



طبقه‌بندی متقاضیان تسهیلات اعتباری بانک‌ها با استفاده از تکنیک ماشین بردار پشتیبان

دکتر عباس طلوعی اشلاقی *

دکتر هاشم نیکومرام **

فرناز مقدوری شریانی ***

چکیده

در صنعت بانکداری یکی از موضوعاتی که همواره بایستی مدنظر سیاستگذاران اعتباری قرار داشته باشد، مبحث مدیریت ریسک است. در بین ریسک‌های مختلفی که بانک‌ها با آن مواجهند، ریسک اعتباری از با اهمیت ترین آن‌ها است که از

زیان‌های ناشی از ناتوانی یا عدم تمایل مشتری به ایفای تعهدات خویش در برابر بانک حاصل می‌گردد.

جهت مدیریت و کنترل ریسک مذکور، سیستم‌های طبقه‌بندی اعتباری مشتریان ضروری انکار ناپذیر است. چنین سیستمی، براساس سوابق و اطلاعات موجود، طبقه‌مشتریان را تعیین می‌کند. بدیهی است بهره‌گیری از چنین سیستمی بانک را در گزینش مطلوب مشتریان خود یاری نموده و ضمن کنترل و کاهش ریسک اعتباری، سطح بهره‌وری فرایند اعطای تسهیلات بانکی را ارتقا می‌دهد.

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. در واقع، در این نوشتار ماشین بردار پشتیبان به همراه دیگر مکانیزم‌ها از جمله تکنیک‌های F-score و Grid search جهت طبقه‌بندی 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.

واژگان کلیدی :

داده کاوی، طبقه‌بندی، ماشین بردار پشتیبان، انتخاب ویژگی

* دانشیار، عضو هیات علمی تمام وقت دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران

تهران- بزرگراه اشرفی اصفهانی- به سمت حصارک- دانشکده مدیریت و اقتصاد دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران

** دانشیار، عضو هیات علمی تمام وقت دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران

تهران- بزرگراه اشرفی اصفهانی- به سمت حصارک- دانشکده مدیریت و اقتصاد دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران

*** دانش آموخته کارشناسی ارشد مدیریت فناوری اطلاعات، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران (farnazmaghdouri@gmail.com)

تهران- بزرگراه اشرفی اصفهانی- به سمت حصارک- دانشکده مدیریت و اقتصاد دانشگاه آزاد اسلامی، واحد علوم و تحقیقات تهران

نویسنده مسئول یا طرف مکاتبه : دکتر عباس طلوعی اشلاقی

مقدمه

از یک مدل ریسک کارآمد نه تنها تصمیم گیری در زمینه اعتبار را تسهیل می‌نماید؛ بلکه افزون بر کاهش هزینه مبادله موجب خواهد شد که سیستم بانکی از الگوی کارآمدی در تخصیص سرمایه به بخش‌های مختلف اقتصادی برخوردار شود.

یکی از مهمترین روش‌های مدیریت ریسک اعتباری استفاده از سیستم‌های طبقه بندی برای کنترل ریسک انواع وام‌ها است (سینکی، ۱۹۹۲). در مطالعات گذشته غالب از روش‌های آماری مانند مدل‌های رگرسیونی لاجیت و پریوبیت و روش تحلیل ممیزی برای این منظور استفاده می‌گردید، ولی در سال‌های اخیر با گسترش فناوری‌های نوین اطلاعاتی و کاربردهای وسیع آن در پردازش و طبقه بندی اطلاعات، مدل‌های مبتنی بر هوش مصنوعی و روش‌های ابتکاری توسعه یافته و مطالعات بسیاری در کاربرد این روش‌ها در مدل‌های طبقه بندی مشاهده می‌شوند (خبری، ۱۳۸۷). بر همین اساس در این تحقیق ماشین بردار پشتیبان را به عنوان یکی از جدیدترین تکنیک‌های داده کاوی جهت طبقه بندی مشتریان بانک‌ها معرفی نموده و از این تکنیک برای طبقه بندی مشتریان استفاده خواهیم نمود که اخیراً در صنعت اعتباری به عنوان ابزاری صحیح و اثربخش برای تحلیل اعتباری مطرح شده است و منجر به عملکرد بالا در بسیاری عملیات از جمله طبقه بندی و رتبه بندی اعتباری می‌شود.

لذا در این مقاله با استفاده از ماشین بردار پشتیبان، چارچوبی برای طبقه بندی متقاضیان تسهیلات اعتباری پیشنهاد و کارایی این مدل با مدل‌های دیگر مقایسه شده است.

مقاله حاضر شامل بخش‌های زیر می‌باشد: پیشینه تحقیق، بیان مساله، ماشین بردار پشتیبان، ساختار اجرایی تحقیق (متداول‌تری تحقیق) رویه اعتبار سنجی مبتنی بر ماشین بردار پشتیبان، چارچوب اجرائی مبتنی بر ماشین بردار پشتیبان، نتایج طبقه بندی با مدل ماشین بردار پشتیبان و در نهایت نتیجه گیری

بانک‌ها به عنوان بخش اصلی نظام مالی، نقش مهمی را در تامین مالی بخش‌های مختلف اقتصادی بر عهده دارند. در راستای ایفای این نقش، بانک‌ها با ریسک‌های متفاوتی روبرو هستند که یکی از عمده‌ترین آنها ریسک اعتباری است (طلوعی، مقدوری، ۱۳۸۸)، ریسک اعتباری عبارت است از احتمال قصور استفاده کنندگان از تسهیلات بانکی در انجام تعهدات مالی خود. بر این اساس لازم است بانک‌ها برای کاهش و تقلیل ریسک اعتباری، قبل از هر پرداختی به متقارضیان، وضعیت اعتباری آنان را بررسی نمایند (طلوعی، مقدوری، ۱۳۸۸). ارزیابی درست درخواست کنندگان و مدیریت ریسک برای بانک‌ها و موسسات اعتباری و فیلتر کردن متقارضیان مباحثی حیاتی هستند. برای اعطای تسهیلات باید درجه اعتبار و توان گیرنده تسهیلات را در بازپرداخت تسهیلات اعطایی تعیین نمود. بحران‌های مشاهده شده در نظام بانکی کشورها عمدتاً ناشی از عدم کارایی در مدیریت ریسک اعتباری بوده است (طلوعی، مقدوری، ۱۳۸۸). حجم قابل ملاحظه‌ای از تسهیلات اعطایی سوخت شده یا معوقه بانک‌ها، گویای فقدان مدل‌های مناسب اندازه گیری ریسک اعتباری و سیستم‌های مدیریت ریسک در شبکه بانکی است. یکی از مهمترین ابزارهایی که بانک‌ها برای مدیریت و کنترل ریسک اعتباری بدان نیازمند هستند سیستم طبقه بندی مشتریان است (سینکی، ۱۹۹۲). بررسی عوامل موثر بر این طبقه بندی به ما کمک خواهد کرد تا بتوانیم خیل عظیم مشتریان بانک را در ابتدای کار در طبقات مختلف دسته بندی و با اختصاص درجه و رتبه، تصمیم مناسبی در جهت تخصیص هرچه بهتر و موثرتر وجود جمع آوری شده، اتخاذ نماییم و بازدهی مناسب را برای بانک، حاصل و احتمال نکول را به نحو بایسته کاهش دهیم. متأسفانه علی رغم اهمیت این موضوع، در کشور ما در زمینه اعطای تسهیلات اعتباری به مشتریان، روند منسجم و منظمی به منظور تعیین ریسک اعتباری، امتیازدهی، طبقه بندی و همچنین تعیین سقف‌های اعتباری بر اساس شاخص‌های ریسک ملاحظه نمی‌شود و شاخص‌ها بر اساس تشخیص کارشناسی و کمیته اعتباری صورت می‌پذیرد. برخورداری

انتخاب شده توسط الگوريتم ژنتيک و ماشين بردار پشتيبان در رابطه با شبکه های عصبی و برنامه ريزى ژنتيک را با هم مقاييسه کردند. اين محققان از پايگاهداده کوچکي استفاده کردند و ويژگي های انتخاب شده توسط ماشين بردار پشتيبان را مقاييسه نکردند و با متدهای عملی بكار رفته از جمله رگرسيون لجستيک مقاييسه نکردند.

(بلوتي، کروك، ۲۰۰۸) به مقاييسه عملکرد ماشين بردار پشتيبان با چندين الگوريتم معروف پرداختند و از پايگاهداده بزرگتری نسبت به تحقيقات قبلی استفاده کردند و به اين نتیجه رسيدند که ماشين بردار پشتيبان موفق تر از تكنیک های قبلی رتبه بندی است و از ماشين بردار پشتيبان به عنوان يکی از متدهای انتخاب ويژگی استفاده کردند.

