

ارائه روشی برای بخش‌بندی پویای پایگاه مشتریان در سیستم هوش تجاری تطبیق‌پذیر

غزل قنبری پناه^۱، کارشناس ارشد؛ اسلام ناظمی^۲، دانشیار؛ سعیده رجائی هرندی^۳، کارشناس ارشد

۱- دانشکده مهندسی برق و کامپیوتر - دانشگاه آزاد قزوین - قزوین - ایران - gh.ghanbaripناه@gmail.com

۲- دانشکده مهندسی و علوم کامپیوتر - دانشگاه شهید بهشتی - تهران - ایران - eslam.nazemi@yahoo.com

۳- دانشکده علوم اجتماعی و اقتصادی - دانشگاه الزهرا - تهران - ایران - saeedeh.rh@gmail.com

چکیده: رکن اصلی هر سیستم هوشمند، توانایی آن در تطبیق با تغییرات محیطی است، با این حال، توجه کافی به مسئله تطبیق‌پذیری در این سیستم‌ها نشده است. از این رو، هدف این مقاله ارائه روشی در سیستم هوش تجاری تطبیق‌پذیر است که به صورت پویا به بخش‌بندی مشتریان پرداخته و با نظارت بر رفتار خرید و همچنین تحلیل تازگی، تکرار و حجم پولی خرید هر یک از مشتریان، این بخش‌بندی را به روزرسانی می‌کند. در این پژوهش، روش‌های داده‌کاوی روی پیمانۀ تطبیق‌پذیری سیستم هوش تجاری تطبیق‌پذیر اعمال شده است تا بدین ترتیب مشتریان فعلی سازمان دسته‌بندی شده و در گذر زمان و با یادگیری از محیط، این دسته‌بندی بهبود یابد تا بتوان خدمات سفارشی‌شده به مشتریان ارائه داد این روش می‌تواند در کمتر از ۰/۵ ثانیه خوشه‌بندی اولیه را با توجه به تغییرات محیطی اصلاح کرده و از زمان‌های طولانی اجرای الگوریتم‌های خوشه‌بندی مرسوم (تقریباً در ۲۲ درصد موارد) بکاهد. روش پیشنهادی با در نظر گرفتن بخش‌های مختلف مشتریان، مقادیر فعلی RFM آن‌ها و تغییراتی که با تکرار خرید در این مقادیر ایجاد می‌شود، خوشه‌بندی بهتر و جامع‌تری از مشتریان سازمان به دست می‌دهد که می‌تواند در بهبود عملکرد سیستم هوش تجاری تطبیق‌پذیر مفید واقع شود.

واژه‌های کلیدی: هوش تجاری، هوش تجاری تطبیق‌پذیر، تصمیم‌گیری، خودتطبیقی، داده‌کاوی

A Method for Dynamic Segmentation of Customer Base in an Adaptive Business Intelligence System

G. Ghanbaripناه¹, M.Sc; E. Nazemi², Associate Professor; S. Rajae Harandi³, M.Sc.

1- Faculty of Electrical, Computer and IT Engineering, Islamic Azad University of Qazvin, Qazvin, Iran, Email: gh.ghanbaripناه@gmail.com

2- Faculty of Science & Computer Eng., Shahid Beheshti University, Tehran, Iran, Email: eslam.nazemi@yahoo.com

3- Faculty of Social Science and Economics, Alzahra University, Tehran, Iran, Email: saeedeh.rh@gmail.com

Abstract: The core of every intelligent system is its ability to adapt to environmental changes, but there is not enough attention to the compatibility issue in these systems. Hence, the aim of this study is to provide a method in adaptive business intelligence system that dynamically segment customers and update this segmentation by monitoring purchasing behavior and analysis of "Recency", "Frequency" and "Monetary" of each one of them. In this research, data mining techniques have been applied on the adaptive modulus of the adaptive business intelligence system so that the current clients of the organization are classified and over time and with learning from the environment, this classification is improved to provide customized services to customers. This method can modify initial clustering with respect to environmental changes in less than 0.5 seconds and reduce the number of execution of conventional clustering algorithms (Approximately 22% of cases). The proposed method, considering different customer segments, their current RFM values and changes made by repeating purchases at these values, provides a better and more comprehensive clustering of the organization's customers that can be useful in improving the performance of an adaptive business intelligent system.

Keywords: Business Intelligence (BI), Adaptive Business Intelligence, Decision Making, Self-adaptivity, Data Mining.

تاریخ ارسال مقاله: ۱۳۹۶/۸/۱۶

تاریخ اصلاح مقاله: ۱۳۹۶/۱۲/۲۵ و ۱۳۹۷/۲/۳۰ و ۱۳۹۷/۳/۷

تاریخ پذیرش مقاله: ۱۳۹۷/۶/۱۰

نام نویسنده مسئول: ناظم اسلامی

نشانی نویسنده مسئول: ایران - تهران - بلوار دانشجو - دانشگاه شهیدبهشتی - دانشکده مهندسی و علوم کامپیوتر

۱- مقدمه

بهبود مستمر فناوری‌های رایانه تأثیر شگرفی بر هر سازمانی داشته و مبحث برنامه‌ریزی مناسب منابع برای تولید به منظور بقا در بازارهای رقابتی در حال توسعه را مطرح کرده است [۱]. بنابراین توسعه یک زیرساخت فناوری اطلاعات که رویکردی جامع از عملیات سازمان، تأمین‌کنندگان و مشتریان ارائه دهد، برای اجرای کسب‌وکار و مدیریت بهتر منابع و بهره‌وری ضروری است [۲-۳].

بنگاه‌ها برای تصمیم‌گیری دقیق‌تر، بهبود عملکرد کسب‌وکار، پیش‌بینی نیازها و کاهش زمان تولید و هم‌چنین کاهش زمان تحویل محصول یا ارائه خدمت به مشتری، نیازمند پردازش حجم بالایی از اطلاعات صریح و به‌موقع هستند. استفاده از یک سیستم هوش تجاری به سازمان کمک می‌کند تا به‌صورت خودکار داده‌ها را از سیستم‌های اطلاعاتی مختلف استخراج کرده و پیچیدگی‌های مدیریت داده را بپوشاند [۴].

بنابراین معماری یک سیستم هوش تجاری باید به‌صورتی باشد که به‌سرعت به کاربران خود، اطلاعاتی مطمئن و دقیق دهد و آن‌ها را در اتخاذ تصمیمات پیچیده یاری کند [۵]. بدین ترتیب سازمان‌ها می‌توانند نیازهای مشتریان را درک کرده و فرآیندهای کسب‌وکار را به‌طور کارآمد هدایت کنند [۶]. اما این سیستم برای اجرای نرم‌افزارهای تحلیلی، نیازمند خبرگان و تحلیل‌گران است. برای رفع مشکل مذکور رویکرد خودتطبیقی پیشنهاد می‌شود که با استفاده از آن، نرم‌افزار می‌تواند بدون دخالت کاربر، خود را با ویژگی‌های مسئله تطبیق داده و با شرایط متغیر محیط سازگار شود [۷].

تطبیق‌پذیری مهم‌ترین مؤلفه هر سیستم هوشمند است که قابلیت تغییر به‌منظور تطابق با شرایط متغیر را برای سیستم فراهم می‌کند. این فرآیند به مدل پیش‌بینی اجازه می‌دهد که ارزش‌های پیش‌بینی‌شده را با نتایج واقعی مقایسه و به‌طور خودکار خود را تنظیم کند [۸]. سیستم هوش تجاری تطبیق‌پذیر، مؤلفه‌ای برای پیش‌بینی، تصمیم‌گیری نزدیک به بهینه و تطبیق پیش‌بینی انجام شده با تغییرات محیطی دارد [۹].

با توجه به این‌که در سازمان‌ها درصد کمی از مشتریان بخش عمده سودآوری شرکت را تشکیل می‌دهند، بهتر است کسب‌وکارها به‌جای جذب مشتریان جدید، به شناسایی و حفظ مشتریانی که حجم پولی بیشتری صرف نموده‌اند، بپردازند [۱۰]. مشتریان به مقدار یکسانی خرید نمی‌کنند در نتیجه، نباید با همه مشتریان با تلاش و هزینه یکسان در ارتباط بود [۱۱]. به‌منظور شناسایی و حفظ مشتریانی که حجم پولی بیشتری صرف نموده‌اند هر کسب‌وکاری باید مشتریان خود را از لحاظ ارزش، تحلیل و بخش‌بندی نماید [۱۲-۱۳].

هم‌چنین با توجه به این‌که سازمان‌ها با بازارهای پویا در تعامل هستند، بسیاری از آن‌ها به‌صورت پیوسته، حجم بالایی از داده‌های مربوط به تعاملات مشتری در زمان‌های مختلف را جمع‌آوری می‌کنند. از آنجاکه این داده‌ها تغییرات رفتاری مشتریان را منعکس می‌کنند، ضروری است که کسب‌وکارهای مختلف این تغییرات را شناسایی کنند، علت وقوع

آن‌ها را به‌درستی تفسیر کنند و نسبت به آن‌ها واکنش مناسب نشان دهند [۱۴]. روش‌های زیادی برای پیش‌بینی درخواست آتی کاربر، ارائه شده است. الگوریتم‌های اولیه از محبوبیت اشیا برای تعیین پیش‌واکنشی شی استفاده می‌کردند. امروزه بیشتر پژوهش‌ها، با استفاده از دنباله درخواست‌های قبلی، درخواست آتی کاربر را پیش‌بینی می‌کنند. به همین دلیل، نیاز به رویکردهای داده‌کاوی مطرح می‌شود تا با استفاده از آن، مرتبط‌ترین تغییرات در مجموعه داده‌ها شناسایی شوند [۱۱] و [۱۴].

مدل RFM (تازگی خرید، تکرار خرید و ارزش پولی خریده‌ها) پایه و اساس بخش‌بندی برای بازاریابی مستقیم است. هنگامی که امتیازات RFM مشتریان تعیین می‌شود، می‌توان مشتریان را به‌صورت بخش‌هایی گروه‌بندی کرد و متعاقباً سودآوری آن‌ها را تحلیل نمود. سپس این تحلیل سودآوری، پایه و اساس تصمیمات درباره نحوه تماس با مشتری در آینده را شکل می‌دهد [۱۱].

مطالعاتی که در مبحث هوش تجاری انجام شده است بیانگر عدم توجه کافی به مسئله تطبیق‌پذیری در این سیستم می‌باشد. بنابراین به یک رویکرد یکپارچه در هوش تجاری تطبیق‌پذیر به‌منظور فراهم کردن پایه و اساسی برای تصمیمات مدیریتی مؤثر در زمینه توسعه پویا و سریع محیط بازار، نیاز است. سیستم‌های قدیمی کسب‌وکار که به‌صورت مجزا هستند، معمولاً توانایی سازگاری با چنین سطحی از پیچیدگی را ندارند. بدین ترتیب، نیاز به یک رویکرد هوش تجاری مدرن که توانایی یکپارچه کردن کارآمد فضاهای اطلاعاتی مختلف و تطبیق با محیط تصمیم‌گیری پویا را دارد، دیده می‌شود.

سیستم‌های تطبیق‌پذیر در حوزه‌های مختلفی مورد استفاده قرار گرفته‌اند. بنابراین برای بهره‌برداری از فواید تطبیق‌پذیری در سیستم‌های سازمانی و توسعه و استقرار موفق آن‌ها، درک نیازمندی‌های یک سیستم تطبیق‌پذیر لازم و ضروری است [۱۵].

