

اولویت‌بندی مکانیزم‌های داده‌کاوی در بانکداری الکترونیک با استفاده از روش تاپسیس فازی

محمد عرفان میرزا‌یی^۱، محمد خلیلی^۲

^۱ گروه کامپیوتر، دانشکده فنی مهندسی، واحد خمین، دانشگاه آزاد اسلامی، خمین، ایران.

^۲ گروه کامپیوتر، دانشکده فنی مهندسی، واحد خمین، دانشگاه آزاد اسلامی، خمین، ایران.

نام نویسنده مسئول:

محمد خلیلی

چکیده

بانکداری الکترونیک نیازمند بررسی و کشف اطلاعات گوناگونی از میان انبوه اطلاعات انباشته خود بر اساس مکانیزم‌های داده‌کاوی هستند. با افزایش خدمات بانک‌ها در اینترنت و رشد تراکنش‌های برخط توسط مشتریان، میزان بروز جرایم در صنعت بانکداری الکترونیک نیز به سرعت در حال رشد است؛ در این راستا بانک‌ها می‌توانند با بکارگیری روش‌های داده‌کاوی جدید بر اساس روش تاپسیس فازی به کشف تقلب و به پیشگیری و حذف فرایندهای حامی این گونه اعمال بپردازنند. لذا هدف از پژوهش حاضر اولویت‌بندی مکانیزم‌های داده‌کاوی در بانکداری الکترونیک با استفاده از تاپسیس فازی است. روش پژوهش حاضر به صورت تحلیلی توصیفی و با استفاده از پرسشنامه انجام گرفته است. در این پژوهش تمام مقالاتی که از الگوریتم‌های Naive Bayes، SVM، C5، CHAID، CART، Logistic-R ANN، QUEST، Discriminant K-mens و RANN در بانکداری الکترونیک استفاده کرده‌اند، جمع‌آوری شده است. با استفاده از پرسشنامه، نظرات ۵ نفر از کارشناسان و استادی، جمع‌آوری شد. سپس داده‌ها، با استفاده از معیارهای «نظرات استادی»، «نظرات کارشناسان»، «تعداد مقالات چاپ شده» و «جدید بودن روش» با روش تاپسیس فازی، الگوریتم‌های داده‌کاوی در بانکداری الکترونیک، اولویت‌بندی شد. نتایج نشان داد که، الگوریتم Naive Bayes در طبقه زیاد قرار گرفته است و الگوریتم‌های SVM و ANN در طبقه متوسط قرار گرفته و سایر الگوریتم‌ها در سطح پایین‌تر دسته‌بندی شده‌اند. لذا بامطالعه پیشینه مقالات انجام گرفته و همچنین نظرات خبرگان، الگوریتم Naive Bayes به دلیل کاربرد زیاد و جدید بودن آن نسبت به همه الگوریتم‌ها در بانکداری الکترونیک برتری دارد. همچنین بر اساس تحقیقات صورت گرفته در مقایسه الگوریتم‌های SVM و ANN، نتایج نشان می‌دهد که الگوریتم SVM نسبت به الگوریتم ANN برتری نسبی دارد. واژگان کلیدی: داده‌کاوی، تاپسیس فازی، بانکداری الکترونیک، Naive Bayes.

مقدمه

در گذشته، عموماً استخراج اطلاعات مفید از داده‌های ثبت‌شده، به صورت دستی و بر عهده تحلیلگران بوده است. با توجه به اینکه تجزیه و تحلیل دستی داده‌ها بسیار کند و گران بوده و هر روز بر پیچیدگی و حجم داده‌ها افزوده می‌شود، تحلیل‌های دستی به سمت تحلیل‌های غیرمستقیم خودکار و استفاده از روش‌های کامپیوترا حركت کرده است و نیاز مبرمی مبنی بر استفاده از فناوری‌های جدید و ابزارهای خودکار به وجود آمد تا به صورت هوشمند، حجم زیاد داده را به اطلاعات و دانش تبدیل کند. در این شرایط ضروری است از فناوری اطلاعات برای استفاده از این دانش بهره گرفت و داده‌کاوی پاسخی مناسب برای استخراج این دارایی است. به کارگیری تفکرات و روش‌های مکانیزم‌های داده‌کاوی در بانکداری الکترونیکی، به عاملین این بانک‌ها برای دریافت دانش واقعاً ارزشمند از مقادیر گسترده اطلاعات و تصمیم‌گیری‌های آنان کمک می‌کند. داده‌های مربوط به تراکنش مشتریان در سیستم بانکداری الکترونیکی، اغلب دارای اطلاعات مفیدی در خصوص نحوه تعامل مشتریان با بانک‌ها و استفاده از سرویس‌های مختلف آن‌ها است. کاوش در این داده‌ها به منظور بررسی الگوهای رفتاری مشتریان امری ضروری است که با استفاده از علم داده‌کاوی می‌توان رفتار مشتریان را تحلیل نمود و با استفاده از نتایج حاصله آن‌ها را دسته‌بندی کرد و گروه مشتریان بالرتبه‌تر را جهت برنامه‌ریزی و سیاست‌گذاری‌های آینده مشخص نمود با پیشرفت‌های اخیر در تکنولوژی کامپیوترا، مقادیر زیاد داده‌ها باید قابل جمع‌آوری و ذخیره‌سازی باشند، اما تمامی این داده‌ها زمانی کارآمدتر خواهند بود که تجزیه و تحلیل شوند و برخی از واپس‌گردی‌ها و روابط آن‌ها شناسایی شوند. این امر به وسیله مکانیزم‌های داده‌کاوی می‌تواند انجام شود. در دنیای دیجیتال امروزی، داده‌ها مانند هر چیز دیگری عمدتاً در قالب فایل‌های ساختار نیافتدۀ افزایش می‌یابند. تکنیک‌های داده‌کاوی بسیاری برای کاوش این فایل‌ها وجود دارند. اما کاوش این داده‌های نیمه ساختاری‌افتدۀ، امری چالش‌برانگیز است^[۱].

با افزایش خدمات بانک‌ها در اینترنت و رشد تراکنش‌های برخط توسط مشتریان، میزان بروز جرایم در صنعت بانکداری الکترونیک نیز به سرعت در حال رشد است، به طوریکه آهنگ رشد جرائم برخط بین ۸ الی ۹ درصد در سال تخمین زده می‌شود. در این راستا بانک‌ها می‌توانند با بکارگیری روش‌های داده‌کاوی جدید بر اساس روش تاپسیس فازی به کشف تقلب و به پیشگیری و حذف فرایندهای حامی این گونه اعمال بپردازند. از آنجایی که هیچ ابزاری برای داده‌کاوی کامل نیست، در این تحقیق به بررسی مکانیزم‌های داده‌کاوی در بانکداری الکترونیک و با استفاده از روش تاپسیس فازی اولویت‌بندی این مکانیزم‌ها انجام خواهد شد.

مکانیزم‌های استفاده شده در حوزه داده‌کاوی در بانکداری الکترونیک**CART درخت تصمیم**

درخت تصمیم‌گیری یک روش تقسیم‌بندی بازگشتی «باینری»^۱ است. داده‌ها در این الگوریتم به صورت خام استفاده می‌شوند و هیچ‌گونه پاکسازی نه نیاز است نه پیشنهاد می‌شود. درختان بدون استفاده از یک قانون متوقف کننده به رشد حداًکثیر خود می‌رسند و سپس اصلاح می‌شوند. اصلاح تا رسیده ادامه دارد و با اصلاح پیچیدگی کار بالا می‌رود. قسمت بعدی برای اصلاح بخشی است که کمترین کمک را به کارکرد کلی درخت در پردازش اطلاعات می‌کند. هدف مکانیزم درخت طبقه‌بندی رگرسیون تولید، تنها یک درخت نیست بلکه تولید یک سری درختان اصلاح شده تودرتو است که همه آن درختان بهینه داوطلب هستند. درخت با اندازه مناسب یا «درخت درست» به وسیله ارزش‌گذاری عملکرد پیش‌گویانه هر درخت در توالی اصلاح، شناخته می‌شود. درخت طبقه‌بندی رگرسیون هیچ‌گونه اندازه عملکرد داخلی برای انتخاب درخت بر اساس پردازش اطلاعات پیشنهاد نمی‌کند زیرا این اندازه‌ها قابل اطمینان نیستند. به جای آن عملکرد درخت در آزمایش داده‌های جدگانه (یا از طریق تأیید میانه) اندازه‌گیری می‌شود و انتخاب درخت تنها پس از ارزشیابی آزمایش داده‌ها صورت می‌گیرد. اگر هیچ آزمایش داده‌ای وجود نداشته باشد و تأییدیه میانی انجام نشده باشد درخت طبقه‌بندی رگرسیون نمی‌تواند بهترین درخت توالی را مشخص کند^[۲].

