

ارائه مدل پیش‌بینی فرار مالیاتی بر مبنای الگوریتم درخت تصمیم ID3

و شبکه بیزین

محمود نظریور^۱

سیدحسین نسل موسوی^۲

میرسعید حسینی شیروانی^۳

تاریخ دریافت: ۱۳۹۸/۶/۲۳، تاریخ پذیرش: ۱۳۹۹/۳/۲۱

چکیده

امروزه دانش به‌عنوان یک منبع ارزشمند و استراتژیک و نیز یک دارایی برای ارزیابی و پیش‌بینی مطرح است و ارائه این راهکارها در زمینه کشف فرار مالیاتی شرکت‌ها به بحث داغی تبدیل شده است. هدف از این تحقیق ارائه مدل جدید برای تشخیص مؤدیان مالیاتی است که فرار مالیاتی دارند. ایده اصلی مقاله از مقایسه نسبت‌های مالی شرکت مورد نظر با نسبت‌های سال گذشته و همچنین برآورد مالیات سال مورد رسیدگی از روی مالیات سال قبل گرفته شده است. الگوریتمی که در این تحقیق از آن استفاده شده مبتنی بر یک الگوریتم ترکیبی است که از ترکیب الگوریتم درخت تصمیم ID3 و شبکه بیزین تشکیل شده است. نتایج حاصل از اجرای مدل‌ها نشان می‌دهد که الگوریتم پیشنهادی با $60/58\%$ دقت، دارای بالاترین دقت صحت و با $43/76\%$ اشتباه دارای کمترین میزان اشتباه می‌باشد که از الگوریتم‌های ID3 و الگوریتم بیزین که الگوریتم‌های پایه روش پیشنهادی می‌باشند، نیز بسیار بهتر عمل می‌کند.

واژه‌های کلیدی: الگوریتم ID3، شبکه بیزین، مجموعه راف، تصمیم‌گیری سلسله‌مراتبی

۱. دانشجوی دکترای حسابداری، واحد قائم‌شهر، دانشگاه آزاد اسلامی، قائم‌شهر، ایران، mahmoodnazarpoor@yahoo.com
۲. عضو هیأت علمی گروه حسابداری، واحد قائم‌شهر، دانشگاه آزاد اسلامی، قائم‌شهر، ایران (نویسنده مسئول)، nseyedhossein2@yahoo.com
۳. عضو هیأت علمی گروه مهندسی کامپیوتر، واحد ساری، دانشگاه آزاد اسلامی، ساری، ایران، mirsaeid_hosseini@iausari.ac.ir

۱- مقدمه

مالیات به دلیل اهمیت آن در جبران مخارج عمومی و آثار اقتصادی که به همراه دارد، همواره مورد توجه تمام دولت‌ها بوده است و مطالعات متعددی پیرامون این موضوع و ابعاد مختلف آن، توسط پژوهش‌گران انجام گرفته است که فرار مالیاتی یکی از موارد مهم در این پژوهش‌ها می‌باشد و برای کشف و شناسایی آن روش‌های بسیاری ارائه می‌شود. فرار مالیاتی یکی از اجزای اقتصاد غیررسمی است که در آن، افراد قانون‌گریز به ازای فعالیت‌های قانونی انجام‌شده، تمام یا قسمتی از مالیات خود را نمی‌پردازند. در فرار مالیاتی، افراد قانون‌گریز بر خلاف قوانین و مقررات کشور فعالیت اقتصادی یا کار غیر قانونی انجام می‌دهند که از این جهت قابل مشاهده نیست و در آمارهای رسمی کشور ثبت نمی‌شود؛ اما به هر حال بررسی و شناخت علل و عوامل مؤثر بر آن اهمیت دارد. فرار مالیاتی در واردات کشور بیانگر آن است که کالاهایی به طور پنهانی و بدون پرداخت مالیات و عوارض گمرکی وارد کشور می‌شوند که این مورد از مصادیق قاچاق کالا به داخل کشور است (مداح و نعمت الهی، ۱۳۹۰). این در حالی است که هر وضعیتی از عدم تمکین که منجر به عدول از انجام تکالیف مالیاتی و قانونی اشخاص حقیقی و حقوقی گردد، نیز فرار مالیاتی به حساب می‌آید مانند عدم تسلیم اظهارنامه مالیاتی در موعد مقرر قانونی، گزارش کمتر از واقع درآمد، سود یا ثروت، گزارش بیش از واقع کسورات، ارائه اطلاعات مخدوش، تأخیر در پرداخت به موقع مالیات برای سوء استفاده از شرایط تورمی (ضیایی و طهماسبی، ۲۰۰۴).

به طور کلی، روش‌های سنتی پیش‌بینی فرار مالیاتی در صورت‌های مالی دارای برخی مفروضات محدود کننده مانند خطی بودن، نرمال بودن و مستقل بودن متغیرهای پیش‌بینی کننده یا ورودی‌ها است. نظر به اینکه در ارتباط با داده‌های مالی، تخطی از این مفروضات متصور است، این روش‌های سنتی در ارتباط با میزان کارایی و اعتبار، دارای محدودیت‌های زیادی هستند. اما روش‌های مصنوعی و از آن جمله الگوریتم ژنتیک دارای ناسازگاری و موارد تخطی کمتری در ارتباط با این مفروضات می‌باشند. یکی از برتری‌های الگوریتم ژنتیک نسبت به سایرین عدم وابستگی این الگوریتم بر فرضیه‌های آماری محدودکننده و نرمال بودن توزیع نسبت‌ها یا برابری واریانس یا کوواریانس ماتریس نسبت‌ها است (پورزمانی، ۱۳۹۲). در این بین جدیدترین روش‌هایی که می‌توان به وسیله آنها فرار مالیاتی را پیش‌بینی و کشف نمود، الگوریتم‌های یادگیری ماشین است. یادگیری ماشین فرآیند استفاده از داده‌ها است که به طور خودکار مدل می‌سازد. این ماشین به عنوان ورودی از مجموعه‌ای از ویژگی‌های شناخته شده استفاده می‌کند و به عنوان خروجی چیزی به عنوان مدلی برای پیش‌بینی ارائه می‌دهد.

با توجه به مطالب بالا، هدف از این تحقیق ارائه مدل جدید برای تشخیص مؤدیان دارای فرار مالیاتی است. ایده اصلی مقاله از مقایسه نسبت‌های مالی شرکت مورد نظر با نسبت‌های سال گذشته و همچنین برآورد مالیات

سال مورد رسیدگی از روی مالیات سال قبل گرفته شده است. الگوریتمی که در این تحقیق از آن استفاده شده مبتنی بر یک الگوریتم ترکیبی است که از ترکیب الگوریتم درخت تصمیم ID3 و شبکه بیزین تشکیل شده است. این الگوریتم‌ها بدین دلیل انتخاب شدند که هر یک به تنهایی دارای مزایا و معایبی می‌باشند ولی با ادغام آنها، معایب این روش‌ها پوشانده می‌شود و به دقت بالاتری دست یافته و همچنین برای انتخاب ویژگی نیز از الگوریتم مجموعه راف ترکیب شده با تحلیل سلسله مراتبی استفاده شده است که از مجموعه تمام نسبت‌های مالی تنها بتوان ویژگی‌ها و یا همان نسبت‌های مالی مؤثرتر را شناسایی نمود.

در این مقاله، در بخش دوم مروری بر ادبیات موضوع ارائه شده است. در بخش سوم به روش تحقیق پرداخته شده است. بخش چهارم به نتایج اجرای مدل اختصاص دارد و در نهایت، در بخش پنجم، نتیجه‌گیری و توصیه‌های سیاستی ارائه شده است.

۲- مروری بر ادبیات موضوع

۲-۱- مبانی نظری

دانستن اینکه چرا فرار مالیاتی ایجاد می‌شود، بسیار مهم است؛ چراکه بدون درک عوامل تعیین کننده فرار مالیاتی، ارائه و ارزیابی سیاستها در جهت رفع و یا کاهش آن مشکل می‌شود. مطالعات نظری، تجربی و آزمایشگاهی پیرامون فرار مالیاتی (یا تمکین مالیاتی) نشان می‌دهند که افراد عموماً نسبت به عواملی نظیر افزایش نرخ مالیات، افزایش نرخ حسابرسی، حسابرسی کاراتر، تکرار حسابرسی، انتخاب استراتژیک یا هدفمند حسابرسی، افشای عمومی نتایج حسابرسی، افزایش نرخ جریمه، انتشار اطلاعات بین سازمانهای دولتی حسابرس، افزایش پاداش برای تمکین مالیاتی، اتصال بیشتر مالیات و خدمات عمومی، افزایش مشارکت مؤدیان در تصمیمات گروهی، عفو مالیاتی، افزایش پیچیدگی و نااطمینانی در قوانین و خدمات بهتر برای مؤدیان، واکنشی قابل پیش‌بینی دارند.

تعریف فرار مالیاتی

ماناسان (۱۹۹۸) هر گونه تلاش غیرقانونی به منظور نپرداختن مالیات را فرار مالیاتی می‌خواند. این امر به طرق مختلف مانند ندادن اطلاعات لازم در مورد عواید و منافع مشمول مالیات، اظهار بیشتر از حد میزان هزینه و استفاده از رسیدهای جعلی صورت می‌پذیرد.

