



Improving Subscriber Retention Using Subscriber Segmentation: Implementing the LRFM Method in a Mobile Virtual Network Operator Company

Ahmad Hakimi ^{a*}, Hossein Saadati ^b

^a Department of Industrial Engineering, University of science and culture, Tehran, Iran


^b Department of Industrial Engineering, Kharazmi University, Tehran, Iran.

Original Article

Use your device to scan
and read the article online



Citation: Hakimi A, Saadati H, Heidari Z. Improving Subscriber Retention Using Subscriber Segmentation: Implementing the LRFM Method in a Mobile Virtual Network Operator Company. *Industrial Innovations*. 2025;3 (1):84 -102.

 <https://doi.org/10.61882/jii.3.1.84>

KEYWORDS

LRFM;
Segmentation method;
Customer behavior analysis;
Churn management.

ABSTRACT

Customer churn is a major concern for telecommunications companies, especially in the highly competitive environment of mobile virtual network operators (MVNOs). Understanding subscriber behavior and the factors influencing churn is essential for developing effective customer retention strategies. This study investigates the behavioral patterns of mobile subscribers using LRFM (Length, Recency, Frequency, Monetary) analysis to identify key segments and churn risks. This outcome demonstrates the tangible benefits of leveraging behavioral analytics to design customer-centric retention initiatives. Unlike previous studies that often overlook MVNO-specific dynamics, this research provides actionable insights tailored to the unique operational context of MVNOs. The findings can help operators refine their promotional strategies, optimize service delivery, and ultimately build stronger, longer-lasting customer relationships in an increasingly saturated market. Our analysis reveals those subscribers with low recency scores—those who have not interacted with the service recently—are significantly more likely to churn. Based on these insights, we developed targeted re-engagement strategies and personalized service packages designed to meet the specific needs of different customer groups. These tailored offerings not only improve customer satisfaction but also help reduce churn effectively. Notably, the implementation of a focused marketing campaign led to the successful reactivation of approximately 15% of previously dormant users. Furthermore, We developed targeted re-engagement strategies and personalized service packages designed to meet the specific needs of different customer groups. These tailored offerings not only improve customer satisfaction but also help reduce churn effectively. Notably, the implementation of a focused marketing campaign led to the successful reactivation of approximately 15% of previously dormant users.

Extended Abstract

1. Introduction

Customer retention has emerged as a central strategic concern for companies operating in the highly competitive telecommunications market, particularly for Mobile Virtual Network Operators (MVNOs) whose business models rely heavily on sustained subscriber engagement and efficient churn management. Unlike traditional operators, MVNOs often operate with limited resources in saturated markets, where customers face numerous alternatives with similar service offerings. Consequently, even small increases in churn rates can substantially reduce revenue and undermine long-term

* Corresponding author.

E-mail address: ahmad.hakimi2010@gmail.com

DOI: <https://doi.org/10.61882/jii.3.1.84>

Received: July 27, 2025; Received in revised form: November 9, 2025; Accepted: November 17, 2025.

Article type: Research Paper



stability. In such environments, leveraging behavioral data to understand customer interactions and identify early signs of churn becomes essential. Among behavior-based analytical approaches, the LRFM model—an extension of the classical RFM framework—offers a richer and more accurate means of segmenting customers by incorporating “Length of Relationship” alongside recency, frequency, and monetary value. This fourth dimension enables operators to distinguish long-standing loyal customers from newly acquired high-value users, an insight that is particularly valuable in designing effective retention strategies.

2. Research Method

The present study investigates the application of the LRFM framework within an Iranian MVNO to segment subscribers, analyze churn behavior, and develop targeted promotional campaigns. A cohort of subscribers who activated their SIM cards during the first quarter of 2022 was selected for analysis. Choosing this window ensured that by early 2024, when the research began, more than 90 days had passed, enabling reliable classification of churned, inactive, and active users. Each subscriber’s record included demographic variables, dates of first and last interactions, usage frequency (measured through weighted averages of mobile data consumption and voice call minutes), and monetary spending during the observed period. The LRFM model was implemented by scoring each dimension on a five-point Likert scale. Length was calculated based on the number of months since activation; recency was measured as the number of days since last activity; frequency combined data and voice usage with weights of 60% and 40% respectively; and monetary value was normalized using a confidential reference amount X . After scoring all subscribers, percentile thresholds were applied to assign values between 1 and 5 within each dimension.

By combining LRFM scores equal to or greater than 3, subscribers were grouped into sixteen possible clusters, such as “Best customers” (LRFM), “High-value but at-risk” (LFM), “New high-consumption users” (RM), “High-frequency but low-value” (LF), and “Lost high-value customers” (M or FM). These clusters provided a comprehensive behavioral map of the subscriber base and revealed meaningful patterns. For example, a significant portion of high-spending customers showed declining recency, indicating early signs of churn despite historically strong usage. Conversely, some newly acquired users displayed high consumption but lacked long-term loyalty indicators, suggesting they required special onboarding assistance rather than standard promotional messaging.

Using these insights, customized service packages were designed for each LRFM segment. The packages varied in price, data allowances, and additional benefits, ensuring that each cluster received an offer relevant to its behavioral profile. These offers were delivered via SMS in two waves on January 22 and January 27, 2024. For churned or long-inactive users who did not open the initial message, the SMS was resent to increase visibility and ensure fair exposure to the campaign. The effectiveness of the campaign was evaluated by comparing subscriber activity status before and after the intervention.

3. Findings

Prior to the campaign, analysis showed that 78% of the selected subscribers were active, with 61% having used services in the previous 15 days. Meanwhile, 22% had been inactive for more than 90 days, classifying them as churned. Following the LRFM-targeted promotional campaign, notable improvements were observed. The proportion of active users increased by approximately 15%, demonstrating the strong impact of personalized interventions. Additionally, about 8% of subscribers who had been inactive for more than 90 days returned to the network. While this rate is lower than the reactivation levels observed in shorter inactivity periods, it still represents a meaningful recovery given the low cost of SMS campaigns and the high cost associated with acquiring new customers.

A more detailed analysis of reactivation behavior revealed a clear temporal pattern: subscribers who had been inactive for 15–30 days exhibited the highest reactivation rate at nearly 34%. Those who had been inactive between 31 and 60 days showed moderate responsiveness, whereas users inactive for more than 90 days returned at a rate of roughly 10%. These results highlight the importance of timely engagement, as recently inactive customers retain a stronger cognitive link to the brand and are therefore more responsive to targeted offers. For long-term inactive customers, even modest reactivation rates are strategically valuable because they often represent users with historical satisfaction or structural dependence on their mobile number—making them promising candidates for future loyalty-building programs.

The findings demonstrate that LRFM segmentation enables MVNOs to identify specific subscriber groups at heightened risk of churn and intervene with tailored offers that address their needs and behavioral tendencies. High-value customers with declining recency, for example, can be approached with incentives designed to reactivate their usage patterns before competitors capture their attention. Meanwhile, newly acquired high-consumption customers may benefit from onboarding communications or introductory bundles that strengthen early loyalty. Importantly, the interpretability of the LRFM model allows marketing teams to translate analytical outputs directly into actionable strategies without requiring advanced machine learning infrastructure. This practicality is crucial for MVNOs that often operate with limited data science resources.

4. Conclusion

In conclusion, the implementation of LRFM-based segmentation in this study significantly enhanced the MVNO’s ability to understand subscriber behavior, reduce churn, and design effective retention strategies. The personalized campaign delivered noticeable improvements in activation rates and demonstrated the strong potential of data-driven marketing approaches in competitive telecom environments. This research contributes to the broader discourse on churn management by providing empirical evidence of the effectiveness of LRFM in a real-world MVNO context. Moreover, the framework developed here is easily replicable and adaptable, offering a practical tool for telecom operators seeking to optimize marketing resources and strengthen subscriber loyalty. Future work may explore integrating LRFM outputs with machine learning-based churn prediction models, analyzing long-term financial impacts of targeted retention strategies, and leveraging real-time behavioral data to develop dynamic segmentation systems that evolve alongside user behavior.



بهبود وضعیت نگهداری مشترکین با استفاده از تقسیم‌بندی مشترکین: پیاده‌سازی روش LRFM در یک شرکت اپراتور مجازی شبکه تلفن همراه

احمد حکیمی^{الف*}، حسین سعادت^ب

^{الف} گروه مهندسی صنایع، دانشکده فنی، دانشگاه علم و فرهنگ، تهران، ایران. ahmad.hakimi2010@gmail.com

^ب گروه مهندسی صنایع، دانشگاه خوارزمی، تهران، ایران. hossein.saadati@khu.ac.ir

واژگان کلیدی	چکیده
تحلیل رفتاری مشتری؛ بخش‌بندی LRFM؛ مدیریت ریزش؛ اپراتور مجازی تلفن همراه؛ بازاریابی هدفمند.	در سال‌های اخیر، افزایش رقابت در بازار خدمات تلفن همراه، به‌ویژه با ظهور اپراتورهای مجازی (MVNO)، موجب شده حفظ مشترکان به یکی از مهم‌ترین دغدغه‌های شرکت‌های مخابراتی تبدیل شود. شناسایی رفتار مشتریان و درک عمیق از الگوهای ریزش آن‌ها، نقش کلیدی در بهبود راهکارهای وفادارسازی ایفا می‌کند. این پژوهش با تمرکز بر مشترکان اپراتورهای مجازی، به بررسی الگوهای رفتاری آن‌ها با هدف کاهش نرخ ریزش می‌پردازد. برای تحلیل دقیق‌تر، از مدل بخش‌بندی LRFM استفاده شده که ابعاد تازه‌تری خرید، تکرار خرید، میزان مصرف و طول مدت ارتباط مشتری با شرکت را در نظر می‌گیرد. نتایج نشان می‌دهد مشتریانی که اخیراً ارتباطی با سرویس نداشته‌اند، بیش از دیگران در معرض ترک خدمات قرار دارند. این یافته اهمیت تدوین کمپین‌های بازاریابی هدفمند را برای بازگرداندن این دسته از کاربران برجسته می‌سازد. در ادامه، بسته‌های خدماتی متناسب با نیازهای گروه‌های مختلف مشتریان طراحی و پیشنهاد شد؛ راهبردی که افزون بر افزایش رضایت مشتری، توانست حدود ۱۵ درصد از کاربران غیرفعال را مجدداً فعال سازد. این موفقیت، اثربخشی پیشنهادها را شخصی‌سازی شده را در حفظ و بازگشت مشتریان تأیید می‌کند. نتایج این پژوهش می‌تواند به اپراتورهای مجازی کمک کند تا با تکیه بر تحلیل دقیق داده‌های مشتریان، برنامه‌های بازاریابی و نگهداشت خود را به‌صورت علمی و هدفمند بازطراحی نمایند.
تاریخ دریافت: ۱۴۰۴/۰۵/۰۵	
تاریخ بازنگری: ۱۴۰۴/۰۸/۱۸	
تاریخ پذیرش: ۱۴۰۴/۰۸/۲۶	

