



Intelligent Model for Predicting Intellectual Capital Maturity in Knowledge-Based Companies Using Machine Learning

Hossein Azizinejad¹, Gholamreza Tavakoli², Mohammad Ehsanifar³ and Amir Najafi⁴

- 1 .Ph.D. Student, Department of Industrial Management, Faculty of Management and Economics, Science and Research Branch, Islamic Azad University, Tehran, Iran. Email: azizinejad@aut.ac.ir
- 2 .Corresponding Author, Associate Professor, Department of Management, Malek Ashtar University of Technology, Tehran, Iran. Email: tavakoli4545@gmail.com
- 3 .Associate Professor, Department of Industrial Engineering, Arak Branch, Islamic Azad University, Arak, Iran. Email: Mo_ehsanifar@iau.ac.ir
- 4 .Associate Professor, Department of Industrial Engineering, North Tehran Branch, Islamic Azad University, Tehran, Iran. Email: asdnjff@gmail.com

Article Info	ABSTRACT
Article type: Research Article Article history: Received 17 March 2025 Received in revised form 16 April 2025 Accepted 6 August 2025 Published online 21 August 2025 Keywords: Intellectual capital, Intellectual capital maturity, Knowledge-based companies, Machine learning.	The aim of this research is to design an intelligent model for predicting the maturity of intellectual capital in knowledge-based companies located in industrial parks using machine learning algorithms. This study is applied-developmental in purpose and descriptive-modeling in methodology, utilizing a mixed approach for data collection. The data were gathered through a review of the literature, interviews with experts, and two questionnaires. For data analysis, various methods were employed, including the Delphi method, confirmatory factor analysis, and machine learning algorithms such as random forests, K-nearest neighbors, decision trees, naive Bayes, and multi-layer perceptron neural networks, using SPSS, PLS software, and various Python libraries. The results indicated that all models were capable of predicting the level of intellectual capital maturity; however, the multi-layer perceptron (MLP) model outperformed the others based on several criteria, including accuracy, precision, sensitivity, and F1 score, yielding the best results with values of 88.37%, 89.75%, 88.37%, 86.51%, and 0.918 in the area under the ROC curve.
Cite this article: Azizinejad, H. & et al, (2025)., Intelligent Model for Predicting Intellectual Capital Maturity in Knowledge-Based Companies Using Machine Learning. <i>Engineering Management and Soft Computing</i>, 11 (1). 307-340. DOI: https://doi.org/10.22091/jemsc.2025.12548.1266	
	© The Author(s) DOI: 10.22091/jemsc.2025.12548.1266
Publisher: University of Qom	

1) INTRODUCTION

In today's knowledge-based economy, organizations' intellectual capital is a crucial competitive advantage. This research aims to design an intelligent model for predicting intellectual capital maturity in knowledge-based companies located in industrial parks, using machine learning algorithms. This study is applied-developmental in purpose and descriptive-modeling in methodology, utilizing a mixed approach for data collection. The data were gathered through a review of the literature, interviews with experts, and two questionnaires. The contribution of this extended abstract lies in providing an operational framework for assessing and predicting the maturity level of intellectual capital using machine learning algorithms, addressing the gap in existing literature regarding the limited use of advanced technologies like machine learning in data analysis for intellectual capital maturity assessment. Some short survey of relevant literature is also presented.

2) Solution Method

For data analysis, various methods were employed, including the Delphi method, confirmatory factor analysis, and machine learning algorithms such as random forests, K-nearest neighbors, decision trees, naive Bayes, and multi-layer perceptron neural networks, using SPSS, PLS software, and various Python libraries.

3) Equations

To enhance the accuracy and speed of machine learning models and mitigate the performance degradation caused by using raw data, data normalization was performed based on Equation (1). This resulted in the final dataset being normalized to the range of 0 to 1, creating a standardized dataset. Furthermore, accuracy and precision metrics, calculated using Equations (2) and (3) respectively, were employed to evaluate and compare the performance of each model.

$$X_n = L + \frac{(X - X_{min})(H - L)}{X_{max} - X_{min}} \quad (7)$$

$$Accuracy = \frac{T_p + T_n}{ALL} \quad (8)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

4) Conclusion


The results indicated that all models were capable of predicting the level of intellectual capital maturity; however, the multi-layer perceptron (MLP) model outperformed the others based on several criteria, including accuracy, precision, sensitivity, and F1 score, yielding the best results with values of 88.37%, 89.75%, 88.37%, 86.51%, and 0.918 in the area under the ROC curve. This research demonstrates that machine learning models, particularly multi-layer perceptron neural networks, are powerful tools for predicting the level of intellectual capital maturity in knowledge-based companies.

5) Tables and Figures

Based on the results obtained from each of the models, their performances were compared to determine the best model for predicting the maturity level of intellectual capital in knowledge-based companies. The best results for each model across different methods, evaluated using accuracy, precision, sensitivity, F1-Score, and the area under the ROC curve for the test data, are presented in Table 1 and Figure 1.

Table 4. Comparison of the Performance of Different Models for Predicting the Maturity Level of Intellectual Capital

Model Type	Data Type	Evaluation Metrics				
		Accuracy	Precision	Recall	F1-Score	ROC-AUC
Gradient MLP Neural Network with 1 Hidden Layer and 5 Neurons	Test	88.37	89.75	88.37	86.51	0.918
Random Forest (RF) n_estimators = 180 Max Depth = 10	Test	74.42	67.30	74.42	70.14	0.898
K-Nearest Neighbors (KNN) K = 4	Test	72.09	70.08	72.09	64.91	0.881
Decision Tree (DT) max_depth = 7	Test	65.12	51.69	65.12	57.55	0.882
Naive Bayes (NB) Alpha = 0.5	Test	62.79	49.07	62.79	55.07	0.870

**Figure 4: Results of Model Performance for Predicting the Maturity Level of Intellectual Capital Based on Test Data**

ACKNOWLEDGEMENTS

The authors would like to acknowledge the contributions of the experts who participated in the interviews and provided valuable insights for this research.

REFERENCES

Azizinejad H., Tavakoli Gh., Ehsanifar M., Najafi A., Intelligent Model for Predicting Intellectual Capital Maturity in Knowledge-Based Companies Using Machine Learning, *Management of Engineering and Soft Computing*, 9(2): 32-33 (2025).

مدل هوشمند پیش‌بینی بلوغ سرمایه فکری در شرکت‌های دانش‌بنیان با استفاده از یادگیری ماشین

حسین عزیزی‌نژاد^۱، غلامرضا توکلی^۲، محمد احسانی‌فر^۳ و امیر نجفی^۴

۱. دانشجوی دکتری، گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: azizinejad@aut.ac.ir

۲. نویسنده مسئول، دانشیار، گروه مدیریت، دانشگاه صنعتی مالک اشتر، تهران، ایران. رایانامه: tavakoli4545@gmail.com

۳. دانشیار، گروه مهندسی صنایع، واحد اراک، دانشگاه آزاد اسلامی، اراک، ایران. رایانامه: Mo_ehsanifar@iaau.ac.ir

۴. دانشیار، گروه مهندسی صنایع، واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران. رایانامه: asdnjff@gmail.com

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی تاریخ دریافت: ۱۴۰۳/۱۲/۲۷ تاریخ بازنگری: ۱۴۰۴/۰۱/۲۷ تاریخ پذیرش: ۱۴۰۴/۰۵/۱۵ تاریخ انتشار: ۱۴۰۴/۰۵/۳۰ کلیدواژه‌ها: بلوغ سرمایه فکری، سرمایه فکری، شرکت‌های دانش‌بنیان، یادگیری ماشین	هدف این پژوهش، طراحی یک مدل هوشمند برای پیش‌بینی بلوغ سرمایه فکری در شرکت‌های دانش‌بنیان مستقر در شهرک‌های صنعتی، با استفاده از الگوریتم‌های یادگیری ماشین است. این تحقیق از نظر هدف، کاربردی-توسعه‌ای و از لحاظ روش، توصیفی-مدل‌سازی و در زمینه جمع‌آوری داده‌ها به صورت آمیخته می‌باشد. داده‌ها از طریق بررسی ادبیات موضوع، مصاحبه با خبرگان و دو پرسشنامه جمع‌آوری شده است. برای تحلیل داده‌ها، روش‌های مختلفی از جمله روش دلفی، تحلیل عاملی تاییدی و الگوریتم یادگیری ماشین مانند جنگل تصادفی، K نزدیک‌ترین همسایه، درخت تصمیم، بیز ساده و شبکه عصبی پرسپترون چندلایه با استفاده از نرم‌افزارهای Spss، PLS و کتابخانه‌های مختلف Python بکار رفته است. نتایج نشان داد که تمامی مدل‌ها توانایی پیش‌بینی سطح بلوغ سرمایه فکری را دارند اما مدل شبکه عصبی پرسپترون چندلایه MLP، عملکرد بهتری نسبت به سایر مدل‌ها براساس معیارهای مختلف از جمله دقت، صحت، حساسیت و امتیاز F1 از خود نشان داد و بهترین نتایج را با مقادیر ۸۸.۳۷ درصد، ۸۹.۷۵ درصد، ۸۸.۳۷ درصد و ۸۶.۵۱ درصد و ۰/۹۱۸ در مساحت زیرمنحنی ROC ارائه کرد.

استناد: عزیزی‌نژاد، حسین و همکاران. (۱۴۰۴). «مدل هوشمند پیش‌بینی بلوغ سرمایه فکری در شرکت‌های دانش‌بنیان با استفاده از یادگیری ماشین».

مدیریت مهندسی و رایانش نرم، دوره ۱۱ (۱). صص: ۳۴۰-۳۰۷. <https://doi.org/10.22091/jemsc.2025.12548.1266>



© نویسندگان.

ناشر: دانشگاه قم

(۱) مقدمه

اقتصاد دانش‌بنیان^۱، سیستمی اقتصادی است که مبتنی بر تولید، توزیع و کاربرد دانش و اطلاعات شکل گرفته و اولویت اصلی آن، سرمایه‌گذاری در دانش و صنایع مرتبط با آن است (حنفی نیری و همکاران، ۲۰۲۳). در اقتصادهای معاصر، دانش به‌عنوان محرک کلیدی توسعه اقتصادی، ایجاد ارزش افزوده و اشتغال‌زایی در تمام سطوح فعالیت‌های اقتصادی عمل می‌کند. برخلاف نگرش سنتی، اقتصاد دانش‌بنیان منحصر به بخش‌های فناوری پیشرفته نیست بلکه تمامی حوزه‌های اقتصادی- از صنایع تولیدی سنتی تا خدمات- بطور فزاینده‌ای به سرمایه‌های دانش‌محور وابسته شده‌اند (بورگل و همکاران^۲، ۲۰۲۳). در اقتصادهای مدرن دانش‌بنیان، رقابت‌پذیری یک منبع اصلی به‌شمار می‌رود (گونوان^۳، ۲۰۱۵) و شرکت‌های دانش‌بنیان^۴، نقش محوری در اقتصاد دانش‌بنیان ایفا می‌کنند و پیشران اصلی دستیابی به اهداف علمی، اقتصادی و تجاری‌سازی دستاوردهای تحقیق و توسعه در حوزه فناوری‌های پیشرفته هستند (وان و چروم جاکووا^۵، ۲۰۲۴).

شرکت‌های دانش‌بنیان به‌عنوان منبع اصلی نوآوری در هر کشور، اهمیت زیادی دارند. این شرکت‌ها از تجاری‌سازی ایده‌های نوآورانه که ناشی از ترکیب سرمایه‌های دانشی و منابع فیزیکی است، سود می‌برند. در حال حاضر ۸۲۷۱ شرکت دانش‌بنیان در کشور وجود دارد که بیشتر در زمینه‌های فناوری اطلاعات، نرم‌افزار، ماشین‌آلات پیشرفته و برق و الکترونیک فعالیت می‌کنند (سامانه جامع دانش‌بنیان^۶، ۲۰۲۳) لذا در عرصه رقابتی نوین که بر پایه اقتصاد دانش‌بنیان بنا شده‌است، دانش و سرمایه‌های فکری^۷ سازمان به‌عنوان یک مزیت رقابتی محسوب می‌شود (وانگ^۸، ۲۰۲۱) و در چنین اقتصاد رقابتی، شرکت‌هایی موفق هستند که با بهره‌گیری از سرمایه‌های فکری بتوانند محصولی با توان رقابتی بالا به بازار عرضه کنند بطوریکه امروزه ارزش‌های شرکت براساس دارایی‌های نامشهود مانند دانش در نظر گرفته می‌شود. این دانش به‌عنوان سرمایه فکری شناخته شده‌است (اندرسون و همکاران^۹، ۲۰۱۷).

سرمایه فکری به‌عنوان دانشی که برای یک سازمان ارزش دارد، تعریف می‌شود. هدف اصلی عملکرد شرکت، توسعه سرمایه فکری است که ارزش چشمگیری برای مالکان، مدیران، کارکنان و کل کشور به ارمغان می‌آورد. این امر نشان‌دهنده اهمیت روزافزون توسعه سرمایه فکری به‌عنوان یک فرآیند کلیدی در فعالیت‌های اقتصادی داخلی است. در یک سازمان، سرمایه فکری عامل اصلی ایجاد ارزش از طریق ترکیب سرمایه انسانی^{۱۰}، سرمایه ساختاری^{۱۱} و سرمایه رابطه‌ای^{۱۲} است که شامل دانش، ایده‌ها، قابلیت‌ها، روابط، مهارت‌ها، نگرش‌ها، فرهنگ کاری و حسن نیت و ارزش‌های شرکت می‌باشد (حدیدن و زکیه^{۱۳}، ۲۰۲۲).

¹ Knowledge-based economy

² Bürge et al

³ Gunwan

⁴ knowledge-based companies

⁵ Van and Chromjaková

⁶ www.pub.daneshbonyan.ir

⁷ Intellectual Capital

⁸ Wang

⁹ Anderson et al

¹⁰ Human Capital

¹¹ Structural capital

¹² Relational capital

¹³ Hadidane and Zakia

با توجه به تحولات سریع محیط کسب و کار، فقط وجود سرمایه فکری برای سازمان‌ها کافی نیست. امروزه آنچه تعیین‌کننده موفقیت سازمان‌هاست، بلوغ آنها در مدیریت سرمایه فکری است. با توجه به تعریف سرمایه فکری و نقش محوری آن در خلق ارزش برای ذینفعان مختلف، می‌توان بلوغ سرمایه فکری را اینگونه تعریف کرد: به سطح توسعه‌یافتگی و کارایی سازمان در مدیریت، اندازه‌گیری و بهره‌برداری بهینه از دارایی‌های فکری شامل سرمایه‌های انسانی، ساختاری و رابطه‌ای اشاره دارد. این مفهوم فراتر از مدیریت دانش سنتی است و بر توانایی سازمان در شناسایی نظام‌مند، یکپارچه‌سازی و خلق ارزش پایدار از دارایی‌های دانشی تاکید می‌کند (سیکاندو و همکاران، ۲۰۱۵).

با افزایش رقابت جهانی و برتری کشورهای دارای فناوری نسبت به کشورهای دارای منابع طبیعی، شناخت و ارزیابی دارایی‌های معنوی و سرمایه فکری به‌عنوان منبع رشد و توسعه پایدار ضروری است. ایران که هدف دارد تا سال ۱۴۰۴ به جایگاهی برتر اقتصادی و علمی در منطقه دست یابد، نیازمند شناسایی اجزا و شاخص‌های اندازه‌گیری سرمایه فکری برای تعیین جایگاه خود در میان سایر کشورهاست (رعنایی کردشولی و همکاران، ۲۰۱۶).

