



Comparison of Artificial Neural Network and Linear Regression Model Performance in Predicting Students' Academic Performance and Their Success in Personalized Learning

(Case Study: Undergraduate and Graduate Students at Payame Noor University of Mashhad)

Masoumeh Ilami¹ , Somaye Ghazi²

1. Assistant Professor, Department of Educational Sciences, Payam Noor University, Mashhad, Iran. E-mail: ilami@pnu.ac.ir

1. Lecturer, Department of Educational Sciences, Farhangian University, Mazandaran Province, Iran. E-mail: somaye.ghazi@gmail.com

Article Info	ABSTRACT
Article type: Research Article Article history: Received 2025/05/27 Received in revised form 2025/08/24 Accepted 2025/09/02 Published online Keywords: Artificial neural network, academic performance, personalized learning, future needs, educational planning, higher education.	This study aims to evaluate the efficiency of artificial intelligence models in educational planning and predicting students' academic performance, as well as optimizing personalized learning. A comparison between Artificial Neural Networks (ANN) and Linear Regression (LR) was conducted to identify the optimal model for analyzing educational data. This quantitative research was conducted using an analytical-comparative method. Educational data were extracted from Learning Management Systems (LMS), and both Linear Regression (LR) and Artificial Neural Networks (ANN) were utilized for analysis. Indicators such as the coefficient of determination (R^2), Mean Absolute Error (MAE), and Root Mean Square Error (RMSE) were examined to assess the accuracy and generalizability of the models. The findings revealed that the neural network, with a coefficient of determination ($R^2 = 0.88$) in the testing phase, exhibited higher accuracy compared to linear regression ($R^2 = 0.75$). The neural network was better at identifying complex relationships among educational variables, demonstrating its superior accuracy in predicting students' academic performance and optimizing educational planning. This study demonstrates that artificial neural networks are powerful analytical tools with significant potential for optimizing educational planning processes. However, effective utilization of these models requires sufficient data, optimal configurations, and appropriate computational infrastructure. It is recommended that universities and educational institutions leverage machine learning models for analyzing large-scale educational data and equip educational planning systems with AI-based technologies. Additionally, increasing awareness and training educators about the applications of AI in educational planning and personalized learning can enhance the quality of education and reduce academic dropout rates.
How To Cite: Ilami, M., Ghazi, S. (2025). Comparison of Artificial Neural Network and Linear Regression Model Performance in Predicting Students' Academic Performance and Their Success in Personalized Learning, <i>Research in Instructional Methods</i>, 3 (4), ...-.... https://doi.org/10.22091/jrim.2025.13050.1295	
	© The Author(s) DOI: https://doi.org/10.22091/jrim.2025.13050.1295 Publisher: University of Qom



Introduction

The rapid advancement of artificial intelligence (AI) and data science has transformed higher education by enabling data-driven educational planning, personalized learning, and predictive analytics. AI integration facilitates the analysis of vast datasets from learning management systems (LMS), identifying student behavior patterns to tailor educational strategies to individual needs, thereby addressing challenges posed by student diversity and labor market demands (Ouyang et al., 2023). Personalized learning, powered by AI algorithms, optimizes engagement and academic outcomes by adapting content to learners' preferences (Nkomo et al., 2021). Predictive analytics further enhances decision-making, with machine learning (ML) models forecasting academic performance and identifying at-risk students through historical data, interaction patterns, and assignment metrics (Goldberg et al., 2021). However, traditional methods like linear regression (LR) often fail to capture complex nonlinear relationships in educational data, limiting their efficacy (Luckin & Cukurova, 2019). In contrast, artificial neural networks (ANN) excel in modeling intricate patterns, improving accuracy in predicting performance, reducing dropout rates, and aligning curricula with industry needs (Bhardwaj et al., 2021; Gasevic et al., 2017). Despite these benefits, AI adoption faces barriers such as inadequate infrastructure, data privacy concerns, and educator resistance (Bowden et al., 2021). This study evaluates AI's efficiency in educational optimization by comparing ANN and LR using LMS-derived data, with performance metrics including R^2 , MAE, and RMSE. The research underscores the potential of integrating ML with educational planning to develop adaptive learning pathways and intelligent decision-support systems, addressing challenges like technological limitations and ethical considerations. By bridging AI capabilities with academic strategies, this approach aims to enhance educational quality and institutional efficiency, offering novel solutions for future-ready pedagogy.

Research findings

This study compared the effectiveness of Linear Regression (LR) and Artificial Neural Network (ANN) models in predicting students' future academic performance and success in personalized learning. Data were collected from 384 students, considering variables such as interaction in virtual classes, previous grades, learning styles, educational interests, number of completed assignments, and participation in class discussions. The LR model identified previous grades and educational interests as the most significant predictors, with coefficients of 0.52 each, followed by interaction in virtual classes (0.32) and participation in class discussions (0.25). The model achieved a coefficient of determination (R^2) of 0.80 and a mean absolute error (MAE) of 0.84, explaining 80% of the variance in academic performance. For predicting success in personalized learning, previous grades and educational interests remained key predictors, with coefficients of 0.47 each. This model had an R^2 of 0.75 and an MAE of 0.84, indicating acceptable accuracy.

The ANN model demonstrated superior performance across training, validation, and testing phases. In the test phase, it achieved an R^2 of 0.88 and an MAE of 0.81, outperforming the LR model. The ANN effectively captured complex nonlinear relationships among variables, as evidenced by higher correlation coefficients and lower errors in all phases. These results suggest that the ANN model provides higher accuracy and better generalization for predicting academic outcomes and optimizing personalized learning.

In conclusion, the ANN model outperforms the LR model in predicting students' academic performance and enhancing personalized learning. Implementing ANN models can assist educational institutions in improving educational planning, personalizing learning pathways, and better supporting student success. The superior accuracy and ability to model complex relationships make ANN a valuable

tool for advancing educational outcomes in higher education. Indirect effect of academic stressors on academic burnout through procrastination is not significant.

Conclusion

This study demonstrates that artificial neural networks (ANN) outperform linear regression (LR) in predicting students' academic performance and optimizing personalized learning and educational planning. In addressing the first research question on predictive accuracy, ANN achieved a higher coefficient of determination ($R^2 = 0.88$) compared to LR ($R^2 = 0.75$) during testing, highlighting ANN's superior generalizability and ability to capture complex, nonlinear relationships among educational variables. ANN also exhibited a lower mean absolute error (MAE) across all stages, indicating greater precision in predicting academic outcomes. These findings align with prior research: Bhardwaj et al. (2021) and Ouyang et al. (2023) emphasize deep learning models' efficacy in analyzing student engagement and enhancing personalized learning, while Luckin & Cukurova (2019) link AI-driven tools to reduced academic dropout rates. Dawson et al. (2019) and Bowden et al. (2021) further validate the role of educational big data and deep learning in understanding student behavior and improving instructional strategies.

The study underscores ANN's advantages over LR, particularly in processing multidimensional data and identifying intricate patterns, enabling more accurate, adaptive educational interventions. ANN's capabilities can reduce academic attrition by enabling early identification of at-risk students and facilitating timely support. Practical recommendations include integrating ANN-based systems into learning management platforms for real-time performance monitoring, adaptive content delivery, and automated alerts for educators. Policymakers are urged to develop AI-driven curricula that align with individual learning styles, leveraging ANN to personalize educational pathways and enhance learning efficacy. By adopting ANN-powered analytics, institutions can optimize digital education systems, improve student success rates, and advance the future of higher education through data-driven, student-centric approaches.

Resources

- Ahmadi, S., Tahmasbzadeh, D., & Mir-Arab Razi, R. (2024). Analysis of opportunities and challenges of personalized learning based on artificial intelligence in higher education. *Journal Educational Planning Studies*, 13(26), 7-33. 10.22080/eps.2025.28091.2292: doi. *Journal Educational Planning Studies* [in Persian].
- Alabbad, Y., Yildirim, E., & Demir, I. (2022). Flood mitigation data analytics and decision support framework: Iowa Middle Cedar Watershed case study. *Science of The Total Environment*, 814, 152768. <https://doi.org/10.1016/j.scitotenv.2021.152768>.
- Alam, A. (2021, December). Should robots replace teachers? Mobilisation of AI and learning analytics in education. In *2021 International Conference on Advances in Computing, Communication, and Control (ICAC3)* (pp. 1-12). IEEE. <https://doi.org/10.1109/ICAC353642.2021.9697300>.
- Alkhalaf, S., Drew, S., & Alhussain, T. (2012). Assessing the impact of e-learning systems on learners: A survey study in the KSA. *Procedia-Social and Behavioral Sciences*, 47, 98-104.
- Baker, R. S., Corbett, A. T., & Aleven, V. (2008). Improving contextual models of guessing and slipping with a truncated training
- Bhardwaj, P., Gupta, P. K., Panwar, H., Siddiqui, M. K., Morales-Menendez, R., & Bhaik, A. (2021). Application of deep learning on student engagement in e-learning environments. *Computers & Electrical Engineering*, 93, 107277. <https://doi.org/10.1016/j.compeleceng.2021.107277>
- Bloom, B. S., & Krathwohl, D. R. (2020). *Taxonomy of educational objectives: The classification of educational goals. Book 1, Cognitive domain*. Longman.
- Bowden, J. L. H., Tickle, L., & Naumann, K. (2021). The four pillars of tertiary student engagement and success: A holistic measurement approach. *Studies in Higher Education*, 46(6), 1207-1224. <https://eric.ed.gov/?id=EJ1299420>

