



فصلنامه علمی پژوهشی
دانش حسابداری و حسابرسی مدیریت
سال اول / شماره سوم / پائیز ۱۳۹۱

داده‌کاوی و کشف تقلب‌های مالی

فریدون رهنمای روپشتی

استاد دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران
rahnama@iau.ir

تاریخ دریافت: ۹۱/۲/۲۰ تاریخ پذیرش: ۹۱/۶/۳۰

چکیده

تقلب از پدیده‌های رایج و متداول در کسب و کار است و طبق بخش ۲۴ استانداردهای حسابرسی ایران عمل فریبکارانه یک یا چند نفر از مدیران، کارکنان یا اشخاص ثالث برای برخورداری از مزیتی ناروا عبارتست از هرگونه اقدام عمدی یا غیرقانونی. بنابراین پیشگیری با کشف تقلب‌های با اهمیت در صورتهای مالی، همواره کانون توجه سرمایه‌گذاران، قانونگذاران، استاندارد گذاران، مدیران و حسابرسان بوده است.

مقاله حاضر، اثربخشی تکنیک‌های داده‌کاوی در تشخیص رفتارهای متقلبانه شرکت‌هایی که صورت‌های مالی متقلبانه گزارش نموده‌اند را بررسی کرده تا عوامل مؤثر بر اینگونه رفتارها را شناسایی کرده. داده‌کاوی پل ارتباطی میان علم آمار، علم کامپیوتر، هوش مصنوعی، الگوشناسی، فرآگیری ماشین و بارنمایی بصری داده‌ها می‌باشد که در چارچوب فرایندی، استخراج اطلاعات معتبر، از پیش ناشناخته، قابل فهم و قابل اعتماد از پایگاه داده‌های بزرگ امکان‌پذیر می‌گردد و استفاده از آن در تصمیم‌گیری در فعالیت‌های تجاری مهم نظیر ارتقاء کیفیت سودمندی اطلاعات از طریق شناسایی تقلب‌های مالی میسر می‌شود.

این پژوهش به روش شناخت تاریخی با بهره گیری از اسناد کتابخانه‌ایی و به پشتونه پیشینه و تحقیقات محققان، شواهدی لازم جهت پاسخ به سوالات تحقیق ارائه می‌کند. نتایج مطالعه نشان می‌دهد که اولاً، تکنیک‌های داده کاوی، در شناسایی در صورتهای مالی متقلبانه سودمند هستند. ثانیاً، داده کاوی، به عنوان کانون هدایت فکر در مدیریت کسب و کارها جهت کشف تقلب می‌تواند مورد توجه قرار گیرد.

واژه‌های کلیدی: داده‌کاوی، تقلب مالی، صورت‌های مالی متقلبانه.

در جایی که هیچ تصور قبلی در مورد چیزی که کسب خواهیم کرد تشکل نیافته باشد (کانتارزیک، ۲۰۰۲). بکارگیری تکنیک‌های داده کاوی برای طبقه‌بندی‌های مالی یکی از حوزه‌های پرثمر تحقیقاتی است، بسیاری از قوانین التزامی و واحدهای تحقیقاتی ویژه، افاده را مامور شناخت فعالیت‌های متقلبانه در اختیار دارند که با موفقیت داده کاوی را بکار می‌برند. هرچند در مقابل سایر زمینه‌های آزموده شده مثل پیش‌بینی ورشکستگی و پریشانی مالی، تحقیقات کاربرد تکنیک‌های DM به منظور کشف تقلبات مدیریتی در حداقل قرار دارد (کالدرون و چه ۲۰۰۲ با کوسکیوارا و مانولوپوس، ۲۰۰۴).

در این مطالعه ما به دنبال آزمون عمیق اطلاعات عمومی مندرج در صورتهای مالی هستیم که در آنها صورتهای مالی متقلبانه^۲ کشف شده به وسیله روش‌های داده کاوی، متغیر می‌باشد. هدف این تحقیق شناختن عواملی است که مورد استفاده حسابرسان برای ارزیابی احتمالی FFS قرار گیرد. اولین هدف اصلی عبارت است از کاربرد و سنجش بکارگیری روش‌های داده کاوی در حالات متفاوت بین مشاهدات تقلب و بدون تقلب است.

پژوهش‌های پشتیبان برای این تحقیق متشکل از تحقیقات مرتبط برای کشف تقلبات مدیریتی با استفاده از آمار و هوش مصنوعی (AI)^۳ و تکنیک‌های داده کاوی است که همگی داده‌های عادی و در دسترس صورتهای مالی را بکار گرفته‌اند. روش‌های AI این مزیت تئوریکالی را دارند که نمی‌تواند مفروضات اختیاری را در ورودی‌های متغیر به آنها تحمیل نمود. هرچند نتایج روش‌های AI گزارش شده اندکی یا گهگاهی در شکل کلی اجرا همان نتایج روش‌های آماری است.

در این مطالعه نتایج پژوهش آزمون سه تکنیک داده کاوی برای کاربرد در کشف تقلبات مدیریتی مبتنی بر یافته‌های یک تحقیق کاربردی که در یونان آزموده شده است استفاده گردید. نظری درخت تصمیم‌گیری، شبکه عصبی، شبکه گمانه زنی بیزی. سه روش در حالاتی که پیش‌بینی صحیحی دارند مقایسه می‌شوند. داده‌های ورودی اکثرًا از نسبت‌های مالی مشتق شده از صورتهای مالی به عنوان نمونه ترازنامه و صورت سود و زیان تشکیل شده است. نمونه متشکل از ۷۶ شرکت تولیدی یونانی است. ارتباط بین متغیرهای ورودی و طبقه‌بندی خروجی‌ها به وسیله مدل‌های کسب و آشکار می‌شود.

۱- مقدمه

امروز حسابرسان با مسؤولیتی که به‌طور فزاینده‌ای سخت‌تر می‌شود درگیر هستند و شواهد زیادی از حساب سازی در بکارگیری حسابداری وجود دارد و به صورت گستره‌ای از آن استفاده می‌شود. که این امر، به عنوان پدیده‌ای رایج و مخرب، کارایی، نقدینگی و امنیت بازارهای مالی جهانی، بازارهای سرمایه و بدھی به دلیل وجود تقلب در صورتهای مالی که عامل اساسی در بحران مالی اخیر و رکود اقتصادی جهانی می‌باشد، تهدید می‌شوند. مبتنی بر پژوهش Kirkos, Spathis and Manolopoulos (2007) کوسیوارا سال ۲۰۰۲ را از نقطه نظر دفتر داری و ادعاهای که دارای دستکاری‌هایی هست که همچنان ادامه دارد، سال ناگوار نامید (کوسیوارا ۲۰۰۴). بعضی گزارشات هزینه تقلب کسب و کارهای ایالات متحده آمریکا را بیش از ۴۰۰ بیلیون دلار در سال برآورد کرده است (ولز ۱۹۹۷). سپاهیز، دویومپوس و زوپویونیوس (۲۰۰۲) اعتقاد دارند که صورتهای مالی متقلبانه به صورت فزاینده‌ای به‌طور مکرر در طی سالیان اخیر در حال ازدیاد می‌باشد. مدیران متقلب را چنین می‌توان تعریف کرد: مشارکت در تقلب عمدى به وسیله مدیران که منجر به آسیب به سرمایه‌گذاران و اعتباردهندگان، به خاطر استفاده از صورتهای مالی به شدت گمراه کننده است. در طی فرایند حسابرسی، حسابرسان باید امکان تقلب مدیران را برآورد کنند. AICPA به صراحت تصدیق کرده که حسابرسان در برابر تقلب‌های کشف شده پاسخگو هستند (کولینا و سوتو، ۲۰۰۲). از این گذشته برای توجه به انتظارات از ایشان حسابرسان تکنیک‌های تحلیلی را برای مروء کارشان به خدمت می‌گیرند، چیزی که به آنها اجازه می‌دهد مانده حسابهای را بدون آزمون مرتبط با تراکنش منحصر به فرد آن برآورد سازند. فراسر، هاردلی و لین (۱۹۹۷) تکنیک‌های تحلیلی احتمالی اجمالی را به صورت غیرکمی، نمونه کمی و پیشرفت‌های کمی طبقه‌بندی نمودند. تکنیک‌های پیشرفت‌های کمی در بردارنده روش‌های پیچیده بکارگیری آمار و هوش مصنوعی مانند شبکه عصبی و تحلیل رگرسیون بود.

داده کاوی (DM)^۱ یک فرآیند تکراری است که در آن، فرآیند به وسیله پوشش آن تعریف می‌شود، همچنین می‌تواند با روش‌های کاملاً خودکار یا دستی انجام شود. DM می‌تواند بیشترین سودمندی را در یک زمینه راهنمای طرح (سناریوی) تحلیلی اکتشافی داشته باشد

افشا از صورتهای مالی به عمد و به منظور فریب استفاده‌کنندگان صورتهای مالی، سروکار دارد.

همچنین رهنما رودپشتی و همتی (۱۳۸۹)، برخی از اصطلاحات متداول و بنیادی در حوزه تقلب نظری مثل تقلب، لوزی تقلب، انواع تقلب‌های داخلی و پرچم‌های قرمز آن، ابزارها و تکنیک‌های پایه کشف تقلب از جمله، ابزارهای ارزیابی ریسک تقلب، تکنیک‌های کشف تقلب با استفاده از نرم افزار حسابرسی (ACL) به عنوان تکنیک‌ها و ابزارهای حسابرسی مبتنی بر کامپیوتر^۶ به نقش و جایگاه پیاده سازی حاکمیت شرکتی به عنوان الگوی راهبری پیشرفت‌هی می‌پردازند و معتقدند، هفت وظیفه اساسی و اصلی حاکمیت شرکتی شامل سرپرستی و نظارت، مدیریت، رعایت مقررات، حسابرسی داخلی، حسابرسی مستقل، مشاور می‌باشد که رضایی (۲۰۰۷) عنوان می‌کند، چهار وظیفه از وظایف فوق شامل سرپرستی، مدیریت، حسابرسی داخلی و مستقل برای پیشگیری و کشف مؤثر تقلب در صورتهای مالی، ضروری می‌باشد.

