



پیش بینی سطح تغییرات بنیادین در فرآیند تحول دیجیتال با بهره گیری از روش های یادگیری عمیق

<p>شيوه استناددهی: هدایتی، ثمانه، ایرانبان فرد، سیدجواد، نجف زاده، سارا، و کلاهدوزی، مصطفی. (۱۴۰۵). پیش بینی سطح تغییرات بنیادین در فرآیند تحول دیجیتال با بهره گیری از روش های یادگیری عمیق، یادگیری هوشمند و تحول مدیریت، ۴(۶)، ۳۲-۱.</p>	<p>تاریخ چاپ نهایی: ۱ اسفند ۱۴۰۵ تاریخ چاپ اولیه: ۲۴ اردیبهشت ۱۴۰۵ تاریخ پذیرش: ۲۶ فروردین ۱۴۰۵ تاریخ بازنگری: ۱۸ فروردین ۱۴۰۵ تاریخ ارسال: ۳۰ بهمن ۱۴۰۴</p>	<p>ثمانه هدایتی^۱ سیدجواد ایرانبان فرد^۲ سارا نجف زاده^۳ مصطفی کلاهدوزی^۴</p>
---	--	---

چکیده


هدف این پژوهش ارائه یک چارچوب پیش بینانه داده محور برای تعیین میزان تغییرات بنیادین مورد نیاز سازمان ها در مسیر تحول دیجیتال با استفاده از الگوریتم های یادگیری ماشین و یادگیری عمیق است. این پژوهش با رویکرد کمی و مبتنی بر داده کاوی انجام شد و از مجموعه داده استاندارد تحول دیجیتال سازمانی استخراج شده از پلتفرم Kaggle استفاده گردید. داده ها شامل ۲۰۰۰ نمونه و ۲۳ ویژگی مرتبط با شاخص های کلیدی تحول دیجیتال از جمله هزینه های تحقیق و توسعه، شدت فناوری، سطح مهارت مدیریتی، زیرساخت دیجیتال و تعامل مشتری بودند. پس از پاکسازی، نرمال سازی و استخراج ویژگی ها، داده ها به الگوریتم های طبقه بندی شامل KNN، SVM، Naive Bayes، Decision Tree و شبکه عصبی پرسپترون چندلایه عمیق (DMLP) وارد شدند. ارزیابی عملکرد مدل ها با استفاده از معیارهای استنباطی شامل Accuracy، Balanced Accuracy، Recall، Precision، F1، AUROC، Log-Loss، Kappa، MCC، Specificity و AUPRC انجام شد و نتایج بر اساس میانگین ۲۰ بار اجرا گزارش گردید. نتایج تحلیل های استنباطی نشان داد مدل یادگیری عمیق DMLP به طور معناداری عملکرد برتری نسبت به سایر الگوریتم های طبقه بندی ارائه می دهد. این مدل با دستیابی به دقت ۹۹.۸۴ درصد، دقت متوازن ۹۹.۹۴ درصد، مقدار F1 برابر ۹۹.۹۱ درصد و AUROC معادل ۹۹.۹۵ درصد بالاترین سطح قدرت پیش بینی را نشان داد. همچنین کمترین مقدار Log-Loss و پایین ترین انحراف معیارهای ارزیابی بیانگر پایداری آماری بالا و توان تعمیم مناسب مدل در مواجهه با داده های دیده نشده بود. نتایج مقایسه ای نشان داد روش های کلاسیک به ویژه KNN عملکرد ضعیف تری در تشخیص الگوهای پیچیده تحول دیجیتال داشته اند، در حالی که ساختار چندلایه شبکه عصبی قادر به استخراج روابط غیرخطی میان متغیرها بوده است. یافته های پژوهش نشان می دهد استفاده از یادگیری عمیق می تواند ابزاری قابل اعتماد برای پیش بینی سطح آمادگی دیجیتال و میزان تغییرات ساختاری مورد نیاز سازمان ها فراهم سازد. مدل پیشنهادی علاوه بر دقت بسیار بالا، چارچوبی عملیاتی برای پشتیبانی از تصمیم گیری راهبردی، تخصیص منابع و برنامه ریزی تحول دیجیتال ارائه می کند و می تواند به عنوان یک سیستم هوشمند راهنما در مدیریت گذار دیجیتال سازمان ها مورد استفاده قرار گیرد.

واژگان کلیدی: تحول دیجیتال، یادگیری عمیق، شبکه عصبی پرسپترون چندلایه، پیش بینی تغییرات سازمانی، طبقه بندی داده

شخصیات نویسندگان:

۱. گروه مدیریت فناوری اطلاعات، واحد بین المللی کیش، دانشگاه آزاد اسلامی، کیش، ایران
۲. گروه مدیریت، واحد شیراز، دانشگاه آزاد اسلامی، شیراز، ایران
۳. گروه کامپیوتر، واحد یادگار امام (ره) شهری، دانشگاه آزاد اسلامی، تهران، ایران
۴. گروه مدیریت فناوری اطلاعات، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

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

© ۱۴۰۵ تمامی حقوق انتشار این مقاله متعلق به نویسنده است.

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



Predicting the Level of Fundamental Changes in the Digital Transformation Process Using Deep Learning Methods

Samaneh Hedayati¹

Seyed Javad Iranbanfard^{2*}

Sara Najafzadeh³

Mostafa Kolahdoozi⁴

Submit Date: 19 February 2026

Revise Date: 07 April 2026

Accept Date: 15 April 2026

Initial Publish: 14 May 2026

Final Publish: 20 February 2027

How to cite: Hedayati, S., Iranbanfard, S. J., Najafzadeh, S., & Kolahdoozi, M. (2026). Predicting the Level of Fundamental Changes in the Digital Transformation Process Using Deep Learning Methods. *Intelligent Learning and Management Transformation*, 4(6), 1-32.

Abstract

This study aims to develop a data-driven predictive framework to determine the level of fundamental organizational changes required for digital transformation using machine learning and deep learning techniques. The research employed a quantitative data-mining approach using a standardized corporate digital transformation dataset obtained from Kaggle. The dataset consisted of 2,000 samples and 23 features representing critical digital transformation indicators, including R&D expenditure, technological intensity, managerial expertise, digital infrastructure, and customer interaction metrics. After data cleaning, normalization, and feature extraction, the dataset was processed using multiple classification algorithms including KNN, SVM, Naive Bayes, Decision Tree, and Deep Multilayer Perceptron (DMLP). Model performance was evaluated through inferential metrics such as Accuracy, Balanced Accuracy, Recall, Precision, F1-score, Specificity, Matthews Correlation Coefficient, Cohen's Kappa, Log-Loss, AUROC, and AUPRC. All results were calculated based on the mean performance of twenty independent experimental runs to ensure statistical reliability. Inferential analysis demonstrated that the DMLP deep learning model significantly outperformed conventional classification approaches. The proposed model achieved an accuracy of 99.84%, balanced accuracy of 99.94%, F1-score of 99.91%, and AUROC of 99.95%, indicating superior predictive capability. The model also exhibited the lowest Log-Loss values and minimal standard deviation across evaluation metrics, confirming strong statistical stability and generalization ability on unseen data. Comparative results revealed that traditional algorithms, particularly KNN, showed limited effectiveness in capturing complex nonlinear relationships, whereas the deep multilayer architecture effectively extracted hidden patterns associated with organizational digital transformation readiness. The findings indicate that deep learning provides a reliable and high-precision mechanism for predicting organizational readiness and required structural changes in digital transformation initiatives. The proposed model functions not only as a predictive system but also as a strategic decision-support framework capable of guiding digital transformation planning, optimizing resource allocation, and assisting organizations in managing complex digital transition processes.

Keywords: Digital Transformation, Deep Learning, Multilayer Perceptron, Organizational Change Prediction, Classification Models

Authors' Information:

javad.iranban@iaiu.ac.ir

1. 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 Computer, Yi.C., Islamic Azad University, Tehran, Iran

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



© 2026 the authors. This is an open access article under the terms of the [CC BY-NC 4.0 License](https://creativecommons.org/licenses/by-nc/4.0/).

مقدمه

تحول دیجیتال در دهه‌های اخیر به یکی از مهم‌ترین نیروهای پیشران تغییرات اقتصادی، سازمانی و فناورانه در سطح جهانی تبدیل شده است. سازمان‌ها در محیطی فعالیت می‌کنند که با رشد سریع فناوری‌های اطلاعاتی، گسترش هوش مصنوعی، افزایش حجم داده‌ها و تغییر الگوهای رقابت همراه است؛ در چنین شرایطی، توانایی انطباق با تحولات دیجیتال به عامل تعیین‌کننده بقا و مزیت رقابتی تبدیل شده است. تحول دیجیتال صرفاً به معنای استفاده از فناوری‌های نوین نیست، بلکه بازآفرینی ساختارهای سازمانی، مدل‌های کسب‌وکار، فرآیندهای عملیاتی و شیوه تعامل با مشتریان را در بر می‌گیرد (Kraus et al., 2022; Vial, 2021). این تحول موجب تغییر در منطق ارزش‌آفرینی سازمان‌ها شده و مسیر حرکت از اقتصاد سنتی به اقتصاد داده‌محور را تسریع کرده است (Paul et al., 2024).

مطالعات نشان می‌دهد سرمایه‌گذاری در فناوری اطلاعات و تدوین راهبردهای دیجیتال نقش اساسی در موفقیت تحول دیجیتال دارد. سازمان‌هایی که تحول دیجیتال را به‌عنوان بخشی از استراتژی کلان خود تعریف کرده‌اند، توانسته‌اند عملکرد مالی، شفافیت اطلاعاتی و کیفیت تصمیم‌گیری را بهبود بخشند (Chen et al., 2022; Zhang et al., 2023). همچنین تحول دیجیتال به‌عنوان کاتالیزوری برای توسعه پایدار کسب‌وکارها شناخته شده و امکان بهینه‌سازی مصرف منابع، افزایش بهره‌وری و ایجاد مدل‌های اقتصادی جدید را فراهم می‌سازد (Shehadeh, 2024). در این راستا، چارچوب‌های مفهومی متعددی برای هدایت سازمان‌ها در مسیر دیجیتالی‌شدن ارائه شده است که بر هماهنگی میان فناوری، فرهنگ سازمانی و نوآوری تأکید دارند (Butt et al., 2024; Elia et al., 2024).

با وجود اهمیت گسترده تحول دیجیتال، اجرای موفق آن همچنان با چالش‌های متعددی همراه است. بسیاری از سازمان‌ها به دلیل فقدان مهارت‌های دیجیتال، هزینه‌های پیاده‌سازی فناوری، محدودیت زیرساختی و مقاومت سازمانی در برابر تغییر، با شکست یا کندی در فرآیند تحول مواجه می‌شوند (Ahmad et al., 2022; Hendrawan et al., 2024). علاوه بر این، وابستگی بیش‌ازحد به فناوری بدون آمادگی مدیریتی و فرهنگی می‌تواند موجب ناکارآمدی تصمیمات و افزایش ریسک‌های عملیاتی شود (Omol, 2024). پژوهش‌ها نشان می‌دهد موفقیت تحول دیجیتال بیش از آنکه به فناوری وابسته باشد، به توانایی سازمان در مدیریت تغییر و بهره‌برداری هوشمند از داده‌ها مرتبط است (Kitsios & Kamarriotou, 2021; Kusuma et al., 2024).

در این میان، هوش مصنوعی و یادگیری ماشین به‌عنوان مهم‌ترین ابزارهای تحول دیجیتال مطرح شده‌اند. این فناوری‌ها با تحلیل داده‌های عظیم، کشف الگوهای پنهان و پیش‌بینی رفتارهای آینده، امکان تصمیم‌گیری مبتنی بر داده را فراهم می‌کنند (Aldoseri et al., 2024; Perifanis & Kitsios, 2023). استفاده از الگوریتم‌های یادگیری ماشین در حوزه‌های مختلف سازمانی، از پیش‌بینی ریسک مالی تا بهینه‌سازی فرآیندهای عملیاتی، موجب افزایش کارایی و انعطاف‌پذیری سازمان‌ها شده است (Chiu et al., 2024; Eom et al., 2024). همچنین پیشرفت‌های

اخیر در شبکه‌های عصبی عمیق و شبکه‌های گرافی، قابلیت مدل‌سازی روابط پیچیده میان متغیرهای سازمانی را به‌طور چشمگیری افزایش داده‌اند (Corso et al., 2024; Fu et al., 2024).

یادگیری عمیق به‌ویژه در تحلیل مسائل پیچیده سازمانی اهمیت ویژه‌ای یافته است، زیرا این مدل‌ها قادرند ویژگی‌های سطح بالا را به‌صورت خودکار استخراج کرده و وابستگی‌های غیرخطی را شناسایی کنند (Mienye et al., 2024; Zhao et al., 2024). ساختارهای پیشرفته شبکه‌های عصبی، شامل شبکه‌های پرسپترون چندلایه و شبکه‌های فیزیکی آموزش‌پذیر، امکان دستیابی به دقت پیش‌بینی بسیار بالا را فراهم کرده‌اند (A. Momeni et al., 2025; Scabini & Bruno, 2023). کاربرد این رویکردها در حوزه‌های مختلف از پزشکی و صنعت تا مدیریت زنجیره تأمین نشان داده است که مدل‌های یادگیری عمیق می‌توانند تصمیمات پیچیده را با دقتی فراتر از روش‌های سنتی پشتیبانی کنند (Derakhshan Barjoei et al., 2025; Manzari Vahed et al., 2025; Sadr et al., 2025).