- Casalino, G., Grilli, L., Limone, P., Santoro, D., & Schicchi, D. (2021). Deep learning for knowledge tracing in learning analytics: an overview. *TeleXbe*.
- Dabic, T. (2016). The Bloom's taxonomy revisited in the context of online tools. In *Sinteza 2016-International Scientific Conference on ICT and E-Business Related Research* (pp. 315-320). Singidunum University
- Dawson, S., Joksimovic, S., Poquet, O., & Siemens, G. (2019). Increasing the impact of learning analytics. In *Proceedings of the Ninth International Conference on Learning Analytics & Knowledge (LAK'19)*. ACM. <https://doi.org/10.1145/3303772.3303784>
- Felder, R., & Silverman, L. (1988). Learning and teaching styles in engineering education. *Engineering Education*, 78(7), 674-681. <http://localhost:8080/xmlui/handle/1/297>
- Gašević, D., Kovanović, V., & Joksimović, S. (2017). Piecing the learning analytics puzzle: A consolidated model of a field of research and practice. *Learning: Research and Practice*, 3(1), 63-78.
- Goldberg, P., Sümer, Ö., Stürmer, K., Wagner, W., Göllner, R., Gerjets, P., & Trautwein, U. (2021). Attentive or not? Toward a machine learning approach to assessing students' visible engagement in classroom instruction. *Educational Psychology Review*, 33, 27-49. <https://doi.org/10.1007/s10648-019-09514-z>
- Hamdi-Nasab, S., & Rahimi, S. (2024). The barriers and challenges of implementing artificial intelligence in higher education systems. *Journal Educational Planning Studies*, 13(26), 57–73. <https://doi.org/10.22080/eps.2025.28149.2295> [in Persian].
- Holmes, Wayne; Bialik, Maya and Fadel, Charles (2019). *Artificial Intelligence In Education: Promises and Implications for Teaching and Learning*. Boston, MA: Center for Curriculum Redesign. URL: <http://udaeducation.com/wp-content/uploads/2019/05...>
- Luckin, R., & Cukurova, M. (2019). Designing educational technologies in the age of AI: A learning sciences-driven approach. *British Journal of Educational Technology*, 50(6), 2824-2838. <https://doi.org/10.1111/bjet.12861>
- Makhambetova, A., Zhiyenbayeva, N., & Ergesheva, E. (2021). Personalized learning strategy as a tool to improve academic performance and motivation of students. *International Journal of Web-Based Learning and Teaching Technologies (IJWLTT)*, 16(6), 1-17. DOI:10.4018/IJWLTT.286743.
- Nistor, N., & Hernández-García, A. (2018). What types of data are used in learning analytics? An overview of six cases. *Computers in Human Behavior*, 89, 335-338. <https://doi.org/10.1016/j.chb.2018.07.038>
- Nkomo, L. M., Daniel, B. K., & Butson, R. J. (2021). Synthesis of student engagement with digital technologies: A systematic review of the literature. *International Journal of Educational Technology in Higher Education*, 18, 1-26. <https://link.springer.com/article/10.1186/s41239-021-00270-1>
- Ouyang, F., Wu, M., Zheng, L., Zhang, L., & Jiao, P. (2023). Integration of artificial intelligence performance prediction and learning analytics to improve student learning in online engineering courses. *International Journal of Educational Technology in Higher Education*, 20(1), 1-23. <https://doi.org/10.1186/s41239-022-00372-4>
- Pourjamshidi, M., & Mozaffari, O. (2024). Use of artificial intelligence technologies in STEAM educational program. *Journal Educational Planning Studies*, 13(26), 34–56. <https://doi.org/10.22080/eps.2025.28359.2303> [in Persian].
- ShariatPanahi, M. (2022). Analysis of the impact of artificial neural networks in predicting students' academic success. *Journal of Research and Innovation in Education and Development*, 2(2), 1-9. <https://jsied.org/index.php/jsied/article/view/32> [in Persian].
- Sit, M., Langel, R. J., Thompson, D., Cwiertny, D. M., & Demir, I. (2021). Web-based data analytics framework for well forecasting and groundwater quality. *Science of the Total Environment*, 761, 144121. <https://doi.org/10.1016/j.scitotenv.2020.144121>

- Smith, P., Powers, E., Anderson, H., Dellinger, J. T., & Siemens, G. (2022). Broadening the NLP agenda in learning analytics for the age of AI. *Companion Proceedings of the 12th International Conference on Learning Analytics & Knowledge (LAK'22)*, 182.
- Xu, H., Demir, I., Koylu, C., & Muste, M. (2019). A web-based geovisual analytics platform for identifying potential contributors to culvert sedimentation. *Science of the Total Environment*, 692, 806-817. <https://doi.org/10.1016/j.scitotenv.2019.07.157>
- Yang, Y. (2021). Does greater engagement in online general education courses lead to better academic performance? Evidence from Chinese university students. *Open Journal of Social Sciences*, 9(6), 298-315. <https://doi.org/10.4236/jss.2021.96022>
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education. *International Journal of Educational Technology in Higher Education*, 16(1), 39.

مقایسه کارایی مدل شبکه عصبی مصنوعی و مدل رگرسیون خطی در پیش بینی عملکرد تحصیلی دانشجویان و موفقیت آن ها در یادگیری شخصی سازی شده

(مطالعه موردی: دانشجویان کارشناسی و کارشناسی ارشد دانشگاه پیام نور مشهد)

معصومه عیلامی رود معجنی^۱، سمیه قاضی^۲ 

۱. استادیار، مطالعات برنامه درسی، علوم تربیتی، پیام نور، تهران، ایران. ilami@pnu.ac.ir

۲. مدرس گروه علوم تربیتی، دانشگاه فرهنگیان، مازندران، نوشهر، ایران. (نویسنده مسئول) mh.rezaei@cfu.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	مقاله حاضر با هدف بررسی کاربرد مدل های هوش مصنوعی در برنامه ریزی آموزشی و پیش بینی عملکرد تحصیلی دانشجویان و بهینه سازی یادگیری شخصی سازی شده انجام شده است. مقایسه میان شبکه عصبی مصنوعی و رگرسیون خطی به منظور شناسایی مدل بهینه در تحلیل داده های آموزشی صورت گرفته است. این پژوهش از نوع کمی و با روش تحقیق تحلیلی-مقایسه ای انجام شده است. داده های آموزشی از سامانه مدیریت یادگیری استخراج و برای تحلیل آن ها از رگرسیون خطی و شبکه عصبی مصنوعی استفاده شده است. شاخص های ضریب تعیین، میانگین خطای مطلق و ریشه میانگین مربعات خطا به منظور ارزیابی دقت و تعمیم پذیری مدل ها مورد بررسی قرار گرفته اند. یافته ها نشان داد که شبکه عصبی (با ضریب تعیین ۰/۸۸) در مرحله آزمون، دقت بالاتری نسبت به رگرسیون خطی (با ضریب تعیین ۰/۷۵) دارد و توانسته روابط پیچیده بین متغیرهای آموزشی را بهتر شناسایی کند و نشان دهنده دقت بیشتر این مدل در پیش بینی عملکرد تحصیلی دانشجویان و بهینه سازی برنامه ریزی آموزشی است. این پژوهش نشان می دهد که شبکه های عصبی مصنوعی به عنوان ابزارهای تحلیلی قدرتمند، توانایی بالایی در بهینه سازی فرآیندهای برنامه ریزی آموزشی دارند. با این حال، استفاده مؤثر از این مدل ها نیازمند داده های کافی، تنظیمات بهینه و زیرساخت های محاسباتی مناسب است. پیشنهاد می شود که دانشگاه ها و مؤسسات آموزشی از مدل های یادگیری ماشینی در تحلیل کلان داده های آموزشی بهره ببرند و سامانه های مدیریت یادگیری را با فناوری های مبتنی بر هوش مصنوعی تجهیز کنند. همچنین، افزایش آگاهی و آموزش اساتید درباره کاربردهای هوش مصنوعی در برنامه ریزی آموزشی و یادگیری شخصی سازی شده می تواند به بهبود کیفیت آموزش و کاهش نرخ افت تحصیلی کمک کند.
تاریخ دریافت: ۱۴۰۴/۰۳/۰۶ تاریخ بازنگری: ۱۴۰۴/۰۶/۰۲ تاریخ پذیرش: ۱۴۰۴/۰۶/۱۱ تاریخ انتشار:	
کلیدواژه ها: شبکه عصبی مصنوعی، عملکرد تحصیلی، یادگیری شخصی سازی شده، نیازهای آینده، برنامه ریزی آموزشی، آموزش عالی.	

استناد: عیلامی رود معجنی، معصومه؛ قاضی، سمیه. (۱۴۰۴). مقایسه کارایی مدل شبکه عصبی مصنوعی و مدل رگرسیون خطی در پیش بینی عملکرد تحصیلی دانشجویان و موفقیت آن ها در یادگیری شخصی سازی شده، پژوهش در روش های آموزش، ۳ (۴)،-..... <https://doi.org/10.22091/jrim.2025.13050.1295>

مقدمه

در دهه‌های اخیر، پیشرفت‌های چشمگیر در حوزه هوش مصنوعی^۱ (AI) و علوم داده^۲، چشم‌اندازهای جدیدی را برای تحول در نظام آموزش عالی ترسیم کرده است. به‌ویژه، کاربرد AI در برنامه‌ریزی آموزشی از طریق تجزیه و تحلیل کلان داده‌های یادگیری، امکان اتخاذ تصمیمات بهینه و مبتنی بر شواهد را برای سیاست‌گذاران و مدیران آموزشی فراهم کرده است. این قابلیت، علاوه بر بهبود کیفیت آموزش، زمینه‌ای برای توسعه استراتژی‌های یادگیری شخصی‌سازی شده^۳ و پیش‌بینی نیازهای آموزشی آینده مهیا می‌کند (Ouyang et al., 2023).

