



استفاده از یادگیری عمیق پشته‌ای مبتنی بر فرایادگیری جمعی در راستای پیش‌بینی موفقیت تحول دیجیتال با بهره‌گیری از چابکی سازمانی

ساناز رضائی افشار ^۱ سیدجواد ایرانبان فرد ^{۲*} محمدحسین درویش متولی ^۳	تاریخ چاپ نهایی: ۱ شهریور ۱۴۰۶ تاریخ چاپ اولیه: ۲۷ مهر ۱۴۰۵ تاریخ پذیرش: ۱۴ اردیبهشت ۱۴۰۵ تاریخ بازنگری: ۱۷ اردیبهشت ۱۴۰۵ تاریخ ارسال: ۶ بهمن ۱۴۰۴	شیوه استناددهی: رضائی افشار، ساناز، ایرانبان فرد، سیدجواد، و درویش متولی، محمدحسین. (۱۴۰۶). گنجینه زبان و ادبیا فارسی.... یادگیری هوشمند و تحول مدیریت، (۳)۵، ۱-۳۲.
---	--	--

چکیده

هدف این پژوهش ارائه یک چارچوب مبتنی بر یادگیری ماشین برای پیش‌بینی میزان موفقیت تحول دیجیتال سازمان‌ها با تأکید بر نقش چابکی سازمانی و طراحی شاخصی کمی برای سنجش آمادگی دیجیتال سازمان‌ها بود. این پژوهش با استفاده از مجموعه داده استاندارد تحول دیجیتال انجام شد و در آن داده‌های مرتبط با اندازه سازمان، ابزارهای دیجیتال مورد استفاده، آموزش مهارت‌های دیجیتال، تعامل با مشتری و شاخص‌های عملکردی سازمان تحلیل گردید. ابتدا شاخص چابکی سازمانی (OAI) بر اساس ترکیب خطی چند متغیر کلیدی طراحی شد تا میزان آمادگی و انعطاف‌پذیری سازمان‌ها در مواجهه با تحول دیجیتال به‌صورت کمی سنجیده شود. سپس با استفاده از الگوریتم خوشه‌بندی K-Means، سازمان‌ها بر اساس تأثیر تحول دیجیتال بر درآمد و کارایی در سه سطح پایین، متوسط و بالا طبقه‌بندی شدند. در مرحله پیش‌پردازش، ویژگی‌های طبقه‌ای با روش One-Hot Encoding و متغیرهای عددی با استفاده از استانداردسازی نرمال‌سازی شدند. در ادامه، معماری یادگیری عمیق پشته‌ای شامل مدل‌های CNN، LSTM، RNN، MLP و ResMLP به‌عنوان یادگیرنده‌های پایه طراحی شد و خروجی آن‌ها توسط الگوریتم جنگل تصادفی به‌عنوان فرایادگیر ترکیب گردید. ارزیابی مدل‌ها با استفاده از معیارهای دقت، حساسیت، صحت، امتیاز MAE و RMSE انجام شد و فرایند آموزش و آزمون در ۳۰ تکرار مستقل مورد بررسی قرار گرفت. نتایج نشان داد که معماری یادگیری عمیق پشته‌ای پیشنهادی در مقایسه با مدل‌های منفرد عملکرد برتری ارائه کرده است. مدل فرایادگیر مبتنی بر جنگل تصادفی توانست با ترکیب خروجی مدل‌های پایه به دقتی معادل ۹۶۸۶ درصد دست یابد که بالاترین عملکرد را در میان روش‌های مقایسه‌شده نشان می‌دهد. همچنین معیارهای حساسیت، صحت و امتیاز F برای مدل پیشنهادی در سطح بالایی قرار داشت و پراکندگی نتایج در تکرارهای مختلف بسیار محدود بود که نشان‌دهنده پایداری و قابلیت تعمیم مناسب مدل است. یافته‌ها نشان دادند که ترکیب شاخص چابکی سازمانی با معماری‌های یادگیری عمیق و فرایادگیری جمعی می‌تواند پیش‌بینی موفقیت تحول دیجیتال را به‌طور معناداری افزایش دهد. افزون بر این، استفاده هم‌زمان از چند معماری عصبی باعث استخراج الگوهای پیچیده‌تر از داده‌ها و کاهش خطای پیش‌بینی در مقایسه با روش‌های تک‌مدلی شد. نتایج این پژوهش نشان داد که بهره‌گیری از چارچوب‌های یادگیری عمیق پشته‌ای همراه با شاخص‌های سازمانی می‌تواند رویکردی مؤثر برای پیش‌بینی موفقیت تحول دیجیتال باشد. طراحی شاخص چابکی سازمانی امکان سنجش کمی آمادگی دیجیتال سازمان‌ها را فراهم کرد و ادغام آن با مدل‌های یادگیری عمیق، دقت و پایداری پیش‌بینی را بهبود بخشید. معماری پیشنهادی نه تنها توانایی شناسایی الگوهای پیچیده موجود در داده‌های سازمانی را دارد، بلکه می‌تواند به مدیران و سیاست‌گذاران در تصمیم‌گیری، تخصیص منابع و ارزیابی آمادگی سازمان‌ها برای تحول دیجیتال کمک کند. این رویکرد ظرفیت آن را دارد که در محیط‌های واقعی و در سازمان‌های جدید نیز به‌عنوان ابزاری هوشمند برای تحلیل و پیش‌بینی موفقیت تحول دیجیتال مورد استفاده قرار گیرد.

واژگان کلیدی: موفقیت تحول دیجیتال، یادگیری عمیق پشته‌ای، فرایادگیری جمعی، چابکی سازمانی، یادگیری ماشین، جنگل تصادفی

مشخصات نویسندگان:

۱. دانشجوی دکتری، گروه مدیریت فناوری اطلاعات، واحد بین‌المللی کیش، دانشگاه آزاد اسلامی، کیش، ایران
۲. گروه مدیریت، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران
۳. گروه مدیریت صنعتی، واحد تهران غرب، دانشگاه آزاد اسلامی، تهران، ایران

پست الکترونیکی: javad.iranban@iau.ac.ir

نویسنده است. © ۱۴۰۶ تمامی حقوق انتشار این مقاله متعلق به CC BY-NC 4.0 است.

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



Utilizing Ensemble Meta-Learning Based Stacking Deep Learning for Predicting Digital Transformation Success by Leveraging Organizational Agility

Sanaz Rezaei Afshar¹
Seyed Javad Iranbanfard^{2*}
Mohammad Hossein Darvish Motevalli³

Submit Date: 26 January 2026
Revise Date: 27 April 2026
Accept Date: 04 May 2026
Initial Publish: 19 October 2026
Final Publish: 23 August 2027

How to cite: Rezaei Afshar, S., Iranbanfard, S. J., & Darvish Motevalli, M. H. (2027). Utilizing Ensemble Meta-Learning Based Stacking Deep Learning for Predicting Digital Transformation Success by Leveraging Organizational Agility. *Intelligent Learning and Management Transformation*, 5(3), 1-32.

Abstract

The aim of this study was to develop a machine learning-based framework for predicting the success of digital transformation in organizations by emphasizing the role of organizational agility and introducing a quantitative index for measuring digital readiness. This study was conducted using a standard digital transformation dataset containing organizational and technological variables such as company size, adopted digital tools, digital skills training, customer engagement changes, and organizational performance indicators. First, an Organizational Agility Index (OAI) was developed through a linear combination of several key organizational variables to quantitatively measure organizational readiness and flexibility toward digital transformation. Then, the K-Means clustering algorithm was employed to classify organizations into three levels of digital transformation success—low, medium, and high—based on the impact of digital transformation on revenue and efficiency. During preprocessing, categorical variables were encoded using One-Hot Encoding, while numerical features were normalized through standardization techniques. Subsequently, a stacking deep learning architecture consisting of MLP, RNN, LSTM, CNN, and ResMLP models was implemented as base learners, and their outputs were integrated using a Random Forest meta-learner. Model performance was evaluated using accuracy, sensitivity, precision, F-score, MAE, and RMSE metrics, and the training-testing process was repeated across 30 independent runs. The findings demonstrated that the proposed stacking deep learning framework significantly outperformed individual models. The Random Forest meta-learner achieved an accuracy of 96.86%, representing the highest predictive performance among all compared approaches. Sensitivity, precision, and F-score values were also considerably high, while the variance across repeated executions remained minimal, indicating strong stability and generalizability of the proposed framework. The results further revealed that integrating the Organizational Agility Index with advanced deep learning and ensemble meta-learning architectures substantially enhanced the prediction capability of digital transformation success. Moreover, combining multiple neural architectures enabled the extraction of more complex hidden patterns from organizational data and reduced prediction errors compared with single-model approaches. The results of this study indicate that stacking deep learning frameworks integrated with organizational indicators can provide an effective approach for predicting digital transformation success. The proposed Organizational Agility Index enabled quantitative assessment of digital readiness, while its integration with deep learning models improved prediction accuracy and stability. The proposed architecture demonstrated a strong capability to identify complex patterns within organizational data and can support managers and policymakers in strategic decision-making, resource allocation, and evaluating organizational preparedness for digital transformation. Furthermore, the framework has the potential to be implemented in real-world organizational environments as an intelligent predictive system for assessing digital transformation outcomes.

Keywords: Digital Transformation Success, Stacking Deep Learning, Ensemble Meta-Learning, Organizational Agility, Machine Learning, Random Forest

Authors' Information:

javad.iranban@iau.ac.ir

1. Ph.D. Student, Department of Information Technology Management, Ki.C., Islamic Azad University, Kish, Iran
2. Department of Management, Shi.C., Islamic Azad University, Shiraz, Iran
3. Department of Industrial Management, WT.C., Islamic Azad University, Tehran, Iran



© 2027 the authors. This is an open access article under the terms of the [CC BY-NC 4.0](https://creativecommons.org/licenses/by-nc/4.0/) License.

مقدمه

تحول دیجیتال در سال‌های اخیر از یک انتخاب فناورانه به یک ضرورت راهبردی برای سازمان‌ها تبدیل شده است؛ ضرورتی که نه تنها شیوه تولید، ارائه خدمت، مدیریت منابع و تعامل با مشتریان را تغییر داده، بلکه منطق رقابت، تصمیم‌گیری و بقا در محیط‌های پیچیده را نیز دگرگون ساخته است. سازمان‌ها در شرایطی فعالیت می‌کنند که فناوری‌های داده‌محور، هوش مصنوعی، تحلیل پیش‌بینانه، سامانه‌های هوشمند و زیرساخت‌های دیجیتال به بخشی جدایی‌ناپذیر از قابلیت‌های عملیاتی و راهبردی آن‌ها تبدیل شده‌اند. در چنین زمینه‌ای، تحول دیجیتال صرفاً به معنای استفاده از ابزارهای فناوری اطلاعات نیست، بلکه فرایندی چندبعدی است که ساختارها، فرایندها، مدل‌های کسب‌وکار، فرهنگ سازمانی و قابلیت‌های تصمیم‌گیری را بازآرایی می‌کند. پژوهش‌های جدید نشان می‌دهند که موفقیت تحول دیجیتال زمانی حاصل می‌شود که سازمان بتواند فناوری را با قابلیت‌های مدیریتی، منابع انسانی، آمادگی عملیاتی و راهبردهای نوآوری پیوند دهد (Omola, 2024; Weritz et al., 2025). از این منظر، تحول دیجیتال پدیده‌ای صرفاً فناورانه نیست، بلکه یک تحول سازمانی عمیق است که در آن فناوری، راهبرد، ساختار و قابلیت‌های انسانی به صورت هم‌زمان عمل می‌کنند (Eom & Lee, 2022; Sagala & Ori, 2024).

با وجود اهمیت فزاینده تحول دیجیتال، شواهد تجربی نشان می‌دهد که همه سازمان‌ها در بهره‌گیری از آن به نتایج مشابهی دست نمی‌یابند. برخی سازمان‌ها با پیاده‌سازی فناوری‌های دیجیتال به افزایش درآمد، بهبود کارایی، ارتقای کیفیت خدمات و چابکی بیشتر می‌رسند، در حالی که برخی دیگر، علی‌رغم سرمایه‌گذاری قابل توجه، با شکست، ناکارآمدی، مقاومت سازمانی و فقدان بازدهی روبه‌رو می‌شوند. این تفاوت نشان می‌دهد که موفقیت تحول دیجیتال به مجموعه‌ای از عوامل درونی و بیرونی وابسته است و صرف دسترسی به فناوری نمی‌تواند تضمین‌کننده موفقیت باشد. مطالعات انجام‌شده درباره بنگاه‌های کوچک و متوسط و همچنین سازمان‌های آموزشی و صنعتی نشان داده‌اند که چالش‌هایی مانند محدودیت منابع، ضعف زیرساخت، کمبود مهارت دیجیتال، مقاومت کارکنان، نبود راهبرد مشخص و ضعف در مدیریت تغییر از موانع اصلی تحقق تحول دیجیتال محسوب می‌شوند (Hendrawan et al., 2024; Purnomo et al., 2024; Singun, 2025). در همین راستا، پژوهش‌های حوزه مدیریت فناوری تأکید کرده‌اند که برای سنجش موفقیت تحول دیجیتال باید افزون بر شاخص‌های فناورانه، ظرفیت سازمان برای یادگیری، سازگاری، بازآرایی فرایندها و پاسخ سریع به تغییرات محیطی نیز ارزیابی شود (Syarkani, 2025; Yuan & Sun, 2024).

