



## ارائه مدل استخدام مبتنی بر شایسته‌سالاری در بانک صادرات با استفاده از هوش مصنوعی

فاطمه پرماسی <sup>۱</sup> شهرام بگ زاده <sup>۲</sup> مجید احمدلو <sup>۳</sup> بابک نوری مقدم <sup>۴</sup>	تاریخ چاپ: ۱۰ دی ۱۴۰۴ تاریخ پذیرش: ۱۸ آذر ۱۴۰۴ تاریخ بازنگری: ۱۱ آذر ۱۴۰۴ تاریخ ارسال: ۱۲ شهریور ۱۴۰۴	<b>شبهه استناددهی:</b> پرماسی، فاطمه، بگ‌زاده، شهرام، احمدلو، مجید، و نوری مقدم، بابک. (۱۴۰۴). ارائه مدل استخدام مبتنی بر شایسته‌سالاری در بانک صادرات با استفاده از هوش مصنوعی. یادگیری هوشمند و تحول مدیریت، ۳(۵)، ۲۴-۱.
--	--	--

### چکیده

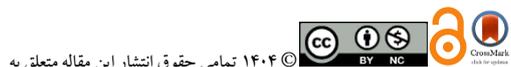
هدف این پژوهش طراحی و اعتبارسنجی یک مدل بهینه استخدام مبتنی بر شایسته‌سالاری در بانک صادرات با بهره‌گیری از الگوریتم‌های هوش مصنوعی است. این پژوهش با رویکرد آمیخته انجام شد؛ در بخش کیفی، با استفاده از روش دلفی و مشارکت مدیران و کارشناسان منابع انسانی بانک صادرات، مؤلفه‌های شایستگی شناسایی و نهایی شدند و در بخش کمی، داده‌های عملکردی، آزمون‌های شغلی، فردی و اجتماعی کارکنان گردآوری و پس از پیش‌پردازش، با چهار الگوریتم یادگیری ماشین شامل شبکه عصبی عمیق، رگرسیون ریب، XGBoost و SVM مدل‌سازی شدند. معیارهای ضریب تعیین تعدیل شده و خطای مطلق برای مقایسه توان پیش‌بینی مدل‌ها به کار رفت. نتایج نشان داد شبکه عصبی عمیق بالاترین توان پیش‌بینی را نسبت به سایر الگوریتم‌ها دارد. در تمامی مدل‌ها، کار تیمی، مهارت‌های ارتباطی، مشتری‌مداری و تعهد سازمانی به‌طور معناداری مهم‌ترین عوامل شایستگی شناسایی شدند، در حالی که متغیرهایی نظیر قومیت، گرایش سیاسی، محل تولد و محل فعالیت کم‌اهمیت‌ترین نقش را در پیش‌بینی شایستگی ایفا کردند. یافته‌ها حاکی از آن است که به کارگیری هوش مصنوعی می‌تواند با کاهش سوگیری‌های غیرمرتبط و تمرکز بر شاخص‌های عملکردی و رفتاری، مبنای علمی و عادلانه برای استقرار نظام استخدام مبتنی بر شایسته‌سالاری در بانک‌ها فراهم سازد.

**واژگان کلیدی:** شایسته‌سالاری، استخدام، هوش مصنوعی، بانک صادرات، یادگیری ماشین

### مشخصات نویسندگان:

۱. دانشجوی دکتری، گروه مدیریت دولتی، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران
۲. گروه مدیریت دولتی، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران
۳. گروه مدیریت، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران
۴. گروه مهندسی کامپیوتر، واحد اردبیل، دانشگاه آزاد اسلامی، اردبیل، ایران

پست الکترونیکی: shahram.begzadeh@iau.ac.ir



تمامی حقوق انتشار این مقاله متعلق به نویسنده است. © ۱۴۰۴

انتشار این مقاله به‌صورت دسترسی آزاد مطابق با گواهی CC BY-NC 4.0 صورت گرفته است.

## Designing a Merit-Based Recruitment Model in Bank Saderat Using Artificial Intelligence

Fatima Parmasi <sup>1</sup> Shahram Begzadeh <sup>2*</sup> Majid Ahmadlu <sup>3</sup> Babak Nouri-Moghaddam <sup>4</sup>	Submit Date: 03 September 2025 Revise Date: 02 December 2025 Accept Date: 09 December 2025 Publish Date: 31 December 2025	<b>How to cite:</b> Parmasi, F., Begzadeh, S., Ahmadlu, M., & Nouri-Moghaddam, B. (2025). Designing a Merit-Based Recruitment Model in Bank Saderat Using Artificial Intelligence. <i>Intelligent Learning and Management Transformation</i> , 3(5), 1-24.
---	--	--

### Abstract

This study aims to design and validate an optimal merit-based recruitment model for Bank Saderat using artificial intelligence techniques. A mixed-methods design was employed. In the qualitative phase, a Delphi approach involving human resource managers and experts of Bank Saderat was used to identify and finalize competency components. In the quantitative phase, employees' performance, test scores, job-related, personal, and socio-cultural data were collected, preprocessed, and modeled using four machine learning algorithms: Deep Neural Network, Ridge Regression, XGBoost, and Support Vector Machine. Adjusted  $R^2$  and mean absolute error were applied to compare predictive performance. The results indicated that the Deep Neural Network achieved the highest predictive power among all models. Across all algorithms, teamwork, communication skills, customer orientation, and organizational commitment were consistently identified as the most significant predictors of employee competency, whereas variables such as ethnicity, political orientation, place of birth, and workplace location showed minimal predictive importance. The findings demonstrate that artificial intelligence-based models can enhance merit-based recruitment by prioritizing performance-related competencies and minimizing irrelevant biases, thereby supporting more objective and efficient human resource decision-making in the banking sector.

**Keywords:** Meritocracy, Recruitment, Artificial Intelligence, Bank Saderat, Machine Learning

### Authors' Information:

[shahram.begzadeh@iaiu.ac.ir](mailto:shahram.begzadeh@iaiu.ac.ir)

1. PhD Student, Department of Public Administration, Ard.C., Islamic Azad University, Ardabil, Iran
2. Department of Public Administration, Ard.C., Islamic Azad University, Ardabil, Iran
3. Department of Management, Ard.C., Islamic Azad University, Ardabil, Iran
4. Department of Computer Engineering, Ard.C., Islamic Azad University, Ardabil, Iran



© 2025 the authors. This is an open access article under the terms of the [CC BY-NC 4.0 License](https://creativecommons.org/licenses/by-nc/4.0/).

## مقدمه

در دهه‌های اخیر، تحولات شتابان محیط‌های اقتصادی، فناورانه و اجتماعی، سازمان‌ها را با الزامات نوینی در حوزه مدیریت منابع انسانی مواجه ساخته است. جهانی‌شدن، رقابت فزاینده برای جذب استعدادها، تحول مشاغل و دیجیتالی‌شدن فرآیندهای سازمانی، سبب شده است که سرمایه انسانی به مهم‌ترین منبع مزیت رقابتی پایدار بدل شود. در چنین شرایطی، سازمان‌ها دیگر نمی‌توانند با تکیه بر الگوهای سنتی جذب و استخدام، پاسخگوی نیازهای پیچیده و پویای خود باشند و ناگزیر به بازاندیشی در نظام‌های استخدامی و ارتقای شایستگی‌های انسانی هستند (Abbaspour, 2019; Armstrong, 2014). یکی از مفاهیم محوری که در این بازاندیشی جایگاهی اساسی یافته، شایسته‌سالاری است؛ مفهومی که بر انتخاب، به‌کارگیری و ارتقای افراد بر اساس توانمندی‌ها، مهارت‌ها، شایستگی‌ها و عملکرد واقعی آنان تأکید دارد و تلاش می‌کند عوامل غیرمرتبط و سوگیرانه را از فرآیندهای تصمیم‌گیری منابع انسانی حذف کند (Abdaspour, 2014; Bell, 2005).

شایسته‌سالاری ریشه‌ای عمیق در ادبیات مدیریت، علوم اجتماعی و حتی فلسفه سیاسی دارد و به‌عنوان سازوکاری برای تحقق عدالت سازمانی، افزایش کارایی و تقویت مشروعیت نظام‌های مدیریتی شناخته می‌شود. در حوزه مدیریت منابع انسانی، شایسته‌سالاری به‌معنای استقرار نظامی است که در آن جذب، گزینش، ارزیابی و ارتقای کارکنان بر پایه شایستگی‌های رفتاری، فنی، دانشی و انگیزشی صورت می‌گیرد (Ahmadi, 2011; Bagheri Zadeh, 2010). پژوهش‌ها نشان می‌دهند سازمان‌هایی که از الگوهای شایسته‌سالارانه بهره می‌گیرند، از سطح بالاتری از بهره‌وری، رضایت شغلی، تعهد سازمانی و ماندگاری کارکنان برخوردارند (Bateman & Snell, 2017; Lawler, 2017). از این‌رو، شایسته‌سالاری نه تنها یک ارزش هنجاری، بلکه راهبردی کارکردی برای بقا و رشد سازمان‌ها در محیط‌های رقابتی محسوب می‌شود.