۱- مقدمه

صنعت مخابرات در دهه‌های اخیر به‌عنوان یکی از ارکان اصلی اقتصادهای پیشرفته شناخته شده و نقشی کلیدی در رشد اقتصادی و توسعه دیجیتال ایفا می‌کند [۱]. در چنین بستری، سازمان‌هایی که با بهره‌گیری از سامانه‌های مدیریت ارتباط با مشتری^۱ به شناختی دقیق از نیازها و ترجیحات مخاطبان خود دست می‌یابند، توان رقابتی بیشتری داشته و مسیر موفقیت را هموارتر طی می‌کنند. ادغام داده‌های رفتاری مشتریان در سامانه‌های CRM، این امکان را فراهم می‌سازد تا سیاست‌های مؤثری برای حفظ مشتری و کاهش نرخ ریزش طراحی و اجرا گردد [۲].

مدیریت ریزش مشتریان^۲ یکی از مفاهیم محوری در این زمینه است؛ رویکردی که به‌منظور ایجاد و حفظ روابط پایدار و سودآور با مشتریان فعلی و ارتقای ارزش طول عمر آنان، از اهمیت بالایی برخوردار است. بررسی‌ها در بازارهای رقابتی نشان

^۱ Customer Relation Management

^۲ Churn Management

می‌دهد که ورود بازیگران جدید و کاهش محدودیت‌های قانونی، شدت رقابت را افزایش داده و شرکت‌ها را به سمت کاهش قیمت و بهبود کیفیت خدمات سوق داده است [۳]. در چنین شرایطی، این رویکرد به‌عنوان بخشی جدایی‌ناپذیر از سامانه‌های CRM، به مجموعه اقداماتی اطلاق می‌شود که با هدف حفظ مشتریان و جلوگیری از مهاجرت آن‌ها به رقبای طراحی می‌گردد. رضایت پایین از کیفیت خدمات، قیمت‌های نامناسب و پیشنهادات جذاب‌تر رقبای، از مهم‌ترین عواملی هستند که در ریزش مشتریان نقش دارند.

از سوی دیگر، مدیریت نگهداشت مشتریان به‌عنوان راهبردی کلیدی برای افزایش وفاداری و جلوگیری از مهاجرت آن‌ها به رقبای، به‌ویژه در صنعت مخابرات، مطرح شده است [۴]. در حال حاضر، انتقال مشتریان از یک شرکت به شرکت دیگر در حوزه‌های فناوری و اینترنت به چالشی جدی تبدیل‌شده و رفتار مصرف‌کنندگان در بازارهای ارتباطی به‌شدت متأثر از رقابت فزاینده میان اپراتورهاست [۵].

پیش‌بینی ریزش مشتریان یکی از ابزارهای حیاتی در چارچوب CRM است که با تحلیل داده‌های تاریخی و بهره‌گیری از الگوریتم‌های یادگیری ماشین، امکان شناسایی مشتریان در معرض ترک را فراهم می‌سازد [۶]. با پیش‌بینی این رفتار پیش از وقوع، شرکت‌ها قادر خواهند بود اقدامات اصلاحی مؤثری برای حفظ مشتریان ارزشمند خود در پیش گیرند.

با گسترش چشمگیر اینترنت در سال‌های اخیر، انتخاب یک ارائه‌دهنده خدمات اینترنتی برای هر کاربر به ضرورتی اجتناب‌ناپذیر تبدیل‌شده است. در نتیجه، برنامه‌ریزی دقیق برای ارتقای کیفیت خدمات و ایجاد مزیت رقابتی در راستای جلوگیری از ریزش مشتریان، اهمیتی دوچندان یافته است. در واقع، در شرایطی که جذب مشتریان جدید هزینه‌بر و دشوار است، تمرکز راهبردی شرکت‌های مخابراتی به‌سوی حفظ و وفادارسازی مشتریان فعلی سوق یافته است. این تغییر رویکرد نه‌تنها در کاهش هزینه‌های جذب مشتری مؤثر است، بلکه با افزایش تعامل و وفاداری مشتریان، سودآوری بلندمدت شرکت‌ها را تضمین می‌کند. به‌طور مثال، بر اساس یافته‌های تاتیکوندا [۷]، حفظ مشتریان فعلی به‌مراتب کم‌هزینه‌تر از جذب مشتریان جدید بوده و به افزایش فروش نیز منجر می‌شود. استفاده از رویکردی مشتری‌محور در مدیریت و تحلیل داده‌ها در سامانه‌های CRM، فرصت شناسایی رفتار مشتریان را پیش از ترک فراهم کرده و در صنایع خدماتی نتایج مطلوبی به همراه داشته است [۸].

مطالعات حوزه بانکداری و بیمه نشان می‌دهد که متغیرهایی همچون رضایت مشتری، سیاست‌های قیمتی و کیفیت خدمات، نقش تعیین‌کننده‌ای در پیش‌بینی ریزش دارند [۹]. در سال‌های اخیر، پژوهش‌های بیشتری به تحلیل ریزش در صنعت مخابرات پرداخته‌اند که بیانگر اهمیت عواملی چون کیفیت خدمات و نرخ‌های رقابتی در ماندگاری مشتریان است [۱۰]. مطالعات بازاریابی نیز حاکی از آن است که افزایش رضایت و اعتماد مشتریان از طریق راهبردهای مؤثر نگهداشت، به شکل معناداری موجب ارتقای وفاداری آنان می‌شود [۱۱]. برخلاف این باور که جذب مشتریان جدید ساده‌ترین راه افزایش درآمد است، شواهد نشان می‌دهد که نگهداشت مشتریان فعلی تا هفت برابر ارزان‌تر بوده و از منظر راهبردی، گزینه‌ای مناسب‌تر برای افزایش سودآوری است [۱۲]. سرمایه‌گذاری بر رضایت مشتریان، به‌ویژه از طریق بهبود خدمات پس از فروش و ارائه ارزش‌افزوده، نقش مهمی در شکل‌دهی رفتار مشتریان ایفا می‌کند. اولویت‌بخشی به این مؤلفه‌ها موجب تقویت وفاداری، افزایش خریدهای مکرر و کاهش احتمال مهاجرت مشتریان به سمت رقبای می‌گردد. این رویکرد بر اهمیت ایجاد ارتباطی پایدار و معنادار با مشتریان تأکید دارد؛ ارتباطی که در آن، نیازها و خواسته‌های آنان واقعاً درک و لحاظ می‌شود.

با وجود پیشرفت‌هایی که در زمینه سامانه‌های مدیریت مشتری و مدل‌های پیش‌بینی ریزش حاصل‌شده، همچنان ضرورت طراحی راهکارهایی هدفمند برای مواجهه با چالش‌های خاص اپراتورهای مجازی تلفن همراه (MVNO) احساس می‌شود. برخلاف اپراتورهای سنتی، MVNOها معمولاً در بازارهای پرتراکم با منابع محدود فعالیت می‌کنند، از این‌رو نیاز بیشتری به سیاست‌های وفادارسازی و نگهداشت مؤثر دارند. درحالی‌که بسیاری از پژوهش‌ها به بررسی موضوع مدیریت مشتریان در صنعت مخابرات پرداخته‌اند، اما مطالعاتی که به‌طور خاص به تحلیل چالش‌های ریزش در MVNOها بپردازد، محدود بوده است.

این پژوهش با هدف پر کردن این خلأ، به بررسی راهکارهای تعامل مؤثر با مشتری و مدل‌های پیش‌بینی ریزش می‌پردازد

که می‌تواند توسط اپراتورهای مجازی برای کاهش نرخ ترک خدمات و افزایش وفاداری مشترکان به کار گرفته شود. سازمان‌دهی این پژوهش به شکل زیر است:

بخش دوم به بررسی نقش سامانه‌های مدیریت مشتری در نگهداشت و پیش‌بینی ریزش در MVNO^۱ها و تحلیل عوامل کلیدی وفاداری می‌پردازد. بخش سوم مدل‌های پیش‌بینی را معرفی و کارآمدی آن‌ها را در بافت MVNO ارزیابی می‌کند. در بخش چهارم راهبردهایی مبتنی بر داده برای ارتقای وفاداری مشتری ارائه شده و در بخش پنجم، جمع‌بندی یافته‌ها و مسیرهای آتی پژوهش مطرح می‌گردد.

