



## A Novel Hybrid Machine Learning Model Based on Deep Learning for Predicting Recruitment Decisions

Mohammad Reza Mehreganan\*<sup>ID</sup>

Arman Rezasoltani\*\*<sup>ID</sup>

Amir Mohammad Khani\*\*\*<sup>ID</sup>

### Extended Abstract

**Introduction and Objectives:** In today's In a highly competitive environment, recruitment decisions can no longer rely only on human judgment. The increasing volume of applicant data and the complexity of the search for candidate attributes and high precision in the selection of personnel have become a need. Artificial intelligence (AI) and machine learning have been chosen as the only solution to such a problem. (ML) a strategic necessity for organizations. Despite that, classical ML models, such as decision trees and logistic regression, are giving acceptable However, when results are applied to imbalanced datasets, complex data structure setups, and high accuracy requirements, they are greatly limited. This study aims to achieve a hybrid machine learning model designed on the forces of both kinds of neural networks as well as the classical algorithms. I demonstrate how to deliver a powerful, accurate, and interpretable solution to predict recruitment outcomes.

**Methods:** A multi layer stacking architecture was used to develop the proposed model, in which Deep Neural Network (DNN) is employed with four of the high performing base learners such as Random Forest, Gradient Boosting, LightGBM and CatBoost. Finally, XGBoost was used as meta learner to learn the final prediction from the outputs of these base models. To handle the class imbalance problem, NearMiss undersampling technique was tried and we used the Tree structured Parzen Estimator (TPE) algorithm provided as a part of the Optuna framework for hyperparameter optimization. Additionally, Recursive Feature Elimination with Cross Validation (RFECV) was used for feature selection to find the most important variables related to the hiring decisions.

Received : Jun. 04, 2025; Revised : Aug. 04, 2025; Accepted : Feb. 26, 2026; Published Online : Feb. 27, 2026.

\* Professor, Department of Industrial Management, Faculty of Industrial Management and Technology, College of Management, University of Tehran, Tehran, Iran.

Corresponding Author : mehregan@ut.ac.ir

\*\* Ph.D. Candidate, Department of Industrial Management, Faculty of Industrial Management and Technology, College of Management, University of Tehran, Tehran, Iran.

\*\*\* Ph.D. Candidate, Department of Industrial Management, Faculty of Industrial Management and Technology, College of Management, University of Tehran, Tehran, Iran.



**Findings:** The proposed hybrid model has been evaluated on a sample dataset of 1500 samples against 16 well-known machine learning models. Results indicated that the proposed model surpassed all key performance metrics in all areas of accuracy, precision, recall and F1 score with an accuracy of 92.47% and F1 score of 92.12%. There were some other models such as CatBoost and LightGBM that also had good scores, no other models performed better than those metrics reported for the proposed model. Likewise, the feature importance assessment of the same dataset with the help of XGBoost displayed that the recruitment strategy, education level, and interview score were the major predictors of final hiring decisions. These findings were not only beneficial in improving model performance but also valuable for improving the research and data examination of the HR decision makers in relation to the policies and criteria used in recruitment.

**Conclusion:** This research develops the hybrid machine learning model that smoothly combines classical algorithms and deep learning by a stacked architecture, which provides an advanced and highly effective structure for predicting hiring outcomes accurately. The model achieved both statistical superiority in benchmark comparisons and practical benefits. These findings imply that the usage of such hybrid models can rewrite the context for intelligent HR systems by streamlining candidate evaluation as faster, fairer, and more data-driven. In addition, HR managers receive focused, evidence-based feedback from feature analysis when predicting with modeling. Future work involving larger datasets and unstructured data such as resumes and interview videos coupled with tools for making the black box more explainable, such as SHAP or LIME, is encouraged to add transparency and build organizational trust in AI-based decision-making systems.

**Keywords:** Hybrid Machine Learning, Deep Learning, Recruitment Prediction, Parameter Optimization, Intelligent Human Resources.

**How to Cite:** Mehreganan, Mohammad Reza; Rezasoltani, Arman; Khani, Amir Mohammad (2026). A Novel Hybrid Machine Learning Model Based on Deep Learning for Predicting Recruitment Decisions. *Ind. Manag. Persp.*, 16(1), 170-196 (In Persian).



## ارائه یک مدل نوآورانه یادگیری ماشین ترکیبی مبتنی بر یادگیری عمیق برای پیش‌بینی تصمیمات استخدامی

محمد رضا مهرگان\*

آرمان رضا سلطانی\*\*

امیر محمد خانی\*\*\*

### چکیده گسترده

**مقدمه و اهداف:** در عصر رقابتی امروز، تصمیمات استخدامی دیگر نمی‌توانند صرفاً بر قضاوت‌های انسانی تکیه داشته باشند. با افزایش حجم داده‌ها، پیچیدگی ویژگی‌های متقاضیان و ضرورت دقت بالا در انتخاب نیروی انسانی، بهره‌گیری از هوش مصنوعی و یادگیری ماشین به یک الزام راهبردی برای سازمان‌ها تبدیل شده است. اگرچه مدل‌های یادگیری ماشین کلاسیک، مانند درخت تصمیم یا رگرسیون لجستیک، نتایج قابل قبولی داشته‌اند، اما این مدل‌ها در مواجهه با داده‌های نامتوازن، ساختارهای پیچیده و نیاز به دقت بالا، محدودیت‌های جدی دارند. پژوهش حاضر با هدف طراحی یک مدل یادگیری ماشین ترکیبی مبتنی بر یادگیری عمیق انجام شده که بتواند با ترکیب مزایای شبکه‌های عصبی و الگوریتم‌های یادگیری ماشین جمعی پیشرفته، مدلی قدرتمند، دقیق و تفسیرپذیر برای پیش‌بینی تصمیمات استخدامی ارائه دهد.

**روش‌ها:** برای توسعه مدل پیشنهادی، از یک ساختار استکینگ چندلایه استفاده شده است که در آن شبکه عصبی عمیق (DNN) به همراه ۴ الگوریتم قدرتمند شامل Random Forest، Gradient Boosting، LightGBM و CatBoost به‌عنوان مدل‌های پایه عمل می‌کنند. خروجی این مدل‌ها به XGBoost به‌عنوان فرامدل منتقل می‌شود تا پیش‌بینی نهایی انجام شود. برای متوازن‌سازی مجموعه داده نامتوازن، از روش NearMiss استفاده شده و برای تنظیم بهینه پارامترها، الگوریتم TPE در چارچوب Optuna به کار رفته است. همچنین، فرآیند انتخاب ویژگی‌ها با روش حذف بازگشتی با اعتبارسنجی متقاطع (RFECV) انجام شده تا مهم‌ترین متغیرهای مؤثر بر تصمیم استخدام شناسایی شوند.

تاریخ دریافت: ۱۴۰۴/۰۳/۱۴، تاریخ بازنگری: ۱۴۰۴/۰۵/۱۳، تاریخ پذیرش: ۱۴۰۴/۱۲/۰۷، تاریخ اولین انتشار: ۱۴۰۴/۱۲/۰۸.

\*استاد، گروه مدیریت صنعتی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران.

نویسنده مسئول: mehregan@ut.ac.ir

\*\*دانشجوی دکتری، گروه مدیریت صنعتی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران.

\*\*\*دانشجوی دکتری، گروه مدیریت صنعتی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران.



**یافته‌ها:** مدل ترکیبی پیشنهادی بر روی یک مجموعه داده نمونه شامل ۱۵۰۰ نمونه در برابر ۱۶ مدل یادگیری ماشین شناخته شده ارزیابی شده است. نتایج نشان داد که مدل پیشنهادی در تمام زمینه‌های دقت، صحت، فراخوانی و امتیاز F1 باصحت ۹۲.۴۷٪ و امتیاز F1 ۹۲.۱۲٪ از تمام معیارهای کلیدی عملکرد پیشی گرفته است. برخی مدل‌های دیگر مانند CatBoost و LightGBM نیز نمرات خوبی داشتند، اما هیچ مدل دیگری بهتر از معیارهای گزارش شده برای مدل پیشنهادی عمل نکرد. افزون بر این، تحلیل اهمیت ویژگی‌ها (Feature Importance) که با بهره‌گیری از الگوریتم XGBoost انجام شد، نشان داد که متغیرهایی مانند «استراتژی جذب نیرو»، «سطح تحصیلات» و «امتیاز مصاحبه» بیشترین سهم را در پیش‌بینی نتیجه نهایی استفاده داشتند. این نتایج نه تنها موجب بهبود اثربخشی مدل در پیش‌بینی تصمیمات استخدامی شد، بلکه با شفاف‌سازی عوامل مؤثر، اطلاعات ارزشمندی را برای تصمیم‌گیرندگان منابع انسانی فراهم کرد که می‌توانند بر پایه آن سیاست‌های جذب و ارزیابی خود را بازطراحی کنند.

**نتیجه‌گیری:** مدل ترکیبی یادگیری ماشین ارائه شده در این پژوهش، با تلفیق منسجم الگوریتم‌های کلاسیک و ساختارهای یادگیری عمیق در قالب معماری استکینگ چندلایه، چارچوبی نوین و اثربخش برای پیش‌بینی دقیق تصمیمات استخدامی فراهم کرده است. این مدل نه تنها در آزمون‌های عددی و مقایسه‌ای عملکرد ممتاز و پایداری از خود نشان داده، بلکه از نظر کاربردی نیز واجد ویژگی‌هایی چون تفسیرپذیری، تعمیم‌پذیری و انعطاف‌پذیری است. دستاوردهای پژوهش حاکی از آن است که بهره‌گیری از چنین مدل‌های ترکیبی می‌تواند منجر به تحول اساسی در سیستم‌های تصمیم‌یار منابع انسانی شود و فرآیند انتخاب و ارزیابی متقاضیان شغلی را هوشمندانه‌تر، سریع‌تر و عادلانه‌تر سازد. از سوی دیگر، تلفیق تحلیل ویژگی‌ها با تکنیک‌های پیش‌بینی، امکان ارائه بازخورد هدفمند و داده‌محور به مدیران جذب نیرو را نیز فراهم می‌سازد. با توجه به این نتایج امیدبخش، پیشنهاد می‌شود در تحقیقات آتی از مجموعه داده‌های بزرگ‌تر، داده‌های غیرساختاریافته مانند رزومه‌های متنی، و مصاحبه‌های ویدیویی استفاده شود.

**کلیدواژه‌ها:** یادگیری ماشین ترکیبی، یادگیری عمیق، پیش‌بینی استخدام، بهینه‌سازی پارامترها، منابع انسانی هوشمند.

**استناددهی:** مهرگان، محمدرضا؛ رضاسلطانی، آرمان؛ خانی، امیرمحمد (۱۴۰۵). ارائه یک مدل نوآورانه یادگیری ماشین ترکیبی مبتنی بر یادگیری عمیق برای پیش‌بینی تصمیمات استخدامی. چشم‌انداز مدیریت صنعتی، ۱۶(۱)، ۱۷۰-۱۹۶.



## ۱. مقدمه

در دنیای پرشتاب و رقابتی امروز، منابع انسانی به‌عنوان اصلی‌ترین سرمایه سازمان‌ها نقشی کلیدی در موفقیت یا شکست آنها ایفا می‌کنند. فرآیند جذب و استخدام نیروی انسانی، از جمله مهم‌ترین تصمیمات راهبردی در حوزه مدیریت منابع انسانی به شمار می‌رود، چرا که انتخاب فردی مناسب نه تنها بهره‌وری سازمان را افزایش می‌دهد، بلکه در بلندمدت به حفظ مزیت رقابتی نیز کمک می‌کند. با این حال، این تصمیمات همواره با پیچیدگی‌های فراوانی همراه هستند؛ عواملی چون تنوع ویژگی‌های متقاضیان، وجود داده‌های گسترده و نامتوازن، و دشواری در سنجش دقیق پتانسیل‌ها، فرآیند انتخاب را به یک چالش جدی تبدیل کرده‌اند [۶۱، ۱۶، ۸]. در چنین شرایطی، استفاده از فناوری‌های نوین همچون یادگیری ماشین و هوش مصنوعی به عنوان ابزارهای تصمیم‌یار، می‌تواند دقت و سرعت فرآیندهای استخدامی را به شکل چشم‌گیری افزایش دهد. یادگیری ماشین با قابلیت تحلیل حجم بالایی از داده‌ها و استخراج الگوهای پنهان در آنها، این امکان را فراهم می‌سازد که تصمیمات استخدامی از حالت شهودی و مبتنی بر قضاوت‌های فردی خارج شده و بر پایه داده‌های واقعی و الگوریتم‌های پیشرفته اتخاذ شوند [۲، ۶۳].

در سال‌های اخیر، مطالعات متعددی به بررسی کاربرد مدل‌های یادگیری ماشین در پیش‌بینی موفقیت استخدام پرداخته‌اند و نتایج آنها نشان می‌دهد که دقت پیش‌بینی‌ها به میزان قابل توجهی نسبت به روش‌های سنتی بهبود یافته است [۵، ۵۰]. با وجود این پیشرفت‌ها، همچنان خلأهای قابل توجهی در بدنه ادبیات علمی این حوزه به چشم می‌خورد. بسیاری از پژوهش‌های پیشین، یا صرفاً به استفاده از الگوریتم‌های کلاسیک همچون درخت تصمیم، رگرسیون لجستیک یا جنگل تصادفی بسنده کرده‌اند و یا در بهره‌برداری از ظرفیت‌های یادگیری عمیق، به محدودیت‌های فنی و محاسباتی برخورد کرده‌اند [۵]. علاوه بر این، اغلب این مطالعات به چالش‌هایی مانند نامتوازن بودن داده‌ها، انتخاب ویژگی‌های مؤثر و بهینه‌سازی دقیق هایپرپارامترها توجه کافی نداشته‌اند. به عنوان مثال، تحقیقات گذشته معمولاً از روش‌های سنتی مانند Grid Search برای تنظیم پارامترها استفاده کرده‌اند که کارایی کمتری در فضای‌های جستجوی بزرگ و پیچیده دارد [۲۴].

با وجود پیشرفت‌های اخیر در استفاده از یادگیری ماشین برای پیش‌بینی تصمیمات استخدامی، مرور ادبیات نشان می‌دهد که چند کاستی اساسی همچنان باقی مانده است. نخست، بسیاری از پژوهش‌های پیشین به استفاده از الگوریتم‌های سنتی منفرد یا ترکیب‌های محدود بسنده کرده‌اند که توانایی کافی در استخراج الگوهای پیچیده و غیرخطی از داده‌های واقعی را ندارند. دوم، مسأله نامتوازن بودن داده‌ها که یکی از چالش‌های جدی در حوزه استخدام است، اغلب یا نادیده گرفته شده یا با روش‌های ساده و کم‌اثر مدیریت شده است. سوم، بهینه‌سازی پارامترها در اغلب این مطالعات با روش‌های سنتی مانند جستجوی شبکه‌ای انجام شده که در فضاهای جستجوی بزرگ کارایی پایینی دارد. این محدودیت‌ها باعث شده است که مدل‌های موجود، علیرغم دستیابی به دقت قابل قبول در برخی شاخص‌ها، نتوانند در تمام معیارهای کلیدی عملکرد برتری همزمان داشته باشند.

