

ارزیابی و پیش‌بینی ارزش شرکت‌ها با استفاده از داده‌های ESG و ریسک اقلیمی

دکتر جواد عین‌آبادی

استادیار گروه مالی و حسابداری، موسسه آموزش عالی الکترونیکی ایرانیان، تهران، ایران.

javadeinabadi@gmail.com

مهتا موسی

دانشجوی کارشناسی ارشد مالی - مهندسی مالی و مدیریت ریسک، موسسه آموزش عالی الکترونیکی ایرانیان، تهران، ایران.

(نویسنده مسئول)

Mahta.mousa.1403@gmail.com

چکیده

در این پژوهش، به تحلیل و پیش‌بینی ارزش شرکت‌ها با استفاده از داده‌های مالی، شاخص‌های ESG (زیست‌محیطی، اجتماعی و حکمرانی) و ریسک‌های اقلیمی پرداخته شده است. هدف اصلی این تحقیق، توسعه یک مدل پیش‌بینی دقیق‌تر با استفاده از الگوریتم‌های پیشرفته یادگیری ماشین نظیر XGBoost و شبکه‌های عصبی چند لایه (MLP) برای تحلیل تأثیر داده‌های ESG و ریسک‌های اقلیمی بر ارزش شرکت‌ها است. نتایج نشان می‌دهند که ROE (بازده حقوق صاحبان سهام) بیشترین تأثیر را بر پیش‌بینی ارزش شرکت‌ها دارد، در حالی که ویژگی‌های غیرمالی مانند ESG و ریسک‌های اقلیمی تأثیر نسبتاً کمتری دارند. مدل MLP عملکرد بهتری نسبت به XGBoost در پیش‌بینی‌ها از خود نشان داد و دقت بالاتری در شبیه‌سازی داده‌ها داشت. این تحقیق همچنین نشان داد که ریسک‌های اقلیمی و شاخص‌های ESG، هرچند تأثیر کمتری بر پیش‌بینی‌های مالی دارند، اما به‌عنوان ابزاری برای ارزیابی پایداری بلندمدت شرکت‌ها باید در تحلیل‌های مالی گنجانده شوند. بر اساس این یافته‌ها، پیشنهاد می‌شود که از مدل‌های پیچیده‌تر و دقیق‌تر برای پیش‌بینی ارزش شرکت‌ها و ارزیابی تأثیر ریسک‌های اقلیمی در بازارهای سرمایه استفاده گردد.

مقدمه

در دهه‌های اخیر، تحولاتی بنیادین در نگرش به ارزیابی عملکرد شرکت‌ها رخ داده است؛ به‌گونه‌ای که دیگر صرفاً معیارهای مالی نظیر بازدهی سرمایه، سودآوری یا ساختار سرمایه به‌تنهایی کافی برای تعیین ارزش شرکت تلقی نمی‌شوند (ویشنوسکا و همکاران^۱، ۲۰۲۱). در این میان، شاخص‌های زیست‌محیطی، اجتماعی و حکمرانی همچنین ریسک‌های اقلیمی به‌عنوان ابعاد مکمل و ضروری برای تحلیل جامع وضعیت شرکت‌ها مورد توجه روزافزون قرار گرفته‌اند (سکینارو و همکاران^۲، ۲۰۲۰). (روند جهانی شدن، تغییرات اقلیمی و انتظارات فزاینده ذی‌نفعان باعث شده است که سرمایه‌گذاران، تحلیل‌گران و نهادهای مالی، داده‌های ESG و مخاطرات ناشی از تغییرات آب‌وهوایی را به‌عنوان عوامل تعیین‌کننده در تصمیم‌گیری‌های اقتصادی و مالی در نظر گیرند (چن و همکاران^۳، ۲۰۲۳). برخلاف رویکردهای

¹ Vyshnevskaya et al

² Secinara et al

³ Chen et al

سنتی که تنها به داده‌های مالی بسنده می‌کنند، مدل‌های نوین تحلیل ارزش شرکت‌ها، بر ادغام داده‌های کیفی و کمی تاکید دارند تا درک دقیق‌تری از عملکرد واقعی و پایدار بنگاه اقتصادی ارائه دهند. در این راستا، پژوهش حاضر با تمرکز بر توسعه یک مدل پیش‌بینی ارزش شرکت‌ها، تلاش می‌کند تا تلفیقی هوشمند از داده‌های مالی، شاخص‌های ESG و ریسک‌های اقلیمی را در قالب یک چارچوب تحلیلی مبتنی بر هوش مصنوعی ارائه دهد (چانگ و همکاران^۱، ۲۰۲۴). به‌منظور دستیابی به پیش‌بینی‌های دقیق‌تر، از الگوریتم‌های یادگیری ماشین نظی XGBoost^۲ و شبکه‌های عصبی چندلایه^۳ استفاده شده است. با طراحی چنین مدلی، هدف آن است که ابزارهایی دقیق‌تر و هوشمندانه‌تر برای تحلیل‌گران بازار سرمایه، مدیران اجرایی و سیاست‌گذاران فراهم شود؛ ابزارهایی که نه تنها توان پیش‌بینی ارزش بازار شرکت‌ها را داشته باشند، بلکه تأثیر پنهان یا غیرمستقیم عواملی چون تاب‌آوری اقلیمی یا مسئولیت‌پذیری اجتماعی را نیز آشکار سازند. این پژوهش می‌کوشد شکاف میان تحلیل‌های مالی سنتی و مقتضیات پایداری در دوران معاصر را با نگاهی تحلیلی و مبتنی بر داده‌های واقعی پر کند (بونلو و همکاران^۴، ۲۰۱۸).

ادبیات پژوهش

در سنت تحلیل مالی، تمرکز بر شاخص‌های کمی مانند سودآوری، بازده سرمایه و ساختار بدهی رایج بوده است. اما در دهه‌های اخیر، تحولاتی در حوزه اقتصاد پایدار و نگرش سرمایه‌گذاران موجب شد که متغیرهای کیفی نیز وارد معادلات ارزش‌گذاری شوند. بر این اساس، شاخص‌های ESG به عنوان ابزاری برای سنجش پایداری بلندمدت شرکت‌ها، جایگاه ویژه‌ای در ارزیابی عملکرد آن‌ها پیدا کرده‌اند (کاتسانتونیس و همکاران^۵، ۲۰۱۶).

نقدی و جدی (۱۴۰۲)، با روش فراترکیب، پیامدهای ریسک‌های اقلیمی بر حسابداری را تحلیل کرده و نشان می‌دهد که این ریسک‌ها می‌توانند منجر به کاهش ارزش دارایی‌ها، افزایش محافظه‌کاری و تغییر در رفتار مالی شرکت‌ها شوند؛ بنابراین، لزوم گنجانیدن آن‌ها در استانداردهای حسابداری بسیار مهم است.

فخری (۱۴۰۳)، با تحلیل داده‌های ۱۴۴ شرکت بورسی در بازه ۱۳۹۶ تا ۱۴۰۱، نشان می‌دهد که عملکرد ESG (زیست‌محیطی، اجتماعی و حکمرانی شرکتی) می‌تواند رابطه معناداری با سطح نگهداشت وجه نقد و ریسک نکول شرکت‌ها داشته باشد؛ به طوری که بهبود در عملکرد ESG ممکن است منجر به کاهش ریسک نکول و مدیریت مؤثرتر منابع نقدی شود.