۲- پیشینه پژوهش

۲-۱- تقسیم‌بندی مشتریان^۲

در حوزه مدیریت ارتباط با مشتریان (CRM)، یکی از موضوعات کلیدی، تحلیل رفتار مشتریان با هدف شناسایی گروه‌های هم‌رفتار و پیش‌بینی ریزش آن‌هاست. با پیشرفت تکنیک‌های داده‌کاوی و الگوریتم‌های یادگیری ماشین، امکان شناسایی دقیق‌تر مشتریانی که در معرض ترک خدمات قرار دارند، فراهم شده و مسیر برای طراحی راهکارهای پیشگیرانه و اثربخش هموارتر شده است. این فرآیندها به کسب‌وکارها کمک می‌کنند تا با تحلیل داده‌های موجود، الگوهای ترجیح مشتریان را شناسایی کرده، راهبردهای حفظ مشتری را تدوین و تعاملات خود را بهینه‌سازی کنند. در همین راستا، خلیلی‌دامغانی و همکاران (۲۰۱۸) رویکردی ترکیبی برای پیش‌بینی رفتار مشتری در کسب‌وکارهای مشتری‌محور ارائه کردند. این مدل، با بهره‌گیری از درخت تصمیم و خوشه‌بندی، امکان پیش‌بینی تراکنش‌های آتی مشتریان را بر اساس سوابق آن‌ها فراهم می‌سازد و می‌تواند در بهینه‌سازی اقدامات تبلیغاتی و نگهداشت مشتری مؤثر واقع شود.

مارگیانتی^۳ و همکاران (۲۰۱۶) با استفاده از مدل RFM، داده‌های تراکنشی ۱۰۰۰ مشتری را در محیط نرم‌افزار MATLAB تحلیل و آن‌ها را به ۵۱ خوشه و در نهایت ۸ گروه رفتاری تقسیم کردند. در ادامه، بابائیان و صفرضی (۲۰۱۹) مدل توسعه‌یافته‌ای از RFM را پیشنهاد دادند که متغیر «اعتماد مشتری» را نیز در تحلیل وارد کرده بود. اگرچه این روش دقت تحلیل را افزایش می‌دهد، اما تمرکز بیش‌ازحد بر مشتریان با امتیازهای بالای RFM ممکن است باعث نارضایتی در مشتریان کم امتیاز شود و تعادل در استراتژی‌های بازاریابی را به هم بزند. جوشی^۴ و همکاران (۲۰۱۶) نیز از همین رویکرد برای تحلیل مدت‌زمان حضور مشتریان در یک فروشگاه زنجیره‌ای بهره گرفتند. نتایج آن‌ها نشان داد مشتریانی با امتیاز TRFM بالا، زمان کمتری صرف خرید می‌کنند و درعین‌حال رضایت بیشتری از تجربه خرید دارند. از سوی دیگر، موری^۵ و همکاران (۲۰۱۷) روش جدیدی برای تقسیم‌بندی مشتریان بر پایه داده‌کاوی ارائه کردند که با تمرکز بر داده‌های بازدید و فروش، دقت شناسایی الگوهای رفتاری مشتری را افزایش می‌داد. گریوا^۶ و همکاران (۲۰۱۸) نیز با تحلیل سبد خرید و بهره‌گیری از تکنیک‌های انتخاب ویژگی، مدلی برای شخصی‌سازی توصیه‌های خرید ارائه کردند که به افزایش فروش منجر شد. در صنعت خرده‌فروشی آنلاین، جها^۷ و همکاران (۲۰۲۰) مدل RFMOC را معرفی کردند که ضمن ترکیب متغیرهای کلاسیک RFM با دو شاخص جدید، به محاسبه ارزش طول عمر مشتری پرداختند. تحلیل‌های مبتنی بر این مدل با استفاده از رگرسیون لجستیک نشان داد که می‌توان مشتریان در معرض ریزش را به‌دقت شناسایی و برای هر گروه، راهبرد مناسب بازاریابی تدوین کرد.

در حوزه مخابرات نیز، شونکه^۸ و همکاران (۲۰۱۰) رفتار خرید مشتریان را شبیه‌سازی کرده و چهار روش مختلف برای خوشه‌بندی آن‌ها پیشنهاد دادند. یافته‌ها نشان داد ترکیب رویکردها در چارچوب اهداف سازمانی می‌تواند منجر به طبقه‌بندی

^۱ Mobile virtual Network Operator

^۲ Customer segmentation

^۳ Margianti

^۴ Joshi

^۵ Murray

^۶ Griva

^۷ Jha

^۸ Schwenke

دقیق تر مشتریان شود. هان^۱ و همکاران (۲۰۱۲) نیز با استفاده از درخت تصمیم، کاربران مخابراتی را بر اساس طول دوره تعامل، به پنج گروه مختلف از منظر ارزش مشتری تقسیم کردند. [۱۳] با پیشنهاد یک چارچوب دو بعدی شامل سودآوری و رفتار مشتری، نشان دادند که خوشه‌بندی دوبعدی با روش K-means نتایج دقیق‌تری نسبت به خوشه‌بندی تک‌بعدی به همراه دارد. این پژوهش تأکید دارد که تحلیل چندبعدی مشتریان منجر به طراحی راهکارهای هدفمندتری برای حفظ مشتریان ارزشمند خواهد شد. در مجموع، نتایج پژوهش‌ها حاکی از آن است که استفاده از تکنیک‌های پیشرفته خوشه‌بندی در کنار تحلیل داده‌های رفتاری مشتریان، می‌تواند به‌طور معناداری اثربخشی کمپین‌های بازاریابی و وفادارسازی را افزایش دهد.

۲-۲- پیش‌بینی ریزش مشتریان^۲

پیش‌بینی ریزش مشتریان یکی از حوزه‌های مهم در CRM و تحلیل داده‌ها به‌شمار می‌رود که هدف آن، شناسایی به‌موقع مشتریان در معرض ترک و طراحی راهبردهای مؤثر برای حفظ آن‌هاست. در سال‌های اخیر، مطالعات متعددی در صنایع مختلف با بهره‌گیری از تکنیک‌های یادگیری ماشین و داده‌کاوی انجام شده است. به‌عنوان نمونه، گوردینی^۳ و وگلیو (۲۰۱۷) در صنعت تجارت الکترونیک B2B، ریزش مشتری را به‌عنوان عدم انجام خرید در یک بازه یک‌ساله تعریف کرده و با استفاده از الگوریتم SVM و معیار AUC، به تحلیل آن پرداختند. رئیسی و ساجدی (۲۰۲۰) نیز در مطالعه‌ای در حوزه سفارش آنلاین غذا در تهران، با تعریف بازه‌های زمانی مختلف (از یک تا شش ماه عدم فعالیت)، از روش گرادبان بوس‌تینگ برای پیش‌بینی ریزش استفاده کردند. رشید و همکاران (۲۰۱۸) با به‌کارگیری مدل LRFM، روند خرید مشتریان را تحلیل و دقت الگوریتم‌های درخت تصمیم ترکیبی را با مدل‌های تکی و شبکه عصبی مصنوعی مقایسه کردند. در پژوهشی دیگر، پودل^۴ و همکاران (۲۰۲۴) با تمرکز بر صنعت مخابرات، از مدل GBM و الگوریتم‌های قابل تفسیر برای پیش‌بینی ریزش مشتری بهره بردند و به دقت ۸۱ درصد دست یافتند. همچنین، ژانگ^۵ و همکاران (۲۰۲۰) با ترکیب مدل RFM و خوشه‌بندی K-Means و سپس اعمال رگرسیون لجستیک، مدلی دقیق برای تحلیل رفتار خرید مشتریان و پیش‌بینی احتمال ریزش آن‌ها ارائه دادند. شیخو^۶ و هارادا^۷ (۲۰۲۲) نیز در صنعت خرده‌فروشی آنلاین، با ترکیب الگوریتم‌های SVM و K-Means توانستند مشتریان پرخطر را به‌دقت شناسایی کرده و استراتژی‌های نگهداشت مؤثرتری ارائه کنند. مطالعه زادو^۸ و همکاران (۲۰۲۲) در حوزه مخابرات، با بهره‌گیری از کاهش ابعاد (PCA) و الگوریتم‌های مختلف یادگیری ماشین، نشان داد که ترکیب این روش‌ها می‌تواند منجر به افزایش دقت مدل‌ها و کاهش نرخ ریزش شود.

در جدول زیر، خلاصه‌ای از پژوهش‌های مهم در حوزه پیش‌بینی ریزش مشتریان با تمرکز بر نوع صنعت، روش‌های خوشه‌بندی و الگوریتم‌های پیش‌بینی ارائه شده است:

^۱ Stehani

^۲ Churn prediction

^۳ Gordini

^۴ Poudel

^۵ Zhung

^۶ Xiahou

^۷ Harada

^۸ Zadoo

جدول ۱ خلاصه الگوریتم‌های یادگیری ماشین و میزان اثربخشی آن‌ها در مطالعات پیش‌بینی ریزش مشتریان

مرجع	صنعت	روش‌های بخش‌بندی (خوشه‌بندی)	الگوریتم‌های پیش‌بینی	یافته‌های کلیدی
[۱۴]	مخابرات	K-Means	(Random Forest), SMOTE, جنگل تصادفی AdaBoost	افزایش دقت پیش‌بینی ریزش از طریق متعادل‌سازی داده‌ها و خوشه‌بندی مؤثر
[۱۵]	خرده‌فروشی آنلاین	مدل RFM, K-Means	رگرسیون لجستیک	شناسایی روندهای رفتاری مشتریان و تسهیل راهبردهای هدفمند نگهداشت
[۱۶]	خرده‌فروشی / مراکز خرید	یادگیری بدون نظارت (K-Means, Affinity Propagation, DBSCAN)		نشان می‌دهد که الگوریتم‌های مختلف خوشه‌بندی می‌توانند مشتریان مراکز خرید را بر اساس ویژگی‌های جمعیت‌شناختی (جنسیت، درآمد، الگوی خرید) تفکیک کنند؛ زنان ۵۶٪ مشتریان را تشکیل می‌دهند و میانگین درآمد مردان بالاتر است؛ K-Means عملکرد ساده و کارآمدی در تفکیک گروه‌ها دارد.
[۱۷]	تجارت الکترونیک	K-Means	(SVM) ماشین بردار پشتیبان	بهبود شناسایی مشتریان در معرض ریزش و بخش‌بندی مؤثر
[۱۸]	مخابرات	تحلیل مؤلفه‌های اصلی (PCA)	(PCA, LDA) الگوریتم‌های یادگیری ماشین، طبقه‌بندی دودویی LDA	نمایش مزایای ترکیب کاهش ابعاد با مدل‌سازی پیش‌بین
[۱۹]	صنایع مختلف	LDA درخت تصمیم،	Naive SVM, رگرسیون لجستیک, Bayes, AdaBoost, KNN, Random Forest	اثبات برتری روش‌های ترکیبی نسبت به (AdaBoost مانند) مدل‌های تکی در پیش‌بینی ریزش
[۲۰]	صنایع مختلف	خوشه‌بندی سلسله‌مراتبی، K-Means	(SVM, XGBoost, Random Forest, KNN) درخت تصمیم، رگرسیون لجستیک،	نشان دادن اثربخشی مدل‌های ترکیبی در بهبود دقت پیش‌بینی
[۲۱]	حوزه‌های گوناگون	DBSCAN, K-Means	Random Forest, XGBoost, KNN	تأکید بر اهمیت انتخاب الگوریتم مناسب با توجه به ویژگی‌های داده‌ها