یکی از مفاهیم کلیدی که در تبیین تفاوت عملکرد سازمان‌ها در مسیر تحول دیجیتال اهمیت یافته، چابکی سازمانی است. چابکی سازمانی به توانایی سازمان برای تشخیص سریع تغییرات، پاسخ مؤثر به فرصت‌ها و تهدیدها، بازآرایی منابع و حفظ انعطاف‌پذیری در شرایط عدم قطعیت اشاره دارد. در زمینه تحول دیجیتال، چابکی سازمانی نقش واسطه‌ای و تقویت‌کننده دارد؛ زیرا سازمان‌هایی که از ساختار منعطف، فرهنگ نوآورانه، مهارت‌های دیجیتال و قابلیت تصمیم‌گیری سریع برخوردارند، می‌توانند فناوری‌های جدید را بهتر جذب کرده و آن‌ها را به نتایج عملکردی تبدیل کنند.

مرورهای جدید نشان می‌دهند که چابکی سازمانی نه تنها پیامد تحول دیجیتال است، بلکه یکی از پیش‌شرط‌های مهم موفقیت آن نیز محسوب می‌شود (Gong & Ribiere, 2025; Syarkani, 2025). در پژوهش‌های تجربی نیز رابطه میان تحول دیجیتال، چابکی سازمانی و عملکرد شرکت تأیید شده است؛ برای مثال، شواهد مربوط به بازارهای نوظهور نشان می‌دهد که ظرفیت‌های دیجیتال زمانی به عملکرد بهتر منجر می‌شوند که سازمان بتواند از طریق چابکی، منابع خود را با تغییرات محیطی هماهنگ سازد (Nguyen et al., 2025). همچنین، پژوهش‌های مبتنی بر رویکرد پیکربندی نشان داده‌اند که ترکیب مناسب قابلیت‌های دیجیتال، منابع انسانی و سازوکارهای سازمانی می‌تواند چابکی را در بنگاه‌های کوچک و متوسط تقویت کند (Pelletier et al., 2025).

با این حال، یکی از خلأهای مهم در ادبیات موجود آن است که چابکی سازمانی غالباً به صورت مفهومی، کیفی یا از طریق مدل‌های پیمایشی بررسی شده و کمتر به صورت یک شاخص کمی قابل استفاده در مدل‌های پیش‌بینی عملیاتی شده است. بسیاری از پژوهش‌ها بر روابط نظری یا علی میان تحول دیجیتال و چابکی متمرکز بوده‌اند، اما هنوز نیاز به چارچوب‌هایی وجود دارد که بتوانند مؤلفه‌های چابکی سازمانی را به متغیرهای قابل اندازه‌گیری تبدیل کرده و آن‌ها را در مدل‌های یادگیری ماشین وارد کنند. این مسئله به‌ویژه زمانی اهمیت می‌یابد که هدف پژوهش، پیش‌بینی سطح موفقیت تحول دیجیتال در سازمان‌های جدید باشد. پژوهش‌هایی که از هوش مصنوعی برای پیش‌بینی چابکی سازمانی استفاده کرده‌اند، نشان می‌دهند که قابلیت‌های داده‌محور می‌توانند در شناسایی الگوهای پنهان چابکی بسیار مؤثر باشند (Shafiabady et al., 2023). افزون بر این، مطالعات اخیر درباره رهبری پارادوکسیکال، فرهنگ نوآوری و چابکی سازمانی نشان می‌دهند که موفقیت تحول دیجیتال وابسته به سازوکارهای مدیریتی و رفتاری پیچیده‌ای است که با روش‌های آماری سنتی به‌تنهایی به‌سختی قابل مدل‌سازی هستند (Su et al., 2026).

در کنار اهمیت چابکی سازمانی، توسعه مدل‌های پیش‌بینی برای تحلیل موفقیت تحول دیجیتال نیز به یکی از محورهای نوظهور پژوهش‌های مدیریت و فناوری تبدیل شده است. محیط‌های سازمانی امروز داده‌های متنوعی درباره عملکرد، فناوری، تعاملات مشتری، مهارت کارکنان و ساختار سازمان تولید می‌کنند و این داده‌ها ظرفیت بالایی برای تحلیل پیش‌بینانه دارند. مدل‌های یادگیری ماشین می‌توانند با کشف الگوهای غیرخطی و روابط پیچیده میان متغیرها، سطح موفقیت تحول دیجیتال را با دقت بیشتری نسبت به روش‌های توصیفی یا آماری ساده پیش‌بینی کنند. پژوهش‌های مرتبط با عملکرد تحول دیجیتال در بنگاه‌های کوچک و متوسط نشان داده‌اند که ترکیب روش‌های یادگیری ماشین، خوشه‌بندی و تحلیل تفسیری می‌تواند در ارزیابی و پیش‌بینی بلوغ و عملکرد دیجیتال بسیار کارآمد باشد (Herdiyeni et al., 2026). همچنین، راهکارهای تحلیل پیش‌بینانه برای شناسایی قابلیت‌های دیجیتال نشان داده‌اند که داده کاوی و یادگیری ماشین می‌توانند در بهبود عملکرد کسب و کار و شناسایی مسیرهای تحول نقش اساسی ایفا کنند (Raeesi Vanani et al., 2025). در همین راستا، مدل‌های پیش‌بینی ریسک تحول دیجیتال نیز نشان می‌دهند که یادگیری

ماشین می‌تواند نه تنها برای پیش‌بینی موفقیت، بلکه برای شناسایی و پیشگیری از شکست‌های احتمالی تحول دیجیتال به کار رود (Liu et al., 2025).

پیشینه پژوهش نشان می‌دهد که روش‌های گوناگونی برای تحلیل تحول دیجیتال به کار رفته‌اند، اما هر یک محدودیت‌هایی دارند. برخی مطالعات بر مدل‌های آماری و پیمایشی برای شناسایی عوامل موفقیت متمرکز شده‌اند (Oh et al., 2022)، برخی دیگر از مدل‌های شبکه عصبی و تحلیل مؤلفه‌های اصلی برای پیش‌بینی ریسک تحول دیجیتال در زنجیره تأمین تولید استفاده کرده‌اند (Liu, 2022)، و گروهی دیگر نقش مدل‌های پیش‌بینی را در مدیریت راهبردی و اقتصاد پیچیدگی بررسی کرده‌اند (Iscaro et al., 2022). با وجود ارزش این رویکردها، بسیاری از آنها یا بر یک مدل منفرد تکیه دارند یا عمدتاً به تحلیل روابط نظری و آماری محدود می‌شوند. در مقابل، رویکردهای یادگیری جمعی و یادگیری عمیق پشته‌ای می‌توانند با ترکیب چند مدل، محدودیت‌های مدل‌های منفرد را کاهش دهند و از توانایی‌های مکمل آنها برای افزایش دقت پیش‌بینی استفاده کنند. مرورهای جدید درباره یادگیری عمیق جمعی نشان می‌دهند که ترکیب چند معماری مانند شبکه‌های عصبی چندلایه، شبکه‌های بازگشتی، شبکه‌های حافظه بلندمدت و شبکه‌های کانولوشنی می‌تواند در مسائل پیچیده طبقه‌بندی و پیش‌بینی عملکردی برتر ایجاد کند (Rane et al., 2024). از این جهت، استفاده از یادگیری پشته‌ای برای پیش‌بینی موفقیت تحول دیجیتال می‌تواند نسبت به رویکردهای تک‌مدلی، جامعیت و پایداری بیشتری فراهم سازد.

از منظر داده و آماده‌سازی مدل، پیش‌بینی موفقیت تحول دیجیتال نیازمند تبدیل ویژگی‌های ناهمگون سازمانی به قالبی عددی، استاندارد و قابل پردازش است. مجموعه داده‌های تحول دیجیتال معمولاً شامل متغیرهای طبقه‌ای مانند صنعت، اندازه سازمان و منطقه جغرافیایی و همچنین متغیرهای عددی مانند سال پذیرش فناوری، درصد تأثیر بر درآمد و کارایی، میزان تعامل مشتری و سطح استفاده از ابزارهای دیجیتال هستند (AprajitByte, 2023). بنابراین، مرحله پیش‌پردازش نقش بنیادینی در کیفیت مدل دارد. روش‌هایی مانند کدگذاری One-Hot برای تبدیل داده‌های طبقه‌ای به بردارهای عددی، به مدل اجازه می‌دهند بدون ایجاد ترتیب مصنوعی میان طبقات، تفاوت میان گروه‌ها را درک کند (Kujawa et al., 2025). همچنین، استانداردسازی داده‌های عددی برای جلوگیری از غلبه متغیرهای دارای مقیاس بزرگ‌تر و افزایش پایداری آموزش شبکه‌های عصبی ضروری است (Izonin et al., 2022). در سطح پیشرفته‌تر، استفاده از سازوکارهای ترکیبی برای ادغام داده‌های عددی و طبقه‌ای می‌تواند کیفیت ماتریس ورودی مدل را بهبود بخشد و زمینه را برای استخراج الگوهای عمیق‌تر فراهم کند (Hijazi et al., 2024).

یکی دیگر از جنبه‌های مهم در طراحی مدل پیش‌بینی، تعیین متغیر هدف است. در بسیاری از مجموعه داده‌ها، برچسب مستقیم موفقیت تحول دیجیتال وجود ندارد و پژوهشگر باید با استفاده از شاخص‌های عملکردی، سطح موفقیت را استخراج کند. خوشه‌بندی K-Means یکی از روش‌های پرکاربرد یادگیری بدون ناظر است که می‌تواند نمونه‌ها را بر اساس شباهت در ویژگی‌های کلیدی به گروه‌های معنادار تقسیم کند

(Suyal & Sharma, 2024). استفاده از خوشه‌بندی برای دسته‌بندی سازمان‌ها بر اساس شاخص‌هایی مانند درآمد و کارایی می‌تواند راهی مناسب برای ساخت برجسب هدف و تبدیل مسئله به یک طبقه‌بندی چند کلاسه باشد. مطالعات مشابه در حوزه مسیریابی، داده‌کاوی و خوشه‌بندی نشان داده‌اند که این روش‌ها می‌توانند الگوهای پنهان در داده‌های پیچیده را آشکار کنند و مبنای تصمیم‌گیری الگوریتمی قرار گیرند (Xie et al., 2023). از این منظر، ترکیب خوشه‌بندی برای تولید برجسب هدف و یادگیری عمیق برای پیش‌بینی آن، چارچوبی منطقی برای تحلیل موفقیت تحول دیجیتال فراهم می‌کند.

برای ارزیابی چنین مدل‌هایی، استفاده از معیارهای معتبر یادگیری ماشین ضروری است. در مسائل طبقه‌بندی چند کلاسه، اتکا به دقت به تنهایی کافی نیست؛ زیرا ممکن است در شرایط عدم توازن داده‌ها، عملکرد واقعی مدل را به خوبی نشان ندهد. معیارهایی مانند حساسیت، صحت، امتیاز F1، میانگین خطای مطلق و ریشه میانگین مربعات خطا می‌توانند ابعاد مختلف عملکرد مدل را مشخص کنند (Naidu et al., 2023). پژوهش‌های مرتبط با تشخیص ناهنجاری و سامانه‌های توصیه‌گر در داده‌های سلامت و اینترنت اشیا نیز نشان داده‌اند که انتخاب معیارهای ارزیابی مناسب برای تفسیر عملکرد مدل و مقایسه روش‌ها اهمیت زیادی دارد (Nanehkaran, Licai, Chen, Jamel, et al., 2022; Nanehkaran, Licai, Chen, Zhongpan, et al., 2022). افزون بر این، مطالعات مبتنی بر انتخاب ویژگی و شبکه‌های یادگیری سریع نشان می‌دهند که کیفیت ویژگی‌ها، کاهش ابعاد و بهینه‌سازی ساختار مدل می‌تواند در افزایش دقت و کاهش خطا نقش مهمی داشته باشد (Einy et al., 2021). بنابراین، در پژوهش‌های پیش‌بینی موفقیت تحول دیجیتال، ارزیابی جامع مدل باید هم جنبه دقت طبقه‌بندی و هم جنبه پایداری و خطای پیش‌بینی را دربر گیرد.


