



<https://amf.ui.ac.ir>

**Journal of Asset Management and Financing**

E-ISSN: 2383-1189

Vol. 11, Issue 3, No. 42, Autumn 2023, p 113-140

Received: 26.08.2023 Accepted: 17.09.2023

**Research Paper**

## **A Novel Approach to Predicting Financial Distress by Using Financial Network-Based Information and the Integrated Method of Gradient Boosting Decision Tree**

**Ezzatollah Abbasian** \* 

Associate Professor, Department of Financial Engineering, Faculty of Accounting and Financial Sciences, University of Tehran, Tehran, Iran  
e.abbasian@ut.ac.ir

**Kaveh Shahraki**

Ph.D. Candidate, Department of Financial Management and Insurance, Alborz Campus, Faculty of Management, University of Tehran, Tehran, Iran  
k.shahraki@ut.ac.ir

**Saeed Fallahpour**

Associate Professor, Department of Financial Management, Faculty of Management, University of Tehran, Tehran, Iran  
falahpor@ut.ac.ir

**Ali Namaki**

Assistant Professor, Department of Financial Management, Faculty of Management, University of Tehran, Tehran, Iran  
alinamaki@ut.ac.ir

### **Abstract**

This study aimed to evaluate the performance of the gradient boosting decision tree model, the parameters of which were optimized with the improved Gray Wolf Algorithm (GWO) by adding financial network-related variables via the selected models of predicting financial distress. The proposed model of this study was implemented on the data of 123 manufacturing companies admitted to the Tehran Stock Exchange and Iran Fara Bourse Co. (IFB) from 2014 to 2021. Initially, the financial network was formed and then, the financial distress of companies was predicted by integrating the network-based variables with financial ratios and using a gradient boosting decision tree model. The model of the gradient boosting decision tree had better performance in terms of precision and Type I error by adding Financial Network Indicators (FNI) compared to the two models of K-Nearest Neighbor (KNN) and Logistic Regression (LR). Companies with betweenness centrality and high degree centrality were found to be less prone to financial distress and vice versa. This is the first study to predict financial distress by using financial network-related variables integrated with financial ratio variables through the novel gradient boosting decision tree method, the parameters of which were optimized with the improved GWO.

**Keywords:** Financial Distress, Financial Network, Gradient Boosting Decision Tree, Improved Gray Wolf Algorithm (GWO), Centrality Criteria.

### **Introduction**

Previous studies on predicting financial distress have mainly adopted financial variables in financial statements as explanatory variables, while ignoring some other potentially useful information, such as financial network-related information. Disregarding such information for predicting financial distress is one of the significant gaps in the literature. Therefore, the present study aimed to evaluate the performance of the gradient boosting decision tree model, the parameters of which were optimized with the improved Gray Wolf Algorithm (GWO), along with the financial network-related variables, which showed another gap in the literature, and then compare its findings with the two recently widely used models of K-Nearest Neighbor (KNN) and Logistic Regression (LR). The following questions were posed in the present study.

1. Can the integrated IGWO-GBDT model provide a better prediction of financial distress compared to the widely selected models of LR and KNN?
2. Does the inclusion of financial network variables improve the performance of the integrated IGWO-GBDT model for predicting financial distress?

\*Corresponding author

Abbasian, E., Shahraki, K., Fallahpour, S., & Namaki, A. (2024). A Novel Approach to Predicting Financial Distress by Using Financial Network-Based Information and the Integrated Method of Gradient Boosting Decision Tree. *Journal of Asset Management and Financing*, 11(3), 113-140.

2383-1189 © University of Isfahan



This is an open access article under the BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<https://doi.org/10.22108/AMF.2023.138909.1818>

3. Does the inclusion of financial network variables improve the performance of the widely used models of LR and KNN for predicting financial distress?

### Materials & Methods

The sample of this study included all the manufacturing companies listed in the Tehran Stock Exchange and Iran Fara Bourse Co. (IFB) from 2014 to 2021, of which 123 companies were selected. The information of the last 30 trading days in each fiscal year was used to form the financial network variables. Finally, 8 financial variables were selected based on those adopted by Ebrahimi Sarvolia et al. (2018), including current ratio, net ratio of working capital to total asset, ratio of current asset to total asset, profit margin, return on assets, return on equity, book to market ratio, and size of company. Furthermore, the total debt ratio, a widely used variable in previous studies, was added to the financial variables. Regarding the financial network variables, the 4 variables of degree centrality, betweenness centrality, eigenvector centrality, and closeness centrality were selected similar to those selected by Montasheri and Sadeqi (2020) and Liu et al. (2019). More than one criterion was applied to measure financial distress in this study. Any companies that met at least one of the four mentioned criteria were considered distressed in that year. These criteria were subject to Article 141 of the Commercial Law, suffering losses for 3 consecutive years (Damoori & Hozhabrie, 2019), subject to Article 412 of the Commercial Law, referring to a debt ratio higher than 1 (Poorheidari & Koopaei, 2011), and had negative equity.

### Findings

The findings indicated that the mean degree of centrality for companies with financial health was 0.203, while it was 0.193 for the distressed companies. Betweenness centrality was 0.007 for the distressed and non-distressed companies. Regarding eigenvector centrality, the means of healthy companies and those with financial distress were 0.083 and 0.104, respectively. Also, the values of closeness centrality were 0.525 and 0.496 for the mentioned companies, respectively. Table 5 shows that all the 3 models have performed quite well in terms of prediction of the class of healthy companies, while the error was below 10%. Still, the distinguished performances of these models were revealed when they could accurately and appropriately predict the class of financially distressed companies, which included only 12% of observations. The type I errors in the LR and KNN models were respectively 20 and 40%, bearing huge costs. In other words, these two models mistakenly predicted distressed companies as healthy ones in 20 and 40% of cases. However, the type I error of the proposed research model was only 5%, indicating high accuracy of the model.

**Table 5. Comparison of the performances of the 3 studied models with and without financial network variables**

	LR	FN-LR	KNN	FN-KNN	GBDT	FN-GBDT
<b>Accuracy</b>	0.901	0.907	0.906	0.895	0.96	0.982
<b>Error 1</b>	0.24	0.20	0.31	0.40	0.11	0.05
<b>Error 2</b>	0.086	0.078	0.011	0.065	0.033	0.013
<b>AUC</b>	0.932	0.959	0.916	0.907	0.989	0.933
<b>G-mean</b>	0.833	0.858	0.826	0.748	0.927	0.968

### Discussion and Conclusion

- (1) Financial network variables can be employed to explore useful information in the financial network and improve the prediction performances of classifiers.
- (2) According to the definition of centrality, companies with high centrality, especially betweenness centrality and degree centrality, are less prone to financial distress and vice versa.
- (3) The improved GWO is a practical method for selecting the parameters of the gradient boosting model.
- (4) The gradient boosting decision tree model is highly efficient when the frequency ratio of the samples of each class is significantly different from those of other classes. The experimental findings revealed that the proposed model outperformed the other two models in predicting financial distress. This was confirmed by the adopted evaluation criteria.

## رویکردی نوین در پیش‌بینی درماندگی مالی با به‌کارگیری اطلاعات مبتنی بر شبکه مالی و روش ترکیبی درخت تصمیم تقویت گرادیان

عزت‌اله عباسیان <sup>ID</sup>\*

دانشیار، گروه مهندسی مالی، دانشکده حسابداری و علوم مالی، دانشگاه تهران، تهران، ایران  
e.abbasian@ut.ac.ir

کاوه شهرکی

دانشجوی دکتر، گروه مدیریت مالی و بیمه، پردیس البرز، دانشگاه تهران، تهران، ایران  
k.shahraki@ut.ac.ir

سعید فلاح‌پور

دانشیار، گروه مدیریت مالی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران  
falahpor@ut.ac.ir

علی نمکی

استادیار، گروه مدیریت مالی، دانشکده مدیریت، دانشگاه تهران، تهران، ایران  
alinamaki@ut.ac.ir

### چکیده

**هدف:** این پژوهش بر آن است که با اضافه کردن متغیرهای مربوط به شبکه مالی، عملکرد الگوی درخت تصمیم تقویت گرادیان را که شاخص‌هایش با الگوریتم بهبود یافته گرگ خاکستری بهینه شده است، با الگوهای منتخب در حوزه پیش‌بینی درماندگی مالی ارزیابی کند.

**روش:** الگوی پیشنهادی این پژوهش روی داده‌های ۱۲۳ شرکت تولیدی پذیرفته شده در بورس و فرابورس ایران در بازه زمانی ۲۰۱۵ تا ۲۰۲۱ اجرا شد. ابتدا شبکه مالی تشکیل شد و سپس با ترکیب متغیرهای مبتنی بر شبکه با برخی نسبت‌های مالی و با استفاده از الگوی درخت تصمیم تقویت گرادیان که شاخص‌های آن با الگوریتم بهبود یافته گرگ خاکستری بهینه شده است، درماندگی مالی شرکت‌ها پیش‌بینی شد.

**نتایج:** الگوی درخت تصمیم تقویت گرادیان با اضافه شدن متغیرهای مربوط به شبکه مالی هم از نظر دقت و هم از نظر خطای نوع یک عملکرد بهتری در مقایسه با دو الگوی k نزدیک‌ترین همسایه و رگرسیون لجستیک از خود نشان داد. شرکت‌های با مرکزیت بینابینی و مرکزیت درجه زیاد، کمتر مستعد قرار گرفتن در شرایط درماندگی مالی هستند و برعکس. در شرایطی که نسبت فراوانی نمونه‌های هر طبقه از طبقات دیگر بسیار متفاوت باشد، استفاده از روش درخت تصمیم تقویت گرادیان بسیار کارآمد خواهد بود.

**نوآوری:** برای نخستین بار متغیرهای مربوط به شبکه مالی با نسبت‌های مالی، ترکیب شد و از طریق روش نوین درخت تصمیم تقویت گرادیان که شاخص‌هایش با الگوریتم گرگ خاکستری بهبود یافته بهینه شده، درماندگی مالی پیش‌بینی شد.

**کلیدواژه‌ها:** درماندگی مالی، شبکه مالی، درخت تصمیم تقویت گرادیان، الگوریتم گرگ خاکستری بهبود یافته، معیارهای مرکزیت

\* نویسنده مسئول

عباسیان، عزت‌اله، شهرکی، کاوه، فلاح‌پور، سعید و نمکی، علی. (۱۴۰۲). رویکردی نوین در پیش‌بینی درماندگی مالی با به‌کارگیری اطلاعات مبتنی بر شبکه مالی و روش ترکیبی درخت تصمیم تقویت گرادیان. *مدیریت دارایی و تأمین مالی*، ۱۱(۳)، ۱۱۳-۱۴۰.



## مقدمه

پیش‌بینی درماندگی مالی که به‌عنوان «پیش‌بینی ورشکستگی و پیش‌بینی شکست کسب و کار» نیز شناخته می‌شود، جایگاه حیاتی برای تصمیم‌گیرندگان مالی مانند سرمایه‌گذاران، اعتباردهندگان و مدیران شرکت‌ها دارد. از یک‌سو مدیران به ارزیابی ریسک شرکت در زمان تدوین و طراحی برنامه‌های توسعه برای شرکت نیازمند هستند و از سوی دیگر اعتباردهندگان و سرمایه‌گذاران نیز به ارزیابی شاخص‌های وضعیت مالی شرکت نظیر نقدشوندگی، کفایت سرمایه و سودآوری نیازمند هستند؛ بنابراین پیش از آنکه آنها در زمینه اعتباری یا سرمایه‌گذاری تصمیم بگیرند باید از این اطلاعات باخبر شوند. با توجه به اینکه بهره‌وران شرکت تا حد زیادی از پیش‌بینی درماندگی مالی شرکت بهره می‌برند (Yang et al., 2001)، کاربرد پیش‌بینی درماندگی مالی مطالعات زیادی را به‌دنبال داشته است. براساس مطالعات پیشین در این حوزه، بیشتر مطالعات روی ساخت الگوهای پیش‌بینی درماندگی مالی با استفاده از رویکردهای آماری یا داده‌کاوی با هدف بهبود عملکرد پیش‌بینی الگو متمرکز بوده است (Gepp et al., 2010; Chen et al., 2011; Kumar & Ravi, 2007). اگرچه ایجاد الگوهای پیش‌بینی مبتنی بر داده است، ولی بسیار ضروری است بهترین استفاده از تمام اطلاعات موجود در ارتباط با شرکت، برای پیش‌بینی اینکه آیا شرکت در موقعیت نکول یا درماندگی مالی هست یا خیر صورت گیرد؛ در نتیجه عملکرد پیش‌بینی درماندگی مالی نه تنها با الگوها و روشهایی تعیین می‌شود که برای پیش‌بینی به‌کار می‌برند، براساس به‌کارگیری اطلاعات موجود نیز ارزیابی می‌شود. مطالعات پیشین دربارهٔ پیش‌بینی درماندگی مالی به‌طور عمده از متغیرهای مالی موجود در صورت‌های مالی به‌صورت متغیرهای توضیحی استفاده می‌کردند؛ به همین دلیل برخی از اطلاعات مفید دیگر بالقوه لحاظ نمی‌شد. از جمله این اطلاعات نادیده گرفته شده به اطلاعات موجود در شبکهٔ مالی<sup>۱</sup> اشاره می‌شود که استفاده نکردن از آن در پیش‌بینی درماندگی مالی، از شکاف‌های اصلی موجود در اصول موضوع پژوهش است. شرکت‌های پذیرفته‌شده در بورس اوراق بهادار به‌عنوان یک «شبکهٔ مالی پیچیده»<sup>۲</sup> در نظر گرفته می‌شوند که شرکت‌ها در جایگاه گره‌ها و همبستگی میان بازده سهام آنها به‌صورت روابط میان آنها در نظر گرفته شود. مانتگنا در سال (1999) در ارائهٔ بازار مالی به‌صورت شبکه پیش‌قدم شد (Mantegna, 1999)؛ برای مثال ارتباط بین دو شرکت با بازده سهامشان و از طریق محاسبهٔ ضریب همبستگی میان سری‌های زمانی‌شان مرتبط می‌شوند. درک بازار مالی به‌صورت یک شبکهٔ پیچیده این امکان را فراهم می‌سازد تا سازمان و فرایند تکامل شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تجزیه و تحلیل شوند. علاوه بر این، از دیدگاه تحلیل شرکت‌ها، سنج‌های مبتنی بر شبکه مانند مرکزیت<sup>۳</sup> تعداد ارتباطات یک شرکت و همین‌طور تعداد شرکت‌های مرتبط با آن را اندازه‌گیری و پس از آن، نفوذ و مرکزیت یک شرکت در بازار مالی را نیز کشف می‌کند؛ بدین ترتیب احتمال اینکه آن شرکت در معرض درماندگی مالی قرار می‌گیرد، مشخص و با سنج‌های مبتنی بر شبکه شناسایی می‌شود. با توجه به شکاف اشاره‌شده در اصول پیش‌بینی درماندگی مالی و بر مبنای تحلیل شبکه، این پژوهش در تلاش است سنج‌های مناسبی از شبکه را به‌کار گیرد و با ترکیب آنها با متغیرهای مالی، با دقت بیشتری بنگاه‌های دارای درماندگی مالی و سلامت مالی را از یکدیگر متمایز سازد. همان‌طور که اشاره شد در زمینهٔ روش‌های کمی پیش‌بینی درماندگی مالی در ابتدا روش‌های آماری شامل تحلیل نسبت تکین (Beaver, 1968)، تحلیل تمایزی چندگانه (Altman, 1968) و رگرسیون لجستیک (Lau, 1987) استفاده شد. پس از آن روش‌های داده‌کاوی مانند شبکهٔ عصبی (Chauhan et al., 2009; Chen & Du, 2009; Iturriaga & Sanz, 2015)، ماشین بردار پشتیبان (Chen et al., 2011) Sun & Li, 2008) و درخت تصمیم (Hsieh et al., 2012; Chen & Hsiao, 2008) Chaudhuri & De, 2011) نیز به‌منظور پیش‌بینی درماندگی استفاده شد. در مقایسه با جداسازهای تکین، از روش‌های ترکیبی<sup>۴</sup> این انتظار می‌رود که واریانس خطای تخمین را کاهش دهند و به‌طور کلی عملکرد شناسایی را بهبود بخشند. بنابراین در سال‌های اخیر، پیش‌بینی درماندگی مالی

1. financial network

2. Complex financial network

3. Centrality

4. Ensemble methods

براساس روش‌های ترکیبی روند فزاینده‌ای در این زمینه داشته است (Zhang & Haghani, 2015; Zheng et al., 2008; Guelman, 2012).