در حوزه تحول دیجیتال، یکی از چالش‌های اساسی، سنجش میزان آمادگی سازمان‌ها و پیش‌بینی سطح تغییرات موردنیاز است. بسیاری از مطالعات پیشین بیشتر بر تحلیل مفهومی یا بررسی عوامل موفقیت تمرکز داشته‌اند و کمتر به ارائه مدل‌های پیش‌بینانه مبتنی بر داده پرداخته‌اند (Xinxian & Jianhui, 2022; Zhu et al., 2024). در حالی که سازمان‌ها برای برنامه‌ریزی مؤثر تحول دیجیتال نیازمند ابزارهایی هستند که بتوانند فاصله میان وضعیت فعلی و مطلوب دیجیتال را به‌صورت کمی ارزیابی کنند. استفاده از داده‌های واقعی سازمانی و مدل‌های یادگیری ماشین می‌تواند این شکاف را کاهش داده و راهکارهای عملیاتی ارائه دهد (Cui et al., 2025).

داده‌کاوی و یادگیری ماشین زمانی اثربخش خواهند بود که داده‌ها به‌درستی آماده‌سازی شوند. مطالعات نشان داده‌اند که پاکسازی، نرمال‌سازی و استانداردسازی داده‌ها نقش اساسی در افزایش دقت مدل‌های یادگیری دارند (P. O. Côté et al., 2024; Kalinina et al., 2025). کیفیت داده‌ها به‌طور مستقیم بر قابلیت تعمیم مدل‌ها اثر می‌گذارد و عدم توجه به پیش‌پردازش می‌تواند موجب بروز خطاهای پیش‌بینی شود (Lamtar-Gholipoor et al., 2024; Lamtar Gholipoor et al., 2024). از این رو، ترکیب روش‌های پیش‌پردازش پیشرفته با الگوریتم‌های یادگیری عمیق به‌عنوان یک رویکرد مؤثر در تحلیل تحول دیجیتال مطرح شده است.

ارزیابی عملکرد مدل‌های پیش‌بینی نیز نیازمند استفاده از شاخص‌های آماری و استنباطی معتبر است. معیارهایی نظیر دقت، امتیاز $F1$ ، ضریب همبستگی متیوز، کاپای کوهن و تحلیل منحنی ROC به‌عنوان ابزارهای استاندارد سنجش عملکرد الگوریتم‌ها شناخته می‌شوند (Chicco & Jurman, 2020; Çorbacioğlu & Aksel, 2023; G. Naidu et al., 2023; Rau & Shih, 2021). استفاده از این معیارها امکان مقایسه علمی میان مدل‌های مختلف را فراهم کرده و اعتبار نتایج پژوهش‌های یادگیری ماشین را افزایش می‌دهد (Mao et al., 2023; YA Nanehkaran, Zhu Licai, Junde Chen, Ahmed AM Jamel, et al., 2022; Y. Nanehkaran et al., 2022). همچنین

پژوهش‌های اخیر در حوزه امنیت شبکه و تحلیل داده‌های پیچیده نشان داده‌اند که ترکیب ویژگی‌های محلی و عمیق می‌تواند دقت تشخیص الگوها را به طور قابل توجهی افزایش دهد (Einy et al., 2021a, 2021b; Einy et al., 2022; Einy et al., 2023).

از سوی دیگر، گسترش فناوری‌های هوش مصنوعی فرصت‌ها و در عین حال ریسک‌های جدیدی را نیز ایجاد کرده است. تهدیدات امنیت سایبری، سوگیری الگوریتمی و چالش‌های اخلاقی از جمله موضوعاتی هستند که در ادبیات تحول دیجیتال مورد توجه قرار گرفته‌اند (Lemieux, 2023; Mhlanga, 2023). با این حال، مطالعات نشان می‌دهد مزایای حاصل از خودکارسازی، تحلیل پیش‌بینانه و بهبود تجربه مشتریان به مراتب بیش از محدودیت‌های آن بوده و سازمان‌ها را به سوی پذیرش گسترده فناوری‌های هوشمند سوق داده است (Gołab-Andrzejak, 2023; Klopov et al., 2023).

در سال‌های اخیر، پژوهشگران تلاش کرده‌اند از الگوریتم‌های یادگیری ماشین برای پیش‌بینی سطح تحول دیجیتال استفاده کنند، اما هنوز نیاز به چارچوب‌های یکپارچه‌ای وجود دارد که بتواند عوامل سازمانی، فناوری و انسانی را به صورت هم‌زمان تحلیل کند (Navaei et al., 2024; Zhang & Chen, 2024). بسیاری از مدل‌های موجود یا تمرکز صرف بر فناوری دارند یا صرفاً بر تحلیل‌های مدیریتی تکیه می‌کنند و کمتر رویکردی داده‌محور و عملیاتی ارائه شده است. استفاده از مجموعه داده‌های استاندارد تحول دیجیتال می‌تواند امکان توسعه مدل‌های تعمیم‌پذیر و قابل مقایسه را فراهم کند (colabsss, 2025).

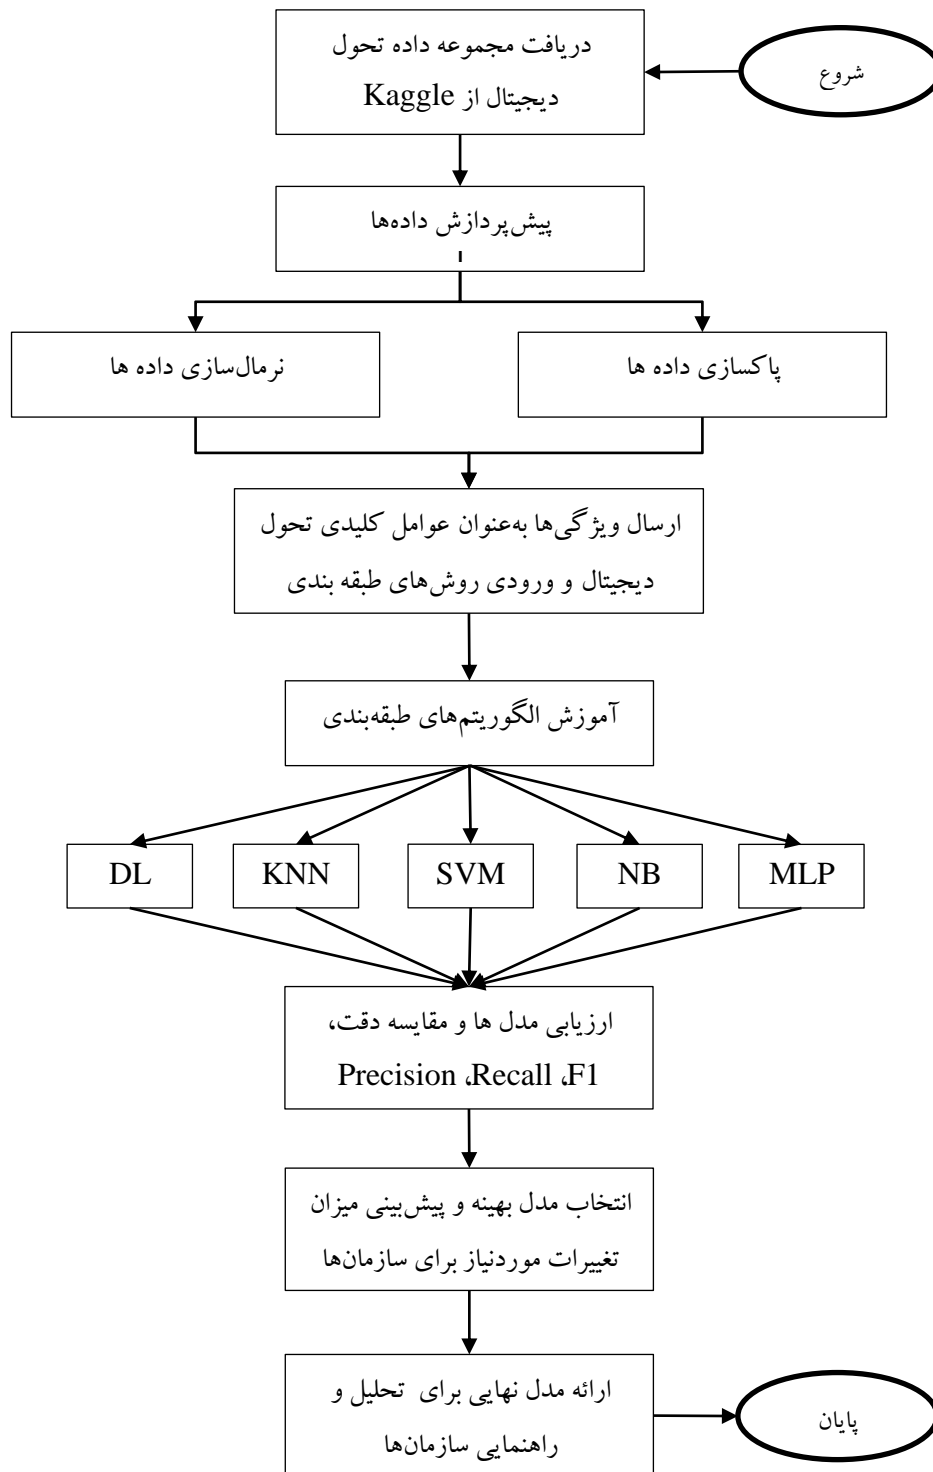
در مجموع، ادبیات موجود نشان می‌دهد که تحول دیجیتال نیازمند رویکردی میان‌رشته‌ای شامل مدیریت راهبردی، تحلیل داده، یادگیری ماشین و نوآوری فناورانه است (Guarda et al., 2021). پیشرفت سریع الگوریتم‌های هوش مصنوعی و افزایش دسترسی به داده‌های سازمانی فرصت بی‌سابقه‌ای برای توسعه مدل‌های پیش‌بینانه فراهم کرده است؛ مدل‌هایی که بتوانند نه تنها وضعیت فعلی سازمان‌ها را تحلیل کنند بلکه مسیر آینده تحول دیجیتال را نیز پیش‌بینی نمایند.

بنابراین، هدف این پژوهش ارائه یک چارچوب پیش‌بینی مبتنی بر یادگیری عمیق برای تعیین سطح تغییرات بنیادین مورد نیاز سازمان‌ها در فرآیند تحول دیجیتال با استفاده از داده‌های واقعی و الگوریتم‌های پیشرفته یادگیری ماشین است.

روش‌شناسی

همانطور که اشاره شد روش پیشنهادی در این مقاله، رویکرد نوینی برای پیش‌بینی تحول دیجیتال در حوزه فناوری اطلاعات ارائه کرده است که هدف آن شناسایی و تحلیل عوامل کلیدی مؤثر بر میزان تغییرات مورد نیاز در سازمان‌هاست. این رویکرد با استفاده از مجموعه داده استاندارد تحول دیجیتال شرکتی منتشر شده در مخزن داده‌های Kaggle طراحی شده و بر آن است تا بر اساس اطلاعات واقعی و قابل اطمینان، پیش‌بینی‌هایی دقیق درباره نیازهای تحول دیجیتال در سازمان‌ها انجام دهد. در این پژوهش از یک مجموعه داده استاندارد و از پیش برچسب‌گذاری شده استفاده شده

است که به‌طور گسترده در مطالعات تحول دیجیتال به کار رفته است. این داده‌ها شامل متغیر `digitaltrans_class` بوده که سطح تحول دیجیتال و هوشمند سازمان‌ها را در سه کلاس مشخص دسته‌بندی می‌کند؛ به‌طوری‌که مقدار ۰ بیانگر سطح پایین، مقدار ۱ نشان‌دهنده سطح متوسط و مقدار ۲ بیانگر سطح بالای تحول دیجیتال در شرکت‌ها است. فرآیند برجسب‌گذاری توسط ارائه‌دهندگان داده و بر اساس شاخص‌های معتبر انجام شده و در این تحقیق، داده‌ها بدون هیچ‌گونه تغییر در برجسب‌ها به‌عنوان ورودی مدل‌های یادگیری ماشین و یادگیری عمیق مورد استفاده قرار گرفته‌اند. پرسش اصلی این تحقیق آن است که این عوامل شناسایی‌شده تا چه اندازه می‌توانند سبب دگرگونی‌های اساسی در ساختار سازمانی، به‌ویژه در بخش فناوری اطلاعات، شوند. به عبارت دیگر، بررسی می‌شود که چگونه باید زیرساخت‌های فنی یک سازمان بازطراحی شوند، چه تحولاتی در شیوه‌های ارتباط با مشتری باید رخ دهد و چه تغییراتی در مدل کسب‌وکار ضروری است تا سازمان بتواند به وضعیت مطلوب دیجیتالی برسد. در این مسیر، سازمان‌ها قادر خواهند بود شکاف موجود بین وضعیت فعلی و اهداف دیجیتالی خود را درک کرده و نقشه راهی هدفمند برای دستیابی به تحول دیجیتال تدوین کنند.