ارزیابی سرمایه فکری به روشی برای سنجش دارایی‌های نامشهود و توصیف نتایج فعالیت‌های مرتبط با دانش تبدیل شده‌است زیرا ذینفعان موسسات دانش‌بنیان بر اهمیت اطلاعات مربوط به سرمایه فکری برای اتخاذ تصمیمات درست تاکید دارند (روسی و همکاران^{۱۴}، ۲۰۱۸). گزارش‌های بانک جهانی جهت تخمین دانش ملی نشان می‌دهد ارزیابی و اندازه‌گیری دانش، ابزاری حیاتی برای کشورهاست تا بتوانند قابلیت‌های خود را در انقلاب دانش جهانی تحلیل کنند. شناسایی دارایی‌های دانشی به کشورها کمک می‌کند تا شایستگی‌ها و توانمندی‌های ملی خود را بشناسند که برای رشد اقتصادی، دستیابی به مزیت رقابتی، توسعه انسانی و بهبود کیفیت زندگی ضروری است (رضائیان و همکاران، ۲۰۱۱).

در دنیای رقابتی و نوآورانه امروز که تقاضا برای محصولات و خدمات دانش‌محور روبه‌افزایش است، داشتن سرمایه‌های فکری به تنهایی برای برتری رقابتی کافی نیست. بلوغ سرمایه فکری^{۱۵} به‌عنوان یک استراتژی منابع انسانی، می‌تواند ظرفیت‌ها و قابلیت‌های رقابتی سازمان را بطور قابل توجهی افزایش دهد (رجب پور و باباشاهی، ۲۰۲۰). بنابراین نخستین گام در ارزیابی و تعیین سطح بلوغ سرمایه فکری سازمان، تحلیل وضعیت فعلی آن است. پس از آن، نقاط ضعف و قوت شناسایی شده و وضعیت مطلوب تعیین خواهد شد. درنهایت راهکارهای مناسب برای ارتقا به سطوح بالاتر بلوغ سازمانی ارائه می‌شود (نجات و همکاران، ۲۰۲۲).

در واقع بلوغ سرمایه فکری بیانگر وضعیت ایده‌آل یک سازمان در بهره‌برداری از پتانسیل‌های نهفته خود به‌منظور افزایش کارایی سازمان است. این مفهوم به‌عنوان ابزاری جهت ارزیابی میزان آمادگی، تکامل و رشد مولفه‌های سرمایه فکری محسوب می‌شود (سلمانی و همکاران، ۲۰۱۹).

برای ارزیابی بلوغ سرمایه فکری، پژوهشگران مدل‌های مختلفی را با استفاده از روش‌های آماری و حسابداری توسعه داده‌اند. اما نکته مهم این است که این مطالعات عمدتاً به ارائه مدل‌های نظری محدود شده و از ایجاد چارچوب‌های عملیاتی برای پیش‌بینی سطح بلوغ سرمایه فکری غافل مانده‌اند. ارزیابی دقیق سرمایه فکری می‌تواند به شرکت‌ها در افزایش ارزش

¹⁴ Rossi et al¹⁵ Intellectual capital maturity

آنها کمک کند. بنابراین اندازه‌گیری دقیق و عینی آن برای شرکت‌ها بسیار اهمیت دارد (چاودوری و همکاران^{۱۶}، ۲۰۱۸). در همین راستا، بسیاری از سازمان‌ها در حال حاضر از سیستم‌های اندازه‌گیری و گزارش‌دهی استفاده می‌کنند که مبتنی بر چارچوب‌های حسابداری سنتی و مقررات داخلی هستند. این رویکرد با وجود کاربرد گسترده، دارای محدودیت‌ها و چالش‌های خاصی است (واز و همکاران، ۲۰۱۸) و همانطور که بیان شد سرمایه فکری یک شرکت معمولاً به دارایی‌های نامشهود بیشتری نسبت به محصولات سودآور اشاره دارد. بنابراین سیستم‌های موجود برای ارزیابی این سرمایه‌ها نمی‌توانند به‌درستی ارزش تجاری آنها را منعکس کنند. در حال حاضر، بسیاری از این سیستم‌ها تنها نظری بوده و از اطلاعات کافی پشتیبانی نمی‌کنند. علاوه بر این، جمع‌آوری داده‌ها برای این شاخص‌ها به راحتی انجام نمی‌شود که این موضوع باعث می‌شود این سیستم‌ها کاربردی نباشند (یوان و همکاران، ۲۰۲۱). اکثر مطالعات انجام‌شده در رابطه با سرمایه فکری و بلوغ آن مانند مطالعات (گرامی و همکاران، ۲۰۲۲)؛ (لیو و کوهه، ۲۰۲۲)؛ (زی و ژانگ، ۲۰۲۱)؛ (آصف و همکاران، ۲۰۲۱)؛ (کوهه و همکاران، ۲۰۲۱)؛ (ساردو و سراسکیرو، ۲۰۱۸) و (براتینو، ۲۰۱۸) نشان می‌دهند سرمایه فکری با ابعاد تشکیل‌دهنده آن دارای رویکرد غیرخطی و پویا در سازمان می‌باشد. همچنین یافته‌های (نجات و کریمی خوزان، ۲۰۲۰) در رابطه با بلوغ سرمایه فکری نشانگر آن است که سازمان‌ها از یک الگوی غیرخطی برای پیاده‌سازی و ویژگی‌های مراحل پنج‌گانه آن پیروی می‌کنند. به عبارت دیگر، آنها بطور همزمان برای تحقق ویژگی‌های این مراحل تلاش می‌کنند. این فرآیند نیاز به استفاده از تکنیک‌ها و روش‌های دقیق‌تر برای ارزیابی، تصمیم‌گیری و شناسایی عوامل موثر بر سرمایه فکری و بلوغ آن دارد. همچنین پیش‌بینی سطح بلوغ سرمایه فکری به دلیل وجود روابط غیرخطی میان عوامل تاثیرگذار بر آن، عمل پیچیده‌ای است (یوان و همکاران، ۲۰۲۱).

امروزه تکنیک‌های مختلف یادگیری ماشین به صورت گسترده برای پیش‌بینی داده‌های با ساختار غیرخطی و پویا بکار گرفته شده‌اند و نتایج خوبی داشته‌اند (میرزائی و دعائی، ۲۰۱۹). بر همین اساس، این مقاله با در نظر گرفتن مسئله پیش‌بینی بلوغ سرمایه فکری به دنبال پیش‌بینی سطح بلوغ سرمایه فکری شرکت‌های دانش‌بنیان از طریق الگوریتم‌های مختلف یادگیری ماشین می‌باشد. لذا در این پژوهش، الگوریتم‌های کلاسیک یادگیری ماشین از جمله درخت تصمیم^{۱۷}، K-نزدیک‌ترین همسایه^{۱۸}، بیز ساده^{۱۹} و جنگل تصادفی^{۲۰} با مدل شبکه عصبی پرسپترون چند لایه^{۲۱} مقایسه شده تا یک مدل مناسب جهت پیش‌بینی سطح بلوغ سرمایه فکری در شرکت‌های دانش‌بنیان ارائه شود. در همین راستا، پژوهشگران حاضر با درک این موضوع و با در نظر گرفتن اهمیت بلوغ سرمایه فکری، به بررسی پرسش‌های پژوهشی زیر می‌پردازند: سطح بلوغ سرمایه فکری در هریک از شرکت‌های دانش‌بنیان مستقر در شهرک‌های صنعتی در قلمرو تحقیق به چه صورت است؟ عوامل اصلی تاثیرگذار بر سرمایه فکری در شرکت‌های دانش‌بنیان مستقر در شهرک‌های صنعتی در قلمرو تحقیق کدامند؟ با در نظر گرفتن عوامل اصلی تاثیرگذار بر سرمایه فکری در شرکت‌های دانش‌بنیان، مدل مناسب پیش‌بینی سطح بلوغ سرمایه فکری در شرکت‌های دانش‌بنیان مستقر در شهرک‌های صنعتی با رویکرد یادگیری ماشین کدام است؟

¹⁶ Chowdhury et al

¹⁷ Decision Tree

¹⁸ K-Nearest Neighbors

¹⁹ Naive Bayesian

²⁰ Random Forest

²¹ Multi Layer Perceptron

۲) مبانی نظری و پیشینه تحقیق

۲-۱) سرمایه فکری

سازمان‌ها دارای سه نوع سرمایه اساسی تحت عنوان سرمایه‌های مالی، فیزیکی و فکری هستند. درحالی‌که سرمایه‌های مالی و فیزیکی به دارایی‌های خالص و ظرفیت تولید اشاره دارند، سرمایه فکری به دانش و علم مرتبط است. در اقتصاد دانش‌محور، مدیریت صحیح سرمایه فکری برای موفقیت سازمان‌ها حیاتی است زیرا این نوع سرمایه موجب رشد سازمان و حتی افزایش ارزش آن می‌شود (مبارک و همکاران، ۲۰۲۲).

سرمایه فکری ترکیبی از دارایی‌های نامشهود کارکنان است و نقش موثری در ارزش‌آفرینی برای مدیران دارد (براتیانو و پینزارو، ۲۰۱۵). این سرمایه بر تصمیم‌گیری‌های ذینفعان تاثیر گذاشته و می‌تواند تصویر و شهرت سازمان را تقویت کند (رامیرز و گوردیلو، ۲۰۱۳؛ تودریسو و استانیت، ۲۰۱۶).

پژوهش‌های انجام‌شده در این زمینه در طبقه‌بندی خود چهار بعد کلیدی شامل: ۱) سرمایه انسانی (دانش و شایستگی‌های نیروی کار)، ۲) سرمایه ساختاری (نظام‌های سازمانی و فرآیندهای مدیریتی)، ۳) سرمایه رابطه‌ای (شبکه‌های ارتباطی با ذینفعان خارجی) و ۴) سرمایه نوآوری را معرفی کرده‌اند. در این چارچوب، سرمایه انسانی به قابلیت‌های فردی کارکنان اشاره دارد، سرمایه ساختاری زیرساخت‌های حمایتی سازمان را دربرمی‌گیرد، و سرمایه رابطه‌ای بر روابط با مشتریان و شرکای تجاری متمرکز است (لاغی و همکاران^{۲۲}، ۲۰۲۲) و سرمایه نوآوری بر توسعه محصولات جدید و تحقیق و توسعه متمرکز است که ترکیب این چهار عنصر می‌تواند به تقویت مزیت رقابتی سازمان کمک کند و نقش کلیدی در فرآیندهای تصمیم‌گیری و ارزش‌آفرینی ایفا نماید (آسیایی و همکاران، ۲۰۱۸).

۲-۲) بلوغ سرمایه فکری

بلوغ در مفهوم کلی به وضعیتی اشاره دارد که یک سیستم یا سازمان به سطحی از تکامل و آمادگی کامل دست یافته باشد. این شاخص را می‌توان هم از جنبه کیفی و هم کمی مورد سنجش قرار داد که این ارزیابی هم به صورت پیوسته و هم گسسته امکان‌پذیر است. در ادبیات موضوع، پژوهشگران برای سنجش درجه بلوغ سیستم‌های مختلف، چارچوب‌های ارزیابی متنوعی تحت عنوان «مدل‌های بلوغ» توسعه داده‌اند. این مدل‌ها عموماً بلوغ را به عنوان فرآیندی تکاملی تعریف می‌کنند که در آن قابلیت‌های سیستم به تدریج و طی مراحل مشخصی، چه از نظر کیفی و چه از نظر کمی ارتقا می‌یابد. این مدل‌ها با تعیین حوزه‌های کلیدی و شاخص‌های ارزیابی، امکان پایش پیشرفت سیستم را در مسیر بلوغ فراهم می‌آورند (واگیر و همکاران^{۲۳}، ۲۰۲۱). مدل‌های بلوغ ابزاری برای مقایسه سطح فعلی سازمان یا فرآیند با سطح مطلوب از نظر بلوغ، مفهوم‌سازی و اندازه‌گیری شناخته می‌شود که برای بهبود مستمر استفاده می‌شود (شوماخر و همکاران^{۲۴}، ۲۰۱۶).

مفهوم سطوح بلوغ نخستین بار توسط کرازبی (۱۹۷۹) در زمینه مدیریت کیفیت مطرح شد و سپس توسط موسسه مهندسی نرم‌افزار در سال ۱۹۸۶ برای ارزیابی فرآیند توسعه نرم‌افزار مورد استفاده قرار گرفت. این مفهوم به حوزه‌های دیگری مانند

²² Laghi et al

²³ Wagire et al

²⁴ Schumacher et al

مدیریت پروژه و دانش نیز گسترش یافته‌است. مدل‌های بلوغ مختلفی مانند KMMM و CMM به‌عنوان ساختارهایی ارائه می‌شوند که روابط با عملکرد سازمانی را بهبود می‌بخشند (واز و همکاران، ۲۰۱۸).

سازمان‌ها، فرآیند مدیریت سرمایه فکری را با توجه به ویژگی‌ها و قابلیت‌های فردی در سطوح مختلف شروع کرده و با سرعت‌های مختلف به مراحل بعدی منتقل می‌شوند. مدل‌های بلوغ کاربردهای عملی متنوعی از جمله: ارزیابی وضعیت فعلی، ارائه نقشه‌های مراحل پیشرفت و ابزارهایی برای نظارت بر روند پیشرفت دارند (نجات و کریمی خوزانی، ۲۰۲۰).

بنابراین بلوغ سرمایه فکری را می‌توان اجرای فرآیندها، شیوه‌ها و رویه‌ها برای بهینه‌سازی استفاده از منابع دانست که هدف آن بهبود بهره‌وری و افزایش رقابت‌پذیری شرکت‌ها با کاهش اثرات نامطلوب است (واز و همکاران، ۲۰۱۸). با این حال، سرمایه فکری مفهومی انتزاعی است که به دارایی‌های نامشهود یک شرکت اشاره دارد و اندازه‌گیری آن به دلیل ویژگی‌های درونی افراد پیچیده و دشوار است (قاسمی و همکاران، ۲۰۲۰).

مدل‌های بلوغ سرمایه فکری عموماً دارای پنج سطح هستند که هر سطح شامل حوزه‌های فرآیندی متعددی است. این سطوح با نام‌های آغازین، مدیریت‌شده، تعریف‌شده، مدیریت کمی‌شده و سطح بهینه‌شده شناخته می‌شوند. به این ترتیب، سازمان‌ها می‌توانند با طی کردن این مراحل، به بلوغ کامل در مدیریت دارایی‌های نامشهود خود دست یابند. به گونه‌ای که سطح پنجم وضعیت ایده‌آل را نشان می‌دهد که در شکل (۱) نشان داده شده‌است.



