

## پیش‌بینی ارزش طول عمر مشتریان بانکی با استفاده از تکنیک دسته‌بندی گروهی داده‌ها (GMDH) در شبکه عصبی

امیر خانلری<sup>۱</sup>، مهدی احراری<sup>۲</sup>، سمیه میرپور<sup>۳</sup>

**چکیده:** امروزه نقش مدیریت ارتباط با مشتری به‌عنوان ابزار راهبردی در توسعه سازمان‌های تولیدی و خدماتی و همچنین جذب و نگهداری مشتریان در صنایع رقابتی، انکارناپذیر است. شناسایی، ارزش‌گذاری و دسته‌بندی مشتریان و تخصیص بهینه منابع به آنها با توجه به ارزشی که برای سازمان‌ها دارند، از دغدغه‌های اصلی حوزه مدیریت ارتباط با مشتری است. در این مقاله با استفاده از شبکه عصبی GMDH به محاسبه و پیش‌بینی ارزش طول عمر مشتریان، به‌عنوان ابزاری کلیدی در تحقق نقش مدیریت ارتباط با مشتری در صنعت بانکداری پرداخته شده است. برای این منظور، اطلاعات جمعیت‌شناختی و مالی ۵۰۰۰ مشتری حقیقی ارزنده یکی از بانک‌های خصوصی کشور با شرط میانگین موجودی بیش از ۵۰۰ میلیون ریال در حداقل یکی از حساب‌ها، وارد شبکه شد. نتایج نشان داد به کمک این روش می‌توان با دقت بالای ۹۰ درصد ارزش طول عمر مشتریان را پیش‌بینی کرد که به نسبت روش‌های آماری متعارف، دقت بیشتری دارد. پس از حذف متغیرهای مؤثر و مضاعف، شبکه بار دیگر آزمایش شد که در این حالت نیز پیش‌بینی با دقت بیش از ۸۵ درصد بود.

**واژه‌های کلیدی:** ارزش طول عمر مشتری، پیش‌بینی، شبکه عصبی GMDH، مدیریت ارتباط با مشتری.

۱. استادیار گروه مدیریت MBA، دانشکده مدیریت دانشگاه تهران، تهران، ایران

۲. دانشجوی دکتری اقتصاد نفت و گاز، بازار و مالیه، دانشگاه علامه طباطبائی، تهران، ایران

۳. کارشناس ارشد مدیریت MBA، دانشگاه مهر البرز، تهران، ایران

تاریخ دریافت مقاله: ۱۳۹۴/۰۹/۱۷

تاریخ پذیرش نهایی مقاله: ۱۳۹۵/۰۵/۱۲

نویسنده مسئول مقاله: امیر خانلری

E-mail: khanlari@ut.ac.ir

## مقدمه

آنچه امروزه سازمان‌ها را به خود مشغول کرده است، کشف رویکردهای نوین برای ایجاد مزیت رقابتی و ربودن گوی سبقت از رقیبان است. تحقیقات نشان می‌دهد یکی از مسائل کلیدی برای ماندگاری و موفقیت سازمان‌ها، توانایی جذب مشتری‌های بالقوه و حفظ مشتری‌های فعلی است. مدیریت ارتباط با مشتری (CRM)<sup>۱</sup> ابزار کارآمدی برای به‌دست‌آوردن، نگهداری و افزایش رضایتمندی مشتریان در صنایع رقابتی به‌شمار می‌رود و دربرگیرنده مجموعه‌ای از فرایندهایی است که سازمان را قادر می‌سازد استراتژی‌های کسب‌وکار خود را در جهت ایجاد روابط بلندمدت و سودآور با مشتریان خاص تنظیم کند و ارزش ایجادشده توسط مشتری را به حداکثر برساند (کفاش‌پور، توکلی و علیزاده، ۱۳۹۱). در این رابطه، پیش‌بینی و محاسبه ارزش طول عمر مشتری (CLV)<sup>۲</sup> نوعی سلاح استراتژیک و مزیت رقابتی در افزایش سودآوری و تشخیص مشتریانی با سودآوری بیشتر به‌شمار می‌رود و از مهم‌ترین مفاهیمی است که برای بخش‌بندی بازار استفاده می‌شود (معینی، بهرام‌مهر، احراری و خادم، ۱۳۹۱). بدیهی است در بازار گسترده‌ای که تعداد مشتریان آن زیاد و نیازهای آنان بسیار متنوع و متفاوت است، هیچ سازمانی نمی‌تواند از عهده خدمات به تمام مشتریان بازار برآید. همچنین نمی‌توان برای همه خریداران از شیوه بازاریابی واحدی استفاده کرد، از این رو نیاز به بازاریابی هدفمند و بخش‌بندی دقیق بازار برای تعیین بازار هدف، امری ضروری به‌شمار می‌رود. طبق قانون پارتو (۸۰/۲۰)، ۸۰ درصد سود سازمان‌ها را ۲۰ درصد از مشتریان به‌وجود می‌آورند (اصغری‌زاده و رمضان‌ی، ۱۳۸۴). بنابراین سعی بر این است که با تکنیک‌های متفاوت CLV مشتریان پیش‌بینی و محاسبه شوند و با شناسایی مشتریانی که بیشترین ارزش را برای سازمان خلق می‌کنند، برای حفظ آنها برنامه‌ریزی شود. آنچه بیش از پیش بر اهمیت این موضوع می‌افزاید و گستردگی و لزوم آن را نمایان می‌کند، آینده کسب‌وکار جهانی است. بدیهی است سازمان‌هایی که از «بازاریابی رابطه‌مند»<sup>۳</sup> بهره‌بردارند، در آینده سهم بیشتری از بازار کسب خواهند کرد و با شناسایی ارزش طول عمر مشتریان خود، توانایی مدیریت بهینه آنها را به‌دست می‌آورند (پیپرز، راجرز و دورف، ۱۹۹۹).

برای شناسایی مشتری‌هایی که سودآوری بیشتری برای سازمان دارند، باید ارزش هر مشتری محاسبه شود و از این طریق مشتریان بر اساس سودی که ایجاد کرده‌اند، در سازمان رتبه‌بندی شوند. این موضوع می‌تواند مبنایی برای تدوین استراتژی سازمان باشد تا طول عمر مشتری و در

1. Customer Relationship Management
2. Customer Lifetime Value
3. Relationship Marketing

نتیجه، بازه زمانی سودآوری آن به حداکثر برسد (گرینبرگ، ۲۰۰۲). همچنین محاسبه و پیش‌بینی CLV به سازمان‌ها کمک می‌کند تا سازمان منابع خود را روی مشتریانی که سود بیشتری برای شرکت به‌وجود می‌آورند، سرمایه‌گذاری کند. به این ترتیب سازمان منابع خود را به بهترین نحو تخصیص داده و به رویکرد مشتری‌محوری نزدیک خواهد شد (کومار و جرج، ۲۰۰۷) هرچه سازمان در به‌کارگیری و تحلیل داده‌ها و اطلاعات خود قوی‌تر عمل کند، برنامه‌ریزی، تخصیص منابع، مدیریت هزینه و افزایش درآمد و سوددهی بیشتری خواهد داشت.

صنعت بانکداری به‌عنوان یکی از مهم‌ترین و فراگیرترین بخش‌های خدماتی و نهادهای اقتصادی، از نمونه‌هایی است که مدیریت ارتباط با مشتری در آن اهمیت زیادی دارد و مدیران این صنعت توجه ویژه‌ای به آن نشان می‌دهند. امروزه بانک‌ها به‌منظور بهینه‌سازی هزینه‌های بازاریابی و بهینه‌کردن سرمایه و بازده، به‌دنبال راهکاری برای تخصیص بهینه منابع و تمرکز بر آن دسته از مشتریانی هستند که معیارهای سودآور زیادی برای بانک دارند (معینی و همکاران، ۱۳۹۱). پژوهش حاضر نیز ضمن استناد به همین مطالب، تلاش دارد با بهره‌مندی از شبکه‌های عصبی مصنوعی، راهکاری برای پیش‌بینی ارزش طول عمر مشتری ارائه دهد تا بر پایه آن بتوان از داده‌های موجود در صنعت بانک و سازمان‌های مشابه، در جهت بهبود ارتباط با مشتری، ارزش‌گذاری و دسته‌بندی مشتریان و همچنین افزایش سودآوری سازمان استفاده کند. از این رو با استفاده از مشخصه‌های مالی و جمعیت‌شناختی مشتریان حقیقی یکی از بانک‌های مشهور ایران، به محاسبه و پیش‌بینی ارزش طول عمر مشتریان می‌پردازد و توانایی شبکه عصبی مصنوعی را در این خصوص ارزیابی می‌کند. هدف اصلی این پژوهش، ارائه راهکاری برای محاسبه و پیش‌بینی ارزش طول عمر مشتریان با استفاده از مشخصه‌های مالی و تراکنشی آنها و کشف روابط میان مشخصات مالی و جمعیت‌شناختی با ارزش طول عمر مشتریان و تأثیر آنها بر تابع هدف است. برای این منظور، به‌دلیل خاصیت خودسازماندهی و پیش‌بینی دقیق رفتار سیستم‌های پیچیده غیرخطی، از شبکه عصبی GMDH استفاده می‌شود.