شکل ۱ - فلوجارت روش پیشنهادی

برای عملی‌سازی این رویکرد، الگوریتم‌های مختلف طبقه‌بندی به کار گرفته شده‌اند تا بتوانند سازمان‌ها را از نظر میزان نیاز به تغییرات، دسته‌بندی کنند. داده‌های موجود به عنوان ورودی به این الگوریتم‌ها داده شده و مدل‌هایی همچون DL، KNN، SVM، NB و MLP مورد ارزیابی قرار گرفته‌اند. هدف از این تحلیل، مشخص کردن سطح تحول مورد نیاز در بخش‌هایی نظیر زیرساخت‌های فناوری اطلاعات، فرآیندهای سازمانی و

تعاملات با ذی‌نفعان است. این طبقه‌بندی به مدیران کمک می‌کند تا تصمیم‌گیری‌های بهتری در خصوص زمان‌بندی و نحوه اجرای پروژه‌های تحول دیجیتال اتخاذ کنند.

در نهایت، خروجی این پژوهش، یک مدل پیش‌بینانه عملیاتی است که می‌تواند سازمان‌ها را در مراحل مختلف توسعه یا گذار دیجیتال هدایت کند. این مدل، با اتکا بر داده‌ها و تحلیل‌های هوشمند، قادر است به سازمان‌هایی که قصد دارند خود را با روندهای سریع فناوری و افزایش انتظارات کاربران هماهنگ سازند، راهکارهایی برای تعیین میزان تغییرات مورد نیاز ارائه دهد. همچنین این مدل می‌تواند به‌عنوان ابزاری برای برنامه‌ریزی استراتژیک در زمینه تحول دیجیتال مورد استفاده قرار گیرد و سازمان‌ها را در دستیابی به مزیت رقابتی پایدار یاری رساند. در شکل ۱ فلوچارت روش پیشنهادی نشان داده شده است

در گام دوم از فرایند تحلیل داده، مرحله پیش‌پردازش داده‌ها نقش بسیار مهمی در افزایش دقت، کارایی و قابلیت تعمیم مدل‌های یادگیری ماشین دارد. پیش‌پردازش، شامل مجموعه‌ای از عملیات بر روی داده خام است که هدف آن آماده‌سازی داده برای مدل‌سازی است (Lamtar, 2024; Gholipour et al., 2024; Zhao et al., 2024). در این پژوهش، عملیات پیش‌پردازش شامل پاکسازی داده‌ها، نرمال‌سازی و استخراج ویژگی‌ها می‌باشد که در ادامه به تفصیل توضیح داده می‌شود.

پاکسازی داده^۱ نخستین مرحله از پیش‌پردازش است. در این گام، داده‌هایی که دارای مقادیر گمشده^۲، داده‌های پرت^۳، یا ناسازگار^۴ هستند شناسایی و اصلاح یا حذف می‌شوند. به عنوان مثال، برای حذف مقادیر گمشده، می‌توان از روش‌هایی مانند میانگین‌گیری یا میانه‌گیری برای جایگزینی استفاده کرد (P.-O. Côté et al., 2024):

$$x_i = \begin{cases} \text{if } x_i \neq \text{missing}, x_i \\ \text{if } x_i = \text{missing}, \mu \end{cases} \quad (1)$$

که در آن μ میانگین مقادیر موجود در آن ویژگی است.

نرمال‌سازی^۵ به فرایندی اطلاق می‌شود که در آن ویژگی‌های عددی در مقیاس مشترکی قرار می‌گیرند تا مدل یادگیری به‌درستی بتواند تفاوت میان ویژگی‌ها را درک کند. یکی از روش‌های رایج، نرمال‌سازی کمینه - بیشینه^۶ است (Korobchynskiy & Nadraga, 2025):

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

¹ Data Cleaning

² missing values

³ outliers

⁴ inconsistent

⁵ Normalization

⁶ Min-Max Normalization

که در آن X مقدار اصلی، X_{min} کمترین مقدار و X_{max} بیشترین مقدار آن ویژگی در کل مجموعه داده است. این روش داده‌ها را در بازه $[0, 1]$ قرار می‌دهد و برای الگوریتم‌هایی طبقه‌بندی مفید است. پیش‌پردازش داده‌ها نقش زیربنایی در عملکرد مدل دارد. بدون انجام دقیق این مرحله، حتی پیشرفته‌ترین الگوریتم‌های یادگیری ماشین نیز عملکرد مناسبی نخواهند داشت. به همین دلیل، در این پژوهش توجه ویژه‌ای به پاکسازی، نرمال‌سازی و استخراج صحیح ویژگی‌ها شده است تا دقت پیش‌بینی تحول دیجیتال افزایش یابد.

همانطور که اشاره شد در روش پیشنهادی در این مقاله به منظور پیش‌بینی سطح تغییرات بنیادین در فرایند تحول دیجیتال از رویکرد شبکه‌های عصبی عمیق استفاده شده است. شبکه‌های عصبی عمیق با تکیه بر آموزش در لایه‌های میانی و تمرکز بر روی ویژگی‌های مربوط به مسئله، توانایی تفکیک نمونه‌های مربوط به سطح تغییرات بنیادین در فرایند تحول دیجیتال را با دقت بالایی دارند. از مهم‌ترین مدل‌های شبکه‌های عصبی عمیق که توانایی طبقه‌بندی دقیق داده‌های عدد و همچنین تصاویر را دارد، شبکه‌های عصبی پرسپترون چندلایه عمیق (DMLP) است. در ادامه این بخش، DMLP به صورت مختصر معرفی خواهد شد.

این بخش بر شبکه‌های عصبی مصنوعی پرسپترون چندلایه عمیق (DMLP¹) کاملاً متصل (FC²) و پیش‌خور³ تمرکز دارد که شبیه به شبکه‌های چندلایه پرسپترون هستند اما دارای چندین لایه مخفی می‌باشند (Ali Momeni et al., 2025). اگرچه این معماری ساده به نظر می‌رسد، اما طیف گسترده‌ای از اجزای سازنده وجود دارد، مانند توابع فعال‌سازی، مقداردهی اولیه سیناپس‌ها و غیره (Koli, 2025). برای مثال، در مقداردهی اولیه سیناپس که فرآیندی است برای ایجاد توزیع اولیه تصادفی به منظور تشکیل ماتریس‌های وزن W_a ، تکنیک‌های بهینه‌سازی شده‌ای مانند Glorot-normal وجود دارند که بهتر از توزیع‌های یکنواخت تصادفی عمل می‌کنند (Scabini & Bruno, 2023).

برای توابع فعال‌سازی نوروها، بیشتر روش‌ها معمولاً قصد دارند ورودی‌ها را به صورت غیرخطی نگاشت کنند. می‌توان به تابع فعال‌سازی Rectifier-Linear-Unit به صورت $f(x) = \max\{0, x\}$ اشاره کرد، که پس از رواج مدل‌های عمیق به دلیل سادگی و کارایی‌اش محبوب شد. با این حال، انتخاب این موارد معمولاً بستگی به مسئله مورد نظر یا سبک معماری دارد و بیشتر بر اساس آزمایش‌های تجربی تعیین می‌شوند (Scabini & Bruno, 2023).

علاوه بر مرحله ساخت شبکه‌های عصبی، نکات خاصی در آموزش وجود دارد، مانند آماده‌سازی/نرمال‌سازی داده‌ها، بهینه‌سازی پارامترهای یادگیری و معیارهای توقف. مدل‌های بینایی کنونی معمولاً داده‌ها را بر اساس استانداردهای معمول نرمال می‌کنند، که شامل نرمال‌سازی به صورت Z-score است؛ به این معنا که داده‌ها حول صفر مرکزدهی می‌شوند (میانگین کم می‌شود) و واریانس آن‌ها برابر با یک می‌شود. در آموزش،

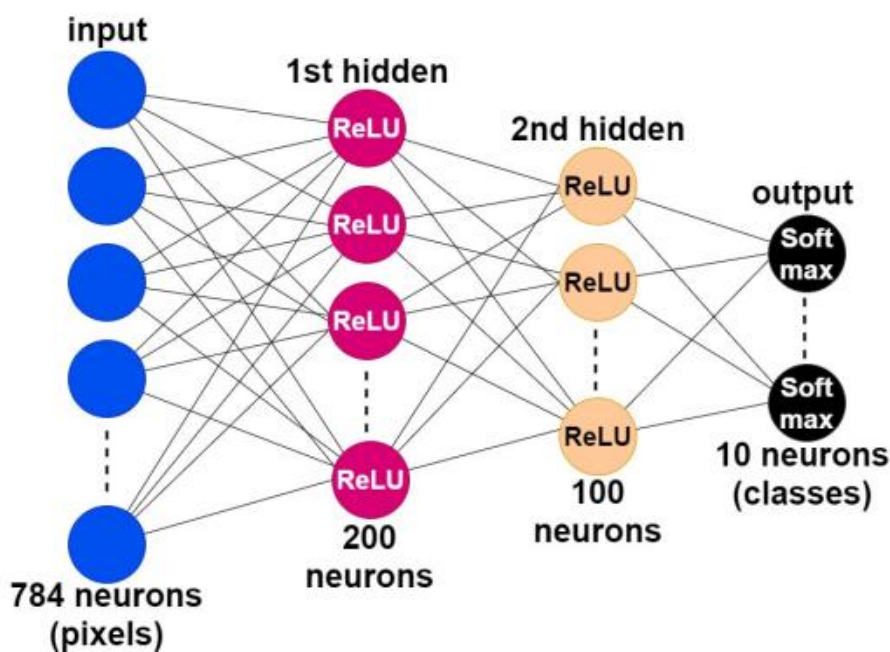
¹ Deep Multi-layer Preceperon

² Fully Connected

³ Feedforward

بهینه‌سازهای رایج شامل روش‌های پس‌انتشار خطا مانند گرادیان نزولی تصادفی (SGD)^۱ با مونتوم هستند. هر بهینه‌ساز دارای ابرپارامترهایی است که باید تنظیم شوند. تعداد اپوک‌های آموزش احتمالاً یکی از تجربی‌ترین پارامترهاست، زیرا کاربر باید عملکرد آموزش را نظارت کند تا تصمیم بگیرد چه زمانی آموزش را متوقف کند (Scabini & Bruno, 2023).

به طور خلاصه، توسعه شبکه‌های عصبی مصنوعی نیازمند مهندسی گسترده معماری و آزمایش‌های تجربی است که همچنین منابع سخت‌افزاری زیادی می‌طلبد. این جستجو تصادفی نیست، یعنی در این حوزه روش‌های خوب و پیکربندی‌های شناخته‌شده وجود دارند که در شرایط رایج کار می‌کنند. با این حال، هیچ تضمینی وجود ندارد که مدل همیشه همان‌طور که انتظار می‌رود عمل کند. علاوه بر این، ویژگی‌های دیگری نیز می‌توانند باعث ناپایداری و آسیب‌پذیری شبکه‌های عصبی شوند، مانند نمونه‌های خصمانه^۲. این نقاط ضعف انگیزه‌ای دیگر برای درک بهتر دینامیک داخلی شبکه‌های عصبی هستند. در شکل ۲ معماری شبکه‌های DMLP نشان داده شده است.



شکل ۲- معماری شبکه DMLP (Scabini & Bruno, 2023)

^۱ Stochastic Gradient Descent

^۲ Adversarial Samples

برای ارزیابی عملکرد مدل‌های دسته‌بندی مورد استفاده در این مطالعه، مجموعه‌ای جامع از معیارهای مبتنی بر برچسب و مبتنی بر احتمال استفاده شد. معیارهای مبتنی بر برچسب شامل دقت^۱، حساسیت^۲، صحت^۳، امتیاز^۴ F1، دقت متوازن^۵، Specificity، کاپا کوهن^۶، و ضریب ماتریس متقابل^۷ هستند، در حالی که معیارهای مبتنی بر احتمال شامل Log-Loss^۸، AUROC^۹ و AUPRC^{۱۰} می‌شوند.

