

# تکنیک های داده کاوی برای کشف تقلب در صورت های مالی

منیرالدین رمضان  
dataacademy.ir

دانشجوی کارشناسی ارشد مکترونیک

شماره دانشجویی:

۹۰۱۲۶۹۶۵۱

بهار ۹۶

۱

## چکیده

این مقاله کارایی تکنیک های طبقه بندی با استفاده از داده کاوی (DM) در شناسایی شرکت هایی را که صورت های مالی خلاف واقع (FFS) منتشر می کنند، بررسی کرده و به شناسایی عوامل مرتبط با FFS نیز می پردازد. حسابرسان می توانند با بهره بردن از تکنیک های داده کاوی برای کشف تقلب های مدیریتی، کار خود را ساده تر کنند. این مطالعه تأثیر استفاده از درخت های تصمیم گیری، شبکه های عصبی و شبکه های بیزین در شناسایی صورت های مالی تقلبی را بررسی می نماید. بردار درون داد از نسبت های برگرفته از صورت های مالی تشکیل شده است. سه مدل مذکور از لحاظ عملکرد مورد مقایسه قرار می گیرند.

**کلمات کلیدی:** صورت های مالی تقلبی، تقلب مدیریتی، داده کاوی، حسابرسی، یونان

# dataacademy.ir

## ۱. مقدمه

امروزه حسابرسی (ممیزی) به کاری بسیار چالش بر انگیز بدل شده و شواهد زیادی موجودست مبنی براین که انجام فعالیت های مربوط به «دستکاری در حساب ها» به شدت رواج دارد. کاسکیوارا سال ۲۰۰۲ را از نظر دستکاری در حساب ها، «سالی هولناک» نامیده و ادعا می کند که این دستکاری ها هنوز هم ادامه دارد (کاسکیوارا، ۲۰۰۴). برخی از برآوردها حاکی از آنند که تقلب و کلاهبرداری سالانه بیش از ۴۰۰ میلیارد دلار برای ایالات متحده هزینه دربردارد (ولز، ۱۹۹۷). اسپاتیس، دامپوس و زاپونیدیس (۲۰۰۲) مدعی این هستند که تقلب در صورت های مالی ظرف چند سال اخیر به شدت رواج گرفته است. تقلب مدیریتی به معنای کلاهبرداری عامدانه از سوی مدیریت است به نحوی که ارائه صورت های مالی ساختگی گمراه کننده باعث خسارت دیدن سرمایه گذاران و بستانکاران شود. حسابرسان می بایست حتما در طول فرایند ممیزی، احتمال وقوع تقلب مدیریتی را برآورد کنند. سازمان AICPA صراحتا به مسئولیت حسابرسان در کشف تقلب اذعان دارد (کالینان و ساتن، ۲۰۰۲). حسابرسان برای گسترش پیش بینی های خود از تکنیک های بازنگری تحلیلی استفاده می کنند که به آن ها اجازه می دهد صورت وضعیت های مالی را بدون نیاز به بررسی تک تک معاملات مربوطه، برآورد کنند. فریسر،

هیزرلی و لین (۱۹۹۷) تکنیک های بازنگری تحلیلی را در قالب گروه های غیر کمی، کمی ساده و کمی پیشرفته، دسته بندی می کنند. تکنیک های کمی پیشرفته شامل روش های پیچیده ای (مانند شبکه های عصبی و تحلیل رگرسیون) است که از آمار و هوش مصنوعی گرفته شده اند.

در سال های اخیر به دلیل افزایش تعداد شرکت های ثبت شده در لیست بورس اوراق بهادار آتن (و انباشت سرمایه از طریق کمک های عمومی) و تلاش برای کاهش مالیات وضع شده بر سود، کشف تقلب در صورت های مالی و بررسی صلاحیت این صورت ها در یونان مورد توجه عموم قرار گرفته است. در یونان همواره عموم مردم تقاضا داشته اند صورت های مالی متقلبانه و نظرات دارای صلاحیت را به عنوان نشانه هایی که وقوع ورشکستگی تجاری را هشدار می دهند، مورد توجه قرار گیرد. درخواست های روزافزونی نیز برای افزایش شفافیت، پایایی و حجم اطلاعات موجود در صورت های مالی دیده می شود (اسپاتیس، دامپوس و زاپونیدیس، ۲۰۰۳).

داده کاوی (DM) فرایندی تکرار شونده است که در آن پیشرفت به معنای اکتشاف است؛ خواه از طریق روش های خودکار باشد یا شیوه های دستی. DM بیشترین فایده را در سناریوی تحلیل جستاری دارد که در آن هیچ نظر از پیش تعیین شده ای راجع به آنچه برون داد «جالب توجه» را تشکیل خواهد داد، وجود ندارد (کنترتزیک، ۲۰۰۲). کاربرد تکنیک های داده کاوی برای طبقه بندی مالی، حوزه ای مناسب برای تحقیق است. بسیاری از سازمان های نظارتی و بخش های خاص بازجویی، که هدفشان کشف فعالیت های متقلبانه است، نیز تکنیک های داده کاوی را به طور موفق به کار برده اند. با این حال، برخلاف حوزه هایی همچون پیش بینی ورشکستگی یا درماندگی مالی که به خوبی مورد بررسی قرار گرفته اند، تحقیق در مورد کاربرد روش های DM در کشف تقلب های مدیریتی نسبتاً ناچیز بوده است (کلدرن و چه، ۲۰۰۲؛ کاسکیوارا، ۲۰۰۴؛ کرکاس و مانولوپولوس، ۲۰۰۴).

در این مطالعه برای کشف FFS با استفاده از روش های طبقه بندی به وسیله داده کاوی، داده های در دسترس عموم از صورت های مالی شرکت های متعدد را عمیقاً مورد بررسی قرار می دهیم. هدف این مقاله شناسایی عوامل

اقتصادی است که حسابرسان باید هنگام بررسی احتمال وقوع FFS از آن ها استفاده کنند. یکی از اهداف اصلی ما معرفی، کاربرد و ارزیابی استفاده از روش های داده کاوی در ایجاد تمایز میان مشاهدات فاقد و دارای تقلب است.

هدف تحقیق حاضر اینست که با به کارگیری تکنیک های داده کاوی آماری و هوش مصنوعی (AI) که بر داده های در دسترس عموم صورت های مالی اعمال می شوند، به تحقیقات مربوط به کشف تقلب مدیریتی کمک نماید. مزیت نظری روش های AI اینست که این شیوه ها پیش فرض های قراردادی را بر متغیرهای ورودی تحمیل نمی کنند. با این حال، نتایج گزارش شده روش های AI به طور جزئی یا مقطعی از نتایج روش های آماری پیشی می گیرند.

در این تحقیق قابلیت کاربرد سه تکنیک داده کاوی در کشف تقلب مدیریتی آزموده شده است: درخت های تصمیم گیری، شبکه های عصبی و شبکه های بیزین. این سه روش از لحاظ دقت در پیش بینی، با یکدیگر مقایسه می شوند. داده های ورودی عمدتاً از نسبت های مالی برگرفته از صورت های مالی (یعنی ترازنامه ها و صورت درآمدها) تشکیل شده اند. نمونه آماری شامل داده هایی از ۷۶ شرکت تولیدی یونان است. روابط میان متغیرهای ورودی و نتایج طبقه بندی به وسیله روش های مورد استفاده شناسایی و نشان داده شدند.

