



A Systematic Review of the Application of the Decision Tree Algorithm in Learning Personalization in Higher Education: With a Look at Potential Applications in the Field of Curriculum Planning

Naima Asghari*, Javad Hatami**, Farhad Seraji***, Esmaeil Azimi Yancheshmeh****

* PhD Student, Department of Educational Sciences, Faculty of Humanities, Tarbiat Modares University.
Email: asghari.najma13886@gmail.com

** Full Professor, Department of Educational Sciences, Faculty of Humanities, Tarbiat Modares University (Corresponding Author). Email: hatami52@gmail.com

*** Full Professor, Department of Educational Sciences and Psychology, University of Tehran.
Email: fseraji@ut.ac.ir

**** Assistant Professor, Department of Educational Sciences, Faculty of Humanities, Tarbiat Modares University.
Email: e.azimi@modares.ac.ir

Article Info

Abstract

Article type:

Research Article

Key words: Learning personalization, higher education, machine learning, decision tree, curriculum planning.

Article history:

Received : 16 June 2025

Accepted : 13 October 2025

The purpose of this study was to systematically review the research conducted on the application of the decision tree algorithm in the personalization of electronic learning in higher education. Given the importance of electronic learning environments in overcoming temporal and spatial limitations and increasing educational efficiency, intelligent learning technologies for adapting education to the individual needs of students have been the subject of much research in recent years. In this article, using the PRISMA protocol, 15 scientific studies (articles and theses) out of 84 initial studies, within the time range of 2015 to 2025, were identified and analyzed. The extracted data included information related to the objectives, type of data, and the process of applying the decision tree algorithm. The analysis of this data was carried out using a comparative approach to examine different methods of implementing the algorithm in different areas of electronic learning. To evaluate the quality of the studies, a descriptive approach based on transparency and qualitative validity was used, which included examining the transparency of objectives, data collection methods, data analysis, and results. The findings showed that the decision tree algorithm has applications in areas such as predicting academic performance, personalizing learning paths, supporting educational decision-making, developing recommender systems, and optimizing learning processes. These studies, by collecting diverse data including cognitive, academic, educational, social, and interactional characteristics, have built and trained decision tree models. With a focus on the field of curriculum planning, this study shows that the decision tree algorithm, as an interpretable and powerful method in machine learning, can facilitate the personalization of students' learning paths based on individual characteristics and needs.

Cite this Article:

N.Asghari, J.Hatami, F.Seraji, E.Azimi Yancheshmeh (2025) A Systematic Review of the Application of the Decision Tree Algorithm in Learning Personalization in Higher Education: With a Look at Potential Applications in the Field of Curriculum Planning. Journal of Higher Education Curriculum Studies, *16*(32), 7–32. <https://doi.org/10.22034/hecs.2025.530632.2017>



© 2016 by Iranian Curriculum Association Press Publisher:

Iranian Curriculum Association Press

DOI: <https://doi.org/10.22034//hecs.2025.530632.2017>

Extended Abstract

Introduction

Electronic learning environments, due to their efficiency and ability to overcome temporal and spatial limitations, have become an unavoidable choice in higher education. However, effective management of students' learning in these environments requires the use of intelligent and data-driven methods (Zhao & Li, 2023). Users of these environments have obvious differences in personality traits, prior knowledge, learning styles, and cognitive abilities, and these differences necessitate the personalization of learning. Personalization of learning means adapting educational content, methods, and paths to the individual needs and characteristics of each learner. In this regard, learning technologies and machine learning algorithms, as powerful tools, can help personalize learning. One of the most widely used machine learning algorithms in this field is the decision tree algorithm.

Decision tree algorithms, due to features such as the possibility of designing targeted educational interventions, providing adaptive feedback, optimizing course materials, appropriate accuracy, interpretability, high processing speed, and the ability to manage numerical data and classification, are considered one of the most popular machine learning methods in higher education and learning personalization (Sun, 2024; Matzavela & Alepis, 2021; Zhao et al., 2017).

Recent systematic and analytical reviews show that the decision tree algorithm has diverse applications in higher education and learning personalization. For example, Mienye and Jere (2024) have reviewed the main concepts, algorithms, the evolution from early stages to powerful hybrid algorithms, and numerous applications in areas such as medical diagnosis and fraud detection. Cañete-Sifuentes, Monroy, and Medina-Pérez (2021), in examining multivariate decision trees, have proposed the possibility of identifying superior algorithm groups for different types of databases. Jena and Dehuri (2020) have analyzed current and widely used decision tree techniques in classification and regression. Blockeel et al. (2023) have also traced the evolution of research related to decision trees in data science and machine learning and examined the strengths and weaknesses of the algorithms.

Experimental studies also show that the decision tree algorithm has been effectively used in predicting academic performance, personalizing students' learning paths, improving educational decision-making, and designing recommender systems. For example, a systematic review by Trujillo, Pozo, and Suntaxi (2025) in the field of career recommendations in higher education showed that models based on random forests,

support vector machines, and neural networks, using academic data, interests, and demographic characteristics, improve the accuracy and personalization of recommendations and play an effective role in designing educational paths appropriate to students' needs. Barnes, Conrad, and Demps (2024) examined the ability of decision tree models to identify factors affecting student graduation and design targeted support policies. Orji and Vassileva (2022) used decision trees to predict academic performance and study strategies.

However, existing studies also have limitations; including the lack of a comprehensive systematic review of the application of decision trees in learning personalization, the absence of longitudinal data to examine long-term effects, the lack of access to open databases, and the limited diversity of geographical and cultural sources. Therefore, a systematic review of research and analysis of the practical applications of decision trees, especially in the context of higher education and with a focus on learning personalization, is necessary to fill existing gaps and provide more effective and scientific solutions for designing intelligent learning systems. The present study aims to systematically analyze scientific research in the field of the application of decision trees in personalizing electronic learning in higher education, examining the objectives, methods, type of data, and potential applications of this algorithm, and examines its application for designing personalized learning paths in the field of curriculum planning.

Methodology

The present study was conducted using a systematic review method. A systematic review attempts to collect and analyze all existing empirical evidence that meets predetermined criteria to answer a specific research question. This method, using transparent and systematic processes, minimizes bias and provides reliable results for inference and decision-making (Higgins, Thomas, Chandler, Cumpston, Li, Page, & Welch, 2020). In this study, the PRISMA protocol (2020) was used, which specifies the objectives, methods, information banks, keywords, screening process, inclusion and exclusion criteria, data extraction, and presentation of results. This protocol increases the quality, repeatability, and transparency of scientific reviews (Frost, Hróbjartsson, & Nejstgaard, 2022).

The study population of this research included studies that addressed the personalization of learning in the field of electronic learning in higher education using decision tree and machine learning algorithms. The information banks of Scopus, Web of Science, ScienceDirect, Google Scholar, IEEE Xplore, SpringerLink, ResearchGate, and IranDoc were searched to access related studies. In the search, a

purposeful combination of keywords "Decision Tree" and ("Personalized Learning" or "Personalized Education") and ("Higher Education" or "Curriculum Development" or "Curriculum Studies") and their Persian equivalents was used. The screening tool for articles was the Rayyan software. To evaluate the quality of the studies, a descriptive approach based on transparency and qualitative validity was used. In this approach, each study was examined based on four main criteria: 1. Transparency of objectives and research question: Has the purpose and question of the study been clearly stated? 2. Transparency of data collection method: Have the data and samples under study been accurately described? 3. Transparency of data analysis: Is the data analysis method clear and logical and consistent with the research objective? 4. Transparency of results and inferences: Are the results of the study clearly presented and are the inferences consistent with the data?

Given the nature of humanities and the limitations of data in the application of the decision tree algorithm in electronic learning environments, some criteria related to the precise control of confounding factors and the use of objective and standard criteria were not applicable (Lincoln & Guba, 1985). Therefore, a descriptive approach was used to evaluate the quality of the studies.

The inclusion criteria were: studies that specifically used the decision tree algorithm for personalizing learning in higher education; articles and theses published in peer-reviewed sources; studies published between 2015 and 2025. Also, the exclusion criteria were: lack of direct use of the algorithm; studies with unspecified research methods; sources published in low-quality journals (Q4); non-English or non-Persian research; studies in which the algorithm was used in courses other than higher education.

Using these criteria, 84 initial studies were identified. After examining the title and abstract, full-text evaluation, and quality evaluation, 15 final studies were selected for analysis. The process of selecting and screening studies is presented in Figure 2 of the original document.

Findings

The content analysis of the selected articles included the research objective, type and source of data used, method of using the decision tree, and key results. The results are presented in Table 1 of the original document.

In response to the first question of the research, i.e., the most prominent objectives of studies related to the application of the decision tree algorithm in the field of electronic learning in higher education, the findings

showed that the studies conducted on the application of the decision tree algorithm in the field of electronic learning in higher education have mainly pursued multiple objectives that can be categorized into three main axes:

First axis: Predicting student academic performance and personalizing education. One of the most prominent approaches in these studies is the use of decision trees to develop models that have the ability to predict students' academic performance. These studies have attempted to identify variables affecting success or academic failure and classify students based on their level of ability, study style, or learning pattern. Studies by Asif et al., 2017; Orji & Vassileva, 2022; Manzavela & Alepis, 2021; Akramifar, 2023; Salari et al., 2024; Haghghi, 2023; Zhang et al., 2022 are among these. Also, studies such as Barnes et al., 2024; Shoaib et al., 2024; Thakaeng et al., 2025; Chen & Lin, 2023, focusing on identifying determining factors in academic success, have provided the ground for designing personalized education.

Second axis: Supporting educational decision-making and developing recommender systems. Another group of studies have examined the application of decision trees in designing educational decision support tools. These tools include recommender systems for course selection (Delahoz-Domínguez & Hijón-Neira, 2024), providing appropriate educational advice, even recommending suitable learning strategies based on students' individual characteristics (Shoaib et al., 2024; Park & Dooris, 2020; Khalaf Hamoud et al., 2018). Such studies indicate the potential of decision trees in helping to improve the quality of educational decisions at individual and organizational levels.

Third axis: Educational data management and optimization of learning processes. The third group of studies, by using decision trees for managing large educational data, have focused on the role of this algorithm, especially in feature selection or as a wrapper in improving the accuracy of decision-making (Park & Dooris, 2020; Khalaf Hamoud et al., 2018). The results of this group of studies show that using decision trees can provide more accurate analysis of learner behavior and ultimately lead to the optimization of educational processes in electronic learning environments.

In total, the applications of decision trees in the field of electronic learning in higher education can be presented in the form of Figure 2 of the original document.

In response to the second question of the research, the method of applying decision tree algorithms in the field of electronic learning in higher education has mainly been in the form of a multi-stage framework based on the cycle of data mining and machine learning. This process can be summarized in several stages as shown in Figure 3 of the original document.

In the first step, most studies collected educational data from various sources. Before entering the modeling stage, this data was evaluated and cleaned in terms of quality, and processes such as normalization, recoding of variables, and in some cases, combination with synthetic data to resolve class imbalance were applied to them. In this environment, tools and libraries such as NumPy and Pandas for execution, Python, and Weka and RapidMiner software have been widely used. These tools have played a key role in removing outliers, normalizing values, reclassifying variables, and also creating derived features to improve model performance.