از این‌رو، هدف این پژوهش ترکیب هوش تجاری تطبیق‌پذیر و بخش‌بندی پویا به‌منظور طراحی سیستمی است که با جمع‌آوری داده از محیط، تحلیل و کاوش آن‌ها، بهترین و مؤثرترین بخش‌بندی در هر بازه زمانی را ارائه دهد تا به این سؤالات پاسخ دهد که آیا تازگی خرید، دفعات خرید و حجم پولی پرداخت‌شده در یک بازه زمانی مشخص تمایز بین رفتارهای مختلف مشتریان در روش پیشنهادی را به‌خوبی مدل می‌کنند؟ چگونه می‌توان مشتریانی که سبب سودآوری سازمان می‌شوند شناسایی کرده و در برنامه بازاریابی هدفمند در نظر گرفت؟ آیا می‌توان تغییر در رفتار مشتریان را از روی داده‌های گذشته سازمان تشخیص داد و از نتایج آن برای پیش‌بینی فروش آینده استفاده کرد؟ چگونه می‌توان این پویایی را با استفاده از فناوری‌های رایانه‌ای مدل‌سازی کرد تا سیستم به‌صورت خودکار خود را با این تغییرات تطبیق دهد؟

در این پژوهش، روش‌های داده‌کاوی روی پیمانانه تطبیق‌پذیری سیستم هوش تجاری تطبیق‌پذیر اعمال شده است تا بدین ترتیب مشتریان

این سیستم به سازمان کمک می‌کند تا محیط رقابتی خود را درک کرده و از سرمایه‌های فکری بنگاه محافظت کند [۲۰]. با ترکیب داده‌کاوی، ساخت مدل، کشف دانش، بهینه‌سازی و پشتیبانی از تصمیمات مدیریت می‌توان به کیفیتی بالا در بهینه‌سازی فرآیندهای کسب‌وکار و تصمیم‌گیری مشارکتی دست یافت [۲۱]. به‌طور کلی مسائل بهینه‌سازی به دو دسته ایستا و پویا تقسیم می‌شوند [۲۲]. داده‌کاوی، شناسایی الگوها از حجم انبوهی از داده است که با هدف پیش‌بینانه و توصیفی می‌تواند استفاده شود [۲۱].

طراحی محصولات و ارائه خدمات مطابق با نیازهای بخش‌های مختلف مشتریان تبدیل به ضرورت برای سازمان‌ها شده است. به‌طوری‌که بخش‌بندی مشتریان به راهبردی ضروری برای مدیریت فعالیت‌های بازاریابی تبدیل شده و فرایندی است که طی آن، بازار به گروه‌های کوچک‌تری از مشتریان با ویژگی‌ها و نیازهای مشابه، تقسیم می‌شود. چارچوب مفهومی جامعی برای بخش‌بندی پویای مشتری ارائه شده است. یکی از متداول‌ترین روش‌ها برای مرتب‌سازی و تحلیل مشتریان، امتیازدهی به آن‌ها براساس دفعات خرید و مقدار پرداخت است. یکی از شناخته‌شده‌ترین روش‌ها برای انجام این کار مدل RFM (تازگی خرید، تکرار خرید و ارزش پولی خریده‌ها) است که پایه و اساس بخش‌بندی برای بازاریابی مستقیم می‌باشد [۲۱].

مدل RFM تنها به‌عنوان یک مدل بخش‌بندی مدنظر نمی‌باشد بلکه مفهومی به نام ارزش مشتری را نیز در خود جای داده و به همین علت در بسیاری از مطالعات برای کشف و تحلیل ارزش مشتری بر مبنای رفتارهای خرید گذشته از این مدل استفاده می‌شود [۲۳]. به‌عنوان مثال، خدابنده‌لو و زیوری رحمان [۲۴] به بخش‌بندی مشتریان براساس تغییر رفتار خرید آن‌ها در طول زمان در حوزه کسب‌وکار الکترونیک پرداختند و نشان دادند که در نظر گرفتن تغییرات رفتار مشتریان و ارزش بیشتر رفتارهای اخیر نسبت به رفتارهای گذشته خرید در بخش‌بندی مشتریان موجب افزایش دقت پیش‌بینی رفتار آتی و همگن‌تر شدن مشتریان هر بخش می‌شود.

سینگ^۷ و رمانتیر^۸ [۲۵] کاربرد روش‌های خوشه‌بندی و طبقه‌بندی برای یافتن گروه‌هایی از خرده‌فروشان که از تسهیلات انتقال الکترونیکی پول^۹ بانک بزرگی در استرالیا استفاده می‌کنند را پیشنهاد می‌دهند. نتایج این پژوهش حاکی از این است که می‌توان به بینشی از تجربه خوشه‌بندی با استفاده از مقادیر RFM دست یافت.

بیرانت^{۱۰} [۲۶] یک رویکرد سه مرحله‌ای پیشنهاد می‌دهد که از تحلیل RFM با سه روش داده‌کاوی استفاده می‌کند: خوشه‌بندی، طبقه‌بندی و کاوش قوانین انجمنی. بدین ترتیب می‌توان محصولات دارای رتبه وابستگی بالاتر را به مشتریان توصیه کرد و رضایتمندی آن‌ها را افزایش داد. انیونا^{۱۱} [۲۷] به بخش‌بندی مشتریان بانکداری الکترونیک براساس مدل RFM-FRAT با در نظر گرفتن اطلاعات جمعیت‌شناختی و طول عمر مشتری پرداخت. پروانه^{۱۲} و همکاران [۲۸] معتقدند که مدل طول ارتباط با مشتری، تازگی تراکنش، دفعات تراکنش، حجم

فعالی سازمان دسته‌بندی شده و در گذر زمان و با یادگیری از محیط، این دسته‌بندی بهبود یابد. همچنین با بررسی مداوم تغییرات محیطی، این بخش‌بندی به‌روزرسانی می‌شود تا با تکیه بر آن بتوان بخش‌های مختلف مشتریان را شناسایی کرد، تغییرات آن‌ها در طول زمان را پیگیری کرد و خدمات سفارشی‌شده به مشتریان ارائه داد. بنابراین با درک انتظارات مشتری (چه در زمان حال و چه در زمان آینده)، می‌توان به افزایش رضایتمندی و وفاداری مشتری به سازمان و هم‌چنین کاهش روگردانی مشتری از کسب‌وکار دست یافت.

مدل پیشنهادی با استفاده از دانش مشتق شده از داده‌کاوی و تحلیل رفتار مشتری، می‌تواند به مدیران در توسعه راهبردهای بهتر برای بازاریابی کمک کند. بدین ترتیب ابتدا داده‌ها باید پیش‌پردازش شوند تا کشف دانش با دقت بیشتری حاصل گردد. مزیت اصلی این فرآیند، قابلیت به‌کارگیری راهبردهای مختلف بازاریابی برای بخش‌های مختلف مشتریان است. پویایی مدل در شناسایی و تطبیق‌پذیری با تغییرات در رفتار مشتری (با استفاده از قابلیت داده‌کاوی) می‌تواند در پیش‌بینی میزان فروش آینده سازمان و ارائه خدمات سفارشی‌سازی شده به هر دسته از مشتریان به‌منظور افزایش رضایتمندی و وفاداری آن‌ها به سازمان کمک کند.

با توجه به هدف، ابتدا مفاهیم مرتبط با هوش تجاری، تطبیق‌پذیری، هوش تجاری تطبیق‌پذیر و داده‌کاوی مطرح و مطالعات پیشین پژوهشگران در ارتباط با موضوع پژوهش به تفصیل آورده می‌شود. در بخش سوم به بیان روش پیشنهادی پرداخته می‌شود و در نهایت، پژوهش با ارزیابی و استخراج نتایج مدل پیشنهادی و نتیجه‌گیری و ارائه پیشنهادات خاتمه می‌یابد.

۲- ادبیات پژوهش

هوش تجاری، محیطی را برای تصمیم‌گیری مؤثر و تفکری راهبردی در سازمان فراهم می‌آورد و می‌تواند پایه و اساسی برای تصمیم‌گیری در حوزه‌های فروش، بازاریابی، مالی، مدیریت سرمایه و غیره باشد [۱۶]. این سیستم اطلاعات را به‌گونه‌ای نمایش می‌دهد تا کاربر بتواند با استفاده از ابزارهای خاص آن‌ها را تحلیل نماید [۱۷]. از دیگر فواید هوش تجاری، امکان اجرای گزارش‌های مقایسه‌ای بر روی داده‌های گذشته، اثربخشی کانال‌های توزیع، میزان سودآوری پیشنهادها و سایر موارد دیگر است [۱۶].

یک سیستم هوش تجاری مجموعه‌ای از راهبردها و ابزارهایی است که به مدیریت کسب‌وکار کمک کرده و بر روی مدیریت داده‌های مورد نیاز برای تصمیم‌گیری تمرکز دارد [۱۷]. این سیستم در بردارنده نرم‌افزاری برای استخراج، انتقال، بارگذاری^۱، انبار داده^۲، بازار داده^۳، گزارش‌ها و پرس‌وجوهای چندبعدی پایگاه داده^۴، پردازش تحلیلی برخط^۵ و داده‌کاوی^۶ است [۱۸]. به‌منظور پشتیبانی از تصمیم‌گیری در این سیستم، داده‌ها از سیستم‌های پردازش تراکنش برخط (OLTP) مختلف استخراج شده و پس از انتقال و بارگذاری در یک انبار داده به کاربر اجازه اجرای پرس‌وجوهای موردی را می‌دهد [۱۹].

باشند، (۲) تبدیل داده به دانش را تسهیل کنند، (۳) این دانش را از طریق گزارش‌های گرافیکی مختلف نمایش دهند.

پژوهش‌های اندکی به بررسی هوش تجاری تطبیق‌پذیر پرداخته‌اند از جمله، آسیار^{۱۸} همکاران [۳۰] مدلی ارائه کردند که در آن به استقرار «روش شناسی توصیه» در «محیط مذاکره باز» هنگامی که مدل‌های پروتکل‌های تعامل از پیش شناخته‌شده نیستند، پرداخته شده است. سیستم مذکور در مراحل مختلف به شرکت‌کننده درباره تصمیم به ادامه روند مذاکره کمک می‌کند.

خان^{۱۹} و کلیند^{۲۰} [۳۱] مدل هوش تجاری تطبیق‌پذیر برای صنایع تولیدی ارائه کردند که ناهمگونی عملکردها مختلف را از بین برده نمایه واحدی را برای کاربران صنایع تولیدی فراهم می‌کند. این مدل با ارائه دیدگاهی از عملکرد متقابل سیستم برای آن‌ها را قادر به اتخاذ تصمیمات صحیح می‌کند.

نورتیت^{۲۱} و همکاران [۱] یک مدل تصمیم‌گیری براساس کاربرد شبکه عصبی مصنوعی و الگوریتم بهینه‌سازی ازدحام ذرات و با بهره‌گیری از کاربرد سیستم‌های هوش تجاری تطبیق‌پذیر ارائه داده‌اند. آن‌ها نشان دادند که پیچیدگی داده‌ها، تغییر مداوم محیط و داده‌های مبهم، فرآیند مدیریت قوانین کسب‌وکار را مشکل کرده است که با استفاده از مدل پیشنهادی می‌توان به نتایج قابل قبولی دست یافت.

