

A Hybrid Intelligent Approach for Predicting Digital Transformation Change Levels Based on Stacked Ensemble Learning and Deep Meta-Learning

1. Samaneh Hedayati¹: Department of Information Technology Management, Ki.C., Islamic Azad University, Kish, Iran

2. Seyed Javad Iranbanfard^{2*}: Department of Management, Shi.C., Islamic Azad university, Shiraz, Iran. Email: javad.iranban@iau.ac.ir (Corresponding Author)

3. Sara Najafzadeh³: Department of Computer, Yi.C., Islamic Azad University, Tehran, Iran

4. Mostafa Kolahdoozi⁴: Department of Information Technology Management, SR.C., Islamic Azad University, Tehran, Iran

Article history



Received: 22 December 2025

Revised: 28 April 2026

Accepted: 06 May 2026

Initial Publish: 16 May 2026

Final Publish: 22 June 2027

Abstract:

This study aimed to develop an intelligent framework based on feature selection and stacked deep learning to predict the level of digital transformation changes in organizations and improve the accuracy of digital transformation classification. The study utilized a standard corporate digital transformation dataset containing 2,000 samples and 24 features. In the first stage, influential features were extracted using the Binary Archimedes Optimization Algorithm (BAOA) and a wrapper-based feature selection approach. The selected features were then fed into a stacked ensemble and deep meta-learning framework (SE-DML). The architecture consisted of four base classifiers, including Random Forest, AdaBoost, XGBoost, and Bagging, while a multilayer deep neural network acted as the meta-learner. The dataset was divided into training (70%) and testing (30%) subsets using stratified sampling. Model performance was evaluated using Accuracy, Balanced Accuracy, Precision, Recall, F1-Score, Kappa, MCC, Log-Loss, AUROC, and AUPRC metrics across 20 independent runs. The results demonstrated that the BAOA algorithm successfully identified stable and influential digital transformation features while achieving rapid convergence. Feature frequency analysis indicated that the variable “digitaltransindex” had the greatest contribution to predicting digital transformation levels. The proposed hybrid model achieved outstanding classification performance. Among all classifiers, Bagging achieved the best results with an Accuracy of 0.9995, F1-score of 0.9994, and the lowest Log-Loss value of 0.0048. The STACK model based on deep meta-learning also showed highly reliable performance with an Accuracy of 0.9985 and an AUROC value of 1.0. Furthermore, MCC and Kappa values confirmed the strong discriminative capability of the proposed framework in identifying digital transformation levels. The findings revealed that integrating BAOA-based feature selection with stacked ensemble learning and deep meta-learning provides an effective framework for predicting digital transformation change levels. The proposed approach successfully reduced data dimensionality, eliminated redundant features, and extracted complex organizational patterns with high predictive accuracy. The model outperformed individual classifiers and demonstrated strong potential for application in managerial decision-support systems and strategic digital transformation planning.

Keywords: Digital transformation, Feature selection, Binary Archimedes Optimization Algorithm, Stacked ensemble learning, Deep meta-learning, Machine learning

Citation: Hedayati, S., Iranbanfard, S. J., Najafzadeh, S., & Kolahdoozi, M. (2027). A Hybrid Intelligent Approach for Predicting Digital Transformation Change Levels Based on Stacked Ensemble Learning and Deep Meta-Learning. *Accounting, Finance and Computational Intelligence*, 5(2), 1-32.



Extended Abstract**Introduction**

Digital transformation has emerged as one of the most influential paradigms shaping modern organizations, industries, and strategic management systems. The increasing integration of advanced technologies, artificial intelligence, big data analytics, cloud infrastructures, and intelligent decision-support systems has fundamentally changed how organizations create value, optimize operations, and maintain competitive advantage (Vial, 2021). In contemporary business environments, digital transformation is no longer limited to technological adoption; rather, it encompasses structural, managerial, cultural, and strategic reconfiguration processes that enable organizations to adapt to rapidly changing digital ecosystems (Kraus et al., 2022). As organizations continue to generate large-scale and multidimensional datasets, the need for intelligent analytical frameworks capable of extracting meaningful patterns from organizational data has become increasingly important (Gupta & George, 2023). Consequently, machine learning and artificial intelligence technologies have become central components of digital transformation strategies and organizational innovation (Davenport & Mittal, 2022; Kitsios & Kamariotou, 2021).

Recent studies have emphasized that artificial intelligence can significantly improve organizational agility, predictive decision-making, customer engagement, and operational efficiency during digital transformation processes (Aldoseri et al., 2024; Perifanis & Kitsios, 2023). Furthermore, AI-powered transformation frameworks have demonstrated their ability to support strategic planning, automate repetitive processes, and optimize business models in digitally driven environments (Kim & Kim, 2022). The role of machine learning in organizational performance has also received substantial attention, particularly in identifying hidden relationships among organizational variables and forecasting transformation-related outcomes (Mikalef et al., 2022; Mikalef et al., 2021). Despite these advancements, organizations still face major challenges in effectively predicting digital transformation levels due to the complexity, heterogeneity, and multidimensionality of transformation indicators (Ahmad et al., 2022; Hendrawan et al., 2024). The presence of redundant, noisy, and highly correlated features within organizational datasets can reduce the efficiency and interpretability of predictive models.

Feature selection therefore plays a critical role in improving the performance of machine learning frameworks by reducing dimensionality, eliminating irrelevant features, and increasing model stability (Merceedi & Abdulazeez, 2025). Metaheuristic optimization algorithms have recently attracted significant interest in feature selection research because of their ability to effectively explore complex search spaces and identify near-optimal feature subsets (Hashim et al., 2021; Hassan et al., 2022). At the same time, stacked ensemble learning and deep meta-learning approaches have shown considerable potential in improving classification accuracy through the integration of multiple heterogeneous learning models (Zhang et al., 2022). Previous studies have demonstrated the effectiveness of ensemble frameworks such as Random Forest, XGBoost, AdaBoost, and Bagging in various predictive domains (Budholiya et al., 2022; Paul et al., 2024). Nevertheless, relatively limited research has combined binary metaheuristic feature selection with stacked ensemble deep learning architectures for predicting organizational digital transformation levels. Therefore, the present study proposed a hybrid intelligent framework based on Binary Archimedes Optimization Algorithm (BAOA) and Stacked Ensemble–Deep Meta Learning (SE-DML) to predict digital transformation change levels in organizations using a standard corporate digital transformation dataset (colabsss, 2025).

Methods and Materials

This study adopted an applied computational research design based on machine learning and intelligent optimization techniques. The proposed framework utilized a standard corporate digital transformation dataset consisting of 2,000

organizational samples and 24 variables, including 23 predictive features and one target variable representing digital transformation levels categorized into Low, Medium, and High classes. The dataset included organizational, financial, managerial, technological, and innovation-related indicators associated with digital transformation processes.

The proposed framework consisted of two major stages: feature selection and stacked ensemble deep learning classification. In the first stage, Binary Archimedes Optimization Algorithm (BAOA) was employed as a wrapper-based feature selection method. Each candidate solution within the optimization process was represented as a binary vector in which “1” indicated feature selection and “0” represented feature exclusion. The algorithm initialized a random population of candidate feature subsets and iteratively updated them using Archimedes-inspired mechanisms involving density, acceleration, and volume parameters. The optimization objective simultaneously minimized classification error and the number of selected features. A K-Nearest Neighbors classifier was utilized as a lightweight evaluator during the feature selection process to estimate the predictive quality of each feature subset.

To improve stability and reduce dependence on random initialization, the feature selection process was repeated across multiple independent runs. Features with higher selection frequencies across iterations were retained as the final optimized feature subset. The selected features were subsequently used as inputs for the second stage of the framework.

In the learning stage, a stacked ensemble deep meta-learning architecture was developed. Four heterogeneous ensemble classifiers, including Random Forest (RF), AdaBoost, XGBoost, and Bagging, served as base learners. Each model independently learned patterns from the selected features and generated probabilistic outputs for the three digital transformation classes. The probabilistic predictions of all base classifiers were then concatenated and transferred to a multilayer deep neural network functioning as the meta-learner.

The deep neural network consisted of multiple dense hidden layers with nonlinear activation functions. Rectified Linear Unit (ReLU) activation was employed in hidden layers, while the Softmax function was utilized in the output layer to generate class probability distributions. The network parameters were optimized using the Adam optimization algorithm and categorical cross-entropy loss function.

The dataset was divided into training and testing subsets using stratified sampling, with 70% allocated for training and 30% reserved for testing. To comprehensively evaluate model performance, multiple label-based and probability-based evaluation metrics were employed, including Accuracy, Balanced Accuracy, Precision, Recall, F1-score, Cohen’s Kappa, Matthews Correlation Coefficient (MCC), Log-Loss, Area Under the Receiver Operating Characteristic Curve (AUROC), and Area Under the Precision-Recall Curve (AUPRC). All experiments were repeated in 20 independent runs to improve statistical reliability and reduce random variation effects.

Findings

The findings demonstrated that the proposed BAOA-SE-DML framework achieved exceptionally high predictive performance in determining digital transformation change levels. The convergence analysis revealed that the BAOA algorithm rapidly converged toward stable fitness values within early optimization iterations, indicating efficient exploration and exploitation balance during the feature selection process. The algorithm successfully identified a stable subset of influential digital transformation indicators while significantly reducing feature dimensionality.

Feature frequency analysis showed that the variable “digitaltransindex” had the highest selection frequency across independent optimization runs, indicating its dominant contribution to digital transformation prediction. Other frequently

selected variables included research and development intensity, financial support, executive education level, and infrastructure-related indicators. These findings suggested that technological investment, managerial capability, and organizational infrastructure represent core determinants of digital transformation maturity.

Among the classification models, the Bagging classifier achieved the highest overall predictive performance. The model obtained an Accuracy value of 0.9995, Balanced Accuracy of 0.9995, Recall of 0.9995, Precision of 0.9992, and F1-score of 0.9994. Additionally, Bagging achieved the lowest Log-Loss value of 0.0048, indicating highly reliable probabilistic predictions. AdaBoost also demonstrated near-perfect performance with Accuracy and F1-score values exceeding 0.9990.

The Random Forest classifier produced highly stable results with an Accuracy of 0.9988 and AUROC value of 1.0, confirming strong discriminative capability across transformation classes. XGBoost, although slightly weaker than the other ensemble methods, still produced highly competitive results with an Accuracy of 0.9951 and F1-score of 0.9928.

The stacked ensemble deep meta-learning framework (STACK) achieved highly robust performance with an Accuracy value of 0.9985, Balanced Accuracy of 0.9982, MCC of 0.9966, and AUROC of 1.0. The deep meta-learner effectively captured nonlinear relationships among the outputs of the base classifiers and generated highly accurate final predictions. The extremely high AUROC and AUPRC values across models confirmed the strong discriminative power and reliability of the proposed framework.

The evaluation metrics demonstrated that the proposed hybrid architecture not only improved classification accuracy but also enhanced prediction stability, probabilistic calibration, and class separability. The results consistently indicated that integrating intelligent feature selection with stacked ensemble deep learning substantially improved digital transformation prediction performance compared with individual base learners.

Discussion and Conclusion

The findings of this study demonstrated that integrating Binary Archimedes Optimization Algorithm with stacked ensemble deep meta-learning provides a highly effective framework for predicting digital transformation levels in organizations. The exceptional performance of the proposed model confirmed the importance of combining intelligent feature selection with ensemble learning architectures in handling complex organizational datasets. By reducing data dimensionality and removing irrelevant features, the BAOA algorithm enhanced model interpretability, stability, and predictive capability.

The results also highlighted the effectiveness of heterogeneous ensemble learning strategies in extracting complementary patterns from multidimensional organizational data. The strong performance of Bagging, Random Forest, and AdaBoost indicated that variance reduction and ensemble aggregation mechanisms are highly beneficial for digital transformation prediction tasks. Moreover, the deep neural network meta-learner successfully captured nonlinear dependencies among the outputs of base classifiers, resulting in superior predictive accuracy and robust classification performance.

From a managerial perspective, the proposed framework provides organizations with a powerful analytical tool for assessing digital transformation readiness and identifying critical transformation drivers. The ability to accurately predict transformation levels can support strategic planning, technology investment prioritization, and resource allocation decisions. Organizations may also use such intelligent systems to identify weaknesses in digital infrastructure, managerial capability, and innovation capacity before implementing large-scale transformation initiatives.

The study further demonstrated the growing importance of artificial intelligence and machine learning technologies in modern organizational transformation processes. Intelligent predictive systems can significantly improve organizational

adaptability, strategic agility, and data-driven decision-making in highly competitive digital environments. The integration of feature optimization, ensemble learning, and deep meta-learning may therefore represent an important direction for future digital transformation analytics and intelligent organizational management systems.

Overall, the proposed BAOA-SE-DML framework achieved highly reliable and stable predictive performance while effectively handling the complexity and multidimensionality of digital transformation datasets. The findings confirmed that combining metaheuristic optimization techniques with advanced ensemble deep learning architectures can substantially improve organizational digital transformation prediction and provide a robust foundation for intelligent decision-support systems in future digital enterprises.

Authors' Contributions

Authors equally contributed to this article.

Acknowledgments

Authors thank all participants who participate in this study.

Declaration of Interest

The authors report no conflict of interest.

Funding

According to the authors, this article has no financial support.

Ethical Considerations

All procedures performed in this study were under the ethical standards.

رویکرد هوشمند ترکیبی پیش‌بینی سطح تغییرات تحول دیجیتال بر اساس یادگیری جمعی پشته‌ای و فرایادگیری عمیق

تاریخچه مقاله

تاریخ دریافت: ۱ دی ۱۴۰۴

تاریخ بازنگری: ۸ اردیبهشت ۱۴۰۵

تاریخ پذیرش: ۱۶ اردیبهشت ۱۴۰۵

تاریخ چاپ اولیه: ۲۶ اردیبهشت ۱۴۰۵

تاریخ چاپ نهایی: ۱ تیر ۱۴۰۶

۱. ثمانه هدایتی^{ID}: گروه مدیریت فناوری اطلاعات، واحد بین‌المللی کیش، دانشگاه آزاد اسلامی، کیش، ایران

۲. سیدجواد ایرانبان فرد^{ID*}: گروه مدیریت، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران. ایمیل: javad.iranban@iau.ac.ir (نویسنده مسئول)

۳. سارا نجف زاده^{ID}: گروه کامپیوتر، واحد یادگار امام (ره) شهری، دانشگاه آزاد اسلامی، تهران، ایران

۴. مصطفی کلاهدوزی^{ID}: گروه مدیریت فناوری اطلاعات، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

چکیده

هدف این پژوهش ارائه یک چارچوب هوشمند مبتنی بر انتخاب ویژگی و یادگیری عمیق پشته‌ای برای پیش‌بینی سطح تغییرات تحول دیجیتال در سازمان‌ها و بهبود دقت تشخیص سطوح تحول دیجیتال است. این پژوهش از مجموعه داده استاندارد تحول دیجیتال سازمانی شامل ۲۰۰۰ نمونه و ۲۴ ویژگی استفاده کرد. در مرحله نخست، ویژگی‌های مؤثر با استفاده از الگوریتم بهینه‌سازی ارشمیدس باینری (BAOA) و رویکرد Wrapper-Based Feature Selection استخراج شدند. سپس ویژگی‌های منتخب به یک چارچوب یادگیری جمعی پشته‌ای و فرایادگیری عمیق (SE-DML) وارد شدند. در این معماری، چهار مدل پایه شامل جنگل تصادفی، AdaBoost، XGBoost و Bagging به‌عنوان طبقه‌بندهای اولیه مورد استفاده قرار گرفتند و خروجی احتمالاتی آن‌ها به یک شبکه عصبی عمیق چندلایه به‌عنوان مدل فراگیر منتقل شد. داده‌ها با روش stratified sampling به دو بخش آموزش (۷۰ درصد) و آزمون (۳۰ درصد) تقسیم شدند. برای ارزیابی عملکرد مدل از معیارهایی نظیر Accuracy، Balanced Accuracy، Precision، Recall، F1-Score، Kappa، MCC، Log-Loss، AUROC و AUPRC استفاده شد و نتایج در ۲۰ اجرای مستقل گزارش گردید. نتایج نشان داد که الگوریتم BAOA توانست به‌صورت پایدار ویژگی‌های کلیدی مرتبط با تحول دیجیتال را استخراج کند و در مدت کوتاهی به همگرایی برسد. تحلیل فراوانی ویژگی‌ها نشان داد که متغیر digitaltransindex بیشترین نقش را در پیش‌بینی سطح تحول دیجیتال ایفا می‌کند. همچنین مدل ترکیبی پیشنهادی عملکرد بسیار بالایی در طبقه‌بندی سطوح تحول دیجیتال ارائه داد. در میان مدل‌ها، Bagging بهترین عملکرد را با Accuracy برابر ۰.۹۹۹۵، F1 برابر ۰.۹۹۹۴ و کمترین مقدار Log-Loss معادل ۰.۰۰۴۸ ثبت کرد. مدل STACK مبتنی بر فرایادگیری عمیق نیز با Accuracy برابر ۰.۹۹۸۵ و AUROC برابر ۱.۰ عملکردی بسیار پایدار و قابل اتکا نشان داد. نتایج معیارهای MCC و Kappa نیز بیانگر توان بالای مدل پیشنهادی در تفکیک دقیق کلاس‌های تحول دیجیتال بود. یافته‌های پژوهش نشان داد که ترکیب انتخاب ویژگی مبتنی بر الگوریتم BAOA با معماری یادگیری جمعی پشته‌ای و فرایادگیری عمیق می‌تواند چارچوبی مؤثر برای پیش‌بینی سطح تغییرات تحول دیجیتال فراهم کند. این رویکرد ضمن کاهش ابعاد داده‌ها و حذف ویژگی‌های غیرضروری، توانست الگوهای پیچیده سازمانی را با دقت بالا شناسایی کرده و عملکرد بهتری نسبت به مدل‌های منفرد ارائه دهد. مدل پیشنهادی قابلیت استفاده در سیستم‌های تصمیم‌یار مدیریتی و برنامه‌ریزی راهبردی تحول دیجیتال را داراست.