در تبیین مبانی داده کاوی، یاس (۱۳۹۰)، عنوان می‌کند داده کاوی پل ارتباطی میان علم آمار، علم بازنمایی بصری داده می‌باشد و فرآیند استخراج اطلاعات معتبر، از پیش ناشناخته، قابل فهم و قابل اعتماد از پایگاه داده‌های بزرگ و استفاده از آن در تصمیم‌گیری در فعالیت‌های تجاری مهم است. بنابراین، داده کاوی به صورت یک محصول قابل خریداری نمی‌باشد بلکه یک رشته علمی و فرآیندی است که بایستی به صورت یک پژوهه پیاده‌سازی شود. اصولاً هرجایی که داده وجود داشته باشد، داده کاوی نیز معنا می‌یابد. این فرآیند، دارای مزایایی با اهمیت است از جمله:

- (۱) کمک به مدیران در تصمیم‌گیری
- (۲) یافتن مقالات خبری روزآمد
- (۳) کمک به کاربر برای جستجو در وب
- (۴) بهبود امر بازاریابی
- (۵) کشف کلاهبرداریها، تقلب و نابهنجارها.

مقاله حاضر چهار بخش اصلی متمرکز شده است: بخش ۱ تحقیقات پیشین و مبانی نظری را مرور می‌کند. بخش ۲ آگاهی در مورد روش‌شناسی (متمولوژی) و ساختار سوالات مورد استفاده در پژوهش را مهیا می‌کند. همچنین در این بخش، استقرار مدل‌ها و الگوها و روش‌ها نیز ارائه می‌شود. در بخش ۳، تحلیل نتایج یک تحقیق کاربردی در کشور یونان به عنوان مبنای یافته‌ها مدنظر قرار گرفت و در پایان یعنی بخش ۴ نتایج ملاحظه شده به همراه نتیجه‌گیری و مباحث پیرامون آن را راهنمای دهد.

۲- مبانی نظری و پیشینه تحقیقات

۲-۱- مبانی نظری

رنما رودپشتی و همتی (۱۳۸۹) در پژوهشی به تبیین مبانی علمی و تشریح مفاهیم مرتبط با موضوع پرداختند و معتقدند طبق تعریف انجمن بازرگانی رسمی تقلب^۴ (ACFE)، تقلب عبارتست از هر عمل غیرقانونی که همراه با فریب، پنهانکاری و تخطی و نقض اعتماد باشد. این اعمال همراه با تهدید و یا فشار فیزیکی نمی‌باشد. تقلب توسط افراد یا سازمانها برای بدست آوردن پول، دارایی یا خدمات، اجتناب از پرداخت یا زیان خدمات یا ایمن ساختن مزیت تجاری یا شخصی صورت می‌گیرد. طبق تعریف انجمن حسابداران رسمی آمریکا^۵ (AICPA)، تقلب عبارتست از یک مفهوم وسیع غیر قانونی که براساس اینکه آیا عمل انجام شده از روی قصد و عمد بوده باشد یا خیر، از اشتباه متمایز شناخته می‌شود (گلدمان، کافمن، ۲۰۰۹).

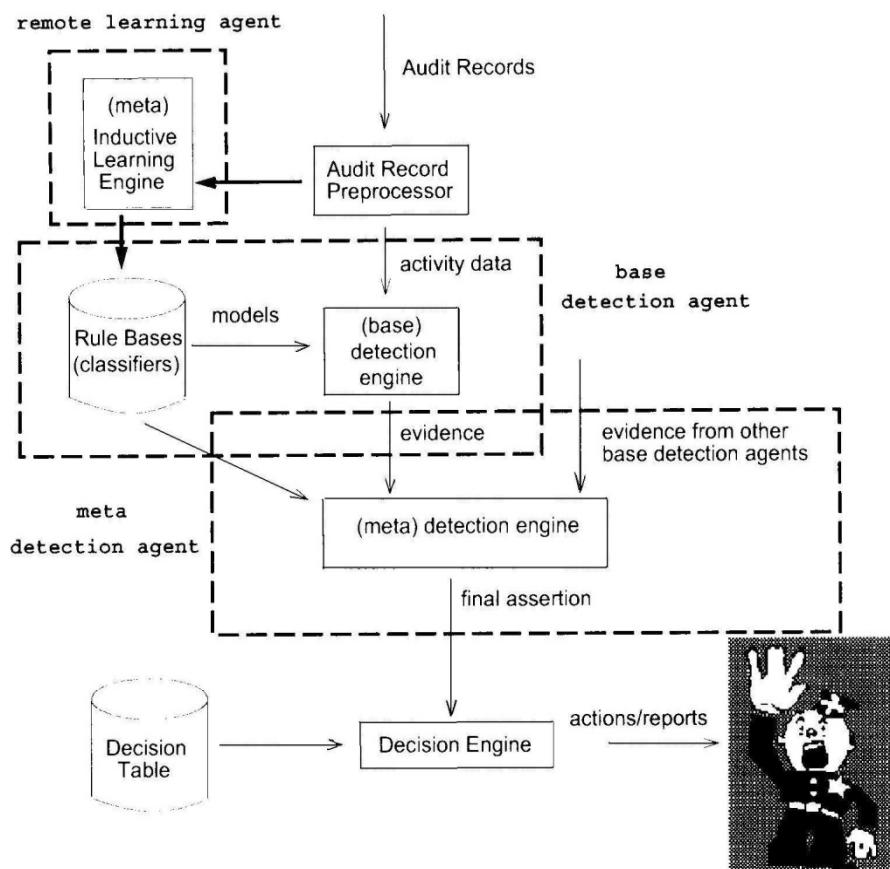
طبق بند ۴ بخش ۲۴ استانداردهای حسابرسی ایران تقلب عبارتست از هر گونه اقدام عمدى یا فریبکارانه یک یا چند نفر از مدیران، کارکنان یا اشخاص ثالث برای برخورداری از یک مزیتی ناروا یا غیرقانونی، تقلب شامل وجود انگیزه برای ارتکاب تقلب و استفاده از فرصت جهت ارتکاب آن است.

تقلب در صورتهای مالی طبق تعریف رضایی و ریلی (۲۰۰۹) بدین شرح است: اظهار غلط عمدی و یا حذف مقادیر یا افشاء لازم در صورتهای مالی به منظور فریب دادن استفاده‌کنندگان صورتهای مالی.

طبق بند ۶ بخش ۲۴ استانداردهای حسابرسی ایران، گزارشگری مالی متقلبانه با تحریف یا حذف مبالغ یا موارد

اساس داده کاوی بر مبنای سه فعالیت اصلی است که عبارتند از:
برای کشف تقلب، با رویکرد توسعه نظام کنترل داخلی نام می برد که به عنوان ماشین یادگیری تلقی گردید و کنترل داخلی به عنوان مکانیسم کشف تقلب معرفی شده است.
اهمیت و توسعه کاربرد داده کاوی در تجارت و اقتصاد و تصمیم‌گیری مدیریت موجب گردید که شرکتهای زیادی در این حوزه به فعالیت بپردازنند و محصولات سخت افزاری و نرم افزارهای متعدد، متنوع و پیشرفته با رویکردها و ساختارهای متفاوتی به بازار عرضه کنند که حاصل پژوهش Abbott, Matkovsky & Elder در سال (۲۰۰۲)، منجر به شناسایی، معرفی و الگوریتم‌های بکار رفته آنها گردید که در جداول شماره ۱ الی ۶ ذیلاً ارائه شده است.

الف- حذف داده‌ها: داده‌های بیارزش و عوامل بیرونی حذف می‌شوند.
ب- فشرده‌سازی داده‌ها: این عمل بوسیله کدگذاری داده‌ها صورت می‌گیرد.
ج- کشف الگوها: الگوهای موجود در پایگاه داده‌ها از قبیل طبقه‌بندی، الگوهای زنجیری و ... کشف می‌شوند.
Lee & Stolf (1998)، چارچوبی تحت عنوان معماری داده کاوی به عنوان نظام پایه‌ایی کشف تقلب ارائه می‌دهد که در شکل شماره (۱) ارائه می‌شود.



شكل ۱

Table 1: Data Mining Products Evaluated

Company	Product	Version
Integral Solutions, Ltd. (ISL) [5]	Clementine	4.0
Thinking Machines (TMC) [6]	Darwin	3.0.1
SAS Institute [7]	Enterprise Miner (EM)	Beta
IBM [8]	Intelligent Miner for Data (IM)	2.0
Unica Technologies Inc. [9]	Pattern Recognition Workbench (PRW)	2.5

Table 2: Software and hardware Supported

Product	Server	Client	Oracle Connect
Clementine	Solaris 2.X	X Windows	Server side ODBC
Darwin	Solaris 2.X	Windows NT	Server side ODBC
Enterprise Miner	Solaris 2.X ¹	Windows NT	SAS Connect>for Oracle
Intelligent Miner	IBM AIX	Windows NT	IBM Data Joiner>
PRW	Data only	Windows NT	Client side ODBC

1 most testing performed on a standalone Windows NT version.

