https://nmrj.ui.ac.ir/
New Marketing Research Journal
E-ISSN: 2228- 7744
Vol. 16, Issue 4, No.63, 2026
Document Type: Research Paper
Received: 19/04/2026 Accepted: 22/08/2026

Application of Incremental Learning in Customer Churn Prediction: A Comparative Study of Logistic Regression and Multi-Layer Perceptron Neural Network

Hossein Norouzi *
Associate professor, Department of Business Management, Faculty of Management, Kharazmi University, Tehran, Iran
norouzi@khu.ac.ir

Zahra Roshanazadeh
Ph.D. candidate in Business Management, Department of Business Management, Faculty of Management, Kharazmi University, Tehran, Iran
faezeroshan66@gmail.com

Abstract
Customer churn prediction is a strategic necessity in today's competitive markets, particularly in industries with high customer lifetime value, such as the automotive sector. This study presented a time-aware incremental learning framework for churn prediction and systematically compared Logistic Regression with a Multi-Layer Perceptron (MLP) neural network. Using real-world historical data from an automobile dealership in Mashhad, Iran, the target variable "churn" was operationally defined as 150 days of customer inactivity. After integrating demographic, transactional, and behavioral features, an expanding window strategy was employed across 5 temporal stages to simulate dynamic operational environments and prevent temporal data leakage. Results demonstrated the consistent and significant superiority of Logistic Regression over MLP across all stages with an average F1-score of 0.834 and ROC-AUC of 0.955. The findings indicated that in the Iranian automotive industry context, a simple, interpretable model within an incremental learning framework provided a more practical, stable, and reliable solution for timely churn prediction than complex non-linear alternatives, enabling targeted customer retention interventions.

Keywords: Customer Churn, Incremental Learning, Expanding Window, Logistic Regression, Multi-Layer Perceptron, Automotive Industry.

Introduction
In contemporary business environments, retaining existing customers is considerably less costly and more profitable than acquiring new ones (Sanches et al., 2024; Lalwani, 2021). Research demonstrates that a 5% increase in customer retention can enhance profits by 25% to 95% (Saleh & Saha, 2023). Customer churn—the phenomenon whereby customers discontinue their relationships with businesses (Singh et al., 2024)—has

*Corresponding author
Norouzi, H. and Roshan Azadeh, Z. (2026). Application of Incremental Learning in Customer Churn Prediction: A Comparative Study of Logistic Regression and Multi-Layer Perceptron Neural Network.. *New Marketing Research Journal*, 16 (4), 157 - 182 .

2228-7744 © The Author(s). Published by University of Isfahan
This is an open access article under the CC BY-NC 4.0 License (https://creativecommons.org/licenses/by-nc/4.0).

10.22108/nmrj.2026.148686.3324

therefore become a critical concern requiring proactive prediction and management (Boozary et al., 2025). While extensive churn prediction research has focused on telecommunications and banking (Saleh & Saha, 2023; Singh et al., 2024), the automotive industry has received limited attention (Swapnil et al., 2025), despite churn directly impacting profitability and brand loyalty. Furthermore, a critical methodological challenge is frequently overlooked: the inherent time-dependent nature of customer's behavioral data. Static evaluation methods like random splitting cause temporal data leakage, yielding unrealistically optimistic performance estimates (Bergmeir & Benítez, 2012; Alboukaey et al., 2020). This study addressed these gaps by proposing a time-aware incremental learning framework for churn prediction in the Iranian automotive industry, systematically comparing Logistic Regression (as an interpretable linear model) with Multi-Layer Perceptron (as a complex non-linear model) to identify the most efficient and stable approach for dynamic operational environments.

Literature Review

Customer churn, alternatively termed customer attrition or defection, occurs when customers voluntarily terminate their relationships with service providers (Lappeman et al., 2022). Churn prediction models utilize historical customer data to identify patterns and factors associated with future defection (Sanches et al., 2024). Previous studies have employed various machine learning algorithms across different industries. Singh et al. (2024) achieved 78.3% accuracy using Random Forest (RF) in banking, while Suh (2023) reported 90% accuracy with LightGBM in home appliance rental. Khodabandehlou and Zivari Rahman (2017) demonstrated that neural networks achieved 97.92% accuracy in retail by extending RFM models with behavioral features. In the automotive sector, Swapnil et al. (2025) identified customer satisfaction and purchase frequency as key churn predictors. However, most studies neglect temporal dependencies in customer data. Alboukaey et al. (2020) emphasized that ignoring temporal patterns causes delayed predictions, while Bergmeir and Benítez (2012) demonstrated that random cross-validation invalidates fundamental assumptions for time-series data. Hyndman and Athanasopoulos (2018) proposed expanding window strategies for time-aware evaluation. Despite these methodological advances, no study has systematically compared algorithms within incremental learning frameworks for automotive churn prediction, particularly in emerging markets like Iran.