اشنایدر و همکارش (۲۰۰۰)^۱ فرار مالیاتی را به عنوان کاهش غیر قانونی مالیات پرداختی از طریق عدم گزارش درآمد یا اعلام نمودن نرخ‌های تفریق بالاتر تعریف می‌نمایند.

1. Schneider et al.

مدل‌های فرار مالیاتی

نظریه‌های مطرح‌شده در باب فرار مالیاتی بسیار فراوان‌اند. عده‌ای از محققان با استفاده از عوامل اقتصادی سعی در توضیح این پدیده نموده‌اند که از آن جمله، می‌توان به مطالعه آلینگهام و ساندمو (۱۹۷۲) اشاره کرد. این محققان در مطالعه مذکور موفق به ارائه مدل استاندارد مالیاتی شدند که یکی از مطرح‌ترین مدل‌ها در مورد فرار مالیاتی است. در این مدل، رفتار یک مؤدی مالیاتی ریسک‌گریز در مورد تصمیم به تمکین و یا عدم تمکین مالیاتی، در لحظه تکمیل اظهارنامه و با توجه به عقلانیت اقتصادی، مورد بررسی قرار می‌گیرد. این دسته از نظریات که تنها عوامل اقتصادی را مورد توجه قرار می‌دهند، با توجه به چندبعدی بودن فرار مالیاتی، مورد انتقادات شدیدی قرار گرفتند. این انتقادات باعث تعدیل نظریه آلینگهام و ساندمو گشت؛ به‌گونه‌ای که عده‌ای تلاش کردند که عوامل غیراقتصادی را نیز به مدل پیشین وارد کنند. در این بین، عده‌ای با نگاهی مبتکرانه به موضوع، سعی در ارائه نظریه‌هایی جدید با استفاده از رهیافت‌های علم اقتصاد رفتاری نمودند. بدین ترتیب، می‌توان دو جریان عمده را در تبیین رفتار فرار مالیاتی تمیز داد: مدل‌های نئوکلاسیکی، و تحلیل‌های علم اقتصاد رفتاری از فرار مالیاتی. همچنین، گروه دوم را می‌توان در دو دسته کلی جای داد: مدل‌های مبتنی بر تئوری مطلوبیت غیر انتظاری، و مدل‌های مبتنی بر تئوری تعاملات اجتماعی (خان‌جان، ۱۳۹۳).

عوامل مؤثر بر فرار مالیاتی

برخی از عوامل مؤثر بر فرار مالیاتی که از مطالعات مختلف استخراج شده، به شرح ذیل مورد بحث و بررسی قرار گرفته است (نوربخش، ۱۳۹۰).

ضعف در شرایط سیاسی و اجتماعی

یکی از دلایل فعالیت بنگاه‌ها در اقتصاد غیررسمی ضعف در شرایط سیاسی و اجتماعی نظیر بوروکراسی، مقررات پیچیده، فساد مالی و نظام قضائی ضعیف است. عده‌ای از این پدیده به‌عنوان سیاسی‌سازی زندگی اقتصادی یاد می‌کنند (فوئست و ریدل، ۲۰۱۹).

جانسون و همکاران (۲۰۱۶)^۱ در این باره بیان می‌کنند: «این نوع ابزار نظارتی شامل اعمال نیروهای تنظیمی بر بنگاه‌های خصوصی، توانایی سامان‌دادن و محدود کردن ورود، نظارت بر استفاده از زمین و ملکی که مشاغل خصوصی در آنها مستقرند، بستن مالیات بر مشاغل، حق واری و تفتیش بنگاه‌ها و متوقف کردن فعالیت آنها در هنگام تخطی از قوانین است. طبق معمول، بسیاری از سیاستمداران از این ابزارها برای پیگیری اهداف خود، نظیر حفظ سطح اشتغال در بنگاه‌های ویژه، حمایت دوستانه سیاسی و مجازات خصمانه سیاسی بنگاه‌ها و یارانه‌دادن به متحدان خویش استفاده می‌کنند. همچنین، سیاستمداران می‌توانند از این حق برای

1. Johnson et al.

ثروتمند شدن خود، از طریق پیشنهاد خلاصی بنگاه‌ها از قوانین، در عوض رشوه استفاده نمایند».

بار^۱ مالیاتی

بر اساس بحث بسیاری از محققان، بار مالیاتی یکی از مهمترین عوامل تعیین کننده فرار مالیاتی است. به نظر می‌رسد که افزایش در نرخ مالیات مؤثر، انگیزه بنگاه را برای فعالیت در اقتصاد غیررسمی افزایش می‌دهد و بدین ترتیب، بر میزان فرار مالیاتی افزوده می‌شود (جانسون و همکاران ۲۰۱۶).

نرخ حسابرسی

احتمال حسابرسی و کشف تخلف از دیگر عواملی است که بر اندازه اقتصاد غیررسمی و فرار مالیاتی اثرگذار است. چنانچه احتمال شناسایی و دستگیری در یک کشور بیشتر باشد، تعداد شاغلین در اقتصاد غیررسمی کمتر است. مطالعاتی نظیر مطالعه اندرونی و همکاران (۲۰۱۶) چنین ارتباطی را از تحقیق خود نتیجه‌گیری کرده‌اند.

جریمه پس از کشف تخلف

همچنین، مجازات پس از کشف تخلف از دیگر متغیرهای تأثیرگذار بر فرار مالیاتی است. اندرونی و همکاران (۲۰۱۵) ارتباط بین مشارکت در اقتصاد غیررسمی و مجازات پس از کشف را بررسی کرده و به این نتیجه رسیدند که ارتباطی منفی بین این دو برقرار است. در این باره، ریچوپان هم به نتایج مشابهی دست یافته است. او با در نظر گرفتن الگوی آیینگهام و ساندمو، اثر عوامل مختلف را بر تصمیم مؤدی و درآمد مورد انتظار وی به بحث گذاشته و نتیجه‌گیری می‌کند که: اولاً، هر چه نرخ جریمه مالیاتی بیشتر باشد، مقدار درآمد اظهار شده هم بیشتر خواهد بود و ثانیاً، با افزایش احتمال کشف تخلف، احتمال اظهار درآمد واقعی نیز افزایش می‌یابد (فرار مالیاتی کاهش می‌یابد).

۲-۲- پیشینه پژوهش

پاپا، سجادی، و ولا (۲۰۱۴) در مطالعه‌ای فرار مالیاتی و فساد را به مدل کینزی جدید با اصطکاک‌های جستجو و تطابق وارد کرده‌اند تا اثر تحکیم مالی مبتنی بر مخارج و مالیات را مورد بازنگری قرار دهند. در این مدل، مخارج عمومی تقاضا برای کالاها در بخش رسمی و غیررسمی کاهش می‌یابد و لذا، از فرار مالیاتی کاسته می‌شود. افزایش مالیات عوامل را به کار و تولید بیشتر در بخش غیررسمی وامی‌دارد. از آنجاکه بهره‌وری در بخش غیررسمی کمتر از بخش رسمی است، این سیاست زیان رفاهی و تولید بیشتری به دنبال دارد.

فرانزونی (۲۰۱۴) با بررسی و مرور نظری پژوهش‌های انجام گرفته در زمینه فرار مالیاتی و نیز تمکین مالیاتی در شرکت‌های ایتالیا عوامل مختلف تأثیرگذار بر عدم تمکین و فرار مالیاتی را شناسایی نموده و راهکارهای پیشگیری از آن را نیز مورد بررسی و آزمون قرار داده است. بر این اساس و با توجه به بررسی‌های انجام گرفته

۱. بار مالیاتی میزان وجوهی است که توسط افراد پرداخت می‌شود. این مقدار به دو قسمت بار پولی و بار واقعی قابل تقسیم است. بار پولی میزان وجوهی است که توسط مشمول مالیات قابل پرداخت است، اما بار واقعی میزان وجوهی است که توسط پرداخت‌کننده نهایی پرداخت می‌شود (جعفری صمیمی، ۱۳۸۷).

محرک‌ها و رویه‌های قانونی دولت سیاست اجرای مالیات را تعیین و بخش عمده از فرار مالیاتی و عدم تمکین مالیاتی برگرفته از خلأهای قانونی بوده است.

هاشم‌زاده و همکاران (۲۰۱۰) در بررسی تقلب مالیاتی شرکت‌ها و حسابرسی مطلوب، یکی از موارد تقلب را ادعای بیش از حد برای تخفیف مالیات بر ارزش افزوده کالاهای صادراتی می‌دانند و نشان دادند که وجود تقلب نمی‌تواند تصمیمات خروجی واقعی شرکت و سیاست‌های مالیاتی دولت را تحت تأثیر قرار دهد.

ریچاردسون (۲۰۱۰) در پژوهشی تحت عنوان عوامل تعیین کننده فرار مالیاتی، علل فرار مالیاتی را برای ۴۵ کشور منتخب جهان به صورت مقطعی بررسی نموده است. مدل ارائه شده در این تحقیق به این صورت می‌باشد که فرار مالیاتی به عنوان متغیر وابسته و سن، جنسیت، تحصیلات عمومی، سطح درآمد، منبع درآمد کشاورزی (درصد اشتغال در بخش کشاورزی)، منبع درآمد خدماتی (درصد اشتغال در بخش خدمات)، نرخ نهایی مالیات، پیچیدگی سیستم مالیاتی، انصاف مالیاتی و روحیه مالیاتی به عنوان متغیرهای توضیحی لحاظ شده است. نتایج مطالعه حکایت از آن دارد که عوامل غیراقتصادی از جمله پیچیدگی، بیشترین اثر را بر فرار مالیاتی دارند. همچنین نتایج نشان می‌دهد که سطح پایین تر پیچیدگی و سطح بالاتر تحصیلات عمومی، انصاف و روحیه مالیاتی موجب سطح پایین تری از فرار مالیاتی خواهد شد.