## پیشینه نظری پژوهش

### مدیریت ارتباط با مشتری

در سال‌های اخیر با اهمیت یافتن مشتری از یک سو و تحولات صورت‌گرفته در زمینه فناوری اطلاعات از سوی دیگر، شاهد پیدایش مفاهیمی چون مدیریت ارتباط با مشتری به‌عنوان رویکرد

مهمی از کسب‌وکار بوده‌ایم. این مفهوم بر این معنا دلالت دارد که هر مشتری محصولات و خدمات خاصی را می‌طلبد، از این رو بهتر است به جای بازاریابی انبوه، مشتریان به صورت فرد به فرد بازاریابی شوند (گرینبرگ، ۲۰۰۲). مدیریت ارتباط با مشتری نوعی ابزار مدیریتی جدید است که ارتباط شرکت با مشتریان را با به‌کارگیری فناوری اطلاعات به‌روز (مانند تحلیل داده‌های برخط، داده‌کاوی و مدیریت پایگاه داده) مدیریت می‌کند. هدف مدیریت ارتباط با مشتری افزایش رضایت و وفاداری مشتری است و نه تنها مزیت رقابتی محسوب می‌شود، بلکه ضرورتی برای سازمان است (دایچ، ۲۰۰۲).

مدیریت ارتباط با مشتری سازمان را قادر می‌سازد تا از دانش مشتری برای تغییر، توسعه یا تجدید خدمات و محصولات به مشتری استفاده کند و از این مسیر سود نهایی حاصل برای سازمان را افزایش دهد (برزین‌پور، اخوان و زارع مقدم، ۱۳۸۹). مدیریت ارتباط با مشتری در واقع یاری‌دهنده‌ای در جهت شناسایی بهتر مشتریانی است که سودآوری بیشتری دارند. اقدامات مدیریت ارتباط با مشتری در چهار بعد شناسایی مشتری، جذب مشتری، حفظ مشتری و توسعه مشتری انجام می‌شود که این چهار بعد CRM برای به‌دست‌آوردن بینش دقیق از مشتری، بسیار مهم و حیاتی است (انگای، ژبو و چاو، ۲۰۰۹).

### ارزش دوره عمر مشتری

یکی از زیرشاخه‌ها و الزامات مدیریت ارتباط با مشتری، محاسبه و تعیین ارزش طول عمر مشتری است و می‌توان گفت اساساً یکی از مزیت‌های CRM، تشخیص مشتریانی با سودآوری بیشتر از طریق محاسبه و پیش‌بینی CLV است (معینی و همکاران، ۱۳۹۱). کورتکس (۱۹۹۵) CLV را مجموع سود خالص تنزیل‌شده‌ای می‌داند که مشتری در طول عمر ارتباط خود با سازمان ایجاد می‌کند. کومار (۲۰۰۶) نیز CLV را مجموعه ارزشی بیان کرده است که در بازه زمانی که مشتری همچنان مشتری سازمان است، برای سازمان به ارمغان می‌آورد و محاسبه آن موجب سودآوری و تخصیص منابع بهینه می‌شود. به‌طور کلی، می‌توان گفت ارزش طول عمر مشتری، ارزشی است که مشتری در طول دوره عمرش برای سازمان ایجاد می‌کند. این مفهوم، علاوه بر ارزش فعلی مشتریان، به ارزش بالقوه و آتی آنها برای سازمان نیز اشاره دارد و هدف اصلی از محاسبه آن، ایجاد برداشت وزنی از مشتریان به‌منظور تخصیص بهینه منابع به آنهاست (رزمی و قنبری، ۱۳۸۸).

### روش‌های محاسبه ارزش طول عمر مشتری

یکی از روش‌های عمده محاسبه ارزش طول عمر مشتری که در بسیاری از تحقیقات به کار رفته است، RFM نام دارد. محاسبه RFM روش مؤثری برای ارزیابی ارزش طول عمر مشتری است و شامل عناصر تازگی مبادله<sup>۱</sup>، تعداد تکرار مبادله در یک دوره زمانی<sup>۲</sup> و حجم مبادله<sup>۳</sup> می‌شود. در این روش باید با توجه به انواع گوناگون صنایع، وزن‌های مختلفی را به متغیرهای RFM اختصاص داد (باتل، ۲۰۰۴).

در روشی دیگر که SOW<sup>۴</sup> نامیده می‌شود، مبنای محاسبه ارزش مشتری، نسبت میزان فروش محصولی مشخص توسط سازمان به میزان کل خرید مشتری از همان محصول در کل بازار و در دوره زمانی معین است (ریناتز و کومار، ۲۰۰۵). به بیان دیگر، این روش میزان برآورده شدن نیازهای مشتری در سازمان را به‌عنوان معیار در نظر می‌گیرد.

یکی دیگر از روش‌هایی که برای محاسبه CLV به کار می‌رود، روشی است که محاسبات آن بر مبنای مدل‌های زنجیره مارکوف است. در این مدل معیار اصلی دسته‌بندی مشتریان، مقدار عایدی است که مشتریان نصیب سازمان می‌کنند. پایه این روش بر این موضوع استوار است که مشتریان هیچگاه سود یکسانی را برای سازمان ایجاد نمی‌کنند (گرینبرگ، ۲۰۰۲).

از روش‌های دیگر مطرح شده در این زمینه، استفاده از شاخص ROI است. در این روش مبنای محاسبه ارزش طول عمر مشتری، مقدار بازگشت سرمایه‌ای است که برای هر مشتری صرف شده است و مقدار هزینه‌ای که برای هر مشتری صرف می‌شود، اهمیت زیادی دارد. این نگرش مشتری را همانند ابزار سرمایه‌گذاری در نظر می‌گیرد (نو، ۲۰۰۱).

تاکنون رابطه‌های مختلفی برای محاسبه CLV ارائه شده است، اما اغلب مدل‌ها برگرفته از معادله ساده‌ای است که در قالب رابطه ۱ مشاهده می‌شود.

$$CLV = \sum_{i=1}^n \frac{(R_i - C_i)}{(1+d)^{i-0.5}} \quad \text{رابطه ۱}$$

$i$  دوره زمانی جریان نقدی تراکنش‌های مشتری،  $R_i$  درآمد به دست آمده از مشتریان در دوره  $i$ ،  $C_i$  هزینه کل صورت گرفته از  $R_i$  در دوره  $i$  و  $n$  تعداد دوره‌های زمانی در طول عمر مشخصی

1. Recency
2. Frequency
3. Monetary
4. Share of Wallet (SOW)

از مشتری است. بنابراین صورت کسر، سود خالص به دست آمده در هر بازه زمانی است و مخرج کسر، ارزش خالص سود را به ارزش فعلی تبدیل می کند.

آنچه در خصوص محاسبات CLV اهمیت دارد، این است که نمی توان معادله ثابتی برای آن در نظر گرفت. CLV می تواند به متغیرهای زیادی وابسته باشد که یک معادله واحد نمی تواند همه آن عوامل را پوشش دهد و مقدار زیادی به اصالت وجودی هر سازمان و نوع آن سازمان بستگی دارد. بنابراین، ایده اصلی در محاسبه CLV، این است که معادله ساده ای برای محاسبه آن در نظر بگیریم و با توجه به نوع سازمان و داده های موجود، تلاش کنیم تا هرچه بیشتر آن را به نتیجه مد نظر نزدیک نماییم (گوپتا، لمان و استوارت، ۲۰۰۴؛ فادر، ۲۰۰۵).

### پیشینه تجربی پژوهش

طی سال های اخیر، مدل های مختلفی در حوزه CLV ارائه شده است. برخی مدل ها ارتباط بین اجزای مختلف CLV را بررسی کرده اند و برخی دیگر به محاسبه و پیش بینی ارزش طول عمر مشتری پرداخته اند. همچنین از روش های متنوعی در این خصوص استفاده شده است. برگر و نسر (۱۹۹۸) از نخستین افرادی بودند که مدل مقدماتی ای برای محاسبه CLV ارائه دادند و در آن ارزش جریان نقدی خالصی که سازمان انتظار دارد از مشتری دریافت کند را همراه با محاسبه هزینه جذب مشتری برای سازمان در نظر گرفتند. فیفر و کاراوی (۲۰۰۰) در مقاله ای از مدل زنجیره مارکوف برای محاسبه CLV استفاده کردند و برای این مدل مزیت هایی چون انعطاف پذیر بودن آن، امکان استفاده برای حفظ و مهاجرت مشتری، احتمالی بودن مدل و امکان استفاده از آن در مسائلی با شرایط نامشخص، برشمردند. همچنین گوپتا و لمان (۲۰۰۳) به ارائه مدلی برای محاسبه ساده CLV پرداختند. آنها در این پژوهش نشان دادند که می توان با استفاده از اطلاعات معمولی از مشتریان که در هر سازمان وجود دارد، ارزش طول عمر مشتریان را تخمین زد و با ایجاد ارتباط بین ارزش مشتری و سازمان، برای تصمیم گیری های راهبردی مانند سیاست های جذب مشتری، بهره برد.

هوانگ، جانگ و سو (۲۰۰۴) مدلی را برای محاسبه ارزش مشتری ارائه دادند و سه عامل سهم سود گذشته مشتری، سود بالقوه مشتری و احتمال فرار مشتری را برای محاسبه CLV در نظر گرفتند. ارزش مشتری را نیز به سه دسته ارزش فعلی، ارزش بالقوه و وفاداری مشتری طبقه بندی کردند؛ سپس چارچوبی برای تحلیل ارزش مشتری و بخش بندی مشتریان بر اساس ارزش آنها ارائه دادند و نتایج تحقیقاتشان را روی مورد مطالعاتی که یک شرکت مخابراتی بود، نشان دادند.

گوپتا و هسنز (۲۰۰۶) نیز به بررسی و تحلیل چندین مدل برای محاسبه CLV پرداختند. تحقیق آنها برای تحقیقات آتی جنبه راهگشایی دارد؛ زیرا هر یک از مدل‌های REM<sup>۱</sup>، احتمالی<sup>۲</sup>، اقتصادی<sup>۳</sup>، تداومی<sup>۴</sup>، علوم کامپیوتر<sup>۵</sup> و انتشار/ رشد<sup>۶</sup> به‌صورت کامل در این مقاله مطرح شده است.