همچنین (تیان-شیوغ لی و همکارانش^۳، ۲۰۰۶) در تحقيق خود به مقاييسه عملکرد امتيازدهی اعتباری دو تكنیک MARS، CART طبقه بندی داده کاوی یعنی پرداخته اند. برای سنجش کاراكي اين دو روش از مجموعه داده های کارت اعتباری يک بانک استفاده شده است. نتایج تحقيق نشان می دهد که عملکرد دو روش مذکور نسبت به رویکردهای تحليل ممیزی سنتي، رگرسيون لجستيک، شبکه های عصبی و ماشين بردار پشتيبان جهت امتيازدهی اعتباری بهتر می باشد و در نهايit اينکه (چنگ-لونگ، هوانگ و همکارانش^۴، ۲۰۰۷) در تحقيق خود به مدلسازی تكنیکي هيبريدی برای اعتبارسنジ پرداخته اند. به اين صورت که ترکيب الگوريتم ژنتيک و ماشين بردار پشتيبان هم برای انتخاب خصيصه ها و هم برای بهينه سازي پaramترهاي مدل اعتبارسنジ بكار رفته است. مقاييساتي نيز بين تكنیک ماشين بردار پشتيبان و طبقه بندهای شبکه های عصبی، برنامه ريزى ژنتيکي و درخت تصميم صورت گرفته که نتایج نسبتاً "يکسانی حاصل شده است. ولی نتایج تجربی نشان می دهد که ماشين بردار پشتيبان، نسبت به تكنیک های موجود داده کاوی، نتایج اميد بخش تری را ارائه می دهد.

پيشينه تحقيق

در سالهای اخیر ماشين بردار پشتيبان در بسياري از مسائل طبقه بندی از جمله طبقه بندی متن، بازشناسی تصاویر و... بطور موفقیت آمیزی بكار رفته است (بلوتي، کروك، ۲۰۰۸). تحقيقات صورت گرفته در زمينه ای استفاده از ماشين بردار پشتيبان برای اعتبارسنジ و طبقه بندی، جديد واندک هستند، با اين حال اخيراً تعدادي مقاله در اين زمينه منتشر شده و به ارزیابي عملکرد ماشين بردار پشتيبان برای اعتبارسنジ پرداخته است که در ادامه به توضيح اين تحقيقات پرداخته می شود. (بيزبن و همکارانش، ۲۰۰۳) در تحقيقی از ماشين بردارپشتيبان همراه با ديگر طبقه بندی کنندها در چندين پايگاه داده استفاده کردند. آنها اعلام کردند که ماشين بردار پشتيبان در مقاييسه با ديگر الگوريتمها عملکرد بهتری دارد ولی همواره بهترین عملکرد را ندارد. (اصچباش و استكينگ، ۲۰۰۵) از ماشين بردار پشتيبان در وام های اعتباری استفاده کردند و به اين نتیجه رسيدند که ماشين بردار پشتيبان نسبتاً بهتر از رگرسيون لجستيک عمل می کند ولی تفاوت زيادي با آن ندارد. در هر دوی اين مقالات از ماشين بردار پشتيبان خطى و هستوي RBF استفاده شده و در هر دو مورد، اندازه هي پايگاه داده اعتباری بكار رفته خيلي کوچکتر از اندازه هي واقعی آن است. (وان گستل و همکارانش، ۲۰۰۶) از حداقل محدودرات ماشين بردار پشتيبان با هسته هي بيزيين برای طبقه بندی ورشکستگي بانک ها استفاده کردند. اين محققان تفاوت مهم و معنی داري بين ماشين بردار پشتيبان، رگرسيون لجستيک و LDA پيدا نکردند. (هوانگ، چن، هسو، ۲۰۰۴) به مقاييسه ماشين بردار پشتيبان با شبکه های عصبی در پيش بينی رتبه های اعتباری سازمان ها پرداختند ولی به تفاوت ناچيزی در عملکرد دست یافتند. (لي^۱، ۲۰۰۷) به نتایج مشابهی در مورد وام های سازمانی دست یافت. (هوانگ و وانگ^۲، ۲۰۰۷) به اين نتیجه رسيدند که طبقه بندی اعتباری ماشين بردارپشتيبان دقیق تر از شبکه های عصبی، درخت تصميم يا الگوريتم ژنتيک نیست واهمیت نسبی استفاده از ويژگي های

3 . Tian-Shyug Lee & et al.

4 . Cheng- Lung, Huang& et al.

1 . Lee

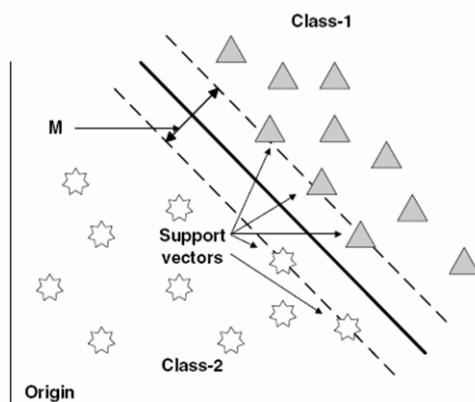
2 . Huang& Wang

اعتباری، مساله تحقیق، پیش‌بینی الگوی رفتاری- بازپرداخت- مشتریان تسهیلات اعتباری در بانکهای ایران است. لذا در این مقاله به دنبال شناسایی الگوی مناسبی جهت طبقه‌بندی مشتریان اعتباری یک بانک با استفاده از الگوریتم ماشین بردار پشتیبان به عنوان یکی از ابزارهای داده کاوی هستیم.

ماشین بردار پشتیبان

ماشین بردار پشتیبان یک طبقه‌بندی کننده‌ی دوتایی است که با استفاده از نگاشت داده‌ها از فضای ورودی اصلی به فضایی با بعد بالاتر برای جداسازی آن‌ها عمل می‌کند (اطلوعی، مقدوری، ۱۳۸۸). این مدل ابرصفحه‌ای را جستجو می‌کند که فاصله‌اش با داده‌های دو کلاس ماکریم است. در این روش سعی بر آنست تا جهت بدست آوردن مرز کلاس‌ها، سیستمی با ظرفیت کمینه و یا به بیان بهتر سیستمی با حداقل پیچیدگی پیاده‌سازی شود. در نتیجه ماشین بردار پشتیبان می‌تواند با استفاده از داده‌های آموزشی کمتر نسبت به روش‌های رقیب، مرزهای سیستم را با دقت مناسبی تخمین بزند، بدون آنکه تعمیم پذیری سیستم را محدود نماید (منیری، ۱۳۸۵). در واقع هدف اصلی طبقه‌بندی کننده‌ی ماشین بردار پشتیبان دستیابی به یک تابع $f(x)$ است که این تابع تعیین کننده‌ی ابرصفحه است. این ابرصفحه دو کلاس را به طور بهینه از هم جدا می‌کند که در شکل انشان داده شده است. در این شکل، M ، حاشیه است یعنی فاصله‌ی ابرصفحه از نزدیکترین نقاط هر دو کلاس (چیا مینگ، ۲۰۰۹).

شکل ۱: ماشین بردار پشتیبان در حالت خطی (چیا مینگ، ۲۰۰۹)



بیان مساله

اعطای تسهیلات، بخش مهمی از عملیات هر بانک را تشکیل می‌دهد و این قسمت از فعالیت‌های بانکی از لحاظ اقتصادی اهمیت زیادی دارد. زیرا افزایش کمی سرمایه، باعث رشد و توسعه اقتصادی می‌شود. در اعطای تسهیلات، بانکها با خطر بزرگی که به آن ریسک اعتباری می‌گویند مواجه هستند. این ریسک علت مواجهه بانک‌ها با بحرانهای عمدۀ مالی است. ریسک اعتباری را می‌توان احتمال عدم بازپرداخت وام از طرف متقاضی در نظر گرفت که بایستی مدیریت گردد (مین، ۲۰۰۶). برای مدیریت ریسک اعتباری از روش‌های مختلفی می‌توان استفاده کرد که یکی از این روش‌ها طراحی نظام تعیین درجه اعتباری برای دریافت کنندگان تسهیلات است (خبراری، ۱۳۸۷). در واقع در این تحقیق به دنبال شناسایی الگوهای رفتاری مشتریان و در نتیجه ایجاد امکان پیش‌بینی رفتارهای مشتریان آتی هستیم. ارزیابی اعتبار مشتریان کار بسیار پیچیدگی ای است زیرا تعداد زیاد عوامل و پیچیدگی روابط مالی، اقتصادی و رفتاری، ارزیابی اعتباری را بسیار دشوار می‌سازد. از طرفی امر ارزیابی اغلب باید در محدوده زمانی کوتاهی صورت گیرد، زیرا طولانی شدن فرآیند ارزیابی باعث تاخیر در عملیات و در نهایت باعث افزایش هزینه‌ها خواهد شد. از طرف دیگر عدم دقت احتمالی در ارزیابی می‌تواند به تصمیمات اشتباه و نهایتاً زیان‌های گزاف منجر گردد. همچنین محدودیت زمانی و ضرورت دقت در ارزیابی، پیچیدگی موضوع را دو چندان می‌کند (خبراری، ۱۳۸۷).