خاندوزی (۱۴۰۳)، با بررسی ۲۶ شرکت کشاورزی بورس تهران طی سال‌های ۱۳۹۴ تا ۱۳۹۹، نشان می‌دهد که ریسک‌های اقلیمی مانند خشکسالی، اثر معناداری بر مدیریت سود (اعم از اقلام تعهدی و سود واقعی) دارند؛ به‌ویژه در صنایعی که بیشتر در معرض بحران‌های زیست‌محیطی‌اند، شرکت‌ها ممکن است برای حفظ ثبات مالی و جلب اعتماد سرمایه‌گذاران، به مدیریت سود متوسل شوند.

تأثیر شاخص‌های ESG بر عملکرد مالی

بر اساس متاآنالیز انجام‌شده توسط Friede et al (۲۰۱۵)، بیش از ۹۰٪ مطالعات علمی نشان داده‌اند که ارتباط مثبت یا خنثی میان عملکرد ESG و بازده مالی شرکت‌ها وجود دارد. این یافته‌ها حاکی از آن است که شرکت‌هایی با عملکرد

¹ Chung et al

² Extreme Gradient Boosting

³ Multilayer Perceptron (MLP)

⁴ Bonello et al

⁵ Kotsantonis et al

قوی در حوزه‌های زیست‌محیطی، اجتماعی و حکمرانی، ریسک کمتری در بلندمدت داشته و سرمایه‌گذاران تمایل بیشتری به سرمایه‌گذاری در آن‌ها دارند. اکلز و همکاران (۲۰۱۲)، نیز در مطالعه‌ای تجربی نشان دادند که شرکت‌هایی با رویکرد بلندمدت و تمرکز بر ESG، عملکرد بهتری در بازار سرمایه داشته‌اند. یافته‌های مشابهی در مطالعات انجام‌شده در بازارهای نوظهور نیز تأیید شده است (سیلا و سک^۱، ۲۰۱۷).

نقش ریسک‌های اقلیمی در ارزش‌گذاری مالی

با رشد بحران اقلیمی جهانی، ریسک‌های اقلیمی به‌عنوان ریسک‌های سیستماتیک در تحلیل‌های سرمایه‌گذاری وارد شده‌اند. پژوهش Battiston et al (۲۰۱۷)، در سطح کلان مالی نشان داد که بیش از ۶۰ درصد دارایی‌های مالی در معرض ریسک‌های ناشی از تغییرات اقلیمی قرار دارند. این موضوع لزوم گنجاندن شاخص‌هایی مانند Climate Risk Exposure و Climate Risk Adaptiveness در تحلیل‌های ارزش‌گذاری را برجسته می‌سازد. کورگر و همکاران (۲۰۲۰)، در پژوهشی مبتنی بر نظرسنجی از سرمایه‌گذاران نهادی، به این نتیجه رسیدند که اکثر آن‌ها در ارزیابی ریسک‌ها، به شدت به میزان آمادگی شرکت در برابر تهدیدهای اقلیمی توجه می‌کنند.

بهره‌گیری از هوش مصنوعی در تحلیل داده‌های ESG و اقلیمی

در شرایطی که داده‌های ESG و اقلیمی دارای ویژگی‌هایی مانند عدم قطعیت، پیچیدگی و روابط غیرخطی هستند، استفاده از روش‌های یادگیری ماشین، به‌ویژه مدل‌های تقویتی مانند XGBoost و شبکه‌های عصبی چندلایه (MLP)، به عنوان رویکردهای برتر در تحلیل این داده‌ها مطرح شده‌اند (گو و همکاران^۲، ۲۰۲۰). مطالعه آویجن و همکاران (۲۰۲۴)، نشان می‌دهد که گنجاندن ریسک‌های اقلیمی (گذار و فیزیکی) در مدل‌های یادگیری ماشین، دقت پیش‌بینی قیمت سهام ESG را به‌طور چشمگیری افزایش می‌دهد. همچنین با بهره‌گیری از روش‌های تفسیرپذیر هوش مصنوعی (مانند SHAP)، اثر متغیرهایی چون تورم، رکود و آلودگی بر شاخص ESG بازار تحلیل شده است.

مطالعه علی و همکاران (۲۰۲۵)، نشان می‌دهد که کیفیت افشای ریسک اقلیمی بر اساس چارچوب TCFD، رابطه‌ای مثبت و معنادار با ارزش‌گذاری شرکت‌ها در بین شرکت‌های شاخص S&P 500 دارد. این اثر به‌ویژه در صنایع آلاینده قوی‌تر است، و بیانگر آن است که شفافیت اقلیمی از دید سرمایه‌گذاران به‌عنوان نشانه‌ای از مشروعیت، کفایت مدیریتی و آینده‌نگری راهبردی تلقی می‌شود.

شکاف پژوهشی و جایگاه مطالعه حاضر

با وجود مطالعات فراوان در زمینه ESG یا ریسک اقلیمی به‌صورت مجزا، پژوهش‌هایی که این دو دسته داده را به‌صورت یکپارچه و همراه با داده‌های مالی وارد چارچوب‌های پیش‌بینی پیشرفته کنند، هنوز نادر هستند. مطالعه حاضر با ترکیب این سه حوزه مالی، ESG، اقلیمی و بهره‌گیری از الگوریتم‌های مدرن یادگیری ماشین، در تلاش است مدلی واقع‌بینانه‌تر و دقیق‌تر برای پیش‌بینی ارزش شرکت‌ها ارائه دهد؛ مدلی که می‌تواند مبنای تصمیم‌گیری در سرمایه‌گذاری‌های پایدار قرار گیرد.

¹ Sila & Cek

² Gu et al

روش‌شناسی تحقیق روند اجرای پروژه

ابتدا دیتاست از منابع معتبر و پایگاه‌های داده استخراج می‌شود. این داده‌ها شامل اطلاعات مالی و غیرمالی شرکت‌ها است که برای پیش‌بینی دقیق ارزش شرکت‌ها استفاده می‌شود. برای شروع تحلیل، تمامی ویژگی‌ها و متغیرها به دقت بررسی شده و به صورت یکپارچه در مدل‌های یادگیری ماشین وارد می‌شوند.

دیتاست

دیتاست مورد استفاده در این پژوهش شامل اطلاعات ۵۰ شرکت از صنایع مختلف است که متغیرهایی از جمله داده‌های مالی، شاخص‌های ESG (زیست‌محیطی، اجتماعی و حکمرانی) و ریسک‌های اقلیمی را در بر می‌گیرد. ویژگی‌های این دیتاست به طور کامل برای تحلیل ارزش شرکت‌ها انتخاب شده است و شامل اطلاعات اساسی مانند شناسه شرکت، صنعت، شاخص‌های مالی (بازده حقوق صاحبان سهام، نسبت بدهی به حقوق صاحبان سهام، سود هر سهم و جریان نقدی، و داده‌های مربوط به عملکرد ESG و ریسک‌های اقلیمی می‌باشد. از جمله ویژگی‌های کلیدی دیگر در این دیتاست می‌توان به میزان آسیب‌پذیری اقلیمی و توانمندی تطبیق با تغییرات اقلیمی اشاره کرد که به ارزیابی نحوه مواجهه شرکت‌ها با ریسک‌های ناشی از تغییرات اقلیمی کمک می‌کند. این ویژگی‌ها به همراه داده‌های ریسک‌های کشوری و ارزش شرکت به عنوان متغیر هدف مورد استفاده قرار می‌گیرند.

بررسی ساختار و ویژگی‌های داده‌ها

پس از بارگذاری داده‌ها، یک بررسی اولیه از ساختار دیتاست انجام می‌شود. این مرحله شامل تحلیل تعداد سطرها و ستون‌ها، انواع داده‌ها (عدد صحیح، اعشاری، متنی) و آمار توصیفی اولیه مانند میانگین، حداقل و حداکثر مقادیر است. هدف از این مرحله بررسی کیفیت داده‌ها و شناسایی ویژگی‌های کلیدی است که می‌تواند تأثیر زیادی بر تحلیل و پیش‌بینی‌ها داشته باشند.