به منظور محاسبه معیارهای ارزیابی، یک از پیش نیازهای مدل‌های طبقه‌بندی محاسبه ماتریس آشفتگی^{۱۱} است. ماتریس آشفتگی در مسائل چندکلاسه یک ابزار ساده و کاربردی است که نتیجه پیش‌بینی مدل را در مقابل برچسب‌های واقعی نمایش می‌دهد. این ماتریس یک جدول مربعی $n \times n$ است که در آن سطرها نشان‌دهنده کلاس‌های واقعی و ستون‌ها نشان‌دهنده کلاس‌های پیش‌بینی شده یا برعکس هستند. هر خانه (i, j) تعداد نمونه‌هایی را نشان می‌دهد که واقعاً از کلاس i بوده‌اند اما مدل آن‌ها را به کلاس j تخصیص داده است. از این ماتریس می‌توان معیارهای کلیدی و مصادیقی مانند نرخ خطاهای بین‌کلاسی و ماتریس اشتباهات رایج را استخراج کرد. به خصوص در مسائل چندکلاسه با کلاس‌های نامتوازن، بررسی ردیف‌ها و ستون‌ها به‌طور همزمان به شناسایی کلاس‌هایی که به اشتباه با هم مخلوط می‌شوند کمک می‌کند و با استفاده از درصدی نرمال شده (مثلاً به ازای هر کلاس) به مقایسه منصفانه‌تری دست می‌دهد. ماتریس آشفتگی برای یک مسئله دسته‌بندی با C کلاس به صورت زیر تعریف می‌شود:

$$\begin{bmatrix} CM_{11} & CM_{12} & \dots & CM_{1c} \\ CM_{21} & CM_{22} & \dots & CM_{2c} \\ \vdots & \vdots & \ddots & \vdots \\ CM_{c1} & CM_{c2} & \dots & CM_{cc} \end{bmatrix} \quad (3)$$

که در آن CM_{ij} تعداد نمونه‌هایی است که واقعی کلاس i و پیش‌بینی شده به عنوان کلاس j هستند. برای هر کلاس C می‌توان عناصر زیر را تعریف کرد:

$$\text{True Positive: } TP_c = CM_{cc} \quad (4)$$

$$\text{True Negative: } TN_c = \sum_{i \neq c, j \neq c} CM_{ij} \quad (5)$$

$$\text{False Positive: } FP_c = \sum_{i \neq c} CM_{ic} \quad (6)$$

¹ Accuracy

² Recall

³ Precision

⁴ F1-score

⁵ Balanced Accuracy

⁶ Cohen's Kappa

⁷ MCC

⁸ Cross-Entropy Loss

⁹ Area Under ROC Curve

¹⁰ Area Under Precision-Recall Curve

¹¹ confusion matrix

$$\text{True Positive: } FN_c = \sum_{j \neq c} CM_{cj} \quad (7)$$

- **دقت:** نسبت نمونه‌های درست پیش‌بینی شده به کل نمونه‌ها (Gireen Naidu et al., 2023; YA Nanehkaran, Zhu Licai, Junde Chen, Qiu Zhongpan, et al., 2022)

$$\text{Accuracy}_c = \frac{\sum_{c=1}^C TP_c}{\sum_{c=1}^C (TP_c + FP_c + TN_c + FN_c)} \quad (8)$$

- **حساسیت:** برای هر کلاس C: (Einy et al., 2021a; Gireen Naidu et al., 2023)

$$\text{Recall}_c = \frac{TP_c}{TP_c + FN_c} \quad (9)$$

$$\text{Recall}_{macro} = \frac{1}{C} \sum_{c=1}^C \text{Recall}_c \quad (10)$$

- **صحت:** برای هر کلاس C: (Gireen Naidu et al., 2023; YA Nanehkaran, Zhu Licai, Junde Chen, Ahmed AM Jamel, et al., 2022)

$$\text{Precision}_c = \frac{TP_c}{TP_c + FP_c} \quad (11)$$

$$\text{Precision}_{macro} = \frac{1}{C} \sum_{c=1}^C \text{Precision}_c \quad (12)$$

- **امتیاز F1:** میانگین هارمونیک حساسیت و صحت برای هر کلاس C

$$F1_c = 2 \cdot \frac{\text{Precision}_c \cdot \text{Recall}_c}{\text{Precision}_c + \text{Recall}_c} \quad (13)$$

- **دقت متوازن**

$$\text{Balanced Accuracy} = \frac{1}{C} \sum_{c=1}^C \frac{TP_c}{TP_c + FN_c} \quad (14)$$

- **Specificity:** برای هر کلاس C: (Einy et al., 2023; Gireen Naidu et al., 2023)

$$\text{Specificity}_c = \frac{TN_c}{TN_c + FP_c} \quad (15)$$

$$\text{Specificity}_{macro} = \frac{1}{C} \sum_{c=1}^C \text{Specificity}_c \quad (16)$$

- **کاپا کوهن**

$$\kappa = \frac{P_0 - P_e}{1 + P_e} \quad (17)$$

$$\mathcal{P}_0 = Accuracy_c \quad (18)$$

$$\mathcal{P}_e = \sum_{c=1}^C \frac{(TP_c + FN_c)(TP_c + FP_c)}{N^2} \quad (19)$$

که در آن n تعداد کل نمونه هاست.

• ضریب ماتریس متقابل (MCC): برای هر کلاس C (Chicco & Jurman, 2020):

$$MCC = \frac{\sum_{k=1}^C \sum_{l=1}^C \sum_{m=1}^C CM_{kk} \cdot CM_{lm} - CM_{kl} \cdot CM_{mk}}{\sqrt{(\sum_{k=1}^C (\sum_{l=1}^C CM_{kl})) (\sum_{k \neq l} \sum_{l'=1}^C CM_{k'l'})} (\sum_{k=1}^C (\sum_{l=1}^C CM_{lk})) (\sum_{k \neq l} \sum_{l'=1}^C CM_{l'l'})}} \quad (20)$$

که در آن k, l, m کلاس‌های خاص و k', l' شاخصی برای همه کلاس‌های دیگر (مجزا از k و l) است.

معیارهای مبتنی بر احتمال

$$LogLoss = \frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(\mathcal{P}_{i,c}) \quad (21)$$

که در آن $y_{i,c} = 1$ اگر نمونه i متعلق به کلاس C باشد و 0 در غیر این صورت، و $\mathcal{P}_{i,c}$ احتمال پیش‌بینی شده توسط مدل برای کلاس C است.

• AUROC: برای هر کلاس C با استراتژی One-vs-Rest

$$AUROC_{macro} = \frac{1}{C} \sum_{c=1}^C AUROC_c \quad (22)$$

که در آن C تعداد کلاس‌ها و $AUROC_c$ مساحت زیر منحنی ROC برای کلاس C (زمانی که کلاس C به عنوان "مثبت" و همه کلاس‌های دیگر به عنوان "منفی" در نظر گرفته شوند). برای هر کلاس C، $AUROC_c$ با محاسبه‌ی نرخ مثبت صحیح (TPR^1) و نرخ منفی صحیح (FPR^2) به دست می‌آید:

$$TPR_c = \frac{TP_c}{TP_c + FN_c} \quad (23)$$

$$FPR_c = \frac{FP_c}{FP_c + TN_c} \quad (24)$$

سپس مساحت منحنی (با انتگرال‌گیری یا تقریب عددی) محاسبه می‌شود.

• AUPRC: برای هر کلاس C

$$AUPRC_{macro} = \frac{1}{C} \sum_{c=1}^C AUPRC_c \quad (25)$$

¹ True Positive Rate

² False Positive Rate

که در آن $AUPRC_c$ مساحت زیر منحنی Precision-Recall برای کلاس c. هر کلاس با تعریف Precision و Recall ارزیابی می‌شود. سپس مساحت زیر منحنی PR محاسبه می‌شود (مثلاً با انتگرال گیری عددی یا الگوریتم‌هایی مثل trapezoidal rule).

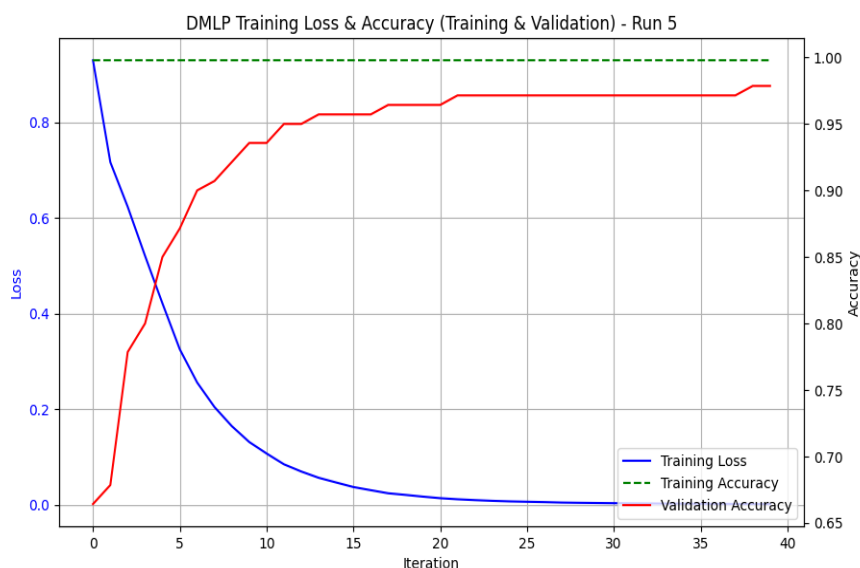
یافته‌ها

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

همانطور که در جدول ۱ نشان داده شده است، ویژگی‌های موجود در مجموعه داده تحول دیجیتال ترکیبی از داده‌های پیوسته است. از این رو در ادامه ابتدا ویژگی‌ها به گام پیش پردازشی ارسال می‌شوند که در پاکسازی و نرمالسازی داده‌ها به منظور از بین بردن تأثیر منفی داده‌های دسته‌ای و پیوسته بر هم اتفاق می‌افتد. در نهایت این داده‌ها به منظور طبقه بندی به عنوان ورودی شبکه‌های *DMLP* و سایر روش‌های طبقه بندی مورد استفاده قرار می‌گیرد. شبکه‌های *DMLP* با توجه به ماهیت خود اقدام به آموزش داده‌ها و افزایش دقت طبقه بندی و همچنین کاهش خطای آموزشی در داده‌ها می‌نماید. در شکل ۳ نمودار روند آموزش و افزایش دقت و کاهش خطای آموزشی *DMLP* نشان داده شده است.




شکل ۳- روند آموزش شبکه DMLP


همانطور که در شکل ۳ می توان دید، شبکه های DMLP با توجه به کمبود نمونه ها و آموزش در مراحل اولیه دارای دقت کم و خطای بالای آموزشی هستند که رفته رفته با آموزش الگوهای مربوط به تحول دیجیتال بر اساس فاکتورهای ورودی، این مقدار دقت افزایش یافته و خطا نیز بالطبع کاهش میس یابد تا این که به نقطه بهینه ای همگرا شود. سایر روش های طبقه بندی نیز بر اساس ماهیت خود اقدام به آموزش بر روی داده های می نماید تا از الگوهای به دست آمده برای پیش بینی سطح تغییرات مورد نیاز برای تحول دیجیتال شرکت های جدید در مجموعه داده تست استفاده کنند.

در این مقاله داده های موجود در مجموعه داده به دو بخش آموزشی و آزمایش تقسیم شدند که الگوهای سطح تغییرات مورد نیاز برای تحول دیجیتال بر اساس داده های آموزشی استخراج شد. حال به منظور ارزیابی دل های یادگیری ماشین در این بخش از مقاله به بررسی معیارهای ارزیابی بر اساس داده ها آزمایشی در این مجموعه داده خواهیم پرداخت. داده های آزمایشی ۳۰ درصد از کل داده ها را تشکیل می دهند که مدل های یادگیری تا کنون با این نمونه ها برخورد نداشته اند و به عنوان نمونه های جدید با آن ها برخورد می شود. همانطور که در بخش قبلی اشاره شد، در این مقاله دو دسته معیارهای ارزیابی مبتنی بر برچسب و مبتنی بر احتمال برای ارزیابی روش های مورد استفاده به کار رفته است. از سوی دیگر با توجه به این که در آزمایش های یادگیری ماشین، نتایج به صورت میانگین چندین بار اجرا گزارش می شوند تا اثر تصادفی بودن کاهش یابد، واریانس کم شود و ارزیابی عملکرد مدل به شکلی قابل اعتمادتر و از نظر آماری معتبرتر انجام گیرد، در روش پیشنهادی نتایج میانگین ۲۰ بار اجرا گزارش شده است. در این راستا، در شکل های ۴ تا ۱۱ به ترتیب معیارهای ارزیابی شامل دقت، دقت متوازن، حساسیت، صحت، امتیاز $F1$ ، $Specificity$ ، کاپا کوهن و MCC که در دسته معیارهای ارزیابی مبتنی بر برچسب هستند، نشان داده شده اند. از سوی دیگر در شکل ها ۱۲ تا ۱۴ معیارهای مبتنی بر احتمال

شامل $AUROC$ ، $Log-Loss$ و $AUPRC$ نشان داده شده‌اند. همه این شکل‌ها شامل دو زیر شکل هستند که در آن زیر شکل (الف) نمودار میانگین معیار ارزیابی در طول اجراها و زیر شکل (ب) نمودار جعبه‌ای میانگین کل معیار ارزیابی در مدل‌های طبقه‌بندی مختلف را نشان می‌دهد.