در سطح کلان، دولت‌ها، سازمان‌های عمومی، بنگاه‌های کوچک و متوسط، صنایع تولیدی و حتی حوزه‌هایی مانند کشاورزی و علم مواد همگی با ضرورت تحول دیجیتال مواجه‌اند. پژوهش‌های مربوط به شاخص بلوغ GovTech نشان داده‌اند که سنجش آمادگی دولت‌ها برای تحول دیجیتال نیازمند مدل‌های داده‌محور و شاخص‌های چندبعدی است (AlMurtadha, 2024). در حوزه علم مواد نیز توسعه گردش کارهای دیجیتال نشان می‌دهد که تحول دیجیتال می‌تواند بازتولیدپذیری، استانداردسازی و اشتراک‌گذاری داده‌ها را بهبود دهد (Bekemeier et al., 2025). این گستره کاربردی نشان می‌دهد که مسئله پیش‌بینی موفقیت تحول دیجیتال محدود به یک صنعت خاص نیست، بلکه برای هر سازمانی که در معرض تغییرات فناورانه قرار دارد، اهمیت دارد. با این حال، نبود چارچوبی که هم چابکی سازمانی را کمی‌سازی کند، هم از داده‌های واقعی تحول دیجیتال استفاده کند و هم از معماری‌های پیشرفته یادگیری جمعی برای پیش‌بینی بهره بگیرد، همچنان یک خلأ مهم در ادبیات موجود محسوب می‌شود.

بر این اساس، پژوهش حاضر با ترکیب سه منطق اصلی شکل گرفته است: نخست، کمی‌سازی چابکی سازمانی در قالب شاخصی قابل استفاده در مدل‌های یادگیری ماشین؛ دوم، استخراج سطح موفقیت تحول دیجیتال از شاخص‌های عملکردی با استفاده از خوشه‌بندی؛ و سوم، استفاده از معماری یادگیری عمیق پشته‌ای و فرایادگیر جنگل تصادفی برای افزایش دقت و پایداری پیش‌بینی. چنین رویکردی می‌تواند به مدیران کمک کند تا پیش از اجرای کامل برنامه‌های تحول دیجیتال، سطح آمادگی و احتمال موفقیت سازمان خود را ارزیابی کنند و تصمیم‌های دقیق‌تری درباره سرمایه‌گذاری، آموزش، زیرساخت و مدیریت تغییر اتخاذ نمایند. همچنین، از منظر علمی، این پژوهش می‌تواند به توسعه ادبیات میان‌رشته‌ای تحول دیجیتال، چابکی سازمانی و یادگیری ماشین کمک کند و نشان دهد که چگونه شاخص‌های مدیریتی می‌توانند در کنار الگوریتم‌های پیشرفته برای تحلیل مسائل پیچیده سازمانی به کار روند.

هدف این پژوهش ارائه یک چارچوب مبتنی بر یادگیری عمیق پشته‌ای و فرایادگیری جمعی برای پیش‌بینی موفقیت تحول دیجیتال سازمان‌ها با بهره‌گیری از شاخص چابکی سازمانی است.

روش‌شناسی

در این پژوهش، یک چارچوب داده‌محور و چندلایه برای پیش‌بینی میزان موفقیت تحول دیجیتال سازمان‌ها طراحی شده است. منطق اصلی روش پیشنهادی بر این فرض استوار است که موفقیت تحول دیجیتال تنها تابع یک متغیر منفرد نیست، بلکه حاصل تعامل میان ویژگی‌های سازمانی، میزان استفاده از فناوری‌های دیجیتال، سطح آمادگی کارکنان، تغییرات عملکردی و چابکی سازمانی است. از این رو، پژوهش حاضر به جای استفاده از یک مدل منفرد، از معماری یادگیری عمیق پشته‌ای بهره می‌گیرد؛ به این معنا که چند مدل پایه به صورت مستقل آموزش داده می‌شوند و سپس خروجی آن‌ها توسط یک فرایادگیر ترکیب می‌شود تا پیش‌بینی نهایی با دقت و پایداری بیشتری انجام گیرد. داده‌های مورد استفاده در این پژوهش شامل ویژگی‌هایی مانند صنعت، اندازه سازمان، ابزارهای دیجیتال به کار گرفته شده، سال پذیرش فناوری، تأثیر تحول دیجیتال بر درآمد، تأثیر آن بر کارایی، آموزش مهارت‌های دیجیتال، تغییر در تعامل مشتری و منطقه جغرافیایی است. در این چارچوب، ابتدا داده‌ها برای ایجاد شاخص چابکی سازمانی و تعیین متغیر هدف پردازش شدند، سپس فرایند پیش‌پردازش انجام گرفت و در نهایت مدل‌های یادگیری عمیق و فرایادگیر جنگل تصادفی برای طبقه‌بندی سطح موفقیت تحول دیجیتال به کار گرفته شدند.



شکل ۱- فلوچارت روش پیشنهادی

در گام نخست، برای کمی‌سازی میزان آمادگی و انعطاف‌پذیری سازمان‌ها در برابر تحول دیجیتال، شاخص چابکی سازمانی طراحی شد. این شاخص از ترکیب چند مؤلفه مهم ساخته شد که هر یک بخشی از ظرفیت سازمان برای انطباق با تغییرات دیجیتال را نشان می‌دهد. اندازه سازمان،

سطح مهارت دیجیتال کارکنان، تعداد ابزارهای دیجیتال مورد استفاده و میزان تعامل کارکنان یا مشتریان از جمله مؤلفه‌هایی بودند که در ساخت این شاخص به کار رفتند. اندازه سازمان پس از تبدیل به مقدار عددی، مهارت دیجیتال به صورت متغیر دودویی، تعداد ابزارهای دیجیتال بر اساس شمارش ابزارهای گزارش شده و تعامل سازمانی به صورت مقدار عددی در شاخص لحاظ شد. فرمول کلی شاخص چابکی سازمانی به صورت زیر تعریف شد:

$$OAI = S_{Size} + S_{Skill} + S_{Tools} + S_{Eng}$$

در این رابطه، S_{Size} مقدار عددی اندازه سازمان، S_{Skill} مقدار دودویی مربوط به وجود یا نبود آموزش و مهارت دیجیتال، S_{Tools} تعداد ابزارهای دیجیتال مورد استفاده و S_{Eng} میزان تعامل کارکنان یا مشتریان است. این شاخص به عنوان یک متغیر تحلیلی جدید وارد مدل شد تا اثر چابکی سازمانی بر پیش‌بینی موفقیت تحول دیجیتال به صورت کمی قابل بررسی باشد.

در مرحله بعد، از آنجا که متغیر هدف یعنی سطح موفقیت تحول دیجیتال به صورت مستقیم در مجموعه داده وجود نداشت، این متغیر با استفاده از خوشه‌بندی K-Means ساخته شد. برای این منظور، دو شاخص عملکردی مهم، یعنی تأثیر تحول دیجیتال بر درآمد و تأثیر آن بر کارایی، مبنای خوشه‌بندی قرار گرفتند. فرض اساسی این بود که سازمان‌هایی که از تحول دیجیتال بهره بیشتری برده‌اند، معمولاً افزایش بالاتری در درآمد و کارایی تجربه کرده‌اند. بنابراین، هر سازمان به صورت یک بردار دوبعدی در فضای درآمد و کارایی تعریف شد:

$$x_i = (Revenue_i, Efficiency_i)$$

سپس الگوریتم K-Means با مقدار $k = 3$ اجرا شد تا سازمان‌ها در سه سطح پایین، متوسط و بالا از نظر موفقیت تحول دیجیتال طبقه‌بندی شوند. تابع هدف این الگوریتم کمینه‌سازی مجموع مربعات فاصله نمونه‌ها از مراکز خوشه‌هاست که به شکل زیر بیان می‌شود:

$$J = \sum_{j=1}^k \sum_{x_i \in C_j} \|x_i - \mu_j\|^2$$

در این رابطه، k تعداد خوشه‌ها، C_j مجموعه نمونه‌های متعلق به خوشه j ، μ_j مرکز خوشه j و $\|x_i - \mu_j\|$ فاصله اقلیدسی هر نمونه از مرکز خوشه است. خروجی این مرحله، یک برجسب طبقه‌بندی شده برای هر سازمان بود که به عنوان متغیر هدف در مدل‌های یادگیری عمیق استفاده شد. به این ترتیب، مسئله پژوهش از تحلیل داده‌های خام عملکردی به یک مسئله طبقه‌بندی چند کلاسه تبدیل شد.

پس از تعیین شاخص چابکی سازمانی و برچسب هدف، مرحله پیش‌پردازش داده‌ها انجام شد. هدف از این مرحله، تبدیل داده‌های ناهمگون به قالبی عددی، هم‌مقیاس و مناسب برای ورود به مدل‌های یادگیری عمیق بود. متغیرهای طبقه‌ای مانند صنعت، اندازه سازمان و منطقه جغرافیایی با استفاده از روش One-Hot Encoding به بردارهای دودویی تبدیل شدند. این روش برای هر مقدار ممکن از یک ویژگی، یک ستون مستقل ایجاد می‌کند و مانع ایجاد ترتیب مصنوعی میان طبقات می‌شود. نمایش ریاضی این تبدیل به صورت زیر است:

$$Encode(x_i) = [\delta(x_i = c_1), \delta(x_i = c_2), \dots, \delta(x_i = c_k)]$$

در این رابطه، $c_1, c_2, \dots, c_k$ مقادیر ممکن ویژگی طبقه‌ای و δ تابع دلتای کرونکر است که در صورت برقراری شرط مقدار ۱ و در غیر این صورت مقدار صفر می‌گیرد. در کنار آن، متغیرهای عددی مانند سال پذیرش فناوری، درآمد، کارایی، تعامل و شاخص چابکی سازمانی با روش استانداردسازی به مقیاس مشترک منتقل شدند:

$$x' = \frac{x - \mu}{\sigma}$$

در این رابطه، μ میانگین ویژگی، σ انحراف معیار و x' مقدار استاندارد شده است. در نهایت، خروجی پیش‌پردازش از ترکیب ویژگی‌های کدگذاری شده و استاندارد شده ساخته شد:

$$D' = [OneHotEncoder(D_{cat}) \parallel StandardScaler(D_{num})]$$

که در آن D_{cat} ویژگی‌های طبقه‌ای، D_{num} ویژگی‌های عددی و $\parallel$ نشان‌دهنده الحاق ستون‌هاست.

در مرحله مدل‌سازی، معماری یادگیری پشته‌ای عمیق طراحی شد. در لایه نخست، پنج مدل پایه شامل MLP، RNN، LSTM، CNN و ResMLP به صورت مستقل روی داده‌های آموزشی آموزش داده شدند. هر مدل برای هر نمونه، برداری از احتمال تعلق آن نمونه به سه سطح موفقیت تحول دیجیتال تولید کرد. اگر خروجی احتمالاتی مدل‌ها برای نمونه i نشان داده شود، بردار ترکیبی خروجی مدل‌های پایه به صورت زیر تعریف می‌شود:

$$Z_i = [P_i^{MLP}, P_i^{RNN}, P_i^{LSTM}, P_i^{CNN}, P_i^{ResMLP}]$$

مدل MLP برای استخراج روابط غیرخطی عمومی میان ویژگی‌ها به کار رفت و رابطه پایه آن در لایه چگال به صورت $h = \sigma(Wx + b)$ تعریف شد. مدل RNN برای بررسی وابستگی‌های ترتیبی میان ویژگی‌ها استفاده شد و حالت پنهان آن به صورت زیر محاسبه گردید:

$$h_t = \sigma(Wx_t + Uh_{t-1} + b)$$

مدل LSTM نیز برای کنترل بهتر جریان اطلاعات و کاهش مشکل محو شدن گرادیان به کار رفت. در این مدل، دروازه‌های ورودی، فراموشی و خروجی به ترتیب جریان اطلاعات را مدیریت می‌کنند و به‌روزرسانی حافظه سلولی به شکل زیر انجام می‌شود:

$$c_t = f_t c_{t-1} + i_t \tilde{c}_t$$

$$h_t = o_t \tanh(c_t)$$

مدل CNN با کانولوشن یک‌بعدی برای استخراج الگوهای محلی میان ویژگی‌های مجاور استفاده شد و عملیات کانولوشن به صورت زیر تعریف گردید:

$$y(i) = \sum_{k=1}^K x(i+k)w(k)$$

در کنار این مدل‌ها، ResMLP به عنوان نسخه بهبود یافته MLP با اتصال باقی مانده به کار گرفته شد تا جریان گرادیان پایدارتر شود و مدل بتواند نگاشت‌های پیچیده‌تری را یاد بگیرد:

$$x_{out} = F(x) + x$$

پس از آموزش مدل‌های پایه، خروجی احتمالاتی آن‌ها به عنوان ورودی وارد فرایادگیر شد. در این پژوهش، جنگل تصادفی با ۲۰۰ درخت تصمیم به عنوان فرایادگیر انتخاب شد، زیرا توانایی بالایی در ترکیب خروجی مدل‌های مختلف، کاهش واریانس و بهبود تعمیم‌پذیری دارد. پیش‌بینی نهایی مدل از طریق رأی‌گیری یا تجمیع خروجی درخت‌ها انجام شد:

$$\hat{y} = \text{majority vote}(h_1(x), h_2(x), \dots, h_N(x))$$

یا به صورت میانگین خروجی درخت‌ها:

$$\hat{y} = \frac{1}{N} \sum_{i=1}^N T_i(Z)$$

برای ارزیابی عملکرد مدل‌ها، معیارهای دقت، حساسیت، صحت، امتیاز F_1 ، میانگین خطای مطلق و ریشه میانگین مربعات خطا استفاده شدند. دقت کلی مدل از نسبت نمونه‌های درست پیش‌بینی شده به کل نمونه‌ها محاسبه شد. حساسیت و صحت نیز برای هر کلاس بر اساس مقادیر مثبت درست، مثبت کاذب و منفی کاذب تعیین شدند:

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

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

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

همچنین برای بررسی خطای پیش‌بینی، دو معیار زیر به کار رفتند:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

در نهایت، پیچیدگی محاسباتی مدل نیز بررسی شد. هزینه آموزش هر مدل عمیق تابعی از تعداد دوره‌های آموزشی، تعداد نمونه‌ها، اندازه دسته و تعداد پارامترهاست و به صورت تقریبی چنین بیان می‌شود:

$$O\left(E \cdot \frac{N}{B} \cdot P\right)$$

در این رابطه، E تعداد دوره‌های آموزشی، N تعداد نمونه‌ها، B اندازه دسته و P تعداد پارامترهای قابل آموزش است. از آنجا که مدل‌های پایه می‌توانند به صورت موازی آموزش داده شوند، پیچیدگی مؤثر کل سیستم به بیشترین پیچیدگی میان مدل‌های پایه به علاوه هزینه فرایادگیر وابسته است:

$$O(\max(P_{models}) + RF)$$

بر این اساس، روش پیشنهادی ضمن بهره‌گیری از چندین مدل عمیق، با استفاده از ساختار پشته‌ای و فرایادگیر جنگل تصادفی توانست تعادلی میان دقت پیش‌بینی، پایداری عملکرد و کارایی محاسباتی ایجاد کند.