روبو^{۲۲} و کرافورد^{۲۳} [۱۷] چارچوبی برای یکپارچه‌سازی برنامه‌نویسی محدودیت و هوش تجاری تطبیق‌پذیر پیشنهاد داده‌اند. هدف آن‌ها ارائه یک برنامه کاربردی هوش تجاری تطبیق‌پذیر بود که از برنامه‌نویسی محدودیت برای انجام اصلاحات در نظام آموزشی یکی از دانشگاه‌های شیلی استفاده می‌کند. مایکلویچ^{۲۴} و همکاران [۹] نیز به بحث درباره مسائل پیش‌بینی و بهینه‌سازی در محیط‌های پویا و بررسی ایده‌های هوش تجاری تطبیق‌پذیر در سه مورد مطالعه کنترل آلودگی نیروگاه‌ها، کشتی‌رانی و توزیع اتومبیل پرداختند. مشاهده شد که با استفاده از این سیستم از میزان آلودگی محیط کاسته شده است. در کشتی‌رانی سیستم هوش تجاری تطبیق‌پذیر در هر لحظه تمامی موارد مذکور را بررسی و در صورت نیاز اطلاعات خود را به‌روزرسانی می‌کند تا یک مسیر امن برای حرکت کشتی پیشنهاد دهد. در مورد توزیع اتومبیل نیز سیستمی طراحی شده که درباره بهترین توزیع برای اتومبیل‌های کرایه‌ای در سایت‌های حراجی تصمیم‌گیری می‌کند.

گورگولو^{۲۴} و پیکل^{۲۵} [۲۳] پژوهشی در قلمرو وسیع پشتیبانی تصمیم مبتنی بر فناوری اطلاعات^{۲۶} و مفهوم آن برای راهبرد کسب‌وکار مدرن، معرفی کردند. این مطالعه به ترکیب یک رویکرد داده‌محور^{۲۷} کلاسیک با مفهوم مهندسی سیستم^{۲۸} جدید، گرایش دارد (سیستمی از سیستم‌ها^{۲۹}). در نتیجه، این رویکرد جدید موجب شکل‌گیری مفهوم هوش تجاری تطبیق‌پذیر می‌شود.

همان‌طور که از پژوهش‌های انجام شده در این زمینه مشخص است، تطبیق‌پذیری در سیستم هوش تجاری خیلی کم مورد توجه قرار گرفته است. با این حال، مطالعه مقالات مرتبط نشان‌دهنده این است که در

پولی برای توسعه برخی از راهبردهای بازاریابی مانند دگرفروشی کافی نیست. برای پرداختن به این مسئله، آن‌ها این مدل را بسط داده و مؤلفه P که نشانگر پتانسیل مشتری است را به آن افزودند. بدین ترتیب ابتدا مشتریان را بر اساس این پنج مشخصه و با استفاده از الگوریتم کا-میانگین بخش‌بندی کرده و براساس اطلاعات هر بخش، سه فعالیت بازاریابی را شناسایی کردند: برنامه‌های دگرفروشی، برنامه‌های ضد فرسایشی و برنامه‌های وفاداری.

بهشتیان اردکانی و همکاران [۲۹] با استفاده از مدل RFM برای محاسبه میزان وفاداری مشتریان، مدل جدیدی را به منظور بخش‌بندی بازار برای بازاریابی مستقیم و توصیه محصول به مشتری ارائه دادند. علاوه بر آن، خواجه‌وند^۱ و همکاران [۳۰] در پژوهش خود در صنعت آرایشی و بهداشتی سعی در دسته‌بندی مشتریان و ارزش‌گذاری آن‌ها بر مبنای متغیرهای RFM نمودند. آن‌ها تعداد محصولات خریداری شده توسط مشتری را در کنار سایر متغیرهای رفتاری در مدل پیشنهادی خود معرفی و به بخش‌بندی مشتریان پرداختند.

مقدم و همکاران^{۱۶} [۲۱] با توجه به راهبردهای دگرفروشی و بیش‌فروشی که از ابزارهای مهم افزایش ارزش مشتری در سازمان می‌باشند و بر پایه محصول و تنوع محصولات استوارند، سعی کردند بر جنبه‌های شناختی مشتری افزوده و شناخت دقیق‌تری از مشتری حاصل کنند. نتایج پژوهش آن‌ها نشان‌دهنده بهبود خوشه‌بندی مشتریان با استفاده از مدل پیشنهادی نسبت به مدل RFM سنتی است.

باچر و همکاران^{۱۷} [۱۴] سیستمی را به منظور بخش‌بندی مشتریان ارائه دادند که پویایی‌های بازار را مورد توجه قرار می‌دهد. رویکرد این سیستم کشف مجموعه‌های تکراری اقلام و تجزیه و تحلیل تغییر آن‌ها در طول زمان بود.

مطالعات زیادی روی بخش‌بندی و کاوش پویای مشتریان انجام شده است اما تا کنون نتایج این پژوهش‌ها در یک سیستم هوش تجاری با قابلیت انطباق با تغییرات محیطی، به کار گرفته نشده است. با افزودن رویکرد «تطبیق‌پذیری» توانایی پیش‌بینی براساس نتایج حاصل از داده‌کاوی، به سیستم داده می‌شود [۹]. آینده هوش تجاری در سیستم‌هایی است که بتوانند به‌جای ارائه توده‌ای از گزارش‌های مختلف، پاسخ‌هایی برای توصیه‌ها فراهم کنند و بتوانند تصمیم‌گیری کنند. در نتیجه گرایشی در بازار به وجود آمد به نام هوش تجاری تطبیق‌پذیر که علاوه بر اجرای نقش هوش تجاری سنتی (تبدیل داده به دانش)، شامل فرآیند تصمیم‌گیری نیز می‌شود که بر اساس پیش‌بینی و بهینه‌سازی است. سیستم هوش تجاری تطبیق‌پذیر دارای مؤلفه‌هایی برای پیش‌بینی، تصمیم‌گیری «نزدیک به بهینه» و تطبیق پیش‌بینی انجام شده با تغییرات محیطی است [۹]. این سیستم، مجموعه‌ای از ابزارهای نرم‌افزاری را برای بازاریابی داده‌های خلاصه‌شده و تفسیر شده به کاربران نهایی ارائه می‌دهد. اکثر این نوع از سیستم‌های هوش تجاری می‌توانند: (۱) از منابع مختلفی به داده‌ها دسترسی داشته

از داده‌ها، روابط ناشناخته‌ای که برای تحلیل و تصمیم‌گیری مؤثر در سازمان لازم است، کشف و شناسایی می‌کنند. این فرآیند شامل دو مرحله اساسی است: ابتدا مشتریان با استفاده از داده‌های گذشته خرید، بخش‌بندی می‌شوند. سپس این مدل باید به صورت برخط مورد بررسی قرار گیرد.

اگر عملکرد مورد نظر در هر بخش دچار تغییر شد، روش پیشنهادی توانایی تحلیل محیط و شناسایی روابط و تغییرات در الگوی رفتار مشتریان را دارد. به این ترتیب می‌تواند مدل بخش‌بندی اولیه را در طول زمان اصلاح کند تا بهترین راهبرد برای هر بخش اتخاذ گردد. در پژوهش حاضر، از الگوریتم کا-میانگین پلاس پلاس برای تعیین مراکز اولیه خوشه‌ها و خوشه‌بندی استفاده شده است. این الگوریتم، یک الگوریتم کا-میانگین بهبودیافته است که مراکز اولیه خوشه‌ها را به صورت تصادفی انتخاب نمی‌کند. بدین ترتیب، با استفاده از آن می‌توانیم به خوشه‌های بهتری دست یابیم [۳۲].

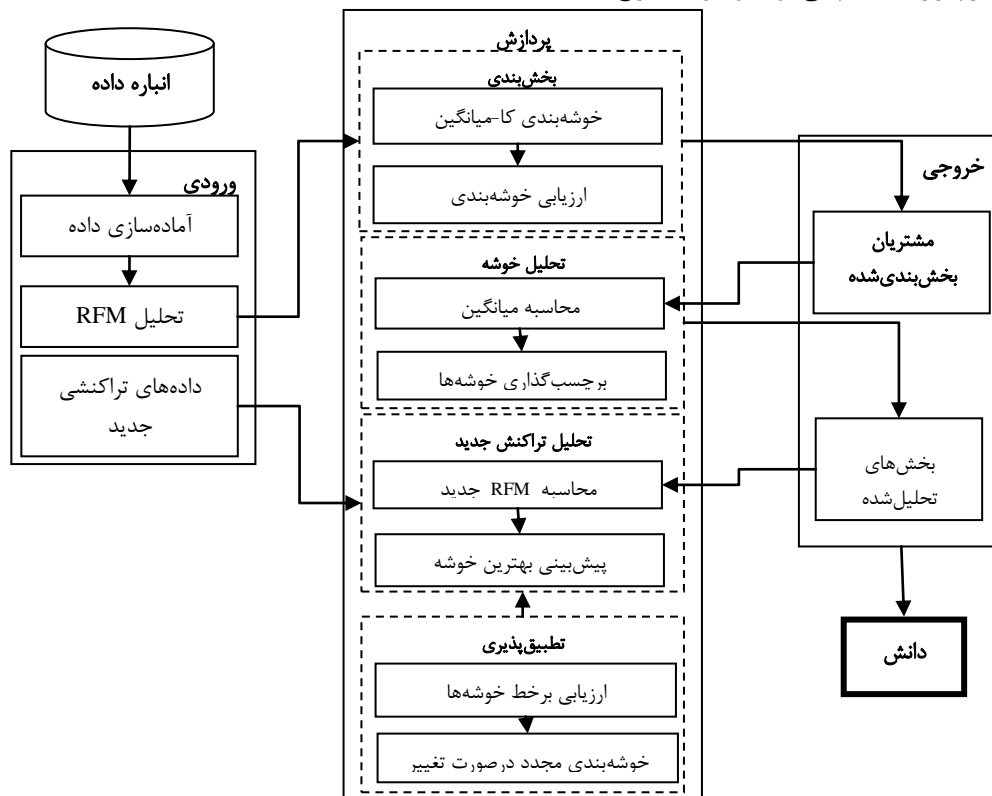
جهت تعیین تعداد خوشه‌های بهینه از شاخص دیویس-بولدین استفاده می‌شود. علاوه بر آن، به منظور اعتبارسنجی خوشه‌ها از معیارهای اعتبارسنجی داخلی و اعتبارسنجی پایداری استفاده می‌شود. سپس آزمون آنووا روی خوشه‌های به دست آمده اجرا شده و به منظور تعیین خوشه‌های متمایز از آزمون تعقیبی دانکن با استفاده از نرم‌افزار Spss.16 استفاده می‌شود. هرکدام از این بخش‌ها یکی پس از دیگری انجام می‌شود و خروجی یک بخش، ورودی بخش بعدی به حساب می‌آید. شکل ۱ چارچوب پیشنهادی را نشان می‌دهد.

طول دهه‌های اخیر، سازمان‌ها توانایی بهبود ظرفیت گردآوری و ذخیره داده برای تصمیم‌گیری را دارند. از آنجاکه هوش تجاری تطبیق‌پذیر یک جهت‌گیری جدید در سیستم‌های هوش تجاری است، باید بیشتر مورد تحلیل و بررسی قرار گیرد.