پژوهش حاضر با هدف پاسخ به چالش‌های پیش‌گفته، به طراحی و پیاده‌سازی یک مدل یادگیری ماشین ترکیبی مبتنی بر یادگیری عمیق پرداخته است که در قالب معماری استکینگ چندلایه، از ظرفیت‌های الگوریتم‌های متنوع بهره می‌برد. وجه تمایز این پژوهش در چند جنبه کلیدی نهفته است: نخست، ترکیب هدفمند الگوریتم‌های یادگیری عمیق و یادگیری ماشین جمعی پیشرفته با رویکرد استکینگ که قدرت تعمیم بالاتری را برای مدل ایجاد می‌کند؛ دوم، مدیریت اصولی داده‌های نامتوازن با به‌کارگیری روش‌های undersampling پیشرفته و سوم، استفاده از تکنیک‌های بهینه‌سازی خودکار و هوشمند برای تنظیم پارامترهای مدل‌ها که سبب ارتقای چشمگیر عملکرد سیستم شده است. اهمیت این تحقیق نه تنها در بهبود عملکرد پیش‌بینی مدل، بلکه در ارائه چارچوبی قابل پیاده‌سازی برای استفاده عملی در سیستم‌های منابع انسانی سازمان‌هاست. با ارائه تحلیلی دقیق از اهمیت ویژگی‌ها، این پژوهش به مدیران منابع انسانی کمک می‌کند تا در فرآیند غربالگری و جذب نیرو، تصمیمات خود را بر پایه داده‌ها و تحلیل‌های علمی اتخاذ کنند. همچنین، ارائه بینش‌های کاربردی در خصوص تأثیر ویژگی‌هایی مانند استراتژی جذب، سطح تحصیلات و امتیاز مصاحبه در نتایج استخدام، می‌تواند نقش مهمی در بازنگری سیاست‌های جذب و ارتقای اثربخشی فرآیندهای استخدامی داشته باشد.

ساختار مقاله حاضر به‌گونه‌ای طراحی شده که در بخش اول، مبانی نظری مرتبط با یادگیری ماشین ترکیبی و چالش‌های پیش‌بینی در تصمیمات استخدامی مرور می‌شود. در بخش دوم، جزئیات روش تحقیق شامل مراحل پیش‌پردازش، انتخاب ویژگی‌ها، طراحی مدل ترکیبی، و بهینه‌سازی پارامترها تشریح می‌شود. در بخش سوم، یافته‌های حاصل از آزمایش مدل بر روی داده‌های واقعی ارائه شده و عملکرد آن با سایر الگوریتم‌های رایج مقایسه می‌شود. در نهایت، مقاله با بحث پیرامون نتایج، ارائه پیشنهاد‌های کاربردی و ترسیم مسیرهای آتی برای تحقیقات مشابه به پایان می‌رسد.

## ۲. مبانی نظری و پیشینه پژوهش

**پیش‌بینی تصمیمات استخدامی.** مبانی نظری زیربنای پیش‌بینی تصمیم‌های استخدام ریشه در همگرایی تجزیه و تحلیل منابع انسانی (HR)، مدل‌سازی پیش‌بینی‌کننده و برنامه‌ریزی نیروی کار دارد. چارچوب‌های اولیه بر همسویی سرمایه انسانی با استراتژی سازمانی تأکید می‌کنند که به موجب آن تحلیل‌های پیش‌بینی‌کننده در برنامه‌ریزی نیروی کار برای پیش‌بینی تقاضا، پرکردن شکاف‌های مهارتی و بهینه‌سازی تخصیص منابع ادغام می‌شود [۵، ۵۰]. چنین مدل‌هایی معیارهای مشتق‌شده از صلاحیت‌های متقاضی، تجربه کاری و اطلاعات جمعیت‌شناختی را در بر می‌گیرند و از رویکرد داده‌محور پشتیبانی می‌کنند که روش‌های سنتی را با تصمیم‌گیری سیستماتیک و مبتنی بر شواهد جایگزین می‌کند [۳۷، ۵۰]. مرکز این پارادایم، کاربرد تکنیک‌های پیشرفته یادگیری ماشینی و پیش‌بینی آماری است. محققان نشان داده‌اند که ساخت مدل‌های پیش‌بینی با استفاده از ابزارهایی مانند رگرسیون لجستیک، درخت‌های تصمیم‌گیری، و روش‌های خوشه‌بندی - پیش‌بینی موفقیت نامزد استخدام و حفظ بالقوه شانس استخدام را ممکن می‌سازد [۳۸]. علاوه بر این، مطالعات تجربی نشان داده‌اند که ادغام این مدل‌ها در سیستم‌های منابع انسانی مبتنی بر ابر، به‌ویژه از طریق پلتفرم‌هایی مانند SAP HCM، به نتایج استخدام بهتر کمک می‌کند و چابکی و پاسخگویی نیروی کار را تقویت می‌کند [۱۰]. ایجاد سیستم‌های پشتیبانی تصمیم که از پلتفرم‌های کلان داده مانند Hadoop استفاده می‌کنند، صحت و دقت این مدل‌های پیش‌بینی را افزایش می‌دهد [۱۲].

پشتوانه این نوآوری‌های تکنولوژیکی چندین دیدگاه نظری کلیدی است. دیدگاه مبتنی بر منابع و تئوری سرمایه انسانی یک چارچوب مفهومی ارائه می‌کند و پیشنهاد می‌کند که سرمایه‌گذاری در سرمایه انسانی باعث ایجاد مزیت‌های رقابتی بلندمدت و عملکرد سازمانی می‌شود [۴۷]. در این زمینه، تجزیه و تحلیل استعداد به عنوان یک ابزار تحول‌آفرین عمل می‌کند و از یک رویکرد داده چند بعدی برای پیش‌بینی نتایج حفظ و عملکرد نامزدها استفاده می‌کند، در نتیجه تصمیمات استخدام را با یک لنز استراتژیک آینده نگر آگاه می‌کند [۵۸]. علاوه بر این، ادغام هوش مصنوعی (AI) و یادگیری ماشین در شیوه‌های استخدام، روش‌های سنتی منابع انسانی را با کاهش سوگیری‌ها و تسریع در فرآیند تصمیم‌گیری، تقویت کرده است، و تضمین می‌کند که فرآیند انتخاب هم کارآمد و هم با اهداف سازمانی هماهنگ است [۳۹]. در نهایت، پیش‌بینی تصمیم‌های استخدام به‌عنوان یک ساختار چندوجهی است که نه تنها شامل مدل‌های پیش‌بینی کمی می‌شود، بلکه به یکپارچگی نظری برنامه‌ریزی استراتژیک نیروی کار، مدیریت استعداد، و نظریه‌های منابع سازمانی نیز نیاز دارد. این ادغام با تسهیل تصمیم‌گیری چابک و مبتنی بر شواهد و با تقویت شناسایی پیشگیرانه نیازهای نیروی کار آینده، از تحول سیستماتیک شیوه‌های منابع انسانی پشتیبانی می‌کند [۵، ۱۰، ۵۰]. در مجموع، زیربنای نظری مدل‌های استخدام پیش‌بینی‌کننده نشان می‌دهد که چگونه می‌توان از تحلیل‌های پیشرفته برای تبدیل فرآیندهای متداول منابع انسانی به قابلیت‌های سازمانی پویا، استراتژیک و رقابتی استفاده کرد.

**یادگیری ماشین ترکیبی مبتنی بر یادگیری عمیق.** یادگیری ماشین ترکیبی مبتنی بر یادگیری عمیق، الگوی نوظهوری را نشان می‌دهد که قدرت بیانی شبکه‌های عصبی عمیق را با استحکام و تفسیرپذیری الگوریتم‌های یادگیری ماشین کلاسیک ادغام می‌کند. مبانی نظری این سیستم‌ها بر مفاهیمی از یادگیری عمیق و یادگیری ماشین سنتی بنا شده است، جایی که مدل‌های ترکیبی با هدف جبران محدودیت‌های هر رویکرد فردی با استفاده از نقاط قوت مکمل آنها، ساخته شده‌اند. برای مثال، شبکه‌های عمیق در استخراج خودکار ویژگی‌ها و مدیریت داده‌های

بدون ساختار در مقیاس بزرگ برتری دارند، در حالی که مدل‌های مرسوم مانند ماشین‌های بردار پشتیبان (SVM) یا درخت‌های تصمیم، مرزهای تصمیم‌گیری واضح و کارایی محاسباتی را برای وظایف ساختار یافته فراهم می‌کنند [۶۲]. علاوه بر این، ادغام این رویکردها منجر به سیستم‌هایی می‌شود که روابط پیچیده‌تری را در داده‌ها بهتر به تصویر می‌کشند، پیش‌بینی‌های دقیق‌تر و بهبود عملکرد تصمیم را ممکن می‌سازند [۱۴]. از منظر نظری، چارچوب‌های یادگیری عمیق ترکیبی اغلب بر اصول یادگیری جمعی و ادغام داده‌های چندوجهی استوار است، جایی که مدل‌های متنوع برای غلبه بر ضعف‌های ذاتی در رویکردهای تک مدلی ترکیب می‌شوند. روش‌های مجموعه یک مبادله بایاس - واریانس را ارائه می‌کنند که می‌تواند با ترکیب شبکه‌های عصبی عمیق با تکنیک‌های یادگیری ماشین سنتی کنترل شود و در نتیجه عملکرد پیش‌بینی کلی را بهبود بخشد [۱۴]. این ادغام از تحلیل‌های نظری بهینه‌سازی غیرمحدب در یادگیری عمیق سود می‌برد، جایی که نشان داده شده است که تحت شرایط خاص، معماری‌های عمیق می‌توانند به بهینه جهانی حتی در مناظر غیر محدب دست یابند [۲۹]. چنین یافته‌ای منطق ادغام این مدل‌ها را تقویت می‌کند، زیرا ویژگی‌های همگرایی معماری‌های عمیق را می‌توان با ترکیب استراتژیک عناصر از روش‌های کلاسیک که ریشه در بهینه‌سازی محدب و نظریه یادگیری آماری دارند، بهبود بخشید [۵۲].

مدل‌های یادگیری ماشین ترکیبی از نظر معماری ممکن است چندین استراتژی طراحی را اتخاذ کنند. یکی از رویکردهای رایج استفاده از مدل‌های یادگیری عمیق برای استخراج ویژگی و به دنبال آن ابزارهای یادگیری ماشین کلاسیک مانند جنگل‌های تصادفی یا SVM برای طبقه‌بندی یا رگرسیون است. این روش دومرحله‌ای با موفقیت در حوزه‌های پیچیده مانند تجزیه و تحلیل تصویر پزشکی استفاده شده است، جایی که مدل‌های ترکیبی قابلیت‌های یادگیری ویژگی شبکه‌های عمیق از پیش آموزش دیده را با استحکام تصمیم‌گیری طبقه‌بندی‌کننده‌های گروه ترکیب می‌کنند [۲۳]. علاوه بر این، معماری‌های ترکیبی جایگزین، مانند ادغام رمزگذارهای خودکار حذف نویز در مدل‌های احتمالی، برای رسیدگی به مشکلات یادگیری نیمه نظارت شده فرمول بندی شده‌اند، که بیشتر بر هم‌افزایی نظری بین نمایش‌های عمیق و روش‌های آماری کلاسیک تأکید می‌کند [۱۴]. استراتژی‌های بهینه‌سازی همچنین بخش مهمی از زیربنای نظری یادگیری عمیق ترکیبی را تشکیل می‌دهند. رفتار همگرایی شبکه‌های عصبی عمیق، علی‌رغم عدم تحدب ذاتی آنها، توسط اصول کشف شده توسط تحقیقات اخیر هدایت می‌شود، که نشان می‌دهد، تحت شرایط خاص، هر حداقل محلی می‌تواند یک حداقل جهانی باشد [۲۹]. با ادغام این بینش‌های نظری با تکنیک‌های بهینه‌سازی به‌خوبی درک شده یادگیری ماشین کلاسیک، مدل‌های ترکیبی می‌توانند مسائل رایجی مانند بیش‌برازش و بهینه‌سازی محلی را کاهش دهند. تحلیل‌های ریاضی دقیقی که از این استراتژی‌ها پشتیبانی می‌کنند، از جمله ملاحظات سوگیری، واریانس، و پیچیدگی محاسباتی، برای طراحی سیستم‌های ترکیبی که نه تنها دقیق هستند، بلکه از نظر محاسباتی نیز قابل حمل هستند، اساسی هستند [۲۹، ۵۲].

در سال‌های اخیر، با رشد سریع فناوری‌های یادگیری ماشین و تجزیه و تحلیل پیش‌بینی‌کننده، پژوهش‌های متعددی به بررسی استفاده از مدل‌های ترکیبی یادگیری ماشین برای بهبود فرآیند برنامه‌ریزی نیروی انسانی و پیش‌بینی استخدام پرداخته‌اند. این مطالعات با بهره‌گیری از ترکیب الگوریتم‌های آماری و یادگیری عمیق، به دنبال افزایش دقت پیش‌بینی، بهینه‌سازی تخصیص منابع انسانی و ارتقای کارایی فرآیند جذب نیرو بوده‌اند. در جدول ۱، خلاصه‌ای از مهم‌ترین پژوهش‌های انجام شده در این حوزه ارائه می‌شود. هر ردیف شامل نویسندگان، عنوان مقاله، هدف مطالعه، مدل ارائه شده، خروجی مدل و نتایج کلیدی است. جدول شماره یک نمای کلی از روند پیشرفت علمی در زمینه مدل‌های پیش‌بینی استخدام ارائه می‌دهد و چارچوبی برای توسعه پژوهش‌های آتی فراهم می‌کند.