روش درخت تصمیم تقویت‌گرادیان<sup>۱</sup> یک روش ترکیبی و گونه‌ای از روش‌های بوستینگ است. GBDT به‌طور هدفمند درخت‌های جدیدی برای کمینه‌کردن تابع هزینه که با الگوهای ساخته‌شده قبلی شکل گرفته است، اضافه می‌کند. روش GBDT سودمندی‌اش را در برخی حوزه‌ها مانند پیش‌بینی زمان سفر، رتبه‌بندی شبکه‌ها و الگوسازی زیان بیمه‌ها اثبات کرده است؛ بنابراین GBDT توانایی پیش‌بینی بالقوه‌ای نسبت به روش‌های دیگر ترکیبی برای پیش‌بینی درماندگی مالی دارد. باید ذکر کرد کارآمدی روش GBDT در پیش‌بینی درماندگی مالی به بهینه‌سازی شاخص‌های آن بستگی دارد (Friedman, 2001). بهینه‌ساز گرگ خاکستری (Mirjalili et al., 2014) به‌صورت یک عضو جدید الگوریتم‌های الهام‌گرفته از طبیعت، سلسله‌مراتب اجتماعی و رفتارهای شکارکردن گرگ‌های خاکستری را تقلید می‌کند. مشخصه‌های اصلی بهینه‌ساز گرگ خاکستری شامل سلسله‌مراتب اجتماعی، محاصره طعمه، شکارکردن، حمله‌کردن به طعمه (بهره‌برداری<sup>۲</sup>) و جست و جوی طعمه (کشف)<sup>۳</sup> است. به‌دلیل توانایی خوب بهینه‌ساز گرگ خاکستری در جست و جو، از این بهینه‌ساز در حوزه‌های مختلفی استفاده شده است. موآنگ کوت و همکاران از بهینه‌ساز گرگ خاکستری همراه اصلاحاتی که در آن انجام دادند، برای آموزش شبکه‌های عصبی شبکه‌های تابع - پیوندی پایه شعاعی گاوسی-q<sup>۴</sup> استفاده کردند. نتایج آزمایش نشان داد الگوریتم پیشنهادی، عملکرد بهتری از روش‌های دیگر فراابتکاری داشت (Muangkote et al., 2014). کمکی و کیوانفر با موفقیت از بهینه‌ساز گرگ خاکستری برای مسئله اصلی دو مرحله‌ای برنامه‌ریزی جریان کار فروشگاه همراه زمان فروش محصولات استفاده کردند تا بهره‌وری را به‌طور درخور ملاحظه‌ای بهبود بخشند (Komaki & Kayvanfar, 2015). سلیمان و همکاران از بهینه‌ساز گرگ خاکستری استفاده کردند تا مسئله توزیع بهینه توان واکنش<sup>۵</sup> را حل کنند (Sulaiman et al., 2015). باوجود کاربردهای مختلف الگوریتم گرگ خاکستری در حوزه‌های مختلف و عملکرد مقبول آن باید خاطر نشان کرد این الگوریتم کاستی‌هایی دارد که در بخش روش پژوهش به تفصیل به آن اشاره شده است. بر اساس همین در این پژوهش از نسخه بهبودیافته آن استفاده شده است. همچنین تا جایی که بررسی شده است و مطالعات نشان می‌دهد، شایستگی این الگوریتم برای تنظیم بهینه شاخص‌های موجود در روش درخت تصمیم تقویت‌گرادیان آزمایش نشده که خود این موضوع یکی از شکاف‌های موجود در اصول موضوع پژوهش است؛ بنابراین این پژوهش چند هدف را دنبال می‌کند: ازجمله اینکه عملکرد الگوی درخت تصمیم تقویت‌گرادیان را که شاخص‌هایش با الگوریتم گرگ خاکستری بهبودیافته، بهینه شده است، در ترکیب با متغیرهای مبتنی بر شبکه مالی که شکاف دیگری در اصول موضوع پژوهش به حساب می‌آید، برای پیش‌بینی درماندگی مالی بررسی می‌کند؛ نتایج آن را نیز با دو الگوی پرکاربرد و جدید در این حوزه یعنی رگرسیون لجستیک که به‌دلیل استفاده زیاد آن در این حوزه انتخاب شده و k نزدیک‌ترین همسایه که یکی از جدیدترین روش‌ها در این حوزه است، با توجه به معیارهایی مانند دقت، سطح زیر منحنی ROC، خطای نوع اول و دوم و G-mean مقایسه می‌کند؛ در پایان بررسی می‌کند آیا افزودن متغیرهای شبکه مالی عملکرد الگوهای پیش‌بینی درماندگی مالی را بهبود می‌بخشد یا خیر؟

با ارزیابی و بررسی اصول موضوع مشخص شد چندین بحث در این حوزه به مطالعات بیشتری نیازمند است که در ادامه به آنها اشاره شده است:

(۱) بیشتر مطالعات این حوزه تنها متغیرهای مالی سنتی یا متغیرهای بازار را به‌صورت ورودی الگو برای پیش‌بینی درماندگی مالی در نظر گرفتند. برخی از متغیرهای مبتنی بر شبکه‌های مالی و تأثیرشان در پیش‌بینی درماندگی مالی بررسی نشده است. براساس دیدگاه لیو و همکاران از آنجاکه بازده سهام به‌طور هم‌زمان انواع مختلفی از ارتباط را در میان شرکت‌ها بیان کرده، به‌روزترین اطلاعات در

<sup>1</sup> Gradient Boosting Decision Tree (GBDT)

<sup>2</sup> Exploitation

<sup>3</sup> exploration

<sup>4</sup> q-Gaussian Radial Basis Functional-link nets neural networks

<sup>5</sup> optimal reactive power dispatch



بازار را نیز منتقل می‌کند، بنابراین با لحاظ‌نکردن اثر اطلاعات شبکه مالی، اطلاعات پیش‌بینی‌کننده مهم و مؤثری از دست خواهد رفت (Liu et al., 2019). اینکه آیا متغیرهای مبتنی بر شبکه عملکرد پیش‌بینی را بهبود می‌بخشد یا خیر یک پرسش جدید است که بررسی نشده است.

(۲) براساس یافته‌های پژوهش آلاکا و همکاران بخش زیادی از مطالعات در این حوزه از روش‌های آماری یا داده‌کاوی مانند تحلیل تمایزی چندگانه، لاجیت، شبکه عصبی و ماشین بردار پشتیبان به‌صورت الگوی طبقه‌بندی برای پیش‌بینی درماندگی مالی استفاده کرده‌اند (Alaka et al., 2018). با این حال توانایی بالقوه الگوهای ترکیبی مانند درخت تصمیم تقویتی برای پیش‌بینی درماندگی مالی کمتر مطالعه شده است. علاوه بر این با استفاده از بهینه‌ساز گرگ خاکستری بهبودیافته نیز شاخص‌های الگوی درخت تصمیم تقویتی بهینه می‌شود که این نیز یک تلاش به‌نسبت جدید است.

(۳) الگوی شبکه مالی، بهینه‌ساز گرگ خاکستری و درخت تصمیم برای پیش‌بینی درماندگی مالی براساس مجموعه داده‌های شرکت‌های پذیرفته‌شده در بورس و فرابورس ایران یک کار جدید است و پیش‌بینی عملکرد الگوی پیشنهادی را اعتبار می‌بخشد. (۴) به‌یقین بیشتر پژوهش‌های انجام‌شده درخصوص پیش‌بینی درماندگی مالی، برای اینکه در انتخاب نهایی نمونه، بین تعداد شرکت‌های درمانده و سالم تناسب ایجاد کنند، از روش حذف استفاده کرده‌اند (برای مثال Liu et al., 2019; Aydin et al., 2022). بدین ترتیب بسیاری از اطلاعات واقعی را نادیده گرفته‌اند. این اقدام برای ایجاد نسبت برابر و یا نسبت‌های سه به یک و یا کمی بیشتر میان شرکت‌های سالم و درمانده صورت گرفته است. در صورتی که یکی از اهداف این پژوهش آن است که ابزاری شناسایی کند که بدون نیاز به حذف اطلاعات و حتی با وجود نسبت‌های بسیار متفاوت میان شرکت‌های سالم و درمانده، با دقت زیاد و خطای کم پیش‌بینی انجام دهد.

براساس ضرورت‌هایی که به آن اشاره شد، این پژوهش به‌دنبال آن است تا عملکرد الگوی درخت تصمیم تقویت‌گرادیان را که شاخص‌هایش با الگوریتم گرگ خاکستری بهبودیافته بهینه شده است، در پیوند با متغیرهای مبتنی بر شبکه مالی برای پیش‌بینی درماندگی مالی بررسی کند. نتایج آن را نیز با برخی الگوهای پرکاربرد در حوزه پیش‌بینی درماندگی مالی<sup>۱</sup> و با توجه به معیارهای مختلف مقایسه کند. در پایان بررسی کند آیا افزودن متغیرهای شبکه مالی عملکرد الگوهای پیش‌بینی درماندگی مالی را بهبود می‌بخشد یا خیر؟

برای تحقق اهداف پژوهش و رسیدن به نتایج نهایی، سؤالات پژوهش به شرح زیر مطرح شده است تا با پاسخ به آنها پژوهش در مسیر درست هدایت شود.

(۱) آیا الگوی ترکیبی IGWO – GBDT برای پیش‌بینی درماندگی مالی در مقایسه با الگوهای پرکاربرد منتخب (LR, KNN) عملکرد بهتری دارد؟

(۲) آیا استفاده از متغیرهای شبکه مالی (FNI) عملکرد الگوی ترکیبی IGWO – GBDT را برای پیش‌بینی درماندگی مالی بهبود می‌بخشد؟

(۳) آیا استفاده از متغیرهای شبکه مالی (FNI) عملکرد الگوهای پرکاربرد منتخب (LR, KNN) را برای پیش‌بینی درماندگی مالی بهبود می‌بخشد؟

ساختار مقاله: در ادامه مبانی نظری و تشریح مفاهیم اصلی پژوهش بیان شده است. پس از آن پیشینه تجربی و پژوهش‌های داخلی و خارجی بررسی شده است. سپس روش پژوهش و یافته‌های حاصل از آن به تفصیل بیان شده و در پایان نیز نتیجه‌گیری و پیشنهادات کاربردی و پژوهشی و منابع مقاله ذکر شده است.

<sup>۱</sup>. LR, KNN

## مبانی نظری

شبکه‌های پیچیده ابزارهای توانمندی برای نشان‌دادن و مطالعه تعامل میان پدیده‌ها در دنیای واقعی هستند. شناسایی و استخراج گره‌های اثرگذار در شبکه‌های پیچیده تبدیل به یک حوزه پژوهشی مهم شده است؛ زیرا اثرات گسترده‌ای در ابعاد مختلف دارند. مبانی نظری شبکه‌های پیچیده در زمینه‌های مختلفی شامل علوم طبیعی، اقتصاد، علم مدیریت، علوم زیست‌شناسی و علوم کامپیوتر مورد توجه شایانی قرار گرفته است؛ بنابراین طراحی روش‌های سریع و اثربخش جهت شناسایی گره‌های اثرگذار در شبکه پیچیده یک اولویت حیاتی است (Sheng et al., 2019). همانطور که در مقدمه نیز اشاره شد، شرکت‌های پذیرفته‌شده در بورس اوراق بهادار به صورت یک شبکه مالی پیچیده<sup>۱</sup> در نظر گرفته می‌شوند که شرکت‌ها در جایگاه گره‌ها و همبستگی میان بازده سهام آنها در جایگاه روابط میان آنها هستند. مانتگنا در سال ۱۹۹۹ در ارائه بازار مالی به صورت شبکه پیش قدم شد (Mantegna, 1999). برای مثال ارتباط بین دو شرکت با بازده سهام‌شان و از طریق محاسبه ضریب همبستگی میان سری‌های زمانی‌شان مرتبط می‌شوند. درک بازار مالی به صورت یک شبکه پیچیده اجازه می‌دهد سازمان و فرایند تکامل شرکت‌های پذیرفته‌شده در بورس اوراق بهادار تجزیه و تحلیل شوند. شبکه‌های بازار مالی با در نظر گرفتن رویکردی مبتنی بر ماتریس‌های همبستگی ساخته شده‌اند. این روش ضرایب همبستگی میان سری‌های زمانی دو سهم  $i$  و  $j$  را در نظر گرفته است که با رابطه زیر محاسبه می‌شوند (Liu et al., 2019):

$$\rho_{ij} = \frac{(Y_i Y_j) - (Y_i)(Y_j)}{\sqrt{((Y_i^2) - (Y_i)^2)((Y_j^2) - (Y_j)^2)}} \quad \text{رابطه (۱)}$$

$$Y_i = \ln P_i(t) - \ln P_i(t-1) \quad \text{رابطه (۲)}$$

در این رابطه  $Y_i$  بازده سهم  $i$  است که از طریق رابطه (۲) به دست آمده و  $P_i(t)$  قیمت پایانی سهام  $i$  در روز  $t$  است. فاصله میان دو سهم  $i$  و  $j$  با رابطه (۳) محاسبه می‌شود این یک معیار واقعی است که از ۳ قاعده کلی فاصله پیروی می‌کند. در صورتی که ضریب همبستگی میان بازده سهام دو شرکت مستقیم و کامل باشد، آنگاه فاصله میان آنها صفر خواهد شد؛ اما اگر همبستگی معکوس و کامل باشد، آنگاه فاصله بیشینه و برابر ۲ می‌شود (Comin et al., 2020).

$$d(i, j) = \sqrt{2(1 - \rho_{ij})} \quad \text{رابطه (۳)}$$

در رابطه (۳)، اگر  $d(i, j) = 0$  و فقط اگر  $j = i$  و  $d(i, j) = d(j, i)$  و  $d(i, j) \leq d(i, k) + d(k, j)$ . ارتباط میان دو بنگاه با شباهت یا تضاد میان رفتار بازده سهامشان در طول زمان منعکس می‌شود. مسافت‌های میان  $N$  بنگاه با یک ماتریس مسافت متقارن  $N \times N$  ارائه می‌شود که آن را « $D$ » می‌نامیم. از طریق ماتریس مسافت، ماتریس موزون  $w$  ایجاد شده است که برای نشان‌دادن توپولوژی شبکه پیچیده به کار می‌رود. سهم  $i$  و سهم  $j$  از طریق یک لینک با وزن  $w_{ij}$  به یکدیگر مرتبط هستند؛ بنابراین قوی‌ترین لینک‌ها، سهام با بیشترین مشابهت سری‌های زمانی را به یکدیگر مرتبط می‌کنند (Liu et al., 2019).

$$w_{ij} = \exp(-d_{ij}) \quad \text{رابطه (۴)}$$

در این پژوهش علاوه بر ۹ نسبت مالی، از متغیرهای مبتنی بر شبکه نیز به صورت پیش‌بینی‌کننده‌های درماندگی مالی استفاده می‌شود. براساس کارهای ابتدایی در نظریه اقتصادی و اجتماعی، این پژوهش از چهار معیار مرکزیت شبکه، شامل مرکزیت درجه، مرکزیت بینابینی، مرکزیت نزدیکی و مرکزیت بردار ویژه براساس پژوهش منتشر شده و صادقی (۱۳۹۹) و پژوهش لیو و همکاران بهره

<sup>۱</sup>. Complex financial network

می‌برد (Liu et al., 2019). براساس دیدگاه شنگ و همکاران این معیارهای مرکزیت به‌تنهایی تمام ویژگی‌های شبکه را اندازه‌گیری نمی‌کنند و باید باهم به‌کار روند (Sheng et al., 2019).

