

Presenting an Improved Lrfm Model for Bank Customer Clustering Based on the Combination of Particle Swarm Algorithm and K-Means Clustering

- Moahmmad Kazemi**  Phd Student, Department of Industrial Management, Central Tehran Branch, Islamic Azad University, Tehran.iran
- Mohammad Ali Keramati** * Associate professor, Department of Industrial Management, Keramati Central Tehran Branch, Islamic Azad University, Tehran.iran
- Mehrزد Minoovie**  Assistant professor, Department of Industrial Management, Central Tehran Branch, Islamic Azad University, Tehran.iran

Abstract

The effort of this article is to solve one of the main problems in the field of banking, which is closely related to the field of information technology. The combination of the management discussion of this issue with the field of information technology will be one of the important topics in the field of information technology management. The main purpose of this article is the clustering of bank customers. At first, all customer characteristics were extracted from the bank's database, which was randomly extracted for 900,000 customers and will be provided as input to the proposed method of this article. All the characteristics of these customers were extracted and 10 characteristics (except four characteristics of the LRFM method) were listed using the opinions of experts. The proposed method should be able to choose among these 10 features for customer clustering that results in more resolution in clustering. This makes more suitable features to be placed next to the four features of LRFM and improve the performance of LRFM. Due to the high number of variations in this problem, it is not possible to do it manually and the proposed method tries to provide a separate pattern for

* Corresponding Author: mohammadalikeramati@yahoo.com

How to Cite: Kazemi, M., Keramati, M. A., Minoovie, M. (2024). Presenting an Improved Lrfm Model for Bank Customer Clustering Based on the Combination of Particle Swarm Algorithm and K-Means Clustering, *Journal of Business Intelligence Management Studies*, 12(48), 197-222. DOI: 10.22054/ims.2023.75014.2364

clustering for the customers of each bank by examining different situations. Also, the problem of choosing the right value for the number of clusters in the K-means method is solved by the method proposed in this article. The results show that it is better than the basic RFM and LRFM methods.

1. Introduction

Today, the Achilles heel of all customer-oriented businesses is customer satisfaction and providing services tailored to each customer's situation. This issue has gone so far that regardless of customer satisfaction, any organization will face failure (Otto et al., 2019). One of the main current challenges for customer-oriented organizations is understanding the differences and ranking customers in order to optimally allocate resources. This issue is very important in managing the correct relationship with the customer. Banks are one of the main customer-oriented institutions in the country (Morzdashti et al., 2022). The bank does not do any proper clustering to know its customers and plan future goals. More precisely, it does not have information about the total number of customers and their distribution. Because of this, more time and money is wasted. As far as the research of this article has followed; The clustering that currently exists for customers does not have the necessary dynamics and people are clustered based on some characteristics such as transaction amounts, occupation or other general characteristics.

LRFM model is a method used to cluster customers in customer relationship management. In this model, customers are clustered based on four characteristics of customer relationship, novelty of exchange, number of times of exchange and monetary value exchanged. In fact, the customer relationship length has been added to the RFM model and created the LRFM model. Because, the RFM model was not able to identify loyal customers (Moslehi et al., 2013).

In the proposed model of this article, an attempt will be made to provide a dynamic method for using variables with the LRFM method to provide the possibility of implementing different clusters depending on the time of use. This issue will lead to more compliance of the proposed clustering method with reality.

Research Question(s)

1. What methodology is used to follow the process of presenting the proposed model?

2. What features can be placed next to the LRFM model to provide appropriate results?
3. What methodology is used to follow the process of presenting the proposed model?
4. What features can be placed next to the LRFM model to provide appropriate results?
5. What will be the structure of particle swarm algorithm?
6. What similarity measure or clustering method would be suitable for customers?
7. How can the LRFM model be improved by the particle swarm algorithm and the creation of different clusters based on the K-means method?

2. Literature Review

Shrahi and Ali Qoli have implemented a clustering method for the customers of one of Sepeh Bank branches in Tehran (Shrahi and Ali Qoli, 2015). This model is based on K-means clustering algorithm. In this method, an attempt has been made to identify sixty companies loyal to the bank from among all legal customers. However, the K-means algorithm has some problems (Bagatini et al., 2019, Santini, 2016):

- 1) Determine the optimal value for the number of clusters.
- 2) The initial points that are chosen randomly at the beginning of the algorithm have a great impact on the final result.
- 3) The order of data entry and their review is effective in the final result.

Ayoubi has tried to cluster bank customers using Kohonen neural networks (Ayoubi, 2016). In this method, the training of a neural network is done using the training data, and after that it is possible to cluster the new customer.

Yousefizad and Sorayai have also used the RFM model to cluster customers in order to design a model for providing services to customers, which consists of two stages (Yousefizad and Sorayai, 2017).

suggested method:

In this section, the proposed method of the article is described in full detail.

3. Methodology

In this part, how to improve the LRFM method using the combination of particle swarm algorithm and K-means method is described. All the steps of particle swarm algorithm are followed and its functions and parameters are specified. The steps of the proposed method will be as follows:

A. Initialization: The schematic of the initial population matrix will be as shown in Figure (2). This matrix consists of two parts. The first part has one element that tries to suggest the number of clusters using the K-means method, and the second part will have 10 binary elements.

B. Calculating the fitness of each particle: Using the fitness function, the fitness level is determined for each particle present in the population. This fitness level is based on clustering using the K-means method. The appropriateness of the clustering done is measured based on the intraclass variance criterion, which corresponds to the image of the fitness of each particle (Ahmar et al., 2018).

C. Update of particle values: Using two parameters, local optimum (LBEST) and global optimum (GBEST), the values present in the particles can be updated. By LBEST, we mean the best value that the I-th particle has reached so far (the best-fit value for the I-th particle). Also, GBEST means the value that has the best fit until T iterations. These two values are used to update the values of other particles.

4. Conclusion

This article tries to provide a dynamic method for clustering bank customers in order to improve their service. The LRFM method has four important features in the field of banking, but its problem is lack of dynamics. More precisely, it is possible that other characteristics such as financial, occupational, or daily transaction characteristics can be added to the four LRFM characteristics and improve the performance of this method. Among all the features that can be placed next to the four features of LRFM; Depending on the customer's data, the appropriate features should be selected. This choice is the responsibility of the particle swarm algorithm. This algorithm tries to put appropriate features along with the four LRFM features depending on the data conditions and customer information to get a better result in clustering. Also, because this algorithm method

K-means helps in finding the number of clusters.

It is also possible to replace the particle swarm with other meta-heuristic methods and compare its results with the results in the article.

Keywords: Relationship Management with Bank Customers, Clustering, RFM model, LRFM Model, Particle Swarm Algorithm, K-Means Method.