جدول ۱. پیشینه پژوهش

نویسندگان	عنوان مقاله	هدف	مدل ارائه شده	خروجی مدل	نتایج
آفاق <sup>۱</sup> (۲۰۲۵) [۵]	یکپارچه‌سازی تجزیه و تحلیل پیش‌بینی برای برنامه‌ریزی نیروی کار	توسعه مدل‌های پیش‌بینی برای بهینه‌سازی برنامه‌ریزی نیروی انسانی در بازاریابی	Neural Networks + Decision Trees + Linear Regression + Time Series Forecasting	Accuracy = 91/5%, AUC = 0/88, Decision Tree : Accuracy = 88/2%	پیش‌بینی نیاز نیروی انسانی، بهبود تخصیص منابع، بهبود کارایی عملیاتی
یاسین و سعید (۲۰۲۴) [۵۶]	استخدام پیش‌بینی‌کننده و هوش مصنوعی: افزایش استخدام با شبکه‌های عصبی بهینه و نزول گرادیان	بهبود فرآیند استخدام با مدل ترکیبی NN و SGD	Neural Network + Logistic Regression + Discriminant Analysis	. Accuracy ≈ 87%	بهبود صحت پیش‌بینی و کارایی استخدام
کندو و سرواوان پالانی <sup>۲</sup> (۲۰۲۴) [۳۱]	بررسی پتانسیل الگوریتم‌های هوش مصنوعی و ML در فرآیند استخدام	پیش‌بینی امکان استخدام با داده‌های ده ساله	ترکیب چند الگوریتم ML	Recall = 92%, Accuracy = 93%	کشف عوامل تاثیرگذار و صحت بالای پیش‌بینی
واهوینینگ و سودیبیو <sup>۳</sup> (۲۰۲۴) [۵۸]	استفاده از یادگیری ماشین برای جذب استعداد: پیش‌بینی داوطلبان با عملکرد بالا در مدیریت منابع انسانی	پیش‌بینی عملکرد بالای متقاضیان با ML	Random Forest	F1-Score . Accuracy = 87% = 0/86	صحت ۸۷ درصد، شناسایی ویژگی‌های کلیدی متقاضیان
گهار <sup>۴</sup> و همکاران (۲۰۲۳) [۴۷]	پیش‌بینی افراد مستعد تغییر شغل	پیش‌بینی تمایل کارمندان به تغییر شغل	RF + LR + DT + XGBoost	F1-Score . Accuracy = 88% = 0/87	ارتقای عملکرد با SMOTE، بهبود معیارهای تصمیم‌گیری
سها <sup>۵</sup> و همکاران (۲۰۲۳) [۴۹]	توصیه شغلی: یک رویکرد ترکیبی با استفاده از پردازش متون	پیشنهاد شغلی با پردازش متن	Hybrid (Content-based + Case-based) + RF	Accuracy = 90%	بهبود دقت و مقیاس‌پذیری سیستم‌های توصیه‌گر شغلی
یاسین و سعید (۲۰۲۳) [۶۳]	پیااده‌سازی هوش مصنوعی در HRM: استفاده از یادگیری ماشینی برای سیستم‌های استخدام هوشمند	بهبود سیستم‌های پیش‌بینی عملکرد شغلی	KNN + LR + SVM	Accuracy = 85%-88%, Precision = 85%, Recall = 84%	بهبود ارزیابی متقاضیان و ارائه بینش‌های کاربردی
لی <sup>۶</sup> و همکاران (۲۰۲۲) [۳۲]	مدل پیش‌بینی تقاضای جذب منابع انسانی بر پایه شبکه عصبی پس‌انتشار همکارانه کانولوشنی	پیش‌بینی نیاز به نیروی انسانی	CNN + BP Neural Network	Precision . Accuracy = 89% Recall = 90%, = 88%	افزایش صحت پیش‌بینی و کاهش خطای انسانی

1. Afaq
2. Kundu and Saravanan Palani
3. Wahyuning and Sudibyo
4. Gahar
5. Saha
6. Li



نویسندگان	عنوان مقاله	هدف	مدل ارائه شده	خروجی مدل	نتایج
کریشنایا و هولکر کادگودا <sup>۱</sup> (۲۰۲۲) [۳۰]	پیش‌بینی اشتغال دانشجویان کارشناسی مهندسی با استفاده از رویکرد ترکیبی در یادگیری ماشین	پیش‌بینی اشتغال فارغ‌التحصیلان مهندسی با رویکرد ترکیبی	MLP + RBF + K-Means	Accuracy = 91%	پیش‌بینی موفق با صحت بالا بر اساس سوابق تحصیلی و شخصیتی
ردی و همکاران <sup>۲</sup> (۲۰۲۰) [۲۴]	پیش‌بینی استخدام با استفاده از یادگیری ماشین	پیش‌بینی موفقیت استخدام پیش از انتخاب رزومه	LR + DT + RF	Accuracy = 87%-90% Precision/Recall > 85%	کاهش هزینه و زمان در فرآیند جذب
پساج و همکاران <sup>۳</sup> (۲۰۲۰) [۴۳]	جذب کارکنان: رویکردی تجویزی با استفاده از تحلیل پیش‌گویانه، یادگیری ماشین و برنامه‌ریزی ریاضی	توسعه یک چارچوب تحلیلی برای پیش‌بینی موفقیت استخدام و بهینه‌سازی فرآیند جذب	Variable-Order Bayesian Network (VOBN) + Mathematical Programming برای بهینه‌سازی	VOBN برای AUC = 0/705 (دقت پیش‌بینی قابل قبول با قابلیت تفسیر)، AUC = 0/73 برای GBM (دقت بالاتر، فاقد تفسیرپذیری)	تنوع متوازن و موفقیت در استخدام ها.

مرور نظام‌مند پژوهش‌های پیشین نشان می‌دهد که اگرچه مدل‌های یادگیری ماشین در پیش‌بینی تصمیمات استخدامی به‌کار گرفته شده‌اند، اما این مطالعات با چند محدودیت اساسی مواجه بوده‌اند. نخست، بیشتر پژوهش‌ها (مانند آفاق، ۲۰۲۴؛ یاسین و سعید، ۲۰۲۳) یا از الگوریتم‌های کلاسیک منفرد نظیر درخت تصمیم، رگرسیون لجستیک یا جنگل تصادفی استفاده کرده‌اند و یا نهایتاً ترکیب محدودی از مدل‌های سنتی را به کار بسته‌اند، بدون آنکه از معماری‌های پیشرفته‌ای همچون استکینگ چندلایه یا شبکه‌های عصبی عمیق برای استخراج ویژگی‌های پیچیده بهره‌گیرند. دوم، مسأله نامتوازن بودن داده‌ها که در مسائل واقعی استخدام بسیار شایع است، در بسیاری از مطالعات پیشین (مانند ساها و همکاران، ۲۰۲۲؛ ردی و همکاران، ۲۰۱۹) یا نادیده گرفته شده یا تنها با روش‌های ساده و کم‌اثر مدیریت شده است. سوم، اغلب پژوهش‌ها از روش‌های سنتی و کم‌بازده مانند جستجوی شبکه‌ای (Grid Search) برای بهینه‌سازی پارامترها استفاده کرده‌اند که در فضاهای جستجوی بزرگ کارایی محدودی دارد، در حالی که روش‌های نوین و تطبیقی مانند الگوریتم TPE در چارچوب Optuna مورد استفاده قرار نگرفته‌اند. چهارم، بسیاری از مطالعات تنها بر شاخص صحت (Accuracy) تمرکز کرده و از ارزیابی چندمعیاری شامل دقت (Precision)، بازخوانی (Recall) و امتیاز F1 که در داده‌های نامتوازن ضروری هستند، غفلت کرده‌اند. پنجم، در بخش عمده‌ای از ادبیات، تحلیل اهمیت ویژگی‌ها یا انجام نشده و یا نتایج آن به سیاست‌گذاری عملی در حوزه منابع انسانی پیوند نخورده است.

پژوهش حاضر با طراحی یک مدل ترکیبی مبتنی بر یادگیری عمیق در قالب معماری استکینگ چندلایه، مدیریت سیستماتیک داده‌های نامتوازن با استفاده از روش NearMiss، بهینه‌سازی جامع پارامترها از طریق Optuna و الگوریتم TPE و ارزیابی کامل با چهار شاخص کلیدی، به‌طور مستقیم این شکاف‌ها را پوشش داده است. علاوه بر این، تحلیل اهمیت ویژگی‌ها و استخراج بینش‌های کاربردی برای بهبود سیاست‌های جذب نیرو، بعد عملی و تصمیم‌یار این تحقیق را تقویت کرده است. این رویکرد نه‌تنها با توصیه‌های اخیر در ادبیات مبنی بر ترکیب یادگیری عمیق و روش‌های جمعی برای ارتقای دقت پیش‌بینی در مسائل پیچیده استخدام (آیژان تورسونبایوا<sup>۴</sup> و همکاران، ۲۰۲۴؛ آگیلار-روئیز و میچالاک<sup>۵</sup>، ۲۰۲۳) همسوست، بلکه با افزودن لایه‌ای از تفسیرپذیری و قابلیت اجرا در شرایط واقعی، گامی فراتر از مطالعات پیشین برداشته و مسیر توسعه سیستم‌های هوشمند تصمیم‌یار در مدیریت منابع انسانی را هموار کرده است.

1. Krishnaiah and Hullekere Kadegowda
2. Reddy
3. Pessach
4. Aizhan Tursunbayeva
5. Aguilar-Ruiz and Michalak

## بیان مسئله و شکاف پژوهشی

### بیان مسئله

فرآیند جذب و استخدام یکی از مهم‌ترین و حساس‌ترین تصمیمات استراتژیک برای سازمان‌ها است، زیرا انتخاب فرد نامناسب می‌تواند منجر به عواقبی مانند از دست دادن بهره‌وری، افزایش نرخ ترک خدمت و همچنین هدر رفتن منابع انسانی و مالی شود. در محیط فعلی، با تشدید رقابت در بازار کار و حجم بسیار زیاد و متنوع داده‌های مرتبط با جویندگان کار، تصمیم‌گیری سنتی مبتنی بر قضاوت انسانی برای برآوردن نیازهای سازمان‌ها کافی نیست. اگرچه تصمیم‌گیری مبتنی بر شهود ممکن است در برخی موارد سرعت داشته باشد، اما به دلیل پیچیدگی داده‌ها، سوگیری‌های شناختی و عناصر ناشناخته ویژگی‌های شخصی و رفتاری متقاضی، با اثربخشی محدودی مواجه خواهد شد. در این میان، یادگیری ماشین و هوش مصنوعی به عنوان ابزارهای تصمیم‌یار نوین، ظرفیت بالایی برای تحلیل داده‌های چندبعدی و پیش‌بینی دقیق نتایج فرآیندهای استخدامی دارند. مدل‌های مختلف یادگیری ماشین می‌توانند روابط پنهان میان متغیرهایی همچون تحصیلات، تجربه کاری، مهارت‌ها، امتیازات مصاحبه و شاخص‌های رفتاری را کشف کرده و بر مبنای آن‌ها تصمیم نهایی استخدام را پیش‌بینی کنند. با این حال، مرور ادبیات نشان می‌دهد که مدل‌های موجود هنوز در تحقق دقت بالا، پایداری و تفسیرپذیری کافی در پیش‌بینی تصمیمات استخدامی با محدودیت‌هایی مواجه‌اند.

اکثر تحقیقات گذشته یا از الگوریتم‌های کلاسیک منفرد مانند درخت‌های تصمیم‌گیری، رگرسیون لجستیک یا جنگل‌های تصادفی استفاده کرده‌اند یا از ترکیب‌های ساده‌ای از چند مدل سنتی بدون بررسی پتانسیل شبکه‌های عصبی عمیق برای استخراج روابط پیچیده استفاده کرده‌اند. علاوه بر این، عدم تعادل داده‌های استخدام، یک مسئله واقعی و رایج در تجزیه و تحلیل منابع انسانی، در بسیاری از مطالعات گذشته نادیده گرفته شده است. در این شرایط، مدل‌ها به سمت پیش‌بینی بیش از حد طبقه غالب (یعنی متقاضی رد شده) متمایل می‌شوند که دقت مدل تمایز متقاضیان واجد شرایط از متقاضیان رد شده را کاهش می‌دهد. افزون بر آن، بیشتر مطالعات برای تنظیم پارامترهای مدل‌ها از روش‌های سنتی مانند Grid Search استفاده کرده‌اند که در فضاهای جستجوی پیچیده و چندبعدی کارایی محدودی دارد. از سوی دیگر، ارزیابی عملکرد مدل‌ها معمولاً تنها بر اساس شاخص صحت (Accuracy) انجام شده است، در حالی که برای داده‌های نامتوازن، استفاده از معیارهای چندگانه نظیر دقت (Precision)، بازخوانی (Recall) و امتیاز F1 ضروری است تا تصویر واقعی‌تری از عملکرد مدل ارائه شود.

با توجه به این چالش‌ها، مسئله‌ی اصلی تحقیق حاضر چنین تعریف می‌شود:

چگونه می‌توان با بهره‌گیری از ترکیب الگوریتم‌های یادگیری ماشین و یادگیری عمیق در قالب معماری استکینگ چندلایه، و با استفاده از روش‌های پیشرفته‌ای چون NearMiss برای متوازن‌سازی داده‌ها و Optuna-TPE برای بهینه‌سازی پارامترها، مدلی دقیق، تعمیم‌پذیر و تفسیرپذیر برای پیش‌بینی تصمیمات استخدامی ارائه کرد؟

پژوهش حاضر در پاسخ به این مسئله، چارچوبی نوآورانه ارائه می‌دهد که ضمن تلفیق نقاط قوت الگوریتم‌های یادگیری عمیق (در استخراج ویژگی‌های پیچیده) و روش‌های یادگیری جمعی (در افزایش پایداری و تعمیم‌پذیری)، می‌تواند ابزار مؤثری برای تصمیم‌سازی در فرآیند جذب و انتخاب نیروی انسانی باشد.

### شکاف پژوهشی

مرور نظام‌مند پژوهش‌های پیشین در حوزه پیش‌بینی تصمیمات استخدامی نشان می‌دهد که اگرچه کاربرد یادگیری ماشین در این حوزه رشد قابل توجهی داشته است، اما هنوز شکاف‌های نظری، فنی و کاربردی متعددی وجود دارد که پژوهش حاضر درصدد پر کردن آنهاست.

**۱. شکاف در ترکیب ساختاری مدل‌ها:** اغلب پژوهش‌های گذشته از یک یا دو الگوریتم کلاسیک به صورت مجزا استفاده کرده‌اند (مانند Logistic Regression، SVM یا Random Forest). و از معماری‌های ترکیبی چندلایه که بتوانند همزمان از توانایی یادگیری عمیق و یادگیری جمعی استفاده کنند، بهره‌مند نشده‌اند. این امر باعث محدودیت در شناسایی روابط غیرخطی و پیچیده بین متغیرهای انسانی شده است.

۲. **کاستی‌های داده‌های نامتوازن:** در بسیاری از مطالعات، رویکرد نامتوازن معمول، عدم تعادل داده‌ها بین داده‌های به‌کاررفته و غیربه‌کاررفته را پنهان می‌کند. عملکرد ضعیف مدل می‌تواند این واقعیت را نشان دهد، زیرا نمونه‌گیری کمتر/بیش از حد تصادفی اغلب منجر به هدر رفتن اطلاعات یا بدتر از آن، بیش‌برازش مدل می‌شود. مطالعه حاضر یک مسیر خاص و مفید برای پیاده‌سازی داده‌های نامتوازن با NearMiss ارائه داد.

۳. **شکاف بهینه‌سازی پارامتر:** اکثر مطالعات، تنظیم پارامتر را با استفاده از جستجوی شبکه‌ای پیاده‌سازی کرده‌اند، که معمولاً برای فضاهای پارامتری بزرگ، بسیار ناکارآمد و اغلب زمان‌بر است. در مقابل، این مطالعه در چارچوب Optuna از الگوریتم TPE برای به حداقل رساندن زمان جستجو و بازگرداندن بهترین مجموعه پارامتر ترکیبی با دقت بیشتر استفاده کرده است.

۴. **نقص در ارزیابی چندمعیاره عملکرد مدل:** ادبیات پیشین توجه خود را عمدتاً بر شاخص دقت معطوف کرده است، در حالی که سایر معیارهای عملکرد، مانند دقت، فراخوانی و امتیاز F1، توجه یکسانی را دریافت نکرده‌اند. عملکرد کلی با توجه به داده‌های نامتوازن، زمانی که صرفاً بر اساس دقت باشد، ممکن است گمراه‌کننده باشد. مطالعه حاضر از طریق ارزیابی چندمعیاره، وضوح بیشتری از عملکرد مدل ارائه می‌دهد.