همچنین یکی از مشکلات اساسی اعطای اعتبار، ضوابط اخذ وثیقه و یا آورده نقدی از طرف متقاضیان استفاده از اعتبارات و تسهیلات شبکه بانکی است. تجزیه و تحلیل اطلاعات نشان می‌دهد که ۷۰٪ جامعه مورد مطالعه، ضوابط اخذ وثیقه و انعطاف ناپذیر بودن معیارهای ارزیابی جهت جلوگیری از سوخت شدن اصل و سود تسهیلات را یکی از مشکلات دسترسی به تسهیلات و اعتبارات اعطایی سیستم بانکی، می‌دانند. همچنین حدود ۹۴٪ از پاسخ دهنده‌گان، طولانی بودن زمان ارزیابی‌ها را مشکل آفرین بیان نموده‌اند (نادعلی، ۱۳۸۷). با توجه به شرایط بازار اعتباری و با در نظر گرفتن انواع سیستم‌های رتبه‌بندی

حد فاصل بین دو ناحیه توسط تفاضل مرزهای ۲ ناحیه
زیر بدست می آید:

$$\begin{aligned} w \cdot x + b &= 1 \\ w \cdot z + b &= -1 \end{aligned}$$

در نتیجه داریم:

$$w \cdot (x-z) = 2, w / \|w\| \cdot (x-z) = 2 / \|w\| \quad (3)$$

حال، جهت بدست آوردن مرز بهینه باید فاصله‌ی بین دو ناحیه بیشینه شود؛ یعنی مقدار $\|w\|$ کمینه شود، لذا داریم:

$$\text{Min } 1/2 \|w\|^2; \quad y_k((w \cdot x_k) + b) \geq 1 \quad k=1,2,\dots,m \quad (4)$$

حل این مساله‌ی بهینه سازی کار مشکلی است، برای ساده‌تر کردن آن از روش ضرایب لاگرانژ استفاده و مقادیر بهینه‌ی w, b بدست آورده می‌شود.

$\text{Max} (\min L(w, b, \alpha))$

$$\begin{aligned} \alpha \geq 0 \quad w, b \\ L(w, b, \alpha) = 1/2 \|w\|^2 - \sum \alpha_k (y_k((w \cdot x_k) + b) - 1) \end{aligned} \quad (5)$$

دو گان روابط فوق بصورت زیربیان می‌شود:

(6)

$$\begin{aligned} \frac{\partial}{\partial b} L(w, b, \alpha) &= 0 \rightarrow \sum \alpha_k y_k = 0 \\ \frac{\partial}{\partial w} L(w, b, \alpha) &= 0 \rightarrow w = \sum \alpha_k y_k x_k \end{aligned}$$

حال اگر مقدار w را در تابع $f(x) = \text{sign}(w \cdot x + b)$ جاگذاری کنیم، رابطه‌ی زیر بدست می‌آید (مینگ چی، ۲۰۰۹، و چن ما، ۲۰۰۸):

$$f(x) = \text{sign}(\sum \alpha_k y_k (x \cdot x_k) + b) \quad (7)$$

و پ نیک برای محاسبه‌ی مرز جداکننده‌ی ۲ کلاس کاملاً جدا از هم، روش حاشیه‌ی بهینه را پیشنهاد کرد. در واقع باید یک مرز خطی را بین ۲ کلاس به گونه‌ای محاسبه کنیم که:

تمام داده‌هایی که به کلاس ۱+ تعلق دارند در یک طرف مرز قرار گیرند و تمام داده‌هایی که متعلق به کلاس ۱- هستند در طرف دیگر مرز واقع شوند.

مرز تصمیم گیری بایستی به گونه‌ای باشد که فاصله‌ی نزدیک ترین نمونه‌های آموزشی هر دو کلاس از یکدیگر در راستای عمود بر مرز تصمیم گیری تا جایی که ممکن است حداقل شود (منیری، ۱۳۸۵).

در ماشین بردار پشتیبان به دو طریق می‌توان مجموعه نقاط را از هم جدا کرد: ۱- خطی ۲- غیرخطی (اوچی، ۲۰۰۹).

در حالت خطی، ماشین بردار پشتیبان با در نظر گرفتن مجموعه‌ی آموزشی R_n و $k=1,2,\dots,m$ ، x_k و y_k ، ابرصفحه بهینه با حداقل حاشیه را از طریق حل مساله بهینه سازی زیر پیدا می‌کند:

$$y_k((w \cdot x_k) + b) \geq 1 \quad k=1,2,\dots,m; \quad \text{Min } 1/2 \|w\|^2 \quad (1)$$

با توجه به انتخاب مقادیر w, b ابرصفحه‌های جداکننده‌ی زیادی وجود دارد. در روش ماشین بردار پشتیبان تلاش می‌شود تا بهترین صفحه‌ی جداکننده‌ی دو کلاس بدست آید. ثابت می‌شود که صفحه‌ی بهینه دارای بیشترین فاصله‌ی بین مرزها است. رابطه‌ی $w \cdot x + b = 1$ بیانگر مرز ناحیه‌ی ۱ و $w \cdot x + b = -1$ بیانگر مرز ناحیه‌ی -1 است.

مرزهای دو ناحیه ای دو ناحیه ای دهنده‌ی صفحه‌ی جداکننده است (طولی، مقدوری، ۱۳۸۸، و منیری، ۱۳۸۵).

$$\begin{aligned} y=1 &\quad w \cdot x + b \geq 1 \\ y=-1 &\quad w \cdot x + b \leq 1 \end{aligned}$$

در نتیجه:

$$y \cdot \text{sign}(w \cdot x + b) \geq 1 \quad (2)$$

می‌شود. با تعمیم معادلات لاگرانژ به حالت جدانانپذیر و حل آن مشاهده می‌شود (منیری، ۱۳۸۵).

$$\sum_{k=1, \dots, m} \alpha_{kk} y_k = 0 \quad (11)$$

$$w = \sum_{k=1, \dots, m} \alpha_{kk} y_k; \quad 0 \leq \alpha_{kk} \leq c$$

در حالتی که داده‌ها جدانانپذیرند و کلاس‌ها باهم همپوشانی دارند، جدا کردن کلاس‌ها توسط مرز خطی همواره با خطا همراه است (منیری، ۱۳۸۵). برای حل این مشکل می‌توان ابتدا داده‌ها را از فضای اولیه R^n با استفاده از یک تبدیل غیرخطی ϕ به فضایی مانند H منتقل کرد که در فضای جدید کلاس‌ها تداخل کمتری باهم داشته باشند (منیری، ۱۳۸۵). سپس در فضای جدید با استفاده از معادلات قبلی و جایگزینی y_k با $\phi(x)$ ، مرز بهینه را محاسبه نمود. درواقع در این حالت داده‌های آموزشی در فضای اولیه (وروپی) توسط یکتابع هسته‌ی ϕ به فضای ویژگی که دارای بعد بیشتری است، منتقل می‌شوند (بلوتوی، ۲۰۰۸) و (هوانگ، ۲۰۰۷). لذا در این حالت یافتن مرز بهینه به حل مساله‌ی بهینه سازی زیر تبدیل می‌شود (بلوتوی، ۲۰۰۸).

$$\text{Max}[-1/2 \sum_{k=1, \dots, m} \sum_{j=1, \dots, m} \alpha_{kj} y_k \alpha_j y_j K(x_k, x_j)] \quad (12)$$

$$0 \leq \alpha_{kj} \leq c; \quad \sum_{k=1, \dots, m} \alpha_{kj} y_k = 0$$

که در آن $K(X_k, X_j) = (\phi(X_k), \phi(X_j))$. لذا ابرصفحه‌ی بهینه‌ی $f(x)$ در حالت غیرخطی بصورت زیر خواهد بود:

$$F(x) = \sum_{k=1, \dots, m} \alpha_{kj} y_k K(x_k, x_k) + b = \sum_{k=1, \dots, m} \alpha_{kj} y_k K(x_k, x_k) \quad (13)$$

$$i \in SV$$

تابع هسته‌ای زیادی وجود دارند که در زیر به آنها اشاره می‌کنیم (چیا مینگ، ۲۰۰۹).

تابع هسته خطی

$$K(x_k, x_j) = (x_k, x_j)$$

تابع هسته‌ی چندجمله‌ای

$$K(x_k, x_j) = (x_k, x_j+1)^d$$

ضرایب α در رابطه‌ی فوق، ضرایب لاگرانژ نامیده می‌شوند. به ازای بسیاری از x ها، ضرایب α برابر صفر است و تنها ضرایب محدودی غیرصفر است نقاطی که به ازای آنها ضرایب K مخالف صفر هستند، بردارهای پشتیبان نامیده می‌شود و همین نقاط، تعیین کننده‌ی مرز جداکننده هستند (هوانگ و هسین چان، ۲۰۰۶).

هرچه مقدار α کوچکتر باشد تاثیر x در مرز جداکننده کمتر است. در نقاط بردار پشتیبان، α مخالف صفر است. در این صورت در این نقاط داریم:

$$y_k ((w \cdot x_k) + b) = 1 \quad (8)$$

یعنی بردارهای پشتیبان روی مرز قراردارند. الگوریتم بالا برای یافتن مرز دو کلاس کاملاً جدا از هم بود که حاصل آن یک مرز خطی است.

بردارهای پشتیبان برای داده‌های جدانانپذیر در حالت جدانانپذیر، نتایج بخش قبل گسترش داده می‌شود.