In the second step, the modeling process was carried out using a range of decision tree algorithms. The most common algorithms used in this field include ID3, C4.5, CART, Random Forest, XGBoost, REPTree, J48, and RandomTree. At this stage, the training data was provided as input to the model, and the tree structure was formed based on criteria such as Gini Index, Information Gain, or Entropy Reduction. Each node of the tree represents a key influential variable, and each leaf is equivalent to a final output in the form of classification or prediction. To implement these algorithms, tools and libraries such as Scikit-learn in the Python environment and Weka and RapidMiner software have been widely used.

In the third stage, after training the model, its performance was evaluated using various validation approaches including k-fold cross-validation, train/test splitting of data, and in some hold-out validation. To measure model efficiency, indicators such as Accuracy, Recall, F1-score, and also the Confusion Matrix have been used. In addition, in part of the studies, decision tree algorithms have been compared with other machine learning models such as KNN, logistic regression, and even neural networks to select the most accurate and optimal model for supporting educational applications.

In the fourth stage, researchers, by analyzing the final structure of the decision tree, extracted key and influential variables on academic success or failure and used them in educational decisions and interventions. This stage highlights the interpretability role of the algorithm, because identifying determining indicators provides the possibility of designing targeted educational policies. For example, in many models, factors such as the amount of attendance in online classes, mid-term grades, academic background, and the level of student interaction with the content of learning management systems (LMS) have been identified as key variables. The use of these indicators has not only been effective in improving the quality of predictions but has also provided the ground for developing personalized educational strategies and improving the learning process in electronic environments.

In the fifth stage, the decision tree algorithm has been used as the main core of recommender systems. These systems, by analyzing students' individual profiles, provide appropriate suggestions such as choosing a field of study, matching with an educational or career advisor, or determining learning strategies appropriate to individual characteristics. In some studies, to improve the accuracy and efficiency of these systems, combined approaches have been used, such as weighting decision trees or combining several of them; in a way that the learner's prediction ability and personalization capability have been significantly improved.

In total, in response to the second question of the research, it can be said that the application of decision tree algorithms in the context of electronic learning in higher education is a multi-stage process that includes collecting educational data from various sources, performing necessary pre-processing, building and training decision tree models, evaluating performance with quantitative indicators, and finally interpretable analysis of outputs. This systematic approach provides the possibility of identifying hidden patterns, designing targeted educational interventions, and developing personalized recommender systems.

In response to the third question of the research; the type and source of machine learning data in the application of decision tree algorithms in the field of electronic learning in higher education has been a wide range of structured and semi-structured data for training decision tree-based models, collected from various online and local sources. This data has mainly been obtained from the main sources: educational institutions, academic records, standard test data; teaching evaluation and quality of education systems (SET Tools); online and structured questionnaires (psychometric, LimeSurvey, Google Forms); learning management systems (LMS: Learning Management System); student management systems (SMS: Student Management System), and/or from combined and integrated databases. In some studies, synthetic or balanced data have also been generated through simulation techniques or a combination of real data and simulated data, especially when data classes have been unbalanced.

Also, the data have been extracted in several distinct types: demographic and individual data (age, gender, ethnicity, generation, marital status, occupation, family income, birth order in the family, parents' education, religion, financial status, and eligibility for scholarships); academic performance and educational data (course grades, specialized courses, practical; test scores; the level of mastery of basic skills; special courses); behavioral and learning interaction data (amount of use of the platform, login to the system, time of activity in the online environment, amount of participation in discussions, downloading resources, participation in online tests, pattern of sending assignments and interaction with course content); psycho-cognitive data (self-efficacy, motivation, stress, anxiety, interest in internal and external learning, learning

styles, self-regulation, self-efficacy, need for belonging, satisfaction with counseling, academic expectations, interaction with professors and advisors); data related to course and instructor characteristics (instructor's experience, teachability, teaching method; course type; in-person or online, practical or theoretical; factors outside the instructor's control (such as mandatory content with a specific structure)); socio-economic and educational background data (type of university, level of education and parents' occupation, economic status, geographical area, place of residence, city skills and understanding). The types of data used in these studies are shown in Figure 4 of the original document.

In response to the fourth question of the research; the main findings regarding the use of decision tree algorithms in the field of electronic learning in higher education, the analysis of the studies under review in this research showed that decision tree algorithms, especially their advanced versions such as J48, C4.5, Random Forest, and XGBoost, have played an important role in analyzing educational data and improving the quality of educational decision-making. The key findings of these studies can be categorized in the following axes:

- High accuracy in predicting and classifying students: Decision tree models have been able to predict academic performance, graduation, or dropout of students with very high accuracy (up to 94.9% in some studies).
- Application in designing adaptive and intelligent educational tools: The decision tree algorithm has been used in the development of tools that can identify students' learning styles and suggest appropriate educational strategies. These tools have provided the ground for increasing student participation and satisfaction.
- High interpretability in analyzing educational data: Decision trees have a high ability to display relationships between variables in a visual and transparent manner and provide more accurate interpretations of influential factors than traditional statistical methods.
- Predicting career path and probability of employment: The decision tree algorithm has been effective in predicting the probability of employment based on skills and academic performance in some studies. These findings have helped to better match education with labor market needs.
- Relative superiority compared to other algorithms: In many studies, decision tree models have performed better than other algorithms such as KNN, SVM in terms of performance indicators such as accuracy, recall, precision, F1 score, and Kappa coefficient.

Finally, in response to the final question of the research, it can be said that the decision tree algorithm in the field of electronic learning has potential capabilities that can be considered as one of the powerful and interpretable machine learning methods in the field of learning personalization. This algorithm can have multiple applications in the field of curriculum planning. These applications are at the level of analysis and design of curricula and also at the level of implementation and evaluation of curricula. Personalization of students' learning paths based on individual characteristics, academic, psychological, and personality characteristics of students such as learning style, motivation, prior knowledge, interaction with educational content, and designing adaptive modules in the curriculum are among the cases that can be considered. In the current situation of curriculum planning in different specialized fields, professional developments have been remarkable and the need to pay attention to specialized learning appropriate to the field, characteristics, and needs of individuals is felt. Curriculum planning specialists have no choice but to pay attention to the diverse needs of learners with different specializations, and with the description and characteristics of each person, the ground for turning into specialized and specific tasks should be provided (Fathi Vajargah, & Sharifzadeh, 2013; Fathi Vajargah, 2021).

Discussion and Conclusion

In general, decision tree algorithms, due to features such as high interpretability, acceptable prediction accuracy, and widespread use in recommendation and classification, have become effective tools in electronic learning in higher education. These algorithms have not only been able to improve data-driven decision-making but also pave the way for personalized learning. However, some limitations such as overfitting, dependence on data quality, and the need for precise parameter tuning have also been reported. Therefore, based on the scientific evidence obtained from the analysis of the studies, it can be concluded that the application of the decision tree algorithm in the field of electronic learning in higher education can play a useful and effective role in personalizing learning and predicting student performance. Also, due to the flexibility of this algorithm in managing educational data, it is possible to benefit from it in optimizing learning processes and providing personalized educational recommendations. According to the results, the following suggestions are made:

- Designing recommender systems using machine learning algorithms including decision trees for course selection and learning activities so that these systems, based on students' academic records, suggest appropriate assignments and prevent inappropriate selections. Also, the "curriculum planning" process should facilitate personalization for students in virtual environments.

- Using the capabilities of the decision tree algorithm in predicting the performance of learners and providing targeted support to identify students at risk (such as grade point average, dropout, lack of participation) in curriculum planning and the possibility of timely educational intervention for curriculum planners and instructors and optimizing the feedback process and academic support.
- Supporting the use of data mining techniques in lesson and syllabus design and using the extensive data obtained from the performance, cognitive, and psychological characteristics of students in analyzing and improving the lesson structure, providing optional units, and presenting course discussions. This type of planning based on evidence responds to the real needs of students in electronic learning and paves the way.

مرور نظام‌مند کاربرد الگوریتم درخت تصمیم در شخصی‌سازی یادگیری در آموزش عالی: با نگاهی به کاربردهای بالقوه در رشته برنامه‌ریزی درسی

نجم‌ا صغری *، جواد حاتمی **، فرهاد سراجی ***، اسماعیل عظیمی یانچشمه ****

* دانشجوی دکتری، گروه علوم تربیتی، دانشکده علوم انسانی، دانشگاه تربیت مدرس. رایانامه:

asghari.najma13886@gmail.com

** استاد تمام، گروه علوم تربیتی، دانشکده علوم انسانی، دانشگاه تربیت مدرس (نویسنده مسئول). رایانامه:

hatami52@gmail.com

*** استاد تمام، گروه علوم تربیتی و روانشناسی، دانشگاه تهران. رایانامه: fseraji@ut.ac.ir

**** استادیار، گروه علوم تربیتی، دانشکده علوم انسانی، دانشگاه تربیت مدرس. رایانامه: e.azimi@modares.ac.ir

چکیده

اطلاعات مقاله

هدف این مطالعه، مرور نظام‌مند پژوهش‌های انجام‌شده پیرامون کاربرد الگوریتم درخت تصمیم در شخصی‌سازی یادگیری الکترونیکی در آموزش عالی است. با توجه به اهمیت محیط‌های یادگیری الکترونیکی در غلبه بر محدودیت‌های زمانی و مکانی و افزایش کارآمدی آموزش، فناوری‌های یادگیری هوشمند برای انطباق آموزش با نیازهای فردی دانشجویان موضوع پژوهش‌های بسیاری در سال‌های اخیر بوده است. در این مقاله، با بهره‌گیری از پروتکل PRISMA، ۱۵ مطالعه علمی (مقالات و پایان‌نامه‌ها) از میان ۸۴ مطالعه اولیه، در بازه زمانی ۲۰۱۵ تا ۲۰۲۵ شناسایی و تحلیل شدند. داده‌های استخراج‌شده شامل اطلاعات مربوط به اهداف، نوع داده‌ها و فرایند به‌کارگیری الگوریتم درخت تصمیم بود. تحلیل این داده‌ها با استفاده از رویکرد مقایسه‌ای انجام شد تا روش‌های مختلف پیاده‌سازی الگوریتم در حوزه‌های مختلف یادگیری الکترونیکی بررسی شود. برای ارزیابی کیفیت مطالعات، از رویکرد توصیفی مبتنی بر شفافیت و اعتبار کیفی استفاده شد که شامل بررسی شفافیت اهداف، روش جمع‌آوری داده‌ها، تحلیل داده‌ها و نتایج بود. یافته‌ها نشان داد که الگوریتم درخت تصمیم در حوزه‌هایی مانند پیش‌بینی عملکرد تحصیلی، شخصی‌سازی مسیرهای یادگیری، پشتیبانی از تصمیم‌گیری آموزشی، توسعه سیستم‌های توصیه‌گر و بهینه‌سازی فرایندهای یادگیری کاربرد دارد. این پژوهش‌ها با جمع‌آوری داده‌های متنوع شامل ویژگی‌های جمعیت‌شناختی، تحصیلی، آموزشی، اجتماعی و تعاملی، مدل‌های درخت تصمیم را ساخته و آموزش داده‌اند. با تمرکز بر رشته برنامه‌ریزی درسی، این مطالعه نشان می‌دهد که الگوریتم درخت تصمیم، به‌عنوان روشی تفسیرپذیر و قدرتمند در یادگیری ماشین، می‌تواند شخصی‌سازی مسیرهای یادگیری دانشجویان را بر اساس ویژگی‌ها و نیازهای فردی تسهیل کند.