دستگیر و غریبی (۱۳۹۴) در کاربست روش‌های داده کاوی به منظور ارتقاء عملکرد تشخیص فرار مالیاتی روش‌ها را به طور تصادفی به سه دسته آموزش، اعتبارسنجی و آزمون تقسیم نموده‌اند. نتایج پژوهش نشان داد که روش‌های داده کاوی مبتنی بر قواعد وابستگی با ایجاد دو مدل یا درصد صحت ۹۱٪ بر روی روش‌های آموزش، با درصد صحت ۸۸٪ بر روی روش‌های اعتبارسنجی و با درصد صحت ۸۶٪ بر روی روش‌های آزمون توانسته است موفق به تشخیص فرار مالیاتی گردد.

عبدلی و همکاران (۱۳۹۴) بر اهمیت مسائل اجرایی مالیات ستانی پرداخته‌اند و با توجه به وجود اطلاعات نامتقارن در زمینه مالیات بر درآمد، برای جلوگیری از فرار مالیاتی (و افزایش درآمد مالیاتی دولت بدون گسترش پایه‌ها و افزایش نرخ‌های مالیاتی) مکانیسم حسابرسی خاصی را معرفی نموده و با استفاده از نظریه بازی‌ها و روش میدانی مورد تحلیل نظری و تجربی قرار داده‌اند. نتایج بیانگر آن است که اگر گزارش مالیاتی گروهی از مؤدیان که دارای ویژگیهای شبیه به هم می‌باشند، با هم مقایسه گردد و آنهایی که از متوسط گزارش گروه کمتر گزارش داده‌اند با احتمال بیشتر حسابرسی شوند، منجر به کاهش فرار مالیاتی، افزایش درآمدهای مالیاتی دولت (در شرایط خاص)، کاهش هزینه‌های حسابرسی و ثبات درآمدهای مالیاتی دولت خواهد شد.

رحیمی کیا و همکاران (۱۳۹۴) فرار مالیاتی را با استفاده از سیستم هوشمند ترکیبی مورد بررسی قرار دادند که نتایج نشان داد استفاده از شبکه عصبی دارای دقت بالاتری بوده و این تفاوت از لحاظ آماری معنادار می‌باشد.

در شبکه عصبی به ترتیب در صنعت مواد غذایی و نساجی دقت کلی $78/83\%$ و $84/85\%$ ، دقت تشخیص شرکت‌های فراری $31/80\%$ و $34/84\%$ و دقت تشخیص شرکت‌های سالم $20/87\%$ و $36/85\%$ می‌باشد.

نویدی (۱۳۸۴) در مطالعه‌ای مدل نظری بازی‌های ریاضی در ارتباط با گریز مالیاتی و فساد در سیستم مالیاتی را مورد بررسی قرار داده است. در این مدل مرکز کنترل مالیاتی می‌تواند بازرسان مالیاتی را از دو دسته صادق یا غیرصادق به کار گیرد. امتیاز و فرق این دو دسته در اختلاف قیمت بازرسی آن‌هاست. بازرس صادق از قیمت و هزینه بیشتری نسبت به بازرس نوع دیگر برخوردار است. از آنجا که اثبات وجود تبانی در کار بازرس ساده نیست، امکان تبانی بازرسان غیرصادق با مالیات‌دهندگان در نظر گرفته شده است. در این مطالعه، عکس‌العمل متقابل مالیات‌دهندگان و بازرسان در مقابل سه استراتژی دولت برای به کارگیری بازرسان مورد بررسی قرار گرفته است. نصر اصفهانی و همکاران (۱۳۹۱) در این پژوهشی عوامل مؤثر بر فرار مؤدیان از پرداخت مالیات با الگوی پستل را مورد بررسی قرار داده‌اند. نویسندگان به دنبال یافتن پاسخی برای این پرسش بوده‌اند که عوامل سیاسی، اقتصادی، اجتماعی، تکنولوژیکی، قانونی و محیطی (که از عوامل تشکیل‌دهنده محیط بیرونی «اجتماعی» و بر گرفته از مدل پستل است) تا چه اندازه بر فرار مؤدیان از پرداخت مالیات تأثیر دارند. در این پژوهش میدانی، از پرسش‌نامه به‌عنوان ابزار گردآوری داده‌ها استفاده شده است. جامعه آماری این مطالعه را دو گروه کارشناسان کادر تشخیص ادارات مالیاتی و مؤدیان مشاغل شهر اصفهان تشکیل می‌دهند. برای تعیین حجم نمونه هر جامعه آماری، از فرمول کوکران استفاده شده که در نهایت، حجم نمونه کارشناسان کادر تشخیص مالیاتی ۸۷ نفر و مؤدیان مشاغل ۱۹۸ نفر به دست آمد.

نتایج این تحقیق نشان می‌دهد که از نقطه نظر مؤدیان مشاغل، عوامل سیاسی و اقتصادی بیشترین تأثیر و عامل محیطی کمترین تأثیر را بر فرار مالیاتی دارند. از نظر کارشناسان کادر تشخیص، عوامل سیاسی، اقتصادی و قانونی بیشترین تأثیر و عامل محیطی کمترین تأثیر را بر فرار مالیاتی داشته‌اند.

جمشیدی نوید و همکاران (۱۳۹۸) با استفاده از شبکه‌های مصنوعی، تعداد ۱۶ عامل مربوط به عملکرد سال ۱۳۹۱ تعداد ۴۰۰ شرکت را استخراج نمودند. نتایج حاصل از این تحقیق نشان می‌دهد که شبکه‌های عصبی مصنوعی با کارایی $82/5\%$ در مقایسه با رگرسیون خطی چند متغیره، فرار مالیاتی را بهتر کشف می‌کنند.

۳- روش تحقیق

هدف این پژوهش رسیدن به مکانیزمی برای تشخیص فرارهای مالیاتی می‌باشد. در این تحقیق سعی شده است که یک روش ترکیبی استفاده شود که دارای مزایای هر یک از روش‌ها بوده و بتواند معایب این روش‌ها را با ترکیب کردن آن‌ها پوشش دهد که از روش‌های ID3 و بیزین استفاده شده است و راهکاری برای ترکیب

این دو روش ارائه شده است. ID3 در دسته بندی دارای دقت مناسبی است ولی ارتفاع درخت زیاد می شود که در این تحقیق راهکاری برای کاهش ارتفاع آن ارائه شده است. شبکه بیزین در موارد تحلیل عددی نتایج مناسبی را بدست می آورد از این رو در این تحقیق از یک راهکار ترکیبی استفاده شده است که از مزایای هر دو الگوریتم استفاده شود و برای انتخاب ویژگی مؤثرتر از مجموعه راف و AHP استفاده شده است.

۳-۱- فرضیه های پژوهش

فرضیه های اصلی

پیش بینی فرار مالیاتی با استفاده از الگوریتم های یادگیری ماشین امکان پذیر است.

پیش بینی فرار مالیاتی با استفاده از الگوریتم پیشنهادی امکان پذیر است.

فرضیه های فرعی

پیش بینی فرار مالیاتی با استفاده از مدل درخت تصمیم ID3 امکان پذیر است.

پیش بینی فرار مالیاتی با استفاده از مدل شبکه بیزین امکان پذیر است.

مدل پیشنهادی دقت بیشتری نسبت به درخت تصمیم ID3 و شبکه بیزین برای پیش بینی فرار مالیاتی دارد.

۳-۲- قلمرو پژوهش

قلمرو موضوعی: این پژوهش به دنبال ارائه مدلی ترکیبی بر مبنای الگوریتم های یادگیری ماشین به منظور پیش بینی فرارهای مالیاتی در صورتهای مالی است.

قلمرو مکانی: به منظور تشخیص شرکت های دارای فرار مالیاتی از شرکت های فاقد فرار مالیاتی می بایست مالیات شرکت مورد نظر به مرحله تشخیص رسیده باشد. از طرف دیگر شرکت های پذیرفته شده در سازمان بورس اوراق بهادار (به استثناء بانکها، بیمه ها، شرکت های سرمایه گذاری و شرکت های میانسالی) به عنوان جامعه تحقیق مورد بررسی قرار گرفت. نظر به اینکه روند رشد (مثبت یا منفی) فرار مالیاتی نیز توسط پژوهشگر محاسبه خواهد شد، لذا شرکت هایی که در هر سه سال ۱۳۹۳ لغایت ۱۳۹۵ در سایت مربوطه دارای اطلاعات مالی باشند به عنوان جامعه تحقیق مورد بررسی قرار گرفت که تعداد اعضاء جامعه ۱۱۸۶ سال/شرکت می باشد.

قلمرو زمانی: قلمرو زمانی این پژوهش دوره سه ساله حداثی سال های ۱۳۹۳ تا ۱۳۹۵ می باشد.