Materials & Methods

This research employed a phased, time-aware framework using real-world data from an automobile dealership in Mashhad, Iran, with brand identity protected for confidentiality. Following expert consultation and company guidelines, "churn" was operationally defined: customers were labeled "churned" (1) if the interval between their last transaction and the cut-off date (November 20, 2025) exceeded 150 days; otherwise, they were classified as "active" (0). Transactions after this cut-off were removed to prevent temporal leakage. Demographic and transactional datasets were merged by using unique customer identifiers. Numerical features were used directly; low-cardinality categorical variables (e.g., gender) were label-encoded; high-cardinality variables (e.g., service names) were transformed into 384-dimensional semantic embeddings using a pre-trained SentenceTransformer model ('all-MiniLM-L6-v2'). To simulate dynamic operational environments, an expanding window strategy was implemented. Customers were chronologically sorted by first transaction date. The initial training set comprised customers with a first transaction before January 1, 2025. Test data was partitioned into 5 sequential windows. Across 5 incremental stages, models were trained on expanding sets (initial training plus previous test windows) and evaluated on subsequent unseen windows. Logistic Regression (with L2 regularization) and a Multi-Layer Perceptron neural network were compared by using Accuracy, Precision, Recall, F1-score, and ROC-AUC.

Research Findings

The findings revealed consistent and significant superiority of the Logistic Regression model over the MLP neural network across all five incremental learning stages. Logistic Regression achieved an average F1-score of 0.834 and ROC-AUC of 0.955, with both metrics demonstrating clear upward trends as training data volume progressively increased. The model successfully maintained high and balanced Recall and Precision throughout all stages, indicating exceptional effectiveness in correctly identifying genuinely churned customers while minimizing costly false alarms. Confusion matrices visually confirmed this improvement, showing substantial reduction in false negatives—the most consequential error type in churn prediction while representing missed retention opportunities—as learning advanced. In contrast, the MLP model exhibited highly volatile and unstable performance across temporal stages. Despite achieving notably high Recall in certain individual stages, its Precision remained consistently low, resulting in a much lower average F1-score of only 0.568. The average

ROC-AUC for MLP was also significantly inferior at 0.629, and critically, in the final incremental stage, while its ROC-AUC deteriorated to approximately 0.5, indicating performance no better than random guessing. This pattern strongly suggested a pronounced tendency for the complex MLP model to overfit the training data, particularly given the incrementally expanding but still limited dataset characteristic of real-world operational environments.

Discussion of Results & Conclusion

The primary finding was the consistent superiority of Logistic Regression over MLP across all incremental stages. Despite expectations that complex models might outperform simpler alternatives, the results demonstrated that in the dynamic Iranian automotive context, a simple, interpretable model like Logistic Regression provided a more practical and reliable solution for timely churn prediction. The strong performance suggested that the relationship between customer features and churn was predominantly linear and separable. The stability of Logistic Regression with increasing data highlighted its suitability for operational environments requiring regular updates. MLP's instability indicated that its complexity was unnecessary without extensive tuning and larger datasets. These findings align with those of Swapnil et al. (2025) on the effectiveness of simple models in automotive contexts and Aghakhani et al. (2023), demonstrating that interpretable models can outperform complex alternatives in specific contexts. However, they contrast with studies identifying neural networks as superior in retail (Khodabandehlou & Zivari Rahman, 2017), emphasizing that optimal algorithm selection is context-dependent. This research contributes methodologically as one of the first applications of incremental learning to Iranian automotive churn prediction, demonstrating the importance of time-aware validation. Managerially, the framework provides dealership managers with an evidence-based tool for proactive retention interventions. By identifying high-risk customers, limited resources can be allocated to personalized campaigns, enhancing retention and strengthening competitive positioning.