یافته‌ها

همانطور که اشاره شد در روش پیشنهادی یک مدل مبتنی بر یادگیری ماشین برای پیش‌بینی موفقیت تحول دیجیتال ارائه شده است که به بررسی نقش چابکی سازمانی می‌پردازد. در این روش از مجموعه داده استاندارد تحول دیجیتال، به عنوان ورودی روش‌های یادگیری ماشین مورد استفاده قرار گرفته است. مجموعه داده حاضر دارای ۹ ویژگی است که جدول ۱ ویژگی‌های مربوط به این مجموعه داده نشان داده شده است.

جدول ۱- ویژگی‌های داده استاندارد تحول دیجیتال

شماره ویژگی	عنوان ویژگی	شماره ویژگی	عنوان ویژگی
۱	Industry	۶	Impact on Efficiency (%)
۲	Company Size	۷	Digital Skills Training
۳	Digital Tools Adopted	۸	Customer Engagement Change (%)
۴	Year of Adoption	۹	Geographic Region
۵	Impact on Revenue (%)		


همانطور که در بخش‌های قبلی اشاره شد، در روش پیشنهادی یک شاخص چابکی سازمانی با ترکیب خطی ویژگی‌های اندازه سازمان، زمان پذیرش فناوری‌های دیجیتال، برنامه‌های آموزشی مهارت‌های دیجیتال، تعداد ابزارهای دیجیتال و تغییر در تعامل مشتری ارائه شد. همچنین ویژگی‌های تأثیر بر بازدهی و کارایی به منظور تعیین ویژگی هدف برای روش‌های طبقه‌بندی، در سه خوشه پایین، متوسط و بالا خوشه بندی شد. در ادامه این بخش به ارزیابی روش پیشنهادی بر اساس معیارهای ارزیابی مطرح شده خواهیم پرداخت.

در این بخش توضیح داده شده که برای سنجش عملکرد مدل پیشنهادی، از چهار شاخص ارزیابی مبتنی بر داده‌های دارای برچسب استفاده شده است. این چهار معیار شامل دقت، حساسیت، صحت و معیار F هستند که هر کدام جنبه متفاوتی از عملکرد مدل را منعکس می‌کنند. دقت نشان می‌دهد که مدل در مجموع چه نسبتی از نمونه‌ها را به درستی طبقه‌بندی کرده است و بنابراین نمایی کلی از میزان صحیح بودن پیش‌بینی‌ها ارائه می‌دهد. حساسیت بیان می‌کند که مدل تا چه اندازه توانایی تشخیص نمونه‌های مثبت واقعی را دارد و درواقع نشان می‌دهد چند مورد از نمونه‌هایی که باید مثبت تشخیص داده شوند توسط مدل شناسایی شده‌اند. صحت نیز معیاری است که کیفیت پیش‌بینی‌های مثبت مدل را بازتاب می‌دهد؛ به این معنی که از میان نمونه‌هایی که مدل آن‌ها را مثبت اعلام کرده، چه تعداد واقعاً مثبت بوده‌اند. در نهایت معیار F که ترکیبی موزون از صحت و حساسیت است، برای زمانی به کار می‌رود که نیاز به یک معیار موازنه‌کننده بین این دو شاخص وجود دارد و امکان سنجش دقیق‌تر در شرایط


داده‌های نامتوازن را فراهم می‌کند. مجموعه این چهار معیار باعث می‌شود ارزیابی جامع‌تری از وضعیت عملکرد مدل صورت گیرد و نقاط قوت و ضعف آن با دقت بیشتری آشکار شود.

از سوی دیگر، در حوزه یادگیری ماشین معمول است که یک مدل فقط یک بار آموزش داده نشود، زیرا بسیاری از الگوریتم‌ها در مراحل مختلف آموزش شامل عناصر تصادفی هستند؛ مانند مقداردهی اولیه وزن‌ها، ترتیب ارائه نمونه‌ها و حتی تقسیم‌بندی داده‌ها به مجموعه‌های آموزش و آزمون. این تصادفی‌بودن می‌تواند باعث ایجاد نوسان در نتایج شود و اگر تنها یک بار اجرا صورت گیرد، نمی‌توان مطمئن بود که نتیجه به‌دست‌آمده منعکس‌کننده عملکرد واقعی مدل است. به همین دلیل، پژوهشگران معمولاً پیاده‌سازی را چندین مرتبه تکرار می‌کنند تا اثرات ناشی از شانس یا نمونه‌بندی محدود کاهش یابد. این تکرارها کمک می‌کند که میانگین نتایج، تصویری پایدارتر و قابل اعتمادتر از توانایی مدل ارائه دهد و احتمال خطاهای ناشی از اجرای اتفاقی کاهش پیدا کند. به بیان دیگر، اجرای چندباره مدل باعث می‌شود ارزیابی دقیق‌تر، منصفانه‌تر و نزدیک‌تر به عملکرد واقعی آن باشد.

در این پژوهش نیز به‌منظور افزایش اعتبار نتایج، فرآیند آموزش و ارزیابی ۳۰ بار تکرار شده است. در هر بار اجرا، مقادیر مربوط به چهار معیار دقت، حساسیت، صحت و معیار F ثبت شده و سپس میانگین این مقادیر به‌عنوان خروجی نهایی در تحلیل‌ها مورد استفاده قرار گرفته است. برای نمایش بصری رفتار مدل در این تکرارها، در شکل ۲ قسمت (الف)، روند تغییرات میانگین معیار دقت در طول این ۳۰ اجرا نشان داده شده است و در قسمت (ب) همین شکل، توزیع کلی مقادیر دقت در قالب نمودار جعبه‌ای ترسیم شده است تا پراکندگی، میانه و نقاط پرت به‌خوبی قابل مشاهده باشد. همچنین در شکل‌های ۳ تا ۵ همین الگو برای سه معیار دیگر یعنی حساسیت، صحت و معیار F ارائه شده است تا امکان مقایسه و تحلیل دقیق‌تر عملکرد مدل در تمامی معیارها فراهم شود. این نمایش‌ها کمک می‌کنند که پژوهشگر درک واضح‌تری از پایداری نتایج، میزان تغییرپذیری مدل و کیفیت عملکرد آن در شرایط مختلف کسب کند.




الف




ب

شکل ۲- معیار دقت الف) میانگین مراحل اجرا ب) میانگین کل

بررسی نتایج ارائه شده در شکل ۲ نشان می‌دهد که عملکرد مدل‌های مختلف در معیار دقت الگوی نسبتاً متمایزی را در طول تکرارهای آزمایش از خود نشان می‌دهد. در نمودار بخش (الف) مشاهده می‌شود که اغلب مدل‌ها با افزایش تعداد اجراها روندی افزایشی و نسبتاً پایدار را تجربه کرده‌اند، به‌طوری که مدل‌های MLP، RNN و CNN از همان مراحل ابتدایی به مقادیر بالایی از دقت دست یافته و در ادامه نیز با نوسان اندکی در محدوده‌ای نزدیک به ۰.۹۵ تا ۰.۹۷ تثبیت شده‌اند. در مقابل، مدل ResMLP هرچند روندی تدریجی و رو به رشد را نشان می‌دهد، اما مقدار دقت آن در بیشتر تکرارها پایین‌تر از سایر مدل‌های پایه قرار گرفته است. از سوی دیگر، عملکرد مدل LSTM به‌طور محسوسی ضعیف‌تر از سایر روش‌ها بوده و با وجود بهبود تدریجی در طول اجراها، همچنان در بازه‌ای به مراتب پایین‌تر از دیگر مدل‌ها قرار دارد که می‌تواند بیانگر محدودیت این معماری در استخراج الگوهای مؤثر از داده‌های مورد بررسی باشد. نکته قابل توجه در این نمودار، برتری مدل فرایادگیر است که با ترکیب خروجی مدل‌های پایه توانسته در اغلب اجراها بیشترین مقدار دقت را کسب کند و به مقدار میانگین حدود ۰.۹۵۵ دست یابد. این الگو در نمودار جعبه‌ای بخش (ب) نیز به‌وضوح تأیید می‌شود؛ به‌گونه‌ای که توزیع مقادیر دقت برای مدل فرایادگیر در مقایسه با سایر مدل‌ها در سطح بالاتری قرار گرفته و دامنه پراکندگی آن نیز محدودتر است که نشان‌دهنده پایداری و قابلیت تعمیم بهتر این روش است. همچنین مشاهده می‌شود که مدل‌های MLP، RNN و CNN توزیعی نسبتاً فشرده و نزدیک به یکدیگر دارند، در حالی که LSTM دارای پراکندگی بیشتر و مقادیر پایین‌تری است. در مجموع، تحلیل این نتایج نشان می‌دهد که استفاده از رویکرد پشته‌ای و ترکیب چند مدل یادگیری عمیق می‌تواند به بهبود محسوس دقت پیش‌بینی و افزایش ثبات عملکرد سیستم در مقایسه با استفاده از مدل‌های منفرد منجر شود.



الف




ب


شکل ۳- معیار حساسیت (الف) میانگین مراحل اجرا (ب) میانگین کل

تحلیل نتایج ارائه شده در شکل ۳ نشان می‌دهد که مدل‌های مورد بررسی از نظر توانایی شناسایی نمونه‌های مثبت رفتارهای متفاوتی را در طول تکرارهای آزمایش از خود نشان داده‌اند. در نمودار بخش (الف)، روند تغییرات حساسیت در طی اجراهای متوالی بیانگر آن است که اغلب مدل‌ها به تدریج به عملکردی پایدارتر و دقیق‌تر دست یافته‌اند. به‌طور مشخص، مدل‌های MLP، RNN و CNN از همان مراحل ابتدایی مقادیر نسبتاً بالایی

از حساسیت را ثبت کرده‌اند و با افزایش تعداد تکرارها این مقادیر به صورت تدریجی افزایش یافته و در بازه‌ای نزدیک به ۰.۹۵ تا حدود ۰.۹۷ تثبیت شده‌اند. در مقابل، مدل ResMLP اگرچه روندی صعودی را در طول اجراها نشان می‌دهد، اما مقدار حساسیت آن در اکثر مراحل اندکی پایین‌تر از سایر مدل‌های پایه قرار دارد. همچنین مدل LSTM در مقایسه با دیگر معماری‌ها عملکرد ضعیف‌تری داشته و مقادیر حساسیت آن حتی با وجود بهبود تدریجی همچنان در سطحی به مراتب پایین‌تر باقی مانده است که می‌تواند نشان‌دهنده محدودیت این ساختار در شناسایی صحیح نمونه‌های مثبت در داده‌های مورد مطالعه باشد. در همین حال، مدل فرایادگیر که بر اساس ترکیب خروجی مدل‌های پایه عمل می‌کند، در اکثر اجراها عملکرد برتری را نشان داده و به مقدار میانگین حدود ۰.۹۵۴ دست یافته است. این الگو در نمودار جعبه‌ای بخش (ب) نیز قابل مشاهده است؛ به گونه‌ای که توزیع مقادیر حساسیت برای مدل فرایادگیر در مقایسه با سایر مدل‌ها در سطح بالاتری قرار گرفته و دامنه تغییرات آن نسبتاً محدود است که بیانگر پایداری بیشتر این روش در پیش‌بینی نمونه‌های مثبت است. افزون بر این، نزدیکی توزیع مقادیر در مدل‌های MLP، RNN و CNN حاکی از عملکرد نسبتاً مشابه آن‌ها در این معیار است، در حالی که پراکندگی بیشتر و مقادیر پایین‌تر در مدل LSTM نشان‌دهنده ناپایداری و کارایی کمتر آن در این مسئله است. در مجموع، این نتایج بیانگر آن است که بهره‌گیری از رویکرد ترکیبی و استفاده از فرایادگیر می‌تواند توانایی سیستم در شناسایی صحیح نمونه‌های مثبت را بهبود داده و عملکردی پایدارتر نسبت به استفاده از مدل‌های منفرد فراهم کند.



