



Predicting the Financial Risk of Public Companies with a Hybrid Algorithm FA-PSO-LSTM

Fatemeh Sadat Mirmoeini¹ | Rahim Ghasemiyeh² | Hasan Ali Sinaie³

1- MS in Financial Management. Faculty of Economics and Social Sciences, Shahid Chamran University of Ahvaz, Ahvaz, Iran

2- Corresponding Author: Associate Professor of Management, Department of Management, Faculty of Economics and Social Sciences, Shahid Chamran University of Ahvaz, Ahvaz, Iran. Email: r.ghasemiyeh@scu.ac.ir

3- Professor, Faculty of Economics and Social Sciences, Department of Management, Shahid Chamran University of Ahvaz, Ahvaz, Iran

Abstract

This research, considering the need for continuous monitoring of financial data and focusing on artificial intelligence algorithms, has carefully evaluated the data of companies active in the three industries of basic metals, automotive, and petroleum products over a ten-year period using an experimental and field study and a new case model. After determining the effective financial factors from factor analysis, the mean square error and predicted values of the LSTM neural network were used to optimize the particle swarm algorithm function and optimize the learning rate and number of hidden layers of the neural networks. The FA-PSO-LSTM deep learning model used is an innovative and relatively new model that can fully benefit from the advantages of the LSTM network in time series processing and lead to the evolution of the theory in this regard. The results indicate that the proposed model predicts financial risk in the petroleum products industry with high accuracy and highlights the importance of variables such as liquidity, cash flow, and profitability. In the automotive industry, indicators such as liquidity, operational capacity, and sustainable development were more effective, while in the basic metals industry, the most data stability was observed and the best model performance was recorded. Overall, the variables of liquidity, profitability, cash flow, operational capacity, and development capability were identified as key common risk factors. It was also found that the proposed model has higher accuracy and efficiency compared to traditional methods and other algorithms.

Keywords: Financial Risk, Deep Learning, Publicly Traded Companies, Optimization

Volume info

Vol. 6
Series: 24
Winter 2026
P.P: 11-30

Article Type

Research Paper

Article History

Received:
2025-01-31
Revised:
2025-09-07
Accepted:
2025-09-07
Published:
2025-12-18

ISSN – E-ISSN

ISSN: 2717-1809
E-ISSN: 2717-199x

Mirmoeini, F. S., Ghasemiyeh, R., & Sinaie, H. A. (2026). Predicting the Financial Risk of Public Companies with a Hybrid Algorithm FA-PSO-LSTM. *Budget and Finance Strategic Research*, 6(4), 11-30

DOR20.1001.1.27171809.1404.6.4.1.1



Publisher: Imam Hossein University.

© The Author(s).



پیش‌بینی ریسک مالی شرکت‌ها بر اساس الگوریتم ترکیبی یادگیری عمیق FA-PSO-LSTM

فاطمه السادات میرمعینی^۱ | رحیم قاسمیه^۲ | حسنعلی سینایی^۳

۱. دانشجوی کارشناسی ارشد مدیریت مالی، دانشکده اقتصاد و علوم اجتماعی، دانشگاه شهید چمران اهواز، اهواز، ایران.
۲. نویسنده مسئول: دانشیار، گروه مدیریت، دانشکده اقتصاد و علوم اجتماعی، دانشگاه شهید چمران اهواز، اهواز، ایران.
R.ghasemiyeh@scu.ac.ir
۳. استاد، گروه مدیریت، دانشکده اقتصاد و علوم اجتماعی، دانشگاه شهید چمران اهواز، اهواز، ایران.

چکیده

این پژوهش با توجه به لزوم نظارت مستمر بر داده‌های مالی و با تمرکز بر الگوریتم‌های هوش مصنوعی طی یک مطالعه تجربی و میدانی و با استفاده از با استفاده از یک مدل جدید مورد، داده‌های شرکت‌های فعال در سه صنعت فلزات اساسی، خودروسازی و فرآورده‌های نفتی را در یک بازه زمانی ده ساله مورد ارزیابی دقیق قرار داده است. پس از تعیین عوامل موثر مالی حاصل از تحلیل عاملی، از خطای میانگین مربعات و مقادیر پیش‌بینی شده شبکه عصبی LSTM جهت بهینه‌سازی تابع الگوریتم ازدحام ذرات و بهینه‌سازی نرخ یادگیری و تعداد لایه‌های پنهان شبکه‌های عصبی استفاده گردید. مدل یادگیری عمیق FA-PSO-LSTM مورد استفاده یک مدل ابتکاری و نسبتاً جدید است که از مزایای شبکه LSTM در پردازش سری‌های زمانی به طور کامل می‌تواند بهره‌مند شده و به تکامل نظریه پردازشی در این خصوص منتهی شود. نتایج حاکی از آن است که مدل پیشنهادی در صنعت فرآورده‌های نفتی با دقت بالا ریسک مالی را پیش‌بینی نموده و اهمیت متغیرهایی چون نقدینگی، جریان نقدی و سودآوری را برجسته ساخته است. در صنعت خودروسازی، شاخص‌هایی مانند نقدینگی، ظرفیت عملیاتی و توسعه پایدار اثرگذارتر بودند، در حالی که در صنعت فلزات اساسی بیشترین ثبات داده‌ها مشاهده و بهترین عملکرد مدل ثبت شد. در مجموع، متغیرهای نقدینگی، سودآوری، جریان نقدی، ظرفیت عملیاتی و قابلیت توسعه به‌عنوان عوامل کلیدی مشترک ریسک‌شناسایی گردیدند همچنین مشخص شد که مدل پیشنهادی در مقایسه با روش‌های سنتی و سایر الگوریتم‌ها، دقت و کارایی بالاتری دارد.

کلیدواژه‌ها: ریسک مالی؛ یادگیری عمیق؛ شرکت‌های سهامی عام؛ بهینه‌سازی

استناد: میرمعینی، فاطمه السادات، قاسمیه، رحیم، & سینایی، حسنعلی. (۱۴۰۴). پیش‌بینی ریسک مالی شرکت‌ها بر اساس الگوریتم ترکیبی یادگیری عمیق FA-PSO-LSTM. پژوهش‌های راهبردی بودجه و مالیه، ۶(۴)، ۱۱-۳۰.

DOR 20.1001.1.27171809.1404.6.4.1.1

سال و شماره

سال ۶، پیاپی: ۲۴
زمستان ۱۴۰۴
صص: ۳۰-۱۱

نوع مقاله

مقاله پژوهشی

سابقه مقاله

تاریخ دریافت: ۱۴۰۳/۱۱/۱۲
تاریخ بازنگری: ۱۴۰۴/۰۶/۱۶
تاریخ پذیرش: ۱۴۰۴/۰۶/۱۶
تاریخ انتشار: ۱۴۰۴/۰۹/۲۷

شاپا چاپی و الکترونیکی

شاپا چاپی: ۱۸۰۹-۲۷۱۷
الکترونیکی: ۱۹۹۶-۲۷۱۷



نویسندگان.

ناشر: دانشگاه جامع امام

حسین (ع).