هوش مصنوعی به دانشجویان این امکان را می‌دهد که با سرعت خود و بر اساس نیازها و توانایی‌های فردی خود یاد بگیرند. این امر می‌تواند منجر به بهبود نتایج یادگیری، افزایش مشارکت و تعامل فعالانه آن‌ها شود. یادگیری شخصی شده با هوش مصنوعی با ارائه تجربه یادگیری سفارشی‌تر، نرخ موفقیت دانشجویان را افزایش می‌دهد (Hamedi Nasab, 1403 and Rahimi.). نتایج پژوهش (Makhambetovat et al., 2021) نشان داده است نسل امروزی، یادگیری شخصی‌سازی شده را بر یادگیری معمول ترجیح داده و یادگیری شخصی‌سازی شده منجر به افزایش عملکرد تحصیلی و انگیزش یادگیرندگان می‌شود. در همین راستا هوش مصنوعی با شخصی‌سازی یادگیری، مبتنی بر بهره‌گیری از الگوریتم‌های یادگیری ماشینی و پردازش داده‌های فردی دانشجویان برای ارائه مسیرهای آموزشی تطبیقی در آموزش عالی توانسته است اثربخشی فرآیند تدریس را بهبود بخشد و نرخ موفقیت تحصیلی را افزایش دهد (Nkomo et al et al., 2021). علاوه بر این، هوش مصنوعی قادر است میزان مشارکت دانشجویان در فرآیند یادگیری را بهینه‌سازی کرده و سطح انگیزه آن‌ها را با ارائه محتوای آموزشی متناسب افزایش دهد (Goldberg et al., 2021). هوش مصنوعی با استفاده از تحلیل داده‌های بزرگ، اطلاعات ارزشمندی از رفتار یادگیری دانشجویان استخراج می‌کند که می‌تواند برای شناسایی نقاط ضعف و قوت یادگیرندگان و طراحی برنامه‌های آموزشی متناسب با نیازهای آن‌ها مورد استفاده قرار گیرد (Zwaki- Richter et al., 2019). از طرف دیگر با شناسایی نیازهای خاص دانشجویان می‌تواند امکان برنامه‌ریزی آموزشی لازم در آموزش عالی برای دسترسی برابر به منابع آموزشی و طراحی برنامه‌هایی که نیازهای گروه‌های محروم را برآورده می‌کند، فراهم سازد (Holmes et al., 2019).

یکی دیگر از قابلیت‌های محوری AI در این حوزه، پیش‌بینی نیازهای آموزشی آینده بر اساس تحلیل داده‌های یادگیری و برنامه‌ریزی آموزشی برای آن است. با استفاده از مدل‌های تحلیل یادگیری، دانشگاه‌ها می‌توانند نیازهای مهارتی بازار کار را شناسایی کرده و برنامه‌های درسی خود را مطابق با این نیازها تطبیق دهند. این امر، نه تنها موجب افزایش قابلیت اشتغال دانشجویان می‌شود، بلکه هم‌راستایی بین برنامه‌ریزی‌های آموزش عالی و بخش‌های صنعتی را تقویت می‌کند (Luckin & Cukurova., 2019) پیش‌بینی نیازهای آموزشی و برنامه‌ریزی برای آن می‌تواند به طراحی برنامه‌های

¹ Artificial Intelligence

² Data Science

³ Personalized Learning

درسی انعطاف‌پذیرتر و همگام با پیشرفت‌های فناوریانه کمک کند. می‌توان گفت تحولات فناورانه در آموزش، ضرورت اتخاذ رویکردهای داده‌محور را بیش‌ازپیش برجسته ساخته و به همین دلیل دانشگاه‌های پیشرو اکنون از سامانه‌های یادگیری ماشینی برای تحلیل الگوهای یادگیری دانشجویان و ارائه برنامه‌ها و راهبردهای آموزشی کارآمد بهره می‌برند. این تحولات نه تنها موجب ارتقای اثربخشی یادگیری شده است، بلکه مسیرهای آموزشی متناسب با نیازهای فردی دانشجویان را نیز فراهم کرده است (Gasevic et al., 2017) بدین ترتیب گسترش این رویکردها می‌تواند در ارزیابی دقیق‌تر میزان پیشرفت تحصیلی دانشجویان و شناسایی نقاط ضعف آن‌ها و برنامه‌ریزی‌های آموزشی دقیق‌تر نقشی کلیدی ایفا کند.

در زمینه ارتباط آموزش با بازار کار، هوش مصنوعی می‌تواند نقش کلیدی در تعریف مسیرهای یادگیری مبتنی بر تقاضای صنعتی ایفا کند. در واقع با بهره‌گیری از AI، مدارس و دانشگاه‌ها می‌توانند دوره‌های آموزشی متناسب با مهارت‌های موردنیاز صنایع مختلف را برنامه‌ریزی و تدوین کرده و فرصت‌های شغلی بهتری برای دانش‌آموختگان ایجاد کنند. این قابلیت به‌ویژه برای کشورهایی که به دنبال بهبود پیوند میان آموزش و صنعت هستند، اهمیت راهبردی دارد (Sit et al., 2021). از این رو به‌کارگیری ابزارهای مبتنی بر AI برای تجزیه و تحلیل بازار کار و برنامه‌ریزی آموزشی و توسعه برنامه‌های درسی در آموزش عالی، می‌تواند نقش مؤثری در افزایش اشتغال‌پذیری دانش‌آموختگان داشته باشد (Alabbad et al., 2022).

با ارائه یک چارچوب تحلیل داده‌ها و پشتیبانی از تصمیم‌گیری در مدیریت سیلاب‌ها، محققان نشان دادند که استفاده از تحلیل داده‌ها و تصمیم‌گیری مبتنی بر داده‌ها می‌تواند به بهبود مدیریت و کارایی در بخش‌های مختلف منجر شود. (et Xu al., 2019). همچنین با توسعه یک پلتفرم وب‌محور برای تحلیل داده‌های محیطی، پژوهشگران نشان دادند که استفاده از فناوری‌های هوش مصنوعی می‌تواند به بهبود فرآیندهای آموزشی و پژوهشی کمک کند. پژوهش (Pour Jamshidi and Mozaffari, ۱۴۰۳) نیز که به کاربرد فناوری‌های هوش مصنوعی در برنامه آموزشی استیم^۱ پرداختند، معتقدند تلفیق هوش مصنوعی در برنامه آموزش استیم تأثیر مثبتی بر دانش و مهارت‌های دانشجویان دارد. (Ahmadi et al., 1403). به تحلیل فرصت‌ها و چالش‌های یادگیری شخصی‌سازی شده مبتنی بر هوش مصنوعی در آموزش عالی ایران پرداختند. آن‌ها اذعان دارند یادگیری شخصی‌سازی شده مبتنی بر هوش مصنوعی با فواید و فرصت‌های زیادی برای برنامه‌ریزی آموزش عالی ایران همراه است اما چالش‌های سخت‌افزاری و انسانی بر سر راه آن قرار دارد که نیازمند توجه ویژه هستند. حامدی نسب و رحیمی^۲ (۱۴۰۳) نیز به موانع و چالش‌های پیاده‌سازی هوش مصنوعی در نظام آموزش عالی پرداختند. آن‌ها بیان کردند برای تسهیل پیاده‌سازی هوش مصنوعی در آموزش عالی، باید برنامه‌ریزی آموزشی شامل ارتقای زیرساخت‌ها، توسعه دوره‌های تخصصی، تغییر نگرش‌ها از طریق برنامه‌های ترویجی، تدوین قوانین حمایتی و گسترش همکاری‌های ملی و بین‌المللی باشد. می‌توان گفت برای غلبه بر چالش‌ها، نیاز به برنامه‌ریزی جامع و همکاری بین نهادهای آموزشی،

^۱ برنامه آموزشی استیم (STEAM): رویکرد آموزشی میان‌رشته‌ای شامل علوم (Science)، فناوری (Technology)، مهندسی (Engineering)، هنر (Arts) و ریاضی (Mathematics)