ارائه‌ی مدل بهبود یافته‌ی LRFM به جهت خوشه‌بندی مشتریان بانک بر مبنای ترکیب الگوریتم ازدحام ذرات و خوشه‌بندی K- میانگین

دانشجوی دکتری مدیریت فناوری اطلاعات، گروه مدیریت صنعتی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

محمد کاظمی

دانشیار، گروه مدیریت صنعتی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

محمدعلی کرامتی

استادیار، گروه مدیریت صنعتی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

مهرزاد مینوئی

چکیده

تلاش این مقاله در جهت حل یکی از مشکلات اصلی حوزه‌ی بانکداری می‌باشد که ارتباط تنگاتنگی با حوزه‌ی فناوری اطلاعات دارد. ترکیب بحث مدیریتی این موضوع با حیطه‌ی فناوری اطلاعات یکی از مباحث مهم حوزه‌ی مدیریت فناوری اطلاعات را رقم خواهد زد. هدف اساسی این مقاله، خوشه‌بندی مشتریان بانک است. در ابتدا، تمامی ویژگی‌های مشتریان از پایگاه داده‌ی بانک استخراج گردیده که استخراج برای ۹۰۰ هزار مشتری و به‌طور تصادفی انجام گرفته است و به‌عنوان ورودی در اختیار روش پیشنهادی این مقاله قرار خواهد گرفت. تمامی ویژگی‌های این مشتریان استخراج شد و با استفاده از نظرات کارشناسان ۱۰ ویژگی (به‌جز چهار ویژگی روش LRFM) لیست گردید. روش پیشنهادی باید از بین این ۱۰ ویژگی بتواند ویژگی‌هایی را برای خوشه‌بندی مشتریان انتخاب کند که تفکیک پذیری بیش‌تری را در خوشه‌بندی نتیجه دهد. این موضوع باعث می‌شود ویژگی‌های مناسب‌تر در کنار چهار ویژگی LRFM قرار گیرند و کارایی LRFM را بهبود بخشند. با توجه به تعداد بالای حالات این مسئله، امکان انجام دستی آن وجود ندارد و روش پیشنهادی سعی می‌کند با بررسی حالات مختلف، برای مشتریان هر بانک الگوی

مقاله حاضر برگرفته از رساله دکتری رشته مدیریت فناوری اطلاعات، دانشگاه آزاد اسلامی واحد تهران مرکز می‌باشد.

* نویسنده مسئول: mohammadalikeramati@yahoo.com

ارائه‌ی مدل بهبودیافته‌ی LRFM به جهت خوشه‌بندی مشتریان بانک...؛ کاظمی و همکاران | ۲۰۳

مجزایی را برای خوشه‌بندی ارائه دهد. همچنین، مشکل انتخاب مقدار مناسب برای تعداد خوشه‌ها در روش K-میانگین به وسیله‌ی روش پیشنهادی این مقاله برطرف می‌گردد. نتایج حاصل، نشان از بهبود آن نسبت به روش RFM و LRFM پایه دارد.

کلیدواژه‌ها: مدیریت ارتباط با مشتریان بانک، خوشه‌بندی، مدل RFM، مدل LRFM، الگوریتم ازدحام ذرات، روش K-میانگین.



مقدمه

امروزه پاشنه آشیل تمامی کسب و کارهایی که با محوریت مشتری انجام می‌گیرد رضایت‌مندی مشتری و ارائه‌ی خدمات متناسب با وضعیت هر مشتری به او است. این موضوع تا آنجا پیش رفته است که بدون در نظر گرفتن رضایت‌مندی مشتری، هر سازمانی با شکست روبرو خواهد شد (Otto et al, 2019). حضور مشتری علاوه بر سود مالی که به همراه دارد؛ امکان ایجاد رقابت در حوزه‌های مختلف را برای سازمان فراهم می‌کند؛ زیرا، توانمندی اجتماعی سازمان را علاوه بر توانمندی مالی افزایش می‌دهد. به همین سبب، در سال‌های اخیر، سفارشی‌سازی^۱ خدمات به مشتریان به شدت مورد توجه قرار گرفته است و تلاش برای تکریم ارباب رجوع به اوج خود در سال‌های آتی خواهد رسید (Chandra et al, 2022).

از اصلی‌ترین چالش‌های حال حاضر برای سازمان‌های مشتری محور، درک تفاوت‌ها و رتبه‌بندی مشتریان به جهت تخصیص بهینه‌ی منابع است. این موضوع در مدیریت ارتباط صحیح با مشتری بسیار حائز اهمیت می‌باشد. از اصلی‌ترین نهادهای مشتری محور کشور بانک‌ها می‌باشند (Marzdashit et al, 2022). بانک برای شناخت مشتریان خود و برنامه‌ریزی اهداف آینده، هیچ خوشه‌بندی^۲ مناسبی انجام نمی‌دهد. به عبارت دقیق‌تر، اطلاعاتی در مورد کلیت مشتریان و پخشش آن‌ها ندارد. به همین سبب زمان و هزینه‌ی زیادتری تلف می‌شود. تا جایی که تحقیقات این مقاله پیگیری کرده است؛ خوشه‌بندی‌هایی هم که در حال حاضر برای مشتریان وجود دارد از پویایی لازم برخوردار نیست و افراد بر اساس برخی ویژگی‌ها مانند مبالغ تراکنش‌ها، شغل یا ویژگی‌های کلی دیگر خوشه‌بندی شده‌اند.

مدل LRFM روشی است که برای خوشه‌بندی مشتریان در مدیریت ارتباط با مشتری استفاده می‌شود. در این مدل، مشتریان بر اساس چهار ویژگی ارتباط مشتری^۳، تازگی

-
1. Personalization.
 2. Clustering.
 3. Length.

مبادله^۱، تعداد دفعات مبادله^۲ و ارزش پولی مبادله شده^۳ خوشه‌بندی می‌شوند. در حقیقت طول ارتباط مشتری به مدل RFM اضافه و مدل LRFM را ایجاد کرده است؛ زیرا، مدل RFM توان مشخص کردن مشتریان وفادار را نداشت (مصلحی و همکاران، ۱۳۹۳).