OPEN ACCESS

مقدمه و بیان مسئله

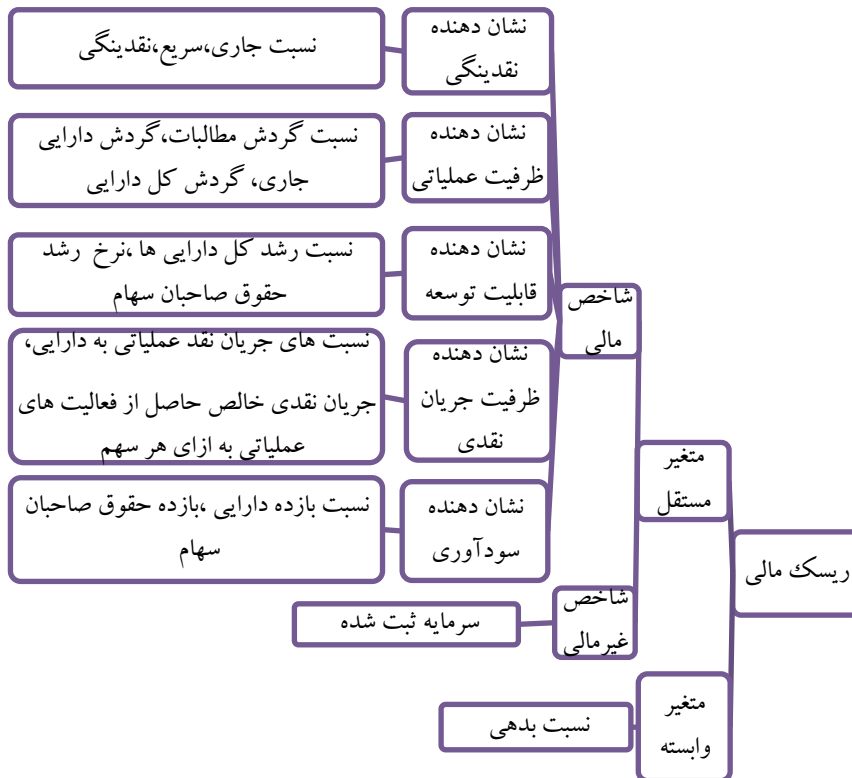
نوسانات تاریخی در بازار مالی؛ مانند تغییر رژیم نرخ ارز ثابت به رژیم منعطف، سقوط بازار در مواجهه با عدم قطعیت‌های متعدد در بازار سهام، ایجاد یک سیستم پیش‌بینی ریسک مالی و همچنین تجزیه و تحلیل علمی و پیش‌بینی جهت یک شاخص مالی خاص در آینده برای حفظ و رشد سازمان به یک ضرورت تبدیل شده است (چن، ۲۰۲۵). محققان زیادی به دشوار بودن تحلیل داده‌های مالی به دلیل حجم زیاد و ناهمگن این داده‌ها اذعان کرده‌اند (وانگ، ۲۰۲۵) به همین دلیل در سالیان اخیر با توسعه کلان‌داده‌ها و یادگیری ماشین، شبکه‌های عصبی مصنوعی (ANN) به دلیل توانایی بالای آنها در مقابله با مسائل نگاشت غیرخطی به طور گسترده مورد توجه قرار گرفته است (چن و لانگ، ۲۰۲۳). با وجود توانایی الگوریتم‌های یادگیری ماشین در حفظ رابطه ذاتی بین سری‌های زمانی و شاخص‌های مالی و پیش‌بینی نسبتاً به موقع مشکلات (خالد و همکاران، ۲۰۲۲) با این حال، تاکنون، هیچ مدل قابل تعمیمی وجود ندارد که بتواند بحران‌های مالی شرکت‌ها را به طور مؤثر پیش‌بینی کند (کین و چن، ۲۰۲۲). ارزیابی ریسک مالی یک شرکت برای توسعه بلندمدت شرکت حائز اهمیت است. اگر بتوان یک پیش‌بینی معقول و ارزیابی ریسک بر اساس توسعه مالی شرکت انجام داد، برای عملیات مالی و بلندمدت شرکت بسیار سودمند خواهد بود (Qin, 2022). محافظت کامل در مقابل ریسک ممکن نیست؛ اما پوشش ریسک به ما این امکان را می‌دهد که از ضررهای ناخواسته جلوگیری شود (Alieva et al, 2020). تکنیک‌های هوش مصنوعی می‌تواند ریسک را با دقت بیشتری نسبت به گذشته پیش‌بینی کند (Khalid et al, 2022). جامعه آماری این پژوهش شامل تعدادی از شرکت‌های فعال در بورس بهادر تهران و فرابورس با تمرکز بر سه صنعت فرآورده‌های نفتی، خودروسازی و فلزات اساسی در بازه زمانی ۱۰ساله ۱۳۹۲_۱۴۰۲ می‌باشد و نمونه‌گیری پژوهش تصادفی و قضاوتی است. در فرآیند انتخاب صنایع سه‌گانه، شرکت‌هایی که دارای ارزش بازار پایین‌تری هستند، به دلیل ایجاد نویز در داده‌ها، کاهش دقت تحلیل و عدم تأثیرگذاری قابل توجه بر صنعت، از نمونه مورد مطالعه حذف گردیدند. در پژوهش حاضر، نسبت بدهی که به عنوان شاخص ارزیابی ریسک مالی لحاظ شده است، متغیر وابسته و همچنین شاخص مالی که شامل ۱۲ نسبت مالی

وسرمایه ثبت شده (شاخص غیر مالی پژوهش) به عنوان متغیرهای مستقل در نظر گرفته شده است. مطالعات موجود در حوزه توسعه یادگیری ماشینی به یادگیری عمیق در خصوص پیش بینی ریسک مالی شرکت‌ها مغفول مانده است به همین دلیل این پژوهش با تمرکز بر ویژگی‌های شبکه‌های عصبی با حافظه بلندمدت (LSTM) و شبکه‌های عصبی بازگشتی (RNN) بر آن است این نقیصه را تا حدی بر طرف نماید. این شیوه می‌تواند در تجزیه و تحلیل داده‌های مالی سری زمانی دیدگاه روشن‌تر و موثرتری ایجاد نماید.

مبانی نظری پژوهش

ریسک مالی به عنوان یکی از پیچیده‌ترین ریسک‌ها، با نتایج مالی فعالیت‌های اقتصادی و تهدیدات زیان مالی ساختارهای تجاری مرتبط است این موضوع به ویژه برای شرکت‌های داخلی مهم است، زیرا در شرایط مدرن ریسک‌های مالی ماهیت پیچیده‌ای دارند ریسک مالی در جریان فعالیت‌های مالی یا معاملات مالی به وجود می‌آید که با توجه به منابع وقوع آنها می‌توان به دو گروه اصلی تقسیم کرد: الف) ریسک غیرسیستماتیک (ب) ریسک سیستماتیک که ریسک مالی سیستماتیک به دلایلی چون پیچیدگی بازارهای مالی، عدم قطعیت جهانی، رفتار غیرعقلایی سرمایه‌گذاران و نوسانات مداوم بازار، قابل پیش‌بینی نیست. این ویژگی باعث می‌شود که مدیریت و کنترل این نوع ریسک دشوار باشد. در مقابل، ریسک‌های غیرسیستماتیک معمولاً مشخص‌تر و قابل‌شناسایی هستند. این ریسک‌ها عمدتاً مربوط به عوامل داخلی شرکت‌ها و صنایع خاص هستند که امکان شناسایی و مدیریت آنها بیشتر است (Arefieva et al., 2019). بنابراین، در این پژوهش تمرکز بر ریسک‌های غیرسیستماتیک است تا از مزایای قابلیت پیش‌بینی و مدیریت پذیری این نوع ریسک‌ها بهره‌برده شود. مطالعات گسترده‌ای در ارتباط با تأثیر ریسک‌های مالی بر نسبت‌های مالی و در واقع عملکرد و کارایی مؤسسات مالی، در کشورهای مختلف صورت گرفته است که وجود رابطه معناداری بین این دو، مورد اثبات قرار گرفته است و این موضوع دلالت بر اهمیت و حساسیت ریسک‌های مالی در مؤسسات مالی دارد که می‌تواند منجر به سودآوری و یا ورشکستگی شرکت‌ها شود (Ostadi & Tadrissi Pajouh, 2019). نسبت‌های مالی ابزارهای مهمی برای پیش‌بینی بحران‌های مالی و ارزیابی وضعیت شرکت‌ها هستند. دلایل اصلی استفاده از