به‌کارگیری تکنیک‌های داده‌کاوی و الگوریتم‌های یادگیری ماشین در پیش‌بینی ریزش مشتری و بخش‌بندی آن‌ها، پیشرفت چشمگیری در حوزه مدیریت ارتباط با مشتری (CRM) به همراه داشته است. مطالعات بررسی‌شده نشان می‌دهند که استفاده از رویکردهای نوآورانه مانند مدل‌های ترکیبی، تحلیل مبتنی بر RFM و روش‌های پیشرفته بخش‌بندی، به‌طور مؤثری در شناسایی مشتریان در معرض ریزش و تدوین راهبردهای هدفمند برای حفظ آن‌ها نقش داشته‌اند. همچنین، تلفیق معیارهای اعتماد مشتری و تحلیل‌های رفتاری، بینش‌های عمیق‌تری نسبت به ترجیحات مصرف‌کنندگان فراهم کرده است؛ موضوعی که امکان تصمیم‌گیری‌های دقیق‌تر و شخصی‌سازی‌شده‌تر در حوزه بازاریابی و خدمات مشتری را فراهم می‌سازد.

۳- روش تحقیق

تقسیم‌بندی مشتریان فرآیندی است که در آن کاربران بر اساس نیازها، ویژگی‌ها یا رفتارهایشان در گروه‌های متمایز طبقه‌بندی می‌شوند؛ گروه‌هایی که ممکن است نیازمند خدمات متفاوتی باشند یا واکنش‌های متفاوتی نسبت به اقدامات بازاریابی نشان دهند. معیارهایی مانند جنسیت، سن، سطح تحصیلات و سایر عوامل می‌توانند به‌عنوان مبنای تقسیم‌بندی مورد استفاده

قرار گیرند. یک بخش‌بندی مؤثر مستلزم آن است که هر بخش دارای ویژگی‌هایی نظیر انسجام درونی، پتانسیل رشد، اندازه مناسب، قابلیت دسترسی، پاسخ‌پذیری و هم‌راستایی با اهداف و منابع سازمان باشد [۲۲].

انتخاب مدل LRFM و توجیه آن: اگرچه مدل کلاسیک RFM [۲۳] به دلیل سادگی و اثربخشی به‌طور گسترده‌ای برای بخش‌بندی مشتریان استفاده شده است، اما این مدل فاقد بُعد حیاتی "طول عمر مشتری (L)" است. این کاستی باعث می‌شود نتوان به‌طور مؤثری بین مشتریان جدید با ارزش مالی بالا و مشتریان با سابقه و وفادار تمایز قائل شد. درحالی‌که هر دو گروه ممکن است در مدل RFM امتیاز مشابهی کسب کنند، استراتژی مورد نیاز برای نگهداشت آن‌ها کاملاً متفاوت است.

به‌ویژه در زمینه اپراتورهای مجازی تلفن همراه (MVNOs) که با منابع محدود در بازارهای پرقابلیت فعالیت می‌کنند، شناسایی و حفظ مشتریان با سابقه و با ارزش که "طول عمر" بالایی دارند، از اولویت استراتژیک برخوردار است. این مشتریان نه تنها پایدارتر هستند، بلکه هزینه نگهداری کمتری داشته است [۲۴].

از این رو، مدل LRFM با افزودن معیار «طول رابطه (L)» به سه معیار تازگی (R)، تکرار (F) و ارزش مالی (M)، یک چارچوب تحلیلی غنی‌تر و متناسب‌تر با اهداف این پژوهش فراهم می‌کند. این مدل امکان شناسایی گروه‌های حساس و باارزشی را فراهم می‌سازد که در مدل RFM استاندارد نادیده گرفته می‌شوند، از جمله:

- مشتریان بالقوه وفادار ($\uparrow L \uparrow R \downarrow F \uparrow M$): مشتریانی با سابقه طولانی و ارزش مالی بالا که اخیراً فعالیت نداشته‌اند و در معرض شدید ریزش هستند. هدف‌گیری این گروه با کمپین‌های بازگردانی برای یک MVNO بسیار مقرون‌به‌صرفه و حیاتی است.

- مشتریان وفادار تاریخی ($\uparrow L \uparrow R \uparrow F \uparrow M$): مشتریانی که در تمامی ابعاد عالی هستند و باید با برنامه‌های وفاداری ویژه حفظ شوند.

اگرچه مدل‌های پیچیده‌تر یادگیری ماشین (مانند خوشه‌بندی با ابعاد بالا) نیز قابل‌استفاده هستند، اما مدل LRFM تعادل بهینه‌ای بین قابلیت تفسیرپذیری بالا، سهولت پیاده‌سازی و عمق تحلیلی ارائه می‌دهد. خروجی این مدل به‌طور مستقیم و بدون نیاز به تفسیرهای پیچیده، به طراحی کمپین‌های بازاریابی هدفمند و قابل‌اجرا تبدیل می‌شود که این ویژگی برای کسب‌وکارهای عملیاتی مانند اپراتورهای مجازی بسیار مطلوب است [۲۵].

بر این اساس، مدل‌های گوناگونی برای قسمت‌بندی مشتریان پیشنهاد شده‌اند که در ادامه، با توجه به ارتباط آن‌ها با موضوع این پژوهش، مورد ارزیابی قرار خواهند گرفت.

۱-۳- مدل‌های تقسیم‌بندی مشتریان

۱-۱-۳- مدل RFM

مدل RFM یکی از ابزارهای رایج در تحلیل ارزش مشتری و بخش‌بندی مشتریان به شمار می‌رود. این مدل مبتنی بر رفتار مصرف‌کننده بوده و با بررسی الگوهای رفتاری مشتریان، آنان را در گروه‌های مختلف تقسیم‌بندی می‌کند [۴،۲۶].

مدل RFM شامل سه بُعد است: تازگی^۱، تعداد دفعات خرید^۲ و ارزش پولی خریدها^۳ که با ترکیب این سه، یک کد سه‌رقمی برای هر مشتری تولید می‌شود.

- تازگی خرید: مدت‌زمان گذشته از آخرین خرید مشتری (مثلاً به‌روز یا ماه).
- تکرار خرید: تعداد خریدهای انجام‌شده توسط مشتری در یک بازه زمانی مشخص.
- ارزش پولی خرید: مجموع مبلغ هزینه‌شده توسط مشتری در یک بازه زمانی معین یا میانگین هزینه هر خرید تا زمان

^۱ Recency

^۲ Frequency

^۳ Monetary Value

حاضر.

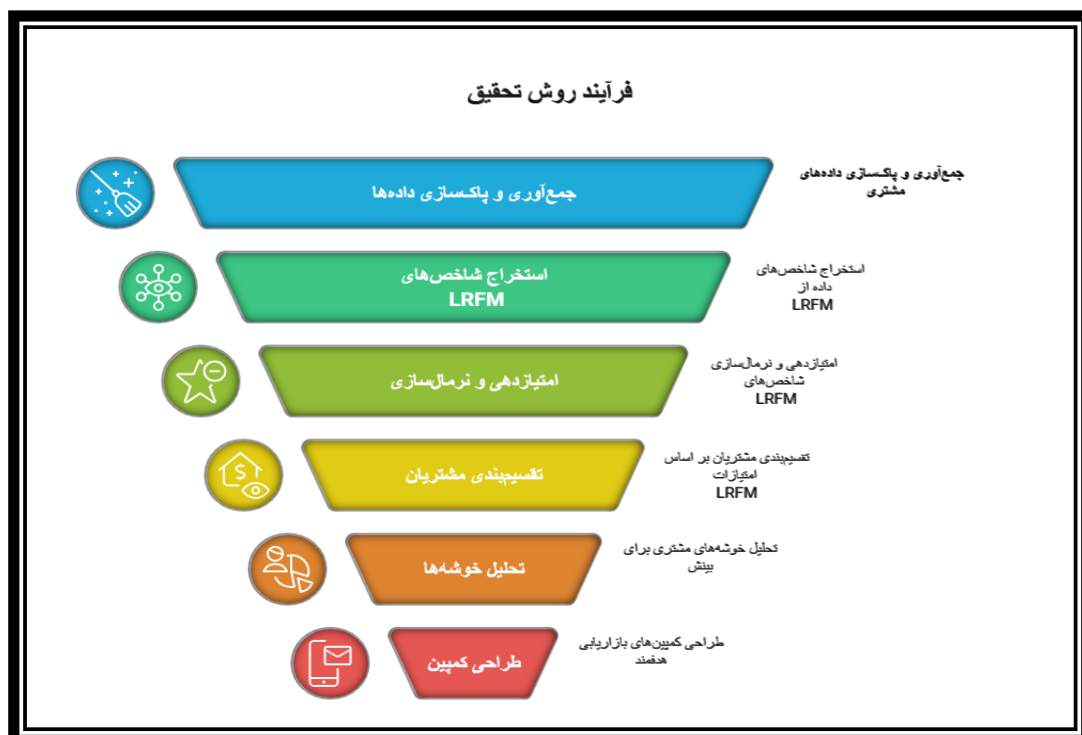
۳-۱-۲- مدل LRFM

برخی پژوهشگران معتقدند که مدل RFM قادر به تفکیک مؤثر بین مشتریانی با ارتباطات بلندمدت و مشتریان دارای تعاملات کوتاه‌مدت با شرکت نیست. این محققان، مفهوم "دوام رابطه مشتری" را پیشنهاد داده‌اند؛ چراکه افزایش طول مدت رابطه مشتری با شرکت، موجب افزایش نرخ حفظ مشتریان می‌شود. این متغیر، فاصله زمانی بین نخستین و آخرین خرید کاربر در دوره ثبت‌شده را نشان می‌دهد. مدت‌زمان رابطه مشتری، معمولاً با میزان اعتماد مشتری و سودآوری وی در ارتباط است. در این پژوهش، متغیر «طول رابطه» (L) به مدل RFM افزوده شده و به‌عنوان مدل LRFM برای بخش‌بندی مورد استفاده قرار می‌گیرد.