شکل ۱. بلوغ سرمایه فکری

۲-۳) یادگیری ماشین

یادگیری ماشین^{۲۵}، یک شاخه از هوش مصنوعی^{۲۶} و علوم کامپیوتر است که از روش‌های یادگیری آماری برای استخراج دانش، شناسایی روندها و کشف الگوهای پنهان موجود در مجموعه داده‌ها استفاده می‌کند. این فناوری به کامپیوترها اجازه می‌دهد تا از داده‌ها یاد بگیرند و به جای اینکه تنها طبق قوانین معین عمل کنند، پیش‌بینی‌ها و تصمیم‌گیری‌ها را براساس داده‌ها انجام دهند. این قابلیت تحول بزرگی در صنایع مختلف ایجاد کرده و موجب پیشرفت در زمینه‌هایی مانند: مالی، پزشکی و بازاریابی شده‌است. تکنیک‌های یادگیری ماشین به دو دسته اصلی یادگیری با نظارت و یادگیری بدون نظارت تقسیم می‌شوند (بسیونی و همکاران^{۲۷}، ۲۰۲۴). یادگیری با نظارت به پیش‌بینی پارامترهای خروجی براساس متغیرهای

²⁵ Machine learning

²⁶ Artificial Intelligence

²⁷ Bassioni et al.

ورودی و یک دیتاست آموزشی برچسب گذاری شده می پردازد. این رویکرد به «نظارت» براساس جفت های ورودی-خروجی وابسته است و هدف آن توسعه مدلی است که بتواند نتایج را به دقت برای داده های جدید پیش بینی کند (باریانیس و همکاران^{۲۸}، ۲۰۱۹)

یکی از رویکردهای بنیادی در یادگیری با نظارت، مدل های طبقه بندی است. وظایف طبقه بندی شامل تعیین اینکه یک ورودی به کدام دسته از پیش تعریف شده ها تعلق دارد، براساس ویژگی های آن است. الگوریتم های رایج در طبقه بندی شامل رگرسیون لجستیک، درخت تصمیم، ماشین بردار پشتیبان، جنگل تصادفی، K نزدیک ترین همسایه، بیز ساده و شبکه عصبی پرسپترون چندلایه هستند (گونگ و همکاران^{۲۹}، ۲۰۲۳).

الگوریتم بیز ساده: یک الگوریتم ساده است که براساس احتمالات وابسته بین ویژگی ها، احتمال تعلق به هر گروه را محاسبه می کند. این الگوریتم نیاز به محاسبات پیچیده ندارد و برای داده های حجیم مناسب است و برای مسائل پیچیده که روابط غیرخطی دارند، ضعیف عمل می کند.

الگوریتم درخت تصمیم: یک الگوریتم طبقه بندی که با استفاده از یک سلسله مراتبی از شرایط و تصمیم ها، داده ها را به گروه های مختلف تقسیم می کند. این الگوریتم می تواند روابط پیچیده بین متغیرها را شناسایی کند. همچنین در این الگوریتم، داده های با ابعاد بالا درخت های عمیق، ممکن است به نوبت حساس شوند.

الگوریتم K نزدیک ترین همسایه: یک الگوریتم طبقه بندی ساده و غیرپارامتری است که براساس شباهت نمونه ها به هم، نمونه ها را به گروه های مشابه تقسیم می کند. تفاوت این طبقه بندی با مابقی یادگیرنده های مبتنی بر نمونه در استفاده از توابع فاصله است و از توابع فاصله براساس آنتروپی استفاده می کند (شمسی و همکاران، ۱۴۰۱). این الگوریتم نیاز به فرضیات اولیه یا مدل سازی پیچیده ندارد ولی اگر ویژگی ها در مقیاس های مختلف باشند، نتایج گمراه کننده می شوند.

الگوریتم جنگل تصادفی: این الگوریتم یک مدل مبتنی بر یادگیری ماشین است که از ترکیب چندین درخت تصمیم به عنوان «جنگل» استفاده می کند. هر کدام از درخت ها با زیرمجموعه ای از داده ها، آموزش داده می شوند. در زمان پیش بینی، هر درخت یک نتیجه را پیش بینی می کند و الگوریتم جنگل تصادفی با رای گیری از بین نتایج، طبقه ای را که بیشترین رای را دارد به عنوان طبقه نهایی انتخاب می کند. به این ترتیب، جنگل تصادفی با ترکیب قدرت چندین درخت، یک مدل طبقه بندی قوی تر ایجاد می کند. (چهره و سرآبادانی، ۱۴۰۲)

شبکه های عصبی مصنوعی: این مدل های محاسباتی با الهام از ساختار و عملکرد سیستم عصبی انسان، توسعه یافته اند و به عنوان ابزاری کارآمد برای تحلیل پیچیده داده ها و شکل دهی به روابط غیرخطی مورد استفاده قرار می گیرند. در میان انواع مختلف این ساختارها، پرسپترون چندلایه به عنوان یکی از پرکاربردترین معماری ها شناخته می شود که از سه بخش اصلی تشکیل شده است: لایه ورودی، لایه های پردازشی (شامل عناصر خطی و غیرخطی) و لایه خروجی. یکی از مهمترین چالش ها در پیاده سازی این شبکه ها، بهینه سازی تعداد لایه های میانی و تعداد واحدهای پردازشی در هر لایه می باشد (سامیک و همکاران^{۳۰}، ۲۰۲۱). عملکرد این الگوریتم از طریق تنظیم پارامترهای ساختاری شامل تعداد لایه های شبکه و

²⁸ Baryannis et al.

²⁹ Gong et al.

³⁰ Samek et al

واحدهای پردازشی هر لایه قابل بهبود است که منجر به ارتقای دقت پیش‌بینی‌های مدل می‌گردد. از سوی دیگر، دستیابی به نتایج قابل اعتماد مستلزم وجود مجموعه داده‌های آموزشی گسترده است تا از بروز خطاهای محاسباتی جلوگیری شود. لازم به ذکر است که فرآیند آموزش این سیستم‌ها معمولاً به زمان محاسباتی قابل توجهی نیازمند است (تای^{۳۱}، ۲۰۲۳). تحقیقات نشان داده‌اند یک تا سه لایه پنهان می‌تواند هر تابع پیچیده و غیرخطی را تقریب‌زنی کند (سلطانی فسقندیس و همکاران، ۲۰۱۷). همچنین مطالعات تجربی نشان داده‌اند که تقریب هر تابع پیچیده‌ای با استفاده از حداکثر سه لایه مخفی امکان‌پذیر است. با این حال، در مواردیکه مدل از دقت کافی برخوردار نباشد، می‌توان با افزودن لایه‌های مخفی بیشتر، کارایی شبکه را بهبود بخشید (تای، ۲۰۲۳).

امروزه اهمیت یادگیری ماشین در پردازش داده‌ها به وضوح مشهود است. سازمان‌ها از این فناوری برای بهبود تصمیم‌گیری، افزایش کارایی عملیاتی و نوآوری در تجزیه و تحلیل‌های پیش‌بینی‌کننده استفاده می‌کنند. بطور خاص الگوریتم‌های یادگیری ماشین در صنایع مختلف (مالی و بهداشت)، بهبودهایی در نمره‌دهی اعتباری و شخصی‌سازی درمان‌ها ارائه می‌دهند (گیولایی و همکاران^{۳۲}، ۲۰۱۸).

۲-۴) پیشینه تحقیق

کردی و همکاران (۲۰۲۳) در پژوهشی با استفاده از روش‌های فراترکیب و مدل‌سازی معادلات ساختاری، مدلی برای شناسایی و سنجش بلوغ سرمایه‌فکری در شرکت‌های بازار سرمایه ارائه می‌دهد. از روش نمونه‌گیری گلوله‌برفی برای بخش کیفی (نخبگان دانشگاهی) و نمونه‌گیری دردسترس برای بخش کمی (مدیران و کارشناسان) استفاده شده است. یافته‌های کیفی شامل ۳ مقوله، ۶ مولفه و ۳۹ مضمون مفهومی است که بر تأثیر بلوغ سرمایه‌فکری بر پایداری شرکتی دلالت دارد. قابلیت دانش منابع انسانی به عنوان تأثیرگذارترین بُعد، شناسایی شده است. مدل ارائه شده توصیفی است و قابلیت پیش‌بینی پویا ندارد و به دلیل تمرکز بر شرکت‌های بازار سرمایه، قابلیت تعمیم‌پذیری محدودی دارد. بنی‌اسدی و همکاران (۲۰۲۲) در پژوهش خود با رویکرد آمیخته (کمی و کیفی)، مدلی چهار مرحله‌ای برای سنجش بلوغ سرمایه‌فکری در بخش دولتی ارائه می‌دهد. در فاز اول با تحلیل محتوا، ۱۰۸ شاخص برای سه بُعد سرمایه‌انسانی، ساختاری و رابطه‌ای طراحی شد. در فاز دوم با روش دلفی، ۸۹ شاخص مورد تایید قرار گرفت. در فاز سوم، الگوی توسعه سرمایه‌فکری با در نظر گرفتن سطوح بلوغ و اقدامات هر سطح ارائه شد. فاز چهارم با پرسشنامه محقق ساخته، سطح بلوغ سازمان بهزیستی خراسان جنوبی را در سطوح مختلف ارزیابی کرد. مدل ارائه شده بیشتر فرآیندمحور است و قابلیت پیش‌بینی ندارد و به دلیل تمرکز بر بخش دولتی (سازمان بهزیستی)، محدودیت در تعمیم‌پذیری دارد.

عبدلی و همکاران (۲۰۲۲) در پژوهشی با استفاده از تکنیک دلفی (با مشارکت ۱۶ متخصص) به شناسایی مولفه‌های بلوغ سرمایه‌فکری و مضامین پیوند یادگیری دوجانبه در شرکت‌های دانش‌بنیان نفت و گاز پرداخت. گرایش‌های استراتژیک در یادگیری بیشترین تأثیر را بر پایداری خلق دانش و در نتیجه بلوغ سرمایه‌فکری داشته است. این گرایش‌ها به تقویت بهره‌وری و جذب و خلق دانش به عنوان یک ارزش در شرکت منجر می‌شوند. مدل ارائه شده بیشتر کیفی است و

³¹ Taye

³² Gyulai et al.

امکان سنجش کمی و پیش‌بینی را فراهم نمی‌کند و همچنین عدم بررسی تاثیر متغیرهای محیطی بر بلوغ سرمایه فکری در آن مشهود است. نجات و همکاران (۲۰۲۲) در یک پژوهش با رویکرد کمی و استفاده از پرسشنامه، سطح بلوغ سرمایه فکری در دانشگاه علوم پزشکی تهران را براساس مدل ICMM ارزیابی کرده‌اند. نمونه آماری ۵۷ نفر به صورت تصادفی انتخاب شده‌اند. نتایج نشان از الگوی غیرخطی در سطوح بلوغ و همچنین عدم آگاهی مدیران سازمان از اهمیت سرمایه فکری دارد. برای رسیدن به سطوح بالاتر بلوغ، شناسایی، فعال‌سازی منابع نامشهود و تمرکز بر کمی‌سازی و بهبود مستمر ضروری است. مدل ارائه شده بیشتر به صورت ارزیابی است و راهکارهای عملیاتی کمی ارائه می‌دهد. همچنین در این مدل، از روش‌های پیشرفته تحلیل داده برای پیش‌بینی روند بلوغ استفاده نشده است. نجات و کریمی خوزانی (۲۰۲۰) در پژوهش خود با استفاده از پرسشنامه (۱۹ سؤال) و رویکرد کمی، سطح بلوغ مدیریت سرمایه فکری در حوزه تحقیقات و مطالعات ناجا را ارزیابی می‌کنند. نمونه آماری شامل ۷۹ نفر از مدیران و کارشناسان ارشد است. یافته‌ها نشان از الگوی غیرخطی در پیاده‌سازی ویژگی‌های مراحل بلوغ و قرارگیری سازمان در سطح «مدیریت شده» دارد. برای رسیدن به سطوح بالاتر، تمرکز بر کمی‌سازی، استانداردسازی و بهبود مستمر ضروری است. مدل ارائه شده به دلیل ماهیت خاص سازمانی، دارای محدودیت در تعمیم‌پذیری است و عوامل خارجی موثر بر بلوغ سرمایه فکری در آن بررسی نشده است. سلمانی و همکاران (۲۰۱۹) در یک پژوهش کیفی با رویکرد داده بنیاد و مصاحبه با ۲۹ خبره، مدلی برای سنجش بلوغ سرمایه فکری در دانشگاه‌های ایرانی ارائه می‌دهد. مدل شامل ۱۲ مولفه و ۵ حوزه است. در پیاده‌سازی مدل، عوامل تسهیل‌کننده و ممانعت‌کننده مانند ابعاد ساختاری، هزینه‌ها و جو سازمانی مشخص شده‌اند. پیاده‌سازی مدل می‌تواند به توسعه شبکه تحقیق و تجاری‌سازی دانش بیانجامد. مدل ارائه شده، کیفی است و امکان سنجش کمی نیست و چارچوب عملیاتی برای پیاده‌سازی مدل در پژوهش مذکور وجود ندارد.

واز و همکاران (۲۰۱۸) در پژوهشی با استفاده از روش موردکاوی و مدل‌سازی معادلات ساختاری، مدلی پنج‌سطحی (از فرآیند اولیه تا بهینه‌شده) برای ارزیابی بلوغ سرمایه فکری ارائه می‌دهد. مبنای ارزیابی، سطح توسعه‌یافتگی پایداری در ابعاد مختلف سرمایه‌ها و کارکردهای حوزه دانش‌افزایی است. کارکردهای دانش‌افزایی برای ارتقای اثربخشی در محیط رقابتی اهمیت دارند. مدل ارائه شده بیشتر توصیفی است و قابلیت پیش‌بینی ندارد و از داده‌های پویا برای ردیابی تغییرات بلوغ در طول زمان ارائه نمی‌کند. رودریگز و سلیگ (۲۰۱۶) در یک پژوهش با روش موردکاوی، مدلی شش‌سطحی برای بلوغ سرمایه فکری در سازمان‌های تولیدی ارائه می‌دهند. این مدل براساس سه بُعد انسانی، سازمانی و رابطه مشتری و با درنظرگرفتن عوامل مختلف هر بعد، طراحی شده است. این مدل به سازمان‌ها در تعیین سطح سرمایه فکری و ارائه نقشه راه برای بهبود آن کمک می‌کند. مدل ارائه شده فاقد مکانیزم‌های پیش‌بینی و بهینه‌سازی است و از روش‌های کمی پیشرفته برای تحلیل داده‌ها استفاده نمی‌کند. سیکانندو و همکاران (۲۰۱۵) هم در پژوهش خود، مدلی هفت‌سطحی با روش آمیخته برای سنجش بلوغ سرمایه فکری در دانشگاه‌های اروپایی ارائه می‌دهد. این مدل پیوستاری از جمع‌آوری داده‌ها تا برنامه‌ریزی و بهبود مستمر را نشان می‌دهد و به عنوان چارچوبی برای بهبود مدیریت استراتژیک و تضمین کیفیت آموزش عالی درنظر گرفته شده است. این مدل براساس تجربیات ۱۵ متخصص بین‌المللی توسعه یافته است. مدل ارائه شده چارچوب محور است و ابزارهای عملیاتی کمی ارائه می‌دهد.

مرور نظام‌مند پژوهش‌های پیشین در حوزه بلوغ سرمایه‌فکری نشان می‌دهد اگرچه تلاش‌های ارزشمندی در طراحی مدل‌های سنجش بلوغ انجام شده‌است اما شکاف‌های پژوهشی قابل توجهی وجود دارد که نیازمند توجه هستند و عبارتند از: محدودیت‌های روش‌شناسی؛ اکثر مطالعات (مانند کردی و همکاران، ۲۰۲۳؛ بنی‌اسدی و همکاران، ۲۰۲۲) از روش‌های سنتی مانند معادلات ساختاری یا تکنیک دلفی استفاده کرده‌اند که قابلیت پیش‌بینی پویا ندارند. همچنین در اکثر تحقیقات نمونه‌های تحقیق عمدتاً محدود به بخش‌های خاص (دولتی، دانشگاهی یا صنایع خاص) بوده و تعمیم‌پذیری نتایج را محدود کرده‌است.