Cores در سال ۱۹۹۵ برای این که بتواند در این حالت یک ابرصفحه‌ی بهینه را برای جداسازی ۲ کلاس بdest آورد، متغیرهای نامنفی ≥ 0 را بعنوان مقدار خطای برای هر بردار تعریف کرد. در این حالت معادلات $w \cdot x + b \geq 1$ و $w \cdot x + b \leq -1$ تبدیل به معادلات زیرمی‌شوند:

$$w \cdot x_k + b \geq 1 - \varepsilon_k y_k = 1 \quad (9)$$

$$w \cdot x_k + b \leq -1 + \varepsilon_k y_k = -1$$

مقدار K خطای هر داده تا مرز ناحیه‌ی مربوط به خود است و مقدار K $\sum_{k=1, \dots, m} \varepsilon_k$ یک خطای حد آموزش است. حال بجای کمینه کردن مقدار $||w||^2/2$ باشد عبارت زیر کمینه شود. (هوانگ، ۲۰۰۷) و (فاتیح آکای، ۲۰۰۹).

$$\min ||w||^2 + c \left(\sum_{k=1, \dots, m} \varepsilon_k \right) \quad (10)$$

$$y_k ((w \cdot x_k) + b) + \varepsilon_k - 1 \geq 0 \quad \varepsilon_k \geq 0$$

در این رابطه c مقدار ارزش خطای را مشخص می‌کند. اگر c عدد بزرگی انتخاب شود، توجه بیشتری به خطای داده

مراحل انجام داده کاوي طبق استاندارد CRISP

مدل فرایندي داده کاوي CRISP، يك متدولوژي استاندارد داده کاوي می باشد که چرخه عمر يك پروژه داده کاوي را نشان می دهد. اين مدل شامل مراحل مرتبط يك پروژه و وظایيف مربوط و ارتباط بين اين وظایيف است. چرخه عمر يك پروژه داده کاوي طبق اين استاندارد، شامل ۶ مرحله است که در ادامه بيان شده است(نادعلي،۱۳۸۷).

طبق استاندارد CRISP، فرایند داده کاوي شامل

موارد زير است:

- درک مساله کسب و کار
- درک دادهها
- آماده سازی دادهها
- مدل سازی
- ارزیابی نتایج
- بکارگیری مدل

درک مساله کسب و کار

در اين فاز از فرایند تحقیق، ابتدا اهداف اصلی کسب و کار تعیین گردید، که اصلی ترین هدف کسب و کار(بانک مورد مطالعه) در این تحقیق، پیش بینی وضعیت اعتباری مشتریان حقوقی بانک مورد مطالعه می باشد و این کار بر اساس کشف الگوهای پنهان موجود بین خصیصه های مشتریانی است که سابقاً "تسهيلات اعتباری به آنها اعطای شده است (نادعلي،۱۳۸۷). بر همین اساس موقعیت موجود محیط که بخش اعتبارات بانک می باشد مورد ارزیابی قرار گرفت؛ تا فرایند اعطای اعتبار به مشتریان و برسیهای کارشناسی خبرگان اعتباری بررسی شد. همچنین نحوه اخذ اطلاعات از مشتریان مورد بررسی دقیق قرار گرفت تا شناخت مناسبی از وضعیت کلی طبقه بندی به مشتریان در حالت فعلی کسب شود (نادعلي،۱۳۸۷).

درک دادهها

در اين مرحله گام های زير دنبال شده است که جزئيات آنها در ادامه بيان شده است (نادعلي،۱۳۸۷):

- جمع آوري دادههای اولیه

تابع هسته‌ی RBF

$$K(x_k, x_j) = \exp(-\gamma \|x_k - x_j\|^2)$$

پارامترهای توابع هسته باید به گونه‌ای انتخاب شوند که صحت طبقه بندی ماشین بردار پشتیبان را فزایش دهند (حسین، ۲۰۰۴). در این تحقیق از تابع هسته‌ی RBF استفاده شده است.

شرح روش تحقیق(متدولوژی تحقیق) ساختار

اجرايی تحقیق

تحقیق حاضر از این حیث که نوعی الگو برای مدیران و تصمیم گیرندگان ارائه می کند تحقیق کاربردی به حساب می آید و از جمع آوري داده شروع شده و سعی در کشف يك سري قوانين دارد. لذا در اين تحقیق از روش كشف دانش استفاده شده است و مراحل اجرائي آن به شرح زير می باشد:

۱- جمع آوري داده از پايگاه دادههای موجود و پيش پردازش آنها

۲- انتخاب ويزگیهای تاثير گذار در رفتار اعتباری مشتریان

۳- انتخاب تابع هسته و تنظيم پارامترهای مربوط

۴- تقسيم دادههای نمونه به دو مجموعه دادههای آموزشي^۱ و دادههای تست^۲،

۵- استفاده از الگوریتم ماشین بردار پشتیبان روی مجموعه آموزش

۶- آزمون مدل با مجموعه دادههای تست؛

۷- اعتبارسنجی مدل و مقایسه با ديگر مدل‌های طبقه بندی.

همچنین با توجه به اينکه ماهیت تحقیق داده محور^۳ بوده و پایه اصلی تحقیق حاضر بر کشف دانش از پايگاه داده های بانک مورد مطالعه نهاده شده است، لذا از استاندارد جهانی CRISP-DM جهت انجام فرایند تحقیق استفاده شده است؛ که در این بخش ساختار اجرائي تحقیق بر اساس مراحل اين استاندارد تشریح شده است.

1 . Training Data Set

2 . Test Data Set

3 . Data Oriented

تعريف کلاسها

قالب بندی داده‌ها (برای مدلسازی در نرم‌افزار از آنجا که حجم داده‌های خام بسیار بالا است و فرمت آنها نیز فرمت استاندارد الگوریتم بکار رفته نیست، لذا در این مرحله با استی اقدامات پاکسازی داده‌ها و کاهش حجم آنها صورت گیرد. در این مرحله همچنین بررسی‌هایی در مورد ویژگی‌های کلاس‌های خوش حساب و بد حساب صورت گرفت.

- **جمع آوری و انتخاب داده‌ها:** در این مرحله، داده‌های مرتبط با مساله (که در مرحله اول فرایند داده کاوی مشخص شد) از منابع موجود که شامل پرونده‌های متقاضیان تسهیلات اعتباری و پایگاه داده‌های مشتریان بود، جمع آوری شد.

- **یکپاچه‌سازی و پاکسازی سازی داده‌ها:** در صورتیکه داده‌ها از منابع مختلف بدست آمده و دارای فرمت یکسانی نباشند، در این مرحله با استی یک شکل و متجانس شوند و پس از آن کار پاکسازی و ادغام صورت گیرد که عملاً کار سخت و زمانبری است. حذف برخی رکوردها و فیلدها از کارهای صورت گرفته در این مرحله می‌باشد. بسیاری از رکوردها غیرضروری بوده و کمکی به ساخت یک طبقه‌بندی خوب و شناسایی مشتریان بدحساب نمی‌کردند و لذا حجم داده‌ها را کاهش داده و این رکوردها را حذف نمودیم. گاهای در مجموعه داده‌های اولیه، مقادیر گم شده در فیلدهای برخی رکوردها وجود داشت و یا در بعضی موارد، مقادیر تخصیص یافته به متغیرها اشتباه بودند که تصحیح و یا حذف شدند.

- **کاهش داده‌ها:** در این مرحله، علی‌رغم پاکسازی و پیش پردازش داده‌ها در مرحله قبل، مواردی از مشتریان با اطلاعات ناکافی وجود داشت که از مجموعه داده‌ها حذف شدند.

- **کاهش ابعاد داده‌ها:** افزایش ابعاد داده‌ها باعث پیچیدگی فرایند و افزایش زمان آموزش و همچنین پائین آمدن کیفیت جواب می‌شود. لذا تعدادی از ویژگی‌ها از جمله نام متقاضی و ... که بی‌تأثیر بودند با استفاده از روش F-score شناسایی و حذف شدند که نتیجه آن افزایش استقلال بین متغیرها می‌باشد.

- توصیف داده‌ها

- جستجو در داده‌ها و بررسی کانال‌های دسترسی
- تصدیق کیفیت داده‌ها و شناسایی داده‌های هدف در مجموع، مهمترین سوالاتی که در این بخش به آنها پاسخ داده شود، ۲ سوال می‌باشد: چه داده‌هایی مورد نیاز است؟ داده‌ها کجا هستند؟

در این مرحله برای ارزیابی اولیه از داده‌های موجود، ابتدا، پایگاه داده‌های موجود در بانک که داده‌های اعتباری مشتریان حقوقی را در خود ذخیره نموده اند، جستجو شد و طبق اظهارات مدیران و کارشناسان مربوطه، نحوه دسترسی به آنها مورد بررسی قرار گرفت.

در این مرحله محقق با نمونه‌هایی از داده‌های موجود در پایگاه‌های فوق آشنا شده و آموزش لازم جهت اخذ داده‌ها و اطلاعات مورد نیاز از سیستم‌های عملیاتی کامپیوتری (ماژول‌های تسهیلات اعتباری و ماژول مشتریان) را فرا گرفته تا با نحوه ذخیره داده‌ها و کسب اطلاعات از آنها آشنایی کامل پیدا کند (نادعلی، ۱۳۸۷).