یکی از گسترده‌ترین معیارهای مرکزیت، درجه مرکزیت است که به‌صورت تعداد روابط مستقیمی که یک گره معین را دربرمی‌گیرد، تعریف می‌شود. میزان درجه درجایگاه خطر فوری یک گره برای گرفتن هرچه در جریان شبکه وجود دارد (مانند اطلاعات)، تفسیر می‌شود. در تحلیل شبکه‌های موزون، درجه مرکزیت به‌طور کلی به میزان مجموعه‌اوزان گسترده می‌شود. این معیار به‌صورت زیر رابطه‌بندی می‌شود (Liu et al., 2019; Montasheri and Sadeghi, 2020):

$$C_D(v_i) = \sum_{j=1}^N w_{ij} \quad \text{رابطه (۵)}$$

در این رابطه  $w$  ماتریس مجاورت وزنی است که در آن مقدار  $w_{ij}$  وزن مسیر بین گره  $i$  و گره  $j$  است. براساس درجه مرکزیت، گره‌های اصلی در بازار مالی، شناسایی و پارتباط‌ترین و جانبی‌ترین (حاشیه‌ترین) شرکت‌ها در بازار مالی شناخته می‌شوند. یک معیار متداول به‌منظور اندازه‌گیری نفوذ یک گره در شبکه، مرکزیت بردار ویژه است. این معیار، امتیازهای نسبی تمام گره‌ها در شبکه و ارتباط گره‌ها با گره‌های با امتیاز زیاد را نشان می‌دهد که در شبکه بیشترین تأثیر را داشته‌اند. برای یک شبکه معین  $G = (V, E)$  با  $|V|$  تعداد گره‌های مشخص.  $A = (a_{ij})$  ماتریس مجاورتی است؛ جایی که  $a_{ij} = w_{ij}$  اگر گره  $i$  با گره  $j$  ارتباط داشته باشد و در غیر این صورت  $v_{ij} = 0$  است. مرکزیت نسبی گره به‌صورت زیر تعریف می‌شود (Liu et al., 2019; Montasheri and Sadeghi, 2020):

$$x_i = \frac{1}{\lambda} \sum_{t \in M(i)} x_t = \frac{1}{\lambda} \sum_{t \in G} a_{it} x_t \quad \text{رابطه (۶)}$$

در اینجا  $M(i)$  یک مجموعه از همسایه‌های  $i$  و  $\lambda$  یک مقدار ثابت است. با یک بازآرایی مختصر آن رابطه به‌صورت معادله بردار ویژه بازنویسی می‌شود.

$$Ax = \lambda x \quad \text{رابطه (۷)}$$

در کل، مقادیر ویژه بسیار متفاوتی وجود خواهد داشت و برای هر مقدار ویژه غیرصفر راه حل وجود دارد. الزامات بیشتری است که تمام ارزش‌ها در مقادیر ویژه باید نامنفی باشد تا تنها بیشترین مقادیر ویژه به اندازه‌گیری مرکزیت دلخواه منجر شود. با دنبال کردن شیوه بالا اندازه‌گیری می‌کنند چگونه یک شرکت در شبکه مالی پیچیده و به‌هم مرتبط جای گرفته است. هرچه مرکزیت بردار ویژه بیشتر باشد، شرکت در شبکه در جایگاه مرکزی تری قرار گرفته است. تعامل بین دو گره غیر مجاور به گره‌هایی که در مسیر بین دو گره قرار گرفته‌اند، بستگی دارد. قرارگیری بینابینی گره‌ها به‌طور بالقوه کنترل روی تعاملات میان دو گره غیر مجاور را به‌دنبال خواهد داشت. بینابینی براساس مفهوم مسیرهای شبکه ایجاد شده است. نیومن در سال 2007 یک مسیر در یک شبکه را به‌صورت پیامد پیمودن گره‌ها با دنبال کردن ارتباطات از یک گره به گره دیگر در طی شبکه تعریف می‌کند. یک مسیر، کوتاه‌ترین مسیر در شبکه از یک گره به گره دیگر است (کوتاه‌ترین خط ترسیم‌شده بین دو نقطه). بینابینی یک گره با نسبتی از کوتاه‌ترین مسیرها بین جفت گره‌هایی که از این گره عبور کردند، محاسبه می‌شود. فریمن شاخص مرکزیت بینابینی را از نظر ریاضی به‌صورت زیر تعریف کرده است (Freeman, 1977):

$$C_B(v_i) = \frac{\sum_{j \neq i} \sigma_{ji}(v_i)}{\sigma_{ji}} \quad \text{رابطه (۸)}$$

در این رابطه  $\sigma_{ji}$  کل تعداد کوتاه‌ترین مسیرها از گره  $j$  به گره  $i$  و  $\sigma_{ji}$  تعداد کوتاه‌ترین مسیرهایی است که از طریق گره  $j$  عبور کرده‌اند. مرکزیت بینابینی براساس این مفهوم ساخته شده است که یک گره مرکزی محسوب می‌شود، اگر نیاز باشد با جفت گره‌های دیگر



مرتبط باشد. شرکت با مرکزیت بینابینی زیاد تأثیر مهمی بر شرکت‌های دیگر دارد؛ زیرا اطلاعاتی را که از آن عبور می‌کند، متوقف یا تحریف می‌کند.

مرکزیت نزدیکی نشان می‌دهد یک گره تا چه اندازه به سایر گره‌ها نزدیک است؛ به عبارت دیگر، تعداد گام‌هایی که طول می‌کشد از یک گره خاص به گره دیگری در شبکه رسید. هرچه مقدار مرکزیت نزدیکی یک گره بیشتر باشد، انتشار اطلاعات از این گره به گره‌های دیگر سریع‌تر خواهد بود. مقدار مرکزیت نزدیکی بیشتر برای یک گره به این معناست که آن گره در کوتاه‌ترین فاصله ممکن برای اتصال به گره‌های دیگر قرار گرفته است و بنابراین از قابلیت دسترسی خوبی در شبکه بهره می‌برد. برای اندازه‌گیری مرکزیت نزدیکی از رابطه زیر استفاده می‌شود که در این رابطه  $d_{ij}$  کوتاه‌ترین فاصله میان گره  $i$  و  $j$  است. اگر گره  $i$  به طور مستقیم به تمام گره‌ها وصل باشد، این معیار برابر با ۱ خواهد شد (Comin et al., 2020).


$$C_c(i) = \sum_{j \neq i}^N \frac{1}{d_{ij}} \quad \text{رابطه (۹)}$$

بهینه‌ساز گرگ خاکستری، یک الگوریتم فراابتکاری موفق مبتنی بر جمعیت است که بر مبنای زندگی اجتماعی گرگ‌ها طراحی شده است (Zhou et al., 2014). این سبک زندگی به طور معمول به سلسله مراتب رهبری وابسته است و رفتارهای مشارکتی شکار در واقع اصلی‌ترین عامل الهام‌بخش این الگوریتم الهام‌گرفته از طبیعت است (Heidari & Aliabbaspour, 2016). در نسخه اصلی بهینه‌ساز گرگ خاکستری، هر گروه یک چینش سلسله‌مراتبی دارد و هرکدام از اعضای گروه باید وظیفه‌ای در جایگاه یک عضو گروه داشته باشند (Niu et al., 2016). برای شکار کردن، رهبر یا رهبران خاصی که اعضای رده بالا هستند، هر گرگ را هدایت می‌کنند. رتبه بندی گرگ‌ها بر مبنای توانایی ذهنی‌شان مانند هوشیاری و سرپرستی انجام می‌شود، نه بر مبنای قابلیت‌های جسمانی؛ بنابراین سه گرگی که شناخت بهتری از مکان احتمالی طعمه دارند، به ترتیب با عناوین «آلفا، بتا و دلتا» شناخته می‌شوند و اعضای دیگر را هدایت می‌کنند. مراحل شکار شامل محاصره و حمله کردن به طعمه است. سپس هر گرگ باید مکان کنونی خود را با توجه به موقعیت رهبران در تمام مراحل شکار تغییر دهد. همانند بهینه‌سازهای دیگر الهام‌گرفته از طبیعت، در مرحله اول بهینه‌ساز گرگ خاکستری برخی از جواب‌های احتمالی به صورت تصادفی در چشم انداز فضایی جست‌وجو پراکنده می‌شوند. در تمام تکرارها، سه جواب برتر با عناوین «آلفا، بتا و دلتا» شناخته می‌شوند. این عامل‌های رهبر طراحی شده اند تا عوامل دیگر را در جهت شناخت مکان‌های بهتر در فضای هدف هدایت کنند. بقیه جواب‌ها را «امگا» می‌نامند. این گرگ‌ها تلاش می‌کنند مکان‌های خود را با توجه به قانون زیر تغییر دهند.

$$D = |C \cdot X_p(t) - X(t)| \quad \text{رابطه (۱۰)}$$

$$X(t+1) = X_p(t) - A \cdot D \quad \text{رابطه (۱۱)}$$

جایی که  $t$  عدد تکرار است و  $a = 2 - (2 * \frac{t}{T})$ ،  $A = 2ar_1 - a$ ،  $C = 2r_2$  شاخصی است که از دو به صفر کاهش می‌یابد.  $X_p$  و  $X$  به ترتیب مکان‌های طعمه و گرگ‌ها و  $T_1$  و  $T_2$  مقادیر تصادفی در  $[0,1]$  هستند. برای اینکه به شناخت روشنی از اثرات معادلات اشاره شده برسیم، بردار موقعیت عامل‌های جست‌وجو و مجموعه‌ای از همسایگان‌شان در شکل (۱) نشان داده شده است. این طرح‌ها نشان می‌دهد گرگ‌ها به موقعیت‌های گوناگون نزدیک طعمه با تغییر دادن مقادیر بردارهای  $A$  و  $C$  می‌رسند. علاوه بر این، بردارهای تصادفی  $T_1$  و  $T_2$  در طول دوره تکرار به‌روزرسانی می‌شوند تا به گرگ کمک کند به هر نقطه در میان نقاط ترسیم‌شده در شکل (۱) برسد.



شکل (۱) جایگاه‌های شکارچیان نزدیک طعمه (Heidari & Aliabbaspour, 2016)

Figure (1) The positions of the hunters near the prey (Heidari & Aliabbaspour, 2016)

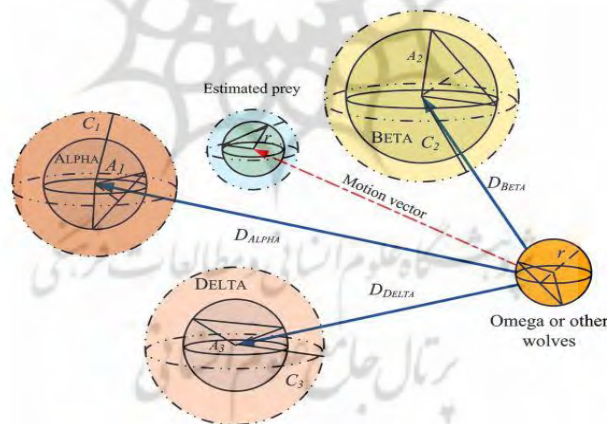
گرگ‌های امگا رهبرانشان را به صورت زیر دنبال می‌کنند:

$$D_\alpha = |C_1 \cdot X_\alpha(t) - X(t)| \quad D_\beta = |C_2 \cdot X_\beta(t) - X(t)| \quad D_\delta = |C_3 \cdot X_\delta(t) - X(t)| \quad \text{رابطه (۱۲)}$$

$$X_1 = X_\alpha - A_1 \cdot D_\alpha \quad X_2 = X_\beta - A_2 \cdot D_\beta \quad X_3 = X_\delta - A_3 \cdot D_\delta \quad \text{رابطه (۱۳)}$$

$$X_n = \overline{0.33} \left( \sum_{i=1}^3 X_i \right) \quad \text{رابطه (۱۴)}$$

جایی که  $X_\alpha, X_\beta, X_\delta$  به ترتیب موقعیت‌های آلفا، بتا و دلتا هستند.  $C_3, C_2, C_1$  سه برداری هستند که به صورت تصادفی ایجاد شده‌اند و  $X(t)$  جواب کنونی است. بردار حرکت سه بعدی شکارچیان در شکل (۲) نشان داده شده است.



شکل (۲) بردار حرکت سه بعدی گرگ‌ها (Heidari & Aliabbaspour, 2016)


Figure (2) 3D motion vector of wolves (Heidari & Aliabbaspour, 2016)

همان طور که میرجلیلی و همکاران و حیدری و پهلوانی بیان کردند، دو شاخص  $A$  و  $C$  به رویکرد بهینه گرگ خاکستری کمک می‌کند تا چشم‌انداز مسئله را کشف و بهره‌برداری کند (Mirjalili et al., 2014; Heidari & Pahlavani, 2017). با کاهش  $A$ ، ۵۰ درصد فرآیند بهینه‌سازی به کشف و بهره‌برداری اختصاص می‌یابد. با وجود این، زمانی که  $|A| > 1$  باشد، بهینه‌ساز گرگ خاکستری کشف می‌کند و زمانی که  $|A| < 1$  باشد، فضای عینی را بهره‌برداری می‌کند. بردار  $C$  در مقایسه با  $A$  موقتی نیست و وزن دهی‌های تصادفی انتخاب شده را در  $[0, 1]$  دارد. این بردار به بهینه‌ساز گرگ خاکستری کمک می‌کند تا رفتارهای تصادفی سازی شده بیشتری را در سراسر جست‌وجو نشان دهد و برای مشکل توقف در بهینه محلی مفید است. کارآمدی بهینه‌ساز گرگ خاکستری در مواجهه با شرایط مختلف ثابت شده است. با وجود این، حیدری و علی عباس‌پور بیان کرده‌اند بهینه‌ساز ابتدایی گرگ خاکستری

ممکن است در زمانی که با برخی از موقعیت‌های پیچیده دنیای واقعی مواجه می‌شود، در تله بهینه محلی گیر بیفتند. این نقطه ضعف به دلیل اکتشاف نکردن گسترده در مقابله با برخی از چشم‌اندازهای برازش تقریبی است؛ بنابراین اشکال اول درباره ضریب همگرایی بود که در الگوریتم پایه با نام متغیر  $a$  شناخته می‌شود. اشکال دوم درباره شیوه راهکار تعیین موقعیت جدید یک گرگ است که به صورت میانگین حرکت سه گرگ آلفا، بتا و دلتا تعیین می‌شود. از منظر الهام گرفتن از طبیعت، مشاهده می‌شود برخی از گرگ‌هایی که در یک شکار مشارکتی واقعی شرکت می‌کنند، نه تنها موقعیت شکارچیان پیشگام را در نظر می‌گیرند، به احساسات، رفتارها و تغییر تصادفی در آرایش و چینش گرگ‌های دیگر نیز واکنش نشان می‌دهند. پس برای بهبود الگوریتم گرگ خاکستری دو اصلاح در این الگوریتم ضروری است: اول تغییر ضریب همگرایی و دوم تغییر در معادله محاسبه جدید موقعیت هر گرگ. با وجود این، این نسخه جدید باید مزایای نسخه ابتدایی بهینه ساز گرگ خاکستری را نیز داشته باشد. ضریب همگرایی  $a$  در الگوریتم GWO به صورت خطی از ۲ تا ۰ متغیر است. در این پژوهش و در الگوریتم گرگ خاکستری بهبودیافته<sup>۱</sup>، معادله ضریب همگرایی به ترتیب زیر برای تعادل بهتر بین اکتشاف و بهره برداری تغییر یافته است (Heidari & Aliabbaspour, 2016)

$$a = 2 * (1 - (\frac{t - 1}{t_{max} - 1})^{1.5}) \quad \text{رابطه (۱۵)}$$

در معادله بالا، عامل همگرایی  $a$  به شکل یک تغییرنمایی توصیف شده است؛ همان‌طور که در شکل ۳ نشان داده شده است. در الگوریتم اصلی گرگ خاکستری، نیمی از تکرارها برای اکتشاف و نیمی دیگر به بهره برداری اختصاص داده شده است. با استفاده از ضریب همگرایی اصلاح شده، تعداد بیشتری از تکرارها برای اکتشاف استفاده می‌شود که برای جلوگیری از گرفتار شدن در بهینه‌های محلی مفید است. با استفاده از این نوع ضریب همگرایی غیرخطی، درصد تکرارهای به کاررفته برای اکتشاف و بهره‌برداری به ترتیب تقریباً ۶۰ و ۴۰ درصد است.



شکل (۳) تأثیر تغییر ضریب همگرایی در اکتشاف و استخراج (Heidari & Aliabbaspour, 2016)

Figure (3) The effect of changing the convergence coefficient in exploration and extraction

موقعیت جدید هر گرگ در الگوریتم پایه بر اساس موقعیت سه گرگ آلفا، بتا و دلتا مشخص می‌شود. رابطه ۱۳ نشان‌دهنده موقعیت جدید گرگ آلفا، بتا و دلتا است. موقعیت جدید یک گرگ امگا از میانگین موقعیت سه گرگ دیگر با توجه به رابطه ۱۴ به دست می‌آید. اشکال این معادله در نگاه یکسان به موقعیت سه گرگ اصلی یعنی آلفا، بتا و دلتا است؛ چراکه از میانگین موقعیت این سه گرگ موقعیت جدید گرگ امگا به دست می‌آید، درحالی‌که این نگرش به دور از موقعیت اجتماعی در گله گرگ‌ها است. در روش بهبودیافته، الگوریتم انتخاب موقعیت گرگ امگا بر اساس درصد برتری سه گرگ با توجه به هرم سلسله مراتب اعمال می‌شود؛ یعنی موقعیت جدید گرگ امگا بر اساس یک وزن منطبق بر سلسله مراتب به دست می‌آید که درصد بیشتری از گرگ آلفا و درصد کمتری از

<sup>1</sup>. Improved Grey Wolf Optimizer

دو گرگ دیگر داشته باشد. به این ترتیب گرگ امگا درصدهای متفاوتی از سه گرگ با توجه به سلسله مراتبشان به دست می آورد (Heidari & Aliabbaspour, 2016). بر همین اساس گروه پژوهش برای شناسایی موقعیت جدید گرگ، رابطه (۱۶) را پیشنهاد کرده‌اند:

$$X_n = 0.5X_1 + 0.35X_2 + 0.15X_3 \quad \text{رابطه (۱۶)}$$

برای ارزیابی عملکرد بهینه‌سازی الگوریتم گرگ خاکستری بهبودیافته نیز از دو تابع تست<sup>۱</sup> راست ریجین<sup>۲</sup> و تابع قلمرو<sup>۳</sup> استفاده شده است. در ریاضیات کاربردی توابع تست ابزارهای سودمندی هستند که برای ارزیابی ویژگی‌هایی مانند نرخ همگرایی<sup>۴</sup>، دقت<sup>۵</sup>، ثبات<sup>۶</sup> و عملکرد کلی الگوریتم‌های بهینه‌سازی استفاده می‌شوند.

