



## پیش‌بینی رویگردانی مشتریان بانک با استفاده از روش داده کاوی

### پروین نجمی

کارشناس ارشد مدیریت فناوری اطلاعات، واحد تهران شمال دانشگاه آزاد اسلامی، تهران، ایران

### عباس راد (نویسنده مسؤول)

استادیار دانشکده مدیریت دانشگاه شهید بهشتی

Email: a-raad@sbu.ac.ir

### مریم شعار

استادیار دانشکده مدیریت واحد تهران شمال، دانشگاه آزاد اسلامی، تهران، ایران

تاریخ دریافت: ۹۷/۲/۱۰ \* تاریخ پذیرش: ۹۷/۸/۱۱

### چکیده

شدت پیدا کردن رقابت در فضای صنعتی و اقتصادی و حرکت بازار به سمت بازار رقابت کامل، باعث شده است که تمایل بنگاه‌های اقتصادی به جذب مشتریان بیشتر کاهش یافته و در عوض، تمایل به فعالیت در زمینه‌های مختلف خدماتی و تولیدی افزایش یافته است. به همین منظور، توسعه روش‌هایی به منظور شناسایی مشتریان رویگردان و پیش‌بینی رویگردانی، از مهمترین فعالیت‌های حوزه فروش به حساب خواهد آمد. در صورتی که بانک فرصت کافی برای پیش‌بینی رویگردانی مشتریان را داشته باشد؛ می‌تواند از این مسئله جلوگیری کرده و یا حداقل به اصلاح ساختارها و خدمات خود به منظور جلوگیری از ریزش تعداد بیشتری از مشتریان پپردازد. تحقیق حاضر، به منظور توسعه چنین مدلی برای بانک شهر صورت گرفته است. به همین منظور، از یک الگوریتم دو مرحله‌ای خوش بندی، دسته بندی داده کاوی استفاده شده است. به منظور خوش بندی مشتریان، از نقشه‌های خودسازمان ده شبکه عصبی که یک روش یادگیری نظرارت نشده است؛ استفاده شده و برای دسته بندی از ماشین بردار پشتیبان و درخت تصمیم استفاده شده است. روش استفاده از این ابزارها به این صورت است که ابتدا از دو مشخصه میانگین موجودی و میانگین تراکنش مشتریان در دوره سه ماهه پایانی استفاده شده و به عنوان ورودی شبکه عصبی در خوش بندی مورد استفاده قرار گرفته است. پس از آن، در مرحله کلاس بندی، از داده‌های مربوط به تراکنش‌های نقدی و اعتباری به منظور کلاس بندی و پیش‌بینی استفاده شده است. نتایج به دست آمده از دقت کلاس بندی صورت گرفته، حاکی از آن است که مدل پیشنهادی تا بیش از ۸۰٪ توانایی پیش‌بینی رویگردانی مشتری را داشته و در این مسیر، ماشین بردار پشتیبان عملکرد بهتری از درخت تصمیم نشان داده است.

**کلمات کلیدی:** مشتری رویگردان، شبکه عصبی، نقشه خود سازمان ده، ماشین بردار پشتیبان، درخت تصمیم.

## ۱- مقدمه

از زمان انقلاب صنعتی و به خصوص بعد از جنگ جهانی دوم که تولید صنعتی رونق گرفته و بنگاه های تولیدی به عرضه محصولات خود در سطح انبو در بازار های مختلف پرداختند؛ سیاست اصلی درآمدزایی شرکت ها، کاهش هزینه ها و افزایش فروش بوده است. در واقع، افزایش سهم بازار با استفاده از قیمت های کمتر و کیفیت بالاتر، مهمترین عملکرد مدیریت بازاریابی و فروش شرکت ها بوده است. با گذشت زمان و بهبود تکنولوژی، فاصله کیفی بین کالاهای مختلف کمتر شد و عملاً کالاهای در بازارهای مختلف به سمت همگنی پیش رفت. همچنین، با اضافه شدن بنگاه های اقتصادی بیشتر و مصرفی شدن هرچه بیشتر فرهنگ مردم، دو سمت عرضه و تقاضا در صنایع مختلف نیز رشد بالایی را تجربه کرده و در نهایت، بازارها به سمت رقابت کامل پیش رفتند که در آن یک بنگاه اقتصادی نمی تواند با اجرای سیاست های قیمتی یا کیفی، به جلب مشتریان جدید بپردازد.

در چنین فضایی، توسعه سهم بازار و افزایش فروش، از اولویت سیستم های بازاریابی و فروش خارج شده و جای خود را به سیاست افزایش سهم کیف پول داد. این سیاست جدید، با فرض اینکه کسب مشتریان جدید در بازار یا غیرممکن بوده و یا با هزینه های بالایی امکان پذیر است؛ پیشنهاد می کند که شرکت ها به فروش کالاهای خود متعدد به مشتریان خود بپردازند. در واقع، به جای جلب تعداد زیادی مشتری، تعداد زیادی کالا یا خدمت به تعداد کمی مشتری فروخته شود. این سیاست مورد استقبال انواع بنگاه های اقتصادی قرار گرفته و این مسئله تا جایی پیش رفت که توسعه خطوط تولید سنگین، جای خود را به آرایش کارگاهی به منظور تولید کالاهای بیشتر و با تنوع بالاتر داد.

در فضایی که تمرکز بنگاه های اقتصادی بر فروش بیشتر به مشتریان موجود می باشد؛ قطعاً حفظ مشتریان اهمیت بسیار بالایی دارد. به همین منظور، مدیران فروش و بازاریابی شرکت ها به استفاده از روش های تحلیل آماری و ریاضی در قالب علم داده کاوی به منظور تحلیل روابط مشتریان پرداخته و به وسیله آن به آنالیز مشتریان و شناسایی بهتر آنها پرداختند. یکی از مهمترین تحقیقات توسعه یافته در این زمینه، شناسایی مشتریان رویگردانی شده است و البته این تعاریف با توجه به نوع صنایع و حتی نوع بازارها می توانند متفاوت باشند؛ لیکن به صورت کلی می توان رویگردانی را به عدم تمایل مشتری به استفاده از کالا یا خدمات ایجاد شده توسط یک شرکت خاص تعییر نمود. شناسایی مشتریان رویگردان از دو جهت برای شرکت ها اهمیت دارد؛ اول اینکه می توانند جلو ریزش مشتریان را با استفاده از پیشنهادهای ویژه گرفته و آنها را حفظ کنند و دوم اینکه می توانند با یک آنالیز رویگردانی جامع، به بررسی دلایل و نقاط ضعف شرکت و بهبود آن بپردازنند.