بررسی داده‌های گم‌شده

در این مرحله، تعداد داده‌های گم‌شده برای هر متغیر بررسی می‌شود. این تحلیل کمک می‌کند تا تصمیمات مناسبی برای پر کردن داده‌های گم‌شده اتخاذ شود. بسته به نوع داده، از روش‌هایی مانند پر کردن با میانگین، میانه یا استفاده از مدل‌های پیش‌بینی برای تکمیل داده‌ها استفاده می‌شود. در صورتی که یک ویژگی دارای مقدار گم‌شده زیادی باشد، ممکن است حذف شود تا از تأثیرات منفی بر مدل جلوگیری شود.

تحلیل و نمایش توزیع داده‌ها

توزیع داده‌ها از جمله ویژگی‌های هدف (ارزش شرکت‌ها) با استفاده از نمودارهای مختلف مانند هیستوگرام و نمودارهای چگالی (KDE) بررسی می‌شود. هدف این مرحله شناسایی نحوه توزیع داده‌ها و ارزیابی نرمال بودن آنهاست. این تحلیل کمک می‌کند تا تصمیم‌گیری‌هایی در خصوص نیاز به تغییرات در داده‌ها یا نرمال‌سازی آنها گرفته شود.

تحلیل همبستگی بین ویژگی‌ها

در این مرحله، همبستگی بین ویژگی‌های مختلف به‌ویژه ویژگی‌های عددی بررسی می‌شود. این تحلیل با استفاده از نمودارهای ماتریس همبستگی انجام می‌شود. هدف از این گام شناسایی ویژگی‌های وابسته و هم‌راستا با یکدیگر است. ویژگی‌هایی که همبستگی بالایی دارند، ممکن است تکراری باشند و در این صورت ممکن است یکی از آن‌ها از مدل حذف شود تا از پیچیدگی مدل جلوگیری گردد.

پیش‌پردازش داده‌ها

داده‌ها پیش از آموزش مدل‌ها باید آماده شوند. این مرحله شامل تبدیل ویژگی‌های متنی به مقادیر عددی مثلاً ویژگی "sector" به کمک Label Encoding به مقادیر عددی تبدیل می‌شود (مقیاس‌بندی ویژگی‌ها) با استفاده از مقیاس‌سازی استاندارد و تقسیم داده‌ها به مجموعه‌های آموزشی و تست است. در این پژوهش، ۸۰ درصد داده‌ها برای آموزش مدل و ۲۰ درصد برای ارزیابی مدل‌ها اختصاص داده می‌شود.

انتخاب مدل‌ها و آموزش آن‌ها

در این پروژه از دو مدل پیشرفته یادگیری ماشین برای پیش‌بینی ارزش شرکت‌ها استفاده شده است:

مدل XGBoost

XGBoost یکی از پیشرفته‌ترین الگوریتم‌ها برای مسائل پیش‌بینی است. این مدل یک نسخه تقویت شده از درخت تصمیم است که برای داده‌های پیچیده و غیرخطی عملکرد خوبی دارد. در این گام، مدل با استفاده از داده‌های آموزشی آموزش داده می‌شود تا به‌طور خودکار ارتباطات پیچیده میان ویژگی‌ها را یاد بگیرد. XGBoost به‌ویژه برای مجموعه‌های داده بزرگ و پیچیده بسیار مناسب است.

مدل شبکه عصبی چند لایه MLP

شبکه عصبی چند لایه یک مدل یادگیری عمیق است که برای یادگیری روابط غیرخطی و پیچیده در داده‌ها مناسب است. این مدل از لایه‌های پنهان متعدد و تابع فعال‌سازی ReLU برای شبیه‌سازی روابط پیچیده میان ورودی‌ها و خروجی‌ها استفاده می‌کند. MLP به‌ویژه برای تحلیل‌هایی که نیاز به شبیه‌سازی روابط پیچیده دارند، مناسب است.

ارزیابی مدل‌ها

پس از آموزش مدل‌ها، عملکرد آن‌ها با استفاده از دو معیار اصلی ارزیابی می‌شود.

RMSE (ریشه میانگین مربعات خطا)

این معیار نشان‌دهنده میزان تفاوت پیش‌بینی‌ها با مقادیر واقعی است. هر چه این مقدار کمتر باشد، مدل دقت بالاتری در پیش‌بینی‌ها دارد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

y_i مقدار واقعی است.

\hat{y}_i مقدار پیش‌بینی شده توسط مدل است.

n تعداد داده‌ها است.

R² Score (ضریب تعیین)

این معیار میزان انطباق پیش‌بینی‌ها با داده‌های واقعی را نشان می‌دهد. R^2 بین ۰ و ۱ قرار دارد و هرچه این مقدار به ۱ نزدیک‌تر باشد، مدل بهتر عمل کرده است.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2)$$

y_i مقدار واقعی است.

\hat{y}_i مقدار پیش‌بینی شده توسط مدل است.

\bar{y} میانگین مقادیر واقعی است.

n تعداد داده‌ها است.

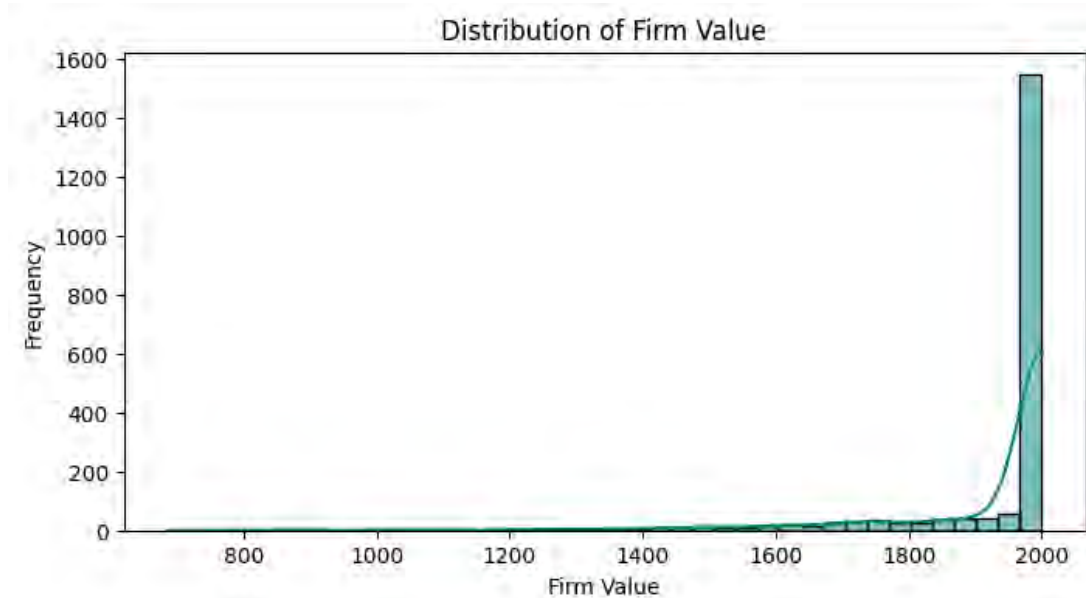
ضریب R^2 میزان تطابق مقادیر پیش‌بینی شده با داده‌های واقعی را اندازه‌گیری می‌کند. مقدار R^2 بین ۰ و ۱ قرار دارد و هرچه این مقدار به ۱ نزدیک‌تر باشد، عملکرد مدل بهتر است.