(الف)




(ب)

شکل ۴ - میانگین معیار دقت الف: در طول اجراها، ب نمودار جعبه‌ای میانگین کل

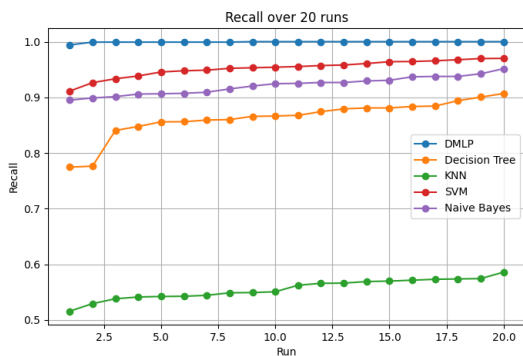


(الف)

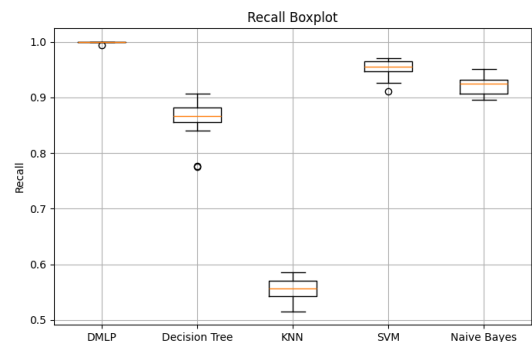


(ب)

شکل ۵ - میانگین معیار دقت متوازن الف: در طول اجراها، ب نمودار جعبه‌ای میانگین کل




(الف)

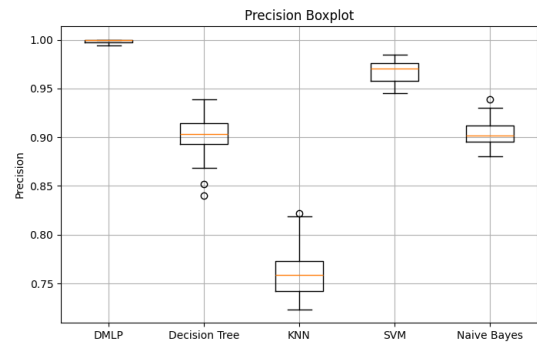


(ب)

شکل ۶ - میانگین معیار حساسیت متوازن الف: در طول اجراها، ب نمودار جعبه‌ای میانگین کل

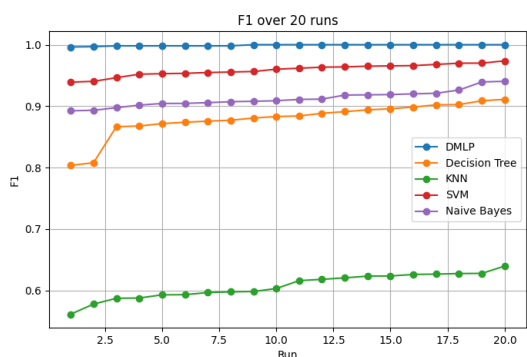


(الف)

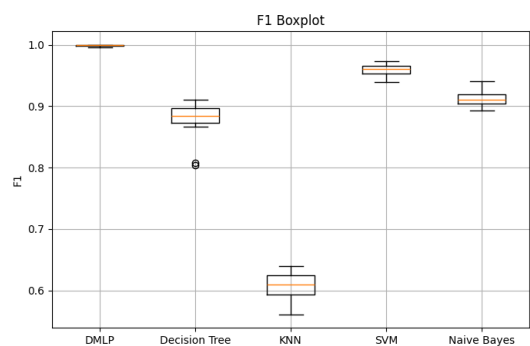


(ب)

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




(الف)

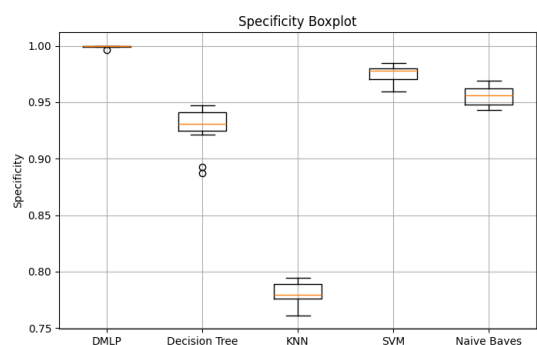


(ب)

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

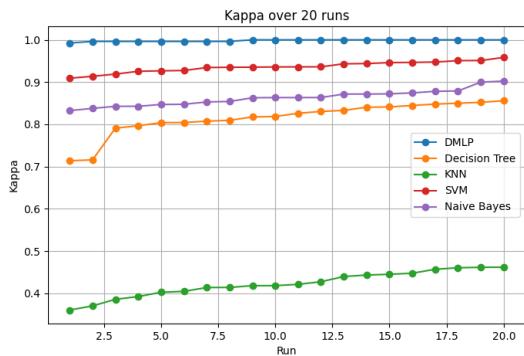


(الف)

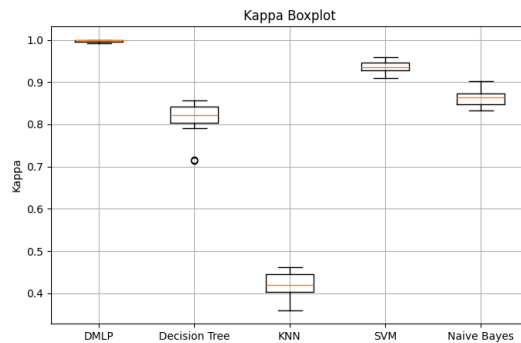


(ب)

شکل ۹ - میانگین معیار $Specificity$ متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

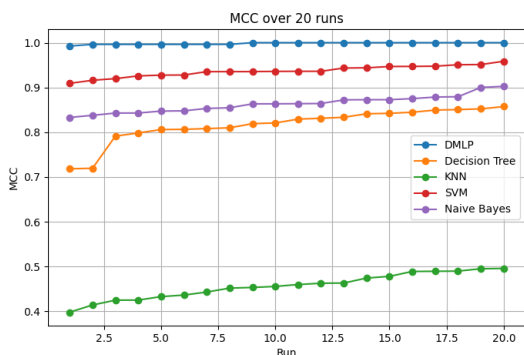


(الف)

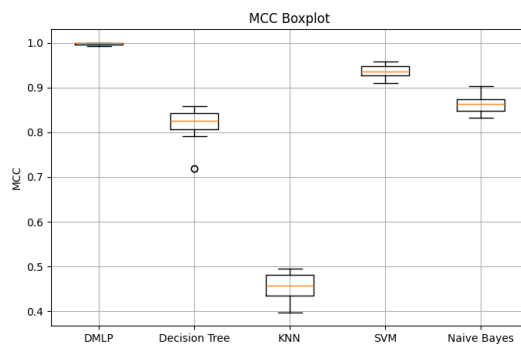


(ب)

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

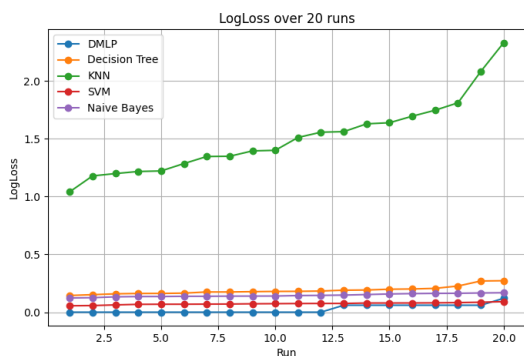


(الف)

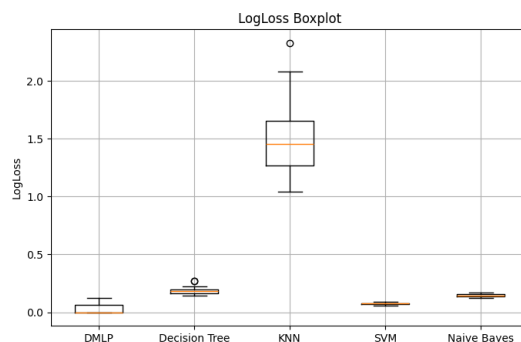


(ب)

شکل ۱۱ - میانگین معیار MCC کوهن متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

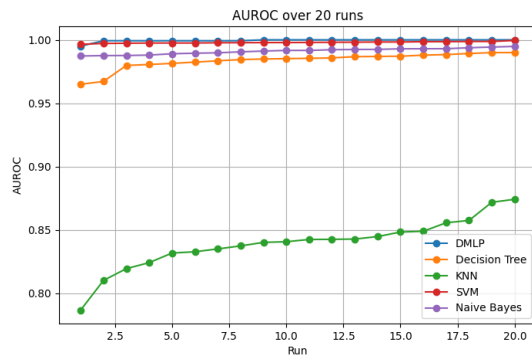


(الف)

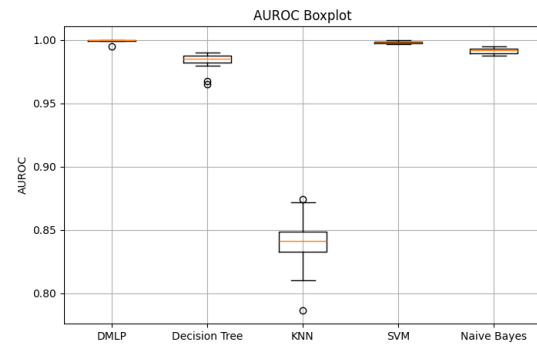


(ب)

شکل ۱۲ - میانگین معیار Log Loss کوهن متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل




(الف)

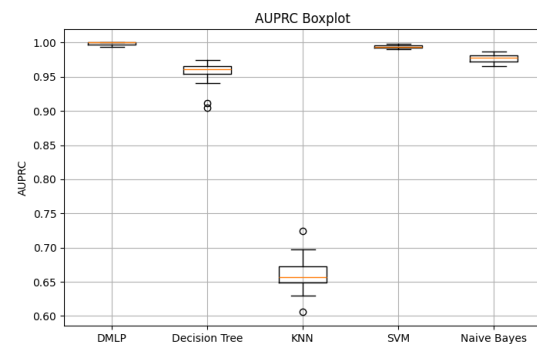


(ب)

شکل ۱۳ - میانگین معیار *AUROC* کوهن متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل



(الف)



(ب)

شکل ۱۴ - میانگین معیار *AUPRC* کوهن متوازن الف: در طول اجراها، ب نمودار جعبه ای میانگین کل

همانطور که در شکل‌های ۴ تا ۱۴ قابل مشاهده است، روش پیشنهادی بر اساس یادگیری توسط شبکه‌های *DMLP* به منظور پیش بینی سطح تغییرات مورد نیاز برای فرایند تحول دیجیتال در شرکت‌های جدید از نظر معیارهای ارزیابی مبتنی بر بچسب و مبتنی بر احتمال، مقادیر بالاتری نسبت به سایر روش‌های طبقه بندی هم در طول همه دورهای اجرا و هم در میانگین کل این معیارهای ارزیابی به دست آورده است. از این رو برای بررسی اختلاف بین مقادیر معیارهای ارزیابی بین روش *DMLP* و سایر روش‌های طبقه بندی، در جدول ۲ مقادیر میانگین کل معیارهای ارزیابی برای مدل‌های طبقه بندی مختلف نشان داده شده است. علاوه بر این به منظور بررسی پایداری نتایج در جدول ۳ مقادیر انحراف معیار کل معیارهای ارزیابی برای مدل‌های طبقه بندی مختلف نشان داده شده است.

جدول ۲- مقادیر میانگین کل معیارهای ارزیابی برای مدل‌های طبقه بندی

Naive Bayes	SVM	KNN	Decision Tree	DMLP	
۰.۹۳۸۸	۰.۹۷۲۰	۰.۷۹۰۱	۰.۹۲۳۰	۰.۹۹۸۴	Accuracy
۰.۹۲۱۴	۰.۹۵۲۲	۰.۵۵۵۷	۰.۸۶۵۸	۰.۹۹۹۴	BalancedAcc
۰.۹۲۱۴	۰.۹۵۲۲	۰.۵۵۵۷	۰.۸۶۵۸	۰.۹۹۹۴	Recall
۰.۹۰۵۰	۰.۹۶۶۶	۰.۷۶۳۳	۰.۹۰۶۵	۰.۹۹۸۸	Precision
۰.۹۱۲۴	۰.۹۵۸۹	۰.۶۰۷۳	۰.۸۸۳۴	۰.۹۹۹۱	F ₁
۰.۹۵۴۸	۰.۹۷۵۴	۰.۷۸۰۹	۰.۹۳۱۱	۰.۹۹۹۶	Specificity
۰.۸۶۳۰	۰.۹۳۶۱	۰.۴۲۲۲	۰.۸۲۰۷	۰.۹۹۸۳	Kappa
۰.۸۶۳۳	۰.۹۳۶۴	۰.۴۵۶۶	۰.۸۲۲۳	۰.۹۹۸۳	MCC
۰.۱۴۵۵	۰.۰۷۳۹	۱.۵۰۹۰	۰.۱۸۸۰	۰.۰۲۷۰	LogLoss
۰.۹۹۱۱	۰.۹۹۸۰	۰.۸۳۹۴	۰.۹۸۳۹	۰.۹۹۹۵	AUROC
۰.۹۷۶۷	۰.۹۹۴۲	۰.۶۶۰۲	۰.۹۵۷۰	۰.۹۹۹۳	AUPRC

جدول ۳- مقادیر انحراف معیار کل معیارهای ارزیابی برای مدل‌های طبقه بندی


Naive Bayes	SVM	KNN	Decision Tree	DMLP	
۰.۰۰۸۱	۰.۰۰۵۴	۰.۰۰۸۹	۰.۰۱۲۴	۰.۰۰۱۰	Accuracy
۰.۰۱۵۵	۰.۰۱۴۹	۰.۰۱۷۶	۰.۰۲۵۵	۰.۰۰۱۳	BalancedAcc
۰.۰۱۵۵	۰.۰۱۴۹	۰.۰۱۷۶	۰.۰۲۵۵	۰.۰۰۱۳	Recall
۰.۰۱۴۹	۰.۰۱۱۴	۰.۰۲۶۷	۰.۰۲۰۴	۰.۰۰۱۷	Precision
۰.۰۱۲۸	۰.۰۰۹۴	۰.۰۲۰۰	۰.۰۲۱۰	۰.۰۰۱۲	F ₁
۰.۰۰۷۸	۰.۰۰۶۶	۰.۰۰۹۴	۰.۰۱۲۶	۰.۰۰۰۹	Specificity
۰.۰۱۸۵	۰.۰۱۲۶	۰.۰۲۹۴	۰.۰۳۰۲	۰.۰۰۲۲	Kappa
۰.۰۱۸۵	۰.۰۱۲۴	۰.۰۲۷۹	۰.۰۲۹۵	۰.۰۰۲۲	MCC
۰.۰۱۳۳	۰.۰۰۸۴	۰.۳۱۱۵	۰.۰۲۴۰	۰.۰۳۵۴	LogLoss
۰.۰۰۲۳	۰.۰۰۰۶	۰.۰۱۹۳	۰.۰۰۴۳	۰.۰۰۱۱	AUROC
۰.۰۰۶۰	۰.۰۰۲۱	۰.۰۲۴۱	۰.۰۱۱۵	۰.۰۰۲۱	AUPRC

با توجه به جدول ۲ می‌توان دید، در روش پیشنهادی *DMLP* نسبت به سایر روش‌ها طبقه بندی در پیش‌بینی سطح تغییرات مورد نیاز در فرایند تحول دیجیتال در ازای مقادیر میانگین کل معیارهای ارزیابی مبتنی بر برچسب و مبتنی بر احتمال در طی مراحل تکرار اجرا، نتایج چشمگیری به دست آورده است. این نتایج چشمگیر حاصل از یادگیری عمیق در لایه‌های میانی *DMLP* بر روی فاکتورهای مهم در تحول دیجیتال شرکت‌ها است.