به منظور شناسایی و تشخیص رویگردانی، شرکت ها باید اطلاعات مرتبط با مشتری های خود را تحلیل کرده و یک الگو بین آنها ایجاد کنند؛ برای مثال با تحلیل روابط مشتری بتوانند الگویی برای رویگردانی تعییف کرده و بر این اساس مشتریان رویگردان را شناسایی کنند. بنابراین، گام اول تحلیل رویگردانی مشتریان، مربوط به جمع آوری داده های مرتبط با مشتریان می باشد. با توجه به اینکه روابط مشتریان با شرکت ها در بسیاری از موارد محدود بوده و یا شرکت ها توانایی دسترسی به اطلاعات تمامی مشتریان ندارند؛ تحلیل رویگردانی به حوزه هایی مربوط می شود که توانایی شناسایی مشتریان و ردگیری استفاده از خدمات یا کالاهای را دارند. به همین دلیل تحلیل رویگردانی بیشتر در صنعت اطلاعات و ارتباطات انجام می پذیرد؛ چرا که شرکت های ارائه دهنده این خدمات به راحتی توانایی دسترسی به اطلاعات مشتریان نظیر طول مدت مکالمه، تعداد مکالمه، پیامک ها، بسته های اینترنتی و سایر موارد را دارند و لذا می توانند با تحلیل این اطلاعات، مشتریانی که نسبت به شرکت رویگردان شده اند را شناسایی کنند.

امیرشاهی و روان بد (۱۳۸۵) نشان داد ۱۲ عامل مؤثر توسط تکنیک آنالیز عاملی به منظور تقویت اعتماد مشتریان شناخته شده است که از جمله می توان به مشاوره، کارکنان، خدمات مکمل، شهرت و پاسخگویی بانک در قبال مشتریان اشاره کرد. محققان توانایی این عوامل در توجیه حس اعتماد مشتریان در مجموع را تا ۶۵٪ تخمین زده اند. بهرام زاده و مقرب (۱۳۸۹) اعتقاد دارند که میزان سوددهی بانک، رابطه مستقیم با میزان اعتماد مشتریان داشته و به منظور آزمون این موضوع، از مشتریان بانک های پاسارگاد، اقتصاد نوین و سینا در استان خوزستان استفاده شده است. بر اساس نتایج به دست آمده، وفاداری، رضایتمندی، اعتماد و تعهد از مهمترین عوامل مؤثر بر وفاداری مشتریان بوده اند. محمدی (۱۳۹۰) عوامل کارکنان، خدمات و محصولات، فرآیندهای

کاری، قیمت خدمات و محصولات، ویژگی شعب، فرآیندهای کاری و فعالیت های بازارافزایی با ترتیب های مختلف، به عنوان مهمترین عوامل مؤثر بر وفاداری شناسایی کرده‌اند.

نخعی و همکاران (۱۳۹۳) نتیجه گرفته اند که نرخ کارمزد پایین، اولین عامل جذب مشتریان می‌باشد. دومین عامل، تقویت امکانات و فناوری بوده و عوامل مدیریت سرمایه، عوامل فیزیکی و ارتباطات مستمر با مشتری به عنوان عوامل مرث ر بعدی شناخته شده اند.

هایگورت (۲۰۱۵) بیان می‌کند که هزینه ایجاد مشتریان جدید به دلیل رقابت شدید، بسیار زیاد است. محقق، در این تحقیق به استفاده از ابزارهای داده کاوی به منظور پیش‌بینی رویگردانی پرداخته است. به منظور انتخاب مشخصه‌های مؤثر در رویگردانی، از نظر خبرگان بازار بیمه و تحقیقات مشابه انجام شده است و در نهایت سن و میزان استفاده از امکانات بیمه، مهمترین مشخصه‌ها انتخاب شده اند. ابزارهای استفاده شده توسط محقق، شامل رگرسیون لاجیت، درخت تصمیم، شبکه عصبی و ماشین بردار پشتیبان بوده است پس از تعیین پارامترهای بهینه برای هریک از روش‌ها و تعیین نمونه‌های آموزش و کنترل در هر مورد، کارایی شبکه عصبی و رگرسیون لاجیت از دو روش دیگر به صورت معناداری بالاتر تخمین زده شده است.

هانگ و همکاران (۲۰۱۶) بر این موضوع که شناسایی مشتریان رویگردان به منظور جلوگیری از ریزش مشتریان، اهمیت بالایی دارد به توسعه یک مدل کلاس بندی فازی پرداخته اند. بر اساس نظر مؤلفان، روش‌های کلاس بندی مبتنی بر قواعد، کارایی بهتری در کلاس بندی مشتریان رویگردان دارند؛ چرا که قواعد استخراج شده از این روش‌ها می‌تواند مورد استفاده شرکت جهت بهبود عملکرد و شناسایی نقاط ضعف قرار بگیرد؛ لیکن، این روش‌ها با فرض پایدار بودن نمونه تحقیق و پایگاه داده مورد استفاده ایجاد شده اند و این در حالی است که عدم تعادل در پایگاه داده می‌تواند نتایج را تحت تأثیر قرار دهد. به این ترتیب، محققان یک مدل کلاس بندی بر مبنای قواعد فازی طراحی کرده اند که این اشکال را برطرف می‌کند. بر اساس نتایج به دست امده، کارایی و دقت روش پیشنهادی در مقایسه با روش‌های دیگر کلاس بندی بر مبنای قاعده، مناسب بوده است.

گردینی و وجليو (۲۰۱۶) اظهار می‌دارند که تجارت الکترونیک چارچوب خوبی برای آسودگی مشتریان و آسانی معاملات فراهم کرده است؛ لیکن ریسک رویگردانی مشتری را نیز افزایش داده است؛ چرا که هزینه رویگردانی و گرایش به رقبا برای مشتریان کم است. به همین دلیل، در این تحقیق از ماشین بردار پشتیبان برای شناسایی و پیش‌بینی رویگردانی به منظور پیشگیری و اصلاحات مرتبط استفاده شده است. به منظور بهینه سازی پارامترهای SVM نیز از تکنیک AUC استفاده شده است. محققان، کارایی روش پیشنهادی را با روش‌های رگرسیون لجستیک، شبکه عصبی و SVM کلاسیک (بدون بهینه سازی پارامترها) مقایسه کرده اند و نتیجه گیری کرده اند که AUC نقش مهمی در کارایی SVM بازی می‌کند و باعث کارایی بهتر آن در مقایسه با سه روش رقیب شده است.