کاستی‌های مدل‌های موجود: مدل‌های فعلی (مانند واز و همکاران، ۲۰۱۸؛ رودریگز و سلیگ، ۲۰۱۶) بیشتر توصیفی هستند و قابلیت پیش‌بینی سطوح بلوغ را ندارند. همچنین تمرکز بیش‌ازحد بر ابعاد سنجش دارد و به مکانیزم‌های پیش‌بینی و بهینه‌سازی بلوغ در این مدل‌ها توجه کمی شده‌است.

شکاف‌های محتوایی: نبود مطالعاتی که از فناوری‌های پیشرفته مانند یادگیری ماشین برای تحلیل پویای سرمایه‌فکری استفاده کرده باشند و از طرف دیگر، کمبود پژوهش‌های تطبیقی بین صنایع مختلف که الگوهای بلوغ را در بافت‌های سازمانی متفاوت بررسی کنند.

نیازهای عملیاتی: فقدان سیستم‌های هوشمند پشتیبان تصمیم‌گیری برای ارزیابی بلوغ سرمایه‌فکری در مدل‌های موجود و فقدان چارچوب‌های پویا که بتوانند تغییرات بلوغ را در طول زمان ردیابی و پیش‌بینی کنند.

لذا مرور مطالعات و پژوهش‌هایی که در حوزه ارزیابی و پیش‌بینی سرمایه‌فکری و بلوغ آن صورت گرفته‌اند، نشان می‌دهد عمدتاً براساس روش‌های آماری و حسابداری بوده‌اند. این مسئله خلا پژوهشی قابل توجهی را در این حوزه ایجاد کرده‌است که لزوم استفاده از روش‌های جدیدی مانند یادگیری ماشین را آشکار می‌کند.

(۳) روش تحقیق

هدف تحقیق حاضر، کاربردی-توسعه‌ای بوده و از روش توصیفی-مدل‌سازی استفاده کرده‌است و جمع‌آوری داده‌ها از نوع آمیخته می‌باشد. در بخش کیفی، نمونه آماری شامل ۱۲ نفر از خبرگان حوزه شرکت‌های دانش‌بنیان است که با روش هدفمند گلوله‌برفی، براساس شرایط احراز خبرگی بر مبنای ویژگی‌های جمعیت‌شناختی به‌عنوان پنل انتخاب گردید و نظرات ایشان مورد تحلیل قرار گرفت. در بخش کمی، نمونه شامل ۲۱۲ شرکت دانش‌بنیان مستقر در شهرک‌های صنعتی غرب کشور است که با استفاده از روش تصادفی طبقه‌ای و براساس دسته فناوری محاسبه شده‌اند. این انتخاب مبتنی بر ملاحظات (تمرکز جغرافیایی: شهرک‌های صنعتی غرب کشور به‌دلیل همگنی نسبی در زیرساخت‌های فناوری و سیاست‌های حمایتی، محیط کنترل‌شده‌ای برای مطالعه فراهم می‌کنند، چگالی دانش: این منطقه دارای تراکم بالایی از شرکت‌های دانش‌بنیان با سطوح مختلف بلوغ سازمانی است که امکان مقایسه سیستماتیک را فراهم می‌سازد، دسترسی پژوهشی: نمونه‌گیری از این منطقه به‌دلیل همکاری نهادهای علمی-صنعتی محلی تسهیل شده‌است و مطالعات پیشین: پژوهش‌های مختلف نشان داده‌اند که مناطق صنعتی غرب ایران از نظر شاخص‌های نوآوری در وضعیت مناسبی قرار دارند) بوده‌است.

$$n = \frac{\frac{z^2 pq}{d^2}}{1 + \frac{1}{N} \left[\frac{z^2 pq}{d^2} - 1 \right]}$$

$$n = \frac{\frac{3.8416 \cdot 0.5 \cdot 0.5}{0.0025}}{1 + \frac{1}{472} \left(\frac{3.8416 \cdot 0.5 \cdot 0.5}{0.0025} - 1 \right)} = 212$$

در این پژوهش گردآوری داده‌ها به این صورت است که به منظور تعیین سطح بلوغ سرمایه فکری هریک از شرکت‌های دانش‌بنیان (متغیر وابسته) که از آنها به عنوان خروجی مدل پیش‌بینی استفاده می‌شود، از مدل بلوغ سرمایه فکری واز و همکاران (۲۰۱۸) استفاده شده است. انتخاب این مدل مبتنی بر ملاحظات (جامعیت سنج‌های این مدل، اعتبارسنجی بین‌المللی این مدل، تناسب مدل با بافت پژوهش، پشتیبانی تجربی مدل و مقایسه آن با سایر مدل‌های موجود) بوده است که نشان می‌دهد بهترین مدل به منظور تعیین سطح بلوغ سرمایه فکری می‌باشد.

این مدل به وسیله پرسشنامه با ۲۱ سنج شامل ۳ معیار اصلی و ۲۱ سؤال (۹ سؤال معرف سرمایه انسانی، ۸ سؤال معرف سرمایه ساختاری و ۴ سؤال معرف سرمایه رابطه‌ای) و براساس ابعاد سه گانه سرمایه فکری، برای شرکت‌ها شاخص بلوغ سرمایه فکری را به صورت خروجی عددی گسسته در بازه [۰-۱۴۷] مشخص می‌کند. سئوالات در قالب طیف هفت‌ارزشی لیکرت تنظیم شد و به تعداد نمونه آماری پرسشنامه توزیع و سپس تحلیل بر روی این تعداد پرسشنامه انجام شد. سپس سطوح بلوغ سرمایه فکری با توجه به خروجی‌های به دست آمده با تعیین ۵ سطح مختلف بلوغ سرمایه فکری براساس نقاط مقیاس بلوغ تعیین می‌شود که در جدول (۱) نشان داده شده است.

جدول ۱. سطوح مقیاس ارزیابی سرمایه فکری

سطوح بلوغ	نقاط مقیاس بلوغ	علائم مقیاس بلوغ
فرآیند اولیه (آغازین)	۱-۱۸	قرمز
فرآیند برنامه‌ریزی شده (مدیریت شده)	۱۹-۳۶	نارنجی
فرآیند ایجاد شده (تعریف شده)	۳۷-۷۴	زرد
فرآیند مدیریت شده (مدیریت کمی شده)	۷۵-۱۱۰	آبی
فرآیند بهینه شده (بهینه)	۱۱۱-۱۴۷	سبز

منبع: واز و همکاران (۲۰۱۸)

همچنین به منظور شناسایی هریک از عوامل تاثیرگذار بر سرمایه فکری شرکت‌های دانش‌بنیان (متغیر مستقل) که از آنها به عنوان ورودی مدل پیش‌بینی استفاده می‌شود، از بررسی ادبیات و پیشینه موضوع، اسناد و مدارک شرکت‌ها، مصاحبه با خبرگان و پرسشنامه محقق ساخته استفاده شده است. لذا ابتدا با توجه به بررسی ادبیات و پیشینه تحقیق و با استفاده از گام‌های هفت گانه روش ساندلوسکی و باروسو و با کدگذاری فاکتورها به روش فراترکیب عوامل اولیه موثر بر سرمایه فکری در قالب ۴ بُعد و ۱۰۴ شاخص (۲۴ شاخص براساس بعد سرمایه انسانی، ۲۵ شاخص براساس بعد سرمایه ساختاری، ۲۷ شاخص براساس بعد سرمایه رابطه‌ای و ۲۸ شاخص براساس بعد سرمایه نوآوری) شناسایی شد. سپس با روش مصاحبه نیمه ساختاریافته و رویکرد دلفی، نظرات خبرگان جمع‌آوری و اجماع حاصل شد. این مراحل شامل برگزاری سه جلسه پنل

با خبرگان و ارزیابی نظریات بود که پس از پایان سه مرحله‌ای رویکرد دلفی، در نهایت عوامل تاییدشده شامل ۵۳ شاخص بود که در قالب چهار مولفه سرمایه انسانی، سرمایه ساختاری، سرمایه ارتباطی و سرمایه نوآوری دسته‌بندی شدند. سرانجام داده‌ها از طریق یک پرسشنامه محقق‌ساخته با طیف پنج‌گزینه‌ای لیکرت که شامل ۵۳ سؤال بود، جمع‌آوری گردید. روایی و پایایی پرسشنامه‌ها به ترتیب به صورت روایی صوری و روایی سازه و پایایی آنها با استفاده از ضریب آلفای کرونباخ مورد بررسی قرار گرفته است. جهت تجزیه و تحلیل داده‌ها از تحلیل عاملی تاییدی، الگوریتم‌های جنگل تصادفی، K نزدیک‌ترین همسایه، درخت تصمیم، بیز ساده و شبکه عصبی پرسپترون چندلایه (MLP) با استفاده از نرم‌افزارهای Spss، PLS و کتابخانه‌های مختلف Python استفاده شده است.

برای استفاده از الگوریتم‌های یادگیری ماشین، ابتدا باید داده‌ها را پیش‌پردازش کرد. داده‌های خام معمولاً برای ورود مستقیم به الگوریتم مناسب نیستند بنابراین باید آنها را تغییر شکل داده و به فرمتی تبدیل کرد که برای الگوریتم قابل استفاده باشد. به عبارت دیگر پیش‌پردازش داده‌ها، آماده‌سازی داده‌ها برای مدل‌سازی است (مولایی‌فرد، ۱۴۰۱). لذا ابتدا مرحله پیش‌پردازش داده‌ها شامل پاک‌سازی داده‌ها، یکپارچه‌سازی داده‌ها، تبدیل داده‌ها (با استفاده از روش One-Hot Encoding و به این صورت که برای طبقات مختلف به ازای مقادیر غیر کمی، ستون‌های جدیدی ایجاد شد و مقدار آن با ۱ و ۰ با طول برابر طبقات جایگذاری انجام و به داده‌های کمی تبدیل شدند، تبدیل به این صورت انجام شد که گره خروجی برای یکی از عناصر بردار طبقه نگاشته می‌شود. برای مثال: اگر داده به طبقه دو تعلق داشته باشد، تنها گره خروجی دوم معادل یک بوده و چهار گره دیگر معادل صفر هستند) و کاهش ابعاد انجام شد و سپس به منظور افزایش دقت و سرعت عملکرد مدل‌های یادگیری ماشین و جلوگیری از کاهش سرعت و دقت ناشی از استفاده از داده‌های خام، نرمال‌سازی و استانداردسازی داده‌ها انجام شد. بدین صورت داده‌های نهایی در رنج ۰ تا ۱ نرمال‌سازی شدند تا یک مجموعه داده استاندارد ایجاد گردد (شمسی و همکاران، ۱۴۰۱).

$$X_n = L + \frac{(X - X_{min})(H - L)}{X_{max} - X_{min}} \quad \text{رابطه (۱)}$$

همچنین از ماتریس درهم‌ریختگی و معیار منحنی مشخصه عملکرد گیرنده ROC برای بررسی عملکرد هریک از مدل‌ها و مقایسه آنها استفاده شده است. ماتریس درهم‌ریختگی در جدول (۲) نشان داده شده است.

جدول ۲. ماتریس درهم‌ریختگی برای طبقه‌بندی

		PREDICTIVE VALUES	
		POSITIVE (1)	NEGATIVE (0)
ACTUAL VALUES	POSITIVE (1)	TP	FN
	NEGATIVE (0)	FP	TN

همانگونه که در ماتریس فوق مشاهده می شود، مقادیر می توانند در یکی از دسته های TN (منفی صحیح)، TP (مثبت صحیح)، FN (منفی کاذب) و FP (مثبت کاذب) قرار بگیرند.

TP: الگوریتم نمونه را در دسته مثبت طبقه بندی کرده و نمونه هم مثبت است.

FP: الگوریتم نمونه را در دسته مثبت طبقه بندی کرده اما نمونه منفی است.

TN: الگوریتم نمونه را در دسته منفی طبقه بندی کرده و نمونه هم منفی است.

FN: الگوریتم نمونه را در دسته منفی طبقه بندی کرده اما نمونه مثبت است.

۳-۱) معیار دقت^{۳۳}

این معیار نسبت تعداد پیش بینی های صحیح به تعداد کل نمونه ها را نشان می دهد. نرخ دقت مدل را می توانیم با نسبت زیر محاسبه کنیم:

$$Accuracy = \frac{T_p + T_n}{ALL} \quad \text{رابطه (۲)}$$

۳-۲) معیار صحت یا درستی^{۳۴}

این معیار نسبت تعداد پیش بینی های صحیح به تعداد پیش بینی هایی است که به یک کلاس اختصاص داده شده اند. منظور از صحت، مقدار نمونه هایی است که الگوریتم کلاس آنها را به درستی پیش بینی کرده و آنها را در دسته مثبت طبقه بندی کرده است. بنابراین:

$$Precision = \frac{TP}{TP + FP} \quad \text{رابطه (۳)}$$

۳-۳) معیار بازخوانی یا حساسیت^{۳۵}

این معیار نسبت تعداد پیش بینی های صحیح به تعداد نمونه هایی است که در واقع به یک کلاس تعلق دارند. این معیار به دنبال محاسبه پوشش بر روی کل داده هاست و تمرکز اصلی آن بر روی داده هایی است که واقعا «بلی» بوده اند.

$$Recall = \frac{TP}{TP + FN} \quad \text{رابطه (۴)}$$

۳-۴) معیار F1-Score

این معیار یک ترکیب از دقت و بازخوانی است که نسبت هندسی آنها را محاسبه می کند. برای اینکه درک بهتر و دقیق تری از معیارهای صحت و حساسیت داشته باشیم، می توانیم از مقدار F1 استفاده کنیم. برای محاسبه مقدار F1 می توانیم از فرمول زیر استفاده کنیم:

³³ Accuracy

³⁴ Precision

³⁵ Recall

$$F - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad \text{رابطه (۵)}$$

۳-۵) معیار منحنی مشخصه عملکرد گیرنده ROC

این معیارها از نمودار ROC به‌دست می‌آیند که در آن محور X نسبت تعداد نمونه‌های نادرست مثلث AUC به کل نمونه‌های منفی و محور Y نسبت تعداد نمونه‌های درست مثلث AUC به کل نمونه‌های مثبت است. AUC نشان‌دهنده مساحت زیر نمودار ROC است و بین ۰ تا ۱ است که مقدار بالاتر آن بهتر است.

۴) یافته‌ها

۴-۱) سطح بلوغ سرمایه فکری شرکت‌های دانش‌بنیان به‌عنوان خروجی‌های مدل

برای تعیین سطوح بلوغ سرمایه فکری شرکت‌های دانش‌بنیان و پاسخ سؤال اول پژوهش، ابتدا میانگین نمره ارزیابی معیارهای بلوغ سرمایه فکری براساس پرسشنامه استاندارد مدل واز و همکاران (۲۰۱۸) برای هر شرکت محاسبه شد. سپس این نمره با جدول استاندارد بلوغ سرمایه فکری واز و همکاران (۲۰۱۸) مقایسه شده و سطح بلوغ سرمایه فکری هر شرکت تعیین گردید. با توجه به اینکه نمونه آماری در این مرحله ۲۱۲ شرکت دانش‌بنیان بود لذا سطح بلوغ سرمایه فکری برای همه آنها محاسبه شد. جدول (۳) سطح بلوغ سرمایه فکری محاسبه‌شده برای شرکت‌های دانش‌بنیان را نشان می‌دهد.