کلیدواژه‌گان: تحول دیجیتال، انتخاب ویژگی، الگوریتم بهینه‌سازی ارشمیدس باینری، یادگیری جمعی پشته‌ای، فرایادگیری عمیق، یادگیری ماشین

شبهه استناددهی: هدایتی، ثمانه، ایرانبان فرد، سیدجواد، نجف زاده، سارا، و کلاهدوزی، مصطفی. (۱۴۰۶). رویکرد هوشمند ترکیبی پیش‌بینی سطح تغییرات تحول دیجیتال بر اساس یادگیری جمعی پشته‌ای و فرایادگیری عمیق. *حسابداری، امور مالی و هوش محاسباتی*، ۵(۲)، ۳۲-۱.



تحول دیجیتال در سال‌های اخیر به یکی از بنیادی‌ترین مسیرهای بازآرایی سازمان‌ها، صنایع و نظام‌های تصمیم‌گیری تبدیل شده است؛ زیرا سازمان‌ها دیگر نمی‌توانند صرفاً با اتکا به زیرساخت‌های سنتی، فرآیندهای خطی و مدل‌های مدیریتی گذشته به رقابت‌پذیری پایدار دست یابند. تحول دیجیتال نه تنها به معنای استفاده از ابزارهای فناوری اطلاعات، بلکه ناظر بر تغییر هم‌زمان در راهبرد، ساختار، فرهنگ سازمانی، قابلیت‌های داده‌محور، مدل کسب‌وکار و شیوه خلق ارزش است (Vial, 2021). از این منظر، تحول دیجیتال یک فرآیند چندبعدی و پویاست که در آن فناوری‌های نوین، داده‌های سازمانی، هوش مصنوعی و ظرفیت‌های تحلیلی در کنار یکدیگر موجب تغییر در منطق تصمیم‌گیری و عملکرد شرکت‌ها می‌شوند (Kraus et al., 2022). پژوهش‌های جدید نشان می‌دهند که سازمان‌ها برای موفقیت در این مسیر باید بتوانند سطح آمادگی، میزان تغییرات موردنیاز و شاخص‌های تعیین‌کننده تحول دیجیتال را به‌صورت دقیق ارزیابی کنند؛ زیرا نبود شناخت روشن از عوامل اثرگذار، موجب تخصیص نامناسب منابع، شکست پروژه‌های فناوری و کاهش بازده سرمایه‌گذاری دیجیتال می‌شود (Omol, 2024). بنابراین، تحلیل داده‌محور سطح تحول دیجیتال به یک ضرورت راهبردی برای سازمان‌های معاصر تبدیل شده است.

در ادبیات مدیریت و فناوری، تحول دیجیتال به‌طور فزاینده‌ای با قابلیت‌های هوش مصنوعی، یادگیری ماشین و تحلیل داده‌های بزرگ پیوند خورده است. هوش مصنوعی به سازمان‌ها امکان می‌دهد حجم گسترده‌ای از داده‌ها را پردازش کرده، الگوهای پنهان را کشف کنند و تصمیمات راهبردی را بر پایه شواهد دقیق‌تری اتخاذ نمایند (Davenport & Mittal, 2022). در همین راستا، قابلیت‌های هوش مصنوعی می‌توانند عملکرد سازمانی را در دوره تحول دیجیتال بهبود دهند، زیرا این قابلیت‌ها از طریق خودکارسازی، تحلیل پیش‌بینانه، بهینه‌سازی فرآیندها و شخصی‌سازی خدمات، مزیت رقابتی ایجاد می‌کنند (Mikalef et al., 2021). مطالعات دیگر نیز نشان داده‌اند که قابلیت‌های یادگیری ماشین، زمانی که با ظرفیت‌های سازمانی و راهبرد دیجیتال همسو شوند، می‌توانند عملکرد سازمانی را در محیط‌های رقابتی ارتقا دهند (Mikalef et al., 2022). افزون بر این، ادغام هوش مصنوعی در راهبرد کسب‌وکار به سازمان‌ها کمک می‌کند تا از رویکردهای واکنشی فاصله گرفته و به سمت تصمیم‌گیری پیش‌نگرانه حرکت کنند (Kitsios & Kamariotou, 2021). از این رو، تحول دیجیتال را باید نه یک پروژه فناوری محدود، بلکه یک فرآیند یادگیری سازمانی مبتنی بر داده دانست.

با وجود فرصت‌های گسترده، تحول دیجیتال همواره با چالش‌هایی جدی همراه است. در بسیاری از سازمان‌ها، موانعی مانند کمبود مهارت‌های دیجیتال، ضعف زیرساخت‌های داده‌ای، مقاومت کارکنان، نبود راهبرد روشن و محدودیت منابع مالی مانع پیاده‌سازی مؤثر فناوری‌های هوشمند می‌شوند (Ahmad et al., 2022). از سوی دیگر، مطالعات مربوط به شرکت‌های کوچک و متوسط نشان می‌دهند که این سازمان‌ها به دلیل محدودیت سرمایه، ضعف مدیریت فناوری و نبود توان تحلیلی پیشرفته، در مسیر تحول دیجیتال با دشواری بیشتری مواجه‌اند (Hendrawan et al., 2024). در محیط‌های نوظهور نیز کاربرد فناوری‌هایی مانند هوش مصنوعی و سامانه‌های زبانی هوشمند، فرصت‌های آموزشی و اقتصادی تازه‌ای ایجاد می‌کند، اما هم‌زمان چالش‌هایی مانند شکاف دیجیتال، محدودیت زیرساخت و نابرابری دسترسی را افزایش می‌دهد (Mhlanga, 2023). از این منظر، پیش‌بینی سطح تحول دیجیتال می‌تواند برای مدیران و سیاست‌گذاران اهمیت ویژه‌ای داشته باشد، زیرا امکان شناسایی سازمان‌های نیازمند تغییرات عمیق‌تر و تخصیص هوشمندانه‌تر منابع را فراهم می‌سازد.

یکی از محورهای مهم در پژوهش‌های اخیر، نقش سرمایه‌گذاری فناوری و جهت‌گیری راهبردی مدیریت عالی در موفقیت تحول دیجیتال است. سرمایه‌گذاری در فناوری اطلاعات زمانی به تحول واقعی منجر می‌شود که با راهبرد دیجیتال روشن و حمایت مدیران ارشد همراه باشد (Zhang et al., 2023). به همین ترتیب، تحول دیجیتال در مدیریت منابع انسانی نشان می‌دهد که فرآیندهای سنتی جذب، آموزش، ارزیابی و نگهداشت کارکنان نیز تحت تأثیر فناوری‌های دیجیتال باطراحی می‌شوند (Zhang & Chen, 2024). در بازار سرمایه نیز شواهد نشان می‌دهند که تحول دیجیتال می‌تواند محیط اطلاعاتی شرکت‌ها را بهبود دهد و رفتار پیش‌بینی‌گری تحلیل‌گران را تحت تأثیر قرار دهد (Chen et al., 2022). از سوی دیگر، تحول دیجیتال می‌تواند با کاهش عدم قطعیت اطلاعاتی، پیش‌بینی ریسک مالی شرکت‌ها را دقیق‌تر سازد (Xinxian & Jianhui, 2022). این یافته‌ها نشان می‌دهند که تحول دیجیتال صرفاً به سطح عملیاتی محدود نیست، بلکه پیامدهای آن در حوزه مالی، راهبردی، منابع انسانی و حکمرانی سازمانی نیز قابل مشاهده است.

در سال‌های اخیر، مدل‌های هوشمند و یادگیری ماشین به ابزارهای مهمی برای تحلیل تحول دیجیتال تبدیل شده‌اند. پژوهش‌های مبتنی بر یادگیری ماشین نشان داده‌اند که می‌توان با استفاده از الگوریتم‌های قابل تفسیر، سطح تحول دیجیتال در صنایع مختلف را پیش‌بینی و عوامل اثرگذار بر آن را شناسایی کرد (Zhu et al., 2024). همچنین مدل‌های تصمیم‌گیری مبتنی بر هوش مصنوعی می‌توانند به سازمان‌ها در تقویت راهبردهای تحول دیجیتال کمک کنند و انتخاب مسیرهای فناورانه را تسهیل نمایند (Kim & Kim, 2022). در سطح کلان‌تر، نوآوری‌های مبتنی بر هوش مصنوعی به عنوان ستون‌های اصلی تحول دیجیتال در صنایع معرفی شده‌اند و می‌توانند اثرات گسترده‌ای بر بهره‌وری، انعطاف‌پذیری و پایداری سازمانی داشته باشند (Aldoseri et al., 2024). مطالعات بازاریابی نیز نشان داده‌اند که ابزارهای هوش مصنوعی اگرچه فرصت‌هایی مانند تحلیل مشتری، خودکارسازی و شخصی‌سازی ایجاد می‌کنند، اما چالش‌هایی مانند کیفیت داده، اعتماد، شفافیت و هزینه پیاده‌سازی را نیز به همراه دارند (Golab-Andrzejak, 2023). بنابراین، توسعه مدل‌های دقیق پیش‌بینی تحول دیجیتال باید هم‌زمان به فرصت‌ها و پیچیدگی‌های داده‌ای این حوزه توجه کند.

از منظر روش‌شناختی، یکی از مسائل اساسی در پیش‌بینی تحول دیجیتال، وجود تعداد زیاد شاخص‌ها و احتمال حضور ویژگی‌های زائد، همبسته یا کم‌اثر است. انتخاب ویژگی می‌تواند با کاهش ابعاد داده، حذف نویز، افزایش سرعت یادگیری و بهبود تفسیرپذیری مدل‌ها، کیفیت پیش‌بینی را ارتقا دهد. ادبیات انتخاب ویژگی نشان می‌دهد که استفاده از روش‌های یادگیری ماشین در انتخاب متغیرهای مهم، به‌ویژه در داده‌های پیچیده و ابعاد بالا، نقش مهمی در افزایش دقت مدل‌ها دارد (Merceedi & Abdulazeez, 2025). در حوزه‌های دیگر مانند داده‌های بیان ژن نیز تأکید شده است که انتخاب ویژگی اگر به‌درستی طراحی نشود، ممکن است دچار سوگیری‌های ساختاری شود و نتایج مدل را تحت تأثیر قرار دهد (Grisci et al., 2024). از این رو، انتخاب ویژگی در مسائل سازمانی نیز باید با روش‌های بهینه‌سازی قدرتمند و معیارهای ارزیابی معتبر همراه باشد. مطالعات مربوط به انتخاب ویژگی مبتنی بر فراابتکاری نشان داده‌اند که ترکیب الگوریتم‌های بهینه‌سازی با طبقه‌بندهای یادگیری ماشین می‌تواند زیرمجموعه‌های مؤثرتری از ویژگی‌ها را شناسایی کند (Hassan et al., 2022). همچنین رویکردهای نوین بهینه‌سازی فراابتکاری در مسائل مختلف نشان داده‌اند که الهام از فرایندهای طبیعی و اجتماعی می‌تواند راهکارهای کارآمدی برای جست‌وجو در فضای پیچیده ویژگی‌ها فراهم سازد (Lamtar Gholipoor et al., 2024).

الگوریتم بهینه‌سازی ارشمیدس یکی از روش‌های فراابتکاری جدید است که با الهام از اصل شناوری و حرکت اجسام در سیال طراحی شده و برای حل مسائل بهینه‌سازی پیچیده کاربرد دارد (Hashim et al., 2021). مزیت این الگوریتم در توانایی آن برای برقراری تعادل میان کاوش و بهره‌برداری است؛ به این معنا که در مراحل اولیه می‌تواند فضای جست‌وجو را به‌طور گسترده بررسی کند و در مراحل بعدی بر نواحی امیدبخش متمرکز شود. در مسائل انتخاب ویژگی، نسخه باینری چنین الگوریتم‌هایی امکان نمایش انتخاب یا حذف هر ویژگی را از طریق بردارهای صفر و یک فراهم می‌کند. مطالعات مرتبط با بهینه‌سازی و انتخاب ویژگی نشان داده‌اند که الگوریتم‌های فراابتکاری می‌توانند نسبت به روش‌های سنتی، عملکرد مناسب‌تری در کاهش ابعاد و حفظ دقت طبقه‌بندی داشته باشند (Got et al., 2024). همچنین در حوزه‌های تشخیصی و پزشکی، مدل‌های ترکیبی مبتنی بر انتخاب ویژگی و یادگیری ماشین توانسته‌اند دقت پیش‌بینی را در مسائل پیچیده افزایش دهند (Agrawal et al., 2025). بنابراین، به‌کارگیری الگوریتم بهینه‌سازی ارشمیدس باینری در پیش‌بینی تحول دیجیتال می‌تواند یک مسیر نوآورانه برای استخراج شاخص‌های اثرگذار و کاهش پیچیدگی مدل باشد.

در کنار انتخاب ویژگی، معماری مدل یادگیری نیز نقش تعیین‌کننده‌ای در عملکرد پیش‌بینی دارد. مدل‌های یادگیری جمعی به دلیل ترکیب چندین یادگیرنده و کاهش خطای تعمیم، در بسیاری از مسائل طبقه‌بندی عملکرد مطلوبی نشان داده‌اند. Random Forest, Bagging, AdaBoost و XGBoost از جمله روش‌هایی هستند که هر یک با منطق متفاوتی به کاهش واریانس، کاهش سوگیری یا بهبود تصمیم‌گیری طبقه‌بند کمک می‌کنند. پژوهش‌های مبتنی بر XGBoost نشان داده‌اند که این الگوریتم به دلیل استفاده از منظم‌سازی و ساختار تقویت‌گرایانی، توانایی بالایی در پیش‌بینی مسائل پیچیده دارد (Budholiya et al., 2022). در مسائل شبکه و سلامت دیجیتال نیز استفاده از مدل‌های یادگیری ماشین و انتخاب ویژگی نشان داده است که ترکیب این دو می‌تواند کارایی سیستم‌های تشخیص را ارتقا دهد (Einy et al., 2021). مطالعات دیگر در حوزه تشخیص ناهنجاری و طبقه‌بندی داده‌های پزشکی نشان داده‌اند که مدل‌های یادگیری عمیق و ویژگی‌های محلی و عمیق می‌توانند الگوهای پیچیده را بهتر استخراج کنند (Einy et al., 2022). همچنین معماری‌های ترکیبی مبتنی بر شبکه‌های عصبی و مدل‌های دنباله‌ای برای تشخیص ناهنجاری، توان بالقوه روش‌های یادگیری عمیق را در تحلیل داده‌های پیچیده تأیید کرده‌اند (Einy et al., 2023).

یادگیری پشته‌ای و فرایادگیری عمیق از رویکردهای پیشرفته برای ترکیب مدل‌های پایه هستند. در این ساختار، خروجی مدل‌های مختلف به عنوان داده‌های سطح دوم به یک مدل فراگیر منتقل می‌شود تا ترکیب بهینه‌ای از پیش‌بینی‌ها به دست آید. پژوهش‌های مربوط به یادگیری پشته‌ای عمیق نشان می‌دهند که استفاده از شبکه عصبی عمیق به عنوان متیادگیر می‌تواند روابط غیرخطی میان پیش‌بینی‌های مدل‌های پایه را یاد بگیرد و عملکرد نهایی طبقه‌بندی را ارتقا دهد (Zhang et al., 2022). در مسائل نوین پیش‌بینی نیز کاهش واریانس عملکرد و افزایش دقت با استفاده از معماری‌های بازآموزی و شبکه‌های مورد توجه قرار گرفته است (Huang et al., 2024). همچنین کاربرد شبکه‌های عصبی در تحلیل عملکرد زنجیره تأمین نشان داده است که روش‌های هوشمند می‌توانند الگوهای پیچیده انحراف، عملکرد و عدالت سازمانی را شناسایی کنند (Manzari et al., 2025). در حوزه تصمیم‌گیری بالینی نیز مدل‌های ترکیبی هوش مصنوعی توانسته‌اند با ادغام چندین منبع اطلاعاتی، تصمیمات پیش‌بینانه دقیق‌تری تولید کنند (Vahed et al., 2025). این شواهد نشان می‌دهند که رویکردهای ترکیبی، به‌ویژه زمانی که انتخاب ویژگی و فرایادگیری عمیق را هم‌زمان به کار می‌گیرند، ظرفیت بالایی برای تحلیل مسائل پیچیده سازمانی دارند.

از سوی دیگر، ارزیابی عملکرد مدل‌های پیش‌بینی باید با مجموعه‌ای جامع از معیارها انجام شود. اتکا به یک شاخص واحد مانند دقت ممکن است تصویری ناقص از عملکرد مدل ارائه دهد؛ به‌ویژه در مسائل چندکلاسه یا داده‌های نامتوازن. معیارهایی مانند Recall، Precision، F1-score، Balanced Accuracy، Kappa، MCC، Log-Loss، AUROC و AUPRC می‌توانند ابعاد مختلف عملکرد مدل را نشان دهند (Naidu et al., 2023). در این میان، کاپای کوهن برای سنجش توافق فراتر از شانس کاربرد دارد و در داده‌های اسمی می‌تواند کیفیت طبقه‌بندی را دقیق‌تر آشکار سازد (Rau & Shih, 2021). معیارهای مبتنی بر احتمال مانند Cross-Entropy یا Log-Loss نیز برای ارزیابی کیفیت احتمال‌های پیش‌بینی شده اهمیت دارند، زیرا صرفاً بر برچسب نهایی تمرکز نمی‌کنند و میزان اطمینان مدل را نیز می‌سنجند (Mao et al., 2023). افزون بر این، AUROC و AUPRC ابزارهای مهمی برای تحلیل توان تفکیک مدل در شرایط چندکلاسه و نامتوازن هستند (Corbacioglu & Aksel, 2023). مطالعات مرتبط با تشخیص بیماری‌های مزمن و ناهنجاری‌ها نیز نشان داده‌اند که استفاده هم‌زمان از چند معیار ارزیابی می‌تواند قضاوت جامع‌تری درباره توان مدل فراهم کند (Nanehkaran et al., 2022; Licai, Chen, Jamel, et al., 2022).