^۲ Hamed Nasab and Rahimi

فناوری و سیاست‌گذاری است. با رویکردی مبتنی بر آینده‌نگری و ارتقای مهارت‌های دانشجویان و استادان، می‌توان به سمت نظام آموزشی کارآمدتر و شخصی‌سازی‌شده حرکت کرد (Ahmadi et al., 1403). همچنین بهره‌گیری از تجربیات بین‌المللی و تطبیق آن با شرایط فرهنگی و اجتماعی ایران می‌تواند راه‌گشای پیاده‌سازی مؤثر هوش مصنوعی در آموزش عالی باشد. بدیهی است هر گونه تصمیم‌گیری و سیاست‌گذاری جهت بهبود فرایندهای آموزشی در آموزش عالی به پیش‌بینی دقیق به‌منظور برنامه‌ریزی آموزشی دقیق در این حوزه نیازمند است و این امر با ارزیابی دقیق میزان پیشرفت تحصیلی دانشجویان و شناسایی نقاط ضعف آن‌ها میسر می‌شود؛ بنابراین نیاز به مدل‌های تحلیل داده‌های یادگیری قدرتمند بسیار ضروری می‌نماید. تحلیل مطالعات مختلف نشان می‌دهد که شبکه‌های عصبی مصنوعی به دلیل توانایی در پردازش داده‌های پیچیده و چندبعدی، نسبت به روش‌های سنتی پیش‌بینی عملکرد بهتری دارند (Shariat Panahi, 1401). طبق پژوهش‌ها، شبکه عصبی مصنوعی یکی از روش‌های هوشمند پردازش داده‌ها هستند که در روش تحلیل اطلاعات مشابه با مغز انسان عمل می‌کنند و دارای ویژگی‌هایی چون داشتن قدرت تعمیم، عدم نیاز به یک مدل ریاضی از پیش تعیین‌شده، عدم نیاز به هم‌راستایی و نرمال بودن داده‌ها و توانایی آموزش و یادگیری هستند (Mottaghian et al., 2013). یکی از نخستین کاربردهای شبکه‌های عصبی در آموزش، استفاده از آن‌ها برای تحلیل نمرات و پیش‌بینی موفقیت تحصیلی دانش‌آموزان است. نتایج پژوهش (Shariat Panahi, 1401). نشان می‌دهد شبکه‌های عصبی مصنوعی می‌توانند با تحلیل طیف گسترده‌ای از متغیرها، از جمله مشارکت در فعالیت‌های کلاسی، سوابق تحصیلی گذشته و عوامل دموگرافیک، عملکرد تحصیلی دانش‌آموزان را با دقت بالایی پیش‌بینی کنند. علیرغم پتانسیل بالای شبکه‌های عصبی، اجرای آن‌ها با چالش‌هایی مانند نیاز به داده‌های بزرگ و با کیفیت و پیچیدگی‌های مربوط به تفسیر نتایج مواجه است. این کاربرد به‌ویژه در سیستم‌های آموزشی برخلاف^۱ که داده‌های زیادی از فعالیت‌های دانش‌آموزان جمع‌آوری می‌شود، بسیار مورد توجه قرار گرفته است (Alkhalaf et al., 2012). نتیجه پژوهش (Baker et al., 2008) نشان داد شبکه‌های عصبی می‌توانند با تحلیل داده‌های مربوط به فعالیت‌های کلاسی و نمرات دانش‌آموزان، احتمال موفقیت یا شکست آن‌ها در دوره‌های تحصیلی را با دقت بالایی پیش‌بینی کنند. این مطالعات نشان داد که شبکه‌های عصبی قادر به شناسایی الگوهای پنهان در داده‌ها هستند که ممکن است برای انسان‌ها قابل شناسایی نباشند.

با توجه به ماهیت پیچیده فرآیند یادگیری و تأثیرپذیری آن از عوامل متنوع رفتاری، شناختی و محیطی، استفاده از ترکیب دو رویکرد مدل‌سازی آماری و یادگیری ماشین در این پژوهش هدف‌گذاری شده است. مدل رگرسیون خطی به دلیل سادگی، قابلیت تفسیر بالا و توانایی بررسی رابطه‌ی خطی میان متغیرها، به‌عنوان یک مدل پایه برای تحلیل اولیه انتخاب شده است. در مقابل، شبکه عصبی مصنوعی با ساختار غیرخطی و چندلایه، قابلیت شناسایی الگوهای پنهان و پیچیده در داده‌های آموزشی را داراست. این مدل‌ها در کنار یکدیگر می‌توانند دید جامعی از عوامل مؤثر بر پیشرفت تحصیلی ارائه دهند (Casalino et al., 2021) با این حال، هریک از این مدل‌ها محدودیت‌هایی دارند؛ مدل رگرسیون خطی در تحلیل روابط غیرخطی و تعاملات پیچیده میان متغیرها کارایی محدودی دارد و مدل شبکه عصبی نیز علی‌رغم دقت بالا، به دلیل

^۱ online

نیاز به داده‌های حجیم، دشواری در تفسیر خروجی‌ها و احتمال بیش‌برازش (overfitting)، در برخی از کاربردهای آموزش عالی با چالش مواجه است؛ بنابراین، تحلیل هم‌زمان نتایج حاصل از هر دو مدل می‌تواند به درک عمیق‌تری از رفتارهای یادگیری و تصمیم‌گیری مؤثرتر در حوزه یادگیری شخصی‌سازی شده منجر شود. این پژوهش با ارائه مقایسه‌ای جامع میان مدل هوش مصنوعی و سنتی در تحلیل داده‌های آموزشی، به توسعه دانش در زمینه برنامه‌ریزی آموزشی مبتنی بر هوش مصنوعی، یادگیری شخصی‌سازی شده و مدل‌سازی پیش‌بینی تحصیلی کمک کرده است. برخلاف مطالعات پیشین که عمدتاً بر روش‌های آماری کلاسیک تمرکز داشتند، این تحقیق بر اهمیت استفاده از مدل یادگیری عمیق در بهینه‌سازی تصمیم‌گیری آموزشی تأکید دارد و چارچوبی علمی برای به‌کارگیری آن در محیط‌های آموزش عالی ارائه می‌دهد.

روش‌شناسی پژوهش

این پژوهش از نظر هدف، کاربردی و از نظر روش، توصیفی-تحلیلی با رویکرد کمی انجام شد. برای پیش‌بینی نیازهای آموزشی و بهینه‌سازی فرآیند یادگیری شخصی‌سازی شده در آموزش عالی، از مدل‌های هوش مصنوعی شامل شبکه عصبی مصنوعی و رگرسیون خطی استفاده شد. داده‌های آموزشی از سامانه‌های مدیریت یادگیری^۱ (LMS) استخراج گردید.

جامعه آماری شامل دانشجویان دانشگاه پیام نور مشهد در مقاطع کارشناسی و کارشناسی ارشد در نیم سال دوم تحصیلی ۱۴۰۲ بوده و حجم نمونه با استفاده از فرمول کوکران ۳۸۴ نفر تعیین شده است. روش نمونه‌گیری به صورت تصادفی طبقه‌ای بر اساس تعداد دانشجویان در هر مقطع تحصیلی انجام شده است. بر این اساس، ۲۶۹ نفر از دانشجویان کارشناسی و ۱۱۵ نفر از دانشجویان کارشناسی ارشد به صورت تصادفی از میان رشته‌های مختلف انتخاب شده‌اند تا پوشش مناسبی از تمامی گروه‌های تحصیلی فراهم شود.

متغیرهای مستقل پژوهش شامل عوامل مختلفی همچون میزان تعامل در کلاس‌های مجازی، سبک یادگیری، تعداد تکالیف انجام شده و میزان مشارکت در بحث‌های کلاسی است. متغیرهای وابسته شامل پیشرفت تحصیلی آینده و میزان موفقیت در یادگیری شخصی‌سازی شده هستند. این متغیرها بر اساس مرور ادبیات نظری و پژوهش‌های پیشین در حوزه یادگیری شخصی‌سازی شده و با بررسی عوامل مؤثر بر عملکرد تحصیلی دانشجویان در محیط‌های آموزش الکترونیکی شناسایی و انتخاب شده‌اند. در جدول زیر، جزئیات متغیرهای پژوهش ارائه شده است:

جدول ۱: متغیرهای پژوهش و ویژگی‌های عملیاتی آن‌ها

^۱ Learning Management System

نوع متغیر	متغیر	تعریف مفهومی	ویژگی‌های عملیاتی
مستقل (ورودی مدل)	میزان تعامل در کلاس مجازی	درجه مشارکت دانشجو در جلسات برخط و فعالیت‌های تعاملی کلاس	مجموع زمان حضور در کلاس‌های برخط (بر حسب دقیقه)، تعداد دفعات ورود به کلاس، تعداد شرکت در نظرسنجی‌ها و استفاده از ابزارهای تعاملی
	نمرات قبلی	سطح پیشینه‌ی تحصیلی دانشجو بر اساس عملکرد گذشته	میانگین نمرات دروس تخصصی ترم‌های گذشته (مقیاس ۰ تا ۲۰)؛ همچنین قابل دسته‌بندی به سه سطح ضعیف (زیر ۱۲)، متوسط (۱۲-۱۶) و قوی (بالای ۱۶)
	سبک یادگیری	ترجیحات شناختی دانشجو در فرایند Felder & Silverman یادگیری طبق مدل	دسته‌بندی در چهار بعد اصلی: فعال/بازتابی، حسی/شهودی، دیداری/کلامی، ترتیبی/اسراسری (بر اساس امتیاز پرسشنامه استاندارد ۴۴ گویه‌ای)
	علاقه‌مندی‌های آموزشی	میزان تمایل فردی به یادگیری در حوزه‌های خاص و انتخاب مسیرهای علمی شخصی‌سازی شده	تعداد دوره‌های انتخابی غیراجباری، درصد انتخاب واحدهای اختیاری نسبت به کل واحدها، ثبت‌نام در دوره‌های مکمل یا کارگاه‌های جانبی
	تعداد تکالیف انجام شده	سطح فعالیت تکلیفی دانشجو در طی ترم	نسبت تعداد تکالیف تحویل شده به کل تکالیف تعریف شده (بر حسب درصد) در هر درس یا کل دروس (مثلاً ۷ از ۱۰ = ۷۰٪)
	میزان مشارکت در بحث‌های کلاسی	میزان تعامل کلامی و فکری دانشجو در محیط‌های گفت‌وگو و یادگیری مشارکتی	تعداد پیام‌های ارسال شده در تالارهای بحث، پاسخ به سؤالات دیگران، مشارکت در فعالیت‌های گروهی برخط (LMS برحسب شمارش سیستمی)
وابسته (خروجی مدل)	پیشرفت تحصیلی آینده	بهبود عملکرد تحصیلی دانشجو در دوره‌های آینده بر اساس روند پیش‌بینی شده توسط مدل	اختلاف معدل کل ترم بعدی نسبت به ترم فعلی؛ یا پیش‌بینی نمره دروس کلیدی آینده بر اساس مدل یادگیری (مقیاس ۰ تا ۲۰)
	موفقیت در یادگیری شخصی‌سازی شده	میزان انطباق روش‌های یادگیری با سبک فردی دانشجو و اثر آن بر نتایج تحصیلی	اختلاف عملکرد دانشجو در محیط‌های آموزشی استاندارد در برابر محیط‌های شخصی‌سازی شده؛ نمرات آزمون‌های پیشرفت در هر دو محیط