۳-۳- روش های گردآوری داده ها

در این تحقیق برای جمع آوری داده ها از روش کتابخانه ای و میدانی استفاده شده است. اطلاعات مربوط به مبانی نظری و تئوریک پژوهش از کتب و مقالات فارسی و لاتین جمع آوری گردیده است. منبع جمع آوری داده های مورد نیاز این پژوهش، صورتهای مالی شرکت ها بوده و از طریق بانک اطلاعات رایانه ای ره آوردنوین

و مراجعه به سامانه جامع اطلاع رسانی ناشران^۱ جمع‌آوری شده است. داده‌های جمع‌آوری شده پس از طبقه‌بندی لازم بر اساس متغیرهای مورد بررسی، با استفاده از نرم‌افزار اکسل وارد رایانه شده است. تجزیه و تحلیل نهایی به کمک نرم‌افزارهای مختلف انجام شده است. از جمله مهمترین مواردی که لازم است هنگام جمع‌آوری داده‌ها به آن توجه کرد، روایی ابزارهای گردآوری داده‌ها است. منظور از روایی ابزارهای گردآوری داده‌ها این است که ابزارها بتوانند واقعیتها را به خوبی نشان دهند از آنجا که ابزار گردآوری داده‌ها در این تحقیق، بانکهای اطلاعاتی تهیه شده توسط سازمان بورس اوراق بهادار تهران و یا کتابخانه سازمان بورس اوراق بهادار تهران است؛ لذا می‌توان به روایی ابزارهای گردآوری داده‌ها اعتماد کرد.

۴- تشریح مدل پیشنهادی

جامعه مورد مطالعه در این پژوهش عبارت است از شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران و نمونه مورد استفاده متشکل از دو گروه شرکت‌های دارای فرار مالیاتی و شرکت‌های فاقد فرار مالیاتی خواهد بود. طبق مفاد ماده ۱۹۴ ق.م.م. در صورتی که درآمد مشمول مالیات قطعی شده با درآمد مشمول مالیات ابرازی واحد تجاری بیش از ۱۵٪ اختلاف داشته باشد علاوه بر تعلق جرایم مقرر مربوط که قابل بخشودن نیز نخواهد بود تا سه سال بعد از ابلاغ مالیات مشخصه قطعی از هرگونه تسهیلات و بخشودگی‌های مقرر در قانون مالیاتها نیز محروم خواهند شد. برای تشخیص و طبقه‌بندی واحدهای اقتصادی به شرکت‌های دارای فرار مالیاتی یا فاقد فرار مالیاتی از نصاب ماده فوق و بررسی پژوهش‌های انجام شده، و از رابطه زیر استفاده می‌شود:

$$\Delta\% = [(TAXIN - ACCIN) / TAXIN] \times 100$$

$\Delta\%$: درصد اختلاف درآمد مشمول مالیات ابرازی و درآمد مشمول مالیات قطعی شرکت i در سال t

ACCIN: درآمد مشمول مالیات ابرازی شرکت i در پایان سال مالی (t)

TAXIN: درآمد مشمول مالیات قطعی شرکت i در پایان سال مالی (t)


بدین ترتیب به‌وسیله معیارهای فوق ابتدا لیستی از شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران که بین سال‌های ۱۳۹۳ تا ۱۳۹۵ مرتکب فرار مالیاتی در صورت‌های مالی شده‌اند، تهیه می‌شود. سپس با استفاده از درخت تصمیم و الگوریتم بیزین به دنبال ارائه راهکاری می‌باشیم که به وسیله آن بتوان تصمیمات مهمی را در زمینه تشخیص فرارهای مالیاتی و همچنین جلوگیری از آن‌ها ارائه نمود. در این تحقیق برای اینکه بتوان به دقت بالاتری در روش پیشنهادی دست یافت می‌بایست ابتدا با استفاده از داده کاوی سیستم مورد آموزش

1. <http://www.rdis.ir> و <http://www.codal.ir>

قرار گیرد. با استفاده از این راهکار پیشنهادی برای هر یک از این الگوریتم‌ها وزنی در نظر گرفته می‌شود و برای محاسبه و پیش‌بینی مقدار محاسبه شده توسط هر یک از این الگوریتم‌ها در وزن آن الگوریتم ضرب می‌شود و در انتها نتیجه واقعی بدست می‌آید که دارای دقت بالاتری خواهد بود زیرا از فواید هر دو این الگوریتم‌ها استفاده نموده است.

روش پیشنهادی دارای مراحل مختلفی می‌باشد که به ترتیب عبارتند از : ۱- پیش پردازش روش‌ها
۲- انتقال روش‌ها ۳- انتخاب ویژگی‌های مؤثر با استفاده از مجموعه راف و AHP ۴- ساخت درخت تصمیم‌گیری ۵- ساخت الگوریتم بیزین ۶- آموزش و محاسبه اوزان الگوریتم‌های درخت تصمیم ID3 و الگوریتم بیزین، فلوچارت کلی روش پیشنهادی را می‌توان در نمودار (۱) مشاهده نمود.

نمودار (۱)- فلوچارت روش پیشنهادی



منبع: یافته‌های پژوهش

۳-۵- انتقال روش‌ها

در این قسمت روش‌ها در دامنه‌های درست قرار می‌گیرند. بدین معنا که روش‌ها باید به رنج‌هایی که در سیستم مشخص شده است منتقل شوند و روش‌های خارج از رنج، روش‌های مشکل دار بوده و می‌بایست حذف شوند. روش‌ها می‌بایست در رنج درست قرار بگیرند بدین معنا که برای مثال اگر فیلد سن وجود داشته باشد فردی که محدوده سنی بین ۵۵ تا ۷۰ دارد می‌بایست در سیستم به صورت خیلی پیر شود که این قسمت به صورت اتوماتیک از روی دیتاست تکمیل می‌شود.

۳-۶- انتخاب ویژگی‌های مؤثر با استفاده از مجموعه راف

بسیاری از مفاهیم و تئوری‌های عدم قطعیت نظیر مجموعه‌های فازی، سیستم‌های خاکستری و مجموعه‌های راف، در گذشته معرفی شده و در سال‌های اخیر ابزارهای ریاضی مبتنی بر آن‌ها با سرعت بالایی توسعه یافته‌اند. هریک از این رویکردها، مفاهیم خاص خود را داشته و دارای ویژگی‌های منحصر به خود می‌باشد. تئوری خاکستری به کنترل سیستم‌ها در شرایط کمبود روش‌ها و اطلاعات ناکامل پرداخته و تئوری راف، تقریب و استدلال درباره روش‌ها را بدنبال دارد. روش‌هایی که از دنیای واقعی اخذ می‌گردند معمولاً شامل تمامی انواع نویزها بوده و عدم قطعیت بسیار و اطلاعات غیر کامل فراوانی به همراه دارند.

مجموعه راف ابزاری قابل استفاده در شرایط ابهام و عدم قطعیت است. یک عدد راف دارای حد پایین (L)، حد بالا (U) و حد میانی که به فاصله مرزی راف^۱ مشهور است تشکیل شده است. اعداد راف در مسائلی استفاده می‌شود که نظرات خبرگان در آن دخیل هستند و به نوعی باعث ایجاد عدم قطعیت و ابهام بشود. برای استفاده از اعداد راف در روش AHP به طریق زیر عمل می‌کنیم.

ابتدا مقایسات زوجی خبره‌ها را از نظر نرخ ناسازگاری بررسی کرده و چنانچه نرخ ناسازگاری کمتر از ۰/۱ باشد یعنی مقایسه زوجی سازگار است و در صورتی که بزرگتر از ۰/۱ باشد باید اعداد مقایسه زوجی اصلاح شود. ایجاد اعداد راف از اعداد خبره‌ها با استفاده از روابطی که در تئوری گفته شد. محاسبه وزن فاصله‌ای معیارها با استفاده از روش میانگین هندسی بعد از پیاده‌سازی گام‌های تئوری راف وزن معیارها به صورت زیر محاسبه می‌شود:

$$W = \{w_1, w_2, w_3, w_4, w_5, w_6, w_7\}$$

$$= \{[2/90.2, 3/556], [0.428, 0.506, 0.198, 1/0.73], [2/663, 3/123],$$

$$[1/563, 1/935], [0.595, 0.703], [0.216, 0.254]\}$$

در این تحقیق نیز ما از خبرگانی استفاده نمودیم که برای انتخاب ویژگی‌های مؤثر کمک نمودند و در این حالت بهترین نسبت‌های مالی انتخاب شدند.