«سوساک و بنسیک»^۲ (۲۰۰۴) در مقاله‌ای به نمره اعتبار کسب‌وکار کوچک: مقایسه رگرسیون لجستیک، شبکه عصبی و مدل درخت تصمیم‌گیری، پرداختند. در این مقاله مدل‌هایی برای ارزیابی اعتبارهای کسب‌وکار کوچک که توسط رگرسیون لجستیک، شبکه‌های عصبی و درخت تصمیم‌گیری رگرسیون در یک مجموعه داده بانکی کروواسی، مقایسه شده است. مدل‌های به دست آمده از هر سه روش برآورد شد، سپس عملکرد آن‌ها مقایسه شدند. تفاوت قابل ملاحظه‌ای بین بهترین مدل شبکه عصبی، مدل درخت تصمیم و مدل رگرسیون لجستیک وجود دارد. موفق‌ترین مدل شبکه عصبی با الگوریتم احتمالی به دست آمده است. بهترین مدل استخراج مهم‌ترین ویژگی‌های کسب‌وکار کوچک کسب‌وکار از داده‌های مشاهده شده است^[۳].

¹. Binery². Susac & Bencik

الگوریتم CHAID

این الگوریتم یک روش درخت تصمیم‌گیری است که بر اساس آزمون معنی‌دار تنظیم شده «آزمایش بونفرونی^۳» است. این تکنیک در آفریقای جنوبی توسعه یافت و توسط «گوردون واکس^۴» منتشر شد که پایان‌نامه دکترای خود را در این زمینه به پایان رسانده است. CHAID را می‌توان برای پیش‌بینی استفاده کرد و همچنین برای طبقه‌بندی و تشخیص تعامل بین متغیرها بکار برد. CHAID بر اساس فرمت رسمی «AID^۵ ایالات متحده و THAID^۶» است. در عمل، CHAID اغلب در زمینه بازاریابی مستقیم برای انتخاب گروهی از مصرف‌کنندگان استفاده می‌شود و پیش‌بینی می‌کند که چگونه آن‌ها به برخی از متغیرها تأثیر می‌گذارد. مزایای CHAID مانند دیگر درخت‌های تصمیم‌گیری این است که خروجی آن بسیار بصری و قابل تفسیر است. یکی از مزیت‌های مهم CHAID همانند رگرسیون چندگانه است که غیر پارامتری است^[۴]. کوثری و همکاران (۱۳۹۲) در پژوهشی به ارائه مدلی جهت کشف رفتارهای مشکوک در بانکداری الکترونیکی با استفاده الگوریتم‌های درخت تصمیم‌گیری، پرداختند. در این پژوهش، ابتدا متغیرهای مؤثر در تولید قوانین رفتاری تعیین شده است و درنهایت، روند چهار الگوریتم CHAID، C4.5، C5.0، ex_C4.5 تعیین شده است و درنهایت، روند چهار الگوریتم CHAID می‌تواند به عنوان روش ماشینی مطمئن جهت کشف الگوهای مشکوک موجود روی تراکنش‌های بانک محسوب شود^[۵].

C5 الگوریتم

الگوریتم C5 یک نوع درخت تصمیم‌گیری تک متغیره و بهبودیافته الگوریتم C4.5 است. این الگوریتم مشابه با درخت طبقه‌بندی رگرسیون ابتدا درختی تقریباً پر ایجاد می‌کند ولی استراتژی هرس آن کامل متفاوت است. این الگوریتم دسته‌بندی را با تقسیم کردن داده‌ها به زیرمجموعه‌هایی که شامل رکوردهای همگن‌تر از والد خود هستند انجام می‌دهد. در C5 تقسیم کردن نمونه‌ها بر اساس فیلدری که بیشترین بهره اطلاعات را دارد صورت می‌گیرد. این الگوریتم روشی افزایشی از هرس کردن درخت را به کار می‌گیرد تا خطای طبقه‌بندی کردن ناشی از نویز یا جزئیات خیلی زیاد را در داده‌های آموزشی کاهش دهد. هرس کردن با جایگزینی گره داخلی با گره برگ رخ می‌دهد که بدان وسیله درصد یا میزان خطای کاهش می‌یابد^[۶]. لنگری و همکاران (۱۴۰۲) در مقاله‌ای به کارگیری الگوریتم‌های درخت تصمیم‌گیری جهت کشف رفتارهای مشکوک در بانکداری اینترنتی پرداختند. در این مقاله، ابتدا متغیرهای مؤثر در تولید قوانین رفتاری تعیین شده است و درنهایت، روند چهار الگوریتم CHAID، C4.5، C5.0 و ex_C4.5 مورد مقایسه قرار گرفته است. نتایج پژوهش نشان می‌دهد که الگوریتم C5.0 با دقت ۹۱ درصد می‌تواند به عنوان روش ماشینی مطمئن جهت کشف الگوهای مشکوک موجود روی تراکنش‌های بانک محسوب شود^[۷].

SVM الگوریتم

الگوریتم ماشین بردار پشتیبان اولیه توسط «ولادیمیر و اپنیک^۸» ابداع شد. یکی از روش‌های «یادگیری با نظرارت^۹» است که از آن برای «طبقه‌بندی^{۱۰}» و رگرسیون استفاده می‌کنند. این روش از جمله روش‌های روش‌های عصبی پرسپترون^{۱۱} نشان داده است. مبنای کاری دسته‌بندی کننده ماشین بردار پشتیبان دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌کنیم خطی را انتخاب کنیم که حاشیه اطمینان بیشتری داشته باشد. الگوریتم ماشین بردار پشتیبان، جز الگوریتم‌های تشخیص الگو دسته‌بندی می‌شود. از الگوریتم ماشین بردار پشتیبان، در هرجایی که نیاز به تشخیص الگو یا دسته‌بندی اشیا در کلاس‌های خاص باشد می‌توان استفاده کرد^[۸]. شربیانی مقدوری و همکاران (۱۳۸۸) در مقاله‌ای به طبقه‌بندی متقاضیان تسهیلات اعتباری بانک‌ها با استفاده از تکنیک ماشین بردار پشتیبان پرداختند. در مقاله حاضر مدل طبقه‌بندی مبتنی بر ماشین بردار پشتیبان با رویکرد هوش مصنوعی، به منظور پیش‌بینی عملکرد مالی مشتریان حقوقی بانک‌ها ارائه گردیده است. درواقع، در این نوشتار ماشین بردار پشتیبان به همراه دیگر مکانیزم‌ها از جمله تکنیک‌های جستجوی گریدی جهت طبقه‌بندی

^۳. Bonfrey Test

^۴. Gordon Wax

^۵. Interaction Automatic Detection

^۶. Vladimir Vapnik

^۷. Supervised learning

^۸. Classification

^۹. Perceptron neural networks

متقاضیان تسهیلات اعتباری بانکی و افزایش کارایی مدل استفاده شده است. نتایج، حاکی از افزایش صحت طبقه‌بندی است و نشان می‌دهد که ماشین بردار پشتیبان در مقایسه با دیگر مدل‌های طبقه‌بندی دارای صحت بیشتری است^[۹].