نوع مقاله:

علمی-پژوهشی

واژگان کلیدی:

شخصی‌سازی یادگیری، آموزش عالی، یادگیری ماشین، درخت تصمیم، برنامه‌ریزی درسی.

تاریخچه مقاله:

تاریخ دریافت: ۱۴۰۴/۰۳/۲۶

تاریخ پذیرش: ۱۴۰۴/۰۷/۲۱

استناد به این مقاله:

نجم‌ا صغری، جواد حاتمی، فرهاد سراجی، اسماعیل عظیمی یانچشمه (۱۴۰۴). مرور نظام‌مند کاربرد الگوریتم درخت تصمیم در شخصی‌سازی یادگیری در آموزش عالی: با نگاهی به کاربردهای بالقوه در رشته برنامه‌ریزی درسی. *دوفصلنامه مطالعات برنامه درسی آموزش عالی*. انجمن مطالعات برنامه درسی ایران؛ ۱۶ (۳۲)، ۷-۳۲.

doi: 10.22034/hecs.2025.530632.2017/



© انجمن مطالعات برنامه درسی ایران

ناشر: انجمن مطالعات برنامه درسی ایران

مقدمه

محیط‌های یادگیری الکترونیکی به دلیل کارآمدی و توانایی غلبه بر محدودیت‌های زمانی و مکانی، به یک انتخاب اجتناب‌ناپذیر در آموزش عالی تبدیل شده‌اند. با این حال، مدیریت مؤثر یادگیری دانشجویان در این محیط‌ها نیازمند استفاده از روش‌های هوشمندانه و داده‌محور است (Zhao & Li, 2023). کاربران این محیط‌ها دارای تفاوت‌های آشکار در ویژگی‌های شخصیتی، پیشینه فرهنگی، توانایی‌ها و ترجیحات یادگیری هستند (Zhou et al., 2017). بنابراین طراحی محیط‌های یادگیری که نیازهای دانشجویان را مدنظر قرار دهد، امری ضروری در آموزش عالی است (Zhou et al., 2017; Sáiz-Manzanares et al., 2019; Shoaib et al., 2024; Manoharan, 2024).

شخصی‌سازی یادگیری با بهره‌گیری از الگوریتم‌های هوش مصنوعی و یادگیری ماشین، رویکردی موثر برای پاسخگویی به نیازهای متفاوت دانشجویان است. در این نوع یادگیری، مسیرهای یادگیری با ادغام فناوری و تحلیل داده، مطابق با اهداف و ویژگی‌های هر دانشجو پیش‌بینی و توصیه می‌شوند و منابع و بازخوردهای لازم برای دستیابی به موفقیت تحصیلی ارائه می‌گردد (Manoharan, 2024). علاوه بر این، رویکرد مبتنی بر طبقه‌بندی، عدالت آموزشی را تقویت کرده و به دانشجویان نیازمند حمایت بیشتر امکان بهره‌مندی هدفمند و شخصی‌سازی شده می‌دهد (Chen & Lin, 2023). در میان تکنیک‌های یادگیری ماشین، الگوریتم درخت تصمیم به دلیل دقت بالا، تفسیرپذیری، سرعت پردازش و توانایی مدیریت داده‌های عددی و طبقه‌بندی، به عنوان یکی از محبوب‌ترین روش‌ها شناخته می‌شود (Zhou et al., 2017; Matzavela & Alepis, 2021). این الگوریتم با استفاده از رویکرد تقسیم و غلبه، داده‌ها را بر اساس ویژگی‌های کلیدی طبقه‌بندی می‌کند و پس از آموزش، قادر به پیش‌بینی داده‌های جدید است. الگوریتم‌های کلاسیک شامل ID3، C4.5 و CART بوده و مراحل اصلی آن شامل ساخت درخت (Tree Building) و بهینه‌سازی (Tree Pruning) است (Chen & Lin, 2023; Jiang, 2021).

با وجود اهمیت و کاربردهای گسترده درخت تصمیم در یادگیری ماشین و علوم داده، مرور نظام‌مند و جامع از کاربرد این الگوریتم در شخصی‌سازی یادگیری در آموزش عالی، به ویژه در رابطه با داده‌های واقعی و تنوع جمعیت دانشجویان، محدود است. پژوهش حاضر با هدف پر کردن این خلا، به تحلیل نظام‌مند ۱۵ مطالعه علمی بین سال‌های ۲۰۱۵ تا ۲۰۲۵ می‌پردازد تا اهداف، روش‌شناسی و نوع داده‌های استفاده‌شده در کاربردهای الگوریتم درخت تصمیم بررسی شود. همچنین ظرفیت‌های بالقوه این الگوریتم در رشته برنامه‌ریزی درسی، به ویژه برای طراحی برنامه‌های شخصی‌سازی شده و پیشنهاد مسیر یادگیری فردی، مورد بحث قرار می‌گیرد.

پرسش‌های پژوهش:

۱. برجسته‌ترین اهداف مطالعات مرتبط با کاربرد الگوریتم درخت تصمیم در یادگیری الکترونیکی چه بوده است؟
۲. نحوه کاربردهای الگوریتم درخت تصمیم در حوزه یادگیری الکترونیکی چگونه بوده است؟
۳. از چه نوع داده‌هایی برای آموزش مدل درخت تصمیم در حوزه یادگیری الکترونیکی استفاده شده است؟
۴. یافته‌های اصلی پژوهش‌ها در کاربردهای الگوریتم درخت تصمیم در حوزه یادگیری الکترونیکی چه بوده است؟
۵. کاربردهای بالقوه الگوریتم درخت تصمیم در رشته برنامه‌ریزی درسی چیست؟

پیشینه پژوهش

الگوریتم‌های درخت تصمیم به دلیل ویژگی‌هایی مانند امکان طراحی مداخلات آموزشی هدفمند، ارائه بازخورد تطبیقی، بهینه‌سازی مواد درسی، دقت مناسب، تفسیرپذیری، سرعت پردازش بالا و توانایی مدیریت داده‌های عددی و طبقه‌بندی، یکی از محبوب‌ترین روش‌های یادگیری ماشین در حوزه آموزش عالی و شخصی‌سازی یادگیری محسوب می‌شوند (Sun, 2024; Zhou et al., 2017; Matzavela & Alepis, 2021).

مرورهای نظام‌مند و تحلیلی اخیر نشان می‌دهند که الگوریتم درخت تصمیم کاربردهای متنوعی در آموزش عالی و شخصی‌سازی یادگیری داشته است. به عنوان نمونه Mienye & Jere (2024) مفاهیم اصلی، الگوریتم‌ها، سیر تکامل از مراحل اولیه تا الگوریتم‌های ترکیبی قدرتمند و کاربردهای متعدد در حوزه‌هایی مانند تشخیص پزشکی و شناسایی تقلب را مرور کرده‌اند. Cañete-Sifuentes et al. (2021) در بررسی درخت‌های تصمیم چندمتغیره، امکان شناسایی گروه‌های الگوریتمی برتر برای انواع مختلف پایگاه داده را مطرح کرده‌اند. Jena & Dehuri (2020) تکنیک‌های روز و پرکاربرد درخت تصمیم را در طبقه‌بندی و رگرسیون تحلیل کرده‌اند. Blockeel et al. (2023) نیز تکامل پژوهش‌های مرتبط با درخت تصمیم در علم داده و یادگیری ماشین را ترسیم کرده و نقاط قوت و ضعف الگوریتم‌ها را بررسی کرده‌اند.

مطالعات تجربی نیز نشان می‌دهند که الگوریتم درخت تصمیم به طور مؤثر در پیش‌بینی عملکرد تحصیلی، شخصی‌سازی مسیر یادگیری دانشجویان، بهبود تصمیم‌گیری آموزشی و طراحی سیستم‌های توصیه‌گر به کار گرفته شده است. به‌طور نمونه، بررسی نظام‌مند Trujillo et al. (2025) در زمینه توصیه‌های شغلی در آموزش عالی نشان داد که مدل‌های مبتنی بر جنگل‌های تصادفی، ماشین بردار پشتیبان و شبکه‌های عصبی با استفاده از داده‌های تحصیلی، علاقه‌مندی‌ها و مشخصات جمعیت شناختی، دقت و شخصی‌سازی توصیه‌ها را بهبود می‌دهند و در طراحی مسیرهای آموزشی متناسب با نیازهای دانشجویان نقش مؤثری دارند. Barnes et al. (2024) توانایی مدل‌های درخت تصمیم در شناسایی عوامل مؤثر بر فارغ‌التحصیلی دانشجویان و طراحی سیاست‌های حمایتی هدفمند را بررسی کردند. Orji & Vassileva (2022) از درخت تصمیم برای پیش‌بینی عملکرد تحصیلی و استراتژی مطالعه استفاده کردند.

با این حال، مطالعات موجود محدودیت‌هایی نیز دارند؛ از جمله کمبود مرور نظام‌مند جامع بر کاربرد درخت تصمیم در شخصی‌سازی یادگیری، غیاب داده‌های طولی برای بررسی اثرات بلندمدت، کمبود دسترسی به پایگاه داده‌های باز و تنوع محدود منابع جغرافیایی و فرهنگی. بنابراین، مرور نظام‌مند پژوهش‌ها و تحلیل کاربردهای عملی درخت تصمیم، به ویژه در بستر آموزش عالی و با تمرکز بر شخصی‌سازی یادگیری، ضروری است تا خلاهای موجود پر شده و راهکارهای مؤثرتر و علمی‌تر برای طراحی سیستم‌های یادگیری هوشمند ارائه گردد. مطالعه حاضر با هدف تحلیل نظام‌مند پژوهش‌های علمی در حوزه کاربرد درخت تصمیم در شخصی‌سازی یادگیری الکترونیک در آموزش عالی، به بررسی اهداف، روش‌ها، نوع داده‌ها و کاربردهای بالقوه این الگوریتم می‌پردازد و کاربرد آن را برای طراحی مسیرهای یادگیری شخصی‌سازی شده در رشته برنامه‌ریزی درسی بررسی می‌کند.