داده‌های مورد نظر تحقیق عبارتند از: مشتریان حقوقی و خصیصه‌های هر یک از آنها؛ که در ادبیات اعتباری به عنوان متغیرهای تاثیرگذار در رفتار اعتباری شناخته شده اند. بنابراین فقط این نوع ویژگی‌ها از پایگاه داده‌ها مورد نظر بوده و جمع آوری خواهد شد. هر چند پایگاه‌های داده مملو از داده‌های زائد می‌باشند که از ثبت آنها صرف نظر می‌گردد.

بنابراین نهایتاً در این مرحله، محقق، داده‌هایی را که باید جمع آوری و پالایش نماید، شناسایی نمود.

آماده سازی داده‌ها برای مدل

در این قسمت، همانطور که از نام آن پیداست باید داده‌های خام را برای ورود به الگوریتم آماده کرد. در این تحقیق، آماده سازی داده‌ها به عنوان بخشی از فرایند داده کاوی، دارای مراحل زیر می‌باشد که در ادامه به تصریح فرایند بکار رفته می‌پردازیم:

جمع آوری و انتخاب داده‌ها

یکپاچه‌سازی داده‌ها

پاکسازی داده‌ها

کاهش ابعاد داده‌ها

ارزیابی نتایج

در این مرحله مدل موردنظر با دیگر مدل ها مقایسه و ارزیابی می شود. معیارهای ارزیابی شامل دقت پیش بینی، سرعت و ... می باشد. روش های ارزیابی شامل ماتریس اغتشاش^۱، منحنی ROC، تابع هزینه و غیره است که در این تحقیق از ماترس اغتشاش استفاده شده است و نتایج آن در ادامه آمده است. هدف ارزیابی، انتخاب مدل مناسب و یا در صورت امکان، مدل بهینه در بین تعدادی از مدل هاست.

مرحله اعتبارسنجی و ارزیابی مدل: در این بخش شیوه ارزیابی مدل و همچنین سنجش کارایی مدل به لحاظ قدرت تفکیک مشتریان در مقایسه با الگوریتم های مختلف و کارشناسان بانک مورد مطالعه، تشریح شده است.

اعتبارسنجی عرضی n لایه: برای دستیابی به یک تخمین پایا و کمینه کردن تاثیر وابستگی به داده های خاص در مدل ارزیابی اعتبار جدید، برای ساخت بخش های تصادفی، n -fold cross validation از مجموعه داده ها، از استفاده شد. در این رویه، مجموعه داده ها به k گروه مستقل تقسیم می شوند. الگوریتم با استفاده از $k-1$ گروه آموزش داده می شود و تنها با استفاده از گروه k ام تست می شود. این رویه تا زمانی تکرار می شود که هر گروه به عنوان گروه آزمایش نیز بکار رفته باشد. مزیت رویه اعتبارسنجی k لایه، استفاده از تمامی لایه ها برای آموزش و همچنین تست الگوریتم ها است. برآورد دقت الگوریتم ها در اعتبارسنجی چندلایه بسیار بیشتر از روش های معمولی قابل اعتماد است. در این تحقیق مقدار k برابر ۵ است.

در انتهای برای ارزیابی قابلیت اطمینان روش ارائه شده، نتایج الگوریتم مورد استفاده را با الگوریتم های دیگر مانند الگوریتم درخت های تصمیم ، شبکه های عصبی، شبکه های بیزین، رگرسیون لجستیک و ... نیز استفاده شده است. برای اعمال این تکنیک ها از نرم افزار های مربوطه استفاده شده است. نتایج حاصله از انجام این کار در جداول ۱-۵ تا ۱۰-۱ ارائه شده است. نتایج حاکی از آن است که مدل پیشنهادی نه تنها دارای بهترین نرخ

- **تعريف کلاسها:** در تعداد اندکی از پرونده های مورد بررسی، نوع کلاسها مشخص نشده و یا به اشتباه مشخص شده بود که اصلاحات لازم صورت گرفت.
- **قابل بندی داده ها (برای مدلسازی در نرم افزار):** همچنین با توجه به ماهیت داده ها در الگوریتم ماشین بردار پشتیبان، کلیه متغیرهای اسمی، عددی شده و پس از آن بمقیاس شده و با استفاده از فرمول زیر به بازه $[0,1]$ منتقل شده اند.

$$x' = \frac{x - \min_a}{\max_a - \min_a}$$

تحلیل داده ها و ساخت مدل

با داشتن مجموعه داده مناسب با فرمت استاندارد، می توان مرحله بعد را شروع کرد. هدف این مرحله ساخت مدلی جهت اعتبارسنجی متقارضیان تسهیلات اعتباری با استفاده از داده های در دسترس است. از تکنیک های داده کاوی متعددی می توان در این مرحله استفاده نمود که در این تحقیق از ماشین بردار پشتیبان استفاده شده است.

آموزش مجموعه داده های آماده سازی شده
در این مرحله، داده های آماده توسط الگوریتم ماشین بردار پشتیبان دو کلاسه غیرخطی آموزش داده شدند و بعد نتایج آن با دیگر الگوریتم ها مقایسه شدند که در بخش های آتی به توضیح آن خواهیم پرداخت.

- **زیر فرایند مرتبط با داده**
در این قسمت از تکنیک f-score برای پیش پردازش داده ها جهت بهبود کیفیت داده های ورودی استفاده شده است.

- **زیر فرایند مرتبط با مدل**
در این بخش داده ها را با استفاده از تکنیک ماشین بردار پشتیبان مدل سازی نموده و پس از آن در مرحله بعدی تحلیل های لازم در خصوص اعتبارسنجی مدل و کارایی آن ارائه می گردد.

استفاده از طبقه بنده کننده‌ی ماشین بردار پشتیبان، تست و در نهایت اعتبار سنجی برای نمونه‌های جدید می‌باشد (چن، ۲۰۰۸). همانطور که می‌دانیم تنظیم درست پارامترهای مدل، می‌توانند صحت مدل طبقه بنده کننده‌ی بهینه‌ی ماشین بردار پشتیبان را بالا ببرند (چن، ۲۰۰۸). پارامترهایی که باستی در صورت استفاده از هسته‌ی RBF بهینه شوند، عبارتند از: گاما. در این تحقیق برای پیدا کردن ویژگی‌های مدل از تکنیک F-Score و پارامترها از Grid Search استفاده شده است. شکل ۲ رویه‌ی مدل مبتنی بر ماشین بردار پشتیبان را نشان می‌دهد.

برای بهبود صحت اعتبارسنجی از F-Score برای انتخاب ویژگی‌ها والگوریتم Grid Search برای بدست آوردن پارامترهایی بهینه استفاده شده است (چن، ۲۰۰۸). در الگوریتم Grid Search برای هر جفت پارامتر، 5-fold cross validation روش مجموعه آموزش بکاررفته است واز نرم افزار Weka برای بکارگیری واجرای ماشین بردار پشتیبان استفاده شده است.

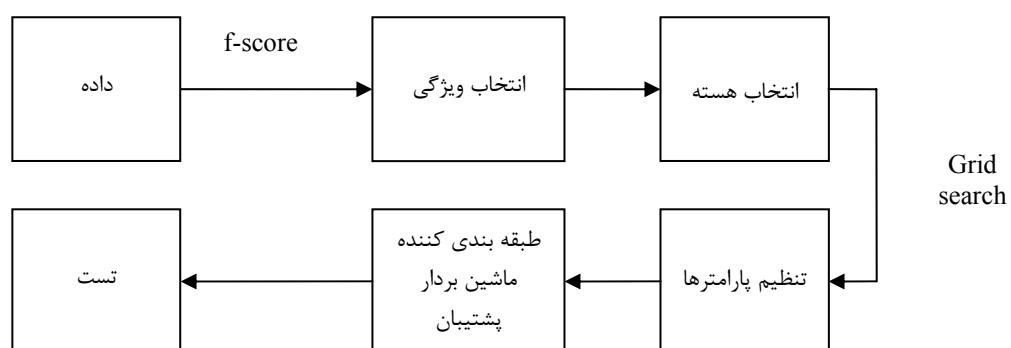
طبقه بنده است بلکه دارای کمترین خطای نوع دوم نیز هست.

بکارگیری مدل

کاراصلی تحلیل گر داده^۱ یا داده کاو^۲ در مرحله قبل تقریباً به اتمام رسیده و در این تحقیق نیز نتایج، بصورت یک گزارش از کل کار در اختیار بانک مورد مطالعه قرار می‌گیرد تا بانک نیز بر اساس استراتژی‌های خود راجع به استفاده از نتایج تصمیم گیری نماید.