تحقیقات بازاریابی نوین
سال شانزدهم، شماره چهارم، شماره پیاپی (۶۳) ۱۴۰۵
تاریخ دریافت: ۱۴۰۵/۱/۳۰ تاریخ پذیرش: ۱۴۰۵/۵/۳۱
ص: ۱۸۲- ۱۵۷

مقاله پژوهشی

کاربرد یادگیری افزایشی در پیش‌بینی روی‌گردانی مشتریان: مقایسهٔ رگرسیون لجستیک با شبکهٔ عصبی پرسپترون چندلایه

حسین نوروزی * [۱]، **زهرا روشن‌آزاده** [۲]

۱- دانشیار گروه مدیریت بازرگانی، دانشکده مدیریت، دانشگاه خوارزمی، تهران، ایران
norouzi@khu.ac.ir
۲- دانشجوی دکتری مدیریت بازاریابی، دانشکده مدیریت، دانشگاه خوارزمی، تهران، ایران
faezeroshan66@gmail.com

چکیده

در فضای رقابتی، امروزه در صنایع مختلف، حفظ مشتریان موجود به‌مراتب کم‌هزینه‌تر و سودآورتر از جذب مشتریان جدید است؛ ازاین‌رو، پیش‌بینی به‌هنگام روی‌گردانی مشتریان به ضرورتی راهبردی تبدیل شده است. این مطالعه با هدف ارائه و ارزیابی یک چارچوب نوآورانهٔ یادگیری افزایشی، برای پیش‌بینی روی‌گردانی مشتریان و انجام مقایسه‌ای نظام‌مند بین مدل رگرسیون لجستیک و شبکهٔ عصبی پرسپترون (MLP) چندلایه انجام شد. بدین منظور، با به‌کارگیری داده‌های واقعی و بر اساس تاریخ مراجعه یک نمایندگی خودرو در شهر مشهد که حجم نمونهٔ آن مشتمل بر ۴۷,۰۸۲ تراکنش متعلق به ۳,۶۸۴ مشتری یکتا بود ضمن رعایت اصل محرمانگی برند، متغیر هدف «روی‌گردانی» تعریف شد. پس‌از ادغام و مهندسی ویژگی‌های جمعیت‌شناختی، تراکنشی و رفتاری از چارچوب یادگیری افزایشی، راهبرد پنجرهٔ گسترش‌یابنده (Expanding Window) در پنج مرحله برای شبیه‌سازی محیط عملیاتی و جلوگیری از نشت اطلاعات زمانی استفاده شد. یافته‌های عددی نشان می‌دهد که مدل رگرسیون لجستیک در این مجموعه داده، به‌طور میانگین در تمام مراحل، عملکرد عددی بهتری نسبت به مدل MLP داشته است: معیار F1-score ۰.۸۳۴ در مقابل ۰.۵۶۸؛ سطح زیر منحنی ROC ۰.۹۵۴ در مقابل ۰.۶۲۸۶، بااین‌حال، با توجه به چارچوب ارزیابی، این نتایج را نمی‌توان به‌عنوان برتری مطلق مدل تعبیر کرد و تعمیم آن به سایر داده‌ها نیازمند بررسی‌های تکمیلی است. این پژوهش نشان می‌دهد که در محیط پویای صنعت خودرو، به‌کارگیری چارچوب یادگیری افزایشی زمان‌محور همراه با مدلی ساده و تفسیرپذیر، مانند رگرسیون لجستیک، راه‌حلی عملی و مؤثر برای پیش‌بینی به‌هنگام روی‌گردانی مشتریان ارائه می‌دهد و چارچوبی مبتنی‌بر داده برای طراحی مداخلات هدفمند حفظ مشتری و تخصیص بهینهٔ منابع بازاریابی و خدمات پس‌ازفروش در اختیار مدیران صنعت خودرو قرار می‌دهد.

کلید واژه‌ها: روی‌گردانی مشتریان، یادگیری افزایشی، پنجرهٔ گسترش‌یابنده، رگرسیون لجستیک، شبکهٔ عصبی پرسپترون چندلایه.

---

* نویسنده مسئول

نوروزی، حسین و روشن‌آزاده، زهرا . (۱۴۰۵). کاربرد یادگیری افزایشی در پیش‌بینی رویگردانی مشتریان: مقایسه رگرسیون لجستیک با شبکه عصبی پرسپترون چندلایه، *تحقیقات بازاریابی نوین*، ۱۶ (۴)، ۱۵۷- ۱۸۲ .