امروزه، با پیشرفت تکنولوژی و توسعه استفاده از خدمات الکترونیک، زمینه تعامل بیشتر شرکت‌ها با مشتریان در بسیاری از صنایع مهیا شده است. از جمله این صنایع، می‌توان به بانکداری اشاره نمود. بانکداری الکترونیک باعث افزایش تعامل مشتریان با بانک‌ها و در نتیجه افزایش استفاده آنها از خدمات مالی شده است. علاوه بر این، خدمات مالی ارائه شده توسط بانک‌ها معمولاً بسیار جامع بوده و از ارائه انواع خدمات بانکی حضوری، اعتباری و اینترنتی تا خریدهای غیرحضوری و همچنین خدمات متفاوت دیگر همچون کارگزاری و مشاوره را شامل می‌گردد. بنابراین، با توجه به این خدمات گسترده و امکان استفاده غیرحضوری از این خدمات، بانک‌ها به سادگی به اطلاعات مشتریان دسترسی پیدا کرده و توانایی تحلیل آنها به منظور شناسایی رویگردانی را پیدا می‌کنند.

پژوهش حاضر، با در نظر داشتن اهمیت و ضرورت تحلیل رویگردانی، به شناسایی مشتریان رویگردان و پیش‌بینی رویگردانی پرداخته و به این منظور، در ابتدا الگوی رویگردانی را با استفاده از روش خوشه بندی شبکه عصبی کشف کرده و سپس با استفاده از ماشین بردار پشتیبان، به پیش‌بینی رویگردانی می‌پردازد. در همین راستا، در ابتدای تحقیق، پژوهش‌های مرتبط انجام شده در داخل و خارج از کشور به صورت مختصر مور می‌گردد. در قسمت بعد، مفاهیم مرتبط با روش‌های خوشه بندی و دسته بندی در داده کاوی به روش‌های شبکه عصبی و ماشین بردار پشتیبان شرح داده شده و در نهایت نتایج به دست آمده از روش تحقیق، نشان داده شده و جمع بندی نهایی صورت می‌پذیرد.

## ۲- روش شناسی

### (الف) تدوین الگوی مفهومی

با توجه به تحقیقات انجام شده تاکنون و متغیرهای در دسترس محقق با استفاده از پایگاه های داده بانکی، متغیرهای تحقیق شامل موارد زیر می گردند:

جدول شماره (۱): الگوی مفهومی

| مشخصات دموگرافیک                                       | تعداد تراکنش  | ارزش تراکنش  | تراکنش های اعتباری                                  |
|--|---|--|---|
| سن مشتری<br>(Prasad and Mahdavi, 2012)                 | تعداد تراکنش  | میانگین ارزش تراکنش نقدی<br>(Mutanen, 2006)                        | تعداد وام های دریافتی<br>(Prasad and Mahdavi, 2012) |
| مدت زمان استفاده از خدمات بانک<br>(Adwan et al., 2014) | تعداد تراکنش نقدی<br>(Mutanen, 2006)                        | میانگین ارزش تراکنش های کارت اعتباری<br>(Prasad and Mahdavi, 2012) | تعداد وام های جاری<br>(Prasad and Mahdavi, 2012)    |
| درآمد<br>(Adwan et al., 2014)                          | تعداد تراکنش های کارت اعتباری<br>(Prasad and Mahdavi, 2012) | میانگین ارزش تراکنش های اینترنت<br>(Prasad and Mahdavi, 2012)      | ارزش وام های دریافتی<br>(Prasad and Mahdavi, 2012)  |
| سطح تحصیلات<br>(Prasad and Mahdavi, 2012)              | تعداد تراکنش های اینترنتی                                   |  | ارزش وام های جاری<br>(Prasad and Mahdavi, 2012)     |

یک نکته در استفاده از متغیرهای معرفی شده، در نظر گرفتن مشخصات مشتریان به صورت نسبی و عدم مقایسه به صورت مطلق می باشد. برای مثال، ممکن است یک مشتری وفادار با درآمد پایین، به نسبت درآمد خود، تراکنش های بالای را انجام داده باشد؛ ولی این میزان در مقابل تراکنش های یک مشتری رویگردن با درآمد بالا، پایین به نظر بیاید. بنابراین، تعداد و ارزش تراکنش ها باید به نسبت درآمد مشتریان تعديل گردد.

علاوه بر این، در نظر گرفتن عملکرد مشتریان به نسبت عملکرد گذشته خود نیز ضروری می باشد. به این معنا که عملکرد تعديل شده با درآمد یک مشتری، می تواند نسبت به مشتری دیگر بالاتر باشد؛ لیکن می تواند به نسبت عملکرد گذشته همان مشتری، کاهش چشمگیری را داشته باشد و در واقع مشتری به سمت رویگردنی حرکت کرده باشد. بنابراین، علاوه بر درآمد، متغیرهای تحقیق به نسبت میانگین متاخر ۱۲ ماهه خود نیز تعديل می گردد :

$$x_{ij} = \frac{X_{ij}}{MA(X_{ij})} \quad (1)$$

در رابطه مذکور،  $X_{ij}$  مقدار هریک از متغیرها (i) برای هریک از مشتریان (j) بوده و  $MA(X_{ij})$  نیز نشان دهنده میانگین متاخر ۱۲ ماهه همان متغیر می باشد. از آنجا که در تحقیق حاضر از روش های شبکه عصبی خودسازمان ده و ماشین بردار پشتیبان به منظور خوش بندی و دسته بندی مشتریان استفاده می شود؛ در این قسمت به صورت مختصر به مرور روش های مذکور پرداخته شده و سپس متغیرهای تحقیق و مراحل اجرای روش تحقیق شرح داده می شود. (ب) نقشه خودسازمان ده شبکه عصبی

در یک شبکه‌ی خود سازمان ده، واحد‌های پردازش گر در گره‌های یک شبکه‌ی یک بعدی، دو بعدی یا بیشتر قرار داده می‌شوند. واحد‌ها در یک فرآیند یادگیری رقابتی نسبت به الگوهای ورودی منظم می‌شوند. محل واحدهای تنظیم شده در شبکه به گونه‌ای نظم می‌یابد که برای ویژگیهای ورودی، یک دستگاه مختصات معنی دار روی شبکه ایجاد شود. لذا یک نقشه‌ی خود سازمان ده، یک نقشه‌ی توپوگرافیک از الگوهای ورودی را تشکیل می‌دهد که در آن، محل قرار گرفتن واحدهای، متناظر ویژگیهای ذاتی الگوهای ورودی است.