تقویت گرادیان یک روش یادگیری ماشین برای مسائل رگرسیون و طبقه بندی است. الگوی تقویت گرادیان ترکیبی خطی از یک سری الگوهای ضعیف است که به صورت تناوبی برای ایجاد یک الگوی نهایی قوی ساخته شده است. این روش به خانواده الگوریتم‌های یادگیری گروهی تعلق دارد و عملکرد آن همواره از الگوریتم‌های اساسی یا ضعیف مثل درخت تصمیم یا روش‌های براساس کیسه گذاری مانند جنگل تصادفی بهتر است، اما درستی این گزاره تا حدی از مشخصات داده‌های ورودی تأثیر می‌پذیرد. مانند روش‌های دیگر تقویتی (بوستینگ)، تقویت گرادیان ترکیبی خطی از یک سری از الگوهای ضعیف برای ایجاد یک الگوی قوی و کارآمد است. تقویت گرادیان از روش ارتقا استفاده می‌کند؛ این روش از روش درخت تصمیم وام گرفته است. یادگیرنده‌های ضعیف موجود بعد از دریافت وزن بیشتر، به درخت بعدی منتقل می‌شوند تا پیش بینی‌های هر درخت از درخت قبلی بهتر باشد. خروجی، میانگین پیش‌بینی‌های نهایی است. الگوریتم تقویت گرادیان زمانی استفاده می‌شود که داده‌های زیاد با پیش‌بینی‌های زیاد داریم. تفاوت بین ارزش پیش‌بینی شده و ارزش واقعی با تابع زیان اندازه‌گیری می‌شود. در مجموع، روش‌های بوستینگ برای نزدیک شدن به جواب از رویکرد الگوسازی مرحله‌ای پیش‌رو استفاده می‌کنند. الگوهای اساسی جدید بدون تغییر شاخص‌ها یا ضرائب الگو به الگوی ترکیبی قبلی اضافه می‌شوند. این نوع از روش بوستینگ مکانیسم کاهش گرادیان را به صورت هدف بهینه‌سازی الگو به کار می‌برد. در روش بوستینگ گرادیان، جداسازهای اساسی جدید به منظور کاهش گرادیان منفی تابع زیان، ساخته می‌شوند (Liu et al., 2019).

فریدمن با استفاده از یک درخت رگرسیون با اندازه ثابت به صورت الگوی پایه یک، شکل اصلاح یافته از روش افزایش گرادیان را پیشنهاد کرد که روش «درخت تصمیم تقویت گرادیان» نامیده می‌شود (Friedman, 2001). نسخه اصلاح شده، کیفیت الگو را بهبود بخشید. در این پژوهش نسخه اصلاح شده الگوی GBM<sup>۷</sup> برای پیش‌بینی درماندگی مالی استفاده می‌شود. با فرض اینکه تعداد برگ‌های هر درخت S است. هر درخت فضای ورودی را به S منطقه جدا شده  $R_{1m}, R_{2m}, \dots, R_{sm}$  تقسیم می‌کند و یک مقدار ثابت  $b_{sm}$  را برای منطقه  $R_{sm}$  پیش‌بینی می‌کند. درخت رگرسیون به صورت زیر بیان می‌شود (Liu et al., 2019):

$$g_m(x) = \sum_{s=1}^S b_{sm} I(x \in R_{sm}) \quad \text{رابطه (۱۷)}$$

$$I(x \in R_{sm}) = \begin{cases} 1, & \text{اگر } x \in R_{sm} \\ 0, & \text{در غیر صورت این} \end{cases} \quad \text{در آن}$$

1. Test Function  
 2. Rastrigin Function  
 3. Sphere Function  
 4. Convergence Rate  
 5. Accuracy  
 6. Robustness  
 7. Gradient Boosting Model

الگوی به‌روزرسانی معادله و اندازه مرحله کاهش شیب به‌صورت زیر نشان داده می‌شود:

$$f_m(x) = f_{m-1}(x) + p_m g_m(x) \quad \text{رابطه (۱۸)}$$

$$p_m = \operatorname{argmin}_p \sum_{i=1}^n L(y_i, f_{m-1}(x_i) + p g_m(x_i)) \quad \text{رابطه (۱۹)}$$

با استفاده از یک درخت رگرسیون برای جایگزینی  $g_m(x_i)$  در روش تقویت گرادیان، دو معادله قبلی به رابطه زیر تبدیل می‌شوند:

$$f_m(x) = f_{m-1}(x) + J \sum_{s=1}^S p_m b_{sm} I(x \in R_{sm}) \quad \text{رابطه (۲۰)}$$

$$p_m = \operatorname{rgmin}_p \sum_{i=1}^n L(y_i, f_{m-1}(x_i) + \sum_{s=1}^S p b_{sm} I(x \in R_{sm})) \quad \text{رابطه (۲۱)}$$

الگوی GBM به‌طور راهبردی هر الگوی پایه را به‌منظور کاهش یک تابع زیان معین اضافه می‌کند. سه شاخص اصلی ارائه‌شده در GBDT عبارتند از: نرخ یادگیری  $J$ ، عمق درخت  $D$  و تعداد درختان  $N$ . شاخص اول یعنی نرخ آموزش، سهم هر الگوی درخت را در الگوی ترکیبی تعیین می‌کند. به‌طور کلی، یک مبادله بین تعداد درختان و میزان یادگیری وجود دارد. مقدار کوچک‌تر  $J$  معمولاً نیاز دارد تعداد بیشتری درخت اضافه شود. دومین شاخص، عمق درخت، بیشترین عمق درخت را نشان می‌دهد. به‌صورت یک قاعده کلی، مقدار بیشتر  $D$  به آموزش دانش بیشتر درباره مسئله در یک مجموعه داده بزرگ کمک می‌کند، در غیر این صورت، مقدار کوچک  $D$  برای مجموعه داده کوچک ترجیح داده می‌شود. آخرین شاخص،  $N$ ، تعداد درختانی است که به الگو اضافه می‌شود. در مقایسه با بیشتر رویکردهای هوش مصنوعی، GBM در مواقعی نظیر پیش‌بینی و الگوسازی هزینه زیان بیمه خودروها (Guelman, 2012)، پیش‌بینی بار (Taieb & Hyndman, 2014) و پیش‌بینی زمان سفر (Zhang & Haghani, 2015) به‌بهبود عملکرد در شناسایی الگو و برآورد رگرسیون منجر می‌شود (Liu et al., 2019).

### پیشینه تجربی

در این بخش نتایج برخی از پژوهش‌های مرتبط به‌صورت اجمالی بررسی شده است. بیشتر مطالعات داخلی که با نگاه شبکه‌های پیچیده به بازار مالی ایران توجه کرده‌اند بیشتر در حوزه‌های گونه‌شناسی و توپولوژی بازار سهام (Montasheri and Sadeghi, 2021)، سنجش و مدیریت ریسک سیستماتیک و انتخاب پرتفوی سهام (Raei, et al., 2010; Fallahpiour and Ghahremani, 2021; Sedaghati, et al., 2021) بوده است.

علی‌بابایی و خان محمدی (۱۴۰۲) با هدف پیش‌بینی ورشکستگی شرکت‌ها با استفاده از سازوکار حاکمیت شرکتی و نسبت‌های مالی، داده‌های شرکت‌های فعال در بورس اوراق بهادار تهران را طی دوره ۸۶ تا ۹۵ تحلیل کردند. پژوهش آنها براساس الگوی بومی‌شده کردستانی - تاتالی مبتنی بر الگوی آلتمن است. آنها با استفاده از سه الگوی شبکه عصبی،  $K$  نزدیک‌ترین همسایه و الگوی ترکیبی الگوریتم ژنتیک و شبکه عصبی فرضیه‌های خود را بررسی کردند. نتایج آنها نشان داد اضافه‌شدن متغیرهای حاکمیت شرکتی به شاخص‌های مالی باعث بهبود در نتایج پیش‌بینی ورشکستگی نشده است. الگوی ترکیبی شبکه عصبی و الگوریتم ژنتیک بیشترین دقت را در پیش‌بینی ورشکستگی داشته‌اند. الگوی  $K$  نزدیک‌ترین همسایه در تمام شاخص‌های ارزیابی الگو نسبت به رقبای خود عملکرد ضعیف‌تری داشته است.

رادووانوویچ و هاس با هدف ارزیابی الگوهای پیش‌بینی ورشکستگی براساس معیار هزینه‌های اقتصادی و اجتماعی پژوهش خود را انجام دادند. داده‌های آنها واقعی و از پایگاه کامپوست بوده که دربرگیرنده شرکت‌های پذیرفته‌شده در بورس آمریکای شمالی طی



سال‌های ۱۹۸۵ تا ۲۰۲۰ و در مجموع ۱۹۰ هزار سال شرکت است. آنها الگوهای مبتنی بر یادگیری ماشین را با الگوهای پرکاربرد آماری مقایسه کردند. نتایج نشان داد الگوهای یادگیری ماشین شامل درخت تصمیم تقویتی و دسته بندی، جنگل تصادفی، شبکه عصبی و ماشین بردار پشتیبان در مقایسه با الگوهای رگرسیون لجستیک و تحلیل تفکیکی خطی، عملکرد بهتری داشته‌اند (Radovanovic & Haas, 2023).

آیدین و همکاران شرکت‌های فعال در بخش‌های تولید، خدمات و بازرگانی را در بورس استانبول طی سال‌های ۲۰۱۵ تا ۲۰۱۷ طبقه بندی کردند. آنها با استفاده از دو روش شبکه عصبی مصنوعی و درخت تصمیم و ارائه الگوهای جداگانه برای هر بخش و با استفاده از ۲۵ نسبت مالی و ۲ متغیر غیر مالی فرضیه‌های خود را بررسی کردند. نتایج آنها نشان‌دهنده سرعت پردازش زیادتر و دقت بیشتر روش شبکه عصبی مصنوعی در مقایسه با روش درخت تصمیم است. الگوی شبکه عصبی مصنوعی با خطای نزدیک به صفر، شرکت‌های ورشکسته و غیرورشکسته را از یکدیگر تفکیک کرد (Aydin et al., 2022).

علی بابایی و خان محمدی با هدف بررسی قدرت پیش‌بینی‌کنندگی الگوریتم‌های فراابتکاری برای پیش‌بینی ورشکستگی، ۶ الگوریتم فراابتکاری را شامل الگوریتم گرانشی، گرگ خاکستری، ژنتیک، رقابت استعماری، نهنگ و تکامل تدریجی باهم مقایسه کردند. آنها با ترکیب این الگوریتم‌ها با شبکه عصبی مصنوعی و استفاده از نسبت‌های نقدشوندگی، سودآوری و ساختار سرمایه، نشان دادند به جز الگوی گرانش، تقریباً تمام الگوها، عملکرد مشابهی با یکدیگر داشته‌اند. البته عملکرد الگوی الگوریتم ژنتیک کمی از بقیه الگوها بهتر بوده و دقتی حدود ۸۶ درصد داشته است (Alibabae & Khanmohammadi, 2022).

علی اکبرلو و همکاران (۱۳۹۹) در پژوهشی با عنوان «مقایسه معیارهای تشخیص شرکت‌های درمانده مالی با استفاده از رگرسیون لجستیک و هوش مصنوعی» با تحلیل داده‌هایی بین سال‌های ۲۰۰۵ تا ۲۰۱۷ به این نتیجه دست یافتند که معیار آسکویت و همکاران (Asquith et al., 1994) در مقایسه با سه معیار ماده ۱۴۱ قانون تجارت، الگوی آلتمن ۱۹۹۵ و الگو آلتمن ۱۹۶۸ (Altman, 1968)؛ (Altman et al., 1995) میانگین پیش‌بینی صحیح‌تری را ارائه می‌دهد.

قلی زاده و همکاران (۱۳۹۸) با استفاده از الگوی یادگیری ماشین سریع مبتنی بر کرنل بهینه‌شده با الگوریتم گرگ خاکستری، ورشکستگی ۱۳۶ شرکت بوری را در بازه زمانی ۲۰۱۵ تا ۲۰۱۹ پیش‌بینی کردند. آنها ضمن مقایسه عملکرد الگوها با الگوریتم ژنتیک به این نتیجه رسیدند الگوریتم گرگ خاکستری در تمام معیارهای ارزیابی مانند دقت، خطاهای نوع اول و دوم و ناحیه زیر منحنی ROC، کارایی بهتری دارد.

ناظمی و همکاران (۱۳۹۷) در پژوهشی به دنبال تبیین الگویی بودند که ورشکستگی صنایع خودرو و قطعات، محصولات شیمیایی و محصولات غذایی به جز قند و شکر را به خوبی پیش‌بینی کند. بر اساس همین با استفاده از الگوی درخت تصمیم و به کمک معیار ماده ۱۴۱ قانون تجارت برای پیش‌بینی ورشکستگی و تحلیل داده‌هایی بین سال‌های ۲۰۰۰ تا ۲۰۱۲ برای هر صنعت الگویی طراحی کردند که به ترتیب با دقت ۹۵/۹۵، ۹۶/۸۳ و ۹۷/۸۳ درصد، ورشکستگی شرکت‌های صنایع ذکر شده را پیش‌بینی کرد. نتایج سایر پژوهش‌های داخلی و خارجی که بررسی شده، در جدول شماره (۱) ارائه شده است.