2228-7744 © The Author(s). Published by University of Isfahan
This is an open access article under the CC BY-NC 4.0 License (https://creativecommons.org/licenses/by-nc/4.0).

10.22108/nmrj.2026.148686.3324

۱. مقدمه

در عصر دیجیتال، مدیریت ارتباط با مشتری به یک مزیت رقابتی راهبردی تبدیل شده است. در این میان، با توجه به هزینه‌های فزاینده و هنگفت جذب مشتریان جدید (Sanches et al., 2025)، راهبرد «حفظ مشتری» به کانون اصلی تلاش‌های بازاریابی مدرن بدل شده است (Geiler et al., 2022). پشتوانهٔ این تحول، دسترسی بی‌سابقه شرکت‌ها به کلان‌داده‌ها و فناوری‌های تحلیلی است که درک عمیق‌تری از رفتار پیچیدهٔ مشتریان را ممکن ساخته است (Nanji, 2024). مطالعات نشان می‌دهند که افزایش ۵درصدی شاخص حفظ مشتری می‌تواند سودآوری شرکت‌ها را بین ۲۵ تا ۹۵درصد افزایش دهد (Saleh & Saha, 2023). افزون‌بر این، مشتریان وفادار ازطریق تبلیغات توصیه‌ای مثبت، ارزش افزودهٔ چشمگیری برای برند ایجاد می‌کنند (Geiler et al., 2022). این موضوع سبب شده است که درک رفتار مشتری و پیش‌بینی به‌هنگام روی‌گردانی، به ضرورتی راهبردی برای کسب‌وکارها تبدیل شود.

روی‌گردانی مشتری، پدیده‌ای است که در آن، مشتریان به رابطهٔ خود با برند یا سازمان پایان می‌دهند. میزان افزایش خروج مشتریان اغلب نشان‌دهندهٔ مشکلات بنیادینی همچون تجربهٔ ضعیف مشتری، فرایندهای ناکارآمد یا کمبود محصولات رقابتی است که به تصویر و اعتبار برند آسیب می‌زند (Singh et al., 2024)؛ ازاین‌رو، مدیریت روی‌گردانی، به مفهوم شناسایی پیش‌دستانهٔ مشتریانی است که قصد مراجعه به رقبا را دارند (Saleh & Saha, 2023). تحلیل روی‌گردانی، کسب‌وکارها را در شناسایی دلایل کلیدی ریزش و تدوین راهبردهای مؤثر برای بهبود حفظ و رضایت مشتری یاری می‌کند (Boozary et al., 2025). با پیش‌بینی مشتریان در معرض ریزش، سازمان‌ها می‌توانند اقدامات پیشگیرانه‌ای نظیر بازاریابی شخصی‌سازی‌شده و پیشنهادهای ارزش‌محور را طراحی کنند که در نهایت به رشد کسب‌وکار و ارتقای تجربهٔ مشتری منجر می‌شود (Boozary et al., 2025).

در سال‌های اخیر، تحلیل تصمیم‌گیری‌های مصرف‌کننده از تاکتیک‌های مبتنی‌بر شهود به رویکردهای مبتنی‌بر داده تغییر یافته است (Nanji, 2024). داده‌های متنوعی ازجمله سوابق تراکنش‌ها، الگوهای رفتاری و بازخورد مشتریان، بستری را برای استخراج بینش‌های عمیق دربارهٔ ترجیحات و رفتار مشتریان فراهم می‌آورند (Boozary et al., 2025). بدین‌ترتیب، رویکردهای تحلیلی از تحلیل گذشته‌نگر «چه اتفاقی افتاد؟» به‌سوی مدل‌های پیش‌بینی‌کننده «چه کسی در شرف ترک است؟» حرکت کرده‌اند (Nanji, 2024). مدل‌های یادگیری ماشین با تحلیل داده‌های مبتنی بر تاریخ مراجعه، می‌توانند الگوهای مرتبط با ریزش و پیش‌بینی مشتریان در معرض خطر را شناسایی کنند (Boozary et al., 2025). چنین رویکرد پیشگیرانه‌ای، سازمان‌ها را در طراحی کمپین‌های هدفمند و ارائهٔ خدمات پیشرفته‌تر برای کاهش ریسک ریزش یاری می‌کند (Boozary et al., 2025).