سهرابی و خانلری (۲۰۰۷) برای تعیین CLV مشتریان یکی از بانک‌های خصوصی تازه‌تأسیس در ایران، از روش خوشه‌بندی k-mean استفاده کردند و بر اساس مقادیر RFM به دسته‌بندی مشتریان پرداختند.

رزمی و قنبری (۱۳۸۸) نیز با معرفی محاسبه ارزش طول عمر مشتری به‌عنوان یکی از مهم‌ترین ابزارهای دستیابی به مدیریت ارتباط با مشتری سودآور، مدلی را برای محاسبه آن ارائه دادند که در آن، ضمن توجه به قوت‌هایی که در روش‌های متداول وجود دارد، با ترکیب دو روش RFM و ROI، احتمال عقد قرارداد مجدد مشتری در دوره‌های آینده و وفادار ماندن او به سازمان را محاسبه کردند و پس از ترکیب این احتمالات با میزان سوددهی مشتری به سازمان، معیاری برای اولویت‌بندی مشتریان ارائه دادند و در نهایت، کارایی مدل خود را با استفاده از اطلاعات یکی از شرکت‌های بیمه ارزیابی کردند.

کفاش‌پور و همکاران (۱۳۹۱) بر اساس ارزش دوره عمر مشتریان، مدلی را برای بخش‌بندی مشتریان ارائه دادند و با تعیین مقدار شاخص‌های مدل RFM برای ۲۶۰ مشتری و وزن‌دهی به شاخص‌ها با استفاده از فرایند سلسله‌مراتبی و در نظر گرفتن تعداد خوشه بهینه، به خوشه‌بندی مشتریان با استفاده از روش کا- میانگین پرداختند. آنها با این روش مشتریان یک شرکت بازرگانی در ایران را به هشت بخش اصلی دسته‌بندی کردند و به بررسی ویژگی هر یک پرداختند. امیری، شکوری، موسی‌خانی و شاوردی (۱۳۹۰) در مقاله‌ای به کمک داده‌های جمع‌آوری شده از تراکنش‌های مالی مشتریان یکی از بانک‌ها و با استفاده از شبکه‌های عصبی پرسپترون، روند آتی تراکنش‌های مشتری (روند مثبت، منفی یا تغییر الگوی رفتاری) را پیش‌بینی کردند و به شناسایی زمان مناسب برای پیشنهاد سرویس‌های مورد علاقه آنان پرداختند. محققان سه

1. RFM Models
2. Probability Models
3. Econometric Models
4. Persistence Models
5. Computer Science Models
6. Diffusion/Growth Models

مشتری را انتخاب کردند و از داده‌های تراکنش مالی حساب اصلی آنها در یک سال، برای پیش‌بینی الگوی رفتاری آتی استفاده کردند.

معینی و همکارانش (۱۳۹۱) در مقاله‌ای با تبیین ضرورت شناخت ارزش طول عمر مشتری در مدیریت ارتباط با مشتری، از شبکه‌های عصبی GMDH برای الگوسازی آن استفاده کردند. آنها با تحقیق روی مشتریان دو بانک ایرانی، به این نتیجه رسیدند که متغیرهای مالی نسبت به متغیرهای جمعیت‌شناختی تأثیر بیشتری بر ارزش طول عمر مشتریان دارند.

مدهوشی و امیری (۱۳۸۵) نیز در مقاله‌ای به ارائه الگویی جامع برای محاسبه ارزش چرخه عمر مشتری و شناسایی عوامل کلیدی مؤثر در این الگو پرداختند. از دید آنها مهم‌ترین عوامل مؤثر در ارزش چرخه عمر مشتری، تعداد مشتریان مورد انتظار، میزان نگهداری یا حفظ، میانگین خرید سالانه هر مشتری، تفاوت هزینه و قیمت در هر کالا، هزینه جذب مشتری جدید، هزینه نگهداری سالانه مشتری و نرخ بهره است. همچنین برای کامل‌تر شدن الگو، عواملی از قبیل خطر، تأخیر بین سفارش و پرداخت وجه و نرخ بازگشت را به آن اضافه کردند و این عوامل را به صورت متغیرهای ریاضی در الگو در نظر گرفتند.

احمدی، طاهر دوست، فخرآور و جلالیون (۲۰۱۱)، روش جدیدی برای محاسبه CLV در بازارهای پرخطر پیشنهاد دادند. آنها معتقدند روش‌های معمول محاسبه CLV بیشتر به محاسبه ارزش فعلی سود مشتری می‌پردازند و از سه عامل مهم تأثیر ریسک بازار بر جریان نقدی مشتری، انعطاف‌پذیری سازمان در برخورد با تغییرات بازار و هزینه جذب و حفظ مشتری، چشم‌پوشی می‌کنند. آنان تلاش کردند این سه عامل را در مدل خود در نظر بگیرند و CLV را برای کسب و کارهای پرخطر محاسبه و بررسی کنند.

چنگ، چپو، چنگ و وو (۲۰۱۲) در مقاله‌ای CLV را مجموع ارزش آینده و جاری مشتری تعریف کردند. آنان از مدل رگرسیون لجستیک و درخت تصمیم برای پیش‌بینی احتمال روی گردانی مشتری؛ از مدل آنالیز رگرسیون برای تعیین شاخص‌های رفتار مشتری؛ از زنجیره مارکوف برای مدل کردن احتمال تغییر تراکنش‌های مشتری و از شبکه‌های عصبی برای پیش‌بینی درآمد حاصل از مشتری استفاده نمودند.

مایکل پیپه (۲۰۱۲) ضمن اشاره به اهمیت شناخت مشتریان سودآور برای هر سازمان، به بررسی انواع مدل‌های محاسبه CLV پرداخت؛ سپس CLV ۵۰۰۰ مشتری را در سه سال متوالی بررسی کرد و پس از جمع‌آوری و مقایسه اطلاعات مشتریان، نرخ حفظ مشتری و ارزش آفرینی مشتریان را پس از اعمال سیاست‌های تبلیغاتی هدفمند که بر اساس نتایج محاسبه



CLV به‌دست آمده بود، با ۳ سال قبل مقایسه نمود. به این ترتیب اثر برنامه‌هایی که برای افزایش وفاداری مشتریان در سازمان به کار گرفته شده بود، مشخص شد.

بوسجنک (۲۰۱۱) نیز از شبکه‌های عصبی چندلایه برای بخش‌بندی مشتریان در صنعت بانکداری استفاده کرد. هدف وی از این کار، ایجاد گروه‌های سودآور و در حال رشد بر پایه ویژگی‌های مشترکی بود که سازمان را قادر می‌سازد تا هر گروه را با پیشنهادهای خاص هدف قرار دهد.

کیم، جانگ، سو و هوانگ (۲۰۰۶) با در نظر گرفتن اهمیت شناخت مشتری به‌منظور ایجاد ارتباط بلندمدت، کسب وفاداری و سودآوری بیشتر، چارچوبی برای تحلیل ارزش مشتری، بخش‌بندی مشتریان بر مبنای این ارزش و در نهایت، تبیین استراتژی‌های مناسب برای هر بخش ارائه دادند. این پژوهش روی داده‌های شش‌ماهه خدمات یک شرکت ارتباطات بی‌سیم در کشور کره به اجرا درآمد و داده‌ها به دو بخش اطلاعات جمعیت‌شناختی و اطلاعات مربوط به استفاده مشتریان از خدمات بی‌سیم دسته‌بندی شده است و با ارائه مدل جدیدی برای طول عمر ارزش مشتری (LTV) مشتری، به تبیین استراتژی‌های بازاریابی بر این مبنای پرداخته است.

شن و هسیه (۲۰۰۶) در پژوهشی به مدل کردن CLV با استفاده از شبکه‌های عصبی انتشار برگشتی پرداختند. آنها ابتدا ۱۳ مشخصه را برای ورودی شبکه عصبی خود انتخاب کردند، سپس در هر مرحله با حذف یکی از متغیرها، تأثیر آن را بر بهبود شبکه ارزیابی نمودند. چنانچه متغیر حذف‌شده تأثیر شایان توجهی روی شبکه ایجاد نمی‌کرد، کنار گذاشته می‌شد و آزمایش با بقیه متغیرها ادامه می‌یافت. آنها با این روش عوامل کلیدی مؤثر بر CLV را نیز شناسایی کردند و در نهایت، شاخص‌های جنسیت، سن، تأهل، درآمد، مصرف و زمان را در اندازه‌گیری CLV مؤثر دانستند.

مروتی شریف‌آبادی (۱۳۹۳) با استفاده از هفت ویژگی جمعیت‌شناختی و رفتاری ۶۰۰ نفر از مشتریان یکی از بانک‌های اروپایی، به خوشه‌بندی آنها توسط شبکه‌های عصبی رقابتی پرداخت. البدوی، نوروزی، سپهری و امین ناصری (۱۳۹۳) نیز تلاش کردند با تلفیق دو روش RFM و Pareto/NBD، کیفیت بخش‌بندی مشتریان را ارتقا دهند. آنها برای این منظور مؤلفه‌های رفتار خرید آتی مشتریان را تخمین زدند تا از آن به‌مثابه مبنایی برای بخش‌بندی مشتریان و پیش‌بینی ارزش دوره عمر هر رده استفاده کنند. نتایج این پژوهش نشان داد این مدل می‌تواند با درصد قابل قبولی، روند رفتار مشتریان را برآورد کند؛ اما علاوه بر پیچیدگی‌های پیاده‌سازی مدل Pareto/NBD، نتایج اجرای آن برای مشتریان با تواتر خرید پایین، تطابق بیشتری با درصد واقعی خریده‌ها در دوره آزمون داشت، در حالی که در تواتر خرید بالاتر این اختلاف بیشتر شد.