برای به‌کارگیری مدل LRFM در تحلیل رفتار مشتری، داده‌های مربوط به مشتریان بر اساس هر یک از ابعاد LRFM مرتب می‌شوند و سپس در پنج صدک مساوی تقسیم می‌گردند. برای متغیر Recency، پایگاه داده مشتریان بر اساس تاریخ خرید به‌صورت نزولی مرتب شده و بالاترین بخش، امتیاز ۵ دریافت می‌کند و به ترتیب، مقادیر ۴، ۳، ۲ و ۱ به سایر بخش‌ها اختصاص داده می‌شود [۲۷].

۳-۲- پیاده‌سازی مدل

هدف این مطالعه، بخش‌بندی مشتریان یکی از اپراتورهای مجازی تلفن همراه (MVNO) در ایران به گروه‌های متمایز است تا بتوان برای هر گروه بسته‌های اختصاصی طراحی کرد و از این طریق نرخ ریزش مشتریان کاهش یابد. در این شرکت، هر کاربر دارای یک پروفایل حاوی اطلاعاتی مانند جنسیت، تاریخ تولد، شماره عضویت، تعداد روزهای بین اولین و آخرین بازدید، و سایر ویژگی‌ها است. با توجه به اینکه در این تحقیق از مدل LRFM استفاده خواهد شد، فرایند بخش‌بندی مشتریان نیز بر اساس همین مدل و متغیرهای تعریف‌شده در آن صورت می‌گیرد.



شکل ۱ فرآیند روش تحقیق

۳-۲-۱- مفاهیم صنعت مخابرات

در صنعت مخابرات، اصطلاحات خاصی برای طبقه‌بندی و تحلیل رفتار مشترکین بر اساس میزان تعامل و فعالیت آن‌ها به کار می‌رود که در ادامه معرفی خواهند شد:



شکل ۲ اصطلاحات رایج مورد استفاده در صنعت مخابرات

۳-۲-۲- مدل LRFM در صنعت مخابرات

شاخص‌های خوشه‌بندی: در فرآیند حاضر، مشترکین با استفاده از چهار متغیر شامل مدت ارتباط^۱، تازگی فعالیت^۲، تعداد دفعات استفاده^۳ و ارزش مالی^۴ طبقه‌بندی می‌شوند. به‌عبارت‌دیگر، تقسیم‌بندی مشترکین بر اساس مدت‌زمان حضور در شبکه، تاریخ آخرین فعالیت، میزان مصرف و درآمد ایجادشده انجام می‌پذیرد.

¹ Latency

² Recency

³ Frequency


⁴ Monetary

مدت ارتباط	<ul style="list-style-type: none"> • مدت‌زمان حضور فعال مشترک در شبکه را نشان می‌دهد و بر حسب ماه بیان می‌شود. این شاخص با تقسیم اختلاف بین تاریخ فعال‌سازی و تاریخ آخرین فعالیت مشترک بر عدد ۳۰۰۵ محاسبه شده و نتیجه نهایی گرد (رُند) می‌شود. در صورتی که این مقدار کمتر از یک باشد، به‌صورت یک در نظر گرفته می‌شود.
تازگی فعالیت	<ul style="list-style-type: none"> • بیانگر مدت‌زمان گذشته از آخرین خرید مشترک، بر حسب روز است. این شاخص با محاسبه اختلاف بین تاریخ آخرین فعالیت و تاریخ خرید به‌دست می‌آید.
ارزش مالی	<ul style="list-style-type: none"> • نمایانگر مجموع ارزش مالی خریدهای مشترک، از جمله شارژ حساب و بسته‌های افزایشی است. در صورتی که بسته افزایشی از محل اعتبار حساب خریداری شود، درآمد آن فقط یک‌بار به‌عنوان درآمد ثبت می‌شود.
تعداد دفعات استفاده	<ul style="list-style-type: none"> • تعداد دفعات استفاده مشترک از خدمات صوتی و اینترنتی را در یک بازه زمانی مشخص نشان می‌دهد. برای محاسبه این شاخص، مجموع وزنی استفاده از خدمات اینترنت و تماس صوتی در نظر گرفته می‌شود؛ به‌طوری که وزن داده (اینترنت) برابر ۰.۶ و وزن تماس صوتی برابر ۰.۴ است.

شکل ۳ ابعاد مدل LRFM

۴- یافته‌های پژوهش

در این مطالعه، هدف شناسایی و تحلیل مشترکین یک شرکت اپراتور همراه مجازی می‌باشد. برای این منظور، نمونه‌ای از دارندگان حساب که سیم‌کارت خود را در سه‌ماهه نخست سال ۲۰۲۲ فعال کرده‌اند، گردآوری شده است. این بازه زمانی به‌گونه‌ای انتخاب شده تا از ابتدای سال ۲۰۲۴ (نقطه شروع این تحقیق) بیش از ۹۰ روز گذشته باشد، تا بتوان وضعیت ریزش (churn) این کاربران را ارزیابی و رفتار آنان را به‌درستی بررسی کرد. در ابتدا، این نمونه از مشترکین بر اساس وضعیت فعلی خود (تا تاریخ ۹ ژانویه ۲۰۲۴) و آخرین رفتارشان طبقه‌بندی خواهند شد.



شکل ۴ وضعیت اولیه مشترکین منتخب

شکل ۴ نشان می‌دهد که ۷۸٪ از مشترکین در دسته فعال (RGS) قرار دارند که از این میان، ۶۱٪ طی ۱۵ روز گذشته

فعالیت داشته‌اند. همچنین، ۸٪ طی ۱۵ تا ۳۰ روز، ۳٪ طی ۳۱ تا ۶۰ روز، و ۶٪ طی ۶۱ تا ۹۰ روز گذشته غیرفعال بوده‌اند. افزون بر این، ۲۲٪ از نمونه بیش از ۹۰ روز است که هیچ فعالیتی نداشته‌اند و عملاً به‌عنوان مشتریان ریزش‌یافته شناخته می‌شوند. شناسایی مشتریان با ارزش بالا از طریق مدل LRFM (طول رابطه، تازگی، تکرار و ارزش مالی) به شرکت‌های ارائه‌دهنده خدمات اینترنتی کمک می‌کند تا مهم‌ترین مشتریان خود را شناسایی کنند. مشتریانی که در شاخص‌های R (تازگی)، F (تکرار) و M (ارزش مالی) امتیاز بالایی دارند، معمولاً استفاده مکرر از خدمات داشته و هزینه بیشتری پرداخت می‌کنند. شناسایی این گروه به شرکت‌ها اجازه می‌دهد تا برنامه‌های وفاداری و پیشنهادات ویژه برای حفظ و تقویت رابطه با آنان طراحی کنند.

با استفاده از تحلیل LRFM، شرکت‌های MVNO می‌توانند استراتژی‌های بازاریابی خود را هدفمندتر تدوین کنند. برای مثال، مشتریانی که امتیاز پایینی در تازگی (R) دارند، ممکن است مدتی است از خدمات استفاده نکرده باشند. کمپین‌های بازاریابی برای جذب مجدد می‌توانند این گروه را هدف قرار دهند. ارائه تخفیف‌های اختصاصی یا پیشنهادات جذاب می‌تواند آن‌ها را به استفاده مجدد از خدمات ترغیب کند. یکی از مزایای اصلی مدل LRFM، کاهش نرخ ریزش مشتریان است. برای مثال، مشتریانی که در شاخص‌های تکرار (F) و ارزش مالی (M) امتیاز بالایی دارند، اما تازگی (R) آن‌ها پایین است، ممکن است در آستانه قطع استفاده از خدمات باشند. شرکت‌ها با اقدام سریع – مانند ارسال یادآور یا ارائه پیشنهادات ویژه – می‌توانند از ریزش این دسته جلوگیری کنند. از طریق تحلیل متغیر M (ارزش مالی)، سازمان‌ها می‌توانند استراتژی‌های قیمت‌گذاری خود را بهبود دهند. با شناسایی مشتریانی که بیشترین هزینه را پرداخت می‌کنند، می‌توان پیشنهادات ویژه برای آن‌ها طراحی کرد؛ مثلاً ارائه بسته‌های اینترنتی با تخفیف یا خدمات افزوده برای این گروه می‌تواند رضایت و وفاداری آن‌ها را افزایش دهد.