مقاله به این صورت پیش می رود: بخش ۲ مروری دارد بر تحقیقات مرتبط پیشین. بخش ۳ در مورد روش تحقیق استفاده شده توضیح می دهد. بخش ۴ مدل های ساخته شده را توصیف و نتایج را تحلیل می کند. در نهایت هم در بخش ۵ نتیجه گیری و جمع بندی مطالب انجام می شود.

## ۲. تحقیقات پیشین

در سال ۱۹۹۷، هیأت استانداردهای حسابرسی بیانیه شماره ۸۲ استانداردهای حسابرسی (SAS) تحت عنوان «توجه به تقلب در ممیزی صورت مالی» را منتشر کرد. این استاندارد حسابرسان را ملزم می کند ریسک تقلب را در طول هر ممیزی ارزیابی کنند و آن ها را تشویق می کند که در هنگام انجام این ارزیابی ها هم به سیستم های

کنترل داخلی و هم به نگرش مدیریت در مورد این سیستم ها توجه داشته باشند. عوامل ریسک یا «پرچم های قرمز» مربوط به گزارش مالی متقلبانه را می توان به سه گروه زیر تقسیم کرد (بیانیه SAS، شماره ۸۲): (۱) ویژگی های مدیریت و تأثیرات آن بر محیط کنترل، (۲) شرایط صنعت، و (۳) ویژگی های اجرایی و ثبات مالی. کمیته بین المللی فعالیت های حسابرسی (IAPC) در فدراسیون بین المللی حسابداران، بیانیه جهانی حسابرسی (ISA) شماره ۲۴۰ را به تصویب رساند. این استاندارد به برداشت حسابرسان مبنی بر احتمال وجود خطا و ریسک تقلب احترام گذاشته و بحث های پیرامون محدودیت های درونی حسابرسان در کشف تقلب، به ویژه تقلب مدیریتی را تصریح می کند. به علاوه، این استاندارد تقلب مدیریتی و کارمندی را از یکدیگر جدا کرده و بحث مفصلی راجع به گزارشگری مالی متقلبانه انجام می دهد.

کشف تقلب مدیریتی با استفاده از روندهای معمول حسابرسی، کاریست دشوار (پورتر و کمرون، ۱۹۸۷؛ کور، ۱۹۹۹). اولاً، دانش اندکی راجع به ویژگی های تقلب مدیریتی موجودست. ثانیاً، به دلیل وقوع کم این نوع تقلب، اکثر حسابرسان تجربه لازم برای کشف آن را ندارند. نهایتاً، مدیران عمداً تلاش می کنند حسابرسان را گمراه کنند (فینینگ و کاگر، ۱۹۹۸). برای چنین مدیرانی که محدودیت های هر گونه ممیزی را درک می کنند، فرایندهای استاندارد حسابرسی ممکنست ناکافی باشند. این محدودیت ها حاکی از نیاز به وجود فرایندهای تحلیلی بیشتر برای کشف ثمربخش تقلب های مدیریتی هستند. همچنین به این نکته هم توجه شده است که تأکید فزاینده بر ارزیابی سیستم، با جایگاه این حرفه از نظر کشف تقلب مغایرت دارد؛ چراکه بیشتر تقلب های قابل توجه در سطوح بالای سازمان اتفاق می افتند که در آن کنترل و سیستم کمترین میزان تسلط و تأثیر را دارند (کالینان و ساتن، ۲۰۰۲).

مطالعات اخیر تلاش کرده اند مدل هایی برای پیش بینی وجود تقلب مدیریتی بسازند. نتایج تحلیل رگرسیون logit از ۷۵ شرکت دارای تقلب و ۷۵ شرکت بدون تقلب، نشان داده است که شرکت های فاقد تقلب دارای هیأت مدیره هایی هستند که درصد اعضای بیرونی در آن ها به مراتب بیشتر از هیأت مدیره شرکت های دارای تقلب است (بیزلی، ۱۹۹۶). هانسون، مک دونالد، مسیر و بل (۱۹۹۶) از یک مدل پاسخ کیفی تعمیم یافته قدرتمند برای

پیش بینی تقلب مدیریتی بر مبنای داده های تولید شده توسط یک شرکت بین المللی حسابداری دولتی، استفاده کردند. این مدل شامل تکنیک های **logit** و **probit** است. نتایج نشان دهنده قدرت پیش بینی بالایی برای برآورد هزینه متقارن و نامتقارن بود.

آینینگ، جونز و لویکی (۱۹۹۷) آزمایشی انجام دادند تا دریابند آیا استفاده از یک سیستم تخصصی عملکرد حسابرسان را ارتقا می دهد یا خیر. آن ها دریافتند حسابرسانی که از سیستم های تخصصی بهره می بردند، در شرایط دارای سطوح مختلف ریسک-تقلب، عملکرد بهتری داشته و تصمیمات یکنواخت تری در مورد اقدامات حسابرسی مقتضی اتخاذ کرده اند. گرین و چوی (۱۹۹۷) یک مدل شبکه عصبی برای طبقه بندی تقلب ایجاد کردند. ورودی های این مدل شامل ۵ نسبت و ۳ وضعیت حساب بود. نتایج حاکی از این بود که شبکه های عصبی از ظرفیت بالایی برای استفاده به عنوان یک ابزار کشف تقلب برخوردارند. وجود تقلب در یک صورت مالی طبق این طبقه بندی، حسابرس را آگاه می کند که باید بررسی های بیشتری صورت دهد. فنینگ و کاگر (۱۹۹۸) از شبکه عصبی برای ایجاد یک مدل کشف تقلب استفاده کردند. بردار ورودی آن ها شامل نسبت های مالی و متغیرهای کیفی بود. آن ها عملکرد مدل خود را با تحلیل تابع مبین درجه دوم و خطی و نیز رگرسیون لجستیک مقایسه کرده و مدعی شدند که مدل آن ها در کشف تقلب کارایی بالاتری نسبت به روش های آماری معمول دارد.

سامرز و سوینی (۱۹۹۸) یک مدل **logit** آبخاری را برای بررسی رابطه میان تجارت افراد داخل شرکت و تقلب، ساختند. آن ها دریافتند که در هنگام وجود تقلب، افراد درون شرکت از طریق فعالیت های فروش عمده، از میزان سهام تحت اختیار خود می کاهند. ابوت، پارک و پارکر (۲۰۰۰) از تحلیل آماری رگرسیون برای بررسی تأثیر وجود یک هیأت ممیزی مستقل بر کاهش احتمال وقوع تقلب، بهره گرفتند. آنان دریافتند احتمال این که شرکت های دارای هیأت های حسابرسی شامل مدیرانی مستقل که حداقل دو بار در سال تشکیل جلسه می دهند، به دلیل ارائه گزارش های مالی متقلبانه یا گمراه کننده تحریم شوند، کمتر است.