1. Rough Boundary Interval

۵- ساخت درخت تصمیم‌گیری

ویژگی‌هایی که برای شناسایی فرارهای مالیاتی در نظر گرفته می‌شوند و به عنوان پارامترهای تأثیرگذار شناسایی شدند در این مرحله می‌بایست به عنوان گره‌های درخت در نظر گرفته شوند ولی اینکه هر یک از این ویژگی‌ها در کدام گره قرار گیرند و یا در چه سطحی از درخت قرار گیرند بسیار مهم می‌باشد. از طرفی چون در این قسمت در راهکار پیشنهادی تفاوتی ندارد که روی چه دیتا ستی کار شود و صرفاً یک مدل بهینه برای پیش‌بینی ارائه می‌شود در این قسمت ویژگی‌ها به صورت A، B و ... در نظر گرفته می‌شود چرا که می‌تواند هر ویژگی‌ای باشد. درخت ID3 یک درخت تصمیم‌گیری می‌باشد که دارای یادگیری نیز می‌باشد و اولین بار توسط راس کوینلن مطرح شد. ایده الگوریتم ID3، ساخت درخت تصمیم‌گیری بالا به پایین می‌باشد که انتخاب گره در آن به وسیله جستجوی حریصانه از میان مجموعه‌ای از صفت‌ها می‌باشد و برای اینکه قادر باشیم تا مفیدترین صفت را از میان صفات بیابیم که در کلاسه‌بندی مفیدتر باشد از الگویی به خصوص استفاده نمودیم. برای اینکه بتوان کلاسه‌بندی مفیدی را برای مجموعه یادگیری انجام داد، می‌بایست تعداد سؤالات را کاهش داد یا می‌توان گفت می‌بایست عمق درخت تصمیم‌گیری را کاهش داد. از این رو در این قسمت نیاز به تابعی است که قادر باشد تا متعادل‌ترین تقسیم را انجام دهد که در این صورت عمق درخت بسیار کاهش می‌یابد و گره‌ها به صورت متعادل در درخت تقسیم می‌شوند.

$$G(S, A) = Entropy(S) - \sum_{v \in Values(A)} Entropy(v)$$

۶- ساخت شبکه بیزین

شبکه‌های بیزین متعلق به ساختار دیگری از مدل‌های گرافیکی به نام گراف‌های غیرمدور جهت‌دار هستند که در زمینه‌های آماری، یادگیری ماشینی و هوش مصنوعی بسیار مشهورند. شبکه‌های بیزین نمایش و محاسبات مؤثری از توزیع احتمالاتی مشترک به روی یک سری متغیر تصادفی را فراهم می‌آورند. به علاوه شبکه‌های بیزین شدت ارتباط بین متغیرها را به صورت کمی مدل می‌کنند که اجازه می‌دهند با دسترسی به اطلاعات جدید، اعتقاد شرطی در مورد آنها به صورت خودکار به روز رسانی شود.

یادگیری شبکه‌های بیزی

در هر شبکه بیزی ساختار آن و جداول احتمالات شرطی تعیین کننده آن هستند. بنابراین، باید بتوان با فرایند یادگیری این دو مورد را تعیین کرد. برای یادگیری خودکار ساختار شبکه یکی از روش‌های اصلی بر پایه تعیین وابستگی بین متغیرها بنا نهاده شده است. برای تعیین این وابستگی‌ها معیارهای زیادی مانند معیار

آنتروپی طراحی شده‌اند. با استفاده از این معیارها، وابستگی هر متغیر X_i را نسبت به متغیرهای $X_1, \dots, X_{i-1}$ می‌سنجیم. پس از تعیین ساختار، اگر مقدار همه متغیرها به طور کامل قابل مشاهده باشند، از تخمین احتمال معمولی (گرفتن تعدادی نمونه و شمردن تعداد اتفاقات یک رویداد در این مجموعه نمونه) استفاده می‌کنیم. اگر بعضی از متغیرها قابل مشاهده نباشند، با استفاده از آموزش یک شبکه نورونی می‌توان مقادیر جداول احتمالات شرطی را یاد گرفت.


الگوریتم شبکه بیزین در روش پیشنهادی

در این مرحله در ابتدای کار نرمال سازی انجام می‌شود و سپس نتایج استخراج شده از نرمال سازی، قسمتی از این روش‌ها به عنوان روش‌های آموزش استفاده شده و مدل شبکه بیزین ایجاد می‌شود و سپس با استفاده از روش‌های تست وزن این الگوریتم محاسبه می‌شود تا اینکه بتوان در ادامه میزان تأثیرگذاری این قسمت از الگوریتم را محاسبه نمود.

۷- آموزش و محاسبه اوزان الگوریتم‌های درخت تصمیم ID3 و الگوریتم شبکه بیزین

در ابتدا درصدی از مجموعه دیتاست مورد استفاده برای محاسبه آموزش و محاسبه وزن مورد استفاده قرار می‌گیرد. از آنجا که الگوریتم ترکیبی از دو الگوریتم درخت تصمیم و الگوریتم شبکه بیزین استفاده شده بنابراین این دو الگوریتم هر کدام سهمی از جواب نهایی را خواهند داشت که بدین شکل دقت سیستم افزایش می‌یابد. می‌توان نمایی از این مرحله را در نمودار ۲ مشاهده نمود.

نمودار (۲) - فلوجارت آموزش و محاسبه اوزان



منبع: یافته‌های پژوهش

همانطور که در نمودار (۲) مشاهده می‌شود الگوریتم پیشنهادی با استفاده از مجموعه داده‌ای در ابتدا به محاسبه وزن می‌پردازد و این محاسبه بدین شکل می‌باشد که هر الگوریتم با استفاده از ۷۰ درصد دیتاست موجود آموزش می‌بیند. در نهایت با توجه به تعداد جواب‌های صحیح امتیاز و یا وزنی به آن تعلق می‌گیرد تا اینکه با استفاده از وزن تعلق گرفته بتوان در مرحله بعدی وزنی را برای خروجی هر الگوریتم در نظر گرفت. همانطور که در معماری نیز می‌توان مشاهده نمود بعد از محاسبه وزن که به صورت تقسیم تعداد جواب‌های درست به تعداد کل جواب‌های حدس زده شده می‌باشد، می‌توان میزان تأثیرگذاری هر کدام از این الگوریتم‌ها را در خروجی نهایی بهتر تشخیص داد. بعد از محاسبه وزن‌ها، به ازای هر رکورد، پیش‌بینی‌ای توسط الگوریتم شبکه بیزین و توسط درخت تصمیم ID3 صورت می‌گیرد که مقدار پیش‌بینی شده می‌بایست در وزن آن الگوریتم ضرب شود و خروجی نهایی

پیش‌بینی الگوریتم برابر است با جمع نتایج هر یک از الگوریتم ضرب در وزن آن الگوریتم که بدین صورت نتیجه نهایی بدست می‌آید و دسته بندی درست صورت می‌گیرد.

۸- روش انتخاب روش‌های آزمون و تست

روشی که برای انتخاب داده‌های آزمون و تست مورد استفاده قرار گرفته است، روش Cross Fold K Validation است. در این گزارش مقدار k برابر مقدار متعارف ۱۰ قرارداد شده است. زیرا اثبات شده است که این مقدار بهترین نسبت برای ارزیابی روش‌های داده کاوی می‌باشد بنابراین در این تحقیق نیز از همین تعداد استفاده شده است. روش‌ها در ابتدا توسط برنامه به فرمت مناسب برای تحلیل قرار می‌گیرد یا به عبارتی پیش پردازش ابتدایی صورت می‌گیرد. فایلی با فرمت ARFF ایجاد می‌شود که ساختاری مناسب و استاندارد برای تحلیل می‌باشد و در حین کار از کتابخانه‌هایی نیز کمک گرفته شده است که عبارتند از:

- Weka¹: این نرم‌افزار، یک واسط همگون برای بسیاری از الگوریتم‌های یادگیری متفاوت، فراهم کرده است که از طریق آن روش‌های پیش پردازش، پس از پردازش و ارزیابی نتایج طرح‌های یادگیری روی همه مجموعه‌های داده موجود، قابل اعمال است. نرم افزار Weka، پیاده سازی الگوریتم‌های مختلف یادگیری را فراهم می‌کند و به آسانی می‌توان آنها را به مجموعه‌های داده خود اعمال کرد.

۹- نتایج اجرای مدل

بعد از اجرای برنامه می‌توان به خروجی‌هایی دست یافت که در ادامه هر یک از این خروجی‌ها مورد بررسی قرار می‌گیرند.

جدول (۱) - نسبت درصد صحت پیش‌بینی‌ها و خطای پیش‌بینی‌ها

درصد صحت پیش‌بینی‌ها		درصد خطای پیش‌بینی‌ها
الگوریتم پیشنهادی	۶۰/۵۸٪	۴۳/۷۶٪
الگوریتم بیزین	۵۶/۰۷٪	۴۳/۹۳٪
الگوریتم ID3	۵۱/۲۶٪	۴۸/۷۳٪

منبع: یافته‌های پژوهش

با توجه به نتایج دریافتی می‌توان به وضوح مشاهده نمود که الگوریتم پیشنهادی با ۶۰/۵۸٪ دقت دارای بالاترین

1. Waikato Environment for Knowledge Analysis

دقت صحت و با ۴۳/۷۶٪ اشتباه دارای کمترین میزان اشتباه می‌باشد. کاملاً مشخص است که الگوریتم پیشنهادی از باقی بهتر و از خود الگوریتم‌های ID3، الگوریتم بیزین و ماشین بردار پشتیبان که الگوریتم‌های پایه روش پیشنهادی می‌باشند، نیز بسیار بهتر عمل می‌کند. در جدول (۲) خطای میانگین مربعات برای روش‌های مورد بررسی نشان داده شده است.