با وجود اهمیت گسترده شایسته‌سالاری، پیاده‌سازی عملی آن همواره با چالش‌های متعددی مواجه بوده است. یکی از مهم‌ترین چالش‌ها، دشواری در شناسایی و سنجش دقیق شایستگی‌ها و ترجمه آن‌ها به معیارهای عملیاتی برای تصمیم‌گیری‌های استخدامی است (Mansfield, 2005; Mirabelle, 2016). بسیاری از سازمان‌ها همچنان از شاخص‌های محدود، ایستا و بعضاً ذهنی برای ارزیابی شایستگی افراد استفاده می‌کنند؛ شاخص‌هایی که توان تبیین پیچیدگی عملکرد انسانی را ندارند و زمینه بروز خطا و سوگیری را فراهم می‌سازند (Diyanti & Irfani, 2010; Gharavand, 2008). این مسئله به‌ویژه در سازمان‌های بزرگ و پیچیده، مانند بانک‌ها، که با حجم بالایی از متقاضیان، تنوع مشاغل و حساسیت بالایی تصمیمات استخدامی مواجه‌اند، اهمیت دوچندان می‌یابد.

در این میان، تحول دیجیتال و پیشرفت‌های چشمگیر در حوزه هوش مصنوعی و تحلیل داده‌های کلان، افق‌های جدیدی را پیش روی نظام‌های استخدامی گشوده است. هوش مصنوعی با توان پردازش حجم عظیمی از داده‌ها، شناسایی الگوهای پنهان و مدل‌سازی روابط پیچیده میان متغیرها، امکان تصمیم‌گیری دقیق‌تر، سریع‌تر و عینی‌تر را فراهم می‌کند (Dai et al., 2022; Olson & Durusun, 2008). به‌کارگیری الگوریتم‌های

یادگیری ماشین، شبکه‌های عصبی و روش‌های داده‌کاوی در مدیریت منابع انسانی، به‌ویژه در حوزه جذب و گزینش، می‌تواند بسیاری از محدودیت‌های رویکردهای سنتی را برطرف سازد و مبنایی علمی برای شایسته‌گزینی فراهم آورد (Khaef et al., 2007; Madadipouya, 2015).

ادبیات پژوهش نشان می‌دهد که استفاده از هوش مصنوعی در فرآیندهای استخدامی، نه تنها دقت پیش‌بینی موفقیت شغلی را افزایش می‌دهد، بلکه می‌تواند سوگیری‌های انسانی را نیز کاهش دهد. الگوریتم‌های هوشمند قادرند مجموعه‌ای گسترده از متغیرهای فردی، شغلی، عملکردی و رفتاری را به‌طور هم‌زمان تحلیل کرده و وزن واقعی هر یک را در پیش‌بینی شایستگی افراد تعیین کنند (Allal-Ch'erif et al., 2021; Meng, 2020). این قابلیت، به‌ویژه در محیط‌های بانکی که تصمیمات استخدامی پیامدهای بلندمدت مالی و اعتباری دارند، از اهمیت ویژه‌ای برخوردار است.

در سال‌های اخیر، پژوهش‌های متعددی به بررسی پیوند میان شایسته‌سالاری، مدیریت منابع انسانی و فناوری‌های نوین پرداخته‌اند. برخی مطالعات بر نقش داده‌کاوی و الگوریتم‌های تصمیم‌گیری در بهبود کیفیت انتخاب نیروی انسانی تأکید کرده‌اند (Azar et al., 2011; Kharazian et al., 2019). برخی دیگر نشان داده‌اند که بهره‌گیری از مدل‌های تحلیلی پیشرفته می‌تواند به شناسایی شایستگی‌های کلیدی و اولویت‌بندی آن‌ها در فرآیند جذب منجر شود (Khodai Ismail Kandi et al., 2019; Timouri et al., 2018). در سطح کلان‌تر، مطالعاتی نیز به تأثیر شایسته‌سالاری بر حکمرانی مطلوب، مشروعیت نهادی و عملکرد سازمانی پرداخته‌اند (Azkiya et al., 2025; Pagano & Picariello, 2024).

با این حال، مرور انتقادی ادبیات نشان می‌دهد که بخش قابل توجهی از پژوهش‌های موجود، با محدودیت‌هایی اساسی مواجه‌اند. بسیاری از مطالعات، شایستگی را به‌صورت تک‌بعدی یا با استفاده از شاخص‌های محدود تعریف کرده‌اند و کمتر به ماهیت چندبعدی و پویای آن توجه داشته‌اند (Boyatzis, 2005; Green, 2015). افزون بر این، در بسیاری از پژوهش‌ها، استفاده از هوش مصنوعی صرفاً به‌عنوان ابزار کمکی مطرح شده و کمتر شاهد ارائه یک مدل جامع، بومی و قابل اجرا برای استخدام مبتنی بر شایسته‌سالاری هستیم (Farndale et al., 2010; Sahay, 2014). این خلأ به‌ویژه در زمینه سازمان‌های مالی و بانکی در کشورهای در حال توسعه، از جمله ایران، محسوس‌تر است.

نظام بانکی به‌عنوان یکی از ارکان اصلی اقتصاد، نقشی تعیین‌کننده در ثبات مالی، توسعه اقتصادی و اعتماد عمومی ایفا می‌کند. کیفیت سرمایه انسانی در بانک‌ها، به‌طور مستقیم بر کیفیت خدمات، رضایت مشتریان و عملکرد مالی تأثیر می‌گذارد (Kumar & Rajesh, 2023). از این رو، استقرار نظام‌های استخدامی کارآمد و شایسته‌سالار در بانک‌ها، نه تنها یک ضرورت سازمانی، بلکه یک الزام اقتصادی و اجتماعی محسوب می‌شود.

(Ghamami & Hosseini, 2019). با وجود این اهمیت، شواهد نشان می‌دهد که فرآیندهای استخدامی در بسیاری از بانک‌ها همچنان متأثر از معیارهای سنتی، غیرشفاف و بعضاً غیرمرتبط با شایستگی‌های واقعی هستند (Ghahramani, 2011, 2016).

در کنار این مسائل، تحولات محیط کار و مسیرهای شغلی نیز بر پیچیدگی تصمیمات استخدامی افزوده است. افزایش تحرک شغلی، تغییر انتظارات کارکنان و دگرگونی ماهیت مشاغل، سبب شده است که پیش‌بینی موفقیت شغلی و ماندگاری کارکنان دشوارتر از گذشته باشد (Grant, 2008; Sullivan & Al Ariss, 2019). در چنین فضایی، سازمان‌ها نیازمند ابزارهایی هستند که بتوانند با دقت بالا، تطابق میان ویژگی‌های فردی و الزامات شغلی را ارزیابی کنند و از سرمایه‌گذاری بلندمدت خود بر نیروی انسانی اطمینان یابند (Porter et al., 2007; Prahalad & Hamel, 2009).

هوش مصنوعی و تحلیل داده‌های پیشرفته، پاسخی بالقوه به این نیاز محسوب می‌شوند. پژوهش‌ها نشان داده‌اند که مدل‌های هوشمند می‌توانند روابط غیرخطی میان متغیرهای شایستگی و عملکرد را آشکار سازند و در مقایسه با روش‌های سنتی، قدرت تبیین و پیش‌بینی بالاتری داشته باشند (Dai et al., 2022; Gilsing & Guysters, 2008). افزون بر این، استفاده از این فناوری‌ها می‌تواند به افزایش شفافیت، پاسخگویی و عدالت در تصمیمات استخدامی منجر شود؛ امری که از منظر حقوقی و نهادی نیز اهمیت فراوانی دارد (Abdaspour, 2014; Ghamami & Hosseini, 2019).