الف




ب


شکل ۴- معیار صحت الف) میانگین مراحل اجرا ب) میانگین کل

نتایج ارائه‌شده در شکل ۴ نشان می‌دهد که الگوهای عملکرد مدل‌ها در شناسایی صحیح نمونه‌های مثبت پیش‌بینی‌شده، تفاوت‌های معناداری را طی تکرارهای آزمایش آشکار می‌سازند. در نمودار بخش (الف)، بیشتر مدل‌ها روندی افزایشی و نسبتاً پایدار را تجربه کرده‌اند؛ به گونه‌ای که مدل‌های MLP، RNN و CNN از همان تکرارهای ابتدایی مقادیر بالایی از صحت را ثبت کرده و با ادامه اجراها به سطوحی نزدیک به ۰.۹۵ دست یافته‌اند. مدل ResMLP نیز هرچند با سرعتی آهسته‌تر پیش می‌رود، اما در نهایت به محدوده‌ای قابل قبول نزدیک می‌شود؛ با این حال هنوز کمی پایین‌تر

از مدل‌های مذکور باقی می‌ماند. در مقابل، مدل LSTM عملکردی به مراتب ضعیف‌تر داشته و حتی با وجود روند بهبود، مقدار صحت آن در اغلب مراحل حدود ۰.۷۰ تا ۰.۷۵ باقی می‌ماند که حاکی از دشواری این معماری در اجتناب از خطای مثبت کاذب در داده‌های مورد مطالعه است. نکته برجسته در این شکل، برتری مدل فرایادگیر است که به واسطه ترکیب خروجی مدل‌های پایه توانسته میانگین صحتی نزدیک به ۰.۹۵۳ کسب کند و در تمام تکرارها در سطحی پایدار و بالاتر از مدل‌های منفرد باقی بماند. این الگو در نمودار جعبه‌ای بخش (ب) نیز به وضوح دیده می‌شود؛ به طوری که توزیع مقادیر صحت برای مدل فرایادگیر متراکم‌تر و در سطح بالاتری قرار گرفته و نوسانات کمتری را نسبت به سایر مدل‌ها نشان می‌دهد. همچنین نزدیکی دامنه تغییرات مدل‌های MLP، RNN و CNN بیانگر پایداری قابل قبول آن‌هاست، در حالی که پراکندگی گسترده و مقادیر پایین LSTM بیانگر ضعف و ناپایداری این مدل در معیار صحت است. در مجموع، نتایج شکل نشان می‌دهد که استفاده از رویکرد پشته‌ای نه تنها موجب ارتقای سطح صحت پیش‌بینی شده است، بلکه پایداری و قابلیت اتکای سیستم را نیز نسبت به استفاده از مدل‌های تکی به شکل قابل توجهی افزایش داده است.



الف




ب

شکل ۷- معیار F (الف) میانگین مراحل اجرا (ب) میانگین کل


بررسی نتایج ارائه شده در شکل ۵ نشان می‌دهد که مدل‌های مورد استفاده در پژوهش از نظر توازن میان صحت و حساسیت رفتاری متفاوت اما قابل تفسیر ارائه کرده‌اند. در نمودار بخش (الف)، سه مدل MLP، RNN و CNN از همان ابتدای اجرا مقادیر نسبتاً بالایی را ثبت کرده و با گذشت تکرارها روندی افزایشی و پایدار را تجربه نموده‌اند؛ به گونه‌ای که میانگین آن‌ها در محدوده‌ای نزدیک به ۰.۹۴ تا ۰.۹۵ تثبیت شده است. مدل ResMLP نیز اگرچه با شیبی آرام‌تر حرکت می‌کند، اما در نهایت به سطح قابل قبولی نزدیک می‌شود و تنها اندکی کمتر از مدل‌های یادشده عمل می‌کند. در مقابل، مدل LSTM ضعیف‌ترین عملکرد را ارائه داده و حتی با وجود افزایش تدریجی مقدار F، همچنان در بازه‌ای به مراتب

پایین تر از سایر مدل‌ها باقی می‌ماند؛ موضوعی که بیانگر دشواری این مدل در ایجاد تعادل مؤثر میان شناسایی نمونه‌های مثبت و جلوگیری از پیش‌بینی‌های نادرست است. در این میان، مدل فرایادگیر که بر پایه ترکیب خروجی مدل‌های پایه شکل گرفته، عملکردی به مراتب بهتر از سایر تکنیک‌ها نشان می‌دهد و با میانگین حدود ۰.۹۵۳ در تمامی اجراها در سطحی بالاتر و پایدارتر قرار می‌گیرد. این برتری در نمودار جعبه‌ای بخش (ب) نیز به وضوح قابل مشاهده است؛ به طوری که گستره تغییرات مدل فرایادگیر کوچک‌تر و توزیع آن متراکم‌تر است و نشان می‌دهد که سیستم ترکیبی نه تنها دقیق‌تر عمل کرده، بلکه ثبات بیشتری نیز دارد. در مقابل، پراکندگی وسیع و میانه پایین‌تر مربوط به LSTM به روشنی ضعف این مدل را در حفظ تعادل عملکردی نشان می‌دهد. در مجموع، تحلیل شکل بیانگر آن است که استفاده از ساختار پشته‌ای موجب ارتقای قابل ملاحظه معیار F شده و نسبت به مدل‌های منفرد توانسته است پیش‌بینی‌هایی پایدارتر و متوازن‌تر ارائه دهد.

در رویکرد ارائه‌شده در این پژوهش، صرفاً به معیارهای مبتنی بر برچسب مانند دقت، صحت، یادآوری و معیار F بسنده نشده است؛ بلکه برای آن که عملکرد مدل‌ها از منظر پیش‌بینی کمی نیز سنجیده شود، از دو شاخص خطا محور MAE و RMSE استفاده شده است. بهره‌گیری همزمان از معیارهای طبقه‌بندی و معیارهای خطا این امکان را فراهم می‌کند که تصویر جامع‌تری از کیفیت خروجی مدل‌ها به دست آید؛ به بیان دیگر، این شیوه روشن می‌سازد که هر مدل علاوه بر توانایی دسته‌بندی صحیح نمونه‌ها، تا چه اندازه خطای کمتری در برآورد میزان موفقیت تحول دیجیتال دارد و در نتیجه برای کاربردهای تصمیم‌گیری در محیط‌های واقعی قابل اعتمادتر است. در واقع، ترکیب این دو دسته معیارها باعث می‌شود نقاط قوت و ضعف مدل‌ها از زوایای متفاوت دیده شود و ارزیابی محدود به نتایج طبقه‌بندی صرف نباشد، بلکه دقت ریاضی مدل‌ها نیز مدنظر قرار گیرد. در ادامه، برای نمایش رفتار مدل‌ها در طول تکرارهای متعدد، شکل ۶ (الف) میانگین مقادیر MAE را در هر مرحله اجرا ارائه می‌کند و با ترسیم روند تغییرات، نشان می‌دهد کدام یک از مدل‌ها در کاهش میانگین خطای MAE عملکرد باثبات‌تری دارند. شکل ۶ (ب) نیز میانگین نهایی تمام اجراها را به صورت نمودار جعبه‌ای نمایش می‌دهد تا امکان مقایسه میزان پراکندگی و ثبات خطا میان مدل‌ها فراهم شود. چنین ترکیبی از نمودارهای روند و نمودارهای توصیفی توزیع، تحلیل دقیق‌تری از رفتار مدل‌ها ارائه می‌دهد و به‌ویژه برای بررسی نوسانات خطا در مدل‌های یادگیری عمیق ضروری است. افزون بر این، شکل ۷ نتایج مشابهی را برای معیار RMSE نمایش می‌دهد؛ شاخصی که با توجه به حساسیت آن نسبت به خطاهای بزرگ، به خوبی نشان می‌دهد مدل‌ها در مواجهه با انحراف‌های شدید چه عملکردی داشته‌اند. مشاهده این دو معیار در کنار هم، به شکل معناداری به تحلیل گران‌کمک می‌کند تا پایداری، دقت و قابلیت اتکای نهایی مدل‌های مورد استفاده را تشخیص دهند.




الف




ب

شکل ۶- معیار صحت الف) میانگین مراحل اجرا ب) میانگین کل



الف



ب

شکل ۷- معیار صحت الف) میانگین مراحل اجرا ب) میانگین کل

در تحلیل نتایج شکل‌های ۶ و ۷، مشخص می‌شود که مدل‌های یادگیری ماشین هر کدام در کاهش میزان خطاهای پیش‌بینی، عملکرد متفاوتی را از خود نشان داده‌اند. در نمودارهای سمت چپ، روند کاهش میانگین خطای MAE و RMSE در طی تکرارهای مختلف، نشان می‌دهد که مدل‌های عمیق مانند ResMLP و CNN عملکرد پایدارتری نسبت به دیگر مدل‌ها دارند؛ به گونه‌ای که در مراحل پایانی مجموعه تکرارها، مقدار این شاخص‌ها به مقادیر بسیار پایین‌تری رسیده است، که این امر بیانگر قدرت بالاتر آن‌ها در برآورد میزان موفقیت تحول دیجیتال است. در مقابل، مدل LSTM در هر دو معیار، میانگین خطای نسبتاً بالاتری را نشان می‌دهد که ممکن است ناشی از ضعف در استخراج وابستگی‌های بلندمدت باشد. در نمودارهای سمت راست، با استفاده از جعبه‌ای، توزیع خطاها و میزان واریانس هر مدل به وضوح قابل مشاهده است؛ جایی که مدل‌های ResMLP، CNN و Meta توزیع خطاهای نسبتاً فشرده و مقیاس پایینی دارند، که نشان از پایداری و اطمینان بیشتر در نتایج آن‌ها است. برعکس، مدل LSTM در این نمودار پراکندگی بیشتری دارد و تفاوت قابل توجهی در نوسانات خطا نشان می‌دهد. در مجموع، تحلیل این نمودارها نشان می‌دهد که انتخاب مدل‌های عمیق و خصوصاً ساختار ResMLP و CNN، می‌تواند در کاهش خطاهای پیش‌بینی بسیار مؤثر باشد و در نتیجه، دقت


برآوردهای مرتبط با موفقیت تحول دیجیتال در سازمان‌ها را به شکل قابل توجهی ارتقا دهد. در جدول ۲ مقادیر میانگین معیارهای ارزیابی نشان داده شده است.

جدول ۲- مقادیر میانگین کل معیارهای ارزیابی

Model	Accuracy	Precision	Recall	F1	MAE	RMSE
ResMLP	۰.۹۲۵۴	۰.۹۲۴۷	۰.۹۲۶۱	۰.۹۲۳۵	۰.۰۹۷۰	۰.۱۳۲۰
MLP	۰.۹۶۴۸	۰.۹۶۳۲	۰.۹۶۵۰	۰.۹۶۳۳	۰.۰۴۲۴	۰.۰۵۳۷
RNN	۰.۹۶۴۰	۰.۹۶۵۴	۰.۹۶۳۷	۰.۹۶۳۱	۰.۰۴۲۰	۰.۰۴۶۶
LSTM	۰.۷۳۱۲	۰.۷۲۳۶	۰.۷۲۲۸	۰.۷۱۱۲	۰.۲۹۸۸	۰.۳۵۱۷
CNN	۰.۹۶۶۸	۰.۹۶۶۱	۰.۹۶۶۳	۰.۹۶۴۴	۰.۰۳۶۷	۰.۰۴۴۳
Meta (Stacking)	۰.۹۶۸۶	۰.۹۶۷۶	۰.۹۶۸۰	۰.۹۶۷۰	۰.۰۳۵۵	۰.۰۳۷۳

با توجه به نتایج ارائه شده در جدول ۲، می‌توان دریافت که عملکرد مدل‌های مختلف یادگیری عمیق در پیش‌بینی موفقیت تحول دیجیتال تفاوت قابل توجهی با یکدیگر دارد. مدل‌های CNN، Meta و RNN با دستیابی به مقادیر بالای Accuracy، Precision، Recall و F1 و در عین حال ثبت کمترین میزان خطای MAE و RMSE، نشان می‌دهند که از ثبات و قابلیت تعمیم‌یابی بیشتری برخوردارند. این الگوها نه تنها خطای پیش‌بینی را به حداقل رسانده‌اند، بلکه توانسته‌اند توازن مطلوبی میان تشخیص درست نمونه‌های مثبت و منفی برقرار کنند. در مقابل، مدل LSTM با وجود ساختار توالی‌محورش، عملکرد نسبتاً ضعیف‌تری داشته و مقادیر پایین شاخص‌های طبقه‌بندی و خطاهای قابل توجه MAE و RMSE بیانگر آن است که این مدل توانایی محدودی در استخراج الگوهای داده‌های این حوزه داشته است. از سوی دیگر، مدل‌های ResMLP و MLP در سطحی میانی قرار گرفته و با وجود دقت مناسب، هنوز فاصله‌ای با مدل‌های برتر دارند. در مجموع، این نتایج نشان می‌دهد که بهره‌گیری از معماری‌های عمیق‌تر و تجمیعی مانند CNN و Meta می‌تواند به شکل معناداری کیفیت برآورد و قابلیت اطمینان پیش‌بینی‌ها را در سناریوهای مرتبط با تحول دیجیتال ارتقا دهد.