تحلیل اهمیت ویژگی‌ها

در این گام، برای مدل XGBoost، اهمیت هر ویژگی مانند داده‌های ESG، ریسک اقلیمی، نسبت بدهی به حقوق صاحبان سهام و غیره محاسبه می‌شود. این تحلیل کمک می‌کند تا مشخص شود کدام ویژگی‌ها بیشترین اثر را بر پیش‌بینی ارزش شرکت دارند. با استفاده از نمودارهای اهمیت ویژگی‌ها، می‌توان ویژگی‌های مهم و تأثیرگذار را شناسایی کرد و تحلیل‌های بیشتری در خصوص نحوه تأثیر آن‌ها بر ارزش شرکت انجام داد.


تحلیل نتایج

شکل ۱، توزیع ارزش شرکت‌ها در نمودار هیستوگرام و تخمین چگالی هسته‌ای (KDE) نشان‌دهنده ویژگی‌های خاصی از داده‌ها است. در ابتدا، یک پیک شدید در نزدیکی مقدار ۲۰۰۰ مشاهده می‌شود که نشان می‌دهد تعداد زیادی از شرکت‌ها دارای ارزشی نزدیک به ۲۰۰۰ واحد هستند. این امر ممکن است نشان‌دهنده وجود یک آستانه یا نقطه مرجع خاص در داده‌ها باشد. علاوه بر این، توزیع به‌طور واضح نامتقارن است و بیشتر داده‌ها به سمت مقادیر پایین‌تر تمایل دارند. این ناپایداری ممکن است به دلیل وجود مقادیر پرت یا ویژگی‌های خاص در برخی شرکت‌ها باشد که باعث تغییرات قابل توجه در توزیع داده‌ها شده‌اند. همچنین، مقادیر پرت در انتهای نمودار مشاهده می‌شوند که نشان‌دهنده حضور تعداد کمی از شرکت‌ها با ارزش‌های بسیار بالا هستند. این مقادیر می‌توانند به عنوان مقادیر پرت شناسایی شوند و بررسی دلایل این تفاوت‌ها می‌تواند برای تحلیل بیشتر مفید باشد. بیشتر داده‌ها در بازه ۱۰۰۰ تا ۱۵۰۰ قرار دارند، اما تمرکز داده‌ها در نزدیکی ۲۰۰۰ نیز قابل توجه است. این تمرکز ممکن است نیازمند اعمال تکنیک‌هایی مانند نرمال‌سازی یا حذف مقادیر پرت باشد تا تحلیل دقیق‌تری از توزیع داده‌ها به دست آید.




شکل (۱): توزیع ارزش شرکت با داده‌های نامتوازن

تحلیل همبستگی‌ها در شکل ۲ نشان می‌دهد که بازده حقوق صاحبان سهام (ROE) بیشترین همبستگی را با ارزش شرکت‌ها دارد (۰.۵۸)، که این رابطه مثبت نشان‌دهنده تأثیر عملکرد مالی مثبت بر ارزش شرکت‌ها است. سایر ویژگی‌ها مانند CashFlow، EPS، و مؤلفه‌های ESG همبستگی ضعیفی با ارزش شرکت‌ها دارند، که به این معنا است که این متغیرها تأثیر چندانی در پیش‌بینی ارزش شرکت‌ها ندارند. همچنین، نسبت بدهی به حقوق صاحبان سهام نیز همبستگی اندکی با ارزش شرکت‌ها دارد (۰.۱۷)، نشان‌دهنده این که استفاده از بدهی در تأمین منابع مالی تأثیر قابل توجهی در تعیین ارزش شرکت‌ها ندارد. ویژگی‌های مربوط به ریسک‌های اقلیمی و کشوری نیز همبستگی ضعیفی با سایر ویژگی‌ها دارند و تأثیر کمی بر ارزش شرکت‌ها نشان می‌دهند. از سوی دیگر، ویژگی‌های ESG به‌طور مستقل تأثیرگذار هستند و هیچ همبستگی قوی میان ابعاد مختلف آن‌ها وجود ندارد، که ممکن است نشان‌دهنده نیاز به بررسی تک‌تک ابعاد ESG به‌طور جداگانه باشد. به‌طور کلی، نتایج این تحلیل نشان می‌دهند که ویژگی‌های مالی مانند ROE تأثیر بیشتری بر ارزش شرکت‌ها دارند، در حالی که ویژگی‌های غیرمالی مانند ESG و ریسک‌های اقلیمی و کشوری تأثیر کمی بر این ارزش‌گذاری‌ها دارند.



شکل (۲): نقشه همبستگی ویژگی‌های عددی در دیتاست

نمودار پراکندگی شکل ۳، رابطه بین آسیب‌پذیری اقلیمی و ارزش شرکت‌ها را نشان می‌دهد. از این نمودار می‌توان مشاهده کرد که داده‌ها به‌طور پراکنده در تمام بازه‌های آسیب‌پذیری اقلیمی از ۰ تا ۱ توزیع شده‌اند، اما ارزش شرکت‌ها در بیشتر موارد تقریباً ثابت و در سطح بالای ۲۰۰۰ قرار دارد. این نشان‌دهنده این است که میزان آسیب‌پذیری اقلیمی شرکت‌ها تأثیر زیادی بر ارزش آن‌ها ندارد، زیرا اکثر شرکت‌ها ارزش مشابهی دارند، حتی با سطوح مختلف ریسک اقلیمی. در نمودار همچنین رنگ‌ها نشان‌دهنده بخش‌های مختلف صنعتی هستند. پراکندگی داده‌ها در تمامی بخش‌ها مشابه است، که این نشان‌دهنده این است که تفاوت‌های موجود در بخش‌های صنعتی تأثیر قابل توجهی بر آسیب‌پذیری اقلیمی یا ارزش شرکت‌ها ندارند. علاوه بر این، در قسمت بالایی نمودار، جایی که بیشتر داده‌ها در ارزش شرکت‌ها نزدیک به ۲۰۰۰ تجمع یافته‌اند، می‌توان مشاهده کرد که تعداد زیادی از شرکت‌ها دارای ارزش مشابه هستند. این می‌تواند نشان‌دهنده وجود مقادیر پرت یا عواملی باشد که باعث تجمع این شرکت‌ها در این مقدار خاص شده‌اند. بنابراین، به نظر می‌رسد که آسیب‌پذیری اقلیمی نمی‌تواند پیش‌بینی‌کننده قوی‌ای برای ارزش شرکت‌ها باشد.



شکل (۳): رابطه میان آسیب پذیری اقلیمی و ارزش شرکت‌ها

جدول ۱، مقایسه بین دو مدل XGBoost و MLP، تفاوت‌های قابل توجهی در شاخص‌های عملکرد آنها، از جمله RMSE (ریشه میانگین مربعات خطا) و R^2 Score نشان می‌دهد. مدل XGBoost دارای RMSE برابر با ۷۸.۷۵ است، که نشان می‌دهد پیش‌بینی‌های این مدل به‌طور متوسط ۷۸.۷۵ واحد از مقادیر واقعی فاصله دارند. در مقابل، مدل MLP دارای RMSE کمتری برابر با ۶۰.۸۹ است، که نشان‌دهنده دقت بالاتر این مدل است و پیش‌بینی‌های آن به مقادیر واقعی نزدیک‌تر است. این نتیجه نشان می‌دهد که مدل MLP از دقت بیشتری در پیش‌بینی برخوردار است. از نظر ضریب تعیین (R^2)، مدل XGBoost قادر است ۸۲.۳٪ از تغییرات داده‌ها (ارزش شرکت‌ها) را توضیح دهد، که نشان‌دهنده عملکرد خوب این مدل است، اما هنوز قسمتی از واریانس داده‌ها باقی می‌ماند که توسط این مدل پیش‌بینی نمی‌شود. مدل MLP نیز دارای R^2 برابر با ۰.۸۹۴ است، که به این معناست که این مدل ۸۹.۴٪ از تغییرات داده‌ها را توضیح می‌دهد و عملکرد بهتری نسبت به XGBoost در شبیه‌سازی داده‌ها داشته است. به‌طور کلی، مدل شبکه عصبی (MLP) عملکرد بهتری نشان داده است، زیرا دارای RMSE پایین‌تر و R^2 بالاتر است و پیش‌بینی‌های دقیق‌تری را ارائه می‌دهد.

