاده از متغیرهای معنادار استخراج‌شده از مدل‌سازی معادلات ساختاری (SEM)، یک تحلیل شبکه عصبی مصنوعی انجام شد. معماری مدل ANN شامل یک لایه پنهان با یک نورون خروجی (نمایانگر رفتار) و پنج نورون ورودی (منعکس‌کننده هنجار اجتماعی، خودکارآمدی، سودمندی درک شده، سهولت درک شده و دسترسی به فناوری) بود. تابع فعال‌سازی سیگموید برای هر دو لایه پنهان و خروجی به کار رفت تا پردازش غیر خطی و انعطاف‌پذیر برای مدل افزایش یابد. مقادیر ورودی و خروجی در محدوده [۰, ۱] نرمال شدند تا کارایی آموزش و دقت پیش‌بینی بهبود یابد (Liébana-Cabanillas *et al.*, 2018). این ساختار به مدل امکان داد تا روابط پیچیده و غیر خطی عوامل مؤثر بر رفتار استفاده از ابزارهای هوش مصنوعی در بین دانشجویان کشاورزی را شناسایی کند (نگاره ۴).

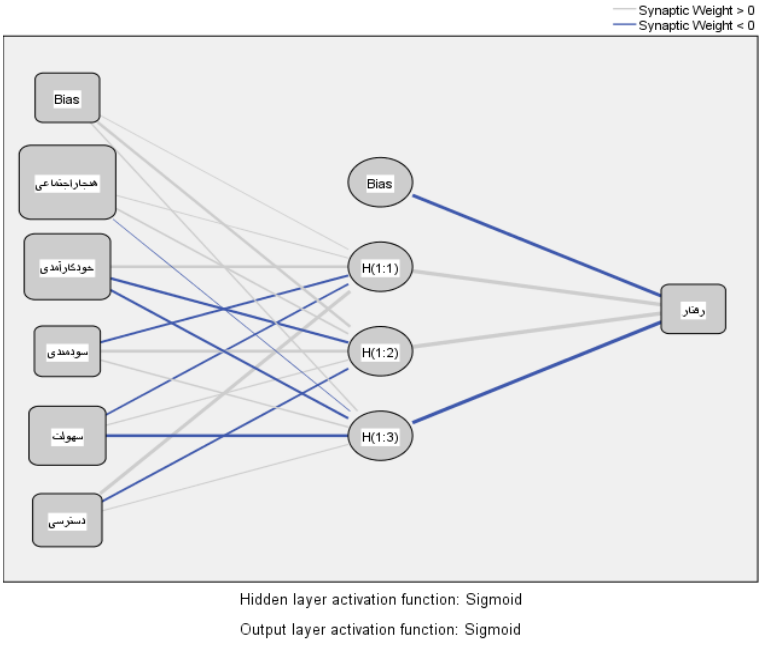

نگاره ۴- معماری پیشنهادی مدل شبکه عصبی مصنوعی

بر اساس روش‌های متداول در مطالعات پیشین دانشگاهی (Elareshi *et al*., 2022; Xu *et al*., 2024; Richter & Tudoran, 2024)، مجموعه داده‌ها به نسبت ۸۰ درصد برای آموزش و ۲۰ درصد برای آزمون تقسیم شدند. برای جلوگیری از بیش‌برازش و اطمینان از استحکام مدل، از اعتبارسنجی متقاطع ده‌گانه (10-fold cross-validation) استفاده شد. در این تحلیل، معیار اصلی ارزیابی عملکرد مدل، شاخص خطای جذر میانگین مربعات (RMSE) بود. نتایج نشان داد که میانگین RMSE برای مجموعه آموزش ۰/۱۰۴ و برای مجموعه آزمون ۰/۰۹۷ بود که نشان‌دهنده سازگاری قوی و دقت پیش‌بینی بالا است. مقادیر پایین RMSE در تمامی اجراهای مدل، دقت و تعمیم‌پذیری بالای شبکه عصبی مصنوعی را تأیید می‌کند. این نتایج حاکی از آن است که مدل پیشنهادی به‌طور مؤثر الگوهای نهفته در داده‌ها را شناسایی کرده و از محدودیت‌های روش‌های خطی فراتر رفته است (جدول ۷).

جدول ۷- نتایج اعتبارسنجی مدل‌های شبکه عصبی مصنوعی

مدل	نمونه آموزش	SSE	RMSE	نمونه آزمون	SSE	RMSE
۱	۱۴۰	۱/۴۰۵	۰/۱۰۰	۳۶	۰/۲۴۳	۰/۰۸۲
۲	۱۳۸	۱/۵۷۵	۰/۱۰۷	۳۸	۰/۴۲۱	۰/۱۰۵
۳	۱۴۵	۱/۴۱۰	۰/۰۹۹	۳۱	۰/۴۱۱	۰/۱۱۵
۴	۱۴۱	۱/۵۸۴	۰/۱۰۶	۳۵	۰/۲۹۵	۰/۰۹۲
۵	۱۳۷	۱/۵۲۰	۰/۱۰۵	۳۹	۰/۳۱۷	۰/۰۹۰
۶	۱۲۸	۱/۳۶۲	۰/۱۰۳	۴۸	۰/۴۲۳	۰/۰۹۴
۷	۱۴۶	۱/۶۶۳	۰/۱۰۷	۳۰	۰/۲۲۷	۰/۰۸۷
۸	۱۳۳	۱/۴۵۴	۰/۱۰۵	۴۳	۰/۴۶۵	۰/۱۰۴
۹	۱۳۴	۱/۵۵۱	۰/۱۰۸	۴۲	۰/۴۱۷	۰/۱۰۰
۱۰	۱۴۱	۱/۴۷۴	۰/۱۰۲	۳۵	۰/۳۵۸	۰/۱۰۱
میانگین	–	۱/۵۰۰	۰/۱۰۴	–	۰/۳۵۸	۰/۰۹۷
انحراف معیار	–	–	۰/۰۰۳	–	–	۰/۰۱۰

مقایسه بینش‌ها: مدل‌سازی معادلات ساختاری در مقابل تحلیل شبکه عصبی مصنوعی

جدول ۸ مقایسه‌ای جامع بین دو رویکرد تحلیلی مدل‌سازی معادلات ساختاری بر پایه کمترین مربعات جزئی (PLS-SEM) و شبکه عصبی مصنوعی (ANN) را در پیش‌بینی رفتار استفاده از ابزارهای هوش مصنوعی در میان دانشجویان کشاورزی ارائه می‌دهد. این مقایسه از طریق شاخص‌های اهمیت عاملی، عملکرد، ضریب تعیین (R^2) و اعتبار پیش‌بینی (Q^2) انجام شده است.