با وجود پیشرفت‌های قابل توجه، هنوز در ادبیات تحول دیجیتال شکافی مهم وجود دارد. بسیاری از مطالعات موجود یا بر تحلیل مفهومی تحول دیجیتال متمرکز بوده‌اند یا از مدل‌های منفرد یادگیری ماشین برای پیش‌بینی استفاده کرده‌اند. برخی پژوهش‌ها نیز به نقش هوش مصنوعی در خلق ارزش کسب‌وکار پرداخته‌اند، اما کمتر به مسئله انتخاب بهینه ویژگی‌ها پیش از طبقه‌بندی سطح تحول دیجیتال توجه کرده‌اند (Perifanis & Kitsios, 2023). برخی دیگر از مطالعات، تحول دیجیتال را از منظر پایداری کسب‌وکار و تغییرات سازمانی بررسی کرده‌اند، اما چارچوبی محاسباتی برای پیش‌بینی سطح تغییرات ارائه نکرده‌اند (Shehadeh, 2024). مطالعات آینده‌نگر نیز بر روندهای آتی و ضرورت نگاه میان‌رشته‌ای به تحول دیجیتال تأکید کرده‌اند، اما همچنان نیاز به مدل‌هایی وجود دارد که بتوانند داده‌های سازمانی را به شاخص‌های تصمیم‌پذیر تبدیل کنند (Paul et al., 2024). در همین راستا، چارچوب‌هایی مانند بوم تحول دیجیتال تلاش کرده‌اند فرایند تحول را مفهومی‌سازی کنند، اما این چارچوب‌ها نیازمند پشتیبانی تحلیلی و پیش‌بینانه هستند تا در سطح عملیاتی قابل استفاده باشند (Elia et al., 2024). بنابراین، پیوند میان چارچوب‌های مفهومی تحول دیجیتال و مدل‌های پیش‌بینی هوشمند هنوز نیازمند توسعه بیشتر است.

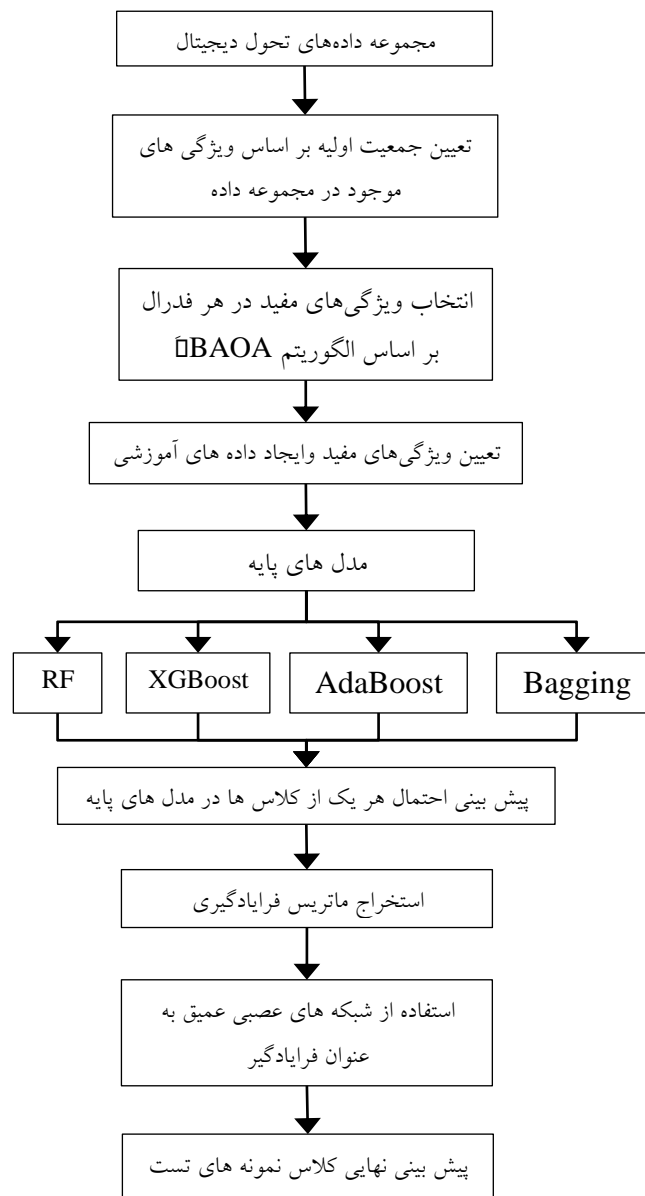
بر اساس این شکاف، پژوهش حاضر تلاش می‌کند با ترکیب انتخاب ویژگی مبتنی بر الگوریتم بهینه‌سازی ارشمیدس باینری و یادگیری جمعی پشته‌ای همراه با فرایادگیری عمیق، یک چارچوب دقیق برای پیش‌بینی سطح تغییرات تحول دیجیتال ارائه کند. داده‌های مورد استفاده از مجموعه‌داده استاندارد تحول دیجیتال شرکتی استخراج شده‌اند که امکان تحلیل تجربی سطح تحول دیجیتال را بر اساس شاخص‌های سازمانی فراهم می‌سازد (colabss, 2025). این رویکرد از یک سو با استفاده از BAOA ویژگی‌های غیرضروری را حذف کرده و شاخص‌های اثرگذار را استخراج می‌کند و از سوی دیگر، با بهره‌گیری از مدل‌های پایه ناهمگن و شبکه عصبی عمیق در لایه متا، توانایی یادگیری روابط پیچیده میان داده‌ها را افزایش می‌دهد. چنین ساختاری می‌تواند نسبت به مدل‌های منفرد، دقت، پایداری و قابلیت تعمیم بالاتری ایجاد کند. افزون بر این، پژوهش حاضر با

استفاده از معیارهای ارزیابی متنوع، عملکرد مدل را از منظر صحت طبقه‌بندی، تعادل کلاس‌ها، کیفیت احتمال‌ها و توان تفکیک بررسی می‌کند و از این طریق تصویری جامع از کارایی چارچوب پیشنهادی ارائه می‌دهد.

هدف این پژوهش ارائه یک رویکرد هوشمند ترکیبی مبتنی بر انتخاب ویژگی با الگوریتم بهینه‌سازی ارشمیدس باینری و یادگیری جمعی پشته‌ای همراه با فرایادگیری عمیق برای پیش‌بینی سطح تغییرات تحول دیجیتال در سازمان‌ها است.

روش پژوهش و مواد

پژوهش حاضر از نظر هدف، کاربردی و از نظر روش، یک مطالعه محاسباتی، تحلیلی و مبتنی بر یادگیری ماشین است که با هدف طراحی و ارزیابی یک چارچوب هوشمند برای پیش‌بینی سطح تغییرات تحول دیجیتال در سازمان‌ها انجام شد. در این مطالعه، به جای اتکا به داده‌های پیمایشی مستقیم، از مجموعه‌داده استاندارد تحول دیجیتال شرکتی استفاده شد که از پلتفرم Kaggle استخراج شده و شامل شاخص‌های کلیدی مرتبط با وضعیت مالی، فناوریانه، مدیریتی و ساختاری شرکت‌ها است. واحد تحلیل در این پژوهش شرکت‌ها بودند و هر رکورد در مجموعه‌داده بیانگر وضعیت یک شرکت از نظر شاخص‌های اثرگذار بر تحول دیجیتال بود. مجموعه‌داده مورد استفاده شامل ۲۰۰۰ نمونه و ۲۳ ویژگی پیش‌بین پیوسته بود و متغیر هدف نیز سطح تغییرات تحول دیجیتال را در سه طبقه Low، Medium و High نشان می‌داد. بنابراین، مسئله پژوهش به صورت یک مسئله طبقه‌بندی چندکلاسه تعریف شد که در آن هدف، پیش‌بینی سطح تغییرات بنیادین تحول دیجیتال شرکت‌ها بر اساس مجموعه‌ای از ویژگی‌های سازمانی و فناوریانه بود. با توجه به ماهیت چندبعدی تحول دیجیتال، ویژگی‌های موجود در مجموعه‌داده طیفی از شاخص‌های مرتبط با هزینه‌های تحقیق و توسعه، شدت تحقیق و توسعه، نسبت فناوری، سطح تحصیلات مدیران، شبکه اجتماعی، تمرکز مالکیت، دوگانگی مدیریتی، نسبت اعضای مستقل هیئت‌مدیره، بازده دارایی، اهرم مالی، رشد، شاخص توبین، حمایت مالی، امتیاز زیرساخت، رشد نقدینگی، حمایت از مالکیت فکری، تمرکز بازار، درآمد گذشته، نسبت جریان نقدی، سن شرکت، اندازه شرکت و شاخص تحول دیجیتال را در بر می‌گرفت. حضور هم‌زمان این متغیرها موجب شد که داده‌ها از نظر اطلاعاتی غنی باشند، اما احتمال وجود ویژگی‌های زائد، کم‌انرژی، همبسته یا نویزی نیز افزایش یابد. به همین دلیل، در طراحی پژوهش، انتخاب ویژگی به عنوان یک مرحله ضروری پیش از آموزش مدل‌های یادگیری ماشین در نظر گرفته شد تا مدل نهایی بتواند با تعداد کمتری از شاخص‌ها، اما با قدرت تمایز بیشتر، سطح تحول دیجیتال را پیش‌بینی کند. از این منظر، طرح پژوهش بر یک ساختار دومرحله‌ای استوار بود: نخست، استخراج زیرمجموعه‌ای بهینه از ویژگی‌ها با استفاده از الگوریتم بهینه‌سازی ارشمیدس باینری و سپس آموزش یک مدل یادگیری جمعی پشته‌ای همراه با فرایادگیری عمیق بر اساس ویژگی‌های منتخب.



شکل ۱. فلوجارت روش پیشنهادی

داده‌های پژوهش از مجموعه‌داده استاندارد تحول دیجیتال شرکتی گردآوری شد که به صورت عمومی در پلتفرم Kaggle در دسترس بوده و برای تحلیل‌های مرتبط با تحول دیجیتال سازمانی طراحی شده است. این مجموعه‌داده به دلیل برخورداری از تعداد مناسب نمونه‌ها، تنوع شاخص‌های سازمانی و وجود برچسب طبقه‌بندی‌شده برای سطح تحول دیجیتال، برای هدف این پژوهش مناسب تشخیص داده شد. پیش از ورود داده‌ها به فرآیند مدل‌سازی، ساختار داده‌ها بررسی شد تا ویژگی‌های ورودی و متغیر هدف به صورت دقیق تفکیک شوند. متغیر هدف، سطح تغییرات تحول دیجیتال بود که در قالب سه طبقه Low، Medium و High تعریف شده بود. سایر متغیرها به عنوان ویژگی‌های پیش‌بین در نظر گرفته شدند. از آنجا که تمام ویژگی‌های اصلی ماهیت عددی و پیوسته داشتند، داده‌ها برای استفاده در الگوریتم‌های یادگیری ماشین و شبکه عصبی مناسب بودند. در مرحله آماده‌سازی داده‌ها، ابتدا داده‌ها از نظر سازگاری ساختاری، نوع متغیرها، وجود مقادیر گم‌شده و قابلیت استفاده در مدل‌های طبقه‌بندی بررسی شدند. سپس ویژگی‌های ورودی و برچسب خروجی از یکدیگر جدا شدند. برای جلوگیری از سوگیری ناشی از توزیع نامتوازن طبقات در مجموعه آموزش و آزمون، داده‌ها با استفاده از نمونه‌گیری تصادفی طبقه‌بندی‌شده به دو بخش آموزش و آزمون تقسیم شدند. بر این اساس، ۷۰ درصد داده‌ها برای آموزش مدل و ۳۰ درصد داده‌ها برای آزمون نهایی مدل اختصاص یافت. استفاده

از نمونه‌گیری اشیاعی موجب شد نسبت نمونه‌های مربوط به هر یک از سطوح تحول دیجیتال در هر دو بخش آموزش و آزمون تا حد امکان حفظ شود. این موضوع از آن جهت اهمیت داشت که در مسائل طبقه‌بندی چندکلاسه، تغییر توزیع طبقات میان داده‌های آموزش و آزمون می‌تواند ارزیابی عملکرد مدل را دچار خطا کند.

پس از تقسیم داده‌ها، فرآیند انتخاب ویژگی تنها بر بخش آموزشی اعمال شد تا از نشت اطلاعات از داده‌های آزمون به فرآیند آموزش جلوگیری شود. در این مرحله، الگوریتم بهینه‌سازی ارشمیدس باینری به عنوان یک روش فراابتکاری مبتنی بر جمعیت برای جست‌وجوی زیرمجموعه‌های ممکن از ویژگی‌ها به کار گرفته شد. در الگوریتم BAOA، هر راه‌حل به صورت یک بردار باینری با طول برابر با تعداد ویژگی‌های اولیه نمایش داده شد؛ مقدار ۱ در هر جایگاه نشان‌دهنده انتخاب ویژگی متناظر و مقدار ۰ نشان‌دهنده حذف آن ویژگی بود. جمعیت اولیه شامل مجموعه‌ای از بردارهای باینری تصادفی بود که در تکرارهای متوالی با استفاده از منطق الگوریتم ارشمیدس به‌روزرسانی شدند. در این فرآیند، کیفیت هر زیرمجموعه ویژگی با استفاده از تابع تناسب ارزیابی شد؛ تابعی که هم‌زمان دو هدف کاهش تعداد ویژگی‌های انتخاب‌شده و کاهش خطای طبقه‌بندی را دنبال می‌کرد. برای ارزیابی سریع هر زیرمجموعه، از طبقه‌بند KNN استفاده شد، زیرا این طبقه‌بند با پیچیدگی محاسباتی نسبتاً پایین می‌تواند عملکرد تمایزی ویژگی‌ها را در فرآیند انتخاب ویژگی به صورت کارآمد برآورد کند.

فرآیند انتخاب ویژگی در چند اجرای مستقل انجام شد تا وابستگی نتایج به جمعیت اولیه تصادفی کاهش یابد و پایداری ویژگی‌های منتخب افزایش پیدا کند. در هر اجرا، الگوریتم BAOA یک زیرمجموعه مناسب از ویژگی‌ها را شناسایی کرد و سپس فراوانی انتخاب هر ویژگی در میان اجراهای مختلف بررسی شد. ویژگی‌هایی که بیش از میانگین فراوانی کل انتخاب شده بودند به عنوان ویژگی‌های پایدارتر و مؤثرتر در نظر گرفته شدند. این راهبرد موجب شد انتخاب نهایی ویژگی‌ها صرفاً حاصل یک اجرای منفرد نباشد، بلکه بر اساس تکرارپذیری و ثبات انتخاب در چندین اجرای مستقل تعیین شود. در نهایت، مجموعه ویژگی‌های منتخب به عنوان ورودی چارچوب یادگیری جمعی پشته‌ای و فرایادگیری عمیق استفاده شد.