Table 3: Algorithms Implemented

Algorithm	IBM	ISL	SAS	TMC	Unica
Decision Trees	✓	✓	✓	✓	
Neural Networks	✓	✓	✓	✓	✓
Regression	1	✓	✓	✓	✓
Radial Basis Functions	✓ ²		✓		✓
Nearest Neighbor			✓		
Nearest Mean Kohonen Self-Organizing Maps		✓	✓		
Clustering	✓	✓			
Association Rules	✓	✓			✓

1 accessed in data analysis only

2 estimation only (not for classification)

Table 4: Options for Decision Trees

Algorithm	IBM	ISL	SAS	TMC
Handles Real-Valued Data	✓	✓	✓	✓
Costs for Misclassification		✓	✓	✓
Assign Priors to Classes			✓	✓
Costs for Fields	✓			
Multiple Splits			✓	
Advanced Pruning Options		✓		
Graphical Display of Trees	✓	✓	✓	

Table 5: Options for Neural Networks

Algorithm	IBM	ISL	SAS	TMC	Unica
Automatic Architecture Selection	✓	✓	✓	✓	✓
Advanced learning Algorithms		✓	✓	✓	✓
Assign Priors to Classes			✓		✓
Costs for Misclassification		✓	✓	✓	
Cross-Validation Stopping Rule		✓	✓	✓	✓

Table 6: Ease of Use Comparison

Category	IBM	ISL	SAS	TMC	Unica
Data Load and Manipulation	3.1	3.7	3.7	3.1	3.9
Model Building	3.1	4.6	3.9	3.2	4.8
Model understanding	3.2	4.2	2.6	3.8	3.8
Technical Support	3.0	4.0	2.8	3.2	4.7
Overall Usability	3.1	4.1	3.1	3.4	4.2

ویژگی‌های تقلب مدیریتی وجود دارد. دوم، کسب آن کمیاب است، اکثر حسابرسان فاقد تجربه لازم در کشف آن هستند. در پایان، مدیران کنکاشانه تلاش می‌کنند حسابرسان را فریب دهند (فانینگ و کوگر، ۱۹۹۸). برای چنین مدیرانی که محدودیت‌های هر حسابرسی را درک کرده‌اند فرایند حسابرسی استاندارد ممکن است ناکافی از اب درآید. این محدودیت‌ها اشاره به نیاز فرایند تحلیل‌های اضافه برای کشف موثر تقلب مدیریت دارد. این همچنین رشد توجه به سامانه ارزیابی موارد غیرعادی با یک وضعیت حرفاًی در مورد کشف تقلب را برجسته کرده است. همان جایی که اکثر تقلب‌های مهم در سطوح بالای سازمان، سازمان‌دهی می‌شود، جایی که کنترل‌ها و سیستم‌ها کمترین شیوع و اثر را دارند (کولینا و سوتون، ۲۰۰۲).

مطالعات جدید متوجه ساخت مدل‌هایی شده‌اند که تقلب پیش آمده مدیریت را پیش‌بینی کنند. نتایج حاصل از تحلیل رگرسیون لاچیت ۷۵ شرکت متقلب و ۷۵ شرکت بدون تقلب اشاره به این موضوع داشته است که هیات مدیره شرکت‌های بدون تقلب به طور معنی‌داری با درصد بیشتری از اعضای خارج از سازمان نسبت به شرکت‌های متقلب تشکیل شده است (پاسلی، ۱۹۹۶). هاتسن، مکدونالد، میزر و بل (۱۹۹۶) یک مدل واکنشی کیفی تعمیم یافته مفید برای پیش‌بینی تقلب مدیران براساس دسته‌ای از داده‌های توسعه یافته به وسیله یک شرکت حسابرسی عمومی بین‌المللی را بکار برند. این مدل در بردارنده تکنیک‌های پرایبیت و لاچیت می‌باشد. نتایج اشاره به ظرفیت خوب پیش‌بینی دو گروه فرضیات مخارج متقارن و نامتقارن داشت.

۲-۲- تحقیقات پیشین

Kirkos, Spathis & Manolopoulos (2007) در ۱۹۹۷، هیات استانداردهای حسابرسی استاندارد حسابرسی (SAS) شماره ۸۲ را صادر کرد که: رسیدگی به تقلب در حسابرسی صورت‌های مالی است. این استاندارد حسابرسان را ملزم به رسیدگی به ریسک تقلب در رسیدگی حسابرس و تشویق حسابرسان برای رسیدگی به دو موضوع سیستم کنترل داخلی و کنترل رویکرد گرایشات مدیریت در زمان ارزیابی را در بر دارد. عوامل ریسک یا «پرچم قرمز» مرتبط با گزارش صورت‌های مالی متقابلانه ممکن است در سه گروه به این شرح طبقه‌بندی شوند (SAS شماره ۸۲):

الف- خصوصیات مدیریت و نفوذ به محیط کنترل؛

ب- خصوصیات صنعت؛

ج- خصوصیات اجرایی و پایداری مالی.

کمیته بین‌المللی مسایل حسابرسی (IAPC) از فدراسیون بین‌المللی حسابداران استاندارد بین‌المللی (ISA) شماره ۲۴۰ را صادر نموده است. این استاندارد انتظار رسیدگی به وسیله حسابرسان به ریسک تقلب و اشتباہ را دارد و به وضوح استدلال‌هایی راجع به محدودیت‌های ذاتی بر توانایی حسابرس برای کشف اشتباہ و خطأ به ویژه تقلب مدیریت را بر شمرده است. علاوه بر این، آن تقویت کننده تمایز بین تقلب مدیریت و کارکنان و علل مفهومی تقلبات مالی است که می‌بایست با جزئیات گزارش شود.

کشف تقلب مدیریتی وقتی در فرآیند معمولی حسابرسی استفاده می‌شود وظیفه سختی است (پورتر و کامرون، ۱۹۸۷؛ کودر، ۱۹۹۹). نخست اینکه آگاهی مفهومی کمی از

پیشینه تحقیقات در خصوص کاربردی داده کاوی در پیشگیری از سوء استفاده‌های مالی و تقلب:

ردیف	محقق	سال	تکنیک داده کاوی	نتایج
۱	اینیگ، جونز و لوبک	۱۹۹۷	سیستم خبره	به شکل کاملاً مشخصی، بهتر می‌توان، وضعیت سرتاسر مراحل متغیر مخاطرات تقلب مدیریت را بررسی نمود
۲	گرین و چوی	۱۹۹۷	شبکه عصبی	به حسابرسان رهنمود مناسبی برای کشف تقلب ارائه می‌دهد
۳	فانینگ و کوگر	۱۹۹۷	شبکه عصبی	نتایج بهتری در مقایسه با رگرسیون لاچستیک و مدل‌های آماری استاندارد ارائه داده است
۴	سامرز و سوئنی	۱۹۹۸	مدل منطقی آبشاری	در تقلب‌های مشاهده شده، کارکنان داخلی، سهام خودشان را از شرکت در سطوح بالای فعالیت‌های فروش کاهش می‌دهند

ردیف	محقق	سال	تکنیک داده کاوی	نتایج
۵	Chan و همکاران او	۱۹۹۹	داده کاوی توزیعی	امکان کشف تقلب کارت های اعتباری جهت مدیریت ریسک فراهم می شود
۶	«سرولو» و «سرولو»	۱۹۹۹	شبکه عصبی	تقلب در گزارشگری مالی را پیش بینی نمود
۷	بل و کارسلو	۲۰۰۰	رگرسیون لجستیک	احتمال گزارش مالی متقابله برای ادعای حسابرس در حالی که ریسک تقلب وجود دارد یا ندارد را افزایش می دهد
۸	اسپادیس	۲۰۰۲	رگرسیون لجستیک	احتمال بیشتر در تقلب و دستکاری در صورتهای مالی پیش بینی شد
۹	اسپادیس و سایرین	۲۰۰۲	داده کاوی توزیعی (UTADIS)	عملکردی بهتر در کشف تقلب در صورتهای نسبت به سایر روش های آماری (رگرسیون لجستیک و تجزیه و تحلیل آماری) دارد
۱۰	«گو» و «لو»	۲۰۰۴	درخت تصمیم گیری	مشکلات مخفی موجود در صورتهای مالی از طریق نسبت های مالی کشف گردید
۱۱	لین، هوانگو و بکر	۲۰۰۸	شبکه عصبی و عصبی فازی	هر دو مدل قادر به ارزیابی و طبقه بندی گزارش های مالی شرکت ها به متقابله و غیر متقابله هستند
۱۲	لیو	۲۰۰۸	رگرسیون لجستیک شبکه عصبی و درخت تصمیم گیری	با توجه به نتایج بدست آمده رگرسیون لجستیک، و شبکه عصبی قادر به طبقه بندی درست شرکت های متقابله می باشد. ولی صحت و درستی طبقه بندی بر اساس الگوریتم درخت تصمیم گیری پایین است و رگرسیون لجستیک یک روش مناسب برای کشف گزارشگری مالی متقابله و پیش بینی شکست تجاری شرکت ها می باشد
۱۳	گلنی و «یاداو»	۲۰۱۰	مدل کشف تقلب محاسبه ای (مدل متنی)	این مدل بر روی تحلیل های موجود در فایل K-۱۰ بورس اوراق بهادر امریکا، آزمون شد که قادر است بین گزارش های همراه با تقلب و بدون تقلب تفکیک قابل شود
۱۴	«زو» و «کاپو»	۲۰۱۰	رگرسیون لجستیک، درخت تصمیم گیری، شبکه عصبی و شبکه بیزیز	مدل ها قادر به کشف موثر تر تقلب در صورتهای مالی هستند
۱۵	حسینی نسب و همکاران	۱۳۹۰	داده کاوی روش Apriori و ترکیب اطلاعات روش Dempster-shaper و OWA	احتمال رخداد تقلب در نسخه های دارویی مربوط به یک فرد برای هر یک از زیر مجموعه داروهای مندرج در نسخ و توسط روش ها پیش بینی می شود
۱۶	Kirkos و همکاران	۲۰۰۷	درخت تصمیم گیری و شبکه عصبی و شبکه های گمانه زنی بیزی	نتایج در ادامه ارائه می شود

پژوهش محققان فوق مبتنی بر تحقیقات دیگران بوده

است که عبارتند از:

۱-۳- داده ها

نمونه تحقیق متشکل از داده های ۷۶ شرکت تولیدی یونانی (بدون اینکه شرکت های مالی در آن باشد) می باشد. حسابرسان تمام ۷۶ شرکت نمونه را بررسی کرده اند. در ۳۸ شرکت از این شرکت ها نشانه یا دلیلی از

۳- روش شناسی و سؤالات اصلی پژوهش

روش پژوهش حاضر، روش شناخت تاریخی مبتنی بر پیشینه تحقیقات با رویکرد فلسفی جهت ارزیابی توان تبیین داده کاوی در کشف تقلب صورتهای مالی است که از نتیجه تحقیقی در یونان که توسط Kirkos, Spathis & Manolopoulos در سال ۲۰۰۷ صورت گرفت به عنوان مطالعه موردی مدنظر قرار گرفت و مبانی بکار گرفته در

ویتنگ هام (۱۹۸۹) و کنی و مک دانل (۱۹۸۹) که در بردارنده پیشنهادهایی با اشاره به FFS می‌باشد.

