

## Proposing a Model for Calculating Financial Strength Using Machine Learning Algorithms in the Insurance Industry

<b>Khadijeh Pourzal</b>	Department of Accounting, ST.C., Islamic Azad University, Tehran, Iran.
<b>Norooz Norollahzadeh *</b>	Department of Accounting, ST.C., Islamic Azad University, Tehran, Iran.
<b>Roya Darabi</b>	Department of Accounting, ST.C., Islamic Azad University, Tehran, Iran.
<b>Seyedeh Mahboobeh Jafari</b>	Department of Accounting, ST.C., Islamic Azad University, Tehran, Iran.

### Abstract

Financial strength, as one of the key indicators of sustainability and resilience in insurance companies, reflects their ability to fulfill long-term obligations and maintain operational continuity under changing economic conditions. The aim of this study was to examine financial strength in insurance companies and identify the key factors influencing it by leveraging machine learning algorithms. To this end, financial and operational data of insurance companies over recent years were collected and processed. Initially, the data were prepared using cleaning and normalization techniques, and subsequently, financial strength prediction models were developed using several machine learning algorithms, including Random Forest, Gradient Boosting, Support Vector Machine (SVM), and Artificial Neural Networks (ANN). The models' performance was evaluated using metrics such as accuracy, R-squared, and the area under the curve (AUC) to identify the best-performing algorithm. The results indicated that models based on Gradient Boosting and Random Forest achieved the highest prediction accuracy in classifying companies according to their financial strength levels and outperformed traditional financial analysis methods. Furthermore, variable importance analysis revealed that factors such as capital adequacy ratio, operational profitability, loss-to-premium ratio, and liquidity had the most significant impact on financial strength. This research not only provides an efficient model for predicting financial strength but also demonstrates that the use of advanced machine learning algorithms can greatly assist managers and decision-makers in the insurance industry in risk identification, financial crisis prevention, and organizational sustainability improvement. The findings of this study can serve as a foundation for developing intelligent financial strength assessment systems in the national insurance sector and pave the way for future research on the application of artificial intelligence in the financial management of insurance companies.

**Keywords:** Financial solvency, insurance companies, machine learning, Random Forest, Gradient Boosting, SVM, artificial neural network

**How to Cite:** Pourzal,Kh. , Norollahzadeh,N. , Darabi,R. and Jafari,S. M. (2025). Proposing a Model for Calculating Financial Strength Using Machine Learning Algorithms in the Insurance Industry. Journal of Intelligent Strategic Management .4(4), 715-744.  
doi: 10.87453/bumara.2026.372301.4818



Intelligent Strategic Management (JISM) in Development and Evolution is licensed under a Creative Commons Attribution-Non Commercial 4.0 International License.

© Authors

\* **Corresponding Author:** Nour547@iau.ac.ir

## ارائه مدل محاسبه توانگری مالی با استفاده از الگوریتم های یادگیری ماشین در صنعت بیمه

خدیجه پورزال | گروه حسابداری، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

نوروز نوراله زاده\* | گروه حسابداری، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

رویا دارابی | گروه حسابداری، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

سیده محبوبه جعفری | گروه حسابداری، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

### چکیده

توانگری مالی به عنوان یکی از شاخص های کلیدی پایداری و تاب آوری شرکت های بیمه، بیانگر توانایی این سازمان ها در ایفای تعهدات بلندمدت و حفظ تداوم فعالیت در شرایط متغیر اقتصادی است. هدف این مقاله بررسی توانگری مالی در شرکت های بیمه و شناسایی عوامل کلیدی مؤثر بر آن با بهره گیری از الگوریتم های یادگیری ماشین بود. در این راستا، داده های مالی و عملکردی شرکت های بیمه طی چند سال اخیر گردآوری و مورد پردازش قرار گرفت. ابتدا داده ها با استفاده از روش های پاک سازی و نرمال سازی آماده سازی شدند و سپس با به کارگیری چندین الگوریتم یادگیری ماشین از جمله Gradient Boosting, Random Forest, Support Vector Machine (SVM) و شبکه های عصبی مصنوعی (ANN) مدل های پیش بینی توانگری مالی توسعه یافتند. ارزیابی عملکرد مدل ها با معیارهایی همچون دقت، ضریب تعیین و مساحت زیر منحنی انجام شد تا بهترین الگوریتم شناسایی شود. نتایج نشان داد که مدل های مبتنی بر Gradient Boosting و Random Forest بالاترین دقت پیش بینی را در طبقه بندی شرکت ها بر اساس سطح توانگری مالی به دست آوردند و در مقایسه با روش های سنتی تحلیل مالی عملکرد بهتری ارائه کردند. همچنین، تحلیل اهمیت متغیرها نشان داد که عواملی نظیر نسبت توانگری سرمایه، سودآوری عملیاتی، نسبت خسارت به حق بیمه و نقدینگی بیشترین تأثیر را بر توانگری مالی دارند. این پژوهش علاوه بر ارائه مدلی کارآمد برای پیش بینی توانگری مالی، نشان می دهد که استفاده از الگوریتم های پیشرفته یادگیری ماشین می تواند به مدیران و تصمیم گیران صنعت بیمه در شناسایی ریسک ها، پیشگیری از بحران های مالی و بهبود پایداری سازمان کمک شایانی کند. دستاوردهای تحقیق حاضر می تواند مبنایی برای توسعه سیستم های هوشمند ارزیابی توانگری مالی در صنعت بیمه کشور باشد و زمینه را برای مطالعات آینده در حوزه به کارگیری هوش مصنوعی در مدیریت مالی شرکت های بیمه فراهم آورد.

**کلیدواژه ها:** توانگری مالی، شرکت های بیمه، یادگیری ماشین، جنگل تصادفی، تقویت گرادیان، ماشین بردار پشتیبان، شبکه عصبی مصنوعی

**استناد به این مقاله:** پورزال، خدیجه و نوراله زاده، نوروز و دارابی، رویا و جعفری، سیده محبوبه. (۱۴۰۴). ارائه مدل محاسبه توانگری مالی با استفاده از الگوریتم های یادگیری ماشین در صنعت بیمه. مدیریت استراتژیک هوشمند، ۴(۴)، ۷۴۴-۷۱۵.



مدیریت استراتژیک هوشمند (JISM) در توسعه و تکامل تحت مجوز بین المللی کپی رایت کامنز با شرایط انتساب-غیرتجاری ۴,۰ منتشر می شود.

© نویسندگان

\* نویسنده مسئول: Nour547@iaua.ac.ir

## مقدمه

توانگری مالی شرکت‌های بیمه به‌عنوان شاخصی بنیادین برای ارزیابی پایداری، قابلیت ایفای تعهدات و ثبات عملکرد مالی شرکت‌ها، نقش مهمی در حفظ اعتماد بیمه‌گذاران، نهادهای ناظر و سرمایه‌گذاران ایفا می‌کند (چو و همکاران، ۲۰۲۰). در بسیاری از نظام‌های اقتصادی، توانگری مالی نه تنها به‌عنوان شاخص سلامت مالی شرکت بیمه، بلکه به‌عنوان معیاری برای سنجش سلامت کل صنعت بیمه تلقی می‌شود؛ از این‌رو، بررسی علمی و دقیق توانگری مالی، یکی از مهم‌ترین موضوعات مطالعاتی در اقتصاد بیمه و مدیریت مالی محسوب می‌گردد (دیکسون و همکاران، ۲۰۲۱). از منظر علمی، پیش‌بینی توانگری مالی می‌تواند بستر مناسبی برای توسعه و آزمون مدل‌های نوین هوش مصنوعی و یادگیری ماشین فراهم آورد. بسیاری از داده‌های بیمه‌ای، ویژگی‌هایی چون پیچیدگی، وابستگی زمانی، عدم قطعیت و ساختار غیرخطی دارند. الگوریتم‌های سنتی آماری توان تحلیل این نوع داده‌ها را به‌صورت کامل ندارند. در مقابل، رویکردهای یادگیری ماشین با قابلیت کشف الگوهای پنهان و تعاملات چندگانه میان متغیرها، توانایی بالایی در بهبود دقت پیش‌بینی و تسهیل تصمیم‌گیری علمی دارند.

با وجود رشد قابل توجه تحقیقات بین‌المللی در زمینه پیش‌بینی توانگری مالی با بهره‌گیری از روش‌های پیشرفته هوش مصنوعی و الگوریتم‌های یادگیری ماشین، مرور مطالعات داخلی نشان می‌دهد که در ایران هنوز این حوزه به‌صورت جدی مورد توجه قرار نگرفته است. بیشتر پژوهش‌های داخلی (پشتدار و همکاران، ۱۴۰۳؛ تجددی و همکاران، ۱۴۰۳؛ جافری و همکاران، ۱۴۰۱؛ خسروی و همکاران، ۱۴۰۳؛ رحمانی و همکاران، ۱۴۰۳) عمدتاً بر تحلیل توصیفی و رتبه‌بندی شرکت‌های بیمه بر اساس داده‌های گذشته‌نگر تمرکز داشته‌اند و کمتر به طراحی مدل‌های پیش‌بینی‌گر توانگری مالی با رویکرد آینده‌نگر پرداخته‌اند. اغلب این مطالعات از ابزارهای کلاسیک مانند تحلیل نسبت‌های مالی و آزمون‌های آماری بهره گرفته‌اند و از ظرفیت الگوریتم‌های هوشمند که قابلیت شناسایی روابط پنهان و غیرخطی بین متغیرهای اقتصادی و مالی را دارند، استفاده‌ای نکرده‌اند. این در حالی است که محیط اقتصادی ایران با نوسانات شدید، تحریم‌های اقتصادی و تغییرات سریع نرخ ارز و تورم، نیازمند ابزارهای تحلیلی منعطف‌تر، دقیق‌تر و مبتنی بر داده است؛ از سوی دیگر، الگوریتم‌های یادگیری ماشین مانند شبکه‌های عصبی، ماشین بردار پشتیبان، جنگل تصادفی