در این بخش از مقاله، اعتبارسنجی نتایج مدل‌های یادگیری ماشین ارائه شده با هدف پیش‌بینی موفقیت تحول دیجیتال از طریق مقایسه با مطالعات و روش‌های پیشین صورت می‌گیرد. برای این منظور، معیارهای ارزیابی مبتنی بر برجسب مانند دقت، یادآوری، دقت مثبت و معیار F که در این پژوهش محاسبه شده‌اند، با مقادیر گزارش شده در سایر مقالات مرتبط مورد مقایسه قرار داده شده است. این مقایسه نه تنها نشان‌دهنده میزان بهبود عملکرد مدل‌های پیشنهادی در برابر رویکردهای قبلی است، بلکه اعتبار علمی و کاربردی بودن روش ارائه شده را نیز تقویت می‌کند و امکان تحلیل دقیق‌تر نقاط قوت و ضعف مدل در زمینه پیش‌بینی تحول دیجیتال را فراهم می‌سازد. در شکل ۱۰ مقایسه روش پیشنهادی با روش‌های پیشین از نظر معیارهای ارزیابی نشان داده شده است.



شکل ۸- مقایسه روش پیشنهادی با روش‌های پیشین

بررسی مقایسه‌ای میان مدل‌های پیشنهادی این پژوهش و نتایج گزارش شده در مطالعات پیشین نشان می‌دهد که معماری‌های مبتنی بر یادگیری عمیق، به‌ویژه CNN، RNN و Meta، از نظر چهار شاخص Accuracy، Precision، Recall و F-Score عملکردی کاملاً رقابتی و در بسیاری موارد برتر ارائه کرده‌اند. این مدل‌ها با دستیابی به مقادیر بالای دقت و تعادل مناسب میان نرخ تشخیص درست و خطا، توانسته‌اند از اغلب الگوریتم‌های کلاسیک مانند Logistic Regression، Naïve Bayes و در برخی موارد حتی از مدل‌های درخت‌محور نظیر Random Forest و Gradient Boosting فراتر عمل کنند. هرچند برخی روش‌های گزارش شده در پژوهش‌های گذشته، مانند KNN در مطالعه

Shafiabady و همکاران، در دقت کلی عملکرد قابل توجهی دارند، اما مدل‌های عمیق مورد استفاده در این تحقیق ثبات بیشتری در تمام معیارها نشان داده‌اند. در مقابل، مدل‌هایی همچون GLM، LSTM و برخی نسخه‌های SVM و DL در مطالعات دیگر، به دلیل محدودیت در استخراج الگوهای پیچیده، مقادیر پایین‌تری از شاخص‌های عملکردی را ثبت کرده‌اند. در مجموع، این نتایج بیانگر آن است که بهره‌گیری از معماری‌های چندلایه و ترکیبی می‌تواند توان تشخیص مدل را در حوزه تحول دیجیتال به شکل محسوسی افزایش دهد و زمینه دستیابی به پیش‌بینی‌های قابل اعتمادتر را فراهم سازد.

بحث و نتیجه‌گیری

نتایج این پژوهش نشان داد که چارچوب پیشنهادی مبتنی بر یادگیری عمیق پشته‌ای و فرایادگیری جمعی توانسته است با دقت بسیار بالا، موفقیت تحول دیجیتال سازمان‌ها را پیش‌بینی کند و در مقایسه با مدل‌های منفرد عملکرد برتری داشته باشد. یافته‌ها بیانگر آن بود که ترکیب چند معماری یادگیری عمیق شامل MLP، RNN، LSTM، CNN و ResMLP در کنار فرایادگیر جنگل تصادفی، موجب استخراج الگوهای پیچیده‌تر و افزایش پایداری پیش‌بینی شده است. عملکرد بالای مدل پیشنهادی، به‌ویژه در معیارهای دقت، حساسیت، صحت و امتیاز F1، نشان می‌دهد که استفاده از معماری‌های یادگیری جمعی می‌تواند محدودیت‌های مدل‌های تک‌ساختاری را کاهش دهد و در تحلیل پدیده‌های پیچیده سازمانی مانند تحول دیجیتال مؤثر واقع شود. این نتیجه با پژوهش‌هایی همسو است که نشان داده‌اند مدل‌های یادگیری جمعی و یادگیری عمیق در مسائل دارای روابط غیرخطی و داده‌های چندبعدی، عملکرد دقیق‌تری نسبت به روش‌های منفرد دارند (Einy et al., 2021; Rane et al., 2024). همچنین یافته‌های پژوهش حاضر از دیدگاه مطالعاتی که بر اهمیت تحلیل پیش‌بینانه در مدیریت راهبردی و تحول دیجیتال تأکید داشته‌اند حمایت می‌کند؛ زیرا نشان می‌دهد مدل‌های مبتنی بر داده می‌توانند درک دقیق‌تری از مسیر موفقیت تحول دیجیتال ارائه دهند (Iscaro et al., 2022; Raeesi, 2025). (Vanani et al., 2025).

یکی از مهم‌ترین یافته‌های این پژوهش، نقش معنادار شاخص چابکی سازمانی در بهبود عملکرد پیش‌بینی بود. نتایج نشان دادند که افزودن شاخص OAI به مدل موجب افزایش دقت و کاهش خطای پیش‌بینی شده است؛ موضوعی که نشان می‌دهد چابکی سازمانی یکی از متغیرهای کلیدی در موفقیت تحول دیجیتال محسوب می‌شود. این یافته با مطالعات نظری و تجربی پیشین همسو است که چابکی سازمانی را به‌عنوان یک قابلیت راهبردی برای پاسخ‌گویی سریع به تغییرات فناورانه و محیطی معرفی کرده‌اند (Gong & Ribiere, 2025; Syarkani, 2025). پژوهش حاضر این دیدگاه را از سطح نظری فراتر برده و نشان داده است که چابکی سازمانی نه تنها مفهومی مدیریتی، بلکه متغیری قابل اندازه‌گیری و قابل استفاده در مدل‌های پیش‌بینی است. این نتیجه با یافته‌های پژوهش‌های انجام‌شده در بازارهای نوظهور نیز همخوانی دارد که نشان داده‌اند سازمان‌های دارای ظرفیت‌های چابک، در بهره‌برداری از تحول دیجیتال موفق‌تر عمل می‌کنند (Nguyen et al., 2025). همچنین، مطالعات مرتبط با بنگاه‌های

کوچک و متوسط تأکید کرده‌اند که سازمان‌های منعطف و یادگیرنده در برابر تغییرات دیجیتال مقاومت کمتری نشان می‌دهند و توان سازگاری بیشتری دارند (Pelletier et al., 2025; Purnomo et al., 2024).

یافته‌های پژوهش نشان داد که مدل فرایادگیر مبتنی بر جنگل تصادفی عملکرد پایدارتری نسبت به مدل‌های پایه داشته است. این نتیجه را می‌توان ناشی از توانایی جنگل تصادفی در ترکیب الگوهای استخراج شده توسط مدل‌های مختلف دانست. در معماری پیشنهادی، هر مدل پایه بخشی از ساختار داده‌ها را استخراج می‌کرد؛ برای مثال، MLP در شناسایی روابط غیرخطی عمومی، RNN و LSTM در کشف وابستگی‌های ترتیبی، و CNN در استخراج الگوهای محلی نقش داشتند. فرایادگیر جنگل تصادفی با تجمع این اطلاعات، توانست تصمیم نهایی دقیق‌تری اتخاذ کند. این موضوع با مطالعاتی که از جنگل تصادفی برای تحلیل داده‌های پیچیده و طبقه‌بندی غیرخطی استفاده کرده‌اند همسو است (Herdiyeni et al., 2026; Liu et al., 2025). همچنین نتایج پژوهش حاضر تأیید می‌کند که رویکردهای پشته‌ای می‌توانند به دلیل هم‌افزایی میان مدل‌ها، در مسائل سازمانی پیچیده عملکرد مؤثرتری داشته باشند (Rane et al., 2024). در واقع، مزیت اصلی معماری پیشنهادی آن است که ضعف یک مدل توسط قابلیت‌های مدل دیگر جبران می‌شود و در نتیجه، سیستم نهایی از قدرت تعمیم بیشتری برخوردار می‌گردد.

یافته‌های مربوط به خوشه‌بندی K-Means نیز نشان داد که استفاده از شاخص‌های عملکردی مانند درآمد و کارایی برای استخراج سطوح موفقیت تحول دیجیتال، رویکردی مناسب و منطقی است. تقسیم سازمان‌ها به سه سطح پایین، متوسط و بالا موجب شد مدل بتواند تفاوت میان سازمان‌های دارای بلوغ دیجیتال متفاوت را به‌خوبی یاد بگیرد. این نتیجه با مطالعاتی همسو است که خوشه‌بندی را ابزاری مؤثر برای کشف ساختارهای پنهان داده و طبقه‌بندی سازمان‌ها بر اساس ویژگی‌های عملکردی معرفی کرده‌اند (Suyal & Sharma, 2024; Xie et al., 2023). همچنین، پژوهش‌های مرتبط با تحلیل بلوغ دیجیتال و GovTech نیز نشان داده‌اند که ارزیابی موفقیت تحول دیجیتال نیازمند دسته‌بندی سازمان‌ها بر اساس شاخص‌های واقعی عملکرد است (AlMurtadha, 2024). در این پژوهش نیز استفاده از داده‌های واقعی عملکردی به جای برچسب‌های ذهنی یا خوداظهاری، موجب شد مدل از اعتبار بیشتری برخوردار باشد و توان تعمیم آن افزایش یابد.

نتایج مرحله پیش‌پردازش نیز اهمیت بالای آماده‌سازی داده‌ها را در عملکرد مدل‌های یادگیری عمیق نشان داد. استفاده از روش‌های استانداردسازی و کدگذاری One-Hot موجب شد داده‌ها در قالبی همگن و قابل‌پردازش برای شبکه‌های عصبی قرار گیرند. این موضوع با پژوهش‌هایی همسو است که نشان داده‌اند کیفیت داده و نحوه پیش‌پردازش تأثیر مستقیمی بر همگرایی و دقت مدل‌های یادگیری ماشین دارد (Izonin et al., 2022; Kujawa et al., 2025). افزون بر این، پژوهش‌های مبتنی بر مدل‌های ترکیبی و داده‌های پزشکی و اینترنت اشیا نیز نشان داده‌اند که نرمال‌سازی و تبدیل مناسب داده‌ها می‌تواند عملکرد طبقه‌بندی را به‌طور قابل توجهی افزایش دهد (Nanehkaran, Licai, Chen, Jamel, 2024).

(et al., 2022; Nanehkaran, Licai, Chen, Zhongpan, et al., 2022). بنابراین، بخشی از موفقیت مدل پیشنهادی را می‌توان ناشی

از ساختار دقیق پیش‌پردازش و تبدیل داده‌ها دانست.

یافته‌های این پژوهش همچنین نشان می‌دهد که موفقیت تحول دیجیتال بیش از آنکه صرفاً تابع فناوری باشد، به قابلیت‌های سازمانی و مدیریتی وابسته است. بسیاری از سازمان‌ها ممکن است به ابزارهای دیجیتال دسترسی داشته باشند، اما در نبود چابکی، مهارت دیجیتال، فرهنگ نوآورانه و ظرفیت یادگیری، نتوانند از این ابزارها به مزیت رقابتی تبدیل کنند. این نتیجه با مطالعات مرتبط با تحول دیجیتال در صنایع، آموزش عالی، دولت الکترونیک و کسب‌وکارهای کوچک همخوانی دارد که بر نقش عوامل انسانی و سازمانی در موفقیت تحول دیجیتال تأکید کرده‌اند (Eom & Singun, 2025; Lee, 2022; Hendrawan et al., 2024). همچنین، پژوهش‌های مربوط به فرهنگ نوآوری و رهبری پارادوکسیکال نشان می‌دهند که موفقیت دیجیتال نیازمند توانایی سازمان در ایجاد تعادل میان ثبات و تغییر است (Su et al., 2026). بنابراین، یافته‌های این پژوهش تأیید می‌کند که تحول دیجیتال یک پدیده چندبعدی است و تحلیل آن نیازمند ترکیب متغیرهای فناورانه، سازمانی و رفتاری است.