جدول (۱) نتایج برخی از پژوهش‌های داخلی و خارجی بررسی شده

Table (1) The results of some internal and external researches have been reviewed

پژوهشگران (سال)	موضوع	الگو/ متغیرهای اصلی	جامعه آماری و روش گردآوری و تحلیل یافته‌های پژوهش
Marso & El Merouani (2020)	پیش‌بینی درماندگی مالی با استفاده از شبکه عصبی پیش‌خوراند ترکیبی و الگوریتم	اطلاعات مختلفی شامل متغیرهای مالی، سیاسی و اقتصاد کلان	داده‌های بنگاه‌های تولیدی کشور لهستان و بازارهای نوظهور شبکه عصبی پیش‌خوراند، الگوریتم جست‌وجوی درحالی‌که الگوهای شبکه عصبی پس انتشار و رگرسیون لجستیک در یک‌سال قبل

از ورشکستگی دقت ۸۲/۱۵ و ۸۸/۳۳ درصدی داشته‌اند. در سه سال قبل از ورشکستگی نیز دقت الگوی فاخته از دو الگوی دیگر بالاتر بود.	جست‌وجوی فاخته		
سهام مخابرات ایران و بانک آینده بر اساس معیار درجه مرکزیت بیشترین تأثیر را بر شبکه مالی و بازار سهام دارند.	اطلاعات مالی مربوط به ۱۰۰ شرکت برتر (2009-2019)	بازده قیمتی لگاریتمی / درجه مرکزیت	گونه‌شناسی شبکه‌های مالی براساس ویژگی‌های مکان شناختی آنها
شبکه عصبی، ماشین بردار پشتیبان و یادگیری تصدیق‌شده در کنار الگوریتم‌های رقابت استعماری، الگوریتم فرهنگی و جست‌وجوی هارمونی	نسبت‌های مالی شامل سود انباشته به کل دارایی، سود عملیاتی به کل دارایی، سود خالص به کل دارایی، کل بدهی به حقوق صاحبان سهام، کل دارایی به حقوق صاحبان سهام، نسبت بدهی، بازده حقوق صاحبان سهام	پیش‌بینی ورشکستگی شرکت‌ها مبتنی بر سیستم‌های هوشمند ترکیبی	متشتری و صادقی (۱۳۹۹)
نتایج نشان داد روش ترکیبی ماشین بردار پشتیبان و روش انتخاب ویژگی پی‌درپی پیشرو شناور از عملکرد بهتری نسبت به الگوی رگرسیون لجستیک برخوردار است.	۱۸۰ شرکت تولیدی بورسی درسال‌های 1996 تا 2012	۲۹ نسبت مالی	غضنفری و همکاران (۱۳۹۷)
استفاده از متغیرهای شبکه مالی در الگوهای پیش‌بینی ورشکستگی عملکرد گوها را بهبود می‌بخشد.	داده‌های شرکت های بورس چین	۳ معیار شبکه مالی و ۱۶ متغیر مالی	کاربرد روش ترکیبی بردار پشتیبان و روش انتخاب ویژگی پیشرو در پیش‌بینی درماندگی مالی
هیچ ابزاری به‌تنهایی تمام معیارهای لازم را برای پیش‌بینی ورشکستگی ندارد. ارائه چارچوبی برای انتخاب ابزار بر اساس اولویت‌های پژوهش	مقالات ۴۹ ژورنال علمی بین سال های ۲۰۱۰ تا ۲۰۱۵	مقایسه عملکرد ۸ الگوی اصلی پرکاربرد در اصول موضوع	به‌بود پیش‌بینی درماندگی مالی با استفاده از اطلاعات شبکه مالی
روش پیشنهادی هارک در یک و دو سال پیش از وقوع درماندگی مالی نسبت به رگرسیون لجستیک و الگوی آلتمن عملکرد بهتری برخوردار است.	روش هارک، روش تولیدی بورسی در بازه ۲۰۰۱ تا ۲۰۱۱	نسبت‌های مالی	Liu et al. (2019)
			Alaka et al. (2018)
			تاج مزینانی و همکاران (۱۳۹۴)

باید خاطر نشان کرد با وجود بررسی فراوان، پژوهشی داخلی مشاهده نشد که از متغیرهای مبتنی بر شبکه مالی برای پیش‌بینی درماندگی مالی استفاده کرده باشد. این یکی از وجوه تمایز و نوآوری‌های اصلی این پژوهش در قیاس با مطالعات پیشین است. از وجوه تمایز دیگر این پژوهش با مطالعات قبلی در ارتباط با پیش‌بینی درماندگی مالی استفاده نکردن از درخت تصمیم تقویتی و همچنین به‌کارگرفتن الگوریتم گرگ خاکستری بهبود یافته برای تنظیم شاخص‌های درخت تصمیم است.

## روش پژوهش

1. Extreme learning
2. Harmony search
3. Imperialist Competition

این پژوهش بر آن است سنجش‌های مناسبی از شبکه مالی را به کارگیرد تا به شیوه بهتری بنگاه‌های دارای درماندگی مالی و بنگاه‌های دارای سلامت مالی را از یکدیگر متمایز سازد. به منظور پاسخ‌دادن به سؤالات پژوهش از الگوی درخت تصمیم تقویت‌گرادیان که شاخص‌هایش با الگوریتم گرگ خاکستری بهبودیافته بهینه شده است، در کنار متغیرهای شبکه مالی استفاده می‌شود. جامعه آماری این پژوهش تمام شرکت‌های تولیدی پذیرفته‌شده در بورس و فرابورس ایران طی سال‌های ۲۰۱۵ تا ۲۰۲۱ است. البته از بین این شرکت‌ها تنها شرکت‌هایی انتخاب شده‌اند که شرایط مدنظر گروه پژوهش را داشته باشند: سال مالی منتهی به آخر اسفندماه، متعلق‌نبودن به صنایع واسطه‌گری مالی، بانک، بیمه و سرمایه‌گذاری‌ها، تغییر نکردن سال مالی در دوره زمانی مدنظر پژوهش و در دسترس بودن اطلاعاتی که پژوهش به آنها نیاز داشت. در نهایت ۱۲۳ شرکت انتخاب شد. در مجموع ۸۶۱ سال - شرکت وجود داشته که از بین این تعداد ۱۰۴ سال - شرکت درمانده و ۷۵۷ سال - شرکت غیردرمانده است. تعداد سال - شرکت‌هایا درماندگی مالی از سال ۲۰۱۵ تا ۲۰۲۱ به ترتیب برابر با ۸، ۱۸، ۲۰، ۲۰، ۱۷، ۱۱ و ۱۰ است. برای ساخت شبکه مالی و استخراج متغیرهای شبکه مالی به صورت پیش‌بینی کننده، اطلاعات موردنیاز برای محاسبه بازده سهام تمام شرکت‌های عضو نمونه گردآوری شد. با توجه به اینکه آخرین اطلاعات بازار ویژگی‌های اصلی وضعیت مالی شرکت‌ها را بهتر نشان می‌دهد، برای تشکیل متغیرهای مبتنی بر شبکه مالی از اطلاعات آخرین ۳۰ روز معاملاتی در هر سال مالی استفاده شده است.

متغیرهای مستقل به دو بخش متغیرهای مالی و متغیرهای مربوط به شبکه مالی تقسیم می‌شوند. ۸ متغیر مالی بر اساس پژوهش ابراهیمی سروعلیا و همکاران (۱۳۹۷) انتخاب شده است: نسبت جاری، نسبت خالص سرمایه در گردش به کل دارایی‌ها، نسبت دارایی جاری به کل دارایی، حاشیه سود، بازده دارایی، بازده حقوق صاحبان سهام، نسبت ارزش بازار به ارزش دفتری و اندازه شرکت. علاوه بر ۸ متغیر اشاره‌شده، نسبت بدهی کل نیز که یکی از پرکاربردترین متغیرها در سایر پژوهش‌ها بوده است، نیز به متغیرهای مالی افزوده شد. درخصوص متغیرهای شبکه مالی نیز چهار متغیر مرکزیت درجه، مرکزیت بینایی، مرکزیت نزدیکی و مرکزیت بردار ویژه بر اساس پژوهش منتشر شده و صادقی (۱۳۹۹) و لیو و همکاران (Liu et al., 2019) انتخاب شده‌اند که به شیوه اندازه‌گیری آنها در بخش پیشینه نظری اشاره شده است. متغیر وابسته این پژوهش نیز درماندگی مالی است که در مطالعات قبلی مربوط به پیش‌بینی درماندگی مالی، معیارهای مختلفی برای آن پیشنهاد شده است. بر اساس این، در این پژوهش تنها از یک معیار برای سنجش درماندگی مالی استفاده نشده و هر شرکتی که دست‌کم یکی از این چهار ویژگی‌های را داشته باشد، در آن سال درمانده لحاظ شده است: مشمول ماده ۱۴۱ قانون تجارت باشد؛ سه سال متوالی زیان داشته باشد (Damoori, D., Hozhabrie, 2019)؛ مشمول ماده ۴۱۲ قانون تجارت باشد که این قانون به حالتی اشاره دارد که نسبت بدهی بزرگ‌تر از یک باشد (Pourheydari and Koopaei, 2010)؛ حقوق صاحبان سهامش منفی باشد (González-Bravo & Mecaj, 2011).

در رابطه با مراحل اجرای پژوهش باید گفت که ابتدا با استفاده از اطلاعات درج‌شده در صورت‌های مالی، نسبت‌های مالی مدنظر محاسبه شده است. همچنین به منظور محاسبه متغیرهای مربوط به شبکه مالی، بازده قیمتی سهام مختلف به صورت لگاریتمی و از روی قیمت تعدیل‌شده سهام و سپس ضریب همبستگی میان بازده سهام مختلف محاسبه شد. آن‌گاه با کمک رابطه ۳، ماتریس فاصله میان سهام مختلف تشکیل یافت و از آن به صورت ورودی گراف برای تشکیل کمینه درخت پویا با کمک الگوی پرایم استفاده شد. همچنین محاسبه شاخص‌های مورد نیاز برای ورود به الگوی درخت تصمیم تقویت‌گرادیان با استفاده از تکنیک بهینه ساز گرگ خاکستری بهبود یافت و با کمک نرم‌افزار پایتون<sup>۱</sup> نسخه ۳،۱۱ و دو نوت‌بوک جویپتر<sup>۲</sup> و اسپایدر<sup>۳</sup> انجام شده است. علاوه بر کتابخانه‌های پانداس<sup>۴</sup>، نامپای<sup>۱</sup>، متپلات لیب<sup>۲</sup>، سوارم‌لیب<sup>۳</sup> و نتورک‌ایکس<sup>۴</sup> در پایتون، از کتابخانه سایکیت لرن<sup>۵</sup> نیز بسیار استفاده شده است. تمام بسته‌ها، ماژول‌ها و توابعی که در این پژوهش استفاده شده، در جدول (۲) ارائه شده است.

1. Python  
2. Jupyter  
3. Spyder  
4. Pandas

جدول (۲) بسته‌ها و توابع استفاده شده در کتابخانه سایکیت لرن

Table (2) Packages and functions used in the scikit Learn library

نام بسته اصلی	نام بسته فرعی	هدف
sklearn.preprocessing	MinMaxScaler	پیش‌پردازش داده‌ها و استاندارد کردن آنها
sklearn.model_selection	train_test_split	انتخاب الگو و تفکیک داده‌های آموزش و تست
sklearn.feature_selection	mutual_info_classif	انتخاب ویژگی و محاسبه بهره اطلاعاتی متغیرها
sklearn.linear_model	LogisticRegression	الگوهای خطی و انجام رگرسیون لجستیک
sklearn.neighbors	KNeighborsClassifier	انجام الگوی طبقه‌بندی نزدیک‌ترین همسایه
sklearn.ensemble	GradientBoostingClassifier	انتخاب الگوی جمعی و درخت تصمیم تقویت‌گرایان
sklearn.metrics	roc_auc_score	ارائه معیارهای ارزیابی الگو
sklearn.metrics	classification_report, confusion_matrix	ارائه و ترسیم ماتریس درهم‌ریختگی
sklearn.metrics	roc_curve	ترسیم منحنی ROC
sklearn.Model_selection	cross_val_score	انتخاب الگو و انجام اعتبارسنجی طبقه‌ای
sklearn.Model_selection	GridSearchCV	انتخاب الگو و تعیین هاپرپارامترها به روش جست‌وجوی شبکه‌ای

در نهایت الگوها اجرا و معیارهای ارزیابی عملکرد الگوهای پیش‌بینی درماندگی مالی محاسبه می‌شود. در پژوهش‌هایی که با هدف طبقه‌بندی انجام می‌شود، استفاده از معیارهای مناسب ارزیابی عملکرد بسیار اهمیت دارد و در صورتی که معیارهای مقایسه عملکرد الگوهای مختلف به خوبی انتخاب نشوند، نتایج و یافته‌های بسیار گمراه‌کننده همراه دارد. این موضوع زمانی بیشتر اهمیت پیدا می‌کند که نسبت میان کلاس‌های نمونه پژوهش بسیار متفاوت باشد؛ برای مثال در این پژوهش نمونه مربوط به شرکت‌های سالم بیش از ۷ برابر نمونه مربوط به شرکت‌های درمانده است (۷۵۷ سال شرکت در مقابل ۱۰۴ سال شرکت). این احتمال وجود دارد که به دلیل این تفاوت در تعداد کلاس‌ها، ارزیابی اشتباه صورت گیرد. با توجه به اینکه در این پژوهش شرکت‌های سالم، مثبت در نظر گرفته شده و شرکت‌های درمانده، منفی است و از آنجاکه تعداد شرکت‌های سالم بیش از ۷ برابر شرکت‌های درمانده است، بنابراین این احتمال وجود دارد که در ماتریس درهم‌ریختگی<sup>۶</sup> تعداد مثبت‌های واقعی (TP) یا مثبت‌های درست (شرکت‌های سالمی که به‌درستی، سالم پیش‌بینی شده‌اند) چندین برابر منفی‌های واقعی (TN) یا منفی‌های درست (شرکت‌های درمانده‌ای که به‌درستی درمانده پیش‌بینی شده‌اند) باشد. همین موضوع باعث می‌شود تمام معیارهایی که در صورت آنها از TP استفاده شده است، مقدار زیادی از خود نشان دهند و این باعث ایجاد گمراهی در نتایج خواهد شد. با توجه به مباحث اشاره‌شده، در چنین حالت‌هایی مقدار دقت الگو (ACCURACY) و مقدار سطح زیر منحنی ROC و تمام معیارهایی که در صورت کسر آنها از TP استفاده شده باشد، مقادیر زیادی نشان می‌دهند که در واقعیت می‌توانند گمراه‌کننده باشند. اگرچه امکان دارد دقت الگو در مواقع مذکور گزارش شود، ولی این زیادبودن بیشتر به دلیل عملکرد الگو در پیش‌بینی درست شرکت‌های سالم بوده است و نه لزوماً در پیش‌بینی درست شرکت‌های درمانده. بر اساس این، کاملاً ضروری است که میزان خطای الگوها نیز ارزیابی شود. در شرایطی که تعداد نمونه‌های طبقات پژوهش

<sup>1</sup>. Numpy

<sup>2</sup>. Matplotlib

<sup>3</sup>. Swarmlib

<sup>4</sup>. Networkx

<sup>5</sup>. Scikit learn

<sup>6</sup>. Confusion Matrix

(سالم یا درمانده) همگن نباشد، هر الگویی که با خطای کمتری پیش‌بینی کند، درحقیقت از توان بیشتر و عملکرد بهتری برای پیش‌بینی درماندگی مالی برخوردار است؛ بنابراین با توجه به اینکه خطای نوع اول هزینه بیشتری دارد و درواقع هدف اصلی ما نیز شناسایی درست شرکت‌های ورشکسته است، هر الگویی که با خطای نوع یک کمتری پیش‌بینی کند، مطلوب‌تر و دقیق‌تر است. خطای نوع یک کمتر به این معنی است که الگو در پیش‌بینی شرکت‌های ورشکسته بهتر عمل کرده و شرکت‌های ورشکسته کمتری را به اشتباه سالم در نظر گرفته است. درمقابل، خطای نوع یک بیشتر به این مفهوم است که الگو، تعداد شرکت‌های درمانده بیشتری را به اشتباه، شرکت سالم پیش‌بینی کرده است. اما به این دلیل که در محاسبه خطای نوع دوم از تعداد TP در مخرج استفاده می‌شود و این مقدار نیز به دلیل زیادبودن تعداد شرکت‌های سالم نسبت به کل نمونه‌ها زیاد گزارش می‌شود، بر اساس همین مخرج افزایش پیدا کرده و حاصل که خطای نوع دوم است مقدار کمتری را نشان خواهد داد؛ بنابراین فقط تکیه بر خطای نوع دوم کمتر نیز در چنین پژوهش‌هایی گمراه‌کننده است. بر اساس همین در این پژوهش از معیارهای مختلف استفاده شده است تا عملکرد الگوها از دیدگاه‌های مختلف سنجیده شود؛ مانند دقت در پیش‌بینی شرکت‌های درمانده، دقت در پیش‌بینی شرکت‌های سالم و میزان خطاهای مربوطه این پیش‌بینی‌ها. معیارهای استفاده‌شده برای ارزیابی دقت پیش‌بینی الگوها بر اساس پژوهش لیو و همکاران، قلی‌زاده و همکاران (۱۳۹۸) و سانکار و همکاران انتخاب شده که به شرح زیر است (Liu et al., 2019; Sankhwar et al., 2020):

$Accuracy \text{ or } Acc = \frac{TP + TN}{TP + FP + TN + FN}$	رابطه (۲۱) دقت
$\text{Type I error} = \frac{FP}{FP + TN}$	رابطه (۲۲) خطای نوع یک
$\text{Type II error} = \frac{FN}{TP + FN}$	رابطه (۲۳) خطای نوع دو
$TPR = \frac{TP}{TP + FN} * \%100$	رابطه (۲۴) حساسیت
$FPR = \frac{FP}{FP + TN} * \%100$	رابطه (۲۵) نرخ مثبت‌های غلط
$TNR = \frac{TN}{FP + TN} * \%100$	رابطه (۲۶) ویژگی
$G - \text{mean} = \sqrt{TPR * TNR}$	رابطه (۲۷) میانگین هندسی
$AUC = \frac{1 + TPR - FPR}{2} * \%100$	رابطه (۲۸) سطح زیر منحنی ROC

در روابط مذکور TP، TN، FP و FN به ترتیب نشان‌دهنده مثبت درست (شرکت‌های سالمی که به‌درستی در دسته شرکت‌های سالم پیش‌بینی شده‌اند)، منفی درست (شرکت‌های درمانده‌ای که به‌درستی در دسته شرکت‌های درمانده پیش‌بینی شده‌اند)، مثبت نادرست (شرکت‌های درمانده‌ای که به‌اشتباه سالم پیش‌بینی شده‌اند) و منفی نادرست (شرکت‌های سالمی که به‌اشتباه درمانده پیش‌بینی شده‌اند) است.