لازم به ذکر است که کلیه نتایج گزارش شده در این پژوهش مربوط به مجموعه داده‌های تست می‌باشد. از آنجا که معیارهای ارزیابی صرفاً بر اساس داده‌های دیده‌نشده محاسبه شده‌اند، مقادیر بالای این معیارها نشان‌دهنده‌ی بیش‌برازش مدل نبوده و بیانگر توان تعمیم مناسب روش پیشنهادی بر داده‌های جدید است.

همچنین مطابق جدول ۳ مشاهده می‌شود که در روش پیشنهادی، نتایج حاصل از *DMLP* در مقایسه با سایر روش‌های طبقه‌بندی، طی تکرارهای اجرا دارای کمترین مقدار انحراف معیار هستند. این امر نشان می‌دهد که *DMLP* علاوه بر دستیابی به دقت بالا، در برابر تغییرات ناشی از نمونه‌گیری و اجرای مجدد آزمایش‌ها نیز از ثبات بیشتری برخوردار بوده و نتایج آن قابل اعتمادتر است.

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 (Xinxian & Jianhui, 2022; Zhu et al., 2024)، مقایسه می‌کنیم که در شکل ۱۹ قابل مشاهده است.



شکل ۱۹- مقایسه روش پیشنهادی با روش‌های پیشین از نظر معیار دقت

همان‌طور که در شکل ۱۹ مشاهده می‌شود، روش پیشنهادی با بهره‌گیری از قابلیت‌های یادگیری عمیق در لایه‌های میانی شبکه *DMLP* توانسته است در مقایسه با سایر روش‌های پیشین، دقت بالاتری در پیش‌بینی نمونه‌های جدید از مجموعه داده تحول دیجیتال به دست آورد. دلیل این برتری آن است که *DMLP* با استفاده از ساختار سلسله‌مراتبی خود قادر است ویژگی‌های پیچیده و الگوهای پنهان موجود در داده‌ها را به‌صورت خودکار استخراج و بازنمایی کند، در حالی که روش‌های کلاسیک عمدتاً متکی بر انتخاب دستی ویژگی‌ها و مدل‌سازی سطحی هستند. این امر سبب می‌شود که مدل پیشنهادی نه تنها به ویژگی‌های ابتدایی داده‌ها بسنده نکند، بلکه با ترکیب سطوح مختلف ویژگی‌ها، نمایشی انتزاعی‌تر و قدرتمندتر از داده ایجاد کند. در نتیجه، توانایی تمایز میان نمونه‌ها افزایش یافته و عملکرد پیش‌بینی در مواجهه با داده‌های ناشناخته به شکل محسوسی بهبود یافته است که نشان‌دهنده برتری و اثربخشی رویکرد پیشنهادی در حوزه تحلیل داده‌های تحول دیجیتال است.

به‌منظور افزایش شفافیت نتایج و ارتقای ارزش کاربردی مدل پیشنهادی، پس از مرحله آموزش و ارزیابی مدل‌های طبقه‌بندی، یک لایه تحلیل تفسیرپذیر بر خروجی مدل‌ها اعمال شد. هدف از این مرحله، بررسی میزان تأثیر هر یک از متغیرهای ورودی بر پیش‌بینی سطح تحول دیجیتال سازمان‌ها و فراهم‌سازی درکی روشن‌تر از رفتار مدل یادگیری عمیق است. این تحلیل به‌عنوان مکمل مرحله پیش‌بینی در نظر گرفته شده و تلاش دارد ارتباط میان عوامل سازمانی و سطوح مختلف تحول دیجیتال را به‌صورت قابل تفسیر ارائه دهد.

در این پژوهش، اهمیت هر یک از ویژگی‌ها با استفاده از تحلیل حساسیت خروجی مدل نسبت به تغییرات متغیرهای ورودی مورد ارزیابی قرار گرفت. ویژگی‌هایی مانند هزینه‌ها و شدت فعالیت‌های تحقیق و توسعه، نسبت فناوری، سطح تحصیلات و مهارت‌های مدیریتی، زیرساخت‌های دیجیتال، شبکه‌های سازمانی و میزان تعامل با مشتریان به‌طور مجزا تحلیل شدند تا نقش هر یک در تمایز میان سطوح مختلف تحول دیجیتال سازمان‌ها (پایین، متوسط و بالا) مشخص شود. نتایج این تحلیل نشان می‌دهد که سهم متغیرها در فرآیند پیش‌بینی یکسان نیست و برخی عوامل، به‌ویژه آمادگی فناوری و مهارت نیروی انسانی، اثرگذاری بیشتری بر تشخیص سازمان‌های با سطح بالای تحول دیجیتال دارند.

افزودن این لایه تفسیرپذیر موجب می‌شود مدل پیشنهادی صرفاً به‌عنوان یک ابزار پیش‌بینی تلقی نشود، بلکه به‌عنوان ابزاری تحلیلی برای پشتیبانی از تصمیم‌گیری‌های مدیریتی نیز قابل استفاده باشد. به این ترتیب، مدیران و تصمیم‌گیران می‌توانند بر اساس نتایج این تحلیل، حوزه‌هایی را که بیشترین نیاز به بهبود و سرمایه‌گذاری دارند شناسایی کرده و برنامه‌های تحول دیجیتال را به‌صورت هدفمندتر طراحی کنند.

بحث و نتیجه‌گیری

هدف اصلی این پژوهش ارائه یک چارچوب پیش‌بینانه مبتنی بر یادگیری عمیق برای پیش‌بینی سطح تغییرات بنیادین موردنیاز سازمان‌ها در فرآیند تحول دیجیتال بود. نتایج حاصل از تحلیل‌های تجربی نشان داد که مدل مبتنی بر شبکه عصبی پرسپترون چندلایه عمیق (*DMLP*) در مقایسه با الگوریتم‌های طبقه‌بندی متداول عملکردی به‌مراتب برتر ارائه کرده است. دستیابی به مقادیر بسیار بالا در شاخص‌هایی نظیر *Accuracy*

Balanced Accuracy، F1، AUROC و MCC نشان می‌دهد که مدل پیشنهادی توانسته روابط پیچیده میان متغیرهای سازمانی و سطح تحول دیجیتال را به طور مؤثر استخراج کند. این یافته‌ها تأیید می‌کند که تحول دیجیتال پدیده‌ای چندبعدی است و تحلیل آن نیازمند ابزارهای محاسباتی پیشرفته و مدل‌های غیرخطی است (Omol, 2024; Paul et al., 2024).

برتری مدل یادگیری عمیق نسبت به روش‌های کلاسیک را می‌توان در توانایی آن برای استخراج الگوهای پنهان داده‌ها جست‌وجو کرد. شبکه‌های عصبی عمیق با بهره‌گیری از لایه‌های میانی قادرند نمایش‌های انتزاعی از داده‌ها ایجاد کنند و تعاملات پیچیده میان عوامل سازمانی، فناوری و انسانی را شناسایی نمایند (A. Momeni et al., 2025; Scabini & Bruno, 2023). این ویژگی سبب می‌شود که مدل‌های عمیق در مسائل مرتبط با تحول دیجیتال که دارای روابط غیرخطی و وابستگی‌های چندسطحی هستند، عملکرد دقیق‌تری ارائه دهند. یافته‌های این پژوهش با مطالعاتی که نقش یادگیری عمیق را در پیش‌بینی تصمیمات پیچیده سازمانی و صنعتی نشان داده‌اند همسو است (Derakhshan Barjoei et al., 2025; Sadr et al., 2025).

نتایج نشان داد که متغیرهایی نظیر زیرساخت دیجیتال، سطح مهارت مدیریتی، تعامل با مشتری و سرمایه‌گذاری تحقیق و توسعه بیشترین نقش را در تشخیص سطح تحول دیجیتال سازمان‌ها دارند. این یافته با ادبیات تحول دیجیتال همخوانی دارد که تحول سازمانی را حاصل تعامل فناوری، سرمایه انسانی و راهبرد مدیریتی می‌داند (Butt et al., 2024; Vial, 2021). پژوهش‌های پیشین نیز تأکید کرده‌اند که موفقیت تحول دیجیتال نه صرفاً به فناوری بلکه به ظرفیت یادگیری سازمان و طراحی فرهنگ دیجیتال وابسته است (Hendrawan et al., 2024; Kusuma et al., 2024). دقت بسیار بالای مدل پیشنهادی نشان می‌دهد که استفاده از داده‌های واقعی سازمانی می‌تواند مبنایی معتبر برای پیش‌بینی میزان تغییرات موردنیاز فراهم کند. مطالعات اخیر نشان داده‌اند که مدل‌های یادگیری ماشین در تحلیل فرآیندهای تحول دیجیتال می‌توانند بینش‌هایی فراتر از تحلیل‌های سنتی ارائه دهند و به سیاست‌گذاری راهبردی کمک کنند (Chiu et al., 2024; Zhu et al., 2024). نتایج این پژوهش نیز تأیید می‌کند که تحلیل داده‌محور می‌تواند فاصله میان تصمیم‌گیری مدیریتی و واقعیت‌های عملیاتی سازمان را کاهش دهد.

یکی دیگر از یافته‌های مهم پژوهش، پایداری بالای مدل DMLP در تکرارهای مختلف اجرا بود که با انحراف معیار بسیار پایین شاخص‌های ارزیابی همراه شد. این موضوع نشان‌دهنده قابلیت تعمیم مناسب مدل در مواجهه با داده‌های دیده‌نشده است. پژوهشگران حوزه یادگیری ماشین بیان کرده‌اند که ثبات آماری یکی از مهم‌ترین معیارهای اعتبار مدل‌های پیش‌بینی است (Chicco & Jurman, 2020; G. Naidu et al., 2023). همچنین استفاده همزمان از معیارهایی نظیر AUROC و Kappa امکان ارزیابی جامع عملکرد مدل را فراهم می‌کند (Çorbacioğlu, 2023; Aksel, 2023; Rau & Shih, 2021).

نتایج مقایسه‌ای میان الگوریتم‌ها نشان داد که روش‌هایی مانند KNN و Decision Tree در تشخیص الگوهای پیچیده تحول دیجیتال عملکرد ضعیف‌تری دارند. این یافته با مطالعاتی که محدودیت مدل‌های سطحی در تحلیل داده‌های پیچیده سازمانی را نشان داده‌اند همسو است (Kim & Xinxian & Jianhui, 2022; Kim, 2022). در مقابل، مدل‌های مبتنی بر یادگیری عمیق قادرند روابط چندبعدی میان متغیرها را بدون نیاز به انتخاب دستی ویژگی‌ها استخراج کنند (Mienye et al., 2024; Zhao et al., 2024).

یکی از دلایل کلیدی موفقیت مدل پیشنهادی، اجرای دقیق مرحله پیش‌پردازش داده‌ها شامل پاکسازی و نرمال‌سازی بوده است. مطالعات سیستماتیک نشان داده‌اند که کیفیت داده‌ها تأثیر مستقیمی بر عملکرد مدل‌های یادگیری ماشین دارد (P. O. Côté et al., 2024; Kalinina et al., 2025). استفاده از تکنیک‌های استانداردسازی داده باعث شده نویز داده کاهش یافته و مدل بتواند ساختار واقعی روابط را شناسایی کند. این نتیجه با پژوهش‌های حوزه بهینه‌سازی مدل‌های شبکه عصبی نیز همخوانی دارد (Lamtar-Gholipoor et al., 2024; Lamtar et al., 2024). (Gholipoor et al., 2024).