روش‌شناسی

پژوهش حاضر به روش مرور نظام‌مند (Systematic Review) انجام شد. مرور نظام‌مند تلاش می‌کند تمام شواهد تجربی موجود که با معیارهای مشخص پیشین مطابقت دارند، برای پاسخ به یک سؤال پژوهشی خاص گردآوری و تحلیل شوند. این روش با استفاده از فرآیندهای شفاف و نظام‌مند، سوگیری را به حداقل می‌رساند و نتایج قابل اعتماد برای استنتاج و تصمیم‌گیری ارائه

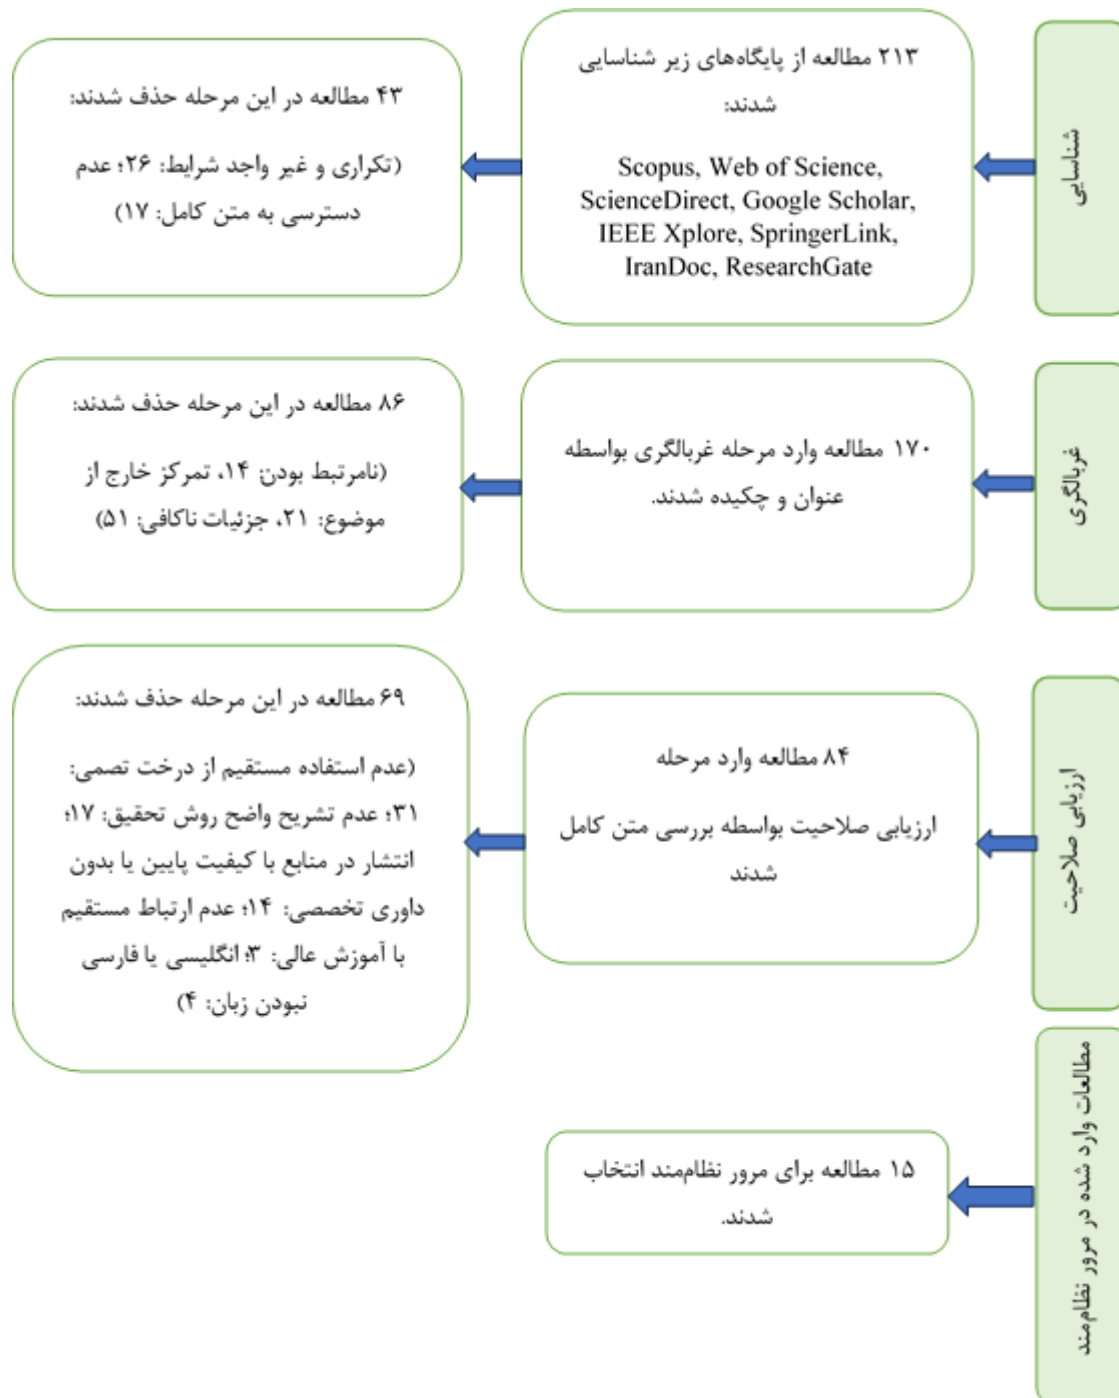
می‌دهد (Higgins et al., 2023). در این مطالعه از پروتکل **PRISMA(2020)** استفاده شد که اهداف، روش، بانک‌های اطلاعاتی، کلمات کلیدی، فرایند غربالگری، معیارهای ورود و خروج، استخراج داده‌ها و ارائه نتایج را مشخص می‌کند. این پروتکل موجب افزایش کیفیت، قابلیت تکرار و شفافیت مرورهای علمی می‌شود (Frost et al., 2022).

جامعه مورد مطالعه این پژوهش شامل پژوهش‌هایی بود که در حوزه یادگیری الکترونیکی در آموزش عالی، با استفاده از الگوریتم‌های درخت تصمیم و یادگیری ماشین، به شخصی سازی یادگیری پرداخته بودند. بانک‌های اطلاعاتی **Web of Science**، **Scopus**، **ScienceDirect**، **Google Scholar**، **IEEE Xplore**، **SpringerLink**، **IranDoc** و **ResearchGate** برای دستیابی به مطالعات مرتبط جستجو شدند. در جستجو، از ترکیب هدفمند کلیدواژه‌ها به صورت ("**Decision Tree**") و ("**Personalized Learning**") یا ("**Personalized Education**") و ("**Higher Education**") یا ("**Curriculum Development**") یا ("**Curriculum Studies**") و نیز معادل‌های فارسی آن‌ها در بازه زمانی ۲۰۱۵ تا ۲۰۲۵ استفاده شد. ابزار غربالگری مقالات، نرم افزار **Rayyan** بود. برای ارزیابی کیفیت مطالعات از رویکرد توصیفی مبتنی بر شفافیت و اعتبار کیفی استفاده شد. در این رویکرد، هر مطالعه براساس چهار معیار اصلی بررسی شد:

۱. شفافیت اهداف و پرسش پژوهش: آیا هدف و پرسش مطالعه به‌طور واضح بیان شده است؟
 ۲. شفافیت روش جمع‌آوری داده‌ها: آیا داده‌ها و نمونه‌های مورد مطالعه به‌طور دقیق توضیح داده شده‌اند؟
 ۳. شفافیت تحلیل داده‌ها: آیا روش تحلیل داده‌ها روشن و منطقی بوده و با هدف پژوهش هماهنگ است؟
 ۴. شفافیت نتایج و استنتاج‌ها: آیا نتایج مطالعه به‌طور شفاف ارائه شده و استنتاج‌ها با داده‌ها همخوانی دارند؟
- باتوجه به ماهیت علوم انسانی و محدودیت‌های داده‌ها در کاربست الگوریتم درخت تصمیم در محیط یادگیری الکترونیک، برخی معیارهای مربوط به کنترل دقیق عوامل مخدوش‌کننده و استفاده از معیارهای عینی و استاندارد غیرقابل اعمال بودند (Lincoln & Guba, 1985)، بنابراین از رویکرد توصیفی برای ارزیابی کیفیت مطالعات استفاده شد.

معیارهای ورود به مطالعه شامل موارد زیر بودند:

- مطالعاتی که به‌طور مشخص الگوریتم درخت تصمیم را برای شخصی‌سازی یادگیری در آموزش عالی به‌کار برده‌اند
 - مقالات و پایان‌نامه‌های منتشرشده در منابع دارای دایره تخصصی
 - مطالعات منتشرشده بین سال‌های ۲۰۱۵ تا ۲۰۲۵
 - همچنین معیارهای خروج شامل موارد زیر بودند:
 - فقدان استفاده مستقیم از الگوریتم
 - مطالعات با روش تحقیق نامشخص
 - منابع منتشرنشده در مجلات معتبر یا با کیفیت پایین (Q4)
 - پژوهش‌های غیرانگلیسی یا غیر فارسی
 - مطالعاتی که الگوریتم در دوره‌های غیر از آموزش عالی به‌کار رفته باشد
- با استفاده از این معیارها، ۸۴ مطالعه اولیه شناسایی شد. پس از بررسی عنوان و چکیده، ارزیابی متن کامل و ارزیابی کیفیت، ۱۵ مطالعه نهایی برای تحلیل انتخاب شدند. فرایند انتخاب و غربالگری مطالعات در شکل ۲ ارائه شده است.



شکل ۱: نمودار پریزما براساس دستورالعمل PRISMA(2020)

داده‌های استخراج‌شده شامل اهداف، نوع داده‌ها و نحوه به کارگیری الگوریتم بود. تحلیل این داده‌ها با استفاده از رویکرد مقایسه‌ای انجام شد تا روشهای مختلف پیاده‌سازی الگوریتم در حوزه‌های مختلف یادگیری الکترونیکی بررسی شود.

گزارش یافته‌ها

تحلیل محتوای مقالات منتخب شامل هدف پژوهش؛ نوع و منبع داده مورد استفاده، روش استفاده از درخت تصمیم، و نتایج کلیدی پژوهش می‌شد. نتایج به دست آمده از تجزیه و تحلیل مقالات در جدول ۱ ارائه شده است.