این مدل برای خوشه‌بندی مشتریان بسیار مورد استفاده قرار می‌گیرد و تحقیقات علمی و عملی زیادی نیز بر مبنای آن انجام گرفته است. با این حال یکی از مهم‌ترین مشکلاتی که هنوز هر دو مدل RFM و LRFM دارند آن است که فقط از تعداد محدودی از متغیرهای برگزیده استفاده می‌کنند (خدابنده لو و همکاران، ۱۳۹۴). در حالی که بسیاری از ویژگی‌های مالی، روزمره و شغلی بر احتمال پاسخ مشتری تأثیر دارد. در صورتی که بتوان الگوریتمی پویا ارائه داد که خوشه‌بندی مشتریان بر مبنای هوش مصنوعی انجام شود و متغیرهای بیشتری را در مدل LRFM درگیر کند؛ می‌توان تمامی حالاتی که به ذهن انسان نمی‌رسد را نیز در خوشه‌بندی مورد بررسی قرار داد. این موضوع باعث می‌شود خوشه‌بندی انجام شده از قابلیت اعتماد بالاتری از طرف سازمان برخوردار گردد (Sharahi & Aligholi, 2015).

در همین راستا هر چه بتوان خدمات را به جامعه هدف دقیق‌تری ارائه نمود، متعاقباً در هزینه و زمان نیز صرفه‌جویی می‌گردد. بر مبنای این هدف؛ سؤالات مهم نیز در این بخش مطرح می‌گردند.

- چه متدولوژی برای پیگیری روند ارائه مدل پیشنهادی استفاده می‌گردد؟
- چه ویژگی‌هایی می‌تواند در کنار مدل LRFM قرار گیرد تا نتایج مناسبی را ارائه نمایند؟
- چه متدولوژی برای پیگیری روند ارائه مدل پیشنهادی استفاده می‌گردد؟
- چه ویژگی‌هایی می‌تواند در کنار مدل LRFM قرار گیرد تا نتایج مناسبی را ارائه نمایند؟

1. Recency.
2. Frequency.
3. Monetary.

- ساختار الگوریتم ازدحام ذرات چگونه خواهد بود؟
- چه معیار شباهت یا روش خوشه‌بندی برای مشتریان مناسب خواهد بود؟
- چگونه می‌توان مدل LRFM را به وسیله الگوریتم ازدحام ذرات و ایجاد خوشه‌های مختلف بر مبنای روش K-میانگین ۱ بهبود داد؟

در مدل پیشنهادی این مقاله تلاش خواهد شد روشی پویا به جهت به کارگیری متغیرهای با روش LRFM ارائه گردد تا امکان اجرای خوشه‌بندی‌های مختلفی بسته به زمان استفاده مهیا شود. این موضوع به انطباق بیش‌تر روش خوشه‌بندی پیشنهادی با واقعیت خواهد انجامید. لذا برای بالابردن کارایی خوشه‌بندی، می‌باید مشتریان را بر اساس ویژگی‌های مناسب گروه‌بندی کرد. لیکن، انتخاب ویژگی‌های کارا از بین تمامی حالات ممکن بسیار زمان‌بر است.

لذا این ویژگی‌ها در کنار سایر ویژگی‌های مشتری قرار خواهد گرفت و با استفاده از پویایی مبتنی بر الگوریتم ازدحام ذرات ۲ به ایجاد خوشه‌های مختلف بر مبنای روش K- میانگین ۳ پرداخته می‌شود. روش پیشنهادی سعی در انجام این امر دارد. بخش دو مقاله به شرح تلاش‌های پیشین این حوزه اختصاص دارد. در بخش سوم به روش پیشنهادی این مقاله پرداخته و جزئیات روش بیان می‌شود. بخش‌های چهار و پنج مقاله به ترتیب، نتایج به‌دست آمده و نتیجه‌گیری را ارائه می‌کند.

پیشینه تحقیق

در این بخش به تلاش‌های مرتبط سایر محققان که در راستای مسئله‌ی این مقاله بوده است پرداخته و نقاط ضعف و قوت هر کدام به اختصار بیان می‌گردد. شراحی و علی‌قلی یکی روش خوشه‌بندی را برای مشتریان یکی از شعب بانک سپه تهران پیاده‌سازی کرده‌اند (Sharahi & Aligholi, 2015). این مدل بر مبنای الگوریتم خوشه‌بندی K-میانگین

-
1. K-means.
 2. Particle Swarm Optimization algorithm.
 3. K-means.

می‌باشد. در این روش تلاش شده است تا شصت شرکت وفادار به بانک از بین تمامی مشتریان حقوقی شناسایی شوند. لیکن، الگوریتم K-میانگین دارای مشکلاتی است (Bagattini et al, 2019):

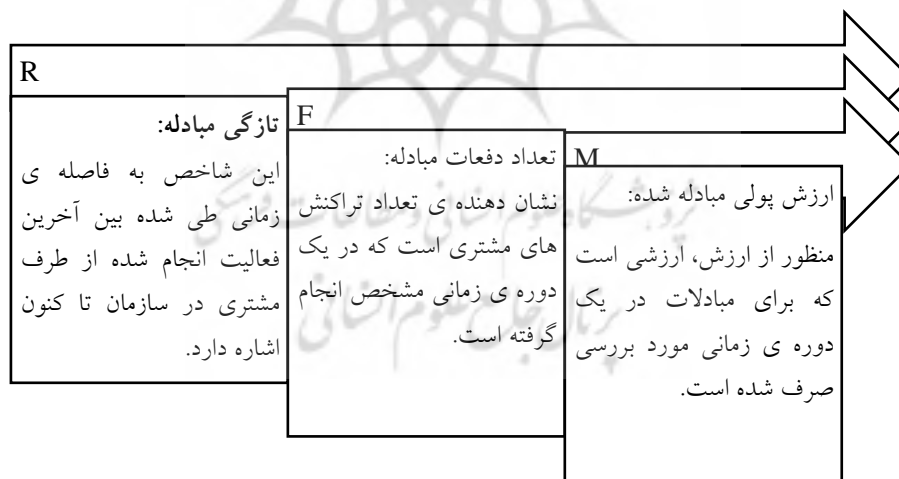
(۱) مشخص کردن مقدار بهینه برای تعداد خوشه‌ها.

(۲) نقاط اولیه که به صورت تصادفی در شروع الگوریتم اختیار می‌شود، در نتیجه‌ی پایانی تأثیر زیادی دارد.

(۳) ترتیب ورود داده‌ها و بررسی آن‌ها در نتیجه‌ی پایانی تأثیرگذار است.

با ترکیب ارائه‌شده در این مقاله، مشکلات فوق برطرف خواهد شد و جدا از بهبود روش LRFM، به بهبود عملکرد روش K-میانگین نیز منجر می‌گردد. مدل RFM یک مدل معتبر در حوزه‌ی ارتباط با مشتری است که برای اولین بار توسط هاگز^۱ در سال ۱۹۹۴ ارائه گردید (Hughes, 1996). این مدل بر پایه‌ی سه شاخص استوار است که در شکل (۱) آمده است.