رویه‌ی اعتبار سنجی مبتنی بر ماشین بردار پشتیبان اعتبار سنجی در واقع شامل طبقه بنده و رتبه‌های (خوب و بد) تخصیص یافته به مقاضیان و شرایط متقاضی از قبیل مقدار وام، موقعیت کاری، اطلاعات شخصی، سن و... به عنوان متغیرهای طبقه بنده است. رویه‌ی اعتبار سنجی مبتنی بر ماشین بردار پشتیبان شامل: جمع آوری داده و پیش پردازش آن، انتخاب ویژگی‌ها، انتخاب هسته و پارامترهای مربوطه، آموزش،

شکل ۲: رویه مبتنی بر ماشین بردار پشتیبان



1 . Data Analyst

2 . Data Miner

فرایند اعتبارسنجی متقابل را انجام داده و میانگین صحت کلی را برای تمامی k بخش حساب می شود.
این رویه به ترتیب زیر می باشد:

گام (۱) محاسبه F-Score برای هریک از ویژگی ها
گام (۲) دسته بندی F-Score و محاسبه مقدار ممکن ویژگی ها با استفاده از فرمول $[n / 2^i]$ که $f = \{0, \dots, m\}$ عدد صحیحی است که:
 $n / 2^m \geq 1$

- گام (۳) انجام مراحل زیر برای هر یک از f ها:
 - حفظ ویژگی های f اول بدست آمده از F-Score
 - تقسیم داده های آموزشی بطور تصادفی به ۲ قسمت 5-fold cross $D_{\text{validation}}$ با استفاده از D_{training} و تکرار مراحل زیر برای هر یک از fold ها.
 - در نظر گرفتن D_{training} به عنوان داده ای آموزشی جدید و استفاده از رویه ای ماشین بردار پشتیبان جهت رسیدن به یک پیشگویی کننده و پس از آن، استفاده از پیشگویی کننده جهت پیش بینی $D_{\text{validation}}$
 - محاسبه متوسط خطای صحت validation
- گام (۴) انتخاب f دارای حداقل متوسط خطای صحت
- گام (۵) حذف ویژگی هایی که دارای F-Score کمتر از f هستند.

استخراج ویژگی های مهم

جدول زیر ویژگی های مهم انتخاب شده توسط تکنیک f-score و ویژگی های انتخابی طبق نظر خبرگان را نشان می دهد. محاسبه مقادیر F_i در f-score نشان می دهد. محاسبه مقادیر F_i در f-score weka نرم افزار Excel و بقیه مراحل آن توسط نرم افزار weka انجام شده است. جدول ۱، مقادیر f-score مربوط به هر ویژگی را نشان می دهد. با توجه به محاسبات، مقدار $n=26$ می باشد. همچنین تعداد ویژگی های اولیه ۱۹ است، لذا داریم :

انتخاب ویژگی

سه مساله ای اساسی هنگام استفاده از ماشین بردار پشتیبان در طبقه بندی وجود دارد که عبارتنداز: (۱) انتخاب ویژگی های بهینه (۲) انتخاب هسته (۳) تعیین پارامترهای هسته (چن، ۲۰۰۸).

انتخاب ویژگی یکی از مباحث مهم در ساخت مدل های طبقه بندی است. هرچه تعداد ویژگی های ورودی کمتر باشد پیش بینی بهتر صورت گرفته و میزان پیچیدگی محاسباتی مدل ها کاهش می یابد (هوانگ، ۲۰۰۷). در واقع انتخاب ویژگی های یکی از مسائل اساسی بهینه سازی است که شامل جستجو در فضا برای یافتن ویژگی هایی است که یا بهینه اند و یا نزدیک به بهینه اند و این امر با در نظر گرفتن یک معیار عملکردی معین مانند صحت، صورت می گیرد (مین، ۲۰۰۶).

F-Score

Rosch F-Score ساده ترین تکنیک برای انتخاب ویژگی هاست که تفاوت دو مجموعه از اعداد حقیقی را اندازه گیری می کند. با در نظر گرفتن بردارهای آموزش x_k و x_i به عنوان تعداد نمونه های $k=1, \dots, m$ ؛ n_+ و n_- مثبت و منفی F-Score مربوط به i امین ویژگی بصورت زیر تعریف می شود (طوعی، مقدوری، ۱۳۸۸):

$$F_i = \frac{(\bar{x}_i^{(+)} - \bar{x}_i)^2 + (\bar{x}_i^{(-)} - \bar{x}_i)^2}{\frac{1}{n_+} \sum_{k=1}^{n_+} (x_{k,i}^{(+)} - \bar{x}_i^{(+)})^2 + \frac{1}{n_-} \sum_{k=1}^{n_-} (x_{k,i}^{(-)} - \bar{x}_i^{(-)})^2},$$

که $\bar{x}_i^{(+)} , \bar{x}_i^{(-)}$ در آن به ترتیب متوسط کل، مثبت و منفی i امین ویژگی مجموعه داده ها هستند و $x_{k,i}^{(+)} , x_{k,i}^{(-)}$ i امین ویژگی مربوط به k امین نمونه مثبت و i امین ویژگی مربوط به k امین نمونه منفی است. صورت کسر نشان دهنده تفاوت بین مجموعه های مثبت و منفی، و مخرج بیانگر یکی از دو مجموعه است و هرچه مقدار F-Score بیشتر باشد با احتمال بیشتری، آن ویژگی متمایز است (مین، ۲۰۰۶). رویه ای به کار رفته به شرح زیر می باشد:

برای هر زیر مجموعه k تابی از مجموعه داده D ، مجموعه ای آموزشی $T=D-K$ را در نظر می گیریم، سپس

جدول ۱: مقادیر f-score مربوط به ویژگی‌ها

ردیف	ویژگی	f-score	نرخ صحبت متوسط (%)
۱	شغل (job)	14.89	57.6
۲	تحصیلات (education)	13.74	59.3
۳	نوع ونیقه (colla-kind)	11.31	61.7
۴	سابقه اعتباری (bank-ref)	9.52	65.2
۵	سن شرکت (company-age)	4.73	67.5
۶	میزان سرمایه (capital)	2.90	71.8
۷	مقدار وام (money)	2.11	77.4
۸	نوع تسهیلات (contract)	1.07	79.1
۹	نوع مصرف وام (use-kind)	0.83	81.3
۱۰	نوع شرکت (company-kind)	0.57	82.3
۱۱	نسبت جاری (current-ratio)	0.41	83.6
۱۲	نسبت بدهی (debt-ratio)	0.32	85.8
۱۳	نرخ بهره (,benefit ratio)	0.20	86.3

جدول ۲: ویژگی‌های بدست آمده از تکنیک F-score

نوع متغیر	مقادیر	عنوان متغیر	ردیف
کیفی	بازرگانی- خدماتی- تولیدی	شغل (job)	۱
کیفی	۱- زیردیبلم- ۲- دیبلم- ۳- فوق دیبلم- ۴- لیسانس- ۵- فوق لیسانس و بالاتر	تحصیلات (education)	۲
کیفی	۱- چک عادی- ۲- چک تصمینی- ۳- سفته مدیران- ۴- سفته اعتباری- ۵- سند ملکی	نوع ونیقه (colla-kind)	۳
کمی	۱- سابقه منعی: ۱: سابقه مثبت	سابقه اعتباری (bank-ref)	۴
کمی	به صورت عدد است.	سن شرکت (company-age)	۵
کمی	به صورت عدد است.	میزان سرمایه (capital)	۶
کمی	به صورت عدد است.	مقدار وام (money)	۷
کیفی	۱- اقساطی- ۲- مضاربه- ۳- مشارکت مدنی- ۴- جاله	نوع تسهیلات (contract)	۸
کیفی	تولید و صنعت- خدمات- واردات- بازرگانی داخلی	نوع مصرف وام (use-kind)	۹
کیفی	تعاونی- محدود- عام- خاص	نوع شرکت (company-kind)	۱۰
کمی	به صورت درصد است.	نسبت جاری (current-ratio)	۱۱
کمی	به صورت درصد است.	نسبت بدهی (debt-ratio)	۱۲
کمی	به صورت درصد است.	نرخ بهره (,benefit ratio)	۱۳

جدول ۳: ویژگی های بدست آمده طبق نظر خبرگان

ردیف	عنوان متغیر	مقادیر	نوع متغیر
۱	زمینه فعالیت	بازرگانی- خدماتی- تولیدی	کیفی
۲	تحصیلات	۱- زیر دیبلم- ۲- دیبلم- ۳- فوق دیبلم ۴- لیسانس- ۵- فوق لیسانس و بالاتر	کیفی
۳	نوع وثیقه	۱- چک عادی- ۲- چک تضمینی- ۳- سفته مدیران- ۴- سفته اعتباری- ۵- سند ملکی	کیفی
۴	شخصیت حقوقی و اجتماعی فرد(سابقه اعتباری)	۱- سابقه منفی ۱: سابقه مثبت	كمی
۵	نوع مصرف وام	تولید و صنعت- خدمات- واردات- بازرگانی داخلی	کیفی
۶	سال تاسیس شرکت	به صورت عدد است.	كمی
۷	نوع شرکت	تعاونی- محدود- عام- خاص	کیفی

تنظیم پارامترها

و تست ، تقسیم شده است و از Grid-Search برای تعیین و شناسایی آن مقادیر پارامترهایی که دارای بیشترین متوسط صحت اعتبار سنجی مقابل هستند، استفاده شده است. جدول زیر مقادیر (C, γ) بدست آمده را برای مقادیر $2^{-13}, 2^{-11}, 2^{-9}, 2^{-7}, 2^{-5}, 2^{-3}, 2^{-1}, 2^1, 2^3, 2^5$ و 2^7 و مقدار بهینه انتخابی (C, γ)= ۷۹,۹۲ را نشان می دهد.