جدول (۲) - خطای میانگین مربعات (MSE) برای روش‌های مختلف مورد بررسی

خطای میانگین مربعات (MSE)	
۰/۴۹۵	الگوریتم پیشنهادی
۰/۵۲۵	الگوریتم بیزین
۰/۶۷۵	الگوریتم ID3

منبع: یافته‌های پژوهش

می‌توان در جدول (۲) مشاهده نمود که روش پیشنهادی دارای کمترین خطای میانگین مربعات می‌باشد و این نشان از عملکرد مناسب تر و دقت بالاتر روش پیشنهادی می‌باشد. می‌توان مشاهده کرد که روش پیشنهادی از بیزین بهتر، بیزین از ID3 بهتر عمل کرده‌اند. در جدول (۳) می‌توان میانگین قدر مطلق خطا (MAE) را برای روش‌های مختلف مورد بررسی در این تحقیق را مشاهده نمود.

جدول (۳) - خطای میانگین قدر مطلق (MAE) برای روش‌های مختلف مورد بررسی

خطای میانگین قدر مطلق (MAE)	
۰/۴۷۷	الگوریتم پیشنهادی
۰/۴۷۸	الگوریتم بیزین
۰/۴۷۲	الگوریتم ID3

منبع: یافته‌های پژوهش

می‌توان مشاهده نمود که از منظر خطای میانگین قدر مطلق، الگوریتم ID3 دارای خطای کمتری می‌باشد و روش پیشنهادی تنها از الگوریتم بیزین بهتر عمل کرده است.


جدول (۴) - خطای جذر میانگین مربعات (RAE) برای روش‌های مختلف مورد بررسی

خطای جذر میانگین مربعات (RAE)	
۱۰۰/۲۹۵	الگوریتم پیشنهادی
۱۰۰/۴۷۹	الگوریتم بیزین
۹۹/۲۸۱	الگوریتم ID3

منبع: یافته‌های پژوهش

در جدول (۴) نیز خطای جذر میانگین مربعات روش پیشنهادی از روش بیزین کمتر و از روش ID3 بیشتر است. در ادامه نمودارهای بدست آمده از برنامه‌نویسی، مورد بررسی قرار گرفته است. اولین نمودار، نمودار مربوط به درصد پیش‌بینی صحیح در میان روش‌های آزمون می‌باشد که می‌توان در نمودار (۳) مشاهده نمود.

نمودار (۳) - نمودار درصد پیش‌بینی‌های صحیح



منبع: یافته‌های پژوهش

همانطور که می‌توان از این نمودار دریافت روش پیشنهادی ما دارای دقت پیش‌بینی صحیح بیشتری نسبت به دیگر الگوریتم مورد بررسی یعنی شبکه بیزین و الگوریتم ID3 می‌باشد. این بدین دلیل می‌باشد که ما در روش پیش‌بینی خود تنها مواردی از روش‌های آزمون را در نظر گرفتیم که تأثیر بیشتری را در نتیجه خروجی

داشتند و در نتیجه روش‌هایی که در خروجی تأثیر نداشتند را استفاده نکردیم و بدین شکل زمان تحلیل را بسیار کاهش دادیم و حال آنکه الگوریتم‌های دیگر به دلیل استفاده از تمامی پارامترها دارای دقت کمتری هستند زیرا ممکن است بعضی از پارامترها دارای مقادیر دوری باشند که ممکن است هیچ تأثیری در نتیجه خروجی نداشته باشند ولی چون در الگوریتم‌های دیگر در ساخت مدل برای پیش‌بینی این پارامترها مورد استفاده قرار گرفته‌اند، باعث ایجاد نویز و کاهش دقت می‌شوند و در روش پیشنهادی ما چون این پارامترها، وجود نداشتند در نتیجه دقت افزایش یافته است و از دیگر الگوریتم‌ها بهتر عمل نموده است. همچنین در الگوریتم پیشنهادی از مجموعه راف و الگوریتم سلسله مراتبی برای محاسبه میزان تأثیرگذاری هر یک از ویژگی‌ها در این تحقیق استفاده شده است.

می‌توان مشاهده نمود که با توجه به جدول (۵) پارامترهای Att18 (بهای تمام شده کالای فروش رفته به فروش) و Att22 (لگاریتم طبیعی دارایی‌ها) بیشترین تأثیر را در خروجی دارند و این در حالی است که پارامترهایی همچون Att25 (دارایی ثابت به جمع دارایی‌ها) و Att24 (موجودی کالا به مجموع دارایی‌ها) کمترین تأثیر را در خروجی دارند. پارامترهایی که به طور کلی دارای کمترین تأثیر در خروجی می‌باشند باعث می‌شوند که نویز در روش‌ها ایجاد شود و علاوه بر اینکه زمان محاسبه را افزایش می‌دهند، دقت را نیز کاهش می‌دهند.


جدول (۵) - جدول نسبت‌های مالی

Att25 : 0/00381343240260058
 Att24 : 0/00427858327479137
 Att20 : 0/00618257889138079
 Att27 : 0/00657365841869104
 Att16 : 0/00736528292505495
 Att14 : 0/0073653915490675
 Att1 : 0/00908759998099143
 Att9 : 0/00935322974807349
 Att17 : 0/00956439270753895
 Att28 : 0/0142025287136042
 Att6 : 0/0142627546874609
 Att2 : 0/0142700407731494
 Att12 : 0/0143807664233505
 Att23 : 0/0185360752681333
 Att26 : 0/0190464464415216
 Att8 : 0/0221482127190511
 Att21 : 0/0237633163633828
 Att11 : 0/0250140506889554
 Att13 : 0/0285061366212412
 Att15 : 0/0349809449035666
 Att4 : 0/0378112532648968
 Att10 : 0/0390482265755149
 Att3 : 0/0401621969319288
 Att5 : 0/0510222259309194
 Att19 : 0/0515867611609809
 Att7 : 0/0523728800527696
 Att22 : 0/062060175951289
 Att18 : 0/0630793576406058

منبع: یافته‌های پژوهش

در نمودار (۴) می‌توان درصد پیش‌بینی غلط را مشاهده نمود. با توجه به این نمودار می‌توان درک نمود که روش پیشنهادی به همان دلیل که پیش‌تر در رابطه با درصد پیش‌بینی درست گفته شد از باقی روش‌ها دارای مقدار کمتری است یعنی پیش‌بینی اشتباه کمتری دارد بنابراین روش پیشنهادی بهتر از باقی روش‌ها عمل کرده است.

نمودار (۴) - نمودار پیش‌بینی‌های غلط




منبع: یافته‌های پژوهش

با توجه به نمودار (۴) می‌توان به این قضیه پی برد که روش پیشنهادی دارای کمترین تعداد خطا و در نتیجه دارای بالاترین دقت خواهد بود و این در حالی است که روش ID3 دارای بیشترین تعداد اشتباه می‌باشد و این یعنی روش ID3 از همه روش‌ها بدتر عمل نموده است. روش پیشنهادی به خوبی در اینجا نشان داده است که روش ترکیبی روش‌های مذکور می‌تواند بسیار بهتر از هر یک این روش‌ها به تنهایی عمل کند و این نشان‌دهنده انتخاب‌های درست الگوریتم‌ها برای ادغام و در نتیجه رسیدن به نتایج بهتر از دیگر روش‌های مورد بررسی می‌باشد.

می‌توان در شکل زیر مشاهده نمود که الگوریتم پیشنهادی دارای MSE کمتری از الگوریتم‌های مورد بررسی می‌باشد که البته پیش‌تر نیز این قضیه نشان داده شد و در این قسمت سعی شد تا به صورت نمودار میله‌ای نیز نشان داده شود. به طور کلی خطای MSE از دیگر پارامترهای اندازه‌گیری خطای دارای محبوبیت بیشتری می‌باشد و در اکثریت مقالات نیز تنها این پارامتر مورد بررسی قرار می‌گیرد ولی در این تحقیق سعی شد تا پارامترهای دیگر همچون RAE و MAE نیز محاسبه شود.


نمودار (۵) - نمودار MSE



منبع: یافته‌های پژوهش


در ادامه نمودارهای میله‌ای پارامترهای خطا MAE و RAE نیز نشان داده شده است.

نمودار (۶) - نمودار MAE



منبع: یافته‌های پژوهش

نمودار (۷) - نمودار RAE



منبع: یافته‌های پژوهش

برای بررسی دقیق‌تر روش پیشنهادی و دیگر روش‌ها TP، TN، FP و FN نیز مورد محاسبه قرار گرفته است.

جدول (۶) - بررسی پارامترهای TP، TN، FP و FN برای روش پیشنهادی و دیگر روش‌های مورد بررسی

FN	FP	TN	TP	
۲۳	۴۴۴	۷۰۰	۱۹	الگوریتم پیشنهادی
۱۲۲	۳۹۹	۶۰۱	۶۴	الگوریتم بیزین
۳۳۳	۲۴۵	۳۹۰	۲۱۸	الگوریتم ID3

منبع: یافته‌های پژوهش

می‌توان در جدول (۶) مشاهده نمود که روش پیشنهادی دارای مجموع TP+TN بیشتری از دیگر روش‌های مورد بررسی می‌باشد زیرا در واقع تعداد TP و TN هر چه بیشتر باشد یعنی تعداد پیش‌بینی‌های صحیح بیشتری صورت گرفته است. و هر چه تعداد FP و FN کمتر باشد یعنی تعداد پیش‌بینی‌های غلط کمتری صورت گرفته است. تعداد کل روش‌های استفاده شده ۱۱۸۶ رکورد می‌باشد که چون از روش cross k fold استفاده شده است یعنی تمامی قسمت‌های روش‌ها هم برای آموزش و هم برای تست قرار گرفته است که در

این حالت اگر هر سطر در جدول (۶) جمع بسته شود به عدد ۱۱۸۶ منتهی می‌شود زیرا ۱۱۸۶ رکورد مورد تست قرار گرفته است. از پارامترهای مهم در علم داده کاوی، نرخ خطا (FPR^1) و نرخ صحت (TPR^2) عملکرد می‌باشد که این پارامترها از طریق روابط زیر نشان داده شده‌اند.

$$FPR = \frac{FP}{FP + TP}$$

$$TPR = \frac{TP}{FP + TP}$$

این دو پارامتر برای روش‌های مورد بررسی در این تحقیق محاسبه و در جدول (۷) نشان داده شده‌اند.