جدول ۸- ارزیابی مقایسه‌ای نتایج تحلیل مدل‌سازی معادلات ساختاری و شبکه عصبی مصنوعی

سازه‌ها	مدل‌سازی معادلات ساختاری				شبکه عصبی مصنوعی	
	Q^2	R^2	اهمیت	عملکرد ٪	R^2	اهمیت	اهمیت نرمال شده ٪
هنجار اجتماعی	–	–	۰/۲۴۹	۶۷/۹۱	–	۰/۲۷۵	۱۰۰
خودکارآمدی	–	–	۰/۱۹۰	۶۱/۷	–	۰/۲۳۱	۸۳/۸
سودمندی درک شده	–	–	۰/۱۹۴	۶۹/۶۶	–	۰/۱۴۵	۵۲/۵
سهولت درک شده	–	–	۰/۲۱۵	۶۲/۴۸	–	۰/۱۹۱	۶۹/۴
دسترسی به فناوری	–	–	۰/۲۱۳	۵۳/۴۹	–	۰/۱۵۸	۵۷/۵
رفتار استفاده از ابزارهای AI	۰/۴۳۷	۰/۶۷۱	–	–	۰/۶۸۴	–	–

در مدل‌سازی معادلات ساختاری، اهمیت عوامل بر اساس ضرایب مسیر استانداردشده (β) تعیین می‌شود که نشان‌دهنده تأثیر مستقیم هر سازه بر متغیر وابسته (رفتار استفاده) است. بدین ترتیب هنجار اجتماعی (β = 0.249) بالاترین تأثیر مستقیم را داشته است. پس از آن سهولت درک شده (β = 0.215) و دسترسی به فناوری (β = 0.213) در رتبه‌های بعدی قرار داشته‌اند. در نهایت سودمندی درک شده (β = 0.194) و خودکارآمدی (β = 0.190) نیز تأثیر معنادار اما نسبتاً پایین‌تری دارند. این یافته‌ها بر اساس روابط خطی و فرضیات نظری (نظریه‌های TAM و TPB) نشان می‌دهند که عوامل اجتماعی و کاربری نقش محوری در پذیرش فناوری دارند.

در مدل شبکه عصبی مصنوعی، اهمیت عوامل از طریق تحلیل حساسیت و وزن‌های شبکه محاسبه می‌شود که بدون نیاز به فرضیات خطی یا ساختاری از پیش تعیین شده، اهمیت نسبی هر ورودی را در پیش‌بینی خروجی برآورد می‌کند. بر اساس این تحلیل، سازه هنجار اجتماعی با اهمیت نرمال شده ۱۰۰ درصد به عنوان مهم‌ترین عامل شناسایی شد. پس از آن، خودکارآمدی با شاخص ۸۳/۸ درصد نشان‌دهنده اهمیت بالای این عامل در چارچوب غیر خطی بوده است. سازه‌های سهولت درک شده با ۶۹/۴ درصد، سازه دسترسی به فناوری با ۵۷/۵ درصد و سازه سودمندی درک شده با ۵۲/۵ در رتبه‌های بعدی قرار داشتند.

تلفیق نتایج نشان می‌دهد که هنجار اجتماعی در هر دو مدل به عنوان مهم‌ترین عامل شناسایی شد که حاکی از روایی همگرا بین روش‌ها است. همچنین، تفاوت چشمگیر در رتبه‌بندی سازه سودمندی درک شده در دو تحلیل مشاهده شد. این موضوع نشان می‌دهد که در یک سیستم غیرخطی و پیچیده، سودمندی درک شده لزوماً تأثیر مستقیم و قوی ندارد، مگر اینکه شرایط دیگر مانند دسترسی به فناوری یا خودکارآمدی فراهم باشند. همچنین، خودکارآمدی در تحلیل شبکه عصبی اهمیت بسیار بالاتری نسبت به مدل‌سازی معادلات ساختاری دارد (۸۳/۸ درصد در مقابل ۰/۱۹۰ ضریب مسیر) که بیانگر نقش میانجی یا تعدیل‌گر این متغیر در سیستم‌های پیچیده است. به عبارت دیگر، ممکن است تأثیر آن به‌صورت غیر مستقیم یا تعاملی باشد که در مدل خطی معادلات ساختاری به‌خوبی شناسایی نشده است.

مقادیر عملکرد (میانگین پاسخ‌ها بر اساس مقیاس لیکرت) در هر دو مدل یکسان است، چراکه این داده‌ها از منبع یکسانی (پرسشنامه) استخراج شده‌اند. با این حال، تفسیر ترکیبی اهمیت و عملکرد (همانند IPMA) در شبکه عصبی مصنوعی دقیق‌تر است، زیرا اهمیت در این مدل از تحلیل داده‌محور (Data-Driven) به‌دست می‌آید و محدود به فرضیات نظری نیست.