این نسبت‌ها عبارتند از: کنترل تأثیر اندازه شرکت‌ها در طول زمان، بهبود برآورد مفروضات آماری مانند تحلیل رگرسیون، ارتباط بین نسبت‌های مالی و پیش‌بینی متغیرهای کلیدی مانند ریسک ورشکستگی، و بررسی دقیق تئوری‌هایی که بر اساس نسبت‌های مالی شکل گرفته‌اند



شکل (۱)

شیوه محاسبه متغیرهای پژوهش به شرح زیر است:

۱- نسبت بدهی^۱ در رابطه (۱) DEA بیانگر نسبت بدهی، TL بیانگر مجموع بدهی و TA بیانگر کل دارایی می‌باشد.

$$DEA = \frac{TL}{TA} \quad (1)$$

۲- نسبت جاری^۱ در رابطه (۲) CR نشان‌دهنده‌ی نسبت جاری، CA بیانگر دارایی‌های جاری و CL بیانگر بدهی‌های جاری می‌باشد.

$$CR = \frac{CA}{CL} \quad (۲)$$

۳- نسبت سریع^۲ در رابطه (۳) QR بیانگر نسبت سریع و I بیانگر موجودی کالا می‌باشد.

$$QR = \frac{CA - I}{CL} \quad (۳)$$

۴- نسبت وجه نقد^۳ در رابطه (۴) Cash R بیانگر وجه نقد، Cash بیانگر موجودی نقدی و SHT بیانگر سرمایه‌گذاری کوتاه مدت می‌باشد.

$$Cash R = \frac{Cash + SHT}{CL} \quad (۴)$$

۵- نسبت گردش مطالبات^۴ در رابطه (۵) AATR بیانگر نسبت گردش مطالبات، NCS بیانگر خالص فروش نسیه و AAR بیانگر میانگین حساب‌های دریافتی می‌باشد.

$$AATR = \frac{NCS}{AAR} \quad (۵)$$

۶- نسبت گردش دارایی جاری^۵ در رابطه (۶) CAT بیانگر نسبت گردش دارایی جاری و NA بیانگر فروش خالص می‌باشد.

$$CAT = \frac{NA}{CA} \quad (۶)$$

۷- نسبت گردش دارایی کل^۶ در رابطه (۷) TAT بیانگر نسبت گردش دارایی کل می‌باشد.

$$TAT = \frac{NA}{TA} \quad (۷)$$

۸- بازده دارایی^۷ در رابطه (۸) ROA بیانگر بازده دارایی، NP بیانگر سود خالص و AA بیانگر متوسط دارایی می‌باشد.

$$ROA = \frac{NP}{AA} \quad (۸)$$

۹- نرخ بازده حقوق صاحبان سهام^۸ در رابطه (۹) ROE بیانگر نرخ بازده حقوق صاحبان سهام و SE بیانگر حقوق صاحبان سهام می‌باشد.

-
1. Current Ratio
 2. Quick Ratio
 3. Cash Ratio
 4. Accounts Receivable Turnover Ratio
 5. Current Asset Turnover
 6. Total Asset Turnover Ratio
 7. Return on Assets
 8. Return on Equity

$$ROE = \frac{NP}{SE} \quad (9)$$

۱۰- جریان نقد عملیاتی به دارایی^۱ در رابطه‌ی (۱۰) OCFT بیانگر جریان نقد عملیاتی به دارایی و OCF بیانگر جریان نقد عملیاتی می‌باشد.

$$OCFT = \frac{OCF}{TA} \quad (10)$$

۱۱- نسبت رشد کل دارایی^۲ در رابطه‌ی (۱۱) OC بیانگر نسبت رشد کل دارایی، ETA بیانگر کل دارایی‌های پایانی BTA و بیانگر کل دارایی‌های ابتدایی می‌باشد.

$$OC = \frac{ETA - BTA}{BTA} \quad (11)$$

۱۲- نرخ رشد حقوق صاحبان سهام^۳. در رابطه‌ی (۱۲) GR بیانگر نرخ رشد حقوق صاحبان سهام، EP بیانگر سرمایه صاحبان در انتهای ماه و BP بیانگر سرمایه صاحبان در ابتدای ماه می‌باشد.

$$GR = \frac{EP - BP}{BP} \quad (12)$$

۱۳- جریان نقدی خالص حاصل از فعالیت‌های عملیاتی به ازای هر سهم^۴ در رابطه‌ی (۱۳) NCFO بیانگر جریان نقدی خالص حاصل از فعالیت‌های عملیاتی به ازای هر سهم، NCF بیانگر جریان نقدی خالص حاصل از فعالیت‌های عملیاتی و NS بیانگر تعداد سهام عادی در جریان می‌باشد.

$$NCFO = \frac{NCF}{NS} \quad (13)$$

۱۴- سرمایه ثبت شده^۵: سرمایه‌ای است که صاحبان یا سهامداران شرکت در آن سرمایه‌گذاری کرده‌اند که به عنوان شاخص غیر مالی تحقیق در نظر گرفته شده است.

پیشینه پژوهش

تحقیقات نظری در مورد ریسک مالی از دهه ۱۹۳۰ آغاز شد و پس از چند دهه با پژوهش‌های نوآورانه محققان توسعه و بالغ‌تر گردید. پژوهشگران در سال‌های اخیر بر پیش‌بینی ریسک مالی و دستیابی سریع به اطلاعات ارزشمند از حجم زیادی از داده‌های مالی متمرکز شده‌اند (چن و لانگ، ۲۰۲۳). در آغاز محققان دریافتند که نسبت حقوق صاحبان سهام و نسبت‌های بدهی به سایر شاخص‌های مالی قدرت تمایز بیشتری دارد (آلیوآ و همکاران، ۲۰۲۰) بعد از آن محققان

1. Operating Cash Flow to Total Assets
2. operation cash in to Asset
3. grow rate of owner's equity
4. Net cash flow from operating activities per share
5. Registered capital

روش‌های تشخیص چند متغیره را پیشنهاد دادند (سان و همکاران، ۲۰۲۲). با توسعه سیستم‌های رایانه‌ای الگوریتم‌های یادگیری ماشین همزمان با سایر حوزه‌های علوم مورد توجه پژوهشگران مالی با هدف خودکار سازی تحلیل داده‌های مالی قرار گرفت (توکلی و آشتاب، ۲۰۲۳). این توجه به توسعه مدل‌های ماشین بردار پشتیبان (SVM)، الگوریتم ژنتیک و مشابه اینها انجامید. با این حال، مدل‌های یادگیری ماشینی برای پیش‌بینی داده‌های مالی که ماهیت سری زمانی دارند، به‌ویژه برای پیش‌بینی بلندمدت نمونه‌های داده پیچیده، کاملاً بی‌فایده هستند (خالد و همکاران، ۲۰۲۲). محققان با درک ناکارآمدی روش‌های یادگیری ماشینی به توسعه مدل‌های پرداختند که بعدها با عنوان "یادگیری عمیق" از آنها یاد می‌شود. در حال حاضر، مدل‌های رایج‌تر در زمینه یادگیری عمیق عبارتند از شبکه‌های عصبی کانولوشن (CNN)، شبکه‌های عصبی بازگشتی (RNN)، شبکه‌های عصبی با حافظه کوتاه‌مدت بلندمدت (LSTM)، شبکه‌های عصبی تخصصی (GAN) و شبکه‌های عصبی گراف (GNN). در ادامه به برخی پژوهش‌های پیشین به صورت اجمالی پرداخته شده است.