محمدی و شیخ (۱۳۹۳) نیز در مقاله‌ای به قاعده‌مندسازی و پیش‌بینی رفتار مشتریان بر اساس نظریه مجموعه راف پرداختند. آنها با بررسی رفتار مشتریان فعلی، مشتریان جدید را طبقه‌بندی کردند. در واقع در این پژوهش، از قانون راف برای بخش‌بندی مشتریان جدید استفاده شده است. محققان با استناد به پاسخی که مشتریان بر اساس قواعد منطقی (اگر... آنگاه) به دو پرسشنامه داده‌اند، آنان را به طبقه‌های مشابه دسته‌بندی کردند؛ سپس رفتار مشتری جدید را با این الگو انطباق داده و به پیش‌بینی نزدیک‌ترین طبقه برای مشتری پرداختند.

بهنامیان و عسگری (۱۳۹۴) و برادران و بیگلری (۱۳۹۴) مدل RFM را مبنای پژوهش خود قرار دادند و به بخش‌بندی مشتریان پرداختند. برادران و بیگلری (۱۳۹۴) با جایگزین کردن متغیر توالی خرید (C) به جای متغیر تازگی خرید (R) مدل خود را ارتقا داده و بهبود کیفیت این مدل را با استفاده از شاخص دیویس - بولدین نشان دادند. همچنین با استفاده از شبکه عصبی نشان دادند که برای پیش‌بینی خوشه مشتریان، مدل CFM در مقایسه با RFM کیفیت بالاتری دارد. در پژوهش‌های اخیر که به چند نمونه از آنها اشاره شد، اغلب تلاش شده است مدل‌های معمول در بخش‌بندی مشتریان، مانند روش RFM بهبود داده شوند که این روش‌ها به دلیل چشم‌پوشی از پویایی تغییرات در رفتار خرید مشتریان در طول زمان، قدرت پیش‌بینی‌کنندگی کمتری دارند. همچنین در پژوهش‌های مختلف، برتری روش شبکه‌های عصبی به روش‌های دیگر در خصوص پیش‌بینی نشان داده شده است.

سین و چاون (۲۰۰۹) در تحقیقی به بررسی روش شبکه‌های عصبی با کاربرد داده‌کاوی پرداختند و آن را ابزار امیدوارکننده‌ای در این خصوص معرفی کردند. آلمن، مارکو و ورتو (۱۹۹۴) از دو روش تحلیل ممیزی و شبکه‌های عصبی پرسپترون برای پیش‌بینی ورشکستگی ۱۰۰۰ شرکت ایتالیایی استفاده کردند و نشان دادند که دقت شبکه‌های عصبی به مراتب بیشتر از روش‌های سنتی آماری است.

کواتس و فانت (۱۹۹۳) از شبکه‌های عصبی MLP و تحلیل ممیزی برای پیش‌بینی ورشکستگی چندین شرکت در دوره زمانی ۱۹۷۰-۱۹۸۹ استفاده کردند. آنها نیز نشان دادند شبکه‌های عصبی به مراتب دقیق‌تر از تحلیل‌های ممیزی عمل می‌کنند.

سالچن گرگر، سینار و لش (۱۹۹۲) ضمن استفاده از شبکه‌های عصبی MLP برای پیش‌بینی سلامت مالی پس‌اندازها و وام‌ها، این روش را با مدل رگرسیونی لاجیت مقایسه کردند. این مطالعه روی اطلاعات S&L از ژانویه ۱۹۸۶ تا دسامبر ۱۹۸۷ انجام گرفت و در نهایت برتری شبکه‌های عصبی بر مدل لاجیت تأیید شد.

تام و کیانگ (۱۹۹۲) دقت محاسبات شبکه‌های عصبی را با دقت تخمین روش‌های تحلیل ممیزی، رگرسیون لاجیت، مدل نزدیک‌ترین همسایگی و درخت تصمیم‌گیری در پیش‌بینی ورشکستگی بانک تگزاس، مقایسه کرده و شبکه‌های عصبی را به‌عنوان مدل برتر انتخاب کردند. دسای (۱۹۹۶) از شبکه‌های عصبی MLP، MOE، تحلیل ممیزی و رگرسیون لاجیت، برای امتیازدهی اعتباری به درخواست‌های اتحادیه اعتباری صنعت استفاده کرد و در نهایت برتری شبکه‌های عصبی به مدل‌های لاجیت و تحلیل ممیزی را نشان داد.

شارما و پانیگرای (۲۰۱۱) در تحقیقی از روش شبکه‌های عصبی برای پیش‌بینی روی گردانی مشتریان سازمان مخابراتی تلفن همراه استفاده کردند. آنها پس از آزمایش به این نتیجه رسیدند که شبکه‌های عصبی می‌توانند با دقت بیش از ۹۲ درصد، روی گردانی مشتریان را پیش‌بینی کنند.

عبدو، پوینتون و المسری (۲۰۰۸) در مقاله‌ای داده‌های مشتریان یکی از بانک‌های مصری را که از آن وام گرفته بودند، مطالعه کردند. الگوریتم‌های به‌کار رفته در این مقاله، شبکه‌های عصبی احتمالی و چندلایه و رگرسیون لاجیت بود. ورودی‌های این الگوریتم‌ها از اطلاعات شخصی مشتری شامل سن، درآمد ماهانه، جنسیت، وضعیت تأهل، وضعیت مسکن، مقدار وام، مدت بازپرداخت و... تشکیل شده بود. در این تحقیق عملکرد شبکه‌های عصبی احتمالی و چندلایه با روش‌های مرسوم مانند آنالیز تفکیکی، رگرسیون منطقی و آنالیز براساس حداقل انحراف از میزان متوسط، مقایسه شده است. نتایج نشان داد در مقایسه کلی، شبکه عصبی با ۹۶ درصد دقت، بهترین عملکرد را دارد.

در میان انواع مختلف شبکه‌های عصبی مصنوعی که برای کاربرد پیش‌بینی استفاده شده‌اند، شبکه عصبی GMDH به‌دلیل خصوصیت خودسازمانده‌بودن و وابسته‌نبودن به تابع هدف، اهمیت ویژه‌ای دارد و تاکنون پژوهش‌های زیادی در زمینه‌های گوناگون با استفاده از این الگوریتم انجام شده است. در ادامه به چند نمونه از این تحقیقات اشاره می‌شود.

نریمان‌زاده و جمالی (۲۰۰۷) در مقاله‌ای به تشریح شبکه‌های عصبی GMDH برای سیستم‌های غیرخطی پرداختند. آنها با استفاده از توسعه الگوریتم ژنتیک برای شبکه‌های عصبی GMDH بهینه‌شده با روش پارتو به مدل کردن سیستم‌های غیرخطی پرداختند.

ورهرامی (۲۰۱۲) در پژوهشی به مقایسه روش MLFF و GMDH برای پیش‌بینی قیمت طلا پرداخت و در نهایت به این نتیجه رسید که روش GMDH نسبت به روش MLFF جواب بهتری می‌دهد. گفتنی است، وی در پژوهش دیگری مقایسه‌ای بین این دو روش برای پیش‌بینی قیمت گاز انجام داد و به نتایج مشابه پژوهش قبل دست یافت.

ابریشمی، مهرآرا، احقراری و میرقاسمی (۱۳۸۸) به الگوسازی و پیش‌بینی رشد اقتصادی ایران با استفاده از شبکه عصبی GMDH پرداختند و برتری این روش را نسبت به روش ARIMA بر اساس معیارهای خطا نشان دادند.

ابریشمی، معینی، مهرآرا و سلیمانی کیا (۲۰۰۸) نیز از روش GMDH برای پیش‌بینی قیمت گازوئیل با دو رویکرد استقرایی و تجزیه و تحلیل فنی استفاده کردند که دقت هر یک از رویکردها در پیش‌بینی به ترتیب بیش از ۹۶ درصد و ۹۹ درصد بود.

با توجه به حساسیت انتخاب روش پیش‌بینی در حوزه مالی به‌ویژه در صنعت بانک، در این پژوهش پیش‌بینی مبتنی بر شبکه‌های عصبی، به دلیل خصوصیات چگون همگرایی سریع، پیاده‌سازی آسان الگوریتم و قابلیت‌های گسترده در یادگیری، انتخاب شد. روش شبکه‌های عصبی نوعی مدل خود تنظیم‌کننده است که بر پایه داده‌ها و اطلاعات و بدون پیش‌زمینه نظری از نحوه عملکرد داده‌ها به طراحی مدل بهینه می‌پردازد و تنها بر اساس کشف ارتباط میان داده‌های ورودی و خروجی مسائل را حل می‌کند. این رویکرد مدل‌سازی همراه با توانایی یادگیری از طریق تجربه، ابزار مفیدی برای دستیابی به بسیاری از مسائل علمی است. همچنین شبکه‌های عصبی قابلیت تعمیم‌دهی بسیار خوبی دارند و بعد از آن که توسط قسمتی از داده‌ها (یک نمونه) آموزش داده شوند، می‌توانند قسمت دیده‌نشده جامعه را حتی زمانی که نمونه دارای اطلاعات نویزی باشد، به خوبی حدس بزنند (ملکوتی، ۱۳۹۳). همچنین در این پژوهش از شبکه عصبی GMDH، به دلیل خودسازمانده‌بودن و وابسته‌نبودن به تابع هدف، به‌عنوان راهکاری مناسب برای پیش‌بینی ارزش دوره عمر مشتری استفاده شده است.