از منظر مفهومی، یافته‌های پژوهش تأیید می‌کند که تحول دیجیتال فرآیندی تدریجی اما مبتنی بر تصمیم‌گیری هوشمند است. استفاده از هوش مصنوعی امکان تحلیل آینده‌نگر و پیش‌بینی ریسک‌های تحول را فراهم می‌کند (Aldoseri et al., 2024; Perifanis & Kitsios, 2023). پژوهش‌های اخیر نیز نشان داده‌اند که ادغام انسان و هوش مصنوعی می‌تواند نقش میانجی نوآوری فناورانه در تحول سازمانی را تقویت کند (Cui et al., 2025).

علاوه بر این، نتایج پژوهش نشان داد که مدل پیشنهادی قادر است سازمان‌ها را بر اساس شکاف دیجیتال میان وضعیت موجود و وضعیت مطلوب دسته‌بندی کند. این موضوع با چارچوب‌های تحول دیجیتال که بر تحلیل آمادگی سازمانی تأکید دارند همسو است (Elia et al., 2024; Kraus et al., 2022). چنین طبقه‌بندی‌هایی می‌تواند به مدیران کمک کند تا منابع را هدفمند تخصیص داده و مسیر تحول را مرحله‌بندی کنند. یافته‌های این پژوهش همچنین نشان می‌دهد که بهره‌گیری از شبکه‌های عصبی پیشرفته و الگوریتم‌های نوین یادگیری می‌تواند به کاهش عدم قطعیت تصمیمات مدیریتی کمک کند. پژوهش‌های مرتبط با شبکه‌های گرافی و شبکه‌های نوری نیز نشان داده‌اند که معماری‌های پیشرفته یادگیری عمیق توان پیش‌بینی سیستم‌های پیچیده را افزایش می‌دهند (Corso et al., 2024; Fu et al., 2024). در حوزه منابع انسانی نیز تحول دیجیتال مبتنی بر تحلیل داده‌ها به بهبود تصمیمات مدیریتی و افزایش بهره‌وری سازمانی منجر شده است (Zhang & Chen, 2024).

در عین حال، نتایج پژوهش نشان می‌دهد که تحول دیجیتال صرفاً یک پروژه فناورانه نیست، بلکه مستلزم تغییرات ساختاری و فرهنگی در سازمان است. مطالعات مختلف نشان داده‌اند که مقاومت سازمانی، نگرانی‌های امنیتی و سوگیری الگوریتمی از چالش‌های مهم پذیرش فناوری‌های هوشمند

محسوب می‌شوند (Lemieux, 2023; Mhlanga, 2023). با این حال، مزایایی مانند خودکارسازی وظایف، افزایش بهره‌وری و بهبود تجربه مشتریان سازمان‌ها را به سمت پذیرش تحول دیجیتال سوق داده است (Gołąb-Andrzejak, 2023; Klopov et al., 2023).

در مجموع، نتایج پژوهش حاضر نشان می‌دهد که ترکیب یادگیری عمیق با داده‌های واقعی سازمانی می‌تواند چارچوبی عملیاتی برای تحلیل تحول دیجیتال فراهم کند. این یافته‌ها با مطالعاتی که تحول دیجیتال را نتیجه هم‌افزایی فناوری اطلاعات، نوآوری و مدیریت راهبردی می‌دانند همسو است (Chen et al., 2022; Guarda et al., 2021). همچنین نتایج نشان می‌دهد که مدل پیشنهادی نه تنها یک ابزار پیش‌بینی، بلکه یک سیستم پشتیبان تصمیم‌گیری برای هدایت سازمان‌ها در مسیر تحول دیجیتال محسوب می‌شود.

با وجود نتایج قابل توجه پژوهش، برخی محدودیت‌ها باید مورد توجه قرار گیرد. نخست، داده‌های مورد استفاده از یک مجموعه داده استاندارد استخراج شده‌اند و ممکن است تمامی ویژگی‌های خاص صنایع مختلف یا شرایط واقعی سازمان‌ها را به طور کامل منعکس نکنند. دوم، مدل پیشنهادی بر داده‌های تاریخی آموزش دیده است و همانند سایر مدل‌های یادگیری ماشین، عملکرد آن به کیفیت و تنوع داده‌های ورودی وابسته است. سوم، ماهیت جعبه‌سیاه مدل‌های یادگیری عمیق می‌تواند تفسیرپذیری کامل تصمیمات مدل را برای برخی مدیران دشوار سازد. علاوه بر این، تغییرات سریع فناوری ممکن است در بلندمدت نیازمند به‌روزرسانی مداوم مدل باشد.

پژوهش‌های آینده می‌توانند با استفاده از داده‌های چندصنعتی و بین‌المللی، قابلیت تعمیم مدل را افزایش دهند. ترکیب مدل‌های یادگیری عمیق با روش‌های انتخاب ویژگی و مدل‌های ترکیبی یا پشته‌سازی می‌تواند دقت پیش‌بینی را ارتقا دهد. همچنین توسعه مدل‌های قابل توضیح (Explainable AI) می‌تواند شفافیت تصمیمات الگوریتمی را افزایش دهد. استفاده از داده‌های بلادرنگ سازمانی، تحلیل شبکه‌های سازمانی و ترکیب داده‌های متنی و رفتاری نیز می‌تواند مسیرهای جدیدی برای تحلیل تحول دیجیتال ایجاد کند.

بر اساس نتایج پژوهش، سازمان‌ها می‌توانند پیش از اجرای پروژه‌های تحول دیجیتال، سطح آمادگی خود را با استفاده از مدل‌های پیش‌بینانه ارزیابی کنند. مدیران باید سرمایه‌گذاری در زیرساخت‌های داده، توسعه مهارت‌های دیجیتال کارکنان و ایجاد فرهنگ تصمیم‌گیری مبتنی بر داده را در اولویت قرار دهند. همچنین توصیه می‌شود سازمان‌ها از هوش مصنوعی نه صرفاً به عنوان ابزار فناوری، بلکه به عنوان بخشی از راهبرد کلان تحول سازمانی استفاده کنند. بهره‌گیری از چارچوب‌های تحلیلی مشابه مدل پیشنهادی می‌تواند به کاهش ریسک تحول دیجیتال، بهینه‌سازی تخصیص منابع و تسریع دستیابی به مزیت رقابتی پایدار کمک کند.

مشارکت نویسندگان

در نگارش این مقاله تمامی نویسندگان نقش یکسانی ایفا کردند.

تعارض منافع

در انجام مطالعه حاضر، هیچ‌گونه تضاد منافی وجود ندارد.

موازن اخلاقی

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

تشکر و قدردانی

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

Extended Abstract

Introduction

Digital transformation has emerged as one of the most significant organizational phenomena of the twenty-first century, fundamentally reshaping business models, operational processes, and competitive dynamics across industries. Rather than representing a purely technological shift, digital transformation involves a comprehensive reconfiguration of organizational structures, decision-making systems, and value creation mechanisms driven by advanced information technologies and data analytics (Vial, 2021). Organizations increasingly rely on digital technologies to enhance efficiency, improve customer engagement, and sustain competitive advantage in rapidly evolving markets (Paul et al., 2024). Consequently, understanding and predicting organizational readiness for digital transformation has become a critical research and managerial priority.

The integration of artificial intelligence (AI) and machine learning technologies has accelerated digital transformation by enabling organizations to extract actionable insights from large-scale datasets and automate complex decision processes (Aldoseri et al., 2024). AI-driven analytics allows firms to anticipate operational risks, forecast strategic outcomes, and optimize organizational performance through data-informed decision-making (Perifanis & Kitsios, 2023). Previous studies emphasize that digital transformation success depends not only on technological adoption but also on organizational capabilities, managerial competencies, and innovation culture (Butt et al., 2024; Kusuma et al., 2024). As a result, predictive models capable of evaluating transformation requirements have become increasingly valuable.

Machine learning models have demonstrated strong potential in predicting organizational change and digital readiness. Research shows that predictive analytics can support business innovation and technological adaptation by identifying hidden relationships among organizational variables (Chiu et al., 2024; Eom et al., 2024). Advances in deep learning architectures, particularly multilayer neural networks, have significantly enhanced pattern recognition capabilities in complex datasets characterized by nonlinear dependencies

(Mienye et al., 2024; Zhao et al., 2024). These models are capable of extracting hierarchical features automatically, reducing reliance on manual feature engineering and improving predictive accuracy.

Deep neural networks have been successfully applied across multiple domains including healthcare decision optimization, industrial forecasting, and engineering systems analysis, demonstrating superior predictive performance compared with traditional algorithms (Derakhshan Barjoei et al., 2025; Sadr et al., 2025). Structural analyses of fully connected neural networks further confirm that multilayer architectures enable efficient learning of complex representations, thereby improving generalization performance (A. Momeni et al., 2025; Scabini & Bruno, 2023). Within the context of digital transformation, such capabilities are particularly relevant because organizational change processes involve multifactorial interactions among technological, human, and strategic dimensions.

Despite growing research attention, existing studies often focus on conceptual frameworks or qualitative assessments rather than quantitative prediction of transformation intensity. Several investigations highlight the need for data-driven models capable of measuring digital transformation readiness and forecasting organizational change requirements (Omol, 2024; Zhu et al., 2024). Predictive modeling based on real organizational datasets can bridge this gap by transforming digital transformation analysis from descriptive evaluation into operational decision support.

Data quality and preprocessing remain essential components of machine learning-based transformation analysis. Data cleaning, normalization, and feature extraction significantly influence model accuracy and reliability (P. O. Côté et al., 2024; Kalinina et al., 2025). Studies demonstrate that optimized preprocessing pipelines improve convergence stability and predictive performance in neural networks (Lamtar-Gholipoor et al., 2024; Lamtar Gholipoor et al., 2024). Furthermore, standardized datasets enable reproducibility and comparability across digital transformation research contexts (colabsss, 2025).

Evaluation metrics play a crucial role in validating predictive models. Performance indicators such as accuracy, F1-score, Matthews correlation coefficient, and ROC-based metrics provide comprehensive insights into classification effectiveness and generalization capacity (Chicco & Jurman, 2020; Çorbacioğlu & Aksel, 2023; G. Naidu et al., 2023; Rau & Shih, 2021). The application of multiple evaluation measures ensures robust assessment of predictive systems operating in complex organizational environments.

Additionally, digital transformation introduces both opportunities and challenges. While AI adoption enhances innovation and operational efficiency, concerns related to cybersecurity risks, algorithmic bias, and technological dependency remain critical considerations (Lemieux, 2023; Mhlanga, 2023). Nevertheless, empirical evidence suggests that AI-supported transformation significantly improves organizational productivity, decision quality, and customer experience (Gołęb-Andrzejak, 2023; Klopov et al., 2023).

In light of these developments, integrating deep learning techniques with organizational data analytics offers a promising pathway for predicting the level of structural change required in digital transformation initiatives.

Therefore, this study proposes a deep learning–based predictive framework designed to classify organizations according to the magnitude of fundamental changes needed during digital transformation processes.

Methods and Materials

This study adopted a quantitative, data-driven research design grounded in machine learning methodology. A standardized corporate digital transformation dataset was employed as the primary data source. The dataset consisted of 2,000 organizational samples characterized by 23 numerical features representing critical digital transformation indicators such as research and development investment, technological adoption intensity, managerial education level, organizational networks, financial performance metrics, and digital infrastructure capacity.

The dependent variable categorized organizations into three transformation levels—low, medium, and high—representing the degree of structural change required for successful digital transformation. Data preprocessing procedures included data cleaning, missing-value handling, normalization using min–max scaling, and feature extraction to ensure model stability and comparability across algorithms.

Multiple classification models were implemented to evaluate predictive performance, including k-Nearest Neighbor (KNN), Support Vector Machine (SVM), Naive Bayes, Decision Tree, and a Deep Multilayer Perceptron (DMLP) neural network. The deep learning model consisted of multiple hidden layers with nonlinear activation functions enabling hierarchical feature learning.

The dataset was divided into training and testing subsets, with 70% allocated for model training and 30% reserved for validation using unseen samples. Model performance was evaluated using a comprehensive set of statistical metrics including accuracy, balanced accuracy, recall, precision, F1-score, specificity, Cohen’s kappa coefficient, Matthews correlation coefficient, Log-Loss, Area Under the Receiver Operating Characteristic Curve (AUROC), and Area Under the Precision–Recall Curve (AUPRC). Experimental results were averaged across twenty independent runs to ensure statistical robustness and minimize random variation effects.

Findings

The experimental results demonstrate that the proposed deep learning framework achieved superior predictive performance compared with all baseline classification algorithms. The Deep Multilayer Perceptron model attained an overall accuracy of 99.84%, significantly outperforming Decision Tree, SVM, Naive Bayes, and KNN classifiers. Balanced accuracy reached 99.94%, indicating consistent classification performance across all transformation levels.

The model also achieved exceptionally high recall and precision values, resulting in an F1-score exceeding 99%, confirming the reliability of classification outcomes. Specificity and Cohen’s kappa coefficients approached unity, demonstrating strong agreement between predicted and actual class labels. The Matthews correlation coefficient further confirmed near-perfect classification consistency.

Probability-based evaluation metrics supported these findings. The DMLP model achieved extremely low Log-Loss values, indicating high confidence in probabilistic predictions. AUROC and AUPRC scores were close to 1.0, reflecting excellent separability among transformation categories and strong predictive discrimination capability.

Comparative analysis revealed that SVM ranked second in performance but showed noticeably lower stability across repeated experiments. Decision Tree and Naive Bayes achieved moderate predictive performance, while KNN displayed substantial performance degradation, particularly in distinguishing medium and high transformation classes.