در سال‌های اخیر، برخی پژوهش‌های جدیدتر تلاش کرده‌اند پیوند میان شایسته‌سالاری، هوش مصنوعی و حکمرانی سازمانی را به صورت جامع‌تری بررسی کنند. برای مثال، مطالعاتی بر نقش رویه‌های شایسته‌سالارانه در بهبود عملکرد کارکنان و ارتقای اعتماد سازمانی تأکید کرده‌اند (Divina, 2024; Hadadnia, 2024). همچنین پژوهش‌هایی با رویکرد انتقادی، به بررسی ابعاد اخلاقی و نهادی شایسته‌سالاری پرداخته و بر ضرورت طراحی نظام‌هایی تأکید کرده‌اند که هم کارآمد و هم عادلانه باشند (Bell, 2005; Tongdong, 2025). با وجود این پیشرفت‌ها، همچنان نیاز به مطالعاتی احساس می‌شود که بتوانند یک مدل عملیاتی، داده‌محور و متناسب با بافت سازمانی بانک‌ها ارائه دهند.

بر این اساس، خلأ اصلی در ادبیات موجود را می‌توان در نبود مدلی جامع و بومی برای استخدام مبتنی بر شایسته‌سالاری با بهره‌گیری نظام‌مند از هوش مصنوعی دانست؛ مدلی که بتواند مجموعه‌ای گسترده از شاخص‌های شایستگی را به صورت هم‌زمان تحلیل کند، وزن واقعی هر شاخص را مشخص سازد و مبنایی علمی برای تصمیم‌گیری‌های استخدامی فراهم آورد (Abbaspour, 2019; Meng, 2020). چنین مدلی می‌تواند ضمن ارتقای کیفیت جذب نیروی انسانی، به کاهش سوگیری‌ها، افزایش عدالت سازمانی و بهبود عملکرد بلندمدت بانک‌ها کمک کند.

با توجه به مطالب پیش گفته، پژوهش حاضر با تمرکز بر پیوند میان شایسته‌سالاری و هوش مصنوعی در بستر نظام بانکی، درصدد پاسخ به این پرسش اساسی است که چگونه می‌توان با بهره‌گیری از الگوریتم‌های هوش مصنوعی، یک مدل بهینه و علمی برای استفاده مبتنی بر شایسته‌سالاری طراحی کرد. هدف این مطالعه طراحی و تبیین یک مدل استفاده مبتنی بر شایسته‌سالاری با استفاده از هوش مصنوعی در بانک صادرات است.

### روش‌شناسی

هدف غائی از اجرای این پژوهش ارائه مدلی به جهت شناسایی افراد شایسته و واجد شرایط در زمینه استخدام می‌باشد. به عبارت بهتر، طراحی الگوی استفاده مبتنی بر توانمندی یا شایستگی با رویکرد هوش مصنوعی هدف اصلی این تحقیق محسوب می‌شود.

به منظور واکاوی اهداف و سوالات پژوهش، جامعه آماری مورد نظر در این تحقیق بانک صادرات لحاظ شده است. بدین ترتیب در بخش کیفی، جامعه آماری این پژوهش شامل مدیران و کارشناسان منابع انسانی بانک صادرات می‌باشد در حقیقت، به جهت مشخص کردن متغیرهای کیفی مورد نظر نظیر شاخص‌های شایستگی (در قالب متغیر هدف) و تعیین سطح کیفی شایستگی کارکنان، از نظرات خبرگان، کارشناسان و مدیران در راستای تکمیل ادبیات موجود تا دستیابی به مولفه‌های نهایی خاص سازمان مورد نظر استفاده می‌شود. همچنین از آنجا که اساس مطالعه حاضر تبیین مدل و الگوی شایستگی کارکنان در قالب تکنیک هوش مصنوعی است، بدین جهت اطلاعات کمی اعم از متغیرهای آزمون و متغیرهای ارزیابی عملکرد و امتیازات شغلی با بهره‌گیری از اطلاعات کارکنان حاصل می‌شود.

در بخش کیفی تحقیق، نمونه‌گیری به شیوه گلوله برفی تا رسیدن به آستانه اشباع صورت خواهد گرفت. همچنین در بخش کمی نیز، به جهت استفاده از همه جامعه آماری در فرآیند تحلیل و ارزیابی، در این مطالعه روند نمونه‌گیری وجود ندارد. مگر آنکه اطلاعات لازم برای بخشی از اعضای جامعه آماری در دسترس نباشد که در این صورت این افراد به طور سیستماتیک از گردونه خارج می‌شوند.

در تحقیق حاضر روش گردآوری اطلاعات مربوط به ادبیات تحقیق، روش کتابخانه‌ای شامل کتب و مقالات مختلف و نشریات داخلی و خارجی می‌باشد. در قسمت کیفی تحقیق با بهره‌گیری از تحقیقات کتابخانه‌ای و نظرات خبرگان و کارشناسان امر، نسبت به تعیین مولفه‌های اولیه اقدام می‌گردد.

ابتدا داده‌های این پژوهش مورد پیش پردازش قرار گرفته اند. که شامل مراحل و کدهای زیر در محیط نرم افزار پایتون است:

کد ۱: وارد کردن کتابخانه‌های ضروری

```
import pandas as pd
import numpy as np
from sklearn.preprocessing import StandardScaler
```

```
from sklearn.compose import ColumnTransformer
from sklearn.model_selection import train_test_split
```

کد ۲: بارگیری داده‌های خام

```
data = pd.read_csv('employee_data.csv')
```

کد ۳: جداسازی ویژگی‌ها و متغیر هدف

```
X = data.drop(columns=['Target'])
```

```
y = data['Target']
```

کد ۴: استانداردسازی داده‌ها

```
scaler = StandardScaler()
```

```
X_scaled = scaler.fit_transform(X)
```

هدف اصلی از استانداردسازی داده‌ها در مدل‌های هوش مصنوعی، بهبود عملکرد و کارایی مدل از طریق یکسان‌سازی مقیاس و توزیع ویژگی‌های داده است. این فرآیند مزایای کلیدی زیر را دارد:

**بهبود همگرایی مدل**

الگوریتم‌های بهینه‌سازی مانند گرادینان کاهش می‌دهد در مدل‌هایی مانند شبکه‌های عصبی، با داده‌های استاندارد شده سریع‌تر و پایدارتر همگرا می‌شوند، زیرا همه ویژگی‌ها در یک محدوده عددی مشابه قرار می‌گیرند.

**جلوگیری از سلطه ویژگی‌های با مقیاس بزرگ**

برخی الگوریتم‌ها مانند K-NN یا SVM تحت تأثیر ویژگی‌های با مقیاس بزرگتر قرار می‌گیرند. استانداردسازی از تحریف نتایج توسط این ویژگی‌ها جلوگیری می‌کند.

**افزایش دقت و عملکرد مدل**

بسیاری از روش‌های یادگیری ماشین مانند رگرسیون با داده‌های استاندارد شده نتایج بهتری تولید می‌کنند، زیرا محاسبات ریاضی آن‌ها به مقیاس داده‌ها حساس است.

**تسریع فرآیند آموزش**

استانداردسازی باعث می‌شود وزن‌های مدل با سرعت متعادلی به‌روزرسانی شوند، که زمان یادگیری را کاهش می‌دهد.

### پشتیبانی از منظم‌سازی (Regularization)

تکنیک‌های منظم‌سازی مانند  $L1/L2$  زمانی مؤثرتر هستند که همه ویژگی‌ها در یک مقیاس باشند.

کد ۵: تقسیم داده‌ها به آموزش و آزمون

```
X_train, X_test, y_train, y_test = train_test_split(X_scaled, y, test_size=۰.۲, random_state=۴۲)
```

۸۰ درصد داده‌ها بعنوان داده‌های آموزش و ۲۰ درصد داده‌ها بعنوان داده‌های تست در نظر گرفته شدند.