۳- چارچوب کلی روش پیشنهادی

هدف این پژوهش ترکیب هوش تجاری تطبیق‌پذیر و بخش‌بندی پویا به منظور طراحی سیستمی است که با جمع‌آوری داده از محیط، تحلیل و کاوش آن‌ها، بهترین و مؤثرترین بخش‌بندی در هر بازه زمانی را ارائه دهد. هم‌چنین با بررسی مداوم تغییرات محیطی، این بخش‌بندی را به‌روزرسانی می‌کند تا با تکیه بر آن بتوان بخش‌های مختلف مشتریان را شناسایی کرد، تغییرات آن‌ها در طول زمان را پیگیری کرد و خدمات سفارشی شده به مشتریان ارائه داد. به این ترتیب انتظار می‌رود که با ارائه روشی در پیمانه تطبیق‌پذیری سیستم هوش تجاری، به منظور بهبود بخش‌بندی پویای مشتریان یک سازمان در طول زمان (با توجه به تغییرات منعکس‌شده در بازار، اجتماع، نحوه خرید، تمایلات و انتظارات مشتریان فعلی و بالقوه)، بهترین تصمیم و راهبرد اتخاذ شود. پیمانه تطبیق‌پذیری، پیمانه پیش‌بینی را اصلاح می‌کند تا خطاهای پیش‌بینی کاهش یابند [۹].

در این بخش، رویکرد پیشنهادی در تحلیل رفتار مشتری براساس «تازگی خرید، دفعات خرید، حجم پولی خرید» بیان می‌شود. محاسبه مقادیر RFM و بخش‌بندی اولیه مشتریان از روی داده‌های یکپارچه انباره داده، با استفاده از نرم‌افزار R^2 انجام می‌شود. قوانین استخراج‌شده



شکل ۱. چارچوب پیشنهادی

۱.۳. پیاده‌سازی روش و مشاهدات تجربی

• شناخت کسب‌وکار

سازمان مورد مطالعه یک شرکت پخش مواد غذایی در ایران است که محصولات را خریداری کرده، انبار می‌کند و به فروش می‌رساند. بنابراین سه دسته داده مربوط به خرید محصولات، رسید و حواله انبار و هم‌چنین فروش محصولات در پایگاه داده‌های این سازمان ذخیره می‌شود. در پژوهش حاضر از داده‌های مربوط به فروش محصولات به مشتریان سازمان در طول دو سال و چهار ماه استفاده شده است.

• گردآوری و پیش‌پردازش داده

مجموعه داده موردنظر در این مطالعه، از پایگاه داده سازمان در طول دو سال و چهار ماه گردآوری شده است (داده‌های مربوط به فروش). از آنجایی که در یک سیستم هوش تجاری، ابتدا داده‌ها به صورت داده‌های مکعبی در یک انبار داده واحد، یکپارچه می‌شوند، داده‌های مورد نیاز استخراج شده و به صورت مکعب داده در Microsoft SQL Server 2014 ذخیره گردید. در طول این مدت حدود ۲۱۶,۵۹۰ سفارش توسط ۳۹۰۰ مشتری بر روی ۷۱۸ محصول (در ۱۲۲ گروه)، به سازمان داده شده است. سفارش‌ها شامل ستون‌هایی چون شماره شناسایی تراکنش، شماره شناسایی محصول، شماره شناسایی مشتری، شماره شناسایی متصدی فروش، تاریخ سفارش، تعداد و قیمت است. در جدول «مشتریان» داده‌های مربوط به نام و نام خانوادگی، جنسیت، نشانی، شماره تماس، اعتبار و غیره ذخیره شده است. جدول «محصولات» دربردارنده مواردی نظیر نام محصول، طبقه‌بندی محصول، بارکد و سایر اطلاعات تکمیلی است.

در مرحله پیش‌پردازش داده، مواردی که فاقد مقدار هستند مقداردهی می‌شوند، ابعاد داده‌ها در صورت لزوم کاهش می‌یابد، سلسله‌مراتب مفهومی داده‌ها تعریف می‌شود، نرمال‌سازی، استانداردسازی و گسسته‌سازی داده‌ها انجام شده و تبدیلات لازم بر روی آن‌ها اعمال می‌شود. در اینجا، صفات غیرضروری مانند نشانی، شماره تماس و غیره که برای استفاده در داده‌کاوی قطعاً غیر مرتبط خواهند بود، حذف می‌شوند. صفاتی که دارای مقادیر پیوسته هستند، گروه‌بندی می‌شوند. جنسیت نیز به صورت ۰ (مذکر) و ۱ (مؤنث) مشخص می‌شود. هم‌چنین از سلسله‌مراتب مفهومی برای گروه‌بندی محصولات استفاده شده است. مقدار «تازگی تراکنش» با محاسبه تعداد روزهایی که از آخرین تاریخ خرید مشتری از سازمان می‌گذرد، به دست می‌آید. مقدار «تعداد دفعات خرید» از طریق یافتن تعداد تراکنش‌های هر مشتری در دوره زمانی که سازمان مورد مطالعه واقع شده است، حساب می‌شود. مجموع بهای پرداختی در کلیه تراکنش‌های هر مشتری نسبت به تعداد دفعات خرید، نیز نشان‌دهنده مقدار «حجم پولی» برای آن‌ها است.

• مدل‌سازی RFM

در این پژوهش از تقسیم‌سازی بدون ناظر با دفعات تکرار مساوی استفاده شده است. در تقسیم‌سازی بدون ناظر، بدون در نظر گرفتن هیچ اطلاعات خاصی از یک ویژگی، به تقسیم‌سازی آن بر اساس طول‌های مساوی یا

دفعات تکرار مساوی پرداخته می‌شود [۳۳]. در واقع هدف، تقسیم‌سازی مقادیر RFM به پنج دسته با دفعات تکرار مساوی است [۱۱]. در مرحله اول، مشتری بر اساس تازگی خرید از سازمان، مرتب‌سازی می‌شود. سپس پایگاه داده به ۵ دسته تقریباً مساوی تقسیم شده و این دسته‌ها از شماره ۱ تا ۵ نام‌گذاری می‌شوند. در گام بعدی، مشتریان بر اساس تعداد دفعات خرید و حجم پولی مرتب‌سازی می‌شوند. بدین ترتیب پایگاه داده به ۱۲۵ گروه بر اساس مقادیر RFM تقسیم می‌شود [۳۴] که مشتریانی که دارای بالاترین امتیاز باشند معمولاً برای سازمان سودآورتر هستند [۳۵].

لازم به ذکر است که روش پیشنهادی، در هر به‌روزرسانی، نقاط انقطاع را با توجه به داده‌هایی که در همان لحظه وارد انبار داده می‌شوند، منطبق می‌کند. به‌صورتی که در هر یک از این ۵ دسته تعداد تقریباً مساوی از مشتریان قرار گرفته و توزیع یکنواختی داشته باشند. در اولین تقسیم‌سازی (جدول ۱) مقادیر R، F و M به‌گونه‌ای تقسیم‌سازی شده‌اند که در هر دسته به‌طور میانگین ۷۲۲ مشتری قرار گیرند. سپس تمامی مشتریان با توجه به مقادیر تازگی خرید، تعداد دفعات خرید و حجم پولی خرید، رتبه‌بندی شده و با کدی به اسم RFM مشخص می‌شوند. به‌عنوان مثال، اگر کد RFM یک مشتری ۵-۳-۴ باشد، به این معناست که این مشتری اخیراً حجم پولی بالایی برای خرید تعداد نسبتاً بالایی محصول پرداخت کرده است. جدول ۱ بهترین نقاط انقطاع به‌دست آمده برای مقادیر RFM مجموعه داده‌های مورد مطالعه را نشان می‌دهد.

جدول ۱. تقسیم‌بندی RFM

دسته	R		F		M	
	تعداد	محدوده	تعداد	محدوده	تعداد	محدوده
۱	۷۲۱	>۴۶۰	۷۷۷	۰-۸	۷۲۸	۰-۱۳۶۰۰
۲	۷۱۷	۲۳۹-۴۶۰	۶۸۱	۹-۲۰	۷۱۰	۱۳۶۰۰-۱۶۶۰۰
۳	۷۲۸	۷۹-۲۳۸	۷۰۷	۲۱-۴۳	۷۳۸	۱۶۶۰۰-۲۰۲۰۰
۴	۷۱۷	۱۵-۷۸	۷۲۵	۴۴-۹۵	۷۲۳	۲۰۲۰۰-۲۷۵۰۰
۵	۷۲۷	-۱۴	۷۲۰	>۹۵	۷۱۱	>۲۷۵۰۰

• تعیین تعداد مناسب خوشه‌ها


خوشه‌بندی کامیاب‌ترین پلاس پلاس برای گروه‌بندی مشتریانی که دارای مقادیر RFM مشابه اعمال شده است. ابتدا باید بهترین و مناسب‌ترین تعداد خوشه‌ها، با توجه به ماهیت داده‌ها مشخص شود تا مشتریان مورد مطالعه، بر اساس مدت زمانی که از آخرین خرید آن‌ها گذشته است (R)، تکرار خریدشان (F) و میانگین پول پرداختی در بازه مورد نظر (M) بخش‌بندی شوند. یکی از روش‌های تعیین تعداد خوشه بهینه، روش آرنج^{۳۱} نام دارد. در این روش ابتدا الگوریتم خوشه‌بندی را برای تعداد خوشه‌های مختلف (به‌عنوان مثال از ۲ تا ۱۵ خوشه) اجرا شده، در هر مرتبه، خطای مجموع مربعات از طریق فرمول (۱) محاسبه می‌شود [۳۹]:

$$SSE = \sum_{i=1}^k \sum_{x \in C_i} dist(c_i, x)^2 \quad (1)$$

که x نشان‌دهنده یک شیء، C_i بیانگر آُمین خوشه، c_i عبارت است از مرکز خوشه C_i در k خوشه و dist برابر با فاصله اقلیدسی استاندارد بین دو شیء در فضای اقلیدسی است.

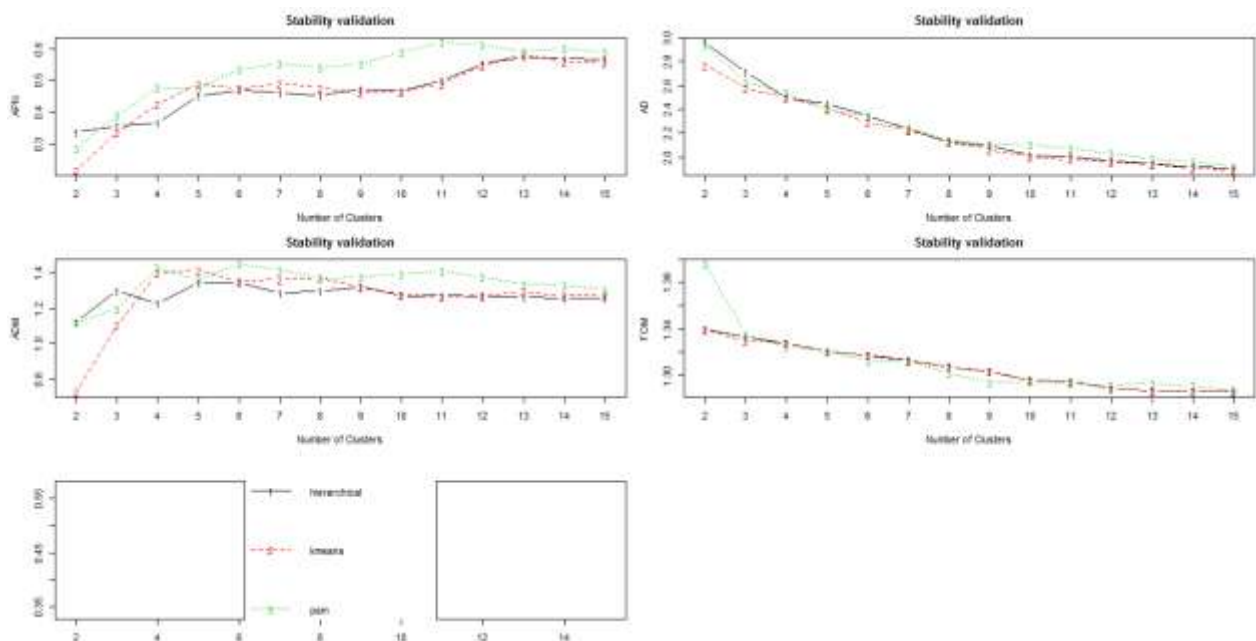
سپس یک نمودار خطی از این مقادیر رسم می‌شود. اگر نمودار شبیه یک دست باشد، آرنج آن بهترین تعداد خوشه برای داده‌ها است (کوچک‌ترین