این جدول شامل متغیرهای مستقل (ورودی مدل) و وابسته (خروجی مدل) پژوهش است. متغیرهای مستقل ویژگی‌های آموزشی و شخصی دانشجویان را شامل می‌شوند که به عنوان داده‌های ورودی در مدل‌های پیش‌بینی عملکرد تحصیلی استفاده می‌شوند. متغیرهای وابسته نشان‌دهنده نتایج مورد انتظار مدل بر اساس این متغیرها هستند. داده‌های پژوهش از دو منبع اصلی جمع‌آوری شد: پرسشنامه یادگیری فلدر و سیلورمن. پرسشنامه سبک‌های یادگیری فلدر و سیلورمن (Felder & Silverman, 1988) ابزاری استاندارد برای سنجش سبک‌های یادگیری دانشجویان است که توسط فلدر و سولومان طراحی شده و شامل ۴ بُعد شناختی است. این پرسشنامه دارای ۴۴ گویه است که هر بُعد آن ۱۱ سؤال دارد و سبک‌های یادگیری افراد را در چهار مقیاس دوگانه ارزیابی می‌کند: فعال در برابر تأملی (نحوه پردازش اطلاعات)، حسی در برابر شهودی (نوع دریافت اطلاعات)، بصری در برابر کلامی (شیوه ارائه اطلاعات) و ترتیبی در برابر کلی‌نگر (روش سازمان‌دهی اطلاعات). هر گویه شامل دو گزینه است و پاسخ‌دهندگان گزینه‌ای را که با

سبک یادگیری آن‌ها مطابقت بیشتری دارد، انتخاب می‌کنند. نمره هر سبک بین ۰ تا ۱۱ متغیر است، به‌طوری که مقادیر ۱ تا ۳ نشان‌دهنده ترجیح ضعیف، ۵ تا ۷ نشان‌دهنده ترجیح متوسط و ۹ تا ۱۱ نشان‌دهنده ترجیح قوی برای یک سبک یادگیری خاص است. روایی محتوایی پرسشنامه با بررسی متخصصان آموزش و روان‌شناسی تأیید شده و پایایی آن نیز با استفاده از آلفای کرونباخ بین ۰,۷۵ تا ۰,۸۵ در مطالعات مختلف گزارش شده است. این ابزار در تحقیقات آموزشی به‌منظور بهینه‌سازی فرآیند یادگیری شخصی‌سازی شده و بهبود عملکرد تحصیلی مورد استفاده قرار می‌گیرد.

منبع دوم گردآوری اطلاعات، اطلاعات آموزشی سامانه مدیریت یادگیری (LMS) است که برای کل ۳۸۴ فراگیر انتخاب شده جمع‌آوری گردید. تحلیل داده‌ها با استفاده از شبکه عصبی مصنوعی و رگرسیون خطی انجام شد. اطلاعات استخراج شده از LMS مربوط به نیم‌سال دوم ۱۴۰۲ بوده و شامل تعاملات کاربران با محتوای درسی، زمان‌های ورود و خروج، مشارکت در بحث‌ها و میزان مشاهده جلسات آموزشی است. معیار ورود نمونه‌ها شامل دانشجویانی بوده است که حداقل در ۲۰ درصد از جلسات آموزشی حضور ثبت شده داشته‌اند و دروس ارائه شده‌ای که دارای حداقل ۱۵ دانشجوی فعال بوده‌اند. در مقابل، معیار خروج شامل حذف درس‌هایی با مشارکت پایین، کاربران دارای داده‌های ناقص یا تعاملات نامعتبر و نیز حذف سوابق تکراری یا ناقص در ثبت فعالیت‌ها بوده است. تحلیل داده‌ها با استفاده از شبکه عصبی مصنوعی (ANN) و رگرسیون خطی (LR) انجام شده است. مدل ANN شامل یک لایه ورودی (۶ نود)، دو لایه مخفی (۱۲ و ۸ نود) با تابع فعال‌سازی ReLU و یک لایه خروجی با تابع Sigmoid است. دقت مدل‌ها با شاخص‌های ریشه میانگین مربعات خطا (RMSE) و ضریب تعیین (R^2) ارزیابی شده و مدلی که عملکرد بهتری داشته باشد، برای پیش‌بینی نیازهای آموزشی دانشجویان انتخاب خواهد شد.

علاوه بر آن، مدل رگرسیون خطی به‌منظور بررسی رابطه بین متغیرهای مستقل (ویژگی‌های آموزشی و فردی دانشجویان) و متغیرهای وابسته (پیش‌بینی عملکرد تحصیلی و موفقیت در یادگیری) مورد استفاده قرار گرفته است. فرمول کلی این مدل به‌صورت $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n$ تعریف شده که در آن Y نشان‌دهنده متغیر وابسته و X_n متغیرهای مستقل مانند تعامل، نمرات قبلی، سبک یادگیری و میزان مشارکت در کلاس‌های مجازی است. هر دو مدل با استفاده از زبان برنامه‌نویسی Python و کتابخانه‌های Scikit-Learn، TensorFlow و Keras پیاده‌سازی شده و دقت آن‌ها با شاخص‌های ضریب تعیین (R^2)، میانگین خطای مطلق و ریشه میانگین مربعات خطا ارزیابی شده است. مقایسه نتایج این مدل‌ها امکان انتخاب بهترین روش برای شخصی‌سازی یادگیری دانشجویان را فراهم می‌کند.

یافته‌ها


در پژوهش حاضر که با هدف مقایسه کارایی مدل شبکه عصبی مصنوعی و مدل رگرسیون خطی در پیش‌بینی عملکرد تحصیلی دانشجویان و موفقیت آن‌ها در یادگیری شخصی‌سازی انجام شد، ابتدا تحلیل داده‌ها با مدل رگرسیون خطی و سپس با مدل شبکه عصبی مصنوعی انجام گرفت. بر این اساس یافته‌های پژوهش به شرح زیر می‌باشد: در تحلیل مدل‌های رگرسیون خطی، برای بررسی تأثیر متغیرهای مختلف بر پیش‌بینی عملکرد تحصیلی آینده و موفقیت در یادگیری شخصی‌سازی شده، از رگرسیون خطی استفاده شد. در این پژوهش، متغیرهای میزان تعامل در کلاس، نمرات

قبلی، سبک یادگیری، علاقه‌مندی‌های آموزشی، تعداد تکالیف انجام‌شده و میزان مشارکت در بحث‌های کلاسی به‌عنوان متغیرهای مستقل در نظر گرفته شدند. در مقابل، دو متغیر پیش‌بینی عملکرد تحصیلی آینده^۱ و موفقیت در یادگیری شخصی‌سازی‌شده^۲ به‌عنوان متغیرهای وابسته مورد بررسی قرار گرفتند.

در مدل تحلیل مدل رگرسیون برای پیش‌بینی عملکرد تحصیلی آینده مطابق معادله زیر، پیشرفت تحصیلی آینده به‌عنوان متغیر وابسته در نظر گرفته شد. ضرایب مدل نشان می‌دهد که نمرات قبلی (۰/۵۲) و علاقه‌مندی‌های آموزشی (۰/۵۲) بیشترین تأثیر را در پیش‌بینی عملکرد تحصیلی دارند. این نتیجه منطقی است، زیرا دانشجویانی که علاقه‌مندی بیشتری به یادگیری نشان می‌دهند و در گذشته عملکرد بهتری داشته‌اند، احتمالاً در آینده نیز موفق‌تر خواهند بود. همچنین، تعامل در کلاس مجازی (۰/۳۲) و میزان مشارکت در بحث‌های کلاسی (۰/۲۵) نیز از عوامل تأثیرگذار بر پیشرفت تحصیلی هستند. دقت مدل با ضریب تعیین (R^2) برابر ۰/۸۰ نشان می‌دهد که این مدل ۸۰٪ از تغییرات متغیر وابسته را توضیح می‌دهد که نشان از دقت بالای مدل دارد.

همچنین، میانگین خطای مطلق مدل ($MAE = ۰/۸۴$) تأیید می‌کند که میزان خطای پیش‌بینی نسبتاً پایین است. نمودار مقایسه مقادیر واقعی و پیش‌بینی‌شده نشان می‌دهد که مدل در بیشتر موارد تخمین دقیقی ارائه داده و نقاط داده به خط ایده‌آل $y = x$ نزدیک هستند.

$$\text{Educational Future} = -0.50 + 0.32 \times \text{Interaction} + 0.52 \times \text{Previous Grades} + 0.12 \times \text{Learning Style} + 0.52 \times \text{Interests} + 0.36 \times \text{Assignments} + 0.25 \times \text{Participation}$$