۵. **نقص در نحوه تفسیر مدل‌ها و ارتباط آنها با تصمیمات سازمانی:** تقریباً همه مطالعات قبلی، تجزیه و تحلیل اهمیت ویژگی‌ها را به صورت دقیق و سیستماتیک انجام نداده‌اند و نتایج مدل مطالعه را در قالب سیاست‌ها و اقدامات واقعی در رویه‌های منابع انسانی تدوین نکرده‌اند. این بدان معناست که خروجی‌های مدل احتمالاً گاهی اوقات صرفاً فنی بوده‌اند و هیچ ارزش تصمیم‌گیری برای مدیر منابع انسانی ارائه نکرده‌اند. در مجموع، شکاف اصلی در ادبیات پیشین را می‌توان در نبود مدلی جامع، هوشمند و چندلایه دانست که ضمن دقت بالا، تعمیم‌پذیری و تفسیرپذیری لازم را در پیش‌بینی تصمیمات استخدامی داشته باشد. پژوهش حاضر با ترکیب ساختار استکینگ چندلایه، مدیریت هوشمند داده‌های نامتوازن و بهینه‌سازی خودکار پارامترها، گامی مؤثر در جهت پر کردن این خلأ علمی و کاربردی برداشته است.

### ۳. روش‌شناسی پژوهش

هدف اصلی این پژوهش، ایجاد مدلی با دقت بالا برای پیش‌بینی تصمیم‌نهایی استخدام بر اساس ویژگی‌های رفتاری، مهارتی و تحصیلی متقاضیان بود. برای این منظور، از یک چارچوب یادگیری ماشین ترکیبی جمعی استفاده شد که به‌صورت استکینگ طراحی گردید. در این ساختار، یک شبکه عصبی عمیق (DNN) به همراه ۴ الگوریتم قدرتمند شامل Random Forest، Gradient Boosting، LightGBM و CatBoost به‌عنوان مدل‌های پایه ایفای نقش کردند. خروجی این مدل‌ها به مدل XGBoost که به‌عنوان فرامدل عمل می‌کرد، داده شد تا تصمیم‌نهایی اتخاذ شود. به‌منظور افزایش دقت پیش‌بینی و جلوگیری از بیش‌برازش، فرآیند بهینه‌سازی دقیق هاپرپارامترهای تمامی مدل‌ها با استفاده از چارچوب Optuna و الگوریتم TPE انجام شد [۵۷]. مراحل پژوهش شامل توصیف ویژگی‌های مجموعه داده، پیش‌پردازش و متوازن‌سازی داده‌ها، تحلیل همبستگی و اهمیت ویژگی‌ها، انتخاب ویژگی‌ها، طراحی مدل پیشنهادی این پژوهش و مقایسه نتایج مدل هیبریدی با ۱۶ روش یادگیری ماشین براساس ۴ معیار ارزیابی با اعتبارسنجی متقاطع پنج‌تایی می‌باشد.

**ویژگی‌های داده‌ها و پیش‌پردازش.** داده‌های مورد استفاده در این پژوهش از پایگاه داده Kaggle گردآوری شده‌اند که یکی از منابع معتبر و شناخته‌شده برای ارائه مجموعه‌داده‌ها در حوزه یادگیری ماشین است. مطابق با جدول ۲، مجموعه داده مورد استفاده در این تحقیق شامل ۱۵۰۰ نمونه از متقاضیان شغلی بوده و شامل اطلاعات مربوط به ویژگی‌های جمعیت‌شناختی، تحصیلی، مهارتی، و رفتاری افراد و همچنین تصمیم‌نهایی استخدام (استخدام یا عدم‌استخدام) برای هر متقاضی می‌باشد و دربرگیرنده ۱۰ ویژگی مستقل و یک متغیر وابسته می‌باشد. متغیر هدف با عنوان HiringDecision بیانگر نتیجه نهایی فرآیند استخدام بوده و دارای دو کلاس است: کلاس ۰ برای متقاضیانی که استخدام نشده‌اند و کلاس ۱ برای افرادی که موفق به استخدام شده‌اند [۴۴].

جدول ۲. توصیف ویژگی‌ها

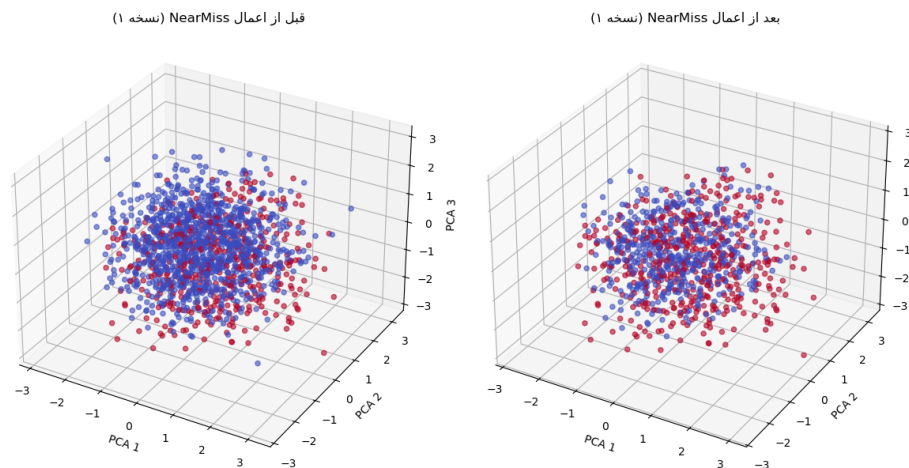
ویژگی	توضیحات	نوع داده	محدوده / دسته‌بندی‌ها
Age	سن متقاضی	عدد صحیح	۲۰ تا ۵۰ سال
Gender	جنسیت متقاضی	دودویی	۰: مرد، ۱: زن
Education Level	بالا‌ترین مدرک تحصیلی متقاضی	دسته‌ای	۱: کارشناسی نوع ۱، ۲: کارشناسی نوع ۲، ۳: ارشد، ۴: دکتری
Experience Years	تعداد سال‌های تجربه کاری متقاضی	عدد صحیح	۰ تا ۱۵ سال
Previous Companies Worked	تعداد شرکت‌هایی که فرد پیش‌تر در آنها فعالیت داشته	عدد صحیح	۱ تا ۵ شرکت
Distance From Company	فاصله محل سکونت متقاضی تا شرکت	اعشاری	۱ تا ۵۰ کیلومتر
Interview Score	امتیاز کسب‌شده در مصاحبه	عدد صحیح	۰ تا ۱۰۰
Skill Score	امتیاز مربوط به مهارت‌های فنی	عدد صحیح	۰ تا ۱۰۰
Personality Score	امتیاز ارزیابی ویژگی‌های شخصیتی	عدد صحیح	۰ تا ۱۰۰
Recruitment Strategy	نوع استراتژی به‌کار رفته برای جذب نیرو	دسته‌ای	۱: تهاجمی، ۲: متعادل، ۳: محافظه‌کار
Hiring Decision	نتیجه نهایی فرآیند استخدام (متغیر هدف مدل)	دودویی	۰: عدم‌استخدام، ۱: استخدام

مجموعه داده مورد استفاده در این مطالعه شامل اطلاعاتی پیرامون فرآیند استخدام متقاضیان است و نمونه‌هایی از افرادی را دربرمی‌گیرد که در نهایت استخدام شده‌اند یا خیر. از آنجا که شناسایی دقیق متقاضیان واجد شرایط اهمیت بالایی دارد، بررسی اولیه داده‌ها نشان می‌دهد که توزیع کلاس‌ها نامتوازن است؛ به طوری که تعداد نمونه‌های مربوط به عدم‌استخدام (کلاس ۰) به مراتب بیشتر از تعداد نمونه‌های مربوط به استخدام (کلاس ۱) است. این عدم‌توازن می‌تواند منجر به کاهش دقت مدل‌های یادگیری ماشین شود، چراکه این مدل‌ها در شرایط نامتوازن معمولاً گرایش بیشتری به پیش‌بینی کلاس غالب دارند. به همین دلیل، بهره‌گیری از تکنیک‌های متوازن‌سازی داده‌ها برای آموزش بهتر مدل و شناسایی دقیق‌تر الگوهای مرتبط با استخدام ضروری است. تحلیل آماری اولیه نشان می‌دهد که ۱۰۳۵ نمونه مربوط به کلاس ۰ (عدم استخدام) و تنها ۴۶۵ نمونه به کلاس ۱ (استخدام) اختصاص دارند؛ بنابراین، استفاده از روش‌های مناسب برای متعادل‌سازی کلاس‌ها، نقش مهمی در بهبود عملکرد مدل‌های پیش‌بینی در این زمینه ایفا می‌کند. برای مقابله با مسأله نامتوانی کلاس‌ها در این پژوهش، از روش NearMiss به عنوان یک تکنیک undersampling استفاده شد [۴۱]. NearMiss یکی از روش‌های محبوب برای متوازن‌سازی مجموعه داده‌های نامتوازن است که با کاهش نمونه‌های کلاس اکثریت (در اینجا، کلاس عدم‌استخدام) تلاش می‌کند تا توزیع کلاس‌ها را متعادل کند [۱۱]. روش NearMiss به جای حذف تصادفی نمونه‌ها، به صورت هدفمند اقدام به انتخاب نمونه‌هایی از کلاس اکثریت می‌کند که نزدیک‌ترین فاصله را با نمونه‌های کلاس اقلیت دارند [۶]. این کار باعث می‌شود که نمونه‌های باقی‌مانده از کلاس غالب، مرز بین کلاس‌ها را بهتر نمایش دهند و به مدل کمک کنند تا الگوهای مرتبط با کلاس اقلیت (در اینجا، استخدام‌شده‌ها) را بهتر یاد بگیرد. در این پژوهش، نسخه ۱ از NearMiss پیاده‌سازی شد. در نسخه اول NearMiss، نمونه‌هایی از کلاس اکثریت حذف می‌شوند که کمترین فاصله میانگین را با نمونه‌های کلاس اقلیت دارند. این فاصله براساس رابطه زیر محاسبه می‌شود:

(۱)

$$\text{NearMiss-1} = \arg \min_{x_i \in \text{Majority Class}} \left( \frac{1}{|C_{\min}|} \sum_{x_j \in C_{\min}} d(x_i, x_j) \right)$$


در این رابطه  $x_i$  نمونه‌های کلاس اکثریت،  $x_j$  نمونه‌های کلاس اقلیت،  $C_{\min}$  مجموعه کلاس اقلیت، و  $d(x_i, x_j)$  بیانگر فاصله اقلیدسی بین نمونه‌ها در فضای ویژگی است. برای ارزیابی بصری تأثیر این تکنیک بر داده‌ها از روش تحلیل مؤلفه‌های اصلی (PCA) استفاده شده است که در شکل ۱ به وضوح قابل مشاهده است.



شکل ۱. تأثیر روش NearMiss را بر روی داده‌ها

در شکل ۱، نمودار سه‌بعدی حاصل از تحلیل مؤلفه‌های اصلی (PCA) برای نمایش توزیع داده‌ها قبل و بعد از اعمال روش NearMiss (نسخه ۱) ارائه شده است. در سمت چپ، توزیع اولیه داده‌ها مشاهده می‌شود که در آن کلاس اکثریت (عدم‌استخدام) به‌وضوح غالب است. این چگالی بالایی نقاط کلاس ۰ در مقایسه با کلاس ۱ نشان‌دهنده نامتوازن بودن مجموعه داده اولیه است. در مقابل، نمودار سمت راست مربوط به داده‌های پس از اعمال NearMiss است. همان‌طور که دیده می‌شود، نمونه‌های کلاس اکثریت (آبی) کاهش یافته و توزیع کلاس‌ها متعادل‌تر شده است. این تعادل در داده‌ها به مدل‌های یادگیری ماشین کمک می‌کند تا بتوانند الگوهای هر دو کلاس را بهتر یاد بگیرند و از تمایل شدید به پیش‌بینی کلاس غالب جلوگیری شود. مجموعه داده مورد استفاده در این پژوهش از کیفیت بالایی برخوردار است و فاقد هرگونه داده مفقود، نویزی یا ناقص بوده است. در مراحل اولیه تحلیل، داده‌ها به دقت بررسی شدند و مشخص شد که تمامی مقادیر در متغیرهای مختلف کامل و سازگار هستند. این امر فرآیند پیش‌پردازش داده‌ها را ساده‌تر کرده و امکان تمرکز بر تحلیل و مدل‌سازی دقیق‌تر را فراهم آورده است. این ویژگی مجموعه داده، یعنی عدم وجود مقادیر مفقود و کیفیت بالای داده‌ها، اعتبار نتایج مدل‌های یادگیری ماشین را افزایش داده و سبب کاهش پیچیدگی مراحل پیش‌پردازش شده است. در این پژوهش به منظور هم‌مقیاس کردن داده‌ها، از StandardScaler استفاده شد. تمامی متغیرها به بازه‌ای با میانگین صفر و انحراف معیار یک تبدیل شدند.


**تحلیل همبستگی.** در این پژوهش، تحلیل همبستگی با هدف بررسی روابط خطی میان متغیرهای موجود در مجموعه داده انجام گرفته است [۲۸]. هدف از این تحلیل، شناسایی آن دسته از متغیرهایی است که بیشترین ارتباط را با متغیر هدف دارند و همچنین تشخیص متغیرهایی است که یا همپوشانی اطلاعاتی با سایر ویژگی‌ها دارند و یا ارتباط ضعیفی از نظر آماری نشان می‌دهند. برای نمایش بصری این روابط و درک بهتر ساختار همبستگی میان ویژگی‌ها، از ماتریس همبستگی در کنار نمودار نقشه حرارتی بهره گرفته شده است (شکل ۲).



شکل ۲. نقشه حرارتی همبستگی

شکل ۲، ماتریس همبستگی میان ویژگی‌های مجموعه داده را به تصویر می‌کشد. این نقشه حرارتی به صورت بصری میزان وابستگی و ارتباط بین متغیرهای مستقل با یکدیگر و با متغیر وابسته (یعنی تصمیم استخدام) را نمایش می‌دهد. در این ماتریس، مقدار +۱ بیانگر همبستگی مثبت کامل، مقدار -۱ نشان‌دهنده همبستگی منفی کامل و مقادیر نزدیک به صفر نمایانگر نبود رابطه خطی معنادار میان دو متغیر هستند [۱۵]. این نمایش به تحلیل دقیق‌تر نقش هر ویژگی در مدل‌سازی و حذف متغیرهای کم‌اهمیت کمک می‌کند. براساس نقشه حرارتی حاصل از تحلیل همبستگی، می‌توان دریافت که بیشتر ویژگی‌های موجود در مجموعه داده دارای همبستگی پایین تا متوسط با متغیر هدف هستند. در میان این ویژگی‌ها، استراتژی جذب نیرو با ضریب همبستگی حدود  $-0.53$ ، بالاترین میزان ارتباط را با متغیر هدف نشان می‌دهد. این ضریب منفی نشان‌دهنده آن است که با حرکت به سمت استراتژی‌های محافظه‌کارانه‌تر، احتمال استخدام کاهش می‌یابد. ویژگی سطح تحصیلات نیز با ضریب همبستگی مثبت  $0.30$  ارتباط نسبتاً معناداری با تصمیم استخدام دارد؛ به این معنا که افزایش سطح تحصیلات احتمال استخدام را افزایش می‌دهد. سایر متغیرها از جمله تجربه کاری و امتیاز مصاحبه دارای همبستگی مثبت ضعیف‌تری با متغیر هدف هستند. همچنین مشاهده می‌شود که بین ویژگی‌های مستقل، میزان همبستگی قابل توجهی وجود ندارد و همپوشانی اطلاعاتی بین آنها بسیار محدود است. این موضوع نشان می‌دهد که داده‌ها فاقد تکرار شدید اطلاعات بین متغیرها هستند و هر ویژگی می‌تواند نقش مجزایی در مدل‌سازی ایفا کند.