جدول ۳. سطح بلوغ سرمایه فکری هریک از شرکت‌های دانش‌بنیان به‌عنوان خروجی‌های مدل

سطوح بلوغ سرمایه فکری	نقاط مقیاس بلوغ	تعداد شرکت متعلق به هر سطح
سطح اول- فرآیند اولیه (آغازین)	۱-۱۸	۱۳۱ شرکت
سطح دوم- فرآیند برنامه‌ریزی شده (مدیریت‌شده)	۱۹-۳۶	۴۱ شرکت
سطح سوم- فرآیند ایجادشده (تعریف‌شده)	۳۷-۷۴	۲۷ شرکت
سطح چهارم- فرآیند مدیریت‌شده (مدیریت کمی‌شده)	۷۵-۱۱۰	۱۱ شرکت
سطح پنجم- فرآیند بهینه‌شده (بهینه)	۱۱۱-۱۴۷	۲ شرکت

از تعداد ۲۱۲ شرکت شناسایی‌شده، ۶۲ درصد دارای سطح اول بلوغ- فرآیند اولیه (آغازین)، ۱۹ درصد دارای سطح دوم بلوغ- فرآیند برنامه‌ریزی‌شده (مدیریت‌شده)، ۱۳ درصد دارای سطح سوم بلوغ- فرآیند ایجادشده (تعریف‌شده)، ۵ درصد دارای سطح چهارم بلوغ- فرآیند مدیریت‌شده (مدیریت کمی‌شده) و فقط ۱ درصد دارای سطح پنجم بلوغ- فرآیند بهینه‌شده (بهینه) بودند که این پنج سطح بلوغ خروجی‌های مدل را تشکیل می‌دهند.

۴-۲) عوامل موثر بر سرمایه فکری شرکت‌های دانش‌بنیان به‌عنوان ورودی‌های مدل

در بخش کیفی این پژوهش، ابتدا ۴ بعد و ۱۰۴ شاخص مرتبط با سرمایه فکری از ادبیات تحقیق شناسایی شد. سپس از طریق مصاحبه نیمه‌ساختاریافته و با استفاده از روش دلفی در سه مرحله، نظرات خبرگان بررسی گردید. در این مراحل، ۲۸ شاخص در مرحله اول، ۲۱ شاخص در مرحله دوم و ۲ شاخص در مرحله سوم حذف شدند. درنهایت ۴ مولفه (سرمایه انسانی، سرمایه ساختاری، سرمایه ارتباطی و سرمایه نوآوری) و ۵۳ شاخص به‌عنوان عوامل موثر بر سرمایه فکری

شرکت‌های دانش‌بنیان برای پاسخ به سؤال دوم پژوهش و تحلیل در بخش کمی و به‌عنوان ورودی‌های مدل شناسایی گردید. این ابعاد و شاخص‌ها در جدول (۴) نشان داده شده‌است.

جدول ۴. ابعاد و شاخص‌های اصلی موثر بر سرمایه فکری

ابعاد اصلی	شاخص	نماد
عوامل سرمایه انسانی (HC)	تحصیلات کارکنان	HC1
	آموزش کارکنان	HC2
	روحیه کارآفرینی و خلاقیت کارکنان	HC3
	نگرش و انگیزش کارکنان	HC4
	دانش، تجارب و سوابق کارکنان	HC5
	شایستگی‌های مرتبط با کار	HC6
	کیفیت و توانایی رهبری استراتژیک	HC7
	مشارکت کارکنان در تصمیم‌گیری	HC8
	مهارت‌های کارکنان	HC9
	رضایت شغلی کارکنان	HC10
	تمایل کارکنان به یادگیری	HC11
	تعهد و روحیه سازمانی کارکنان	HC12
	مهارت انجام کار تیمی	HC13
	بهره‌وری نیروی کار	HC14
عوامل سرمایه ساختاری (SC)	فرهنگ سازمانی	SC1
	ساختار سازمانی	SC2
	رویه‌ها، سیاست‌ها و فرآیندها	SC3
	یادگیری سازمانی	SC4
	تحقیق و توسعه	SC5
	زیرساخت فناوری و سیستم‌های اطلاعاتی	SC6
	تفکر، دیدگاه و سبک مدیریت	SC7
	مالکیت فکری	SC8
	سرمایه اجتماعی	SC9
	مستندسازی اطلاعات و ایجاد پایگاه دانش	SC10
	تحول و بهبود مستمر فرآیندها	SC11
	سطح اشتراک‌گذاری اطلاعات و دانش	SC12
	شفافیت و دقت اطلاعات و مستندات	SC13
عوامل سرمایه رابطه‌ای (RC)	مشتری‌مداری	RC1
	تصویر و شهرت شرکت	RC2
	سهم بازار	RC3
	ارتباط با مصرف‌کنندگان	RC4
	ارزش برند شرکت	RC5

ابعاد اصلی	شاخص	نماد
	وفاداری مشتریان	RC6
	کانال‌های توزیع	RC7
	رضایت مشتریان	RC8
	هزینه‌های بازاریابی	RC9
	توانایی شناسایی مشتریان و نیاز آنها	RC10
	انعطاف‌پذیری در پاسخگویی به نیاز مشتری	RC11
	تنوع محصولات و خدمات	RC12
	مسئولیت‌های اجتماعی شرکت	RC13
	شبکه‌ها و ارتباطات مشتری	RC14
	سرمایه‌گذاری برای توسعه محصول	IC1
	پذیرش و سرمایه‌گذاری در ایده‌های جدید	IC2
	ارتقای آموزش در بخش نوآوری	IC3
	تشویق و تعلق‌پاداش به نوآوری و ایده‌پردازی	IC4
	نوآوری در محصولات و خدمات جدید	IC5
عوامل سرمایه نوآوری (IC)	ارتقای فرهنگ نوآوری	IC6
	توانایی ایجاد کسب‌وکار جدید	IC7
	استفاده از فناوری‌های جدید توسعه‌یافته	IC8
	ظرفیت نوآوری	IC9
	ایجاد فضای خلاق و نوآوری	IC10
	مدیریت زنجیره تامین برای نوآوری	IC11
	نوآوری پایدار و سازگار با محیط زیست	IC12

۴-۳) تحلیل عاملی تاییدی

برای بررسی اینکه آیا شاخص‌های موثر بر سرمایه فکری می‌توانند به‌عنوان سنج در ابعاد اصلی سرمایه انسانی، سرمایه ساختاری، سرمایه رابطه‌ای و سرمایه نوآوری قرار گیرند، از تحلیل عاملی تاییدی استفاده شده‌است تا این ابعاد اصلی پژوهش استخراج و تایید شوند. به‌همین منظور از تحلیل عاملی براساس شاخص‌های KMO و آزمون بارتلت استفاده شده‌است. برای استفاده از تحلیل عاملی تاییدی در پژوهش، ابتدا باید از این مسئله اطمینان حاصل شود که می‌توان داده‌های موجود را برای تحلیل مورد استفاده قرار داد. به عبارت دیگر تعداد داده‌های موردنظر برای تحلیل عاملی کافی باشند. در تحلیل عاملی تاییدی بارهای عاملی بزرگتر از ۰/۵، مقدار شاخص KMO حداقل ۰/۵ و سطح معنی‌داری آزمون بارتلت باید کوچکتر از ۰/۰۵ به‌دست آید. همچنین در این بخش به‌منظور اطمینان از سازگاری دورنی سنج‌ها از ضریب آلفای کرونباخ استفاده شده‌است. نتایج تحلیل عاملی تاییدی در جدول (۵) نشان داده شده‌است.

جدول ۵. تحلیل عاملی تاییدی برای تایید سازه‌های پژوهش

ابعاد اصلی	سنج	بار عاملی	KMO	سطح معنی‌داری آزمون بارتلت	واریانس تبیین شده	آلفای کرونباخ
	HC1	0/942	0/853	0/000	66/472	0/931

ابعاد اصلی	سنجه	بار عاملی	KMO	سطح معنی داری آزمون بارتلت	واریانس تبیین شده	آلفای کرونباخ
عوامل سرمایه انسانی	HC2	0/786	0/921	0/000	62/396	0/896
	HC3	0/889				
	HC4	0/824				
	HC5	0/809				
	HC6	0/936				
	HC7	0/830				
	HC8	0/856				
	HC9	0/792				
	HC10	0/864				
	HC11	0/833				
	HC12	0/934				
	HC13	0/773				
	HC14	0/801				
	SC1	0/931				
عوامل سرمایه ساختاری	SC2	0/798	0/842	0/000	69/194	0/872
	SC3	0/890				
	SC4	0/820				
	SC5	0/861				
	SC6	0/859				
	SC7	0/804				
	SC8	0/827				
	SC9	0/811				
	SC10	0/927				
	SC11	0/951				
	SC12	0/811				
	SC13	0/870				
	RC1	0/764				
	RC2	0/879				
عوامل سرمایه رابطه‌ای	RC3	0/815	0/861	0/000	71/186	0/902
	RC4	0/875				
	RC5	0/885				
	RC6	0/851				
	RC7	0/894				
	RC8	0/848				
	RC9	0/752				
	RC10	0/845				
	RC11	0/867				
	RC12	0/920				
	RC13	0/817				
	RC14	0/881				
	IC1	0/873				
	IC2	0/837				
عوامل سرمایه نوآوری	IC3	0/902	0/884	0/000		
	IC4	0/731				
	IC5	0/892				
	IC6	0/869				
	IC7	0/813				
	IC8	0/911				
	IC9	0/807				
	IC10	0/841				
	IC11	0/916				
	IC12	0/884				


نتایج جدول ۵، نشان می‌دهد که مقدار KMO برای تمام ابعاد اصلی بالاتر از ۰/۵ و سطح معنی داری آزمون بارتلت کوچکتر از ۰/۰۵ محاسبه شده است که نشان‌دهنده کفایت نمونه‌گیری و ناشناخته‌بودن ماتریس همبستگی بین سنجه‌ها برای استخراج ابعاد اصلی است.

بر اساس نتایج به دست آمده، همبستگی مطلوبی بین ابعاد نظری پژوهش وجود دارد و تمامی ابعاد اصلی، مورد تایید قرار می‌گیرند. علاوه بر این، مقدار آلفای کروناخ برای هریک از ابعاد اصلی که نشان‌دهنده سازگاری درونی سنجش‌هاست، بالای ۰/۷ به دست آمده است. این مقدار، پایایی مناسب و سازگاری درونی بالای سنجش‌ها را تایید می‌کند.

۴-۴) پیش‌بینی بلوغ سرمایه فکری شرکت‌های دانش‌بنیان بر اساس مدل‌های مختلف

در این پژوهش با توجه به اینکه هدف آن پیش‌بینی سطح بلوغ سرمایه فکری شرکت‌های دانش‌بنیان با استفاده از الگوریتم‌های مختلف یادگیری ماشین از جمله الگوریتم‌های جنگل تصادفی، K نزدیک‌ترین همسایه، درخت تصمیم، بیز ساده و شبکه عصبی پرسپترون چندلایه (MLP) بود، به منظور طراحی مدل‌های پیش‌بینی بلوغ سرمایه فکری، داده‌های موجود به دو بخش داده‌های آموزش به میزان ۸۰ درصد (۱۶۹ نمونه) و داده‌های تست به میزان ۲۰ درصد (۴۳ نمونه) تقسیم شده است. ابتدا پیش‌بینی سطح بلوغ سرمایه فکری با استفاده از ۴ الگوریتم کلاسیک و معمول یادگیری ماشین انجام شد و سپس از شبکه عصبی پرسپترون چندلایه استفاده گردید. سپس عملکرد مدل‌ها بر اساس معیارهای دقت، صحت، حساسیت، F1-Score و مساحت زیر منحنی ROC مورد ارزیابی قرار گرفته است. در این پژوهش، هایپرپارامترهای هریک از الگوریتم‌ها به روش سعی و خطا و بر اساس ارزیابی معیارهای عملکردی روی داده‌های اعتبارسنجی تنظیم شدند تا پیکربندی بهینه برای هر مدل تعیین گردد.

اشکال ۲، ۳، ۴ و ۵ به ترتیب نتایج به دست آمده برای داده‌های تست الگوریتم‌های کلاسیک یادگیری ماشین از جمله جنگل تصادفی (RF)، K نزدیک‌ترین همسایه (KNN)، درخت تصمیم (DT) و بیز ساده (NB) را نشان می‌دهد. در الگوریتم جنگل تصادفی مشاهده شد افزایش تعداد درخت‌ها به بیش از ۲۰۰، تاثیر چندانی بر دقت ندارد اما زمان آموزش را افزایش می‌دهد. در نهایت $N_Estimators=180$ و $Max\ Depth=10$ انتخاب شدند.




شکل ۲. نتایج ماتریس درهم‌ریختگی و منحنی ROC به دست آمده برای داده‌های تست الگوریتم جنگل تصادفی (RF)

نتایج به صورت خلاصه در جدول (۶) نشان داده شده است.

جدول ۶. نتایج به دست آمده برای داده‌های تست الگوریتم جنگل تصادفی (RF)

معیارهای ارزیابی					نوع داده	نوع مدل
Accuracy	Precision	Recall	F1-Score	AUC-ROC		
۷۴/۴۲	۶۷/۳۰	۷۴/۴۲	۷۰/۱۴	۰/۸۹۸	تست	جنگل تصادفی (RF) n_estimators = 180 Max Depth=10

در الگوریتم نزدیک‌ترین همسایه مشاهده شد که مقدار $K=4$ با فاصله اقلیدسی و وزن‌دهی براساس فاصله بهترین نتیجه را داشت. مقادیر کمتر از ۴ منجر به نویزپذیری شد درحالی‌که مقادیر بالاتر، باعث کاهش حساسیت مدل به الگوهای محلی شد.



شکل ۳. نتایج ماتریس درهم‌ریختگی و منحنی ROC به دست آمده برای داده‌های تست الگوریتم K نزدیک‌ترین همسایه


نتایج به صورت خلاصه در جدول (۷) نشان داده شده است.

جدول ۷. نتایج به دست آمده برای داده‌های تست الگوریتم K نزدیک‌ترین همسایه

معیارهای ارزیابی					نوع داده	نوع مدل
Accuracy	Precision	Recall	F1-Score	AUC-ROC		
۷۲/۰۹	۷۰/۰۸	۷۲/۰۹	۶۴/۹۱	۰/۸۸۱	تست	K نزدیک‌ترین همسایه (KNN) K = 4

در الگوریتم درخت تصمیم ابتدا از مقادیر پیش فرض استفاده شد سپس با افزایش تدریجی Max Depth، مشاهده شد عمق بیش از ۷ منجر به بیش‌برازش^{۳۶} می‌شود. در نهایت Max Depth=7 بهترین تعادل بین دقت و تعمیم‌پذیری را ارائه داد.

³⁶ Overfitting




شکل ۴. نتایج ماتریس درهم‌ریختگی و منحنی ROC به‌دست آمده برای داده‌های تست الگوریتم درخت تصمیم (DT)

نتایج به‌صورت خلاصه در جدول (۸) نشان داده شده‌است.