الگوریتم «نایوبیز»^{۱۰}

یک الگوریتم یادگیری ساده است که از قاعده بیز به همراه فرض محکمی که صفات با توجه به کلاس از نظر شرطی مستقل هستند، استفاده می‌کند. اگرچه این فرض استقلال در عمل اغلب نقض می‌شود، با این وجود، اغلب شبکه‌های بیزی صحت دسته‌بندی قابل رقابتی ارائه می‌کند. این ویژگی به همراه کارایی محاسباتی و ویژگی‌های مطلوب بسیار دیگری، سبب شده نایوبیز در عمل به صورت گسترده مورد استفاده قرار بگیرد. «کریچن»^{۱۱} (۲۰۱۷) در پژوهشی به استفاده از یک روش طبقه‌بندی بیزی برای ارزیابی ریسک وام شواهدی از بانک تجاری تونس، پرداخت. نتایج آزمون اعتبار سنجی نشان می‌دهد که میزان طبقه‌بندی خوب ۵۸,۶۶ درصد است، با این وجود، خطاهای نوع I و II نسبتاً بالا به ترتیب ۴۲,۴۲ و ۴۰,۴۷ درصد می‌باشند. منحنی مشخصه عامل گیرنده برای ارزیابی عملکرد مدل طراحی شده است. نتیجه نشان می‌دهد که سطح زیر معیار منحنی، به ترتیب ۶۹ درصد است و نشان از برتری روش طبقه‌بندی بیزین دارد^[۱۰].

الگوریتم «تفکیک کننده»^{۱۲}

«تشخیص خطی فیشر»^{۱۳} روش‌های آماری هستند که از جمله در یادگیری ماشین و بازناخت الگو برای پیدا کردن ترکیب خطی خصوصیاتی که به بهترین صورت دو یا چند کلاس از اشیا را از هم جدا می‌کند، استفاده می‌شوند. آنالیز تشخیصی خطی بسیار به تحلیل واریانس و تحلیل رگرسیونی نزدیک است، در هر سه این روش‌های آماری متغیر وابسته به صورت یک ترکیب خطی از متغیرهای دیگر مدل‌سازی می‌شود. با این حال دو روش آخر متغیر وابسته را از نوع فاصله‌ای در نظر می‌گیرند در حالی که آنالیز افتراقی خطی برای متغیرهای وابسته اسمی یا رتبه‌ای به کار می‌رود. از این رو آنالیز افتراقی خطی به رگرسیون لجستیک شباهت بیشتری دارد. آنالیز تشخیصی خطی همچنین با تحلیل مؤلفه‌های اصلی و تحلیل عاملی هم شباهت دارد، هر دوی این روش‌های آماری برای ترکیب خطی متغیرها به شکلی که داده را به بهترین نحو توضیح بدهد به کار می‌روند یک کاربرد عمده هر دوی این روش‌ها، کاستن تعداد بعدهای داده است. با این حال این روش‌ها تفاوت عمده‌ای باهم دارند: در آنالیز افتراقی خطی، تفاوت کلاس‌ها مدل‌سازی می‌شود درحالی که در تحلیل مؤلفه‌های اصلی تفاوت کلاس‌ها نادیده گرفته می‌شود^[۱۱]. «آنته و آنا»^{۱۴} (۲۰۱۳) در مقاله‌ای به تجزیه و تحلیل الگوریتم تفکیک کننده برای سطح سوددهی بانک پرداختند. در مجموع، تحلیل تفکیک کننده به عنوان یک روش آماری مناسب برای حل مسئله تحقیق ارائه شده در سوددهی و جلوگیری از ورشکستگی، رتبه‌بندی اعتباری یا مسائل پیش‌فرض در امور مالی است^[۱۲].

QUEST

این الگوریتم توسط «لو و شی»^{۱۵} برای متغیرهای پاسخ اسمی طراحی شد. درخت رده‌بندی حاصل از این الگوریتم نظری مدل درخت طبقه‌بندی رگرسیون دارای تقسیمات دوتایی بوده و ملاک تصمیم برای انتخاب متغیرها با استفاده از مقدار P-Value مربوط به آماره F آزمون «آنو»^{۱۶} برای متغیرهای کمی و P-Value آماره کای-دو مربوط به جداول توافقی برای متغیرهای کیفی صورت می‌پذیرد. این الگوریتم با توجه به این که از مقدار P-Value برای تصمیم‌گیری استفاده می‌نماید، موجب تشکیل درختی نالریب از متغیرها می‌گردد. این الگوریتم ضمن حفظ دقت برآورد در مدل درخت طبقه‌بندی رگرسیون، از سرعت بالاتری در معرفی یک درخت رده‌بندی نسبت به آن برخوردار است. «کیزیس و همکاران»^{۱۷} (۲۰۱۵) در پژوهشی به تلاش برای پایداری بانکداری الکترونیکی با استفاده از الگوریتم Quest نتایج نشان داد که استفاده از الگوریتم QUEST می‌تواند در کاهش ارزش وثیقه وام و همچنین پایداری بانک مؤثر بوده و نسبت به دیگر الگوریتم‌ها از صحت بیشتری برخوردار است^[۱۳].

¹⁰. naïve Bayes

¹¹. Krichen

¹². Discriminant

¹³. Fisher's Linear Detection

¹⁴. Ante & Ana

¹⁵. Lu & Shi

¹⁶. ANOVA

¹⁷. Kizis et al

الگوریتم شبکه‌های عصبی مصنوعی

شبکه‌های عصبی سیستم‌ها و روش‌های محاسباتی نوین برای یادگیری ماشینی، نمایش دانش و در انتها اعمال دانش به دست آمده در جهت پیش‌بینی پاسخ‌های خروجی از سامانه‌های پیچیده هستند. ایده اصلی این گونه شبکه‌ها تا حدودی الهام گرفته از شیوه کارکرد سیستم عصبی زیستی برای پردازش داده‌ها و اطلاعات به منظور یادگیری و ایجاد دانش قرار دارد. عنصر کلیدی این ایده، ایجاد ساختارهایی جدید برای سامانه پردازش اطلاعات است. این سیستم از شمار زیادی عناصر پردازشی فوق العاده بهم پیوسته با نام «نرون» تشکیل شده که برای حل یک مسئله باهم همانگ عمل می‌کنند و توسط «سیناپس‌ها»^{۱۸} (ارتباطات الکترومناطیسی) اطلاعات را منتقل می‌کنند. در این شبکه‌ها اگر یک سلول آسیب بیند بقیه سلول‌ها می‌توانند نبود آن را جبران کرده و نیز در بازسازی آن سهیم باشند. این شبکه‌ها قادر به یادگیری‌اند. مثلاً با اعمال سوزش به سلول‌های عصبی لامسه، سلول‌ها یاد می‌گیرند که به طرف جسم داغ نزند و با این الگوریتم سیستم می‌آموزد که خطای خود را اصلاح کند. یادگیری در این سیستم‌ها به صورت تطبیقی صورت می‌گیرد، یعنی با استفاده از مثال‌ها وزن سیناپس‌ها به گونه‌ای تغییر می‌کند که در صورت دادن ورودی‌های جدید، سیستم پاسخ درستی تولید کند. لطفی (۱۳۸۶) با استفاده از داده‌های مربوط به ۶۴۰ مشتری حقوقی بانک کشاورزی، اقدام به طراحی الگویی بهمنظور رتبه‌بندی اعتباری با بهره‌گیری از ۳ مدل لاجیت، پروفیت و شبکه‌های عصبی شده است. نتایج حاصل تحقیق نشان می‌دهد که از بین ۳ مدل مورد بررسی، مدل لاجیت پیش‌بینی صحیح‌تری از موارد نکول و عدم نکول مشتریان نسبت به دیگر مدل‌ها داشته است [۱۴].