پریشانی مالی ممکن است یک مشوق برای تلقبات مدیریتی باشد (فانینگ و کوگر، ۱۹۹۸؛ استیک، ۱۹۹۱؛ لوبیک و سایر همکاران، ۱۹۹۸؛ کینی و مک دانل، ۱۹۸۹). به منظور تطبیق نمودن یک نسبت در باب پریشانی مالی ما امتیاز Z آلتمن را که مشهور است را برای برآورد پریشانی مالی به طور گستردۀ امتیاز Z را استفاده کرده‌اند.

پیرسوس (۱۹۹۵) معتقد بود که یک پرسش مطرح این است که آیا یک ساختار بدھی سنگین در گزارش مالی متقلبانه دخالت دارد. یک ساختار بدھی سنگین ممکن است احتمال FFS را افزایش دهد بدین صورت که این موضوع با ریسک حقوق مالکان و مدیریت بدھی توسط مالکان مرتبط است. مدیران ممکن است بدھی‌هایی را که براساس قراردادهای بدھی در صورتهای مالی در حال سرسید شدن می‌باشد را دستکاری کنند. این موضوع اشاره به این دارد که سطوح بالاتری از بدھی ممکن است احتمال FFS را افزایش دهد. ما آن را به وسیله استفاده از لگاریتم کل بدھی (LOGDEBT)، نسبت بدھی به ارزش ویژه (DEBTEQ) و نسبت کل بدھی به کل دارایی‌ها (TDTA) اندازه گرفته‌ایم.

انگیزه دیگر تلقی مدیریتی نیاز به رشد پایدار است. شرکتهای ناتوان در سیدن به نتایج مشابه عملکرد گذشته ممکن است درگیر فعالیتهای متقلبانه برای حفظ روند پیشین خود شوند (استیک، آبرچت و براؤن، ۱۹۹۱). شرکت‌هایی که رشد سرعی داشته‌اند ممکن است فرایندی را تحت نظر قرار دهند که قابلیت نظارت مناسب را تدارک می‌بیند و آن را پشت سر گذاشته باشند (فانینگ و کوگر، ۱۹۹۸). برای اندازه گیری رشد، از نسبت رشد فروش (SALGRTH) استفاده می‌کنیم.

حسابرسی محدودی از حسابهایی که استفاده از برآورد در آنها مجاز است، مشکل می‌باشد در نتیجه آنها مستعد تحریف‌های متقلبانه هستند. حسابهای دریافتی، موجودی و فروش‌ها در این گروه قرار می‌گیرند. پیرسونس (۱۹۹۵)، استیک (۱۹۹۱) و فروز و همکاران (۱۹۹۱)

وجود صورت‌های مالی متقلبانه اعلام شده است. طبقه‌بندی صورت‌های مالی به عنوان خطاب مبنی بر معیارهای معین به این شرح است: نتیجه گزارش حسابرسی راجع به تردیدهای جدی راجع به درستی حسابهای، اسناد مالیاتی راجع به عدم تراضی مالیاتی جدی که از دگرگونی شدید ترازنامه و صورت سود و زیان سالانه شرکت در بکارگیری قوانین یونان در مورد رد خالص ارزش آنها می‌باشد که عاقبت چنین شرکت‌هایی در بورس آتن قرار گرفتند که در زمرة شرکتهای تحت نظر و «معلق در حال مذکوره» برای مشخص شدن دلایل دخیل در تحریف داده‌های مالی شرکت‌ها و ارسال پرونده آنها جهت گذراندان، طی فرایند قضایی با اتهام FFS یا جرایم شدید مالیاتی است.

۳۸ شرکت دارای تقلب با ۳۸ شرکت بدون تقلب تطبیق داده شد. شرکت‌هایی که به عنوان شرکت‌های بدون FFS مشخص شده‌اند براساس نبود (فقدان) هیچ اشاره یا گواهی رد باب گزارشی از FFS در گزارشات حسابرسی در امور مالی و پایگاه داده مالیاتی در بورس سهام آتن می‌باشد. این مسیر تضمین نمی‌کند که صورتهای مالی این شرکت‌ها بدون تحریف یا رفتارهای FFS باشند که در آینده شناسایی شود. این تنها پیدا شده در یک بررسی مرتبط مبسوط را تضمین کرده است. تمام متغیرهای مورد استفاده از نمونه‌ها از صورتهای مالی رسمی مانند ترازنامه‌ها و صورتهای سود و زیان استخراج شده است. این بدان معنا است که سودمندی این مطالعه به واسطه این واقعیات که تنها از داده‌های شرکت‌های یونانی استفاده شده است، محدود نمی‌شود.

۳-۲- متغیرهای پژوهش

گرینش متغیرها با استفاده از معرفی داده‌های خط دهنده‌ی با مشارکت مبتنی بر کارهای تحقیقاتی پیشین مرتبط با موضوعات FFS بوده است. مانند کار انجام شده به وسیله اسپادیس (۲۰۰۲)، اسپادیس و سایر همکاران (۲۰۰۲؛ فانینگ و کوگر، ۱۹۹۸؛ پرسونس، ۱۹۹۵؛ استیک، ۱۹۹۱)، فروز، پارک و پاستنا (۱۹۹۱)، لوبیک، اینینگ،

با قابلیت پیش‌بینی FFS آنها آزموده شد. این نسبت‌ها عبارتند از: لگاریتم مجموع دارایی‌ها (LTA)، سرمایه در گردش (WCAP)، نسبت تاسیسات و تجهیزات net به مجموع دارایی‌ها (NFATA) و فروش به مجموع دارایی‌ها (SALTA) و دارایی‌های جاری / بدھی‌های جاری (CACL) و خالص درآمد / دارایی‌های ثابت (NIFA) و موجودی نقد / مجموع دارایی‌ها (CASHTA) و دارایی‌های آنی / بدھی‌های جاری (QACL)، سود قبل از بهره و مالیات (EBIT) و بدھی‌های بلند مدت / مجموع دارایی‌ها (LTDTA).

در مطالعه Kirkos و همکاران او ۲۷ نسبت مالی را گردآوری گردید. در کوششی برای کاهش ابعاد، آنالیز واریانس یک طرفه ANOVA را به منظور آزمون اینکه آیا اختلاف دو گروه برای هر متغیر معنی‌دار است، اجرا گردید. اگر اختلاف معنی‌دار نبود ($P > 0.05$) مغایر به عنوان اطلاعات غیرمفید تلقی می‌شود. جدول ۷ میانگین، انحراف استاندارد و P -value و P -value را برای هر متغیر نشان می‌دهد.

همانطور که در جدول ۷ می‌بینید، ۱۰٪ متغیر P کم value با عنوان متغیرهای دخالت کننده در داده‌های خط دهنده انتخاب می‌شوند و از بقیه متغیرها تفکیک می‌گردد. متغیرهای انتخاب شده، SALTA، COSAL، EBIT، GPTA، WCTA، NDTA، TDTA، ZSCORE، WCAP، DEBTEQ هستند.

۳-۳- روش‌ها و الگوهای آزمون

شناسایی صورت‌های مالی متنقلبانه را می‌توان به عنوان نوعی طبقه‌بندی مشکل در نظر داشت. طبقه‌بندی یک رویه دو مرحله‌ای دارد. گام اول، یک مدل که با استفاده از نمونه‌های آموزشی، آموزش می‌بیند. نمونه با چندین متغیر (به شکل سطرها) و توزیع آنها (در ستون‌ها) سازمان دهی می‌شود. یکی از توزیع‌ها و برچسب توزیع در بردارنده ارزش معرف از پیش تعیین شده طبقه برای هر کدام از چندین متغیر متعلق به آن متغیر می‌باشد. این مرحله به عنوان آموزش هدایت شده شناخته می‌شود.

معتقدند که مدیریت ممکن است در حسابهای دریافتی دستکاری کند. فعالیت‌های متنقلبانه ثبت فروش قبل از اینکه تحقق یابد ممکن است حسابهای دریافتی را اضافه‌تر نشان دهد (فانینگ و کوگر، ۱۹۹۸). در این تحقیق، حسابهای دریافتی را با استفاده از نسبت حسابهای دریافتی / فروش (RECSAL) و نسبت حسابهای دریافتی / حسابهای دریافتی برای دو سال REC11 پیاپی (RETREND) و متغیر رقومی (دیجیتال) که اشاره به تغییرات ۱۰٪ دارد مدنظر قرار گرفت.

بسیاری از تحقیقات به این موضوع اشاره دارد که ممکن است مدیریت موجودی‌ها را دستکاری کند (استیک، ۱۹۹۱؛ پرسون، ۱۹۹۵؛ اس چلیت، ۲۰۰۲). گزارش موجودیها با بهای تمام شده کمتر و ثبت موجودیهای راکد بعضی از تدبیر شناخته شده است. ما موجودی‌ها را به وسیله استفاده از نسبت موجودی / فروش (INVSAL) و موجودی به مجموع دارایی‌ها (INVTA) بررسی می‌کنیم. حاشیه سودناخالص نیز مستعد دستکاری است. شرکتها ممکن است تطابق فروش‌هایشان را با بهای تمام شده کالای فروش رفته مربوط انجام ندهند. در نتیجه حاشیه سود ناخالص، خالص درآمد و استحکام ترازنامه افزایش یابد (فانینگ و کوگر، ۱۹۹۸). ما حاشیه سود ناخالص را با استفاده از نسبت فروش منهای حاشیه سودناخالص (COSAL) و نسبت سود ناخالص / مجموع دارایی‌ها (GPTA) و نسبت حاشیه سود ناخالص / حاشیه سود ناخالص دو سال پیاپی (GMTREND) و متغیر دو تایی باینری GM11 که اشاره به ۱۰٪ افزایش نسبت به ارزش سال پیش دارد، آزمون می‌کنیم.