شکل ۱: عملکرد مدل رگرسیون برای پیش‌بینی عملکرد تحصیلی آینده

^۱. Educational Future

^۲. Personalized learning

در مدل رگرسیون برای پیش‌بینی موفقیت در یادگیری شخصی سازی شده به عنوان متغیر وابسته مورد بررسی قرار گرفت. ضرایب مدل نشان می‌دهد که نمرات قبلی (۰,۴۷) و علاقه‌مندی‌های آموزشی (۰,۴۷) همچنان دو عامل کلیدی در موفقیت دانشجویان در یادگیری شخصی سازی شده هستند. علاوه بر این، تعداد تکالیف انجام شده (۰,۳۱) و میزان تعامل در کلاس (۰,۲۷) تأثیر مهمی در موفقیت این روش آموزشی دارند. این یافته‌ها نشان می‌دهد که دانشجویانی که تعامل بیشتری با محیط یادگیری دارند و علاقه شخصی‌تری به یادگیری نشان می‌دهند، احتمالاً در یادگیری شخصی سازی شده نیز عملکرد بهتری خواهند داشت. ضریب تعیین این مدل ($R^2 = 0.75$) نشان می‌دهد که مدل ۷۵٪ از تغییرات متغیر وابسته را توضیح می‌دهد که دقت بالایی مدل را نشان می‌دهد. همچنین، مقدار میانگین خطای مطلق ($MAE = 0.84$) نشان‌دهنده میزان خطای پایین پیش‌بینی مدل است. نمودار مقایسه مقادیر واقعی و پیش‌بینی شده نشان می‌دهد که پیش‌بینی‌های مدل به مقدار واقعی نزدیک بوده و دقت آن برای تحلیل‌های آموزشی قابل قبول است.

$$\text{Learning Success} = -0.50 + 0.27 \times \text{Interaction} + 0.47 \times \text{Previous Grades} + 0.07 \times \text{Learning Style} + 0.47 \times \text{Interests} + 0.31 \times \text{Assignments} + 0.20 \times \text{Participation}$$



شکل ۲: عملکرد مدل رگرسیون برای پیش‌بینی یادگیری شخصی سازی شده

نتایج این پژوهش نشان مطابق شکل ۱ و شکل ۲ می‌دهد که مدل‌های رگرسیون خطی ابزار قدرتمندی برای پیش‌بینی عملکرد تحصیلی و موفقیت دانشجویان در یادگیری شخصی سازی شده هستند. این مدل‌ها می‌توانند به دانشگاه‌ها و مؤسسات آموزشی کمک کنند تا برنامه‌ریزی دقیق‌تری برای دانشجویان انجام دهند و منابع آموزشی را بر اساس نیازهای فردی هر دانشجو تخصیص دهند. همچنین، این تحلیل‌ها می‌توانند راهنمایی دقیقی برای توسعه روش‌های یادگیری هوشمند و مبتنی بر هوش مصنوعی در آموزش عالی ارائه دهند. با استفاده از این مدل‌ها، می‌توان دانشجویانی را که در معرض افت تحصیلی هستند شناسایی کرده و راهکارهای بهینه‌ای برای بهبود عملکرد تحصیلی آن‌ها پیشنهاد داد.

برای کاربرد تحلیل عملکرد شبکه عصبی در این مطالعه، یک مدل شبکه عصبی مصنوعی برای پیش‌بینی عملکرد تحصیلی دانشجویان آموزش داده شد و عملکرد آن با استفاده از داده‌های آموزشی، اعتبارسنجی و آزمون مورد بررسی قرار گرفت. سه شاخص کلیدی شامل میانگین خطای مربعی و ضریب همبستگی (R) برای ارزیابی دقت مدل در سه مرحله مختلف مورد استفاده قرار گرفتند.

نتایج مطابق جدول ۲ نشانگر این است که در مرحله آموزش، مدل با استفاده از ۲۶۸ نمونه داده، الگوهای پنهان بین متغیرهای ورودی و خروجی را یاد گرفت. مقدار میانگین خطای مربعی در این مرحله برابر با ۱/۱۹۰۵ به دست آمد که نشان می‌دهد مدل به‌طور کلی داده‌ها را به خوبی درک کرده و خطای نسبی کمی دارد. علاوه بر این، مقدار ضریب همبستگی ($R = ۰/۹۰۰۷$) نشان‌دهنده رابطه قوی بین مقادیر واقعی و مقادیر پیش‌بینی شده در مرحله آموزش است. این مقدار نزدیک به ۱ بوده و نشان می‌دهد که مدل وابستگی‌های قوی بین متغیرهای مستقل و وابسته را به خوبی فرا گرفته است.

جدول ۲: بررسی عملکرد مدل شبکه عصبی

مرحله ارزیابی	تعداد نمونه‌ها	میانگین خطای مربعی (MSE)	ضریب همبستگی (R)
آموزش (Training)	۲۶۸	۱,۱۹۰۵	۰,۹۰۰۷
اعتبارسنجی (Validation)	۵۸	۰,۹۴۵۲	۰,۹۴۰
آزمون (Test)	۵۸	۱,۴۹۱۲	۰,۸۸۱۹


در این پژوهش، برای ارزیابی قابلیت تعمیم‌پذیری مدل شبکه عصبی و جلوگیری از بیش‌برازش^۱، از یک مجموعه داده مستقل شامل ۵۸ نمونه داده اعتبارسنجی استفاده شد. مقدار میانگین خطای مربعی در این مرحله برابر با ۰/۹۴۵۲ بوده که نسبت به مقدار میانگین خطای مربعی در مرحله آموزش کمتر است و نشان‌دهنده بهینه بودن مدل در تنظیم پارامترها و افزایش دقت آن در پردازش داده‌های جدید است. همچنین، مقدار ضریب همبستگی ($R = ۰,۹۴۰۶$) در این مرحله نسبت به مرحله آموزش افزایش یافته که حاکی از توانایی بالای مدل در تعمیم‌دهی بر روی داده‌های جدید است. مقدار بالای ۰/۹۴ در ضریب همبستگی نشان می‌دهد که مدل روابط بین داده‌ها را به‌درستی شناسایی کرده و توانایی پیش‌بینی مناسبی دارد.

مرحله آزمون برای ارزیابی عملکرد نهایی مدل بر روی داده‌های کاملاً جدید طراحی شده است که مدل در حین آموزش هرگز این داده‌ها را مشاهده نکرده است. این مجموعه شامل ۵۸ نمونه داده آزمون بوده و مقدار میانگین خطای مربعی میانگین خطای مربعی در این مرحله برابر با ۱/۴۹۱۲ محاسبه شده که نسبت به مراحل آموزش و اعتبارسنجی کمی افزایش یافته است. این افزایش در مقدار خطای میانگین مربعی معمولاً به دلیل تفاوت‌های موجود بین داده‌های آزمون و داده‌های

^۱ Overfitting

آموزشی رخ می‌دهد. با این حال، مقدار ضریب همبستگی ($R=0.819$) همچنان بالا بوده و نشان‌دهنده دقت مناسب مدل در پیش‌بینی داده‌های جدید است.


نتایج حاصل از سه مرحله ارزیابی مطابق جدول ۲ و شکل ۳ نشان می‌دهد که مدل شبکه عصبی توسعه‌یافته توانسته به‌خوبی روابط میان متغیرهای آموزشی را یاد گرفته و بر روی داده‌های جدید تعمیم دهد. مقدار میانگین خطای مربعی نسبتاً کم و مقدار R بالا در تمامی مراحل نشان‌دهنده کارایی مطلوب مدل در پیش‌بینی عملکرد تحصیلی دانشجویان است. از سوی دیگر، مقدار میانگین خطای مربعی در مرحله آزمون نسبت به مراحل آموزش و اعتبارسنجی کمی افزایش یافته که بیانگر چالش‌های مربوط به تعمیم‌دهی در مواجهه با داده‌های کاملاً جدید است. این موضوع معمولاً با افزایش حجم داده‌های آموزشی، بهینه‌سازی ساختار شبکه عصبی، و استفاده از تکنیک‌های تنظیم مدل^۱ مانند Dropout یا γ_2 Regularization بهبود می‌یابد. به‌طور کلی، با توجه به مقدار R بالای ۰.۸۸ در تمامی مراحل و مقدار میانگین خطای مربعی که در حد قابل قبولی باقی مانده است، می‌توان نتیجه گرفت که مدل شبکه عصبی طراحی شده از دقت و قابلیت تعمیم بالایی برخوردار بوده و می‌تواند به‌عنوان یک ابزار کارآمد برای پیش‌بینی عملکرد تحصیلی دانشجویان مورد استفاده قرار گیرد.



شکل ۳: عملکرد مدل شبکه عصبی

^۱: Regularization

شکل ۴ هیستوگرام خطا را با ۲۰ دسته‌بندی^۱ برای شبکه عصبی مصنوعی نمایش می‌دهد. محور افقی مقدار خطاها (اختلاف بین مقادیر واقعی و پیش‌بینی‌شده) و محور عمودی تعداد نمونه‌ها^۲ را نشان می‌دهد. سه دسته آموزش^۳، اعتبارسنجی^۴ و آزمون^۵ با رنگ‌های آبی، سبز و قرمز مشخص شده‌اند که توزیع خطاهای مدل را در این سه بخش نشان می‌دهد. خط نارنجی نشان‌دهنده خطای صفر است که نشان می‌دهد مدل در برخی موارد کاملاً دقیق عمل کرده است. توزیع داده‌ها شکل نرمال دارد، اما وجود مقدار کمی عدم تقارن ممکن است نشان‌دهنده خطای سیستماتیک یا سوگیری مدل باشد.



شکل ۴: میزان خطا شبکه عصبی

در این پژوهش، دو مدل رگرسیون خطی و شبکه عصبی مصنوعی برای پیش‌بینی عملکرد تحصیلی آینده و موفقیت در یادگیری شخصی‌سازی‌شده مورد ارزیابی قرار گرفتند. تحلیل داده‌ها با استفاده از ضریب تعیین و میانگین خطای مطلق نشان داد که شبکه عصبی مصنوعی در تمامی مراحل (آموزش، اعتبارسنجی و آزمون) عملکرد بهتری نسبت به مدل رگرسیون خطی دارد.