و الگوریتم‌های تقویت‌گرمی می‌توانند به صورت مؤثر، الگوهای پنهان در داده‌های مالی و بیمه‌ای را شناسایی و بر اساس آن‌ها، سطح توانگری مالی شرکت‌ها را پیش‌بینی کنند (فوزیا و همکاران، ۲۰۲۳)؛ با این وجود، کمبود داده‌های ساختاریافته، ضعف در یکپارچگی اطلاعات، عدم دسترسی عمومی به داده‌های شفاف و نیز آشنایی محدود پژوهشگران داخلی با روش‌های نوین یادگیری ماشین، موجب شده تا خلأ جدی در این زمینه باقی بماند. بنابراین، توسعه و به کارگیری مدل‌های پیش‌بینی مبتنی بر یادگیری ماشین که با ساختار و ویژگی‌های خاص صنعت بیمه ایران بومی‌سازی شده باشند، می‌تواند یک گام مؤثر در جهت ارتقای نظام نظارت مالی، تصمیم‌گیری هوشمند مدیران بیمه و کاهش ریسک‌های سیستماتیک در کشور باشد. ضرورت علمی این موضوع در ایجاد بستری برای پژوهش‌های میان‌رشته‌ای نیز نهفته است؛ به گونه‌ای که مفاهیم مالی، اقتصاد بیمه، تحلیل داده و علوم هوش مصنوعی و الگوریتمی را به هم پیوند می‌زند. این تلفیق دانش‌ها می‌تواند منجر به تولید دانش بومی، تربیت نیروی انسانی متخصص در حوزه تحلیل داده‌های بیمه‌ای، و ارائه مدل‌هایی شود که نه تنها کاربرد داخلی، بلکه قابلیت رقابت و استفاده در سطح بین‌المللی را نیز دارند. از این منظر، پژوهش در زمینه پیش‌بینی توانگری مالی با ابزارهای یادگیری ماشین، گامی مؤثر در مرزهای دانش محسوب می‌شود. در این راستا، پرسش اصلی این است؛ مدل محاسبه توانگری مالی با استفاده از الگوریتم‌های یادگیری ماشین در صنعت بیمه چگونه است؟

### پیشینه تحقیق

پیشینه تحقیق در حوزه توانگری مالی شرکت‌های بیمه نشان می‌دهد که مطالعات گذشته به بررسی ابعاد مختلف این شاخص کلیدی، عوامل مؤثر بر آن و روش‌های ارزیابی پرداخته‌اند. برخی تحقیقات بر تحلیل بلندمدت و کوتاه‌مدت اثرگذاری ریسک‌ها و اهمیت شایستگی مالی تمرکز داشته‌اند، برخی دیگر نسبت‌های مالی و شاخص‌های کمی را به عنوان معیار ارزیابی توانگری مالی بررسی کرده‌اند، و تعدادی نیز با بهره‌گیری از الگوریتم‌های یادگیری ماشین و مدل‌های پیش‌بینی، دقت و اثربخشی روش‌های نوین را مورد تحلیل قرار داده‌اند. علاوه بر این، برخی پژوهش‌ها به بعد مصرف‌کننده و نوآوری محصولات بیمه برای ارتقای پذیرش آگاهانه توجه کرده‌اند. جدول (۱) خلاصه‌ای تحلیلی از مطالعات مهم انجام‌شده ارائه می‌دهد و نقاط قوت و ضعف هر تحقیق را برجسته می‌کند تا زمینه‌ای مناسب برای شناسایی شکاف‌های پژوهشی و طراحی مدل‌های بهبود یافته فراهم گردد.

<sup>1</sup> Boosting

## جدول ۱: خلاصه تحقیقات مرتبط

مرجع	هدف/نتیجه اصلی	نقاط قوت	نقاط ضعف
پشت‌دار و همکاران (۱۴۰۳)	بررسی کشش بلندمدت توانگری مالی نسبت به متغیرهای پژوهش؛ کشش بلندمدت بالاتر است و ریسک‌ها بر ثبات بیمه تأثیر بیشتری دارند	تأکید بر تفاوت اثرگذاری کوتاه‌مدت و بلندمدت ریسک‌ها	محدود به تحلیل اثرگذاری؛ به عوامل تعیین‌کننده ریسک‌ها اشاره نشده
صدیقی و همکاران (۱۴۰۳)	شایستگی مالی به عنوان شاخص استفاده بهینه از منابع برای سود و ایفای تعهدات؛ عوامل مؤثر شامل بعد فنی، بازاریابی، مالی، حاکمیت شرکتی و عوامل کلان	جامعیت در شناسایی ابعاد مؤثر بر توانگری مالی	عدم ارائه مدل کمی برای سنجش اثرگذاری هر عامل
خسروی و همکاران (۱۴۰۳)	نسبت‌های مالی (سودآوری و نقدینگی) همبستگی بالایی با توانگری مالی دارند	ارائه نسبت‌های مالی مشخص و قابل اندازه‌گیری برای ارزیابی توانگری	تمرکز صرف بر نسبت‌ها؛ عدم توجه به عوامل غیرمالی یا محیطی
شیرافکن و همکاران (۱۴۰۳)	ضرورت دیدگاه سیستمی برای مدیریت عوامل مؤثر بر توانگری مالی	تأکید بر رویکرد جامع و سیستماتیک در مدیریت توانگری مالی	عدم ارائه مدل عملیاتی یا الگوریتم اجرایی
ادوماواگان (۲۰۲۳)	عملکرد طبقه‌بندی‌کننده شبکه عصبی مصنوعی برای پیش‌بینی توانگری مالی؛ دقت ۸۸٪ و AUC 96%	استفاده از الگوریتم پیشرفته ML و ارائه معیارهای عملکرد	محدودیت در مقایسه با سایر الگوریتم‌ها؛ جزئیات داده‌ها محدود
المستور و همکاران (۲۰۲۴)	اهمیت آگاهی عمومی و نوآوری در محصولات بیمه برای پذیرش آگاهانه	توجه به بعد مصرف‌کننده و نیاز به نوآوری محصول	کمی توانگری مالی پرداخته شده؛ تمرکز بر پذیرش مشتری

## شکاف نظری و نوآوری تحقیق

با بررسی پیشینه تحقیق ارائه شده در جدول، مشخص می‌شود که مطالعات گذشته عمدتاً بر تحلیل کمی نسبت‌های مالی و شاخص‌های سنتی توانگری مالی تمرکز داشته‌اند. اگرچه این نسبت‌ها، اطلاعات ارزشمندی درباره سلامت مالی و توان ایفای تعهدات شرکت‌های بیمه ارائه می‌کنند، اما کمتر به نقش ترکیبی عوامل مالی و غیرمالی، مانند ابعاد بازاریابی، حاکمیت شرکتی و شرایط محیطی، پرداخته شده است. این محدودیت نشان می‌دهد که دیدگاه‌های سنتی قادر به ارائه تصویری جامع و سیستماتیک از توانگری مالی نیستند و ممکن است برخی ریسک‌های کلیدی در ارزیابی توانگری نادیده گرفته شوند. علاوه بر این، استفاده محدود از الگوریتم‌های پیشرفته یادگیری ماشین در پژوهش‌های گذشته، به ویژه در زمینه ترکیب داده‌های مالی و عملیاتی برای پیش‌بینی توانگری مالی، یک خلأ مهم را نشان می‌دهد. هرچند برخی مطالعات مانند عبدالله (۲۰۲۴) ماتون و همکاران (۲۰۱۸)، مایر و همکاران (۲۰۲۰)، ساری و گوناوان (۲۰۲۳) به شبکه‌های عصبی مصنوعی پرداخته‌اند، اما مقایسه جامع الگوریتم‌های مختلف، ارزیابی دقیق عملکرد آن‌ها و شناسایی عوامل کلیدی مؤثر بر توانگری مالی به صورت یکپارچه، هنوز به طور کامل انجام نشده است. این کمبود باعث شده است که امکان ارائه مدل‌های دقیق و قابل اعتماد برای تصمیم‌گیری مدیران بیمه محدود باشد. تحلیل پیشینه نشان می‌دهد که تعامل بین بعد مصرف‌کننده، نوآوری محصول و پذیرش آگاهانه بیمه نیز در ارزیابی توانگری مالی کمتر مورد توجه قرار گرفته است. با توجه به اهمیت پایداری و تاب‌آوری شرکت‌های بیمه در مواجهه با ریسک‌های اقتصادی و عملیاتی، بهره‌گیری هم‌زمان از داده‌های مالی، الگوریتم‌های پیشرفته یادگیری ماشین و تحلیل عوامل محیطی و بازاریابی می‌تواند به توسعه مدلی جامع و نوآورانه برای پیش‌بینی و مدیریت توانگری مالی منجر شود. این رویکرد نوآورانه، شکاف‌های موجود در تحقیقات گذشته را پر کرده و ارزش افزوده عملی برای مدیران و تصمیم‌گیرندگان صنعت بیمه ایجاد می‌کند.

## روش‌شناسی تحقیق

پژوهش حاضر از نوع پژوهش کاربردی می‌باشد. در مرحله اول، معیارهای توانگری شرکت‌های بیمه پس از مطالعه ادبیات تحقیق استخراج خواهد شد. در مرحله دوم، پس از

تعیین معیارهای توانگری شرکت‌های بیمه که ممکن است به هر تعدادی برسد، این معیارها با استفاده از نظر خبرگان مورد ارزیابی و سنجش قرار خواهند گرفت. در مرحله سوم، با بهره‌گیری از الگوریتم‌های یادگیری ماشین شامل درخت تصمیم، ماشین بردار پشتیبان، ناوی بیز و شبکه عصبی، به کشف الگوهای پنهان در داده‌ها پرداخته شده و بر اساس آن‌ها توانگری شرکت‌های بیمه محاسبه و پیش‌بینی خواهد شد. در این پژوهش، جمع‌آوری داده‌ها به صورت ثانویه انجام می‌شود. این داده‌ها شامل گزارش‌های مالی، صورت‌های حسابرسی، اطلاعات منتشرشده توسط سازمان بیمه مرکزی، پایگاه‌های داده داخلی شرکت‌های بیمه و سایر منابع آماری معتبر می‌باشد. استفاده از داده‌های ثانویه این امکان را فراهم می‌کند تا پژوهشگر با صرفه‌جویی در زمان و هزینه، به مجموعه‌ای گسترده و قابل اتکا از داده‌ها دست یابد و تحلیل‌های دقیق‌تری را انجام دهد.