کدنویسی مدل‌ها

مدل شبکه عصبی عمیق

کد ۶: وارد کردن کتابخانه‌های مورد نیاز

```
import tensorflow as tf
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout, BatchNormalization
from tensorflow.keras.optimizers import Adam
from tensorflow.keras.callbacks import EarlyStopping
from sklearn.metrics import r۲_score, mean_absolute_error
```

• **tensorflow/keras**: برای ساخت و آموزش مدل‌های شبکه عصبی

• **sklearn.metrics**: برای محاسبه معیارهای ارزیابی

کد ۷: تعریف معماری مدل DNN

```
model = Sequential([
    Dense(۶۴, activation='relu', input_shape=(X_train.shape[۱],)),
    BatchNormalization(),
    Dropout(۰.۳),
```

Dense(۳۲, activation='relu'),

BatchNormalization(),

Dropout(۰.۲),

Dense(۱) # لایه خروجی بدون تابع فعال‌ساز برای مسئله رگرسیون

)

model.summary()

• لایه‌های Dense :

- لایه اول: ۶۴ نورون با تابع فعال‌ساز ReLU

- لایه دوم: ۳۲ نورون با ReLU

- لایه خروجی: ۱ نورون بدون تابع فعال‌ساز (برای رگرسیون)

• **BatchNormalization**: نرمال‌سازی خروجی هر لایه برای پایداری آموزش

• **Dropout**: غیرفعال کردن تصادفی ۳۰٪ نورون‌ها در لایه اول و ۲۰٪ در لایه دوم برای جلوگیری از بیش‌برازش

کد ۸: کامپایل مدل

optimizer = Adam(learning\_rate=۰.۰۰۱)

model.compile(

optimizer=optimizer,

loss='mse',

metrics=['mae']

)

• Adam Optimizer: الگوریتم بهینه‌سازی با نرخ یادگیری ۰.۰۰۱

• تابع زیان: MSE مناسب برای مسائل رگرسیون

• EarlyStopping: توقف آموزش اگر خطای اعتبارسنجی به مدت ۱۰ دوره بهبود نیابد

کد ۹: آموزش مدل

```
early_stop = EarlyStopping(monitor='val_loss', patience=۱۰, restore_best_weights=True)

history = model.fit(
    X_train, y_train,
    validation_split=۰.۲,
    epochs=۲۰۰,
    batch_size=۳۲,
    callbacks=[early_stop],
    verbose=۱
)
```

- validation\_split=۰.۲: اختصاص ۲۰٪ داده‌های آموزشی برای اعتبارسنجی
- epochs=۲۰۰: حداکثر تعداد دوره‌های آموزش
- batch\_size=۳۲: تعداد نمونه‌ها در هر به‌روزرسانی وزن‌ها

کد ۱۰: ارزیابی مدل

```
y_pred = model.predict(X_test).flatten()

r۲ = r۲_score(y_test, y_pred)

mae = mean_absolute_error(y_test, y_pred)

print(f"\nنتایج ارزیابی نهایی")
print(f"R2 Score: {r۲:.۴f}")
print(f"MAE: {mae:.۴f}")
print(f"RMSE: {np.sqrt(history.history['val_loss'][-۱]):.۴f}")
```

کد ۱۱: تحلیل اهمیت متغیرها

```
def calculate_feature_importance(model, X_sample, feature_names):
```

```

baseline_pred = model.predict(X_sample).mean()

importances = []

for i in range(X_sample.shape[1]):

    X_perturbed = X_sample.copy()

    X_perturbed[:,i] = 0 # حذف اثر متغیر i

    perturbed_pred = model.predict(X_perturbed).mean()

    importance = abs(baseline_pred - perturbed_pred)

    importances.append(importance)

return pd.DataFrame({

    'Feature': feature_names,

    'Importance': importances

}).sort_values('Importance', ascending=False)

feature_names = [data.columns[i] for i in range(X_test.shape[1])]

importance_df = calculate_feature_importance(model, X_sample, feature_names)

print(importance_df)

```

مدل رگرسیون ریج

کد ۱۲: وارد کردن کتابخانه‌های مورد نیاز

```

from sklearn.linear_model import Ridge

from sklearn.metrics import r2_score, mean_absolute_error

```

- **Ridge**: برای پیاده‌سازی مدل رگرسیون ریج
- **r2\_score, mean\_absolute\_error**: برای ارزیابی مدل

کد ۱۳: آموزش مدل رگرسیون ریج

```
ridge_model = Ridge(alpha=۱.۰)
```

```
ridge_model.fit(X_train,y_train)
```

- $\alpha$ : پارامتر تنظیم (regularization) که مقدار پیش فرض ۱ دارد و هرچه بزرگتر باشد تاثیر regularization بیشتر است.

کد ۱۴: ارزیابی مدل

```
y_pred = ridge_model.predict(X_test)
```

```
r2 = r2_score(y_test,y_pred)
```

```
mae = mean_absolute_error(y_test,y_pred)
```

```
print(f"R2 Score: {r2:.4f}")
```

```
print(f"MAE: {mae:.4f}")
```

- $R^2$  Score: نشان می‌دهد چند درصد از واریانس داده‌ها توسط مدل توضیح داده می‌شود که در محدوده ۰ (بد) تا ۱ (عالی) است.

- MAE: میانگین قدر مطلق خطاها

کد ۱۵: تحلیل اهمیت متغیرها

```
feature_importance = pd.DataFrame({
    'Feature': [X.columns[i] for i in range(X_train.shape[۱])],
    'Coefficient': ridge_model.coef_,
    'Absolute_Coefficient': np.abs(ridge_model.coef_)
}).sort_values('Absolute_Coefficient', ascending=False)
```

مدل XGBOOST

کد ۱۶: آماده‌سازی محیط و کتابخانه‌ها

```
from xgboost import XGBRegressor
from sklearn.metrics import r2_score, mean_absolute_error
from sklearn.model_selection import GridSearchCV
```

XGBRegressor: کلاس اصلی مدل XGBoost برای مسائل رگرسیون

GridSearchCV: برای تنظیم هیپرپارامترها

R<sup>2</sup>\_score, mean\_absolute\_error: معیارهای ارزیابی

کد ۱۷: آموزش مدل پایه

```
xgb_model = XGBRegressor(
    n_estimators=۱۰۰, # تعداد درختان
    max_depth=۶, # حداکثر عمق هر درخت
    learning_rate=۰.۱, # نرخ یادگیری
    random_state=۴۲ # برای تکرارپذیری
)
```

```
xgb_model.fit(X_train, y_train)
```

n\_estimators (معمولاً ۱۰۰-۱۰۰۰)

max\_depth (معمولاً ۳-۱۰): کنترل پیچیدگی مدل

learning\_rate (۰.۰۱-۰.۳): اندازه گام بهینه‌سازی

کد ۱۸: ارزیابی مدل

```
y_pred = xgb_model.predict(X_test)
```

```
print(f"R2 Score: {r2_score(y_test, y_pred):.۴f}")
```

```
print(f"MAE: {mean_absolute_error(y_test, y_pred):.۴f}")
```

کد ۱۹: تحلیل اهمیت ویژگی‌ها

```
importance = xgb_model.feature_importances_
```

```
feature_importance = pd.DataFrame({
    'Feature': [data.columns[i] for i in range(X_train.shape[۱])],
    'Importance': importance
})
```

```
}).sort_values('Importance', ascending=False)
```

مدل SVM با هسته RBF

کد ۲۰: آماده‌سازی محیط و کتابخانه‌ها

```
from sklearn.svm import SVR
```

```
from sklearn.metrics import r2_score, mean_absolute_error
```

SVR: پیاده‌سازی SVM برای رگرسیون

کد ۲۱: آموزش مدل پایه

```
svm_model = SVR(
```

```
    kernel='rbf', # هسته تابع پایه شعاعی
```

```
    C=۱.۰, # پارامتر تنظیم
```

```
    gamma='scale', # پارامتر تأثیر پذیری
```

```
    epsilon=۰.۱ # حد مجاز خطا
```

```
)
```

```
svm_model.fit(X_train, y_train)
```

C: کنترل تعادل بین حاشیه اطمینان و خطا (مقادیر معمول: ۰.۱ تا ۱۰۰)

gamma: تعیین تأثیر هر نمونه آموزشی (مقادیر کوچک: تصمیم‌گیری سراسری)

epsilon: حد مجاز خطا در رگرسیون

کد ۲۲: ارزیابی مدل

```
y_pred = svm_model.predict(X_test)
```

```
print(f"R2 Score: {r2_score(y_test, y_pred):.4f}")
```

```
print(f"MAE: {mean_absolute_error(y_test, y_pred):.4f}")
```

کد ۲۳: تحلیل اهمیت ویژگی‌ها

```
from sklearn.inspection import permutation_importance

result = permutation_importance(

    svm_model,

    X_test,

    y_test,

    n_repeats=۱۰,

    random_state=۴۲

)

importance_df = pd.DataFrame({

    'Feature': [data.columns[i] for i in range(X_test.shape[۱])],

    'Importance': result.importances_mean

}).sort_values('Importance', ascending=False)
```

## یافته‌ها

جدول زیر مهمترین عوامل تاثیر گذار پیش بینی شده توسط هریک از ۴ مدل طراحی شده در این پژوهش را نشان میدهد:

جدول ۱. مقایسه نتایج مدل‌ها

رتبه	DNN	Ridge	XGBoost	SVM-RBF
۱	کار تیمی	تعهد سازمانی	تعهد سازمانی	تعهد سازمانی
۲	مهارت ارتباطی	مهارت ارتباطی	مهارت ارتباطی	مهارت ارتباطی
۳	مشتری مداری	مشتری مداری	مشتری مداری	مشتری مداری
۴	تعهد سازمانی	کار تیمی	کار تیمی	کار تیمی
۵	نمره ارتقای شغلی	نمره ارزشیابی عملکرد	نمره ارزشیابی عملکرد	نمره ارزشیابی عملکرد
۶	ارتقای مدرک تحصیلی	نمره ارتقای شغلی	نمره ارتقای شغلی	نمره ارتقای شغلی
۷	نمره ارزشیابی عملکرد	گواهینامه‌ها	گواهینامه‌ها	گواهینامه‌ها
۸	گواهینامه‌ها	ارتقای مدرک تحصیلی	ارتقای مدرک تحصیلی	ارتقای مدرک تحصیلی
۹	سطح شغلی	امتیاز آزمون استخدامی	امتیاز آزمون استخدامی	سطح شغلی
۱۰	امتیاز آزمون استخدامی	مدرک تحصیلی	مدرک تحصیلی	مدرک تحصیلی

۱۱	مدرک تحصیلی	محل فعالیت	محل تولد	عضویت در بسیج
۱۲	سن	حضور در مناسبات	محل فعالیت	گرایش سیاسی
۱۳	گرایش سیاسی	جنسیت	سن	سن
۱۴	عضویت در بسیج	سطح شغلی	سطح شغلی	محل تولد
۱۵	حضور در مناسبات	محل تولد	حضور در مناسبات	جنسیت
۱۶	قومیت	سن	عضویت در بسیج	قومیت
۱۷	محل تولد	گرایش سیاسی	جنسیت	حضور در مناسبات
۱۸	جنسیت	قومیت	قومیت	امتیاز آزمون استخدامی
۱۹	محل فعالیت	عضویت در بسیج	گرایش سیاسی	محل فعالیت

از مهمترین نکاتی که از جدول فوق برداشت میشود اتفاق نظر تقریبی تمام مدل‌ها در تشخیص مهمترین متغیر هاست. در تمامی مدل‌های دوم تا چهارم تعهد سازمانی، مهارت ارتباطی، مشتری مداری، کار تیمی و نمره ارزشیابی عملکرد به عنوان پنج عامل مهم تعیین شده است. در مدل شبکه عصبی عمیق این ویژگی‌ها تنها در دو متغیر تفاوت دارد و آن متغیر گواهینامه‌ها و نمره ارتقای شغلی است که اضافه شده و تعهد سازمانی و نمره ارزشیابی عملکرد در صدر عوامل نیستند. ولی درکل مدل‌ها اتفاق نظر مفهوم داری در تعیین متغیرهای مهم دارند. تفاوت مدل‌ها در تعیین کم اهمیت ترین متغیر هاست که اتفاق نظر در این بخش کمتر است. با این حال قومیت با حضور در لیست همه مدل‌ها به طور معنی داری عنوان کم اهمیت ترین متغیر را اخذ نموده است.

با توجه به تحلیل‌های صورت گرفته، همانگونه که مشخص شد، برآوردگر شبکه عصبی (DNN)، به عنوان برآوردگر بهینه تعیین شد، بر این اساس با توجه به نتایج تحلیل این مدل، ضرایب نهایی مدل بهینه شایسته سالاری در بانک صادرات، به شرح جدول زیر می‌باشد.

جدول ۲. ضرایب مدل بهینه شایسته سالاری

ردیف	DNN	ضریب
۱	کار تیمی	۰/۶۶۰۵۳۸
۲	مهارت ارتباطی	۰/۳۲۷۷۲۴
۳	مشتری مداری	۰/۱۷۵۵۴۵
۴	تعهد سازمانی	۰/۱۶۳۸۶۰
۵	نمره ارتقای شغلی	۰/۱۲۵۸۴۳
۶	ارتقای مدرک تحصیلی	۰/۱۰۷۴۹۸
۷	نمره ارزشیابی عملکرد	۰/۰۹۰۰۵۰
۸	گواهینامه‌ها	۰/۰۵۵۹۸۸
۹	سطح شغلی	۰/۰۵۳۰۳۲
۱۰	امتیاز آزمون استخدامی	۰/۰۵۰۱۷۵
۱۱	مدرک تحصیلی	۰/۰۴۲۰۸۰
۱۲	سن	۰/۰۳۷۵۲۱

۰/۰۳۲۷۷۲	گرایش سیاسی	۱۳
۰/۰۲۸۷۹۷	عضویت در بسیج	۱۴
۰/۰۱۷۱۴۷	حضور در مناسبات	۱۵
۰/۰۱۷۰۰۲	قومیت	۱۶
۰/۰۱۳۹۹۲	محل تولد	۱۷
۰/۰۱۰۴۶۸	جنسیت	۱۸
۰/۰۰۲۵۱۴	محل فعالیت	۱۹

## بحث و نتیجه گیری

یافته‌های این پژوهش نشان داد که به‌کارگیری رویکردهای مبتنی بر هوش مصنوعی در طراحی مدل استفاده مبتنی بر شایسته‌سالاری می‌تواند به شکل معناداری دقت، شفافیت و کارآمدی تصمیمات جذب و گزینش نیروی انسانی را افزایش دهد. نتایج حاصل از مقایسه چهار الگوریتم شبکه عصبی عمیق، رگرسیون ریج، XGBoost و ماشین بردار پشتیبان نشان داد که شبکه عصبی عمیق از بالاترین توان تبیین و پیش‌بینی برخوردار است؛ موضوعی که بیانگر توانایی این الگوریتم در مدل‌سازی روابط پیچیده و غیرخطی میان متغیرهای شایستگی و عملکرد کارکنان است. این نتیجه با ادبیات مربوط به برتری شبکه‌های عصبی در تحلیل داده‌های چندبعدی و پیچیده همسو است و پژوهش‌هایی که بر قدرت بالای مدل‌های یادگیری عمیق در پیش‌بینی رفتارها و نتایج سازمانی تأکید دارند، آن را تأیید می‌کنند (Dai et al., 2022; Olson & Durusun, 2008). در این چارچوب، یافته‌های پژوهش حاضر نشان می‌دهد که استفاده از الگوریتم‌های پیشرفته می‌تواند ضعف رویکردهای سنتی و خطی در ارزیابی شایستگی را تا حد زیادی جبران کند.

یکی از مهم‌ترین نتایج پژوهش، شناسایی چهار مؤلفه کار تیمی، مهارت‌های ارتباطی، مشتری‌مداری و تعهد سازمانی به‌عنوان مهم‌ترین عوامل شایستگی در تمامی مدل‌ها بود. این همگرایی نتایج در میان الگوریتم‌های مختلف، نشان‌دهنده پایداری و اعتبار این متغیرها در تبیین شایستگی کارکنان بانکی است. کار تیمی به‌عنوان یک شایستگی کلیدی، نقش اساسی در هماهنگی فعالیت‌ها، حل مسائل پیچیده و ارتقای کیفیت خدمات در سازمان‌های خدمات‌محور ایفا می‌کند. این یافته با دیدگاه‌هایی که بر اهمیت شایستگی‌های رفتاری و اجتماعی در عملکرد سازمانی تأکید دارند، همخوانی دارد (Bateman & Snell, 2017; Green, 2015). همچنین مطالعات مرتبط با مدیریت منابع انسانی در محیط‌های رقابتی نشان می‌دهند که توانایی همکاری مؤثر، یکی از پیش‌نیازهای اصلی خلق ارزش و مزیت رقابتی پایدار است (Gilsing & Guysters, 2008; Prahalad & Hamel, 2009).

مهارت‌های ارتباطی نیز به‌عنوان دومین مؤلفه کلیدی شناسایی شد؛ نتیجه‌ای که با ماهیت صنعت بانکداری و نقش حیاتی تعاملات انسانی در ارائه خدمات مالی سازگار است. پژوهش‌های پیشین نشان داده‌اند که کیفیت ارتباطات کارکنان با مشتریان و همکاران، تأثیر مستقیمی بر رضایت مشتری، اعتماد سازمانی و عملکرد کلی بانک‌ها دارد (Kumar & Rajesh, 2023). از منظر شایسته‌سالاری، تمرکز بر مهارت‌های

ارتباطی نشان می‌دهد که شایستگی صرفاً به دانش فنی یا تحصیلات محدود نمی‌شود، بلکه مجموعه‌ای از توانمندی‌های رفتاری و بین‌فردی را نیز در بر می‌گیرد؛ موضوعی که در ادبیات شایستگی به‌طور گسترده مورد تأکید قرار گرفته است ( Boyatzis, 2005; Mirabelle, 2016).