یادگیری رقابتی که در این قبیل شبکه‌ها بکار گرفته می‌شود بدین صورت است که در هر قدم یادگیری، واحدها برای فعال شدن با یکدیگر به رقابت پرداخته و در پایان یک مرحله رقابت تنها یک واحد برنده می‌شود، که وزنهای آن نسبت به وزنهای سایر واحدها به شکل متفاوتی تغییر داده می‌شود. این نوع از یادگیری نظارت نشده می‌نامند. شبکه‌های خودسازمان ده به لحاظ ساختاری به چند دسته تقسیم می‌شوند که از جمله می‌توان به شبکه همینگ، کلاه مکزیکی و کوهونن اشاره نمود. شبکه کوهونن که در این تحقیق از آن استفاده شده است؛ به صورت چند لایه ای می‌باشد. یک لایه کوهونن آرایه ای از نورون‌ها به صورت یک بعدی، دو بعدی یا بیشتر است که نمونه ای از آن را در شکل فوق مشاهده می‌شود. در فاز یادگیری هر یک از واحدها فاصله‌ی بردار ورودی تا وزن‌های خود را به صورت زیر محاسبه می‌کند.

$$I_i = D(X, w_i) \quad (2)$$

که  $D$  تابع سنجش فاصله است و می‌توان هر یک از توابع مرسوم برای سنجش فاصله را استفاده نمود؛ مثلاً فاصله‌ی کمان کروی یا فاصله‌ی اقلیدسی را می‌توان استفاده نمود. واحدها با این محاسبه می‌خواهند بدانند نزدیکترین بردار وزن به بردار ورودی را دارند یا خیر؛ که این همان بخش رقابتی در این‌گونه از شبکه‌ها می‌باشد.

واحد دارای نزدیکترین وزن به بردار ورودی، برندۀ این مرحله از رقابت خواهد بود که برای آن  $Z_i$  مربوطه برابر ۱ قرار داده می‌شود و سایر  $Z_i$ ‌ها برابر صفر خواهند بود. آنگاه قانون کوهونن که به صورت ذیل است برای به روز رسانی وزن‌ها استفاده می‌شود:

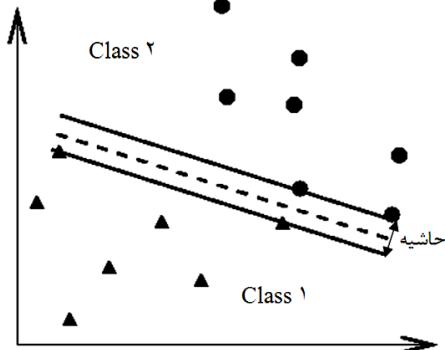
$$w_i^{new} = w_i^{old} + \alpha(X - w_i^{old})Z_i \quad (3)$$

به این ترتیب، توسط این قانون، می‌توان به صورت جداگانه به بررسی اوزان و بهینه سازی آنها در هر مرحله از آموزش شبکه پرداخت.

### ج) ماشین بردار پشتیبان

ماشین بردار پشتیبان یکی از تکنیک‌های دسته‌بندی است که بر اساس تئوری یادگیری آماری پایه گذاری و معرفی شده است (Vapnik, 1998). ماشین بردار پشتیبان به دنبال یافتن ابرصفحه‌ای است که با استفاده از آن داده‌ها را دسته بندی کند.

این ابرصفحه به گونه‌ای یافته می‌شود که حاشیه دسته بندی را حداقل نماید، شکل شماره (۱).



شکل شماره (۱): ابرصفحه ماشین بردار پشتیبان

مدل کلی برای یافتن ابرصفحه‌ای مطابق با شکل فوق را می‌توان به صورت رابطه زیر نوشت:

$$\max \min_{i=1,\dots,n} d(X_i, H) \quad (3)$$

و محدودیت های مسئله باید به گونه ای باشند که داده های دسته یک در نیم فضای مثبت و داده های دسته دوم در نیم فضای منفی قرار بگیرند. به عبارت دیگر می توان محدودیت های مسئله را همانند زیر بدست آورد:

$$\begin{cases} \omega^T X_i + b \geq 0 & \forall X_i \in \text{class 1} \\ \omega^T X_i + b \leq 0 & \forall X_i \in \text{class 2} \end{cases} \quad (4)$$

از آنجایی که ابرصفحه دسته بند در ماشین بردار پشتیبان متعارفی است. فاصله هر کدام از بردارهای پشتیبان تا ابر صفحه متعارفی طبق رابطه زیر است:

$$\frac{\omega^T X_i + b}{\|\omega\|} = \begin{cases} 1 & \forall \text{ supportvector} \\ & \in \text{class 1} \\ -1 & \forall \text{ supportvector} \\ & \in \text{class 2} \end{cases} \quad (5)$$

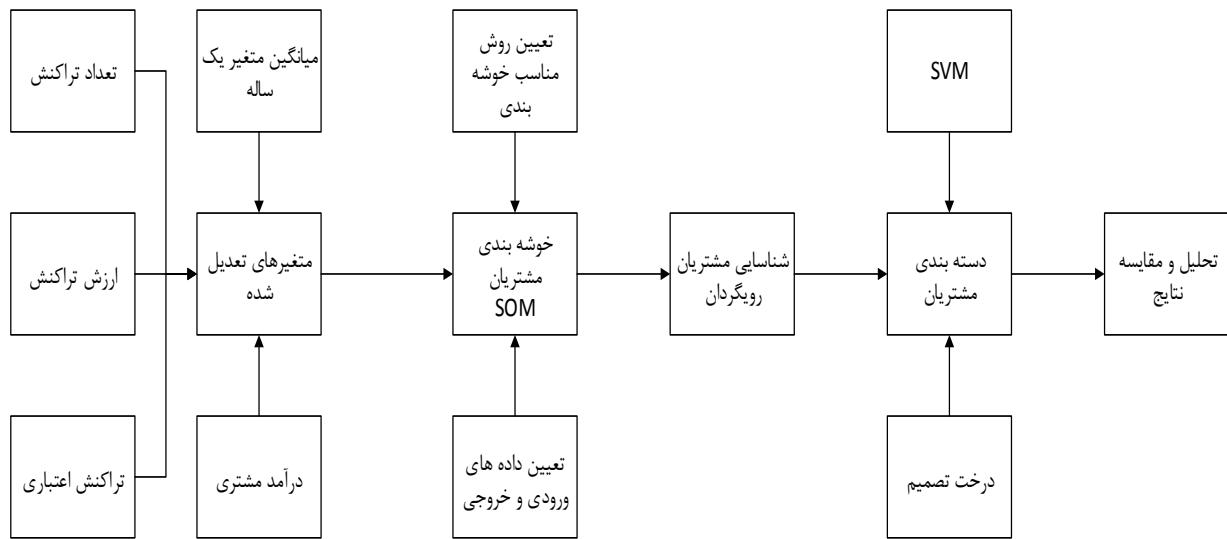
بنابراین حاشیه دسته بندی از رابطه زیر محاسبه می شود:

$$\frac{1}{\|\omega\|} - \frac{1}{\|\omega\|} = \frac{2}{\|\omega\|} \quad (6)$$

تابع هدف ماشین بردار پشتیبان ببه صورت ماکزیمم سازی حاشیه تشکیل می گردد.