تحلیل داده‌ها در این پژوهش در چند مرحله پیوسته انجام شد. در مرحله نخست، انتخاب ویژگی با استفاده از الگوریتم BAOA اجرا شد. الگوریتم بهینه‌سازی ارشمیدس از اصل شناوری الهام گرفته است و در آن هر عامل جست‌وجو به منزله جسمی در یک سیال فرض می‌شود که دارای موقعیت، چگالی، حجم و شتاب است. منطق اصلی الگوریتم بر به‌روزرسانی این ویژگی‌ها و حرکت تدریجی عامل‌ها به سمت راه‌حل بهینه استوار است (Hashim et al., ۲۰۲۱). رابطه تعادل اولیه میان نیروی شناوری و وزن جسم به صورت زیر تعریف شد:

$$F_b = W_o, p_b v_b a_b = p_o v_o a_o$$

بر اساس این رابطه، شتاب جسم به شکل زیر به دست آمد:

$$a_o = \frac{p_b v_b a_b}{p_o v_o}$$

در حالتی که اثر برخورد با جسم مجاور نیز در نظر گرفته شود، رابطه تعادل به شکل زیر گسترش یافت:

$$F_b = W_o, W_b - W_r = W_o, p_b v_b a_b - p_r v_r a_r = p_o v_o a_o$$

در فرآیند بهینه‌سازی، موقعیت اولیه هر عامل جست‌وجو به صورت تصادفی در فضای جست‌وجو مقدردهی شد. موقعیت، چگالی، حجم و شتاب اولیه عامل‌ها بر اساس روابط زیر تعریف شدند:

$$O_i = lb_i \times rand + (ub_i - lb_i), i = 1, 2, \dots, N$$

$$Oden_i = rand, vol_i = rand$$

$$acc_i = lb_i \times rand + (ub_i - lb_i)$$

پس از مقداردهی اولیه و ارزیابی جمعیت، بهترین راه حل به عنوان x_{best} شناسایی شد و چگالی، حجم و شتاب متناظر با آن ذخیره گردید. در هر تکرار، چگالی و حجم عاملها با توجه به بهترین راه حل به روزرسانی شد:

$$\begin{aligned} den_i^{t+1} &= den_i^t + rand \times (den_{best} - den_i^t) \\ vol_i^{t+1} &= vol_i^t + rand \times (vol_{best} - vol_i^t) \end{aligned}$$

برای کنترل گذار میان فاز کاوش و بهره برداری، از عامل انتقال و ضریب کاهش چگالی استفاده شد:

$$\begin{aligned} TF &= \exp\left(\frac{t - t_{max}}{t_{max}}\right) \\ d^{t+1} &= \exp\left(\frac{t - t_{max}}{t_{max}}\right) - \frac{t}{t_{max}} \end{aligned}$$

زمانی که $TF \leq 0.5$ بود، الگوریتم در فاز کاوش قرار گرفت و شتاب عامل بر اساس برخورد با یک عامل تصادفی به روزرسانی شد:

$$acc_i^{t+1} = \frac{den_{mr} + vol_{mr} \times acc_{mr}}{den_i^{t+1} \times vol_i^{t+1}}$$

در مقابل، زمانی که $TF > 0.5$ بود، الگوریتم وارد فاز بهره برداری شد و شتاب عامل با تکیه بر بهترین راه حل به روزرسانی گردید:

$$acc_i^{t+1} = \frac{den_{best} + vol_{best} \times acc_{best}}{den_i^{t+1} \times vol_i^{t+1}}$$

سپس شتاب برای کنترل اندازه گام حرکت نرمال سازی شد:

$$acc_{i-norm}^{t+1} = u \times \frac{acc_i^{t+1} - \min(acc)}{\max(acc) - \min(acc)} + l$$

در ادامه، موقعیت عاملها در فاز کاوش و بهره برداری به ترتیب بر اساس روابط زیر به روزرسانی شد:

$$\begin{aligned} x_i^{t+1} &= x_i^t + C_1 \times rand \times acc_{i-norm}^{t+1} \times d \times (x_{rand} - x_i^t) \\ x_i^{t+1} &= x_{best}^t + F \times C_2 \times rand \times acc_{i-norm}^{t+1} \times d \times (T \times x_{rand} - x_i^t) \end{aligned}$$

در نسخه باینری الگوریتم، موقعیت‌های به روز شده به مقادیر صفر و یک تبدیل شدند تا وضعیت انتخاب یا حذف هر ویژگی مشخص شود. تابع تناسب طراحی شده برای انتخاب ویژگی، ترکیبی از نسبت ویژگی‌های انتخاب شده، جریمه انتخاب ویژگی، خطای پیش بینی و آنتروپی راه حل نسبت به برجسب کلاس بود. این تابع به صورت زیر تعریف شد:

$$Min F = \sum_{n=1}^N L_n + \sum_{n=1}^N \sum_{m=1}^M s_{nm} e_{nm} + \sum_{m=1}^M E N_m$$

$$\begin{aligned}
 s. t. \quad & \sum_{n=1}^N L_n \leq N \\
 & \sum_{m=1}^M E_m \leq 1 \\
 & \sum_{n=1}^N S_n \leq \alpha \\
 & \sum_{m=1}^M e_m \leq \beta
 \end{aligned}$$

در این رابطه، m تعداد ویژگی‌های انتخاب شده از میان N ویژگی موجود، m نشان‌دهنده راه‌حل‌های موجود در جمعیت، L_n نسبت ویژگی‌های انتخاب شده به کل ویژگی‌ها، S_{nm} جریمه مربوط به ویژگی‌های انتخاب شده، e_{nm} میزان خطای پیش‌بینی و EN_m آنتروپی هر راه‌حل نسبت به برچسب کلاس است. همچنین α حداکثر مقدار جریمه مجاز و β حداکثر خطای قابل قبول را مشخص می‌کند. منطبق این تابع آن بود که زیرمجموعه‌ای از ویژگی‌ها انتخاب شود که ضمن حداقل‌سازی تعداد شاخص‌ها، خطای طبقه‌بندی را نیز کاهش دهد.

پس از استخراج ویژگی‌های منتخب، مرحله یادگیری با استفاده از چارچوب SE-DML انجام شد. در لایه نخست این چارچوب، چهار مدل پایه شامل Random Forest، XGBoost، AdaBoost و Bagging آموزش داده شدند. هر یک از این مدل‌ها با سازوکار یادگیری متفاوت، بخشی از الگوهای موجود در داده‌های تحول دیجیتال را استخراج کردند Random Forest با ترکیب چندین درخت تصمیم و استفاده از رأی‌گیری اکثریت، پیش‌بینی نهایی را تولید کرد (Paul et al., ۲۰۱۸).

$$\hat{y} = \text{mode}\{h_1(x), h_2(x), \dots, h_T(x)\}$$

در مدل Bagging، چندین مدل پایه روی نمونه‌های بوت‌استرپ شده آموزش داده شدند و تصمیم نهایی از طریق رأی‌گیری اکثریت حاصل شد (Tüysüzöğlü & Birant, ۲۰۲۰):

$$\hat{y} = \arg \max_c \sum_{m=1}^M I(h_m(x) = c)$$

در الگوریتم AdaBoost، طبقه‌بندهای ضعیف به صورت تدریجی آموزش داده شدند و نمونه‌هایی که در مراحل قبلی اشتباه طبقه‌بندی شده بودند وزن بیشتری دریافت کردند. خطای هر طبقه‌بند و وزن آن به صورت زیر محاسبه شد (Tüysüzöğlü & Birant, ۲۰۲۰):

$$\begin{aligned}
 \epsilon_t &= \frac{\sum_{i=1}^N w_i I(y_i \neq h_t(x_i))}{\sum_{i=1}^N w_i} \\
 \alpha_t &= \frac{1}{2} \ln \left(\frac{1 - \epsilon_t}{\epsilon_t} \right) \\
 H(x) &= \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right)
 \end{aligned}$$

در مدل XGBoost نیز پیش‌بینی نهایی از جمع چندین درخت تصمیم حاصل شد و تابع هدف شامل خطای پیش‌بینی و جمله منظم‌سازی بود. (Budholiya et al., ۲۰۲۲):

۲۰۲۲):

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i)$$

$$L = \sum_{i=1}^N l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k)$$

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2$$

خروجی احتمالاتی مدل‌های پایه به عنوان ورودی لایه متا استفاده شد. اگر تعداد مدل‌های پایه M و تعداد کلاس‌ها C باشد، بردار ورودی مدل متا به صورت ترکیب احتمال‌های

پیش‌بینی شده برای هر کلاس تعریف شد: (Zhang, ۲۰۲۲)

$$z = [p_{1,1}, p_{1,2}, \dots, p_{1,C}, p_{2,1}, \dots, p_{M,C}]$$

در لایه متا، یک شبکه عصبی عمیق چندلایه طراحی شد که شامل سه لایه پنهان با ۳۲، ۱۶ و ۸ نورون بود. این شبکه با استفاده از لایه‌های متراکم، روابط غیرخطی میان

پیش‌بینی‌های احتمالاتی مدل‌های پایه را یاد گرفت. خروجی هر نورون در لایه l به صورت زیر تعریف شد: (Zhang, ۲۰۲۲)

$$h_j^{(l)} = f\left(\sum_{i=1}^{n_{l-1}} w_{ij}^{(l)} h_i^{(l-1)} + b_j^{(l)}\right)$$

در لایه‌های پنهان از تابع فعال‌سازی ReLU استفاده شد:

$$ReLU(x) = \max(0, x)$$

در لایه خروجی نیز تابع Softmax برای تولید احتمال تعلق هر نمونه به کلاس‌های Low، Medium و High به کار رفت:

$$Softmax(z_i) = \frac{e^{z_i}}{\sum_{k=1}^C e^{z_k}}$$

برای آموزش شبکه عصبی، تابع هزینه آنتروپی متقاطع دسته‌ای استفاده شد:

$$L = - \sum_{i=1}^C y_i \log(\hat{y}_i)$$

بهینه‌سازی پارامترهای شبکه با الگوریتم Adam انجام شد تا نرخ یادگیری به صورت تطبیقی تنظیم شود و فرآیند همگرایی با پایداری بیشتری پیش رود. (Zhang, ۲۰۲۲)

عملکرد مدل‌ها در ۲۰ اجرای مستقل ارزیابی شد تا اثر تصادفی بودن تقسیم داده‌ها، مقداردهی اولیه و فرآیند انتخاب ویژگی کاهش یابد. برای ارزیابی مدل‌ها، ابتدا ماتریس آشفتگی

چندکلاسه محاسبه شد و سپس شاخص‌های مبتنی بر برچسب و مبتنی بر احتمال استخراج شدند. عناصر اصلی ماتریس آشفتگی برای هر کلاس به صورت زیر تعریف شدند:

$$TP_c = CM_{cc}$$

$$TN_c = \sum_{i \neq c, j \neq c} C M_{ij}$$

$$FP_c = \sum_{i \neq c} C M_{ic}$$

$$FN_c = \sum_{j \neq c} C M_{cj}$$

معیارهای مبتنی بر برچسب شامل Accuracy، Recall، Precision، F1-score، Balanced Accuracy، Specificity، Cohen's Kappa و MCC بودند. دقت کلی، حساسیت، صحت، امتیاز F1 و دقت متوازن به صورت زیر محاسبه شدند:

$$Accuracy = \frac{\sum_{c=1}^C TP_c}{\sum_{c=1}^C (TP_c + FP_c + TN_c + FN_c)}$$

$$Recall_c = \frac{TP_c}{TP_c + FN_c}$$

$$Precision_c = \frac{TP_c}{TP_c + FP_c}$$

$$F1_c = 2 \times \frac{Precision_c \times Recall_c}{Precision_c + Recall_c}$$

$$Balanced Accuracy = \frac{1}{C} \sum_{c=1}^C \frac{TP_c}{TP_c + FN_c}$$

همچنین Specificity، کاپای کوهن و ضریب همبستگی متیوز برای بررسی دقیق‌تر عملکرد مدل در شرایط چندکلاسه استفاده شدند:

$$Specificity_c = \frac{TN_c}{TN_c + FP_c}$$

$$\kappa = \frac{P_0 - P_e}{1 - P_e}$$

$$P_0 = Accuracy$$

$$P_e = \sum_{c=1}^C \frac{(TP_c + FN_c)(TP_c + FP_c)}{N^2}$$

معیارهای مبتنی بر احتمال نیز شامل Log-Loss، AUROC و AUPRC بودند Log-Loss. برای سنجش کیفیت احتمال‌های پیش‌بینی شده به صورت زیر محاسبه شد:

$$LogLoss = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C Y_{i,c} \log(P_{i,c})$$

هدایتی و همکاران

برای AUROC و AUPRC، از راهبرد one-vs-rest استفاده شد؛ به این معنا که هر کلاس یک بار به عنوان کلاس مثبت و سایر کلاس‌ها به عنوان کلاس منفی در نظر گرفته شدند. سپس میانگین کل کلاس‌ها به عنوان مقدار نهایی گزارش شد:

$$AUROC_{macro} = \frac{1}{C} \sum_{c=1}^C AUROC_c$$

$$AUPRC_{macro} = \frac{1}{C} \sum_{c=1}^C AUPRC_c$$

در نهایت، عملکرد روش پیشنهادی BAOA-SE-DML با عملکرد مدل‌های پایه مقایسه شد تا مشخص شود ترکیب انتخاب ویژگی مبتنی بر BAOA و یادگیری جمعی پشته‌ای عمیق تا چه حد می‌تواند نسبت به استفاده از مدل‌های منفرد برتری داشته باشد. معیارهای ارزیابی به گونه‌ای انتخاب شدند که هم صحت طبقه‌بندی نهایی و هم کیفیت خروجی‌های احتمالاتی مدل را پوشش دهند. این رویکرد تحلیلی امکان قضاوت جامع‌تری درباره مدل در پیش‌بینی سطح تغییرات تحول دیجیتال فراهم کرد و نشان داد که استفاده هم‌زمان از انتخاب ویژگی فراابتکاری، مدل‌های یادگیری جمعی و شبکه عصبی عمیق می‌تواند چارچوبی دقیق، پایدار و قابل تعمیم برای تحلیل تحول دیجیتال سازمانی ایجاد کند.

یافته‌ها

در این مقاله به منظور پیش‌بینی سطح تغییرات بنیادین در فرآیند تحول دیجیتال از رویکرد یادگیری عمیق استفاده شده است. در این راستا در این مقاله از مجموعه داده استاندارد تحول دیجیتال استفاده شده است. این مجموعه داده دارای ۲۳ ویژگی و ۲۰۰۰ نمونه است که هر نمونه فاکتورهای مهم در تغییرات بنیادین در فرآیند تحول دیجیتال در یک شرکت را نشان می‌دهد. برچسب این نمونه‌های در مجموعه داده شامل سطح تغییرات در فرآیند تحول دیجیتال است که به سه کلاس Low, Medium, High تقسیم می‌شود. هدف این مقاله پیش‌بینی سطح تغییرات بنیادین در فرآیند تحول دیجیتال در شرکت‌های جدید است. در این راستا ویژگی‌های مجموعه داده استاندارد تحول دیجیتال در جدول ۱ نشان داده شده است.

جدول ۱. ویژگی‌های مجموعه داده تحول دیجیتال

شماره ویژگی	عنوان ویژگی	نوع ویژگی	شماره ویژگی	عنوان ویژگی	نوع ویژگی
۱	rd_expenses	پیوسته	۱۳	tobin_q	پیوسته
۲	rd_intensity	پیوسته	۱۴	fin_support	پیوسته
۳	tech_ratio	پیوسته	۱۵	infra_score	پیوسته
۴	manager_ln	پیوسته	۱۶	m2_growth	پیوسته
۵	exec_edu_level	پیوسته	۱۷	ip_protection	پیوسته
۶	social_network	پیوسته	۱۸	hhi_d	پیوسته
۷	top10_share	پیوسته	۱۹	past_revenue_ln	پیوسته
۸	duality	پیوسته	۲۰	cashflow_ratio	پیوسته
۹	ind_dir_ratio	پیوسته	۲۱	firm_age	پیوسته
۱۰	roa	پیوسته	۲۲	size_ln	پیوسته
۱۱	lev	پیوسته	۲۳	digitaltransindex	پیوسته
۱۲	growth	پیوسته	۲۴	digitaltrans_class	برچسب

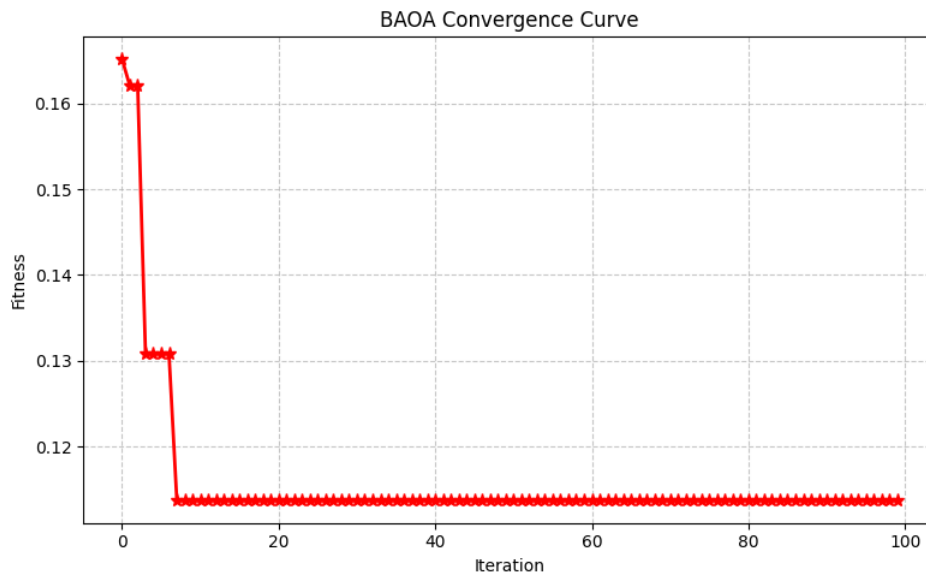
حسابداری، امور مالی و هوش محاسباتی

با توجه به ساختار داده‌های تحول دیجیتال، که در آن تعداد ویژگی‌ها معمولاً زیاد و تعداد نمونه‌ها محدود است، به‌کارگیری یک روش مؤثر برای کاهش ابعاد و شناسایی شاخص‌های کلیدی امری ضروری است. این امر مانع از بیش‌برازش مدل‌های یادگیری ماشین شده و موجب بهبود پایداری و قابلیت تعمیم آن‌ها می‌شود. در این پژوهش، انتخاب ویژگی با استفاده از الگوریتم BAOA انجام شده است. این الگوریتم با تکیه بر اصول دینامیکی مدل ارشمیدس در فضای جست‌وجوی باینری، مجموعه‌ای از پارامترهای کنترلی دارد که تنظیم دقیق آن‌ها بر فرایند اکتشاف، بهره‌برداری و همگرایی تأثیرگذار است. مقادیر پارامترها با استفاده از تنظیمات رایج در مطالعات معتبر انتخاب ویژگی تعیین شده‌اند. جدول ۲ شامل مقادیر استفاده‌شده برای پارامترهای الگوریتم BAOA به‌همراه توضیحاتی مختصر درباره نقش هر پارامتر است. در این مطالعه، تنظیم این مقادیر با رجوع به مقادیر پیش‌فرض و رایج در مقالات مرتبط با مسئله انتخاب ویژگی انجام گرفته است.