ادامه فرایند این پژوهش بدین صورت بوده که برای تضمین اعتبار نتایج ارزیابی دقت طبقه‌بندی از روش اعتبارسنجی k طبقه‌ای<sup>۱</sup> بهره گرفته شده است. اعتبارسنجی ۱۰ طبقه‌ای برای هر الگو ۱۰ بار اجرا شده، سپس از نتایج حاصل به‌منظور ارائه خروجی نهایی میانگین‌گیری شده است. در ادامه عملکرد الگوی پیشنهادی با دو روش دیگر از روش‌های متداول پیش‌بینی درماندگی مالی مقایسه شد. این مقایسه میان الگوها هم با در نظر گرفتن متغیرهای شبکه مالی و هم بدون آنها انجام و اعتبارسنجی شده است. در پایان به‌منظور ارائه یک ارزیابی جامع از روش پیشنهادشده، نتایج پیش‌بینی‌ها با استفاده از چندین معیار ارزیابی عملکرد شامل دقت، حساسیت، خطای نوع یک، خطای نوع دو و سطح زیر منحنی ROC آزمون شد.

<sup>۱</sup> K-Fold Cross Validation



### یافته‌ها

این پژوهش به دنبال آن است با پیوند دادن متغیرهای مبتنی بر شبکه مالی با الگوی IGWO – GBDT قدرت پیش‌بینی الگو را بهبود بخشد. بر اساس این، یک روش ترکیبی مبتنی بر درخت بر مبنای اطلاعات شبکه و GBDT که با IGWO بهینه شده است، برای پیش‌بینی درماندگی مالی پیشنهاد شد. این روش به‌طور خلاصه «FNI-IGWO-GBDT» نام‌گذاری شده و رویکرد جدیدی برای مقابله با درماندگی مالی است. به‌طور خاص در این پژوهش در ابتدا متغیرهای مبتنی بر شبکه به متغیرهای مالی سستی به‌صورت پیش‌بینی‌کننده اضافه شد و آنگاه الگوی GBDT که شاخص‌هایش با IGWO بهینه شده است، برای تعیین جداسازهای درخت به‌کار برده می‌شود. در پایان برای یسنجش و شناسایی قابلیت پیش‌بینی متغیرهای مبتنی بر شبکه و GBDT در پیش‌بینی درماندگی مالی، تحلیلی مقایسه‌ای نیز انجام شده است. به همین دلیل در این پژوهش الگوهای نزدیک‌ترین همسایه و رگرسیون لجستیک در کنار الگوی درخت تصمیم تقویت‌گرا دیان به‌صورت ابزارهای پیش‌بینی درماندگی مالی استفاده شده است. برای رگرسیون لجستیک از جریمه<sup>۱</sup>، 2، تolerانس<sup>۲</sup> یک ده هزارم و حداکثر تکرار<sup>۳</sup> ۱۰۰ استفاده شده است. برای الگوی k نزدیک‌ترین همسایه نیز از تعداد ۵ همسایه<sup>۴</sup>، اندازه برگ<sup>۵</sup> ۳۰، وزن یکنواخت<sup>۶</sup>، الگوریتم اتو<sup>۷</sup> و سنجه‌ی مینکوفسکی<sup>۸</sup> استفاده شده است. برای بررسی توانایی متمایز متغیرهای مبتنی بر شبکه ابتدا ویژگی‌های آماری این متغیرها تشریح شده است. جدول (۳) نشان می‌دهد برای شرکت‌های با درماندگی مالی در هر سال مقدار این متغیرها به چه میزان بوده است. میانگین درجه مرکزیت برای شرکت‌های دارای سلامت مالی ۰/۲۰۳ بوده، در حالی که میانگین درجه مرکزیت برای شرکت‌های درمانده ۰/۱۹۳ است. از روند تغییرات درجه مرکزیت برمی‌آید شبکه مالی در طول زمان دچار تحول شده است و شرکت‌هایی که در آستانه درماندگی هستند، بیشتر به حاشیه شبکه سوق پیدا می‌کنند. مرکزیت بینایی، برای شرکت‌های درمانده و غیردرمانده برابر ۰/۰۰۷ است. از منظر مرکزیت بردار ویژه، میانگین شرکت‌های سالم ۰/۰۸۳ بوده و برای شرکت‌های دارای درماندگی مالی این میانگین ۰/۱۰۴ است. مرکزیت نزدیکی، برای شرکت‌های سالم ۰/۵۲۵ بوده و برای شرکت‌های دارای درماندگی مالی این میانگین ۰/۴۹۶ است. مطابق با جدول (۳) شرکت‌هایی که مستعد درماندگی مالی هستند، هم‌زمان که شبکه مالی دچار تغییر می‌شود، روند تغییرات مشابهی دارند و در واقع برای شرکت‌های با مرکزیت کمتر، احتمال بیشتری وجود دارد که دچار درماندگی مالی شوند. نتایج مربوط به آمار توصیفی نسبت‌های مالی نیز در جدول (۴) و به تفکیک شرکت‌های سالم و درمانده ارائه شده است. با توجه به اینکه درباره شرکت‌های درمانده به دلیل منفی بودن حقوق صاحبان سهام و یا صفر بودن میزان فروش در بعضی سال‌ها، محاسبه برخی نسبت‌ها ممکن است باعث تحلیل‌های اشتباه و گمراه‌کننده شود، به همین دلیل محاسبه نشده است.

جدول (۳) مقادیر مربوط به متغیرهای شبکه مالی

Table (3) Values related to financial network variables

	مرکزیت درجه DC	مرکزیت بینایی BC	مرکزیت بردار ویژه EC	مرکزیت نزدیکی CC
شرکت‌های سالم	۰/۲۰۳	۰/۰۰۷	۰/۰۸۳	۰/۵۲۵
درمانده ۱۴۰۰	۰/۰۷۳	۰/۰۰۱	۰/۰۲۲	۰/۴۶۷
درمانده ۱۳۹۹	۰/۱۷۲	۰/۰۰۳	۰/۰۳۲	۰/۵۳۹
درمانده ۱۳۹۸	۰/۴۹۵	۰/۰۰۳	۰/۱۱۲	۰/۶۶۱

1. penalty
2. tolerance
3. Max-iteration
4. N-neighbors
5. Leaf size
6. Weight = uniform
7. Algorithm = auto
8. Metric = minkovski

درمانده ۱۳۹۷	۰/۱۶۵	۰/۰۰۹	۰/۰۶۴	۰/۵۲۸
درمانده ۱۳۹۶	۰/۰۹	۰/۰۰۵	۰/۰۴۸	۰/۴۵۱
درمانده ۱۳۹۵	۰/۱۹۸	۰/۰۱۸	۰/۱۲۵	۰/۵۴۲
درمانده ۱۳۹۴	۰/۰۸۱	۰/۰۰۳	۰/۰۳	۰/۴۴۶
کل شرکت‌های درمانده	۰/۱۹۳	۰/۰۰۷	۰/۱۰۴	۰/۴۹۶

جدول (۴) مقایسه نسبت‌های مالی بین شرکت‌های سالم و درمانده

Table (4) Comparison of financial ratios between healthy and distressed companies

نماد	نسبت مالی	شرکت‌های سالم	شرکت‌های درمانده
ROA	سود خالص به کل دارایی	۰/۱۶۲	-۰/۱۶۴
ROE	سود خالص به حقوق صاحبان سهام	۰/۳۶۲	۰/۲۰۵
ROS	سود خالص به فروش	۰/۲	-
DR	کل بدهی به کل دارایی	۰/۵۶۱	۱/۷۸
CR	دارایی جاری به بدهی جاری	۱/۷۳۵	۰/۴۹۸
NWC/TA	خالص سرمایه در گردش به کل دارایی	۰/۱۷۶	-
CA/TA	دارایی جاری به کل دارایی	۰/۶۸	۰/۴۵۴
MV/BV	ارزش بازار به ارزش دفتری	۷/۱۵	-
SIZE	لگاریتم کل دارایی‌ها	۶/۴۷۵	۶/۱۵

به منظور اعتبارسنجی اینکه آیا متغیرهای مبتنی بر شبکه می‌توان عملکرد پیش‌بینی درماندگی مالی الگوها را بهبود میبخشند یا نه، تمام الگوها در دو حالت اجرا شدند. هر سه الگو هم با وجود متغیرهای شبکه مالی و هم بدون آن اجرا شده و دقت پیش‌بینی کننده‌های مختلف مقایسه شده که این مقایسه‌ها در جدول (۵) آورده شده است. جدول (۵) نشان می‌دهد درخت تصمیم تقویت‌گرادیان در ترکیب با اطلاعات شبکه مالی بهترین عملکرد پیش‌بینی را داشته است و این موضوع نشان‌دهنده این نکته است که الگوی پیشنهادی هم از مزایای اطلاعات شبکه و هم انتخاب شاخص‌های بهینه بر مبنای الگوریتم گرگ خاکستری بهبود یافته بهره برده است.

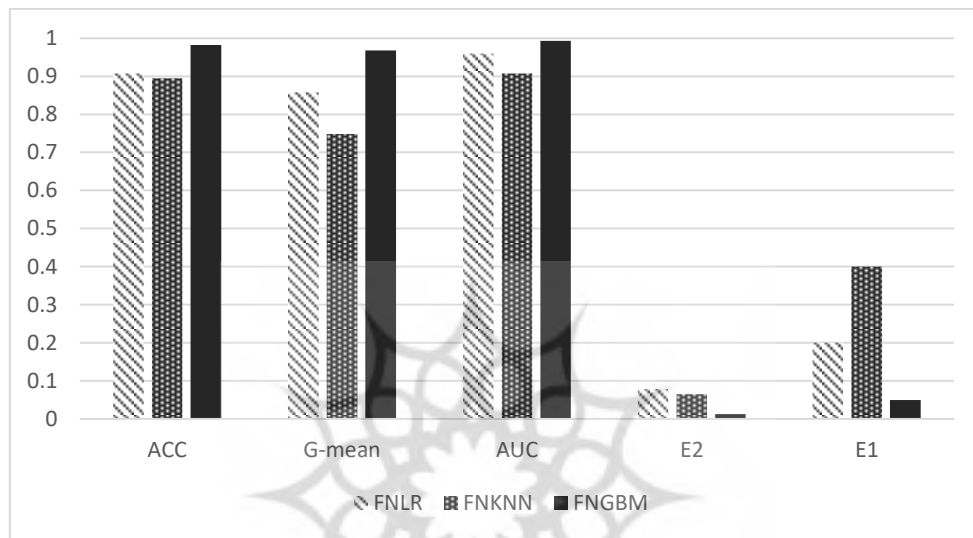
جدول (۵) مقایسه عملکرد سه الگو با وجود متغیرهای شبکه مالی و بدون آن

Table (5) Comparing the performance of three models with and without financial network variables

	LR	FN-LR	KNN	FN-KNN	GBDT	FN-GBDT
Accuracy	۰/۹۰۱	۰/۹۰۷	۰/۹۰۶	۰/۸۹۵	۰/۹۶	۰/۹۸۲
Error1	۰/۲۴	۰/۲۰	۰/۳۱	۰/۴۰	۰/۱۱	۰/۰۵
Error2	۰/۰۸۶	۰/۰۷۸	۰/۰۱۱	۰/۰۶۵	۰/۰۳۳	۰/۰۱۳
Auc	۰/۹۳۲	۰/۹۵۹	۰/۹۱۶	۰/۹۰۷	۰/۹۸۹	۰/۹۹۳
G-mean	۰/۸۳۳	۰/۸۵۸	۰/۸۲۶	۰/۷۴۸	۰/۹۲۷	۰/۹۶۸

نتایج جدول ۵ نشان می‌دهد دو الگوی رگرسیون لجستیک و نزدیک‌ترین همسایه از نظر دقت، عملکرد مشابهی داشتند و میزان دقت آنها در حدود ۹۰ درصد است. این معیار برای الگوی پیشنهادی پژوهش برابر با ۹۸ درصد است. از نظر معیار سطح زیر منحنی ROC نیز هر سه الگو وضعیت مشابهی را نشان می‌دهند و مقدار این معیار برای هر سه الگو، بیشتر از ۹۰ درصد است که در شکل ۵ نیز مشاهده می‌شود. هر سه الگو در خصوص پیش‌بینی‌های مربوط به طبقه شرکت‌های سالم که ۸۸ درصد مشاهدات را نیز تشکیل می‌دهند، بسیار خوب عمل کرده‌اند و خطای زیر ۱۰ درصد دارند، اما هنر اصلی این الگوها زمانی نمایان می‌شود که طبقه شرکت‌های

درمانده مالی را که تنها ۱۲ درصد مشاهدات را به خود اختصاص داده‌اند، به‌خوبی و دقیق پیش‌بینی کنند. همان‌طور که مشاهده می‌شود خطای نوع اول در الگوی رگرسیون لجستیک برابر ۲۰ درصد و برای الگوی نزدیک‌ترین همسایه ۴۰ درصد است که این مقدار خطا ممکن است هزینه زیادی را همراه داشته باشد؛ یعنی این دو الگو به ترتیب در ۲۰ و ۴۰ درصد مواقع شرکت‌های درمانده را به اشتباه، سالم پیش‌بینی کرده‌اند. اما خطای نوع اول در الگوی پیشنهادی پژوهش تنها ۵ درصد بوده و این نشان‌دهنده دقت زیاد الگو است که در شکل ۵ نیز این تفاوت مشهود است. با توجه به اینکه معیار G-mean این توانایی را دارد که حتی در شرایط ناتراز بودن نمونه‌های پژوهش نیز، عملکرد برخی از روش‌های طبقه‌بندی را تقویت کند (Faris et al., 2020)، به همین دلیل در این پژوهش از آن استفاده شده و نتایج آن نشان‌دهنده برتری الگوی درخت تصمیم تقویت‌گرایان است.



شکل (۵) مقایسه عملکرد سه الگو

Figure (5) Performance comparison of three models

با نگاه به نتایج مربوط به جدول (۶) مشاهده می‌شود الگوی پیشنهادی پژوهش از تعداد ۱۷۳ پیش‌بینی که انجام داده است، ۱۷۰ پیش‌بینی درست و فقط ۳ پیش‌بینی اشتباه داشته است و تنها در یک نمونه از ۲۰ پیش‌بینی در خصوص شرکت‌های ورشکسته خطا داشته است. ولی این خطا برای الگوی رگرسیون لجستیک ۴ خطا در ۲۰ پیش‌بینی و برای الگوی نزدیک‌ترین همسایه ۸ خطا در ۲۰ پیش‌بینی بوده است. همچنین باید اشاره کرد با اضافه‌شدن متغیرهای مربوط به شبکه مالی، تمام معیارهای ارزیابی در الگوی درخت تصمیم تقویت‌گرایان و رگرسیون لجستیک بهبود می‌یابند، اما درباره الگوی نزدیک‌ترین همسایه نتیجه عکس است. به احتمال زیاد دلیل این موضوع حساسیت الگوی نزدیک‌ترین همسایه به پراکندگی زیاد در طبقات نمونه است. در جدول (۶)، خروجی‌های مربوط به ماتریس درهم‌ریختگی در هر سه الگوی به‌کار رفته، مقایسه شده است.