الگوریتم رگرسیون لجستیک

رگرسیون لجستیک یک مدل آماری رگرسیون برای متغیرهای وابسته دوسویی مانند بیماری یا سلامت، مرگ یا زندگی است. این مدل را می‌توان به عنوان مدل خطی تعمیم‌یافته‌ای که از تابع لوジت به عنوان تابع پیوند استفاده می‌کند و خطايش از توزیع چندجمله‌ای پیروی می‌کند، به حساب آورد. منظور از دو سویی بودن، رخ داد یک واقعه تصادفی در دو موقعیت ممکنه است. به عنوان مثال خرید یا عدم خرید، ثبت‌نام یا عدم ثبت‌نام، ورشکسته شدن یا ورشکسته نشدن و ... متغیرهایی هستند که فقط دارای دو موقعیت هستند و مجموع خرید، احتمال هر یک آن‌ها در نهایت یک خواهد شد. کاربرد این روش عمدها در ابتدای ظهور در مورد کاربردهای پژوهشی برای احتمال وقوع یک بیماری مورداستفاده قرار می‌گرفت. لیکن امروزه در تمام زمینه‌های علمی کاربرد وسیعی یافته است. رگرسیون لجستیک می‌تواند یک مورد خاص از مدل خطی عمومی و رگرسیون خطی دیده شود. مدل رگرسیون لجستیک، بر اساس فرض‌های کاملاً متفاوتی (درباره رابطه متغیرهای وابسته و مستقل) از رگرسیون خطی است. تفاوت مهم این دو در دو ویژگی رگرسیون لجستیک می‌تواند دیده شود. اول توزیع شرط $y|x$:^{۱۹} یک توزیع برنولی به جای یک توزیع گوسی است چون که متغیر وابسته دودویی است. دوم مقادیر پیش‌بینی احتمالاتی: محدود بین بازه صفر و یک و به کمک تابع توزیع لجستیک به دست می‌آید. رگرسیون لجستیک احتمال خروجی پیش‌بینی می‌کند. بی‌نظری (۱۳۸۴) در تحقیقی با استفاده از مدل رگرسیون لجستیک به تحلیل ریسک اعتباری مشتریان حقوقی بانک کشاورزی پرداخته است. محقق با توجه به فقدان وجود پایگاه اطلاعات کامپیوتری، از طریق روش میدانی و تکمیل پرسشنامه از شعب بانک مورد مطالعه، نمونه ۲۸۵ تایی از داده‌های مشتریان تهیه نموده است و مدل را با ۱۷ متغیر (خصیصه‌های مشتریان) با استفاده از مدل رگرسیون لجستیک تخمین زده است [۱۵].

الگوریتم «کامینز»^{۱۹}

روش «کامینز» یکی از روش‌های خوشبندی داده‌ها در داده‌کاوی است. این روش علی‌رغم سادگی آن‌بک روش پایه برای بسیاری از روش‌های خوشبندی دیگر (مانند خوشبندی فازی) محسوب می‌شود. این روش، روشهای انحصاری و مسطح محسوب می‌شود. برای این الگوریتم شکل‌های مختلفی بیان شده است. ولی همه آن‌ها دارای روالی تکراری هستند که برای تعدادی ثابت از خوشبندی‌ها سعی در تخمین موارد زیر دارند: به دست آوردن نقاطی به عنوان مرکز خوشبندی‌ها. این نقاط درواقع همان میانگین نقاط متعلق به هر خوشبندی هستند. نسبت دادن هر نمونه داده به یک خوشبندی کمترین فاصله تا مرکز آن خوشبندی را دارا باشد. در نوع ساده‌ای از این روش ابتدا به تعداد خوشبندی‌های موردنیاز نقاطی به صورت تصادفی انتخاب می‌شود. سپس در داده‌ها با توجه به میزان نزدیکی (شباهت) به یکی از این خوشبندی‌ها نسبت داده می‌شوند و بدین ترتیب خوشبندی‌های جدیدی حاصل می‌شود. با تکرار همین روال می‌توان در هر تکرار با میانگین‌گیری از داده‌ها مرکز جدیدی برای آن‌ها محاسبه کرد و مجدداً داده‌ها را به خوشبندی‌های جدید نسبت داد. این روند تا زمانی ادامه پیدا می‌کند که دیگر

^{۱۸}. Synapses^{۱۹}. k-means

تغییری در داده‌ها حاصل نشود. تابع زیر به عنوان تابع هدف مطرح است. «کالیش و همکاران»^{۲۰} (۲۰۱۵) به کاربرد داده‌کاوی در بخش بانکداری الکترونیکی با روش خوشه‌بندی و طبقه‌بندی، پرداختند. در این مطالعه که در بخش بانکداری الکترونیکی انجام شد، هدف آن کاهش میزان ریسک در تصمیم‌گیری و به حداقل رساندن وام‌های موجود و ارزیابی عملکرد مشتریان بالقوه با استفاده از روش کامپیوتری بود که یکی از تکنیک‌های خوشه‌بندی و روش درخت تصمیم است. نتایج نشان‌دهنده برتری مدل ارائه‌شده نسبت به دیگر مدل‌ها را دارد[۱۶].

روش تاپسیس فازی

در این مقاله جهت اولویت بندی مکانیزم‌های داده کاوی، از روش تاپسیس فازی(مثلثی) استفاده می‌شود. بدین منظور داده‌های مورد نیاز روش پیشنهادی به صورت مثلثی فرض می‌نماییم. بنابراین در مسائل واقعی اکثرًا مسائل تصمیم‌گیری چند معیاره، بصورت گروهی می‌باشد. در ابتدا گروه خبره که شامل کارشناسان و اساتید هستند با D_1 و D_2 تصمیم‌گیرنده که آشنا با روش‌های داده کاوی در بانکداری الکترونیک هستند، تشکیل می‌دهیم و این مجموعه افراد را E_D می‌نامیم. فرض می‌کنیم که n زیرفاکتور روی مسئله اولویت‌بندی موثرند، بنابراین این مجموعه معیارها را C_j می‌نامیم. درنهایت متناسب با معیارها و مسئله، m گزینه تعیین گردیده و این مجموعه از گزینه‌ها را A_i می‌نامیم.

بنابراین فرض می‌شود که معیارهای ارزیابی و اهمیت وزن‌های فازی هر معیار توسط $\tilde{x}_{ijk} = (x_{ijk}^a, x_{ijk}^b, x_{ijk}^c, x_{ijk}^d)$ به ترتیب به صورت $i=1, 2, \dots, m$ و $j=1, 2, \dots, n$ باشد. از این‌رو تلفیق نرخ‌های فازی معیارهای هر گزینه $\tilde{w}_{jk} = (w_{jk}^a, w_{jk}^b, w_{jk}^c, w_{jk}^d)$ به صورت $x_{ij}^c = \frac{1}{K} \sum_{k=1}^K x_{ijk}^c$ و $x_{ij}^b = \frac{1}{K} \sum_{k=1}^K x_{ijk}^b$ محاسبه می‌گردد، به طوری که $\tilde{x}_{ij} = (x_{ij}^a, x_{ij}^b, x_{ij}^c, x_{ij}^d)$ تلفیق وزن‌های فازی هر معیار C_j نیز به صورت $x_{ij}^d = \max_k \{x_{ijk}^d\}$ محاسبه می‌گردد، به طوری که $C_j^d = \min_k \{C_{jk}^d\}$ و $C_j^c = \frac{1}{K} \sum_{k=1}^K C_{jk}^c$ و $C_j^b = \frac{1}{K} \sum_{k=1}^K C_{jk}^b$ و $C_j^a = \min_k \{C_{jk}^a\}$.

پس با توجه به محاسبات مربوط به تلفیق نرخ‌های فازی معیارهای هر گزینه و تلفیق وزن‌های هر معیار ماتریس‌های تصمیم‌گیری فازی جهت بانکداری الکترونیکی را می‌توان به صورت زیر تعریف نمود:

$$\tilde{D} = \begin{bmatrix} \tilde{A}_{11} & \tilde{A}_{12} & \cdots & \tilde{A}_{1n} \\ \tilde{A}_{21} & \tilde{A}_{22} & \cdots & \tilde{A}_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \tilde{A}_{m1} & \tilde{A}_{m2} & \cdots & \tilde{A}_{mn} \end{bmatrix}, \quad \tilde{C} = [\tilde{C}_1, \tilde{C}_2, \dots, \tilde{C}_n] \quad (1-3)$$

به طوری که $\tilde{x}_{ij} = (x_{ij}^a, x_{ij}^b, x_{ij}^c, x_{ij}^d)$ و $\tilde{w}_{jk} = (C_j^a, C_j^b, C_j^c, C_j^d)$ و $\tilde{r}_{ij} = (\tilde{r}_{ij}^a, \tilde{r}_{ij}^b, \tilde{r}_{ij}^c, \tilde{r}_{ij}^d)$ می‌باشد.