**اهمیت ویژگی‌ها.** شکل ۳ نمودار اهمیت ویژگی‌ها را براساس مدل XGBoost نمایش می‌دهد که با استفاده از روش بهینه‌سازی Optuna تنظیم شده است. مدل XGBoost یکی از الگوریتم‌های قدرتمند مبتنی بر درخت‌های تصمیم است که برای مسائل طبقه‌بندی، عملکرد بسیار دقیقی از خود نشان می‌دهد، به‌ویژه زمانی که داده‌ها از پیچیدگی ساختاری بالایی برخوردارند [۲۵]. در این پژوهش، به‌منظور استخراج میزان اهمیت هر ویژگی در پیش‌بینی تصمیم نهایی استخدام، مدل XGBoost با استفاده از Optuna بهینه‌سازی شد. Optuna یک چارچوب پیشرفته برای جستجوی خودکار در فضای هایپرپارامترهاست که به کمک آن بهترین ترکیب از پارامترهای مدل انتخاب شد [۳].



شکل ۳. اهمیت ویژگی‌ها با XGBoost

در تحلیل به‌دست‌آمده از مدل XGBoost بهینه‌شده با استفاده از روش Optuna، مشخص شد که ویژگی استراتژی جذب نیرو با امتیاز اهمیت بیش از ۵۰٪، تأثیرگذارترین عامل در پیش‌بینی تصمیم استخدام است. این مقدار اهمیت نشان می‌دهد که نوع استراتژی به‌کاررفته در فرآیند جذب، نقش محوری در انتخاب یا عدم‌انتخاب متقاضیان ایفا می‌کند. پس از آن، سطح تحصیلات نیز با مقدار اهمیت حدود ۱۳٪ به‌عنوان دومین ویژگی مهم شناسایی شد که بیانگر تأثیر تحصیلات بالاتر در احتمال استخدام است. علاوه بر این، ویژگی‌هایی نظیر تجربه کاری، امتیاز مصاحبه و امتیاز شخصیتی نیز در رتبه‌های بعدی قرار دارند و هرکدام به‌نحوی در بهبود عملکرد مدل و پیش‌بینی بهتر تصمیم نهایی استخدام مؤثر بوده‌اند. اهمیت این متغیرها، هرچند کمتر از دو ویژگی اول است، اما در مجموع می‌توانند اطلاعات ارزشمندی درباره ویژگی‌های رفتاری و شایستگی‌های فردی متقاضی ارائه دهند. این تحلیل از اهمیت ویژگی‌ها، ابزار مؤثری برای شناسایی عوامل کلیدی در فرآیند تصمیم‌گیری استخدام به شمار می‌رود. نتایج حاصل می‌توانند مبنای مناسبی برای بهینه‌سازی سیاست‌های جذب نیرو در سازمان‌ها فراهم آورند و به مدیران منابع انسانی کمک کنند تا براساس داده‌های واقعی، تصمیم‌گیری آگاهانه‌تری در انتخاب نیروی انسانی انجام دهند.

**انتخاب ویژگی‌ها.** در این پژوهش، به‌منظور انتخاب مجموعه‌ای از ویژگی‌های مؤثر و کاهش ابعاد داده‌ها، از روش حذف بازگشتی ویژگی‌ها با اعتبارسنجی متقاطع (Recursive Feature Elimination with Cross-Validation - RFECV) بهره‌گرفته شد [۷]. برای اجرای این فرآیند، از الگوریتم قدرتمند XGBoost به‌عنوان مدل پایه استفاده شد که پیش از آن، با بهره‌گیری از چارچوب بهینه‌سازی Optuna، بهترین مقادیر هایپرپارامترهای آن به‌دست آمده بود. این ترکیب موجب شد تا فرآیند انتخاب ویژگی‌ها با دقت و کارایی بالاتری انجام گیرد. روش RFECV به‌صورت گام‌به‌گام عمل می‌کند، به این صورت که در هر مرحله، یک یا چند ویژگی با کمترین اهمیت حذف شده و مدل با مجموعه ویژگی‌های باقی‌مانده آموزش داده می‌شود. در ادامه، عملکرد مدل با استفاده از اعتبارسنجی متقاطع ارزیابی شده و این روند تا زمانی ادامه می‌یابد که بهترین ترکیب ممکن از ویژگی‌ها برای مدل به‌دست آید [۱۳]. بهره‌گیری از XGBoost در این فرآیند باعث شد تا اهمیت ویژگی‌ها به‌صورت دقیق‌تری سنجیده شده و تعاملات پیچیده میان متغیرها نیز مورد توجه قرار گیرد. در نهایت، ۸ ویژگی کلیدی شامل سن، سطح تحصیلات، تجربه کاری، فاصله محل سکونت تا شرکت، امتیاز مصاحبه، امتیاز مهارت‌های فنی، امتیاز ویژگی‌های شخصیتی و استراتژی جذب نیرو به‌عنوان مهم‌ترین عوامل مؤثر بر تصمیم استخدام شناسایی شدند. حذف سایر ویژگی‌ها که ارتباط معناداری با متغیر هدف نداشتند، منجر به کاهش پیچیدگی مدل، کاهش نویز و بهبود تعمیم‌پذیری مدل در مواجهه با داده‌های جدید شد. ترکیب روش RFECV با XGBoost بهینه‌شده با Optuna، نه تنها فرآیند انتخاب ویژگی را دقیق‌تر و هدفمندتر ساخت، بلکه پایه‌ای قوی برای ساخت مدل‌های یادگیری ماشین با عملکرد بالا فراهم کرد.


**مدل‌سازی.** در این پژوهش، پس از انجام مراحل پیش‌پردازش داده‌ها، متعادل‌سازی کلاس‌ها با استفاده از روش NearMiss و انتخاب ویژگی‌های مؤثر با روش RFECV، فرآیند مدل‌سازی به‌منظور پیش‌بینی تصمیم نهایی در فرآیند استخدام متقاضیان انجام گرفت. هدف اصلی این مرحله، طراحی مدلی دقیق و قابل اعتماد برای طبقه‌بندی متقاضیان به دو گروه «استخدام‌شده» و «عدم‌استخدام» بود. برای دستیابی به این هدف، از یک ساختار یادگیری جمعی مبتنی بر استکینگ (Stacking) استفاده شد که قابلیت ترکیب قدرت چندین الگوریتم یادگیری ماشین را دارد. در این رویکرد، مجموعه‌ای از مدل‌های متنوع به‌عنوان مدل‌های پایه به کار گرفته شدند که شامل یک شبکه عصبی عمیق (Deep Neural Network) با معماری بهینه‌شده و همچنین مدل‌های پیشرفته‌ای نظیر Random Forest، Gradient Boosting، CatBoost و LightGBM بودند. هریک از این مدل‌ها به‌صورت مستقل بر روی داده‌های آموزش‌یافته اعمال شده و پیش‌بینی‌های خود را تولید کردند. سپس خروجی این مدل‌ها به‌عنوان ورودی به مدل XGBoost که به‌عنوان فرامدل (Meta-learner) در ساختار استکینگ عمل می‌کرد، منتقل شد تا تصمیم نهایی برای هر نمونه اتخاذ گردد. برای بهینه‌سازی دقیق و کارآمد هابیر پارامترهای مدل‌های پایه و فرامدل، از الگوریتم جستجوی پیشرفته TPE (Tree-structured Parzen Estimator) در چارچوب Optuna استفاده شد [۵۱]. این الگوریتم با مدل‌سازی توزیع احتمالاتی فضای جستجو، فرآیند تنظیم پارامترها را به‌صورت هوشمند و هدفمند انجام داده و در مقایسه با روش‌هایی نظیر جستجوی تصادفی یا شبکه‌ای، به‌طور قابل توجهی کاراتر عمل می‌کند. به‌کارگیری Optuna منجر به بهبود عملکرد مدل‌ها، افزایش دقت و کاهش خطای پیش‌بینی در سطح سیستم شد. جدول ۳ شبه کد مدل پیشنهادی این پژوهش را نشان می‌دهد.

جدول ۳. شبه کد مدل پیشنهادی پژوهش

مرحله	اقدام
۱	Input : Training dataset $D = \{(x_i, y_i)\}_{i=1}^n$ , test dataset $D_{test}$ , base models : RF, GB, LGBM, CatBoost, DNN, meta-model : XGBoost, optimization method : TPE
۲	Initialize base models : $M_{RF}, M_{GB}, M_{LGBM}, M_{Cat}, M_{DNN}$ , meta-model : $M_{XGB}$
۳	For each base model $M \in \{M_{RF}, M_{GB}, M_{LGBM}, M_{Cat}, M_{DNN}\}$ :
۴	Optimize hyperparameters using TPE with objective : cross-validated MAE/RMSE/Accuracy on $D$
۵	Train $M$ on $D$ with optimal hyperparameters
۶	End For
۷	Generate out-of-fold predictions for training set using k-fold cross-validation :
۸	For each fold $k$ :
۹	Train all base models on $D \setminus D_k$
۱۰	Predict on $D_k$ to get $\hat{y}_k^{(1)}, \hat{y}_k^{(2)}, \dots, \hat{y}_k^{(5)}$
۱۱	End For
۱۲	Construct meta-feature matrix $X_{meta}$ : each row is $[\hat{y}^{(1)}, \hat{y}^{(2)}, \hat{y}^{(3)}, \hat{y}^{(4)}, \hat{y}^{(5)}]$ for $D$
۱۳	Optimize meta-model $M_{XGB}$ using TPE with objective : cross-validated performance on $X_{meta}, \mathcal{Y}$
۱۴	Train $M_{XGB}$ on $X_{meta}, \mathcal{Y}$ with optimal hyperparameters
۱۵	Predict on test set :
۱۶	For each base model $M$ :
۱۷	Predict $M$ on $D_{test} \rightarrow \hat{y}_{test}^{(1)}, \dots, \hat{y}_{test}^{(5)}$
۱۸	End For
۱۹	Construct meta-test matrix $X_{meta}^{test}$ : each row is $[\hat{y}_{test}^{(1)}, \dots, \hat{y}_{test}^{(5)}]$
۲۰	Predict $\hat{y}_{final} = M_{XGB}(X_{meta}^{test})$
۲۱	Output : Final predictions $\hat{y}_{final}$ on $D_{test}$

شکل ۴ ساختار مدل پیشنهادی را نشان می‌دهد.





شکل ۴. ساختار مدل پیشنهادی

در این پژوهش، از شبکه عصبی عمیق (Deep Neural Network) به‌عنوان یکی از مدل‌های پایه در ساختار یادگیری جمعی مبتنی بر استکینگ استفاده شده است [۴۲]. این مدل به دلیل توانایی بالا در شناسایی روابط غیرخطی و پیچیده میان متغیرهای ورودی، گزینه مناسبی برای مدل‌سازی پدیده‌هایی مانند تصمیم‌گیری در استخدام به‌شمار می‌رود. معماری شبکه از چندین لایه مخفی تشکیل شده که هر یک با استفاده از توابع فعال‌سازی غیرخطی، الگوهای پنهان در داده‌ها را استخراج می‌کنند [۳۴]. برای تنظیم دقیق شبکه عصبی و بهینه‌سازی عملکرد آن، مجموعه‌ای از هایپرپارامترهای کلیدی مورد بررسی قرار گرفت. این هایپرپارامترها شامل تعداد لایه‌های مخفی ( $n\_layers$ )، تعداد نورون‌ها در هر لایه ( $n\_units$ )، نرخ ریزش (Dropout) برای هر لایه به‌منظور جلوگیری از بیش‌برازش، نرخ یادگیری (Learning Rate)، اندازه دسته‌های آموزشی (Batch Size) و تعداد دوره‌های آموزشی (Epochs) بودند. برای هر یک از این پارامترها، بازه‌های معقولی براساس تجربیات گذشته و استانداردهای رایج در یادگیری عمیق در نظر گرفته شد. فرآیند جستجوی مقادیر بهینه با استفاده از الگوریتم TPE (Tree-structured Parzen Estimator) در چارچوب Optuna انجام شد. Optuna با اجرای ۱۰۰ تکرار از جستجوی هوشمند در فضای پارامترها، ترکیبی از مقادیر را انتخاب کرد که منجر به بالاترین صحت (Accuracy) مدل در طبقه‌بندی داده‌ها به دو کلاس «استخدام‌شده» و «عدم‌استخدام» شد. این بهینه‌سازی نقش مؤثری در افزایش کیفیت پیش‌بینی مدل و کاهش خطای عمومی داشت. جدول ۴، مقادیر جستجو شده و مقدار نهایی انتخاب‌شده توسط Optuna برای هر یک از هایپرپارامترها را ارائه می‌دهد. این نتایج، پایه طراحی شبکه عصبی در ساختار استکینگ بوده‌اند و سهم قابل‌توجهی در بهبود عملکرد کلی مدل پیشنهادی ایفا کرده‌اند.