### روش‌شناسی پژوهش

پژوهش پیش رو به دلیل ارائه روشی برای محاسبه و پیش‌بینی CLV و کاربرد آن در بخش‌بندی و افزایش سوددهی سازمان، از نظر هدف کاربردی به‌شمار می‌رود. نمونه‌گیری به روش احتمالی تصادفی ساده و پیش‌بینی CLV با استفاده از شبکه عصبی GMDH در محیط نرم‌افزار متلب انجام شده است. نمونه مطالعه، ۵۰۰۰ نفر از مشتریان حقیقی ارزنده یکی از بانک‌های خصوصی کشور با شرط میانگین موجودی بیش از ۵۰۰ میلیون ریال در حداقل یکی از حساب‌هاست که اطلاعات تراکنشی و جمعیت‌شناختی آنها، اطلاعات ورودی شبکه عصبی محسوب می‌شود. شایان ذکر است که این حجم نمونه مربوط به شش ماه از سال ۱۳۹۱ است. ۱۶ شاخص برای ورودی در نظر گرفته شده که شش مورد از مشخصات در خصوص اطلاعات جمعیت‌شناختی و

۱۰ مورد، اطلاعات مالی و تراکنشی مشتریان است. ارزش طول عمر مشتری (CLV) نیز به‌عنوان متغیر خروجی و هدف در نظر گرفته شده است.

متغیرهای جمعیت‌شناختی نیز متغیرهای جنسیت، سن، سطح تحصیلات (دیپلم، فوق دیپلم، لیسانس، فوق لیسانس، دکتری، حوزوی، سیکل، ابتدایی، بی‌سواد)، شهر (تهران و غیر تهران)، تعداد حساب‌های مشتری (تعداد سپرده‌های مشتری) و همچنین میزان سابقه مشتری در بانک (تفاضل سال افتتاح حساب و سال ۱۳۹۱) را دربرمی‌گیرد.

متغیرهای مالی نیز شامل میانگین مبلغ حساب جاری، میانگین حساب قرض‌الحسنه، میانگین حساب کوتاه‌مدت، میانگین حساب بلندمدت، مانده جاری، مانده سررسید، مانده معوقه و مانده مشکوک‌الوصول، تعداد چک برگشتی و مبلغ چک برگشتی، می‌شود. شایان ذکر است متغیرهای مالی یادشده همگی به‌صورت میانگین شش‌ماهه‌اند که با توجه به بازه تغییرات هر یک از متغیرها در دسته‌های ۸ تا ۱۲ تایی رتبه‌بندی شده‌اند. ارزش طول عمر مشتری نیز به‌عنوان متغیر هدف، از رابطه ۱ محاسبه می‌شود.

### معرفی شبکه عصبی GMDH

شبکه عصبی GMDH از الگوریتم GMDH شکل گرفته است. الگوریتم GMDH مخفف Group Model of Data Handling و از خانواده الگوریتم‌های استنتاجی<sup>۱</sup> برای مدل‌سازی ریاضی از مجموعه داده‌های چند پارامتری است که از ویژگی بهینه‌سازی ساختاری و پارامتریک خودکار از مدل برخوردار است. از این الگوریتم در شبکه‌های عصبی استفاده می‌شود و جایگزین مناسبی برای رگرسیون‌های استاندارد با فرم حاصل‌ضرب است (ایواخنکو، ۱۹۶۸). یکی از مهم‌ترین ویژگی‌های الگوریتم GMDH، توانایی شناسایی و حذف متغیرهای زائد است (فارلو، ۱۹۸۴؛ اناستاساکیس و مورت، ۲۰۰۱). ایواخنکو و مولر (۱۹۹۵) این الگوریتم را برای رهایی از پیچیدگی محاسبات و مشکل وابستگی خطی رگرسیون‌ها ابداع کرد. در واقع، این الگوریتم تکنیکی برای ساخت یک چندجمله‌ای بسیط با مراتب بالاست در مدل GMDH با چندین ورودی و یک خروجی، زیرمجموعه‌ای از اجزای تابع پایه است که در رابطه ۲ مشاهده می‌شود.

$$Y(x_1, \dots, x_n) = a_0 \sum_{i=1}^m (a_i - f_{ij}) \quad \text{رابطه ۲}$$

$f$  معرف تابع ابتدایی وابسته به مجموعه‌های مختلف از ورودی‌ها،  $a$  معرف ضرایب و  $m$  تعداد اجزای عملکرد پایه است.

برای پیدا کردن بهترین راه‌حل، الگوریتم GMDH چند راهکار دارد که به آنها مدل‌های جزئی<sup>۱</sup> یا مشتقات جزئی می‌گویند. ضرایب این مدل توسط روش کمترین مربعات<sup>۲</sup> برآورد می‌شود. الگوریتم GMDH به تدریج تعدادی از مدل‌های جزئی را افزایش می‌دهد و از میان آنها، یک مدل ساختاری با پیچیدگی مطلوب را که با ارزش حداقل یک معیار خارجی نشان داده می‌شود، پیدا می‌کند. به این فرایند مدل خودسازمانده<sup>۳</sup> می‌گویند. بنابراین می‌توان گفت GMDH شبکه‌ای خودسازمانده و یک‌سویه است که از چندین لایه تشکیل شده و هر لایه نیز از چندین نرون به وجود می‌آید (ایواخنکو و مولر، ۱۹۹۵).

محبوب‌ترین تابع پایه که در GMDH استفاده می‌شود، چندجمله‌ای کولموگوروف - گابور<sup>۴</sup> است (رابطه ۳).

$$y = a_0 + \sum_{i=1}^m (a_i x_i) + \sum_{j=1}^m \sum_{j=1}^m (a_{ij} x_i x_j) + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m (a_{ijk} x_i x_j x_k) \quad (\text{رابطه ۳})$$

که  $m$  متغیر ورودی شامل  $x_1, x_2, \dots, x_n$  را فقط به یک متغیر خروجی  $Y$  مرتبط می‌سازد. (ایواخنکو و همکاران، ۱۹۸۹).

شبکه عصبی GMDH نیز مانند همین الگوریتم، شبکه‌ای خودسازمانده و یک‌سویه است که از چندین لایه به وجود آمده و هر لایه نیز از چندین نرون تشکیل شده است (ایواخنکو، ۱۹۶۸؛ ایواخنکو و همکاران، ۱۹۹۵). تمام نرون‌ها ساختار مشابهی دارند، به طوری که دو ورودی و یک خروجی دارند و هر نرون با پنج وزن و یک بایاس، عمل پردازش را میان داده‌های ورودی و خروجی انجام می‌دهد. وزن‌ها بر اساس روش‌های کمترین مربعات خطا به دست می‌آیند؛ سپس به عنوان مقادیر مشخص و ثابت در داخل هر نرون جای‌گذاری می‌شوند. ویژگی بارز این شبکه آن است که نرون‌های مرحله قبلی یا لایه قبلی، عامل و مولد تولید نرون‌های جدید به تعداد  $\binom{m}{2} = m(m-1)/2$  هستند. از میان نرون‌های تولید شده، لزوماً تعدادی از آنها حذف

1. Partial Model
2. Least Square
3. Self Organized Model
4. Kolmogorov -Gabor

شده‌اند تا از واگرایی شبکه جلوگیری شود. نرون‌هایی که برای ادامه و گسترش شبکه باقی می‌مانند، امکان دارد برای ایجاد فرم هم‌گرایی شبکه و عدم ارتباط آنها با نرون لایه آخر، حذف شوند که در اصطلاح به آنها نرون غیرفعال می‌گویند. بنابراین شبکه عصبی GMDH مدل خودسازماندهی است که برای پیدا کردن بهترین راه‌حل، مدل‌های جزئی را به تدریج افزایش می‌دهد تا یک مدل ساختاری با پیچیدگی مطلوب را پیدا کند (ابریشمی و همکاران، ۱۳۸۸).

روش‌های تکاملی<sup>۱</sup> مانند الگوریتم ژنتیک، در مراحل مختلف طراحی شبکه‌های عصبی به‌طور گسترده‌ای به کار می‌روند و در پیدا کردن مقادیر بهینه و امکان جست‌وجو در فضاهای پیش‌بینی‌ناپذیر، قابلیت‌های منحصر به فردی دارند. شبکه عصبی GMDH نیز از این روش استفاده می‌کند (نریمان‌زاده، درویره و قربابایی، ۲۰۰۲).

### یافته‌های پژوهش

در این پژوهش ابتدا در هر بار آموزش شبکه عصبی، تعداد ۵۰۰ یا ۱۰۰۰ مشتری به صورت تصادفی انتخاب شده و ورودی‌ها و تابع هدف به شبکه داده شده است. برای نمونه ۵۰۰ تایی، ۴۵۰ نمونه برای آموزش و ارزیابی شبکه و ۵۰ نمونه برای آزمون در نظر گرفته شد، این اعداد برای نمونه هزارتایی دو برابر شدند. پس از آموزش شبکه عصبی و تأیید نتیجه مد نظر، داده‌های آزمون وارد شبکه عصبی شده و CLV پیش‌بینی شده مشتریان با مقادیر واقعی آنها مقایسه می‌شود. شبکه عصبی در دو حالت، دو لایه میانی و سه لایه میانی، هر یک به صورت جداگانه آزمایش شدند که نتایج آن در جدول ۱ آمده است. همان‌طور که در جدول مشاهده می‌شود، متغیرهای مربوط به میانگین حساب جاری، قرض‌الحسنه، کوتاه‌مدت و بلندمدت، بیش از بقیه در ارزش طول عمر مشتری تأثیرگذار بوده‌اند. گفتنی است متغیرهایی که شبکه آنها را متغیرهای بی‌اثر شناسایی می‌کند، به این معناست که نسبت به بقیه متغیرها اثر کمتری دارند و نمی‌توان آنها را کاملاً بی‌اثر تلقی کرد.