اسپادیس (۲۰۰۲) در یک مطالعه رگرسیون لاجستیک برای پیش‌بینی FFS معتقد بود سود خالص / مجموع دارایی‌ها (NPTA) و سرمایه در گردش / مجموع دارایی‌ها (WCTA) نسبت‌های معنی‌داری هستند. به علاوه اسپادیس و همکارانش (۲۰۰۲) به این موضوع اشاره داشتند که همچنین نسبت سود خالص / فروش (NPSAL) بیشترین معنی داری را در خود دارد. در این مطالعه، ارتباط بعضی از «پرچم‌های قرمز» صورتهای مالی

آمده است. سه روش که از شهرت خوب در قابلیت طبقه بندی بهره مندند در این مطالعه نیز از تحقیقات دیگر محققان نیز استفاده گردید. این روش‌ها عبارتند از درخت تصمیم‌گیری، شبکه‌های عصبی و شبکه‌های گمانهزنی بیزی می‌باشند.

در گام دوم مدل تلاشی می‌شود موضوعاتی را با استفاده از اعتبار نمونه‌ها بر پا کرد که به نمونه‌های آزمایشی تعلق ندارند.

فرایندهای داده کاوی روش‌های چندین دسته بندی است که از رشته‌هایی از آمار و هوش مصنوعی به دست

جدول شماره ۷: نتایج آزمون

p-value	F	SD non-FFS	Mean non-FFS	SD FFS	Mean FFS	Variables
۰/۰۰۷	۷/۵۶	۰/۹۳۷	۱/۰۷۵	۳/۰۳۱	۲/۷۰۶	۱- بدھی به ارزش و پریز (DEBTEQ)
۰/۰۰۳	۹/۵۳	۰/۵۷۷	۱/۰۵۵	۰/۴۱۶	۰/۶۹۹	۲- فروش به مجموع دارایی‌ها (SALTA)
۰/۱۸۸	۱/۷۷	۰/۱۵۹	۰/۰۶۷	۲/۴۳۴	-۰/۴۵۹	۳- سود خالص به فروش (NPSAL)
۰/۱۷۹	۱/۸۴	۰/۳۴۹	۰/۴۵۶	۵/۸۹۷	۱/۷۵۵	۴- حسلهای دریافتی به فروش (RECSAL)
۰/۲۵۷	۱/۳۱	۰/۱۴۰	۰/۲۷۶	۰/۱۹۳	۰/۳۲۰	۵- تابیسات و تجهیزات به کل دارایی (NFATA)
۰/۳۵۸	۰/۸۶	۳/۰۲۸	۱/۷۳۳	۰/۴۹۱	۱/۲۷۳	۶- حسابهای دریافتی به حسابهای دریافتی برای دو سال پیاپی (RETRNET)
۰/۳۴۰	۰/۹۲	۰/۴۶۰	۰/۷۱۱	۰/۴۹۵	۰/۶۰۵	۷- متغیر رقومی (دیجیتال) نسبت ۶ به میزان (%) (REC11)
۰/۳۶۳	۰/۸۴	۱۰/۸/۴۸۴	۱۸/۷۱۵	۹/۰۱۴	۲/۵۶۴	۸- حاشیه سود ناخالص به سود ناخالص برای دو سال پیاپی (GMTREND)
۰/۱۱۱	۲/۶۰	۰/۵۰۰	۰/۵۷۹	۰/۴۹۵	۰/۳۹۵	۹- متغیر دوتایی بایتری نسبت ۸ به میزان (%) (GM11)
۰/۳۲۰	۱/۰۰	۲۵۵۴/۴۶۴	۴۱۵/۶۱۶	۰/۷۰۵	۱/۱۶۳	۱۰- رشد فروشی (SALGRTH)
۰/۱۰۵	۲/۷۰	۰/۱۵۹	۰/۱۷۹	۰/۵۶۵	۰/۳۵۹	۱۱- موجودی به فروشی (INVSAL)
۰/۷۳۲	۰/۱۳	۰/۱۴۲	۰/۱۷۸	۰/۱۶۰	۰/۱۹۱	۱۲- موجودی به کل دارایی‌ها (INVTA)
۰/۳۵۶	۰/۸۶	۰/۱۱۴	۰/۰۹۶	۰/۱۲۲	۰/۰۷۱	۱۳- موجودی نقد به کل دارایی‌ها (CASHTA)
۰/۹۳۳	۰/۰۱	۰/۲۸۸	۸/۴۷۳	۰/۹۹۶	۸/۴۵۱	۱۴- لگاریتم مجموع دارایی‌ها (LTA)
۰/۲۴۳	۱/۳۹	۱/۴۱۱	۷/۵۱۲	۱/۲۳۳	۷/۸۷۰	۱۵- لگاریتم مجموع بدھی‌ها (LOGDEBT)
۰/۰۵۰	۳/۹۸	۷۷۳۴/۲۸۵	۵۸۸۹/۷۴۲	۳۰۶۶/۱۸۸	۳۱۹۶/۶۰۰	۱۶- فروش منهای حاشیه سود ناخالص (COSAL)
۰/۰۳۳	۴/۷۳	۲۸۷۵/۹۲۹	۱۰۹۳/۲۵۳	۱۳۹۲/۹۳۰	-۳۳/۶۲۴	۱۷- سود قبل از بهره و مالیات (EBIT)
۰/۰۱۶	۶/۰۳	۴۲۷۹/۶۸۵	۲۲۸۰/۷۳۷	۲۱۶۶/۶۸۵	۳۶۹/۱۷۱	۱۸- سرمایه در گردش خالص (WCAP)
۰/۰۰۰	۳۹/۵۹	۰/۷۳۰	۱/۹۹۰	۰/۹۳۶	۰/۷۷۸	۱۹- آلتمن Z (ZSCORE)
۰/۵۹۵	۰/۲۹	۱۱/۶۳۵	-۱/۵۵۴	۱/۹۹۶	-۰/۵۳۱	۲۰- خالص درآمد به دارایی ثابت (NIFA)
۰/۰۰۰	۱۴/۳۱	۰/۱۹۶	۰/۴۳۷	۰/۲۴۳	۰/۶۲۹	۲۱- کل بدھی به کل دارایی (TDTA)
۰/۰۰۰	۲۶/۱۱	۰/۰۶۵	۰/۰۷۴	۰/۰۹۵	-۰/۰۲۱	۲۲- سود خالص به کل دارایی (NPTA)
۰/۱۸۵۹	۰/۰۳	۲/۲۶۷	۲/۳۰۲	۶/۰۹۵	۲/۱۱۳	۲۳- دارایی جاری به بدھی جاری (CACL)
۰/۰۰۰	۱۵/۱۵	۰/۲۰۵	۰/۲۵۳	۰/۲۳۹	۰/۰۵۴	۲۴- سرمایه در گردش به کل دارایی (WCTA)
۰/۱۹۶	۱/۷۰	۱/۸۰۴	۱/۷۷۲	۲/۲۴۵	۱/۱۶۳	۲۵- دارایی آنی به بدھی جاری (QACL)
۰/۰۰۰	۱۸/۷۸	۰/۱۴۰	۰/۲۷۴	۰/۱۲۱	۰/۱۴۴	۲۶- سود ناخالص به کل دارایی‌ها (GPTA)
۰/۳۵۳	۰/۸۷	۰/۰۷۷	۰/۰۴۱	۰/۱۳۸	۰/۰۶۵	۲۷- بدھی بلندمدت به کل دارایی (LTDTA)

۳-۳-۲- شبکه‌های عصبی

شبکه‌های عصبی (NN^۹) یک فن‌آوری کامل در اجرای یک تئوری و شناخت حوزه‌های کاربردی آن است. یک NN متشکل از تعدادی سلول عصبی و امثال آن به صورت واحدهای پردازش به هم پیوسته است. اشتراک در هر اتصال با یک ارزش عددی است که «وزن» نامیده می‌شود. هر سلول عصبی علامتی از اتصال سلول عصبی می‌گیرد و ترکیب علامت‌های ورودی محاسبه می‌شود. مجموع علامت ورودی برای سلول عصبی $\sum w_{i,j} \times x_i = u_j$ است چنانکه x_i علامت ورودی از سلول عصبی i و $w_{i,j}$ وزن اتصال بین سلول عصبی i و سلول عصبی j باشد. اگر قدرت علامت ورودی ترکیب شده بیش از یک آستانه‌ای باشد در این صورت ارزش ورودی به وسیله بخش ویژه انتقال شبکه عصبی انتقال داده می‌شود و در پایان سلول عصبی برانگیخته می‌گردد (هان و کمبر، ۲۰۰۰).

سلول‌های عصبی در لایه‌هایی چیده می‌شوند. هر لایه شبکه متشکل از یک ورودی (اولیه) و یک خروجی (ثانویه) به عنوان کوچکترین جزء هر لایه است. در بین ورودی و خروجی لایه ممکن است یک لایه مخفی یا بیشتر وجود داشته باشد. اختلاف انواع NN‌ها در اختلاف تعداد لایه‌های آنها است. طرح‌های سازمان یافته طبیعی (SOM^{۱۰}) تنها یک لایه ورودی و خروجی دارند. در حالیکه یک NN پس انتشار یک یا چندین لایه مخفی بیشتر دارد.