در مسائل تصمیم‌گیری اکثرًا فاکتورها، ماهیتشان با یکدیگر در تعارض می‌باشند. عده‌ای از آن‌ها مانند جدید بودن و تعداد مقالات استفاده شده به صورت هزینه معرفی شده و بعضی دیگر از معیارها مانند اساتید و کارشناسان به صورت سود معرفی می‌گردند. بنابراین، برای

بی مقایس کردن ماتریس تصمیم‌گیری فازی را به صورت $R = [\tilde{r}_{ij}]_{m \times n}$ نرم‌المل می‌کنیم.

اگر C و B به ترتیب معیارهای سود و هزینه باشند، آنگاه:

$$\begin{aligned} \tilde{r}_{ij} &= \left(\frac{x_{ij}^a}{\theta_j^*}, \frac{x_{ij}^b}{\theta_j^*}, \frac{x_{ij}^c}{\theta_j^*}, \frac{x_{ij}^d}{\theta_j^*} \right) & (j \in B) \\ \tilde{r}_{ij} &= \left(\frac{\varphi_j}{x_{ij}^a}, \frac{\varphi_j}{x_{ij}^b}, \frac{\varphi_j}{x_{ij}^c}, \frac{\varphi_j}{x_{ij}^d} \right) & (j \in C) \end{aligned} \quad (2-3)$$

که $\varphi_j^- (j \in C)$ و $\theta_j^* (j \in B)$ به ترتیب به صورت $\min_i \{x_{ij}^a\}$ و $\max_i \{x_{ij}^d\}$ و تعریف می‌گردد.

روش نرمال سازی فوق، تمام خصوصیات را همچنان حفظ می‌نماید، در حالی که ازای هر i و j اعداد فازی مثلثی نرمال می‌باشند. حال ماتریس تصمیم‌گیری فازی نرمال وزین شده را به صورت $\tilde{Q} = [\tilde{q}_{ij}]_{m \times n}$ و $i = 1, 2, \dots, m$ و $j = 1, 2, \dots, n$ به دست می-

آوریم، به طوری که $\tilde{q}_{ij} \cong (q_{ij}^a, q_{ij}^b, q_{ij}^c, q_{ij}^d)$ عناصر ماتریس تصمیم‌گیری فازی نرمال وزین

اکنون حل ایده‌آل فازی (F^*) و حل ضد ایده‌آل فازی (F^-) را به صورت زیر می‌توانیم تعریف نماییم:

$$\begin{aligned} F^* &= (\tilde{V}_1^*, \tilde{V}_2^*, \dots, \tilde{V}_n^*) \\ F^- &= (\tilde{V}_1, \tilde{V}_2, \dots, \tilde{V}_n) \end{aligned} \quad (3-3)$$

به طوری که

$$\begin{aligned} \tilde{V}_j^* &= (v_j^*, v_j^*, v_j^*, v_j^*) \quad , \quad \tilde{V}_j = (v_j, v_j, v_j, v_j) \quad \forall i, j. \\ v_j^* &= \max_i \{q_{ij}^d\} \quad , \quad v_j = \min_i \{q_{ij}^a\} \end{aligned} \quad (4-3)$$

حل ایده‌آل فازی یک حل مجازی ایده‌آل است که معیارهای سود را ماقزیم کرده و معیارهای زیان را مینیمم می‌کند یا به عبارتی دیگر گزینه‌ای است که معیارهای آن در بهترین مقدار خود می‌باشند، بنابراین در ماتریس تصمیم‌گیری فازی نرمالیزه وزین می‌توانیم گزینه را به عنوان حل ایده‌آل فازی در نظر بگیریم که هر یک از معیارهای آن به صورت $(1, 1, 1, 1)$ می‌باشد. از طرف دیگر، حل ضد-ایده‌آل فازی یک حل مجازی ضد ایده‌آل است که معیارهای سود را مینیمم کرده و معیارهای زیان را ماقزیم می‌کند یا به عبارتی دیگر گزینه‌ای که معیارهای آن در بدترین مقدار خود می‌باشند، بنابراین، در ماتریس تصمیم‌گیری فازی نرمالیزه وزین می‌توانیم گزینه را به عنوان حل ضد-ایده‌آل فازی در نظر بگیریم که هریک از معیارهای آن به صورت $(0, 0, 0, 0)$ می‌باشد. در این پایان‌نامه همانطور که از رابطه (3-3) مشاهده می‌گردد، گزینه ایده‌آل و ضد ایده‌آل از بین درایه‌های ماتریس تصمیم‌گیری فازی نرمال وزین شده انتخاب می‌گردد. فاصله هر گزینه از F^* و F^- بر اساس رابطه (2-3) به صورت $H(R)$ می‌باشد، به ازای α های گوناگون از رابطه زیر به دست می‌آید:

$$\begin{aligned} d_i^*(\alpha) &= \sum_{j=1}^n d(\tilde{V}_j^*, \tilde{q}_{ij}) = \sum_{j=1}^n (2v_j^* - q_{ij}^a - q_{ij}^d) + \left(\frac{\alpha}{2}\right) \sum_{j=1}^n (q_{ij}^a + q_{ij}^d - q_{ij}^b - q_{ij}^c), \quad \forall i, \\ d_i(\alpha) &= \sum_{j=1}^n d(\tilde{q}_{ij}, \tilde{V}_j) = \sum_{j=1}^n (q_{ij}^a + q_{ij}^d - 2v_j) + \left(\frac{\alpha}{2}\right) \sum_{j=1}^n (q_{ij}^b + q_{ij}^c - q_{ij}^a - q_{ij}^d), \quad \forall i. \end{aligned} \quad (5-3)$$

توجه کنید که در رابطه فوق $d(0,0)$ و مقدار فاصله بین دو عدد فازی بوده و $\alpha \in [0,1]$ می‌باشد. هدف در این تکنیک تصمیم‌گیری این است که گزینه‌ای را انتخاب کنیم که به طور همزمان تا حد ممکن به گزینه ایده‌آل فازی نزدیک بوده و از گزینه ضد ایده‌آل فازی دور باشد. بدین منظور یک شاخص ضریب نزدیکی برای رتبه‌بندی تمام گزینه‌ها با توجه به فاصله حل ایده‌آل فازی (F^*) و حل ضد-ایده‌آل فازی (F^-) با توجه به α مربوطه می‌باشد. بدین منظور شاخص ضریب نزدیکی (CC_i) برای هر گزینه به ازای α خاص به صورت زیر محاسبه می‌گردد:

$$CC_i(\alpha) = \frac{d_i^*(\alpha)}{d_i^*(\alpha) + d_i(\alpha)}, \quad i = 1, 2, \dots, m \quad (6-3)$$

واضح است که از رابطه (6-3) اگر $CC_i(\alpha) = 0$ باشد، و اگر $CC_i(\alpha) = 1$ باشد، آنگاه $F^* = F^-$ است، و اگر $CC_i(\alpha) \neq 0$ باشد، آنگاه $CC_i(\alpha) \in (0, 1)$ می‌گردد. به عبارت دیگر زمانی که گزینه i به F^* نزدیک و دور می‌گردد، با توجه به رابطه (6-3) شاخص ضریب نزدیکی $CC_i(\alpha)$ به عدد ۱ نزدیک می‌شود.

نتایج

ویژگی‌های داده‌ها

به دلیل فقدان اطلاعات لازم در رابطه با الگوریتم‌های داده‌کاوی نمونه آماری از حفاظ استاتید و کارشناسان، بسیار کم می‌باشد، نمونه آماری مشکل از ۵ نفر، ۲ نفر کارشناس و ۳ نفر استاتید می‌باشد.

تحلیل داده‌ها

در ابتدا جهت بکار بردن روش تاپسیس فازی لازم است که اطلاعات را از پرسشنامه جمع آوری کرده و سپس آنرا به اعداد فازی تبدیل نماییم.