جدول (۱): تحلیل مقایسه عملکرد مدل‌ها

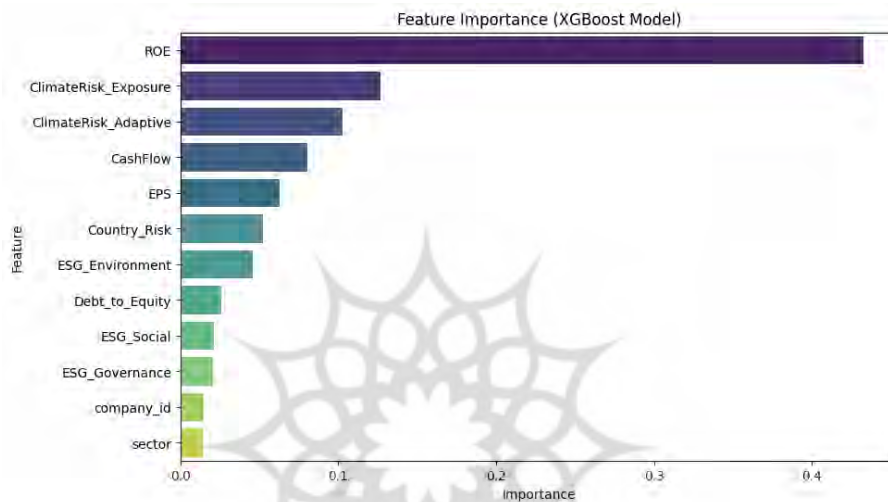
Model	RMSE	R^2 Score
XGBoost	۷۸.۷۵	۰.۸۲۳
Neural Network (MLP)	۶۰.۸۹	۰.۸۹۴

شکل ۴، تحلیل اهمیت ویژگی‌ها در مدل‌های XGBoost و شبکه عصبی (MLP) ویژگی‌های کلیدی که بر پیش‌بینی ارزش شرکت تأثیر زیادی دارند را نشان می‌دهد. در مدل XGBoost، ROE (بازده حقوق صاحبان سهام) مهم‌ترین ویژگی است، که با فاصله زیادی از سایر ویژگی‌ها قرار دارد. پس از آن، میزان آسیب‌پذیری اقلیمی^۱ و توانمندی تطبیق با ریسک‌های اقلیمی^۲ قرار دارند. این نتایج نشان می‌دهد که عملکرد مالی، به ویژه ROE، و ریسک‌های اقلیمی مهم‌ترین

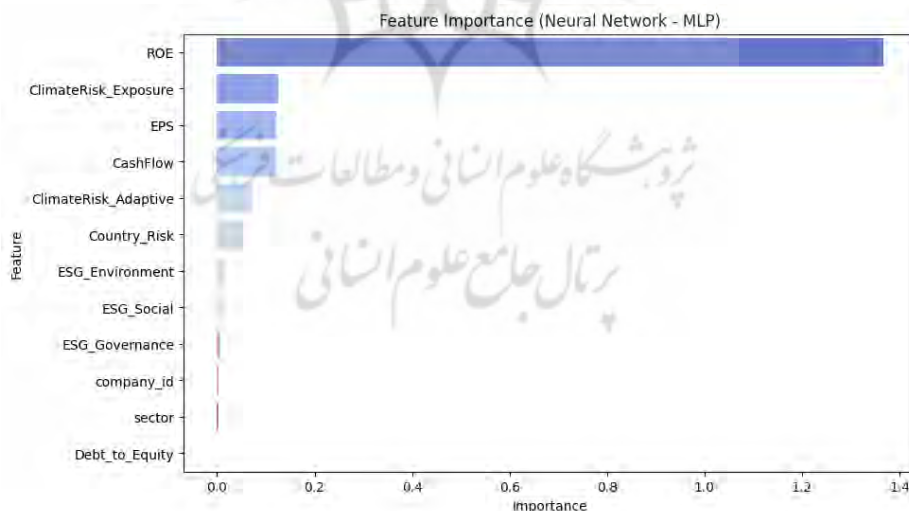
^۱ ClimateRisk_Exposure

^۲ ClimateRisk_Adaptive

پیش‌بینی‌کننده‌های ارزش شرکت‌ها هستند. دیگر ویژگی‌های مالی مانند جریان نقدی و سود هر سهم نیز اهمیت دارند، اما تأثیر آن‌ها کمتر از ریسک‌های اقلیمی و ROE است. در این مدل، ویژگی‌های مرتبط با ESG و بخش صنعت تأثیر کمتری دارند. در مدل MLP، ROE همچنان به‌عنوان مهم‌ترین ویژگی شناخته می‌شود، اما وزن آن در این مدل بسیار بیشتر از مدل XGBoost است، که نشان‌دهنده نقش برجسته‌تر این ویژگی در پیش‌بینی ارزش شرکت‌هاست. میزان آسیب‌پذیری اقلیمی نیز در این مدل اهمیت زیادی دارد و پس از آن ویژگی‌های مالی EPS و CashFlow قرار دارند، که نشان می‌دهد مد MLP توجه بیشتری به داده‌های مالی دارد. همچنین، ویژگی‌هایی مانند توانمندی تطبیق با ریسک‌های اقلیمی و Country_Risk به مدل کمک می‌کنند، اما تأثیر آن‌ها کمتر از ویژگی‌های مالی و اقلیمی است. مانند مدل XGBoost، ویژگی‌های مربوط به ESG و شناسه شرکت در مد MLP اهمیت کمتری دارند، که به‌طور کلی نشان‌دهنده تأثیر بیشتر ریسک‌های اقلیمی و عملکرد مالی شرکت‌ها در پیش‌بینی ارزش آن‌ها است.



(الف)

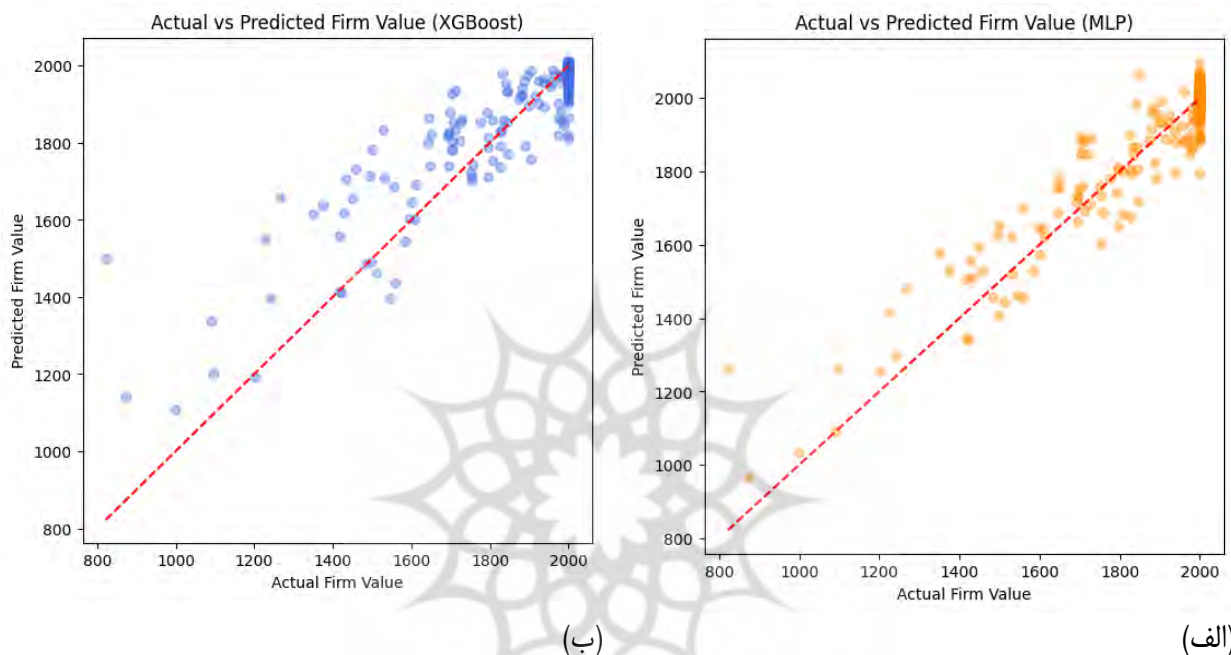


(ب)