دیویس بولدین



شکل ۲. شاخص دیویس بولدین برای تعداد خوشه ۲ الی ۱۲ در الگوریتم کا- میانگین پلاس پلاس

دو نوع دیگر از اعتبارسنجی خوشه‌ها، اعتبارسنجی داخلی و اعتبارسنجی پایداری هستند که برای کسب اطمینان بیشتر از تعداد مناسب خوشه‌ها و الگوریتم مورد استفاده، مورد بحث و بررسی قرار می‌گیرند [۳۹]. در اعتبارسنجی داخلی، سنج‌های «ارتباط»، «شاخص دون» و «عرض سیلهوت» باید به ترتیب دارای کمترین، بیش‌تر و بیش‌ترین مقدار باشند. مقدار این سه سنج برای الگوریتم کا- میانگین پلاس پلاس با ۸ خوشه در بهترین حالت خود قرار دارند. در اعتبارسنجی پایداری، سنج‌های میانگین نسبت عدم تداخل، میانگین مسافت، میانگین مسافت بین مراکز و معیار شایستگی باید همواره دارای حداقل مقدار باشند. شکل ۳ نشان می‌دهد که مقدار این سنج‌ها برای الگوریتم کا- میانگین پلاس پلاس با ۸ خوشه تقریباً در حالت مساعدی هستند.



شکل ۳. اعتبارسنجی پایداری برای سه نوع الگوریتم بخش‌بندی

R (یا F یا M) داشته باشد که مقدار آن بالاتر و یا پایین‌تر (۲ حالت) از این میانگین باشد.

برای مثال، R (پایین) F (بالا) M (بالا) نمایانگر این است که مقدار «تازگی خرید» مشتریانی که در این دسته قرار دارند از میانگین «تازگی تراکنش» تمامی مشتریان پایین‌تر است در حالی که «تعداد دفعات خرید»

خطای مجموع مربعات). اما با افزایش تعداد خوشه‌ها، این خطا به مراتب کمتر می‌شود (اگر تعداد خوشه‌ها برابر با تعداد نقاط داده در فضا باشد برابر ۰ است. زیرا در این صورت هر نقطه داده، خوشه خود را دارد و هیچ خطایی بین آن و مرکز خوشه خود وجود ندارد). بنابراین هدف دستیابی به کمترین خوشه‌هایی است که کمترین خطا را دارند [۳۷].

الگوریتم کا- میانگین پلاس پلاس برای تعداد خوشه ۲ الی ۱۲ اجرا شده و خطای مجموع مربعات محاسبه شده است. در جایی که تعداد خوشه‌ها برابر با ۸ است، یک آرنج کوچک دیده می‌شود. بنابراین بهترین تعداد خوشه برای داده‌های ما ۸ می‌باشد. لازم به ذکر است که این روش همیشه به خوبی عمل نمی‌کند؛ به خصوص اگر داده‌ها خوشه‌بندی شده نباشند [۳۷]. بنابراین از شاخص دیویس-بولدین برای سنجش تعداد مناسب خوشه‌ها استفاده می‌شود که تابعی از مجموع نسبت پراکندگی درون خوشه‌ای به تفکیک‌پذیری بین خوشه‌ای است. هرچه مقدار این شاخص کمتر باشد، یعنی تعداد خوشه‌ها برای داده‌های ورودی به الگوریتم مناسب‌تر هستند [۳۸]. شاخص دیویس-بولدین با استفاده از معادله (۲) به دست می‌آید:

$$DB = \frac{1}{n_c} \sum_{i=1}^{n_c} R_i \quad (2)$$

با محاسبه این شاخص برای تعداد خوشه‌های بین ۲ الی ۱۲ در الگوریتم کا- میانگین پلاس پلاس، کمترین حالت مربوط به زمانی است که تعداد خوشه‌ها ۸ باشد (شکل ۲).

• خوشه‌بندی مشتریان

با توجه به نتایج به دست آمده از بخش پیشین، مقدار پارامتر «کا» را برابر با ۸ در نظر می‌گیریم. با توجه به [۲۶] در این حالت می‌توان ۸ ترکیب مختلف (۲*۲*۲) برای RFM تعیین کرد؛ به طوری که اگر میانگین هر یک از این سه مقدار را به صورت جداگانه در نظر بگیریم، هر مشتری می‌تواند

تمایز بین خوشه‌ها از تحلیل واریانس (آنووا) استفاده می‌شود. جدول ۳ نتایج اجرای تحلیل واریانس روی نتایج خوشه‌بندی را نشان می‌دهد. همان‌طور که مشاهده می‌شود سطح تفاوت (sig) بین خوشه‌ها برای هر سه ویژگی بخش‌بندی برابر با $P = 0.000$ است که کمتر از ۰,۰۵ می‌باشد. بنابراین تفاوت چشم‌گیری بین مراکز این ۸ خوشه وجود دارد.

پس از مشخص شدن وجود ناسازگاری میان متغیرها به‌منظور اطمینان از این‌که خوشه‌ها درگروه‌های متمایز قرار می‌گیرند از آزمون تعقیبی دانکن استفاده می‌شود. نتایج به‌دست‌آمده از اجرای آزمون دانکن روی خوشه‌ها در جدول ۴ نشان داده شده است. در این آزمون ابتدا میانگین خوشه‌ها از بیش‌ترین تا کمترین مرتب می‌شوند. سپس هر میانگین، با تمامی میانگین‌های کوچک‌تر از خود (از کوچک‌ترین تا یکی مانده به خود) مقایسه می‌شود. اگر اختلاف بین آن‌ها از مقدار بحرانی بیشتر نبود، بدین معناست که تفاوت چشم‌گیری بین آن دو خوشه وجود ندارد [۴۰]. با توجه به نتایج می‌توان گفت که ۸ خوشه براساس سه ویژگی بخش‌بندی، به‌اندازه کافی باهم متمایز هستند.

و «حجم پولی خرید» مشتریان همان دسته، از میانگین این مقادیر برای تمامی مشتریان بالاتر است.

این هشت گروه از مشتریان شامل بهترین (ارزشمندترین)، باارزش، خریداران (یا خرده‌فروشان)، جدید، روی‌گردان، خریدار مکرر در گذشته، هزینه‌کننده و نامطمئن هستند [۲۶]. جدول ۲ نشان‌دهنده نتایج خوشه‌بندی اولیه مشتریان در ۸ دسته است که هر ردیف شامل تعداد مشتریان خوشه و مقادیر میانگین RFM است. آخرین ردیف شامل میانگین کل هر یک از مقادیر برای تمامی مشتریان می‌باشد. درحالی‌که خوشه شماره ۱ دارای بیش‌ترین تعداد مشتری (۱۶,۵ درصد) است، خوشه شماره ۳ کمترین تعداد (۱۰ درصد) را دارد. خوشه‌های ۱، ۳، ۶ و ۷ کسانی هستند که اخیراً خرید کرده‌اند که از بین آن‌ها، خوشه‌های ۱ و ۶ تعداد دفعات خرید بالاتری دارند. در مقابل، مدت زمان زیادی از خرید مشتریان خوشه‌های ۲، ۴، ۵ و ۸ می‌گذرد اما خوشه‌های ۴ و ۸ در گذشته تعداد خرید بیشتری نسبت به دو خوشه دیگر داشته‌اند.

جدول ۲. نتایج خوشه‌بندی اولیه مشتریان با استفاده از الگوریتم کامیانگین

پلاس پلاس

شماره خوشه	اندازه‌های خرید (میانگین)		دفعات خرید (میانگین)		حجم پولی (میانگین)	
	روز	امتیاز	تعداد	امتیاز	پول	امتیاز
۱	۱۸,۴۳	۴,۶	۱۲۲,۷۷	۴,۳۹	۱۶۰,۵۹۹,۷	۲,۳۱
۲	۵۶۹,۲۷	۱,۲۴	۱۳,۲۶	۱,۷۹	۱۲۰,۷۹۰,۸	۱,۴۲
۳	۶۱,۵۳	۴,۰۲	۱۹,۳۵	۲,۲۳	۵۸۱,۸۳۱,۵	۴,۵۹
۴	۲۸۹,۹۹	۲,۳	۷۰,۲	۳,۸۸	۱۳۵۹۰,۴۸	۱,۵۶
۵	۴۲۲,۲۸	۱,۷۸	۷۰,۷	۱,۳۹	۵۰۱۷۳۷,۸	۴,۳۴
۶	۳۴,۵۲	۴,۳۶	۱۴۸,۲۵	۴,۶۱	۳۲۲۲۷۰,۹	۴,۴۳
۷	۹۶,۱۵	۳,۶۸	۱۲,۲۶	۱,۶۹	۱۴۷۹۲۴	۱,۹۹
۸	۳۰۸,۵۵	۲,۸۱	۶۰,۶۲	۳,۶۷	۲۴۴۷۷۳,۵	۳,۶۶
میانگین کل	۲۲۲,۵۶	۳,۰۰۴	۵۹,۱	۲,۹۸	۲۶۸۹۶	۲,۹۹

جدول ۳. نتایج آزمون تحلیل واریانس

		Sum of Squares	df	Mean Square	F	Sig.
R	Between Groups	۵۷۳۲,۷۱۲	۷	۸۱۸,۹۵۹	۱۹۷۵,۴۸۵	۰,۰۰۰
	Within Groups	۱۴۹۳,۲۴۸	۳۶۰۲	۰,۴۱۵		
	Total	۷۲۲۵,۹۶۰	۳۶۰۹			
F	Between Groups	۲۸۱۶,۴۲۸	۷	۴۰۲,۳۴۷	۱۸۹۸,۸۳۳	۰,۰۰۰
	Within Groups	۱۵۷۶,۲۱۵	۳۶۰۲	۰,۴۳۸		
	Total	۷۳۹۲,۶۴۳	۳۶۰۹			
M	Between Groups	۵۶۳۱,۷۷۸	۷	۸۰۴,۵۴۰	۱۸۶۱,۱۲۱	۰,۰۰۰
	Within Groups	۱۵۵۷,۱۰۰	۳۶۰۲	۰,۴۳۲		
	Total	۷۱۸۸,۷۸۷	۳۶۰۹			

• ارزیابی خوشه‌بندی

هدف خوشه‌بندی کامیانگین این است که داده‌ها به‌صورتی خوشه‌بندی شوند که خوشه‌ها تا حد ممکن از هم متمایز باشند. برای سنجش میزان

• بخش‌بندی پویا

قطعاً خوشه‌بندی اولیه برای مدت زمان محدودی اعتبار دارد و مشتریان در طول زمان ممکن است خرید خود را تکرار کرده و یا سازمان، مشتریان جدیدی را جذب کند. از این‌رو، پویایی در بخش‌بندی