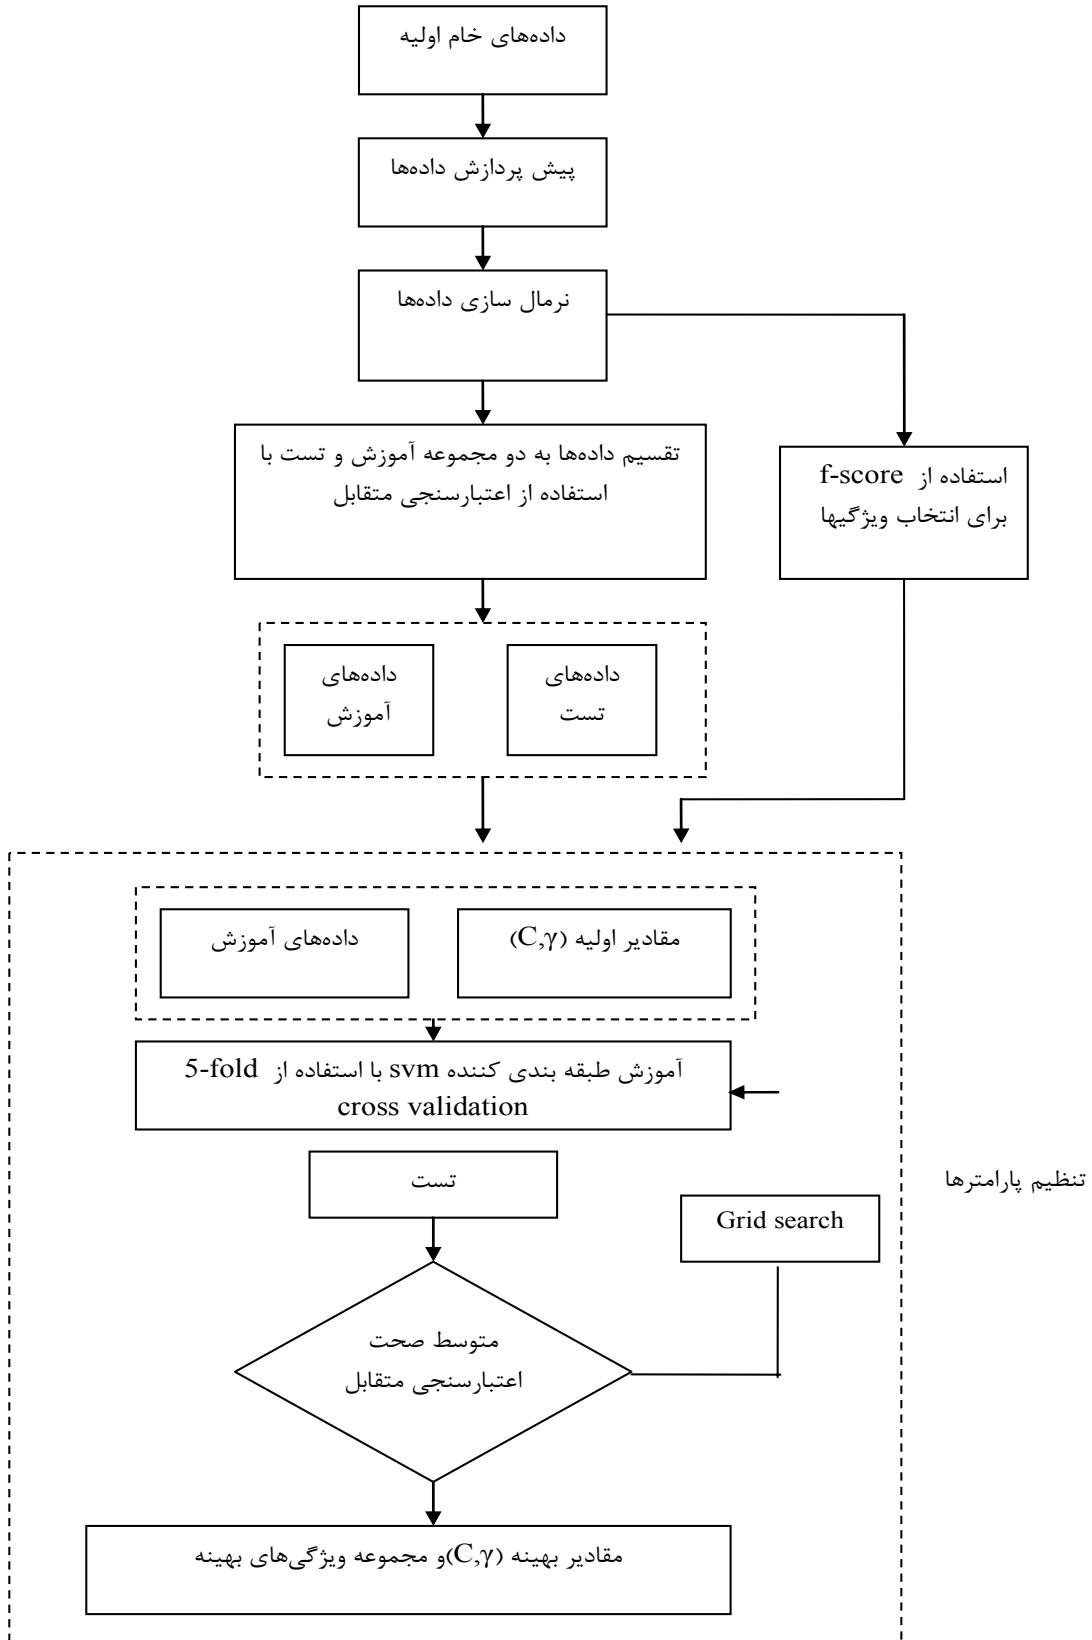
ماشین بردار پشتیبان نیازمند تنظیم یکسری پارامترها قبل از طبقه بندی است (منیری، ۱۳۸۵). این پارامترها روی یک مجموعه داده \mathcal{D} جداگانه می باشند که مجموعه داده \mathcal{D} بکار رفته برای طبقه بندی، تنظیم می شوند که این مجموعه داده بکار رفته برای تنظیم پارامترها شامل ۲۳۶ پرونده است . این مجموعه داده به ۲ قسمت آموزش

جدول ۴: نتایج استفاده از grid search با استفاده از ۵-fold cross validation

C	γ												
		2^{-13}	2^{-11}	2^{-9}	2^{-7}	2^{-5}	2^{-3}	2^{-1}	2^1	2^3	2^5	2^7	
2^{-5}	61.32	61.32	61.32	61.32	61.37	61.32							
2^{-3}	61.32	61.32	61.32	61.37	61.32	77.48	65.3	66.4	67.39	61.32			
2^{-1}	61.32	61.32	61.32	61.37	68.2	79.92	66.29	66.93	67.7	62.02			
2^1	61.32	61.32	62.46	62.46	62.68	78.39	67.09	67.94	68.45	62.28			
2^3	61.32	61.32	62.59	62.51	63.74	77.46	67.52	68.53	66.9	62.69			
2^5	61.32	62.58	62.59	63.61	63.89	75.46	69.49	71.44	70.44	63.7			
2^7	62.47	63.62	63.54	65.24	67.12	75.32	72.46	69.36	71.33	63.54			
2^9	63.54	66.68	67.36	68.37	69.8	75.32	73.38	75.28	71.96	66.34			
2^{11}	66.34	69.84	69.63	70.73	70.72	75.24	75.62	76.39	72.03	69.73			
2^{13}	69.73	69.84	69.91	70.92	72.48	74.11	75.83	76.9	72.28	69.93			

چارچوب اجرائی مبتنی بر ماشین بردار پشتیبان

برای تنظیم پارامترها نیز از نرم افزار weka-libsvm استفاده شده است.



شبکه های بيzin، شبکه های عصبی چند لایه و درخت ژنتيکي که نتایج طبقه بندی هر يك از آنها در جدول های ۱-۵ تا ۱۰-۱۱ نمایش داده شده است. همچنان كارايی مدل با عملكرد كارشناسان اعتبارسنج بانک نيز مقايسه شده است که نتایج آن در جدول ۱۲ آمده است.