بل و کارسلو (۲۰۰۰) یک مدل رگرسیون لجستیک را برای برآورد احتمال ارائه گزارش های مالی متقلبانه برای یک ارباب رجوع متقاضی ممیزی، تحت شرایط عوامل ریسک-تقلب مختلف، ایجاد کرده و آزمودند. عوامل ریسک قابل توجه گنجانده شده در مدل نهایی شامل این موارد بودند: محیط کنترل درونی ضعیف، رشد سریع شرکت، سوددهی نسبی ناکافی یا ناپایدار، مدیریتی که تأکید بیش از حدی بر پیش بینی عواید جلسات دارد، مدیریتی که به حسابرسان دروغ گفته یا شدیداً طفره می رود. وضعیت مالکیت نهاد مورد نظر (دولتی یا خصوصی) و میزان تعامل میان محیط کنترلی ضعیف و نگرش های متخصصانه مدیریت نسبت به گزارشگری مالی. اسپاتیس (۲۰۰۲) مدلی برای کشف صورت های مالی دستکاری شده ساخت. وی در این مدل از روش آماری رگرسیون لجستیک بهره گرفت. در این مدل از دو بردار ورودی جایگزین شامل نسبت های مالی استفاده شد. میزان دقتی که گزارش شد، بیش از ۸۴ درصد بود. این نتایج حکایت از آن دارند که احتمال کشف FFS از طریق تحلیل صورت های مالی منتشر شده، وجود دارد. اسپاتیس و همکاران (۲۰۰۲) برای ساخت یک مدل کشف صورت های مالی دستکاری شده، از روش UTADIS استفاده کردند. این روش برمبنای یک چارچوب مبتنی بر رگرسیون غیرپارامتری عمل می کند. آن ها همچنین از روش های تحلیل تابع مبین و رگرسیون logit نیز به عنوان معیارهای سنجش بهره بردند. نتایج آنان حاکی از اینست که روش UTADIS از لحاظ نمونه اعتبارسنجی و آموزش، بهتر از دیگر روش ها عمل می کند. نتایج آن ها همچنین نشان داد که نسبت های «کل بدهی به کل سرمایه» و «موجودی به فروش»، عوامل توضیحی مرتبط با FFS هستند.

### ۳. روش تحقیق

#### ۳,۱ داده ها

نمونه آماری ما شامل داده هایی از ۷۶ شرکت تولیدی یونانی بود (هیچ شرکت مالی را مورد استفاده قرار ندادیم). حسابرسان تمامی شرکت های موجود در این نمونه را مورد بررسی قرار دادند. برای ۳۸ مورد از این شرکت ها، نشانه یا تأییدیه ای منتشر شده مبنی بر ارائه FFS وجود داشت. برمبنای پارامترهای زیر، یک صورت مالی در گروه صورت های خلاف واقع قرار داده می شد: جای گرفتن در زمره مواردی که حسابرسان از نظر صحت وضعیت های مالی شدیداً به آن ها شک داشتند، مشاهدات مقامات مالیاتی مبنی بر وجود ناترازی های مالیاتی مهمی که

جایگزین ترازنامه ها و صورت درآمد سالیانه شرکت ها شده بودند، کاربرد قوانین یونان در زمینه ارزش خالص منفی، قرار گرفتن در لیست شرکت هایی که به دلایل مربوط به دستکاری در اطلاعات مالی شرکت، از سوی بورس اوراق بهادار یونان تحت نظارت یا «ممنوع معامله» قلمداد شده بودند و، وجود دادرسی های در حال انجام مربوط به FFS یا تخطی های مالیاتی مهم.

شرکت های ۳۸ گانه دارای FFS در کنار ۳۸ شرکت بدون FFS قرار داده شدند. این شرکت ها بر این اساس جزء شرکت های فاقد FFS قرار گرفتند که در گزارش های ارائه شده توسط حسابرسان، پایگاه داده های مالی و مالیاتی و نیز در سازمان معاملات آتن، هیچ گونه نشانه یا تأییدیه ای مبنی بر انتشار FFS از سوی آن ها به چشم نمی خورد. البته، قطعاً این مسئله بدین معنا نبود که صورت های مالی این شرکت ها به هیچ وجه دستکاری نشده و یا در آینده رفتاری در راستای FFS از آن ها سر نخواهد زد. این امر تنها تضمین می کرد که در جستجوی مفصل در این رابطه، هیچ گونه FFS یافت نشده است. تمامی متغیرهای استفاده شده در نمونه آماری از صورت های مالی رسمی (مانند ترازنامه های مالی و صورت وضعیت حساب ها) استخراج شد. این بدان معناست که ثمربخشی این مطالعه تنها به دلیل استفاده صرف از داده های مالی شرکت های یونانی، محدود نمی شود.

## ۳,۲ متغیرها

انتخاب متغیرها برای استفاده به عنوان گزینه های جایگذاری شده در بردار ورودی، براساس تحقیقات قبلی مرتبط با FFS صورت گرفت. تحقیقاتی مانند کارهای اسپاتیس (۲۰۰۲)، اسپاتیس و همکاران (۲۰۰۲)، فنینگ و کاگر (۱۹۹۸)، پرسنز (۱۹۹۵)، استایس (۱۹۹۱)، فروز، پارک و پاستینا (۱۹۹۱)، لوبکی، آیینگ و ویلینگهام (۱۹۸۹) و کینی و مک دنیل (۱۹۸۹)، شامل شاخصه های پیشنهادی FFS بودند.

درماندگی مالی می تواند انگیزه ای برای تقلب مدیریتی باشد (فنینگ و کاگر، ۱۹۹۸؛ استایس، ۱۹۹۱؛ لوبکی و همکاران، ۱۹۸۹؛ کینی و مک دنیل، ۱۹۸۹). به منظور ایجاد نسبی برای درماندگی مالی، از نمرات  $Z$  مشهور آلتمن استفاده کردیم. آلتمن در اثر پیشتاز خود نسبت نمره  $Z$  را برای برآورد درماندگی مالی ایجاد کرد (آلتمن،



۱۹۶۸). از آن پس، بسیاری از محققان در تحقیقات مرتبط با درماندگی مالی و پیش بینی ورشکستگی، از نمره Z او استفاده های زیادی بردند.

پرسنز (۱۹۹۵) ادعا می کند این سؤال که آیا بدهی زیاد با FFS در ارتباط است یا خیر، پاسخ مشخصی ندارد. البته ساختاری با بدهی بالا می تواند احتمال وقوع FFS را افزایش دهد؛ چراکه باعث می شود ریسک از مدیران و صاحبان سهم در شرکت به سمت صاحبان بدهی ها حرکت کند. ممکنست مدیران به دلیل نیاز به ادای دیون طبق قرارداد، مجبور به دستکاری صورت های مالی شوند. این بدان معناست که بدهی های بیشتر ممکنست احتمال انتشار FFS را افزایش دهد. ما این احتمال را با استفاده از لگاریتم مجموع بدهی ها (LOGDEBT)، نسبت بدهی به سهم (DEBTEQ) و نسبت کل بدهی به کل دارایی (TDTA)، اندازه گیری کردیم.