شکل ۱. مدل RFM



نظرات متفاوتی در مورد وزن هر کدام از این شاخص‌ها وجود دارد (یوسفی زاد و ثریایی،

1. Hughes.

(۱۳۹۷). لیکن، هاگز به عنوان پیشنهاددهنده‌ی این مدل اهمیت آن‌ها را یکسان می‌داند (Hughes, 1996). در صورتی که لازم باشد به وسیله‌ی مدل RFM به خوشه‌بندی مشتریان پرداخته شود باید مقدار هر کدام از این شاخص‌ها برای هر مشتری محاسبه گردد تا بتوان مشتریان را بر اساس مقادیر این سه شاخص خوشه‌بندی کرد.

یوبی تلاش کرده است با استفاده از شبکه‌های عصبی کوهونن^۱، به خوشه‌بندی مشتریان بانک پردازد (Ayoubi, 2016). در این روش، آموزش یک شبکه‌ی عصبی با استفاده از داده‌های آموزشی انجام می‌گیرد و پس از آن امکان خوشه‌بندی مشتری جدید فراهم می‌گردد. در پایگاه داده‌ی این مقاله، ۵۶۰۰۰ مشتری و اطلاعات آن‌ها وجود دارد که از بانک توسعه‌ی تعاون اخذ گردیده است. در این روش، ابتدا تعداد مناسب خوشه‌ها و تعدادی از اعضای داخل آن‌ها به وسیله‌ی متخصص مشخص گردیده و سپس، شبکه‌ی عصبی به منظور خوشه‌بندی مشتریان استفاده پیاده‌سازی شده است. ویژگی‌های استفاده‌شده در این شبکه‌ی عصبی تازگی مبادله، تعداد دفعات مبادله و ارزش پولی مبادله شده هستند (ویژگی‌های مدل RFM) که هر کدام وزن مختلفی دارند. این وزن‌ها توسط شبکه‌ی عصبی تولید شده است و حاکی از اهمیت هر کدام از این ویژگی‌ها در خوشه‌بندی مشتریان می‌باشد. به همین سبب به این روش WRFM گفته می‌شود.

یوسفی زاد و ثریایی نیز از مدل RFM برای خوشه‌بندی مشتریان به جهت طراحی الگویی برای ارائه‌ی خدمات به مشتریان بهره برده‌اند که از دو مرحله تشکیل شده است (یوسفی زاد و ثریایی، ۱۳۹۷). مرحله‌ی اول جهت تعیین وزن شاخص‌های R، F، M و R بوده که ۱۸ نفر از خبرگان بانک ملت مازندران هستند و مرحله‌ی دوم، خوشه‌بندی مشتریان بر اساس مدل RFM و با استفاده از داده‌های اسنادی بانک مشتریان، اصناف و فروشگاه‌هایی که دارای POS بانکی هستند بوده است. روش تجزیه و تحلیل داده‌ها تکنیک تحلیل سلسله مراتبی فازی، تکنیک آنتروپی، روش K-میانگین و روش DBSCAN می‌باشد. طبق نتایج، وزن هر کدام از شاخص‌های R، F و M با استفاده از فرآیند تحلیل سلسله مراتبی و آنتروپی

1. Kohonen Neural Network.

به دست آمده و در نهایت وزن شاخص‌ها به صورت ترکیبی برآورد گردیده است. وزن شاخص‌های R، F و M به ترتیب برابر با ۰/۱۳۳۰، ۰/۲۶۷۲ و ۰/۵۹۹۸ بوده‌اند. این روش نیز سعی دارد از بین این سه شاخص، مهم‌ترین را مشخص کند و وزن بالاتری را به آن دهد. مشخص است که روش‌های خوشه‌بندی ذکر شده بر روی داده‌ها اعمال شده‌اند و هیچ تغییر یا انطباقی با داده‌های مختلف یا ویژگی‌های مختلف مشتریان پیدا نمی‌کند.

در نظر بگیرید؛ فردی با نام A به تازگی ارزش مالی بالایی را برای بانک B ایجاد کرده است. همچنین، فرد A توانسته است در یک مدت زمان کوتاه و معین، تناوب خریدی بیش از متوسط تناوب خرید در بین مشتریان بانک B ایجاد کند. این موضوع باعث می‌شود مشتری A به عنوان یک مشتری با ارزش شناخته شود. در حالی که عامل ارتباط مشتری با سازمان در نظر گرفته نشده است و مشتری A توانسته است با این کار خود را در قامت یک مشتری وفادار قرار دهد که این طور نیست؛ بنابراین، مدت زمان ارتباط یک مشتری با سازمان می‌تواند تأثیر مستقیمی بر سودآوری و تأثیرگذاری یک مشتری بر سازمان داشته باشد. این موضوع باعث ایجاد LRFM شده است.

مدل LRFM روشی است که برای خوشه‌بندی مشتریان در مدیریت ارتباط با مشتری استفاده می‌شود. در حقیقت طول ارتباط مشتری به مدل RFM اضافه و مدل LRFM را ایجاد کرده است؛ زیرا، مدل RFM توان مشخص کردن مشتریان وفادار را نداشت (مصلحی و همکاران، ۱۳۹۳). روش پیشنهادی در رسیدن به خوشه‌بندی مناسب مشتریان بانک، با استفاده از ویژگی‌هایی که الگوریتم ازدحام ذرات در کنار چهار ویژگی روش LRFM قرار می‌دهد گام برمی‌دارد. به عبارت دقیق‌تر، ممکن است بر مبنای داده‌های مشتریان هر بانک و شرایط حاضر در هر جامعه، بتوان ویژگی‌های خاصی را در کنار چهار ویژگی LRFM قرار داد و برای خوشه‌بندی مشتریان بانک اقدام دقیق‌تری کرد. به همین سبب، ویژگی‌هایی که برای جامعه مورد بررسی این مقاله مناسب هستند به وسیله‌ی روش ازدحام ذرات انتخاب و در کنار چهار ویژگی LRFM قرار می‌گیرد. سپس، از روش K- میانگین برای خوشه‌بندی مشتریان استفاده می‌گردد. در کنار فراهم آوردن ویژگی‌های

مفید برای الگوریتم K-میانگین، مشکل مشخص نبودن تعداد خوشه‌ها نیز توسط الگوریتم ازدحام ذرات برای الگوریتم K-میانگین برطرف می‌گردد؛ بنابراین، کارایی این الگوریتم نیز در خوشه‌بندی افزایش می‌یابد.

روش پیشنهادی

در این بخش، روش پیشنهادی مقاله با جزئیات کامل و به تفصیل شرح داده می‌شود.