جدول ۲. پارامترهای الگوریتم BAOA

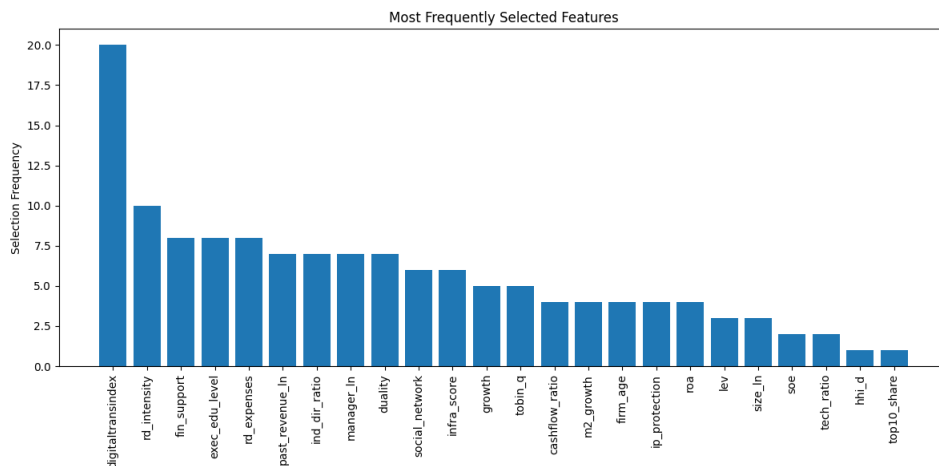
پارامتر	توضیح	مقدار
جمعیت اولیه (Population Size)	تعداد پاسخ‌های اولیه (بردارهای باینری ویژگی‌ها) که الگوریتم با آن‌ها آغاز می‌شود.	۱۰۰
حداکثر تعداد تکرارها (Max Iterations)	تعداد چرخه‌های به‌روزرسانی برای یافتن بهترین زیرمجموعه ویژگی.	۱۰۰
بُعد جست‌وجو (Dimensionality)	تعداد ویژگی‌های مسئله که باید انتخاب یا رد شوند (تعداد بیت‌ها در بردار باینری).	برابر با تعداد ویژگی‌های اولیه داده
چگالی سیال (Fluid Density, ρ)	پارامتری برگرفته از مدل ارشمیدس که رفتار شناوری و حرکت عوامل را کنترل می‌کند.	۱.۰
شتاب خارجی (External Acceleration, g)	عامل کنترلی برای شدت تأثیر نیروهای خارجی در حرکت عامل‌ها.	۹.۸۱
ضریب میرایی (Damping Factor, λ)	کنترل‌کننده کاهش تدریجی انرژی و نوسانات عامل‌ها در طول تکرارها.	۰.۹
نرخ باینری‌سازی (Transfer Function Threshold)	آستانه تبدیل موقعیت‌های پیوسته به مقادیر ۰ و ۱ برای انتخاب ویژگی.	۰.۵
فاکتور کاوش (Exploration Coefficient, α)	کنترل میزان جست‌وجوی وسیع در فضای کل ویژگی‌ها.	۰.۶
فاکتور بهره‌برداری (Exploitation Coefficient, β)	کنترل تمرکز الگوریتم بر نواحی امیدبخش پس از نزدیک شدن به جواب‌های خوب.	۰.۴

در این چارچوب، تابع برازندگی BAOA بر مبنای خطای طبقه‌بندی تعریف گردیده تا کیفیت هر زیرمجموعه ویژگی به‌طور مستقیم از عملکرد مدل ارزیابی شود. الگوریتم با ایجاد جمعیت اولیه، به‌روزرسانی گام‌به‌گام موقعیت‌ها و انتخاب پاسخ‌های برتر، تا رسیدن به شرط توقف پیش می‌رود و در نهایت مجموعه‌ای بهینه از ویژگی‌های مرتبط با سطح تحول دیجیتال استخراج می‌شود. در شکل ۲ نمودار همگرایی الگوریتم BAOA بر روی مجموعه داده تحول دیجیتال نشان داده شده است.




شکل ۲. نمودار همگرایی الگوریتم BAOA

الگوی همگرایی ارائه شده در نمودار نشان می‌دهد که الگوریتم BAOA در همان مراحل ابتدایی اجرای خود به سرعت به یک مقدار پایدار از تابع برازندگی دست می‌یابد. مقدار اولیه خطا در چند تکرار اول شبیهی تند رو به کاهش دارد و پس از رسیدن به حدود ۰.۱۱۴، روند تغییرات تقریباً ثابت می‌شود. این رفتار بیانگر آن است که الگوریتم توانسته در همان گام‌های نخست نواحی بهینه فضای جست‌وجو را شناسایی کند و پس از آن با حفظ تعادل میان کاوش و بهره‌برداری، راه‌حلی با پایداری مناسب ارائه دهد. نبود نوسان‌های شدید در تکرارهای میانی و پایانی نشان‌دهنده ثبات ساختاری مدل و عدم افتادن آن در بهینه‌های محلی است. در مجموع، شکل همگرایی به‌وضوح نشان می‌دهد که BAOA برای مسئله انتخاب ویژگی در این پژوهش از کارآمدی بالا و رفتار همگرا برخوردار است و می‌تواند مجموعه‌ای از ویژگی‌های مؤثر را بدون نیاز به تکرارهای طولانی استخراج کند. در روش پیشنهادی، برای کاهش وابستگی الگوریتم BAOA به جمعیت اولیه تصادفی و جلوگیری از گیر افتادن آن در بهینه‌های محلی، فرایند انتخاب ویژگی در ۲۰ تکرار مستقل اجرا می‌شود و میانگین نتایج به عنوان خروجی نهایی گزارش می‌گردد. در هر تکرار، راه‌حل بهینه‌ی به‌دست‌آمده ذخیره شده و در پایان، میزان تکرار هر ویژگی در میان همه راه‌حل‌های نهایی بررسی می‌شود. سپس برای دستیابی به مجموعه‌ای نزدیک به بهینه سراسری، تنها ویژگی‌هایی انتخاب می‌شوند که درصد تکرار آن‌ها از میانگین کل درصد تکرار ویژگی‌ها بیشتر باشد. این رویکرد موجب می‌شود نتایج نهایی از پایداری بالاتر و وابستگی کمتر به انتخاب‌های تصادفی اولیه برخوردار باشد. در شکل ۳ نمودار فراوانی ویژگی‌های انتخاب شده در طی مراحل تکرار شبیه‌سازی نشان داده شده است.



شکل ۳. نمودار فراوانی ویژگی‌های انتخاب شده در طی مراحل تکرار

نمودار نشان می‌دهد که شدت تکرار ویژگی‌ها در فرایند انتخاب ویژگی کاملاً نامتوازن است و برخی متغیرها به‌طور معناداری برجسته‌تر از سایرین ظاهر شده‌اند. شاخص «digitaltransindex» با اختلاف قابل توجه، بیشترین فراوانی انتخاب را دارد و همین امر بیانگر نقش محوری آن در تبیین سطح تحول دیجیتال شرکت‌هاست. پس از آن، ویژگی‌هایی مانند «rd_intensity»، «fin_support» و «exec_edu_level» با فراوانی متوسط قرار می‌گیرند و نشان می‌دهند که ابعاد مرتبط با سرمایه‌گذاری در تحقیق و توسعه، حمایت مالی و سطح تحصیلات مدیران نقش مکمل اما مهمی در تفکیک کلاس‌ها دارند. با حرکت به سمت ویژگی‌های انتهایی نمودار، روند نزولی انتخاب‌ها حکایت از آن دارد که برخی متغیرها سهم اندکی در بهبود کارایی مدل داشته‌اند و حضور آن‌ها کمتر ضروری بوده است. این الگو به‌طور کلی نشان می‌دهد که الگوریتم BAOA در ۲۰ تکرار اجرا توانسته مجموعه‌ای نسبتاً پایدار از ویژگی‌های کلیدی را شناسایی کند و در عین حال، تفاوتی روشن میان متغیرهای اثرگذار و کم‌اهمیت ایجاد کند؛ موضوعی که از منظر تحلیل داده و مدل‌سازی، اعتبار انتخاب ویژگی‌ها را تقویت می‌کند. در شکل ۴ نیز نمودار الگوی ویژگی‌های انتخاب شده در مراحل تکرار شبیه‌سازی نشان داده شده است.



شکل ۴. نمودار الگوی ویژگی‌های انتخاب شده در مراحل تکرار

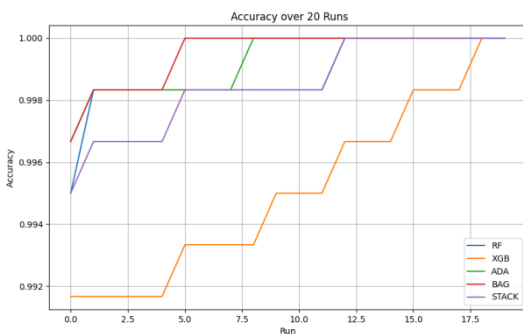
در شکل ۴، نقشه الگوی انتخاب ویژگی‌ها را در ۲۰ اجرای مستقل به‌خوبی ترسیم می‌کند و نشان می‌دهد که میزان پایداری و تکرارپذیری متغیرها در فرآیند جست‌وجوی الگوریتم BAOA تا چه اندازه متفاوت است. همان‌طور که مشاهده می‌شود، برخی ویژگی‌ها مانند «digitaltransindex» تقریباً در تمامی تکرارها حضور دارند و این الگوی انتخاب منسجم بیانگر اهمیت ساختاری آن‌ها در تشخیص سطح تحول دیجیتال است. در مقابل، گروهی از ویژگی‌ها تنها در تعداد محدودی از اجراها ظاهر می‌شوند و این رفتار ناپایدار نشان می‌دهد که نقش آن‌ها در عملکرد مدل چندان اساسی نیست یا تأثیرشان وابسته به شرایط خاص هر جمعیت اولیه است. توزیع پراکنده انتخاب‌ها در برخی ستون‌ها نیز تأیید می‌کند که الگوریتم در فرایند جست‌وجو از انعطاف کافی برای کاوش بخش‌های مختلف فضای ویژگی برخوردار بوده است. در مجموع، این الگو نه‌تنها ثبات نسبی برخی متغیرهای کلیدی را برجسته می‌کند، بلکه تنوع انتخاب در سایر ویژگی‌ها را نیز به‌عنوان نشانه‌ای از توازن مناسب میان کاوش و بهره‌برداری در رفتار الگوریتم آشکار می‌سازد. ویژگی‌های منتخب در هر مرحله تکرار به عنوان ورودی مدل یادگیری جمعی پشته‌ای SE-DML مورد استفاده قرار می‌گیرند. در این مدل، چهار الگوریتم جمعی—جنگل تصادفی، AdaBoost، XGBoost و Bagging—به عنوان طبقه‌بندهای پایه عمل کرده و احتمال تعلق نمونه‌ها به سطوح تحول دیجیتال را تولید می‌کنند. خروجی احتمالاتی این مدل‌ها به لایه متا منتقل شده و یک شبکه عصبی عمیق، با یادگیری روابط غیرخطی میان آن‌ها، پیش‌بینی نهایی را ارائه می‌دهد. چنین ساختاری با تلفیق قدرت روش‌های جمعی و فرایادگیری عمیق، قابلیت استخراج الگوهای پیچیده رفتاری در داده‌های سازمانی را افزایش می‌دهد.

در روش پیشنهادی این مقاله، داده‌های موجود در مجموعه داده تحول دیجیتال ابتدا با استفاده از تقسیم‌بندی تصادفی و stratified sampling به دو بخش آموزشی (۷۰٪) و آزمایشی (۳۰٪) تقسیم شدند تا توزیع کلاس‌ها در هر دو بخش حفظ شود. الگوریتم بهینه‌سازی ارشمیدس باینری (BAOA) در مرحله آموزشی برای انتخاب ویژگی‌های مؤثر در تشخیص سطح تحول دیجیتال به کار رفت و سپس مجموعه ویژگی‌های منتخب برای آموزش مدل‌های طبقه‌بندی مورد استفاده قرار گرفت. در این فرایند، مدل ترکیبی

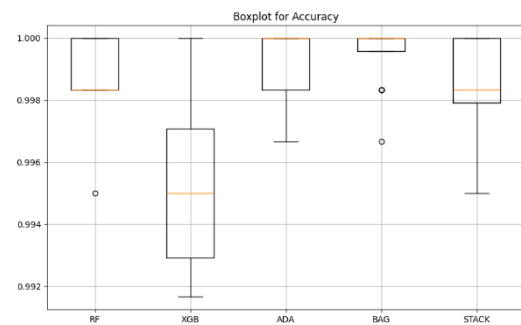
هدایتی و همکاران

BAOA-SE-DML شامل چهار طبقه‌بند پایه—جنگل تصادفی، AdaBoost، XGBoost و Bagging—و یک شبکه عصبی عمیق به‌عنوان لایه متا عمل می‌کند. پس از استخراج الگوهای سطح تحول از داده‌های آموزشی، عملکرد مدل با داده‌های آزمایشی—که ۳۰ درصد از کل داده‌ها را تشکیل می‌دهند و در مراحل یادگیری استفاده نشده‌اند—ارزیابی شد تا توانایی مدل در تعمیم و پیش‌بینی نمونه‌های جدید مورد سنجش قرار گیرد.

در مرحله ارزیابی، همان‌گونه که در ساختار تجربی روش پیشنهادی تشریح شد، از دو دسته معیار شامل معیارهای مبتنی بر برچسب و معیارهای مبتنی بر احتمال برای تحلیل عملکرد مدل استفاده گردید. معیارهای مبتنی بر برچسب مانند دقت، دقت متوازن، حساست، صحت، امتیاز F1، کاپای کوهن و MCC برای ارزیابی صحت پیش‌بینی کلاس‌ها و معیارهای مبتنی بر احتمال شامل Log-Loss، AUROC و AUPRC برای سنجش کیفیت خروجی احتمالاتی مدل‌ها مورد استفاده قرار گرفتند. به‌منظور کاهش تأثیر نوسانات تصادفی و افزایش اعتبار آماری نتایج، فرآیند ارزیابی در ۲۰ اجرای مستقل تکرار شد و میانگین مقادیر معیارها گزارش گردید. در نمودارهای شکل‌های ۵ تا ۱۶، زیرشکل (الف) تغییرات میانگین معیارها در طول اجراها و زیرشکل (ب) نمودار جعبه‌ای مقایسه میانگین کل معیارها میان مدل‌های مورد استفاده را نمایش می‌دهد که برتری مدل پیشنهادی BAOA-SE-DML را نسبت به سایر طبقه‌بندها نشان می‌دهد. همچنین در جدول ۳ مقادیر میانگین کل معیارهای ارزیابی برای مدل‌های پایه و فرایادگیر عمیق را نشان می‌دهد.

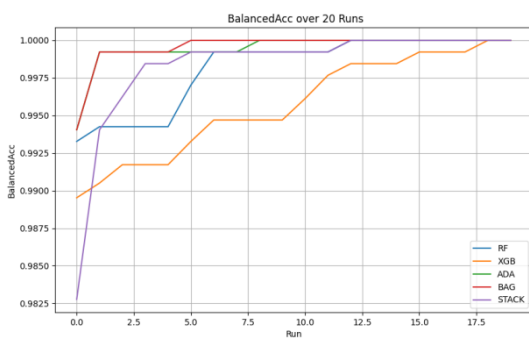


(الف)




(ب)

شکل ۵. میانگین معیار دقت الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

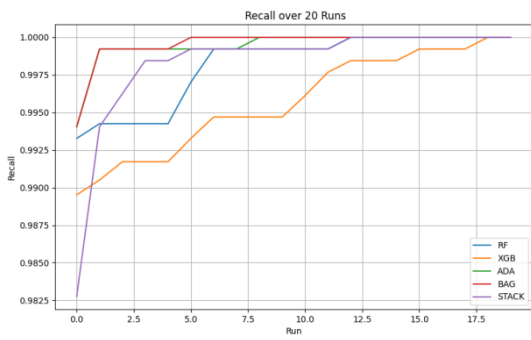


(الف)

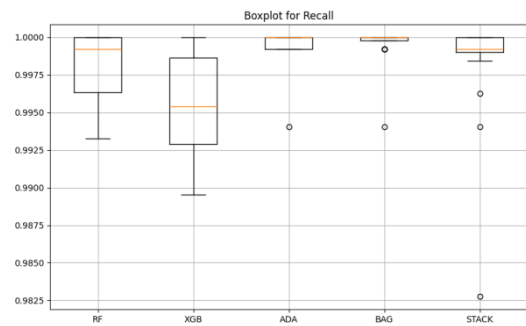


(ب)

شکل ۶. میانگین معیار دقت متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

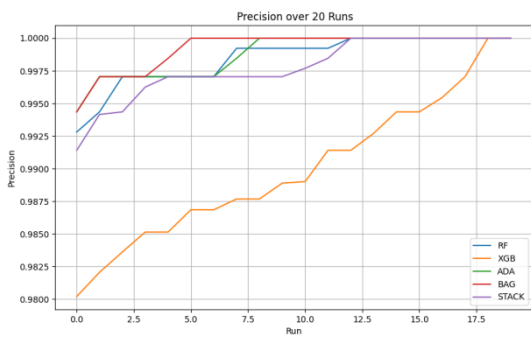


(الف)




(ب)

شکل ۷. میانگین معیار حساسیت متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

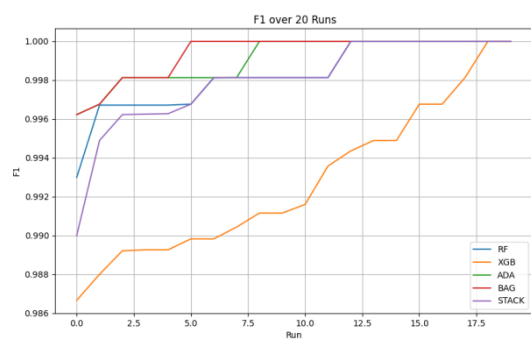


(الف)