در مرحله آموزش، مقدار R^2 برای شبکه عصبی ۰,۹۰۰۷ و برای رگرسیون خطی ۰,۸۰ به دست آمد که نشان‌دهنده توانایی بالاتر شبکه عصبی در شناسایی روابط پیچیده میان متغیرها است. در مرحله اعتبارسنجی، مقدار R^2 در شبکه عصبی ۰,۹۴۰۶ و در رگرسیون خطی ۰,۷۸ بود که حاکی از تعمیم‌پذیری بهتر شبکه عصبی مصنوعی است. در مرحله آزمون،

^۱. Bins

^۲. Instances

^۳. Training

^۴. Validation

^۵. Test

مقدار R^2 برای شبکه عصبی ۰,۸۸۱۹ و برای رگرسیون خطی ۰,۷۵ بود که دقت بالاتر شبکه عصبی را در مواجهه با داده‌های جدید تأیید می‌کند. علاوه بر دقت، میزان میانگین خطای مطلق نیز نشان داد که شبکه عصبی خطای کمتری نسبت به رگرسیون خطی دارد. در مرحله آموزش، مقدار میانگین خطای مطلق برای شبکه عصبی ۰,۷۴ و برای رگرسیون خطی ۰,۸۴ بود. همچنین در مرحله آزمون، میانگین خطای مطلق برای شبکه عصبی ۰,۸۱ و برای رگرسیون خطی ۰,۸۹ گزارش شد که نشان می‌دهد مدل شبکه‌های عصبی مصنوعی در پیش‌بینی عملکرد تحصیلی دانشجویان دقت بیشتری دارد و تعمیم‌پذیری بالاتری را ارائه می‌دهد.

در مجموع، نتایج نشان داد که مدل شبکه عصبی مصنوعی، با قابلیت پردازش روابط غیرخطی، نسبت به رگرسیون خطی دقت بالاتری دارد و می‌تواند به‌طور مؤثرتری برای پیش‌بینی نیازهای آموزشی و بهینه‌سازی یادگیری شخصی‌سازی شده در آموزش عالی استفاده شود.

جدول ۳: مقایسه میزان دقت و خطا شبکه عصبی و رگرسیون خطی

معیار ارزیابی	رگرسیون خطی	شبکه عصبی
ضریب تعیین - (R^2) آموزش	۰,۸۰	۰,۹۰۰۷
ضریب تعیین - (R^2) اعتبارسنجی	۰,۷۸	۰,۹۴۰۶
ضریب تعیین - (R^2) آزمون	۰,۷۵	۰,۸۸۱۹
میانگین خطای مطلق - (MAE) آموزش	۰,۸۴	۰,۷۴
میانگین خطای مطلق - (MAE) آزمون	۰,۸۹	۰,۸۱

بحث و نتیجه‌گیری

یافته‌های پژوهش نشان داد که مدل شبکه عصبی مصنوعی عملکرد بهتری نسبت به رگرسیون خطی در پیش‌بینی عملکرد تحصیلی دانشجویان و موفقیت در یادگیری شخصی‌سازی شده دارد. در پاسخ به سؤال پژوهش که بین مدل شبکه عصبی مصنوعی و مدل رگرسیون خطی کدام یک دقت بیشتری در پیش‌بینی عملکرد تحصیلی دانشجویان دارد؛ نتایج حاکی از آن بود که مقدار ضریب تعیین در مرحله آزمون برای شبکه‌های عصبی مصنوعی برابر با ۰,۸۸ و برای رگرسیون خطی برابر با ۰,۷۵ است. این امر نشان می‌دهد که شبکه عصبی در تعمیم‌پذیری و شناسایی روابط پیچیده میان متغیرهای آموزشی عملکرد بهتری دارد. همچنین، میانگین خطای مطلق در تمامی مراحل برای مدل شبکه‌های عصبی مصنوعی کمتر از رگرسیون خطی بود، که بیانگر توانایی بالاتر این مدل در کاهش خطای پیش‌بینی و ارائه تحلیل‌های دقیق‌تر از عملکرد تحصیلی دانشجویان است.

نتایج این مطالعه با یافته‌های پژوهش‌های مطالعه (Bhardwaj et al., 2021) همخوانی قابل توجهی دارد که نشان داد مدل‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی مصنوعی، قادرند تعامل دانشجویان را در محیط‌های آموزشی مجازی با دقت بیشتری تحلیل کنند و تخمین‌های بهتری از پیشرفت تحصیلی ارائه دهند. همچنین با نتایج پژوهش (Ouyang et al., 2023) همخوانی دارد که تأیید کرده است ترکیب یادگیری ماشین و تحلیل‌های یادگیری تأثیر

قابل توجهی بر بهبود یادگیری شخصی سازی شده دارد. این پژوهش همسو با پژوهش (Luckin & Cukurova, 2019) نشان داد که استفاده از هوش مصنوعی در فرآیند یادگیری دیجیتال، به‌ویژه از طریق شبکه‌های عصبی، می‌تواند به افزایش کیفیت آموزش و کاهش میزان افت تحصیلی منجر شود. یافته‌های این پژوهش همچنین با یافته‌های پژوهش (Dawson et al., 2019) نیز همخوانی دارد که بر اهمیت کلان داده‌های آموزشی و استفاده از آن‌ها برای بهبود روش‌های پیش‌بینی عملکرد تحصیلی تأکید کرده است. علاوه بر این، (Bowden et al., 2021) در بررسی عوامل مؤثر بر تعامل دانشجویان و موفقیت تحصیلی نشان دادند که تحلیل‌های یادگیری عمیق می‌تواند درک بهتری از الگوهای رفتاری دانشجویان ارائه دهد و به بهینه‌سازی فرآیندهای آموزشی کمک کند که همسو با یافته‌های پژوهش حاضر است. نتایج این پژوهش همچنین با نتیجه‌ی پژوهش (Ahmadi et al., 1403) همسو می‌باشد که در پژوهش خود تأیید کردند یادگیری شخصی سازی شده مبتنی بر هوش مصنوعی با فواید و فرصت‌های زیادی برای برنامه‌ریزی آموزش عالی ایران از جمله ارتقای کیفیت در نظام آموزش عالی همراه است.

در تبیین این یافته‌ها می‌توان گفت این برتری ناشی از توانایی مدل شبکه عصبی مصنوعی در شناسایی روابط غیرخطی و پردازش داده‌های چندبعدی است که مدل‌های سنتی مانند رگرسیون خطی قادر به انجام آن نیستند. مقایسه شاخص‌های عملکردی این دو مدل نشان داد که شبکه عصبی مصنوعی در تمامی مراحل ارزیابی، دقت بالاتری دارد، میزان خطای پیش‌بینی آن کمتر است و قادر است الگوهای پیچیده‌تری را در داده‌های آموزشی شناسایی کند. نتایج نشان داد که شبکه عصبی در مرحله آزمون ضریب تعیین (R^2) معادل ۰,۸۸ را به دست آورد، درحالی‌که این مقدار برای مدل رگرسیون خطی ۰,۷۵ بود. همچنین، مقدار میانگین خطای مطلق برای شبکه‌های عصبی مصنوعی کمتر از مدل رگرسیون خطی ثبت شد که بیانگر دقت بالاتر این مدل در تحلیل و پیش‌بینی عملکرد تحصیلی است. این یافته‌ها تأکید می‌کنند که استفاده از مدل‌های یادگیری عمیق در برنامه‌ریزی آموزشی می‌تواند دقت تحلیل داده‌های آموزشی را افزایش داده و شخصی سازی مسیرهای یادگیری را به‌طور کارآمدتری بهینه‌سازی کند. علاوه بر این، بهره‌گیری از هوش مصنوعی در آموزش می‌تواند به کاهش نرخ افت تحصیلی، بهبود فرآیندهای یادگیری و ارتقای سطح موفقیت دانشجویان کمک کند. طراحی سیستم‌های توصیه‌گر آموزشی مبتنی بر شبکه‌های عصبی مصنوعی، می‌تواند مسیرهای یادگیری را بر اساس نیازهای فردی دانشجویان تنظیم کرده و شخصی سازی یادگیری را به سطح بالاتری ارتقا دهد. در مجموع، نتایج پژوهش حاضر نشان می‌دهد که شبکه‌های عصبی مصنوعی ابزارهای مؤثری در بهینه‌سازی نظام‌های آموزشی دیجیتال هستند و می‌توانند نقش مهمی در آینده آموزش عالی ایفا کنند. نوآوری این پژوهش در تأکید بر ادغام یادگیری ماشین با برنامه‌ریزی آموزشی و توسعه سیستم‌های تصمیم‌یار هوشمند است که می‌تواند کیفیت فرآیندهای آموزشی را در آموزش عالی ارتقا داده و کارآمدی برنامه‌ریزی تحصیلی را افزایش دهد.