مصلی و مقدم^۱ (۲۰۲۰) دریافتند که رابطه معناداری بین اهرم مالی و ریسک مالی وجود دارد. توکلی و آشتاب (۲۰۲۱) در پژوهش خود نشان دادند دقت مدل‌های یادگیری ماشین در پیش‌بینی ریسک مالی از مدل‌های آماری بیشتر است و بهترین مدل یادگیری ماشین پس از بهینه‌سازی مدل ماشین بردار پشتیبان تکاملی است. همچنین ریسک مالی پیش‌بینی شده بر اساس صنایع مختلف متفاوت بوده است مدل‌های یادگیری ماشین نسبت به مدل‌های آماری از محدودیت‌هایی کمتری برخوردار هستند (قاسمیه و همکاران، ۱۴۰۳) و می‌توانند به‌عنوان ابزاری مهم در پیش‌بینی ریسک مالی شرکت‌ها به کار روند. توکلی و آشتاب^۲ (۲۰۲۳) در پژوهش خود که به شناسایی عوامل موثر بر ریسک مالی پرداخته بودند نتیجه‌گیری کردند که نسبت‌های مالی از اهمیت بالایی در تبیین ریسک مالی برخوردارند. میرزایی‌نژاد و همکاران (۲۰۲۱) با تحلیل دینامیکی عملکرد بازارهای مالی ایران دریافتند که شناسایی ریسک‌های بحرانی و تعاملات آن‌ها می‌تواند به بهبود عملکرد بازارهای مالی کمک کند. همچنین، سلمانیان و همکاران (۲۰۲۱) نشان دادند که مدل‌های پیش‌بینی می‌توانند شرکت‌هایی که با محدودیت‌های مالی مواجه هستند را به‌طور مؤثر شناسایی

1. Mosala & Moghaddam

2. Tavakoli & Ashtab

کنند. در ادامه، محمدی (2022) گزارش کرد که رفتار ریسک‌پذیری و بحران مالی تأثیر قابل توجهی بر کیفیت سود شرکت‌ها دارند. یانگ و همکارانش¹ (2022) یک مدل کنترل ریسک مالی بر اساس NN های یادگیری عمیق ارائه دادند که ریسک مالی را کاهش می‌دهد. مشخصات آزمایش نهایی نشان می‌دهد که LSTM در مقایسه با روش های سنتی دقت بهتری دارد. بر اساس پژوهش ژانگ و همکارانش در سال ۲۰۲۰ ریشه اصلی بروز ریسک مالی در شرکت‌ها را می‌توان در ارتباطات مستقیم یا غیرمستقیم اقتصادی موجود بین اجزای مختلف سیستم مالی آن‌ها دانست. سان و همکارانش² (2022) با اذعان بر این واقعیت که ریسک مالی در همه شرکت‌ها وجود دارد و ارزیابی اولیه ریسک برای شرکت‌های پذیرفته شده در بورس می‌تواند از زیان قابل توجه جلوگیری کند اعلام کردند که روش‌های سنتی عمدتاً بر صورت‌های مالی شرکت‌ها تمرکز می‌کنند و فاقد روابط پیچیده بین آنها هستند (قاسمیه و هکاران، ۲۰۲۳). مقدم نیا و حسینی (2025) در جهت تحلیل عملکرد سازمان شرکت ملی نفت ایران، دریافتند تمام متغیرهای اقدامات مدیریت مالی تأثیر بسزایی بر عملکرد سازمان و افزایش منابع مالی سازمان دارد. مارتین در سال ۱۹۹۷ برای اولین بار مدل لجستیک را برای هشدار زودهنگام ریسک مالی به کار برد. در همین راستا واپنیک مدل SVM را پیشنهاد کرد که دقت پیش‌بینی داده‌های مالی را با متغیرهای بیشتر افزایش می‌دهد. در پژوهشی مشابه مین و همکارانش مدل SVM را با دیگر مدل‌های هشدار اولیه ریسک مالی سنتی تجزیه و تحلیل و مقایسه کرده و نشان دادند که دقت پیش‌بینی SVM بهتر از مدل‌های دیگر است (چن و لانگ، 2023). بر اساس یافته‌های ظهیر و همکارانش (2023) ریسک عملیاتی نیز بر سلامت مالی تأثیر منفی و معنا دارد؛ از این رو می‌توان این نوع ریسک را عاملی موثر در شکل‌گیری و افزایش ریسک مالی دانست. کیاو و دو اولین کسانی بودند که مدل‌های شبکه عصبی را در زمینه پیش‌بینی مشکلات مالی معرفی (Zhai, 2021). چن (2025) (یک رویکرد جدید مبتنی بر یادگیری عمیق برای هشدار اولیه ریسک مالی در شرکت‌های پذیرفته شده ارائه داد که از شبکه توجه سلسله‌مراتبی استفاده می‌کند. وانگ و همکارانش (2025) با استفاده از مدل‌های یادگیری ماشین، پیش‌بینی ورشکستگی مالی را در شرکت‌های چینی انجام دادند و نشان دادند که

1. Yang et al

2. Sun et al

این مدل‌ها می‌توانند به‌طور مؤثری ورشکستگی را پیش‌بینی کنند. سیامی و همکاران^۱ (2018) دریافتند که مدل الگوریتم یادگیری عمیق (LSTM) از مدل الگوریتم یادگیری ماشین سنتی (ARIMA) بهتر عمل کرده است. پژوهش حاضر با توجه به فقدان مطالعه‌ای در خصوص پیش‌بینی ریسک مالی با استفاده از الگوریتم ترکیبی یادگیری عمیق، از ایده ترکیب تحلیل عاملی برای کاهش ویژگی و الگوریتم PSO برای بهینه‌سازی پارامترهای LSTM و پیش‌بینی با الگوریتم یادگیری عمیق استفاده نموده است و درصدد آن است که کارایی و دقت الگوریتم FA_PSO_LSTM در پیش‌بینی ریسک مالی شرکت‌های بورس اوراق بهادار تهران و فرابورس بررسی نماید.

روش‌شناسی پژوهش

در این پژوهش، ابتدا فهرستی از متغیرهای مرتبط از پژوهش‌های پیشین تهیه گردید. فرآیند پیش‌پردازش داده‌ها بلافاصله پس از جمع‌آوری اطلاعات مالی شرکت‌ها آغاز شد. ابتدا مقادیر گم‌شده با استفاده از روش میانگین جایگزین شدند، سپس کلیه داده‌های ورودی با روش Min-Max نرمال‌سازی گردیدند. داده‌ها به دو بخش داده‌های آموزشی (سال‌های ۱۳۹۲ تا ۱۴۰۱) برای ساخت مدل و داده‌های آزمایشی (سال ۱۴۰۲) برای ارزیابی عملکرد مدل، به نسبت ۷۰ به ۳۰ تقسیم شده‌اند. ابتدا برای کاهش ابعاد داده‌ها از تحلیل عاملی استفاده شد که صحت آن با دو شاخص کلیدی یعنی آزمون بارتلت برای بررسی کرویت داده‌ها و شاخص KMO برای سنجش کفایت نمونه‌گیری تأیید گردید. کفایت بار عاملی بیشتر از ۰٫۶ قابل قبول می‌باشد. در مرحله بعد، بهینه‌سازی پارامترهای شبکه عصبی LSTM با استفاده از الگوریتم ازدحام ذرت (PSO) انجام پذیرفت. این فرآیند بهینه‌سازی شامل چهار مرحله اساسی بود: ابتدا جمعیت اولیه ذرات با پارامترهایی شامل تعداد بسته‌های آموزشی (بین ۱۰ تا ۶۴)، نرخ یادگیری (بین ۰٫۰۰۱ تا ۱)، تعداد واحدهای حافظه (بین ۵ تا ۱۵) و تعداد تکرارها (بین ۱۰ تا ۱۰۰) مقداردهی شدند. سپس با تعریف تابع برازندگی مناسب، موقعیت ذرات به صورت پویا به روزرسانی شد تا همزمان معیارهای کاهش زمان اجرا و حداقل‌سازی خطای مدل محقق گردد. این فرآیند تکراری نهایتاً پس از ۳۰ تکرار به نتیجه رسید و منجر به توسعه مدل ترکیبی FA_PSO_LSTM با قابلیت پیش‌بینی دقیق ریسک

1. Siami et al

مالی گردید. این پروژه در Google Colab با پایتون اجرا شده و از کتابخانه های pandas و numpy برای پردازش داده، matplotlib برای مصورسازی، و scikit-learn برای مدل‌سازی کلاسیک و ارزیابی استفاده شده است. برای مدل‌های یادگیری عمیق مانند LSTM از TensorFlow/Keras و برای تحلیل عاملی از factor_analyzer بهره گرفته شده است. جهت اطلاع بیشتر از الگوریتم های مورد استفاده و نحوه محاسبه آنها به کای (۲۰۲۵) و چن و لانگ (۲۰۲۳) مراجعه شود.