جدول (۶) مقایسه ماتریس درهم‌ریختگی روش درخت تصمیم تقویت‌گرایان با الگوهای رگرسیون لجستیک و نزدیک‌ترین همسایه

Table (6) Comparison of the confusion matrix in gradient boosting decision tree method with logistic regression and nearest neighbor models

		مقادیر پیش‌بینی شده						
		الگو	خروجی	سالم	درمانده	مجموع	دقت	خطای پیش‌بینی
مقادیر واقعی	FNI-IGWO-GBDT		سالم	۱۵۱	۲	۱۵۳	۰/۹۸۶	۰/۰۱۳
			درمانده	۱	۱۹	۲۰	۰/۹۵	۰/۰۵
			مجموع	۱۵۲	۲۱	۱۷۳	۰/۹۸۲	۰/۰۱۷

	سالم	۱۴۱	۱۲	۱۵۳	۰/۹۲۱	۰/۰۷۸
<b>FNI-LR</b>	درمانده	۴	۱۶	۲۰	۰/۸۰	۰/۲۰
	مجموع	۱۴۵	۲۸	۱۷۳	۰/۹۰۷	۰/۰۹۲
	سالم	۱۴۳	۱۰	۱۵۳	۰/۹۳۴	۰/۰۶۵
<b>FNI-KNN</b>	درمانده	۸	۱۲	۲۰	۰/۶۰	۰/۴۰
	مجموع	۱۵۰	۲۳	۱۷۳	۰/۸۹۵	۰/۱۰۵

آزمون مقایسه میانگین برای چهار معیار ارزیابی عملکرد الگوهای پیش‌بینی انجام شده که نتایج حاصل در جدول (۷) ارائه شده است. همان‌طور که مشاهده می‌شود در سطح اطمینان ۹۵ درصد تفاوت در میانگین خطای نوع اول در الگوی درخت تصمیم معنادار بوده و بدین مفهوم است که با اضافه‌شدن متغیرهای شبکه مالی خطای نوع یک الگو کاهش یافته است. این استدلال در سطح اطمینان ۹۰ درصد برای معیار سطح زیر منحنی ROC نیز انجام می‌شود که در نتیجه آن با اضافه‌شدن متغیرهای شبکه مالی، معیار سطح زیر منحنی ROC افزایش یافته است. نتایج آزمون مقایسه میانگین در الگوی رگرسیون لجستیک نیز مشابه الگوی درخت تصمیم است؛ با این تفاوت که تأیید معناداری اختلاف میانگین برای معیار خطای نوع یک در سطح ۹۰ درصد و برای معیار سطح زیر منحنی ROC در سطح ۹۵ درصد است. برخلاف دو الگوی قبل، در الگوی نزدیک‌ترین همسایه، با اضافه‌شدن متغیرهای شبکه مالی خطای نوع یک به میزان ۹ درصد افزایش یافت که این اختلاف در سطح اطمینان ۹۵ درصد معنادار نیز بوده است. اما در سایر معیارها تفاوت معناداری مشاهده نشد.

جدول (۷) آزمون مقایسه میانگین برای معیارهای ارزیابی هر سه الگو

**Table (7) Mean comparison test for the evaluation criteria of all three models**

الگو	خطای نوع ۲	خطای نوع ۱	سطح زیر منحنی ROC	دقت	آماره و سطح معناداری
درخت تصمیم	T-value	۳/۳۵۴	-۲/۴۹۵	-۰/۲۳	
	Sig.(2-tailed)	۰/۰۲	۰/۰۵۵	۰/۸۲۲	
رگرسیون لجستیک	T-value	۲/۴۲۸	-۲/۷۳۳	۱/۱۶۴	
	Sig.(2-tailed)	۰/۰۶	۰/۰۴۱	۰/۲۹۷	
نزدیکترین همسایه	T-value	-۶/۳۱۲	۲/۳۸۲	۱/۶۵۹	
	Sig.(2-tailed)	۰/۰۰۱	۰/۰۶۳	۰/۱۵۸	

در مجموع ایجاد روش‌های جمعی مبتنی بر درخت ساده‌تر و نتایج آنها نیز باثبات‌تر است. برای بررسی ثبات نتایج، الگوی پیشنهاد شده، در ۶ حالت مختلف، تحلیل حساسیت روی شاخص‌های ورودی الگو که با استفاده از الگوریتم گرگ خاکستری بهبود یافته انتخاب شده بود، نشان داد نتایج الگو از ثبات برخوردار است. جدول (۸) نتایج تحلیل حساسیت روی الگوی پیشنهاد شده را نشان می‌دهد. با توجه به اینکه با تغییر شاخص‌های الگوی پیشنهادی همچنان دقت عملکرد پیش‌بینی الگو زیاد است، بنابراین نتایج حاصل از اعتبار و ثبات لازم برخوردار است.

جدول (۸) نتایج تحلیل حساسیت روی الگوی درخت تصمیم تقویت‌گرایان

**Table (9) Results of sensitivity analysis on gradient boosting decision tree model**

	۱	۲	۳	۴	۵	۶	میانگین
(J, D, N)	(۰/۱، ۳، ۲۰۰)	(۰/۱، ۵، ۲۰۰)	(۰/۰۵، ۵، ۲۰۰)	(۰/۰۵، ۳، ۲۰۰)	(۰/۱، ۳، ۱۰۰)	(۰/۱، ۵، ۱۰۰)	
ACC	۰/۹۷	۰/۹۷	۰/۹۶	۰/۹۵	۰/۹۷	۰/۹۶	۰/۹۶۵
AUC	۰/۹۹۲	۰/۹۹۳	۰/۹۹۱	۰/۹۸۳	۰/۹۹۳	۰/۹۹۰	۰/۹۹۰

در این بخش، اهمیت نسبی هر متغیر برای پیش‌بینی درماندگی مالی با استفاده از معیار بهره اطلاعاتی<sup>۱</sup> بررسی شده است. اهمیت نسبی هر متغیر بر اساس الگوی درخت تصمیم تقویت‌گرایان به دست آمده است. از میان ۱۳ متغیر به‌صورت ورودی‌ها یا پیش‌بینی‌کننده‌های درماندگی مالی، سه متغیر حاشیه سود، بازده دارایی‌ها و نسبت ارزش بازار به ارزش دفتری دارایی‌ها با مقادیر ۰/۲۳، ۰/۲۱ و ۰/۱۷ بیشترین تأثیر نسبی را در خروجی الگو داشته‌اند. مطابق جدول ۹ اگرچه معیارهای مرکزیت شبکه در مقایسه با نسبت‌های مالی، اهمیت نسبی کمتری در پیش‌بینی درماندگی مالی داشته‌اند، ولی در هر صورت تأثیر مثبتی نیز روی پیش‌بینی درماندگی مالی داشته‌اند. از بین چهار متغیر مربوط به شبکه مالی، مرکزیت بینابینی بیشترین اهمیت نسبی را داشته و پس از آن مرکزیت درجه با اهمیت‌ترین متغیر شبکه مالی در پیش‌بینی درماندگی مالی بوده است.

جدول (۹) اهمیت نسبی متغیرهای پیش‌بینی‌کننده

Table (9) Relative importance of predictor variables

مقدار بهره اطلاعاتی	نام متغیر	رتبه	مقدار بهره اطلاعاتی	نام متغیر	رتبه
۰/۰۷	اندازه شرکت	۸	۰/۲۳	حاشیه سود خالص	۱
۰/۰۶۴	دارایی‌های جاری به کل داراییها	۹	۰/۲۱۴	بازده داراییها	۲
۰/۰۳۲	مرکزیت بینابینی	۱۰	۰/۱۷۳	ارزش بازار به ارزش دفتری	۳
۰/۰۲۳	مرکزیت درجه	۱۱	۰/۱۶	نسبت بدهی	۴
۰/۰۱۴	مرکزیت نزدیکی	۱۲	۰/۱۵۷	خالص سرمایه در گردش به کل داراییها	۵
۰/۰۰۶	مرکزیت بردار ویژه	۱۳	۰/۱۴۷	نسبت جاری	۶
			۰/۰۹۲	بازده حقوق صاحبان سهام	۷

### نتیجه‌گیری

الگوی پیشنهادشده به‌طور اثربخشی شرکت‌های با درماندگی مالی را از شرکت‌های دارای سلامت مالی تفکیک کرده است. با استفاده از نظریه شبکه پیچیده و به‌کمک بازده سهام شرکت‌های پذیرفته‌شده در بورس و فرابورس تهران، شبکه مالی ایجاد شد. سپس با به‌کارگیری معیارهای مرکزیت، موقعیت و ارتباطات هر شرکت در شبکه بازار مشخص شد. سرانجام در این پژوهش رابطه بین مرکزیت شبکه و درماندگی مالی بررسی شد. به‌منظور اعتبارسنجی تأثیر متغیرهای شبکه مالی در پیش‌بینی درماندگی مالی، شبکه مالی ایجاد و متغیرهای مربوط به شبکه به‌صورت متغیرهای پیش‌بینی‌کننده محاسبه شد. علاوه بر آن به‌منظور دست‌یافتن به بیشترین عملکرد طبقه‌بندی الگو از الگوریتم گرگ خاکستری بهبودیافته به‌منظور جست‌وجوی بهینه ترکیب شاخص‌های الگوی تقویت‌گرایان استفاده شد. در نهایت الگوی پیشنهادی این نتایج را به‌دنبال داشت: (۱) هم‌راستا با نتایج پژوهش لیو و همکاران (Liu et al., 2019) متغیرهای مبتنی بر شبکه مالی به‌منظور کشف اطلاعات سودمند در شبکه مالی به‌کار می‌روند و عملکرد پیش‌بینی طبقه‌بندی‌کننده‌ها را بهبود می‌بخشند؛ (۲) مطابق با تعریف مرکزیت، شرکت‌های با مقدار مرکزیت زیاد به‌ویژه مرکزیت بینابینی و مرکزیت درجه، کمتر مستعد قرار گرفتن در شرایط درماندگی مالی هستند و برعکس؛ (۳) مطابق نتایج پژوهش قلی‌زاده و همکاران (۱۳۹۸)، الگوریتم گرگ خاکستری بهبودیافته یک روش کاربردی برای انتخاب شاخص‌های الگوی تقویت‌گرایان است؛ (۴) در شرایطی که نسبت فراوانی نمونه‌های هر طبقه بسیار متفاوت از طبقات دیگر باشد، استفاده از روش درخت تصمیم تقویت‌گرایان بسیار کارآمد خواهد بود. نتایج تجربی نشان داد الگوی پیشنهادشده بهتر از دو الگوی دیگر در پیش‌بینی درماندگی مالی عمل کرده و معیارهای ارزیابی به‌کار

<sup>1</sup>. Information Gain



رفته نیز تأییدکننده این موضوع است. از طرفی دقت پیش‌بینی الگوی پیشنهادشده با تغییر شاخص‌هایی که در ابتدای مقاله تشریح شده بود، آزمون پایداری نتایج شد؛ بنابراین این الگو به صورت یک ابزار سودمند پیش‌بینی در ماندگی مالی شرکت‌ها به کار گرفته می‌شود. بر اساس نتایج که شاید و به احتمال بسیار زیاد نخستین پژوهشی باشد که در آن از الگوی ترکیبی FNI-GWO-GBDT برای پیش‌بینی در ماندگی مالی شرکت‌ها استفاده شده است، به سایر پژوهشگران علاقه‌مند به حوزه پیش‌بینی در ماندگی مالی و به طور کلی موضوعات مربوط به طبقه‌بندی، پیشنهاد می‌شود این پژوهش را یک کار جدید مبنایی برای پژوهش‌های آتی قرار دهند. از جمله پیشنهادات کاربردی با توجه به نتایج حاصل از این پژوهش آن است که مدیران شرکت‌ها از متغیرهای حاشیه سود خالص، بازده دارایی‌ها و نسبت ارزش بازار به ارزش دفتری با وزن و اهمیت بیشتری برای پیش‌بینی در ماندگی مالی شرکت‌ها استفاده کنند. همچنین توجه به موضوعات مربوط به بازار سرمایه با رویکرد شبکه‌ی مالی نیز خالی از فایده نخواهد بود. سایر پژوهشگران الگوی پیشنهادی این پژوهش را در مقایسه با سایر روش‌هایی مانند شبکه عصبی مصنوعی، جنگل تصادفی، ماشین‌های یادگیری سریع و ... در مطالعات بعدی به کار گیرند. همچنین به علاقه‌مندان به مطالعات در حوزه روش‌های فراابتکاری پیشنهاد می‌شود شاخص‌های درخت تصمیم را با سایر الگوریتم‌ها مانند ژنتیک، جست‌وجوی فاخته، کاوش باکتری، کلونی مورچگان، کرم شب تاب و ... بهینه و نتایج آن را با سایر روش‌ها مقایسه کنند. به جز روش‌های فراابتکاری الهام‌گرفته از طبیعت، شاخص‌های درخت تصمیم با روش‌هایی مانند جست‌وجوی تصادفی<sup>۱</sup> و جست‌وجوی شبکه‌ای<sup>۲</sup> نیز بهینه می‌شود. همچنین در مطالعات بعدی برای ساخت شبکه‌ی مالی به جای متغیرهای مبتنی بر قیمت از متغیرهای مبتنی بر حجم معاملات و یا متغیرهای مبتنی بر تحلیل‌های تکنیکال استفاده شود. برای اندازه‌گیری ویژگی‌های شبکه‌ی مالی نیز سایر معیارها مانند SIR<sup>۳</sup>، PageRank، HITS، K-shell، H-index و Profit Leader پیشنهاد می‌شود. نتایج این پژوهش به درک بهتری از الگوی ترکیبی FNI-GWO-GBDT برای پیش‌بینی در ماندگی مالی شرکت‌ها منجر می‌شود. در خصوص محدودیت‌های این پژوهش باید اشاره کرد اصلی‌ترین محدودیت، موجود نبودن برخی اطلاعات مالی مربوط به قیمت تعدیل‌شده برخی از سهام است که برای محاسبه بازده سهام، ضریب همبستگی میان بازده سهام و در نهایت تشکیل شبکه‌ی مالی ضروری است.

## منابع

- ابراهیمی سروعلیا، محمدحسن، باباجانی، جعفر، آخوند، محمدرضا، و فاخر، اسلام (۱۳۹۷). ارائه الگویی برای پیش‌بینی پویای در ماندگی مالی با استفاده از تحلیل بقا. *فصلنامه علمی پژوهشی اقتصاد مقداری*، ۱۵(۴)، ۱۶۷-۱۹۸. <https://doi.org/10.22055/jqe.2019.25894.1877>
- پورحیدری، امید، و کوپایی حاجی، مهدی (۱۳۸۹). پیش‌بینی بحران مالی شرکت‌ها با استفاده از الگو مبتنی بر تابع تفکیکی خطی. *پژوهش‌های حسابداری مالی*، ۲(۱)، ۳۳-۴۶.
- تاج مزینانی، مائده، فلاح‌پور، سعید، و باجلان، سعید (۱۳۹۴). کاربرد روش انتخاب ویژگی هارک (HARC) در پیش‌بینی در ماندگی مالی شرکت‌ها در بورس اوراق بهادار تهران. *راهبرد مدیریت مالی*، ۳(۹)، ۷۷-۱۰۶. <https://doi.org/10.22051/jfm.2015.2169>
- دموری، داریوش، و هژبری، فرحناز (۱۳۹۸). بررسی تأثیر چرخه عمر بر تجدید ساختار شرکت در شرایط در ماندگی مالی. *دانش حسابداری*، ۱۰(۲)، ۱۱۳-۱۳۵. <https://doi.org/10.22103/jak.2019.11201.2614>
- راعی، رضا، جعفری، غلامرضا، و نمکی، علی (۱۳۸۹). تحلیل بازار بورس اوراق بهادار تهران با استفاده از شبکه‌های پیچیده مبتنی بر روش حد آستانه. *بررسی‌های حسابداری و حسابرسی*، ۱۷(۴)، ۳۳-۸۰.