همان‌طور که در نتایج مدل‌سازی معادلات ساختاری با رویکرد حداقل مربعات جزئی مشاهده شد، ضریب تعیین (R^2) برای رفتار استفاده از ابزارهای هوش مصنوعی برابر با ۶۷/۱ درصد بود. همچنین، نتایج بلایندفولدینگ (Blindfolding) مقادیر مثبت Q^2 را نشان داد که بیانگر قدرت پیش‌بینی خوب مدل است ($Q^2 = 0.437$). با این حال، مدل عصبی مصنوعی از نظر قدرت پیش‌بینی عملکرد به‌مراتب بهتری داشت و واریانس‌های تبیین شده ۶۸/۴ درصد را ارائه کرد (نگاره ۵).

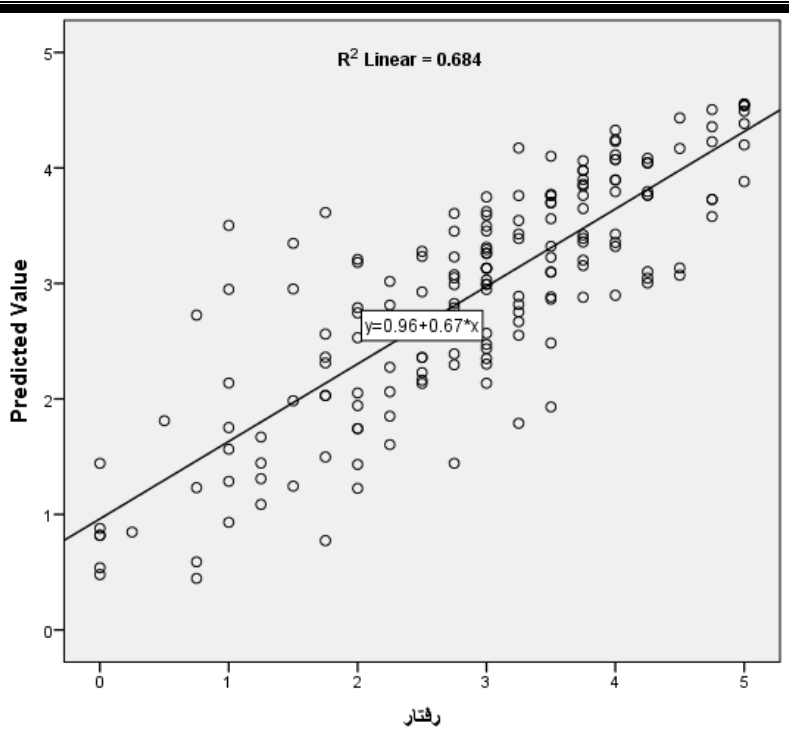

نگاره ۵- نمودار تبیین متغیر وابسته رفتار هوش مصنوعی در شبکه عصبی مصنوعی

از نظر قدرت پیش‌بینی، در شبکه عصبی مصنوعی (R^2 = ۰/۶۸۴) مقدار کمی برتری نسبت به مدل‌سازی معادلات ساختاری (R^2 = ۰/۶۷۱) قابل مشاهده بود. این بدان مفهوم است که شبکه عصبی مصنوعی می‌تواند اثرات غیر خطی، تعاملی و غیرمستقیم را بهتر شناسایی کند. به‌ویژه خودکارآمدی و هنجار اجتماعی اهمیت بالایی دارند که ممکن است از طریق مسیرهای غیرمستقیم، به عنوان مثال از طریق تأثیر بر سهولت یا دسترسی درک‌شده، بر رفتار دانشجویان اثرگذار باشند.

اگرچه مدل‌سازی معادلات ساختاری برای تأیید نظریه و تفسیر روابط علت و معلول بسیار کارآمد بوده است، شبکه عصبی مصنوعی نیز توان پیش‌بینی دقیق‌تر و کشف الگوهای پنهان در داده‌ها را دارد. به طور کلی، می‌توان بیان داشت که ترکیب هر دو روش (رویکرد تلفیقی تحلیل داده‌ها)، چارچوب قدرتمندی برای تحلیل فراهم می‌کند.

یافته‌های تحقیق نشان می‌دهد که برای درک کامل رفتار پیچیده کاربران در محیط‌های دیجیتال، ترکیب رویکردهای نظری و داده محور ضروری است. در عمل، این بدان معناست که سیاست‌های آموزشی نباید تنها بر بهبود سودمندی درک شده یا سهولت درک شده متمرکز باشند، بلکه باید با تقویت هنجار اجتماعی و خودکارآمدی دیجیتال دانشجویان و همچنین رفع محدودیت‌های دسترسی به فناوری، زمینه‌های پذیرش پایدار هوش مصنوعی را فراهم کنند.

نتایج نشان داد که هنجار اجتماعی با ضریب استانداردشده ۰/۲۴۹ و آماره t برابر با (۰/۰۰۱ > p) t=۳/۳۲۱ تأثیر مثبت و معناداری بر رفتار استفاده از ابزارهای هوش مصنوعی دارد. این یافته بیانگر آن است که دانشجویان زمانی بیشتر تمایل به استفاده از فناوری هوش مصنوعی دارند که احساس کنند اطرافیانشان (همسالان، اساتید، یا جامعه دانشگاهی) این رفتار را تأیید و تشویق می‌کنند. این نتیجه با نظریه رفتار برنامه‌ریزی شده (TPB) و مدل پذیرش فناوری (TAM) همسو است که نقش تأثیرات اجتماعی را در شکل‌گیری رفتار پذیرش فناوری برجسته می‌کند. در محیط‌های دانشگاهی به عنوان فضایی برای پشتیبانی از فناوری‌های نوین آموزشی، استفاده از هوش مصنوعی به عنوان رفتاری مطلوب تلقی می‌شود و احتمال بهره‌برداری از ابزارهای هوش مصنوعی افزایش می‌یابد. درهمین راستا مطالعه دلجو و همکاران (۱۴۰۳) و حاجی‌انوری و رمضانی (۱۴۰۳) بر نقش کلیدی هنجار ذهنی (به عنوان سازه‌ای مشابه در TPB) در پیش‌بینی قصد و رفتار استفاده از هوش مصنوعی تأکید کرده‌اند. به‌طور مشابه، مطالعه خاروبی و همکاران (Kharroubi *et al.*, 2024) نشان داد که نفوذ اجتماعی یکی از متغیرهای پیش‌بینی‌کننده اصلی نگرش مثبت نسبت به هوش مصنوعی است. این همخوانی در سطح بین‌المللی حاکی از آن است که ماهیت اجتماعی محیط‌های آموزشی، فارغ از بافت فرهنگی، عاملی تعیین‌کننده در پذیرش فناوری‌های نوظهور است. علاوه بر این، یافته حاضر مبنی بر اینکه محیط