باوجود گسترش پژوهش‌ها در حوزهٔ پیش‌بینی روی‌گردانی مشتریان، تمرکز غالب مطالعات بر صنایعی نظیر مخابرات، خدمات مالی و بانکداری اینترنتی بوده است (Ehsani & Hosseini, Saleh & Saha, 2023; Lalwani, 2022 (2025). در مقابل، پژوهش‌های اندکی در صنعت خودرو انجام شده است (Chaodhari & Gade, 2025). این درحالی است که این صنعت با چالش‌هایی نظیر دیجیتالی شدن و تغییرات پساکرونا، نیازمند ارتقای سیستم‌های مدیریت ارتباط با مشتری و بهره‌گیری از داده‌های مشتریان برای بهبود کیفیت

تعاملات است (Hu & Basiglio, 2023). در ایران نیز مطالعات محدودی با به‌کارگیری رویکردهای داده‌کاوی به پیش‌بینی روی‌گردانی مشتریان در صنعت خودروسازی پرداخته‌اند، به‌ویژه پژوهش‌هایی که ویژگی‌های منحصربه‌فرد رفتاری، اقتصادی و ساختار رقابتی این بازار را لحاظ کرده باشند. این خلأ، مانع از آن شده است که شرکت‌های خودروسازی ایرانی بتوانند از بینش‌های داده‌محور برای کاهش میزان ریزش مشتریان و حفظ سهم بازار خود در محیطی با رقابتی روبه‌افزایش بهره‌مند شوند.

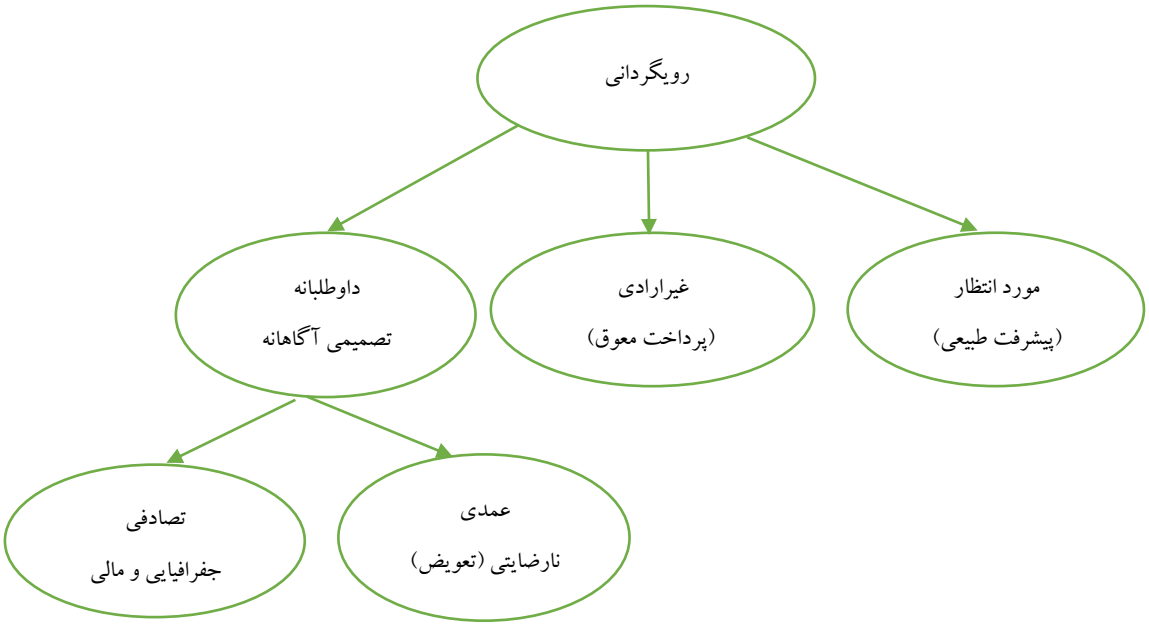
افزون‌بر کمبود پژوهش در صنعت خودرو، بسیاری از مدل‌های پیش‌بینی روی‌گردانی، ازجمله مطالعات محدود این حوزه، چالش اساسی روش‌شناختی را نادیده می‌گیرند: وابستگی ذاتی داده‌های رفتاری مشتریان به زمان. در محیط واقعی، داده‌ها به‌صورت جریانی تولید می‌شوند و استفاده از روش‌های ارزیابی ایستا، مانند تقسیم‌بندی تصادفی، منجر به نشت اطلاعات زمانی می‌شود و در نتیجه، برآوردی غیرواقعی از عملکرد مدل در محیط عملیاتی ارائه می‌دهد (Bergmeir et al., 2012). به‌کارگیری روش پنجرهٔ گسترش‌یابنده به‌عنوان چارچوب یادگیری افزایشی، می‌تواند با افزودن تدریجی داده‌های جدید، فرایند تطبیق مدل را با محیط پویا شبیه‌سازی و از نشت اطلاعات جلوگیری کند (Van de Ven et al., 2022 ; Hyndman & Athanasopoulos, 2018).