بعد از اینکه معماری شبکه مشخص شد، شبکه باید آموزش ببینند. در شبکه‌های پس انتشار یک الگو برای لایه ورودی و محاسبه خروجی نهایی در لایه خروجی بکار می‌رود. خروجی با نتیجه مورد درخواست مقایسه شده و خطاهای به عقب NN انتشار می‌یابد یا وسیله تنظیم وزن اتصال‌ها قرار گیرد. این فرایند تا زمانی تکرار می‌شود که به یک نرخ خطای قابل پذیرش برسیم. شبکه‌های عصبی که هیچ فرضی در مورد صفات مستقل ندارند قابلیت رسیدگی به داده‌های مخدوش یا متناقض را ندارند و پیشنهاد انعطاف‌پذیر مناسب بر مشکلاتی هستند که یک الگوریتم چاره ساز در آن کارایی ندارد. از آنجایی که NN‌های پس انتشار بیشترین عمومیت را به عنوان یک پیش‌بینی کننده و طبقه‌بندی کننده مشکلات دارد (سه‌هل

۳-۳-۱- درخت تصمیم‌گیری

یک درخت تصمیم‌گیری (DT) یک ساختار درختی است که هر گره آن یک آزمون برای یک صفت را نشان می‌دهد و هر انشعب نشان دهنده یک خروجی از آزمون می‌باشد. در این طریق، هر شاخه تلاش می‌کند مشاهدات را در زیر گروه‌هایی به صورت دو به دو ناسازگار تقسیم کند. خوبی یک انشعب بر مبنای انتخاب صفاتی است که بهترین جداسازی نمونه را انجام دهد. نمونه‌ها با موفقیت به دسته‌هایی تقسیم می‌شوند، یعنی تا زمانی که هر یک از دو تا دیگر مسیر تقسیم شدن را دیگر طی ننمایند می‌توان اختلاف معنی دار را به طور آماری یا زیر گروه‌ها برای ایجاد تقسیم معنی دار مشابه بسیار کوچک تولید کرد. چندین الگوریتم تقسیم پیشنهاده شده است. در ردبیایی یا بازیابی متنقابل خودکار (AID^{۱۱}) بیشترین آماره t معنی دار به عنوان هر تحلیل واریانس استفاده می‌شود. در مربع آماره AID chi^{۱۲} و طبقه بندی و رگرسیون درختی (CART^{۱۳}) برای استفاده از شاخص تفاوت‌ها بکار رفته است (کوه و لو، ۲۰۰۴). در این مطالعه ما الگوریتم شناخته شده ID3 را بکار می‌بریم. ID3 اندازه گیری مبتنی بر انتروپی است که به عنوان اطلاعات سودمند شناخته می‌شود و آن را برای تعیین صفت متمایز کننده انتخابی بکار می‌بریم (هانک و گمیر، ۲۰۰۰).

تقسیم‌های پی در پی نمونه ممکن است یک درخت بزرگ تولید کند. برخی از شاخه‌های درخت ممکن است بازتاب خلاف قاعده‌ای از دسته آموزشی باشد مانند ارزش‌های نادرست یا طرح‌های کلی نگر. به همین دلیل شاخه به میزان نیاز هرس می‌شود. هرس شاخه با حذف گره‌های تقسیم شده در راهی است که در نرخ درستی مدل معنی دار نمی‌باشد.

برای تعیین طبقه هدف مشاهده نشده پیشین، وزن صفت هدف دوباره در گره‌های تصمیم‌گیری شاخه آزموده می‌شود. براساس این آزمون یک مسیر پیموده می‌شود که به هدف طبقه در پیشگویی ختم خواهد شد. مزیت اصلی درخت تصمیم‌گیری این است که یک راه معنی دار با نمایش دانش کسب شده تدارک می‌بیند و قواعد طبقه‌بندی اگر-آنگاه را به آسانی استخراج می‌کند.

برای هر گره X موجود یک جدول احتمالات شرطی نیز موجود است، هم چنانکه احتمالات شرطی ویژه برای هر ارزش X برای هر ترکیب ارزش‌های ممکن پدراشان نیز موجود است (توزیع شرط $P(X|Parents(X))$). احتمال یک مجموعه $(X_1, X_2, X_3, \dots, X_n)$ توزیع دارند که به این شکل است.

ساختار یک شبکه را می‌توان از پیش تعريف نمود یا از داده‌ها استنباط کرد به منظور طبقه‌بندی یک گره از میان گره‌ها می‌توان طبقه گره را تعريف نمود. شبکه توانایی خوش‌بندی احتمال هر طبقه متنابوی را دارد.

و ون کاتاچalam، ۱۹۹۵) ما شبکه‌های عصبی پس انتشار را در این مطالعه گزیدیم.

۳-۳-۳- شبکه‌های گمانه زنی بیزی (شبکه‌های احتمالات شرطی)

طبقه‌بندی بیزی بر مبنای قضیه آماری بیز است. قضیه بیز یک خوش‌بندی از احتمالات پس گرا تدارک می‌بیند. بر اساس قضیه بیز، اگر H یک فرضیه باشد- مانند اینکه شیء (یا موضوع) X به طبقه C تعلق داشته باشد- آنگاه احتمال جا افتادن (تحقیق) فرضیه به صورت $P(H|X) = (P(X|H) * P(H)) / P(X)$ می‌باشد.

اگر یک شیء (یا موضوع) X به یک گروهی از طبقات متنابوی A تعلق داشته باشد برای تعیین طبقه‌بندی شیء در یک خوش‌بندی طبقه‌بندی شده بیزی، احتمالات ممکن به صورت $P(C_i|X)$ برای تمام طبقات C_i ممکن بوده و بیشترین احتمال تخصیص شیء (یا موضوع) به طبقه‌ای خاص می‌باشد $P(C_i|X)$.

طبقه‌بندی‌های بیزی ساده با فرض حالت مستقل ساخته می‌شود که این در علم آمار از یک ارزش صفت داده شده در یک طبقه که مستقل از ارزش سایر صفات است نتیجه می‌شود. فرض ساده خوش‌بندی به صورت $P(C_i|X)$ است. اگر این فرض درست انگاشته شود طبقه‌بندی ساده بیزی بهترین برآورد صحیح را در مقایسه با بقیه طبقه‌بندی‌ها خواهد داشت. هرچند در بسیاری از موارد این فرض تایید نمی‌شود چون که وابستگی بین صفات می‌تواند وجود داشته باشد.

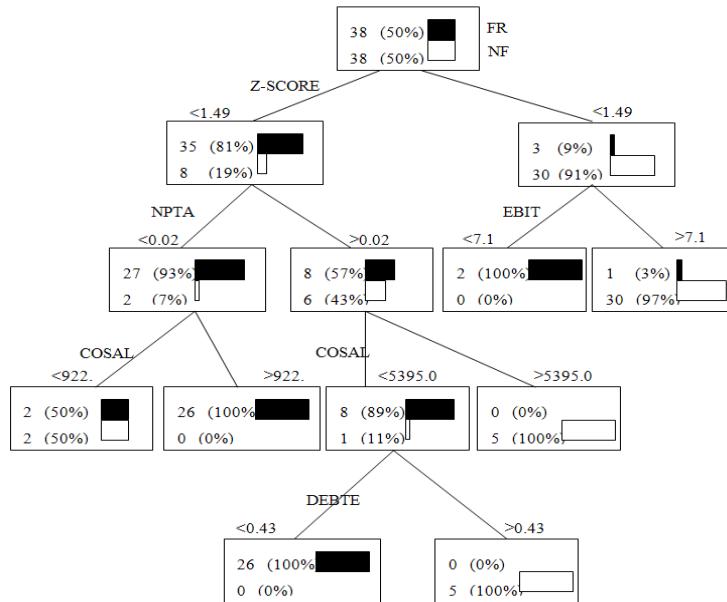
شبکه‌های گمانه زنی بیزی ($BNN^{(1)}$) اجازه گزارش مقادیر وابسته زیرمجموعه‌ای از صفات را می‌دهد. یک BNN نمودار ناچرخه‌ای (مارپیچی) مستقیم است که هرگاه یک صفت را نشان می‌دهد و هر فلش نشان‌دهنده وابستگی احتمالی است. اگر یک فلش به صورت اگر گره A به گره B رسم شود، آنگاه A پدر B و B زاده A است. در یک شبکه گمانه‌زنی هر متغیر شرطی مستقل از نازاده آن که توسط پدرش داده شده، می‌باشد (هان و کمبر، ۲۰۰۰).

۴- آزمون‌ها و نتایج تحلیل‌ها

سه مدل متنوع که هر کدام بر مبنای روش‌های مختلف بود ساخته شد، مدل درخت تصمیم‌گیری با استفاده از نرم‌افزار ویرایش تحقیقاتی سیپینیا^{۱۲} بنا شد. مدل با سطح اطمینان ۹۵٪ ساخته شد. ما تمام نمونه‌ها را به عنوان دسته آموزشی استفاده کردیم. شکل شماره (۲) نشان دهنده ساختار ایجاد شده درخت تصمیم‌گیری است.

مدل در برابر داده‌های آموزشی آزمون شد و تا طبقه بندی ۷۳ مورد به طور صحیح مدیریت شود (عملکرد کلی برابر ۹۶٪). در این مورد درخت تصمیم‌گیری تمام موارد قادر تقلب (۱۰۰٪) و ۳۵ مورد از ۳۸ مورد تقلب را بطور صحیح طبقه بندی کرد.

همانطور که در شکل شماره (۲) مشاهده می‌شود، الگوریتم، متغیر امتیاز Z را به عنوان اولین جداساز استفاده نموده است. ۳۵ مورد از ۳۸ مورد شرکتهای متقلب نشان داده شده ارزش امتیاز Z کم قابل توجهی داشتند ($1/49 < \text{امتیاز}(Z)$). از آنجاییکه آلتمن ارزش امتیاز Z برابر $1/81$ را نقطه شناسایی پریشانی مالی برای شرکت‌های تولیدی ایالات متحده آمریکا مطرح کرده است (آلتمن، ۲۰۰۱)، ما می‌توانیم استنتاج کنیم شرکت‌هایی با پریشانی مالی در نمونه ما گرایش بیشتری به دستکاری صورت‌های مالی یشان را دارند.