جدول ۱- نتایج ارزیابی مکانیزم‌های داده‌کاوی در بانکداری الکترونیک

الگوریتم‌ها	تعداد مقالات استفاده‌کننده از این روش	نظر کارشناسان	نظر استاتید	جديد بودن روش*
CART	۳	۲	۳	کم
CHAID	۲	۱	۳	ضعیف
C5	۲	۲	۲	کم
SVM	۶	۲	۳	متوسط
Naive Bayes	۵	۲	۳	زیاد
Discriminant	۲	۱	۱	ضعیف
QUEST	۱	۲	۲	کم
ANN	۵	۲	۳	متوسط
Logistic -R	۳	۲	۳	کم
mens-K	۲	۱	۳	کم

*نکته: منظور از جدید بودن روش، تعداد مقالات چاپ شده در سال‌های بعد از ۲۰۱۰ که از الگوریتم موردنظر استفاده کرده‌اند و همچنین میانگین نظرات کارشناسان و استاتید که در مورد هر الگوریتم می‌باشد. بنابراین تعداد مقالاتی که بعد از ۲۰۱۰ و میانگین نظرات کارشناسان و استاتید بیشتر باشد در طبقه زیاد و در غیر این صورت در طبقات متوسط، کم و ضعیف قرار می‌گیرند.

نتایج روش تاپسیس فازی

با توجه به اینکه یک کمیته خبره از تصمیم‌گیرندگان، D_2 ، D_1 تشکیل شده است تا الگوریتم‌های داده‌کاوی در بانکداری الکترونیکی را بررسی کند، A_1 ، A_2 ، A_3 ، A_4 ، A_5 ، A_6 ، A_7 ، A_8 ، A_9 و A_{10} ، تا مناسب ترین الگوریتم را انتخاب نماید. چهار معیار در نظر گرفته می‌شود.

CART: A_1	:تعداد مقالات استفاده‌کننده از الگوریتم C_1
CHAID: A_2	:نظر کارشناسان C_2
C5: A_3	:نظر استاتید C_3
SVM: A_4	:جديد بودن روش C_4
Naive Bayes: A_5	
Discriminant: A_6	
QUEST: A_7	
ANN: A_8	
Logistic -R: A_9	
K-mens: A_{10}	

فرآیند انتخاب نرم افزار مناسب به وسیله روش تاپسیس فازی ذوزنقه‌ای شامل مراحل زیر است:

گام اول: عبارت‌های کلامی استفاده شده برای اولویت‌های تصمیم‌گیرندگان و شاخص‌ها در جدول ۲-۴ آمده است.

جدول ۲- ارزش‌های کلامی اعداد فازی ذوزنقه‌ای برای عبارت‌های کلامی

متغیرهای کلامی	ارزش‌های کلامی اعداد فازی ذوزنقه‌ای
ضعیف	$((1.0, 0.0, 1.0, 0.0))$
کم	$((2.0, 1.0, 1.0, 0.0))$
متوسط	$((2.0, 2.0, 2.0, 1.0))$
زیاد	$((3.0, 2.0, 2.0, 3.0))$

هر متخصص ارزش‌های کلامی اعداد فازی ذوزنقه‌ای را به اوزان شاخص‌ها اختصاص می‌دهد. تصمیم‌گیرندگان را به k_1 تا k_5 تقسیم نماییم.

جدول ۳- اوزان شاخص‌ها تعیین شده به وسیله تصمیم‌گیرندگان ($C_j^{(k)}$)

K	C_1	C_2	C_3	C_4
k_1	(0.4, 0.4, 0.5, 0.6)	(0.3, 0.4, 0.5, 0.5)	(0.6, 0.4, 0.5, 0.6)	(0.3, 0.4, 0.5, 0.6)
k_2	(0.4, 0.6, 0.7, 0.8)	(0.1, 0.2, 0.3, 0.4)	(0.5, 0.6, 0.7, 0.8)	(0.1, 0.3, 0.3, 0.5)
k_3	(0.5, 0.6, 0.7, 0.8)	(0.1, 0.2, 0.3, 0.4)	(0.3, 0.4, 0.5, 0.6)	(0.3, 0.4, 0.5, 0.6)
k_4	(0.3, 0.6, 0.7, 0.6)	(0.5, 0.4, 0.5, 0.6)	(0.3, 0.4, 0.5, 0.6)	(0.5, 0.6, 0.7, 0.8)
k_5	(0.5, 0.5, 0.7, 0.7)	(0.6, 0.4, 0.4, 0.6)	(0.5, 0.4, 0.3, 0.6)	(0.4, 0.6, 0.5, 0.8)

گام دوم: تعیین اهمیت نسبی نظرات و اوزان تصمیم‌گیرندگان در جدول ۴ نشان داده شده است.

جدول ۴- اهمیت نسبی نظرات تصمیم‌گیرندگان

	K	C_1	C_2	C_3	C_4		k	C_1	C_2	C_3	C_4
A_1	1	0.274	0.309	0.278	0.309	A_1	1	0.169	0.167	0.167	0.168
A_2		0.297	0.309	0.278	0.168	A_2		0.251	0.278	0.198	0.214
A_3	2	0.203	0.168	0.167	0.214	A_3	2	0.329	0.278	0.317	0.303
A_4		0.226	0.214	0.278	0.309	A_4		0.251	0.278	0.317	0.168
A_5	3	0.309	0.309	0.250	0.168	A_5	3	0.274	0.309	0.278	0.309
A_6		0.214	0.167	0.321	0.214	A_6		0.297	0.309	0.278	0.168
A_7	4	0.309	0.309	0.250	0.309	A_7	4	0.203	0.168	0.167	0.214
A_8		0.168	0.215	0.179	0.303	A_8		0.226	0.214	0.278	0.309
A_9	5	0.309	0.309	0.250	0.168	A_9	5	0.215	0.226	0.278	0.309
A_{10}		0.214	0.167	0.321	0.214	A_{10}		0.309	0.303	0.278	0.168
A_1	1	0.309	0.303	0.167	0.168	A_1	1	0.309	0.309	0.250	0.168
A_2		0.167	0.168	0.278	0.309	A_2		0.214	0.167	0.321	0.214
A_3	2	0.215	0.226	0.278	0.309	A_3	2	0.309	0.309	0.250	0.309
A_4		0.309	0.303	0.278	0.168	A_4		0.168	0.215	0.179	0.303
A_5	3	0.309	0.309	0.250	0.168	A_5	2	0.274	0.309	0.278	0.309
A_6		0.214	0.167	0.321	0.214	A_6		0.297	0.309	0.278	0.168

A_7	۴	۰,۳۰۹	۰,۳۰۹	۰,۲۵۰	۰,۳۰۹	A_7	۴	۰,۲۰۳	۰,۱۶۸	۰,۱۶۷	۰,۲۱۴
A_8		۰,۱۶۸	۰,۲۱۵	۰,۱۷۹	۰,۳۰۳	A_8		۰,۲۲۶	۰,۲۱۴	۰,۲۷۸	۰,۳۰۹
A_9	۵	۰,۲۱۵	۰,۲۲۶	۰,۲۷۸	۰,۳۰۹	A_9	۵	۰,۲۵۱	۰,۲۷۸	۰,۳۱۷	۰,۱۶۸
A_{10}		۰,۳۰۹	۰,۳۰۳	۰,۲۷۸	۰,۱۶۸	A_{10}		۰,۲۷۴	۰,۳۰۹	۰,۲۷۸	۰,۳۰۹

گام سوم: تشکیل ماتریس تصمیم گیری فازی ذوزنقه‌ای ادغامی برپایه نقطه نظرات هر تصمیم گیرنده مطابق جدول ۵.