براین‌اساس، پژوهش حاضر با هدف پوشش خلأ پژوهشی یادشده در صنعت خودروی ایران، چارچوبی مبتنی‌بر یادگیری افزایشی را با راهبرد پنجرهٔ گسترش‌یابنده برای پیش‌بینی روی‌گردانی مشتریان ارائه می‌کند. در این راستا، پژوهش حاضر از چندین جهت دارای نوآوری است: نخست، به‌کارگیری داده‌های واقعی و عملیاتی یکی از نمایندگی‌های خودرو در ایران که امکان بررسی الگوهای رفتاری منحصربه‌فرد مصرف‌کننده ایرانی را در این صنعت فراهم می‌آورد؛ دوم، استفاده از چارچوب یادگیری افزایشی زمان‌محور به‌جای ارزیابی‌های ایستای متداول که امکان شبیه‌سازی محیط عملیاتی پویا و جلوگیری از پدیدهٔ نشت اطلاعات زمانی را میسر می‌سازد؛ سوم، تدوین مطالعهٔ مقایسه‌ای نظام‌مند که به ارزیابی تطبیقی پایداری دو الگوریتم پایه‌ای یادگیری ماشین، یعنی رگرسیون لجستیک و شبکهٔ عصبی پرسپترون چندلایه می‌پردازد و نشان می‌دهد که در محیط‌های پویای عملیاتی، آیا افزایش پیچیدگی مدل، خود مزیت محسوب می‌شود یا خیر؛ چهارم، موضوع ویژگی‌های متنی داده‌های مشتریان است که اغلب در پژوهش‌ها، کمتر به ویژگی‌های عددی آن‌ها توجه شده است. این ویژگی‌ها متغیرهایی نظیر نام و نوع کالا یا خدمت، و نوع پذیرش را در بر می‌گیرند که در کنار ویژگی‌های عددی و رسته‌ای، در این پژوهش بررسی می‌شوند. به‌کارگیری تعبیه‌های معنایی برای متغیرهای متنی، با بهره‌گیری از اطلاعات ارزشمند نهفته در داده‌های متنی در کنار متغیرهای عددی، به غنای فضای ویژگی‌های مدل کمک شایانی می‌کند، به‌طوری که امکان یادگیری شباهت‌های معنایی بین خدمات، انواع پذیرش و کالاها را برای مدل فراهم می‌سازد. براساس یافته‌های نگارندگان، در پیشینهٔ پژوهش به‌ندرت به بررسی هم‌زمان این مؤلفه‌ها در حوزهٔ روی‌گردانی مشتریان پرداخته شده است. در این زمینه، سؤال اصلی پژوهش این است: عملکرد و پایداری دو مدل رگرسیون لجستیک و شبکهٔ عصبی پرسپترون چندلایه در پیش‌بینی روی‌گردانی مشتریان صنعت خودروی ایران، در چارچوب یادگیری افزایشی چگونه است؟