سؤالات پژوهش

کارایی و دقت الگوریتم FA_PSO_LSTM در پیش‌بینی ریسک مالی شرکت های بورس اوراق بهادار تهران و فرابورس چگونه است؟

یافته‌های پژوهش

صنعت فرآورده‌های نفتی: در مورد شرکت‌های فعال در این صنعت، مقدار شاخص KMO برابر با ۰/۶۲۱ و نتایج آزمون کرویت بارتلت با $X^2(۱۳۹۱/۸۲۳)$ ، درجه آزادی (۹۱) df و سطح معناداری Sig(۰/۰۰۰) نشان داد که داده‌ها برای تحلیل عاملی مناسب هستند. در ادامه، از روش تحلیل مؤلفه‌های اصلی^۱ برای استخراج عوامل استفاده شد. در این تحلیل، مؤلفه‌هایی که مقدار ویژه بزرگ‌تر از ۱ داشتند، به عنوان عوامل معنادار انتخاب شدند. در مجموع، ۵ مؤلفه استخراج شدند که در مجموع ۷۲/۶۶۵ درصد از واریانس کل داده‌ها را توضیح می‌دهند. این مقدار نشان‌دهنده‌ی قدرت توضیح‌دهندگی بالای عوامل استخراج شده است. بارهای عاملی در این تحلیل، پنج عامل استخراج شده‌اند که فاکتور اول بیانگر نقدینگی صنعت، فاکتور دوم نشان‌دهنده عملکرد عملیاتی و فاکتور سوم به جریان‌های نقدی عملیاتی و خالص صنعت مربوط می‌شود. فاکتور چهارم به رشد و قابلیت توسعه صنعت اشاره دارد. فاکتور پنجم به سودآوری صنعت مرتبط است.

1. Principal Component Analysis
2. Eigenvalue
3. loading

جدول ۱. تحلیل عاملی صنعت فراورده های نفتی

	۱	۲	۳	۴	۵
سرمایه ثبت شده	-۰/۰۴۴	۰/۰۶۷	-۰/۰۱۰	۰/۰۳۷	۰/۰۳۴
وجه نقد عملیات به دارایی	۰/۲۶۸	۰/۰۴۶	۰/۴۳۷	۰/۶۸۲	-۰/۲۱۹
نرخ رشد حقوق صاحبان سهام	۰/۱۹۶	۰/۰۳۳	۰/۴۳۹	۰/۷۱۲	-۰/۲۱۶
جریان نقد عملیاتی به کل دارایی ها	۰/۳۳۶	۰/۲۹۸	۰/۷۲۶	۰/۴۲۴	۰/۰۹۶
جریان نقد خالص حاصل از فعالیت های عملیاتی به ازای هر سهم	-۰/۰۱۱	۰/۲۲۴	۰/۸۲۳	۰/۴۰۷	۰/۱۷۲
بازده دارایی	۰/۵۷۴	۰/۰۱۶	۰/۲۵۱	۰/۰۲۹	۰/۶۹۸
بازده حقوق صاحبان سهام	۰/۵۶۳	۰/۰۳۱	۰/۲۳۰	۰/۰۱۰	۰/۶۴۱
نسبت گردش حساب های دریافتی	-۰/۲۰۰	۰/۷۷۶	۰/۳۰۵	-۰/۰۸۶	۰/۰۸۰
گردش دارایی های جاری	-۰/۲۴۵	۰/۸۴۹	۰/۱۵۱	-۰/۰۶۲	۰/۱۱۵
نسبت گردش کل دارایی ها	-۰/۲۹۶	۰/۸۲۰	۰/۰۵۸	-۰/۰۴۲	۰/۰۲۱
نسبت جاری	۰/۷۵۷	۰/۲۲۶	۰/۰۲۰	-۰/۱۷۲	-۰/۲۸۵
نسبت سریع	۰/۶۷۸	-۰/۰۳۷	۰/۱۰۶	-۰/۲۷۳	-۰/۲۱۳
نسبت وجه نقد	۰/۷۶۶	۰/۲۷۰	-۰/۱۰۷	-۰/۲۴۸	-۰/۱۶۴

الگوریتم پیشنهادی در صنعت فراورده های نفتی با دقت ۹۸٪ و خطای میانگین ۵٪ بهترین عملکرد را دارد و توانسته است تغییرات داده‌ها را به خوبی مدل‌سازی کند. خطای بیشینه آن تنها ۹٪ است، که نشان‌دهنده پایداری بالا در پیش‌بینی‌هاست.


جدول ۲. مقایسه نتایج روش های مختلف در صنعت فراورده نفتی

معیارهای ارزیابی		MAE	MSE	RMSE	R2	Adjusted R2	Max Error
روش های یادگیری عمیق	الگوریتم پیشنهادی FA_PSO_LSTM	۰/۰۵	۰/۰۰۳	۰/۰۶۳	۰/۹۸	۰/۹۳	۰/۰۹
	FA_PSO_RNN	۰/۱۳	۰/۰۲	۰/۱۴	۰/۹۱	۰/۶۶	۰/۲۴
	FA_PSO_GRU	۰/۰۷	۰/۰۰۷	۰/۰۸	۰/۹۶	۰/۸۷	۰/۱۴

جدول ۲. مقایسه نتایج روش‌های مختلف در صنعت فراورده نفتی

الگوریتم تکاملی	FA-DE-LSTM	۰/۰۶	۰/۰۰۷	۰/۰۸	۰/۹۶	۰/۸۷	۰/۱۷
	FA-GA-LSTM	۰/۰۸	۰/۰۱	۰/۱	۰/۹۵	۰/۶۶	۰/۲۰
روش‌های یادگیری ماشین	رگرسیون خطی	۰/۳۰	۰/۲۳	۰/۴۸	۰/۰۲۷	۰/۰۳	۱/۴
	درخت تصمیم	۰/۴۲	۰/۲۸	۰/۵۳	۰/۱۷	۰/۱۵	۱/۹۹
	بیزین	۰/۳۱	۰/۲۴	۰/۴۹	۰/۳۸	۰/۳۹	۱/۷۰
	SVR	۰/۳۱	۰/۲۴	۰/۴۹	۰/۳۵	۰/۲۶	۰/۰۹

روش پیشنهادی در صنعت فراورده نفتی برای سال ۱۴۰۲ مشابهت رفتاری بیشتری نسبت به دیگر روش‌های یادگیری عمیق داشته است.



شکل ۲. نتایج پیش‌بینی با روش‌های یادگیری عمیق صنعت فراورده‌های نفتی در سال ۱۴۰۲

در این مطالعه، عملکرد روش‌های ترکیبی برای پیش‌بینی در صنعت فرآورده‌های نفتی مورد بررسی قرار گرفته است. روش FA-GA-LSTM با ۴۵ بسته آموزشی، نرخ آموزش ۰/۰۳۵، ۱۱ واحد حافظه و ۸۵ تکرار، بیشترین تعداد پارامترها را در میان روش‌های مورد بررسی دارد. روش FA-DE-LSTM با ۲۸ بسته آموزشی، نرخ آموزش ۰/۰۲۱، ۷ واحد حافظه و ۶۸ تکرار، در جایگاه دوم قرار می‌گیرد. در نهایت، روش FA-PSO-LSTM با ۳۲ بسته آموزشی، نرخ آموزش ۰/۰۱۵، ۵ واحد حافظه و ۴۵ تکرار، کمترین تعداد پارامترها را به خود اختصاص داده است. تحلیل ANOVA و آزمون Tukey HSD بر اساس MAE نشان داد که تفاوت عملکرد ۹ مدل پیش‌بینی در صنعت فرآورده‌های نفتی معنادار است. $(F(8,261)=115.36, p<0.001)$. مدل FA_PSO_LSTM با $MAE=0.05$ به طور قابل توجهی برتر از سایر مدل‌ها بود.