جدول ۵- ماتریس تصمیم فازی ذوزنقه‌ای ادغامی

	C_1	C_2	C_3	C_4
A_1	(0.22, 0.32, 0.42, 0.52)	(0.48, 0.58, 0.68, 0.78)	(0.17, 0.27, 0.37, 0.47)	(0.27, 0.34, 0.48, 0.57)
A_2	(0.32, 0.42, 0.52, 0.62)	(0.46, 0.56, 0.66, 0.76)	(0.33, 0.43, 0.53, 0.63)	(0.45, 0.58, 0.78, 0.78)
A_3	(0.27, 0.37, 0.47, 0.57)	(0.67, 0.77, 0.87, 0.97)	(0.29, 0.39, 0.49, 0.59)	(0.58, 0.58, 0.68, 0.78)
A_4	(0.48, 0.58, 0.68, 0.78)	(0.32, 0.42, 0.52, 0.62)	(0.35, 0.45, 0.55, 0.65)	(0.46, 0.56, 0.66, 0.76)
A_5	(0.23, 0.32, 0.42, 0.52)	(0.48, 0.58, 0.68, 0.78)	(0.17, 0.27, 0.37, 0.47)	(0.27, 0.34, 0.48, 0.57)
A_6	(0.32, 0.42, 0.52, 0.62)	(0.46, 0.56, 0.66, 0.76)	(0.33, 0.43, 0.53, 0.63)	(0.45, 0.58, 0.78, 0.78)
A_7	(0.24, 0.37, 0.47, 0.57)	(0.67, 0.77, 0.87, 0.97)	(0.29, 0.39, 0.49, 0.59)	(0.58, 0.58, 0.68, 0.78)
A_8	(0.48, 0.58, 0.68, 0.78)	(0.32, 0.42, 0.52, 0.62)	(0.35, 0.45, 0.55, 0.65)	(0.46, 0.56, 0.66, 0.76)
A_9	(0.22, 0.32, 0.42, 0.52)	(0.48, 0.58, 0.68, 0.78)	(0.17, 0.27, 0.37, 0.47)	(0.27, 0.34, 0.48, 0.57)
A_{10}	(0.48, 0.58, 0.67, 0.78)	(0.32, 0.42, 0.50, 0.62)	(0.35, 0.45, 0.54, 0.65)	(0.46, 0.56, 0.66, 0.76)

گام چهارم: تعیین ارزش وزنی مورد انتظار نرمالیزه شده شاخص‌ها. بر اساس اهمیت شاخص‌ها ($\xi^{(k)}$) تعیین شده به وسیله تصمیم گیرنده‌کام، ابتدا $\xi^{(k)}$ را محاسبه می‌کنیم که نشان دهنده ارزش وزنی شاخص c_i برای گزینه O_i می‌باشد، و سپس ارزش وزنی مورد انتظار نرمالیزه شده $\xi_{ij}^{(k)}$ می‌تواند به صورت زیر به دست می‌آید:

$$(\xi'') = \begin{bmatrix} 0.418 & 0.254 & 0.347 \\ 0.411 & 0.363 & 0.345 \\ 0.417 & 0.245 & 0.319 \\ 0.424 & 0.343 & 0.353 \end{bmatrix}$$

گام پنجم: تعیین PIS و NIS.

هزینه نرم افزار و سخت افزار (C_1) تعداد مقالات استفاده‌کننده از الگوریتم، نظر کارشناسان (C_2) و نظر استادی (C_3) جدید بودن روش (C_4) هستند. بنابرین PIS و NIS به صورت زیر به دست می‌آیند:

$$R^+ = \{((0.21, 0.42, 0.42, 0.52), (0.16, 0.31, 0.41, 0.61)), ((0.67, 0.77, 0.87, 0.97), (0.65, 0.77, 0.88, 0.98)), ((0.36, 0.46, 0.55, 0.64))\}$$

$$R^- = \{((0.47, 0.55, 0.61, 0.78), (0.40, 0.58, 0.62, 0.85)), ((0.33, 0.42, 0.52, 0.62), (0.24, 0.42, 0.54, 0.71)), ((0.17, 0.27, 0.37, 0.47))\}$$

گام ششم: اندازه‌های فاصله‌های وزنی مثبت و منفی در جدول ۶ نشان داده شده‌اند.

جدول ۶- اندازه‌های فاصله و ضرایب نزدیکی نسبی هر گزینه

	D ⁺	D ⁻	U ⁻
A ₁	۰,۱۱۰	۰,۱۴۲	۰,۶۶۵
A ₂	۰,۱۰۰	۰,۱۵۳	۰,۳۸۱
A ₃	۰,۰۴۰	۰,۲۱۱	۰,۵۳۴
A ₄	۰,۱۸۲	۰,۰۶۴	۰,۷۵۲
A ₅	۰,۱۱۷	۰,۱۴۵	۰,۸۴۷
A ₆	۰,۱۰۵	۰,۱۳۵	۰,۲۵۶
A ₇	۰,۰۴۰	۰,۲۱۱	۰,۵۰۹
A ₈	۰,۱۱۰	۰,۱۵۳	۰,۷۴۹
A ₉	۰,۰۴۵	۰,۲۱۸	۰,۶۳۹
A ₁₀	۰,۱۸۷	۰,۰۶۴	۰,۴۸۸

گام هفتم: ضرایب نزدیکی نسبی U_i^- هر گزینه A_i بر اساس جدول ۶ به دست می‌آید.

گام هشتم: در حالیکه $U_5^- > U_4^- > U_8^- > U_1^-$ باشد، رتبه بندی گزینه‌ها مطابق $A_5 > A_4 > A_8 > A_1$ می‌باشد، بنابراین بهترین گزینه می‌باشد.

بنابراین طبق نتایج فوق رتبه بندی ۱۰ الگوریتم به ترتیب:

$A_6 < A_2 < A_{10} < A_7 < A_3 < A_9 < A_1 < A_8 < A_4 < A_5$ خواهد بود. بهوضوح بهترین حالت A_5 می‌باشد چون بیشترین

نزدیکی نسبی را دارد. بنابراین بهترین الگوریتم داده کاوی در بانکداری الکترونیک، الگوریتم نایوبیز می‌باشد.

با توجه به نتایج بدست آمده، مشاهده می‌گردد الگوریتم نایوبیز از لحاظ چهار معیار مکانیزم داده کاوی در بانکداری الکترونیک که در این پژوهش مطرح گردید، بهتر عمل می‌کند. لذا معیار انتخابی ما برای داده کاوی در بانکداری الکترونیک، استفاده از الگوریتم نایوبیز می‌باشد. بزرگ‌ترین ویژگی این روش این است که حجم آموزش اندکی برای شروع کار و تخمین پارامترها نیاز دارد. برنامه‌های کاربردی بسیاری هستند که پارامترهای نایوبیز را تخمین می‌زنند، بنابراین افراد بدون سروکار داشتن با تئوری بیز می‌توانند از این امکان بهمنظور حل مسائل موردنظر بهره ببرند. باوجود مسائل طراحی و پیش‌فرض‌هایی که در خصوص روش بیز وجود دارد، این روش برای طبقه‌بندی کردن بیشتر مسائل در جهان واقعی، مناسب است.

مقایسه

همانطور که نتایج این پژوهش نشان داد الگوریتم نایوبیز نسبت به دیگر الگوریتم‌ها در داده کاوی بانکداری الکترونیک در اولویت اول قرار دارد. نتایج تحقیق ما با نتایج [۱] مقایسه شده است. در مقاله [۱] جهت جمع آوری نمونه‌های تحقیق از پرسشنامه استفاده شد و اندازه‌ی نمونه تحقیق برابر ۱۰۸۱ بوده است و مجموعاً ۳۴ متغیر را تحلیل شده است. در این زمینه، مقاله [۱] روش‌های داده کاوی و تکنیک‌های مختلف جهت تعیین اینکه کدام متغیرها مهمترین متغیر برای موسسات مالی هستند را بررسی می‌کند، مؤسسات مالی از مهمترین متغیرها جهت پیش‌بینی سطوح احتمالی اطمینان میان کاربران بانکداری الکترونیکی استفاده می‌کنند. نتایج مقاله [۱] نشان داد که از بین همه الگوریتم‌های داده کاوی، الگوریتم SVM نسبت به دیگر الگوریتم‌های داده کاوی، بهترین متغیر برای پیش‌بینی سطوح احتمالی اطمینان میان کاربران بانکداری الکترونیکی است. این در حالی است که بر اساس نتایج پژوهش ما، الگوریتم نایوبیز نسبت به دیگر الگوریتم‌ها جدید و دقیق‌تر است.

نتیجه‌گیری

کل فرآیند این تحقیق به دنبال پاسخ به این سؤال بود که چگونه می‌توان با کمک روش تاپسیس فازی، مکانیزم‌های داده‌کاوی در بانکداری الکترونیک را اولویت‌بندی نمود. در فصل سوم و چهارم مراحل چگونگی این موضوع را با استفاده از روش‌های طبقه‌بندی با الگوریتم‌های داده‌کاوی تشریح گردیده است.