مقادیر خطای پیش‌بینی در حالت دو لایه و سه لایه برای نمونه‌های پانصدتایی و هزارتایی نیز به شرح جدول ۲ است.

جدول ۱. متغیرهای مؤثر و مضاعف<sup>۱</sup> در نمونه ۵۰۰ و ۱۰۰۰ تایی با شبکه دو لایه و سه لایه

ردیف	متغیر	دو/۵۰۰ لایه	سه/۵۰۰ لایه	دو/۱۰۰۰ لایه	سه/۱۰۰۰ لایه
۱	جنسیت				
۲	سن	✓			
۳	سطح تحصیلات		✓		
۴	کد شهر				
۵	تعداد حساب				
۶	سابقه مشتری		✓		
۷	میانگین حساب جاری مشتری	✓	*	*	*
۸	میانگین حساب قرض الحسنه مشتری	*	*	*	*
۹	میانگین حساب کوتاه مدت مشتری	*	✓	*	*
۱۰	میانگین حساب بلندمدت مشتری	✓	*	✓	*
۱۱	مانده جاری				✓
۱۲	مانده سررسید				
۱۳	مانده معوقه		✓		✓
۱۴	مانده مشکوک الوصول				*
۱۵	تعداد چک برگشتی	✓	✓	✓	
۱۶	مبلغ چک برگشتی		✓		


جدول ۲. خطا و دقت پیش‌بینی با شبکه دو لایه و سه لایه

آماره خطا	دو/۵۰۰ لایه	سه/۵۰۰ لایه	دو/۱۰۰۰ لایه	سه/۱۰۰۰ لایه
MSE	۰/۳۳۰۴۰۵۷۸۵	۰/۲۸۰۳۳۲۹۳۴	۰/۳۴۴۹۵۵۹۳۱	۰/۲۷۹۹۱۷۷۲۸
RMSE	۰/۵۷۴۸۰۹۳۴۷	۰/۵۲۹۴۶۴۷۶۲	۰/۵۸۱۳۲۹۴۹۱	۰/۵۲۹۰۷۲۵۱۷
خطای پیش‌بینی	۷/۸۴۱۳۱۱	۷/۲۰۱۰۵۴	۹/۵۰۵۹۶۳	۹/۰۷۲۹۷۱
دقت پیش‌بینی	۹۲/۱۵۸۶۹	۹۲/۷۹۸۹۵	۹۰/۴۹۴۰۴	۹۰/۹۲۷۰۳


۱. متغیرهای با اثر مضاعف در شبکه‌های عصبی GMDH به متغیری گفته می‌شود که تعداد تکرار بیشتری نسبت به سایر متغیرها در خروجی برنامه شبکه داشته باشد. به تعبیر دیگر، متغیرهایی که در مقایسه با متغیرهای دیگر، بیشترین تأثیر را روی متغیر هدف دارند.



شایان ذکر است در این حالت، شبکه عصبی رتبه CLV تمام نمونه‌های آموزن را حداکثر با یک رتبه اختلاف، درست پیش‌بینی کرده است. نمودارهای مقایسه مقادیر پیش‌بینی شده توسط شبکه عصبی GMDH و مقادیر واقعی آن، در قالب شکل‌های ۱ و ۲ به نمایش گذاشته شده است.



شکل ۱. نمودار مقایسه CLV ۵۰ مشتری با مقادیر واقعی (شبکه دو لایه)



شکل ۲. نمودار مقایسه CLV ۵۰ مشتری با مقادیر واقعی (شبکه سه لایه)

در مرحله بعدی به کشف رابطه میان متغیرهای جمعیت‌شناختی و مالی غیر مرتبط با فرمول CLV پرداخته شده است. به این ترتیب متغیرهای ورودی که تأثیر مستقیمی در محاسبه CLV دارند، حذف شدند و قدرت پیش‌بینی شبکه عصبی GMDH با استفاده از متغیرهای ورودی دیگر ارزیابی می‌شود. از این رو چهار متغیر میانگین حساب جاری، میانگین حساب قرض‌الحسنه، میانگین حساب کوتاه‌مدت و میانگین حساب بلندمدت حذف شدند و بقیه شاخص‌ها وارد شبکه می‌شوند. بر این اساس الگوسازی و پیش‌بینی CLV، مبتنی بر ۱۲ متغیر ورودی صورت گرفته است. نتایج آزمون شبکه در جدول ۳ آمده است.

جدول ۳. متغیرهای مؤثر و مضاعف در نمونه ۵۰۰ و ۱۰۰۰ تایی با شبکه دو لایه و سه لایه پس از حذف متغیرهای تأثیرگذار در معادله CLV

ردیف	متغیر	۵۰۰/دو لایه	۵۰۰/سه لایه	۱۰۰۰/دو لایه	۱۰۰۰/سه لایه
۱	جنسیت	*	*	*	*
۲	سن	*	*	*	*
۳	سطح تحصیلات	✓	✓	✓	✓
۴	کد شهر	✓	✓	✓	✓
۵	تعداد حساب	*	✓	✓	*
۶	سابقه مشتری	✓	*	*	*
۷	مانده جاری	✓	*	✓	*
۸	مانده سررسید				
۹	مانده معوقه				
۱۰	مانده مشکوک‌الوصول		*	✓	*
۱۱	تعداد چک برگشتی	✓			*
۱۲	مبلغ چک برگشتی		✓	*	✓


در این حالت تأثیر متغیرهای جمعیت‌شناختی و سایر متغیرهای مالی بر متغیر هدف CLV آشکار شده است.

مقادیر خطای پیش‌بینی در حالت دو لایه و سه لایه برای نمونه‌های ۵۰۰ تایی و ۱۰۰۰ تایی نیز به شرح زیر است.


جدول ۴. خطا و دقت پیش‌بینی با شبکه‌ی دولایه و سه‌لایه

آماره خطا	۵۰۰/دو لایه	۵۰۰/سه‌لایه	۱۰۰۰/دولایه	۱۰۰۰/سه‌لایه
MSE	۰/۷۸۸۱۵۵۲۱۸	۰/۷۶۳۱۶۹۱۴۱	۱/۱۰۳۹۷۵۵۱۲	۱/۰۷۶۶۶۲۰۳
RMSE	۰/۸۸۷۷۸۱۰۶۴	۰/۸۷۳۵۹۵۵۲۵	۱/۰۵۰۷۰۲۳۹	۱/۰۳۷۶۲۳۲۶
خطای پیش‌بینی	۱۳/۶۵۱۱۵	۱۳/۴۹۵۹۲	۱۳/۹۸۱۷	۱۴/۰۳۰۵۶
دقت پیش‌بینی	۸۶/۳۴۸۸۵	۸۶/۵۰۴۰۸	۸۶/۰۱۸۳	۸۵/۹۶۹۴۴

همان‌طور که مشاهده می‌شود با اینکه متغیرهای اصلی تأثیرگذار حذف شده‌اند، شبکه‌ی عصبی توانسته است در حد قابل قبولی تأثیر بقیه شاخص‌ها را در مقدار CLV شناسایی کند و با دقت خوبی آن را پیش‌بینی نماید. در این حالت نیز شبکه‌ی عصبی، رتبه‌ی CLV مربوط به ۸۵ درصد از نمونه‌های آزمایش شده را حداکثر با یک رتبه اختلاف، درست پیش‌بینی کرده است. نمودارهای مقایسه‌ی مقادیر پیش‌بینی شده توسط شبکه‌ی عصبی GMDH و مقادیر واقعی آن در قالب شکل‌های ۳ و ۴ نمایش داده شده است.



شکل ۳. نمودار مقایسه‌ی CLV ۵۰ مشتری با مقادیر واقعی (شبکه‌ی دولایه) پس از حذف متغیرهای مؤثر



شکل ۴. نمودار مقایسه CLV ۵۰ مشتری با مقادیر واقعی (شبکه سه لایه) پس از حذف متغیرهای مؤثر

### نتیجه‌گیری و پیشنهادها

از آنجا که محاسبه و پیش‌بینی ارزش دوره عمر مشتری به‌عنوان ابزار کلیدی برای بخش‌بندی مشتریان، تدوین برنامه‌های بازاریابی و تخصیص منابع سازمان به‌شمار می‌رود، محاسبه و پیش‌بینی آن در سال‌های اخیر، بسیار در کانون توجه مدیران سازمانی قرار گرفته است. از این رو، در این پژوهش به‌صورت اختصاصی به ارائه راهکاری برای پیش‌بینی CLV پرداخته شده است. در مقایسه با پژوهش‌های دو سال اخیر، می‌توان گفت دقت پیش‌بینی در این پژوهش ارتقای چشمگیری داشته است؛ اگرچه بیشتر پژوهش‌ها به‌دنبال ارائه راهکار و مدل جدید برای بخش‌بندی مشتریان بوده‌اند و اغلب تنها با توجه به متغیرهای RFM و تلاش برای بهبود آن با تلفیق روش‌های دیگر، تلاش کرده‌اند به این مهم دست یابند.