شکل (۴): مقایسه اهمیت ویژگی‌ها: XGBoost در مقابل شبکه عصبی (MLP)

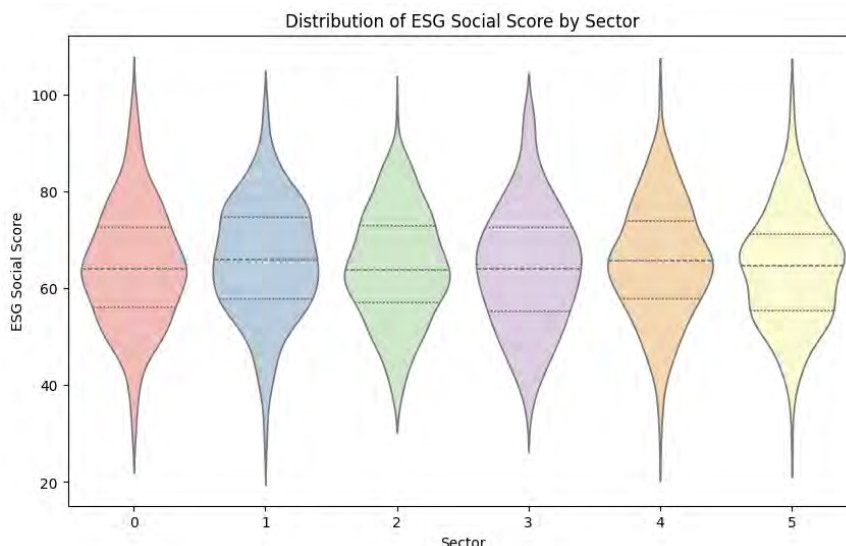
در شکل ۵ الف، نمودار مربوط به مدل MLP، بیشتر نقاط داده‌ها مشابه نمودار XGBoost به‌طور نزدیکی به خط $y=x$ قرار دارند، که نشان‌دهنده عملکرد خوب مدل MLP در پیش‌بینی Firm Value است. این مدل نیز توانسته است پیش‌بینی‌های دقیقی برای اکثر داده‌ها انجام دهد. با این حال، مانند نمودار XGBoost، در اینجا نیز نقاطی با فاصله بیشتر از خط $y=x$ وجود دارند که احتمالاً به دلیل داده‌های پرت هستند. این نقاط در محدوده بالای Firm Value قرار

دارند. در مقایسه با مدل XGBoost، مدل MLP عملکرد بهتری در پیش‌بینی‌ها داشته است، زیرا پیش‌بینی‌های آن در مقایسه با نمودار XGBoost به‌ویژه در مقادیر متوسط و بالا، دقیق‌تر به نظر می‌رسند. در شکل ۵ ب، بیشتر نقاط داده‌ها به‌طور نزدیک به خط $y=x$ قرار دارند که نشان‌دهنده دقت نسبی خوب مدل XGBoost در پیش‌بینی Firm Value است. هرچند پیش‌بینی‌ها از مقادیر واقعی کمی فاصله دارند، اما به‌طور کلی مدل توانسته است پیش‌بینی‌های مناسبی ارائه دهد. در عین حال، در سمت راست نمودار، نقاطی وجود دارند که فاصله بیشتری از خط $y=x$ دارند، که احتمالاً داده‌های پرت هستند و مدل در پیش‌بینی این مقادیر دچار مشکل شده است. این نقاط در محدوده بالای Firm Value قرار دارند و احتمالاً نیاز به تحلیل دقیق‌تری دارند. به‌طور کلی، مدل XGBoost پیش‌بینی‌های دقیق‌تری به‌ویژه در مقادیر نزدیک به ۱۰۰۰ تا ۱۸۰۰ ارائه داده است.



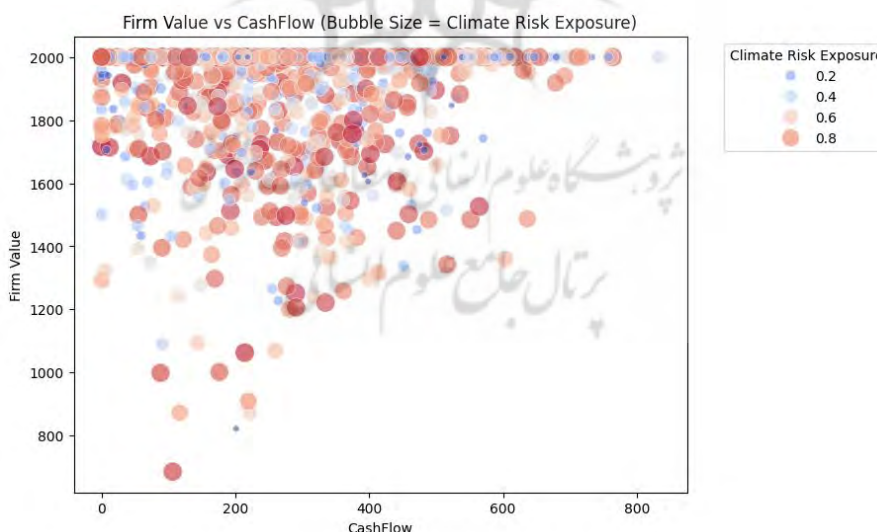
شکل (۵): مقایسه پیش‌بینی ارزش شرکت‌ها (مدل‌های XGBoost و MLP)

نمودار شکل ۶، Violin Plot توزیع امتیای ESG Social Score را بر اساس بخش‌های مختلف (Sector) نشان می‌دهد. همان‌طور که مشاهده می‌شود، بیشتر امتیازهای ESG Social در تمامی بخش‌ها در یک محدوده مشابه توزیع شده‌اند، اما میزان پراکندگی در برخی بخش‌ها بیشتر از سایرین است. به‌ویژه، در Sector 0 (قرمز) و Sector 5 (زرد) توزیع‌ها باریک‌تر هستند و امتیازهای اجتماعی در این بخش‌ها بیشتر در حدود مقادیر متوسط متمرکز شده‌اند. از طرف دیگر، در Sector 2 (سبز) و Sector 3 (بنفش) توزیع‌های گسترده‌تری مشاهده می‌شود، که نشان‌دهنده تنوع بیشتر امتیازهای اجتماعی در این بخش‌ها است. در اکثر بخش‌ها، خط میانه (میانگین امتیاز اجتماعی) در حدود ۶۰ تا ۷۰ قرار دارد، که نشان‌دهنده عملکرد متوسط در زمینه ESG Social Score در این بخش‌ها است. این نمودار می‌تواند تأثیر عوامل بخش صنعتی را بر عملکرد اجتماعی شرکت‌ها نشان دهد.