جدول ۱: تحلیل مقایسه‌ای مقالات منتخب بر اساس هدف پژوهش و روش استفاده از الگوریتم درخت تصمیم

ردیف	مطالعه	هدف پژوهش	منبع و نوع داده	روش استفاده از درخت تصمیم	نتایج کلیدی
۱	Barnes et al. (2024)	- رسیدگی به چالش‌های منحصر بفرد فراگیران در آموزش عالی (فرهنگی، اجتماعی، اقتصادی، نهادی) - ارزیابی دقت پیش‌بینی مدل‌های درخت‌های سطح‌بندی و رگرسیون	سامانه مدیریت دانشجو (Student Management System - SMS) - ویژگی‌های نوع دانشجو ^۱ ، نسل ^۲ ، جنسیت، سن، قومیت، و واجد شرایط بودن گرنت پل ^۳	فرایند: گردآوری و پیش‌پردازش داده‌ها؛ ساخت مدل درخت تصمیم (مدل‌های مختلف درخت؛ ارزیابی عملکرد مدل‌ها؛ و تحلیل اهمیت ویژگی‌ها دنبال شده است.	- توانایی مدل‌های درخت تصمیم در شناسایی عوامل موثر بر فارغ‌التحصیلی دانشجویان با دقت مناسب؛ و کمک به طراحی سیاست‌های حمایتی هدفمند
۲	Orji & Vassileva (2022)	تدوین مدل یادگیری ماشین جهت پیش‌بینی عملکرد تحصیلی و استراتژی مطالعه دانشجویان	پرسش‌نامه آنلاین و داده‌های دانشگاهی - ویژگی‌های جمعیت‌شناختی، تحصیلی، انگیزه، خودمختاری ^۴ ، ارتباط ^۵ ، شایستگی ^۶ ، عزت نفس ^۷ ، استراتژی‌های مطالعه	استفاده از Scikit-learn در پایتون برای ساختن مدل‌های یادگیری ماشین از جمله درخت تصمیم برای مقایسه انجام وظایف رگرسیون و طبقه‌بندی	مدل‌های مبتنی بر درخت تصمیم بهترین نتایج را در مقایسه با سایر مدل‌های مورد مطالعه نشان دادند.
	He, M. (2024)	بررسی کاربرد و تاثیر درخت تصمیم به عنوان ابزار wrapper جهت مدیریت بهتر	- داده حاصل از سیستم مدیریت یادگیری و داده‌های آموزشی مؤسسات آموزش عالی	۱- تولید داده‌های متعادل شده (ترکیبی از داده‌های واقعی و مصنوعی)	- عملکرد خوب مدل‌های درخت تصمیم در انجام وظایف مدیریت آموزشی و افزایش دقت پیش‌بینی

1 student type

2 generation

3 Pell Grant

4 autonomy

5 relatedness

6 competence

7 self-esteem

		داده‌های نامتوازن در بهبود تصمیم‌گیری و مدیریت فرایندهای آموزش و یادگیری در دانشگاه‌ها	-ویژگی‌های اطلاعات جمعیت‌شناختی، عملکرد تحصیلی، روش‌های ارزیابی، استفاده از فناوری در یادگیری	۲- آموزش مدل درخت تصمیم ۳- پیش‌بینی توسط الگوریتم درخت تصمیم ۴- به حداقل رساندن تابع هزینه	نتایج دانشجویان و تصمیم‌گیری‌های آموزشی
۴	Matzavala & Alepis (2021)	ساخت مدل طبقه‌بندی مشخصات و پیش‌بینی عملکرد تحصیلی دانشجو	داده‌های دوره‌ای دانشجویان در دانشگاه -ویژگی‌های جنسیت، پایه، تحصیلات والدین، درآمد والدین، فرزندچندم خانواده بودن، اشتغال دانشجو؛	ترکیبی از داده‌های کاوی و یادگیری درخت تصمیم؛ با مراحل جمع‌آوری داده‌ها، طبقه‌بندی، ایجاد یک مدل پیش‌بینی، و ارزیابی؛	نرخ بالای پذیرش سیستم تطبیقی توسط دانشجویان؛ حفظ سطح بالایی از توانایی آموزشی؛ توانایی ایجاد آزمون پویا و موثر سطح دانش دانشجویان؛
۵	Shoaib et al. (2024)	- تسهیل کاربرد یادگیری دانشجو محور با استفاده از تکنیک درخت تصمیم - تدوین ابزار توصیه‌گر آموزشی (پیشنهاد را هربردهای آموزشی مناسب براساس سبک یادگیری دانشجو)	داده‌های حاصل از پرسشنامه -ویژگی‌های مربوط به سبک یادگیری دانشجویان طبق پرسشنامه فیلدر و سیلورمن ^۱	- جمع‌آوری داده - آموزش مدل - ارزیابی دقت ابزار توصیه‌گر - استفاده از فریم‌ورک Django و کتابخانه‌های Numpy، Pandas، Scikit-learn	ابزار طراحی شده قادر است بصورت فوری سبک یادگیری دانشجو (ورودی) را تشخیص دهد و راهبرد آموزشی مناسب (خروجی هدف) را پیشنهاد دهد.
۶	Park, & Doorisb (2020)	شناسایی مهم‌ترین متغیرهایی که نمرات کلی بالای تدریس و دروس را در ابزار ارزشیابی دانشجویی تدریس ^۲ پیش‌بینی می‌کند.	- ابزار SET سطح دانشجویی - ویژگی‌های فردی دانشجو، ویژگی‌های دوره خارج از کنترل مدرس، ویژگی‌های مربی	- جمع‌آوری داده - پیش‌پردازش داده‌ها - تعیین متغیر هدف - ساخت مدل درخت تصمیم - تحلیل و تفسیر نتایج	تجزیه و تحلیل درخت تصمیم یک رویکرد قوی و شهودی برای تجزیه و تحلیل و تفسیر امتیازات SET در مقایسه با رویکردهای آماری پارامتری رایج است.

1 The Felder and Silverman learning style model
2 student evaluation of teaching (SET) instrument

طراحی سیستمی جهت پیش بینی عملکرد تحصیلی دانشجویان	داده‌های حاصل از سیستم آموزشی - ویژگی‌های سال خروج و ورود، سنوات، سن، سهمیه قبولی، نوبت پذیرش، ترم‌های مشروطی، و تعداد واحدهای پاس شده	استفاده از درخت تصمیم برای مدل سازی داده ها بعد از پیش پردازش داده ها به کمک نرم افزار رپیدماینر (بدون نیاز به کدنویسی)	شناسایی برخی ویژگی‌های موثر بر پیشرفت تحصیلی دانشجویان
بررسی عوامل مؤثر در پیش بینی عملکرد دانشجویان مقطع کارشناسی	مجموعه داده حاصل از سامانه آموزش دانشجویی - ویژگی‌های مشخصات دانشجویان و جزئیات پذیرش آنها (سربازی، تاهل، سهمیه، مشروطی، ممتازی، ...)، نتایج تحصیلی	استفاده از الگوریتم های درخت تصمیم در ترکیب با سایر الگوریتم های یادگیری ماشین؛ استفاده از ابزار مدل سازی RapidMiner 9.9 و اعتبارسنجی متقاطع ۱۰ برابری برای آزمایش عملکرد مدل	بهبود دقت الگوریتم درخت تصمیم C4.5 (با اعمال شاخص جینی و با الگوریتم انتخاب بهینه) نسبت به سایر الگوریتم ها
پیش بینی سطح علمی و عملکرد دانشجویان	داده حاصل از سیستم مدیریت یادگیری - ویژگی ها شامل مشخصات دانشجو از جمله جنسیت، ملیت و اطلاعات تحصیلی از جمله تعداد دفعات ورود به سیستم، منابع، پیام ها، گفتگوها و ...	ترکیبی از الگوریتم های یادگیری ماشین از جمله درخت تصمیم و جنگل های تصادفی؛ استفاده از ماتریس درهم ریختگی و روش ویژگی انتخاب مستقیم جهت گزیندن ویژگی های مهم در مدل	در حالت دوسطحی الگوریتم جنگل های تصادفی (مجموعه ای از درخت های تصمیم) بالاترین دقت را داشته است.

۱۰	Thakaeng et al. (2025)	تدوین مدلی برای بهبود آموزش با استفاده از تکنیک های طبقه بندی و داده کاوی و مطابقت با مشاورهای مناسب	داده های حاصل از پرسشنامه و دیتاست ^۱ نقش های مشاوران از جمله مربی، معلم، عامل انگیزش؛ صداقت، خودمختاری، چالش و حمایت، ارتباطات، منابع، علایق تحصیلی.	آموزش و بهینه سازی مدل های یادگیری ماشین از جمله درخت تصمیم برای دسته بندی و بهینه سازی داده ها؛ و مقایسه تطابق مشاور و دانشجو	مدل درخت تصمیم بالاترین کارایی را نشان داد و برای پیش بینی انتظارات ویژگی های مشاور و رضایت دانشجو موثرترین بود.
۱۱	Chen, Lin (2023)	کاربست الگوریتم درخت تصمیم برای دسته بندی دانشجویان بر اساس داده های استخراج شده از فعالیت های یادگیری آنها (طبقه بندی براساس توانایی جهت شخصی سازی تجربه یادگیری)	داده حاصل از پلتفرم مدیریت آموزشی - اطلاعات آموزشی و رفتاری؛ سطوح تسلط بر دانش نظری و عملی پایه رشته از جمله توانایی خلاقیت و طراحی؛ مهارت در کارهای آزمایشگاهی؛ و توانایی بازیابی اطلاعات از منابع فنی	- شناسایی ویژگی های کلیدی موثر بر موفقیت دانشجویان - ساخت مدل درخت تصمیم بر اساس آنها - استفاده از Gain اطلاعاتی (Information Gain) بر اساس آنتروپی برای انتخاب بهترین ویژگی جهت تقسیم داده ها	مدل درخت تصمیم توانست به طور دقیق دانشجویان را در دو دسته سطح بالا و پایین طبقه بندی کند؛ - الگوریتم درخت تصمیم ابزاری موثر در پیش بینی و بهبود عملکرد تحصیلی دانشجویان است.

۱۲	Delahoz-Domínguez and Hijón-Neira (2024)	معرفی یک سیستم توصیه‌گر نوین برای انتخاب رشته دانشگاهی که ترکیبی از داده‌های عملکرد تحصیلی و اطلاعات اجتماعی-اقتصادی یادگیرندگان را مورد استفاده قرار می‌دهد.	داده حاصل از موسسه آموزشی - نمرات آزمون استاندارد؛ اطلاعات اجتماعی-اقتصادی؛ (جنسیت، نوع مدرسه، سطح تحصیلات و شغل والدین، تقویم آموزشی مدرسه، منطقه محل سکونت)	۴ مدل XGBoost (برپایه درخت تصمیم) Random Forest (ترکیبی از درختان تصمیم) و دو الگوریتم دیگر باهم مقایسه شده‌اند.	الگوریتم XGBoost به‌ترین مدل در کل پژوهش بود و دقیق‌ترین پیش‌بینی را در آزمون واقعی انجام داد.
۱۳	Asif et al. (2017)	تحلیل داده‌های آموزشی برای پیش‌بینی عملکرد تحصیلی دانشجویان کارشناسی با استفاده از الگوریتم‌های یادگیری ماشین، به‌ویژه با هدف شناسایی عوامل مؤثر در افت یا موفقیت تحصیلی.	داده‌های حاصل از سیستم اطلاعات دانشگاهی - ویژگی‌های آکادمیک؛ رفتاری و تعهد(حضور در کلاس، انجام بموقع تکالیف، فعالیت در پروژه‌ها)؛ دموگرافیک	استفاده از چند مدل یادگیری ماشین از جمله درخت تصمیم برای مقایسه دقت. - پیش‌پردازش داده‌ها؛ تقسیم داده به دو دسته آموزشی و آزمون؛ پیاده‌سازی الگوریتم (معیار تقسیم Gini Index)؛ ارزیابی و مقایسه	درخت تصمیم و جنگل تصادفی دقت پیش‌بینی بالایی نسبت به سایر الگوریتم‌ها داشتند. - مدل‌ها توانستند با دقت حدود ۸۵٪ عملکرد دانشجویان را پیش‌بینی کنند.
۱۴	Zhang et al. (2022)	پیش‌بینی عملکرد تحصیلی و موفقیت دانشجویان تمرکز بر شناسایی دانشجویان با عملکرد ضعیف (ریسک افت تحصیلی)	داده حاصل از سیستم آموزشی - داده‌های نمرات و عملکرد تحصیلی دانشجویان	استفاده از مدل پایه درخت تصمیم برای طبقه‌بندی دانشجویان؛ بهبود دقت با مدل تقویت شده؛ استفاده از جنگل تصادفی برای افزایش پایداری و کاهش خطا. - آموزش مدل و ارزیابی مبتنی بر دقت	شناسایی عوامل مهم مؤثر بر عملکرد تحصیلی از طریق تحلیل اهمیت ویژگی‌ها در هر مدل ممکن بود. امکان شناسایی و حمایت از دانشجویان نیازمند کمک بیشتر وجود داشت.