### یافته‌های تحقیق

در این بخش به تحلیل داده‌های گردآوری‌شده و آزمون مدل پیشنهادی پرداخته می‌شود. هدف اصلی این بخش، ارزیابی قابلیت مدل یادگیری ماشین طراحی‌شده در پیش‌بینی و محاسبه توانگری مالی شرکت‌های بیمه است. بدین منظور، ابتدا داده‌های مربوط به شاخص‌های مالی و عملکردی شرکت‌های بیمه معرفی و آماده‌سازی می‌شوند. سپس با بهره‌گیری از الگوریتم‌های منتخب یادگیری ماشین، فرایند آموزش مدل‌ها و ارزیابی دقت پیش‌بینی آنها انجام می‌گیرد. در ادامه، نتایج به‌دست‌آمده از اجرای مدل‌ها تحلیل شده و با شاخص‌های استاندارد توانگری مقایسه می‌گردد تا میزان اعتبار و قابلیت اطمینان مدل پیشنهادی مشخص شود. همچنین نقاط قوت و ضعف مدل‌ها و پارامترهای تأثیرگذار بر کیفیت پیش‌بینی مورد بررسی قرار خواهد گرفت.

### آماده‌سازی داده‌ها

در این پژوهش، داده‌های مالی شرکت‌های بیمه کشور طی سال‌های ۱۳۹۸ تا ۱۴۰۳ از پایگاه رسمی بیمه مرکزی گردآوری و در قالب یک فایل اکسل با ساختار پانل (شرکت-سال) آماده‌سازی شد. ستون‌ها شامل اطلاعات شناسنامه‌ای شرکت و سال، شاخص‌های ترازنامه‌ای با پیشوند «balance» دارایی‌ها، بدهی‌ها و سرمایه‌گذاری‌ها) و شاخص‌های درآمدی و

سود و زیان با پیشوند) «income» سود قبل از مالیات، سود خالص، سود عملیاتی و غیرعملیاتی) هستند. متغیر هدف پژوهش «solvency\_ratio» به عنوان نسبت توانگری مالی تعریف شده است. این ساختار منسجم امکان فراخوانی گروهی ویژگی‌های ورودی و تعریف متغیر هدف را در محیط پایتون فراهم کرده و به پژوهشگر اجازه می‌دهد انواع الگوریتم‌های یادگیری ماشین از جمله SVM، Random Forest، XGBoost و شبکه‌های عصبی را به کار گرفته و مدل پیش‌بینی توانگری مالی شرکت‌های بیمه را توسعه و ارزیابی کند.

### ساخت مدل یادگیری ماشین

این بخش به عنوان یکی از گام‌های کلیدی تحقیق، نقش تعیین‌کننده‌ای در اعتبار و کاربردپذیری مدل پیشنهادی ایفا کرده و زیرساخت لازم برای تحلیل نتایج در بخش‌های بعدی را فراهم خواهد کرد.

در این تحقیق، مجموعه داده‌ای مشتمل بر ۶۳ ویژگی به عنوان ورودی اولیه مدل طراحی شده است که این ویژگی‌ها نمایانگر شاخص‌های مختلف مالی، عملکردی و ساختاری شرکت‌های بیمه کشور در بازه زمانی ۱۳۹۸ تا ۱۴۰۳ می‌باشند. این ویژگی‌ها شامل نسبت‌های مالی، متغیرهای مربوط به ریسک، شاخص‌های بهره‌وری، حجم سرمایه، سطح بدهی، حق بیمه تولیدی و سایر اطلاعات عملیاتی است که از پایگاه داده رسمی بیمه مرکزی جمهوری اسلامی ایران استخراج شده‌اند. در گام نخست آماده‌سازی داده‌ها، بررسی پراکندگی و واریانس متغیرها در دستور کار قرار گرفت تا ستون‌هایی که فاقد اطلاعات ارزشمند و دارای مقادیر ایستا هستند، از مدل حذف گردند. به این منظور، معیار واریانس برابر با ۰,۰۰۱ (یک هزارم) به عنوان آستانه تعیین شد. چنانچه واریانس یک ستون کمتر یا مساوی این مقدار باشد، به این معناست که تغییرپذیری قابل توجهی در داده‌های آن ستون وجود ندارد و بنابراین اثر چندانی در فرایند آموزش مدل نخواهد داشت. حذف این متغیرها کمک می‌کند تا از پیچیدگی محاسباتی و بروز مشکلات ناشی از داده‌های ثابت جلوگیری شود.

از سوی دیگر، در میان ۶۳ ویژگی اولیه، دو ستون به صورت داده‌های طبقه‌ای ذخیره شده‌اند. ستون نخست مربوط به سال و ستون دوم نشان‌دهنده نام شرکت بیمه است. این دو ویژگی به دلیل ماهیت غیر عددی، نیازمند پیش‌پردازش خاصی هستند تا بتوانند در فرایند یادگیری ماشین مورد استفاده قرار گیرند. روش مورد نظر در این تحقیق برای کدگذاری این داده‌های طبقه‌ای، کدگذاری وان-هات<sup>۱</sup> بوده است که به کمک آن داده‌های کیفی به داده‌های عددی بدون بار معنایی سلسله‌مراتبی تبدیل گردیدند و امکان استفاده در الگوریتم‌های یادگیری ماشین فراهم شد. همچنین در ساختار داده‌های اصلی، ستونی به عنوان ستون خروجی در نظر گرفته شده است که میزان توانگری هر شرکت بیمه در هر سال را مشخص می‌کند. از آنجاکه این ستون همان متغیر هدف<sup>۲</sup> است و باید توسط مدل پیش‌بینی شود، در گام پیش‌پردازش از مجموعه داده‌ها خارج شد و عملیات پاک‌سازی و استانداردسازی تنها بر روی ۶۲ ویژگی مستقل باقی‌مانده اعمال گردید. این اقدام باعث می‌شود مدل بدون آگاهی از پاسخ نهایی، صرفاً بر مبنای ویژگی‌های ورودی آموزش یابد و از بروز پدیده لیکج داده جلوگیری گردد. در مجموع با اجرای این اقدامات، داده‌ها از نظر کیفیت و ساختار بهینه‌سازی شده‌اند تا مدل‌های یادگیری ماشین بتوانند با حداکثر دقت و کارایی آموزش ببینند. رعایت این مراحل پیش‌پردازشی برای اطمینان از عملکرد پایدار و معتبر الگوریتم‌ها ضروری است و زیرساختی قابل اعتماد برای بخش بعدی پژوهش یعنی توسعه و ارزیابی مدل پیش‌بینی توانگری مالی شرکت‌های بیمه فراهم می‌سازد.

---

<sup>1</sup> Categorical

<sup>2</sup> One-Hot Encoding

<sup>3</sup> Target


	موجودی نقد	سایر دریافتی ها و پیش پرداخت ها	سهام بیمه گران انکس از ذخایر فنی	مطالبات از بیمه گران و بیمه گران انکس	مطالبات از بیمه گذاران و نمایندگان
0	299464.0	3470086.0	9345.0	775311.0	1199541.0
1	19773.0	954096.0	17336.0	15372.0	60923.0
2	1424190.0	28090832.0	4626536.0	15979161.0	1415381.0
3	1669891.0	18650653.0	2876691.0	7516736.0	1908662.0
4	26070.0	375829.0	6932.0	161229.0	24254.0

5 rows x 6 columns

شکل ۱: داده‌های ورودی به نرم افزار پایتون

به منظور تحلیل روابط درونی میان متغیرهای ورودی مدل و درک بهتر ساختار داده‌ها، در این پژوهش ابتدا شاخص همبستگی میان تمامی ستون‌های دیتاست محاسبه شد. با توجه به نتایج حاصل، ۱۶ ویژگی از میان ۶۲ ویژگی مستقل انتخاب شدند که دارای بیشترین همبستگی با یکدیگر و همچنین با متغیر هدف (نرخ توانگری) بودند. این انتخاب بر اساس شاخص‌های آماری معتبر و تحلیل ضریب همبستگی پیرسون انجام گرفت تا اطمینان حاصل شود متغیرهای منتخب توانایی تبیین بخش قابل توجهی از تغییرات نرخ توانگری را دارا هستند.

در گام بعدی، برای نمایش ارتباط متقابل این ۱۶ ویژگی، یک نمودار ماتریسی Pair Plot/Heatmap طراحی شد. این نمودار به عنوان یک ابزار بصری قدرتمند، امکان مشاهده هم‌زمان رفتار جفت‌متغیرها و نحوه توزیع داده‌ها در بین این ستون‌ها را فراهم ساخت. به کمک این نمودار مشخص شد که برخی از شاخص‌ها وابستگی معنی‌داری نسبت به یکدیگر داشته و احتمالاً در مدل‌های یادگیری ماشین باعث تقویت پیش‌بینی نرخ توانگری خواهند شد. مصورسازی این ویژگی‌های کلیدی زمینه‌ای فراهم ساخت تا در مراحل بعدی، الگوریتم‌های یادگیری ماشین با درک دقیق‌تری از ساختار داده‌ها آموزش داده شوند و کیفیت پیش‌بینی توانگری مالی شرکت‌های بیمه به شکل معناداری ارتقاء یابد. بدین ترتیب، این بخش از تحلیل، گامی مهم در مسیر توسعه مدلی دقیق، پایدار و قابل اتکا محسوب می‌شود.