شکل (۶): توزیع امتیاز ESG Social Score بر اساس بخش‌های مختلف

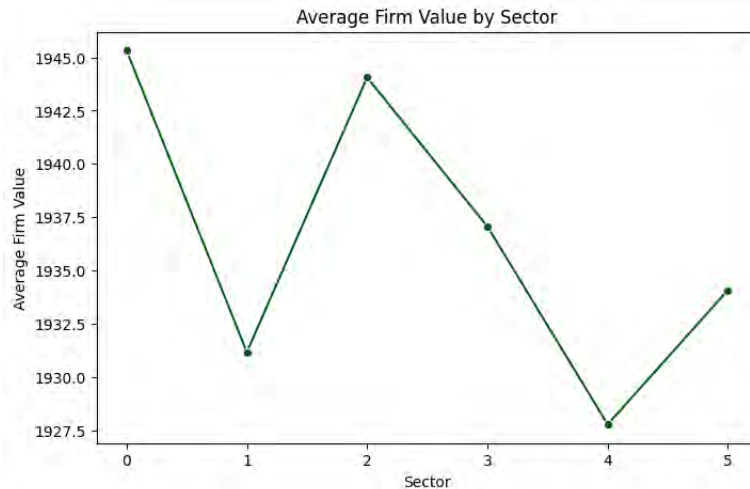
نمودار شکل ۷، Bubble Plot رابطه بین ارزش شرکت و جریان نقدی را نشان می‌دهد و اندازه حباب‌ها نمایانگر آسیب‌پذیری اقلیمی است. از این نمودار مشخص می‌شود که به طور کلی رابطه‌ای مثبت بین CashFlow و Firm Value وجود دارد؛ به این معنی که با افزایش جریان نقدی، ارزش شرکت‌ها نیز به طور معناداری افزایش می‌یابد. این نشان‌دهنده این است که شرکت‌هایی با جریان نقدی بالاتر، معمولاً دارای ارزش بالاتری هستند. با این حال، Climate Risk Exposure تأثیر زیادی بر رابطه بین CashFlow و Firm Value ندارد، زیرا اندازه حباب‌ها (که نشان‌دهنده میزان آسیب‌پذیری اقلیمی است) تغییرات زیادی نشان نمی‌دهند و پراکندگی حباب‌ها بیشتر در مقادیر بالا از CashFlow و Firm Value مشاهده می‌شود. بنابراین، ریسک‌های اقلیمی به نظر نمی‌رسد که تأثیر مستقیمی بر این رابطه داشته باشند.



شکل (۷): رابطه بین ارزش شرکت و جریان نقدی با توجه به آسیب‌پذیری اقلیمی (Bubble Plot)

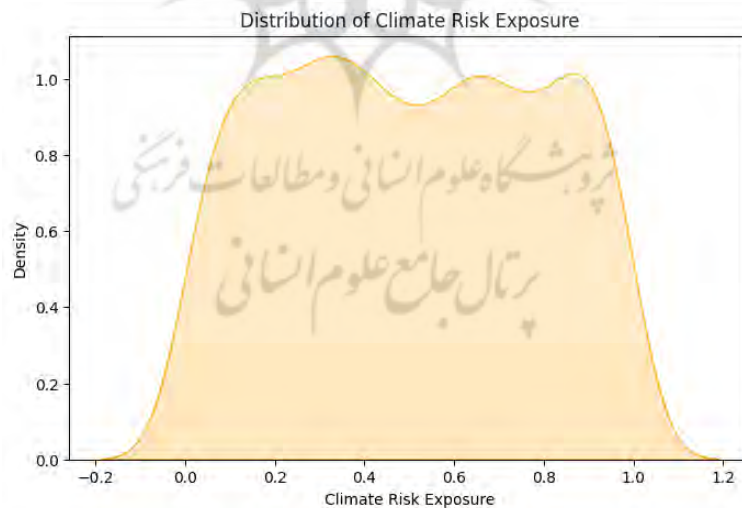
نمودار شکل ۸، نمودار خطی تغییرات میانگین ارزش شرکت‌ها را در بخش‌های مختلف نشان می‌دهد. همانطور که در نمودار مشاهده می‌شود، میانگین Firm Value در بخش‌های مختلف به طور قابل توجهی نوسان دارد. برای مثال، Sector ۳ بالاترین میانگین را دارد، در حالی که Sector ۲ کمترین مقدار را نشان می‌دهد. همچنین، Sector ۲ بیشترین افزایش را تجربه کرده و در نهایت در Sector ۵ مقدار Firm Value به شکل ملایم افزایش پیدا می‌کند. این نوسانات

می‌توانند نشان‌دهنده تأثیرات مختلفی از جمله ویژگی‌های صنعت، شرایط اقتصادی و ویژگی‌های شرکت‌ها در هر بخش باشند. تفاوت‌های قابل توجه در میانگین‌ها به‌طور مستقیم با عوامل خاص هر بخش مرتبط است.



شکل (۸): میانگین ارزش شرکت‌ها بر اساس بخش‌های مختلف

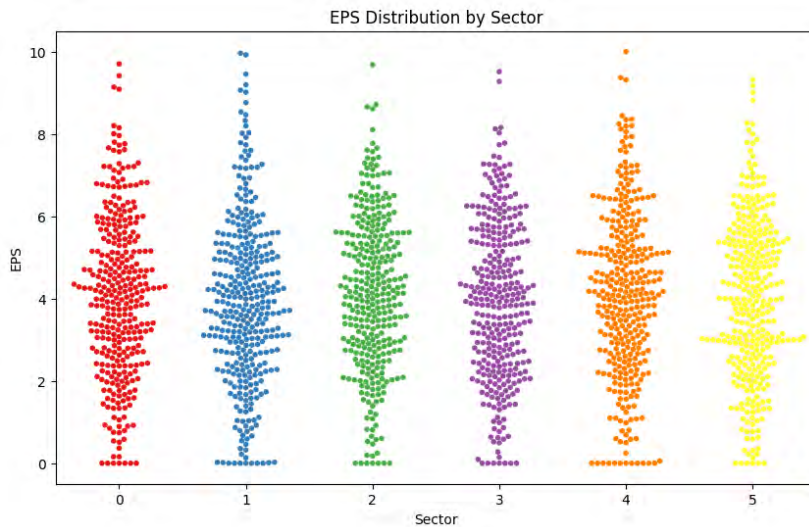
این نمودار توزیع چگالی آسیب‌پذیری اقلیمی را نشان می‌دهد که به‌طور کلی توزیع تقریباً یکنواختی در بازه ۰ تا ۱ دارد. بیشترین چگالی در مقادیر بین ۰.۲ تا ۰.۸، به‌ویژه در حوالی ۰.۴ تا ۰.۶ مشاهده می‌شود، که نشان‌دهنده این است که اکثر شرکت‌ها در این داده‌ها ریسک اقلیمی متوسطی را تجربه می‌کنند. با این حال، پیک‌های جزئی در سمت چپ و راست نمودار نشان‌دهنده وجود شرکت‌هایی با ریسک‌های اقلیمی پایین‌تر یا بالاتر است. به‌طور کلی، پراکندگی به سمت مقادیر بالاتر کاهش می‌یابد، که نشان می‌دهد تعداد کمی از شرکت‌ها تحت تأثیر ریسک‌های اقلیمی بالا قرار دارند. این توزیع نشان می‌دهد که بیشتر شرکت‌ها در معرض ریسک‌های اقلیمی متوسط قرار دارند و نیاز به اقدامات برای بهبود تطبیق‌پذیری در برابر تغییرات اقلیمی وجود دارد.