مشتری‌مداری به‌عنوان سومین عامل مهم، جایگاه ویژه‌ای در نتایج این پژوهش دارد. این یافته بیانگر آن است که در نظام‌های استخدامی بانکی، توجه به نگرش‌ها و رفتارهای معطوف به مشتری، یکی از شاخص‌های اساسی شایستگی محسوب می‌شود. این نتیجه با پژوهش‌هایی که مشتری‌مداری را عامل کلیدی در بهبود عملکرد سازمان‌های خدماتی و افزایش وفاداری مشتریان می‌دانند، همراستاست ( Kumar & Rajesh, 2023). همچنین این یافته با رویکردهای نوین مدیریت منابع انسانی که بر همسویی شایستگی‌های فردی با استراتژی‌های کلان سازمان تأکید دارند، سازگار است (Armstrong, 2014; Lawler, 2017).

تعهد سازمانی نیز به‌عنوان یکی از مهم‌ترین مؤلفه‌ها شناسایی شد که نشان‌دهنده اهمیت پیوند روانی و ارزشی کارکنان با سازمان است. این نتیجه با مطالعاتی که تعهد سازمانی را عامل مؤثر بر ماندگاری کارکنان، کاهش ترک خدمت و افزایش بهره‌وری می‌دانند، همخوانی دارد (Grant, 2008; Sullivan & Al Ariss, 2019). در چارچوب شایسته‌سالاری، توجه به تعهد سازمانی بیانگر آن است که استخدام موفق صرفاً به جذب افراد توانمند محدود نمی‌شود، بلکه انتخاب افرادی که از همسویی ارزشی و انگیزشی با سازمان برخوردارند نیز اهمیت دارد (Abbaspour, 2019; Ahmadi, 2011).

در مقابل، نتایج پژوهش نشان داد که متغیرهایی نظیر قومیت، گرایش سیاسی، محل تولد و محل فعالیت، کم‌اهمیت‌ترین نقش را در پیش‌بینی شایستگی ایفا می‌کنند. این یافته از منظر نظری و عملی حائز اهمیت است؛ زیرا نشان می‌دهد که مدل‌های مبتنی بر هوش مصنوعی، در صورت طراحی و آموزش مناسب، می‌توانند معیارهای غیرمرتبط و بالقوه سوگیرانه را به حاشیه رانده و تمرکز را بر شایستگی‌های واقعی و عملکردمحور معطوف سازند. این نتیجه با مبانی نظری شایسته‌سالاری که بر حذف روابط غیرحرفه‌ای و معیارهای نامرتبط تأکید دارد، همسو است (Abdaspour, 2014; Bell, 2005). همچنین پژوهش‌های حقوقی و نهادی در حوزه استخدام نشان می‌دهند که کاهش تأثیر این عوامل می‌تواند به افزایش عدالت سازمانی و مشروعیت نظام‌های استخدامی منجر شود (Ghamami & Hosseini, 2019).

از منظر روش‌شناختی، نتایج این پژوهش نشان می‌دهد که ترکیب رویکردهای کیفی و کمی، به‌ویژه تلفیق نظرات خبرگان با تحلیل‌های داده‌محور، می‌تواند به طراحی مدل‌های جامع‌تر و بومی‌تر شایستگی منجر شود. این یافته با مطالعاتی که بر ضرورت بومی‌سازی مدل‌های شایستگی و توجه به اقتضائات سازمانی تأکید دارند، همخوانی دارد (Ghahramani, 2016; Timouri et al., 2018). همچنین استفاده

از داده‌کاوی و الگوریتم‌های یادگیری ماشین در این پژوهش، با روندهای جهانی در حوزه استخدام هوشمند و مدیریت استعداد همراستا است (Allal-Ch'erif et al., 2021; Meng, 2020).

به‌طور کلی، نتایج پژوهش حاضر نشان می‌دهد که استخدام مبتنی بر شایسته‌سالاری، در صورتی که با بهره‌گیری نظام‌مند از هوش مصنوعی همراه شود، می‌تواند از یک مفهوم هنجاری و آرمانی به یک سازوکار عملی، قابل اندازه‌گیری و اثربخش در نظام بانکی تبدیل شود. این یافته‌ها نه تنها با بخش قابل توجهی از ادبیات موجود همخوانی دارد، بلکه با ارائه شواهد تجربی در بستر بانکی ایران، به غنای ادبیات شایسته‌سالاری و استخدام هوشمند می‌افزاید.

یکی از محدودیت‌های اصلی این پژوهش، تمرکز آن بر یک سازمان بانکی خاص است که می‌تواند تعمیم‌پذیری نتایج به سایر بانک‌ها یا سازمان‌ها را با احتیاط همراه سازد. همچنین وابستگی تحلیل‌ها به کیفیت داده‌های در دسترس و صحت اطلاعات ثبت‌شده کارکنان، می‌تواند بر دقت نتایج اثرگذار باشد. افزون بر این، هرچند تلاش شد سوگیری‌ها در داده‌ها به حداقل برسد، اما امکان حذف کامل سوگیری‌های پنهان در داده‌های انسانی همواره با محدودیت مواجه است.

پیشنهاد می‌شود پژوهش‌های آتی با گسترش دامنه مطالعه به چند بانک یا سازمان خدماتی مختلف، به مقایسه الگوهای شایستگی و نتایج مدل‌های هوش مصنوعی پردازند. همچنین بررسی نقش متغیرهای روان‌شناختی عمیق‌تر و داده‌های رفتاری پویا، مانند داده‌های طولی عملکرد، می‌تواند به غنای مدل‌های پیش‌بینی شایستگی کمک کند. به‌کارگیری و مقایسه الگوریتم‌های نوظهور یادگیری عمیق نیز می‌تواند مسیرهای جدیدی را برای توسعه این حوزه بگشاید.

به مدیران بانکی توصیه می‌شود نظام‌های استخدامی خود را به تدریج از رویکردهای سنتی به سمت مدل‌های داده‌محور و هوشمند سوق دهند و از نتایج چنین مدل‌هایی به‌عنوان ابزار پشتیبان تصمیم‌گیری استفاده کنند. سرمایه‌گذاری در زیرساخت‌های داده و آموزش مدیران منابع انسانی برای کار با ابزارهای تحلیلی، می‌تواند اثربخشی این رویکرد را افزایش دهد. همچنین تأکید بر شایستگی‌های رفتاری کلیدی مانند کار تیمی، مهارت‌های ارتباطی و مشتری‌مداری در فرآیندهای جذب و توسعه کارکنان، می‌تواند به بهبود عملکرد بلندمدت بانک‌ها و افزایش اعتماد ذی‌نفعان منجر شود.

## مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

## تعارض منافع

در انجام مطالعه حاضر، هیچ‌گونه تضاد منافی وجود ندارد.

## موازین اخلاقی

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

## تشکر و قدردانی

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

## Extended Abstract

### **Introduction**

In recent decades, organizations have been operating in environments characterized by rapid technological change, intensified global competition, evolving labor markets, and increasing expectations regarding transparency and fairness in human resource practices. Under such conditions, human capital has emerged as the most critical strategic asset for organizational sustainability and competitive advantage. Consequently, recruitment and selection systems have attracted growing scholarly and managerial attention, particularly with respect to their ability to identify, attract, and retain competent individuals who can contribute effectively to organizational goals (Abbaspour, 2019; Armstrong, 2014). Within this context, meritocracy has become a central concept in contemporary human resource management, emphasizing the selection and promotion of employees based on competencies, skills, performance, and potential rather than non-job-related attributes or informal considerations (Abdaspour, 2014; Bell, 2005).

Theoretical and empirical studies indicate that merit-based systems enhance organizational efficiency, strengthen employee commitment, and improve perceptions of organizational justice (Bateman & Snell, 2017; Lawler, 2017). However, translating meritocracy from a normative principle into an operational recruitment system remains challenging. Traditional recruitment approaches often rely on limited indicators such as educational credentials, work experience, or subjective judgments, which are insufficient for capturing the multidimensional nature of competency and may introduce bias into decision-making processes (Mansfield, 2005; Mirabelle, 2016). These challenges are particularly salient in large and complex service organizations such as banks, where recruitment decisions have long-term implications for service quality, customer trust, and financial performance (Ghamami & Hosseini, 2019; Kumar & Rajesh, 2023).

Recent advances in artificial intelligence and data analytics have created new opportunities for addressing these limitations. Artificial intelligence techniques, including machine learning and deep learning, enable the analysis of large, heterogeneous datasets and the modeling of complex, nonlinear relationships among

variables (Dai et al., 2022; Olson & Durusun, 2008). In the recruitment domain, AI-based systems can integrate diverse indicators—behavioral, performance-based, psychological, and organizational—to generate more accurate and objective predictions of employee competency (Allal-Ch'erif et al., 2021; Meng, 2020). Prior research suggests that such approaches can reduce human bias, improve predictive validity, and support evidence-based human resource decisions (Khaef et al., 2007; Madadipouya, 2015).