جدول ۸. نتایج به‌دست آمده برای داده‌های تست الگوریتم درخت تصمیم (DT)

معیارهای ارزیابی					نوع داده	نوع مدل
Accuracy	Precision	Recall	F1-Score	AUC-ROC		
۶۵/۱۲	۵۱/۶۹	۶۵/۱۲	۵۷/۵۵	۰/۸۸۲	تست	max_depth= 7 (DT) درخت تصمیم

از آنجاکه در الگوریتم بیز ساده داده‌ها عمدتاً عددی بودند، توزیع گاوسی انتخاب شد. مقدار $\text{Alpha}=0.5$ بهترین تعادل را بین انعطاف‌پذیری و پایداری مدل ایجاد کرد.



شکل ۵. نتایج ماتریس درهم‌ریختگی و منحنی ROC به‌دست آمده برای داده‌های تست الگوریتم بیز ساده (NB)

نتایج به‌صورت خلاصه در جدول (۹) نشان داده شده‌است.

جدول ۹. نتایج به‌دست آمده برای داده‌های تست الگوریتم بیز ساده (NB)


معیارهای ارزیابی					نوع داده	نوع مدل
Accuracy	Precision	Recall	F1-Score	AUC-ROC		
۶۲/۷۹	۴۹/۰۷	۶۲/۷۹	۵۵/۰۷	۰/۸۷۰	تست	بیز ساده (NB) Alpha=0.5

در طراحی شبکه عصبی پرسپترون چندلایه (با استفاده از الگوریتم‌های گرادیانی)، تغییر در هایپر پارامترهای مختلف شامل تعداد لایه‌ها، تعداد نورون‌ها در هر لایه، نوع تابع فعال‌سازی و ضرایب وزن‌های شبکه جهت تنظیمات بهینه و مدل‌سازی با عملکرد مناسب انجام شد. همچنین برای بهبود عملکرد شبکه، پارامترهای آموزش مانند نرخ یادگیری و تعداد دوره‌ها به دقت بهینه‌سازی شدند. ابتدا ساختار شبکه با ۵۳ نورون در لایه ورودی، یک لایه پنهان با یک نورون و ۵ نورون در لایه خروجی پیاده‌سازی شد. در ادامه به منظور دستیابی به نتایج بهتر و نیز بهبودهای احتمالی، تعداد نورون‌های لایه پنهان افزایش یافت. سپس تعداد لایه‌های پنهان افزایش پیدا کرد و با استفاده از شاخص‌های حاصل از ماتریس درهم‌ریختگی و منحنی‌های ROC بهترین شبکه عصبی MLP انتخاب شد. نتایج در جدول (۱۰) نشان داده شده‌است.

جدول ۱۰. نتایج شبکه عصبی MLP با یک لایه پنهان و نورون‌های مختلف

معیارهای ارزیابی					نوع داده	تعداد نورون‌ها لایه پنهان
Accuracy	Precision	Recall	F1-Score	AUC-ROC		
۶۹/۷۷	۵۶/۸۹	۶۹/۷۷	۶۲/۲۷	۰/۸۷۲	تست	۱ لایه پنهان و ۱ نورون
۷۲/۸۷	۷۳/۳۵	۷۲/۸۷	۶۸/۸۹	۰/۸۹۸	تست	۱ لایه پنهان و ۲ نورون
۷۷/۰۳	۷۵/۶۱	۷۷/۰۳	۷۲/۶۵	۰/۹۰۱	تست	۱ لایه پنهان و ۳ نورون
۸۳/۶۵	۸۲/۴۳	۸۳/۶۵	۷۹/۷۷	۰/۹۰۴	تست	۱ لایه پنهان و ۴ نورون
۸۸/۳۷	۸۹/۷۵	۸۸/۳۷	۸۶/۵۱	۰/۹۱۸	تست	۱ لایه پنهان و ۵ نورون
۸۶/۲۶	۸۴/۹۴	۸۶/۲۶	۸۲/۰۱	۰/۹۰۲	تست	۱ لایه پنهان و ۶ نورون
۸۵/۶۷	۸۴/۴۵	۸۵/۶۷	۸۱/۲۹	۰/۸۸۷	تست	۱ لایه پنهان و ۷ نورون
۸۴/۱۳	۸۲/۶۱	۸۴/۱۳	۷۹/۶۵	۰/۸۷۴	تست	۱ لایه پنهان و ۸ نورون
۸۲/۶۸	۸۱/۳۶	۸۲/۶۸	۷۸/۹۰	۰/۸۵۹	تست	۱ لایه پنهان و ۹ نورون
۷۹/۳۵	۷۸/۲۳	۷۹/۳۵	۷۵/۶۷	۰/۸۴۳	تست	۱ لایه پنهان و ۱۰ نورون
۷۶/۷۴	۷۵/۴۲	۷۶/۷۴	۷۲/۵۶	۰/۸۸۰	تست	۲ لایه پنهان و هر لایه ۵ نورون
۶۷/۴۴	۵۴/۲۹	۶۷/۴۴	۵۹/۹۴	۰/۷۷۱	تست	۳ لایه پنهان و هر لایه ۵ نورون

نتایج اجرای شبکه عصبی پرسپترون چندلایه با یک لایه پنهان و تعداد نورون‌های مختلف در جدول ۱۰ نشان می‌دهد که بیشترین مقدار معیار دقت، معیار صحت، معیار حساسیت، معیار F1-Score و مساحت زیرمنحنی ROC برای داده‌های تست در شبکه عصبی MLP با ۵ نورون اتفاق افتاده‌است. پس از آن میزان این معیارها با افزایش تعداد نورون، کاهش یافته‌است. بنابراین بهترین ساختار شبکه عصبی، شبکه‌ای با پنج نورون در لایه پنهان است. شکل ۶ نتایج به‌دست آمده برای داده‌های تست شبکه عصبی با ۵ نورون در لایه پنهان را نشان می‌دهد.




شکل ۶. نتایج ماتریس درهم‌ریختگی و منحنی ROC به‌دست آمده برای شبکه عصبی MLP با یک لایه پنهان و پنج نورون

نتایج به‌صورت خلاصه در جدول (۱۱) نشان داده شده‌است.

جدول ۱۱. نتایج داده‌های تست شبکه عصبی MLP با یک لایه پنهان و پنج نورون

معیارهای ارزیابی					نوع داده	مشخصات اشکال
Accuracy	Precision	Recall	F1-Score	AUC-ROC		
۸۸/۳۷	۸۹/۷۵	۸۸/۳۷	۸۶/۵۱	۰/۹۱۸	تست	نتایج شبکه عصبی با ۱ لایه پنهان و ۵ نورون

همچنین منحنی ضرر در مقابل دقت برای درک بهتر نحوه یادگیری و پیشرفت مدل برای شبکه عصبی با ۵ نورون در لایه پنهان با ۵۰ دوره آموزش در شکل ۷ نشان داده شده‌است که بیانگر این است که هم خطای یادگیری و هم خطای تست بطور یکنواخت کاهش یافته‌است و در نتیجه در فرآیند آموزش مدل بایاس^{۳۷} و در فرآیند آزمون مدل واریانس^{۳۸} کم بوده‌است و مدل دارای برازش مناسبی می‌باشد. بطور کلی جهت برازش مناسب همه مدل‌های این پژوهش از راهکارهای پیش‌پردازش مناسب داده‌ها، تنظیم وزن (Regularization) به تابع هزینه مدل، روش‌های تطبیقی نرخ یادگیری مثل استفاده از الگوریتم بهینه‌ساز Adam و افزودن Dropout به لایه‌های پنهان استفاده شده‌است.



شکل ۷. آموزش مدل شبکه عصبی MLP با ۱ لایه پنهان و ۵ نورون براساس منحنی ضرر و دقت

^{۳۷} Bias

^{۳۸} Variance

نتایج مربوط به تعداد لایه‌های پنهان شبکه عصبی پرسپترون چندلایه در جدول (۱۱) نشان می‌دهد که بیشترین مقدار معیار دقت، معیار صحت، معیار حساسیت، معیار F1-Score و مساحت زیرمنحنی ROC برای داده‌های تست در شبکه عصبی MLP با ۱ لایه پنهان و ۵ نورون اتفاق افتاده است. بنابراین بهترین ساختار شبکه عصبی پرسپترون چندلایه (با استفاده از الگوریتم‌های گرادیانی)، از بین ساختارهای مختلف، شبکه‌ای با ۵ نورون و ۱ لایه پنهان انتخاب می‌شود که معماری آن در جدول (۱۲) نشان داده شده است.

جدول ۱۲. ساختار شبکه عصبی MLP بهینه‌شده جهت پیش‌بینی سطح بلوغ سرمایه فکری

تعداد نورون لایه ورودی	۵۳ نورون
تعداد لایه پنهان و نورون‌های آن	۱ لایه پنهان با ۵ نورون
تعداد نورون‌های لایه خروجی	۵ نورون
تابع فعال‌ساز لایه پنهان	Relu
تابع فعال‌ساز لایه خروجی	Softmax
الگوریتم بهینه‌ساز	الگوریتم‌های گرادیانی-Adam
تعداد دوره	Epoch 50
نرخ یادگیری	0/001 با استفاده از روش‌های تطبیقی نرخ یادگیری
اندازه دسته	Batch 8
ترکیب داده‌ها	۸۰ درصد آموزش (۱۶۹ نمونه) و ۲۰ درصد تست (۴۳ نمونه)


۴-۵) انتخاب بهترین مدل پیش‌بینی سطح بلوغ سرمایه فکری شرکت‌های دانش‌بنیان از بین مدل‌های مختلف

براساس نتایج به‌دست‌آمده برای هریک از مدل‌های درخت تصمیم (DT)، K نزدیک‌ترین همسایه (KNN)، بیز ساده (NB)، جنگل تصادفی (RF) و شبکه عصبی پرسپترون چندلایه با الگوریتم گرادیانی و مقایسه عملکرد آنها به‌منظور تعیین بهترین مدل پیش‌بینی سطح بلوغ سرمایه فکری شرکت‌های دانش‌بنیان و نیز پاسخ به سؤال سوم پژوهش، بهترین نتایج مربوط به هریک از این مدل‌ها در روش‌های مختلف و براساس معیار دقت، معیار صحت، معیار حساسیت، معیار F1-Score و مساحت زیرمنحنی ROC برای داده‌های تست در جدول (۱۳) نشان داده شده است.

جدول ۱۳. مقایسه عملکرد مدل‌های مختلف جهت پیش‌بینی سطح بلوغ سرمایه فکری

معیارهای ارزیابی					نوع داده	نوع مدل
Accuracy	Precision	Recall	F1-Score	AUC-ROC		
۸۸/۳۷	۸۹/۷۵	۸۸/۳۷	۸۶/۵۱	۰/۹۱۸	تست	شبکه عصبی MLP گرادیانی با ۱ لایه پنهان و ۵ نورون
۷۴/۴۲	۶۷/۳۰	۷۴/۴۲	۷۰/۱۴	۰/۸۹۸	تست	جنگل تصادفی (RF) n_estimators = 180 Max Depth=10
۷۲/۰۹	۷۰/۰۸	۷۲/۰۹	۶۴/۹۱	۰/۸۸۱	تست	K نزدیک‌ترین همسایه (KNN) K = 4
۶۵/۱۲	۵۱/۶۹	۶۵/۱۲	۵۷/۵۵	۰/۸۸۲	تست	درخت تصمیم (DT) max_depth= 7
۶۲/۷۹	۴۹/۰۷	۶۲/۷۹	۵۵/۰۷	۰/۸۷۰	تست	بیز ساده (NB) Alpha=0.5

نمودار (۱) نشان‌دهنده بهترین نتایج مربوط به هریک از این مدل‌ها در روش‌های مختلف و براساس معیار دقت، معیار صحت، معیار حساسیت، معیار F1-Score و مساحت زیرمنحنی ROC برای داده‌های تست می‌باشد.



نمودار ۱. نتایج عملکرد مدل‌ها جهت پیش‌بینی سطح بلوغ سرمایه فکری براساس داده‌های تست

نتایج جدول (۱۳) و نمودار (۱)، نشان می‌دهد که بهترین مدل برای پیش‌بینی سطح بلوغ سرمایه فکری شرکت‌های دانش‌بنیان، شبکه عصبی MLP گزاردیانی با ۱ لایه پنهان و ۵ نورون است که دارای بیشترین مقدار معیار دقت با ۸۸/۳۷ درصد می‌باشد. این عدد نشان می‌دهد که مدل MLP در ۸۸/۳۷٪ از موارد توانسته‌است سطح بلوغ سرمایه فکری را به درستی پیش‌بینی کند و در ارتباط با اهداف تحقیق، دقت بالا نشان می‌دهد که مدل از توانایی بالایی در طبقه‌بندی سطوح بلوغ برخوردار است. معیار صحت با ۸۹/۷۵ درصد، نشان می‌دهد که از بین تمام پیش‌بینی‌های مدل برای یک سطح خاص از بلوغ، ۸۹/۷۵٪ صحیح بوده‌اند و در ارتباط با اهداف تحقیق، صحت بالا نشان می‌دهد که مدل، نرخ خطای کمی در پیش‌بینی‌های مثبت کاذب دارد. معیار حساسیت با ۸۸/۳۷ درصد، نشان می‌دهد که مدل توانسته‌است ۸۸/۳۷٪ از موارد واقعی هر سطح بلوغ را به درستی شناسایی کند و در ارتباط با اهداف تحقیق، حساسیت بالا نشان می‌دهد که مدل توانایی خوبی در تشخیص سطوح مختلف بلوغ دارد و موارد واقعی را نادیده نمی‌گیرد. در ارتباط با اهداف تحقیق، معیار F1-Score با ۸۶/۵۱ درصد، ترکیبی از صحت و حساسیت است و تعادل بین آنها را نشان می‌دهد و در ارتباط با اهداف تحقیق، از آنجا که این معیار به هر دو خطای مثبت کاذب و منفی کاذب حساس است، مقدار بالا نشان می‌دهد که مدل نه تنها دقیق است بلکه در شناسایی تمام سطوح بلوغ تعادل خوبی دارد و مساحت زیرمنحنی ROC با ۰/۹۱۸ نشان می‌دهد که مدل چقدر خوب می‌تواند بین سطوح مختلف بلوغ تمایز قائل شود. مقدار ۰/۹۱۸ (نزدیک به ۱) نشان‌دهنده تمایز عالی است و در ارتباط با اهداف تحقیق، AUC بالا تایید می‌کند که مدل نه تنها در پیش‌بینی سطوح بلوغ دقیق است بلکه قابلیت تشخیص تفاوت بین سطوح مختلف را نیز دارد. برای داده‌های تست در پیش‌بینی سطح بلوغ سرمایه فکری شرکت‌های دانش‌بنیان می‌باشد.

نتایج این پژوهش نشان می‌دهد شبکه عصبی پرسپترون چندلایه (MLP) به دلیل توانایی یادگیری روابط غیرخطی، توانایی یادگیری عمیق (استخراج ویژگی‌ها)، انعطاف‌پذیری معماری (تنظیم تعداد لایه‌ها و نورون‌ها)، مکانیزم‌های بهینه‌سازی پیشرفته (Adam, Dropout)، انعطاف‌پذیری در مدل‌سازی داده‌های پیچیده و مقاومت در برابر نویز، عملکرد

بهتری نسبت به سایر مدل‌ها داشته‌است. در مقابل محدودیت‌های سایر الگوریتم‌ها، باعث شده‌است که نتوانند به سطح دقت MLP دست یابند. نتایج مقایسه الگوریتم‌های یادگیری ماشین مورد استفاده در پژوهش و دلایل برتری الگوریتم شبکه عصبی در جدول (۱۴) نشان داده شده‌است.