بهبود تجربه کاربری با تحلیل LRFM به شرکت‌ها این امکان را می‌دهد که نقاط ضعف را شناسایی کرده و خدمات خود را ارتقا دهند. برای نمونه، اگر مشتریانی با امتیاز پایین در شاخص تکرار (F) از خدمات خاصی استفاده نمی‌کنند، این ممکن است نشان‌دهنده نیاز به ارتقای تجربه کاربری یا تبلیغات هدفمندتر در آن حوزه باشد. چنین بهبودهایی می‌تواند رضایت مشتریان را افزایش داده و مشتریان جدید جذب کند.

در جدول زیر، سناریوهای مختلف در روش LRFM ارائه شده است.

جدول ۲ توصیف هر دسته در روش LRFM

متغیرهای مشتری	وضعیت نهایی	نماد LRFM	نوع مشتری	متغیرهای LR	متغیرهای FM
LRFM	فعال	L↑R↑F↑M↑	مشتریان وفادار و با ارزش بالا	نزدیک (فعال در دوره اخیر)	
RFM	فعال	L↓R↑F↑M↑	مشتریان جدید و با ارزش بالا	جذب‌شده (تازه‌وارد)	
LFM	غیرفعال یا ریزش‌یافته	L↑R↓F↑M↑	مشتریان بالقوه وفادار	بالقوه	بهترین‌ها (Best)
FM	غیرفعال یا ریزش‌یافته	L↓R↓F↑M↑	مشتریان ارزشمند از دست‌رفته	از دست‌رفته	
LRM	فعال	L↑R↑F↓M↑	مشتریان پلاتینیوم (ارزش بالا با تکرار کمتر)	نزدیک	
RM	فعال	L↓R↑F↓M↑	مشتریان تبلیغاتی با مصرف بالا	جذب‌شده	پرمصرف‌ها (Spender)
LM	غیرفعال یا ریزش‌یافته	L↑R↓F↓M↑	مشتریان بالقوه پرمصرف	بالقوه	
M	غیرفعال یا ریزش‌یافته	L↓R↓F↓M↑	مشتریان پرمصرف ریزش‌یافته	از دست‌رفته	
LRF	فعال	L↑R↑F↑M↓	مشتریان با تکرار بالا	نزدیک	پرتکرارها (Frequent)
RF	فعال	L↓R↑F↑M↓	مشتریان تبلیغاتی پرتکرار	جذب‌شده	

شناسه گروهی مشتری	وضعیت نهایی	نماد LRFM	نوع مشتری	متغیرهای LR	متغیرهای FM
LF	غیرفعال یا ریزش یافته	L↑R↓F↑M↓	مشتریان بالقوه پرتکرار	بالقوه	
F	غیرفعال یا ریزش یافته	L↓R↓F↑M↓	مشتریان پرتکرار ریزش یافته	از دست رفته	
LR	فعال	L↑R↑F↓M↓	مشتریان با هزینه پایین	نزدیک	
R	فعال	L↓R↑F↓M↓	مشتریان جدید نامطمئن	جذب شده	
L	غیرفعال یا ریزش یافته	L↑R↓F↓M↓	مشتریان با هزینه بالا ولی فعالیت کم	بالقوه	نامطمئن‌ها (Uncertain)
NON	غیرفعال یا ریزش یافته	L↓R↓F↓M↓	مشتریان نامطمئن ریزش یافته	از دست رفته	

با استفاده از جدول فوق، می‌توان به تحلیل تفاوت میان ۱۶ گروه مختلف از مشترکین بر اساس مدل LRFM پرداخت. این دسته‌بندی به شرکت‌ها کمک می‌کند تا بسته‌ها و راهبردهای متناسب‌تری برای تعامل با مشترکین خود انتخاب کنند.

ستون «نوع مشتری» (Type of Customer) ترکیب این چهار به چهار حالت را در ۱۶ سناریوی متفاوت خلاصه می‌کند. بر این اساس، مشتریان ابتدا در هر یک از چهار معیار Length, Recency, Frequency و Monetary امتیازدهی شدند. این امتیازدهی با استفاده از مقیاس لیکرت پنج‌درجه‌ای (Likert Scale: 1 تا ۵) انجام گرفت. جزئیات مربوط به نحوه امتیازدهی برای هر معیار در جدول زیر آورده شده است:

شامل مدت ارتباط، تازگی فعالیت، تعداد دفعات استفاده و ارزش مالی طبقه‌ب

جدول ۳ روش امتیازدهی برای هر یک از ۴ معیار در مدل LRFM

ارزش مالی	تعداد دفعات استفاده		تازگی فعالیت	مدت ارتباط	امتیازها
	میانگین استفاده از تماس صوتی	میانگین مصرف اینترنت (داده)	تعداد روز از آخرین فعالیت	ماه فعالیت	
< X IRR	< 5 Min	< 2 GB	90 +	<= 1	1
X - 3X IRR	5 - 10 Min	2 - 5 GB	61 - 90	2 < < 5	2
3X - 5X IRR	10 - 20 Min	5 - 7 GB	31 - 60	6 < < 10	3
5X - 7X IRR	20 - 60 Min	7 - 17 GB	15 - 30	11 < < 15	4
> 7X IRR	> 60 Min	> 17 GB	< 15	>= 16	5

جدول ۳، نحوه امتیازدهی به هر یک از چهار معیار مدل LRFM را بر اساس مقیاس لیکرت (Likert Scale) نشان می‌دهد. در خصوص معیار طول رابطه، اگر مدت‌زمان حضور یک مشترک در شبکه کمتر از یک ماه باشد، امتیاز ۱ دریافت می‌کند. در صورتی که این مدت بین دو تا پنج ماه باشد، امتیاز ۲ به آن اختصاص می‌یابد و این روند به همین ترتیب ادامه دارد تا حداکثر امتیاز ۵ که به مشترکینی تعلق می‌گیرد که بیش از ۱۶ ماه فعال بوده‌اند. لازم به ذکر است که بازه‌های این معیارها بر اساس توزیع درصدی رفتار مشترکین تعیین شده‌اند.

در ستون تازگی، مشترکینی که به‌طور کامل قطع ارتباط کرده‌اند (churned) امتیاز ۱ می‌گیرند، در حالی که آن‌هایی که طی ۱۵ روز گذشته فعالیت داشته‌اند، امتیاز ۵ دریافت می‌کنند. در معیار تکرار مصرف، میانگین مصرف دیتا و دقائق مکالمه در طول دوره حضور کاربر بررسی می‌شود. این معیار به‌صورت وزنی ارزیابی می‌شود: ۶۰ درصد وزن برای مصرف اینترنت و ۴۰ درصد برای مکالمه صوتی در نظر گرفته شده و در نهایت، میانگین وزنی گرد (round) می‌شود تا امتیاز نهایی مشخص گردد.

در خصوص معیار ارزش مالی، به دلیل محرمانه بودن اطلاعات مالی، از پارامتر فرضی X استفاده شده است، که واحد آن ریال ایران (IRR) می‌باشد. در این معیار، اگر میزان هزینه‌کرد مشترک کمتر از X باشد، امتیاز ۱ تعلق می‌گیرد و در صورت هزینه‌کرد

بیش از ۷ برابر X، امتیاز ۵ ثبت می شود.

با توجه به توضیحات و نظام امتیازدهی فوق، هر مشترک در یکی از دسته های LRFM قرار می گیرد. یک نمونه از این دسته بندی در جدول ۳ ارائه شده است. در این طبقه بندی، تنها معیارهایی که امتیاز ۳ یا بیشتر دارند، در نام گروه^۱ مشترکین لحاظ می شوند.

جدول ۴ نمونه ای از طبقه بندی مشتریان با استفاده از روش LRFM

کد شناسایی مشترک	L	R	F	M	خوشه
SID8201991_TS1672413342223_0	1	1	1	1	
SID6760039_TS1661865979560_0	1	4	1	2	R
SID12534714_TS1705765237183_0	5	5	5	2	LRF
SID13559456_TS1712125775494_0	4	4	2	1	LRF
SID8114139_TS1671863613651_0	5	5	2	3	LRFM
SID12135584_TS1704107502059_0	3	2	1	1	L
SID7517343_TS1668159963007_0	5	5	4	2	LRF
SID5358751_TS1646567175641_0	3	5	3	3	LRFM
SID12525584_TS1705740573774_0	3	5	1	1	LR
SID7530175_TS1668248559187_0	3	4	3	2	LRF
SID148678_TS1527184290104	5	5	3	3	LRFM
SID4272031_TS1632666794775_0	5	5	3	1	LRF
SID12569464_TS1705934775321_0	4	4	1	2	LR
SID8010655_TS1671261938476_0	1	2	1	1	
SID115466_TS1524369403333	4	5	3	3	LRFM
SID11124426_TS1697963712955_0	4	5	3	1	LRF
SID4791035_TS1639566027451_0	5	5	3	3	LRFM
SID5509067_TS1648305283905_0	3	2	3	1	L F
SID3994263_TS1627716201969_0	3	4	3	1	LRF
SID5216479_TS1644763916348_0	4	5	4	4	LRFM
SID11823481_TS1702280077524_0	5	5	4	2	LRF
SID4400809_TS1635235119608_0	5	5	3	5	LRFM
SID3152579_TS1609841347240_0	4	4	3	1	LRF

بر اساس جدول ۴، ستون Subscriber ID شناسه یکتای هر مشترک را نشان می دهد و ستون Cluster دسته بندی اختصاص یافته به هر مشترک را مشخص می سازد. این جدول نمونه ای از ۲۳ رکورد اولیه موجود در مجموعه داده اصلی است. اکنون، بر اساس هر یک از دسته های تعریف شده، تلاش خواهیم کرد بسته های پیشنهادی ویژه ای برای هر گروه از مشترکین طراحی کنیم.

این رویکرد موجب خواهد شد که مشترکین فعال به استفاده از خدمات ادامه داده و حتی مصرف خود را افزایش دهند، و در عین حال، مشترکین غیرفعال یا ریزش یافته (churned) نیز برای بازگشت به شبکه ترغیب شوند.