Standard deviation analysis indicated that the DMLP model maintained minimal variability across repeated runs, confirming high statistical stability and strong generalization capability when applied to unseen organizational data.

Discussion and Conclusion

The findings demonstrate that deep learning provides a highly effective approach for predicting the level of organizational change required in digital transformation processes. The superior performance of the multilayer neural network highlights the importance of modeling nonlinear relationships among technological, managerial, and structural organizational variables. Digital transformation represents a complex adaptive process influenced by numerous interacting factors, and deep learning architectures appear particularly well suited to capture these multidimensional interactions.

The results suggest that predictive analytics can move digital transformation research beyond descriptive assessment toward operational decision support systems. By accurately classifying organizations according to transformation readiness, predictive models can help managers identify capability gaps, prioritize investment areas, and design phased transformation strategies. Such analytical tools reduce uncertainty in strategic planning and support evidence-based digital governance.

Another key implication concerns organizational intelligence. The ability to forecast transformation intensity enables proactive rather than reactive adaptation to technological change. Organizations can evaluate structural weaknesses before transformation initiatives begin, improving resource allocation efficiency and minimizing implementation risks.

Furthermore, the high stability of the deep learning model indicates strong potential for real-world deployment. Reliable predictive systems are essential for managerial adoption, as decision-makers require consistent outputs across varying operational contexts. The demonstrated robustness of the proposed framework suggests that deep learning-based transformation assessment may become an integral component of future digital strategy development.

From a broader perspective, this study reinforces the view that digital transformation is fundamentally a data-driven phenomenon. Successful transformation depends on organizations' capacity to leverage analytics,

integrate intelligent technologies, and align technological innovation with strategic objectives. Predictive modeling therefore serves as a bridge connecting technological capability with managerial decision-making. In conclusion, the proposed deep learning framework offers a powerful and scalable approach for predicting fundamental organizational changes required during digital transformation. By combining standardized datasets, advanced neural architectures, and rigorous evaluation metrics, the study contributes to both academic research and practical digital transformation management. The approach provides organizations with an intelligent analytical foundation for navigating complex digital transitions and achieving sustainable competitive advantage in increasingly technology-driven environments.

References

- Ahmad, M. F., Husin, N. A. A., Ahmad, A. N. A., Abdullah, H., Wei, C. S., & Nawi, M. (2022). Digital transformation: An exploring barriers and challenges practice of artificial intelligence in manufacturing firms in Malaysia. *Journal of Advanced Research in Applied Sciences and Engineering Technology*. https://semarakilmu.com.my/journals/index.php/applied_sciences_eng_tech/article/view/939
- 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. <https://doi.org/10.3390/su16051790>
- Butt, A., Imran, F., Helo, P., & Kantola, J. (2024). Strategic design of culture for digital transformation. *Long Range Planning*, 57(2), 102415. <https://doi.org/10.1016/j.lrp.2024.102415>
- 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. <https://doi.org/10.1111/acfi.12873>
- Chicco, D., & Jurman, G. (2020). The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*, 21(1), 6. <https://doi.org/10.1186/s12864-019-6413-7>
- Chiu, M. C., Huang, Y. J., & Wei, C. J. (2024). Enhancing SMEs digital transformation through machine learning: A framework for adaptive quality prediction. *Journal of Industrial Information Integration*, 41, 100666. <https://doi.org/10.1016/j.jii.2024.100666>
- colabss. (2025). *Corporate Digital Transformation Dataset*. <https://www.kaggle.com/datasets/colabss/corporate-digital-transformation-dataset>
- Çorbacioğlu, Ş. 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. https://doi.org/10.4103/tjem.tjem_182_23
- Corso, G., Stark, H., Jegelka, S., Jaakkola, T., & Barzilay, R. (2024). Graph neural networks. *Nature Reviews Methods Primers*, 4(1), 17. <https://doi.org/10.1038/s43586-024-00294-7>
- Côté, P.-O., Nikanjam, A., Ahmed, N., Humeniuk, D., & Khomh, F. (2024). Data cleaning and machine learning: a systematic literature review. *Automated Software Engineering*, 31(2), 54.
- Côté, P. O., Nikanjam, A., Ahmed, N., Humeniuk, D., & Khomh, F. (2024). Data cleaning and machine learning: a systematic literature review. *Automated Software Engineering*, 31(2), 54. <https://doi.org/10.1007/s10515-024-00453-w>
- Cui, J., Wan, Q., & Shin, S. (2025). Human-AI integration and sound-vibration technology-driven enterprise digital transformation: The mediating role of technological innovation. *Sound & Vibration*, 59(1), 1733. <https://doi.org/10.59400/sv1733>
- Derakhshan Barjoei, P., Zamani Boroujeni, F., Davami, F., & Habibinikou, H. (2025). A 3D approach design for aircraft landing on runways using Convolutional Neural Networks. *Computational Algorithms and Numerical Dimensions*. https://www.journal-cand.com/article_221731.html
- Einy, S., Oz, C., & Navaei, Y. D. (2021a). The anomaly-and signature-based IDS for network security using hybrid inference systems. *Mathematical Problems in Engineering*, 2021(1), 6639714. <https://doi.org/10.1155/2021/6639714>
- Einy, S., Oz, C., & Navaei, Y. D. (2021b). 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>
- Einy, S., Saygin, H., Hivehchi, H., & Dorostkar Navaei, Y. (2022). Local and deep features based convolutional neural network frameworks for brain MRI anomaly detection. *Complexity*, 2022(1), 3081748. <https://doi.org/10.1155/2022/3081748>
- 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. <https://doi.org/10.1155/2023/2426601>
- 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. <https://doi.org/10.1016/j.bushor.2024.03.007>

- Eom, T., Woo, C., & Chun, D. (2024). Predicting an ICT business process innovation as a digital transformation with machine learning techniques. *Technology Analysis & Strategic Management*, 36(9), 2271-2283. <https://doi.org/10.1080/09537325.2022.2132927>
- Fu, T., Zhang, J., Sun, R., Huang, Y., Xu, W., Yang, S., & Chen, H. (2024). Optical neural networks: progress and challenges. *Light: Science & Applications*, 13(1), 263. <https://doi.org/10.1038/s41377-024-01590-3>
- Gołęb-Andrzejak, E. (2023). AI-powered digital transformation: Tools, benefits and challenges for marketers-case study of LPP. *Procedia Computer Science*, 219, 397-404. <https://doi.org/10.1016/j.procs.2023.01.305>
- Guarda, T., Balseca, J., García, K., González, J., Yagual, F., & Castillo-Beltran, H. (2021). Digital transformation trends and innovation. IOP Conference Series: Materials Science and Engineering,
- 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. <https://doi.org/10.60083/jidt.v6i2.551>
- Kalinina, I., Gozhyj, A., Bidyuk, P., Gozhyi, V., Korobchynskiy, M., & Nadruga, V. (2025). A Systematic Approach to Data Normalization and Standardization in Machine Learning Problems. Lecture Notes in Data Engineering, Computational Intelligence, and Decision-Making, Volume 2: 2024 International Scientific Conference "Intelligent Systems of Decision-Making and Problems of Computational Intelligence", Proceedings,
- Kim, K., & Kim, B. (2022). Decision-making model for reinforcing digital transformation strategies based on artificial intelligence technology. *Information*, 13(5), 253. <https://doi.org/10.3390/info13050253>
- Kitsios, F., & Kamariotou, M. (2021). Artificial intelligence and business strategy towards digital transformation: A research agenda. *Sustainability*, 13(4), 2025. <https://doi.org/10.3390/su13042025>
- 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. <https://doi.org/10.18421/TEM124-74>
- Koli, S. (2025). Shree-L1: A dynamic CNN architecture for efficient tumor classification in medical imaging. *Big Data and Computing Visions*, 5(2), 94-101. <https://doi.org/10.22105/bdcv.2024.491412.1219>
- Korobchynskiy, M., & Nadruga, V. (2025). A Systematic Approach to Data Normalization and Standardization in Machine Learning Problems. Lecture Notes in Data Engineering, Computational Intelligence, and Decision-Making, Volume 2: 2024 International Scientific Conference "Intelligent Systems of Decision-Making and Problems of Computational Intelligence", Proceedings,
- 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. <https://doi.org/10.1016/j.ijinfomgt.2021.102466>
- Kusuma, A. R., Syarif, R., Sukmawati, A., & Ekananta, A. (2024). Factors influencing the digital transformation of sales organizations in Indonesia. *Heliyon*, 10(5). https://www.researchgate.net/publication/378702985_Factors_influencing_the_digital_transformation_of_sales_organizations_in_Indonesia
- Lamtar-Gholipoor, M., Fakheri, S., & Alimoradi, M. (2024). Artificial neural network TSR for optimization of actinomycin production. *Big Data and Computing Visions*, 4(1), 57-66. <https://doi.org/10.22105/bdcv.2024.474793.1184>
- 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://www.researchgate.net/publication/383038719_Metaheuristic_Algorithms_with_Applications_A_Novel_Metaheuristic_Approach_Inspired_by_Trees_Social_Relationships_and_Models_for_Fermentation_Medium_Citation
- Lemieux, F. (2023). Digital transformation and artificial intelligence: opportunities and challenges. In *Digital Strategies And Organizational Transformation* (pp. 103-117). https://doi.org/10.1142/9789811271984_0006
- 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://www.apem.reapress.com/journal/article/view/39>
- Mao, A., Mohri, M., & Zhong, Y. (2023). Cross-entropy loss functions: Theoretical analysis and applications. International conference on Machine learning,
- Mhlanga, D. (2023). Digital transformation education, opportunities, and challenges of the application of ChatGPT to emerging economies. *Education Research International*, 2023(1), 7605075. <https://doi.org/10.1155/2023/7605075>
- Mienye, I. D., Swart, T. G., & Obaido, G. (2024). Recurrent Neural Networks: A Comprehensive Review of Architectures, Variants, and Applications. *Information*, 15(9), 517. <https://doi.org/10.3390/info15090517>
- Momeni, A., Rahmani, B., Scellier, B., Wright, L. G., McMahon, P. L., Wanjura, C. C., & Fleury, R. (2025). Training of physical neural networks. *Nature*, 645(8079), 53-61. <https://doi.org/10.1038/s41586-025-09384-2>
- Momeni, A., Rahmani, B., Scellier, B., Wright, L. G., McMahon, P. L., Wanjura, C. C., Li, Y., Skalli, A., Berloff, N. G., Onodera, T., Oguz, I., Morichetti, F., del Hougne, P., Le Gallo, M., Sebastian, A., Mirhoseini, A., Zhang, C., Marković, D., Brunner, D., . . . Fleury, R. (2025). Training of physical neural networks. *Nature*, 645(8079), 53-61. <https://doi.org/10.1038/s41586-025-09384-2>
- Naidu, G., Zuva, T., & Sibanda, E. M. (2023). A review of evaluation metrics in machine learning algorithms. https://doi.org/10.1007/978-3-031-35314-7_2
- 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. <https://doi.org/10.1155/2022/5663001>
- 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.
- Navaei, Y. D., Rezvani, M. H., & Moghaddam, A. M. E. (2024). A novel neighborhood-based importance measure for social network influence maximization using NSGA-III. 2024 10th International Conference on Artificial Intelligence and Robotics (QICAR),
- 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>
- Paul, J., Ueno, A., Dennis, C., Alamanos, E., Curtis, L., Foroudi, P., & Marvi, R. (2024). Digital transformation: A multidisciplinary perspective and future research agenda. *International Journal of Consumer Studies*, 48(2), e13015. <https://doi.org/10.1111/ijcs.13015>
- 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. <https://doi.org/10.3390/info14020085>
- 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. <https://doi.org/10.1016/j.jeap.2021.101026>
- 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://www.bidacv.com/article_233609.html
- Scabini, L. F., & Bruno, O. M. (2023). Structure and performance of fully connected neural networks: Emerging complex network properties. *Physica A: Statistical Mechanics and its Applications*, 615, 128585.
- Shehadeh, M. (2024). Digital transformation: a catalyst for sustainable business practices. In *Technological Innovations for Business, Education and Sustainability* (pp. 29-45). <https://doi.org/10.1108/978-1-83753-106-620241003>
- Vial, G. (2021). Understanding digital transformation: A review and a research agenda. In *Managing digital transformation* (pp. 13-66). <https://doi.org/10.4324/9781003008637-4>
- Xinxian, C., & Jianhui, C. (2022). Digital transformation and financial risk prediction of listed companies. *Computational Intelligence and Neuroscience*, 2022(1), 7211033. <https://doi.org/10.1155/2022/7211033>
- Zhang, J., & Chen, Z. (2024). Exploring human resource management digital transformation in the digital age. *Journal of the Knowledge Economy*, 15(1), 1482-1498. <https://doi.org/10.1007/s13132-023-01214-y>
- 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. <https://doi.org/10.1108/BPMJ-06-2022-0254>
- Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., & Parmar, M. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*, 57(4), 99. <https://doi.org/10.1007/s10462-024-10721-6>
- Zhu, C., Liu, X., & Chen, D. (2024). Prediction of digital transformation of manufacturing industry based on interpretable machine learning. *PLoS One*, 19(3), e0299147. <https://doi.org/10.1371/journal.pone.0299147>