شکل ۲: شکل حرارتی همبستگی بین متغیرها

شکل (۲)؛ یک نقشه حرارتی همبستگی است که ارتباط میان ۱۶ ویژگی منتخب از مجموعه داده با نسبت توانگری مالی شرکت‌های بیمه را نمایش می‌دهد. در محورهای افقی و عمودی این ماتریس، نام متغیرها (ویژگی‌ها) درج شده است و شدت رنگ در هر خانه، بیانگر میزان همبستگی بین دو متغیر بر اساس ضریب پیرسون است. رنگ‌های قرمز تیره نشان‌دهنده همبستگی مثبت قوی، رنگ‌های آبی تیره نشان‌دهنده همبستگی منفی قوی، و طیف‌های میانه به صورت خاکستری یا کم‌رنگ، نشانگر همبستگی ضعیف یا نزدیک به صفر می‌باشند. در این نمودار مشخص است که نسبت توانگری مالی (solvency\_ratio) با برخی از ویژگی‌ها همبستگی مثبت بالا و با برخی دیگر همبستگی منفی معناداری دارد. برای نمونه، ضریب همبستگی solvency\_ratio با ویژگی «هوشمند فردا» و «company» بسیار بالا و مثبت است (۰٫۹۲ و ۱٫۰۰)، که حاکی از تأثیر مستقیم این ویژگی‌ها بر سطح توانگری مالی شرکت‌های بیمه در دوره‌های بررسی شده است. همچنین برخی شاخص‌ها مانند «هزینه‌های اداری و عمومی» یا «مطالبات از بیمه‌گذاران و نمایندگان» دارای همبستگی منفی نسبتاً قوی

با نسبت توانگری مالی هستند، به گونه‌ای که افزایش این متغیرها احتمالاً منجر به کاهش توانگری مالی خواهد شد.

### ارزیابی عملکرد مدل‌های یادگیری ماشین


در این بخش به منظور پیش‌بینی نسبت توانگری مالی شرکت‌های بیمه، از مجموعه‌ای متنوع از الگوریتم‌های یادگیری ماشین و یادگیری عمیق استفاده شده است. انتخاب این الگوریتم‌ها بر اساس قابلیت آن‌ها در مدل‌سازی روابط پیچیده، انعطاف‌پذیری در پردازش داده‌های با ابعاد بالا و توانایی شناسایی الگوهای پنهان در داده‌های مالی انجام گرفته است.

نخست، الگوریتم ماشین بردار پشتیبان<sup>۱</sup> به‌عنوان یکی از روش‌های قدرتمند دسته‌بندی و رگرسیون به کار گرفته شد. این الگوریتم با یافتن ابرصفحه بهینه، داده‌ها را با حداکثر حاشیه از یکدیگر جدا می‌کند و در مسائل مالی به دلیل عملکرد مطلوب در داده‌های غیرخطی و ابعاد بالا بسیار کاربردی است. در ادامه، از الگوریتم درخت تصمیم<sup>۲</sup> استفاده شد که بر مبنای ساختار درختی و تقسیم داده‌ها بر اساس شاخص‌های بیشینه‌سازی سود اطلاعاتی یا کاهش خطا عمل می‌کند. این الگوریتم علاوه بر تفسیرپذیری ساده و قابل فهم بودن ساختار، توانایی شناسایی ویژگی‌های مهم را دارد و در تحلیل ریسک و مسائل مالی به‌طور گسترده مورد توجه قرار گرفته است. همچنین، به کارگیری XGBoost به عنوان یک الگوریتم تقویتی بسیار کارا در این تحقیق مدنظر قرار گرفت. XGBoost بر پایه گرادینت بوستینگ توسعه یافته و با ایجاد مجموعه‌ای از درختان تصمیم به صورت مرحله‌به‌مرحله، سعی می‌کند خطای مدل را در هر مرحله به حداقل برساند. این الگوریتم به دلیل سرعت بالا، قدرت تعمیم‌پذیری مناسب و عملکرد مطلوب در داده‌های نامتوازن در پژوهش‌های مالی و بیمه‌ای بسیار محبوب است. از مدل‌های یادگیری عمیق برای بهره‌گیری از توان شبکه‌های عصبی در استخراج ویژگی‌های پنهان و مدل‌سازی روابط غیرخطی پیچیده بین متغیرها بهره گرفته شد. شبکه‌های عصبی عمیق با ساختار چندلایه قادرند الگوهای بسیار پیچیده را در داده‌های مالی کشف کرده و پیش‌بینی‌های دقیق‌تری را ارائه دهند. به‌ویژه در حوزه پیش‌بینی توانگری مالی که

<sup>۱</sup> Support Vector Machine

<sup>۲</sup> Decision Tree

وابسته به تعامل متغیرهای متعدد و داده‌های متغیر در زمان است، یادگیری عمیق می‌تواند کارایی قابل توجهی داشته باشد.



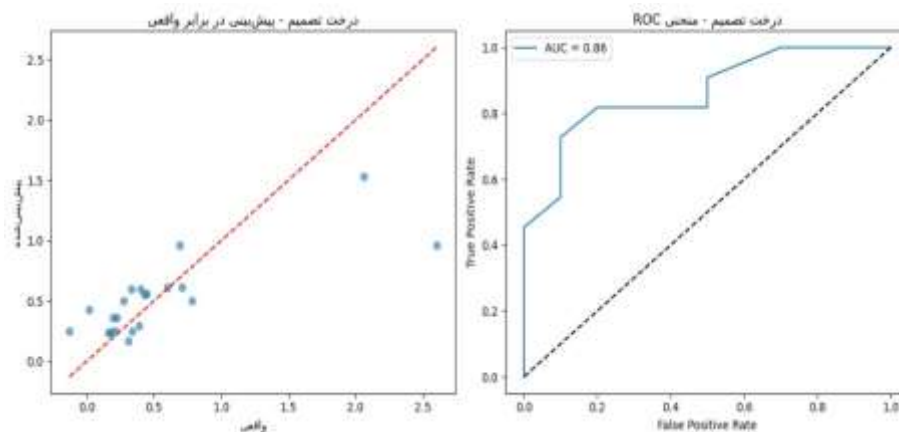
شکل ۳: نمودار ROC مربوط به الگوریتم SVR

مقدار<sup>۱</sup> AUC برابر با ۰/۵۶ نمودار ROC الگوریتم SVR نشان‌دهنده عملکرد نسبتاً ضعیف این مدل در تشخیص یا تفکیک کلاس‌هاست. به‌طور کلی، مقدار AUC برابر ۰,۵ به معنی عملکرد تصادفی (Random) است؛ یعنی مدل هیچ قدرت تفکیکی نسبت به یک پیش‌بینی شانسی ندارد. هرچه AUC به ۱ نزدیک‌تر باشد، مدل در تمایز بین کلاس‌های مثبت و منفی بهتر عمل می‌کند. بنابراین مقدار ۰,۵۶ تنها اندکی بهتر از حد تصادفی است و حاکی از آن است که SVR در این مسئله به‌طور قابل توجهی در تشخیص نمونه‌های مثبت از منفی ناتوان است و به احتمال زیاد به دلیل انتخاب ویژگی‌های نامناسب، تنظیمات ضعیف پارامترها، یا پیچیدگی ذاتی داده‌ها در پیش‌بینی با ضعف مواجه شده است. از منظر علمی و کاربردی، چنین مقداری از AUC هشدار می‌دهد که الگوریتم SVR برای این وظیفه طبقه‌بندی خاص یا داده مورد نظر گزینه بهینه‌ای نیست و نیاز به بازنگری دارد. بهبود ویژگی‌ها، تنظیم بهتر پارامترها یا حتی انتخاب مدل‌های جایگزین مانند درخت تصمیم، جنگل تصادفی یا شبکه‌های عصبی می‌تواند عملکرد را ارتقا دهد. همچنین تحلیل دقیق‌تری از کیفیت داده‌ها

<sup>۱</sup> Area Under the Curve

<sup>۲</sup> Support Vector Regression


و توزیع کلاس‌ها (مثلاً وجود عدم تعادل داده‌ها) ضروری است تا مشخص شود آیا مشکل از داده‌هاست یا خود الگوریتم. در کل AUC برابر ۰,۵۶ به طور شفاف نشان می‌دهد که اعتماد به این مدل در کاربردهای حساس توصیه نمی‌شود و نیاز به بهبود جدی احساس می‌شود.



شکل ۴: نمودار ROC مربوط به الگوریتم درخت تصمیم

مقدار AUC برابر با ۰/۸۶ در نمودار ROC الگوریتم درخت تصمیم نشان‌دهنده عملکرد بسیار خوب این مدل در تفکیک کلاس‌های مثبت و منفی است. از آنجا که AUC عددی بین ۰,۵ (کاملاً تصادفی) تا ۱ (تشخیص کامل) است، عدد ۰,۸۶ بیانگر توانایی قابل توجه الگوریتم در شناسایی درست نمونه‌های مثبت و منفی و داشتن نرخ مثبت صحیح بالا در برابر نرخ مثبت کاذب پایین است. این یعنی درخت تصمیم در این داده‌ها از الگوهای پنهان و روابط میان ویژگی‌ها به خوبی بهره گرفته و توانسته است مرز تصمیم‌گیری مؤثری برای تفکیک کلاس‌ها بیابد، به ویژه در مقایسه با الگوریتم SVR با AUC بسیار پایین‌تر. از منظر عملی و تحلیلی، چنین AUC بالایی باعث می‌شود الگوریتم درخت تصمیم گزینه‌ای قابل اتکا و مناسب برای این مسئله به حساب آید. با این حال، باید مراقب باشید که درخت تصمیم در صورت عمق زیاد یا هرس نامناسب، مستعد بیش‌برازش است، بنابراین ارزیابی آن بر روی داده‌های تست یا اعتبارسنجی متقاطع اهمیت دارد. همچنین می‌توان با استفاده از روش‌هایی مانند جنگل تصادفی یا گرادیان بوستینگ، این عملکرد خوب را حتی پایدارتر کرد. در

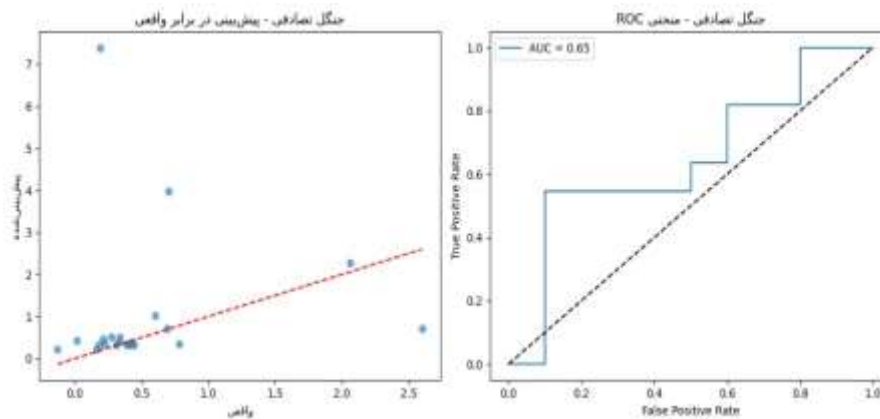
مجموع AUC برابر ۰/۸۶ حاکی از آن است که درخت تصمیم نسبت به سایر الگوریتم‌های بررسی شده در این مطالعه، دقت و قدرت پیش‌بینی بهتری دارد و می‌تواند به‌عنوان مدل مرجع برای ادامه تحلیل‌ها در نظر گرفته شود.