نتایج حاصل از یافته‌های تحقیق نشان داد که بر اساس اولویت‌بندی الگوریتم‌های داده‌کاوی، الگوریتم‌های CHAID و Discriminant در طبقه‌بندی «ضعیف» قرار گرفته‌اند زیرا این الگوریتم‌ها باتوجه به مقالات چاپ شده در این زمینه، قدیمی می‌باشد و همچنین این الگوریتم‌ها از دیدگاه خبرگان در حد ضعیف بوده و در بانکداری الکترونیک از لحاظ تئوری و عملی، کاربردی نمی‌باشد. بر اساس نتایج به دست آمده، اولویت‌بندی الگوریتم‌های K-mens، Logistic-R، QUEST، C5، CART و الکترونیک در طبقه «کم» قرار گرفته است. چراکه این الگوریتم‌ها با توجه به مطالعه پیشینه مقالات انجام گرفته، در بانکداری الکترونیک به تعداد کم می‌باشد و میانگین نظرات خبرگان از لحاظ آشنایی و کاربرد این الگوریتم‌ها در بانکداری الکترونیک، در حد کم دانسته‌اند.

بر اساس نتایج به دست آمده، اولویت‌بندی الگوریتم‌های SVM و ANN، در بانکداری الکترونیک در طبقه «متوسط» قرار گرفته است. با توجه به مطالعه پیشینه مقالات انجام شده، این دو الگوریتم به دلیل کاربرد بیشتر و جدید بودن آن نسبت به دیگر الگوریتم‌ها در بانکداری الکترونیک برتری دارد و همچنین از دیدگاه خبرگان، این الگوریتم‌ها در سطح متوسط قرار گرفته است. تحقیقات نشان داده است که الگوریتم SVM از جمله روش‌های جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به دیگر روش‌های قدیمی‌تر برای طبقه‌بندی، از خود نشان داده است. با توجه به اینکه این الگوریتم در هرجایی که نیاز به تشخیص الگو یا دسته‌بندی اشیا در کلاس‌های خاص باشد می‌توان استفاده نمود. با توجه به مطالعه پیشینه تحقیقات انجام گرفته، الگوریتم ANN برای تخمین و تقریب در حوزه بانکداری الکترونیک نسبت به دیگر الگوریتم‌ها، کارایی بسیار بالایی از خود نشان داده است. بر اساس تحقیقات صورت گرفته در رابطه با الگوریتم‌های SVM و ANN، نشان می‌دهد که الگوریتم ANN نسبت به الگوریتم SVM کاربردی‌تر و برتری نسبی دارد.

درنهایت نتایج حاصل از اولویت‌بندی الگوریتم‌های داده‌کاوی، نشان داد که الگوریتم «نایوبیز» در بانکداری الکترونیک در طبقه «زیاد» قرار گرفته است. چراکه بامطالعه پیشینه مقالات انجام گرفته، این الگوریتم به دلیل کاربرد زیاد و جدید بودن آن نسبت به همه الگوریتم‌ها در بانکداری الکترونیک برتری دارد و همچنین از دیدگاه خبرگان، این الگوریتم‌ها در سطح زیاد قرار گرفته است. الگوریتم نایوبیز یک الگوریتم یادگیری است که دارای ویژگی‌هایی به همراه کارایی محاسباتی بسیار مطلوب نسبت به دیگر الگوریتم‌ها، سبب شده تا الگوریتم نایوبیز در عمل به صورت گسترده مورد استفاده قرار گیرد. الگوریتم نایوبیز دارای چند ویژگی در بانکداری الکترونیکی است از جمله خطای کم و یادگیری تدریجی در داده‌کاوی بانکداری الکترونیکی نسبت به دیگر الگوریتم‌ها است. نتایج مقالات انجام شده و نتایج حاصل از فصل قبل نشان می‌دهد که الگوریتم نایوبیز بیشترین کاربرد نسبت به کلیه الگوریتم‌های طبقه‌بندی داده‌کاوی مورد استفاده در این پژوهش دارد، بنابراین دانش استخراج شده از این الگوریتم به عنوان مورد اعتمادترین دانش داده‌کاوی موردنرسی می‌باشد و قواین حاصل از الگوریتم نایوبیز به عنوان دانش سازمانی استخراج شده از داده‌کاوی در بانکداری الکترونیک مورد مطالعه تلقی می‌گردند.

منابع و مراجع

- [1] Prashar, S., Comparing Predictive Ability of Classifiers in Forecasting Online Buying Behaviour: An Empirical Study. International Journal of Strategic Decision Sciences, 2016, 6(4), 5-18.
- [۲] ناظمی، ع؛ مشکانی، ع. داده کاوی کاربردی، دانشگاه آزاد اسلامی واحد نیشابور، ۱۳۸۸.
- [3] Zekic-Susac, M. Sarlija, N., Bensic, M. Small business credit scoring: a comparison of logistic regression, neural network, and decision tree models, International Conference on Information Technology Interfaces, 2004.
- [4] Antipov, E., Elena, P. Applying CHAID for logistic regression diagnostics and classification accuracy improvement. Journal of Targeting, Measurement and Analysis for Marketing, 2010. 18(2), 109-117.
- [۵] کوثری لنگری، ر؛ مقدم، ن؛ وحدت، د. معرفی یک مدل برای تشخیص رفتارهای مشکوک در بانکداری الکترونیک با استفاده از الگوریتم های تصمیم گیری درخت، مجله پردازش اطلاعات و مدیریت، شماره ۲۸، دوره ۳، ۱۳۹۳، ص ۶۸۱-۷۰۰.
- [6] Chattamvelli, R., Data mining Algorithm. Alpha science, 2011.
- [۷] لنگری، ر. ارائه مدلی جهت کشف رفتارهای مشکوک در بانکداری الکترونیکی با استفاده الگوریتم های درخت تصمیم گیری، پایان نامه کارشناسی ارشد، دانشگاه پیام نور تهران: تهران، ۱۳۸۹.
- [8] Ying, C., Ying, Y. Learning with Support Vector Machines. Synthesis Lectures on Artificial Intelligence and Machine Learning, 2011, 95(4), 95-106.
- [۹] شربیانی مقدوری، ف؛ نیکومرام، ۵؛ طلوعی اشلقی، ع. طبقه بندی متغیرهای تسهیلات اعتباری بانک ها با استفاده از تکنیک ماشین بردار پشتیبان، آینده پژوهی مدیریت، دوره ۲۱، شماره ۱، ۱۳۸۹، ص ۱-۱۹.
- [10] Krichene, A., Using a naive Bayesian classifier methodology for loan risk assessment: Evidence from a Tunisian commercial bank. Journal of Economics, Finance and Administrative Science, 2017, 22(42), 451-462.
- [11] McLachlan, G.J. Discriminant Analysis and Statistical Pattern Recognition. Wiley Series in Probability and Statistics, 2004.
- [12] Ante, R., Ana, K, DISCRIMINANT ANALYSIS OF BANK PROFITABILITY LEVELS. Croatian Operational Research Review, 2013, 11(3), 39-49.
- [13] Kizys, R., Paltalidis, N., Vergos, K. The Quest for Banking Stability in the Euro Area: The Role of Government Interventions. Journal of International Financial Markets, Institutions and Money, 12(40), 2015, 111-133.
- [۱۴] لطفی، ل. مدل سازی ریسک اعتباری در بانک کشاورزی؛ رویکرد مدل-های لاجیت، پروبیت و شبکه های عصبی، پایان نامه کارشناسی ارشد، دانشگاه علامه طباطبائی، ۱۳۸۶.
- [۱۵] بی نظیر، ع. امتیاز دهی اعتباری مشتریان حقوقی بانکها با استفاده از روش آلتمن مطالعه موردی بانک ملت، ۱۳۸۸، موسسه عالی بانکداری: تهران.
- [16] Çalış, A., Boyaci, A., Kasim. Data mining application in banking sector with clustering and classification methods. International Conference on Industrial Engineering and Operations Management Dubai, United Arab Emirates, 2015.