مقاييسه الگوريتم های مختلف طبقه بندی جهت بررسی کارایی مدل

برای سنجش كارايی مدل ارائه شده توسط ماشين بردار پشتيبان، صحت نتایج اين مدل با الگوريتم های طبقه بندی ديگري مورد مقاييسه قرار گرفته اند. اين الگوريتم ها عبارتند از: درخت تصميم C4.5 Tree، رگرسيون لجستيک،

نتایج طبقه بندی با مدل SVM

جدول ۵ : ماشين بردار پشتيبان

SVM(Support Vector Machine)		
نمونه های طبقه بندی شده بطور صحيح	181	%76.7
نمونه های طبقه بندی شده بطور غلط	55	%23.3
کل نمونه ها	236	%100

	طبقه بندی شده در کلاس خوش حساب	طبقه بندی شده در کلاس بد حساب	مجموع
کلاس خوش حساب	12	30	150
کلاس بد حساب	25	61	86
مجموع	145	91	236

جدول ۶ : درخت تصميم C4.5 Tree

C4.5 Tree		
نمونه های طبقه بندی شده بطور صحيح	158	%67
نمونه های طبقه بندی شده بطور غلط	78	%33
کل نمونه ها	236	%100

	طبقه بندی شده در کلاس خوش حساب	طبقه بندی شده در کلاس بد حساب	مجموع
کلاس خوش حساب	99	51	150
کلاس بد حساب	27	59	86
مجموع	126	110	236

جدول ۷ : رگرسیون لجستیک-R

Logistic -R		
نمونه های طبقه بندی شده بطور صحیح	153	%64.8
نمونه های طبقه بندی شده بطور غلط	83	%35.2
کل نمونه ها	236	%100

	طبقه بندی شده در کلاس خوش حساب	طبقه بندی شده در کلاس بد حساب	مجموع
کلاس خوش حساب	106	44	150
کلاس بد حساب	39	47	86
مجموع	145	91	236

جدول ۸ : شبکه‌های بیزین

BayesNet		
نمونه های طبقه بندی شده بطور صحیح	170	%72
نمونه های طبقه بندی شده بطور غلط	66	%28
کل نمونه ها	236	%100

	طبقه بندی شده در کلاس خوش حساب	طبقه بندی شده در کلاس بد حساب	مجموع
کلاس خوش حساب	95	55	150
کلاس بد حساب	11	75	86
مجموع	106	130	236

جدول ۹ : شبکه‌های عصبی چند لایه

MultilayerPerceptron

MultilayerPerceptron(MLP)		
نمونه های طبقه بندی شده بطور صحیح	146	%61.8
نمونه های طبقه بندی شده بطور غلط	90	%38.2
کل نمونه ها	236	%100

	طبقه بندی شده در کلاس خوش حساب	طبقه بندی شده در کلاس بد حساب	مجموع
کلاس خوش حساب	128	22	150
کلاس بد حساب	68	18	86
مجموع	196	40	236

جدول ۱۰: درخت ژنتيکي GATree

GATree			
نمونه های طبقه بندی شده بطور صحيح	165	%69.9	
نمونه های طبقه بندی شده بطور غلط	71	%30.1	
کل نمونه ها	236	%100	

	طبقه بندی شده در کلاس خوش حساب	طبقه بندی شده در کلاس بد حساب	مجموع
کلاس خوش حساب	۱۰۳	۴۷	۱۵۰
کلاس بد حساب	۲۴	۶۲	۸۶
مجموع	۱۲۷	۱۰۹	۲۳۶

جدول ۱۱: مقاييسه نتائج صحت مدلها

الگوريتم	SVM	C4.5 Tree	Logistic R	Bayes Net	NN(MLP)	GA Tree
صحت پيش بيني مدل	%76.7	%67	%64.8	%72	%61.8	%69.9

كارابي مدل در مقاييسه با عملكرد كارشناسان اعتبارسنچ بانک

جدول ۱۲: عملكرد كارشناسان اعتبارسنچ بانک در خصوص پيش بيني طبقه مشتريان

كارشناسان اعتبارسنچي بانک			
نمونه های طبقه بندی شده بطور صحيح	134	%56.8	
نمونه های طبقه بندی شده بطور غلط	102	%43.2	
کل نمونه ها	236	%100	

	طبقه بندی شده در کلاس خوش حساب	طبقه بندی شده در کلاس بد حساب	مجموع
کلاس خوش حساب	84	56	150
کلاس بد حساب	46	50	86
مجموع	130	106	236

فراهم گردد. نتایج بدست آمده از این مطالعه نشان داد که متغیرهای نوع وثیقه، سابقه اعتباری و زمینه فعالیت، از جمله مهمترین عوامل تاثیر گذار بر بازپرداخت تسهیلات هستند.

نتایج بدست آمده از برآورد مدل ماشین بردار پشتیبان نشان داد که اگر بانک در پرداخت تسهیلات به اشخاص حقوقی، به عوامل تاثیرگذاری که در این مطالعه مشخص شد توجه کند، می‌تواند احتمال بازپرداخت تسهیلات را افزایش دهد. همچنین نتایج حاصل از مقایسه تکنیک‌ها نشان داد که ماشین بردار پشتیبان در مقایسه با دیگر تکنیک‌های طبقه‌بندی از کارائی بالاتری برخوردار است. از این رو تدوین یک نظام جامع اعتبارسنجی برای بانک در جهت کاهش ریسک عدم بازپرداخت تسهیلات یک ضرورت و در عین حال یک گام موثر در این راستاست.

نتیجه گیری

در این تحقیق که هدف اصلی آن بررسی کارائی استفاده از ماشین بردار پشتیبان در طبقه‌بندی متقاضیان بوده است، نتایج مدل ماشین بردار پشتیبان در مقایسه با مدل‌های رگرسیون لجستیک و... بررسی شده است. یافته‌های تحقیق حاکی از آنست که در طبقه‌بندی متقاضیان، مدل ماشین بردار پشتیبان نسبت به مدل‌های دیگر بطور معناداری از دقت کلی بیشتری برخوردار است. در مقاله حاضر با استفاده از آمار و اطلاعات مربوط به مشتریان حقوقی بانک مورد مطالعه، که در طی سالهای ۸۶ تا ۸۶ از بانک تسهیلات دریافت نموده‌اند و با بهره گیری از روش ماشین بردار پشتیبان، سعی شد عوامل موثر بر عدم بازپرداخت بموقع تسهیلات اعتباری شناسایی شود تا بدین وسیله اطلاعات لازم برای درجه بندی مشتریان آتی بانک

منابع و مأخذ:

۱. اخباری، مهدیه، «رتبه بندی اعتباری مشتریان حقوقی بانک‌ها با رویکرد هوش مصنوعی»، پایان نامه کارشناسی ارشد، دانشگاه صنعتی اصفهان، ۱۳۸۷.
۲. طلوعی اشلقی، عباس، مقدوری شربیانی، فرناز، دانشگر، فرید، «امتیاز دهی اعتباری متقاضیان کارت‌های اعتباری بانک‌ها با استفاده از تکنیک ماشین بردار پشتیبان»، دومین کنفرانس شهر الکترونیکی، ۱۳۸۸.
۳. منیری آرش، «استفاده از ماشین بردار پشتیبان در باز شناسی کلمات گستته فارسی»، پایان نامه کارشناسی ارشد، دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران، ۱۳۸۵.
۴. نادعلی، احمد، «طبقه بندی متقاضیان تسهیلات اعتباری بانکی با استفاده از داده کاوی و منطق فازی»، پایان نامه کارشناسی ارشد، دانشگاه آزاد اسلامی واحد علوم و تحقیقات تهران، ۱۳۸۷.

5. Avci, Engin, "Selecting of the optimal feature subset and kernel parameters in digital modulation classification by using hybrid genetic algorithm-support vector machines:HGASVM", Expert systems with applications, Vol.36, pp. 1391-1402, 2009.
6. Bellotti, Tony, Crook, Jonathan, "Support vector machines for credit scoring and discovery of significant features", Expert systems with applications, pp. 102-109, 2008.
7. Chia-Ming Wanmg, Yin-Fu Huang, " Evolutionary- based feature selection approaches with new criteria for data mining." A case study of credit approval data", Expert systems with applications, Vol.36, pp. 5900-5908, 2009.
8. Chen, Weimin, Ma, Chaoqun, Ma, Lin, "Mining the customer credit using hybrid support vector machine technique", Expert systems with applications, pp.1-6, 2008.

-
-
9. Fatih Akay, Mehmet, "support vector machines combined with feature selection for breast cancer diagnosis", Expert systems with pp.3240-3247, 2009 applications, Vol.36.
 10. Hsieh, N. C., "An integrated data mining and behavioral scoring model for analyzing bank customers", Expert systems with applications, Vol.4, pp.623-633, 2004.
 11. Huang, Cheng-Lung, Chen, Mu-Chen, "Credit scoring with a data mining approach based on support vector machines", Expert systems with applications, Vol.3,pp.847-856,2007.
 12. Huang, Zan, Chen, Hsinchun, "Credit Rating analysis with support vector machines and neural networks: a market comparative study", Decision support systems, Vol.37, pp.549-551, 2006.
 13. Ming-Chi Lee, "Using support vector machine with a hybrid feature selection method to the stock trend prediction", Expert systems with applications, 2009.
 14. Min, Sung-Hwan, Lee, Jumin, "Hybrid genetic algorithms and support vector machines for bankruptcy prediction", Expert systems with applications, Vol.31, pp. 652-660, 2006.
 15. Sinky jr.,Joseph f., "commercial Bank Financial Management", 4th Edition; Macmillan, p.519,1992.