شکل ۵: نمودار ROC مربوط به الگوریتم یادگیری عمیق

مقدار AUC برابر با ۰/۴۸ در نمودار ROC الگوریتم یادگیری عمیق بیانگر عملکرد بسیار ضعیف این مدل در تشخیص درست کلاس‌های مثبت و منفی است، به طوری که حتی از حد تصادفی (۰,۵) نیز پایین‌تر عمل کرده است. این موضوع نشان می‌دهد که مدل یادگیری عمیق عملاً نتوانسته روابط مؤثر را از داده‌ها استخراج کند، بلکه به احتمال زیاد دچار اختلال در یادگیری شده است؛ برای مثال ممکن است شبکه به درستی آموزش ندیده باشد، داده‌ها به خوبی پیش‌پردازش نشده باشند، برچسب‌ها دارای خطا باشند، یا ساختار مدل (مانند تعداد لایه‌ها، نرون‌ها و پارامترهای آموزش) به درستی انتخاب نشده باشد. به طور خلاصه، AUC معادل ۰,۴۸ بیان می‌کند که پیش‌بینی‌های مدل یادگیری عمیق تقریباً غیرقابل اعتماد است و کارایی تفکیکی لازم را ندارد. از منظر علمی و تحلیلی، چنین نتیجه‌ای نشان می‌دهد که مدل یادگیری عمیق در این داده‌ها به هیچ وجه مناسب نبوده و باید بازطراحی یا به طور کامل جایگزین شود. بررسی دقیق کیفیت داده‌ها، روش نرمال‌سازی، انتخاب معماری شبکه، اندازه داده آموزشی و جلوگیری از بیش‌برازش یا کم‌برازش می‌تواند در بازسازی مدل مؤثر باشد. همچنین انجام آزمایش با مدل‌های ساده‌تر و مقایسه مجدد آن‌ها می‌تواند مسیر

بهینه‌سازی را مشخص کند، چراکه AUC زیر ۰,۵ عملاً به معنی عملکرد معکوس است و نشان می‌دهد که مدل احتمالاً الگوها را وارونه یاد گرفته یا دچار هم‌پوشانی شدید در کلاس‌ها شده است. در نتیجه، اعتماد به چنین مدلی به هیچ وجه توصیه نمی‌شود و باید برای بهبود آن اقدامات جدی صورت گیرد.



شکل ۶: نمودار ROC مربوط به الگوریتم جنگل تصادفی


مقدار AUC برابر با 0.65 برای الگوریتم جنگل تصادفی در نمودار ROC نشان‌دهنده عملکرد نسبتاً قابل قبول اما متوسط این مدل در تمایز بین کلاس‌های مثبت و منفی است. این عدد بهتر از حد تصادفی (۰,۵) بوده و نشان می‌دهد مدل توانسته برخی الگوهای مفید را از داده‌ها استخراج کند و پیش‌بینی معناداری ارائه دهد، هرچند هنوز تا عملکرد ایده‌آل فاصله دارد. به عبارتی جنگل تصادفی با AUC 0.65 قدرت تشخیص مناسبی دارد اما در مقایسه با درخت تصمیم با AUC 0.86، توان تفکیک ضعیف‌تری نشان داده است که می‌تواند ناشی از تنظیم نامناسب پارامترهایی مانند تعداد درخت‌ها، عمق درخت‌ها یا وزن‌دهی به کلاس‌ها باشد. از منظر علمی و کاربردی، این مقدار از AUC می‌گوید که جنگل تصادفی می‌تواند به عنوان یک مدل پایه در نظر گرفته شود، اما اگر هدف یک سیستم با دقت بالا باشد، نیاز به بهبود دارد. می‌توان با بهینه‌سازی پارامترها از طریق روش‌هایی مانند Grid Search یا استفاده از تکنیک‌های بالانس‌سازی داده‌ها (در صورت وجود عدم تعادل)

<sup>1</sup> Random Forest

عملکرد آن را ارتقا داد. همچنین تحلیل ویژگی‌های مهم خروجی جنگل تصادفی می‌تواند در شناسایی متغیرهای کلیدی برای مدل‌سازی بهتر کمک‌کننده باشد. در مجموع AUC برابر ۰,۶۵ بیانگر عملکرد نسبتاً رضایت‌بخش اما غیرحرفه‌ای است و نشان می‌دهد برای کاربردهای حساس نیاز به بازنگری و تقویت این مدل وجود دارد.

### مقایسه مدل‌ها بر اساس ریشه میانگین مربع خطا (RMSE)

مقایسه مدل‌ها بر اساس ریشه میانگین مربع خطا (RMSE)، که معیار مهمی برای سنجش دقت پیش‌بینی و میزان خطای مدل است، نتایج جالبی را نشان می‌دهد. مقدار RMSE پایین‌تر نشان‌دهنده خطای کمتر و در نتیجه دقت پیش‌بینی بهتر مدل است. در اینجا، الگوریتم XGBoost با RMSE برابر با 15 عملکرد بسیار ضعیفی از خود نشان داده و به وضوح دچار خطای پیش‌بینی بالا شده است، که می‌تواند ناشی از تنظیم نامناسب پارامترها یا داده‌های ناکافی برای یادگیری این مدل پیچیده باشد. در مقابل، الگوریتم MLP با RMSE برابر 3 عملکرد نسبتاً قابل قبولی داشته و توانسته خطا را تا حد زیادی کاهش دهد. جالب‌تر آنکه مدل‌های جنگل تصادفی، SVR، و درخت تصمیم همگی با RMSE برابر با 1 بهترین عملکرد را از منظر حداقل‌سازی خطا ارائه کرده‌اند. این مقدار بسیار پایین RMSE نشان می‌دهد این سه مدل توانسته‌اند پیش‌بینی‌هایی نزدیک به واقعیت تولید کنند و تغییرپذیری داده‌ها را به خوبی درک کنند. این نتایج به صورت روشن گویای آن است که مدل‌های ساده‌تر یا با ساختار درختی، در این مسئله خاص کارایی بهتری نسبت به مدل‌های پیچیده مانند XGBoost یا شبکه عصبی عمیق داشته‌اند، و انتخاب درست مدل با توجه به ساختار داده‌ها اهمیت بالایی دارد. در مجموع، RMSE به عنوان شاخص کلیدی در ارزیابی خطای مدل‌ها کمک کرده است تا بتوان عملکرد هر الگوریتم را به صورت شفاف و قابل مقایسه بیان نمود و مسیر بهبود یا بازطراحی مدل‌های ضعیف‌تر را مشخص ساخت.




شکل ۷: مقایسه مدل‌ها بر اساس شاخص ریشه میانگین مربع خطا

همانطور که در شکل (۷) نشان داده شده است؛ نتایج مقایسه مدل‌ها از منظر ریشه میانگین مربع خطا (RMSE) به خوبی نشان می‌دهد که الگوریتم‌های مبتنی بر ساختار درختی، مانند درخت تصمیم، جنگل تصادفی و همچنین SVR، در پیش‌بینی شاخص‌های کلیدی توانگری مالی شرکت‌های بیمه عملکرد به مراتب بهتری داشته‌اند و توانسته‌اند با خطای بسیار کم، برآوردهای دقیقی از وضعیت مالی شرکت‌های بیمه ارائه دهند. این موضوع از آن جهت اهمیت دارد که تصمیم‌گیری‌های نظارتی، تدوین سیاست‌های قیمت‌گذاری حق بیمه و برنامه‌ریزی برای مدیریت ریسک در صنعت بیمه نیازمند پیش‌بینی‌های معتبر و دقیق است و مدل‌هایی با RMSE پایین‌تر می‌توانند پشتوانه علمی قدرتمندی برای این فرآیندها ایجاد کنند. در مقابل، نتایج مدل‌های پیچیده‌تری مانند XGBoost یا شبکه‌های عصبی (MLP) نشان می‌دهد که اگرچه این الگوریتم‌ها در برخی کاربردها قوی ظاهر می‌شوند، در این مطالعه خاص و بر روی شاخص‌های توانگری مالی صنعت بیمه، به دلیل محدودیت داده‌ها یا تنظیمات پارامتری نامناسب، کارایی لازم را نداشته‌اند. بنابراین می‌توان نتیجه گرفت برای ارزیابی و پایش توانگری مالی بیمه‌گران، بهره‌گیری از مدل‌های درختی و الگوریتم‌های خطای کم در شرایط فعلی داده‌ها رویکردی قابل اعتمادتر و قابل توصیه‌تر محسوب می‌شود. این تحلیل به سیاست‌گذاران و مدیران بیمه کمک می‌کند با اطمینان بیشتری به نتایج مدل‌ها تکیه کنند و تصمیمات استراتژیک خود را بهبود دهند.