یکی از تفاوت‌های عمده این پژوهش با سایر پژوهش‌ها در این زمینه، پرداختن به پیش‌بینی تابع هدف با اهمیتی به نام ارزش دوره عمر مشتری است. به‌دلیل غیرخطی بودن رفتار مشتریان و پیچیدگی‌های فرایند پیش‌بینی، اغلب پژوهش‌ها از ابزارها و مدل‌های مختلف استفاده کرده‌اند تا با بررسی رفتار مشتریان به خوشه‌بندی و طبقه‌بندی مشتریان بپردازند. در این پژوهش با استفاده از شبکه عصبی GMDH تلاش شده است ضمن جلوگیری از محاسبات پیچیده و امکان‌یاده‌سازی این روش در کاربردهای تجاری، با دقت قابل قبولی به پیش‌بینی ارزش دوره عمر

مشتریان پرداخته شود. همچنین در این روش بر خلاف روش‌های معمول دیگر، امکان به‌کارگیری متغیرهای ورودی با تعداد زیاد نیز فراهم است، این در حالی است که اغلب پژوهش‌ها به دلیل پیچیدگی‌های محاسباتی در روش‌های آماری از ۳ تا ۵ متغیر یا نهایتاً ۷ تا ۱۰ متغیر برای شاخص ورودی در روش‌های مشابه استفاده کرده‌اند.

همچنین در روش به‌کار رفته در این پژوهش برای پیش‌بینی ارزش دوره عمر مشتری (شبکه عصبی GMDH)، علاوه بر پیاده‌سازی آسان‌تر و اجرایی‌بودن آن در کاربردهای تجاری، تطابق روند پیش‌بینی برای مشتریان با CLV بالا و پایین با مقدار واقعی به‌صورت یکسان و هماهنگ بوده و با دقت زیادی انجام شده است که این نکته در پژوهش‌های مشابه با دقت کمتر دیده شده است. در واقع با مرور پژوهش‌های دیگر می‌توان گفت محققان اغلب سعی در بهبود مدل‌های معمول در بخش‌بندی مشتریان، مانند روش RFM، داشته‌اند که این روش‌ها به دلیل چشم‌پوشی از پویایی تغییرات در رفتار خرید مشتریان در طول زمان، قدرت پیش‌بینی‌کنندگی کمتری دارند.

صنعت بانکداری به‌عنوان یکی از فراگیرترین بخش‌های خدماتی، یکی از نمونه‌هایی است که مدیریت ارتباط با مشتری در آن اهمیت زیادی دارد و مدیران این صنعت توجه ویژه‌ای به آن نشان می‌دهند. راهبرد بلندمدت و اصلی تمام بانک‌های موفق در سراسر جهان، «در مرکز کسب‌وکار قراردادن مشتریان است» (رشیدی، ۱۳۸۷). بانک‌های ایرانی نیز از این قاعده مستثنا نیستند؛ زیرا در تلاش برای افزایش سهم از کل بازار خدمات بانکی، آن بانکی موفق‌تر است که بهبود کیفیت خدمات بانکی را به‌عنوان راهبرد در نظر بگیرد، نه یک طرح تاکتیکی. بنابراین محاسبه و پیش‌بینی ارزش طول عمر مشتری و شناسایی عوامل مؤثر بر آن از طریق تکنیک‌های جدید آماری، به‌ویژه هوش مصنوعی و شبکه‌های عصبی، نقش مهمی در بازاریابی خدمات بانکی ایفا می‌کند و از دستاوردهای مهم آن می‌توان به بهینه‌سازی هزینه‌های جذب مشتری‌های جدید و حفظ مشتریان کنونی برای سودآوری در بلندمدت اشاره کرد (معینی و همکاران، ۱۳۹۱).

نتایج این پژوهش نشان داد با استفاده از شبکه عصبی GMDH، می‌توان ارزش طول عمر مشتریان را با دقت بیش از ۹۰ درصد پیش‌بینی کرد؛ به‌طوری که روند کلی مقادیر پیش‌بینی‌شده CLV مشتریان بسیار نزدیک به مقادیر واقعی آنها بود. همچنین متغیرهایی که بیشترین تأثیر را بر تابع هدف می‌گذارند، مشخص شدند. این شبکه علاوه بر این که با هوشمندی برای رویدادهای ورودی از نظر کمی و کیفی، تصمیم‌سازی می‌کند، لایه‌های ناشناخته ارتباطی را نیز درست محک می‌زند و از همین رو، صحت پیش‌بینی را با توجه به اعتبار نرون‌سازی در شبکه عصبی مصنوعی با متغیرهای استنتاجی، افزایش می‌دهد (ملکوتی، ۱۳۹۳).

از جالب‌ترین و مهم‌ترین نتایج پژوهش، این است که شبکه عصبی GMDH می‌تواند مقادیر CLV را حتی در حالت حذف متغیرهای اصلی تأثیرگذار در تابع هدف با دقت بیش از ۸۵ درصد تخمین بزند.

با وجودی که در حالت کلی متغیرهای جمعیت‌شناختی نسبت به متغیرهای مالی تأثیر کمتری بر ارزش طول عمر مشتری داشتند، طبق نتایجی که از شبکه عصبی بعد از حذف متغیرهای مؤثر بر CLV به دست آمد، مشخص شد که متغیرهای جمعیت‌شناختی با متغیرهای مالی ارتباط معناداری برقرار می‌کنند که این نتیجه از مهم‌ترین یافته‌های این پژوهش محسوب می‌شود؛ چراکه با این روش می‌توان حتی بدون دانستن متغیرهای مالی مشتریان که به‌طور مستقیم در محاسبه CLV به کار می‌روند، تنها با توجه به مشخصه‌های دیگر، CLV مشتریان را پیش‌بینی کرد. این امر به‌ویژه هنگامی اهمیت خود را نشان می‌دهد که رفتار مشتری پایدار نیست و در فضای رقابتی کسب‌وکار، احتمال دارد تغییری در رابطه با سازمان و حتی روی‌گردانی از سازمان ایجاد شود. از این رو، می‌توان ارزش دوره عمر مشتری در آینده را با استفاده از مشخصه‌هایی که نسبت به زمان تغییرات کم یا پیش‌بینی‌پذیری دارند یا حتی بدون تغییرند (مانند مشخصات جمعیت‌شناختی مشتریان)، استخراج کرد که این کمک بسیار زیادی به تصمیم‌گیری‌ها و تدوین استراتژی‌های سازمان خواهد کرد. در راستای این هدف، شبکه عصبی به دلیل خاصیت تکاملی و خودسازماندهی خود، روابط موجود میان متغیرهای ورودی و متغیر خروجی را به نحوی به دست می‌آورد که بتواند بدون توجه به متغیرهای اصلی تابع هدف، با کشف رابطه میان هر یک از ورودی‌ها و خروجی، با کمترین خطا آن را پیش‌بینی کند. می‌توان ادعا کرد که چنین آزمایشی در هیچ‌یک از مقالات گذشته انجام نشده است. همچنین با توجه به تعداد نمونه‌های آزمایش شده، نتایج این تحقیق نسبت به تحقیق‌های اجرا شده در گذشته، دقت پیش‌بینی بیشتری دارد. از این رهنمود می‌توان برای جذب مشتریان جدید راهکارهایی ارائه داد. برای مثال می‌توان در زمان جذب مشتری با توجه به اطلاعات جمعیت‌شناختی، برای پیش‌بینی سودآور بودن یا نبودن مشتریان استفاده کرد. به این ترتیب برنامه و استراتژی‌های سازمان بر پایه تجربه کسب‌شده از مشتریان قبلی اجرا می‌شود و مشتریانی که ویژگی‌های جمعیت‌شناختی مؤثری در ارزش طول عمر مشتری دارند، از همان ابتدا به‌عنوان مشتریانی با استعداد ارزش-آفرینی خوب برای سازمان، در نظر گرفته می‌شوند و برنامه‌هایی برای افزایش وفاداری و حفظ آنها تدوین خواهد شد. در این پژوهش پس از حذف متغیرهای مالی تأثیرگذار بر محاسبه CLV، متغیرهای جمعیت‌شناختی جنسیت، سن و سطح تحصیلات، به‌عنوان متغیرهای مؤثر در ارزش طول عمر مشتری شناسایی شدند. از این رو می‌توان سیاست‌ها و استراتژی‌های بازاریابی را برای

این گروه سنی و افراد با رده تحصیلاتی که بیشترین CLV را به خود اختصاص داده‌اند، متمرکز کرد تا جذب هدفمند، به افزایش سود سازمان منجر شود.

## References

- Abdou, H., Pointon, J. & El-Masry, A. (2008). Neural nets versus conventional techniques in credit scoring in Egyptian banking. *Expert Systems with Applications*, 35(3), 1275-1292.
- Abrishami, H., Mehrara, M., Ahrari, M. & Mirghasemi, S. (2010). Forecasting the GDP in Iran Based on GMDH Neural Network. *Journal of Economic Research*, 44(3), 1-24. (in Persian)
- Abrishami H, Moeini A, Mehrara M, Ahrari M, & Soleimanikia F. (2008). Forecasting Gasoline Price Using GMDH Neural Network Based on GA. *Journal of Quarterly Iranian Economic Research, Allameh Tabatabaai University*, 12(36), 37-59. (in Persian)
- Ahmadi, K., Taherdoost, H., Fakhravar, S. & Jalaliyoon, N. (2011). A New Model for Evaluating Customer Lifetime Value in High Risk Markets. *International Conference on Social Science and Humanity*, Singapore: IPEDR 5, IACSIT Press.
- Albadavi, A., Noroozi, A., Sepehri, M. M. & Nasri, A. (2014). An Integrated Pareto/NBD- fuzzy weighted RFM model for customer segmentation in non-contractual setting. *Quarterly Journal of Business Management*, 6(3), 417- 440. (in Persian)
- Altman, E., Marco, G. & Varetto, F. (1994). Corporate distress diagnosis: comparisons using linear discriminant analysis and neural network - the Italian experience. *Journal of Banking and Finance*, 18(3), 505-529.
- Amiri, B., Shakouri, H., Moosakhani, M. & Shaverdi, M. (2011). Predicting bank customer's behavior patterns for recognizing right time to deliver recommended services. *Knowledge & Technology Quarterly*, 1(4), 155-173. (in Persian)
- Anastasakis, L. & Mort, N. (2001). *The Development of Self-Organization Techniques in Modelling: A Review of the Group Method of Data Handling (GMDH)*. Department of Automatic Control and Systems Engineering. No. 813, The University of Sheffield, United Kingdom.