جمع‌آوری داده‌ها

داده‌های این مقاله برابر با P رکورد می‌باشد که از تاریخ ۱۳۹۹/۱/۱ تا ۱۳۹۹/۲/۳۱ جمع‌آوری شده است. برای جمع‌آوری این داده‌ها هیچ‌گونه پیش‌فرضی در نظر گرفته نشده است و انتخاب برای تمامی مشتریان، از احتمال یکسانی برخوردار است. لازم به ذکر است که هیچ رکوردی دارای اطلاعات هویتی، خصوصی یا محرمانه نبوده و اخلاق حرفه‌ای در جمع‌آوری داده‌ها رعایت شده است. تعداد ویژگی‌های هر رکورد برابر با ۱۰ مورد بوده (به‌غیر از ویژگی‌های LRFM) که لیست آن‌ها در جدول (۱) آمده است. تمامی داده‌ها در مرحله اول تمیز^۱ و ناسازگاری‌های^۲ احتمالی رفع می‌گردد. داده‌ی گمشده‌ای^۳ در پایگاه داده وجود نداشت. لیکن در صورت وجود، ابتدا باید تدبیری در مورد جانهای^۴ آن‌ها اندیشیده شود.

روش اجرایی

در این قسمت چگونگی بهبود روش LRFM با استفاده از ترکیب الگوریتم ازدحام ذرات و روش K-میانگین شرح داده می‌شود. تمامی قدم‌های الگوریتم ازدحام ذرات در ادامه آمده و توابع و پارامترهای آن مشخص می‌گردد. گام‌های روش پیشنهادی به‌صورت زیر

1. Data Cleaning.
2. Inconsistency.
3. Missing Value.
4. Imputation.

خواهد بود:

A. مقداردهی اولیه: شماتیک ماتریس جمعیت اولیه به صورت آمده در شکل (۲) خواهد بود. این ماتریس از دو قسمت تشکیل شده است. قسمت اول دارای یک عنصر است که سعی در پیشنهاد تعداد خوشه‌ها به روش K-میانگین دارد و قسمت دوم، دارای ۱۰ عنصر باینری خواهد بود. اگر عنصر I ام قسمت باینری برابر با یک باشد به معنای در نظر گرفتن ویژگی I ام جدول (۱) در کنار ویژگی‌های LRFM خواهد بود. همچنین، در صورتی که عنصر I ام قسمت باینری برابر با صفر باشد به معنای در نظر نگرفتن ویژگی I ام جدول (۱) در کنار ویژگی‌های LRFM خواهد بود. تعداد ذرات (سطر) های در نظر گرفته شده برای جمعیت اولیه M مورد می‌باشد که در تمامی تکرارهای الگوریتم ازدحام ذرات ثابت خواهد بود؛ بنابراین، ماتریس جمعیت دارای ۱۱ ستون و M سطر می‌باشد. بازه‌ای که برای تعداد خوشه‌ها در نظر گرفته شده است از L تا B خوشه بوده و حتماً در بین M ذره، اعداد تکراری برای K وجود خواهد داشت.

جدول ۱. بازه‌ی تاریخی اخذ و محاسبه‌ی ویژگی‌های مشتریان.

ویژگی	بازه‌ی تاریخی اخذ و محاسبه
طول ارتباط مشتری با بانک صادرات (L)	تا تاریخ ۱۳۹۹/۲/۳۱
تازگی مبادله (R)	۱۳۹۹/۱/۱ تا ۱۳۹۹/۲/۳۱
تعداد دفعات مبادله (F)	۱۳۹۹/۱/۱ تا ۱۳۹۹/۲/۳۱
ارزش پولی مبادله شده (M)	۱۳۹۹/۱/۱ تا ۱۳۹۹/۲/۳۱
کد نوع عملیات	۱۳۹۹/۱/۱ تا ۱۳۹۹/۲/۳۱
کد پایانه	۱۳۹۹/۱/۱ تا ۱۳۹۹/۲/۳۱
بانک میزبان	۱۳۹۹/۱/۱ تا ۱۳۹۹/۲/۳۱
تاریخ انجام تراکنش	۱۳۹۹/۱/۱ تا ۱۳۹۹/۲/۳۱
مبلغ تسهیلات دریافتی از بانک صادرات	تا تاریخ ۱۳۹۹/۲/۳۱
میزان تسهیلات معوق از بانک صادرات	تا تاریخ ۱۳۹۹/۲/۳۱
ارزش انتقال وجه شتابی	۱۳۹۹/۱/۱ تا ۱۳۹۹/۲/۳۱
میانگین تراکنش ماهیانه	تا تاریخ ۱۳۹۹/۲/۳۱
مبلغ کل سپرده‌ی مشتری در بانک صادرات	تا تاریخ ۱۳۹۹/۲/۳۱
مبلغ کل چک‌های وصول نشده از بانک صادرات	۱۳۹۹/۱/۱ تا ۱۳۹۹/۲/۳۱

شکل ۲. شماتیک جمعیت اولیه

مقدار پیشنهادی برای متغیر k	ویژگی ۱ از جدول (۱)	ویژگی ۲ از جدول (۱)	ویژگی ۳ از جدول (۱)	ویژگی ۴ از جدول (۱)	ویژگی ۵ از جدول (۱)	ویژگی ۶ از جدول (۱)	ویژگی ۷ از جدول (۱)	ویژگی ۸ از جدول (۱)	ویژگی ۹ از جدول (۱)	ویژگی ۱۰ از جدول (۱)
۱	۱۸	۰	۱	۱	۰	۰	۰	۱	۱	۰
۲	۳۱	۱	۰	۱	۰	۱	۱	۰	۰	۱
۳	۱۵	۱	۱	۱	۱	۰	۰	۱	۰	۰
۴	۲۲	۱	۰	۱	۱	۰	۰	۱	۰	۱
...
۵۰۰	۱۸	۱	۰	۱	۱	۱	۰	۰	۰	۰

B. محاسبه‌ی برازندگی هر ذره: با استفاده از تابع برازش^۱، برای هر ذره حاضر در جمعیت میزان برازندگی مشخص می‌شود. این میزان برازندگی بر اساس عمل خوشه‌بندی با استفاده از روش K-میانگین انجام می‌گیرد. میزان مناسب بودن خوشه‌بندی انجام شده بر مبنای معیار واریانس درون کلاسی^۲ سنجیده می‌شود که متناظر با عکس برازندگی هر ذره است (Ahmar et al, 2018).