شکل شماره ۲: ساختار ایجاد شده درخت تصمیم‌گیری

گونه که به موفقیت ۱۰۰ درصدی در عمل دست یافت. مitasfaneh نرم افزار نمی‌توانست یک ارتباط شفاف از وزن‌های سیناپس‌های ارتباطی برای ما مهیا کند، بنابراین برآورده از میزان اهمیت هر متغیر ورودی ممکن نبود. در آزمایش سوم، یک شبکه گمانه زنی بیزی (BBN) را توسعه دادیم. نرم افزاری که استفاده کردیم BN با قدرت پیش‌بینی بود. این نرم افزار ظرفیت آموزش یک طبقه‌بندی کننده را با داده‌ها دارد. متعلقات الگوریتمی که برپا شده دسته‌ای از الگوریتم‌های مبتنی بر آزمون مستقل شرطی است و نیاز به تنظیم گره نیست (جنگ و گرینر ۲۰۰۱). به اقتضای محدودیت‌های نرم افزار ما باید مقادیر را به صورت نظری اعمال کنیم. پس از آزمون روش‌های نظری مختلف (با پهنا و ژرفای مساوی) ما روش نظری بر نگری شده را انتخاب کردیم. برخلاف سایر روش‌های نظری، مبنای نظری در گاشت محور^{۱۴} در رده‌بندی اطلاعاتی بکار می‌رود. این ساختار شbahتی را که فاصله تعريف شده ممکن است برای کمک به بهبود طبقه‌بندی صحیح ایجاد کند را می‌سازد (هان و کمبر، ۲۰۰۰).

از این رو برای آموزش شبکه گمانه زنی، تمام نمونه‌ها را به عنوان دسته آموزشی استفاده و بعد از آموزش شبکه، آن را در مقابل دسته آموزشی آزمون نمودیم. شبکه به درستی ۷۲ مورد را طبقه‌بندی نمود (عملکرد ۹۵٪). در این مورد مدل ۳۷ مورد تقلب (۹۷٪) و ۳۵ مورد فاقد

در مرحله دوم جداسازی دو متغیر سهیم در سودآوری EBIT و NPTA (با کار رفته است. شرکت‌های بدون تقلب با امتیاز Z بالا نشان دهنده سودآوری بالا در حالیکه شرکت‌های متقلب با امتیاز Z کم نشان دهنده سودآوری پایین می‌باشد. جدول شماره (۳) متغیرهای جداساز نمود یافته در درخت تصمیم‌گیری را شرح می‌دهد.

جدول شماره ۳: تفکیک متغیرها در درخت تصمیم‌گیری

The splitting variables

Variables
Z-SCORE
NPTA
EBIT
COSAL
DEBTEQ

در آزمون دوم مدل شبکه عصبی را ساختیم. نرم افزار ناکلاس^{۱۳} با شبکه غیرخطی برای طبقه‌بندی را به منظور ساخت یک شبکه پیش خور مفهومی چند لایه بکار برده شد. بعد از آزمون تعدادی از طرح‌های متعدد، و انجام آموزش‌های مقدماتی، وضعیتی با یک لایه مخفی محتوی پنج گره مخفی را برگزیدیم.

شبکه انتخاب شده دوم، با استفاده از تمامی نمونه‌ها آموزش دید و در مقابل دسته آموزشی آزمون شد. شبکه موفق شد تمام موارد را به درستی طبقه‌بندی کند؛ بدین

جدول شماره (۶) عملکرد سه مدل را بر نمونه آموزشی تشریح می‌کند. نتایج اشاره به این دارد که مدل NN به صورت کاملاً کارا قدرت تشخیص بین شرکتهای دارای FFS و بدون FFS را دارد و بعد از آن مدل‌های BBN و ID3 قرار دارند.

جدول شماره ۶: عملکرد سه مدل منتخب داده کاوی
جهت کشف تقلب

Performance against the training set			
Model	Fraud (%)	Non-fraud (%)	Total (%)
ID3	92.1	100.0	96.2
NN	100.0	100.0	100.0
BBN	97.4	92.1	94.7

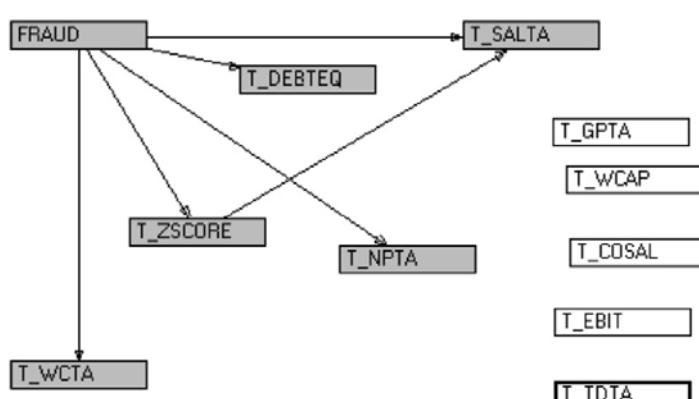
۴- (روایی) اعتبار مدل‌ها
استفاده از دسته آموزشی به منظور تعیین برآورده از توان اجرایی یک مدل به عنوان یک مبنا معرفی شده است. در بسیاری از موارد در مدل‌ها گرایش به خلاصه‌سازی نمونه در برابر آموزش وجود دارد، (داده‌هایی که قرار است برآرžش شوند). برای برطرف نمودن چنین مواردی یک زیربنای اجرایی از مدل قبل از اینکه الگوها دیده شوند برآورد می‌شود. چندین رویکرد اعتباربخشی به مدل مانند تقسیم نمونه‌ها به آموزشی و بخش کنارگذاشته نمونه، ۱۰ لایه متقاطع اعتباربخشی و کنار گذاشتن یکی برای اعتبار بخشی وجود دارد.

تقلب (٪۹۲) را به درستی طبقه‌بندی نمود. شکل شماره (۴) ساختار شبکه گمانه زنی را نشان می‌دهد. همانطور که در شکل شماره (۴) می‌توان دید، شبکه گمانه زنی به منظور وفق دادن تعیین یافته‌گی بیشتر، ظاهری با ملاحظه به انگیزه‌های تحریف صورت‌های مالی مدنظر داشته است. براساس شبکه تقلبات گزارش داده شده به شدت وابستگی به ورودی متغیرهای امتیاز Z، NPTA، DEBTEQ و SALTA و WCTA دارند. هر کدام از این متغیرها ادعای اختلاف یک جنبه از وضعیت مالی شرکت را دارد. امتیاز Z بازتابی از پریشانی مالی است؛ DEBTEQ به اهرم اشاره دارد؛ NPTA نشان از قابلیت سودآوری؛ SALTA به عملکرد فروش اشاره دارد و WCTA نشان از نقدشوندگی است.

برایین اساس شبکه گمانه زنی برای ثبت وابستگی بین صورتهای مالی تحریف شده، تعدادی از جنبه‌های مالی شایان توجه هر شرکت را مدنظر قرار داده است. جدول شماره (۵) متغیرهای انتخاب شده برای شبکه گمانه زنی را نشان می‌دهد.

جدول شماره ۵: متغیرهای منتخب

Variables
Z-SCORE
NPTA
DEBITQ
SALTA
WCTA



شکل شماره ۴: ساختار شبکه گمانه زنی

۸۲/۵٪ از موارد تقلب و ۷۷/۵٪ موارد فاقد تقلب. در پایان شبکه گمانه‌زنی بیزی که کمترین صحت را در دسته آموزشی داشت، با موفقیت ۹۱/۷٪ موارد آموزشی و ۸۸/۹٪ موارد فاقد تقلب و در کل ۹۰/۳٪ دسته اعتباربخشی را به درستی طبقه‌بندی نمود.

در یک ارزیابی تطبیقی از عملکرد مدل‌ها می‌توانیم نتیجه بگیریم که شبکه گمانه‌زنی بیزی کاربردی‌ترین نسبت به دو مدل دیگر است و به عنوان: بر جسته‌ترین طبقه‌بندی کننده صحیح رسیده است. شبکه‌های عصبی به عنوان: عملکرد بالا به طور رضایت‌بخش رسیده و در پایان عملکرد درخت تصمیم‌گیری به عنوان: ترجیح کمتر مطرح شد.

در ارزیابی عملکرد یک مدل سایر ملاحظات مهم، نرخ‌های خطاهای نوع ۱ و ۲ است. خطای نوع ۱ چنین پذیرفته شده: وقتی یک شرکت متقلب به عنوان فاقد تقلب طبقه‌بندی شود. خطای نوع ۲ چنین پذیرفته شده است: وقتی یک شرکت فاقد تقلب به عنوان متقلب طبقه‌بندی شود. خطاهای نوع ۱ و ۲ هزینه‌های متفاوتی دارند. طبقه‌بندی یک شرکت متقلب به عنوان یک شرکت فاقد تقلب ممکن است ما را به سمت تصمیمات نادرست هدایت کند که عواقب وخیم اقتصادی در بر خواهد داشت. طبقه‌بندی اشتباه یک شرکت فاقد تقلب ممکن است به علت صرفه هزینه زمانی بررسی بیشتر شود. هر چند هیچ مدلی به کاهش نرخ‌های هر دو نوع خطا نائل نشده است. یک مدل فرض رجحان خطای نوع ۱ نسبت به خطای نوع ۲ آن را دارد. در آزمون، تمام مدل‌ها نرخ خطای نوع ۱ کمتری را به نمایش گذاشتند. شبکه عصبی مصنوعی بیشترین اختلاف بین نرخ خطای نوع ۱ و ۲ را ارائه نمود.

۵- نتیجه‌گیری و بحث

داده کاوی به عنوان یکی از ده دانش در حال توسعه، پل ارتباطی میان علم آمار، علم کامپیوتر، هوش مصنوعی، الگوشناسی، فرآگیری ماشین و بازنمایی بصری داده می‌باشد که کاربرد گسترده‌ای در زمینه‌های پژوهشی، صنعت، مهاجرت، هتلداری، مدیریت ریسک و بالاخص کشف تقلب دارد، بطوریکه امروزه فعالیت حسابرسی باید چیرگی بر موارد رو به فزونی تقلب مدیران

اگرچه سه بسته نرم‌افزاری که در تحقیق مورد استفاده گردید متضمن (دربردارنده) قابلیت‌های اعتباربخشی بودند، دنبال کردن فرآیند یک اعتباربخشی عمومی در معنای روش‌شناسی (متدولوژی) و داده برای هر سه بسته نرم‌افزاری غیرممکن بود. در نتیجه باید به شکل دستی نمونه‌ها را تقسیم و نمونه آموزشی و نمونه اعتبارسنجی ساخته می‌شد.