### ۳- نتایج و بحث

مراحل اجرای تحقیق به صورت کلی مطابق شکل (۲) می باشد؛ محقق در ابتدا داده های مربوط به مشتریان را از پایگاه های داده مربوطه استخراج کرده و سپس متغیرهای تحقیق را ایجاد نموده است. در ادامه، متغیرها به منظور قابل مقایسه بودن، با درآمد و میانگین تعديل شده و آماده استفاده در فرآیند خوش بندی و دسته بندی می گردند. خوش بندی تحقیق با استفاده از روش نقشه خود سازمان ده شبکه عصبی و دسته بندی با استفاده از ماشین بردار پشتیبان صورت می گیرد.



شکل شماره (۲): توانایی ماشین بردار پشتیبان

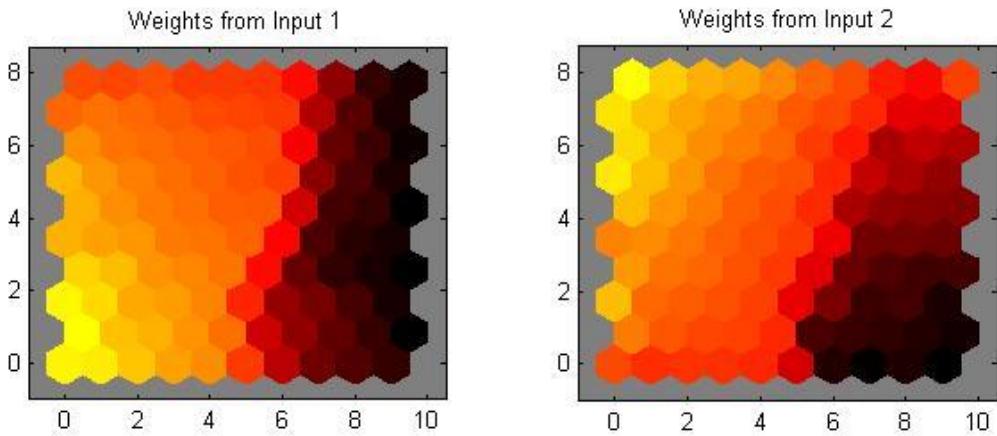
همانگونه که از شکل مشخص می‌گردد؛ به منظور بررسی توانایی ماشین بردار پشتیبان در دسته بندی و پیش‌بینی رویگردانی، از درخت تصمیم نیز به عنوان معیار مقایسه استفاده شده است. مورد مطالعاتی تحقیق، مشتریان بانک شهر در بازه سال‌های ۱۳۹۳ تا ۱۳۹۵ می باشد که تعداد مورد نیاز نمونه با استفاده از روش کوکران و نمونه گیری توسط روش خوش بندی تصادفی صورت گرفته است. مشخصه‌های آماری مربوط به نمونه ایجاد شده همانند جدول (۱) می‌باشد.

جدول شماره (۲): مشخصه‌های آماری مربوط به نمونه ایجاد شده

| آماره        | تغییرات تراکنش | تغییرات ارزش کل تراکنش | تغییرات میانگین | تغییرات ارزش کل |
|--------------|----------------|------------------------|-----------------|-----------------|
|              | نقدی           | اعتباری                | موجودی          | تراکنش          |
| کمینه        | -۰/۴۸۰         | -۰/۴۷۸                 | -۰/۴۹۱          | -۰/۸۸۳          |
| بیشینه       | .۰/۵۲۳         | .۰/۵۵۷                 | .۰/۴۸۷          | .۰/۵۳۴          |
| میانه        | .۰/۰۶۴         | .۰/۰۵۷                 | .۰/۰۵۳          | .۰/۰۳۲          |
| میانگین      | .۰/۰۴۲         | .۰/۰۴۱                 | .۰/۰۳۶          | -۰/۱۲۲          |
| انحراف معیار | .۰/۲۰۴         | .۰/۱۹۸                 | .۰/۱۹۸          | .۰/۳۹۱          |
| چولگی        | -۰/۳۷۲         | -۰/۳۹۶                 | -۰/۵۳۰          | -۰/۶۳۷          |
| کشیدگی       | ۲/۸۸۷          | ۲/۹۰۶                  | ۲/۹۷۴           | ۱/۹۸۶           |
|              |                |                        |                 | ۲/۲۶۰           |

لازم به ذکر است که مشخصه‌های آماری مربوطه در جدول (۱)، مربوط به متغیرهای تعدیل شده با درآمد می‌باشد. مشاهده می‌شود که مقدار چولگی و کشیدگی در مورد تمامی متغیرها در حد نرمال یا با مقدار کم می‌باشد و لذا می‌توان فرم تمام آنها را به صورت نرمال فرض کرد.