جدول ۴. تنظیمات بهینه‌سازی هایپرپارامترهای شبکه عصبی عمیق با استفاده از Optuna

مؤلفه / هایپرپارامتر	بازه جستجو / تنظیم‌شده	مقدار بهینه انتخاب‌شده توسط Optuna
تعداد لایه‌های مخفی ( $n\_layers$ )	۳ تا ۱۰	۳
تعداد نورون‌ها در لایه اول	۶۴ تا ۱۰۲۴ (گام ۶۴)	۶۴
تعداد نورون‌ها در لایه دوم	۶۴ تا ۱۰۲۴	۹۶۰
تعداد نورون‌ها در لایه سوم	۶۴ تا ۱۰۲۴	۱۰۲۴
Dropout لایه اول	۰.۱ تا ۰.۵	۰.۴۵۹
Dropout لایه دوم	۰.۱ تا ۰.۵	۰.۳۷۵
Dropout لایه سوم	۰.۱ تا ۰.۵	۰.۳۳۵
نرخ یادگیری (Learning Rate)	۰.۰۰۰۱ تا ۰.۰۱ (مقیاس لگاریتمی)	۰.۰۰۳۲۵
Batch Size	{۱۶, ۳۲, ۶۴}	۱۶
Epochs	۱۰۰ تا ۳۰۰	۱۶۷

مؤلفه / هایپرپارامتر	بازه جستجو / تنظیم‌شده	مقدار بهینه انتخاب‌شده توسط Optuna
تابع فعال‌سازی (مخفی)	ثابت (ReLU)	ReLU
تابع فعال‌سازی (خروجی)	ثابت (Sigmoid)	Sigmoid
تابع هزینه	ثابت (Binary Crossentropy)	Binary Crossentropy
بهینه‌ساز (Optimizer)	ثابت (Adam)	Adam با LR بهینه‌شده
Batch Normalization	استفاده شده بعد از هر لایه	فعال
EarlyStopping	فعال - patience=15, monitor='loss'	استفاده شده
ReduceLRonPlateau	فعال - patience=5, factor=0/5, min_lr=1e-5	استفاده شده

در این پژوهش، برای طراحی ساختار مدل، از ترکیبی از الگوریتم‌های قدرتمند یادگیری ماشین استفاده شد که هر یک با ویژگی‌های منحصر به فرد خود، به بهبود عملکرد کلی مدل کمک کردند. الگوریتم Random Forest به دلیل توانایی در کاهش بیش‌برازش و ارائه پیش‌بینی‌های پایدار با استفاده از مجموعه‌ای از درخت‌های تصمیم، به عنوان یک مدل پایه به کار گرفته شد. Gradient Boosting نیز به عنوان یک الگوریتم تقویتی تدریجی، در تشخیص الگوهای ظریف و کاهش خطاهای مدل‌های قبلی عملکرد بسیار خوبی دارد [۲۷]. LightGBM با توجه به سرعت بالا و مصرف منابع پایین، گزینه‌ای مناسب برای پردازش سریع داده‌ها در کنار دقت بالا محسوب می‌شود [۳۳]. CatBoost به دلیل توانایی عالی در مدیریت داده‌های رده‌ای و جلوگیری از بیش‌برازش، به ساختار مدل انعطاف‌پذیری بالاتری بخشید [۵۴]. در نهایت، XGBoost به عنوان متامدل استفاده شد تا با ترکیب خروجی مدل‌های پایه و یادگیری از آنها، تصمیم نهایی را با دقت بالا اتخاذ کند. انتخاب این ترکیب از الگوریتم‌ها، تعادل مناسبی بین دقت، تعمیم‌پذیری و توانایی شناسایی الگوهای پیچیده در داده‌های مرتبط با تصمیم‌گیری ایجاد کرد [۵۹]. به منظور بهبود عملکرد مدل‌های پایه و همچنین مدل متامدل نیز فرآیند بهینه‌سازی هایپرپارامترها با استفاده از چارچوب Optuna انجام شد. برای هر یک از مدل‌ها، مجموعه‌ای از هایپرپارامترهای مهم تعیین شده و با اجرای ۱۰۰ تکرار از فرآیند بهینه‌سازی، بهترین ترکیب از پارامترها انتخاب گردید. این فرآیند در قالب اعتبارسنجی متقاطع پنج‌لایه صورت گرفت. جدول ۵ شامل بازه جستجو و مقادیر بهینه نهایی برای مدل‌های مورد استفاده در ساختار استکینگ آورده شده است.

جدول ۵. نتایج بهینه‌سازی هایپرپارامتر برای سایر مدل‌های پایه و فرامدل

مدل	هایپرپارامتر	بازه جستجو	مقدار بهینه
Random Forest	n_estimators	۱۰۰-۳۰۰	۱۹۰
	max_depth	۵-۲۰	۷
	min_samples_split	۲-۶	۳
	min_samples_leaf	۱-۴	۲
	max_features	sqrt, logv, None	None
Gradient Boosting	n_estimators	۱۰۰-۳۰۰	۱۹۶
	learning_rate	۰.۰۱-۰.۲	۰.۰۱۷۸
	max_depth	۳-۱۰	۵
	subsample	۰.۶-۱	۰.۷۴۷۹
LightGBM	n_estimators	۱۰۰-۳۰۰	۱۰۴
	learning_rate	۰.۰۱-۰.۲	۰.۰۴۳۸
	max_depth	۳-۱۰	۴
	num_leaves	۳۱-۷۰	۳۵
CatBoost	iterations	۱۰۰-۳۰۰	۱۹۸
	learning_rate	۰.۰۱-۰.۲	۰.۰۴۲۰
	depth	۴-۱۰	۶

مدل	هایپارامتر	بازه جستجو	مقدار بهینه
XGBoost (Meta)	l2_leaf_reg	۱-۷	۳
	n_estimators	۱۰۰-۳۰۰	۱۴۹
	learning_rate	۰.۰۱-۰.۲	۰.۰۲۸۸
	max_depth	۳-۱۰	۴
	subsample	۰.۶-۱	۰.۶۵۲۲
	colsample_bytree	۰.۶-۱	۰.۷۶۱۱

**مقایسه با مدل‌های یادگیری ماشین.** مطابق با جدول شماره ۶، به منظور ارزیابی عملکرد مدل استکینگ پیشنهادی، از ۱۶ الگوریتم متنوع یادگیری ماشین به عنوان روش‌های مقایسه‌ای استفاده شد که هرکدام با تنظیم دقیق هایپارامترها با استفاده از Grid Search و اعتبارسنجی متقاطع، بهینه‌سازی شدند. هدف از این مقایسه، بررسی توان مدل ترکیبی پیشنهادی در برابر الگوریتم‌های رایج در حوزه طبقه‌بندی و شناسایی مؤثرترین روش در پیش‌بینی تصمیم استخدام بود.

جدول ۶. مدل‌های یادگیری ماشین و هایپارامترهای بهینه

مدل	تعریف مختصر	منبع
Logistic Regression	مدلی خطی برای طبقه‌بندی دودویی برپایه تابع لجستیک	[۵۵]
Decision Tree	درخت تصمیم ساده با تقسیم داده براساس ویژگی‌ها	[۱۷]
Random Forest	مجموعه‌ای از درخت‌های تصمیم با رأی‌گیری اکثریت	[۹]
Gradient Boosting	تقویت تدریجی مدل‌ها با اصلاح خطای مرحله قبل	[۴۸]
AdaBoost	الگوریتم تقویتی مبتنی بر وزن‌دهی به خطاها	[۲۲]
Extra Trees	درخت‌های تصمیم بسیار متنوع با انتخاب تصادفی ویژگی‌ها	[۴]
Gaussian Naive Bayes	طبقه‌بند ساده مبتنی بر قضیه بیز با فرض استقلال ویژگی‌ها	[۱۸]
SVC (Support Vector Classifier)	مدل برپایه یافتن مرز حداکثر جداساز بین کلاس‌ها	[۲۰]
KNN (K-Nearest Neighbors)	طبقه‌بندی براساس نزدیک‌ترین همسایگان	[۴۶]
XGBoost	مدل تقویتی بسیار دقیق با کاهش خطای گرادینتی	[۶۰]
LightGBM	نسخه سریع‌تر و سبک‌تر گرادینت بوستینگ	[۳۶]
CatBoost	مدل تقویتی با قابلیت بالا در داده‌های دسته‌ای	[۵۳]
LDA (Linear Discriminant Analysis)	روش آماری برای جداسازی کلاس‌ها براساس ترکیب خطی ویژگی‌ها	[۱۹]
QDA (Quadratic Discriminant Analysis)	نسخه پیشرفته‌تر LDA با مرزهای تصمیم غیرخطی	[۴۰]
MLP (Multi-Layer Perceptron)	شبکه عصبی پایه با یک لایه مخفی	[۲۶]
Bagging Classifier	مدل تجمعی با نمونه‌برداری تصادفی و آموزش مدل‌های مشابه	[۳۵]

براساس جدول شماره ۷، برای ارزیابی عملکرد مدل‌های یادگیری ماشین در پیش‌بینی تصمیم نهایی استخدام، از مفاهیم پایه‌ای همچون True Positive (TP) و True Negative (TN) استفاده می‌شود. TP به مواردی اشاره دارد که مدل به درستی پیش‌بینی کرده متقاضی استخدام خواهد شد، در حالی که TN بیانگر پیش‌بینی صحیح عدم استخدام برای افراد رد شده است. در مقابل، False Positive (FP) زمانی رخ می‌دهد که مدل به اشتباه استخدام فردی را پیش‌بینی کند که در واقع استخدام نشده است. همچنین، False Negative (FN) حالتی است که مدل پیش‌بینی می‌کند فردی استخدام نخواهد شد، اما در واقع استخدام شده است [۴۵]. بر مبنای این ۴ شاخص پایه، معیارهای ارزیابی مهمی مانند صحت (Accuracy)، دقت (Precision)، بازخوانی (Recall)، و امتیاز F1 (F1 Score) محاسبه می‌شوند. برای دستیابی به نتایج دقیق و پایدار، از روش اعتبارسنجی متقابل پنج‌تایی استفاده شده است [۲۱]. در این روش، مجموعه داده به ۵ بخش مساوی تقسیم شده و هر بار یکی از بخش‌ها به عنوان داده آزمون و ۴ بخش دیگر برای آموزش مدل به کار گرفته می‌شوند. این فرآیند در ۵ مرحله تکرار شده تا تمامی داده‌ها یک بار در نقش

داده آزمون قرار گیرند. سپس میانگین نتایج ۵ تکرار به‌عنوان عملکرد نهایی مدل گزارش می‌شود. استفاده از این روش نه تنها از بیش‌برازش جلوگیری می‌کند، بلکه قابلیت تعمیم‌پذیری مدل‌ها بر داده‌های جدید را نیز افزایش می‌دهد [۱].

جدول ۷. شاخص‌های ارزیابی مدل‌های یادگیری ماشین

شاخص	تعریف	فرمول
صحت (Accuracy)	نسبت پیش‌بینی‌های صحیح به کل نمونه‌ها.	$\frac{TP + TN}{TP + FP + FN + TN}$
دقت (Precision)	نسبت پیش‌بینی‌های درست برای یک کلاس به کل نمونه‌هایی که به عنوان آن کلاس پیش‌بینی شده‌اند.	$\frac{TP}{TP + FP}$
بازخوانی (Recall)	نسبت پیش‌بینی‌های درست برای یک کلاس به کل نمونه‌های واقعی آن کلاس.	$\frac{TP}{TP + FN}$
امتیاز F1	میانگین هارمونیک بین Precision و Recall برای ایجاد تعادل بین آنها.	$\frac{2 \times Precision \times Recall}{Precision + Recall}$

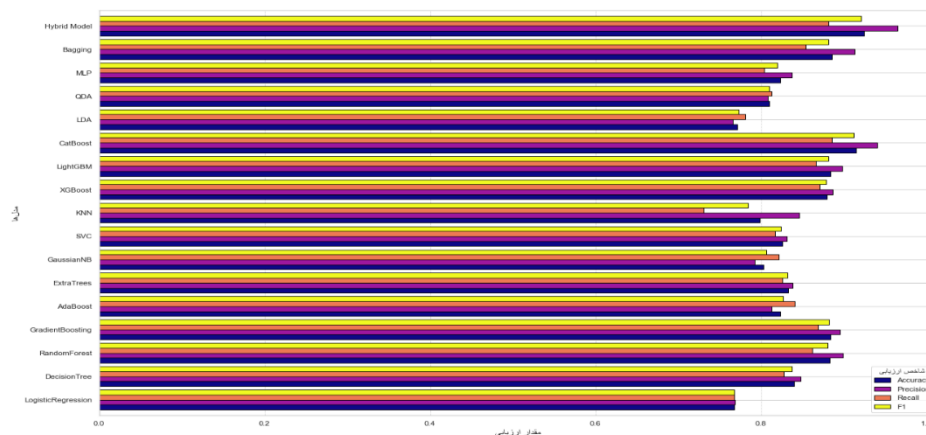
#### ۴. تحلیل داده‌ها و یافته‌های پژوهش

در این بخش، عملکرد مدل ترکیبی پیشنهادی و سایر مدل‌های یادگیری ماشین ارائه می‌شود. در این پژوهش از زبان برنامه‌نویسی پایتون استفاده شده است و تمامی مدل‌ها بر روی سیستمی با پردازنده Intel Core i7-13700H و ۱۶ گیگابایت رم و پایتون ۳/۱۲ اجرا شدند. جدول ۸ عملکرد مدل‌های یادگیری ماشین براساس معیارهای ارزیابی را نشان می‌دهد.

جدول ۸. مقایسه مدل‌ها براساس معیارهای ارزیابی

مدل	Accuracy	Precision	Recall	امتیاز F1
Logistic Regression	۰.۷۶۷۷۴۲	۰.۷۶۸۲۰۶	۰.۷۶۷۷۴۲	۰.۷۶۷۵۵۸
Decision Tree	۰.۸۳۹۷۸۵	۰.۸۴۸۱۳۴	۰.۸۲۷۹۵۷	۰.۸۳۷۱۲۷
Random Forest	۰.۸۸۲۷۹۶	۰.۸۹۹۰۶۸	۰.۸۶۲۳۶۶	۰.۸۸۰۲۶۴
Gradient Boosting	۰.۸۸۳۸۷۱	۰.۸۹۵۹۴۷	۰.۸۶۸۸۱۷	۰.۸۸۲۰۰۹
AdaBoost	۰.۸۲۳۶۵۶	۰.۸۱۲۸۸۹	۰.۸۴۰۸۶۰	۰.۸۲۶۴۲۰
Extra Trees	۰.۸۳۳۳۳۳	۰.۸۳۸۵۵۵	۰.۸۲۵۸۰۶	۰.۸۳۲۰۲۵
Gaussian NB	۰.۸۰۳۲۲۶	۰.۷۹۲۴۵۸	۰.۸۲۱۵۰۵	۰.۸۰۶۶۵۶
SVC	۰.۸۲۵۸۰۶	۰.۸۳۱۳۸۸	۰.۸۱۷۲۰۴	۰.۸۲۴۲۰۰
KNN	۰.۷۹۸۹۲۵	۰.۸۴۶۲۹۱	۰.۷۳۱۱۸۳	۰.۷۸۴۱۳۲
XGBoost	۰.۸۷۹۵۷۰	۰.۸۸۶۴۸۵	۰.۸۷۰۹۶۸	۰.۸۷۸۳۹۰
LightGBM	۰.۸۸۳۸۷۱	۰.۸۹۷۸۲۴	۰.۸۶۶۶۶۷	۰.۸۸۱۶۹۵
CatBoost	۰.۹۱۵۰۵۴	۰.۹۴۰۸۰۳	۰.۸۸۶۰۲۲	۰.۹۱۲۳۸۴
LDA	۰.۷۷۰۹۶۸	۰.۷۶۶۰۹۲	۰.۷۸۰۶۴۵	۰.۷۷۲۷۴۰
QDA	۰.۸۰۹۶۷۷	۰.۸۰۸۰۲۸	۰.۸۱۲۹۰۳	۰.۸۱۰۱۱۹
MLP	۰.۸۲۳۶۵۶	۰.۸۳۷۰۵۶	۰.۸۰۴۳۰۱	۰.۸۱۹۷۸۵
Bagging	۰.۸۸۶۰۲۲	۰.۹۱۳۳۷۹	۰.۸۵۳۷۶۳	۰.۸۸۱۷۹۲
مدل ترکیبی پیشنهادی پژوهش	۰.۹۲۴۷۳۱	۰.۹۶۴۶۹۸	۰.۸۸۱۷۲۰	۰.۹۲۱۲۹۴

در میان تمامی مدل‌ها، مدل ترکیبی پیشنهادی مبتنی بر یادگیری عمیق بهترین عملکرد را ارائه داد. این مدل توانست با کسب صحت ۹۲.۴۷ درصد، دقت ۹۶.۴۶ درصد، بازخوانی ۸۸.۱۷ درصد، و امتیاز F1 برابر با ۵۲.۱۲ درصد، از تمامی مدل‌های منفرد پیشی بگیرد. چنین عملکردی نشان می‌دهد که مدل ترکیبی پیشنهادی نه تنها توانایی بسیار بالایی در شناسایی صحیح متقاضیان واجد شرایط برای استخدام دارد، بلکه در تمایز بین دو کلاس نیز دقت فوق‌العاده‌ای دارد. پس از مدل پیشنهادی، مدل CatBoost با صحت ۹۱.۵۰ درصد و امتیاز F1 برابر با ۹۱.۲۳ درصد در رتبه دوم قرار گرفت. اگرچه عملکرد این مدل نیز قابل توجه است، اما در تمامی شاخص‌ها نسبت به مدل پیشنهادی ضعیف‌تر ظاهر شده است. همچنین، مدل‌های LightGBM، Gradient Boosting، Random Forest و XGBoost نیز عملکرد مناسبی داشتند، اما به‌ویژه در بازیابی و دقت، با اختلاف بسیار زیاد از مدل پیشنهادی عقب ماندند. این مسأله نشان می‌دهد که ترکیب چند مدل و استفاده از قدرت شبکه عصبی عمیق در لایه‌های پایه، منجر به افزایش قدرت تعمیم و کاهش خطاهای دسته‌بندی شده است. در مقابل، مدل‌هایی نظیر Logistic Regression، KNN، Naive Bayes، SVC، LDA و QDA عملکرد ضعیف‌تری داشتند. برای مثال، Logistic Regression تنها توانست به صحت ۷۶.۷۷ درصد و امتیاز F1 معادل ۷۶.۷۵ درصد دست یابد که نشان‌دهنده ناتوانی این مدل در استخراج روابط پیچیده میان ویژگی‌ها و تصمیم نهایی استخدام است.