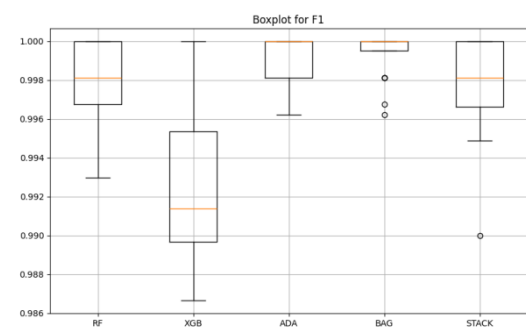


(ب)

شکل ۸. میانگین معیار صحت متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

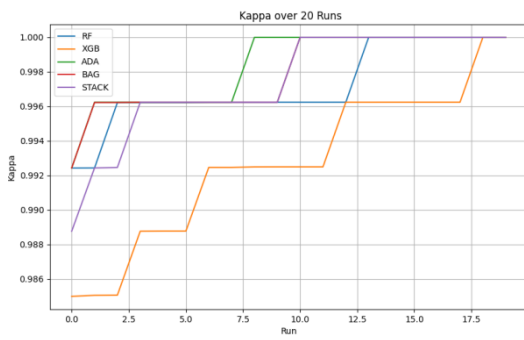


(الف)

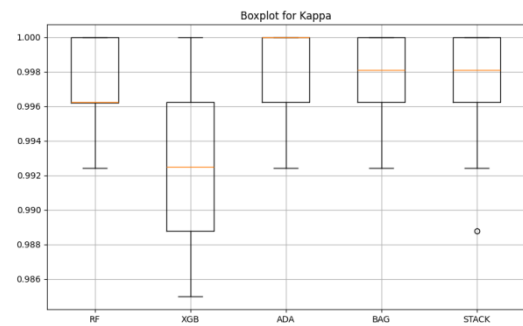


(ب)

شکل ۹. میانگین معیار F متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

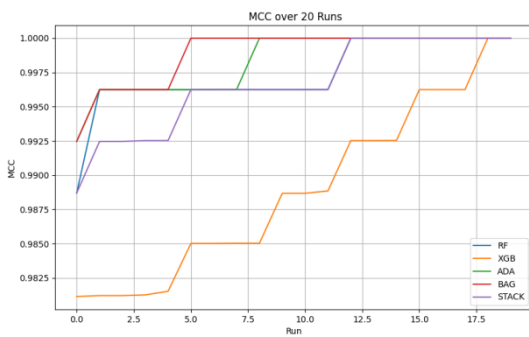


(الف)




(ب)

شکل ۱۰. میانگین معیار کاپا کوهن متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

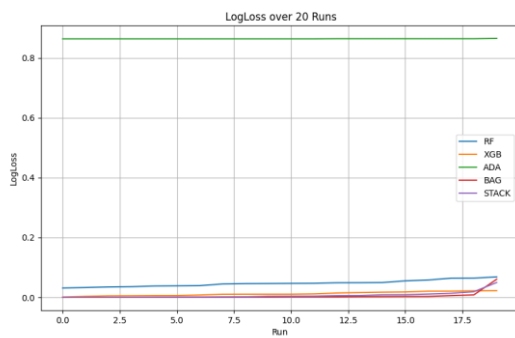


(الف)

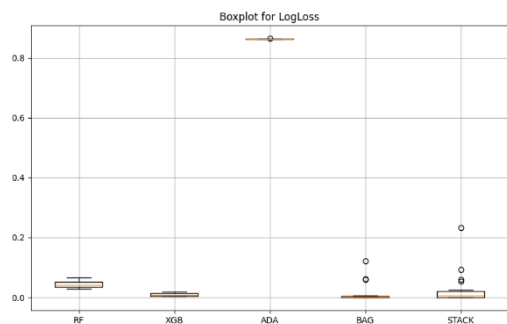


(ب)

شکل ۱۲. میانگین معیار MCC متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

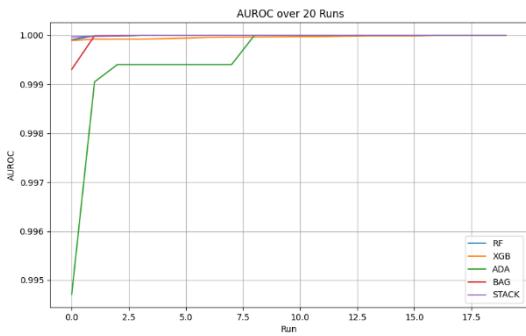


(الف)

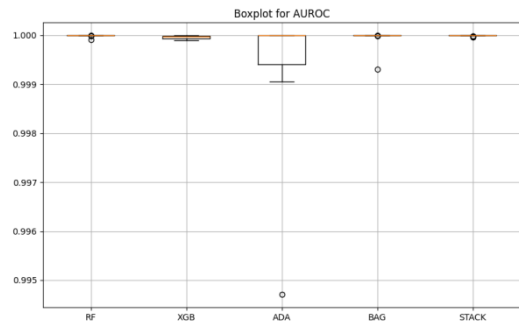


(ب)

شکل ۱۳. میانگین معیار Log Loss متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

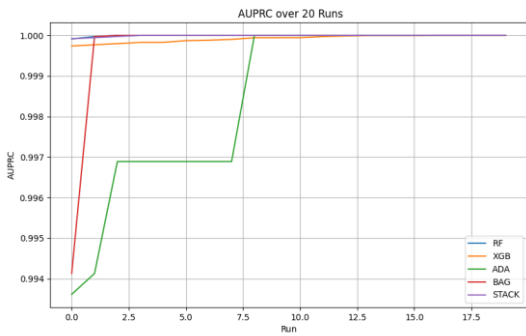


(الف)

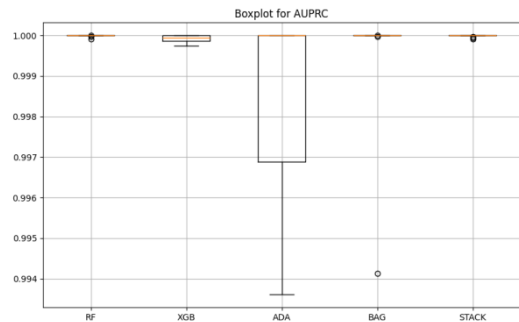


(ب)

شکل ۱۴. میانگین معیار AUROC متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل



(الف)



(ب)

شکل ۱۵. میانگین معیار AUPRC متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

جدول ۳- مقادیر میانگین کل معیار های ارزیابی برای مدل های طبقه بندی

AUPRC	AUROC	LogLoss	MCC	KAPA	F ₁	PRC	REC	Bal_ACC	ACC	Model
۱.۰	۱.۰	۰.۰۴۶۹	۰.۹۹۷۴	۰.۹۹۷۴	۰.۹۹۸۳	۰.۹۹۸۴	۰.۹۹۸۱	۰.۹۹۸۱	۰.۹۹۸۸	RF
۰.۹۹۹۹	۱.۰	۰.۰۱۲	۰.۹۸۸۹	۰.۹۸۸۹	۰.۹۹۲۸	۰.۹۹	۰.۹۹۵۷	۰.۹۹۵۷	۰.۹۹۵۱	XGB
۰.۹۹۸۵	۰.۹۹۹۵	۰.۸۶۴۲	۰.۹۹۸۳	۰.۹۹۸۳	۰.۹۹۹۱	۰.۹۹۸۸	۰.۹۹۹۴	۰.۹۹۹۴	۰.۹۹۹۲	ADA
۰.۹۹۹۷	۱.۰	۰.۰۰۴۸	۰.۹۹۸۹	۰.۹۹۸۹	۰.۹۹۹۴	۰.۹۹۹۲	۰.۹۹۹۵	۰.۹۹۹۵	۰.۹۹۹۵	BAG
۱.۰	۱.۰	۰.۰۰۶۹	۰.۹۹۶۶	۰.۹۹۶۶	۰.۹۹۸	۰.۹۹۷۷	۰.۹۹۸۲	۰.۹۹۸۲	۰.۹۹۸۵	STACK

ارزیابی عملکرد پنج مدل طبقه بندی نشان می دهد که اگرچه تمامی روش ها دقت بالایی را ثبت کرده اند، اما میزان برتری هر مدل بسته به نوع معیار متفاوت است. این تنوع رفتاری، تصویری چندلایه از توانمندی واقعی مدل ها ارائه می دهد و امکان قضاوت دقیق تری درباره قابلیت تعمیم آن ها فراهم می سازد. در ادامه، هر معیار به طور مجزا تحلیل شده است.

مقادیر دقت نشان می دهد که تقریباً تمامی مدل ها عملکردی بسیار بالا دارند و اختلاف آن ها در حد چند ده هزارم است. ADA و BAG کمی بهتر ظاهر شده اند و مقدار دقت آن ها به ترتیب ۰.۹۹۹۲ و ۰.۹۹۹۵ گزارش شده است. RF نیز مقدار ۰.۹۹۸۸ را ثبت کرده که همچنان بسیار نزدیک به سقف عملکردی است. تنها مدلی که اندکی کمتر از سایرین

هدایتی و همکاران

عمل کرده XGB با دقت ۰.۹۹۵۱ است. مدل فرایادگیر عمیق که با عنوان STACK مشخص شده است در رتبه دوم قرار می‌گیرد و مقدار ۰.۹۹۸۵ را ارائه می‌دهد. به‌طور کلی، Accuracy نشان می‌دهد که تفاوت‌ها ناچیز بوده و مسئله برای تمامی مدل‌ها نسبتاً آسان بوده است.

الگوی مشاهده‌شده در دقت متعادل نیز تقریباً مشابه Accuracy است؛ یعنی تمام مدل‌ها توزیع یکنواختی از موفقیت در طبقه‌های مختلف داشته‌اند. بهترین مقدار متعلق به BAG (0.9995) و سپس ADA (0.9994) است. RF و STACK نیز مقدارهای بسیار نزدیکی ارائه کرده‌اند (به ترتیب ۰.۹۹۸۱ و ۰.۹۹۸۲). پایین‌ترین مقدار باز هم مرتبط با XGB است (۰.۹۹۵۷). این روند نشان می‌دهد که مدل‌ها در یادگیری کلاس‌های اقلیت و اکثریت عملکردی تقریباً مشابه دارند.

شاخص حساسیت (Recall) میزان موفقیت مدل‌ها را در تشخیص صحیح نمونه‌های مثبت نشان می‌دهد. در این معیار نیز BAG و ADA با مقدارهای ۰.۹۹۹۵ و ۰.۹۹۹۴ عملکرد تقریباً بی‌نقص دارند. مدل STACK با Recall برابر ۰.۹۹۸۲ در رتبه بعدی قرار می‌گیرد. RF مقدار ۰.۹۹۸۱ را ثبت کرده و XGB با مقدار ۰.۹۹۵۷ باز هم ضعیف‌ترین عملکرد را در مقایسه با سایر مدل‌ها نشان می‌دهد. این داده‌ها بیانگر آن است که مدل‌های قدرتمندتر در تشخیص تمامی نمونه‌های هدف از احتمال خطای بسیار پایینی برخوردار بوده‌اند.

در معیار دقت مثبت (Precision)، مدل BAG با مقدار ۰.۹۹۹۲ و سپس ADA با مقدار ۰.۹۹۸۸ عملکرد برتری دارند. مقدار ثبت‌شده برای RF برابر ۰.۹۹۸۴ است و مدل STACK اندکی کمتر و برابر ۰.۹۹۷۷ عمل کرده است. XGB با مقدار ۰.۹۹۰۰ فاصله قابل‌توجهی نسبت به سایر مدل‌ها دارد. این نتایج نشان می‌دهد که XGB بیش از سایر مدل‌ها نمونه‌های اشتباه را به‌عنوان مثبت پیش‌بینی کرده است.

امتیاز F1، که میانگینی موزون از Precision و Recall است، تصویری کلی از توان مدل‌ها ارائه می‌دهد. BAG با مقدار ۰.۹۹۹۴ و ADA با مقدار ۰.۹۹۹۱ بالاترین عملکرد را نشان می‌دهند. RF نیز مقدار ۰.۹۹۸۳ را ثبت کرده و STACK با مقدار ۰.۹۹۸۰ تنها اندکی پایین‌تر قرار دارد. XGB با مقدار ۰.۹۹۲۸ بیشترین افت را در این معیار تجربه می‌کند. مشاهده این روند نشان می‌دهد که F1 نیز مشابه سایر شاخص‌ها، برتری واضح BAG و ADA و همچنین ضعف نسبی XGB را تأیید می‌کند.

معیار کاپا کیفیت طبقه‌بندی را با در نظر گرفتن شانس ارزیابی می‌کند. BAG در این شاخص مقدار ۰.۹۹۸۹ را کسب کرده و ADA و RF نیز مقدار مشابه ۰.۹۹۸۳ و ۰.۹۹۷۴ را ثبت کرده‌اند. STACK کمی پایین‌تر و با مقدار ۰.۹۹۶۶ عمل می‌کند، در حالی که XGB با مقدار ۰.۹۸۸۹ اختلاف قابل‌توجهی با بقیه دارد. کاپا یک شاخص حساس‌تر از دقت است و نتایج آن نشان می‌دهد که مدل‌های برتر حتی زمانی که اثر تصادفی بودن حذف می‌شود، همچنان عملکرد بسیار بالایی دارند.

ضریب MCC نیز تصویر مشابهی ارائه می‌دهد. بهترین عملکرد متعلق به BAG (0.9989) و پس از آن ADA (0.9983) است. RF دارای مقداری برابر ۰.۹۹۷۴ بوده و STACK مقدار ۰.۹۹۶۶ را ثبت کرده است. XGB با مقدار ۰.۹۸۸۹ بار دیگر پایین‌ترین عملکرد را ارائه داده است. از آنجا که MCC معیار سخت‌گیرانه‌تری محسوب می‌شود، برتری مدل‌های قوی‌تر در این بخش ارزش بیشتری پیدا می‌کند.

این معیار که بر پایه احتمال درست بودن پیش‌بینی‌ها است، شکاف روشنی میان مدل‌ها ایجاد می‌کند. BAG با مقدار بسیار کوچک ۰.۰۰۴۸ بهترین عملکرد را دارد. XGB با مقدار ۰.۰۱۲ عملکرد قابل‌قبولی ارائه کرده است. STACK و RF با مقدارهای ۰.۰۰۶۹ و ۰.۰۴۶۹ در رتبه‌های بعدی قرار می‌گیرند. ADA با مقدار نسبتاً بالای ۰.۸۶۴۲ نشان می‌دهد که اگرچه در معیارهای طبقه‌بندی مستقیم بسیار موفق بوده، اما خروجی‌های احتمالاتی آن از ثبات کافی برخوردار نیستند.

در این معیار تقریباً تمامی مدل‌ها عملکرد کاملی دارند. RF، XGB، BAG و STACK همگی مقدار ۱.۰ را ثبت کرده‌اند. تنها مدل ADA مقدار اندکی پایین‌تر (۰.۹۹۹۵) دارد که از نظر عملی قابل چشم‌پوشی است. این نتایج بیانگر توان کلیه مدل‌ها در جداسازی مؤثر کلاس‌ها است.


رفتار مدل‌ها در این معیار نیز تقریباً مشابه AUROC است. RF، BAG و STACK مقدار کامل ۱.۰ را نشان می‌دهند. XGB مقدار ۰.۹۹۹۹ و ADA مقدار ۰.۹۹۸۵ را ثبت کرده‌اند. این نتایج به‌وضوح نشان می‌دهد که حتی در شرایطی که کلاس مثبت نادر باشد، مدل‌ها دقت و توان تفکیک بالایی دارند.

بر مبنای تمامی معیارها، مدل BAG پایدارترین و قوی‌ترین عملکرد را ارائه کرده و در بخش قابل‌توجهی از شاخص‌ها در رتبه اول قرار گرفته است. مدل ADA نیز بسیار نزدیک به آن عمل می‌کند، هرچند در معیار LogLoss ضعف مشخصی دارد. مدل STACK عملکردی بسیار رقابتی دارد و در شاخص‌های کلیدی مانند F1، AUROC و AUPRC

سطحی نزدیک به مدل‌های برتر نشان می‌دهد. RF رفتار نسبتاً ثابتی دارد اما کم‌اثرتر از مدل‌های یادشده ظاهر شده است. در مقابل، XGB در اغلب شاخص‌ها پایین‌ترین مقدار را در میان پنج مدل ثبت کرده و اگرچه عملکرد آن همچنان بالا است، اما در مقایسه مستقیم با سایر مدل‌ها ضعف نسبی بیشتری دارد.

این تحلیل نشان می‌دهد که مسئله مورد بررسی برای اکثر مدل‌ها ساده بوده، اما تفاوت‌های ظریف میان روش‌ها می‌تواند برای انتخاب نهایی مدل، بسته به نیاز عملی و وزن‌دهی به معیارهای مختلف، تعیین‌کننده باشد.

پس از پیاده‌سازی و ارزیابی روش پیشنهادی در راستای پیش‌بینی سطح تغییرات مورد نیاز در فرایند تحول دیجیتال، حال به منظور اعتبار سنجی نتایج نیاز به مقایسه نتایج روش پیشنهادی با روش‌های پیشین داریم. یکی از مهم‌ترین فاکتورهایی که به منظور مقایسه می‌توان از آن استفاده کرد، معیار دقت است. معیار دقت در واقع معیار جامعی است که بیشتر روش‌های پیش‌بینی تحول دیجیتال از آن بهره می‌برند. از این رو در این بخش دقت مدل‌های مورد استفاده در روش پیشنهادی را با سایر روش‌های پیشین، مقایسه می‌کنیم که در شکل ۱۶ قابل مشاهده است.