برای هر یک از دسته بندی های مشخص شده، بسته های پیشنهادی متناسب با ویژگی های آن گروه طراحی و ارائه شده که جزئیات آن در جدول زیر آمده است.

جدول ۵ بسته های پیشنهادی برای هر گروه


خوشه	شناسه بسته
None	Data_Portal_6MonthNonRw_Sum21_Data_03_NP
R	Data_Pre_3MonthlysNonRw_wint21_Data_01_PO1
LRF	Data_Pre_3MonthlysNonRw_wint21_Data_01_PO2
LRFM	Data_Pre_3MonthlysNonRw_wint21_Data_01_PO3
L	Data_Pre_3MonthlysNonRw_wint21_Data_01_PO4

¹ Category Name

شناسه بسته	خوشه
LR	Data_Pre_3MonthlysNonRw_wint21_Data_02_PO1
L F	Data_Pre_3MonthlysNonRw_wint21_Data_02_PO2
L FM	Data_Pre_3MonthlysNonRw_wint21_Data_02_PO3
R M	Data_Pre_3MonthlysNonRw_wint21_Data_02_PO4
F	Data_Pre_Monthly_Aut19_Combo_01_PO
RFM	Data_Pre_MonthlyNonRw_wint21_Combo_01_PO2
LR M	Data_Pre_MonthlyNonRw_wint21_Combo_01_PO3
L M	Data_Pre_MonthlyNonRw_wint21_Combo_01_PO4
M	Data_Pre_MonthlyNonRw_wint21_Data_01_PO1
RF	Data_Pre_MonthlyNonRw_wint21_Data_01_PO2
FM	Data_Pre_MonthlyNonRw_wint21_Data_01_PO3

همان‌طور که در جدول قبلی نشان داده شد، برای هر دسته از مشترکین، بسته‌ای معرفی شده است که شناسه (ID) آن نیز مشخص شده است. این بسته‌ها در دو مرحله، در تاریخ‌های ۲۲ ژانویه و ۲۷ ژانویه ۲۰۲۴، از طریق پیامک (SMS) به شماره هر مشترک ارسال شدند. به‌طور خاص، برای مشترکین ریزش‌یافته (Churned) که لینک را مشاهده نکرده بودند، پیامک مجدداً ارسال شد تا اطمینان حاصل شود که پیشنهاد به دست آن‌ها رسیده است.

بر اساس گزارش‌های به‌دست‌آمده پس‌از این کمپین پیامکی، نتایج جالب‌توجهی مشاهده شد که در ادامه به بررسی آن‌ها خواهیم پرداخت. در ابتدا، تغییرات ایجادشده را در نمودار ذیل ارائه می‌کنیم که درصد مشترکین در هر وضعیت را نشان می‌دهد.




شکل ۵ وضعیت مشترکین پس از ارسال بسته‌های پیشنهادی

همان‌طور که در شکل ۵ نشان داده شده است، تعداد مشترکین فعال با افزایشی قابل توجه حدود ۱۵٪ مواجه شده، در حالی که تعداد مشترکین غیرفعال^۱ و ریزش‌یافته به‌طور چشمگیری کاهش یافته است. علاوه بر این، حدود ۸٪ از مشترکینی که بیش از ۹۰ روز غیرفعال بودند، در نتیجه ارائه این بسته‌ها به شبکه بازگشتند. اجرای کمپین هدفمند مبتنی بر مدل LRFM، تأثیر قابل توجه و مثبتی بر ترکیب جمعیتی مشترکین داشته است. مطابق با هدف اصلی پژوهش، سهم مشترکین غیرفعال و ریزش‌یافته به‌طور چشمگیری کاهش یافته است. مهم‌تر آنکه، سهم مشترکین فعال با افزایشی حدود ۱۵ درصدی مواجه شده است. این رقم نه‌تنها از نظر آماری، بلکه از نظر کسب‌وکاری نیز بسیار معنادار است، چراکه به‌طور مستقیم به افزایش درآمد پایدار و کاهش

^۱ Dormant

هزینه‌های جیرانی منجر می‌شود. مشترکین غیرفعال و ریزش‌یافته). ارزیابی‌های اخیر در ماه‌های گذشته نشان داده است که به‌طور میانگین (در یک دوره شش‌ماهه)، میزان بازگشت به شبکه از هر دسته به‌صورت زیر و در نمودار بعدی نشان داده شده است:



شکل ۶ نرخ فعال‌سازی (بازگشت به شبکه) از دسته‌های مختلف غیرفعال و ریزشی

بر اساس شکل ۶، نرخ بازگشت به شبکه برای مشترکینی که بین ۱۵ تا ۳۰ روز غیرفعال بوده‌اند، حدود ۳۴٪ بوده است. در مقابل، برای مشترکینی که بیش از ۹۰ روز غیرفعال بوده‌اند یا به‌طور کامل از شبکه خارج شده‌اند، نرخ بازگشت تقریباً ۱۰٪ بوده است. این تحلیل نشان می‌دهد که ارائه بسته‌های پیشنهادی به مشترکینی که اخیراً شبکه را ترک کرده‌اند، در مقایسه با افرادی که مدت‌زمان طولانی‌تری غیرفعال بوده‌اند، اثربخشی بیشتری در بازگرداندن آن‌ها به شبکه دارد. تحلیل نرخ بازگشت به شبکه در گروه‌های مختلف مشترکین غیرفعال، الگوی معناداری را آشکار می‌سازد که نه‌تنها اثربخشی کمپین بازگردانی مبتنی بر مدل LRFM را تأیید می‌کند، بلکه بینش‌های استراتژیک ارزشمندی را برای مدیریت بهینه منابع در اختیار تصمیم‌گیران قرار می‌دهد.

مشترکینی که بین ۱۵ تا ۳۰ روز غیرفعال بوده‌اند، با بالاترین نرخ بازگشت (حدود ۳۴٪) مواجه شدند. این نتیجه، اهمیت حیاتی مداخله به‌موقع را در فرآیند نگهداشت مشتری نشان می‌دهد. این دسته از مشتریان هنوز در مرحله‌ای قرار دارند که ارتباطشان با برند به‌طور کامل قطع نشده و حافظه مصرفی آنان از خدمات اپراتور به‌راحتی قابل فعال‌سازی است. اقدام سریع پیش از آنکه الگوهای مصرفی آنان به‌طور کامل توسط رقبا تصاحب شود، مؤثرترین و مقرون‌به‌صرفه‌ترین راهکار برای جلوگیری از ریزش قطعی است.

در مقابل، نرخ بازگشت برای مشترکینی که بیش از ۹۰ روز غیرفعال بوده‌اند یا به‌طور کامل از شبکه خارج شده‌اند، به‌طور قابل‌توجهی پایین‌تر و در حدود ۱۰٪ اندازه‌گیری شد. اگرچه این نرخ در مقایسه با گروه قبلی کاهش چشمگیری دارد، اما از دو منظر دارای اهمیت راهبردی است: نخست، از منظر اقتصادی، حتی بازگرداندن ۱۰٪ از مشتریان کاملاً از دست‌رفته با در نظر گرفتن هزینه ناچیز اجرای کمپین‌های پیامکی از نظر نرخ بازگشت سرمایه (ROI) کاملاً توجیه‌پذیر باشد، چراکه هزینه جذب یک مشتری جدید به‌مراتب بالاتر است. دوم، از منظر شناختی مشتری، افرادی که با وجود قطع رابطه طولانی‌مدت بازمی‌گردند، معمولاً مشتریانی با "وابستگی ساختاری یا عاطفی نهفته" هستند، مانند دل‌بستگی به شماره تلفن یا رضایت تاریخی بسیار بالا، که آنان را به کاندیداهای ایده‌آل برای برنامه‌های وفاداری بلندمدت تبدیل می‌کند.

۵- بحث و نتیجه‌گیری

این تحلیل بر ضرورت حیاتی تدوین راهبردهای مؤثر برای مدیریت ریزش مشتری در بخش مخابرات، به‌ویژه در مورد

اپراتورهای مجازی شبکه تلفن همراه (MVNO) ها تأکید دارد. با وجود پیشرفت‌های چشمگیر در سیستم‌های مدیریت مشتری و تکنیک‌های پیش‌بینی ریزش، نتایج به‌دست‌آمده نشان‌دهنده نیاز فوری به اتخاذ راهکارهای سفارشی‌شده‌ای است که به‌طور خاص چالش‌های منحصربه‌فرد MVNO ها را در بازارهای اشباع‌شده هدف قرار دهند.

با استفاده از مدل بخش‌بندی LRFM، این پژوهش نشان داد که یک طبقه‌بندی پیشرفته از مشترکین می‌تواند به‌طور چشم‌گیری توانایی اپراتورهای مجازی شبکه تلفن همراه (MVNO) ها را در شناسایی مشتریان باارزش و اجرای فعالیت‌های بازاریابی هدفمند بهبود بخشد. یافته‌های به‌دست‌آمده نشان می‌دهند که این نوع دسته‌بندی امکان طراحی بسته‌های خدماتی منحصربه‌فردی را فراهم می‌کند که نه تنها خطر از دست دادن مشتریان را کاهش می‌دهد، بلکه در بلندمدت باعث افزایش وفاداری آنان نیز می‌شود.

علاوه بر این، نتایج واقعی ارائه‌شده در این تحقیق، اثربخشی قابل توجه اقدامات تبلیغاتی طراحی‌شده به‌صورت راهبردی را در فعال‌سازی مجدد مشترکین غیرفعال و ریزشی نشان می‌دهد. افزایش مشاهده‌شده در نرخ بازگشت، به‌ویژه در میان مشتریانی که اخیراً غیرفعال شده‌اند، این فرضیه را تقویت می‌کند که ارائه پیشنهادهای به‌موقع و مرتبط می‌تواند به‌طور قابل توجهی مشارکت مشتریان را افزایش دهد.