شکل ۵. مقایسه عملکرد مدل‌ها

همانطور که در شکل ۵ نشان داده شده است، نتایج حاصل از مقایسه مدل‌ها نشان می‌دهد که مدل ترکیبی پیشنهادی، با بهره‌گیری از قدرت چندین الگوریتم قوی و ساختار انعطاف‌پذیر یادگیری عمیق، در تمامی شاخص‌های کلیدی عملکرد برتر بوده است. این رویکرد می‌تواند در کاربردهای عملی مانند غربالگری متقاضیان شغلی، بهینه‌سازی فرآیند جذب نیرو و افزایش دقت در تصمیم‌گیری‌های منابع انسانی بسیار مؤثر واقع شود.

## ۵. نتیجه‌گیری و پیشنهادها

مدل پیشنهادی این پژوهش که مبتنی بر یادگیری ماشین ترکیبی و ساختار استکینگ چندلایه است، توانسته است در پیش‌بینی تصمیمات استخدامی عملکردی بسیار دقیق‌تر و کارآمدتر نسبت به مدل‌های متداول ارائه دهد. بر اساس مقایسه نتایج با ۱۶ مدل رایج یادگیری ماشین، از جمله Gradient Boosting، Random Forest، XGBoost، و CatBoost، مشخص شد که مدل پیشنهادی نه تنها در شاخص صحت (Accuracy) بلکه در تمامی شاخص‌های کلیدی از جمله دقت پیش‌بینی (Precision)، بازخوانی (Recall) و امتیاز F1 برتری مطلق دارد. این در حالی است که در اکثر پژوهش‌های قبلی، عملکرد مدل‌ها در یکی از این شاخص‌ها قوی بوده ولی در دیگر معیارها ضعف‌هایی مشاهده شده است. برای ارزیابی جایگاه مدل پیشنهادی در مقایسه با پژوهش‌های پیشین، نتایج این تحقیق در کنار یافته‌های مطالعات مرتبط قرار گرفت.

جدول ۹، خلاصه‌ای از مهم‌ترین تحقیقات انجام‌شده در حوزه پیش‌بینی تصمیمات استخدامی را ارائه می‌دهد که بر اساس نوع مدل استفاده‌شده، میزان صحت، مزایا و محدودیت‌های هر رویکرد دسته‌بندی شده‌اند. این مقایسه نشان می‌دهد که اگرچه برخی از مدل‌های پیشین در برخی معیارها عملکرد مطلوبی داشته‌اند، اما مدل ترکیبی پیشنهادی پژوهش حاضر با بهبود همزمان تمام شاخص‌های کلیدی و ارائه بینش‌های مدیریتی عملی، نسبت به سایر روش‌ها برتری معناداری دارد.

جدول ۹. مقایسه مطالعات پیشین با مدل پیشنهادی پژوهش حاضر

عنوان تحقیق	مدل استفاده‌شده	صحت (Accuracy)	مزیت‌ها	محدودیت‌ها
آفاق (۱۴۰۴)	درخت تصمیم + رگرسیون لجستیک	٪۸۴	سادگی پیاده‌سازی، زمان آموزش کوتاه، تفسیرپذیری نسبتاً خوب	عملکرد ضعیف در داده‌های پیچیده و چندبعدی، حساسیت به داده‌های نامتوازن
یاسین و سعید (۱۴۰۳)	شبکه عصبی ساده	٪۸۷	توانایی یادگیری روابط غیرخطی، انعطاف‌پذیری بالا	نیاز به داده آموزشی بزرگ، ضعف در تفسیرپذیری، ریسک بیش‌برازش
سها و همکاران (۱۴۰۲)	Random Forest	٪۸۹	مقاومت در برابر نویز داده‌ها، مناسب برای داده‌های با ویژگی‌های زیاد	افت عملکرد در داده‌های بسیار نامتوازن، پیچیدگی در تفسیر مدل
ردی و همکاران (۱۳۹۹)	CatBoost	٪۹۱	عملکرد مناسب با داده‌های دسته‌ای و متنی، کاهش نیاز به پیش‌پردازش نسبتاً بالا	محدودیت در بهبود همزمان همه شاخص‌های عملکرد، زمان آموزش نسبتاً بالا
آگیلار-روئیز و میخالاک (۲۰۲۴)	LightGBM	٪۹۰	سرعت آموزش بالا، کارایی خوب در داده‌های حجیم	حساسیت به تنظیمات پارامترها، افت عملکرد در داده‌های بسیار نامتوازن
آیزان تورسونیاوا و همکاران (۲۰۲۵)	مدل ترکیبی Gradient Boosting + Logistic Regression	٪۸۸	ترکیب مزایای مدل‌های خطی و غیرخطی، بهبود نسبی دقت	عدم استفاده از معماری‌های یادگیری عمیق، محدودیت در استخراج ویژگی‌های پیچیده
<b>مدل پیشنهادی پژوهش حاضر</b>	ترکیب شبکه عصبی عمیق + الگوریتم‌های جمعی پیشرفته + معماری استکینگ و بهینه‌سازی Optuna (TPE)	٪۹۲/۴۷	بهبود همزمان صحت، دقت، بازخوانی و F1؛ مدیریت داده‌های نامتوازن با NearMiss؛ تحلیل اهمیت ویژگی‌ها؛ قابلیت تعمیم بالا؛ ارائه بینش‌های مدیریتی کاربردی	نیاز به توان محاسباتی بیشتر، زمان آموزش طولانی‌تر نسبت به مدل‌های ساده

در اغلب این مطالعات، موضوعاتی همچون توازن کلاس‌ها، بهینه‌سازی دقیق‌های پارامترها، و تحلیل اهمیت ویژگی‌ها به‌طور کامل لحاظ نشده است. در مقابل، پژوهش حاضر با استفاده از روش NearMiss، توانست مسأله عدم توازن کلاس‌ها را به‌شکل مؤثر حل کند. این تکنیک به جای حذف تصادفی داده‌ها، نمونه‌هایی را حذف می‌کند که کمترین فاصله با کلاس اقلیت دارند و به این ترتیب، مدل را قادر می‌سازد که مرز تصمیم‌گیری بین کلاس‌ها را بهتر شناسایی کند. همچنین، تنظیم دقیق پارامترهای مدل‌ها با استفاده از الگوریتم TPE در چارچوب Optuna،

به مدلی منجر شد که نه تنها از نظر دقت بلکه از نظر تعمیم‌پذیری و پایداری نیز عملکرد برتری داشت. این موضوع در ارزیابی عملکرد مدل در مرحله اعتبارسنجی متقاطع نیز تأیید شد.

از سوی دیگر، تحلیل ویژگی‌ها نشان داد که متغیرهایی چون استراتژی جذب نیرو، سطح تحصیلات، و امتیاز مصاحبه نقش کلیدی در پیش‌بینی تصمیم نهایی استخدام دارند. این یافته‌ها نه تنها در خدمت افزایش دقت مدل بوده‌اند بلکه بینش‌هایی عملی برای سیاست‌گذاران منابع انسانی فراهم می‌کنند. به عنوان مثال، شناسایی استراتژی جذب به‌عنوان مؤثرترین ویژگی می‌تواند مدیران را به بازنگری در سیاست‌های استخدامی سوق دهد. در کنار آن، مشخص شدن تأثیر مثبت سطح تحصیلات و تجربه کاری در تصمیم‌گیری استخدام، نشان‌دهنده آن است که تحلیل داده‌محور می‌تواند جایگزین شهود و قضاوت فردی شود و تصمیمات انسانی را پشتیبانی کند، نه جایگزین آن. مزیت مدل پیشنهادی صرفاً به عملکرد عددی محدود نمی‌شود؛ بلکه در ساختار طراحی، انعطاف‌پذیری و قابلیت اجرا در شرایط واقعی نیز برتری دارد. استفاده از یک شبکه عصبی به‌عنوان استخراج‌کننده ویژگی‌های سطح بالا، در کنار مدل‌های تصمیم‌یار قدرتمند مانند XGBoost و CatBoost، نوعی هم‌افزایی میان یادگیری عمیق و کلاسیک ایجاد کرده است که تاکنون در پژوهش‌های مشابه کمتر مشاهده شده است. این ترکیب به مدل اجازه داده تا هم از ظرفیت‌های بالای استخراج روابط پیچیده استفاده کند و هم در شرایط واقعی، با حجم محدود داده‌ها، دچار بیش‌برازش یا تضعیف عملکرد نشود.

در مجموع، می‌توان نتیجه گرفت که مدل ترکیبی ارائه‌شده در این تحقیق توانسته است شکاف‌های مهمی را که در پژوهش‌های پیشین مشاهده می‌شد، پوشش دهد. از جمله این شکاف‌ها می‌توان به فقدان ترکیب ساختارمند الگوریتم‌های یادگیری عمیق با مدل‌های کلاسیک، استفاده ضعیف از تکنیک‌های پیشرفته بهینه‌سازی، بی‌توجهی به نامتوازن بودن داده‌ها و نبود ارزیابی چندمعیاری اشاره کرد. این مدل با برخورداری از چارچوب بهینه‌سازی قوی، انتخاب هدفمند ویژگی‌ها، ساختار استکینگ پیشرفته و ارزیابی دقیق، نه تنها از نظر آماری بلکه از نظر عملی نیز شایستگی بالایی برای پیاده‌سازی در سیستم‌های جذب و استخدام دارد. همچنین، می‌تواند مبنای توسعه سیستم‌های تصمیم‌یار هوشمند در منابع انسانی باشد و در بهینه‌سازی فرآیندهای استخدام در سازمان‌های مختلف مورد استفاده قرار گیرد. با وجود این مزایا، پژوهش حاضر نیز بدون محدودیت نیست. استفاده از یک مجموعه داده خاص با اندازه متوسط ممکن است بر تعمیم‌پذیری نتایج اثرگذار باشد؛ بنابراین پیشنهاد می‌شود در مطالعات آینده از داده‌های چندمنظوره و واقعی‌تری استفاده شود. همچنین، با گسترش پژوهش به داده‌های متنی مانند رزومه یا تحلیل‌های ویدیویی از مصاحبه‌ها، می‌توان عملکرد مدل را در شرایط پیچیده‌تر نیز سنجید. در نهایت، استفاده از ابزارهای تفسیرپذیری مانند SHAP می‌تواند درک تصمیمات مدل را برای مدیران غیرمتخصص ساده‌تر کرده و اعتماد به مدل‌های هوش مصنوعی را در سیستم‌های انسانی افزایش دهد.

نتایج این تحقیق علاوه بر ارزش علمی، پیامدهای مدیریتی مهمی نیز دارد که می‌تواند به بهبود فرآیندهای جذب و استخدام در سازمان‌ها کمک کند. نخست، شناسایی «استراتژی جذب نیرو» به‌عنوان اثرگذارترین عامل در پیش‌بینی تصمیم نهایی استخدام، می‌تواند مدیران را به بازنگری در سیاست‌های جذب و انتخاب رویکردهای مؤثرتر سوق دهد. دوم، نقش مثبت «سطح تحصیلات»، «امتیاز مصاحبه» و «امتیاز ویژگی‌های شخصیتی» در موفقیت استخدام، نشان می‌دهد که تمرکز بر این شاخص‌ها در غربالگری اولیه می‌تواند دقت و کارایی فرآیند انتخاب را افزایش دهد. سوم، استفاده از مدل ترکیبی مبتنی بر یادگیری عمیق و الگوریتم‌های جمعی که در این تحقیق ارائه شده، به مدیران منابع انسانی این امکان را می‌دهد که با تکیه بر داده‌های واقعی و تحلیل‌های پیشرفته، فرآیند تصمیم‌گیری را از حالت شهودی به رویکردی داده‌محور و عادلانه ارتقا دهند. چهارم، این مدل با قابلیت شناسایی دقیق‌تر متقاضیان واجد شرایط، می‌تواند نرخ موفقیت استخدام را افزایش داده و هزینه‌ها و زمان صرف‌شده برای مراحل غیرضروری فرآیند جذب را کاهش دهد. در نهایت، بهره‌گیری از چنین رویکردهایی می‌تواند به ایجاد مزیت رقابتی پایدار از طریق انتخاب بهینه سرمایه انسانی و بهبود عملکرد بلندمدت سازمان منجر شود.

**تعارض منافع.** برای ارائه مطالب و نگارش این مقاله هیچ‌گونه کمک مالی از هیچ فرد، نهاد و سازمانی دریافت نشده است و نتایج و دستاوردهای این مقاله به نفع یا ضرر سازمان یا فردی خاص نخواهد بود. حضور نویسندگان در این پژوهش به‌عنوان شهادی بی‌طرف ولی متخصص بوده است و نویسندگان هیچ‌گونه تعارض منافی ندارند.