جدول (۷) - نرخ خطا و نرخ صحت برای روش پیشنهادی و دیگر روش‌های مورد بررسی

TPR	FPR	
۰/۴۵۲	۰/۳۸۸	الگوریتم پیشنهادی
۰/۳۴۴	۰/۳۹۹	الگوریتم بیزین
۰/۳۹۶	۰/۳۸۶	الگوریتم ID3

منبع: یافته‌های پژوهش

با توجه به جدول (۷) می‌توان دریافت که روش پیشنهادی دارای نرخ صحت بیشتری می‌باشد ولی دارای کمترین نرخ خطا می‌باشد این بدین معنا است که روش پیشنهادی خطای بسیار کمی دارد بنابراین می‌توان گفت قطعاً دارای دقت بیشتری می‌باشد. در اینجا کاملاً قابل مشاهده است که از دو الگوریتم ID3 و بیزین بهتر عمل کرده است و دارای نرخ صحت بیشتری می‌باشد و از طرفی الگوریتم ID3 نیز دارای نرخ صحت عملکرد بیشتری از بیزین می‌باشد.

یکی دیگر از پارامترهای بسیار مهم، دقت^۳ می‌باشد که در اکثر مقالات برای مقایسه روش‌ها استفاده شده است که در این تحقیق نیز برای روش‌های مختلف محاسبه شده است. دقت با استفاده از رابطه زیر بدست می‌آید.

$$ACC = (TP + TN) / (TP + TN + FP + FN)$$

1.False Positive Rate

2.True Positive Rate

3.Accuracy

در جدول (۸) دقت محاسبه برای روش‌های مورد بررسی در این تحقیق نشان داده شده است.

جدول (۸) - دقت محاسبه شده برای روش پیشنهادی و دیگر روش‌های مورد بررسی

دقت (Accuracy)	
الگوریتم پیشنهادی	۰/۶۰۶
الگوریتم بیزین	۰/۵۶۱
الگوریتم ID3	۰/۵۱۳

منبع: یافته‌های پژوهش

همانطور که نتایج می‌توان مشاهده نمود روش پیشنهادی دارای دقت بالاتری از روش بیزین و دیگر روش‌ها می‌باشد و همچنین صحت یا TPR روش پیشنهادی نیز از روش بیزین بیشتر می‌باشد که این نشان دهنده عملکرد مناسب روش پیشنهادی نسبت به روش بیزین و دیگر روش‌های مورد بررسی می‌باشد. در همین جا می‌توان مشاهده نمود که تمامی فرضیه‌ها به اثبات رسیدند زیرا راهکاری در این تحقیق بیان شده است که ترکیبی از دو روش ID3 و بیزین می‌باشد و مشاهده شد که از هر یک از این روش‌ها دارای دقت بیشتری می‌باشد و مشاهده شد که دارای نرخ صحت پیش‌بینی بیشتری از دیگر روش‌های مورد بررسی می‌باشد. در ادامه ماتریس درهم ریختگی^۱ مربوط به روش پیشنهادی و دیگر روش‌های مورد بررسی در این تحقیق نشان داده شده است. جدول یا ماتریس درهم ریختگی، نتایج حاصل از طبقه‌بندی را بر اساس اطلاعات واقعی موجود، نمایش می‌دهد. حال براساس این مقادیر می‌توان معیارهای مختلف ارزیابی دسته بند و اندازه‌گیری دقت را تعریف کرد.

جدول (۹) - ماتریس درهم ریختگی روش پیشنهادی

TP + FN: 42	FN: 23	TP: 19
FP + TN: 1144	TN: 700	FP: 444
FPR: 0.388 TPR: 0.452 Accuracy: 0.606	FN + TN: 723	TP + FP: 463

منبع: یافته‌های پژوهش

جدول (۱۰) - ماتریس درهم ریختگی روش الگوریتم بیزین

TP + FN: 186	FN: 122	TP: 64
FP + TN: 1000	TN: 601	FP: 399
FPR: 0.399 TPR: 0.344 Accuracy: 0.561	FN + TN: 723	TP + FP: 463

منبع: یافته‌های پژوهش

جدول (۱۱) - ماتریس درهم ریختگی روش ID3

TP + FN: 551	FN: 333	TP: 218
FP + TN: 635	TN: 390	FP: 245
FPR: 0.386 TPR: 0.396 Accuracy: 0.513	FN + TN: 723	TP + FP: 463

منبع: یافته‌های پژوهش

در اینجا می‌توان مشاهده نمود که روش پیشنهادی دارای دقت بالاتری می‌باشد زیرا در این جدول دارای مقدار TP و TN بیشتری از دیگر الگوریتم‌ها می‌باشد و در کنار آن نیز دارای FP و FN کمتری از دیگر الگوریتم‌های مورد بررسی در اینجا می‌باشد. زیرا هر چه یک الگوریتم دارای TP و TN بیشتری باشد، یعنی فراری بودن و یا نبودن‌ها در مجموعه داده‌های تست را به مقدار بیشتری درست تشخیص داده است و FP و FN نشان دهنده برعکس این قضیه یعنی پیش‌بینی اشتباه می‌باشد.

۱۰ - نتیجه‌گیری و توصیه‌های سیاستی

به طور کلی، فرار مالیاتی یکی از اجزای اقتصاد غیررسمی است که در آن، افراد قانون‌گریز به ازای فعالیت‌های قانونی انجام شده، تمام یا قسمتی از مالیات خود را نمی‌پردازند. این در حالی است که روش‌های پیش‌بینی فرار مالیاتی از اهمیت زیادی برخوردار است. در این میان، روش‌های سنتی پیش‌بینی فرار مالیاتی در صورت‌های مالی، دارای برخی مفروضات محدود کننده مانند خطی بودن، نرمال بودن و مستقل بودن متغیرهای پیش‌بینی کننده یا ورودی‌ها است. نظر به اینکه در ارتباط با داده‌های مالی، تخطی از این مفروضات متصور است،

این روش‌های سنتی در ارتباط با میزان کارایی و اعتبار، دارای محدودیت‌های زیادی هستند. اما روش‌های مصنوعی و از آن جمله الگوریتم ژنتیک دارای ناسازگاری و موارد تخطی کمتری در ارتباط با این مفروضات می‌باشند. یکی از برتری‌های الگوریتم ژنتیک نسبت به سایرین، عدم وابستگی این الگوریتم بر فرضیه‌های آماری محدودکننده و نرمال بودن توزیع نسبت‌ها یا برابری واریانس یا کوواریانس ماتریس نسبت‌ها است. در این بین جدیدترین روش‌هایی که می‌توان به وسیله آنها فرار مالیاتی را پیش‌بینی و کشف نمود، الگوریتم‌های یادگیری ماشین است. یادگیری ماشین فرآیند استفاده از داده‌ها است که به طور خودکار یک مدل می‌سازد. این ماشین به عنوان ورودی از مجموعه‌ای از ویژگی‌های شناخته شده استفاده می‌کند و به عنوان خروجی، مدلی برای پیش‌بینی ارائه می‌دهد.

هدف از این تحقیق ارائه مدل جدید برای تشخیص مؤدیانی است که دارای فرار مالیاتی هستند. ایده اصلی مقاله از مقایسه نسبت‌های مالی شرکت مورد نظر با نسبت‌های سال گذشته و همچنین برآورد مالیات سال مورد رسیدگی از روی مالیات سال قبل گرفته شده است. الگوریتمی که در این تحقیق از آن استفاده شده مبتنی بر یک الگوریتم ترکیبی است که از ترکیب الگوریتم درخت تصمیم ID3 و شبکه بیزین تشکیل شده است. این الگوریتم‌ها بدین دلیل انتخاب شدند که هر یک به تنهایی دارای مزایا و معایبی می‌باشند ولی با ادغام آنها، معایب این روش‌ها پوشانده می‌شود و به دقت بالاتری دست یافته و همچنین برای انتخاب ویژگی نیز از الگوریتم مجموعه راف ترکیب‌شده با تحلیل سلسله مراتبی استفاده شده است که از مجموعه تمام نسبت‌های مالی تنها بتوان ویژگی‌های مؤثرتر و یا همان نسبت‌های مالی مؤثرتر را شناسایی نمود.