۲. پیشینهٔ پژوهش

۲.۱. روی‌گردانی

به‌طور کلی روی‌گردانی مشتری که با واژگانی نظیر ریزش، فرار و فرسایش مشتری نیز شناخته می‌شود برای توصیفِ از دست دادن مشتریان به کار می‌رود (Lappeman et al., 2022). براساس مبانی نظری پژوهش، روی‌گردانی، زمانی رخ می‌دهد که مشتری با رها کردن رابطهٔ پایدار خود با شرکت، خرید خود را ازطریق شرکت دیگری انجام می‌دهد (Lappeman et al., 2022). براساس مدلی که کلپاک در سال ۲۰۱۴ ارائه کرد، انواع روی‌گردانی مشتریان را می‌توان به سه دستهٔ اصلی تقسیم کرد: داوطلبانه، غیرارادی و مورد انتظار (شکل ۱). روی‌گردانی غیرارادی زمانی روی می‌دهد که کسب‌وکار به‌دلیل پرداخت نشدن صورت‌حساب‌ها یا نقض شرایط و ضوابط، ارائهٔ خدمت را متوقف می‌کند (Klepac et al., 2015). روی‌گردانی مورد انتظار به وضعیتی اطلاق می‌شود که مشتری به‌دلیل پایان روند طبیعی چرخهٔ عمر محصول یا خدمت (مانند پایان عمر مفید خودرو) ارتباط خود را با شرکت قطع می‌کند. روی‌گردانی داوطلبانه زمانی رخ می‌دهد که مشتریان تصمیم آگاهانه‌ای برای ترک ارائه‌دهندهٔ خدمت می‌گیرند و ممکن است به برند دیگری روی آورند (ManzoorKlepac et al., 2015 ; et al., 2024). روی‌گردانی داوطلبانه، خود به دو بخش عمدی و تصادفی تقسیم می‌شود. روی‌گردانی تصادفی، ناشی از تغییر شرایط مالی یا جغرافیایی مشتری است و پیش‌بینی آن، ارزش چندانی ندارد؛ درحالی‌که در روی‌گردانی عمدی، مشتریان به‌دلیل نارضایتی از محصول یا خدمت و نیز به دست آوردن جایگزینی بهتر به رقیب روی می‌آورند (Klepac et al., 2014 ; Lappeman et al., 2022). این نارضایتی ممکن است تحت‌تأثیر عوامل مختلفی مانند کیفیت پایین خدمات، خدمات قدیمی، تجربهٔ بد مشتری، دسترسی ضعیف یا نگرانی‌های مالی باشد (Manzoor et al., 2024). با توجه به مطالب پیش‌گفته، پژوهش حاضر به‌طور ویژه بر روی‌گردانی عمدی مشتریان متمرکز است.



شکل ۱: مدل رویگردانی مشتریان کلپاک (۲۰۱۴)

Figure 1: Klepac's Kopfer's Customer Churn Model

با توجه به اهمیت نکات یادشده، باید توجه داشت که این تعریف در صنایع مختلف، متناسب با ماهیت تعامل با مشتری، به شاخص‌های عملیاتی متفاوتی تبدیل می‌شود؛ برای نمونه، در صنایع دارای تراکنش‌های مکرر (مانند خرده‌فروشی یا خدمات دیجیتال)، معیار رایج، فعالیت نکردن مشتری در یک بازهٔ زمانی معین (همچون ۹۰ روز) است (Manzoor et al., 2024). در صنعت خودرو که چرخهٔ خرید و تعامل مشتریان به‌نسبت طولانی‌تر است، بازهٔ زمانی شاخص روی‌گردانی نیز طولانی‌تر تعریف می‌شود. برای تعیین مدت‌زمان دقیق این روند با خبرگان صنعت خودرویی کشور مشورت شد. براین‌اساس، با استناد به دستورالعمل‌های فنی شرکت و مشورت با خبرگان و مدیران فنی نمایندگی‌های خودرویی، در این پژوهش، «مشتری روی‌گردان» به مشتری اطلاق می‌شود که از آخرین تعامل معنادار او با شرکت (اعم از سرویس دوره‌ای یا خرید قطعه و خدمت) بیشتر از ۵ ماه گذشته باشد. به گفتهٔ این کارشناسان، مبنای این شاخص، استاندارد فنی شرکت (۵۰۰۰ کیلومتر) برای مراجعه جهت خدمت پس‌از فروش است. ازآنجاکه پیمودن این مسافت به‌طور متوسط ۵ ماه زمان می‌برد، مراجعه نکردن مشتری در این بازهٔ ۵ماهه، به‌منزلهٔ قطع رابطه و روی‌گردانی او به نمایندگی‌های رقیب به شمار می‌آید.