جدول ۴. نتایج آزمون دانکن

Subset for alpha = 0.05

خوشه	تعداد	۱	۲	۳	۴	۵	۶	۷	۸
R	۲	۱,۲۴							
	۵		۱,۷۸						
	۸			۲,۱۸					
	۴				۲,۳۰				
	۷					۳,۶۸			
	۳						۴,۰۳		
	۶							۴,۳۶	
	۱								۴,۶۰
F	۵	۱,۲۹							
	۷		۱,۶۹						
	۲			۱,۷۹					
	۳				۲,۲۳				
	۸					۳,۶۷			
	۴						۳,۸۸		
M	۲	۱,۴۲							
	۴		۱,۵۶						
	۷			۱,۹۹					
	۱				۲,۳۱				
	۸					۳,۶۶			
	۵						۴,۳۴		

مشتریان، یک اصل مهم به‌حساب می‌آید. از سوی دیگر، خوشه‌های به‌دست‌آمده باید از هم متمایز باشند تا بتوان برای تحلیل داده‌ها و تصمیم‌گیری در سیستم هوش تجاری به آن نتایج ارجاع داد. بنابراین در روش پیشنهادی، هر زمان که تراکنش جدیدی به سیستم اضافه شود، بخش‌بندی در صورت نیاز به‌روزرسانی شده و آزمون دانکن

جدول ۵ پویایی بخش‌بندی پیشنهادی را به‌خوبی نشان می‌دهد. به ازای هر تراکنش جدیدی که یک مشتری (قدیم یا جدید) انجام می‌دهد، سیستم به‌صورت خودکار بخش‌ها را تغییر داده، مقادیر لازم را به‌روزرسانی کرده و تنها در صورتی که تمایز کافی بین بخش‌ها وجود نداشته باشد، خوشه‌بندی را از ابتدا اجرا می‌کند (که این امر سبب کاسته شدن سربار سیستم خواهد شد).

• ارزیابی و مقایسه عملکرد روش پیشنهادی با الگوریتم کا میانگین

در مقایسه عملکرد روش پیشنهادی نسبت به الگوریتم خوشه‌بندی کا- میانگین باید اذعان داشت که هر دو روش به‌دنبال محاسبه مراکز متمایزی هستند که برای خوشه‌بندی داده‌ها استفاده خواهد شد. بدین منظور با در نظر گرفتن مراکز خوشه‌بندی کا- میانگین اولیه، از روشی که در [۴۱] و [۴۲] عنوان شده بود استفاده می‌شود. هنگام صحبت از پویایی در بخش‌بندی، اگر داده جدیدی وارد انبار داده و سیستم هوش تجاری شد، باید داده‌ها تحلیل شده و خوشه‌بندی به‌روزرسانی شود که این امر را می‌توان به دو صورت انجام داد: (۱) خوشه‌بندی مجدد داده‌های قدیم به‌علاوه داده‌های جدید با استفاده از الگوریتم کا- میانگین مرسوم و (۲) به‌روزرسانی خوشه‌ها با استفاده از روش پیشنهادی. روش دوم روی خوشه‌های موجود عمل می‌کند و داده‌های جدید را با در نظر گرفتن نزدیک‌ترین فاصله اقلیدسی آن‌ها با مراکز فعلی خوشه‌ها، بخش‌بندی می‌کند. تعداد خوشه‌های اولیه ۸ عدد است. زمان لازم برای تحلیل داده‌ها از طریق روش System.Time در نرم‌افزار آر اندازه‌گیری می‌شود. در حالت اول، پس از ورود داده‌های جدید به سیستم در هر نوبت، مقادیر لازم محاسبه و با داده‌های قدیم ترکیب می‌شود تا در نهایت الگوریتم کا- میانگین بر روی آن‌ها اجرا شود. در حالت دوم، روش پیشنهادی برای داده‌های جدیدی که وارد انبار داده می‌شوند، اجرا می‌شود.

تا زمانی که تمایز چشم‌گیری بین بخش‌های مشتریان وجود دارد، این روش به‌صورت مستقیم و بدون اجرای الگوریتم کا- میانگین، داده‌های جدید را با محاسبه فاصله اقلیدسی تا مراکز خوشه‌ها به خوشه‌ها اضافه می‌کند. رابطه بین زمان لازم برای تحلیل داده‌های جدید و هم‌چنین اجرای دو حالت مذکور روی آن‌ها نسبت به میزان داده‌های ورودی در جدول ۶ و شکل ۳ نشان داده شده است. اکنون می‌توان با ترکیب این دو نتیجه، درصد تغییراتی که نسبت به آن، روش پیشنهادی بهتر از روش خوشه‌بندی کا- میانگین مرسوم عمل می‌کند را محاسبه کرد. ابتدا درصد تغییرات در انبار داده با استفاده از فرمول (۳) محاسبه می‌شود [۴۲]:

$$(3) \quad \text{درصد تغییرات در انبار داده} = \frac{(\text{داده قدیم} - \text{داده جدید})}{\text{داده قدیم}} \times 100$$

جدول ۳۶. مقایسه زمان لازم برای تحلیل داده‌های جدید، اجرای الگوریتم کا-

میانگین و اجرای روش پیشنهادی			
داده جدید	زمان تحلیل داده (ثانیه)	زمان اجرای الگوریتم (ثانیه)	زمان اجرای روش پیشنهادی (ثانیه)
۱۰۰	۱۵۷/۱۷	۲۱۷۴/۳۱ (۱۳۲)	۰/۳۴

اجرا می‌شود، اگر تمایز از بین رفته بود، خوشه‌بندی دوباره انجام خواهد شد. به‌منظور نمایش تغییرات در طول زمان، خروجی تراکنش‌های جدیدی که بعد از بخش‌بندی اولیه در سیستم ثبت شده است را در بازه‌های زمانی دو هفته یک‌بار، از روش پیشنهادی استخراج کرده و نتایج تحلیل می‌شوند.

پس از بخش‌بندی اولیه و مشخص شدن ۸ خوشه از مشتریان، حدود ۶۰ هزار تراکنش جدید وارد سیستم شد. که از این تراکنش‌ها برای نمایش قابلیت تطبیق‌پذیری روش پیشنهادی استفاده می‌شود. برخی از این تراکنش‌ها مربوط به مشتریان گذشته و برخی دیگر متعلق به مشتریانی هستند که بعد از آن تاریخ وارد سازمان شده‌اند. لازم به ذکر است که پویایی بخش‌بندی و جایگاه مشتریان در هر خوشه به دو عامل بستگی دارد: (۱) تراکنش‌های جدیدی که مشتری انجام می‌دهد و (۲) تراکنش‌های جدیدی که سایر مشتریان انجام می‌دهند.

به‌منظور اثبات صحت روش پیشنهادی در بررسی تمایز بین بخش‌ها، نتایج به‌دست‌آمده در یکی از این هشت برهه زمانی وارد نرم‌افزار SPSS شد که نتایج آزمون دانکن تأیید کرد که هشت بخش براساس سه ویژگی «تازگی خرید»، «تعداد دفعات خرید» و «حجم پولی خرید» که بخش‌بندی براساس آن‌ها انجام شده است، به‌طور قابل‌توجهی از یکدیگر متمایز هستند.

جدول ۵. آزمودن صحت روش پیشنهادی در بررسی تمایز بین خوشه‌ها


Subset for alpha = 0.05								خوشه	تعداد
۸	۷	۶	۵	۴	۳	۲	۱		
							۱,۴۹	۶۴۳	R
						۱,۶۹		۴۸۲	
					۲,۱۳			۴۳۹	
				۲,۲۴				۴۳۶	
		۳,۷						۳۶۴	
		۳,۹۰						۴۶۱	
	۴,۴۸							۴۶۷	
۴,۷								۵۲۸	
							۱,۴۸	۴۶۷	F
						۱,۷۰		۴۳۹	
					۱,۸۳			۵۲۸	
				۱,۹۶				۴۳۶	
		۳,۵۶						۴۶۱	
		۳,۸۵						۳۶۴	
	۴,۴۳							۶۴۳	
۴,۶۲								۴۸۲	
							۱,۳۵	۵۲۸	M
						۱,۵۵		۳۶۴	
					۱,۸۸			۴۳۹	
				۲,۳۷				۶۴۳	
		۳,۷						۴۶۱	
	۴,۱۹							۴۶۷	
	۴,۴۳							۴۸۲	
۴,۶۳								۴۳۶	

۱۳۲ تکرار (هر دفعه با نقاط اولیه متفاوت) به ۸ خوشه متمایز دست یافته، اما هنگامی که ۲۰ درصد افزایش در داده‌ها داشته‌ایم، تنها با ۹۱ تلاش به نتیجه رسیده است. هم‌چنین نقاطی از شکل ۳ (روش پیشنهادی) جهش داشته است که در آن نقطه، با افزودن شدن داده جدید به داده‌های موجود، تمایز بین خوشه‌ها از بین رفته و الگوریتم کا-میانگین مجدداً اجرا شده است. به‌طور کلی می‌توان نتیجه گرفت که قطعاً با انجام تراکنش‌های جدید، خوشه‌بندی اولیه مشتریان دقت خود را از دست می‌دهد و نیاز به به‌روزرسانی خوشه‌ها وجود دارد. در روش‌های مرسوم می‌توان در بازه‌های زمانی مختلف الگوریتم کا-میانگین را دوباره اجرا کرد تا خوشه‌ها به‌روز شوند اما دست یافتن به خوشه‌هایی که به‌اندازه چشم‌گیری باهم تمایز داشته باشند، زمان‌بر است. روش پیشنهادی در کمتر از ۵٪ ثانیه خوشه‌های اولیه را به‌روز کرده و تنها در صورتی که تمایز بین آن‌ها از بین رود خوشه‌بندی را تکرار می‌کند. از آنجایی که سیستم هوش تجاری در تحلیل کسب‌وکار و اتخاذ تصمیمات حیاتی به مدیریت یاری می‌رساند، و مشتریان کسانی هستند که بر روی سودآوری سازمان تأثیر مستقیم دارند، سرعت عمل در تحلیل وضعیت آن‌ها می‌تواند دقت تصمیمات را افزایش دهد [۳]. به‌علاوه، پویایی که در روش پیشنهادی وجود دارد، میزان دخالت انسان و خطاهای انسانی را کاهش خواهد داد.