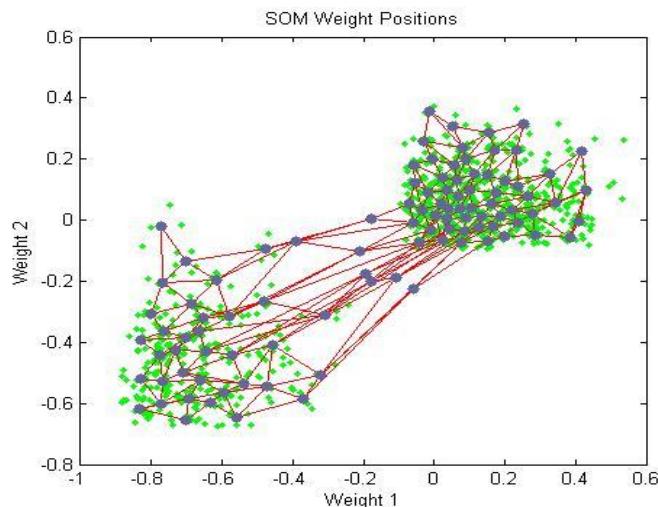
خوش بندی مشتریان، همانگونه که پیش از این نیز ذکر شد؛ توسط روش SOM صورت می‌پذیرد که متغیرهای ورودی آن شامل میانگین موجودی و ارزش کل تراکنش‌ها می‌باشد. نقشه اولیه تشکیل شده، شامل یک شبکه ۱۰۰ نرونی  $10 \times 10$  می‌باشد که در آن از ۷۰٪ داده‌های نمونه تحقیق به منظور آموزش نرون‌ها و بهینه سازی اوزان آنها استفاده شده است. شکل (۳) نشان دهنده اوزان اخذ شده توسط نرون‌ها به تفکیک دو متغیر ورودی می‌باشد.



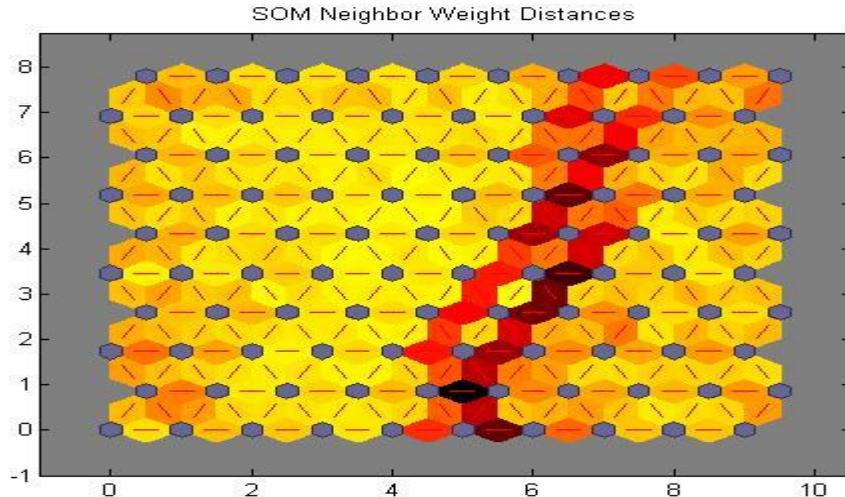
شکل شماره (۳): وزنهای درون داده ۱

بر اساس شکل (۳) مشخص است که از چپ به راست، اوزان نسبت داده شده به نرون ها در مورد هر دو متغیر ورودی، افزایش یافته است و به صورت مشخص، می توان انتظار داشت که نرون های با وزن کمتر در یک خوش و نرون های با وزن بیشتر در خوش دیگر قرار گیرند. به منظور درک بهتر فاصله اوزان تخصیص داده شده به نرون ها، می توان آنها را در فضای دو بعدی متغیرهای ورودی یعنی میانگین موجودی و ارزش کل تراکنش مطابق شکل (۴) ترسیم نمود.

شکل شماره (۴): وضعیتهای وزن SOM



همانگونه که مورد انتظار بود؛ اوزان تخصیص داده شده به نرون ها، آنها را با فاصله زیاد از یکدیگر و در دو خوش مشخص قرار می دهند. بنابراین، می توان نرون های با فاصله کمتر از یکدیگر را در یک خوش در نظر گرفت. فاصله میان نرون ها در شبکه آموزش دیده، به خوبی در شکل (۵) قابل مشاهده است.



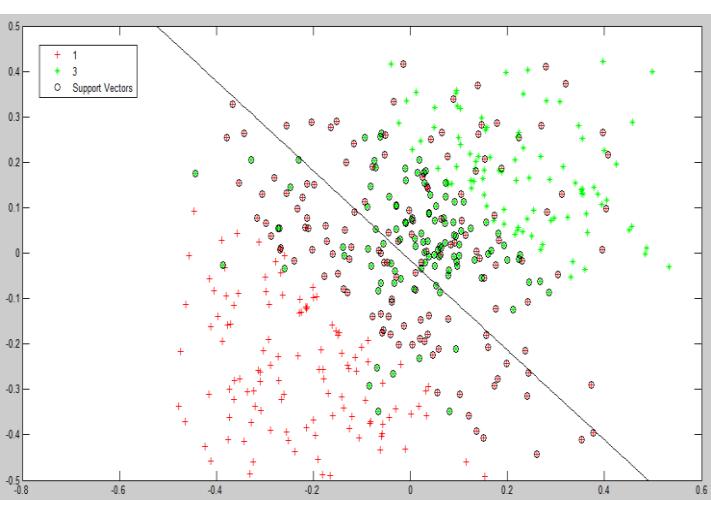
شکل شماره (۵): فواصل وزن های همچوار SOM

در شکل (۵)، نرون های سمت راست در فاصله اندک با یکدیگر و با فاصله زیاد از نرون های سمت چپ قرار گرفته اند. به این ترتیب، می توان مشتریان تخصیص داده شده به نرون های سمت راست را در یک خوشه و مشتریان تخصیص داده شده به نرون های سمت چپ را در خوشه دیگر طبقه بندی نمود و به این ترتیب، تعداد مشتریان حاضر در هر خوشه مطابق جدول (۲) خواهد بود.

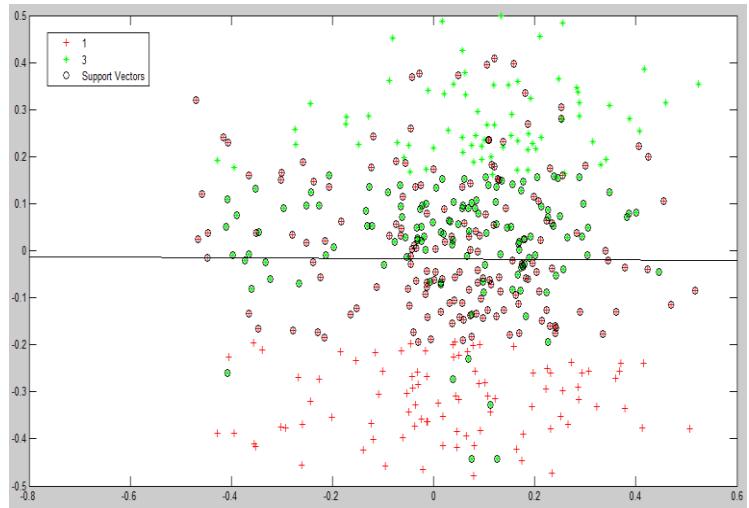
جدول شماره (۳): خوشه بندی

| خوشه             | مرکز خوشه       | تعداد اعضای خوشه |
|------------------|-----------------|------------------|
| مشتریان وفادار   | (-۰/۴۵ و -۰/۶۷) | ۴۳۸              |
| مشتریان معمولی   | (۰/۰۷ و ۰/۰۴)   | ۲۴۸              |
| مشتریان رویگردان | (۰/۰۵ و ۰/۲۷)   | ۳۴۱              |