دانشگاهی می‌تواند به عنوان بستری تسهیل‌گر، استفاده از هوش مصنوعی را به یک هنجار مطلوب تبدیل کند، با دیدگاه‌های کلان‌تر در حوزه آموزش دیجیتال هماهنگ است. مطالعه سان و همکاران (Son *et al*., 2025)، گزارش سازمان همکاری اقتصادی (OECD, 2023) و هولمز و همکاران (Holmes *et al*., 2021)، بر این موضوع تأکید دارند که موفقیت ادغام هوش مصنوعی در آموزش، صرفاً به قابلیت‌های فنی آن وابسته نیست، بلکه تا حد زیادی به ایجاد یک «فرهنگ سازمانی» حمایتگر وابسته است که در آن استفاده از این ابزارها تشویق و عادی‌سازی شود. مطالعه ثانی‌حیدری و صفری (۱۴۰۴) نیز نشان داده‌اند که حمایت اجتماعی و سازمانی یکی از قوی‌ترین عوامل مؤثر بر رفتار استفاده از فناوری است. بنابراین، توجه سیاست‌گذاران و مدیران آموزشی به بعد اجتماعی و فرهنگی پذیرش فناوری، فراتر از آموزش مهارت‌های فنی، ضروری است. ایجاد فضایی که اساتید و دانشجویان در آن به استفاده از هوش مصنوعی تشویق شوند، می‌تواند بهره‌برداری از پتانسیل‌های این فناوری در آموزش عالی را تسریع کند.

خودکارآمدی با ضریب ۰/۱۹۰ و (p =۰/۰۴۴) t=۱/۰۱۸ تأثیر مثبت و معناداری بر رفتار استفاده از هوش مصنوعی دارد. این یافته نشان می‌دهد که دانشجویانی که احساس می‌کنند توانایی کافی برای استفاده از ابزارهای هوش مصنوعی دارند، احتمال بیشتری دارد که از این فناوری استفاده کنند. خودکارآمدی به عنوان یک عامل روان‌شناختی کلیدی، نقش مهمی در غلبه بر ترس یا مقاومت در برابر فناوری‌های جدید ایفا می‌کند. این یافته اهمیت آموزش‌های عملی، کارگاه‌های مهارتی و محیط‌های یادگیری حمایتگر را در دانشگاه‌ها برجسته می‌کند تا اعتماد دانشجویان به توانایی خود در کار با فناوری‌های پیچیده افزایش یابد. این نتیجه که باور دانشجویان به توانایی خود در استفاده از این فناوری، رفتار آنان را پیش‌بینی می‌کند، کاملاً با چارچوب نظریه شناختی-اجتماعی بندورا و پژوهش‌هایی مانند لی و همکاران (Li *et al*., 2025) و عسکر (۱۴۰۴) همسو است و نشان می‌دهند خودکارآمدی یک عامل کلیدی در کاهش اضطراب و افزایش پذیرش فناوری‌های جدید است. این یافته همچنین بر اهمیت راهبردهای عملی برای افزایش اعتماد به نفس دانشجویان تأکید می‌کند. مطالعاتی مانند سان و همکاران (Son *et al*., 2025)، سازمان همکاری اقتصادی (OECD, 2023) و حاجی‌انوری و رمضانی (۱۴۰۳) نیز بر ضرورت ارائه آموزش‌ها و کارگاه‌های مهارت محور در محیط‌های دانشگاهی برای تقویت خودکارآمدی و در نهایت، افزایش بهره‌وری از هوش مصنوعی در آموزش تاکید می‌کند.

سودمندی درک شده با ضریب ۰/۱۹۴ و (p=۰/۰۱۴) t=۲/۴۵۶ به عنوان یکی از عوامل مؤثر در رفتار استفاده از ابزارهای هوش مصنوعی تأیید شد. این نتیجه بیانگر آن است که دانشجویان تنها زمانی به سمت ابزارهای هوش مصنوعی گرایش پیدا می‌کنند که باور داشته باشند این ابزارها به آن‌ها در یادگیری، تحقیق یا انجام تکالیف دانشگاهی کمک می‌کنند. این یافته با چارچوب مدل پذیرش فناوری (TAM) همخوانی دارد که سودمندی درک شده را به عنوان یکی از پیش‌نیازهای اصلی پذیرش فناوری معرفی می‌کند. بنابراین، طراحی ابزارهای هوش مصنوعی با قابلیت‌های عملی و مرتبط با نیازهای تحصیلی دانشجویان کشاورزی (مانند تحلیل داده‌های مزرعه‌ای، پیش‌بینی عملکرد محصول یا مدیریت منابع آب) می‌تواند پذیرش این فناوری را تسهیل کند. در همین راستا مطالعه ثانی‌حیدری و صفری (۱۴۰۴) در بخش کشاورزی و آدهیکاری و گوپه (Adhikari & Gope, 2025) در محیط‌های آموزش عالی، هر دو بر نقش محوری سودمندی درک شده به عنوان قوی‌ترین پیش‌بینی‌کننده قصد و رفتار استفاده از فناوری تأکید دارند. همان‌طور که گزارش سازمان همکاری اقتصادی (OECD, 2023)، نیز پیشنهاد می‌کند، موفقیت این فناوری‌ها در گرو تمرکز بر حل مشکلات واقعی کاربران است؛ بنابراین، توسعه ابزارهایی پاسخ‌دهنده به نیازهای خاص دانشجویان کشاورزی، مانند تحلیل داده یا مدیریت منابع، ضروری است تا ارزش واقعی آن‌ها را به‌طور ملموس نشان داده و پذیرش را افزایش دهند.