۱۵	Hamoud et al. (2018)	بررسی امکان استفاده از نتایج حاصل از الگوریتم‌های درخت تصمیم در پشتیبانی از تصمیم‌گیری‌های آموزشی برای بهبود عملکرد تحصیلی و ارائه مسیر مناسب برای دانشجویان و مدرسان؛ شناسایی عوامل مؤثر بر موفقیت یا شکست تحصیلی دانشجویان	داده‌های حاصل از پرسش‌نامه (مبتنی بر LimeSurvey (متن باز و محلی) و Google Form (آنلاین))؛ - ویژگی‌هایی مانند سلامت، فعالیت‌های اجتماعی، روابط فردی و عملکرد تحصیلی	- ساخت پرسش‌نامه به‌عنوان بخشی از مرحله پیش‌پردازش داده (آماده‌سازی، پاکسازی، تبدیل محدوده، ایجاد یک ستون مشتق‌شده بر اساس ستون دیگر) - استفاده از ابزار Weka و سه الگوریتم از الگوریتم‌های درخت تصمیم (J48، Random Tree، RepTree)	- الگوریتم J48 عملکرد بهتری از خود نشان داد. - میزان بزرگ بودن مجموعه داده و تعداد ویژگی‌ها می‌تواند بر دقت الگوریتم درخت تصمیم اثرگذار باشد.
----	----------------------	--	---	---	--

بحث

با توجه به تحلیل مطالعات فوق، نتایج تحلیل به تفکیک سوالات پژوهش بررسی می‌گردد. در پاسخ به سوال اول پژوهش، یعنی برجسته‌ترین اهداف مطالعات مرتبط با کاربست الگوریتم درخت تصمیم در حوزه یادگیری الکترونیک در آموزش عالی، یافته‌ها نشان دادند که مطالعات انجام شده پیرامون کاربرد الگوریتم درخت تصمیم در حوزه یادگیری الکترونیک در آموزش عالی عمدتاً با اهداف چندگانه‌ای دنبال شده‌اند که در سه محور اصلی قابل دسته‌بندی هستند:

• محور اول: پیش‌بینی عملکرد تحصیلی دانشجو و شخصی‌سازی آموزش

یکی از پررنگ‌ترین رویکردها در این پژوهش‌ها، استفاده از درخت تصمیم برای توسعه مدل‌هایی است که توانایی پیش‌بینی عملکرد تحصیلی دانشجویان را دارند. این مطالعات کوشیده‌اند متغیرهای اثرگذار بر موفقیت یا افت تحصیلی را شناسایی کنند و دانشجویان را بر اساس سطح توانمندی، سبک مطالعه یا الگوی یادگیری طبقه‌بندی نمایند. مطالعات Matzavela & Alepis (2021)، Orji & Vassileva (2022)، Asif et al. (2017)، Ekramifar (2023)، Salari et al. (2024)، Haghi (2023)، و Zhang et al. (2022) از این جمله‌اند. همچنین پژوهش‌هایی مانند Barnes et al. (2024)، Shoaib et al. (2024)، Thakaeng (2025)، و Chen & Lin (2023) با تمرکز بر شناسایی عوامل تعیین‌کننده در موفقیت تحصیلی، زمینه طراحی آموزش‌های شخصی‌سازی شده را فراهم آورده‌اند.

• محور دوم: پشتیبانی از تصمیم‌گیری آموزشی و توسعه سیستم‌های توصیه‌گر


گروهی دیگر از مطالعات، کاربرد درخت تصمیم را در طراحی ابزارهای پشتیبان تصمیم‌گیری آموزشی بررسی کرده‌اند. این ابزارها شامل سیستم‌های توصیه‌گر برای انتخاب رشته مناسب (Delahoz-Domínguez & Hijón-Neira, 2024)، ارائه مشاوره آموزشی شخصی‌سازی شده، یا حتی توصیه راهبردهای یادگیری متناسب با ویژگی‌های فردی دانشجویان هستند (مطالعات

(Shoaib et al. (2024), Park & Dooris (2020), Hamoud et al. (2018)). چنین پژوهش‌هایی بیانگر ظرفیت الگوریتم‌های درخت تصمیم در کمک به ارتقای کیفیت تصمیم‌گیری‌های آموزشی در سطوح فردی و سازمانی است.

• محور سوم: مدیریت داده‌های آموزشی و بهینه‌سازی فرایندهای یادگیری

بعد سوم مطالعات، به کارگیری درخت تصمیم برای مدیریت داده‌های آموزشی حجیم و نامتوازن و بهینه‌سازی تحلیل داده‌هاست. این الگوریتم بویژه در نقش انتخاب ویژگی (feature selection) یا بصورت wrapper در بهبود دقت تصمیم‌گیری کاربرد داشته است (He (2024), Park & Dooris (2020), Hamoud et al. (2018)). نتایج این دسته از پژوهش‌ها نشان می‌دهد که استفاده از درخت تصمیم می‌تواند کارایی پردازش داده‌ها را ارتقا دهد، امکان تحلیل دقیق‌تر رفتار یادگیرندگان را فراهم کند و نهایتاً به بهینه‌سازی فرایندهای آموزشی در محیط‌های یادگیری الکترونیک بینجامد.

در مجموع موارد کاربرد درخت تصمیم در حوزه یادگیری الکترونیک در آموزش عالی را می‌توان به صورت شماتیک زیر ارائه داد.



شکل ۲: موارد کاربرد درخت تصمیم در حوزه یادگیری الکترونیک در آموزش عالی

در پاسخ به سوال دوم پژوهش، نحوه کاربست الگوریتم‌های درخت تصمیم در حوزه یادگیری الکترونیک در آموزش عالی، عمدتاً در قالب چارچوبی مرحله‌ای و مبتنی بر چرخه داده‌کاوی و یادگیری ماشین صورت گرفته است. این فرایند را می‌توان در چند مرحله کلیدی و الگوهای متداول کاربرد، به صورت شماتیک زیر خلاصه کرد:



شکل ۳: فرایند مرحله‌ای کاربست الگوریتم‌های درخت تصمیم در حوزه یادگیری الکترونیک در آموزش عالی

در گام نخست، بیشتر مطالعات به جمع‌آوری داده‌های آموزشی از منابع متنوع پرداخته‌اند. این داده‌ها پیش از ورود به مرحله مدل‌سازی، از نظر کیفیت مورد ارزیابی و پاک‌سازی قرار گرفته، و فرایندهایی نظیر نرمال‌سازی، بازکدگذاری متغیرها و در برخی موارد، ترکیب با داده‌های مصنوعی به‌منظور رفع عدم تعادل طبقه‌ای بر روی آن‌ها اعمال شده است. برای اجرای این فرایندها، ابزارها و کتابخانه‌هایی همچون **Pandas** و **NumPy** در محیط پایتون، و نرم‌افزارهای **Weka** و **RapidMiner** به‌طور گسترده مورد استفاده قرار گرفته‌اند. این ابزارها در حذف داده‌های پرت، نرمال‌سازی مقادیر، دسته‌بندی مجدد متغیرها و همچنین ایجاد ویژگی‌های مشتق‌شده برای بهبود عملکرد مدل نقش کلیدی ایفا کرده‌اند.

در گام دوم، فرایند مدل‌سازی با استفاده از طیفی از الگوریتم‌های درخت تصمیم انجام شده است. رایج‌ترین الگوریتم‌های به‌کاررفته در این حوزه شامل **ID3**، **C4.5** و نسخه بهینه‌شده آن **J48**، **CART**، **Random Forest**، **XGBoost**، **REPTree** و **RandomTree** بوده‌اند. در این مرحله، داده‌های آموزشی به‌عنوان ورودی به مدل ارائه شده و ساختار درختی بر اساس شاخص‌هایی نظیر **Gini Index**، **Information Gain** یا **Entropy Reduction** شکل گرفته است. هر گره درخت نمایانگر یک متغیر کلیدی اثرگذار و هر برگ معادل یک برون‌داد نهایی در قالب طبقه‌بندی یا پیش‌بینی است. برای پیاده‌سازی این الگوریتم‌ها، ابزارها و کتابخانه‌هایی همچون **Scikit-learn** در محیط پایتون و نرم‌افزارهای **Weka** و **RapidMiner** به‌طور گسترده مورد استفاده قرار گرفته‌اند.

در مرحله سوم، پس از آموزش مدل، عملکرد آن با بهره‌گیری از رویکردهای مختلف اعتبار سنجی از جمله **k-fold cross-validation**، تقسیم‌بندی داده‌ها به **train/test**، و در برخی موارد **hold-out validation** ارزیابی شده است. برای سنجش کارایی مدل، شاخص‌هایی همچون دقت (**Accuracy**)، فراخوانی (**Recall**)، ضریب **F1** (**F1-score**) و همچنین ماتریس درهم‌ریختگی (**Confusion Matrix**) به‌کار گرفته شده‌اند. افزون بر این، در بخشی از مطالعات، الگوریتم‌های درخت تصمیم با سایر مدل‌های یادگیری ماشین نظیر **KNN**، شبکه‌های عصبی، رگرسیون لجستیک و حتی مدل‌های ترکیبی مقایسه شده‌اند تا دقیق‌ترین و بهینه‌ترین مدل برای پشتیبانی از کاربردهای آموزشی انتخاب گردد.

در مرحله چهارم، پژوهشگران با تحلیل ساختار نهایی درخت تصمیم، متغیرهای کلیدی و اثرگذار بر موفقیت یا شکست تحصیلی را استخراج کرده و از آن‌ها در تصمیم‌سازی‌ها و مداخلات آموزشی بهره گرفته‌اند. این مرحله به‌نوعی نقش تفسیرپذیری الگوریتم را برجسته می‌سازد، زیرا شناسایی شاخص‌های تعیین‌کننده، امکان طراحی سیاست‌های آموزشی هدفمند را فراهم می‌کند. برای نمونه، در بسیاری از مدل‌ها عواملی چون میزان حضور در کلاس‌های آنلاین، نمرات میان‌ترم، پیشینه تحصیلی، و سطح تعامل دانشجویان با محتوای سیستم‌های مدیریت یادگیری (**LMS**) به‌عنوان متغیرهای کلیدی ظاهر شده‌اند. استفاده از این شاخص‌ها نه تنها در ارتقای کیفیت پیش‌بینی‌ها مؤثر بوده، بلکه زمینه را برای توسعه راهبردهای شخصی‌سازی شده آموزشی و بهبود فرایند یادگیری در محیط‌های الکترونیک فراهم آورده است.