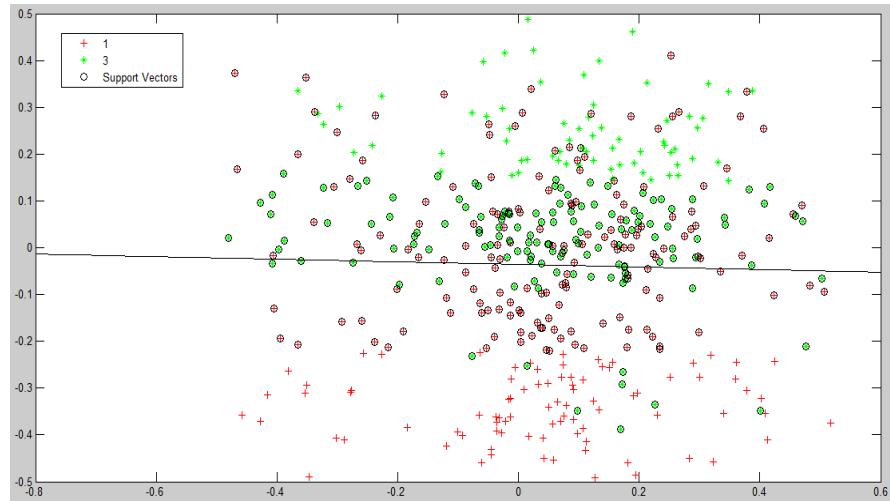
برای محاسبه مرکز خوشه، از میانگین اوزان نرون های حاضر در هر خوشه به نسبت هریک از ورودی ها، استفاده شده است. برای مثال، میانگین اوزان تمامی نرون های خوشه مشتریان رویگردان در متغیر اول، نشان دهنده پارامتر اول و میانگین اوزان نرون ها در متغیر دوم، نشان دهنده پارامتر دوم می باشد. در پایان این مرحله، داده های حاضر در نمونه تحقیق برچسب گذاری شده و لذا می توان با استفاده از ماشین بردار پشتیبان به پیش بینی رویگردانی پرداخت. همانگونه که گفته شد؛ ماشین بردار پشتیبان با استفاده از یک ابر صفحه جدا کننده به دسته بندی مشتریان در دو دسته رویگردان و غیر رویگردان شامل معمولی و وفادار می پردازد. بر اساس روش تحقیق، سه متغیر به منظور دسته بندی یا همان پیش بینی رویگردانی به عنوان ورودی ماشین بردار پشتیبان استفاده شده اند که نتایج به دست آمده از دسته بندی در فضای دو بعدی هر چهت از متغیرهای مربوطه در مطابق شکل (۶) می باشد.



شکل شماره (۷): تعداد تراکنش اعتباری - ارزش تراکنش اعتباری



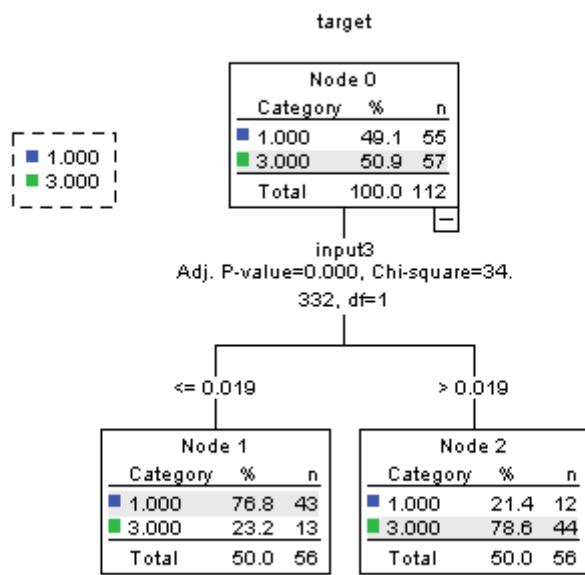
شکل شماره (۶): تعداد تراکنش نقدی - ارزش تراکنش نقدی



شکل شماره (۸): ارزش تراکنش نقدی - اعتباری

در شکل (۶)، رنگ سبز نشان دهنده مشتریان رویگردان و رنگ قرمز مشتریان معمولی و وفادار را نشان می‌دهد. نقاط دایره‌شکل، نقاطی هستند که به عنوان بردار پشتیبان انتخاب شده‌اند و ابر صفحه جداکننده به گونه‌ای تشکیل شده است که فاصله آن با تمامی این نقاط بیشینه گردد.

علاوه بر روش ماشین بردار پشتیبان، از درخت تصمیم نیز به عنوان یک معیار به منظور رویگردانی استفاده شده و به منظور دسته بنده با استفاده از آن از الگوریتم CHAID استفاده شده است. شکل (۷) نشان دهنده درخت تشکیل شده بر اساس داده‌های آموزش می‌باشد.



مشاهده می شود که درخت تصمیم تنها از یک متغیر و آن هم تراکنش های اعتباری به منظور دسته بندی بین مشتریان رویگردان و وفادار استفاده کرده است و دو متغیر دیگر، بهبودی در دسته بندی توسعه داده شده، ایجاد نکرده اند. بر اساس نتایج به دست آمده از درخت تصمیم و ماشین بردار پشتیبانی، می توان نتایج به دست آمده از این دو روش را با جدول (۳) مقایسه نمود.

| روش                 | درخت تصمیم | SVM |
|---------------------|------------|-----|
| تحداد پیش بینی صحیح | ۸۶         | ۹۱  |
| تعداد پیش بینی غلط  | ۲۶         | ۲۱  |

صحت پیش بینی  
% ۷۷/۷

تحداد پیش بینی صحیح  
% ۸۱/۳

بر اساس نتایج به دست آمده، ماشین بردار پشتیبان در بیش از ۸۱٪ موارد توانسته است مشتریان رویگردان را به درستی تشخیص دهد و این آمار برای درخت تصمیم ۷۷٪ بوده است که حاکی از عملکرد بهتر SVM در پیش بینی رویگردانی می باشد.