در نتیجه، این تحقیق به گفتمان مستمر پیرامون راهبردهای مدیریت ریزش مشتری در بخش مخابرات، به‌ویژه برای اپراتورهای مجازی شبکه تلفن همراه (MVNO) ها، کمک شایانی می‌کند. با بهره‌گیری از مدل بخش‌بندی LRFM، این پژوهش نشان می‌دهد که طبقه‌بندی دقیق مشترکین می‌تواند به‌طور چشمگیری توانایی MVNO ها را در شناسایی مشتریان باارزش افزایش دهد.

یافته‌ها حاکی از آن است که این نوع طبقه‌بندی امکان طراحی بسته‌های خدماتی سفارشی را فراهم می‌سازد؛ بسته‌هایی که نه تنها ریسک ریزش مشتری را کاهش می‌دهند، بلکه زمینه‌ساز تقویت وفاداری بلندمدت مشتریان نیز هستند. این رویکرد مبتنی بر داده، مسیری کاربردی برای بهینه‌سازی راهبردهای بازاریابی و حفظ مشتری در فضای رقابتی صنعت مخابرات ترسیم می‌کند. علاوه بر این، نتایج عملی ارائه‌شده در این مطالعه، اثربخشی تلاش‌های تبلیغاتی هدفمند را در بازفعال‌سازی مشتریان غیرفعال و ریزشی به‌خوبی نشان می‌دهد. افزایش نرخ بازگشت به شبکه، به‌ویژه در میان مشتریانی که به‌تازگی غیرفعال شده‌اند، گویای آن است که ارائه پیشنهادهای به‌موقع و مرتبط می‌تواند مشارکت مشتری را به‌طور قابل توجهی افزایش دهد.

این بینش‌ها نه تنها برای اپراتورهای (MVNO) ها، بلکه برای اپراتورهای سنتی تلفن همراه و حتی سایر صنایع مواجه با چالش‌های مشابه ریزش مشتری نیز چارچوبی کاربردی و قابل‌تعمیم ارائه می‌دهد. پیشنهاد می‌شود که در پژوهش‌های آتی، تأثیرات بلندمدت این راهبردهای نگهداشت مشتری بر وفاداری و عملکرد مالی شرکت‌های مخابراتی مورد بررسی قرار گیرد. همچنین، ترکیب تحلیل‌های پیش‌بینی‌پذیر پیشرفته با شیوه‌های تعامل با مشتری می‌تواند به بهینه‌سازی بیشتر این راهکارها کمک کند.

بر اساس یافته‌های این مقاله، چندین پیشنهاد برای MVNO ها جهت تقویت رضایت و کاهش ریزش مشتری ارائه می‌شود، از جمله:

- ✓ توسعه مدل‌های نوین طبقه‌بندی مشترکین با استفاده از تکنیک‌های یادگیری ماشین؛
- ✓ بهره‌گیری از سیستم‌های پیشنهاددهنده مبتنی بر هوش مصنوعی برای طراحی بسته‌های خدماتی شخصی‌سازی‌شده؛
- ✓ اجرای کمپین‌های بازاریابی پویا مبتنی بر تحلیل لحظه‌ای رفتار مشتریان؛
- ✓ و سرمایه‌گذاری در زیرساخت‌های داده‌محور برای تقویت تصمیم‌گیری‌های استراتژیک.

۶- منابع و مأخذ

- [1] Gordini N, Veglio V. Customers churn prediction and marketing retention strategies: Application of SVM using AUC parameter selection in B2B e-commerce. *Industrial Marketing Management*. 2017; 62: 100–107.
- [2] Sulikowski P, Zdziebko T. Churn factors identification in telecom. *Procedia Computer Science*. 2021; 192: 4800–4809.
- [3] Xu T, Ma Y, Kim K. Telecom churn prediction based on ensemble learning using feature grouping. *Applied Sciences*. 2021; 11(11): 4742.
- [4] Ahmad AK, Jafar A, Aljoumaa K. Customer churn prediction in telecom using machine learning in big data platform. *Journal of Big Data*. 2019; 6(1): 1–24.
- [5] Tatikonda LU. The hidden costs of customer dissatisfaction. *Management Accounting Quarterly*. 2013; 14: 34.
- [6] Khajvand M. Estimating customer lifetime value based on RFM analysis: Case study. *Procedia Computer Science*. 2011; 3: 57–63.
- [7] Zhuang Y. Customer churn prediction using improved value model and XG-Boost. *Management Science and Engineering*. 2018; 12(3): 51–56.
- [8] Stehani S, Karunya N, Ranjan D, Sumathipala S, Sandanayake T. Customer churn reasoning in telecom. *ICIP 2020*; 1–5.
- [9] Zhang Y, Qi J, Shu H, Cao J. A hybrid KNN-LR classifier for customer churn prediction. *IEEE SMC*. 2007; 3265–3269.
- [10] Raeisi S, Sajedi H. Customer churn prediction using gradient boosted trees. *ICCKE 2020*; 055–059.
- [11] Hamdi K, Zamiri A. Identifying and segmenting customers through RFM. *International Business Management*. 2016; 10(18): 4209–4214.
- [12] Huang B, Kechadi MT, Buckley B. Customer churn prediction in telecommunications. *Expert Systems with Applications*. 2012; 39(1): 1414–1425.
- [13] Saxena A, Agarwal A, Pandey BK, Pandey D. Examination of the criticality of customer segmentation using unsupervised learning methods. *Circular Economy and Sustainability*. 2024; 4(2): 1447–1460.
- [14] Wu S, Yau W, Ong T, Chong S. Integrated churn prediction and segmentation for telco. *IEEE Access*. 2021; 9: 62118–62136.
- [15] Xiahou X, Harada Y. E-commerce churn prediction based on K-means and SVM. *JTAECR*. 2022; 17: 458–475.
- [16] Khalili-Damghani K, Abdi F, Abolmakarem S. Hybrid soft computing approach for customer segmentation. *Applied Soft Computing*. 2018; 73: 816–828.
- [17] Owczarczuk M. Churn models for prepaid customers in telecom. *Expert Systems with Applications*. 2010; 37: 4710–4712.
- [18] Babaiyan V, Sarfarazi SA. Analyzing customers with LRFM model. *Journal of AI and Data Mining*. 2019; 7(2): 331–340.
- [19] Gordini N, Veglio V. Customers churn prediction and marketing retention strategies: Application of SVM using AUC parameter selection in B2B e-commerce. *Industrial Marketing Management*. 2017; 62: 100–107.
- [20] Cooil B, Aksoy L, Keiningham TL. Approaches to customer segmentation. *Journal of Relationship Marketing*. 2008; 6(3-4): 9–39.
- [21] Schwenke C, Koller M, Wenzel S. Simulation and analysis of buying behavior in supermarkets. *IEEE ETFA*. 2010; 1–4.
- [22] Griva A, Kourentzes N, Petropoulos F. Retail business analytics: Customer visit segmentation using market basket data. *Expert Systems with Applications*. 2018; 100: 1–16.

- [23] Hu YH, Yeh TW. Discovering valuable frequent patterns based on RFM analysis without customer identification information. *Knowledge-Based Systems*. 2014; 61: 76–88.
- [24] International Telecommunication Union. *Global telecommunications report*. ITU; 2021.
- [25] Joshi A, Gupta S, Joshi R. Design analysis of purchasing behavior of customers in supermarkets using TRFM model. *International Journal of Innovative Research in Computer and Communication Engineering*. 2016; 4(4): 7799–7806.
- [26] Morozov V, Mezentseva O, Kolomiiets A, Proskurin M. Predicting customer churn using machine learning in IT startups. *Lecture Notes in Computational Intelligence and Decision Making*. Springer; 2022: 645–664.
- [27] Poudel SS, Pokharel S, Timilsina M. Explaining customer churn prediction in telecom using tabular machine learning models. *Machine Learning with Applications*. 2024; 17: 100567.
- [28] Tauni S, Khan RI, Durrani MK, Aslam S. Impact of CRM on customer retention in telecom industry of Pakistan. *Industrial Engineering Letters*. 2014; 4(10): 54–59.
- [29] Xia G, He Q. Online shopping customer churn prediction based on integrated learning. *MECAE 2018*. Atlantis Press; 2018: 259–267.
- [30] Zhang T, Moro S, Ramos RF. A data-driven approach to improve customer churn prediction based on telecom customer segmentation. *Future Internet*. 2022; 14(3): 94.
- [31] Cheng CH, Chen YS. Segmenting customer value using RFM and RS theory. *Expert Systems with Applications*. 2009; 36(3): 6005–6011.
- [32] Jha N, Parekh D, Mouhoub M, Makkar V. Customer segmentation and churn prediction in online retail. *Advances in Data Science and Management*. 2020: 328–334.
- [33] Joshi A, Gupta S, Joshi R. Design analysis of purchasing behavior using TRFM model. *IJIRCCE*. 2016; 4(4): 7799–7806.
- [34] Khamlichi FI, Zaim D, Khalifa K. Hybrid ML model for customer churn prediction. *ICDS 2019*: 1–4.
- [35] Margianti ES, et al. Affinity propagation and RFM model for CRM analysis. *JTAIT*. 2016; 84(2): 272–282.
- [36] Murray PW, Agard B, Barajas MA. Market segmentation through data mining. *Computers Industrial Engineering*. 2017; 109: 233–252.
- [37] Pamina J, Raja B, SathyaBama S, Sruthi M, VJ A. Classifier for predicting churn in telecom. *JARDC Systems*. 2019; 11.
- [38] Rachid AD, Abdellah A, Belaid B, Rachid L. Churn prediction in e-commerce. *International Journal of Electrical and Computer Engineering*. 2018; 8(4): 2367.
- [39] Zadoo A, Jagtap T, Khule N, Kedari A, Khedkar S. Review on churn prediction and customer segmentation using ML. *COM-IT-CON 2022*; 174–178.