از منظر نظری، پژوهش حاضر چند دستاورد مهم دارد. نخست آنکه مفهوم چابکی سازمانی را از سطح مفهومی به سطح عملیاتی و داده‌محور منتقل کرده و شاخصی کمی برای آن ارائه داده است. دوم آنکه نشان داده است معماری‌های یادگیری عمیق پشته‌ای می‌توانند در تحلیل مسائل مدیریتی و سازمانی، همانند حوزه‌های مهندسی و پزشکی، کارایی بالایی داشته باشند. سوم آنکه این پژوهش پلی میان ادبیات تحول دیجیتال، چابکی سازمانی و یادگیری ماشین ایجاد کرده و نشان داده است که مدل‌های داده‌محور می‌توانند به درک بهتر پویایی‌های سازمانی کمک کنند. این موضوع با مطالعاتی که بر اهمیت استفاده از تحلیل پیش‌بینانه در مدیریت راهبردی تأکید کرده‌اند همسو است (Hossin et al., 2025; Iscaro et al., 2022). افزون بر این، پژوهش حاضر نشان داد که تحلیل تحول دیجیتال را می‌توان از سطح توصیفی و پیمایشی فراتر برد و به سمت مدل‌های پیش‌بینی عملیاتی حرکت کرد.

از منظر کاربردی نیز نتایج این پژوهش اهمیت زیادی دارد. سازمان‌ها می‌توانند از چارچوب پیشنهادی برای ارزیابی میزان آمادگی دیجیتال، تحلیل نقاط ضعف و پیش‌بینی احتمال موفقیت برنامه‌های تحول دیجیتال استفاده کنند. همچنین مدیران قادر خواهند بود با شناسایی مؤلفه‌های اثرگذار بر چابکی سازمانی، سرمایه‌گذاری هدفمندتری در حوزه آموزش، فناوری، زیرساخت و فرهنگ سازمانی انجام دهند. این موضوع به‌ویژه برای سازمان‌هایی که در مراحل اولیه تحول دیجیتال قرار دارند اهمیت دارد؛ زیرا می‌تواند از اتلاف منابع و شکست پروژه‌های دیجیتال جلوگیری کند. مطالعات مرتبط با مدیریت فناوری و تحول دیجیتال نیز تأکید کرده‌اند که تصمیم‌گیری داده‌محور نقش مهمی در موفقیت پروژه‌های دیجیتال دارد (Oh et al., 2022; Weritz et al., 2025). بنابراین، چارچوب پیشنهادی می‌تواند به‌عنوان یک ابزار تصمیم‌یار برای مدیران و سیاست‌گذاران مورد استفاده قرار گیرد.

در مجموع، یافته‌های پژوهش حاضر نشان می‌دهد که ترکیب شاخص‌های سازمانی، خوشه‌بندی عملکردی و معماری یادگیری عمیق پشته‌ای می‌تواند چارچوبی قدرتمند برای پیش‌بینی موفقیت تحول دیجیتال فراهم آورد. مدل پیشنهادی نه تنها از نظر دقت و پایداری عملکرد مناسبی داشت، بلکه توانست نقش متغیرهای سازمانی را در موفقیت تحول دیجیتال به صورت عملیاتی نشان دهد. این نتایج تأیید می‌کند که آینده تحلیل تحول دیجیتال به سمت رویکردهای هوشمند، داده‌محور و مبتنی بر یادگیری جمعی حرکت خواهد کرد و سازمان‌هایی که بتوانند از چنین ابزارهایی استفاده کنند، در محیط رقابتی آینده از مزیت بیشتری برخوردار خواهند بود.

یکی از محدودیت‌های این پژوهش به ماهیت مجموعه داده مورد استفاده بازمی‌گردد؛ زیرا داده‌ها از یک منبع استاندارد ثانویه استخراج شده بودند و امکان کنترل کامل بر نحوه گردآوری، کیفیت اولیه داده‌ها و تنوع صنایع وجود نداشت. همچنین، برخی متغیرهای کیفی مهم مانند فرهنگ سازمانی، سبک رهبری، مقاومت کارکنان و میزان حمایت مدیریتی در مجموعه داده موجود نبودند و بنابراین امکان ورود آن‌ها به مدل فراهم نشد. محدودیت دیگر مربوط به حجم داده‌ها و تنوع جغرافیایی نمونه‌ها بود که ممکن است تعمیم‌پذیری نتایج را به برخی صنایع یا کشورها محدود کند. علاوه بر این، اگرچه معماری یادگیری پشته‌ای عملکرد بالایی داشت، اما پیچیدگی محاسباتی آن نسبت به مدل‌های ساده‌تر بیشتر بود و اجرای آن به منابع پردازشی و تنظیم دقیق پارامترها نیاز داشت.

پیشنهاد می‌شود پژوهش‌های آینده از مجموعه داده‌های بزرگ‌تر و متنوع‌تر شامل صنایع مختلف، سازمان‌های دولتی و خصوصی و محیط‌های جغرافیایی متفاوت استفاده کنند تا قابلیت تعمیم مدل افزایش یابد. همچنین، افزودن متغیرهای رفتاری و فرهنگی مانند سبک رهبری، فرهنگ نوآوری، رضایت کارکنان و مقاومت در برابر تغییر می‌تواند درک جامع‌تری از موفقیت تحول دیجیتال فراهم کند. استفاده از روش‌های پیشرفته‌تر مانند مدل‌های ترنسفورمر، یادگیری تقویتی و مدل‌های توضیح‌پذیر هوش مصنوعی نیز می‌تواند به بهبود دقت و تفسیرپذیری نتایج کمک کند. علاوه بر این، بررسی عملکرد مدل در داده‌های بلادرنگ و محیط‌های واقعی سازمانی می‌تواند گامی مهم در جهت عملیاتی‌سازی چارچوب پیشنهادی باشد.

سازمان‌ها می‌توانند از شاخص چابکی سازمانی به عنوان ابزاری برای سنجش میزان آمادگی دیجیتال خود استفاده کنند و پیش از اجرای پروژه‌های تحول دیجیتال، نقاط ضعف و قوت خود را شناسایی نمایند. مدیران باید توجه داشته باشند که موفقیت تحول دیجیتال صرفاً وابسته به خرید فناوری نیست، بلکه نیازمند توسعه مهارت‌های دیجیتال، ایجاد فرهنگ یادگیری، افزایش انعطاف‌پذیری سازمان و تقویت تعامل کارکنان است. همچنین، استفاده از مدل‌های پیش‌بینی مبتنی بر یادگیری ماشین می‌تواند در تخصیص بهینه منابع، کاهش ریسک پروژه‌های دیجیتال و بهبود تصمیم‌گیری راهبردی مؤثر باشد. پیشنهاد می‌شود سازمان‌ها به سمت ایجاد زیرساخت‌های داده‌محور و سامانه‌های تحلیلی هوشمند حرکت کنند تا بتوانند روند تحول دیجیتال را به صورت مستمر پایش و ارزیابی نمایند.

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

تعارض منافع

در انجام مطالعه حاضر، هیچ گونه تضاد منافی وجود ندارد.

موازین اخلاقی

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

تشکر و قدردانی

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

Extended Abstract

Introduction

Digital transformation has become one of the most critical strategic priorities for organizations operating in increasingly dynamic, uncertain, and technology-driven environments. The rapid expansion of digital technologies, artificial intelligence, predictive analytics, cloud infrastructures, and data-centric decision systems has fundamentally transformed organizational structures, business models, operational processes, and customer interaction mechanisms. In this context, digital transformation is no longer perceived merely as technological adoption, but rather as a multidimensional organizational transition that reshapes the strategic, operational, and cultural foundations of institutions. Contemporary organizations are required to continuously adapt to volatile environments characterized by uncertainty, complexity, and accelerated technological change, and this necessity has intensified the importance of digital transformation across public, private, industrial, educational, and governmental sectors (Eom & Lee, 2022; Omol, 2024). Research indicates that organizations capable of integrating technological capabilities with organizational flexibility, innovation culture, and strategic responsiveness are more likely to achieve sustainable digital transformation outcomes (Nguyen et al., 2025; Weritz et al., 2025).

Despite the widespread implementation of digital technologies, organizations exhibit substantial differences in digital transformation outcomes. While some organizations achieve improvements in operational efficiency, customer engagement, revenue growth, and strategic adaptability, others encounter resistance, implementation failures, financial inefficiencies, and limited returns on technological investments. This inconsistency demonstrates that digital transformation success depends on a broad range of organizational, technological, managerial, and behavioral variables rather than technology alone. Studies focusing on small and medium

enterprises, public organizations, and higher education institutions have highlighted challenges such as inadequate infrastructure, insufficient digital competencies, financial limitations, organizational rigidity, and lack of strategic alignment as major barriers to successful digital transformation (Purnomo et al., 2024; Sagala & Ori, 2024; Singun, 2025). Consequently, researchers have increasingly emphasized the role of organizational agility as a key enabling factor in digital transformation success. Organizational agility refers to an organization's capability to rapidly sense environmental changes, reconfigure resources, adapt operational processes, and respond effectively to technological disruptions and market uncertainties. Integrative reviews have confirmed that organizational agility plays both a mediating and facilitating role in digital transformation and firm performance relationships (Gong & Ribiere, 2025; Syarkani, 2025). Furthermore, empirical studies have demonstrated that agile organizations are more capable of leveraging digital capabilities to improve performance outcomes (Pelletier et al., 2025; Su et al., 2026).

In parallel with the growing importance of organizational agility, machine learning and predictive analytics have emerged as powerful approaches for modeling digital transformation success. Organizations generate massive volumes of heterogeneous data related to technology adoption, operational efficiency, customer behavior, employee engagement, and organizational performance. Machine learning techniques provide the capability to identify hidden nonlinear relationships within these complex datasets and generate accurate predictive insights regarding organizational digital maturity and transformation outcomes. Prior studies have utilized clustering methods, random forests, artificial neural networks, and predictive analytics frameworks to evaluate digital transformation readiness and organizational performance (Herdiyeni et al., 2026; Liu et al., 2025; Raeesi Vanani et al., 2025). Other investigations have highlighted the strategic value of predictive models in supporting managerial decision-making and digital transformation planning (Hossin et al., 2025; Iscaro et al., 2022). However, most previous studies have either relied on single-model architectures or focused primarily on conceptual and statistical analyses. Limited attention has been devoted to integrating organizational agility indicators with advanced ensemble deep learning architectures for predicting digital transformation success. Additionally, many prior approaches lacked comprehensive frameworks capable of simultaneously modeling organizational characteristics, digital capabilities, and predictive performance through hybrid intelligent systems. Therefore, a significant research gap remains regarding the development of integrated machine learning frameworks that combine organizational agility indicators with ensemble meta-learning and stacking deep learning models for digital transformation prediction.

Methods and Materials

This study developed a multi-layer ensemble deep learning framework to predict organizational digital transformation success by incorporating an Organizational Agility Index (OAI). The research utilized the Digital Transformation Dataset, which contains organizational information regarding industry, company size, digital tools adoption, year of adoption, impact on revenue, impact on efficiency, digital skills training, customer engagement change, and geographic region. Initially, an Organizational Agility Index was designed

to quantify organizational readiness and flexibility toward digital transformation. The index was constructed through a linear combination of organizational size, digital skills training, the number of digital tools utilized, and employee engagement indicators. The Organizational Agility Index was formulated as follows:

$$OAI = S_{Size} + S_{Skill} + S_{Tools} + S_{Eng}$$

where S_{Size} represents the encoded company size, S_{Skill} indicates digital skills training status, S_{Tools} corresponds to the number of adopted digital tools, and S_{Eng} denotes employee engagement level.

To construct the target variable, K-Means clustering was employed based on organizational revenue and efficiency indicators. Organizations were grouped into three clusters representing low, medium, and high levels of digital transformation success. The K-Means objective function minimized the intra-cluster Euclidean distance as follows:

$$J = \sum_{j=1}^k \sum_{x_i \in C_j} \|x_i - \mu_j\|^2$$

where $k = 3$ indicates the number of clusters, C_j represents the samples belonging to cluster j , and μ_j denotes the cluster centroid.

During preprocessing, categorical variables were transformed using One-Hot Encoding, while numerical variables were standardized using StandardScaler normalization. The processed dataset was then fed into five independent deep learning base learners: Multilayer Perceptron (MLP), Recurrent Neural Network (RNN), Long Short-Term Memory Network (LSTM), Convolutional Neural Network (CNN), and a residual-based MLP architecture (ResMLP). Each model generated probabilistic predictions for the three digital transformation classes. These outputs were concatenated into a stacked feature matrix:

$$Z_i = [P_i^{MLP}, P_i^{RNN}, P_i^{LSTM}, P_i^{CNN}, P_i^{ResMLP}]$$

The resulting matrix was used as input to a Random Forest meta-learner containing 200 decision trees. The meta-learner aggregated the outputs of all base models to generate final predictions. Model performance was evaluated using Accuracy, Recall, Precision, F1-score, Mean Absolute Error (MAE), and Root Mean Square Error (RMSE). To ensure robustness and stability, the training and evaluation process was repeated 30 times, and average performance metrics were reported.