شکل ۱۶. مقایسه روش پیشنهادی با روش‌های پیشین از نظر معیار دقت

همان‌طور که در شکل ۱۶ مشاهده می‌شود، می‌توان مشاهده کرد که مدل‌های سنتی یادگیری ماشین که در مطالعات پیشین گزارش شده‌اند، از جمله SVM با هسته‌های مختلف، KNN و همچنین مدل‌های لجستیک، شبکه عصبی چندلایه و گرادایان بوستینگ، همگی عملکردی نسبتاً متوسط داشته و دقت آن‌ها عمدتاً در بازه ۶۳ تا ۷۸ درصد قرار گرفته است. این مقادیر نشان می‌دهد که این مدل‌ها در مواجهه با ماهیت پیچیده و چندبعدی داده‌های نوآوری دیجیتال، توانایی محدودی در استخراج الگوهای عمیق داشته‌اند. در مقابل، مدل‌های ترکیب‌شده با الگوریتم پیشنهادی BAOA چشمگیری چشمگیر را در دقت تجربه کرده‌اند، به گونه‌ای که حتی ضعیف‌ترین آن‌ها، یعنی BAOA-XGB، با دقت ۹۹.۵۱ درصد عملکردی بسیار فراتر از روش‌های کلاسیک نشان می‌دهد. سایر مدل‌ها نیز مانند BAOA-ADA و BAOA-BAG با مقادیر ۹۹.۹۵ و ۹۹.۹۲ درصد تقریباً به سطح بی‌نقص رسیده‌اند. در نهایت، مدل پیشنهادی BAOA-SE-DML با دقت ۹۹.۸۵ درصد نشان می‌دهد که ترکیب بهینه‌سازی مبتنی بر فراابتکاری با یادگیری عمیق و ساختارهای چندلایه‌ای، به طور مؤثری محدودیت‌های مدل‌های کلاسیک را برطرف کرده و توان پیش‌بینی را به سطحی رسانده که تقریباً تمام پیچیدگی‌های مسئله را به درستی بازتاب می‌دهد. این تفاوت چشمگیر بیانگر اهمیت ترکیب روش‌های انتخاب و ویژگی هوشمند با معماری‌های یادگیری عمیق در مسائل طبقه‌بندی پیچیده است.

به منظور ارتقای فهم عمیق تر از سازوکار درونی روش پیشنهادی BAOA-SE-DML و دستیابی به تصویری روشن تر از چرایی عملکرد برتر آن نسبت به مدل های مرسوم، یک لایه تحلیل تفسیرپذیر بر خروجی سیستم ترکیبی اعمال شد. هدف از این مرحله، نه فقط سنجش میزان دقت مدل، بلکه تبیین نحوه تصمیم گیری آن و مشخص کردن عواملی است که بیشترین نقش را در تمایز میان سطوح مختلف تحول دیجیتال ایفا می کنند. چنین تحلیلی به کاربران نهایی کمک می کند تا مدل پیشنهادی را صرفاً به عنوان یک «جعبه سیاه با دقت بالا» نبینند، بلکه آن را ابزاری شفاف، قابل استناد و ارزشمند برای تصمیم سازی سازمانی تلقی کنند.

در گام نخست، الگوی انتخاب ویژگی ها که از طریق ۲۰ اجرای مستقل الگوریتم BAOA استخراج شد، به عنوان شاخصی برای سنجش اهمیت نسبی متغیرها مورد استفاده قرار گرفت. بررسی فراوانی انتخاب ویژگی ها نشان داد که برخی عوامل سازمانی با احتمال قابل توجهی در اغلب تکرارها انتخاب شده اند و بنابراین نقش محوری تری در پیش بینی مدل دارند. متغیرهایی مانند بلوغ فناوری سازمان، سطح مهارت های دیجیتال نیروی انسانی، کیفیت زیرساخت های اطلاعاتی، میزان داده محوری فرآیندهای داخلی و درجه یکپارچگی سیستم های سازمانی به طور پیوسته در میان مهم ترین ویژگی ها ظاهر شده اند. این روند نشان می دهد که مدل پیشنهادی برای تمایز میان سازمان های با تحول دیجیتال پایین، متوسط و بالا، بیش از هر چیز بر شاخص هایی تکیه می کند که منشأ ساختاری و زیرساختی دارند و کمتر تحت تأثیر عوامل گذرا یا بیرونی قرار می گیرند.

در گام دوم، رفتار مدل در مرحله تصمیم گیری توسط لایه متا، یعنی شبکه عصبی عمیق، مورد بررسی تفسیری قرار گرفت. ورودی این لایه که شامل احتمال پیش بینی شده توسط چهار مدل پایه (RF، XGB، ADA و BAG) است، امکان تحلیل حساسیت مدل نسبت به تغییرات خروجی طبقه بندی کننده های پایه را فراهم کرد. نتایج نشان داد که لایه متا معمولاً وزن بیشتری به خروجی هایی می دهد که همگرایی و ثبات بیشتری دارند؛ به عنوان مثال، مدل های ADA و BAG که در اغلب معیارهای ارزیابی عملکرد برتری نسبی داشته اند، تأثیر بیشتری بر تصمیم نهایی شبکه متا گذاشته اند. این یافته نشان می دهد که ساختار SE-DML نه تنها رأی مدل ها را تجمیع می کند، بلکه به طور هوشمندانه بر خروجی های پایدارتر تکیه می کند و بدین ترتیب پایداری و قابلیت تعمیم مدل افزایش می یابد.

در نهایت، افزودن لایه تفسیرپذیری موجب شده است که روش BAOA-SE-DML صرفاً یک ابزار پیش بینی با عملکرد بالا نباشد، بلکه به ابزاری استراتژیک برای تحلیل وضعیت تحول دیجیتال سازمان ها تبدیل شود. تفسیر روشن این که کدام ویژگی ها بیشترین اثر را در تشخیص سطح بلوغ دیجیتال دارند، به مدیران کمک می کند تا نقاط ضعف کلیدی را شناسایی کرده و برنامه های توسعه دیجیتال را بر اساس شواهد داده محور تنظیم کنند. بدین ترتیب، روش پیشنهادی علاوه بر ارائه دقت بالا، قابلیت استفاده عملی را نیز ارتقا می دهد و پیوندی میان یادگیری عمیق، بهینه سازی فرآینکاری و تحلیل سازمانی برقرار می کند؛ پیوندی که می تواند مسیر تحول دیجیتال را برای سازمان ها شفاف تر و هدفمندتر سازد.

بحث و نتیجه گیری

یافته های این پژوهش نشان داد که چارچوب پیشنهادی مبتنی بر انتخاب ویژگی با الگوریتم بهینه سازی ارشمیدس باینری و یادگیری جمعی پشته ای همراه با فرایادگیری عمیق، توانست عملکرد بسیار بالایی در پیش بینی سطح تغییرات تحول دیجیتال سازمان ها ارائه دهد. نتایج بیانگر آن بود که مدل های ترکیبی، به ویژه ساختار مبتنی بر Bagging و مدل STACK، در اغلب معیارهای ارزیابی شامل Accuracy، Balanced Accuracy، Recall، Precision، F1-score، Kappa، MCC، AUROC و AUPRC، عملکردی نزدیک به حالت ایده آل داشتند و میزان خطای آن ها نیز بسیار پایین بود. این یافته نشان می دهد که ترکیب انتخاب ویژگی هوشمند با معماری های یادگیری عمیق و مدل های جمعی، می تواند به استخراج الگوهای پیچیده و چندبعدی مرتبط با تحول دیجیتال منجر شود. برتری مدل های ترکیبی در این پژوهش با مطالعاتی که بر نقش یادگیری ماشین و هوش مصنوعی در بهبود عملکرد سازمانی در عصر تحول دیجیتال تأکید کرده اند همسو است (Davenport & Mittal, 2022; Mikalef et al., 2022). همچنین نتایج حاضر با پژوهش هایی که نشان داده اند معماری های یادگیری پشته ای می توانند نسبت به مدل های منفرد دقت بالاتری ایجاد کنند، هم راستا است (Zhang et al., 2022). دلیل این موضوع آن است که هر مدل پایه بخشی متفاوت از ساختار داده را یاد می گیرد و مدل فرایادگیر قادر است روابط غیرخطی میان خروجی آن ها را به صورت مؤثرتری ترکیب کند.

یکی از مهم‌ترین یافته‌های پژوهش، موفقیت الگوریتم BAOA در انتخاب زیرمجموعه‌ای پایدار و مؤثر از ویژگی‌های تحول دیجیتال بود. نمودارهای همگرایی نشان دادند که الگوریتم در تعداد نسبتاً کمی از تکرارها به ناحیه‌ای پایدار از تابع برازش رسید و از نوسانات شدید جلوگیری کرد. این موضوع بیانگر تعادل مناسب میان کاوش و بهره‌برداری در فرآیند جست‌وجوی الگوریتم است. یافته حاضر با نتایج Hashim و همکاران درباره توان الگوریتم ارشمیدس در جست‌وجوی مؤثر فضای راه‌حل همخوانی دارد (Hashim et al., 2021). همچنین مطالعات مرتبط با انتخاب ویژگی مبتنی بر فراابتکاری نشان داده‌اند که روش‌های بهینه‌سازی جمعیتی در مقایسه با روش‌های سنتی فیلتر یا انتخاب دستی، توان بیشتری در شناسایی ویژگی‌های اثرگذار دارند (Got et al., 2024; Hassan et al., 2022). در پژوهش حاضر نیز ویژگی‌هایی مانند digitaltransindex، شدت تحقیق و توسعه و حمایت مالی بیشترین فراوانی انتخاب را داشتند که نشان می‌دهد شاخص‌های مرتبط با سرمایه‌گذاری فناورانه و بلوغ دیجیتال نقش اساسی در تعیین سطح تحول سازمان‌ها ایفا می‌کنند.

نتایج پژوهش همچنین نشان داد که استفاده از انتخاب ویژگی پیش از مرحله یادگیری، موجب کاهش پیچیدگی داده‌ها و افزایش پایداری مدل شده است. این یافته از منظر نظری اهمیت زیادی دارد؛ زیرا یکی از چالش‌های اصلی در تحلیل تحول دیجیتال، وجود متغیرهای متعدد و همبسته است که می‌تواند باعث بیش‌برازش مدل شوند. مطالعات گذشته نیز بر این موضوع تأکید کرده‌اند که انتخاب ویژگی، به‌ویژه در داده‌های ابعاد بالا، نقش کلیدی در افزایش دقت و کاهش نویز دارد (Mercedi & Abdulazeez, 2025). افزون بر این، پژوهش‌های انجام‌شده در حوزه داده‌های زیستی و بیان ژن نشان داده‌اند که وجود ویژگی‌های زائد می‌تواند باعث سوگیری و ناپایداری در مدل‌های یادگیری شود (Grisci et al., 2024). بنابراین، موفقیت الگوریتم BAOA در حذف ویژگی‌های غیرضروری و تمرکز بر شاخص‌های کلیدی، یکی از عوامل اصلی عملکرد بالای چارچوب پیشنهادی محسوب می‌شود.

یافته‌های این پژوهش نشان داد که مدل‌های مبتنی بر یادگیری جمعی، به‌ویژه Bagging و Random Forest، عملکرد بسیار مناسبی در تشخیص سطوح تحول دیجیتال داشتند. این نتیجه با منطق نظری یادگیری جمعی سازگار است؛ زیرا چنین مدل‌هایی از طریق ترکیب چندین یادگیرنده و کاهش واریانس، پایداری پیش‌بینی را افزایش می‌دهند. مطالعات پیشین نیز نشان داده‌اند که Bagging و Random Forest در مسائل پیچیده طبقه‌بندی، به دلیل مقاومت در برابر نویز و قابلیت تعمیم بالا، عملکرد مطلوبی ارائه می‌کنند (Paul et al., 2024). همچنین پژوهش Budholiya و همکاران نشان داده است که XGBoost به دلیل ساختار منظم‌سازی و یادگیری تدریجی، توان بالایی در مسائل پیش‌بینی دارد (Budholiya et al., 2022). اگرچه در پژوهش حاضر XGBoost نسبت به سایر مدل‌ها عملکرد ضعیف‌تری داشت، اما همچنان دقت بالایی ثبت کرد. این موضوع احتمالاً ناشی از تفاوت ماهیت داده‌های تحول دیجیتال با داده‌های ساختاریافته سنتی است؛ به‌گونه‌ای که مدل‌های مبتنی بر تجمیع و نمونه‌گیری مجدد توانسته‌اند بهتر با پراکندگی و تنوع الگوهای سازمانی سازگار شوند.

یکی دیگر از یافته‌های مهم، عملکرد بسیار مطلوب مدل فرایادگیر عمیق در ترکیب خروجی مدل‌های پایه بود. شبکه عصبی چندلایه توانست روابط غیرخطی میان پیش‌بینی‌های احتمالاتی مدل‌های پایه را یاد بگیرد و ترکیبی پایدار و دقیق از آن‌ها ایجاد کند. این یافته با مطالعات مربوط به یادگیری پشته‌ای عمیق همسو است که نشان می‌دهند استفاده از شبکه‌های عصبی در لایه متا می‌تواند دقت طبقه‌بندی را نسبت به ترکیب‌های خطی افزایش دهد (Zhang et al., 2022). همچنین نتایج حاضر با پژوهش‌های مرتبط با شبکه‌های عصبی و استخراج ویژگی‌های عمیق در مسائل تشخیص ناهنجاری و طبقه‌بندی سازگار است (Einy et al., 2022; Einy et al., 2023). علت این موضوع آن است که شبکه عصبی عمیق قادر است تعاملات پنهان میان پیش‌بینی‌های مدل‌های پایه را شناسایی کند؛ تعاملاتی که در روش‌های سنتی ترکیب مدل‌ها قابل آشکارسازی نیستند. در بخش دیگری از نتایج، معیارهای مبتنی بر احتمال مانند AUROC، AUPRC و Log-Loss نشان دادند که مدل پیشنهادی نه‌تنها برچسب کلاس‌ها را به‌درستی پیش‌بینی می‌کند، بلکه احتمال‌های تولیدشده نیز از کیفیت بالایی برخوردارند. اهمیت این یافته در آن است که در تصمیم‌گیری‌های مدیریتی، میزان اطمینان مدل به پیش‌بینی‌ها نیز اهمیت دارد و صرفاً طبقه‌بندی نهایی کافی نیست. مطالعات مربوط به تحلیل منحنی ROC و معیارهای مبتنی بر احتمال نیز تأکید کرده‌اند که AUPRC و AUROC می‌توانند تصویری دقیق‌تر از عملکرد مدل در شرایط چندکلاس و نامتوازن ارائه دهند (Corbacioglu & Aksel, 2023). همچنین استفاده از تابع Cross-Entropy برای آموزش شبکه عصبی

موجب شده است که مدل بتواند احتمال‌های پیش‌بینی‌شده را به شکل بهینه‌تری تنظیم کند (Mao et al., 2023). این موضوع نشان می‌دهد که چارچوب پیشنهادی نه‌تنها از منظر طبقه‌بندی، بلکه از منظر کالیبراسیون احتمال نیز عملکرد مطلوبی دارد.

از منظر کاربردی، یافته‌های پژوهش نشان می‌دهد که تحلیل داده‌محور تحول دیجیتال می‌تواند به مدیران در تصمیم‌گیری‌های راهبردی کمک کند. پژوهش‌های اخیر تأکید کرده‌اند که تحول دیجیتال موفق نیازمند هم‌راستایی فناوری، منابع انسانی، ساختار سازمانی و راهبرد مدیریتی است (Elia et al., 2024; Vial, 2021). نتایج حاضر نیز نشان داد که متغیرهای مرتبط با سرمایه‌گذاری فناوری، سطح دانش مدیریتی، زیرساخت و حمایت مالی نقش کلیدی در پیش‌بینی سطح تحول دارند. این یافته با مطالعاتی که نقش مدیریت عالی و سرمایه‌گذاری فناوری را در موفقیت تحول دیجیتال برجسته کرده‌اند همسو است (Kim & Kim, 2022; Zhang et al., 2023). همچنین مطالعات حوزه منابع انسانی دیجیتال نشان داده‌اند که بلوغ دیجیتال سازمان‌ها بدون تحول در ساختارهای مدیریتی و سرمایه انسانی امکان‌پذیر نیست (Zhang & Chen, 2024). بنابراین، نتایج پژوهش حاضر می‌تواند به سازمان‌ها کمک کند تا مهم‌ترین شاخص‌های اثرگذار بر تحول دیجیتال را شناسایی کرده و اولویت‌های سرمایه‌گذاری خود را بر اساس داده‌های واقعی تنظیم کنند.

نتایج پژوهش حاضر همچنین از منظر نظری، اهمیت هوش مصنوعی را در مسیر تحول دیجیتال تأیید می‌کند. پژوهش‌های جدید نشان داده‌اند که هوش مصنوعی می‌تواند به‌عنوان یک توانمندساز راهبردی در تحول دیجیتال عمل کند و فرآیندهای سازمانی را بازطراحی نماید (Perifanis & Kitsios, 2023). همچنین در مطالعات مرتبط با نوآوری مبتنی بر AI تأکید شده است که سازمان‌ها از طریق تحلیل هوشمند داده‌ها می‌توانند بهره‌وری، سرعت تصمیم‌گیری و کیفیت خدمات را افزایش دهند (Aldoseri et al., 2024). پژوهش حاضر نیز نشان داد که ترکیب مدل‌های یادگیری ماشین و یادگیری عمیق قادر است الگوهای تحول دیجیتال را با دقت بسیار بالایی شناسایی کند. این یافته‌ها با مطالعاتی که تحول دیجیتال را به‌عنوان فرآیندی مبتنی بر داده، هوش مصنوعی و یادگیری سازمانی تعریف کرده‌اند همسو است (Kitsios & Kamariotou, 2021; Kraus et al., 2022).