در مرحله پنجم، الگوریتم‌های درخت تصمیم به‌عنوان هسته اصلی تصمیم‌گیری در سیستم‌های توصیه‌گر آموزشی به‌کار گرفته شده‌اند. این سیستم‌ها با تحلیل پروفایل فردی دانشجویان، پیشنهادهایی نظیر انتخاب رشته تحصیلی مناسب، تطبیق با مشاور یا راهنمای آموزشی، و تعیین استراتژی‌های یادگیری متناسب با ویژگی‌های فردی ارائه می‌دهند. در برخی پژوهش‌ها، به‌منظور ارتقای دقت و کارایی این سیستم‌ها، از رویکردهای ترکیبی (**Ensemble**) بهره گرفته شده است؛ به‌گونه‌ای که با وزندهی به درخت‌ها یا ترکیب چند یادگیرنده، توان پیش‌بینی و قابلیت شخصی‌سازی توصیه‌ها به‌طور چشمگیری بهبود یافته است.

در مجموع در پاسخ به سوال دوم پژوهش می‌توان گفت کاربرد الگوریتم‌های درخت تصمیم در بستر یادگیری الکترونیکی آموزش عالی یک فرایند چندمرحله‌ای است که شامل گردآوری داده‌های آموزشی از منابع متنوع، انجام پیش‌پردازش‌های لازم، ساخت و آموزش مدل‌های درخت تصمیم، ارزیابی عملکرد با شاخص‌های کمی، و در نهایت تحلیل تفسیرپذیر خروجی‌ها می‌باشد. این رویکرد نظام‌مند، امکان شناسایی الگوهای پنهان، طراحی مداخلات آموزشی هدفمند و توسعه سیستم‌های توصیه‌گر شخصی‌سازی شده را فراهم می‌سازد.

در پاسخ به سوال سوم پژوهش؛ نوع و منبع داده یادگیری ماشین در کاربرد الگوریتم‌های درخت تصمیم در حوزه یادگیری الکترونیک در آموزش عالی، طیف گسترده‌ای از داده‌های ساختاریافته و نیمه ساختاریافته جهت آموزش مدل‌های مبتنی بر درخت تصمیم، و جمع‌آوری شده از منابع گوناگون آنلاین و محلی بوده است. این داده‌ها به‌طور عمده از منابع اصلی: مؤسسات آموزشی، سوابق تحصیلی، داده‌های آزمون‌های استاندارد؛ سیستم‌های ارزشیابی تدریس و کیفیت آموزش (SET Tools)؛ پرسش‌نامه‌های آنلاین و ساختاریافته (روان‌سنجی، Google Forms, LimeSurvey)؛ سیستم‌های مدیریت یادگیری (LMS: Learning Management System)؛ سیستم‌های مدیریت دانشجو (SMS: Student Management System)، و یا از پایگاه‌های داده ترکیبی و یکپارچه‌شده به دست آمده است. در برخی مطالعات، داده‌های مصنوعی یا متعادل‌شده نیز از طریق تکنیک‌های **oversampling** یا ترکیب داده‌های واقعی و داده‌های شبیه‌سازی شده تولید شده‌اند، به‌ویژه زمانی که کلاس‌های داده نامتوازن بوده‌اند.

همچنین داده‌ها در قالب چند نوع متمایز استخراج شده‌اند: داده‌های جمعیت شناختی و فردی (سن، جنسیت، قومیت، نسل، وضعیت تأهل، شغل، درآمد خانوار، ترتیب تولد در خانواده، تحصیلات والدین، مذهب، وضعیت مالی و صلاحیت برای دریافت کمک‌هزینه)؛ داده‌های تحصیلی و عملکرد آموزشی (نمرات دروس پایه، تخصصی، عملی؛ آزمون‌های استاندارد؛ نمرات ارزیابی نهایی یا میان‌ترم؛ سطح تسلط بر مهارت‌های خاص)؛ داده‌های رفتاری و تعاملات یادگیری (میزان استفاده از پلتفرم، ورود به سیستم، زمان فعالیت در محیط آنلاین، میزان مشارکت در بحث‌ها، دانلود منابع، شرکت در آزمون‌های آنلاین، الگوی زمان‌بندی ارسال تکالیف و تعامل با محتوای درسی)؛ داده‌های روان‌شناختی و انگیزشی (خودکارآمدی، عزت‌نفس، انگیزش درونی و بیرونی، سبک‌های یادگیری، میزان احساس شایستگی، خودمختاری، نیاز به تعلق، رضایت از مشاوره تحصیلی، انتظارات از تعامل با اساتید و مشاوران)؛ داده‌های مربوط به ویژگی‌های دوره و مدرس (مشخصات مدرس: تجربه، تعامل‌پذیری، روش تدریس؛ نوع دوره: حضوری یا آنلاین، عملی یا نظری؛ عوامل خارج از کنترل مدرس (مانند محتوای اجباری یا ساختار برنامه)؛ داده‌های اجتماعی-اقتصادی و آموزش پیشین (نوع دانشگاه، سطح تحصیلات والدین، شغل والدین، تقویم آموزشی منطقه، منطقه جغرافیایی محل سکونت، داده‌های مهارت‌های شهروندی و درک مطلب) از انواع داده‌های مورد استفاده در این پژوهش‌ها بوده‌اند. شکل شماتیک زیر در ارائه اجمالی این پاسخ ترسیم شده است.



شکل ۴: نوع و منبع داده برای یادگیری ماشین در کاربری درخت‌های تصمیم در حوزه یادگیری الکترونیک در آموزش عالی

در پاسخ به سوال چهارم پژوهش؛ یافته‌های اصلی در مورد استفاده از الگوریتم‌های درخت تصمیم در حوزه یادگیری الکترونیک در آموزش عالی، تحلیل مطالعات مورد بررسی این پژوهش در حوزه یادگیری الکترونیک آموزش عالی نشان داد که الگوریتم‌های درخت تصمیم، به‌ویژه نسخه‌های پیشرفته آن‌ها مانند **J48**، **C4.5**، **Random Forest** و **XGBoost**، در تحلیل داده‌های آموزشی و ارتقاء کیفیت تصمیم‌گیری‌های آموزشی نقش مهمی ایفا کرده‌اند. یافته‌های کلیدی این مطالعات در قالب محورهای زیر قابل جمع‌بندی هستند:

- دقت بالا در پیش‌بینی و طبقه‌بندی دانشجویان: مدل‌های درخت تصمیم توانسته‌اند با دقت بسیار بالا (حتی تا ۹۴٫۹٪ در برخی پژوهش‌ها)، عملکرد تحصیلی، احتمال فارغ‌التحصیلی، یا ترک تحصیل دانشجویان را پیش‌بینی کنند.
- کاربرد در طراحی ابزارهای توصیه‌گر تطبیقی و هوشمند: از الگوریتم درخت تصمیم برای توسعه ابزارهایی استفاده شده که می‌توانند به صورت آنی سبک یادگیری دانشجویان را تشخیص داده و راهبردهای آموزشی مناسب را پیشنهاد دهند. این ابزارها، تجربه یادگیری تطبیقی و شخصی‌سازی شده‌ای را فراهم کرده‌اند که منجر به افزایش مشارکت و رضایت دانشجویان شده است.
- تفسیرپذیری بالا در تحلیل داده‌های آموزشی: درخت‌های تصمیم توانایی بالایی در نمایش بصری و شفاف روابط بین متغیرها دارند و نسبت به روش‌های آماری سنتی، تفسیر دقیق‌تری از عوامل مؤثر ارائه می‌دهند.
- پیش‌بینی مسیر شغلی و احتمال استخدام فارغ‌التحصیلان: الگوریتم درخت تصمیم در برخی پژوهش‌ها به‌طور مؤثر برای پیش‌بینی احتمال استخدام براساس مهارت‌ها و عملکرد تحصیلی دانشجویان به کار رفته است. این یافته‌ها به دانشگاه‌ها کمک کرده‌اند تا آموزش‌ها را بهتر با نیازهای بازار کار تطبیق دهند.

- برتری نسبی در مقایسه با سایر الگوریتم‌ها: در بسیاری از پژوهش‌ها، مدل‌های درخت تصمیم از نظر شاخص‌های عملکرد مانند درستی، یادآوری، دقت، امتیاز $F1$ ، و ضریب همبستگی کندال و اسپیرمن، برتری نسبی نسبت به سایر الگوریتم‌ها مانند KNN و SVM داشته‌اند.

نهایتاً در پاسخ به سوال نهایی پژوهش که الگوریتم درخت تصمیم در حوزه یادگیری الکترونیکی رشته برنامه‌ریزی درسی چه کاربردهای بالقوه‌ای می‌تواند داشته باشد؟ الگوریتم درخت تصمیم، به‌عنوان یکی از روش‌های قدرتمند و تفسیرپذیر یادگیری ماشین، در حوزه یادگیری الکترونیکی می‌تواند کاربردهای متعددی در رشته برنامه‌ریزی درسی داشته باشد. این کاربردها هم در سطح تحلیل و طراحی برنامه درسی و هم در سطح اجرا و ارزشیابی آن قابل بررسی هستند. شخصی‌سازی مسیرهای یادگیری، دانشجویان براساس ویژگی‌های فردی، تحصیلی و روان‌شناختی دانشجویان نظیر سبک یادگیری، انگیزه، پیش‌زمینه تحصیلی، تعامل با محتوای آموزشی و طراحی مازول‌های تطبیقی در برنامه درسی که متناسب با نیازهای یادگیرنده ارائه شوند. مخصوصاً در وضعیت کنونی که رشته برنامه‌ریزی درسی در حوزه‌های تخصصی مختلف پیشرفت‌های حرفه‌ای چشمگیری داشته است و نیازمند توجه به یادگیری تخصصی با توجه به زمینه، ویژگی‌ها و نیازهای افراد است. متخصص برنامه‌درسی همه‌فن‌حریف دیگر معنی ندارد و متخصص برنامه‌درسی با توجه به حیطه عمل و کاری که انجام می‌دهد می‌تواند دارای زیرتخصص‌های متنوعی باشد که هر یک، زمینه تبدیل شدن به مشاغل خاص و با توصیف و ویژگی منحصر به فرد را دارند (Fathi-Yadegarzadeh et al., 2013; Vajargah, 2018).