به عبارت دقیق‌تر، برای تعیین میزان برازندگی هر ذره، ویژگی‌هایی که در ذره با مقدار یک مشخص شده‌اند در کنار چهار ویژگی LRFM قرار می‌گیرد و با استفاده از این ویژگی‌ها، ماتریس مشتریان ایجاد می‌گردد. هر سطر یک مشتری و هر ستون یکی ویژگی خواهد بود. این داده‌ها با استفاده از روش K-میانگین خوشه‌بندی می‌شود (کوهن -Cohen addad et al, 2022). تعداد خوشه‌ها نیز به وسیله‌ی ذره مورد بررسی پیشنهاد داده شده است. پس از اتمام روند خوشه‌بندی با روش K-میانگین، واریانس هر خوشه بر مبنای رابطه

1. Fitness Function.
2. Within-class Variance.

(۱) و (۲) به دست می‌آید. میانگین تمامی این واریانس‌ها با استفاده از رابطه (۳) محاسبه و در رابطه‌ی (۴) برای محاسبه‌ی میزان برازندگی ذره موردنظر استفاده می‌شود. هر چه میانگین واریانس‌ها کم‌تر باشد، نشان می‌دهد که خوشه‌بندی انجام‌شده بهتر خواهد بود و به برازندگی بالاتری برای ذره موردنظر می‌رسیم. پس از محاسبه مقدار میانگین واریانس درون کلاسی برای تمامی خوشه‌ها می‌توان میزان مناسب بودن پیشنهاد ذره I ام را متوجه شد (Nickfarjam et al, 2015).

$$var_c = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2 \quad (1)$$

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

$$\overline{var} = \frac{1}{K} \sum_{c=1}^K var_c \quad (3)$$

$$fitness_{particle} = \frac{1}{\overline{var}} \quad (4)$$

که:

• var_c : واریانس داده‌های مشتریان داخل خوشه‌ی C.

• x_i : داده‌ی مشتری I ام در خوشه C.

• \bar{x} : میانگین داده‌های مشتریان داخل خوشه C.

• N : تعداد مشتریان داخل خوشه‌ی C.

• \overline{var} : میانگین واریانس درون کلاسی برای همه خوشه‌ها.

• $fitness_{particle}$: برازندگی ذره مورد نظر.

C. به‌روزرسانی مقادیر ذرات: با استفاده از دو پارامتر بهینه محلی ۱ (LBEST) و بهینه سراسری ۲ (GBEST) می‌توان مقادیر حاضر در ذرات را به‌روزرسانی کرد. منظور از LBEST، بهترین مقداری است که ذره I ام تاکنون به آن رسیده است (مقداری با بهترین برازندگی برای ذره I ام). همچنین منظور از GBEST، مقداری است که تا تکرار T ام دارای بهترین برازش بوده است. از این دو مقدار برای به‌روزرسانی مقادیر ذرات دیگر

-
1. Local Optima (LBest).
 2. Global Optima (GBest).

استفاده می شود. استدلال این قضیه مربوط به حرکت ذرات به سمت مکان های بهتر در فضای جست و جو خواهد بود. روابط (۵) تا (۹) این موضوع را نشان می دهد (Khanesar et al, 2007).

$$C \quad x_i^{NEW} = \begin{cases} \text{if } r_3 < V_i^{NEW} \\ 0 \text{ در غیر این صورت} \end{cases} \quad (5)$$

$$D \quad V_i^{NEW} = \omega V_i + c_1 r_1 (LBest_i - x_i) + c_2 r_2 (GBest - x_i) \quad (6)$$

$$E \quad V_0 = 0 \quad (7)$$

$$F \quad V_i^{NEW} = \frac{1}{1+e^{-V_i}} \quad (8)$$

$$G \quad K_i^{NEW} = [K_i + V_i^{NEW}] \quad (9)$$

که:

- V_i^{NEW} : سرعت جدید هر ذره است که بر مبنای سرعت قبلی او و رابطه (۶) محاسبه می شود.
- V_i : سرعت قبلی هر ذره.
- r_1 و r_2 و r_3 : مقادیری تصادفی هستند که با استفاده از توزیع یکنواخت به دست می آیند.
- ω : میزان تأثیر سرعت قبلی ذره در سرعت فعلی.
- $LBest_i$: بهترین مقداری که ذره مورد نظر تا تکرار فعلی به آن دست یافته است (مقداری که بهترین برازندگی را داشته است).
- $GBest$: بهترین مقداری که تا کنون توسط ذره ها به دست رسیده است.
- K_i : مقدار K ی که در ذره I ام وجود داشته است.
- K_i^{NEW} : مقدار جدید K ی که برای ذره I ام قرار می گیرد.

همان طور که مشخص است رابطه ای که برای به روزرسانی مقادیر K استفاده می شود (رابطه (۱۰)) و در ستون اول جمعیت قرار دارد با سایر ستون ها متفاوت است. دلیل این امر آن است که مقدار K می تواند تمامی اعداد صحیح در بازه L تا B را شامل شود؛ ولی،

مقادیر سایر ستون‌ها باید یک یا صفر باشد؛ زیرا، وجود یا عدم وجود یک ویژگی را در کنار ویژگی‌های LRFM بیان می‌کند. لازم به ذکر است منظور از علامت جزء صحیح می‌باشد تا از ایجاد اعداد اعشاری جلوگیری شود.

D. خاتمه‌ی الگوریتم: تمامی ذرات جمعیت جدید مورد ارزیابی قرار می‌گیرند و مراحل یک تا سه تا رسیدن به تعداد مشخص تکرار می‌شود. شرط خاتمه‌ی الگوریتم، تعداد تکرار مشخص است. ذره‌ای که بیش‌ترین برازندگی را در جمعیت پایانی دارد به‌عنوان پاسخ نهایی انتخاب می‌گردد. به عبارت دقیق‌تر، ویژگی‌هایی که این ذره پیشنهاد می‌دهد در کنار ویژگی‌های مدل LRFM قرار می‌گیرد و مشتریان با استفاده از روش K- میانگین به تعدادی که این ذره پیشنهاد می‌دهد خوشه‌بندی می‌شوند.

یافته‌ها

در این بخش به نتایج به‌دست آمده در این مقاله پرداخته و بحث در مورد آن‌ها انجام می‌شود. در پیاده‌سازی روش پیشنهادی، داده‌های موجود در اختیار روش قرار داده شد تا از بین ویژگی‌های حاضر به انتخاب بپردازد؛ بنابراین، اولین نکته آن است که باید پارامترهای روش پیشنهادی در جدولی ذکر گردد. جدول (۲) مقادیر پارامترها ذکر می‌گردد.

جدول ۲. پارامترهای روش پیشنهادی.