## منابع

1. Aguilar-Ruiz J.S., Michalak M. (2024). Classification performance assessment for imbalanced multiclass data. *Scientific Reports*, 14(1), <https://doi.org/11038/s41598-024-61365-z>
2. Akram N., Irfan R., Al-Shamayleh A.S., Kousar A., Qaddos A., Imran M., Akhuzada A. (2024). Online recruitment fraud (ORF) detection using deep learning approaches. *IEEE Access*, 12, 109388–109408. <https://doi.org/10.1109/access.2024.3435670>
3. Almarzooq H., Waheed U. bin. (2024). Automating hyperparameter optimization in geophysics with Optuna: A comparative study. *Geophysical Prospecting*. <https://doi.org/10.1111/1365-2478.13484>
4. Ampomah E.K., Qin Z., Nyame G. (2020). Evaluation of tree-based ensemble machine learning models in predicting stock price direction of movement. *Information*, 11(6), 332. <https://doi.org/10.3390/info11060332>
5. Afaq A. (2025). Integrating predictive analytics for workforce planning. *Journal of Information Systems Engineering and Management*, 10(30s), 93–111. <https://doi.org/10.52783/jisem.v10i30s.4780>
6. Aubaidan B.H., Kadir R.A., Lajb M.T., Anwar M., Qureshi K.N., Taha B.A., Ghafoor K. (2025). A review of intelligent data analysis: Machine learning approaches for addressing class imbalance in healthcare – challenges and perspectives. *Intelligent Data Analysis: An International Journal*. <https://doi.org/10.1177/1088467x241305509>
7. Awad M., Fraihat S. (2023). Recursive feature elimination with cross-validation with decision tree: Feature selection method for machine learning-based intrusion detection systems. *Journal of Sensor and Actuator Networks*, 12(5), 67. <https://doi.org/10.3390/jsan12050067>
8. Ayoko O.B., Fujimoto Y. (2023). Diversity, inclusion, and human resource management: A call for more belongingness and intersectionality research. *Journal of Management & Organization*, 29(6), 983–990. <https://doi.org/10.1017/jmo.2023.72>
9. Azad M., Nehal T.H., Moshkov M. (2024). A novel ensemble learning method using majority-based voting of multiple selective decision trees. *Computing*, 107(1). <https://doi.org/10.1007/s00607-024-01394-8>
10. Bhutoria A.J., Lewis C. (2011). 100 things you should know about HR management with SAP. *SAP Press*.
11. Carvalho M., Pinho A.J., Brás S. (2025). Resampling approaches to handle class imbalance: A review from a data perspective. *Journal of Big Data*, 12(1). <https://doi.org/10.1186/s40537-025-01119-4>
12. Chen W., Du C. (2022). Human resource decision-making and recommendation based on Hadoop distributed big data platform. *Mathematical Problems in Engineering*, 2022, 1–9. <https://doi.org/10.1155/2022/8325677>
13. Dhinakaran D., Srinivasan L., Raja S.E., Valarmathi K., Gomathy Nayagam M. (2025). Synergistic feature selection and distributed classification framework for high-dimensional medical data analysis. *MethodsX*, 14, 103219–103219. <https://doi.org/10.1016/j.mex.2025.103219>
14. Du K.-L., Zhang R., Jiang B., Zeng J., Lu J. (2025). Foundations and innovations in data fusion and ensemble learning for effective consensus. *Mathematics*, 13(4), 587. <https://doi.org/10.3390/math13040587>
15. Dudáš A. (2024). Graphical representation of data prediction potential: Correlation graphs and correlation chains. *The Visual Computer*. <https://doi.org/10.1007/s00371-023-03240-y>
16. El Kharoua R. (2024). Predicting hiring decisions in recruitment data [Data set]. *Kaggle*. <https://doi.org/10.34740/KAGGLE/DSV/8715385>
17. Fürnkranz J. (2011). Decision tree. In: Sammut C., Webb G.I. (eds), *Encyclopedia of Machine Learning*. Springer, Boston, MA. [https://doi.org/10.1007/978-0-387-30164-8\\_204](https://doi.org/10.1007/978-0-387-30164-8_204)
18. Gohari K., Kazemnejad A., Mohammadi M., Eskandari F., Saberi S., Esmaili M., Sheidaei A. (2023). A Bayesian latent class extension of naive Bayesian classifier and its application to the classification of gastric cancer patients. *BMC Medical Research Methodology*, 23(1). <https://doi.org/10.1186/s12874-023-02013-4>
19. Graf R., Zeldovich M., Friedrich S. (2022). Comparing linear discriminant analysis and supervised learning algorithms for binary classification—A method comparison study. *Biometrical Journal*. <https://doi.org/10.1002/bimj.202200098>
20. Guido R., Ferrisi S., Lofaro D., Conforti D. (2024). An overview on the advancements of support vector machine models in healthcare applications: A review. *Information*, 15(4), 235. <https://doi.org/10.3390/info15040235>



21. Heydari M., Alinezhad A., Vahdani B. (2024). Application of deep learning networks to design quality control process in the motor oil industry. *Journal of Industrial Management Perspective*, 14(1), 211–237. <https://doi.org/10.48308/jimp.14.1.211> (In Persian)
22. Hornyák O., Iantovics L.B. (2023). AdaBoost algorithm could lead to weak results for data with certain characteristics. *Mathematics*, 11(8), 1801. <https://doi.org/10.3390/math11081801>
23. Irem E. (2024). Brain tumor classification and detection using a hybrid deep learning model. *Global Journal of Computer Sciences: Theory and Research*, 14(2), 24–29. <https://doi.org/10.18844/gjcs.v14i2.9604>
24. Jafarnejad A., Rezasoltani A., Khani A.M. (2025). Analyzing and predicting hiring decisions using machine learning and deep learning. *Journal of Public Administration*, 17(2), 295–327. <https://doi.org/10.22059/jipa.2025.390322.3649> (In Persian)
25. Jafarnejad A., Rezasoltani A., Khani A.M. (2025). Predicting heart disease using automated machine learning based on genetic algorithms. *Journal of Information Technology Management*, 17(2), 91–122. <https://doi.org/10.22059/jitm.2024.382556.3829> (In Persian)
26. Jafarnejad Chaghoshti A., Khani A.M., Rezasoltani A. (2024). Risk modeling in banking services for the blind using fuzzy FMEA and graph neural network (GNN). *Journal of Industrial Management Perspective*, 14(4), 223–255. <https://doi.org/10.48308/jimp.14.4.223> (In Persian)
27. Jafarnejad Chaghoshti A., Rezasoltani A., Khani A.M. (2024). Unleashing the power of ensemble learning: Predicting national ranks in Iran's university entrance examination. *Industrial Management Journal*, 16(3), 457–481. <https://doi.org/10.22059/imj.2024.381521.1008178> (In Persian)
28. Khani A.M., Kazazi A., Taqhvani Fard M.T. (2022). Evaluating the quality of services of the cultural and social deputy of Tehran municipality in the field of culture and art. *Social Development & Welfare Planning*, 13(50), 205–250. <https://doi.org/10.22054/qjsd.2021.58035.2110> (In Persian)
29. Kim K.G. (2016). Book review: Deep learning. *Healthcare Informatics Research*, 22(4), 351–354.
30. Krishnaiah V., Hullukere Kadegowda Y. (2022). Undergraduate engineering students employment prediction using hybrid approach in machine learning. *International Journal of Electrical and Computer Engineering (IJECE)*, 12(3), 2783–2791. <https://doi.org/10.11591/ijece.v12i3.pp2783-2791>
31. Kundu S., Palani S. (2024). Unlocking talent: Exploring the potential of AI and ML algorithms in recruitment process. *Proceedings of the IEEE International Conference on Electrical, Electronics, Communication Technologies (ICEECT)*, 1–6. <https://doi.org/10.1109/iceect61758.2024.10739192>
32. Li H., Wang Q., Liu J., Zhao D. (2022). A prediction model of human resources recruitment demand based on convolutional collaborative BP neural network. *Computational Intelligence and Neuroscience*, 2022, e3620312. <https://doi.org/10.1155/2022/3620312>
33. Lokker C., Abdelkader W., Bagheri E., Parrish R., Cotoi C., Navarro T., Germini F., Linkins L.-A., Haynes R.B., Chu L., Afzal M., Iorio A. (2024). Boosting efficiency in a clinical literature surveillance system with LightGBM. *PLOS Digital Health*, 3(9), e0000299–e0000299. <https://doi.org/10.1371/journal.pdig.0000299>
34. Lopez-Pacheco M., Yu W. (2021). Complex valued deep neural networks for nonlinear system modeling. *Neural Processing Letters*. <https://doi.org/10.1007/s11063-021-10644-1>
35. Mahajan P., Uddin S., Hajati F., Moni M.A. (2023). Ensemble learning for disease prediction: A review. *Healthcare*, 11(12), 1808–1808. <https://doi.org/10.3390/healthcare11121808>
36. Mishra D., Naik B., Nayak J., Soury A., Dash P.B., Vimal S. (2022). Light gradient boosting machine with optimized hyperparameters for identification of malicious access in IoT network. *Digital Communications and Networks*. <https://doi.org/10.1016/j.dcan.2022.10.004>
37. Mohammed A.Q. (2019). HR analytics: A modern tool in HR for predictive decision making. *Journal of Management*, 10(3). <https://doi.org/10.34218/jom.6.3.2019.007>
38. Nooraei Abadeh M., Bahadori S., Mirzaei M., Ebrahimi N. (2024). A quantitative approach for prioritizing supply chain priorities in smart industries using data-driven prediction: Two common industrial case studies. *Journal of Industrial Management Perspective*, 14(3), 169–188. <https://doi.org/10.48308/jimp.14.3.169> (In Persian)
39. Okatta C.G., Ajayi F.A., Olawale O. (2024). Navigating the future: Integrating AI and machine learning in HR practices for a digital workforce. *Computer Science & IT Research Journal*, 5(4), 1008–1030.
40. Pagan M., Simoncelli E.P., Rust N.C. (2016). Neural quadratic discriminant analysis: Nonlinear decoding with V1-like computation. *Neural Computation*, 28(11), 2291–2319. [https://doi.org/10.1162/neco\\_a\\_00890](https://doi.org/10.1162/neco_a_00890)
41. Pala A., Oleynik A., Utseth I., Handegard N.O. (2023). Addressing class imbalance in deep learning for acoustic target classification. *ICES Journal of Marine Science*, 80(10), 2530–2544. <https://doi.org/10.1093/icesjms/fsad165>

42. Passemiers A., Folco P., Raimondi D., Birolo G., Moreau Y., Fariselli P. (2024). A quantitative benchmark of neural network feature selection methods for detecting nonlinear signals. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-82583-5>
43. Pessach D., Singer G., Avrahami D., Chalutz Ben-Gal H., Shmueli E., Ben-Gal I. (2020). Employees recruitment: A prescriptive analytics approach via machine learning and mathematical programming. *Decision Support Systems*, 134(1), 113290. <https://doi.org/10.1016/j.dss.2020.113290>
44. Priyanka M., Kaur M.R., Anmoldeep M., Malhotra M.R. (2024). From hiring to retention: The impact of AI on modern HR practices. In *Blockchain and AI in Business*, 271.
45. Rainio O., Teuvo J., Klén R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14(1), 1–14. <https://doi.org/10.1038/s41598-024-56706-x>
46. Rajagopalan B., Lall U. (1999). A k-nearest-neighbor simulator for daily precipitation and other weather variables. *Water Resources Research*, 35(10), 3089–3101. <https://doi.org/10.1029/1999wr900028>
47. Ravichandran T., Lertwongsatien C. (2005). Effect of information systems resources and capabilities on firm performance: A resource-based perspective. *Journal of Management Information Systems*, 21(4), 237–276. <https://doi.org/10.1080/07421222.2005.11045820>
48. Rizkallah L.W. (2025). Enhancing the performance of gradient boosting trees on regression problems. *Journal of Big Data*, 12(1). <https://doi.org/10.1186/s40537-025-01071-3>
49. Saha D., Bhandari D., Mukherjee G. (2023). Job recommendation: A hybrid approach using text processing. In *Proceedings of International Conference on Computational Intelligence and Data Engineering*, 74–85. [https://doi.org/10.1007/978-981-99-3478-2\\_8](https://doi.org/10.1007/978-981-99-3478-2_8)
50. Sasirekha V., Abinash T., Venkateswara Prasad B. (2024). HR analytics and people management. In *Emerging Trends in Human Resource Management*. <https://doi.org/10.2174/9789815274196124010007>
51. Shen Y., Wu S., Wang Y., Wang J., Yang Z. (2024). Interpretable model for rockburst intensity prediction based on Shapley values-based Optuna-random forest. *Underground Space*. <https://doi.org/10.1016/j.undsp.2024.09.002>
52. Shukla R., Singh T.R. (2024). AlzGenPred - CatBoost-based gene classifier for predicting Alzheimer's disease using high-throughput sequencing data. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-82208-x>
53. Shinde P.P., Shah S. (2018). A review of machine learning and deep learning applications. In *Proceedings of the International Conference on Computing, Communication, Control and Automation (ICCUBEA)*. <https://doi.org/10.1109/ICCUBEA.2018.8697857>
54. Srinivasu P.N., Jaya Lakshmi G., Gudipalli A., Narahari S.C., Shafi J., Woźniak M., Ijaz M.F. (2024). XAI-driven CatBoost multi-layer perceptron neural network for analyzing breast cancer. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-79620-8>
55. Starbuck C.M. (2023). Logistic regression. In *Springer EBooks*, 223–238. [https://doi.org/10.1007/978-3-031-28674-2\\_12](https://doi.org/10.1007/978-3-031-28674-2_12)
56. Temsamani Khallouk Yassine, Said A. (2023). Implementing AI in HRM: Leveraging machine learning for smart recruitment systems. In *Proceedings of the International Conference on Technology, Management, Operations and Decisions (ICTMOD)*. <https://doi.org/10.1109/ictmod59086.2023.10472910>
57. Toufighi, S. P., Khani, A. M., Rezasoltani, A., Sahebi, I. G., & Vang, J. (2025). Forecasting stock market anomalies in emerging markets: An OPTUNA-optimized isolation forest and K-means approach. *Machine Learning With Applications*, 22, 100770. <https://doi.org/10.1016/j.mlwa.2025.100770>
58. Wahyuning S., Sudiby S.K. (2024). Leveraging machine learning for talent acquisition: Predicting high-performance candidates in human resource management. *Journal of Management and Informatics*, 3(1), 87–104. <https://doi.org/10.51903/jmi.v3i1.44>
59. Wang Q., Lu H. (2024). A novel stacking ensemble learner for predicting residual strength of corroded pipelines. *NPJ Materials Degradation*, 8(1). <https://doi.org/10.1038/s41529-024-00508-z>
60. Wiens M., Verone-Boyle A., Henscheid N., Podichetty J.T., Burton J. (2025). A tutorial and use case example of the eXtreme Gradient Boosting (XGBoost) artificial intelligence algorithm for drug development applications. *Clinical and Translational Science*, 18(3). <https://doi.org/10.1111/cts.70172>
61. Wilkens U., Lutzeyer I., Zheng C., Beser A., Prilla M. (2025). Augmenting diversity in hiring decisions with artificial intelligence tools. *The International Journal of Human Resource Management*, 1–38. <https://doi.org/10.1080/09585192.2025.2492867>

62. Yanagimoto H. (2017). Support vector machines with neural network. *Frontiers in Artificial Intelligence and Applications*. <https://doi.org/10.3233/978-1-61499-800-6-124>
63. Yassine T., Said A. (2024). Predictive hiring and AI: Elevating recruitment with optimized neural networks and gradient descent. *International Journal of Intelligent Information Systems*, 13(6), 117–127. <https://doi.org/10.11648/j.ijis.20241306.11>