انگیزه ای دیگر برای تقلب مدیریتی، نیاز به رشد مداومست. شرکت هایی که در کسب نتایجشبهه به عملکرد سابقشان ناکامند، ممکنست برای تداوم حرکت در مسیر قبلی خود دست به فعالیت های متقلبانانه بزنند (استایس، آلبرکت و براون، ۱۹۹۱). ممکنست شرکت هایی که رشد سریعی دارند، از توان فرایندهای کنترلیبرای نظارت مناسب هم سریع تر حرکت کنند فنینگ و کاگر، ۱۹۹۸). ما از نسبت رشد فروش (SALGRTH) به عنوان مقیاسی برای سنجش میزان رشد استفاده کردیم.

گروهی از حساب ها (که به برآوردهایی غیر عینی منجر می شوند)، حسابرسی دشوارتری داشته و در نتیجه در معرض دستکاری متقلبانانه خواهند بود. میزان حساب های دریافتنی، موجود و فروش در چنین گروهی قرار می گیرند. پرسنز (۱۹۹۵)، استایس (۱۹۹۱) و فروز و همکاران (۱۹۹۱) مدعی اینند که ممکنست مدیریت شرکت حساب های دریافتنی را دستکاری نماید. فعالیت متقلبانانه ثبت فروش پیش از وصول مبالغ مربوطه می تواند خود را در غالب افزایش میزان حساب های دریافتنی نشان دهد (فنینگ و کاگر، ۱۹۹۸). ما میزان حساب های دریافتنی را با استفاده از نسبت حساب های دریافتنی به فروش (RECSAL)، نسبت حساب های دریافتنی به حساب های

دریافتنی متعلق به دو سال پیاپی (RETREND) و متغیر دیجیتال REC11، که نشان دهنده تغییری ۱۰ درصدی است، چک می کنیم.

بسیاری از محققان اعتقاد دارند که ممکنست مدیریت به دستکاری میزان موجودی مبادرت کند (استایس، ۱۹۹۱؛ پرسنز، ۱۹۹۵؛ شیلیت، ۲۰۰۲). گزارش موجودی با بهایی کمتر و ثبت موجودی از کارافتاده، تکنیک هایی شناخته شده در این راستا هستند. ما میزان موجودی را با استفاده از نسبت موجودی به فروش (INNVSAL) و نسبت موجودی به کل دارایی ها (INVTA) چک می کنیم. احتمال دستکاری حاشیه ناخالص نیز وجود دارد. ممکنست شرکت میزان فروش را با بهای متناظر اجناس فروخته شده مطابقت ندهد و در نتیجه باعث افزایش حاشیه ناخالص، درآمد خالص و تقویت ترازنامه شود (فنینگ و کاگر، ۱۹۹۸). ما مقدار حاشیه ناخالص را با استفاده از نسبت فروش منهای حاشیه ناخالص (COSAL)، نسبت سود ناخالص به مجموع دارایی ها (GPTA)، نسبت حاشیه ناخالص به حاشیه ناخالص متعلق به دوسال پیاپی (GMTREND) و متغیر دوشاخه GM11، که افزایشی ۱۰ درصدی نسبت به ارزش سال گذشته را نشان می دهد، می آزمایشیم.

dataacademy.ir

اسپاتیس (۲۰۰۲) در یک تحقیق رگرسیون لجستیک روی پیش بینی FFS، ادعا می کند که نسبت های سود خالص به مجموع دارایی ها (NPTA) و سرمایه در گردش به مجموع دارایی ها (WCTA) همبستگی معناداری را نشان می دهند. به علاوه، اسپاتیس و همکاران (۲۰۰۲) عقیده دارند که معناداری نسبت سود خالص به فروش (NPSAL) نیز ثابت شده است.

در مطالعه حاضر، «نسبت های هشداردهنده» (پرچم های قرمز) دیگری در مورد صورت های مالی نیز از لحاظ ارتباط با پیش بینی FFS مورد بررسی قرار می گیرند. این نسبت ها عبارتند از: لگاریتم مجموع دارایی ها (LTA)، سرمایه در گردش (WCAP)، نسبت اموال، ماشین آلات و تجهیزات (دارایی های ثابت خالص) به مجموع دارایی ها (NFATA)، نسبت فروش به مجموع دارایی ها (SALTA)، نسبت دارایی های جاری به دیون جاری (CACL)، درآمد خالص به دارایی های ثابت (NIFA)، نقدینگی به مجموع دارایی ها (CASHTA)،

دارایی های آنی به دیون جاری (QACL)، میزان عواید پیش از محاسبه بهره و مالیات (EBIT) و نسبت بدهی های بلندمدت به مجموع دارایی ها (LTDTA).

در مجموع، ۲۷ نسبت مالی را گردآوری کردیم. در تلاش برای کاهش بعدیت، از آزمون ANOVA استفاده کردیم تا ببینیم آیا تفاوت های میان گروه ها برای هر متغیر، معنادارست یا خیر. در صورت معنادار نبودن تفاوت (بالا بودن مقدار P)، متغیر مورد نظر فاقد اطلاعات مفید در نظر گرفته می شد. جدول ۱ میانگین ها، انحراف های معیار، مقادیر F و مقادیر P برای هر متغیر را نشان می دهد.

جدول ۱: مقادیر P و آمار متغیرهای ورودی

متغیرها	میانگین FFS	انحراف معیار FFS	میانگین فاقد FFS	انحراف معیار فاقد FFS	F	مقدار P
DEBTEQ	2.706	3.531	1.075	0.937	7.56	0.007
SALTA	0.699	0.416	1.055	0.577	9.53	0.003
NPSAL	-0.459	2.434	0.067	0.159	1.77	0.188
RECSAL	1.755	5.897	0.456	0.349	1.84	0.179
NFATA	0.320	0.193	0.276	0.140	1.31	0.257
RETREND	1.273	0.491	1.733	3.028	0.86	0.358
RECI1	0.605	0.495	0.711	0.460	0.92	0.340
GMTREND	2.564	9.014	18.715	108.484	0.84	0.363
GMI1	0.395	0.495	0.579	0.500	2.60	0.111
SALGRTH	1.163	0.705	115.016	255.444	1.00	0.320
INVSAL	0.359	0.656	0.179	0.159	2.70	0.105
INVTA	0.191	0.160	0.178	0.142	0.13	0.722
CASHTA	0.071	0.122	0.096	0.114	0.86	0.356
LTA	8.451	0.996	8.473	1.288	0.01	0.933
LOGDEBT	7.870	1.233	7.512	1.411	1.39	0.243
COSAL	3196.600	3066.188	5889.742	7734.285	3.98	0.050
EBIT	-33.624	1392.930	1093.253	2875.929	4.73	0.033
WCAP	369.171	2166.685	2280.737	4279.685	6.03	0.016
ZSCORE	0.778	0.936	1.990	0.730	39.59	0.000
NIFA	-0.531	1.996	-1.554	11.635	0.29	0.595
TDTA	0.629	0.243	0.437	0.196	14.31	0.000
NPTA	-0.021	0.095	0.074	0.065	26.11	0.000
CACL	2.113	6.095	2.302	2.267	0.03	0.859
WCTA	0.054	0.239	0.253	0.205	15.15	0.000
QACL	1.163	2.245	1.772	1.804	1.70	0.196
GPTA	0.144	0.121	0.274	0.140	18.78	0.000
LTDTA	0.065	0.138	0.041	0.077	0.87	0.353

نوشته های ایتالیک نشان دهنده متغیرهای منتخب هستند.