عنوان	مقدار
تعداد مشتریان (تعداد رکوردها) P	۹۰۰ هزار
تعداد جمعیت اولیه M	۵۰۰
مقدار پایین برای L / K	۱۰
مقدار بالا برای B / K	۳۰
ω	۰/۵
c_1	۰/۵
c_2	۰/۵

جدول (۳) نشان‌دهنده مقادیر میانگین واریانس درون کلاسی برای هر سه روش RFM، LRFM و روش پیشنهادی است و تعداد خوشه‌هایی که به وسیله‌ی روش K- میانگین برای هر سه روش مشخص شده نیز در این جدول آمده است.

جدول ۳. مقایسه‌ای بین روش پیشنهادی و روش‌های رقیب با معیار واریانس درون کلاسی

روش پیشنهادی	LRFM	RFM	عنوان
۰,۵۳۳۹	۰,۶۷۷۴	۰,۸۵۶۳	میانگین واریانس درون کلاسی
۱۹	۱۵	۱۱	تعداد خوشه‌ها

از مقایسه‌ی مقادیر شاخص میانگین واریانس درون کلاسی برای هر سه روش در جدول (۳)، مشخص است که مقدار شاخص برای روش پیشنهادی کم‌تر از روش‌های رقیب است. کم‌تر بودن این شاخص بیان‌گر کیفیت بالاتر خوشه‌ها در خوشه‌بندی با روش پیشنهادی این مقاله است.

لازم به ذکر است که تعداد بالاتر خوشه‌ها الزاماً به معنای دقت بالاتر نیست. لیکن، با توجه به بهتر شدن شاخص میانگین واریانس درون کلاسی می‌توان انتظار داشت کیفیت خوشه‌بندی بهتر شده است. ویژگی‌هایی که در پایان برای داده‌های حاضر انتخاب شده‌اند در جدول (۵) آمده است. این ویژگی‌ها توسط بهترین ذره در آخرین تکرار الگوریتم پیشنهادشده و باید در کنار ویژگی‌های LRFM قرار گیرد.

در کنار میانگین واریانس درون کلاسی از شاخص سیلیوت^۱ نیز برای مقایسه استفاده شده است. سیلیوت به روشی برای اعتبارسنجی مناسب بودن در خوشه‌های داده اشاره دارد. این تکنیک توسط آماردان بلژیکی پیتر روسیو در سال ۱۹۸۷ پیشنهاد شد (Rousseeuw, 1987). مقدار سیلیوت حاصل از معیاری است که نشان می‌دهد یک داده چقدر به خوشه خود در مقایسه با خوشه‌های دیگر شبیه است. مقدار سیلیوت از ۱- تا ۱+ است و هر چه این مقدار بالاتر باشد نشان از آن دارد که داده به خوبی با خوشه خودش مطابقت دارد؛ بنابراین، با خوشه‌های همسایه همخوانی ضعیفی دارد. پس، مقدار سیلیوت برای همه داده‌ها با توجه

¹Silhouette.

به خوشه‌ها به دست می‌آید و هر چه میانگین مقدار سیلیوت بیش تر باشد، روش بهتری در مقایسه با روش‌های رقیب ارائه شده است (Shahapure & Nicholas, 2020). در این مقاله از فاصله اقلیدسی^۱ برای یافتن میزان سیلیوت استفاده شده است. برای یافتن فاصله اقلیدسی بین دو بردار P و Q از رابطه (۱۰) استفاده می‌شود:

$$Sil(q) = \frac{1}{|C|-1} \sum_{p \in C \text{ and } p \neq q} D(p, q) \quad (10)$$

که N تعداد ابعاد (طول بردار) P و Q می‌باشد؛ بنابراین، برای یافتن میزان سیلیوت برای هر داده برابر با:

$$Sil(q) = \frac{1}{|C|-1} \sum_{p \in C \text{ and } p \neq q} D(p, q) \quad (11)$$

می‌باشد که:

- $D(p, q)$ ، فاصله داده Q با داده P و
- $|C|$ مساوی با تعداد داده‌های موجود در خوشه Q و
- $Sil(q)$ سیلیوت داده Q می‌باشد.

سیلیوت برای تمامی داده‌ها (Q ها) را با توجه به داده‌های هم خوشه‌اش (P ها) به دست آورده و میانگین گرفته می‌شود. هر چه این مقدار بیش تر باشد؛ نشان از مناسب‌تر بودن خوشه‌بندی دارد. این مقادیر در جدول (۴) آمده است.

جدول ۴. مقایسه‌ای بین روش پیشنهادی و روش‌های رقیب با معیار سیلیوت.

عنوان	RFM	LRFM	روش پیشنهادی
میانگین سیلیوت	۰,۶۸	۰,۷۱	۰,۷۵
تعداد خوشه‌ها	۱۱	۱۵	۱۹

نتیجه‌گیری و پیشنهادها

این مقاله تلاش دارد روشی پویا برای خوشه‌بندی مشتریان بانک در جهت بهبود

1. Euclidean Distance.

سرویس دهی به آن‌ها ارائه کند. روش LRFM دارای چهار ویژگی مهم در حوزه بانکداری و لیکن مشکل آن، عدم پویایی است. به عبارت دقیق‌تر، ممکن است ویژگی‌های دیگری اعم از ویژگی‌های مالی، شغلی یا تراکنش‌های روزمره بتواند در کنار چهار ویژگی LRFM قرار گیرد و عملکرد این روش را بهبود بخشد. از بین تمامی ویژگی‌هایی که می‌تواند در کنار چهار ویژگی LRFM قرار گیرد؛ باید بسته به داده‌های مشتریان، ویژگی‌های مناسب را انتخاب کرد. این انتخاب بر عهده الگوریتم ازدحام ذرات است. این الگوریتم تلاش می‌کند بسته به شرایط داده‌ها و اطلاعات مشتریان، ویژگی‌های مناسبی را در کنار چهار ویژگی LRFM قرار دهد تا نتیجه بهتری در خوشه‌بندی کسب شود. همچنین، چون این الگوریتم به روش K-میانگین در یافتن تعداد خوشه‌ها کمک می‌کند.

جدول ۵. ویژگی‌های انتخاب‌شده توسط روش پیشنهادی.