سهولت درک شده نیز با ضریب ۰/۲۱۵ و (p=۰/۰۴۲) t=۲/۰۴۲ تأثیر مثبت و معناداری بر رفتار استفاده از ابزارهای هوش مصنوعی دارد. این نتیجه نشان می‌دهد که دانشجویان زمانی بیشتر از هوش مصنوعی استفاده می‌کنند که فرآیند استفاده از آن را ساده، کاربرپسند و بدون پیچیدگی بدانند. این یافته، توسط مطالعاتی مانند سرگیوا و همکاران (Sergeeva *et al*., 2025) تأیید شده که نشان می‌دهند حتی کاربران با سواد دیجیتال بالا، اگر فناوری را دشوار ببینند، از آن اجتناب می‌کنند. اهمیت این یافته برای توسعه‌دهندگان و سیاست‌گذاران آموزشی بسیار زیاد است. همان‌طور که واکاس و همکاران (Waqas *et al*., 2025) نیز اشاره کرده‌اند، پیچیدگی فناوری می‌تواند به عنوان یک مانع عمده بر سر راه ادغام معنادار آن در آموزش عمل کند. بنابراین، سرمایه‌گذاری بر روی طراحی کاربرپسند

ابزارها باید مدنظر قرار گیرد. در این راستا در پژوهش جین (Jin, 2025) نیز تأکید شده است که کاربر پسندبودن، ارائه آموزش‌های عملی مقدماتی و ایجاد سیستم‌های پشتیبانی فنی قوی، نه‌تنها استفاده از ابزار را افزایش می‌دهد، بلکه شکاف دیجیتالی بین کاربران با سطوح مهارت مختلف را نیز کاهش می‌دهد و منجر به پذیرش عادلانه‌تر و گسترده‌تر فناوری می‌شود.

دسترسی به فناوری با ضریب ۰/۲۱۳ و ($p < ۰/۰۰۱$) $t=۳/۲۰۱$ تأثیر معناداری بر رفتار استفاده دارد. این یافته بیانگر آن است که وجود زیرساخت‌های لازم (مانند دسترسی به اینترنت پرسرعت، دستگاه‌های مناسب، نرم‌افزارهای مورد نیاز و دسترسی به پلتفرم‌های هوش مصنوعی) شرط اولیه‌ای برای پذیرش و استفاده عملی از این فناوری‌هاست. بدون دسترسی فیزیکی و عملیاتی، سایر عوامل انگیزشی (مانند خودکارآمدی یا سودمندی) نیز نمی‌توانند به‌طور کامل تأثیر خود را بگذارند. به‌طور مشابه، مطالعه سان و همکاران (Son *et al.*, 2025) و شعبانیان و همکاران (Shabanian *et al.*, 2025) بر روی دانشجویان رشته‌های غیرکامپیوتر نشان می‌دهد که فقدان دسترسی به ابزارهای مناسب، یکی از موانع اصلی برای درگیر شدن آنان با محتوای هوش مصنوعی است. اهمیت این یافته برای سیاست‌گذاران و مدیران آموزشی بسیار حیاتی است. همان‌طور که واکاس و همکاران (Waqas *et al.*, 2025) نیز اشاره کرده‌اند، بدون برطرف کردن شکاف زیرساختی، سایر سرمایه‌گذاری‌ها در حوزه آموزش مهارت‌ها یا توسعه محتوا نمی‌تواند به پتانسیل کامل خود دست یابد. بنابراین، این نتیجه به طور قاطع بر لزوم تخصیص بودجه و منابع برای تضمین دسترسی عادلانه تمامی دانشجویان به فناوری‌های لازم تأکید می‌کند. راه‌حل‌هایی مانند ایجاد آزمایشگاه‌های مجهز، ارائه اشتراک‌های نرم‌افزاری دانشگاهی و تضمین پوشش اینترنت پرسرعت در محوطه دانشگاه، گام‌های ضروری برای ایجاد بستری هستند که در آن سایر عوامل مؤثر (مانند خودکارآمدی و سودمندی درک‌شده) بتوانند به درستی عمل کنند و از ظهور یک «شکاف دیجیتالی دوم» در عصر هوش مصنوعی جلوگیری شود.

نتیجه‌گیری و پیشنهادها

نتایج پژوهش حاضر نشان داد که رویکرد ترکیبی SEM-ANN، استحکام اعتبارسنجی مدل‌های نظری را تقویت می‌کند و بینش عمیق‌تری در مورد مسیرهای خطی و غیرخطی مؤثر بر رفتار استفاده از ابزارهای هوش مصنوعی درون دانشگاه‌های کشاورزی ارائه می‌دهد. بر این اساس، نتایج بخش مدل‌سازی پژوهش نشان داد که مدل‌های ترکیبی با استفاده از روش‌هایی مانند IPMA و شبکه‌های عصبی (برای نمونه ANN)، نسبت به مدل‌های تک‌بعدی بهبودهای معناداری را ارائه می‌دهند و توانایی توضیح و پیش‌بینی رفتار هدف را افزایش می‌دهند. نتایج آماری نشان می‌دهد که اثرات معناداری بر متغیرهای هدف وجود دارد و در بیشتر شاخص‌ها این معناداری در سطح قابل قبول و قابل توجهی قرار دارد. این یافته‌ها بر اهمیت به‌کارگیری رویکرد تلفیقی در مدل‌سازی رفتار کاربری تأکید می‌کند. تبیین نتایج با شاخص‌های استاندارد مانند RMSE، SSE و ضرایب β نشان می‌دهد که مدل‌های ترکیبی مانند SEM-ANN و TPB-ANN در مقایسه با مدل‌های تک‌بعدی، عملکرد پیش‌بینی بهتری از خود نشان داده‌اند. با وجود این، برخی شاخص‌ها با وجود بهبود، همچنان نوسان داشته و واریانس قابل توجهی نشان می‌دهند که تعمیم‌پذیری دقیق در برخی موقعیت‌ها را محدود می‌سازد. این امر می‌تواند ناشی از کیفیت داده‌ها، اندازه‌گیری‌های حاشیه‌ای یا پیچیدگی سامانه باشد و نشان می‌دهد که در برخی مقاطع به داده‌های باکیفیت‌تر و نمونه‌های بزرگ‌تر نیاز است تا پایداری نتایج تقویت شود.