در سطح کلان‌تر، یافته‌های پژوهش نشان می‌دهد که تحول دیجیتال را باید یک فرآیند سیستماتیک و چندلایه دانست که تحت تأثیر تعامل میان فناوری، داده، ساختار سازمانی و ظرفیت تحلیلی قرار دارد. پژوهش‌های مربوط به روندهای تحول دیجیتال نیز تأکید کرده‌اند که سازمان‌های آینده برای بقا در محیط رقابتی ناگزیر به استفاده از فناوری‌های هوشمند خواهند بود (Guarda et al., 2021). همچنین مطالعات میان‌رشته‌ای تحول دیجیتال نشان داده‌اند که این پدیده نه‌تنها بر کسب‌وکار، بلکه بر آموزش، مدیریت دانش، زنجیره تأمین و حتی پایداری سازمانی اثرگذار است (Klopov et al., 2023; Shehadeh, 2024). یافته‌های پژوهش حاضر این دیدگاه را تقویت می‌کند که تحلیل تحول دیجیتال باید بر پایه مدل‌های ترکیبی و داده‌محور انجام شود تا بتواند پیچیدگی و پویایی محیط‌های سازمانی را به‌درستی منعکس کند.

از سوی دیگر، کاربرد مجموعه‌داده استاندارد تحول دیجیتال شرکتی در این پژوهش امکان مقایسه و بازتولید نتایج را فراهم کرد (colabsss, 2025). استفاده از داده‌های استاندارد یکی از نقاط قوت پژوهش محسوب می‌شود؛ زیرا امکان ارزیابی مدل در شرایط مشابه را برای پژوهشگران دیگر فراهم می‌کند. علاوه بر این، استفاده از چندین اجرای مستقل و گزارش میانگین معیارها موجب شد نتایج از پایداری بیشتری برخوردار باشند. این رویکرد با توصیه‌های پژوهش‌های حوزه یادگیری ماشین مبنی بر ارزیابی مدل‌ها در چند اجرای مستقل همسو است (Naidu et al., 2023). همچنین استفاده از معیارهایی مانند MCC و Kappa موجب شد ارزیابی عملکرد مدل صرفاً به Accuracy محدود نشود و توافق واقعی مدل با داده‌ها بررسی شود (Rau & Shih, 2021). در مجموع، یافته‌های پژوهش حاضر نشان می‌دهد که ترکیب انتخاب ویژگی فراابتکاری و یادگیری جمعی پشته‌ای می‌تواند به‌عنوان یک چارچوب قدرتمند برای تحلیل و پیش‌بینی سطح تحول دیجیتال سازمان‌ها مورد استفاده قرار گیرد.

یکی از محدودیت‌های پژوهش حاضر، استفاده از یک مجموعه‌داده استاندارد واحد بود که اگرچه امکان ارزیابی کنترل‌شده مدل را فراهم کرد، اما ممکن است تمامی ابعاد تحول دیجیتال در صنایع و کشورهای مختلف را پوشش ندهد. همچنین متغیرهای مورد استفاده عمدتاً کمی و ساختاریافته بودند و عوامل کیفی مانند فرهنگ سازمانی، سبک رهبری، مقاومت کارکنان و بلوغ فرهنگی دیجیتال در مدل لحاظ نشدند. از سوی دیگر، اگرچه مدل پیشنهادی عملکرد بسیار بالایی نشان داد، اما افزایش پیچیدگی مدل و استفاده از چندین

لایه یادگیری می‌تواند هزینه محاسباتی و زمان آموزش را افزایش دهد. علاوه بر این، پژوهش حاضر بر داده‌های ایستا تمرکز داشت و تغییرات زمانی و پویایی تحول دیجیتال در طول دوره‌های مختلف مورد بررسی قرار نگرفت.

پیشنهاد می‌شود در پژوهش‌های آینده، مدل پیشنهادی بر روی مجموعه‌داده‌های واقعی سازمانی در صنایع مختلف آزمایش شود تا قابلیت تعمیم آن در محیط‌های متنوع ارزیابی گردد. همچنین می‌توان از داده‌های زمانی و سری‌های زمانی سازمانی استفاده کرد تا روند تحول دیجیتال در طول زمان مدل‌سازی شود. به‌کارگیری روش‌های یادگیری گراف، شبکه‌های عصبی توجه‌محور و مدل‌های مولد نیز می‌تواند مسیرهای جدیدی برای افزایش دقت پیش‌بینی فراهم کند. علاوه بر این، بررسی ترکیب شاخص‌های کمی و کیفی، استفاده از داده‌های متنی سازمانی و تحلیل احساسات مدیران و کارکنان می‌تواند دیدگاه جامع‌تری درباره تحول دیجیتال ارائه دهد. پیشنهاد دیگر، مقایسه الگوریتم BAOA با سایر الگوریتم‌های فراابتکاری جدید در شرایط یکسان است تا نقاط قوت و ضعف هر روش به‌صورت دقیق‌تر مشخص شود.

از منظر کاربردی، نتایج این پژوهش می‌تواند برای مدیران، سیاست‌گذاران و مشاوران تحول دیجیتال سودمند باشد. سازمان‌ها می‌توانند از مدل پیشنهادی برای ارزیابی سطح آمادگی دیجیتال، شناسایی شاخص‌های کلیدی تحول و پیش‌بینی میزان تغییرات موردنیاز استفاده کنند. همچنین مدیران قادر خواهند بود منابع مالی و فناورانه را بر اساس مهم‌ترین عوامل اثرگذار تخصیص دهند و ریسک شکست پروژه‌های تحول دیجیتال را کاهش دهند. استفاده از چنین مدل‌هایی در سامانه‌های تصمیم‌یار مدیریتی می‌تواند به افزایش دقت تصمیم‌گیری، بهبود برنامه‌ریزی راهبردی و ارتقای مزیت رقابتی سازمان‌ها کمک کند. علاوه بر این، نتایج پژوهش می‌تواند مبنایی برای طراحی سیاست‌های کلان تحول دیجیتال در صنایع مختلف و توسعه زیرساخت‌های مبتنی بر هوش مصنوعی و تحلیل داده باشد.

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

تشکر و قدردانی

از تمامی کسانی که در طی مراحل این پژوهش به ما یاری رساندند تشکر و قدردانی می‌گردد.

تعارض منافع

در انجام مطالعه حاضر، هیچ‌گونه تضاد منافی وجود ندارد.

حمایت مالی

این پژوهش حامی مالی نداشته است.

موازین اخلاقی

در انجام این پژوهش تمامی موازین و اصول اخلاقی رعایت گردیده است.

References

Agrawal, P., Kaur, G., Gupta, V., Agarwal, K., Pinjarkar, L., & Patil, S. (2025). AI Applications in Analyzing Gene Expression for Cancer Diagnosis: A Comprehensive Review. In *Genomics at the Nexus of AI, Computer Vision, and Machine Learning* (pp. 285-307).

- Ahmad, M. F., Husin, N. A. A., Ahmad, A. N. A., Abdullah, H., Wei, C. S., & Nawli, M. (2022). Digital Transformation: Exploring Barriers and Challenges in the Practice of Artificial Intelligence in Manufacturing Firms in Malaysia. *Journal of Advanced Research in Applied Sciences and Engineering Technology*.
- Aldoseri, A., Al-Khalifa, K. N., & Hamouda, A. M. (2024). AI-Powered Innovation in Digital Transformation: Key Pillars and Industry Impact. *Sustainability*, 16(5), 1790.
- Budholiya, K., Shrivastava, S. K., & Sharma, V. (2022). An Optimized XGBoost Based Diagnostic System for Effective Prediction of Heart Disease. *Journal of King Saud University - Computer and Information Sciences*, 34(7), 4514-4523.
- Chen, W., Zhang, L., Jiang, P., Meng, F., & Sun, Q. (2022). Can Digital Transformation Improve the Information Environment of the Capital Market? Evidence from the Analysts' Prediction Behaviour. *Accounting & Finance*, 62(2), 2543-2578.
- colabss. (2025). *Corporate Digital Transformation Dataset* Kaggle. <https://www.kaggle.com/datasets/colabsss/corporate-digital-transformation-dataset>
- Corbacioglu, S. K., & Aksel, G. (2023). Receiver Operating Characteristic Curve Analysis in Diagnostic Accuracy Studies: A Guide to Interpreting the Area Under the Curve Value. *Turkish Journal of Emergency Medicine*, 23(4), 195-198.
- Davenport, T., & Mittal, N. (2022). AI-Driven Digital Transformation: A Review and Research Agenda. *Business & Information Systems Engineering*, 64(4). <https://doi.org/10.1007/s12599-021-00742-2>
- Einy, S., Oz, C., & Navaei, Y. D. (2021). Network Intrusion Detection System Based on the Combination of Multiobjective Particle Swarm Algorithm-Based Feature Selection and Fast-Learning Network. *Wireless Communications and Mobile Computing*, 2021(1), 6648351.
- Einy, S., Saygin, H., Hivehch, H., & Dorostkar Navaei, Y. (2022). Local and Deep Features Based Convolutional Neural Network Frameworks for Brain MRI Anomaly Detection. *Complexity*, 2022(1), 3081748.
- Einy, S., Sen, E., Saygin, H., Hivehchi, H., & Dorostkar Navaei, Y. (2023). Local Binary Convolutional Neural Networks' Long Short-Term Memory Model for Human Embryos' Anomaly Detection. *Scientific Programming*, 2023(1), 2426601.
- Elia, G., Solazzo, G., Lerro, A., Pigni, F., & Tucci, C. L. (2024). The Digital Transformation Canvas: A Conceptual Framework for Leading the Digital Transformation Process. *Business Horizons*, 67(4), 381-398.
- Golab-Andrzejak, E. (2023). AI-Powered Digital Transformation: Tools, Benefits and Challenges for Marketers - Case Study of LPP. *Procedia Computer Science*, 219, 397-404.
- Got, A., Zouache, D., Moussaoui, A., Abualigah, L., & Alsayat, A. (2024). Improved Manta Ray Foraging Optimizer-Based SVM for Feature Selection Problems: A Medical Case Study. *Journal of Bionic Engineering*, 21(1), 409-425.
- Grisci, B. I., Feltes, B. C., de Faria Poloni, J., Narloch, P. H., & Dorn, M. (2024). The Use of Gene Expression Datasets in Feature Selection Research: 20 Years of Inherent Bias? *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 14(2), e1523.
- Guarda, T., Balseca, J., Garcia, K., Gonzalez, J., Yagual, F., & Castillo-Beltran, H. (2021). Digital Transformation Trends and Innovation. IOP Conference Series: Materials Science and Engineering,
- Gupta, M., & George, J. F. (2023). Toward the Development of a Big Data Analytics Capability. *Journal of Big Data*, 10(1). <https://doi.org/10.1186/s40537-023-00696-3>
- Hashim, F. A., Hussain, K., Houssein, E. H., Mabrouk, M. S., & Al-Atabany, W. (2021). Archimedes Optimization Algorithm: A New Metaheuristic Algorithm for Solving Optimization Problems. *Applied Intelligence*, 51, 1531-1551.
- Hassan, I. H., Abdullahi, M., Aliyu, M. M., Yusuf, S. A., & Abdulrahim, A. (2022). An Improved Binary Manta Ray Foraging Optimization Algorithm Based Feature Selection and Random Forest Classifier for Network Intrusion Detection. *Intelligent Systems with Applications*, 16, 200114.
- Hendrawan, S. A., Chatra, A., Iman, N., Hidayatullah, S., & Suprayitno, D. (2024). Digital Transformation in MSMEs: Challenges and Opportunities in Technology Management. *Jurnal Informasi Dan Teknologi*, 141-149.
- Huang, Z., Li, K., Jiang, Y., Jia, Z., Lv, L., & Ma, Y. (2024). Graph Relearn Network: Reducing Performance Variance and Improving Prediction Accuracy of Graph Neural Networks. *Knowledge-Based Systems*, 301, 112311. <https://doi.org/10.1016/j.knosys.2024.112311>
- Kim, K., & Kim, B. (2022). Decision-Making Model for Reinforcing Digital Transformation Strategies Based on Artificial Intelligence Technology. *Information*, 13(5), 253.
- Kitsios, F., & Kamariotou, M. (2021). Artificial Intelligence and Business Strategy Towards Digital Transformation: A Research Agenda. *Sustainability*, 13(4), 2025.
- Klopov, I., Shapurov, O., Voronkova, V., Nikitenko, V., Oleksenko, R., Khavina, I., & Chebakova, Y. (2023). Digital Transformation of Education Based on Artificial Intelligence. *Tem Journal*, 12(4), 2625.
- Kraus, S., Durst, S., Ferreira, J. J., Veiga, P., Kailer, N., & Weinmann, A. (2022). Digital Transformation in Business and Management Research: An Overview of the Current Status Quo. *International Journal of Information Management*, 63, 102466.
- Lamtar Gholipoor, M., Alimoradi, M., & Fakheri, S. (2024). A Novel Metaheuristic Approach Inspired by Trees Social Relationships and Models for Fermentation Medium. *Metaheuristic Algorithms with Applications*, 1(1), 1-11. <https://doi.org/10.22105/maa.v1i1.17>
- Manzari Vahed, N., Chaharsoughi, S. K., & Ashnavar, H. (2025). The Fairness Analysis of the Supply Chain in the Saipa Automotive Group: Examining Deviations and Supplier Performance Using a Neural Network Approach. *Annals of Process Engineering and Management*, 2(3), 131-142. <https://doi.org/10.48314/apem.v2i3.39>
- Mao, A., Mohri, M., & Zhong, Y. (2023). Cross-Entropy Loss Functions: Theoretical Analysis and Applications. International Conference on Machine Learning,
- Merceedi, K. J., & Abdulazeez, A. M. (2025). Feature Selection Methods of Gene Expression Based on Machine Learning: A Review. *International Journal of Research and Applied Technology (INJURATECH)*, 5(1), 104-138.
- Mhlanga, D. (2023). Digital Transformation Education, Opportunities, and Challenges of the Application of ChatGPT to Emerging Economies. *Education Research International*, 2023(1), 7605075.

- Mikalef, M., Krogstie, J., Pappas, I. O., & Pavlou, P. (2022). Machine Learning Capabilities and Organizational Performance in the Digital Transformation Era. *Information Systems Frontiers*.
- Mikalef, M., Pappas, I. O., & Krogstie, J. (2021). Artificial Intelligence Capability and Firm Performance During Digital Transformation. *Information & Management*.
- Naidu, G., Zuva, T., & Sibanda, E. M. (2023). A Review of Evaluation Metrics in Machine Learning Algorithms. *Computer Science On-Line Conference*,
- Nanehkaran, Y., Licai, Z., Chen, J., Jamel, A. A., Shengnan, Z., Navaei, Y. D., & Aghbolagh, M. A. (2022). Anomaly Detection in Heart Disease Using a Density-Based Unsupervised Approach. *Wireless Communications and Mobile Computing*, 2022(1), 6913043.
- Nanehkaran, Y., Licai, Z., Chen, J., Zhongpan, Q., Xiaofeng, Y., Navaei, Y. D., & Einy, S. (2022). Diagnosis of Chronic Diseases Based on Patients' Health Records in IoT Healthcare Using the Recommender System. *Wireless Communications and Mobile Computing*, 2022(1), 5663001.
- Omolu, E. J. (2024). Organizational Digital Transformation: From Evolution to Future Trends. *Digital Transformation and Society*, 3(3), 240-256.
- Paul, J., Ueno, A., Dennis, C., Alamanos, E., Curtis, L., Foroudi, P., Kacprzak, A., Kunz, W. H., Liu, J., & Marvi, R. (2024). Digital Transformation: A Multidisciplinary Perspective and Future Research Agenda. *International Journal of Consumer Studies*, 48(2), e13015.
- Perifanis, N. A., & Kitsios, F. (2023). Investigating the Influence of Artificial Intelligence on Business Value in the Digital Era of Strategy: A Literature Review. *Information*, 14(2), 85.
- Rau, G., & Shih, Y. S. (2021). Evaluation of Cohen's Kappa and Other Measures of Inter-Rater Agreement for Genre Analysis and Other Nominal Data. *Journal of English for Academic Purposes*, 53, 101026.
- Sadr, H., Zahiri, Z., Nazari, M., Bahadori, M. H., Ashoobi, M. T., & Hoseini, A. (2025). Optimizing Clinical Decisions in Reproductive Medicine with a Hybrid AI Predictive Model. *Big Data and Computing Visions*, 5(4), 287-306. <https://doi.org/10.22105/bdcv.2025.532035.1288>
- Shehadeh, M. (2024). Digital Transformation: A Catalyst for Sustainable Business Practices. In *Technological Innovations for Business, Education and Sustainability* (pp. 29-45). Emerald Publishing Limited.
- Vial, G. (2021). Understanding Digital Transformation: A Review and a Research Agenda. In *Managing digital transformation* (pp. 13-66).
- Xinxian, C., & Jianhui, C. (2022). Digital Transformation and Financial Risk Prediction of Listed Companies. *Computational Intelligence and Neuroscience*, 2022(1), 7211033.
- Zhang, J., & Chen, Z. (2024). Exploring Human Resource Management Digital Transformation in the Digital Age. *Journal of the Knowledge Economy*, 15(1), 1482-1498.
- Zhang, X., Xu, Y. Y., & Ma, L. (2023). Information Technology Investment and Digital Transformation: The Roles of Digital Transformation Strategy and Top Management. *Business Process Management Journal*, 29(2), 528-549.
- Zhang, Y., Chen, X., & Li, J. (2022). Deep Stacking Ensemble Learning for Classification Problems. *Expert Systems with Applications*, 187, 115978.
- Zhu, C., Liu, X., & Chen, D. (2024). Prediction of Digital Transformation of Manufacturing Industry Based on Interpretable Machine Learning. *PLoS One*, 19(3), e0299147.