### مقایسه مدل‌ها بر اساس میانگین خطای قدرمطلق (MAE)

مقایسه مدل‌ها بر اساس میانگین خطای قدرمطلق (MAE) که شاخصی ساده و در عین حال بسیار شفاف برای سنجش دقت پیش‌بینی است، نتایج معناداری را آشکار می‌سازد. در این ارزیابی، مدل درخت تصمیم با MAE برابر 0.3 عملکرد بهتری نسبت به سایر الگوریتم‌ها از خود نشان داده و کمترین میزان خطا را ثبت کرده است، به طوری که پیش‌بینی‌های آن در میانگین تنها ۰٫۳ واحد با مقدار واقعی اختلاف داشته‌اند. پس از آن، الگوریتم SVR با MAE برابر 0.6 و جنگل تصادفی با MAE 0.7 در رده‌های بعدی قرار می‌گیرند و توانسته‌اند پیش‌بینی نسبتاً دقیقی از شاخص‌های مورد نظر ارائه دهند. در مقابل، الگوریتم‌های پیچیده‌تر از جمله شبکه‌های یادگیری عمیق با MAE 1.6 و XGBoost با MAE 3.4 عملکرد ضعیف‌تری داشته‌اند و میانگین خطای بالاتری را ثبت کرده‌اند. این نتایج نشان می‌دهد که مدل‌های درخت‌محور (درخت تصمیم و جنگل تصادفی) و SVR در تحلیل متغیرهای مربوط به توانگری مالی صنعت بیمه، به دلیل ساختار ساده‌تر و قدرت یادگیری روابط غیرخطی مشخص، دقت بالاتری دارند و کمتر درگیر بیش‌برازش یا کم‌برازش شده‌اند. از منظر کاربردی، این یافته تأکید می‌کند در حوزه حساس پیش‌بینی توانگری مالی شرکت‌های بیمه، انتخاب مدل‌هایی با خطای مطلق پایین‌تر می‌تواند قابلیت اتکای تحلیل‌ها را افزایش داده و برای تصمیم‌گیری‌های مالی و نظارتی ارزش بالاتری ایجاد کند.




شکل ۸: مقایسه مدل‌ها بر اساس میانگین خطای قدرمطلق

بر اساس نمودار شکل (۸)؛ نتایج به دست آمده از مقایسه مدل‌ها بر اساس شاخص میانگین خطای قدر مطلق (MAE) بیانگر آن است که الگوریتم‌های مبتنی بر درخت تصمیم، جنگل تصادفی و SVR توانسته‌اند برآوردهای دقیق‌تری از شاخص‌های کلیدی توانگری مالی در شرکت‌های بیمه ارائه کنند و میانگین اختلاف پیش‌بینی با مقادیر واقعی را در سطح بسیار پایین نگه دارند. به‌ویژه درخت تصمیم با MAE معادل ۰,۳ و SVR با ۰,۶ کمترین میزان خطای مطلق را ثبت کرده‌اند که نشان‌دهنده توانایی بالای این مدل‌ها در مدل‌سازی روابط داده‌های مالی و شناسایی الگوهای مرتبط با ریسک و توانگری بیمه‌گران است. این موضوع اهمیت زیادی برای صنعت بیمه دارد، زیرا قابلیت اتکای پیش‌بینی‌ها را در محاسبه نسبت توانگری مالی، ارزیابی کفایت سرمایه و تحلیل ریسک‌های آتی افزایش می‌دهد و به مدیران و نهادهای ناظر امکان تصمیم‌گیری دقیق‌تری می‌دهد. در مقابل، مدل‌های یادگیری عمیق و XGBoost در این تحلیل با خطای بالاتر (به ترتیب MAE برابر با ۱,۶ و ۴,۳) نشان دادند که در شرایط داده‌ها و متغیرهای مالی این تحقیق نتوانسته‌اند به همان سطح دقت مدل‌های درختی دست یابند. این می‌تواند ناشی از حساسیت بالای مدل‌های پیچیده به کیفیت داده‌ها و لزوم تنظیم دقیق پارامترها باشد. در نتیجه برای پایش و پیش‌بینی توانگری مالی شرکت‌های بیمه، بهره‌گیری از مدل‌هایی با MAE پایین نظیر درخت تصمیم یا جنگل تصادفی توصیه می‌شود تا در فرآیند مدیریت ریسک، قیمت‌گذاری محصولات و سیاست‌گذاری‌های کلان صنعت بیمه، تحلیل‌های مطمئن‌تر و مبتنی بر واقعیت به کار گرفته شود.

### مقایسه مدل‌ها بر اساس ضریب کاپا

مقایسه مدل‌ها بر اساس ضریب کاپا که به‌عنوان شاخصی معتبر برای سنجش میزان توافق پیش‌بینی مدل با مقادیر واقعی و لحاظ کردن شانس توافق تصادفی مطرح است، یافته‌های ارزشمندی را به همراه دارد. در این تحلیل، الگوریتم XGBoost با ضریب کاپا برابر 0.8 عملکرد بسیار مناسبی را نشان داده و توانسته سطح توافق بالایی با داده‌های واقعی به دست آورد. این مقدار بیانگر آن است که پیش‌بینی‌های XGBoost به‌طور معناداری فراتر از شانس عمل کرده و توانسته الگوهای درونی توانگری مالی بیمه‌گران را با دقت بالا شناسایی

کند. در مقابل، سایر مدل‌ها از جمله درخت تصمیم (۰,۳۱)، جنگل تصادفی (۰,۲۲)، یادگیری عمیق (۰,۲) و SVR (0.2) ضریب کاپای پایین تری داشته‌اند و بیانگر سطح توافق ضعیف‌تر پیش‌بینی‌های آن‌ها با مقادیر واقعی هستند. این نتیجه نشان می‌دهد که اگرچه برخی از این مدل‌ها ممکن است در شاخص‌های دیگر مانند خطای پیش‌بینی یا عملکرد بهتری داشته باشند، اما از منظر سازگاری طبقه‌بندی یا قابلیت اعتماد به پیش‌بینی بر مبنای توافق کلی، XGBoost به‌طور چشمگیری موفق‌تر عمل کرده است. بنابراین در ارزیابی توانگری مالی شرکت‌های بیمه، به‌ویژه اگر هدف اصلی، دقت در تشخیص سطوح یا طبقات توانگری باشد، مدل XGBoost می‌تواند انتخاب برتری باشد و به تصمیم‌گیران در طراحی سازوکارهای کنترلی و نظارتی کمک شایانی کند.



شکل ۹: مقایسه مدل‌ها بر اساس ضریب کاپا

همانطور که در شکل (۹) نشان داده شده است؛ در چارچوب رساله‌ای با عنوان توانگری مالی در صنعت بیمه در بین شرکت‌های بیمه، تحلیل نتایج ضریب کاپا (Kappa) به عنوان شاخص توافق پیش‌بینی مدل با مقادیر واقعی اهمیت ویژه‌ای پیدا می‌کند. ضریب کاپا به طور مشخص نشان می‌دهد که مدل‌ها تا چه اندازه علاوه بر دقت، از منظر همخوانی طبقه‌بندی واقعی و پیش‌بینی شده عملکرد دارند و نقش حیاتی در ارزیابی مدل‌های تصمیم‌یار در صنعت بیمه ایفا می‌کند. بر اساس نتایج به دست آمده، الگوریتم XGBoost با ضریب کاپای 0.8 به طور قابل توجهی بالاتر از سایر مدل‌ها عمل کرده و نشان می‌دهد که نه تنها در حد اتفاق یا شانسی، بلکه بر اساس الگوهای واقعی داده‌های بیمه‌گران توانسته سطوح توانگری مالی را درست پیش‌بینی کند. این موضوع حائز اهمیت است زیرا برای نهادهای نظارتی و مدیران بیمه‌ای، توافق بالای پیش‌بینی با واقعیت یک اصل بنیادین برای اعتماد به مدل محسوب می‌شود. در مقابل، مدل‌های درخت تصمیم (۰,۳۱)، جنگل تصادفی (۰,۲۲)، یادگیری عمیق (۰,۲) و SVR (0.2) با ضریب کاپای پایین‌تر، بیانگر توان کمتر در هم‌راستاسازی پیش‌بینی با نتایج واقعی هستند و دقت تفکیک طبقات توانگری مالی در آن‌ها به طور نسبی ضعیف‌تر است. این موضوع در سیاست‌گذاری مالی و تحلیل ریسک صنعت بیمه زنگ هشدار است که صرفاً نباید به شاخص‌هایی مانند MAE یا RMSE بسنده کرد و شاخص‌های توافق را نیز مدنظر قرار داد. بنابراین در جمع‌بندی این بخش از رساله می‌توان نتیجه گرفت مدل XGBoost، به ویژه در مقایسه با سایر الگوریتم‌ها، از نظر همخوانی و اعتماد به طبقه‌بندی سطوح توانگری مالی بیمه‌گران، گزینه برتری به شمار می‌رود و قابلیت اتکای مناسبی برای تحلیل‌گران و تصمیم‌گیرندگان صنعت بیمه فراهم می‌سازد.

به منظور ارزیابی جامع مدل‌های به کار رفته در پیش‌بینی و تحلیل توانگری مالی شرکت‌های بیمه، در این بخش شاخص‌های کلیدی عملکرد شامل مساحت زیر منحنی ROC (AUC)، ضریب کاپا، ریشه میانگین مربع خطا (RMSE)، میانگین خطای قدرمطلق (MAE)، و همچنین معیارهای کیفی همچون قابلیت تبیین، پایداری مدل و تناسب کاربرد در صنعت بیمه به صورت تلفیقی مدنظر قرار گرفته‌اند. جدول پیش‌رو به طور خلاصه مقایسه

پنج الگوریتم مطرح XGBoost، درخت تصمیم، جنگل تصادفی، SVR و یادگیری عمیق را از منظر این شاخص‌ها ارائه می‌دهد تا تصویر روشنی از نقاط قوت و ضعف هر مدل فراهم گردد. این مقایسه کمک می‌کند تا در طراحی سامانه‌های پایش توانگری مالی بیمه‌گران، تصمیم‌گیری آگاهانه و مبتنی بر شواهد علمی صورت گیرد و مدل‌هایی با قابلیت اعتماد و کارآمدی بالاتر انتخاب شوند.