Despite this growing body of literature, several gaps remain. Many existing studies focus on limited sets of predictors or specific organizational contexts, and relatively few propose comprehensive, empirically validated models that integrate meritocratic principles with artificial intelligence in banking environments, particularly in developing economies (Farndale et al., 2010; Timouri et al., 2018). Furthermore, the relative importance of different competency dimensions and the comparative performance of various AI algorithms in predicting merit-based outcomes are not yet fully understood (Boyatzis, 2005; Green, 2015). Addressing these gaps is essential for advancing both theory and practice in intelligent recruitment systems.

Against this background, the present study develops and evaluates an artificial intelligence-based recruitment model grounded in meritocracy within the context of a large commercial bank. By combining expert knowledge with advanced machine learning techniques, the study seeks to identify the most influential competency factors and determine the optimal predictive model for merit-based recruitment.

### Methods and Materials

This study employed a mixed-method research design. In the qualitative phase, expert opinions from human resource managers and specialists were used to identify and refine a comprehensive set of competency indicators relevant to merit-based recruitment in the banking sector. The quantitative phase involved collecting employee-related data encompassing performance evaluations, job characteristics, individual attributes, and assessment scores.

Data preprocessing included cleaning, normalization, and transformation to ensure analytical consistency. Four artificial intelligence models were developed and tested: a Deep Neural Network, Ridge Regression, XGBoost, and Support Vector Machine. The dataset was divided into training and testing subsets, and each model was trained using standardized procedures. Model performance was evaluated using adjusted coefficient of determination and mean absolute error to compare predictive accuracy and robustness.

### Findings

The results of the data analysis demonstrated clear differences in predictive performance among the tested models. The Deep Neural Network consistently outperformed the other algorithms, achieving the highest explanatory power and the lowest prediction error. This finding indicates the superior capability of deep learning in capturing complex, nonlinear relationships among competency variables in recruitment contexts.

Across all models, four competency factors emerged as the most influential predictors of merit-based suitability: teamwork, communication skills, customer orientation, and organizational commitment. These factors ranked highly and consistently, regardless of the algorithm applied, suggesting strong stability and

robustness in their predictive relevance. Teamwork was identified as the most critical factor, followed closely by communication skills and customer orientation, reflecting the service-oriented and collaborative nature of banking operations. Organizational commitment also showed substantial predictive weight, underscoring the importance of employee alignment with organizational values and long-term objectives.

In contrast, variables such as ethnicity, political orientation, place of birth, and workplace location exhibited minimal predictive importance across all models. Their consistently low weights indicate that they contribute little to explaining merit-based competency outcomes within the studied context.

Comparative analysis further revealed that while Ridge Regression also demonstrated relatively strong performance, its predictive accuracy was slightly lower than that of the Deep Neural Network. XGBoost and Support Vector Machine models showed acceptable but comparatively weaker performance, particularly in capturing higher-order interactions among variables.

### **Discussion and Conclusion**

The findings of this study provide strong empirical support for the application of artificial intelligence in operationalizing meritocracy within recruitment systems. The superior performance of the Deep Neural Network highlights the value of advanced learning architectures in modeling the multidimensional and interdependent nature of employee competencies. This result suggests that organizations seeking to enhance recruitment quality should consider moving beyond linear or rule-based approaches toward more sophisticated, data-driven models.

The consistent prominence of teamwork, communication skills, customer orientation, and organizational commitment aligns with the strategic requirements of service-based organizations, particularly banks. These competencies reflect not only technical capability but also behavioral and relational capacities that are essential for delivering high-quality services and maintaining customer trust. The convergence of results across multiple algorithms strengthens confidence in the centrality of these factors for merit-based recruitment decisions.

Equally important is the finding that non-job-related attributes played a negligible role in predicting merit-based suitability. This outcome demonstrates the potential of AI-driven systems to minimize the influence of irrelevant or bias-prone variables, thereby promoting fairness, transparency, and objectivity in recruitment processes. By focusing on performance-relevant competencies, such systems can support organizational justice while enhancing decision quality.

Overall, this study contributes to the literature by presenting an integrated, empirically validated model that combines meritocratic principles with artificial intelligence in a real organizational context. The results indicate that intelligent recruitment systems can transform meritocracy from an abstract ideal into a practical, measurable, and effective mechanism for human resource management. From a practical perspective, adopting such models can help banks and similar organizations improve long-term performance, strengthen human capital quality, and build stakeholder trust.

## References

- Abbaspour, A. (2019). *Advanced Human Resource Management: Approaches, Processes, and Functions*. Tehran: Organization for the Study and Compilation of Humanities Books (SAMT).
- Abdaspour, F. (2014). Providing a Conceptualization and Pathology Model of Meritocracy in Organizations. *Scientific-Developmental Journal of Human Resource Studies*, 10, 21-44. [http://www.jhrs.ir/article\\_66251.html](http://www.jhrs.ir/article_66251.html)
- Ahmadi, R. (2011). *The Meritocracy System in the Management of the Country*. Tehran: Organization of Administrative and Employment Affairs.
- Allal-Ch'erif, O., Arenga, A., & Sanchez, R. (2021). Intelligent Recruitment: How to Identify, Select, and Retain Talents from Around the World Using Artificial Intelligence. *Technological Forecasting and Social Change*, 169, 1-11. <https://www.sciencedirect.com/science/article/pii/S0040162521002547>
- Armstrong, M. (2014). *Armstrong's Handbook of Human Resource Management Practice*. Ashford Colour Press Ltd. [https://e-uczelnia.uek.krakow.pl/pluginfile.php/604792/mod\\_folder/content/0/Armstrongs%20Handbook%20of%20Human%20Resource%20Management%20Practice\\_1.pdf](https://e-uczelnia.uek.krakow.pl/pluginfile.php/604792/mod_folder/content/0/Armstrongs%20Handbook%20of%20Human%20Resource%20Management%20Practice_1.pdf)
- Azar, A., Ahmadi, P., & Sabt, M. V. (2011). Designing a Human Resource Selection Model with a Data Mining Approach. *Journal of Information Technology Management*, 4, 3-22. <https://www.sid.ir/paper/140379/>
- Azkiya, S. N., Rodiyah, R., & Rahayu, S. A. P. (2025). Construction of an Ideal Bureaucratic Meritocracy System Based on Good Governance in Civil Servant Recruitment. *International Journal of Research and Innovation in Social Science*, VIII(XII), 4239-4253. <https://doi.org/10.47772/ijriss.2024.8120354>
- Bagheri Zadeh, M. (2010). *Management of Organizational Change and Transformation*. Darakhshesh Publications.
- Bateman, S. T., & Snell, A. S. (2017). *Management: Leading & Collaborating in a Competitive World*. Seventh Edition, McGraw Hill Irwin. <https://www.amazon.com/Management-Leading-Collaborating-Competitive-World/dp/0078029333>
- Bell, D. (2005). On Meritocracy and Equality. *The Public Interest*, 29-68. <https://search.proquest.com/openview/efef2c6254de0f06d0e504346bf3e1f6/1?pq-origsite=gscholar&cbl=1817076>
- Boyatzis, R. E. (2005). *The Competent Manager: A Model for Effective Performance*. NY: Wiley. [https://books.google.com/books?hl=en&lr=&id=KmFR7BnLdCoC&oi=fnd&pg=PR11&dq=Boyatzis,+R.+E.+\(2005\).+The+Competent+Manager:+A+Model+for+Effective+Performance,+NY:+Wiley.+%09&ots=wx9HTpNnYC&sig=wsvQg93WIRFWOUONmMpqMhZY6YE](https://books.google.com/books?hl=en&lr=&id=KmFR7BnLdCoC&oi=fnd&pg=PR11&dq=Boyatzis,+R.+E.+(2005).+The+Competent+Manager:+A+Model+for+Effective+Performance,+NY:+Wiley.+%09&ots=wx9HTpNnYC&sig=wsvQg93WIRFWOUONmMpqMhZY6YE)
- Dai, W., Wu, J. Y., & Lu, C. J. (2022). Combining nonlinear independent component analysis and neural network for the prediction of Asian stock market indexes. *Expert Systems with Applications*, 39(4), 4444-4452. <https://doi.org/10.1016/j.eswa.2011.09.145>
- Divina, L. V. (2024). Upholding the Strategy on Hiring Employee Under Meritocracy Procedure Towards a Refined Performance. *International Journal of Scientific Research and Management*, 12(02), 5821-5830. <https://doi.org/10.18535/ijstrm/v12i02.em01>
- Diyanti, M., & Irfani, M. (2010). Competence: Concepts and Applications. *Tadbir Journal*, 206, 14-19. <https://ensani.ir/fa/article/download/164394>
- Farndale, E., Scullion, H., & Sparrow, P. (2010). The Role of the Corporate HR Function in Global Talent Management. *Journal of World Business*, 45(2), 161-168. <https://doi.org/10.1016/j.jwb.2009.09.012>
- Ghahramani, E. (2011). Implementing a Meritocracy System in Organizations. <https://civilica.com/doc/17604/>
- Ghahramani, E. (2016). Implementing a Meritocracy System in Organizations. Fourth International Conference on Industrial Engineering, Ghamami, S. M., & Hosseini, S. H. (2019). Merit Selection in the Employment Legal System of Iran and the United States. *Administrative Law Journal*, 15, 75-83. [http://qjal.smtc.ac.ir/browse.php?a\\_code=A-10-1-100&slc\\_lang=fa&sid=1](http://qjal.smtc.ac.ir/browse.php?a_code=A-10-1-100&slc_lang=fa&sid=1)
- Gharavand, O. (2008). *Developing a Competency Model for Educational Managers and Assessing Competencies of School Managers in the Country* Master's Thesis in Public Management, Faculty of Management, Tarbiat Modares University].
- Gilting, V. A., & Guysters, G. M. (2008). Understanding Novelty Creation in Exploration Networks: Structural and Relational Embeddedness Jointly Considered. *Technovation*, 28(10), 693-708. <https://doi.org/10.1016/j.technovation.2008.03.004>
- Grant, E. A. (2008). How to Retain Talent in India. *MIT Sloan management review*, 50(1), 6. <https://search.proquest.com/openview/ef97d3cdb21facdce5a1510284dbabf0/1?pq-origsite=gscholar&cbl=26142>
- Green, P. C. (2015). *Building Robust Competencies: Linking Human Systems to Organization Strategies*. San Francisco: Jossey-Bass. <https://www.amazon.com/Building-Robust-Competencies-Organizational-Strategies/dp/0787946494>
- Hadadnia, S. (2024). Testing a Conceptual Model Linking HR Management and Meritocracy Through Organizational Ingratiation.
- Khaef, E., Ahmad, A., Mottaghi, P., & Sebt, M. V. (2007). Examining the Influence of Employment Model Utilization Based on Data Mining on the Employees' Replacement Rate. First Iran Data Mining Conference,
- Kharazian, M., Shahbazi, M. M., & Fathhi, M. (2019). Discovering the Optimal Pattern for Employing Knowledge Workers Using an Integrated DEA and CArT Approach. *Production and Operations Management*, 18, 65-82. <https://www.sid.ir/paper/217614/fa>
- Khodai Ismail Kandi, P., Amini, P., Mohammadi, A., & Fatehi, A. (2019). Utilization of Decision Tree Algorithms in Predicting Accounting Quality. *Journal of Management Accounting and Auditing*, 32, 209-224. <https://www.sid.ir/paper/397469/fa>
- Kumar, V., & Rajesh, R. (2023). Customer-Centric Banking: Impact on Customer Satisfaction and Organizational Performance. *Journal of Banking and Financial Services*, 45(3), 210-225. [https://www.researchgate.net/publication/324601595\\_Impact\\_of\\_Customer\\_Satisfaction\\_on\\_Customer\\_Loyalty\\_in\\_the\\_Banking\\_Sector](https://www.researchgate.net/publication/324601595_Impact_of_Customer_Satisfaction_on_Customer_Loyalty_in_the_Banking_Sector)