صنعت خودروسازی: مقدار KMO برابر با ۰/۶۱۸ همچنین، آزمون بارنلت برابر با ۱۰۰۸/۵۴۱ و سطح معناداری برابر با ۰/۰۰۰ است که نشان می‌دهد بین متغیرها همبستگی معناداری وجود دارد و تحلیل عاملی قابل اجرا است. در ادامه، ۵ عامل استخراج شده‌اند که در مجموع ۷۰/۰۴۹ درصد از واریانس کل داده‌ها را توضیح می‌دهند. در این تحلیل، ۵ عامل اول دارای مقدار ویژه بیشتر از ۱ هستند و به همین دلیل انتخاب شده‌اند. تحلیل عاملی به روش مؤلفه‌های اصلی به دست آمده که فاکتور اول نقدینگی، فاکتور دوم قابلیت توسعه، فاکتور سوم ظرفیت عملیاتی، فاکتور چهارم سودآوری و فاکتور پنجم ظرفیت جریان نقدی شرکت را نشان می‌دهد.

جدول ۳. تحلیل عاملی صنعت خودرو سازی


	۱	۲	۳	۴	۵
سرمایه ثبت شده	-۰/۵۴۵	۰/۵۲۱	-۰/۰۷۴	-۰/۰۰۸	-۰/۰۶۰
نسبت وجه نقد عملیاتی به دارایی	-۰/۳۸۷	۰/۸۰۶	۰/۲۷۵	۰/۱۴۲	۰/۱۴۲
نرخ رشد حقوق صاحبان سهام	-۰/۳۹۱	۰/۸۰۹	۰/۲۶۵	۰/۱۳۰	۰/۱۵۴
جریان نقد عملیاتی به کل دارایی‌ها	۰/۰۷۵	۰/۰۰۴	-۰/۲۱۴	-۰/۳۰۴	۰/۷۳۷
جریان نقد خالص حاصل از فعالیت‌های عملیاتی به ازای هر سهم	۰/۱۴۷	۰/۰۲۱	-۰/۱۳۸	-۰/۲۸۱	۰/۷۴۳
بازده دارایی S	۰/۰۲۵	-۰/۰۹۱	-۰/۳۱۸	۰/۷۹۰	۰/۲۰۶
بازده حقوق صاحبان سهام	۰/۱۰۷	-۰/۰۹۰	-۰/۲۷۴	۰/۷۹۵	۰/۲۴۷
نسبت گردش حساب‌های دریافتی	-۰/۱۹۱	-۰/۳۶۶	۰/۶۲۵	۰/۰۲۱	۰/۱۸۵
گردش دارایی‌های جاری	-۰/۰۷۴	-۰/۲۱۶	۰/۶۳۳	۰/۱۹۱	۰/۱۱۰
نسبت گردش کل دارایی‌ها	-۰/۱۰۷	-۰/۳۳۸	۰/۷۴۸	۰/۱۷۲	۰/۱۹۴
نسبت جاری	۰/۶۹۹	۰/۲۱۹	۰/۲۹۲	۰/۰۵۳	-۰/۰۷۵
نسبت آنی	۰/۷۸۷	۰/۳۸۹	۰/۰۷۹	۰/۰۲۲	-۰/۰۲۷
نسبت وجه نقد	۰/۷۳۱	۰/۲۸۷	۰/۱۷۳	۰/۱۱۵	-۰/۱۰۰

در جدول زیر نشان می‌دهد الگوریتم پیشنهادی با خطای میانگین ۱۰٪ و دقت ۹۵٪ بهترین عملکرد را در صنعت خودروسازی دارد و برای تحلیل داده‌ها مناسب‌تر است.

جدول ۴. مقایسه نتایج روش‌های مختلف در صنعت خودروسازی

معیارهای ارزیابی		MAE	MSE	RMSE	R2	Adjusted R2	Max Error
الگوریتم پیشنهادی	FA_PSO_LSTM	۰/۱۰	۰/۰۱۳	۰/۱۱	۰/۹۵	۰/۸۳	۰/۱۹
	روش یادگیری عمیق	FA_PSO_RNN	۰/۱۹	۰/۰۵	۰/۲۳	۰/۸۳	۰/۳۵
الگوریتم‌های تکاملی	FA-DE-LSTM	۰/۱۲	۰/۰۱۸	۰/۱۳	۰/۹۳	۰/۷۷	۰/۲۲
	FA-GA-LSTM	۰/۱۴	۰/۰۲۷	۰/۱۶	۰/۹۱	۰/۶۶	۰/۲۹
روش‌های یادگیری ماشین	رگرسیون خطی	۰/۵۵	۰/۲۳	۰/۴۷	۰/۲۵	۰/۱۵	۸/۶
	درخت تصمیم	۰/۶۱	۰/۳۵	۰/۱۱	۰/۰۸	۰/۱۹	۱۰/۰۲
	بیزین	۰/۵۸	۰/۲۹	۰/۱۹	۰/۱۲	۰/۲۱	۹/۴۵
	بردار پشتیبان SVR	۰/۲۸	۰/۱۵	۰/۶۵	۰/۷۵	۰/۴۶	۵/۲۵

روش پیشنهادی در صنعت خودروسازی برای سال ۱۴۰۲ مشابهت رفتاری بیشتری نسبت به دیگر روش‌های یادگیری عمیق داشته است.



شکل ۳. نتایج پیش‌بینی با روش یادگیری عمیق صنعت خودروسازی در سال ۱۴۰۲

در این مطالعه، عملکرد روش‌های ترکیبی در صنعت خودرویی مورد بررسی قرار گرفته است. روش FA-GA-LSTM با ۸۵ بسته آموزشی، نرخ آموزش ۰/۰۴۵، ۲۵ واحد حافظه و ۱۰۵ تکرار، بیشترین تعداد پارامترها را در میان روش‌های مورد بررسی دارد. روش FA-DE-LSTM با ۶۴ بسته آموزشی، نرخ آموزش ۰/۰۳۵، ۲۲ واحد حافظه و ۹۸ تکرار، در جایگاه دوم قرار می‌گیرد. در نهایت، این روش با ۲۵ بسته آموزشی، نرخ آموزش ۰/۰۱۱، ۱۰ واحد حافظه و ۷۸ تکرار، کمترین تعداد پارامترها را در بین این سه روش به خود اختصاص داده است. تحلیل ANOVA و Tukey HSD بر

اساس MAE نشان داد که تفاوت عملکرد ۹ مدل پیش‌بینی در صنعت خودروسازی معنادار است .
 مدل FA_PSO_LSTM با بهترین عملکرد $(F(8,261)=93.84, p=1.92e-72)$
 به طور معناداری از تمام مدل‌های دیگر برتر بود. ($MAE \approx 0.05$)

صنعت فلزات اساسی: در صنعت فلزات، مقدار KMO برابر با ۰/۶۴۳ و آزمون کرویت بارلت مقدار (Chi-Square) برابر با ۱۵۹۱/۱۳۱ و سطح معناداری (Sig) برابر با ۰/۰۰۰ است. در مرحله دوم، نتایج تحلیل مؤلفه‌های اصلی برای صنعت فلزات ارائه شده است. این تحلیل نشان می‌دهد که ۵ مؤلفه اصلی با مقادیر ویژه بزرگتر از یک می‌توانند ۷۲/۹۰۱٪ از کل واریانس داده‌ها را توضیح دهند. جدول (۵) نتایج تحلیل عاملی صنعت فلزات اساسی را نشان می‌دهد که فاکتور اول نقدینگی، فاکتور دوم ظرفیت عملیاتی، فاکتور سوم سود آوری، فاکتور چهارم جریان نقدی و فاکتور پنجم ظرفیت قابلیت توسعه را نشان می‌دهد.