نتایج حاصل از اجرای مدل‌ها که با تأیید تمام فرضیه‌ها همراه می‌باشد نشان می‌دهد که الگوریتم پیشنهادی با $60/58\%$ دقت، دارای بالاترین دقت صحت و با $43/76\%$ اشتباه دارای کمترین میزان اشتباه می‌باشد. کاملاً مشخص است که الگوریتم پیشنهادی از باقی بهتر و از خود الگوریتم‌های ID3 و الگوریتم بیزین که الگوریتم‌های پایه روش پیشنهادی می‌باشند، نیز بسیار بهتر عمل می‌کند.

به طور کلی نتایج تحقیق نشان می‌دهد که مأموران مالیاتی در هنگام رسیدگی به پرونده مؤدیان با محدودیت‌هایی مواجه هستند که مهمترین آنها، کمبود زمان و عدم تفکیک مؤدیان دارای فرار یا فاقد فرار مالیاتی (اصطلاحاً کم ریسک و پرریسک) می‌باشد، به نحوی که ممکن است برای رسیدگی یک پرونده که فاقد فرار مالیاتی می‌باشد زمان بیشتری اختصاص یابد و برعکس برای رسیدگی به پرونده‌ای که دارای فرار مالیاتی می‌باشد زمان کمتری اختصاص یابد و نهایتاً سازمان مالیاتی را از رسیدن به اهدافش که مهمترین آنها وصول مالیات می‌باشد باز دارد و یا هزینه‌های وصول مالیات را افزایش دهد. در این تحقیق جهت شناسایی فرار مالیاتی مؤدیان، با استفاده از اطلاعات پرونده مالیاتی و همچنین اطلاعات استخراجی از سایت بورس اوراق

بهدار، مدل‌هایی مبتنی بر یادگیری ماشین و هوش مصنوعی ارائه شد که چنانچه سازمان مالیاتی از این مدل‌ها استفاده نماید می‌تواند قبل از رسیدگی مالیاتی، مؤدیان را به دو دسته دارای فرار مالیاتی و فاقد فرار مالیاتی تقسیم بندی کند تا با برنامه‌ریزی بهتر و دقیق‌تر، زمان بیشتر برای رسیدگی به پرونده مالیاتی مؤدیان دارای فرار مالیاتی اختصاص یابد و درنهایت با هزینه کمتر، مالیات بیشتر وصول نموده و باعث افزایش کارایی سازمان مالیاتی شود. به عبارت دیگر، در مقالات اقتصادی فرار، میزان فرار مالیاتی با استفاده از الگوهای مختلف اقتصادی پیش‌بینی می‌شود. در مقالات حسابداری فرار، غالباً بر اساس پرسشنامه به تبیین فرار مالیاتی و اثرات آن پرداخته می‌شود. لیکن در مقاله حاضر با استفاده از نسبت‌های مالی شرکت‌ها و روش‌های هوش مصنوعی، قبل از رسیدگی مالیاتی مشخص می‌شود که پرونده مؤدی مالیاتی دارای فرار می‌باشد یا خیر؟ سرعت و دقت بالای روش‌های یادگیری ماشین و همچنین قابلیت تغییر و تکمیل ورودی‌های سیستم، ویژگی‌هایی هستند که سازمان مالیاتی در صورت استفاده از هوش مصنوعی، می‌تواند از آنها به نحو مطلوب استفاده نماید و دقت تشخیص فرار مالیاتی را بیش از پیش نماید.

بر این اساس، می‌توان پیشنهادات تحقیق را به شرح ذیل ارائه کرد:

الف) در این روش پیشنهادی از مجموعه راف و روش تصمیم‌گیری سلسله‌مراتبی برای انتخاب ویژگی‌های تأثیرگذار استفاده شده است. این روش دارای دقت بالاتری است ولی می‌توان از راهکارهای دیگری نیز برای این کار استفاده نمود که برای نمونه می‌توان به روش ترکیبی ژنتیک و شبکه‌های عصبی اشاره کرد. زیرا روش‌های ژنتیک و عصبی دارای سرعت بسیار بالاتری از روش استفاده شده در این تحقیق می‌باشد.

ب) می‌توان روش پیشنهادی را با بهبود در الگوریتم C4.5 نیز استفاده نمود یعنی روش پیشنهادی را روی C4.5 با بهبودی مشابه بهبودی که روی ID3 در این تحقیق انجام شد، انجام داد تا عملکرد آن افزایش یابد البته نمی‌توان به‌طور قطع گفت که عملکرد آن بهتر می‌شود بلکه می‌بایست این روش مورد آزمایش قرار گیرد تا صحت عملکرد بررسی شود.

فهرست منابع

۱. مداح، مجید، نعمت الهی، سمیه (۱۳۹۰). بررسی و تحلیل اثر نرخ تعرفه بر فرار مالیاتی در واردات ایران، پژوهشنامه مالیات، شماره ۱۲، ۹-۲۵.
۲. ضیائی بیگدلی، محمدتقی، طهماسبی بلداجی، فرهاد (۱۳۸۴). مالیات بر ارزش افزوده (مالیات مدرن) تهران: پژوهشکده امور اقتصادی.
۳. خان جان، علیرضا (۱۳۹۳). پتانسیل فرار و تقلب در نظام مالیات بر ارزش افزوده، بازخورد تجربه عملیاتی کشورهای در حال توسعه، مجله اقتصادی.
۴. نصر اصفهانی، مهدی، نصر اصفهانی، مهرناز، دلوی اصفهان، محمدرضا (۱۳۹۱). بررسی عوامل مؤثر بر فرار مالیاتی از دیدگاه مؤدیان و کارشناسان مالیاتی. پژوهش‌های مالیه اسلامی، ۱(۱)، ۲۷-۳۶.
۵. نویدی، حمیدرضا (۱۳۸۴). مدل مالیاتی بازی‌های ریاضی در وضعیت گریز مالیاتی و تبانی. مجله تحقیقات اقتصادی، ۶۹ (۲)، ۲۶۱-۲۷۶.
۶. صمدی، علی‌حسین، تابنده، رضیه (۱۳۹۲). فرار مالیاتی در ایران (بررسی علل و آثار و برآورد میزان آن). پژوهشنامه مالیات، ۱۹ (۳)، ۷۷-۱۰۶.
۷. روستا، محمود، حیدریه، سیدعبدالله (۱۳۹۳). رتبه بندی علل فرار مالیاتی به روش AHP پژوهشنامه مالیات، ۲۴ (۴)، ۱۵۷-۱۷۳.
۸. نوربخش، محسن (۱۳۷۷). کد اقتصادی، سیستم گردش پول و کالا و نقش آن در وصول مالیات (تجربه جمهوری اسلامی ایران). مجله تحقیقات اقتصادی، ۵۲ (بهار و تابستان)، ۱-۴۲.
۹. دستگیر، محسن، غریبی، مریم (۱۳۹۴). کاربست روش‌های داده کاوی به منظور ارتقای عملکرد تشخیص فرار مالیاتی، فصلنامه پژوهشنامه مالیات، شماره ۲۶، ۹۵-۱۱۶.
۱۰. عبدلی، قهرمان، ابریشمی، حمید، حسینی فرد، سیدمحمد (۱۳۹۴). تحلیل نظری و تجربی حسابرسی مالیاتی مطلوب در مالیات بر درآمد جهت کاهش فرار مالیاتی، فصلنامه پژوهشنامه مالیات، شماره ۲۸.
۱۱. رحیمی کیا، اقبال، محمدی، شاپور، غضنفری، مهدی (۱۳۹۴). تشخیص فرار مالیاتی با استفاده از سیستم هوشمند ترکیبی، فصلنامه پژوهشنامه مالیات، شماره ۲۶، ۱۳۵-۱۶۳.
۱۲. قانون مالیات‌های مستقیم، مصوب ۱۳۹۴/۴/۳۱.
۱۳. جعفری صمیمی، احمد (۱۳۸۷)، اقتصاد بخش عمومی ۲، تهران، نشر سمت، ۲۰.
۱۴. جمشیدی نوید، بابک، ناصرآبادی، دلیر، طاهرآبادی، علی اصغر، قنبری، مهرداد (۱۳۹۸). کشف فرار مالیاتی اشخاص حقوقی: مقایسه کارایی رگرسیون خطی چند متغیره و شبکه‌های عصبی مصنوعی، فصلنامه پژوهشنامه مالیات، شماره ۴۰، ۱۵۷-۱۸۵.

15. Manasan, R. G. (1988). Tax Evasion in the Philippines 1981–1985. *Journal of Philippine Development*, 27(2), 167- 190.
16. Fuest, C. & Riedel, N. (2019). Tax Evasion, Tax Avoidance and Tax Expenditures in Developing Countries: A Review of the Existing Literature (Report prepared for the UK Department for International Development (DFID), June 19th.
17. Sandmo, A. (2005). The Theory of Tax Evasion: A Retrospective View. *National Tax Journal*, 58(4), 643–666.
18. Schneider, F., & Enste, D. H. (2000). Shadow Economies: Size, Causes, and Consequences. *Journal of Economic Literature*, 38(1), 77–114.
19. Franzoni, A., (2014). Tax Evasion and Social Interactions, Cirano Working Papers, *Journal of Public Economics*.18.
20. Hashimzade, Nigar, Huang, Zhanyi, and Myles, Gareth D. (2010). Tax Fraud by Firms and Optimal Auditing, *International Review of Law and Economics*, Volume 30, Issue 1, 10-17.
21. Richardson, L., (2010). *The Underground Economics: Tax Evasion and Detections Information*, Cambridge University Press.