- Lawler, E. E. (2017). *Reinventing Talent Management: Principles and Practices for the New World of Work*. Berrett-Koehler Publishers. [https://books.google.com/books?hl=en&lr=&id=Ck75DQAAQBAJ&oi=fnd&pg=PP1&dq=Lawler,+E.+E.+\(2017\).+Reinventing+Talent+Management:+Principles+and+Practices+for+the+New+World+of+Work,+Berrett-Koehler+Publishers.+%09&ots=sonKc0qll\\_&sig=U5sg7HTihXJ1Oh4ykecS29GJMI](https://books.google.com/books?hl=en&lr=&id=Ck75DQAAQBAJ&oi=fnd&pg=PP1&dq=Lawler,+E.+E.+(2017).+Reinventing+Talent+Management:+Principles+and+Practices+for+the+New+World+of+Work,+Berrett-Koehler+Publishers.+%09&ots=sonKc0qll_&sig=U5sg7HTihXJ1Oh4ykecS29GJMI)
- Madadipouya, K. (2015). A New Decision Tree Method for Data Mining in Medicine. *Advanced Computational Intelligence: An International Journal (ACIJ)*, 2(3), 31-37. <https://www.academia.edu/download/55256735/2315acii04.pdf>
- Mansfield, R. S. (2005). Building Competency Models: Approaches for HR Professionals. *Human Resource Management*, 35(1), 7-18. [https://doi.org/10.1002/\(SICI\)1099-050X\(199621\)35:1<7::AID-HRM1>3.0.CO;2-2](https://doi.org/10.1002/(SICI)1099-050X(199621)35:1<7::AID-HRM1>3.0.CO;2-2)
- Meng, Q. (2020). Talent Recruitment Analytics in the Era of Big Data. <https://search.proquest.com/openview/6b34dadcf15ed1a82b856aab1af4ec7/1?pq-origsite=gscholar&cbl=18750&diss=y>
- Mirabelle, R. J. (2016). Everything You Wanted to Know About Competency Modeling. *Training and Development*, 73-77. <https://assets.td.org/m/558a98f44899e587/original/Everything-you-wanted-to-know-about-competency-modeling.pdf>
- Olson, D. L., & Durusun, D. (2008). *Advanced Data Mining Techniques*. Heidelberg: Springer. [https://books.google.com/books?hl=en&lr=&id=2vb-LZEn8uUC&oi=fnd&pg=PA3&dq=Olson,+D.+L.+and+D.+Durusun+\(2008\).+Advanced+Data+Mining+Techniques,+Heidelberg:+Springer.+%09&ots=zY8WZ40OrX&sig=6H4Zhxyt6m6JCOOfE0Fqkc018M](https://books.google.com/books?hl=en&lr=&id=2vb-LZEn8uUC&oi=fnd&pg=PA3&dq=Olson,+D.+L.+and+D.+Durusun+(2008).+Advanced+Data+Mining+Techniques,+Heidelberg:+Springer.+%09&ots=zY8WZ40OrX&sig=6H4Zhxyt6m6JCOOfE0Fqkc018M)
- Pagano, M., & Picariello, L. (2024). Corporate Governance, Meritocracy, and Careers. *Review of Finance*. <https://doi.org/10.1093/rof/rfae042>
- Porter, K., Smith, P., & Fagg, R. (2007). *Leadership and management for HR professionals*. Routledge. <https://api.taylorfrancis.com/content/books/mono/download?identifierName=doi&identifierValue=10.4324/9780080492810&type=googlepdf>
- Prahalad, C. K., & Hamel, G. (2009). The core competence of the corporation. In *Knowledge and strategy* (pp. 41-59). Routledge. <https://api.taylorfrancis.com/content/chapters/edit/download?identifierName=doi&identifierValue=10.4324/9780080509778-4&type=chapterpdf>
- Sahay, P. (2014). Design thinking in talent acquisition: a practitioner's perspective. *Strategic Hr Review*, 13(4/5), 170-180. <https://www.emerald.com/insight/content/doi/10.1108/SHR-04-2014-0027/full/html>
- Sullivan, S. E., & Al Ariss, A. (2019). Making sense of different perspectives on career transitions: A review and agenda for future research. *Human Resource Management Review*. <https://doi.org/10.1016/j.hrmr.2019.100727>
- Timouri, N., Rangriz, H., Abdollahi, B., & Zainabadi, H. R. (2018). Prioritizing Factors Affecting Human Resource Attraction and Proposing a Suitable Model Based on a Competency Framework. *Quarterly Journal of Human Resource Management Research, Imam Hussein University*, 31, 75-100. [https://hrmj.ihu.ac.ir/article\\_32465.html](https://hrmj.ihu.ac.ir/article_32465.html)
- Tongdong, B. (2025). Against Virtue Politics: Han Fei Zi's Critique of Confucian Meritocracy. *Journal of Social and Political Philosophy*, 4(1), 24-37. <https://doi.org/10.3366/jsp.2025.0097>