جدول ۵. تحلیل عاملی صنعت فلزات اساسی


	۱	۲	۳	۴	۵
نسبت جاری	۰/۸۴۵	۰/۴۰۶	۰/۱۶۳	۰/۱۰۰	۰/۰۲۷
نسبت وجه نقد	۰/۷۷۹	۰/۴۱۹	۰/۱۸۷	۰/۰۴۳	-۰/۰۴۰
نسبت آنی	۰/۸۴۵	۰/۴۳۶	۰/۱۸۷	۰/۰۶۷	-۰/۰۱۶
نسبت گردش حساب‌های دریافتی	-۰/۵۴۹	۰/۷۲۸	۰/۲۳۰	۰/۱۰۸	۰/۰۷۸
گردش دارایی‌های جاری	-۰/۶۰۰	۰/۶۸۳	۰/۱۵۴	۰/۱۰۱	۰/۱۲۷
نسبت گردش کل دارایی‌ها	-۰/۶۰۸	۰/۷۴۶	۰/۲۰۳	۰/۱۱۰	۰/۱۰۹
بازده حقوق صاحبان سهام	-۰/۰۲۹	-۰/۴۳۲	۰/۸۳۲	۰/۳۳۱	-۰/۰۳۴
بازده دارایی	-۰/۰۸۴	-۰/۴۲۰	۰/۸۲۵	۰/۳۳۹	-۰/۰۶۳
جریان نقد عملیاتی به کل دارایی	-۰/۰۰۷	-۰/۰۵۶	-۰/۴۲۴	۰/۸۲۲	-۰/۰۴۲
جریان نقد خالص حاصل از فعالیت‌های عملیاتی به ازای هر سهم	۰/۰۱۱	-۰/۰۲۳	-۰/۳۹۵	۰/۸۳۴	-۰/۰۳۱
نسبت نقد عملیاتی به دارایی‌ها	۰/۰۳۲	-۰/۱۷۲	-۰/۰۱۰	۰/۰۲۹	۰/۷۹۲
نرخ رشد حقوق صاحبان سهام	-۰/۰۰۴	-۰/۱۳۴	۰/۰۴۰	۰/۰۹۸	۰/۸۱۰
سرمایه ثبت شده	۰/۴۶۶	-۰/۰۵۵	-۰/۰۸۹	-۰/۱۳۸	۰/۳۳۹

نتایج نشان می‌دهد الگوریتم FA_PSO_LSTM با خطای میانگین ۹٪ و دقت ۹۹٪ بهترین عملکرد را در صنعت فلزات دارد.

جدول ۶. مقایسه نتایج روش‌های مختلف در صنعت فلزات اساسی

معیارهای ارزیابی		MAE	MSE	RMSE	R2	Adjusted R2	Max Error
الگوریتم پیشنهادی	FA_PSO_LSTM	۰/۰۹	۰/۰۱۱	۰/۱۰	۰/۹۹	۰/۹۷	۰/۱۸
روش‌های یادگیری عمیق	FA_PSO_RNN	۰/۲۱	۰/۰۵	۰/۲۴	۰/۹۶	۰/۸۷	۰/۴۱
	FA_PSO_GRU	۰/۱۳	۰/۰۲	۰/۱۵	۰/۹۸	۰/۹۵	۰/۲۶
الگوریتم‌های تکاملی	FA-DE-LSTM	۰/۱۰۵	۰/۰۱۵	۰/۱۲	۰/۹۸	۰/۹۶	۰/۲۰
	FA-GA-LSTM	۰/۱۰۶	۰/۰۲	۰/۱۸	۰/۹۶	۰/۹۵	۰/۲۷
روش‌های یادگیری ماشین	رگرسیون خطی	۰/۲۲	۰/۲۱	۰/۴۵	۰/۶۵	۰/۵۵	۹/۲۵
	درخت تصمیم	۰/۲۸	۰/۲۶	۰/۵۱	۰/۴۵	۰/۳۸	۱۲/۱۵
	بیزین	۰/۲۴	۰/۲۳	۰/۴۷	۰/۵۵	۰/۵۱	۱۰/۸۵
	بردار پشتیبان SVR	۰/۱۸	۰/۱۳	۰/۳۶	۰/۷۰	۰/۶۹	۵/۱۵

روش پیشنهادی در صنعت فلزات اساسی برای سال ۱۴۰۲ مشابه رفتاری بیشتری نسبت به دیگر روش‌های یادگیری عمیق داشته است.



شکل ۴. نتایج پیش‌بینی روش‌های یادگیری عمیق صنعت فلزات اساسی در سال ۱۴۰۲

در این بخش، عملکرد روش‌های ترکیبی در صنعت فلزات اساسی مورد بررسی قرار گرفته است. روش FA-GA-LSTM با ۵۵ بسته آموزشی، نرخ آموزش ۰,۲۵، ۳۵ واحد حافظه و ۸۸ تکرار، بیشترین تعداد پارامترها را در میان روش‌های مورد بررسی دارد. روش FA-DE-LSTM

با ۴۰ بسته آموزشی، نرخ آموزش ۰,۰۱۵، ۳۰ واحد حافظه و ۶۸ تکرار، در جایگاه دوم قرار می‌گیرد. در نهایت، این روش با ۳۸ بسته آموزشی، نرخ آموزش ۰,۰۱۰، ۱۵ واحد حافظه و ۵۱ تکرار، کمترین تعداد پارامترها را در بین این سه روش به خود اختصاص داده است. نتایج تحلیل واریانس (ANOVA) نشان داد تفاوت عملکرد مدل‌های پیش‌بینی در صنعت فلزات اساسی معنادار است ($F=21.83, p<0.001$). آزمون Tukey HSD بیانگر برتری مدل‌های ترکیبی مبتنی بر بهینه‌سازی و شبکه‌های عصبی، به ویژه FA_PSO_LSTM، نسبت به مدل‌های کلاسیک بود. به طور کلی، مدل‌ها در چهار گروه عملکردی طبقه‌بندی شدند که در آن مدل‌های FA_PSO_LSTM، FA-DE-LSTM، FA-GA-LSTM و FA_PSO_GRU در گروه عالی و مدل درخت تصمیم در گروه بسیار ضعیف قرار گرفتند.

نتیجه‌گیری و پیشنهادها

در مواجهه با عوامل متعدد و غالباً غیرقابل پیش‌بینی در فعالیت‌های مالی استفاده از یک سیستم مالی نسبتاً کامل جهت نظارت مستمر و اخذ هشدارهای زودهنگام اهمیت بسیار دارد. در پژوهش حاضر در فرآیند ساخت مدل، ابتدا با کمک تحلیل عاملی عوامل مشترک بین شاخص‌های مالی و غیرمالی استخراج گردید و سپس به منظور تطبیق با ویژگی‌های داده‌های مالی سازمانی با سری‌های زمانی تاریخی، از مدل پیش‌بینی یادگیری عمیق FA-PSO-LSTM استفاده شده است. این یک مدل ابتکاری و نسبتاً جدید در این زمینه است که از مزایای شبکه LSTM در پردازش سری‌های زمانی به طور کامل می‌تواند بهره‌مند شده و به تکامل نظریه پردازشی در این خصوص منتهی شود. با استفاده از این مدل شرکت‌ها قادر خواهند بود به ریسک‌های با سرعت بیشتری پاسخ داده و ظرفیت مالی خود را در مقابله با ریسک‌های مالی ارتقا دهند. مدل ارائه شده در این مطالعه می‌تواند در سایر علوم مورد استفاده قرار گیرد.