در این راستا، از رویکرد اعتباربخشی ۱۰- لایه متقاطع طبقه‌بندی شده انتخاب شد که نمونه‌ها را در ۱۰ لایه تقسیم می‌کرد. در رویکرد طبقه‌بندی شده هر لایه از تعداد مساوی موارد تقلب و فاقد تقلب تشکیل شده است. برای هر لایه، مدل با استفاده ۹ لایه باقیمانده آموزش می‌دید و با لایه کنار گذاشته شده آزمون می‌شد. در پایان میانگین عملکرد محاسبه گردید. در جدول شماره (۷) اعتباربخشی ۱۰ لایه متقاطع عملکرد سه مدل خلاصه شده است.

جدول شماره ۷: نتایج حاصل از اعتباربخشی مدل‌های منتخب

Performance against the training set			
Model	Fraud (%)	Non-fraud (%)	Total (%)
ID3	75.0	72.5	73.6
NN	82.5	77.5	80.0
BBN	91.7	88.9	90.3

همانطور که انتظار می‌رفت، نسبت درستی دسته اعتباربخشی کمتر از نسبت درستی دسته آموزشی بود. هر چند عملکرد هر کدام از سه مدل به شکل شایان توجهی متفاوت بود. مدل درخت تصمیم‌گیری که در طبقه‌بندی خود به درستی ۹۶٪ نمونه‌های آموزشی را مدیریت نموده بود، کاهش شایان توجهی در درصد صحت طبقه‌بندی وقتی در مقابل نمونه اعتباربخشی قرار گرفت، از خود نشان داد. مدل به درستی ۷۳/۶٪ کل نمونه‌ها را طبقه‌بندی نمود یعنی ۷۵٪ موارد تقلب و ۷۲/۵٪ موارد فاقد تقلب. مدل شبکه عصبی که از یک عملکرد خالص ۱۰۰٪ با دسته آموزشی بهره‌مند بود، به درستی ۸۰٪ طبقه‌بندی نمونه اعتباربخشی را مدیریت نمود یعنی

شبکه گمانه زنی بیزی وابستگی بین تحریف و نسبت‌های بدھی به ارزش ویژه، سود خالص به مجموع دارایی‌ها، فروش به مجموع دارایی‌ها، سرمایه در گرددش به مجموع دارایی‌ها و امتیاز Z را آشکار نمود. هر کدام از این نسبت‌ها بازگشتی از اختلاف مورد انتظار از وضعیت مالی یک شرکت به ترتیب همچون اهرم قابلیت سودآوری، عملکرد فروش، نقد شوندگی و پریشانی مالی است. مدل درخت تصمیم‌گیری در ابتدا تحریف را با پریشانی مالی همبسته کرد، از این رو امتیاز Z را به عنوان اولین مرحله جداسازی استفاده نمود.

همانگونه که معمولاً اتفاق می‌افتد، این مطالعه می‌تواند به عنوان سنگ زیر بنای تحقیقات آتی استفاده شود. یکی از اختلافات مهم بین آزمون‌ها این بود که در مدل BBN به علت محدودیت‌های نرم افزار داده‌ها به صورت نظری بکار گرفته شد. داده‌های نظری عناصر تاثیرگذار در طرح کلی دخیل در هزینه، فقدان بعضی از اطلاعات است. پیشبرد تحقیق نیاز به تعیین عناوین داده‌های نظری، بر عملکرد مدل و عناوین الگوریتم‌های نظری تأثیر زیادی دارد. همچنان تحقیق نیازمند آزمون چگونگی این موضوع است که کدام مدل‌های داده کاوی (DM) عملکرد بهتری نسبت به بقیه ترفندها (تکنیک‌ها) دارند.

ورویدی‌های خط دهنده مبنایی در این تحقیق، مبتنی بر تحقیق spathis & manolopoulos Krikos، بوده است که تنها متشکل از نسبت‌های مالی بودند. غنی‌سازی ورودی‌های خط دهنده با اطلاعات کیفی مانند صلاحیت حسابرسان پیشین با ترکیب هیات مدیره می‌تواند درستی نسبت را افزایش دهد. از این گذشته مطالعه ویژه یک صنعت می‌تواند نتایج ویژه آن را آشکار نماید. امید است مطالعه ارائه شده در این مقاله موجبات تحقیقات بیشتر در مورد عناوین مهم این موضوع باشد.

فهرست منابع

- (۱) حسینی نسب، مرضیه و همکاران (۱۳۹۰)، «کشف تقلب در نسخ دارویی به کمک روش‌های داده کاوی و ترکیب اطلاعات Fwltext»

باشد، نیازمند ابزارهای مؤثر می‌باشد. تکنیک‌های داده کاوی که ادعا می‌شود ظرفیت‌های پیشرفته‌ای در طبقه‌بندی و پیش‌بینی دارند، توان تسهیل کنندگی برای حسابرسان در انجام وظیفه کشف تقلب مدیریتی را دارند. ادعای این مطالعه بررسی سودمندی و مقایسه عملکرد سه ترفنده (تکنیک) داده کاوی در کشف صورت‌های مالی متقلبه به وسیله استفاده از داده‌های مالی عمومی بوده است. مدل‌های بکار رفته درخت تصمیم‌گیری، شبکه‌های عصبی، شبکه‌های گمانه زنی بیزی بود.

نتایج حاصل از آزمون‌ها که مؤید نتایج تحقیقات پیشین بود به این اشاره داشت که داده‌های صورت‌های مالی، محتوى اطلاعاتی جهت کشف تحریف است. از این گذشته به طور نسبی فهرست نسبت‌های مالی کوچک به شدت تأثیر تعیین‌کننده‌ای در طبقه‌بندی دارند. این آگاهی، زوج همزمان^{۱۵} (نقطه اتصال) الگوریتم‌های داده کاوی است که می‌تواند ظرفیت مدل در رسیدن به صحت و توجه به نتایج طبقه‌بندی را تدارک ببیند.

مطالعه ارائه شده مبنی بر تجربیات تحقیقات حسابرسی و حسابداری را که توان ایجاد بهترین تمایز موارد FFS را دارد، مشارکت داده است. این مطالعه همچنان متغیرهای معینی از اطلاعات عمومی آماده که حسابرسان باید زمان حسابرسی بیشتری به آن اختصاص دهند را توصیه کرده است. چهارچوب روش شناسی پیشنهادی مورد استفاده می‌تواند کمکی برای حسابرسان داخلی و خارجی و مالیاتی و سایر اعتباردهنده‌گان، گزارشات، اشخاص حقیقی و حقوقی، سرمایه‌گذاران، معامله گران سهام، شرکت‌های وکالت، تحلیل گران اقتصادی، موسسات رتبه‌دهی اعتباری و سامانه (سیستم) بانکی باشد. برای حسابرسی حرفه‌ای این مطالعه می‌تواند در مساعدت برای شناسایی (روش‌های) پاسخگویی در برابر کشف FFS سودمند باشد.

از نظر کارایی مدل شبکه گمانه‌زنی بیزی با بهترین عملکرد، به میزان ۹۰/۳٪ صحت طبقه‌بندی از نمونه اعتباری در فرایند اعتباری‌خشی ۱۰- لایه متقاطع دست یافت. نسبت صحت مدل شبکه بندی عصبی و مدل درخت تصمیم‌گیری به ترتیب ۸۰٪ و ۷۳/۶٪ بود. نسبت خطای نوع ۱ برای هر سه مدل کم بود.

(۲) رهنمای رودپشتی، فریدون، همتی، هدی (۱۳۸۹)، «روش‌شناسی پژوهش‌های دانشگاهی تقلب و سوء استفاده‌های مالی» مجموعه مقالات اولین کنفرانس پیشگیری از تقلب و سوء استفاده‌های مالی، تهران، سالن برج میلاد، آذر ماه.

(۳) یاس (۱۳۹۰)، «کانون هدایت فکر: داده کاوی چیست؟»

- 4) <http://www.civilica.com/paper-IDMCO2-IDMCO2-035.html>
- 5) 4. Chan, P.K & et.al [1999] "Distributed data mining in credit card fraud detection" IEEE intelligent systems, November / December, pp.67-74
- 6) 5. Jans, M. Lybaert, N. & Vanhoof, K [2007] "Data mining for fraud detection: Toward an Improvement on internal control systems" <http://www.fraud>
- 7) 6. Kirkos, E, Spathis, C. and Manolopoulos, Y [2007] "Data mining techniques for the detection of fraudulent financial statement" expert systems with applications, vol.32, pp.995-1003.
- 8) 7. Lee, W. and Stolfo, S.J. [1998] "Data mining approaches for intrusion detection" sysmposium San Antonio, Texas, January 26-29.

* از آقای محمود انصار دانشجوی کارشناسی ارشد رشته مدیریت مالی واحد علوم و تحقیقات دانشگاه آزاد اسلامی که در ترجمه بخش‌هایی از مقاله مرجع همکاری داشته‌اند، تشکر و قدردانی می‌شود

یادداشت‌ها

- ¹. Data Mining
- ². Fraudulent Financial Statement (FFS)
- ³. Artificial Intelligence
- ⁴. Association of Certified Fraud Examiners
- ⁵. American Institute of Certified Public Accountants
- ⁶. Computer-Assisted Audit tools & Techniques (CAATTS)
- ⁷. Automatic Interaction Detection
- ⁸. Classification and Regression Trees
- ⁹. Neural Networks
- ¹⁰. Self-organizing maps
- ¹¹. Bayesian Belief Networks
- ¹². Sipina Research Edition
- ¹³. Nuclass7
- ¹⁴. Entropy-based
- ¹⁵. couple