با توجه به دقت بالای شبکه‌های عصبی مصنوعی در پیش‌بینی عملکرد تحصیلی، پیشنهاد می‌شود دانشگاه‌ها و مؤسسات آموزشی از شبکه‌های عصبی مصنوعی به‌عنوان ابزارهای تحلیل داده‌های آموزشی و پیش‌بینی عملکرد تحصیلی استفاده کنند. به‌ویژه، توسعه سامانه‌های هوشمند مبتنی بر شبکه‌های عصبی مصنوعی در سیستم‌های مدیریت یادگیری

می‌تواند به شناسایی سریع‌تر دانشجویان در معرض افت تحصیلی کمک کند و اقدامات اصلاحی لازم را برای آن‌ها فراهم آورد. با توجه به بهبود تعمیم‌پذیری شبکه‌های عصبی مصنوعی نسبت به رگرسیون خطی در تحلیل رفتارهای یادگیری، پیشنهاد می‌شود در برنامه‌ریزی آموزشی، از مدل‌های یادگیری عمیق برای تحلیل رفتار یادگیری دانشجویان استفاده شود. به این منظور، سامانه‌های آموزشی می‌توانند با بهره‌گیری از الگوریتم‌های شبکه‌های عصبی مصنوعی، مسیرهای آموزشی شخصی‌سازی شده‌ای را برای دانشجویان طراحی کرده و توصیه‌های تطبیقی ارائه دهند. همچنین با توجه به تأثیر مثبت شبکه‌های عصبی مصنوعی در کاهش نرخ افت تحصیلی، پیشنهاد می‌شود دانشگاه‌ها از سیستم‌های تحلیل یادگیری مبتنی بر شبکه عصبی برای پایش مستمر عملکرد تحصیلی دانشجویان استفاده کنند. این سیستم‌ها می‌توانند به‌طور خودکار، روندهای یادگیری دانشجویان را تحلیل کرده و در صورت مشاهده افت تحصیلی، به اساتید و مشاوران آموزشی هشدار دهند. در نهایت با توجه به اینکه استفاده از شبکه‌های عصبی مصنوعی به بهینه‌سازی فرآیند یادگیری شخصی‌سازی شده می‌انجامد، پیشنهاد می‌شود سیاست‌گذاران آموزشی، برنامه‌های درسی تطبیقی را بر اساس تحلیل‌های یادگیری ماشینی طراحی کنند. این برنامه‌ها می‌توانند به کمک هوش مصنوعی، محتواهای آموزشی را متناسب با سبک‌های یادگیری و نیازهای فردی دانشجویان تنظیم کنند و اثربخشی فرآیند یادگیری را افزایش دهند.

برای ارزیابی اطمینان یافته‌ها استفاده از روش‌هایی مانند bootstrap استفاده از روش‌های آماری تقویتی مانند Bootstrap می‌تواند بسیار مؤثر باشد. این روش با بازنمونه‌گیری تصادفی (با جای‌گذاری) از داده‌ها و تکرار چندین باره تحلیل، امکان برآورد دقیق‌تری از توزیع آماری ضرایب مدل و میزان خطا را فراهم می‌سازد. اگرچه در این پژوهش از روش‌های اعتبارسنجی همچون تفکیک مجموعه داده‌ها و اعتبارسنجی متقابل برای بررسی پایداری مدل استفاده شده است، به‌کارگیری تکنیک Bootstrap در مطالعات بعدی، به‌ویژه در تحلیل حساسیت و تخمین بازه‌های اطمینان برای مقادیر پیش‌بینی شده، می‌تواند به افزایش دقت و قابلیت تعمیم نتایج کمک کند.

- Ahmadi, S., Tahmasbzadeh, D., & Mir-Arab Razi, R. (2024). Analysis of opportunities and challenges of personalized learning based on artificial intelligence in higher education. *Journal Educational Planning Studies*, 13(26), 7-33. 10.22080 / eps.2025.28091.2292: doi. *Journal Educational Planning Studies* [in Persian].
- Alabbad, Y., Yildirim, E., & Demir, I. (2022). Flood mitigation data analytics and decision support framework: Iowa Middle Cedar Watershed case study. *Science of The Total Environment*, 814, 152768. <https://doi.org/10.1016/j.scitotenv.2021.152768>.
- Alam, A. (2021, December). Should robots replace teachers? Mobilisation of AI and learning analytics in education. In *2021 International Conference on Advances in Computing, Communication, and Control (ICAC3)* (pp. 1-12). IEEE. <https://doi.org/10.1109/ICAC353642.2021.9697300>.
- Alkhalaf, S., Drew, S., & Alhussain, T. (2012). Assessing the impact of e-learning systems on learners: A survey study in the KSA. *Procedia-Social and Behavioral Sciences*, 47, 98–104.
- Baker, R. S., Corbett, A. T., & Aleven, V. (2008). Improving contextual models of guessing and slipping with a truncated training
- Bhardwaj, P., Gupta, P. K., Panwar, H., Siddiqui, M. K., Morales-Menendez, R., & Bhaik, A. (2021). Application of deep learning on student engagement in e-learning environments. *Computers & Electrical Engineering*, 93, 107277. <https://doi.org/10.1016/j.compeleceng.2021.107277>
- Bloom, B. S., & Krathwohl, D. R. (2020). *Taxonomy of educational objectives: The classification of educational goals. Book 1, Cognitive domain*. Longman.
- Bowden, J. L. H., Tickle, L., & Naumann, K. (2021). The four pillars of tertiary student engagement and success: A holistic measurement approach. *Studies in Higher Education*, 46(6), 1207-1224. <https://eric.ed.gov/?id=EJ1299420>
- Casalino, G., Grilli, L., Limone, P., Santoro, D., & Schicchi, D. (2021). Deep learning for knowledge tracing in learning analytics: an overview. *TeleXbe*.
- Dabic, T. (2016). The Bloom's taxonomy revisited in the context of online tools. In *Sinteza 2016-International Scientific Conference on ICT and E-Business Related Research* (pp. 315-320). Singidunum University
- Dawson, S., Joksimovic, S., Poquet, O., & Siemens, G. (2019). Increasing the impact of learning analytics. In *Proceedings of the Ninth International Conference on Learning Analytics & Knowledge (LAK'19)*. ACM. <https://doi.org/10.1145/3303772.3303784>
- Felder, R., & Silverman, L. (1988). Learning and teaching styles in engineering education. *Engineering Education*, 78(7), 674-681. <http://localhost:8080/xmlui/handle/1/297>
- Gašević, D., Kovanović, V., & Joksimović, S. (2017). Piecing the learning analytics puzzle: A consolidated model of a field of research and practice. *Learning: Research and Practice*, 3(1), 63-78.
- Goldberg, P., Sümer, Ö., Stürmer, K., Wagner, W., Göllner, R., Gerjets, P., & Trautwein, U. (2021). Attentive or not? Toward a machine learning approach to assessing students' visible engagement in classroom instruction. *Educational Psychology Review*, 33, 27-49. <https://doi.org/10.1007/s10648-019-09514-z>
- Hamdi-Nasab, S., & Rahimi, S. (2024). The barriers and challenges of implementing artificial intelligence in higher education systems. *Journal Educational Planning Studies*, 13(26), 57–73. <https://doi.org/10.22080/eps.2025.28149.2295> [in Persian].
- Holmes, Wayne; Bialik, Maya and Fadel, Charles (2019). *Artificial Intelligence In Education: Promises and Implications for Teaching and Learning*. Boston, MA: Center for Curriculum Redesign.URL: <http://udaeducation.com/wp-content/uploads/2019/05...>
- Luckin, R., & Cukurova, M. (2019). Designing educational technologies in the age of AI: A learning sciences-driven approach. *British Journal of Educational Technology*, 50(6), 2824-2838. <https://doi.org/10.1111/bjet.12861>
- Makhambetova, A., Zhiyenbayeva, N., & Ergesheva, E. (2021). Personalized learning strategy as a tool to improve academic performance and motivation of students. *International Journal of Web-Based Learning and Teaching Technologies (IJWLTT)*, 16(6), 1-17. DOI:10.4018/IJWLTT.286743.
- Nistor, N., & Hernández-García, A. (2018). What types of data are used in learning analytics? An overview of six cases. *Computers in Human Behavior*, 89, 335-338. <https://doi.org/10.1016/j.chb.2018.07.038>
- Nkomo, L. M., Daniel, B. K., & Butson, R. J. (2021). Synthesis of student engagement with digital technologies: A systematic review of the literature. *International Journal of Educational Technology in Higher Education*, 18, 1-26. <https://link.springer.com/article/10.1186/s41239-021-00270-1>
- Ouyang, F., Wu, M., Zheng, L., Zhang, L., & Jiao, P. (2023). Integration of artificial intelligence performance prediction and learning analytics to improve student learning in online engineering courses. *International Journal of Educational Technology in Higher Education*, 20(1), 1-23. <https://doi.org/10.1186/s41239-022-00372-4>
- Pourjamshidi, M., & Mozaffari, O. (2024). Use of artificial intelligence technologies in STEAM educational program. *Journal Educational Planning Studies*, 13(26), 34–56. <https://doi.org/10.22080/eps.2025.28359.2303> [in Persian].
- ShariatPanahi, M. (2022). Analysis of the impact of artificial neural networks in predicting students' academic success. *Journal of Research and Innovation in Education and Development*, 2(2), 1-9. <https://jsied.org/index.php/jsied/article/view/32> [in Persian].
- Sit, M., Langel, R. J., Thompson, D., Cwiertny, D. M., & Demir, I. (2021). Web-based data analytics framework for well forecasting and groundwater quality. *Science of the Total Environment*, 761, 144121. <https://doi.org/10.1016/j.scitotenv.2020.144121>

- Smith, P., Powers, E., Anderson, H., Dellinger, J. T., & Siemens, G. (2022). Broadening the NLP agenda in learning analytics for the age of AI. *Companion Proceedings of the 12th International Conference on Learning Analytics & Knowledge (LAK'22)*, 182.
- Xu, H., Demir, I., Koylu, C., & Muste, M. (2019). A web-based geovisual analytics platform for identifying potential contributors to culvert sedimentation. *Science of the Total Environment*, 692, 806-817 <https://doi.org/10.1016/j.scitotenv.2019.07.157>
- Yang, Y. (2021). Does greater engagement in online general education courses lead to better academic performance? Evidence from Chinese university students. *Open Journal of Social Sciences*, 9(6), 298-315. <https://doi.org/10.4236/jss.2021.96022>
- Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education. *International Journal of Educational Technology in Higher Education*, 16(1), 39.

آماده به انتشار