مقایسه الگوریتم‌های تکاملی در صنایع مختلف نشان داد که در صنعت فلزات اساسی، هر سه الگوریتم دقت بالایی ارائه کردند، اما PSO به دلیل سرعت همگرایی و بهینه‌سازی بهتر، عملکرد بهتری داشت. در صنعت خودروسازی، تفاوت عملکرد بین الگوریتم‌ها کمتر بود، اما باز هم PSO کمی برتر بود. در صنعت فرآورده‌های نفتی، DE و GA عملکرد مناسبی داشتند، ولی ترکیب

FA_PSO_LSTM همچنان دقت بالاتری ارائه کرد و توانست الگوهای پیچیده داده‌ها را بهتر شناسایی کند.

با وجود عملکرد بهتر مدل ارائه شده نسبت به مدل‌های پیشین، باید از تعداد محدود شاخص‌های غیرمالی، و تاثیر پذیری بحران‌های مالی شرکت‌ها از شاخص‌های کلان محیطی مانند شرکت‌های رقیب، سطح مصرف، تولید ناخالص داخلی، عدم استفاده از داده‌های شرکت‌های خصوصی، دسترسی محدود به صورت‌های مالی حسابرسی شده و مشابه اینها به عنوان محدودیت این پژوهش نام برد.

پیشنهاد می‌شود در پژوهش‌های آتی ضمن استفاده از الگوریتم‌های جید هوش مصنوعی مانند الگوریتم فراابتکاری هوش مصنوعی آتش‌فشانی، الگوریتم فراابتکاری تکامل تفاضلی در هوش مصنوعی، الگوریتم فراابتکاری هوش مصنوعی هایبرید و مشابه اینها، همبستگی ذاتی بین داده‌های مرتبط با شاخص‌ها غیرمالی و انتخاب متغیرهای هدفمندتر مورد توجه قرار گیرد تا نتایج بهتری حاصل شود.

فهرست منابع

- Alieva, B., Saparbayev, A., Zhanibekova, G., Noiyanov, M., & Kim, V. (2020). Methodology for managing financial risks of Kazakhstan enterprises. *E3S Web of Conferences*, 159, 04018. <https://doi.org/10.1051/e3sconf/202015904018>
- Arefieva, O. V., Miagkyh, I. M., & Yashchuk, A. M. (2019). Challenges and pathways to improve company's financial management by risk minimization. *Bulletin of the Kyiv National University of Technologies and Design. Series: Economic Sciences*. <https://doi.org/10.30857/2413-0117.2019.1.5>
- Cai, M. (2025). Using Cuckoo Search Algorithm to Predict Corporate Financial Risks and Alleviate Economic Uncertainty. *International Journal of Computational Intelligence Systems*, 18(1), 216. <https://link.springer.com/article/10.1007/s44196-025-00950-0>
- Chen, S. (2022). Cryptocurrency financial risk analysis based on deep machine learning. *Complexity*. <https://doi.org/10.1155/2022/2611063>
- Chen, X., & Long, Z. (2023). E-Commerce enterprises financial risk prediction based on FA-PSO-LSTM neural network deep learning model. *Sustainability*, 15. <https://doi.org/10.3390/su15075882>
- Chen, W. (2025). Enterprise financial risk prediction and intelligent early warning model based on deep learning. *Discover Artificial Intelligence*. <https://doi.org/10.1007/s44163-025-00497->
- Ghasemiyeh, R., Sinaei, H., & Dodange, A. R. (2024). A prediction-based portfolio optimization model using CNN neural network and MSAD criterion in Tehran Stock Exchange. [In Persian] *Budget and Finance Strategic Research*, 5(3), 11-3 DOR:20.1001.1.27171809.1403.5.3.1.2
- Ghasemiyeh, R., Sinaei, H., & Ghalambor Dezfuli, E. (2023). A method based on wavelet denoising and DTW algorithm for stock price pattern recognition in Tehran stock exchange. *Quietly Journal of quantitative Economics*, 20(4), pp1-27. <https://doi.org/10.22055/jqe.2023.42285.2521>
- Khalid, S., Khan, M. A., Mazliham, M. S., Alam, M. M., Aman, N., Taj, M. T., Zaka, R., & Jehangir, M. (2022). Predicting risk through artificial intelligence based on machine learning algorithms: A case of Pakistani nonfinancial firms. *Complexity*. <https://doi.org/10.1155/2022/6858916>
- Mirzaei-Najad, M., Radfar, R., & Fathi, K. (2021). Designing a dynamic model of Iranian financial markets using system dynamics [In Persian]. *Journal of Management Accounting*. <https://www.sid.ir/filesserver/jf/4003714005101.pdf>
- Mohammadi, M. (2024). Investigating the effect of risk-taking behavior and financial crisis on earnings quality and financial performance in companies listed on the Tehran Stock Exchange [In Persian]. *Accounting and Auditing Research*. https://www.iaaar.com/asrticle_206115.html
- Mosala, M., & Moghaddam, F. (2020). Investigating the effect of financial leverage on the risk and return of shares of companies listed on the Tehran Stock Exchange [In Persian]. *Journal of Financial Research*. <https://www.majournal.ir/index.php/ma/article/view/356>
- Moghadamnia, E., & Hosseini, Z. S. (2025). Analysis of the organizational performance of National Iranian Oil Company — exploration management through the effectiveness of financial management measures of the organization [In Persian]. *Budget and Finance Strategic Research*. DOR:20.1001.1.27171809.1404.6.2.6.2

- Qin, R., & Chen, M. (2022). The construction of corporate financial management risk model based on XGBoost algorithm. *Journal of Mathematics*. <https://doi.org/10.1155/2022/2043369>
- Raei, R., Fallahpour, S., & Amery Matin, H. (2023). Financial risk assessment model for LNG projects: Case study — Iran LNG project [In Persian]. *Journal of Financial*. <https://doi.org/10.22059/jfr.2013.51058>
- Salmanian, M., Vakilifard, H., Hamidian, M., Sarraf, F., & Darabi, R. (2021). Predicting financial constraints of companies listed on the Tehran Stock Exchange using Relief-SVM-Caiid methods [In Persian]. *Investment Knowledge*. http://www.jik-ifea.ir/article_17096.html?lang=en
- Siami-Namini, S., & Namin, A. S. (2018). Forecasting economics and financial time series: ARIMA vs. LSTM. *arXiv*. <https://doi.org/10.48550/arXiv.1803.06386>
- Sun, X., Shen, H., Bi, W., Xu, B., Wang, Z., & Cheng, X. (2022). Company-as-Tribe: Company financial risk assessment on tribe-style graph with hierarchical graph neural networks. In *KDD '22 Proceedings*. <https://doi.org/10.1145/3534678.3539129>
- Tavakoli, S., & Ashtab, A. (2021). Identifying the factors affecting the financial risks of companies using the structural equations approach [In Persian]. *Journal of Financial Studies*. <https://doi.org/10.22108/amf.2021.127996.1647>
- Tavakoli, S., & Ashtab, A. (2023). Comparison of the effectiveness of machine learning models and statistical models in predicting financial risk [In Persian]. *Journal of Financial Management*. <https://doi.org/10.22108/amf.2023.136720.1784>
- Wang, C. (2025). Corporate financial distress prediction with multiperiod annual report data: A fusion deep neural network model. *PLOS ONE*. <https://doi.org/10.1371/journal.pone.0333064>
- Yang, D., Ma, H., Chen, X., Liu, L., & Lang, Y. (2022). Design of financial risk control model based on deep learning neural network. *Computational Intelligence and Neuroscience*. <https://doi.org/10.1155/2022/5842039>
- Zahir, M., Hamidian, M., & Darabi, R. (2024). Designing a conceptual model of factors affecting on financial health in life cycle of companies by using the Foundation's data approach [In Persian]. *Budget and Finance Strategic Research*, 5(2), 45-76.
- DOR: 20.1001.1.27171809.1403.5.2.2.1
- Zhai, M. (2021). Risk prediction and response strategies in corporate financial management based on optimized BP neural network. *Complexity*. <https://doi.org/10.1155/2021/9973377>