۴ بحث و نتیجه‌گیری و کارهای آتی

این پژوهش به‌دنبال ترکیب هوش تجاری تطبیق‌پذیر و بخش‌بندی پویا به‌منظور طراحی سیستمی است که با جمع‌آوری داده از محیط، تحلیل و کاوش آن‌ها، بهترین و مؤثرترین بخش‌بندی در هر بازه زمانی را ارائه دهد. هم‌چنین با بررسی مستمر تغییرات محیطی، این بخش‌بندی را به‌روزرسانی می‌کند تا با تکیه بر آن بتوان بخش‌های مختلف مشتریان را شناسایی کرد، تغییرات آن‌ها در طول زمان را پیگیری کرد و خدمات سفارشی به مشتریان ارائه داد. رویکرد پیشنهادی، پس از خوشه‌بندی مشتریان سازمان، همواره بر رفتارشان نظارت داشته و با مشاهده تغییرات چشم‌گیر در آن‌ها، بخش‌ها را تغییر می‌دهد. در واقع هدف بهبود الگوریتم کا-میانگین است و تلاش شده از اجرای مکرر و زمان‌بر الگوریتم تاحد امکان جلوگیری شود. نتایج به‌دست‌آمده نشان می‌دهند که روش پیشنهادی، رویکردی نوین در بخش‌بندی می‌باشد و با استفاده از آن می‌توان به‌صورت خودکار، داده‌ها را در بازه‌های زمانی مختلف به‌روزرسانی کرد. روش پیشنهادی با در نظر گرفتن بخش‌های مختلف مشتریان، مقادیر فعلی RFM آن‌ها و تغییراتی که با تکرار خرید در این مقادیر ایجاد می‌شود، خوشه‌بندی بهتر و جامع‌تری از مشتریان سازمان به دست می‌دهد که این امر می‌تواند در بهبود عملکرد سیستم هوش تجاری تطبیق‌پذیر مفید واقع شود. با استفاده از این روش، مدیران امکان تحلیل و نظارت دقیق‌تر مشتریان را خواهند داشت. بدین ترتیب، سازمان می‌تواند مشتریانی که باید روی آن‌ها تمرکز بیشتری شود و مشتریانی

داده جدید	زمان تحلیل داده (ثانیه)	زمان اجرای الگوریتم (ثانیه)	زمان اجرای روش پیشنهادی (ثانیه)
۲۰۰	۲۲۴/۴۲	۲۴۴۷/۱۴ (۱۵۵)	۰/۳۵
۳۰۰	۴۹۷/۹۵	۲۰۶۱/۲۵ (۹۱)	۰/۳۵
۴۰۰	۶۲۴/۸۶	۲۴۰۴/۹۱ (۱۴۶)	۰/۳۵
۵۰۰	۷۹۷/۵۷	۲۱۰۵/۸۱ (۱۲۴)	۰/۳۷
۶۰۰	۹۵۷/۵۹	۲۴۲۳/۲ (۲۰۸)	۰/۴ + ۲۹۲۰/۸۸
۷۰۰	۱۱۵۷/۷۷	۲۳۳۶/۰۵ (۳۱)	۰/۴۶
۸۰۰	۱۳۰۴	۵۰۴۹/۲ (۲۹۶)	۰/۴۶
۹۰۰	۱۴۷۵/۶۲	۵۱۴۵/۷۴ (۲۹)	۰/۴۶
۱۰۰۰	۱۶۵۸/۸۲	۳۲۲۱/۹۵ (۱۸۶)	۰/۴۶ + ۱۲۰۲/۷۲
...



شکل ۳. مقایسه زمان لازم برای تحلیل داده‌های جدید، اجرای الگوریتم کا-میانگین و اجرای روش پیشنهادی

در تمامی مراحل اجرای روش پیشنهادی، کیفیت خوشه‌ها بررسی شده و خوشه‌بندی تنها در صورتی تکرار می‌شود که براساس آزمون دانکن این کیفیت از بین رفته باشد. بر اساس روش پیشنهادی این امر تنها ۲۰ درصد مواقع رخ می‌دهد. اختلاف مشاهده شده در شکل ۳ حاکی از آن است که به‌منظور به‌روزرسانی خوشه‌بندی، تا حد امکان باید از اجرای دوباره الگوریتم کا-میانگین مرسوم خودداری شود. زیرا با توجه به ماهیت داده‌ها که در بازه ۱ تا ۵ قرار دارند، (۱) یافتن نقاط اولیه متمایز به‌عنوان مراکز خوشه‌های اولیه به‌منظور اجرای فرآیند خوشه‌بندی و (۲) رسیدن به ۸ خوشه متمایز، امری زمان‌بر محسوب می‌شود و باید این الگوریتم چندین بار اجرا شود. بنابراین بهتر است که هر زمان تغییری در داده‌ها رخ می‌دهد، از روش پیشنهادی استفاده شود که در کمتر از ۵٪ ثانیه تغییر در خوشه‌ها را اعمال می‌کند و تنها زمانی که تمایز بین خوشه‌ها از بین برود، الگوریتم کا-میانگین مرسوم را اجرا می‌کند. (دلیل زمان اجرای بالا در ۵۰ درصد و ۹۰ درصد). با توجه به این که هدف، داشتن خوشه‌های متمایز است، در هر دو حالت، الگوریتم کا-میانگین به‌طور میانگین ۱۲۰ مرتبه اجرا می‌شود (در حالت دوم اگر تمایز بین خوشه‌ها برقرار نباشد، الگوریتم خوشه‌بندی اجرا می‌شود). همان‌طور که در شکل ۱ مشاهده می‌شود، تقریباً در تمامی حالات، استفاده از روش پیشنهادی برای به‌روزرسانی خوشه‌ها بهتر از استفاده از خوشه‌بندی کا-میانگین مرسوم است. لازم به ذکر است که علت تفاوت در زمان‌های اجرای الگوریتم در حالت اول، تلاش برای رسیدن به خوشه‌های متمایز است. به‌عنوان مثال هنگامی که ۱۰۰ تراکنش جدید وارد سیستم شده است، الگوریتم با

اطلاعات دموگرافیک، جغرافیایی، اقتصادی و غیره نیز به این تحلیل اضافه گردد.

از جمله دستاوردهای این روش می‌توان به طراحی کمپین‌های تبلیغاتی هدفمند، ارائه خدمات، پیشنهادات و تخفیف‌های شخصی‌سازی شده، برنامه‌ریزی برای رشد و توسعه محصول جدید، افزایش فروش و سودآوری، افزایش رضایتمندی و وفاداری و در نتیجه کاهش رویگردانی مشتری اشاره کرد. محدودیت اصلی پژوهش عدم وجود سیستم هوش تجاری و انباره داده مناسب برای مطالعه بود که برای رفع محدودیت حاضر، داده‌های موجود در پایگاه‌های داده شرکت مورد مطالعه را یکپارچه کرده و مکعب‌های داده‌ای مورد نیاز را ایجاد کردیم. هم‌چنین این داده‌ها منحصر به درون سازمان بود و شناسایی رفتار مشتری تنها بر اساس همین داده‌ها انجام گرفت. دسترسی به اطلاعات خارج سازمانی درباره هر مشتری (اطلاعات دموگرافیک، موقعیت جغرافیایی و غیره) به‌علاوه داده‌های مربوط به وضعیت اقتصادی و اجتماعی جامعه، می‌تواند دقت تحلیل رفتار آن‌ها را افزایش دهد.

در آخر، اگر امکان اجرای موازی روش پیشنهادی در کنار سیستم فعلی در سازمان مورد مطالعه وجود داشت، قطعاً ارزیابی نتایج و فواید این روش، بهتر و ملموس‌تر بود. هم‌چنین آزمایش نتایج به‌دست آمده از یک سیستم تطبیق‌پذیر نیازمند داده‌های مختلف در دوره‌های زمانی متفاوت است تا بتوان تطبیق‌پذیر بودن سیستم در طول زمان را اثبات کرد. دسترسی به همان مجموعه داده اولیه در بازه‌های زمانی مختلف نیز یکی از محدودیت‌های اصلی این پژوهش است. از سوی دیگر، علی‌رغم تلاش برای پوشش تمامی جنبه‌های سازمانی، انسانی، رفتاری و اجتماعی تأثیرگذار روی بخش‌بندی پویای مشتریان در روش پیشنهادی، ممکن است معیارهای دیگری وجود داشته باشند که علی‌رغم تأثیرگذار بودن در دنیای واقعی، در نظر گرفته نشده باشند.

علاوه بر آن، مطالعات آتی می‌توانند رویکردی را ارائه کنند که بتواند نسخه‌های مختلف RFM (مانند RFM وزن دار، FRAT یا دفعات خرید، تازگی خرید، مقدار و نوع محصول) را روی روش پیشنهادی آزمایش کند. هم‌چنین، اثربخشی روش پیشنهادی می‌تواند برای حوزه‌های کاربردی مختلف مانند بازدیدکنندگان پایگاه وب (RFD)، گراف‌های شبکه‌های اجتماعی (RFR) و RML ارزیابی شود. علاوه‌براین پیشنهاد می‌شود عملکرد الگوریتم پیشنهادی با سایر الگوریتم‌های موجود در زمینه بخش‌بندی پویا از نظر زمان و کیفیت مورد بررسی قرار گرفته و مقایسه شود.

پیاده‌سازی روش پیشنهادی در صنایع مختلف (مانند تامین‌کنندگان خدمات اینترنتی، خطوط هوایی و غیره) نیز می‌تواند در آینده به مرحله اجرا گذاشته شود. هم‌چنین پیشنهاد می‌شود با افزودن قابلیت پیش‌بینی رفتار آینده مشتری را به‌طور خودکار پیش‌بینی کرده و براساس آن در طراحی کمپین‌های تبلیغاتی هدفمند، برنامه‌ریزی‌های

که باید کنار گذاشته شوند را بهتر شناسایی کند و سودآوری سازمان به‌طور قابل‌توجهی بهبود می‌یابد.

از بین پیمان‌های اصلی سیستم هوش تجاری تطبیق‌پذیر، پیمان‌ه تطبیق‌پذیری مورد بررسی قرار گرفت و با توجه به چرخه تطبیق‌پذیری که با نظارت بر محیط درون سازمانی، تغییرات رفتاری مشتریان در طول زمان را تحلیل کرده و با توجه به خوشه‌بندی اولیه، در صورت نیاز، جایگاه مشتریان در سازمان را به‌طور خودکار تغییر می‌دهد. روش پیشنهادی در پیمان‌ه تطبیق‌پذیری سیستم هوش تجاری تطبیق‌پذیر، در زمان کمتر از ۰/۵ ثانیه، داده‌های جدید را بخش‌بندی کرده و خوشه‌های اولیه را به‌روزرسانی می‌کند. با توجه به اجرای این روش روی داده‌های واقعی، مشاهده شد که فرآیند خوشه‌بندی بهینه شده و در مواقعی که زمان، عامل بسیار مهمی است، به‌خوبی عمل می‌کند. هم‌چنین به‌صورت برخط و در هر لحظه از زمان، خوشه‌ها را با توجه به تغییرات محیط داخلی سازمان (رفتار خرید مشتریان) تطبیق می‌دهد. کاهش زمان به‌روزرسانی و تطابق بخش‌های مشتریان در پیمان‌ه تطبیق‌پذیری و جلوگیری از اجرای دوباره الگوریتم خوشه‌بندی (در ۸۰ درصد مواقع) در هر بار تغییر در داده‌ها از مزایای روش پیشنهادی محسوب می‌شود که در پژوهش‌های پیشین به آن اشاره‌ای نشده بود. بنابراین کاربرد این روش در سیستم هوش تجاری که نسبت به زمان و اتخاذ تصمیمات به‌موقع، حساسیت دارد، می‌تواند مفید واقع گردد. به‌منظور اثبات این‌که در یک سیستم هوش تجاری تطبیق‌پذیر، روش‌های داده‌کاوی در پیمان‌ه تطبیق‌پذیری، تصمیم‌گیری سیستم را بهبود می‌دهد و خطاهای پیمان‌ه پیش‌بینی را اصلاح می‌کند تا تصمیماتی بهینه اتخاذ شوند، روش پیشنهادی را روی داده‌های یک سازمان پخش مواد غذایی پیاده‌سازی کردیم. که نتایج حاصل از آن، پویایی و تغییر در خوشه‌بندی در طول زمان را به‌خوبی منعکس می‌کند. ممکن است با تکرار خرید، جایگاه مشتری برای سازمان ثابت بماند و یا دچار تغییر شود. هم‌چنین مشاهده شد که رفتار خرید یک مشتری، هم بر خود شخص و هم بر سایر مشتریان سازمان تأثیر می‌گذارد. به‌طوری‌که ممکن است در یک بازه زمانی طولانی، خرید مجدد انجام ندهد اما جایگاه او در سازمان دستخوش تغییر شود. بنابراین با داشتن دیدگاهی جامع و دقیق از مشتریان در هر لحظه می‌توان در ایجاد مزیت رقابتی و بهبود عملکرد سازمان، بهتر از سایر رقبا عمل کرد.