بر اساس یافته‌های این پژوهش، می‌توان نتیجه گرفت که پذیرش و استفاده از ابزارهای هوش مصنوعی در بین دانشجویان کشاورزی تحت تأثیر پنج عامل کلیدی قرار دارد: هنجار اجتماعی، خودکارآمدی، سودمندی درک‌شده، سهولت درک‌شده و دسترسی به فناوری. در این میان، هنجار اجتماعی با بالاترین ضریب تأثیر به عنوان قوی‌ترین پیش‌بینی کننده رفتار استفاده شناسایی شد که این امر نشان‌دهنده نقش محوری محیط اجتماعی و فرهنگ دانشگاهی در ترغیب دانشجویان به استفاده از فناوری‌های نوین است. علاوه بر این، دسترسی به فناوری و سهولت درک‌شده نیز تأثیر معناداری بر رفتار استفاده داشتند. این نتایج نشان می‌دهد که بدون وجود زیرساخت‌های فنی مناسب و رابط‌های کاربری ساده، حتی مفیدترین ابزارهای هوش مصنوعی مورد استقبال کاربران قرار نمی‌گیرند. این موضوع در سایر پژوهش‌ها نیز مورد تأکید قرار گرفته است؛ به‌گونه‌ای که نبود دسترسی به ابزارهای مناسب، به‌عنوان یکی از موانع اصلی پیش‌روی دانشجویان رشته‌های غیرفنی معرفی شده است. بنابراین، سرمایه‌گذاری در توسعه زیرساخت‌های دیجیتال و طراحی کاربرپسند باید به عنوان اولویتی اساسی در سیاست‌گذاری‌های آموزشی مورد توجه قرار گیرد.

از سوی دیگر، اگرچه سودمندی درک‌شده و خودکارآمدی تأثیر کمتری نسبت به سایر عوامل در رفتار استفاده از ابزارهای هوش مصنوعی دانشجویان داشتند، اما تحلیل شبکه عصبی مصنوعی (ANN) نقش غیرخطی و تعاملی این متغیرها را آشکار کرد. به‌طور خاص، خودکارآمدی در مدل ANN به عنوان دومین عامل مهم شناسایی شد که نشان می‌دهد باور دانشجویان به توانایی خود در استفاده از هوش مصنوعی می‌تواند از طریق مسیرهای پیچیده‌تر (مانند افزایش انگیزه یا کاهش اضطراب) بر رفتار نهایی تأثیر بگذارد. این یافته بر لزوم برگزاری کارگاه‌های آموزشی عملی و ارائه پشتیبانی روان‌شناختی را برای تقویت اعتمادبه‌نفس دانشجویان تأکید می‌کند. در ادامه با توجه به یافته‌های پژوهش پیشنهادهای کاربردی زیر ارائه می‌شود؛

- تقویت هنجار اجتماعی مثبت: دانشگاه‌ها می‌توانند با ایجاد فرهنگ سازمانی حمایتگر، از طریق برگزاری کارگاه‌های مشترک استاد-دانشجو و تشویق همسالان، استفاده از هوش مصنوعی را به یک هنجار مطلوب و پذیرفته‌شده تبدیل کنند.

- ارتقای خودکارآمدی دیجیتال دانشجویان: پیشنهاد می‌شود کارگاه‌های آموزشی عملی، دوره‌های مهارت‌محور و فرصت‌های یادگیری تجربی برای دانشجویان طراحی شود تا اعتمادبه‌نفس و توانایی آنان در کار با ابزارهای هوش مصنوعی افزایش یابد.

- بهبود زیرساخت‌ها و دسترسی عادلانه: فراهم‌سازی اینترنت پرسرعت در محوطه‌های دانشگاهی، تجهیز آزمایشگاه‌ها به سخت‌افزار و نرم‌افزارهای موردنیاز و ارائه دسترسی رایگان یا یارانه‌ای به ابزارهای مبتنی بر هوش مصنوعی از اولویت‌های ضروری است.

- توسعه ابزارهای کاربرپسند و مرتبط با نیازهای رشته کشاورزی: طراحی و معرفی اپلیکیشن‌ها و پلتفرم‌هایی که مستقیماً با حوزه‌های تخصصی دانشجویان کشاورزی (مانند تحلیل داده‌های مزرعه‌ای، پیش‌بینی عملکرد محصول، یا مدیریت منابع طبیعی) مرتبط باشند، می‌تواند پذیرش را افزایش دهد.

- تمرکز بر آموزش سودمندی کاربردی هوش مصنوعی: لازم است از طریق نمونه‌های عملی، پروژه‌های پژوهشی مشترک و ارائه محتواهای مرتبط، ارزش افزوده این فناوری برای موفقیت تحصیلی و حرفه‌ای دانشجویان به‌طور ملموس نشان داده شود.