ویژگی	انتخاب‌شده است یا خیر
طول ارتباط مشتری با بانک صادرات (L)	✓
تازگی مبادله (R)	✓
تعداد دفعات مبادله (F)	✓
ارزش پولی مبادله شده (M)	✓
کد نوع عملیات	✓
کد پایانه	
بانک میزبان	
تاریخ انجام تراکنش	
مبلغ تسهیلات دریافتی از بانک صادرات	✓
میزان تسهیلات معوق از بانک صادرات	✓
ارزش انتقال وجه شتابی	
میانگین تراکنش ماهیانه	✓
مبلغ کل سپرده‌ی مشتری در بانک صادرات	✓
مبلغ کل چک‌های وصول نشده از بانک صادرات	

در پژوهش‌های آتی می‌توان از داده‌های سایر بانک‌ها استفاده و نتایج به‌دست‌آمده روی داده‌های مختلف را مقایسه کرد. این موضوع کمک می‌کند تا این موضوع که کارکرد روش پیشنهادی مقاله پویا است و بسته به شرایط داده‌ها، خوشه‌بندی‌های مختلفی را ارائه می‌کند اثبات گردد. همچنین می‌توان روش‌های فراابتکاری دیگر را جایگزین ازدحام ذرات کرده و نتایج آن را با نتایج حاضر در مقاله مقایسه کرد.

تعارض منافع

تعارض منافع وجود ندارد.

ORCID

Mohammad Kazemi

Mohammad Ali Keramati

Mehrzaad Minooe




<http://orcid.org/0000-0002-0382-3921>



<http://orcid.org/0000-0002-6339-6562>



<http://orcid.org/0000-0002-8474-2938>



منابع

۱. خدابنده لو، س. نیک‌نفس، ع. قاضی‌زاده، ف.، «۱۳۹۴»، «بررسی مزایا، معایب و نحوه‌ی کاربرد RFM در ارزیابی وفاداری مشتری»، دومین همایش ملی پژوهش‌های کاربردی در علوم کامپیوتر و فناوری اطلاعات. Doi://civilica.com/doc/455223/
۲. مصلحی، ن. کفاش پور، آ. ناجی عظیمی، ز.، «۱۳۹۳»، «استفاده از مدل LRFM برای بخش‌بندی مشتریان بر اساس ارزش چرخه‌ی عمر آن‌ها»، پژوهش‌های مدیریت عمومی. DOI:10.22111/JMR.2014.1908
۳. یوسفی زاد، ا. ثریایی، ع.، «۱۳۹۷»، «بررسی و خوشه‌بندی مشتریان، بر اساس مدل RFM و طراحی الگویی برای ارائه‌ی خدمات به مشتریان کلیدی»، پژوهشنامه‌ی مدیریت اجرایی علمی-پژوهشی. DOI :10.22080/JEM.2019.15814.2834

References

4. Ahmar, A. S., Napitupulu, D., Rahim, R., Hidayat, R., Sonatha, Y., & Azmi, M. (2018). Using K-means clustering to cluster provinces in Indonesia. In *Journal of Physics: Conference Series* (Vol. 1028, p. 012006). IOP Publishing. Doi:10.1088/1742-6596/1028/1/012006
5. Ayoubi, M., (2016), "Customer Segmentation Based On CLV Model And Neural Network", *International Journal Of Computer Science*. Doi:10.20943/01201602.3137
6. Bagattini, F., Schoen, F., Tigli, L., (2019), "Clustering Methods For Large Scale Geometrical Global Optimization", *Optimization Methods And Software*. Doi:10.1080/10556788.2019.1582651
7. Chandra, S., Verma, S., Lim, W. M., Kumar, S., & Donthu, N. (2022). Personalization in personalized marketing: Trends and ways forward. *Psychology & Marketing*, 39(8), 1529-1562. Doi:10.1002/mar.21670
8. Cohen-Addad, V., Green Larsen, K., Saulpic, D., Schwiegelshohn, C., & Sheikh-Omar, O. A., (2022), Improved Coresets for Euclidean k -Means. *Advances in Neural Information Processing Systems*, 35, 2679-2694. DOI:https://doi.org/10.48550/arXiv.2211.08184
9. Hughes, A. M., (1996), "Boosting response with RFM", *Marketing Tools*.
10. Khanesar, M. A., Teshnehlal, M., & Shoorehdeli, M. A., (2007), A novel binary particle swarm optimization. In 2007 Mediterranean conference on control & automation (pp. 1-6). *IEEE*. DOI:

10.1109/MED.2007.4433821

11. Otto, A. S., Szymanski, D. M., Varadarajan, R., (2019), "Customer Satisfaction And Firm Performance: Insights From Over A Quarter Century Of Empirical Research", *Journal Of The Academy Of Marketing Science*.Doi:10.1007/s11747-019-00657-7
12. Sharahi, M., Aligholi, M., (2015), "Classify The Data Of Bank Customers Using Data Mining And Clustering Techniques (Case Study: Sepah Bank Branches Tehran)", *Journal Of Applied Environmental And Biological Sciences*.
13. Marzdashti, T., Jazani, N., & Mehrabi, J. (2022). Designing a strategic model of customer-oriented human resources in the Iranian banking system. *Journal of Positive School Psychology*, 6800-6818.
14. Nickfarjam, A. M., Ebrahimpour-komleh, H., & Hosseini, F., (2015), Multi-level image thresholding based on local variance and particle swarm optimization. In 2015 International Congress on Technology, Communication and Knowledge (ICTCK) (pp. 508-512). *IEEE*.Doi:10.1109/ICTCK.2015.7582720
15. Rousseeuw, P. J. (1987). Silhouettes: a graphical aid to the interpretation and validation of cluster analysis. *Journal of computational and applied mathematics*, 20, 53-65.Doi:10.1016/0377-0427(87)90125-7
16. Shahapure, K. R., & Nicholas, C. (2020). Cluster quality analysis using silhouette score. In 2020 *IEEE 7th international conference on data science and advanced analytics (DSAA)* (pp. 747-748). *IEEE*.Doi:10.1109/DSAA49011.2020.00096

References [In Persian]

17. Khudabandeh Lu, S. Nik Nafs, A. Ghazizadeh, F., (2014), "Investigation of the advantages, disadvantages and application of RFM in evaluating customer loyalty", the second national conference of applied research in computer science and information technology.
18. Moslehi, N. Kafashpour, A. Naji Azimi, Z., (2014), "Using the LRFM model to segment customers based on their life cycle value", *Public Management Research*. Doi:10.1371/journal.pone.0279262

19. Yousefizad, A. Soryaei, A., (2017), "*Investigation and clustering of customers, based on the RFM model and design of a model for providing services to key customers*", scientific-research executive management research paper.



استناد به این مقاله: کاظمی، محمد، کرامتی، محمدعلی، مینویی، مهرزاد. (۱۴۰۳). ارائه‌ی مدل بهبودیافته‌ی LRFM به جهت خوشه‌بندی مشتریان بانک بر مبنای ترکیب الگوریتم ازدحام ذرات و خوشه‌بندی K-میانگین، مطالعات مدیریت کسب و کار هوشمند، ۱۲(۴۸)، ۱۹۷-۲۲۲. DOI: 10.22054/ims.2023.75014.2364



Journal of Business Intelligence Management Studies is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License..