جمع‌بندی، نتیجه‌گیری و پیشنهادات

بطور کلی الگوریتم‌های درخت تصمیم با ویژگی‌هایی چون تفسیرپذیری، دقت بالا، توانایی پیش‌بینی دقیق، و کاربرد گسترده در توصیه‌گری و طبقه‌بندی، به ابزارهای مؤثر در یادگیری الکترونیکی در آموزش عالی تبدیل شده‌اند. این الگوریتم‌ها نه تنها فرایند تصمیم‌سازی برای دانشجویان و دانشگاه‌ها را ارتقاء داده‌اند، بلکه توانسته‌اند تحلیل‌های دقیق‌تری از انواع داده‌ها (جمعیت‌شناختی، تحصیلی، روان‌شناختی، اجتماعی، اقتصادی، و سایر انواع داده‌ها) فراهم کرده و به بهبود برنامه‌ریزی، پشتیبانی تحصیلی و اشتغال فارغ‌التحصیلان کمک کنند. درعین حال برخی محدودیت‌ها، چالش‌ها و نکات حساسیت‌زایی همچون تاثیر حجم داده‌ها و تعداد ویژگی‌ها یا بیش‌برازش (Overfitting)، وابستگی به کیفیت داده‌ها، و نیاز به تنظیم دقیق پارامترها نیز درمورد آنها گزارش شده است. بنابراین براساس شواهد حاصل از مطالعات علمی تحلیل شده در این پژوهش، می‌توان چنین نتیجه گرفت که کاربرست الگوریتم درخت تصمیم در حوزه یادگیری الکترونیک در آموزش عالی می‌تواند نقش مفید و کارآمدی در شخصی‌سازی یادگیری، و پیش‌بینی عملکرد تحصیلی دانشجویان ایفا کند. هم‌چنین با تکیه بر قابلیت این الگوریتم در مدیریت داده‌های آموزشی، می‌توان از آن در بهینه‌سازی فرایندهای یادگیری در جهت پاسخگویی به پیشینه، نیازها، ویژگی‌ها و سبک‌های یادگیرندگان، ارائه توصیه‌های آموزشی شخصی‌سازی شده، و پشتیبانی از تصمیم‌گیری‌های آموزشی یادگیرندگان بهره گرفت. طبق این نتایج در حوزه رشته برنامه‌ریزی درسی موارد زیر پیشنهاد می‌شود:

- طراحی نظام‌های توصیه‌گر با کاربرست الگوریتم‌های یادگیری ماشین از جمله الگوریتم درخت تصمیم برای انتخاب دروس و فعالیت‌های یادگیری تخصصی و حرفه‌ای که براساس داده‌های پیشین دانشجو، دروس یا تکالیف مناسب را پیشنهاد دهند و از انتخاب‌های نامتناسب جلوگیری کنند و همچنین فرایند «برنامه‌ریزی درسی شخصی‌سازی شده» و مشاوره تحصیلی مبتنی بر داده را در محیط‌های مجازی تسهیل کنند.

- استفاده از قابلیت‌های الگوریتم درخت تصمیم در پیش‌بینی عملکرد یادگیرندگان و پشتیبانی هدفمند با شناسایی به‌موقع دانشجویان در معرض خطر (مثلاً افت تحصیلی، انصراف، عدم مشارکت) در رشته برنامه‌ریزی درسی و امکان مداخله آموزشی به‌موقع برای طراحان درسی و مدرسان و بهینه‌سازی فرایند بازخورددهی و حمایت تحصیلی.
- پشتیبانی از تصمیم‌گیری‌های کلان در طراحی دروس و سرفصل‌ها، با کاربست الگوریتم‌های درخت تصمیم که می‌توانند داده‌های گسترده عملکردی، جمعیت‌شناختی و محیطی دانشجویان را تحلیل کرده و بینش‌های کلان برای اصلاح ساختار دروس، واحدهای اختیاری، یا توالی ارائه مباحث درسی ارائه دهند. این امر برنامه‌ریزی کلان درسی مبتنی بر شواهد برای پاسخ به نیازهای واقعی دانشجویان در یادگیری الکترونیکی را میسر خواهد کرد.

References

- Asif, R., Merceron, A., Ali, S. A., & Haider, N. G. (2017). **Analyzing undergraduate students' performance using educational data mining**. *Computers & education*, 113, 177-194. <https://doi.org/10.1016/j.compedu.2017.05.007>
- Ekramifar, M. (2023). *Predicting student performance using a decision tree algorithm* [Master's thesis, Sina Institute of Higher Education]. [In Persian]. <https://ganj.irandoc.ac.ir/viewer/a501ab5ba6fcb4e80106c5cf6257e442>
- Barnes, T., Conrad, R. M., & Demps, E. (2024). **Predicting adult learners' success using decision tree models in online higher education**. *Journal of Learning Analytics*, 11(1), 45–60. <https://doi.org/10.1234/jla.2024.1101>
- Blockeel, H., Devos, L., Frénay, B., Nanfack, G., & Nijssen, S. (2023). **Decision trees: from efficient prediction to responsible AI**. *Frontiers in artificial intelligence*, 6, 1124553. <https://doi.org/10.3389/frai.2023.1124553>
- Cañete-Sifuentes, L., Monroy, R., & Medina-Pérez, M. A. (2021). **A review and experimental comparison of multivariate decision trees**. *IEEE Access*, 9, 110451-110479. <https://doi.org/10.1109/ACCESS.2021.3102239>
- Chen, Y., & Lin, K. (2023). **General academic performance prediction using CART in higher education**. *IEEE Access*, 11, 44123–44132. <https://doi.org/10.1109/ACCESS.2023.3258693>
- Delahoz-Domínguez, E. J., & Hijón-Neira, R. (2024). **Recommender System for University Degree Selection: A Socioeconomic and Standardised Test Data Approach**. *Applied Sciences* (2076-3417), 14(18). <https://doi.org/10.20944/preprints202408.0905.v1>
- Fathi-Vajargah, K. (2018). **Moving toward the third wave in Iranian curriculum studies: Moving beyond reconceptualization and searching for pluralism in curriculum landscapes**. *Journal of Higher Education Curriculum Studies*, 18(9), 45–69. [In Persian]. <https://www.noormags.ir/view/en/articlepage/downloadpdf/1436387>
- Frost, A. D., Hróbjartsson, A., & Nejtgaard, C. H. (2022). **Adherence to the PRISMA-P 2015 reporting guideline was inadequate in systematic review protocols**. *Journal of Clinical Epidemiology*, 150, 179-187. <https://doi.org/10.1016/j.jclinepi.2022.07.002>
- Haghi, M. (2023). **Predicting the performance of medical sciences students based on educational data analysis using data mining techniques: A case study of selected medical sciences universities** [Master's thesis, Iran University of Science and Technology]. [In Persian]. <https://ganj.irandoc.ac.ir/viewer/be4b29c28ce434c7bd1dad24cbcd74e7>
- Hamoud, A., Hashim, A. S., & Awadh, W. A. (2018). **Predicting student performance in higher education institutions using decision tree analysis**. *International Journal of Interactive Multimedia and Artificial Intelligence*, 5, 26-31. <https://doi.org/10.9781/ijimai.2018.02.004>
- He, Xiaohu. (2024). **Application of Decision Tree Algorithm in Teaching and Learning Management in Colleges and Universities**. *Journal of Electrical Systems*. 20. 1870-1880. 10.52783/jes.3103. <https://doi.org/10.52783/jes.3103>
- He, M. (2024). **Decision tree application in university educational management**. *International Journal of Educational Management*, 38(1), 91–103. <https://doi.org/10.1108/IJEM-01-2024-0054>
- Higgins JPT, Thomas J, Chandler J, Cumpston M, Li T, Page MJ, Welch VA (editors) (2023). **Cochrane Handbook for Systematic Reviews of Interventions Version 6.4**. Cochrane . <https://training.cochrane.org/handbook>

- Jena, M., & Dehuri, S. (2020). **DecisionTree for classification and regression: a state-of-the art review**. Informatica, 44(4). <https://doi.org/10.31449/inf.v44i4.3023>
- Jiang, X. (2021). **Online English teaching course score analysis based on decision tree mining algorithm**. complexity, 2021(1), 5577167. <https://doi.org/10.1155/2021/5577167>
- Manoharan, Ashok. (2024). **MACHINE LEARNING ALGORITHMS FOR PERSONALIZED LEARNING PATHS**. International Research Journal of Modernization in Engineering Technology and Science. 06. 211-218. <https://doi.org/10.56726/IRJMETS49965>
- Matzavela, V., & Alepis, E. (2021). **Mobile learning analytics and decision trees for student performance prediction**. Education and Information Technologies, 26(3), 2983–3002. <https://doi.org/10.1007/s10639-020-10341-9>
- Mienye, I. D., & Jere, N. (2024). **A survey of decision trees: Concepts, algorithms, and applications**. IEEE access. <https://doi.org/10.1109/ACCESS.2024.3416838>
- Lincoln, Y. S., & Guba, E. G. (1985). **Naturalistic Inquiry**. Beverly Hills, CA: SAGE Publications.
- Orji, R., & Vassileva, J. (2022). **Using decision trees to analyze learning styles and motivation in higher education**. Computers & Education, 180, 104456. <https://doi.org/10.1016/j.compedu.2022.104456>
- Park, Y., & Dooris, M. (2020). **Predictive analytics of teaching evaluations using decision tree classification**. Journal of Higher Education Policy and Management, 42(6), 591–605. <https://doi.org/10.1080/1360080X.2020.1788954>
- Salari, M., Radfar, R., & Faqihi, M. (2024). **Predicting student performance using machine learning algorithms and educational data mining: A case study of Shahid Beheshti University**. Smart Business Management Studies, 12(47), 315–366. [In Persion]. <https://doi.org/10.22054/ims.2023.75523.2375>
- Sáiz-Manzanares, M. C., Marticorena-Sánchez, R., & Ochoa-Orihuel, J. (2019). **Improving learning management through learning analytics using decision trees**. Frontiers in Psychology, 10, 939. <https://doi.org/10.3389/fpsyg.2019.00939>
- Shoaib, L. A., Safii, S. H., Idris, N., Hussin, R., & Sazali, M. A. H. (2024). **Utilizing decision tree machine learning model to map dental students' preferred learning styles with suitable instructional strategies**. BMC Medical Education, 24(1), 58. <https://link.springer.com/article/10.1186/s12909-023-05022-5>
- Sun, Y. (2024). **Decision trees for evaluating blended learning effectiveness in higher education**. Journal of Educational Technology Systems, 53(2), 112–134. <https://doi.org/10.1177/0047239524123456>
- Thakaeng, K., Temdee, P., & Wicha, S. (2025). **A Decision Tree-Based Advisory Recommendation System for Dental Students**. Journal of Mobile Multimedia, 21(1), 179-195. <https://doi.org/10.13052/jmm1550-4646.2117>
- Trujillo, F., Pozo, M., & Suntaxi, G. (2025). **Artificial intelligence in education: A systematic literature review of machine learning approaches in student career prediction**. JOTSE: Journal of Technology and Science Education, 15(1), 162-185. <https://doi.org/10.3926/jotse.3124>
- Yadegarzadeh, G., Fathi-Vajargah, K., Mehrmohammadi, M., & Arefi, M. (2013). **Analysis of the occupational roles and professional activities of curriculum specialists**. Iranian Journal of Curriculum Studies, 8(30).[In Persion]. <https://www.noormags.ir/view/fa/articlepage/1059884/>

- Zhang, W., Wang, Y., & Wang, S. (2022). **Predicting academic performance using tree-based machine learning models: A case study of bachelor students in an engineering department in China.** Education and Information Technologies, 27(9), 13051-13066. <https://doi.org/10.1007/s10639-022-11170-w>
- Zhao, X., & Li, H. (2023). **Predicting academic performance in ideological education using decision trees.** Journal of Educational Research, 116(4), 367–379. <https://doi.org/10.1016/j.jer.2023.116456>
- Zhou, T. F., Pan, Y. Q., & Huang, L. R. (2017, December). **Research on personalized e-learning based on decision tree and RETE algorithm.** In 2017 International conference on computer systems, electronics and control (ICCSEC) (pp. 1392-1396). IEEE. <https://doi.org/10.1109/ICCSEC.2017.8446741>