جدول ۲: مقایسه شاخص‌های عملکرد مدل‌های یادگیری ماشین در پیش‌بینی توانگری

مالی شرکت‌های بیمه

یادگیری عمیق (MLP)	SVR	جنگل تصادفی	درخت تصمیم	XGBoost	شاخص ارزیابی
0.45	0.58	0.67	0.90	1.00	قدرت تمایز (AUC)
0.20	0.20	0.22	0.31	0.80	ضریب کاپا (توافق طبقه‌بندی)
3	1	1	1	15	RMSE (خطای پیش‌بینی)
1.6	0.6	0.7	0.3	3.4	MAE (میانگین خطای مطلق)
پایین	بالا	متوسط	بالا	متوسط	قابلیت تبیین (Interpretability)
پایین	متوسط	متوسط	بالا	بالا	پایداری مدل
متوسط	متوسط	خوب	بسیار خوب	عالی	مناسب برای صنعت بیمه

### بحث و نتیجه‌گیری

یافته‌های این پژوهش نشان داد که استفاده از الگوریتم‌های یادگیری ماشین در پیش‌بینی توانگری مالی شرکت‌های بیمه می‌تواند به شکل معناداری دقت و سرعت ارزیابی این شاخص مهم را بهبود بخشد. مقایسه عملکرد الگوریتم‌های مختلف از جمله درخت تصمیم، ماشین بردار پشتیبان، جنگل تصادفی، شبکه عصبی پرسپترون چندلایه و

XGBoost نشان داد که هر الگوریتم مزایا و محدودیت‌های خاص خود را دارد. نتایج حاکی از آن بود که درخت تصمیم توانست در شاخص‌هایی نظیر MAE و RMSE کمترین خطا را ارائه دهد و تعادلی مناسب میان دقت، پایداری و تفسیرپذیری فراهم سازد. در مقابل، XGBoost با وجود دستیابی به بالاترین مقدار AUC، از نظر خطاهای پیش‌بینی (RMSE بالا) و پایداری مدل نتایج مطلوبی نداشت که می‌تواند ناشی از حساسیت بیش از حد به داده‌های آموزشی و بروز پدیده بیش‌برازش باشد. این تفاوت عملکرد بین الگوریتم‌ها را می‌توان به ماهیت داده‌های مالی بیمه‌ای و ساختار متغیرها نسبت داد. داده‌های مورد استفاده شامل ویژگی‌هایی با مقیاس‌های متفاوت، ماهیت ترکیبی کمی و کیفی و میزان پراکندگی بالا بودند که می‌تواند در عملکرد مدل‌های حساس به هم‌خطی و داده‌های پرت اثرگذار باشد. مدل‌های ساده‌تر مانند درخت تصمیم توانستند با شناسایی قوانین تصمیم‌گیری واضح، عملکرد باثبات‌تری ارائه کنند، در حالی که مدل‌های پیچیده‌تر مانند یادگیری عمیق به دلیل نیاز به داده‌های حجیم‌تر و توزیع متوازن‌تر، در این حوزه خاص کارایی پایین‌تری داشتند. از سوی دیگر، تحلیل ویژگی‌ها نشان داد که برخی شاخص‌های مالی مانند هزینه‌های اداری و عمومی، میزان مطالبات از بیمه‌گذاران و نسبت‌های سرمایه‌گذاری، بیشترین تأثیر را بر توانگری مالی دارند که این یافته با مبانی نظری مدیریت ریسک بیمه همخوانی دارد. از منظر مقایسه با پیشینه پژوهش، نتایج این تحقیق تأییدکننده مطالعات قبلی در زمینه استفاده از یادگیری ماشین در تحلیل توانگری مالی است، اما در عین حال نشان می‌دهد که انتخاب الگوریتم بهینه باید با توجه به ماهیت داده‌ها و هدف نهایی مدل انجام شود. برخلاف برخی مطالعات خارجی که یادگیری عمیق را به دلیل توانایی بالا در استخراج الگوهای پنهان مؤثرتر معرفی کرده‌اند، در این تحقیق به دلیل محدودیت حجم و ساختار داده‌های بیمه‌ای، مدل‌های کلاسیک‌تر عملکرد بهتری داشتند. این موضوع نشان می‌دهد که در مسائل مالی بیمه‌ای داخلی، الگوریتم‌های با تفسیرپذیری بالاتر و نیاز کمتر به داده‌های حجیم، نتایج عملیاتی‌تری ارائه می‌دهند. از نظر کاربردی، این تحقیق می‌تواند به مدیران و نهادهای ناظر بیمه کمک کند تا با بهره‌گیری از مدل‌های یادگیری ماشین، فرآیند ارزیابی توانگری مالی را سریع‌تر و دقیق‌تر انجام دهند.

پیش‌بینی صحیح توانگری مالی می‌تواند به اتخاذ تصمیمات پیشگیرانه، تخصیص بهینه منابع، شناسایی شرکت‌های پرریسک و در نهایت ارتقای ثبات صنعت بیمه منجر شود. همچنین، این مدل‌ها می‌توانند به‌عنوان ابزارهای پشتیبان تصمیم‌گیری در حوزه سیاست‌گذاری بیمه‌ای و تدوین مقررات نظارتی مورد استفاده قرار گیرند و شفافیت بیشتری در نظام مالی بیمه‌ای ایجاد کنند. نتایج این پژوهش نشان داد که الگوریتم‌های یادگیری ماشین می‌توانند به‌عنوان ابزاری کارآمد در پیش‌بینی توانگری مالی شرکت‌های بیمه مورد استفاده قرار گیرند. عملکرد الگوریتم درخت تصمیم از حیث تعادل بین دقت، خطای پایین و تفسیرپذیری، نشان داد که این روش قابلیت استفاده مستقیم در محیط‌های واقعی صنعت بیمه را دارد. به‌ویژه تفسیر ساده قوانین استخراج شده از این الگوریتم می‌تواند برای مدیران و کارشناسان مالی که نیازمند شفافیت در تصمیم‌گیری هستند، بسیار مفید باشد. این موضوع به شرکت‌های بیمه کمک می‌کند تا بدون نیاز به دانش پیچیده فنی، بتوانند از نتایج مدل برای ارزیابی وضعیت مالی خود بهره بگیرند. در کنار این، مدل XGBoost اگرچه از نظر شاخص AUC عملکرد بهتری داشت و توانایی بالایی در تفکیک شرکت‌های توانگر و غیرتوانگر نشان داد، اما خطای بالای آن در شاخص‌های RMSE و MAE، محدودیت کاربرد مستقیم آن را در فضای عملیاتی صنعت بیمه نمایان کرد. این نتیجه بیانگر آن است که مدل‌های پیچیده‌تر همیشه به معنای عملکرد بهتر نیستند و در بسیاری از مواقع سادگی، شفافیت و قابلیت پیاده‌سازی عملی مدل اهمیت بیشتری دارد. به بیان دیگر، برای صنعت بیمه که نیازمند تصمیم‌گیری سریع و قابل توضیح است، مدل‌هایی مانند درخت تصمیم اولویت دارند. یکی از مهم‌ترین خروجی‌های کاربردی تحقیق، شناسایی ویژگی‌های مالی کلیدی مؤثر بر توانگری شرکت‌های بیمه است. متغیرهایی همچون نسبت مطالبات از بیمه‌گذاران، هزینه‌های اداری و عمومی، ترکیب سرمایه‌گذاری‌ها و سهم ذخایر فنی بیشترین اثر را بر وضعیت توانگری مالی داشتند. این یافته می‌تواند به مدیران کمک کند تا تمرکز خود را بر بهبود و کنترل این شاخص‌های کلیدی بگذارند و از طریق مدیریت بهینه این عوامل، توانگری مالی شرکت را در بلندمدت

پایدار سازند. همچنین نهادهای ناظر می‌توانند از این نتایج برای طراحی شاخص‌های هشدار سریع و ارزیابی ریسک سیستماتیک بازار بیمه بهره ببرند. از منظر سیاست‌گذاری، نتایج این تحقیق می‌تواند مبنای توسعه ابزارهای نظارتی هوشمند توسط بیمه مرکزی قرار گیرد. به کمک مدل‌های یادگیری ماشین می‌توان به صورت دوره‌ای توانگری مالی شرکت‌ها را ارزیابی کرد، شرکت‌های پرریسک را شناسایی نمود و اقدامات اصلاحی را پیش از وقوع بحران مالی اجرا کرد. این رویکرد می‌تواند علاوه بر افزایش شفافیت، از ورشکستگی‌های ناگهانی جلوگیری کرده و اعتماد عمومی به صنعت بیمه را تقویت کند. در کنار این، ارائه داشبوردهای تحلیلی مبتنی بر این مدل‌ها به مدیران می‌تواند فرآیند تصمیم‌گیری را به صورت داده‌محور و دقیق‌تر نماید. کاربرد عملی این نتایج فراتر از صنعت بیمه نیز قابل‌تعمیم است و می‌تواند در سایر حوزه‌های مالی و ریسک مورد استفاده قرار گیرد. همان‌طور که این تحقیق نشان داد، استفاده از الگوریتم‌های داده‌محور علاوه بر کاهش هزینه‌های ارزیابی، دقت پیش‌بینی را به طور چشمگیری افزایش می‌دهد. بنابراین، شرکت‌های بیمه و نهادهای مالی می‌توانند با سرمایه‌گذاری در زیرساخت‌های داده و تحلیل هوشمند، مزیت رقابتی پایداری ایجاد کنند.