1. Randomized Search CV

2. Grid Search CV

3. Susceptible Infected Recovered

4. Hyperlink Induced Topic Search

- صداقتی، صمد، فرهادی، روح‌اله، و فلاح شمس لیلاستانی، میرفیض (۱۴۰۰). مدیریت پرتفوی براساس توپولوژی شبکه بازار سهام ایران. *دوفصلنامه علمی تحقیقات مالی اسلامی*، ۱۰(۱)، ۱۵۱-۱۸۶. <https://www.doi.org/10.30497/ifr.2021.240229.1592>
- علی اکبرلو، علیرضا، منصورفر، غلامرضا، و غیور، فرزاد (۱۳۹۹). مقایسه معیارهای تشخیص شرکت‌های در مانده مالی با استفاده از رگرسیون لجستیک و روش‌های هوش مصنوعی. *چشم‌انداز مدیریت مالی*، ۱۰(۲۹)، ۱۴۷-۱۶۶. <https://doi.org/10.52547/jfmp.10.29.147>
- علی بابایی، غزاله، و خان‌محمدی، محمد حامد (۱۴۰۲). ارائه الگوی به منظور پیش‌بینی ورشکستگی شرکت‌ها با استفاده از مکانیزم‌های حاکمیت شرکتی و نسبت‌های مالی. *دانش سرمایه‌گذاری*، ۱۲(۴۸)، ۶۷-۹۸.
- فلاح‌پور، سعید، راعی، رضا، و نوروزیان، عیسی (۱۳۹۷). استفاده از روش ترکیبی انتخاب ویژگی پی‌درپی پیشرو شناور و ماشین بردار پشتیبان در پیش‌بینی در ماندگی مالی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران. *تحقیقات مالی*، ۲۰(۳)، ۲۸۹-۳۰۴. <https://doi.org/10.22059/frj.2018.113928.1005868>
- فلاح‌پور، سعید، و قهرمانی، علی (۱۴۰۰). معرفی و بررسی ویژگی‌های مرکزیت به عنوان معیاری نوین برای تحلیل شبکه، سنجش ریسک و انتخاب پرتفوی سهام. *تحقیقات مالی*، ۲۳(۲)، ۱۵۸-۱۷۱. <https://doi.org/10.22059/jfr.2018.241407.1006515>
- قلی‌زاده سالطه، توحید، اقبال‌نیا، محمد، و آقابابائی، محمد ابراهیم (۱۳۹۸). پیش‌بینی ورشکستگی با الگو یادگیری ماشین سریع مبتنی بر کرنل بهینه شده با الگوریتم گرگ خاکستری. *تحقیقات مالی*، ۲۱(۲)، ۱۸۷-۲۱۲. <https://doi.org/10.22059/frj.2019.277620.1006839>
- غضنفری، مهدی، رحیمی‌کیا، اقبال، و عسکری، علی (۱۳۹۷). پیش‌بینی ورشکستگی شرکت‌ها مبتنی بر سیستم‌های هوشمند ترکیبی. *پژوهش‌های حسابداری مالی و حسابداری*، ۱۰(۳۷)، ۱۵۹-۱۹۳.
- منتشری، مجید، و صادقی، حجت‌الله (۱۴۰۰). ایجاد شبکه مالی غیرخطی مبتنی بر ویژگی مکان‌شناختی آن بر مبنای نظریه گراف (مطالعه‌ای در بورس اوراق بهادار تهران). *مدیریت دارایی و تامین مالی*، ۹(۱)، ۱-۲۲. <https://doi.org/10.22108/amf.2020.122895.1538>
- منتشری، مجید، و صادقی، حجت‌الله (۱۳۹۹). گونه‌شناسی شبکه‌های مالی براساس ویژگی‌های مکان‌شناختی آن‌ها (مطالعه‌ای در بورس اوراق بهادار تهران). *مهندسی مالی و مدیریت اوراق بهادار*، ۱۱(۴۵)، ۳۱۹-۳۴۲.
- ناظمی اردکانی، مهدی، زارع مهرجردی، وحید، و محمدی ندوشن، علیرضا (۱۳۹۷). طراحی و تبیین الگوی پیش‌بینی ورشکستگی شرکت‌ها بر حسب صنایع منتخب با استفاده از الگوی درخت تصمیم. *مدیریت دارایی و تامین مالی*، ۲۰(۲)، ۱۲۱-۱۳۸. <https://doi.org/10.22108/amf.2017.21355>

## References

- Alaka, H. A., Oyedele, L. O., Owolabi, H. A., Kumar, V., Ajayi, S. O., Akinade, O. O., Bilal, M. (2018). Systematic review of bankruptcy prediction models: Towards a framework for tool selection. *Expert Systems with Applications*, 94, 164-184. <https://doi.org/10.1016/j.eswa.2017.10.040>
- Aliakbarlou, A., Mansourfar, G., & Ghayour, F. (2020). Comparing the identifying criteria for financially distressed companies using logistic regression and artificial intelligence methods. *Financial Management Perspective*, 10(29), 147-166. <https://doi.org/10.52547/jfmp.10.29.147> [In Persian].
- Alibabae, G., & Khanmohammadi, M. (2022). The Study of the predictive power of meta-heuristic algorithms to provide a model for bankruptcy prediction. *International Journal of Finance & Managerial Accounting*, 7(26), 33-51. <https://doi.org/10.30495/ijfma.2022.19523>
- Alibabae, G., & Khanmohammadi, H. (2023). A Model to predict bankruptcy using the mechanisms of corporate governance and financial ratios. *Journal of Investment Knowledge*, 12(48), 67-98. [In Persian].
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4), 589-609. <https://doi.org/10.2307/2978933>
- Altman, E. I., Eom, Y. H., & Kim, D. W. (1995). Failure prediction: Evidence from Korea. *Journal of International Financial Management & Accounting*, 6(3), 230-249. <https://doi.org/10.1111/j.1467-646X.1995.tb00058.x>
- Asquith, P., Gertner, R., & Scharfstein, D. (1994). Anatomy of financial distress: An examination of junk-bond issuers. *The Quarterly Journal of Economics*, 109(3), 625-658.

- Aydin, N., Sahin, N., Deveci, M., Pamucar, D. (2022). Prediction of financial distress of companies with artificial neural networks and decision trees models. *Machine Learning with Applications*, 10, 100432. <https://doi.org/10.1016/j.mlwa.2022.100432>
- Beaver, W. H. (1968). Alternative accounting measures as predictors of failure. *The Accounting Review*, 43(1), 113-122.
- Chaudhuri, A., & De, K. (2011). Fuzzy support vector machine for bankruptcy prediction. *Applied Soft Computing*, 11(2), 2472-2486. <https://doi.org/10.1016/j.asoc.2010.10.003>
- Chauhan, N., Ravi, V., & Chandra, D. K. (2009). Differential evolution trained wavelet neural networks: Application to bankruptcy prediction in banks. *Expert Systems with Applications*, 36(4), 7659-7665. <https://doi.org/10.1016/j.eswa.2008.09.019>
- Chen, W. S., & Du, Y. K. (2009). Using neural networks and datamining techniques for the ifinancial distress prediction model. *Expert Systems with Applications*, 36(2), 407-4086. <https://doi.org/10.1016/j.eswa.2008.03.020>
- Chen, L. H., & Hsiao, H. D. (2008). Feature selection to diagnose a business crisis by using a real GA-based support vector machine: An empirical study. *Expert Systems with Applications*, 35(3), 1145-1155. <https://doi.org/10.1016/j.eswa.2007.08.010>
- Chen, H. L., Yang, B., Wang, G., Liu, J., Xu, X., Wang, S. J., & Liu, D. Y. (2011). A novel bankruptcy prediction model based on an adaptive fuzzy k-nearest neighbor method. *Knowledge-Based Systems*, 24(8), 1348-1359. <https://doi.org/10.1016/j.knsys.2011.06.008>
- Comin, C. H., Peron, T., Silva, F. N., Amancio, D. R., Rodrigues, F. A., Cost, L. F. (2020). Complex systems: Features, similarity and connectivity. *Physics Reports*, 861, 1-41. <https://doi.org/10.1016/j.physrep.2020.03.002>
- Damoori, D., Hozhabrie, F. (2019). Impact of life cycle on corporate restructuring while in financial distress. *Journal of Accounting Knowledge*, 10(2), 113-135. <https://doi.org/10.22103/jak.2019.11201.2614> [In Persian].
- Ebrahimi S., M. H., Babajani, J., Akhond, M., & Fakher, E. (2019). A Pattern for dynamic prediction of financial distress by using survival analysis. *Quarterly Journal of Quantitative Economics*, 15(4), 167-198. <https://doi.org/10.22055/qje.2019.25894.1877> [In Persian].
- Fallahpor, S., Ghahramani, A. (2021). An Analysis of centrality's features as a new measure for network analysis, risk measurement & portfolio selection. *Financial Research Journal*, 23(2), 158-171. <https://doi.org/10.22059/jfr.2018.241407.1006515> [In Persian].
- Fallahpor, S., Raei, R., Norouzian L., E. (2018). Applying combined approach of sequential floating forward selection and support vector machine to predict financial distress of listed companies in Tehran Stock Exchange market. *Financial Research Journal*, 20(3), 289-304. <https://doi.org/10.22059/frj.2018.113928.1005868> [In Persian].
- Faris, H., Abukhurma, R., Almanaseer, W. (2020). Improving financial bankruptcy prediction in a highly imbalanced class distribution using oversampling and ensemble learning: A case from the Spanish market. *Progress in Artificial Intelligence*, 9, 31-53 <https://doi.org/10.1007/s13748-019-00197-9>
- Freeman, L. (1977). A set of measures of centrality based on betweenness. *sociometry*, 40(1), 35-41. <https://doi.org/10.2307/3033543>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232. <https://www.researchgate.net/publication/280687718>
- Gepp, A., Kumar, K., & Bhattacharya, S. (2010). Business failure prediction using decision trees. *Journal of Forecasting*, 29(6), 536-555. <https://doi.org/10.1002/for.1153>
- Golizadeh Salteh, T., Eghbalian, M., & Aghababaei, M. E. (2019). Grey Wolf optimization evolving kernel extreme learning machine: Application to bankruptcy prediction. *Financial Research Journal*, 21(2), 187-212. <https://doi.org/10.22059/frj.2019.277620.1006839> [In Persian].
- Ghazanfari, M., Rahimikiya, E., & Askari, A. (2018). Predicting bankruptcy of companies based on hybrid intelligent systems. *Financial Accounting and Auditing Research*, 10(37), 159-194. [In Persian].
- Guelman, L. (2012). Gradient boosting trees for auto insurance loss cost modeling and prediction. *Expert Systems with Applications*, 39(3), 3659-3667. <https://doi.org/10.1016/j.eswa.2011.09.058>
- Heidari, A. A., & Ali Abbaspour, R. (2016). Rough set reduction: A novel orthogonal learning-based Grey Wolf optimization strategy. *1st International Conference on Advances Research on Electrical and Computer Engineering*, Tehran, Iran.
- Heidari, A. A., & Pahlavani, P. (2017). An Efficient modified grey wolf optimizer with Lévy Flight for optimization tasks. *Applied Soft Computing*, 60, 115-134. <https://doi.org/10.1016/j.asoc.2017.06.044>
- Hsieh, T. J., Hsiao, H. F., & Yeh, W. C. (2012). Mining ifinancial distress trend data using penalty guided support vector machines based on hybrid of particle swarm optimization and artiificial bee colony algorithm. *Neurocomputing*, 82, 1-206. <https://doi.org/10.1016/j.neucom.2011.11.020>
- Iturriaga, F. J. L., & Sanz, I. P. (2015). Bankruptcy visualization and prediction using neural networks: A study of US commercial banks. *Expert Systems with Applications*, 42(6), 2857-2869. <https://doi.org/10.1016/j.eswa.2014.11.025>
- Komaki, G. M., & Kayvanfar, V. (2015). Grey Wolf optimizer algorithm for the two-stage assembly flow shop scheduling problem with release time. *Journal of Computational Science*, 8, 10-120. <https://doi.org/10.1016/j.jocs.2015.03.011>

- Kumar, P. R., & Ravi, V. (2007). Bankruptcy prediction in banks and ifrms via statistical and intelligent techniques.- A review. *European Journal of Operational Research*, 180(1), 1–28. <https://doi.org/10.1016/j.ejor.2006.08.043>
- Lau, A. H. L. (1987). A five-state financial distress prediction model. *Journal of Accounting Research*, 25(1), 127–138. <https://doi.org/10.2307/2491262>
- Liu, J., Wu, C., & Li, Y. (2019). Improving financial distress prediction using financial network-based information and GA-Based gradient boosting method. *Computational Economics*, 53(2), 851-872. <https://doi.org/10.1007/s10614-017-9768-3>
- Mantegna, R. N. (1999). Hierarchical structure in ifnancial markets. *The European Physical Journal . - Condensed Matter and Complex Systems*, 11(1), 193–197. <https://doi.org/10.1007/s100510050929>
- Marso, S. & El Merouani, M. (2020). Predicting financial distress using hybrid feedforward neural network with cuckoo search algorithm. *Procedia Computer Science*, 170, 1134-1140. <https://doi.org/10.1016/j.procs.2020.03.054>
- González-Bravo, M. I., & Mecaj, A. (2011). Structural and evolutionary patterns of companies in a financial distress situation. *Advances in Decision Sciences*, 2011. <http://dx.doi.org/10.1155/2011/928716>
- Mirjalili, S. A., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in Engineering Software*, 69, 46–61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- Montasheri, M., & Sadeqi, H. (2021). Establishment of a non-linear financial network based on its typological characteristics based on Graph theory, A Study in Tehran Stock Exchange. *Journal of Asset Management and Financing*, 9(1), 1-22. <https://doi.org/10.22108/amf.2020.122895.1538> [In Perssian].
- Montasheri, M., & Sadeqi, H. (2020). A Typology of financial networks according to their typological characteristics, A study of Tehran Stock Exchange. *Financial Engineering and Portfolio Management*, 11(45), 319-342. [In Persian].
- Muangkote, N., Sunat, K., & Chiewchanwattana, S. (2014). An improved grey wolf optimizer for training q-Gaussian Radial Basis Functional-link nets. In *2014 international computer science and engineering conference (ICSEC)* (pp. 209-214). IEEE. <https://doi.org/10.1109/ICSEC.2014.6978196>
- Nazemi, A. M., Zare, M. V., & Mohammadi, N, A. (2018). A firms bankruptcy prediction model based on selected industries by using decision trees model. *Journal of Asset Management and Financing*, 6(2), 121-138. <https://doi.org/10.22108/amf.2017.21355> [In Persian].
- Niu, M., Wang, Y., Sun, S., & Li, Y. (2016). A novel hybrid decomposition-and-ensemble model based on CEEMD and GWO for short-term PM 2.5 concentration forecasting. *Atmospheric Environment*, 134, 168–180. <https://doi.org/10.1016/j.atmosenv.2016.03.056>
- Pourheydari, O., & Koopaei, H. M. (2010). Predicting of firm’s financial distress by use of linear discriminant function the model. *Financial Accounting Researches*, 2(1), 33-46. [In Persian].
- Radovanovic, J., & Haas, C. (2023). The evaluation of bankruptcy prediction models based on socio-economic costs, *Expert Systems with Applications*, 227, 120275. <https://doi.org/10.1016/j.eswa.2023.120275>
- Raei, R., Jafari, G., & Namaki, A. (2010). Analysis of Tehran Stock Exchange by Complex Network based on Threshold method. *Accounting and Auditing Review*, 17(4), 33-80. [https://acctgrev.ut.ac.ir/article\\_22517.html](https://acctgrev.ut.ac.ir/article_22517.html) [In Persian].
- Sankhwar, S., Gupta, D., Ramya, K. C. Sheeba Rani, S., Shankar, K., & Lakshmanprabu, S. K. (2020). Improved grey wolf optimization-based feature subset selection with fuzzy neural classifier for financial crisis prediction. *Soft Computing*, 24, 101–110. <https://doi.org/10.1007/s00500-019-04323-6>
- Sedaghati, S., Farhadi, R., Fallah S, L, M. (2021). Portfolio management based on the topology of the Iranian stock market network. *Bi-Quarterly Scientific Journal of Islamic Finance Researches*, 10(1), 151-186. <https://www.doi.org/10.30497/ifr.2021.240229.1592> [In Persian].
- Sheng, J., Dai, J., Wang, B., Duan, G., Long, J., Zhang, J., ... & Guan, W. (2020). Identifying influential nodes in complex networks based on global and local structure, *Physica A: Statistical Mechanics and its Applications*, 541, 123262. <https://doi.org/10.1016/j.physa.2019.123262>
- Sulaiman, M. H., Mustaffa, Z., Mohamed, M. R., & Aliman, O. (2015). Using the gray wolf optimizer for solving optimal reactive power dispatch problem. *Applied Soft Computing*, 32, 286-292. <https://doi.org/10.1016/j.asoc.2015.03.041>
- Sun, J., & Li, H. (2008). Data mining method for listed companies’ financial distress prediction. *Knowledge Based Systems*, 21(1), 1–5. <https://doi.org/10.1016/j.knosys.2006.11.003>
- Taieb, S. B., & Hyndman, R. J. (2014). A gradient boosting approach to the Kaggle load forecasting competition. *International Journal of Forecasting*, 30(2), 382–394. <https://doi.org/10.1016/j.ijforecast.2013.07.005>
- Tajmazinani, M., Fallahpour, S., & Bajalan, S. (2015). The Use of Feature Selection Method (HARC) in predicting financial distress in Tehran Stock Exchange. *Financial Management Strategy*, 3(9), 77-106. <https://doi.org/10.22051/jfm.2015.2169> [In Persian].
- Yang, B., Li, L. X., Xie, Q., & Xu, J. (2001). Development of a KBS for managing bank loan risk. *Knowledge Based Systems*, 14(5-6), 299–302. [https://doi.org/10.1016/S0950-7051\(01\)00109-5](https://doi.org/10.1016/S0950-7051(01)00109-5)
- Zhang, Y., & Haghani, A. (2015). A gradient boosting method to improve travel time prediction. *Transportation Research Part C: Emerging Technologies*, 58, 308–324. <https://doi.org/10.1016/j.trc.2015.02.019>



- Zheng, Z., Zha, H., Zhang, T., Chapelle, O., Chen, K., & Sun, G. (2008). A general boosting method and its application to learning ranking functions for web search. *Advances in neural Information Processing Systems*, 20, 1697–1704.
- Zhou, Y., Bao, L., & Chen, C. P. (2014). A new 1D chaotic system for image encryption. *Signal Processing*, 97, 172–182. <https://doi.org/10.1016/j.sigpro.2013.10.034>