Findings

The findings demonstrated that the proposed ensemble stacking deep learning framework achieved superior predictive performance compared with individual deep learning models. Among all evaluated approaches, the

Random Forest meta-learner generated the highest predictive accuracy, reaching 96.86%. The proposed architecture consistently outperformed standalone MLP, RNN, LSTM, CNN, and ResMLP models across all evaluation metrics.

The analysis of classification performance revealed that the ensemble model achieved substantially higher Recall, Precision, and F1-score values compared with individual models. The Recall metric indicated that the proposed framework successfully identified the majority of organizations belonging to each digital transformation success level with minimal false negatives. Similarly, Precision values confirmed that the predicted classifications were highly reliable and contained limited false positive classifications. The F1-score further demonstrated balanced predictive performance across all classes, indicating that the model effectively maintained equilibrium between sensitivity and classification precision.

The comparison of individual base learners showed that MLP, RNN, and CNN models achieved relatively high performance levels independently, whereas the LSTM model exhibited comparatively lower predictive capability. Nevertheless, integrating all models within the stacking architecture substantially improved the overall prediction accuracy and stability. The ResMLP architecture also demonstrated considerable effectiveness due to the implementation of residual shortcut connections, which enhanced gradient flow and stabilized the learning process in deeper network layers.

The K-Means clustering process successfully categorized organizations into three distinct levels of digital transformation success based on revenue and efficiency indicators. Organizations classified within the high-level transformation cluster exhibited stronger organizational agility scores, higher digital tool utilization, and greater employee engagement levels. In contrast, organizations in the low-level cluster generally demonstrated weaker agility characteristics and lower digital adoption indicators.

The repeated experimental runs indicated strong stability and robustness of the proposed framework. Boxplot analyses and average metric distributions revealed minimal variance across repeated executions, confirming the consistency and generalizability of the ensemble architecture. Additionally, MAE and RMSE values remained relatively low across all repetitions, indicating limited prediction deviation between actual and predicted class labels.

The findings also demonstrated that incorporating the Organizational Agility Index significantly improved predictive performance. Models trained without the OAI variable exhibited lower classification accuracy and reduced stability, highlighting the substantial contribution of organizational agility in determining digital transformation outcomes. The results therefore confirm that organizational agility serves as a critical predictive factor in digital transformation success modeling.

Discussion and Conclusion

The findings of this study demonstrate that digital transformation success is a multidimensional phenomenon influenced not only by technological adoption but also by organizational agility, digital readiness, employee engagement, and operational adaptability. The superior performance of the proposed stacking deep learning

architecture indicates that hybrid ensemble learning frameworks are highly effective for modeling complex organizational behaviors characterized by nonlinear and multidimensional relationships. Unlike single-model approaches, the proposed framework benefited from the complementary strengths of multiple deep learning architectures, enabling the extraction of richer patterns from organizational data.

The significant contribution of the Organizational Agility Index highlights the strategic importance of agility in digital transformation initiatives. Organizations capable of rapidly adapting to technological changes, integrating digital competencies, and maintaining flexible operational structures are more likely to achieve successful transformation outcomes. The quantitative operationalization of organizational agility within a predictive machine learning framework represents an important advancement because it transforms an abstract managerial concept into a measurable and actionable analytical variable.

The successful implementation of K-Means clustering for target generation also demonstrates the effectiveness of unsupervised learning methods in identifying meaningful organizational transformation levels from raw performance indicators. By utilizing revenue and efficiency metrics as clustering dimensions, the study established a realistic and data-driven mechanism for constructing digital transformation success categories. This approach improved the reliability of the predictive framework and reduced dependency on subjective labeling methods.

Another important implication of this study is the demonstrated value of ensemble meta-learning in organizational analytics. The Random Forest meta-learner successfully aggregated probabilistic outputs from diverse neural architectures and generated stable, high-accuracy predictions. The architecture exhibited strong generalizability and robustness across repeated executions, indicating its suitability for real-world organizational environments characterized by uncertainty and heterogeneous data structures.

From a practical perspective, the proposed framework can support managers and policymakers in evaluating organizational readiness for digital transformation before extensive technological investments are made. The model can assist organizations in identifying weaknesses in agility, digital capability, and operational flexibility, thereby facilitating more effective resource allocation and strategic planning. Additionally, the framework can function as an intelligent decision-support system for monitoring digital transformation initiatives and predicting potential implementation outcomes.

Overall, this study demonstrates that integrating organizational agility indicators with ensemble stacking deep learning architectures provides a powerful and reliable framework for predicting digital transformation success. The proposed model not only achieved high predictive accuracy but also offered a comprehensive analytical perspective capable of capturing the complex interplay between organizational and technological factors in digital transformation processes.

References

- AlMurtadha, Y. (2024). AI Prediction Model to Investigate the GovTech Maturity Index (GTMI) Indicators for Assessing Governments' Readiness for Digital Transformation. *Journal of Applied Data Sciences*, 5(4), 1838-1849. <https://doi.org/10.47738/jads.v5i4.373>
- AprajitByte. (2023). *Digital Transformation Dataset*. <https://www.kaggle.com/datasets/aprajitbyte/digital-transformation-dataset>
- Bekemeier, S., Caldeira Rego, C. R., Mai, H. L., Saikia, U., Waseda, O., Apel, M., & Schaarschmidt, J. (2025). Advancing digital transformation in material science: The role of workflows within the materialdigital initiative. *Advanced Engineering Materials*, 27(8), 2402149. <https://doi.org/10.1002/adem.202402149>
- 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. <https://doi.org/10.1155/2021/6648351>
- Eom, S. J., & Lee, J. (2022). Digital government transformation in turbulent times: Responses, challenges, and future direction. *Government Information Quarterly*, 39, 101690. <https://doi.org/10.1016/j.giq.2022.101690>
- Gong, C., & Ribiere, V. (2025). Understanding the role of organizational agility in the context of digital transformation: An integrative literature review. *VINE Journal of Information and Knowledge Management Systems*, 55(2), 351-378. <https://doi.org/10.1108/VJIKMS-09-2022-0312>
- 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*, 6(2), 141-149. <https://doi.org/10.60083/jidt.v6i2.551>
- Herdienyeni, Y., Juanda, B., Zhafira, N., Anggraeni, L., & Probokawuryan, M. (2026). Machine-learning-based assessment and prediction of digital transformation performance for MSMEs in Indonesia. *International Journal of Information Technology and Decision Making*, 25(1), 339-367. <https://doi.org/10.1142/S0219622025500415>
- Hijazi, A., Ozaltin, O., & Uzsoy, R. (2024). All you need is an improving column: Enhancing column generation for parallel machine scheduling via transformers. *arXiv preprint arXiv:2410.15601*.
- Hossin, M. E., Rahman, M. M., Hossain, S., Siddiqua, K. B., Rozario, E., Khair, F. B., & Mahmud, F. (2025). Digital Transformation in the USA Leveraging AI and Business Analytics for IT Project Success in the Post-Pandemic Era. *Journal of Posthumanism*, 5(4), 958-976. <https://doi.org/10.63332/joph.v5i4.1180>
- Iscaro, V., Castaldi, L., Maresca, P., & Mazzoni, C. (2022). Digital transformation in the economics of complexity: The role of predictive models in strategic management. *Journal of Strategy and Management*, 15(3), 450-467. <https://doi.org/10.1108/JSMA-02-2021-0059>
- Izonin, I., Ilchysyn, B., Tkachenko, R., Gregus, M., Shakhovska, N., & Strauss, C. (2022). Towards data normalization task for the efficient mining of medical data. 2022 12th International Conference on Advanced Computer Information Technologies (ACIT),
- Kujawa, A., Booth, T., & Vercauteren, T. (2025). Beyond one-hot encoding? Journey into compact encoding for large multi-class segmentation. In *International Workshop on Efficient Medical Artificial Intelligence* (pp. 1-10). https://doi.org/10.1007/978-3-032-13961-0_1
- Liu, C. (2022). Risk prediction of digital transformation of manufacturing supply chain based on principal component analysis and backpropagation artificial neural network. *Alexandria Engineering Journal*, 61(1), 775-784. <https://doi.org/10.1016/j.aej.2021.06.010>
- Liu, R., Xue, H., & Xue, Q. (2025). The Study on Risk Prediction and Prevention Models for Enterprise Digital Transformation Based on Machine Learning. Proceedings of the 2025 2nd International Conference on Informatics Education and Computer Technology Applications,
- Naidu, G., Zuva, T., & Sibanda, E. M. (2023). A review of evaluation metrics in machine learning algorithms. In *Computer Science On-line Conference*. https://doi.org/10.1007/978-3-031-35314-7_2
- Nanehkanan, 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. <https://doi.org/10.1155/2022/6913043>
- Nanehkanan, 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. <https://doi.org/10.1155/2022/5663001>
- Nguyen, K. C., Ngoc-Long, N., Ho, T. D., & Van Hai, T. (2025). Digital transformation, organizational agility, and firm performance in emerging markets: Evidence from Vietnam's machinery sector. *Problems and Perspectives in Management*, 23(3), 342. [https://doi.org/10.21511/ppm.23\(3\).2025.25](https://doi.org/10.21511/ppm.23(3).2025.25)
- Oh, K., Kho, H., Choi, Y., & Lee, S. (2022). Determinants for successful digital transformation. *Sustainability*, 14(3), 1215. <https://doi.org/10.3390/su14031215>
- Omol, E. J. (2024). Organizational digital transformation: From evolution to future trends. *Digital Transformation and Society*, 3(3), 240-256. <https://doi.org/10.1108/DTS-08-2023-0061>
- Pelletier, C., L'Ecuier, F., & Raymond, L. (2025). Building organizational agility through digital transformation: A configurational approach in SMEs. *Industrial Management and Data Systems*, 125(4), 1503-1529. <https://doi.org/10.1108/IMDS-05-2024-0488>
- Purnomo, S., Nurmalitasari, N., & Nurchim, N. (2024). Digital transformation of MSMEs in Indonesia: A systematic literature review. *Journal of Management and Digital Business*, 4(2), 301-312. <https://doi.org/10.53088/jmdb.v4i2.1121>
- Raeesi Vanani, I., Taghavifard, M. T., & Yalpanian, M. A. (2025). Predictive Analytics Solution for Digital Capabilities Identification Towards Business Performance Improvement. *Sn Computer Science*, 6(1), 85. <https://doi.org/10.1007/s42979-024-03630-6>

- Rane, N., Choudhary, S. P., & Rane, J. (2024). Ensemble deep learning and machine learning: Applications, opportunities, challenges, and future directions. *Studies in Medical and Health Sciences*, 1(2), 18-41. <https://doi.org/10.48185/smhs.v1i2.1225>
- Sagala, G. H., & Ori, D. (2024). Toward SMEs digital transformation success: A systematic literature review. *Information Systems and e-Business Management*, 22(4), 667-719. <https://doi.org/10.1007/s10257-024-00682-2>
- Shafiabady, N., Hadjinicolaou, N., Din, F. U., Bhandari, B., Wu, R. M., & Vakilian, J. (2023). Using Artificial Intelligence (AI) to predict organizational agility. *PLoS One*, 18(5), e0283066. <https://doi.org/10.1371/journal.pone.0283066>
- Singun, A. J. (2025). Unveiling the barriers to digital transformation in higher education institutions: A systematic literature review. *Discover Education*, 4(1), 37. <https://doi.org/10.1007/s44217-025-00430-9>
- Su, Y., Khan, M. T., Ullah, S., Kukreti, M., Sami, A., & Dangwal, A. (2026). Steering the digital transformation: How paradoxical leadership juggles innovation culture and organizational agility. *Human Systems Management*, 45(3), 396-407. <https://doi.org/10.1177/01672533251372833>
- Suyal, M., & Sharma, S. (2024). A review on analysis of k-means clustering machine learning algorithm based on unsupervised learning. *Journal of Artificial Intelligence and Systems*, 6(1), 85-95. <https://doi.org/10.33969/AIS.2024060106>
- Syarkani, Y. (2025). The mediating role of organizational agility in the relationship between digital transformation and firm performance. *Journal of Social and Economics Research*, 7(2), 102-116. <https://doi.org/10.54783/jsr.v7i2.1057>
- Weritz, P., Braojos, J., Matute, J., & Benitez, J. (2025). Impact of strategic capabilities on digital transformation success and firm performance: Theory and empirical evidence. *European Journal of Information Systems*, 34(3), 415-435. <https://doi.org/10.1080/0960085X.2024.2311137>
- Xie, X., Navaei, Y. D., & Einy, S. (2023). A Clustering-Based Routing Protocol Using Path Pattern Discovery Method to Minimize Delay in VANET. *Wireless Communications and Mobile Computing*, 2023(1), 3776815. <https://doi.org/10.1155/2023/3776815>
- Yuan, Y., & Sun, Y. (2024). Practices, challenges, and future of digital transformation in smallholder agriculture: Insights from a literature review. *Agriculture*, 14(12), 2193. <https://doi.org/10.3390/agriculture14122193>