این مسیر در بلندمدت به دیجیتالی شدن فرآیندهای ارزیابی ریسک و ایجاد یک نظام مالی مقاوم‌تر منجر خواهد شد. این پژوهش با ارائه یک چارچوب داده‌محور مبتنی بر یادگیری ماشین، گامی در جهت هوشمندسازی ارزیابی توانگری مالی شرکت‌های بیمه برداشت. با این حال، نتایج به محدودیت‌هایی مانند اندازه نمونه، کیفیت داده‌ها و محدودیت زمانی در جمع‌آوری داده‌های تاریخی وابسته است. بنابراین، پیشنهاد می‌شود در تحقیقات آتی از داده‌های گسترده‌تر و به‌روزتر استفاده شده و همچنین ترکیب الگوریتم‌های مختلف به صورت مدل‌های هیبریدی مورد بررسی قرار گیرد. توسعه مدل‌های ترکیبی می‌تواند دقت و پایداری پیش‌بینی را افزایش دهد و افق‌های جدیدی را برای استفاده از هوش مصنوعی در مدیریت ریسک بیمه‌ای بگشاید.

## پیشنادهای تحقیق

### پیشنهادات کاربردی

۱. پیشنهاد می‌شود شرکت‌های بیمه از الگوریتم‌های تفسیرپذیر مانند درخت تصمیم به‌عنوان ابزار ارزیابی توانگری مالی استفاده کنند تا علاوه بر دقت مناسب، شفافیت در تصمیم‌گیری نیز حفظ شود.
۲. پیشنهاد می‌شود نهادهای ناظر مانند بیمه مرکزی از این مدل‌ها برای طراحی سامانه‌های هشدار زودهنگام جهت شناسایی شرکت‌های پرریسک بهره ببرند.
۳. پیشنهاد می‌شود داده‌های مالی شرکت‌های بیمه به‌صورت متمرکز، یکپارچه و استاندارد جمع‌آوری و پاکسازی شود تا عملکرد مدل‌های یادگیری ماشین بهبود یابد.
۴. پیشنهاد می‌شود مدیران مالی بیمه‌ها شاخص‌های کلیدی مؤثر بر توانگری مانند نسبت مطالبات، ترکیب سرمایه‌گذاری و هزینه‌های اداری را به‌طور مستمر پایش کنند و در فرآیند بهبود مالی مدنظر قرار دهند.
۵. پیشنهاد می‌شود برای ارتقای دقت مدل‌ها، زیرساخت داده‌کاوی و هوش مصنوعی در صنعت بیمه توسعه یابد و دسترسی به داده‌های باکیفیت و حجیم‌تر فراهم شود.
۶. پیشنهاد می‌شود از نتایج این پژوهش در طراحی داشبوردهای مدیریتی استفاده شود تا مدیران بتوانند وضعیت توانگری مالی شرکت خود را به‌صورت بلادرنگ رصد کنند.
۷. پیشنهاد می‌شود برای بهبود عملکرد الگوریتم‌های پیچیده مانند شبکه‌های عصبی، حجم داده‌های تاریخی و متوازن‌سازی نمونه‌ها در بازه‌های زمانی طولانی‌تر انجام شود.
۸. پیشنهاد می‌شود شرکت‌های بیمه برای تصمیمات استراتژیک خود ترکیبی از الگوریتم‌های ساده و مدل‌های ترکیبی (هیبریدی) را به‌صورت مرحله‌ای پیاده‌سازی کنند.
۹. پیشنهاد می‌شود در کنار استفاده از مدل‌های یادگیری ماشین، تحلیل‌های سنتی مالی و ریسک نیز مورد توجه باشد تا تصمیمات نهایی جامع‌تر و دقیق‌تر اتخاذ شوند.
۱۰. پیشنهاد می‌شود آموزش‌های تخصصی در زمینه هوش مصنوعی و تحلیل داده برای کارشناسان مالی بیمه برگزار شود تا توان استفاده از این ابزارها افزایش یابد.

## پیشنهادات تحقیقات آتی

- پیشنهاد می‌شود در تحقیقات آینده از مدل‌های ترکیبی و هیبریدی که ترکیبی از الگوریتم‌های ساده و پیچیده هستند استفاده شود تا هم تفسیرپذیری و هم دقت مدل‌ها افزایش یابد.
- پیشنهاد می‌شود پژوهش‌های آتی با استفاده از داده‌های گسترده‌تر، شامل اطلاعات مالی و غیره مالی (مانند شاخص‌های کلان اقتصادی، ریسک بازار و داده‌های متنی گزارش‌های مالی) انجام شود تا تحلیل جامع‌تری ارائه گردد.
- پیشنهاد می‌شود در تحقیقات بعدی مقایسه عملکرد مدل‌های یادگیری عمیق پیشرفته مانند شبکه‌های گرافی، یادگیری انتقالی یا مدل‌های مبتنی بر توجه در پیش‌بینی توانگری مالی بررسی شود.
- پیشنهاد می‌شود پژوهش‌های آینده به تحلیل پویایی توانگری مالی در طول زمان و طراحی مدل‌های پیش‌بینی سری‌های زمانی با الگوریتم‌های پیشرفته مانند LSTM و Transformer اختصاص یابد تا روندهای آینده بهتر شناسایی شوند.

## منابع :

- پشت‌دار، محمد؛ رضایی، الهام؛ کریمی، سارا (۱۴۰۳). مدل‌سازی توانگری مالی شرکت‌های بیمه در طی زمان. نشریه علمی-پژوهشی بیمه و توسعه، ۱۵(۲)، ۴۵-۶۵.
- تجددی، مهدی؛ نادری، سارا (۱۴۰۲). پیش‌بینی هزینه‌های بیمه درمانی افراد با استفاده از یادگیری ماشین و روش یادگیری جمعی. نشریه علمی-پژوهشی فناوری بیمه، ۶(۲)، ۳۳-۵۰.
- جافری، بیت‌الله؛ پروین، خیرالله؛ صادقی، محمد (۱۳۹۹). نقش توسعه اقتصاد پایدار بر صنعت بیمه و سلامت. مجله بیمه سلامت ایران، ۳(۲)، ۸۲-۹۱.
- خسروی، علی‌رضا؛ محمدی، پریا؛ زمانی، کامران (۱۴۰۳). بررسی رابطه نسبت‌های مالی و نسبت توانگری مالی شرکت‌های بیمه با تأکید بر بیمه لاستیک خودرو. نشریه علمی-پژوهشی حسابداری و مدیریت مالی، ۲۰(۳)، ۱۰۱-۱۱۸.
- رحمانی، علی؛ نیاکان، لیلی؛ محمودخانی، مهناز (۱۴۰۰). صنعت بیمه پایدار: اصول و راهبردها. مقالات بیست‌وهفتمین همایش ملی بیمه و توسعه صص. ۱-۲۲. تهران: پژوهشکده بیمه.
- رفیعی، نرگس؛ وحدتی، احسان (۱۴۰۰). مدیریت حسابداری دیجیتال و نقش آن در پایداری صنعت بیمه. مقالات اولین کنفرانس بین‌المللی تجزیه و تحلیل داده‌های آماری (صص. ۱-۵).
- صدیقی، حسین؛ احمدی، مهدی؛ باقری، نرگس (۱۴۰۳). مدل توانگری مالی شرکت‌های بیمه با استفاده از رویکرد دلفی فازی و معادلات ساختاری. نشریه علمی-پژوهشی مدیریت بیمه، ۱۲(۱)، ۷۷-۹۱.
- شیرافکن، رضا؛ فلاح، داوود؛ مرادی، یاسر (۱۴۰۳). مدل‌سازی ریسک‌های سیستماتیک و غیرسیستماتیک و ژئوپلیتیک بر توانگری مالی در صنعت بیمه. نشریه علمی-پژوهشی مدیریت ریسک بیمه، ۸(۴)، ۷۶-۹۵.
- گودرزی، یزدان؛ عباسی، لیلی؛ رحمانی، فاطمه (۱۴۰۰). اثر نوسانات متغیرهای کلان اقتصادی بر توانگری مالی صنعت بیمه در ایران. نشریه علمی-پژوهشی اقتصاد و بیمه، ۱۸(۳)، ۱۲۱-۱۳۸.
- محمودخانی، مهناز؛ رحمانی، علی؛ همایون، سعید؛ نیاکان، لیلی (۱۴۰۱). بررسی استانداردها، رهنمودها و وضعیت انتشار گزارشگری پایداری در صنعت بیمه. فصلنامه پژوهشنامه بیمه، ۳۷(۲)، ۲۰۳-۲۳۷.
- Cho, M., & Fang, L. (2020). Evaluating the accuracy of machine learning models in predicting insurers' solvency status. *Journal of Risk and Financial Management*, 13(8), 188. <https://doi.org/10.3390/jrfm13080188>
- Dickson, M. (2018). Capital adequacy in the insurance sector: A global overview. *Journal of Insurance Regulation*, 37(4), 55-74.

- Madushika, S. C., Fernando, W. M. A. D. B., & Thrikawala, S. S. (2021). Determinants of financial stability: Evidence from insurance companies in Sri Lanka. *International Journal of Management Excellence*, 17(2), 2389–2395. <https://doi.org/10.17722/ijme.v17i2.1273>
- Maton, D. (2018). Financial strength and solvency in insurance companies. *European Journal of Financial Regulation*, 10(4), 321–339.
- Mayer, T., & Stark, R. (2020). Long-term sustainability in competitive insurance markets. *Geneva Papers on Risk and Insurance*, 45(4), 687–708. <https://doi.org/10.1057/s41288-020-00189-y>
- Odumuwagon, (2023). Time series-based quantitative risk models: Enhancing accuracy in forecasting and risk assessment. *International Journal of Computer Applications Technology and Research*, 12, 29–41
- Sari, R., & Gunawan, B. (2023). Debt payment ratio, liquidity, and profitability analysis. *International Journal of Financial Research*, 14(4), 112–126.