#### ۴- نتایج پژوهش

تحلیل روابط مشتریان و پیش بینی رفتار آنها در قبال بانک، اهمیت بسیار بالایی دارد. دلیل این امر، این است که یک مشتری، تنها از یک خدمت بانکی استفاده نمی کند؛ بلکه از مجموعه ای از خدمات بانکی و مالی که گستردگی بالایی دارد؛ بهره می برد و در واقع، هزینه از دست دادن مشتری برای بانک ها، زیاد است. در همین راستا، در این تحقیق جهت شناسایی مشتریان رویگردان، از دو متغیر میانگین موجودی و میانگین تراکنش به صورت تعديل شده با درآمد استفاده شده است. بر اساس این دو متغیر و با استفاده از نقشه خود سازمان ده شبکه عصبی، مشتریان رویگردان شناسایی شده و برچسب وفادار، معمولی و رویگردان به مشتریان تخصیص داده شد. در ادامه، در یک فضای سه بعدی تشکیل شده توسط متغیرهای تعداد و ارزش تراکنش های نقدی و تراکنش های اعتباری و با استفاده از ماشین بردار پشتیبانی، مشتریان دسته بندی شده و رویگردانی مشتریان پیش بینی گردید. بر اساس نتایج به دست آمده، روش پیشنهادی قابلیت پیش بینی رویگردانی تا ۸۱٪ موارد را داشته است. علاوه بر این، ماشین بردار پشتیبان نیز عملکرد بهتری در دسته بندی مشتریان نسبت به درخت تصمیم با ۷۷٪ کارایی، داشته است. بر اساس نتایج به دست آمده، بانک می تواند با اعمال روش پیشنهادی، ۶ ماه قبل از رویگردانی مشتریان، این مسئله را پیش بینی کردد و نسبت به اقدامات اصلاحی و پیشگیراته، اقدام نمایند.

#### ۴- منابع

- Adwan, Omar et al. (2014). Predicting customer churn in telecom industry using multilayer perception neural networks: Modeling and analysis. *Life Science Journal*, 11(3): 75-81.

2. Amir Shahi, Mirahmad, Siahtiri, Vida, Ravanbod, Fariba. (2010). Identifying the factors affecting the creation of “trust” in key bank customers: key customers of the Bank of Entrepreneur in Tehran. *Management Researches in Iran*, 4(64): 61-67.
3. Haghghi Kafash, Mehdi, & Akbari, Masoud. (2011). Prioritizing Factors Affecting Customer Loyalty Using the ECSI Model. *Marketing Management*, 6 (10): 95-118.
4. Bahramzadeh, Mohammad Mehdi, Shokati Maghareb, Somayeh. (2010). Identification and ranking of factors affecting customer loyalty in private banks of Khuzestan province. Second International Financial Services Marketing Conference.
5. Castanedo, Federico, et al. (2014). Using deep learning to predict customer churn in a mobile telecommunication network.
6. Datta, P., Masand, B., Mani, D., & Li, B. (2000). Automated cellular modeling and prediction on a large scale. *Artificial Intelligence Review*, 14: 485–502.
7. Ghanbarterani, Nasim. (2014). Customer clustering based on RFM model and data mining approach to increase customer loyalty. MSc Thesis, Tarbiat Moalem University, Faculty of Engineering.
8. Gordini, Niccolò, and Valerio, Veglio. (2017). Customers churn prediction and marketing retention strategies: An application of support vector machines based on the auc parameter-selection technique in b2b e-commerce industry. *Industrial Marketing Management*, 62: 100-107.
9. Huang, Bingquan et al. (2016). A Fuzzy Rule-Based Learning Algorithm for Customer Churn Prediction. Industrial Conference on Data Mining. Springer International Publishing, 2016.
10. Huigevoort, Chantine, and Remco, Dijkman. (2015). Customer churn prediction for an insurance company. Diss. M. Sc. Thesis, Eindhoven University of Technology, Eindhoven, Netherland, 2015.
11. Lee, W. S., Tzeng, G. H., Guan, J. L., Chein, K. T., and Huang, J. M. (2009). Combined MCDM Techniques for Exploring Stock Selection Based on Gordon Model. *Expert Systems with Applications*, 36(7): 6421-6430.
12. Mutanen, Teemu. (2006). Customer churn analysis—a case study. *Journal of Product and Brand Management*, 14(1): 4-13.
13. Óskarsdóttir, María, et al. (2016). A comparative study of social network classifiers for predicting churn in the telecommunication industry. *Advances in Social Networks Analysis and Mining (ASONAM), 2016 IEEE/ACM International Conference on*. IEEE.
14. Prasad, U. Devi, and S. Mahdavi. (2012). Prediction of churn behavior of bank customers using data mining tools. *Business Intelligence Journal* 5(1): 96-101.
15. Sharma, Anuj, Panigrahi, and Prabin Kumar. (2013). A neural network based approach for predicting customer churn in cellular network services. *ArXiv preprint ArXiv*:1(309):39-45.
16. Vafeiadis, Thanasis et al. (2015). A comparison of machine learning techniques for customer churn prediction. *Simulation Modeling Practice and Theory*, 55: 1-9.
17. Vapnik, Viladimir, N. (1998). An overview of statistical learning theory. John Wiley & Sons Inc., New York.
18. Zhang, L., and Zhou, W. D. (2011). Density-Induced Margin Support Vector Machines. *Pattern Recognition*, 44(8): 1448-1460.

## Using Data Mining to Predict Bank Customers Churn

### Abstract

The intensity of finding competition in the industrial and economic space and the market move towards a complete competition market has made the inclination of firms to attract more customers and, instead, have increased the tendency to operate in various service and manufacturing areas. This policy, which is known for increasing the share of wallet, makes it more important to maintain customer relationships and analyze their relationships and it is necessary to conduct customer behavioral analysis, customer relationship analysis, and customer behavior forecasting. The present research seeks to identify customers who are turning away and anticipates the decline of customers in order to prevent customers from falling. In this regard, the variables associated with the reversal analysis are first identified and then the bank customers are clustered using a neural network and classified into three categories of loyal, regular, and negative clients. With the receipt of the above labels, a backup vector machine has been used to classify and reverse prediction. Based on the results, the proposed method has the ability to predict rotational deviation of up to 80% and, moreover, has a better performance than the classical decision tree.

**Keywords:** Neural analysis, Neural network, Support vector machine, Decision tree.