- آموزش مداوم و به‌روز ابزارهای نوین هوش مصنوعی: با توجه به تغییرات سریع در حوزه هوش مصنوعی، ضروری است دانشگاه‌ها برنامه‌های آموزشی مداوم و مستمر طراحی کنند تا دانشجویان بتوانند همواره با جدیدترین ابزارها و قابلیت‌های آن‌ها آشنا شوند. این آموزش‌ها باید متناسب با نیازهای آموزشی و پژوهشی دانشجویان کشاورزی تدوین شود تا بتوانند از ظرفیت‌های به‌روز فناوری در یادگیری، پژوهش و فعالیت‌های حرفه‌ای بهره‌مند گردند.

در پایان، با توجه به نتایج به دست آمده، پیشنهاد می‌شود دانشگاه‌ها و مراکز آموزشی با اتخاذ یک رویکرد چندبعدی، همزمان بر تقویت هنجار اجتماعی از طریق آگاه‌سازی و فرهنگ‌سازی، بهبود دسترسی به فناوری از طریق توسعه زیرساخت‌ها و افزایش خودکارآمدی دانشجویان از طریق آموزش‌های هدفمند تمرکز کنند. همچنین توصیه می‌شود پژوهش‌های آتی به بررسی تعاملات پیچیده بین این عوامل در بافت‌های مختلف آموزشی و با استفاده از روش‌های ترکیبی (مانند SEM-ANN) بپردازند تا درک عمیق‌تری از فرآیند پذیرش هوش مصنوعی حاصل شود.

سپاسگزاری

این مقاله مستخرج از طرح پژوهش با عنوان "واکاوی سازه‌های نگرشی و دانشی دانشجویان نسبت به فناوری‌های هوش مصنوعی" با کد، ۰۷-۱۴۰۴-۰۱ دانشگاه علوم کشاورزی و منابع طبیعی ساری می‌باشد. بدین‌وسیله از حمایت مادی و معنوی معاونت پژوهشی دانشگاه سپاسگزاری می‌شود.

منابع

حاجی‌انوری، ل؛ و رمضانی، ع. (۱۴۰۳). بررسی وضعیت سواد، کاربست و عوامل مؤثر بر پذیرش هوش مصنوعی در بین اعضای هیئت‌علمی. *نامه آموزش عالی*، دوره ۱۷، شماره ۶۸، صص ۱۳۱-۱۰۶. 10.22034/hel.2024.2036769.1985 https://doi.org/

ثانی‌حیدری، ع.ث؛ و صفری، ا. (۱۴۰۴). بررسی عوامل مؤثر بر قصد رفتاری و رفتار استفاده از فناوری هوش مصنوعی: مطالعه موردی کشت و صنعت‌های شرکت کشاورزی رضوی. *مجله اقتصاد کشاورزی و توسعه*. دوره ۳۹، شماره ۱، صص ۵۶-۳۳. https://doi.org/10.22067/jead.2024.88807.1277

دلجو، ح.، سلیمانی، ت؛ و آزاد، ح. (۱۴۰۳). ارزیابی عوامل مؤثر بر قصد استفاده از هوش مصنوعی در آموزش عالی از منظر دانشجویان. *ماهنامه علمی تخصصی پایاشهر*، دوره ۶، شماره ۶۹، صص ۱۹-۱. https://civilica.com/doc/2141462

سبحانی، س. م. ج؛ و تاکی، م. (۱۴۰۴). توسعه مدل پذیرش هوش مصنوعی در نظام آموزش عالی کشاورزی ایران. *علوم ترویج و آموزش کشاورزی ایران*. دوره ۲۱، شماره ۱، صص ۶۴-۴۷. https://doi.org/10.22034/iaeej.2025.505374.1848

عسکر، ف. (۱۴۰۴)، بررسی رابطه بین عوامل مؤثر بر پذیرش ابزارهای آموزشی مبتنی بر هوش مصنوعی و قصد رفتاری معلمان، اولین همایش بین‌المللی هوش مصنوعی در آموزش و پرورش، روانشناسی، علوم تربیتی و مطالعات دینی، فرهنگی، اجتماعی و مدیریتی در هزاره سوم، مؤسسه چندمنظوره بام پژوهش پرواز جنوب، بوشهر. قابل دسترسی در ادرس اینترنتی: <https://civilica.com/doc/2219295>

فتحعلی‌بیگی، پ. ابطحی، م.ا.، مقامی، ح؛ و مرادی، ر. (۱۴۰۳). رتبه‌بندی عوامل مؤثر بر کارکرد هوش مصنوعی در بهبود آموزش ضمن خدمت معلمان با استفاده از روش تصمیم‌گیری چندمعیاره. *مدیریت هوشمند سرمایه انسانی*، دوره ۲، شماره ۲، صص ۱۵۱-۱۲۵. https://doi.org/10.22034/imhr.2025.506738.1021

Adhikari, N., and Gope, L. (2025). Students perception and preference of the application of artificial intelligence (AI) in higher education: A metacognitive exploration. *The International Journal of Indian Psychology*, 13(1), 207-218. https://doi.org/10.25215/1301.019

Bampasidou, M., Goldgaber, D., Gentimis, T., and Mandalika, A. (2024). Overcoming 'Digital Divides': Leveraging higher education to develop next generation digital agriculture professionals. *Computers and Electronics in Agriculture*, 224, 109181. https://doi.org/10.1016/j.compag.2024.109181

Elareshi, M., Habes, M., Youssef, E., Salloum, S. A., Alfaisal, R., and Ziani, A. (2022). SEM-ANN-based approach to understanding students' academic-performance adoption of YouTube for learning during Covid. *Heliyon*, 8(4), e09236. https://doi.org/10.1016/j.heliyon.2022.e09236

Hair, J. F., Hult, G. T. M., Ringle, C. M., and Sarstedt, M. (2022). *A primer on partial least squares structural equation modeling (PLS-SEM)*. 3rd Edition. Dublin, Irland: Sage.

Hair, J. F., Risher, J. J., Sarstedt, M., and Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, 31(1), 2–24. https://doi.org/10.1108/EBR-11-2018-0203.