رویکرد پیشنهادی می‌تواند به مدیران سازمان‌ها در تعیین و توسعه بهتر راهبردهای بازاریابی کمک کند و برای پیش‌بینی رفتار آینده مشتریان مفید واقع شود. به‌علاوه، این روش می‌تواند در توصیه محصول به مشتریان نیز بهتر از سایر روش‌های موجود عمل کند زیرا چندین معیار را باهم در نظر می‌گیرد: بخش‌های مختلف مشتریان، مقادیر RFM فعلی، تحلیل مبتنی بر میانگین مقادیر RFM در هر بخش و رفتار آینده مشتری در سازمان. اما برای افزایش دقت در شناسایی رفتار مشتریان، بهتر است داده‌های برون‌سازمانی مانند

- approaches, research challenges and applications.” *Expert Systems with Applications*, Vol. 40, No. 18, pp. 7267-7279. 2013.
- [16] C. M. Olszak & E. Ziemba. “Approach to building and implementing business intelligence systems.” *Interdisciplinary Journal of Information, Knowledge & Management*, p. 2. 2007.
- [17] J. M. Rubio & B. Crawford. “An approach towards the integration of Adaptive Business Intelligent and Constraint Programming.” In *Information Processing (ISIP), International Symposiums on* (pp. 364-369). IEEE. 2008
- [18] G. R. Gangadharan & S. N. Swami. “Business intelligence systems: design and implementation strategies.” In *Information Technology Interfaces, 2004. 26th International Conference on* (pp. 139-144). IEEE.
- [19] L. Van Dyk & P. Conradie. “Creating business intelligence from course management systems.” *Campus-Wide Information Systems*, Vol. 24, No. 2, pp. 120-133. 2007.
- [20] H. Cheng, Y. C. Lu & C. Sheu. An ontology-based business intelligence application in a financial knowledge management”, system. *Expert Systems with Applications*, Vol. 36, No. 2, pp. 3614-3622. 2009.
- [۲۱] مجید محمدپور و حمید پروین. لگوریتم ژنتیک آشوب‌گونه مبتنی بر حافظه و خوشه‌بندی برای حل مسائل بهینه‌سازی پویا. *مجله مهندسی برق دانشگاه تبریز*، جلد ۴۶، شماره ۳، پاییز ۱۳۹۶.
- [22] Z. K. Görgülü & S. Pickl. “Adaptive Business Intelligence: The Integration of Data Mining and Systems Engineering into an Advanced Decision Support as an Integral Part of the Business Strategy.” In *Business Intelligence and Performance Management* (pp. 43-58). Springer London. 2013.
- [۲۳] سمیرا خدابنده‌لو، محمود زیوری رحمان. ارائه رویکرد جدید بخش‌بندی مشرین براساس تغییر رفتار خرید آن‌ها در طول زمان در حوزه کسب‌وکار الکترونیک. *مجله مدیریت فناوری اطلاعات*، دوره ۹، شماره ۲، صص ۲۷۷-۳۰۰. تابستان ۱۳۹۶.
- [24] A. Singh & G. W. Rumantir. “Two-tiered clustering classification experiments for market segmentation of EFTPOS retailers.” *Australasian Journal of Information Systems*, Vol. 19. 2015.
- [25] D. Birant. Data Mining Using RFM Analysis. In *Knowledge-oriented applications in data mining*. InTech. 2011.
- [26] J. O. Onyuna. “Data Mining Using FRAT-RFM Analysis Approach For Customer Segmentation And Profiling: Case Study Co-operative Bank Of Kenya. 2017.
- [27] A. Parvaneh, M. Tarokh & H. Abbasimehr. “Combining data mining and group decision making in retailer segmentation based on LRFMP variables”. *International Journal of Industrial Engineering & Production Research*, Vol. 25, No. 3, pp. 197-206. 2014.
- [28] Beheshtian-Ardakani, A., Fathian, M., & Gholamian, M. “A novel model for product bundling and direct marketing in e-commerce based on market segmentation”. *Decision Science Letters*, Vol. 7, No.1, pp. 39-54. 2018
- [29] M. Khajvand, K. Zolfaghar, S. Ashoori & S. Alizadeh. “Estimating customer lifetime value based on RFM analysis of customer purchase behavior: Case study”. *Procedia Computer Science*, Vol. 3, pp. 57-63. 2011.
- کوتاه‌مدت، میان‌مدت و بلندمدت، توسعه محصولات و غیره راه‌کارهای مفید ارائه شود.
- مراجع**
- [1] J. Nenortaitė & R. Butleris. “Improving business rules management through the application of adaptive business intelligence technique.” *Information Technology and Control*, Vol. 38, No. 1. 2009.
- [2] Muntean, M., Bologa, A. R., Bologa, R., & Florea, A. “The use of multidimensional models to increase the efficiency of management support systems. *IJM3AS*, 8(5), 1334-1344. 2011.
- [3] C. M. Olszak, E. Ziemba & A. Koochang. Business Intelligence Systems in the Holistic Infrastructure Development Supporting Decision-Making in Organisations. *Interdisciplinary Journal of Information, Knowledge & Management*, Vol. 1. 2006.
- [4] Z. Michalewicz, M. Schmidt, M. Michalewicz & C. Chiriac. *Adaptive business intelligence*. Springer Science & Business Media. 2006.
- [5] T. H. Davenport & J. G. Harris. The architecture of business intelligence”. *Competing on analytics: The new science of winning*. 2007. [Online], October, 2012 (<http://www.studymode.com/essays/The-Architecture-Of-Business-Intelligence-1182020.html>).
- [6] W. Bonney. “Applicability of business intelligence in electronic health record.” *Procedia-Social and Behavioral Sciences*, No. 73, pp. 257-262. 2013.
- [7] T. Bäck. Adaptive business intelligence based on evolution strategies: some application examples of self-adaptive software. *Information Sciences*, Vol. 148, No. 1, pp. 113-121. 2002.
- [8] Kh. Sumaiya and D. R. Kalbande. *Adaptive Business Intelligence model for Cross Functional Integration for Manufacturing Industry*. International Conference in Recent Trends in Information Technology and Computer Science (ICRTITCS), Proceedings published in International Journal of Computer Applications (IJCA). pp. 7-11. 2012.
- [9] Z. Michalewicz, M. Schmidt, M. Michalewicz & C. Chiriac. “Adaptive business intelligence: three case studies.” *Evolutionary computation in dynamic and uncertain environments*, pp. 179-196. 2007.
- [10] R. S. Wu & P. H. Chou. Customer segmentation of multiple category data in e-commerce using a soft-clustering approach. *Electronic Commerce Research and Applications*, Vol. 1, No. 3, pp. 331-341. 2011.
- [۱۱] سیامک عبدالله زاده، محمدعلی بالافر و لیلی محمدخانی. استفاده از خوشه‌بندی و مدل مارکوف جهت پیش‌بینی درخواست آی کاربر در وب. *مجله مهندسی برق دانشگاه تبریز*، جلد ۴۵، شماره ۳، پاییز ۱۳۹۴.
- [12] C. H. Cheng, & Y. S. Chen. “Classifying the segmentation of customer value via RFM model and RS theory”. *Expert systems with applications*, Vol. 36, No. 3, PP. 4176-4184. 2009.
- [13] Liang, Y. H. “Integration of data mining technologies to analyze customer value for the automotive maintenance industry”. *Expert systems with Applications*, Vol. 37, No. 12, pp. 7489-7496. 2010
- [14] M. Böttcher, M. D. Spott, D. Nauck & R. Kruse. “Mining changing customer segments in dynamic markets.” *Expert systems with Applications*, Vol. 36, No. 1, pp. 155-164. 2009.
- [15] F. D. Macías-Escrivá, R. Haber, R. Del Toro & V. Hernandez. “Self-adaptive systems: A survey of current

- [36] S. M. S. Hosseini, A. Maleki & M. R. Gholamian. "Cluster analysis using data mining approach to develop CRM methodology to assess the customer loyalty." *Expert Systems with Applications*, Vol. 37, No. 7, pp. 5259-5264. 2010.
- [37] R. Gove. *Using the elbow method to determine the optimal number of clusters for k-means clustering*. Robert Gove's Block. [Online], December 3, 2015 (<https://bl.ocks.org/rpgove/0060ff3b656618e9136b>).
- [38] Charrad, M., Ghazzali, N., Boiteau, V., Niknafs, A., & Charrad, M. M. Package 'NbClust'. *J. Stat. Soft*, 61, 1-36. 2014.
- [39] Klonimus. *Duncan's new multiple range test*. Wikipedia. [Online], August, 2005 (https://en.wikipedia.org/wiki/Duncan%27s_new_multiple_range_test).
- [40] S. Chakraborty, N. K. Nagwani & L. Dey. "Performance comparison of incremental k-means and incremental dbSCAN algorithms". 2014. *arXiv preprint arXiv:1406.4751*.
- [41] S. Chakraborty & N. K. Nagwani. "Analysis and study of incremental k-means clustering algorithm". *High performance architecture and grid computing*, pp. 338-341. 2011.
- [30] S. Khan, & D. R. Kalbande (2013). "Adaptive Business Intelligence model for Cross Functional Integration for Manufacturing Industry." *International Journal of Computer Applications*, Vol. 2013, pp. 7-11. 2013.
- [31] J. Xiao, L. Xie, C. He & X. Jiang. "Dynamic classifier ensemble model for customer classification with imbalanced class distribution." *Expert Systems with Applications*, Vol. 39, No. 3, pp. 3668-3675. 2012.
- [32] H. M. Cannon & A. Yaprak. "A dynamic framework for understanding cross-national segmentation". *International Marketing Review*, Vol. 28, No. 3, pp. 229-243. 2011.
- [33] D. Arthur & S. Vassilvitskii. "k-means++: The advantages of careful seeding." In *Proceedings of the eighteenth annual ACM-SIAM symposium on Discrete algorithms (pp. 1027-1035)*. Society for Industrial and Applied Mathematics. 2007, January.
- [34] H. Jopia. "R Package 'smbinning': Optimal Binning for Scoring Modeling". Daily news about using open source R for big data analysis, predictive modeling, data science and visualization. [Online], March 24, 2015 (<http://blog.revolutionanalytics.com/2015/03/r-package-smbinning-optimal-binning-for-scoring-modeling.html>).
- [35] D. D. Nimbalkar & P. Shah. "Data mining using RFM Analysis." *International Journal of Scientific & Engineering Research (IJSRE)*, Vol. 4, No. 12, pp. 940-943. 2013.

15. Khajvand
16. S. Q. Moghaddam
17. Böttcher
18. Khan,
19. Kalbande
20. Nenortaitė
21. Rubio
22. Crawford
23. Görgülü
24. Pickl
25. IT-Based Decision Support
26. Data-centric
27. Systems engineering
28. System of Systems
29. R (RStudio)
30. Elbow Method

زیر نویس‌ها:

1. Extract, Transform, Load
2. Data Warehouse
3. Data Mart
4. Online Analytical Processing
5. Online Transaction Processing (OLAP)
6. Data Mining
7. Singh
8. Rumantir
9. Electronic Funds Transfer at Point of Sale (EFTPOS)
10. Birant
11. Onyuna
12. Parvaneh
13. Cheng
14. Chen.