شکل (۹): توزیع چگالی آسیب‌پذیری اقلیمی

نمودار Violin Plot در شکل ۱۰، توزیع EPS را بر اساس بخش‌های مختلف (Sector) نشان می‌دهد. همانطور که مشاهده می‌شود، توزیع EPS در هر بخش به‌طور گسترده‌ای تغییر می‌کند و بیشتر داده‌ها در محدوده مقادیر پایین‌تر از ۶ قرار دارند. در بخش Sector 0، توزیع گسترده‌تری در مقادیر پایین‌تر (کمتر از ۲) مشاهده می‌شود، در حالی که در Sector 4 و Sector 5 بیشتر داده‌ها در محدوده ۲ تا ۶ قرار دارند. این نشان‌دهنده تفاوت‌های عملکرد مالی شرکت‌ها در بخش‌های مختلف است، به‌طوری‌که برخی بخش‌ها مانند Sector 0 دارای مقادیر گسترده‌تری از EPS هستند و در

بخش‌هایی مانند Sector 4 و Sector 5 بیشتر داده‌ها در مقادیر بالاتری قرار دارند. به‌طور کلی، بیشتر شرکت‌ها در هر بخش دارای EPS متوسط هستند، اما در برخی بخش‌ها، داده‌ها به سمت مقادیر بالاتری متمایل‌اند.



شکل (۱۰): توزیع EPS بر اساس بخش‌های مختلف

نتیجه‌گیری و پیشنهادها

در این پژوهش، به تحلیل و پیش‌بینی ارزش شرکت‌ها با استفاده از داده‌های مالی، شاخص‌های ESG و ریسک‌های اقلیمی پرداخته شد. نتایج نشان می‌دهند که ویژگی‌های مالی مانند ROE (بازده حقوق صاحبان سهام) بیشترین تأثیر را بر پیش‌بینی ارزش شرکت‌ها دارند. در حالی که ویژگی‌های غیرمالی مانند ESG و ریسک‌های اقلیمی تأثیر نسبی کمتری داشته‌اند، این پژوهش به اهمیت داده‌های اقلیمی و اجتماعی در ارزیابی عملکرد شرکت‌ها اشاره می‌کند. همچنین، مدل MLP (شبکه عصبی چند لایه) عملکرد بهتری نسبت به XGBoost در پیش‌بینی‌ها از خود نشان داد، که دقت بالاتری در شبیه‌سازی داده‌ها و کاهش خطا داشت. با توجه به نتایج به‌دست‌آمده، پیشنهاد می‌شود که مدل‌های پیش‌بینی ارزش شرکت‌ها به‌طور منظم از داده‌های ESG و ریسک‌های اقلیمی به‌عنوان عوامل تعیین‌کننده در تحلیل‌های مالی استفاده کنند. به‌ویژه در بخش‌هایی که آسیب‌پذیری اقلیمی بیشتر است، شرکت‌ها باید با اتخاذ استراتژی‌های مناسب، تأثیرات تغییرات اقلیمی را در مدل‌های ارزیابی خود لحاظ کنند. همچنین، با توجه به کارایی مدل MLP، توصیه می‌شود از این مدل به‌عنوان ابزار دقیق‌تر برای پیش‌بینی ارزش شرکت‌ها در آینده استفاده گردد. برای تحقیقات آتی، به‌ویژه در بازارهای نوظهور، پیشنهاد می‌شود که تأثیرات متقابل داده‌های اقلیمی و اجتماعی با ویژگی‌های مالی و نرخ‌های بازده سرمایه، در چارچوب مدل‌های پیچیده‌تر بررسی شود.

منابع

- ✓ خاندوزی، حسنیه، (۱۴۰۳)، بررسی تأثیر ریسک اقلیمی بر مدیریت سود. بررسی تأثیر ریسک اقلیمی بر مدیریت سود، نشریه علمی رویکردهای پژوهشی نوین مدیریت و حسابداری، دوره ۸، شماره ۳۰، صص ۴۷۳-۴۹۷.
- ✓ فخری، زهره، (۱۴۰۳)، بررسی ارتباط بین عملکرد محیطی، اجتماعی و حاکمیتی (ESG) با سطح نگهداشت وجه نقد و ریسک نکول شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران یازدهمین کنفرانس بین‌المللی چشم اندازهای نوین در مدیریت، حسابداری و کارآفرینی.

- ✓ نقدی، سجاد، جدی، رقیه، (۱۴۰۲)، مطالعه جامع پسايندهای ريسک‌های اقليمي از منظر حسابداری با رهيافت فراترکيب، دانش حسابداری مالی، دوره ۱۰، شماره ۴، صص ۲۷-۵۵.
- ✓ Ali, A., Haider, A., & Senturk, I. (2025). Climate Disclosure and Corporate Valuation: Evidence from S&P 500 Companies. *Policy Journal of Social Science Review*, 3(4), 645-658 .
 - ✓ Awijen, H., Ben Jabeur, S., & Pillot, J. (2024). Interpretable machine learning models for ESG stock prices under transition and physical climate risk. *Annals of operations research*, 1-31 .
 - ✓ Battiston, S., Mandel, A., Monasterolo, I., Schütze, F., & Visentin, G. (2017). A climate stress-test of the financial system. *Nature Climate Change*, 7(4), 283-288 .
 - ✓ Bonello, J., BrÉdart, X., & Vella, V. (2018). Machine learning models for predicting financial distress. *Journal of Research in Economics*, 2(2), 174-185 .
 - ✓ Chen, S., Song, Y., & Gao, P. (2023). Environmental, social, and governance (ESG) performance and financial outcomes: Analyzing the impact of ESG on financial performance. *Journal of environmental management*, 345, 118829 .
 - ✓ Chung, R., Bayne, L., & Birt, J. (2024). The impact of environmental, social and governance (ESG) disclosure on firm financial performance: evidence from Hong Kong. *Asian Review of Accounting*, 32(1), 136-165 .
 - ✓ Eccles, R. G., Ioannou, I., & Serafeim, G. (2012). The impact of a corporate culture of sustainability on corporate behavior and performance (Vol. 17950) .National Bureau of Economic Research Cambridge, MA, USA .
 - ✓ Friede, G., Busch, T., & Bassen, A. (2015). ESG and financial performance: aggregated evidence from more than 2000 empirical studies. *Journal of sustainable finance & investment*, 5(4), 210-233 .
 - ✓ Gu, S., Kelly, B., & Xiu, D. (2020). Empirical asset pricing via machine learning. *The Review of financial studies*, 33(5), 2223-2273 .
 - ✓ Kotsantonis, S., Pinney, C., & Serafeim, G. (2016). ESG integration in investment management: Myths and realities. *Journal of Applied Corporate Finance*, 28(2), 10-16 .
 - ✓ Krueger, P., Sautner, Z., & Starks, L. T. (2020). The importance of climate risks for institutional investors. *The Review of financial studies*, 33(3), 1067-1111 .
 - ✓ Secinaro, S., Brescia, V., Calandra, D., & Saiti, B. (2020). Impact of climate change mitigation policies on corporate financial performance: Evidence- based on European publicly listed firms. *Corporate Social Responsibility and Environmental Management*, 27(6), 2491-2501 .
 - ✓ Sila, I., & Cek, K. (۲۰۱۷) .The impact of environmental, social and governance dimensions of corporate social responsibility on economic performance: Australian evidence. *Procedia computer science*, 120, 797-804 .
 - ✓ Vyshnevskaya, O., Litvak, O., Melnyk, I., Oliynyk, T., & Litvak, S. (20۱۷) .Impact of globalization on the world environment. *Ukrainian Journal of Ecology*, 11(1), 77-83 .