چنان که می توان در جدول ۱ مشاهده کرد، ۱۰ متغیر مقدار P پایین را نشان می دهند ( $p < 0.05$ ). این متغیرها برای جایگذاری در بردار ورودی انتخاب و متغیرهای باقی مانده کنار گذاشته شدند. متغیرهای منتخب عبارت بودند

از: WCTA, NPTA, TDTA, ZSCORE, WCAP, EBIT, COSAL, SALTA, DEBTEQ و  
.GPTA

### روش ها

۳,۳

شناسایی صورت های مالی متقلبانه را می توان یک مسئله طبقه بندی معمول در نظر گرفت و طبقه بندی هم یک فرایند دو مرحله ای است. در گام اول یک مدل با استفاده از نمونه ای آموزشی پرورانده می شود. این نمونه آماری به صورت گروه های چندعضوی (ردیف ها) و خصوصیات (ستون ها) سازماندهی می شوند. یکی از خصوصیات، یعنی مشخصه برچسب دسته، حاوی مقادیری است که دسته از پیش تعیین شده ای را که هر گروه به آن تعلق دارد، نشان می دهند. این مرحله را آموزش تحت نظارت نیز می نامند. در گام دوم، مدل تلاش می کند مواردی را که به نمونه آماری آموزشی تعلق ندارند و نمونه اعتبارسنجی را تشکیل می دهند، دسته بندی کند.

داده کاوی چندین روش طبقه بندی برگرفته از حوزه های آمار و هوش مصنوعی را ارائه می کند. سه روش که به لحاظ قدرت طبقه بندی از اعتبار بالایی برخوردارند، در این مطالعه مورد استفاده قرار گرفتند. این روش ها عبارتند از درخت های تصمیم گیری، شبکه های عصبی و شبکه های بیزین.

### درخت تصمیم گیری

۳,۳,۱

درخت تصمیم گیری (DT) ساختاری درختی شکل است که در آن هر یک از گره ها نشان دهنده یک آزمون روی یکی از خصوصیات بوده و هر شاخه نیز یکی از نتایج هر آزمون را نشان می دهد. بدین ترتیب، درخت تصمیم تلاش می کند مشاهدات را به زیرگروه های متقابل منحصر به فرد تقسیم کند. خوبی یک تفکیک بسته به انتخاب براساس خصوصیتی است که نمونه آماری را به بهترین شکل جدا می کند. نمونه به طور پی در پی به زیرمجموعه های مختلف تقسیم می شود، تا جایی که هیچ تقسیم دیگری نتواند تفاوت های معنادار آماری ایجاد کند و یا زیرمجموعه ها آنقدر کوچک باشند که نتوانند مجدداً به طور معنادار تقسیم شوند. چندین الگوریتم جداکننده ارائه شده اند. در کشف خودکار تعامل (AID)، معنادارترین آماره  $T$  در هر تحلیل واریانس، مورد استفاده قرار می

گیرد. روش کایاسکوئر AID از کایاسکوئر استفاده کرده و درخت های رگرسیون و طبقه بندی (CART) از یک شاخص پراکندگی بهره می برند (کو و لو، ۲۰۰۴). ما در این مطالعه از الگوریتم مشهور ID3 استفاده کردیم. الگوریتم ID3 برای انتخاب خصوصیت تفکیک کننده، از مقیاسی مبتنی بر گشتاور بهره می برد که به حصول اطلاعات مشهورست (هن و کمبر، ۲۰۰۰).

تقسیم پیاپی نمونه ممکنست درختی بزرگ تولید کند. ممکنست برخی از شاخه های این درخت درهم ریختگی هایی (مانند مقادیر خلاف واقع یا واخوردها) را در مجموعه آموزشی نشان دهند. به همین دلیل نیاز به هرس کردن درخت داریم. هرس کردن درخت به معنای حذف گره های تقسیم کننده به شکلی است که لطمه چشمگیری به میزان دقت مدل وارد نشود.

برای طبقه بندی موردی که پیش تر آن را ندیده ایم، مقادیر خصوصیات آن مورد را براساس گره های تفکیک کننده درخت تصمیم، می آزماییم. براساس این آزمون، مسیری را دنبال می کنیم که به پیش بینی دسته مربوط به آن مورد منجر شود. مزیت اصلی درخت های تصمیم گیری اینست که آن ها راهی معنادار برای نمایش دانش کسب شده فراهم آورده و درصورت لزوم، استخراج قوانین طبقه بندی را به کاری ساده بدل می کند.

### شبکه عصبی

۳،۳،۲

شبکه عصبی (NN) یک فناوری کامل با نظریه ای تثبیت شده و حوزه های کاربرد معلوم است. یک NN شامل تعدادی نورون، یعنی واحدهای پردازشی به هم پیوسته، است. مقداری عددی به نام «وزن» برای هر یک از اتصال ها وجود دارد. هر نورون سیگنال هایی را از نورون های متصل به خود دریافت کرده و سیگنال ورودی ترکیبی محاسبه می شود. مجموع سیگنال ورودی برای نورون  $i$  برابرست با  $u_i = \sum w_{ji} x_j$  که در آن  $x_j$  سیگنال ورودی از نورون  $j$  بوده و  $w_{ji}$  وزن اتصال بین نورون های  $j$  و  $i$  است. اگر قدرت سیگنال ورودی ترکیبی از مقداری آستانه ای فراتر رود، نتیجتاً مقدار ورودی توسط تابع انتقالی نورون تغییر یافته و نهایتاً هم نورون شروع به کار می کند (هن و کمبر، ۲۰۰۰).

نورون ها به صورت لایه لایه قرار می گیرند. یک شبکه لایه ای حداقل از یک لایه ورودی (ابتدایی) و یک لایه خروجی (انتهاایی) تشکیل شده است. در بین این لایه های ورودی و خروجی، ممکنست یک یا چند لایه مخفی وجود داشته باشد. انواع مختلف  $NN$ ، تعداد لایه های متفاوتی دارند. شبکه های عصبی از نوع «نقشه خود سازماندهی» ( $SOM$ ) دارای یک لایه ورودی و یک لایه خروجی هستند درحالی که یک شبکه عصبی «انتشار معکوس»، یک یا چند لایه مخفی اضافی هم دارد.

پس از تعریف معماری شبکه، باید شبکه را پروراند. در شبکه های انتشار معکوس، الگویی بر لایه ورودی اعمال شده و برون دادی نهایی هم در لایه خروجی محاسبه می گردد. برون داد حاصله با نتیجه مطلوب مقایسه شده و خطاها با انطباق وزن اتصالات به طور معکوس در  $NN$  منتشر می شوند. این فرایند آنقدر تکرار می شود تا نرخ خطای قابل قبولی به دست آید.

dataacademy.ir

شبکه های عصبی هیچ نظری درمورد استقلال خصوصیات نداده، قابلیت کنترل داده های شلوغ یا ناپایدار را داشته و برای حل مسائلی که در آن ها استفاده از هیچ راه حل الگوریتمی ممکن نیست، جایگزینی مناسبند. از آنجایی که  $NN$  های انتشار معکوس به محبوب ترین شبکه های عصبی برای پیش بینی و طبقه بندی مسائل تبدیل شده اند (سول و ونکتچلم، ۱۹۹۵)، ما هم تصمیم گرفتیم در مطالعه حاضر یک شبکه عصبی انتشار معکوس تولید کنیم.