جدول ۱۴. مقایسه الگوریتم‌های یادگیری ماشین مورد استفاده در پژوهش و دلایل برتری الگوریتم شبکه عصبی

الگوریتم	محدودیت‌های کلیدی	دلایل عملکرد بهتر الگوریتم شبکه عصبی مصنوعی
درخت تصمیم (DT)	- مستعد بیش‌برازش - حساس به تغییرات کوچک در داده - عملکرد ضعیف در داده‌های پرابعد	- استفاده از تکنیک‌های منظم‌سازی (Dropout, L2) - توانایی یادگیری ویژگی‌های انتزاعی در ابعاد بالا
نزدیک‌ترین همسایه (KNN)	- حساس به مقیاس داده‌ها - هزینه محاسباتی بالا - مشکل در داده‌های پرابعد	- عدم وابستگی به محابات فاصله‌ای - کاهش ابعاد با لایه‌های پنهان - یادگیری ویژگی‌های غیرخطی
بیز ساده (NB)	- فرض استقلال نادرست بین ویژگی‌ها - عدم توانایی در مدل‌سازی روابط غیرخطی	- عدم نیاز به فرض استقلال - یادگیری روابط پیچیده با توابع فعال‌سازی غیرخطی
جنگل تصادفی (RF)	- محدودیت در یادگیری روابط عمیق - تفسیرپذیری کمتر نسبت به DT	- توانایی کشف الگوهای سلسله‌مراتبی عمیق - انعطاف‌پذیری بیشتر در معماری شبکه

(۵) نتیجه‌گیری و پیشنهادها

این پژوهش به دنبال یافتن یک مدل مناسب برای پیش‌بینی سطح بلوغ سرمایه فکری در شرکت‌های دانش‌بنیان واقع در شهرک‌های صنعتی با استفاده از رویکرد یادگیری ماشین است. در حال حاضر، هیچ مدل هوشمندی برای ارزیابی و پیش‌بینی سطح سرمایه فکری در این شرکت‌ها وجود ندارد که این کمبود مانع تبدیل سرمایه به ارزش می‌شود. عدم آگاهی از سطح سرمایه فکری می‌تواند به شکست پروژه‌های مدیریت دانش و نوآوری منجر شود. این پژوهش نشان می‌دهد سرمایه فکری دارای ویژگی‌های غیرخطی و پویایی است و به همین دلیل نیاز به یک مدل هوشمند برای پیش‌بینی آن احساس می‌شود. در این راستا، از الگوریتم‌های مختلف یادگیری ماشین شامل جنگل تصادفی، K نزدیک‌ترین همسایه، درخت تصمیم، بیز ساده و شبکه عصبی پرسپترون چندلایه استفاده شده و نتایج حاصل از این الگوریتم‌ها با هم مقایسه شده تا یک مدل مناسب جهت پیش‌بینی سطح بلوغ سرمایه فکری در شرکت‌های دانش‌بنیان ارائه شود.

در این پژوهش ابتدا با استفاده از پرسشنامه استاندارد براساس مدل واز و همکاران (۲۰۱۸) سطح بلوغ سرمایه فکری برای شرکت‌های دانش‌بنیان به عنوان خروجی‌های مدل و در جهت پاسخ به سؤال اول پژوهش، در قلمرو تحقیق تعیین شد. نتایج نشان داد از تعداد ۲۱۲ شرکت شناسایی شده، ۶۲ درصد دارای سطح اول بلوغ- فرآیند اولیه (آغازین)، ۱۹ درصد دارای سطح دوم بلوغ- فرآیند برنامه‌ریزی شده (مدیریت شده)، ۱۳ درصد دارای سطح سوم بلوغ- فرآیند ایجاد شده (تعریف شده)، ۵ درصد دارای سطح چهارم بلوغ- فرآیند مدیریت شده (مدیریت کمی شده) و فقط ۱ درصد دارای سطح پنجم بلوغ- فرآیند بهینه شده (بهینه) بودند. سپس ضمن مروری بر ادبیات تحقیق و پیشینه، ابتدا عوامل موثر بر سرمایه فکری شناسایی و از طریق پنل خبرگان و روش دلفی استخراج شد و ۵۳ شاخص به عنوان عوامل موثر بر سرمایه فکری شرکت‌های

دانش‌بنیان برای پاسخ به سؤال دوم پژوهش و تحلیل در بخش کمی و به‌عنوان ورودی‌های مدل شناسایی گردید. در ادامه با استفاده از مدل‌های مختلف یادگیری ماشین، پیش‌بینی بلوغ سرمایه‌فکری صورت گرفت و با محاسبه شاخص‌های دقت، صحت، بازخوانی و معیار F1-Score، با استفاده از تشکیل ماتریس درهم‌ریختگی و همچنین معیار منحنی مشخصه عملکرد گیرنده ROC، بهترین روش پیش‌بینی تعیین شد. در نهایت جهت پاسخ به سؤال سوم پژوهش، مناسب‌ترین مدل برای پیش‌بینی سطح بلوغ سرمایه‌فکری انتخاب گردید.

براساس نتایج به‌دست‌آمده از مقایسه عملکرد مدل‌های درخت تصمیم (DT)، K نزدیک‌ترین همسایه (KNN)، بیز ساده (NB)، جنگل تصادفی (RF) و شبکه عصبی پرسپترون چندلایه با الگوریتم گرادیانی، همه این مدل‌ها قابلیت پیش‌بینی سطح بلوغ سرمایه‌فکری در شرکت‌های دانش‌بنیان را دارند ولی مدل شبکه عصبی چندلایه با ۵ نورون و ۱ لایه پنهان بهترین کارایی را نشان می‌دهد. براساس معیارهای دقت، صحت، حساسیت، F1-Score و مساحت زیرمنحنی ROC، عملکرد این مدل به ترتیب برابر ۸۸/۳۷ درصد، ۸۹/۷۵ درصد، ۸۸/۳۷ درصد، ۸۶/۵۱ درصد و ۰/۹۱۸ محاسبه شده‌است که نشان‌دهنده برتری آن نسبت به سایر مدل‌ها در پیش‌بینی بلوغ سرمایه‌فکری است.

در این پژوهش، مدلی هوشمند برای پیش‌بینی بلوغ سرمایه‌فکری در شرکت‌های دانش‌بنیان شهرک‌های صنعتی، با استفاده از الگوریتم‌های یادگیری ماشین ارائه شد. نتایج نشان داد که تاکنون کارهای تجربی در رابطه با پیش‌بینی سطح بلوغ سرمایه‌فکری شرکت از طریق الگوریتم‌های یادگیری ماشین انجام نشده‌است بلکه مطالعات و پژوهش‌هایی که در حوزه ارزیابی بلوغ سرمایه‌فکری شرکت‌ها صورت گرفته‌است، براساس روش‌های آماری و حسابداری بوده‌است که مدل ارائه‌شده قادر به ارزیابی دقیق‌تر و پیش‌بینی موثرتر بلوغ سرمایه‌فکری نسبت به روش‌های سنتی است. همچنین یافته‌ها نشان می‌دهند که سرمایه‌فکری و ابعاد آن در سازمان‌ها، ماهیت غیرخطی و پویا دارند. سازمان‌ها در مراحل پنج‌گانه بلوغ سرمایه‌فکری، از الگوی غیرخطی پیروی می‌کنند که با یافته‌های (لیو و کوهه، ۲۰۲۲؛ گرامی و همکاران، ۲۰۲۲ آصف و همکاران، ۲۰۲۱؛ زی و ژانگ، ۲۰۲۱؛ کوهه و همکاران، ۲۰۲۱؛ نجات و کریمی خوزان، ۲۰۲۰؛ براتینو، ۲۰۱۸ و ساردو و سراسکیرو، ۲۰۱۸) هم‌راستا است.

این مدل از سه جنبه دارای ارزش کاربردی قابل توجه برای شرکت‌های دانش‌بنیان است: اول؛ مدل ارائه‌شده با دقت بالای ۸۵ درصد، از قابلیت اطمینان کافی برای تصمیم‌گیری‌های مدیریتی برخوردار است. دوم؛ سرعت و دقت آن در مقایسه با روش‌های سنتی ارزیابی بلوغ سرمایه‌فکری که مبتنی بر روش‌های آماری و حسابداری هستند، بطور محسوسی بالاتر است. سوم؛ این مدل قابلیت یکپارچه‌سازی با سیستم‌های مدیریتی موجود در شرکت‌ها را دارد. همچنین از دیدگاه عملی، این مدل می‌تواند به‌عنوان ابزاری راهبردی در موارد زیر مورد استفاده قرار گیرد:

- تشخیص مرحله بلوغ فعلی شرکت
- بهینه‌سازی تخصیص منابع برای ارتقای سرمایه‌فکری
- پایش مستمر تغییرات سطح بلوغ
- تسهیل انتقال مدیریت دانش در سازمان

هرچند برای پیاده‌سازی عملی این مدل، نیاز به زیرساخت‌های داده‌ای مناسب و آموزش نیروی انسانی وجود دارد اما با توجه به دقت بالا و قابلیت‌های منحصربه‌فرد آن، می‌توان نتیجه گرفت که این نتایج نه تنها در سطح تئوریک ارزشمند هستند بلکه از قابلیت پیاده‌سازی عملی در شرکت‌های دانش‌بنیان نیز برخوردار می‌باشند. برای تبدیل کامل این پژوهش به یک راهکار عملی، پیشنهاد می‌شود در گام بعدی، مدل در چند شرکت به‌صورت پایلوت اجرا شده و مازول‌های صنعت محور برای آن توسعه داده شود.

علاوه بر این، مدل پیشنهادی با ارائه رویکردی سیستماتیک برای استانداردسازی و تسهیل انتقال مدیریت دانش، گامی مهم در جهت ارتقای نوآوری و رقابتی‌تر شدن شرکت‌های دانش‌بنیان برداشته‌است. این مدل می‌تواند به‌عنوان ابزاری راهبردی برای مدیران این شرکت‌ها در تصمیم‌گیری‌های کلیدی و برنامه‌ریزی‌های استراتژیک در حوزه مدیریت سرمایه فکری مورد استفاده قرار گیرد. مطالعات آتی می‌توانند بر گسترش این مدل به دیگر صنایع و بررسی تاثیر آن بر عملکرد بلندمدت شرکت‌ها متمرکز شوند.

این پژوهش دارای محدودیت‌هایی می‌باشد که شامل موارد زیر می‌باشند: نخستین محدودیت این پژوهش، محدودبودن انتخاب شبکه عصبی مصنوعی مناسب براساس تعداد نوروں و لایه پنهان بوده‌است. به‌عبارت دیگر، در این پژوهش برای انتخاب تعداد نوروں مناسب در شبکه عصبی مصنوعی یا تعداد لایه‌های پنهان، محقق به روش سعی و خطا اکتفا کرده و از این طریق مدل مناسب جهت پیش‌بینی سطح بلوغ سرمایه فکری در شرکت‌های دانش‌بنیان را انتخاب نموده‌است. محدودیت دیگر این پژوهش، محدودبودن انتخاب پارامترها در الگوریتم‌های کلاسیک و معمول یادگیری ماشین از جمله K نزدیک‌ترین همسایه، درخت تصمیم و جنگل تصادفی براساس تعداد همسایه‌ها، حداکثر عمق و تعداد درخت تصمیم بوده‌است. از دیگر محدودیت‌های این پژوهش، دوره زمانی تحقیق می‌باشد که می‌تواند بر نتایج تحقیقات اثرگذار باشد. در صورتیکه قلمرو زمانی تحقیق برای دوره طولانی‌تری در نظر گرفته می‌شد، ممکن بود نتایج قابلیت تعمیم بیشتری داشته باشد. بنابراین در تعمیم نتایج پژوهش باید به دوره زمانی تحقیق توجه شده و تحلیل‌های انجام گرفته در این چارچوب قرار گیرد. یکی دیگر از محدودیت‌های این پژوهش، مربوط به جامعه آماری این تحقیق می‌باشد. جامعه آماری تنها مربوط به شرکت‌های دانش‌بنیان مستقر در شهرک‌های صنعتی غرب کشور است و نتایج قابل تعمیم به تمامی صنایع، تخصص‌ها و فعالیت‌های دیگر نمی‌باشد.

پیشنهادهای کاربردی برای بهبود و پیاده‌سازی مدل هوشمند پیش‌بینی بلوغ سرمایه فکری در شرکت‌های دانش‌بنیان به شرح زیر ارائه می‌شود:

- توسعه و استقرار مدل در سایر صنایع: پیشنهاد می‌شود که مدل پیش‌بینی بلوغ سرمایه فکری به صنایع دیگر نیز گسترش یابد تا قابلیت‌های آن مورد ارزیابی قرار گیرد و بتواند به شرکت‌های غیردانش‌بنیان نیز کمک کند.
- آموزش و آگاهی‌بخشی به مدیران: مدیران و کارکنان شرکت‌های دانش‌بنیان باید درخصوص اهمیت سرمایه فکری و کاربرد مدل‌های هوشمند یادگیری ماشین آموزش ببینند تا بتوانند بهتر از این ابزارها برای تصمیم‌گیری‌های استراتژیک بهره‌برداری کنند.

- ایجاد بانک اطلاعاتی از داده‌های سرمایه فکری: لازم است بانک اطلاعاتی از داده‌های مربوط به سرمایه فکری در شرکت‌ها ایجاد شود تا مدل بتواند به مرور زمان با داده‌های جدید به‌روزرسانی شود و دقت پیش‌بینی‌های خود را افزایش دهد.
- تحلیل و بهبود مستمر مدل: برای نگهداری و بهبود دقت مدل، به‌روزرسانی‌های مستمر با استفاده از داده‌های جدید و تکنیک‌های یادگیری ماشین باید انجام شود. این امر به ایمن‌سازی عملکرد مدل و پایداری پیش‌بینی‌ها در طول زمان کمک خواهد کرد.
- تسهیل انتقال دانش و فناوری: شرکت‌ها باید فرآیندهای انتقال دانش و فناوری را با استفاده از مدل پیش‌بینی بهینه کنند. این می‌تواند شامل ایجاد ساختارهای مناسب برای انتقال تجربیات و موفقیت‌های مرتبط با سرمایه فکری باشد.
- استفاده از نتایج برای تدوین استراتژی‌های کسب و کار: شرکت‌ها می‌توانند از نتایج حاصل از مدل‌های پیش‌بینی برای تنظیم و بهبود استراتژی‌های کسب و کار خود در حوزه تحقیق و توسعه، بازاریابی و مدیریت منابع انسانی استفاده کنند.
- همکاری با دانشگاه‌ها و مراکز تحقیقاتی: ایجاد همکاری‌های مستمر با دانشگاه‌ها و مراکز تحقیقاتی می‌تواند به بهبود کیفیت و دقت داده‌ها و الگوریتم‌های استفاده‌شده در مدل، کمک کند و به توسعه فناوری‌های نوآورانه منجر شود.
- این پیشنهادات می‌توانند به ارتقای عملکرد و تحقق اهداف شرکت‌های دانش‌بنیان کمک کرده و زمینه‌ساز افزایش نوآوری و رقابت‌پذیری آنها در بازار شوند.
- در پایان، پیشنهادات برای تحقیقات آینده به شرح زیر ارائه می‌شود:
- استفاده از سایر الگوریتم‌های یادگیری ماشین: با توجه به استفاده از پنج الگوریتم یادگیری ماشین در این پژوهش، پیشنهاد می‌شود از سایر الگوریتم‌های یادگیری ماشین استفاده شود و نتایج با یافته‌های این تحقیق مقایسه گردد.
- استفاده از الگوریتم‌های فراابتکاری: پیشنهاد می‌شود از ترکیب شبکه عصبی مصنوعی با الگوریتم‌های فراابتکاری مختلف استفاده شود و نتایج با یافته‌های این تحقیق مقایسه گردد. همچنین ترکیب شبکه عصبی مصنوعی فازی با الگوریتم‌های فراابتکاری می‌تواند به بهبود مدل‌ها کمک کند.
- افزایش دوره زمانی پژوهش: از آنجاکه این تحقیق محدود به یک سال بود، پیشنهاد می‌شود در تحقیقات آینده دوره زمانی طولانی‌تر (حداقل ۲ سال) در نظر گرفته شود تا تعمیم‌پذیری نتایج افزایش یابد. همچنین مطالعات بلندمدت برای بررسی تاثیر بلوغ سرمایه فکری بر شاخص‌های عملکردی مانند ROI، نرخ نوآوری و سهم بازار مفید خواهد بود.
- بومی‌سازی مدل در صنایع مختلف: تنظیم هایپرپارامترها و ایجاد کتابخانه‌های وزنی اختصاصی براساس ویژگی‌های صنایع گوناگون (مانند فناوری اطلاعات، بیوتکنولوژی و نانوتکنولوژی) به‌منظور افزایش دقت پیش‌بینی.