- Asgharizadeh, E. & Ramazani, A. (2005). Applying Analytical Hierarchy Process (AHP) for Prioritizing Customers in Banking System. *Third International Conference in Management*, 17-18 May, Iran, Tehran. (in Persian)
- Baradaran, V. & Biglari, M. (2014). Customer segmentation in fast moving consumer goods (FMCG) industries by using developed RFM model in Golestan province. *Quarterly Journal of Business Management*, 7(1), 23-42. (in Persian)
- Barzinpour, F., Akhavan, P., Zaremoghaddam, Z. (2010). Developing a Framework for Evaluating the Customer Knowledge Management Indicators in Iranian Banks. *Journal of Modiriati-e- Farda*, 9(24), 115-132. (in Persian)
- Behnamian, J. & Asgari, R. (2016). Bi-objective customer segmentation using data mining technique (A case study in Sima-choob), *Quarterly Journal of Business Management*, 7(4), 23-42. (in Persian)
- Berger, P. D. & Nasr, N. I. (1998). Customer lifetime value: Marketing Models and Applications. *Journal of Interactive Marketing*, 12(1), 17- 30.
- Bosjank, Z. (2011). Credit user's segmentation for improved customer relationship management in banking. *Applied Computational Intelligence and Informatics (SACI)*, 6<sup>th</sup> IEEE International Symposium, 379-384.
- Buttle, F. (2004). *Customer Relationship Management. Concepts and Tools*, Oxford: Elsevier.
- Cheng, C.J., Chiu, S.W., Cheng, C.B. & Wu, J.Y. (2012). Customer lifetime value prediction by a Markov chain based data mining model: Application to an auto repair and maintenance company in Taiwan. *Scientia Iranica*, 19(3), 849-855.
- Coats, P. & Fant, L. (1993). Recognizing Financial Distress Patterns Using a Neural Network Tool. *Financial Management*, 22(3), 142-155.
- Courtheoux, R. (1995). *Customer retention: How much to invest, research and the customer lifecycle*, New York, NY: DMA.
- Desai, V.S., Crook, J.N. & Overstreet JR. G.A. (1996). A Comparison of Neural Networks and Linear Scoring model in the Credit union Environment. *European Journal of Operational Research*, 95(1), 24-37.



- Dyche, J. (2002). *The CRM Handbook – A Business Guide to Customer Relationship Management*. Addison: Wesley.
- Fader, P.S., Hardie, B.G.S. & Lee, K.L. (2005). RFM and CLV: using iso-value curves for customer base analysis. *Journal of Marketing Research*, 42(4), 415-430.
- Farlow, S.J. (1984). The GMDH Algorithm of Ivakhnenko. *The American Statistician*, 35(4), 210-215.
- Greenberg, P. (2002). *CRM at the Speed of Light: Capturing and Keeping Customers in Internet Real Time*. Second Edition. Berkeley, California: McGraw-Hill.
- Gupta, S., Hanssens, D., Hardie, B., Kahn, W., Kumar, V., Lin, N., Ravishanker, N. & Sriram, S. (2006). Modeling customer lifetime value. *Journal of Service Research*, 9(2), 139-155.
- Gupta, S. & Lehmann, D. R. (2003). Customers as Assets. *Journal of Interactive Marketing*, 17(1), 9-24.
- Gupta, S., Lehmann, D. R. & Stuart, J. A. (2004). Valuing customers. *Journal of Marketing Research*, 41(1), 7-18.
- Hwang, H., Jung, T. & Suh, E. (2004). An LTV Model and Customer Segmentation Based on Customer Value: A Case Study on the Wireless Telecommunications Industry. *Expert systems with applications*, (26), 181-188.
- Ivakhnenko, A. G. (1968). The group method of data handling; a rival of the method of stochastic approximation, *Soviet Automatic Control*, 13(3), 43-55.
- Ivakhnenko, A.G. & Müller, J.A. (1995). Self-organisation of nets of active neurons. *SAMS*, 20, 1(2), 93-106.
- Ivakhnenko, A.G., Ivakhnenko, A.N., Kostenko, Y.V., Muller, J.A., Sarychev, A.P. & Yurachkovskiy, Y.P. (1989). Nonparametric forecasting GMDH models, Part 3. Models in the pattern- and clusteranalysis language, for forecasting processes in economic macro-systems. *Soviet Journal of Automation and Information Sciences*, 22(3), 1-14.

- Kafashpour, A. & Tavakoli, A. & Alizadeh Zavarem, A. (2012). Customers Segmentation Base on Lifetime Value, Use RFM Data Mining. *Journal of Public Management*, 5 (15), 63-84. (in Persian)
- Kim, S.Y. & Jung, T.S. & Suh, E.H. & Hwang, H.S. (2006). Customer Segmentation and Strategy Development Based on Customer Lifetime Value: A Case Study. *Expert Systems with Applications*, 31(1), 101-107.
- Kumar, V. (2006). *Customer lifetime value*. Handbook of Marketing Research, California: Sage.
- Kumar, V. & George, M. (2007). Measuring and maximizing customer equity: a critical analysis. *Journal of the Academic Marketing Science*, 35 (2), 157-171.
- Madhoushi, M. & Asgharnejad-Amiri, M. (2006). Provide a comprehensive model to calculate the customer lifetime value (CLV). *Fourth International Conference on Management*, 20-22 August, Iran, Tehran. (in Persian)
- Malakouti, N. (2014). Improve prediction in financial and investment markets, using GMDH neural network. *Payame Ayandeh Journal*, (7), 36-38. (in Persian)
- Mohammadi, E. & Sheikh, R. (2015). Customer Classification and Prioritize them in Decision Making Using Rough Set Theory and D number Approach (Case Study: Sony Ericsson Mobile Phone). *Quarterly Journal of Business Management*, 7(1), 163-185. (in Persian)
- Moeini, A. & Behradmehr, N. & Ahrari, M. & Khadem Shariat, S. (2012). Determining valuation indexes and Scoring Customers in Banking Services Marketing: A Case Study on Two Iranian Banks (Text in Persian). *Quarterly Business Journal*, 16(64), 1-25. (in Persian)
- Morovati Sharif Abadi, A. (2014). Clustering bank's customers using artificial neural networks, *Quarterly Journal of Business Management*, 6(1), 187-206. (in Persian)
- Nariman-zadeh, N. & Jamali, N. (2007). Pareto genetic design of GMDH-type neural networks for nonlinear systems. *International Workshop on Inductive Modelling*, Prague.

- Nariman-zadeh, N., Darvizeh, A., Darvizeh, M., Gharababaei, H. (2002). Modelling of explosive cutting process of plates using GMDH-type neural network and singular value decomposition. *Journal of Materials Processing Technology*, 128(1-3), 80-87.
- Ngai, E.W.T, Xiu, L. & Chau, D.C.K. (2009). Application of data mining techniques in customer relationship management: A literature review and classification. *Expert Systems with Applications*, 36(2), 2592-2602.
- Novo, J. (2001). *Maximizing Marketing ROI with Customer Behavior Analysis*. Available in: <http://www.drilling-own.com>. abgerufen am 11.01.2007, Stand 2007.
- Pepe, M. (2012). Customer lifetime value: A vital marketing/financial concept for businesses. *Journal of Business & Economics Research*, 10(1), 1-10.
- Peppers, D., Rogers, M. & Dorf, B. (1999). Is Your Company Ready for One to One Marketing? *Harvard Business Review*, 77(1), 151-160.
- Pfeifer, P.E. & Carraway, R.L. (2000). Modeling customer relationships as markov chain. *Jurnal of Interactive Marketing*, 14(2), 43-55.
- Rashidi, D. (2008). *Banking Services Marketing*. Tehran, Koohsar Press. (in Persian)
- Razmi, J. & Ghanbari, A. (2009). Provide a new model for calculating customer lifetime value. *Journal of Information Technology Management*, 1(2), 35-50. (in Persian)
- Reinartz, T. & Kumar, V. (2005). Balancing acquisition and retention resources to maximize customer profitability. *Journal of Marketing*, 69 (1), 63-79.
- Salchengerger, L.M., Cinar, E.M. & Lash, N.A. (1992). Neural networks: A new tool for predicting thirft failures. *Decision Siences*, 23(4), 899-916.
- Sharma, A. & Panigrahi, P. K. (2011). A Neural Network based Approach for Predicting Customer Churn in Cellular Network Services. *International Journal of Computer Applications*, 27(11), 26-31.
- Shen, C.C. Hsieh, K.L. (2006). Applying ANNs into constructing the CLV discriminant model. *5th WSEAS international conference on Data networks, communications and computers, Communications & Computers*, Bucharest, Romania, October 16-17.

Singh, Y. Chauhan, A.S. (2009) "Neural Networks in Data Mining". *Journal of Theoretical and Applied Information Technology*, 5(6), 37-42.

Sohrabi Yourtchi, B. & Khanlari, A. (2007). Customer lifetime value (CLV) measurement based on RFM model, *Journal Of The Accounting And Auditing Review*, 14(47), 7-20. (in Persian)

Tam, K.Y. & Kiang, M.Y. (1992). Managerial applications of neural networks: the case of bank failure predictions. *Management science*, 38(7), 926-947.

Varahrami, V. (2012). Good Prediction of Gas Price between MLFF and GMDH Neural Network. *International Journal of Finance and Accounting*, 1(3), 23-27.

Archive of SID