### شبکه بیزین

۳,۳,۳

طبقه بندی بیزین بر مبنای قضیه آماری بیز است. قضیه بیز راه حلی برای محاسبه احتمال پسین فراهم می کند. براساس قضیه بیز، اگر  $H$  فرضیه ای باشد (مانند این که مورد  $X$  متعلقست به دسته  $C$ )، احتمال درستی فرضیه برابرست با:  $P(H|X) = (P(X|H) * P(H))/P(X)$ .

اگر مورد  $X$  متعلق به یکی از دسته های جایگزین باشد، طبقه بندی کننده بیزین به منظور دسته بندی مورد مذکور، احتمالات  $P(C_i|X)$  را برای تمامی دسته های محتمل  $C_i$  محاسبه کرده و مورد  $X$  را به گروهی که بیشترین احتمال  $P(C_i|X)$  را دارد انتقال می دهد.

افراد بی تجربه در طبقه بندی بیزین، فرض استقلال شرایط دسته را مطرح می کنند که براساس این فرض، تأثیر مقدار یک خصوصیت بر دسته ای خاص مستقل از مقادیر دیگر خصوصیات است. این فرض محاسبه  $P(C_j|X)$  را ساده می کند. در صورت درست بودن این فرض، افراد بی تجربه در طبقه بندی بیزین بیشترین میزان دقت را نسبت به دیگر افراد طبقه بندی کننده خواهند داشت. با این حال، در بسیاری از موارد چنین فرضی درست نیست؛ چراکه وابستگی هایی نیز میان خصوصیات وجود دارد.

شبکه های بیزین (BBN) امکان نمایش وابستگی های میان زیرمجموعه های خصوصیات را فراهم می آورند. یک BBN نموداری غیرمدور هدایت شده است که در آن هر گره نشان دهنده یک خصوصیت است و هر پیکان نشان دهنده یک وابستگی احتمالی. اگر پیکانی از گره  $A$  به گره  $B$  کشیده شود،  $A$  والد  $B$  بوده و  $B$  هم فرزند  $A$  است. در چنین گره ای هر یک از متغیرها به طور شرطی و با توجه به والدینش، مستقل از غیر فرزندان است (هن و کمبر، ۲۰۰۰).

برای هر گره  $X$  جدول احتمالاتی وجود دارد که احتمال شرطی هر مقدار  $X$  را به ازای هر یک از ترکیبات احتمالی مقادیر والدین آن مشخص می کند (توزیع شرطی  $P(X|Parents(X))$  احتمال یک گروه چندعضوی  $(x_1, x_2, \dots, x_n)$  دارای تعداد  $N$  خصوصیت، برابرست با:

$$P(x_1, x_2, \dots, x_n) = \prod P(x_i | Parents(x_i))$$

ساختار شبکه را می توان از قبل تعریف کرد و یا از روی داده ها استنباط نمود. برای طبقه بندی، می توان یکی از گره ها را به عنوان گره یک دسته تعیین کرد. شبکه می تواند احتمال هر یک از دسته های جایگزین را محاسبه کند.

#### ۴. آزمایشات و تحلیل نتایج

سه مدل مختلف، هر یک براساس روشی جداگانه، ساخته شدند. ابتدا مدل درخت تصمیم گیری با استفاده از نسخه تحقیقاتی نرم افزار Sipina و با سطح اطمینان ۰,۰۵ ساخته شد. از کل نمونه به عنوان مجموعه آموزشی استفاده کردیم. شکل ۱ درخت تصمیم گیری ساخته شده را نشان می دهد.

مدل براساس نمونه آموزشی مورد آزمون قرار گرفته و توانست ۷۳ مورد را به درستی طبقه بندی کند (عملکرد کلی ۹۶ درصد). به طور خاص تر، درخت تصمیم گیری تمامی موارد غیر متقلبانه (۱۰۰ درصد) و ۳۵ مورد از میان ۳۸ صورت متقلبانه (۹۲ درصد) را به درستی طبقه بندی کرد.

dataacademy.ir

چنان که در شکل ۱ می توان دید، الگوریتم از نمره Z ب عنوان اولین تفکیک کننده استفاده می نماید. از میان ۳۸ شرکت متقلب، ۳۵ مورد آن ها مقدار نمره Z بسیار پایینی را نشان می دهند (نمره Z کمتر از ۱,۴۹). از آنجایی که آلتمن نمره Z برابر ۱,۸۱ را به عنوان حد تعریف درماندگی مالی برای شرکت های تولیدی ایالات متحده در نظر گرفت (آلتمن، ۲۰۰۱)، می توانیم نتیجه بگیریم شرکت های دچار درماندگی مالی موجود در نمونه آماری ما، به دستکاری صورت های مالی خود تمایل دارند.

دو متغیر مربوط به سوددهی (EBIT و NPTA) به عنوان تفکیک کننده های سطح دوم مورد استفاده قرار گرفتند. هیچ یک از شرکت های متقلب دارای نمره Z بالا، سوددهی بالایی را نشان نمی داد. جدول ۲ متغیرهای جداکننده را به ترتیب قرار گرفتن در درخت تصمیم گیری به نمایش می گذارد.



## جدول ۲: متغیرهای تفکیک کننده

متغیرها  
Z-SCORE  
NPTA  
EBIT  
COSAL  
DEBTEQ

در دومین آزمایش، مدل شبکه عصبی را ساختیم. به عنوان نرم افزار طبقه بندی از شبکه های غیرخطی Nuclass 7 استفاده کردیم تا شبکه مفهومی تغذیه رو به جلو را بسازیم. پس از آزمون تعدادی از طرح های جایگزین و انجام آموزش های پیش نیاز، وضعیتی شامل یک لایه مخفی حاوی ۵ گره مخفی را برگزیدیم.



شکل ۱: درخت تصمیم گیری

شبکه انتخاب شده به وسیله کل نمونه پرورانه شده و براساس مجموعه آموزشی مورد آزمون قرار گرفت. شبکه به طور پیاپی به کار خود ادامه داده و با طبقه بندی درست تمامی موارد به عملکرد ۱۰۰ درصدی دست یافت. متأسفانه نرم افزار رابط واضحی به سمت اوزان پیوندگامی اتصالات در اختیار نگذاشت و در نتیجه برآورد میزان اهمیت هر یک از متغیرهای ورودی میسر نشد.

در آزمایش سوم، یک شبکه بیزین (BBN) ساختیم. برای این کار از نرم افزار theBN Power Predictor استفاده کردیم. این نرم افزار توانایی فراگیری یک طبقه بندی کننده از روی داده ها را دارد. الگوریتم به کار رفته به دسته الگوریتم های مبتنی بر آزمون استقلال شرطی تعلق داشته و نیاز به مرتب کردن گره ها ندارد (چنگ و گراینر، ۲۰۰۱). به دلیل محدودیت های نرم افزار، مجبور بودیم مقادیر را از هم تفکیک نماییم. پس از آزمون روش های تفکیک مختلف (عمق یکسان، عرض یکسان)، سرانجام روش تفکیک تحت نظارت را برگزیدیم. روش تفکیک تحت نظارت مبتنی بر گشتاور، برخلاف دیگر روش های تفکیک، از اطلاعات مربوط به دسته ها بهره می گیرد. این امر احتمال کمک فواصل تعیین شده به بالا رفتن دقت طبقه بندی، را افزایش می دهد (هن و کمبر، ۲۰۰۰).