Hasan, H. E., Jaber, D., Al Tabbah, S., Lawand, N., Habib, H. A., and Farahat, N. M. (2024). Knowledge, attitude and practice among pharmacy students and faculty members towards artificial intelligence in pharmacy practice: A multinational cross-sectional study. *Plos One*, 19(3), e0336818, 1-24. https://doi.org/10.1371/journal.pone.0296884

Henseler, J., Ringle, C. M., and Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115-135. https://doi.org/10.1007/s11747-014-0403-8

Holmes, W., Bialik, M., and Fadel, C. (2021). *Artificial intelligence in education: Promises and implications for teaching and learning*. Boston: Center for Curriculum Redesign. https://curriculumredesign.org

Jin, S. H. (2025). Measures of learner-generative AI relationships. *Computers and Education Open*, (8), e100258, https://doi.org/10.1016/j.caeo.2025.100258

Kharroubi, S. A., Tannir, I., Abu El Hassan, R., and Ballout, R. (2024). Knowledge, attitude, and practices toward artificial intelligence among university students in Lebanon. *Education Sciences*, 14(8), 863.

Li, R., Ouyang, J., Lin, J., and Ouyang, S. (2025). *Mediating effect of AI attitudes and AI literacy on the relationship between career self-efficacy and job-seeking anxiety*. *BMC Psychology*, 15(1), e2757. https://doi.org/10.1186/s40359-025-02757-2

Liébana-Cabanillas, F., Marinkovic, V., De Luna, I. R., and Kalinic, Z. (2018). Predicting the determinants of mobile payment acceptance: A hybrid SEM-neural network approach. *Technological Forecasting and Social Change*, 129, 117-130. https://doi.org/10.1016/j.techfore.2017.12.015

Luckin, R., Holmes, W., Griffiths, M., and Forcier, L. B. (2016). *Intelligence unleashed: An argument for AI in education*. London, United Kingdom: Pearson. https://www.pearson.com

OECD. (2023). *Digital education outlook 2023: AI and the future of learning*. OECD Publishing, Paris, France. https://doi.org/10.1787/19963712

Pallottino, F., Violino, S., Figorilli, S., Pane, C., Aguzzi, J., Colle, G., Nemmi, E. N., Montaghi, A., Chatzievangelou, D., Antonucci, F., Moscovini, L., Mei, A., Costa, C., and Ortenzi, L. (2025). *Applications and perspectives of Generative Artificial Intelligence in agriculture*. Computers and Electronics in Agriculture, 230, 109919. https://doi.org/10.1016/j.compag.2025.109919

Rane, J., Kaya, Ö., Mallick, S. K., and Rane, N. L. (2024). *Generative Artificial Intelligence in agriculture, education, and business*. Bengaluru, India: Deep Science Publishing. https://doi.org/10.70593/978-81-981271-7-4

Richter, N. F., and Tudoran, A. A. (2024). Elevating theoretical insight and predictive accuracy in business research: Combining PLS-SEM and selected machine learning algorithms. *Journal of Business Research*, 173, 114453. https://doi.org/10.1016/j.jbusres.2023.114453

Ringle, C. M., and Sarstedt, M. (2016). Gain more insight from your PLS-SEM results: The importance-performance map analysis. *Industrial Management & Data Systems*, 116(9), 1865-1886. https://doi.org/10.1108/IMDS-10-2015-0449

Salameh, B., Qaddumi, J., and Hammad, B. (2025). Nursing students' attitudes toward artificial intelligence: Palestinian perspectives. *SAGE Open*, 15(1), Article 23779608251343297. https://doi.org/10.1177/23779608251343297

Salmon, G. (2019). Learning innovation: A framework for transformation. *European Journal of Open, Distance and E-learning*, 22(2), 32–41.

Sergeeva, O. V., Masalimova, A. R., Zheltukhina, M. R., Chikileva, L. S., Lutskovskai, L. Y., and Luzin, A. (2025). Impact of digital media literacy on attitude toward generative AI acceptance in higher education. *Frontiers in Education*, 10, e1563148. https://doi.org/10.3389/feduc.2025.1563148

Shabanian, H., Pourghasemi, M., and Devi, S. (2025). Preliminary findings toward Inclusive AI education: Insights from CS and non-CS students. In *Proceedings of the 2025 ACM Southeast Conference* (PP. 295-296). Cape Girardeam, Missouri, USA, (24-26 April, 2025). https://doi.org/10.1145/3696673.3723091

Son, J. B., Ružić, N. K., and Philpott, A. (2025). Artificial intelligence technologies and applications for language learning and teaching. *Journal of China Computer-Assisted Language Learning*, 5(1), 94-112. https://doi.org/10.1515/jccall-2023-0015

Spanaki, K., Sivarajah, U., Fakhimi, M., Despoudi, S., and Irani, Z. (2022). Disruptive technologies in agricultural operations: A systematic review of AI-driven AgriTech research. *Annals of Operations Research*, 308(1), 491-524. https://doi.org/10.1007/s10479-020-03922-z

Waqas, M., Hania, A., and Chunyan, X. U. (2025). Understanding AIgiarism in higher education: The lens of general AI attitudes and moral disengagement. *Studies in Higher Education*,13(454), 1-17. https://doi.org/10.1080/03075079.2025.2497479

Xu, S., Wang, Y., and Luo, W. (2024). Hybrid SEM-ANN model for predicting undergraduates'e-learning continuance intention based on perceived educational and emotional support. *PloS One*, 19(12), e0308630. https://doi.org/10.1371/journal.pone.0308630

Yasin, M. I. (2022). *Youth perceptions and attitudes about artificial intelligence. Izvestiya of Saratov University. Philosophy. Psychology. Pedagogy*, 22(2), 197–205. https://www.researchgate.net/publication/361705403

Zawacki-Richter, O., Marín, V. I., Bond, M., and Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education: Challenges and opportunities. *International Journal of Educational Technology in Higher Education*, 16(1), 1-27. https://doi.org/10.1186/s41239-019-0171-0