- در نظر گرفتن ابعاد دیگر سرمایه فکری: بررسی تاثیر سایر ابعاد موثر بر سرمایه فکری که در این پژوهش مورد توجه قرار نگرفته‌اند، به عنوان عوامل کلیدی در رشد سرمایه فکری شرکت‌ها.
- کاربرد روش پژوهش در سایر شرکت‌ها: آزمون مدل ارائه شده در این تحقیق بر روی شرکت‌های دیگر برای پیش‌بینی سطح بلوغ سرمایه فکری و ارزیابی میزان تعمیم‌پذیری آن.

منابع

- Abdali, M., Kordy, E., & Velian, H. (2022). Assessing the maturity of intellectual capital based on the themes of dual learning linkage in knowledge-based companies in the oil and gas sector. *Human Resource Management Research Journal*, 14(48), 227–270. DOR: [20.1001.1.82548002.1401.14.2.4.7](https://doi.org/10.1001.1.82548002.1401.14.2.4.7). [In persian]
- Andersen, S., & Hanstad, D. (2017). Knowledge development and transfer in a mindful project-organization. *International Journal of Managing Projects in Business*, 6(2), 236-250. [dx.doi.org/10.1108/17538371311319007](https://doi.org/10.1108/17538371311319007).
- Asiaei, K., Jusoh, R., & Bontis, N. (2018). Intellectual capital and performance measurement systems in Iran. *Journal of Intellectual Capital*, 19(2), 294-320. <https://doi.org/10.1108/JIC-11-2016-0125>.
- Asif, J., Ting, I. W. K., & Kweh, Q. L. (2021). Intellectual Capital Investment and Firm Performance of the Malaysian Energy Sector-A New Perspective from a Nonlinearity Test. *Energy Research Letters*, 1(1), 1-4. <https://doi.org/10.46557/001c.13622>.
- Bani Asadi, M., Roshan, A., Yaghoubi, N., & Ronaghi, M. H. (2022). Designing a comprehensive intellectual capital model using a meta-synthesis approach. *Human Resource Management Research Journal*, 13(4), 221–254. <https://dor.isc.ac/dor/20.1001.1.82548002.1400.13.4.7.7>.
- Baryannis, G., Dani, S. & Antoniou, G. (2019). "Predicting supply chain risks using machine learning: The trade-off between performance and interpretability", *Future Generation Computer Systems*, Vol. 101, pp. 993– 1004. <https://doi.org/10.1016/j.future.2019.07.059>.
- Bassiouni, M.M., Chakraborty, R.K., Sallam, K.M. & Hussain, O.K. (2024), "Deep learning approaches to identify order status in a complex supply chain", *Expert Systems with Applications*, Vol. 250, p. 123947. <https://doi.org/10.1016/j.eswa.2024.123947>.
- Bratianu, C., & Pinzaru, F. (2015). Challenges for the university intellectual capital in the knowledge economy. *Management Dynamics in the Knowledge Economy*, 3(4), 609–627. <https://EconPapers.repec.org/RePEc:nup:jrmldke:v:3:y:2015:i:4:p:609-627>.
- Bratianu, C. (2018), "Intellectual capital research and practice: 7 myths and one golden rule", *Management & Marketing. Challenges for the Knowledge Society*, Vol. 13, No. 2, pp. 859-879. DOI: [10.2478/mmcks-2018-0010](https://doi.org/10.2478/mmcks-2018-0010).
- Bürgel, T. R., Hiebl, M. R., & Pielsticker, D. I. (2023). Digitalization and entrepreneurial firms' resilience to pandemic crises: Evidence from COVID-19 and the German Mittelstand. *Technological Forecasting and Social Change*, 186, 122135. <https://doi.org/10.1016/j.techfore.2022.122135>.
- Chowdhury, L.A.M., Rana, T., Akter, M. and Hoque, M. (2018), "Impact of intellectual capital on financial performance: evidence from the Bangladeshi textile sector", *Journal of Accounting & Organizational Change*, Vol. 14 No. 4, pp. 429-454. <https://doi.org/10.1108/JAOC-11-2017-0109>.
- Chehreh, S., & Sarabadani, A. (2024). A model based on random forest algorithm and Jaya optimization to predict bank customer churn. *Engineering Management and Soft Computing*, 9(2), 132-148. doi: [10.22091/jemsc.2024.9541.1174](https://doi.org/10.22091/jemsc.2024.9541.1174). [In persian]
- Hanifi Niyri, K., Pourjabali, R., & Babaei, M. (2023). Drawing a knowledge-based economy model to achieve knowledge-based development. *Studies of Knowledge Research*, 2(4), 1–22. [doi: 10.22034/jkrs.2024.59246.1042](https://doi.org/10.22034/jkrs.2024.59246.1042). [In persian]
- Gerami, A., Kamsari, H., Rabiei, F., & Salmani, M. (2022). Investigating the nonlinear relationship between intellectual capital and firm performance. *Management and Accounting Outlook*, 5(68), 47–58. https://www.jamv.ir/article_160329.html. [In persian]
- Ghasemi, F., Danesh Fard, K., Najafbeigi, R., & Afshar Kazemi, M. A. (2020). Designing an indigenous model for measuring intellectual capital with a pathological approach in the Ministry of Petroleum. *Scientific-Research Quarterly of Human Resource Management in the Oil Industry*, 11(44), 211–238. <http://iieshrm.ir/article-1-895-fa.html>. [In persian]
- Gong, Y., Liu, G., Xue, Y., Li, R. & Meng, L. (2023), A survey on dataset quality in machine learning, *Information and Software Technology*, Vol. 162, p. 107268, <https://doi.org/10.1016/j.infsof.2023.107268>.
- Gunawan, T., Jacob, J. & Duysters, G. (2015). Entrepreneurial orientation and network ties: innovative performance of SMEs in an emerging-economy manufacturing cluster. Working Paper, No. 2013/28. <https://ideas.repec.org/p/msm/wpaper/2013-28.html>.
- Gyulai, D., Pfeiffer, A., Nick, G., Gallina, V., Sihn, W. & Monostori, L. (2018), Lead time prediction in a flow-shop environment with analytical and machine learning approaches, *IFAC-PapersOnLine*, Vol. 51 No. 11, pp. 1029–1034. <https://doi.org/10.1016/j.ifacol.2018.08.472>

- Hadidane, S., & Zakia, L. (2022). Intellectual Capital: Concepts, Characteristics and Classifications. *afak-revues*, 7(2), 1-10. <https://asjp.cerist.dz/en/article/181678>.
- Kordy, E. (2023). Designing an intellectual capital maturity model (ICMM) for stock market companies to develop sustainable corporate functions. Doctoral dissertation, Faculty of Humanities, Islamic Azad University, Shahrood Branch. DOR: [20.1001.1.82548002.1401.14.2.4.7](https://doi.org/10.1108/JIC-05-2020-0167). [In persian]
- Laghi, E., Di Marcantonio, M., Cillo, V. & Paoloni, N. (2022), The relational side of intellectual capital: an empirical study on brand value evaluation and financial performance, *Journal of Intellectual Capital*, Vol. 23 No. 3, pp. 479-515. <https://doi.org/10.1108/JIC-05-2020-0167>.
- Liu, W. H., & Kweh, Q. L. (2022). Reexamining nonlinear effects of intellectual capital on firm efficiency. *Annals of Operations Research*, 315(2), 1319-1344. DOI: [10.1007/s10479-021-04252-4](https://doi.org/10.1007/s10479-021-04252-4).
- Mirzaei, S. A., & Douaei, M. (2019). Presenting a new model with an artificial intelligence approach to predict stock prices. Sixth National Conference on Applied Research in Computer Engineering and Information Technology, Tehran. <https://civilica.com/doc/101173>. [In persian]
- Molae fard, R. (2023). Developing a recommender system for the health tourism industry using data mining methods. *Engineering Management and Soft Computing*, 8(2), 125-142. https://jemsc.qom.ac.ir/article_1848.html. [In persian]
- Mubarik, M. S., Bontis, N., Mubarik, M., & Mahmood, T. (2022). Intellectual capital and supply chain resilience. *Journal of intellectual capital*, 23(3), 713-738. DOI: [10.1108/JIC-06-2020-0206](https://doi.org/10.1108/JIC-06-2020-0206).
- Nejat, S. A., & Karimi Khuzani, A. (2020). Measuring the maturity level of intellectual capital management research and studies of the Police Force. *Scientific Journal of Resource Management in the Police Force*, 8(2), 155-180. <https://www.noormags.ir/view/fa/articlepage/1692026>. [In persian]
- Nejat, S. A., Bigler, M., & Kashiyan, S. B. (2022). Evaluating the maturity of intellectual capital in the field of management and planning at Tehran University of Medical Sciences. *Payaward Salamat Journal*, 16(1), 71-80. <http://dorl.net/dor/20.1001.1.17358132.1401.16.1.6.3>. [In persian]
- Raenayi Kordshouli, H., Farhangian, B., & Amini, M. (2016). The status of intellectual capital in Iran and regional countries in line with the 2025 vision of the Islamic Republic of Iran. *Iranian Management Sciences Quarterly*, 11(41), 1-28. https://journal.iams.ir/article_224.html. [In persian]
- Rajabpour, I., & Babashahi, J. (2020). Identifying career path anchors of knowledge workers based on the competency model (Case study: Oil Industry Research Institute). *Human Resource Management Research*, 12(4), 9-36. <https://dor.isc.ac/dor/20.1001.1.82548002.1399.12.4.2.5>. [In persian]
- Ramírez, Y., & Gordillo, S. (2013). Recognition of intellectual capital importance in the university sector. *International Journal of Business and Social Research*, 3(4), 27-41. <https://EconPapers.repec.org/RePEc:lrc:larjib:v:3:y:2013:i:4:p:27-41>
- Rezaeian, A., Danaeifard, H., & Zangouejinejad, A. (2011). Designing a conceptual model for measuring knowledge assets - intellectual capital at the national level. *Government Management Outlook*, 2(6), 25-41. <https://manuscript.isc.ac/Inventory/8/601748.htm>. [In persian]
- Rodrigues V. C., Mauricio S. P., & Viviane V. C. (2018). A proposal of intellectual capital maturity model (ICMM) evaluation. *Journal of Intellectual Capital*; 20(2): 208-34. DOI: [10.1108/JIC-12-2016-0130](https://doi.org/10.1108/JIC-12-2016-0130).
- Rossi, F. M., Nicolò, G., & Polcini, P. T. (2018). New trends in intellectual capital reporting. *Journal of Intellectual Capital*, 19(4), 814-835. <https://doi.org/10.1108/JIC-09-2017-0119>.
- Salmani, D., Piran Nejad, A., Farhangi, A. A., & Mandagari, M. A. (2019). Development and explanation of intellectual capital maturity model in Iranian universities. *Management in Islamic University*, 8(2), 247-260. https://miu.nahad.ir/article_723.html. [In persian]
- Samek, W., Montavon, G., Lapuschkin, S., Anders, C. J., & Müller, K. R. (2021). Explaining deep neural networks and beyond: A review of methods and applications. *Proceedings of the IEEE*, 109(3), 247-278. DOI: [10.1109/JPROC.2021.3060483](https://doi.org/10.1109/JPROC.2021.3060483).
- Santoso, E. (2012). Intellectual capital in Indonesia: The influence on financial performance of banking industry. University of Phoenix.
- Sardo, F., Serrasqueiro, Z., & Alves, H. (2018). On the relationship between intellectual capital and financial performance: A panel data analysis on SME hotels. *International Journal of Hospitality Management*, 75, 67-74. <https://doi.org/10.1016/j.ijhm.2018.03.001>.
- Schumacher, A., Erol, S. & Sihn, W. (2016). A maturity model for assessing Industry 4.0 readiness and maturity of manufacturing enterprises. *Procedia Cirp*, 52, 161-166. <https://doi.org/10.1016/j.procir.2016.07.040>.
- Secundo, G., Elena-Perez, S., Martinaitis, Ž., & Leitner, K. H. (2015). An intellectual capital maturity model (ICMM) to improve strategic management in European universities: A dynamic approach. *Journal of intellectual Capital*, Vol. 16, no 2, pp 419 - 442. <https://doi.org/10.1108/JIC-06-2014-0072>.
- Shamsi, M., Karimian, M., & Karimian, M. (2023). Breast Cancer Detection Using Ensemble Classifiers for Accuracy Improvement. *Engineering Management and Soft Computing*, 8(2), 92-109. https://jemsc.qom.ac.ir/article_1596.html. [In persian]
- Todericiu, R., & Stanit, A. (2016). Universities intellectual capital. *Management and Economics*, 4(84), 348-356. https://www.armyacademy.ro/reviste/rev4_2016/TODERICIU.pdf.
- Van Luu, T., & Chromjaková, F. (2024). Knowledge-based circular economics model for sustainable competitiveness: framework development and analysis. *Environment, Development and Sustainability*, 1-20. DOI: [10.1007/s10668-023-04415-2](https://doi.org/10.1007/s10668-023-04415-2).

- Vaz, C. R., Paulo M. S., & Claudia V. V. (2018). A proposal of intellectual capital maturity model (ICMM) evaluation, Journal of Intellectual Capital, Vol. 20, No. 2, pp 208-234. <https://doi.org/10.1108/JIC-12-2016-0130>.
- Wagire, A. A., Joshi, R., Rathore, A. P. S. & Jain, R. (2021). Development of maturity model for assessing the implementation of Industry 4.0: learning from theory and practice. Production Planning & Control, 32(8), 603-622. <https://doi.org/https://doi.org/10.1080/09537287.2020.1744763>.
- Wang, P. (2021). A study on the intellectual capital management over cloud computing using analytic hierarchy process and partial least squares. Kybernetes, ahead-of-print(ahead-of-print). 9-23. doi.org/10.1080/09585192.2018.1511611.
- Yuan, B., Xia, H., & Guo, C. (2021). An evaluation index system for intellectual capital evaluation based on machine learning. Alexandria Engineering Journal, 60(1), 1519-1524. <https://doi.org/10.1016/j.aej.2020.11.006>.