به منظور پروراندن شبکه بیزین، از کل نمونه به عنوان مجموعه آموزشی استفاده کردیم. پس از اتمام آموزش، شبکه براساس مجموعه آموزشی مورد آزمایش قرار گرفت. شبکه توانست ۷۲ مورد (عملکرد ۹۵ درصد) را به درستی طبقه بندی کند. به طور خاص، این شبکه قادر بود ۳۷ مورد دارای تقلب (۹۷ درصد) و ۳۵ مورد فاقد تقلب (۹۲ درصد) را به درستی طبقه بندی نماید. شکل ۲ شبکه بیزین ساخته شده را نمایش می دهد.

dataacademy.ir

چنان که می توان در شکل ۲ مشاهده کرد، به نظر می رسد شبکه بیزین جنبه عمومی تری را در مورد انگیزه های دستکاری صورت های مالی نشان دهد. براساس این شبکه، تقلب وابستگی های زیادی را نسبت به متغیرهای ورودی نمره Z، DEBTEQ، NPTA، SALTA و WCTA، نشان می دهد. هریک از این متغیرها بیانگر جنبه متفاوتی از وضعیت مالی شرکت است. نمره Z به درماندگی مالی اشاره دارد، DEBTEQ به نسبت بدهی به دارایی، NPTA به سوددهی، SALTA به عملکرد فروش و WCTA به توانایی پرداخت بدهی.

بنابراین، به نظر می رسد شبکه بیزین وابستگی های میان دستکاری در صورت های مالی و تعداد قابل توجهی از جنبه های مالی شرکت را ثبت کند. جدول ۳ متغیرهای انتخاب شده برای قرار گرفتن در شبکه بیزین را نشان می دهد.

### جدول ۳: متغیرهای انتخاب شده

متغیرها  
Z-SCORE  
NPTA  
DEBTEQ  
SALTA  
WCTA

### جدول ۴: عملکرد در مقابل مجموعه آزمایشی

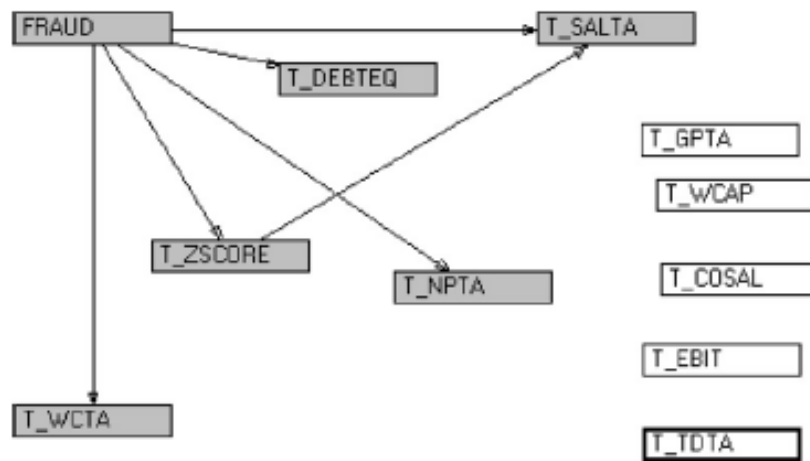
مدل	درصد تقلب	درصد بدون تقلب	درصد مجموع
ID3	92.1	100.0	96.2
NN	100.0	100.0	100.0
BBN	97.4	92.1	94.7

جدول ۴ عملکرد هر سه مدل بر روی نمونه آموزشی را نشان می دهد. نتایج حاکی از اینست که مدل NN کارایی بسیار بالایی در ایجاد تمایز میان شرکت های دارای تقلب و فاقد تقلب دارد و پس از آن هم به ترتیب مدل های

BBN و ID3 قرار می گیرند. [dataacademy.ir](http://dataacademy.ir)

#### ۴.۱ سنجش اعتبار مدل ها

استفاده از مجموعه آموزشی به منظور برآورد عملکرد مدل، ممکنست باعث جهتگیری در قضاوت شود. در بسیاری از موارد، مدل ها به جای «یادگیری»، تمایل دارند نمونه را به حافظه بسپارند (بیش برآزش داده ها). برای پرهیز از چنین جهتگیری هایی، عملکرد مدل ها براساس الگوهای از پیش دیده نشده برآورد می شود. رویکردهای متعددی، مانند تقسیم نمونه به دو بخش نمونه آموزشی و نمونه دست نخورده جداگانه، اعتبارسنجی مقطعی ۱۰ لایه و اعتبارسنجی بیرون گذاشتن یک مورد، برای اعتبارسنجی مدل ها وجود دارد. اگرچه هر سه بسته نرم افزاری مورد استفاده ما قابلیت اعتبارسنجی را داشتند، ممکن نبود برای هر سه آن ها از یک روند اعتبارسنجی مشترک از لحاظ روش و داده ها، استفاده کنیم. در نتیجه، مجبور بودیم نمونه را به صورت دستی تقسیم کرده و زیرمجموعه های آموزشی و اعتبارسنجی را تشکیل دهیم.



شکل ۲: متغیرهای انتخاب شده شبکه بیزین

جدول ۵: عملکرد اعتبارسنجی مقطعی ۱۰ لایه

مدل	درصد تقلب	درصد بدون تقلب	درصد مجموع
ID3	75.0	72.5	73.6
NN	82.5	77.5	80.0
BBN	91.7	88.9	90.3

dataacademy.ir

تصمیم گرفتیم از یک رویکرد اعتبارسنجی مقطعی ۱۰ لایه استفاده کنیم. در این روش اعتبارسنجی، نمونه آماری به ۱۰ بخش تقسیم می شود. در یک رویکرد لایه لایه، هر بخش موارد متقلبان و غیر متقلبان مساوی دارد. برای هر لایه، مدل به وسیله ۹ لایه دیگر پروارنده شده، با استفاده از لایه دست نخورده مورد آزمایش قرار گرفته و در نهایت هم عملکرد متوسط محاسبه می شود. جدول ۵ خلاصه عملکرد هر سه مدل در اعتبارسنجی مقطعی ۱۰ لایه را نشان می دهد.

مطابق انتظار، میزان دقت برای مجموعه اعتبارسنجی کمتر از مجموعه آموزشی است. با این حال، هر یک از سه مدل عملکرد بسیار متفاوتی دارند. مدل درخت تصمیم که قادرست ۹۶ درصد از مجموعه آموزشی را به درستی طبقه بندی کند، هنگام آزموده شدن با مجموعه اعتبارسنجی، کاهش قابل توجهی را در دقت طبقه بندی خود نشان می دهد. اینبار مدل ۷۳,۶ درصد از کل نمونه، ۷۵ درصد موارد متقلبان و ۷۲,۵ درصد موارد فاقد تقلب را به درستی

طبقه بندی می کند. مدل شبکه عصبی که در طبقه بندی نمونه آموزشی از دقت مطلق ۱۰۰ درصدی برخوردارست، تنها می تواند ۸۰ درصد از کل نمونه اعتبارسنجی، ۸۲,۵ درصد موارد متقلبانه و ۷۷,۵ درصد موارد فاقد تقلب این نمونه را به درستی دسته بندی نماید. نهایتاً، مدل شبکه بیزین که پایین ترین میزان دقت را برای مجموعه آموزشی در اختیار دارد، موفق می شود ۹۱,۷ درصد موارد متقلبانه، ۸۸,۹ درصد موارد فاقد تقلب و ۹۰,۳ درصد کل مجموعه اعتبارسنجی را به طور صحیح طبقه بندی کند.

در ارزیابی مقایسه ای عملکرد این سه مدل، می توانیم نتیجه بگیریم که مدل شبکه بیزین از دو مدل دیگر پیشی گرفته و دقت طبقه بندی فوق العاده ای را از خود به نمایش می گذارد. شبکه عصبی عملکرد رضایت بخشی داشته و نهایتاً سطح عملکرد درخت تصمیم هم نسبتاً پایین است.

نکته قابل توجه دیگری در هنگام سنجش عملکرد یک مدل، نرخ های خطای نوع اول و نوع دوم است. خطای نوع اول زمانی رخ می دهد که یک شرکت متقلب به عنوان شرکتی فاقد تقلب طبقه بندی شود و خطای نوع دوم هنگامی به وقوع می پیوندد که شرکتی فاقد تقلب در زمره شرکت های متقلب قرار گیرد. هر یک از این دو نوع خطا، هزینه های متفاوتی در پی خواهد داشت. طبقه بندی یک شرکت متقلب به عنوان شرکتی فاقد تقلب می تواند به اتخاذ تصمیماتی اشتباه منجر شود که ممکنست خسارت مالی شدیدی را به دنبال داشته باشند. طبقه بندی اشتباه یک شرکت فاقد تقلب ممکنست با هدر دادن زمان مورد نیاز، به بررسی های بیشتر احتیاج پیدا کند. اگرچه هدف همه مدل ها کاهش هر دو نوع این خطاهاست اما مدلی ارجحیت دارد که در آن میزان خطای نوع اول کمتر از نوع دوم باشد. در آزمایشات ما، نرخ خطای نوع اول در تمامی مدل ها پایین ترست. بیشترین میزان تفاوت بین مقادیر خطای نوع اول و دوم در شبکه عصبی دیده می شود.

## ۵. نتیجه گیری

امروزه می بایست در فعالیت های حسابرسی به موارد تقلب مدیریتی فزاینده ای رسیدگی کرد. تکنیک های داده کاوی که مدعی داشتن توانایی های بالای پیش بینی و طبقه بندی هستند، می توانند حسابرسان را در کشف تقلب

مدیریتی یاری کنند. هدف این مطالعه این بود که کارایی سه روش داده کاوی در کشف صورت های مالی متقلبانه به وسیله داده های انتشار یافته را بررسی و با یکدیگر مقایسه کنند. روش های مورد استفاده عبارت بودند از: درخت تصمیم گیری، شبکه عصبی و شبکه بیزین.

نتایج حاصل از آزمایشات با یافته های تحقیقات پیشین مطابقت داشته و حاکی از اینند که داده های صورت های مالی منتشر شده حاوی شاخصه های تقلب هستند. به علاوه، تعداد نسبتا کمی از نسبت های مالی تأثیر تعیین کننده ای بر نتایج طبقه بندی دارند. همراهی این دانش با الگوریتم های داده کاوی می تواند به ساخت مدل هایی کمک کند که از قدرت طبقه بندی بسیار بالایی برخوردار باشند.

مطالعه حاضر می تواند با بررسی متغیرهای پیشنهادی به منظور شناسایی آن هایی که موارد FFS را به بهترین شکل متمایز می کنند، به تحقیقات حوزه حسابرسی و حسابداری کمک نماید. این تحقیق همچنین متغیرهای خاصی از میان اطلاعات انتشار یافته را پیشنهاد می دهد که حسابرسان می بایست در زمان ممیزی وقت بیشتری را صرفشان کنند. چارچوب روش شناختی ما می تواند به حسابرسان (هم حسابرسان داخلی و هم بیرونی)، مقامات مالیاتی و دیگر مقامات دولتی، افراد و سازمان های سرمایه گذار، بورس اوراق بهادار، شرکت های حقوقی، تحلیلگران اقتصادی، آژانس های ارزیابی اعتبار و نیز به سیستم بانکی، کمک کند. نتایج این تحقیق می تواند حرفه حسابرسی را در توجه به مسئولیتش که همان کشف FFS است، یاری نماید.

از نظر عملکرد، شبکه بیزین بهترین عملکرد را داشته و موفق شد در یک فرایند اعتبارسنجی مقطعی ۱۰ لایه، ۹۰,۳ درصد نمونه اعتبارسنجی را به درستی طبقه بندی کند. میزان دقت مدل های شبکه عصبی و درخت تصمیم گیری به ترتیب برابر ۸۰ و ۷۳,۶ درصد بود. تمامی مدل ها خطای نوع اول کمتری داشتند.

شبکه بیزین وابستگی هایی را میان دستکاری اطلاعات و نسبت های بدهی به دارایی خالص، سود خالص به مجموع دارایی، میزان فروش به مجموع دارایی، سرمایه در گردش به مجموع دارایی و نمره Z نشان می داد. هریک از این

نسبت ها به جنبه خاصی از وضعیت مالی شرکت (یعنی نسبت بدهی به دارایی، سوددهی، عملکرد فروش، توان پرداخت بدهی و درماندگی مالی) اشاره دارند. درخت تصمیم گیری اساساً دستکاری در اطلاعات را با درماندگی مالی مرتبط می دانست؛ چراکه از نمره  $Z$  به عنوان اولین تفکیک کننده استفاده می کرد.

طبق معمول، این مطالعه می تواند باعث پیشرفت تحقیقات دیگر شود. تفاوتی مهم در میان آزمایشات ما اینست که مدل BBN به دلیل محدودیت های نرم افزاری، از داده های تفکیک شده بهره می گرفت. تفکیک داده ها به بهای از دست رفتن برخی اطلاعات، تأثیر واخوردن ها را از بین می برد. تحقیقات دیگر باید به موضوع تأثیر تفکیک داده ها بر عملکرد مدل ها و همچنین موضوع بهترین الگوریتم های تفکیک توجه نمایند. همچنین لازمست تحقیقات آینده به بررسی شرایطی پردازند که تحت آن ها تکنیک های داده کاوی بهتر از دیگر روش ها عمل می کنند.

بردار ورودی ما تنها از نسبت های مالی تشکیل شده است. افزودن اطلاعات کیفی (مانند بررسی های حسابرسان قبلی یا ترکیب هیأت اجرایی) به بردار ورودی، می تواند میزان دقت را افزایش دهد. به علاوه، انجام مطالعه ای ویژه روی این صنعت، می تواند شاخصه های خاصی را آشکار نماید. امیدواریم تحقیق ارائه شده در این مقاله محققان را به انجام کارهای پژوهشی دیگر در مورد این موضوعات مهم، ترغیب کند.