۲.۲. مدل‌های پیش‌بینی روی‌گردانی

ابزارهای موجود در حوزهٔ هوش مصنوعی و یادگیری ماشین، در دامنهٔ وسیعی از علوم به کار می‌روند. یکی از امکاناتی که در این ابزارها ارائه می‌شود، استفاده از روش‌های یادگیری ماشین برای انجام دادن عملیات پیش‌بینی است (عباباف‌ها و فضلی، ۱۴۰۲). مدل پیش‌بینی روی‌گردانی، با بهره‌گیری از داده‌های گذشتهٔ مشتریان (مجموعه ویژگی‌ها و رفتارها) پیش‌بینی می‌کند کدام مشتریان در آینده در معرض روی‌گردانی قرار دارند. بیشتر این مدل‌ها از الگوریتم‌های یادگیری ماشین برای تحلیل الگوها و شناسایی عوامل مرتبط با روی‌گردانی استفاده می‌کنند (Sanches et al., 2025). با تشخیص سیگنال‌هایی که پیش‌از ریزش مشتریان پدیدار می‌شوند، کسب‌وکارها می‌توانند اقدامات پیشگیرانه‌ای را برای حفظ مشتریان ارزشمند به کار گیرند (Suh, 2023). پیش‌از این نیز از الگوریتم‌های یادگیری ماشین در صنعت خودرو جهت پیش‌بینی روی‌گردانی مشتریان استفاده شده است (Chaodhari & Gade, 2025).

۲.۳. ضرورت رویکرد زمان‌محور در پیش‌بینی روی‌گردانی

در مدل‌سازی پیش‌بینی روی‌گردانی، ماهیت زمان‌محور داده‌ها یکی از چالش‌های محوری به شمار می‌رود. آلبوکایی و همکاران (Alboukaey et al., 2020) نشان داده‌اند که تغییرات رفتاری منجر به روی‌گردانی، معمولاً در مقیاس‌های زمانی خُرد (مانند روزانه) رخ می‌دهند و تجمیع داده‌ها در سطح ماهانه، نه‌تنها از دقت مدل می‌کاهد، بلکه شناسایی مشتریانی که در ابتدای ماه تصمیم به ترک گرفته‌اند، با تأخیر مواجه می‌سازد. این چالش، زمانی عمیق‌تر می‌شود که از روش ارزیابی متقاطع تصادفی استفاده شود. برگمیر و بنیتز بیان می‌کنند که این روش، مبتنی‌بر فرض استقلال داده‌هاست و برای داده‌های زمانی برقرار نیست؛ زیرا آثار تکاملی و وابستگی‌های درون داده‌ها، مفروضات بنیادی آن را باطل می‌سازد. به‌کارگیری این روش در داده‌های زمانی، باعث پدیدهٔ «نشت اطلاعات» می‌شود و عملکردی غیرواقعی گزارش می‌دهد. راه‌حل این چالش، اتخاذ رویکرد

ارزیابی زمان‌محور است که در آن، محور زمان به‌عنوان معیار اصلی تقسیم‌بندی داده‌ها در نظر گرفته می‌شود (Bergmeir & Benítez, 2012). برای شبیه‌سازی دقیق‌تر محیط عملیاتی، از روش «پنجرهٔ گسترش‌یابنده» استفاده می‌شود. در این روش، مدل به‌صورت مرحله‌ای با افزودن تدریجی بلوک‌های زمانی جدید، بازآموزی و عملکرد آن بر روی بخش کاملاً مشاهده‌نشدهٔ آینده ارزیابی می‌شود. این رویکرد به‌طور ذاتی از نشت اطلاعات جلوگیری کرده و ارزیابی واقع‌بینانه‌ای از توانایی مدل در تعمیم به داده‌های آینده فراهم می‌آورد (Hyndman & Athanasopoulos, 2018).

۲.۴. یادگیری افزایشی

یادگیری افزایشی به رویکردی از یادگیری ماشین گفته می‌شود که در آن، مدل به‌جای آموزش یک‌باره با کل داده‌ها، به‌صورت تدریجی و گام‌به‌گام با ورود داده‌های جدید به‌روزرسانی می‌شود (Van de Ven et al., 2022). این رویکرد به یادگیری از داده‌های جریانی اشاره دارد که به‌مرور زمان دریافت می‌شوند؛ فرایندی که تحت محدودیت منابع حافظه و در حالت ایدئال بدون افت دقت مدل صورت می‌گیرد. یادگیری افزایشی به‌ویژه در کاربردهایی با داده‌های پیوسته و درحال تغییر –مانند سیستم‌های آنلاین، پردازش جریان داده و رباتیک هوشمند– اهمیت بسزایی دارد و به افزایش کارایی، کاهش هزینهٔ محاسباتی و سازگاری بهتر مدل با تغییرات محیط می‌انجامد (Gepperth & Hammer, 2016).

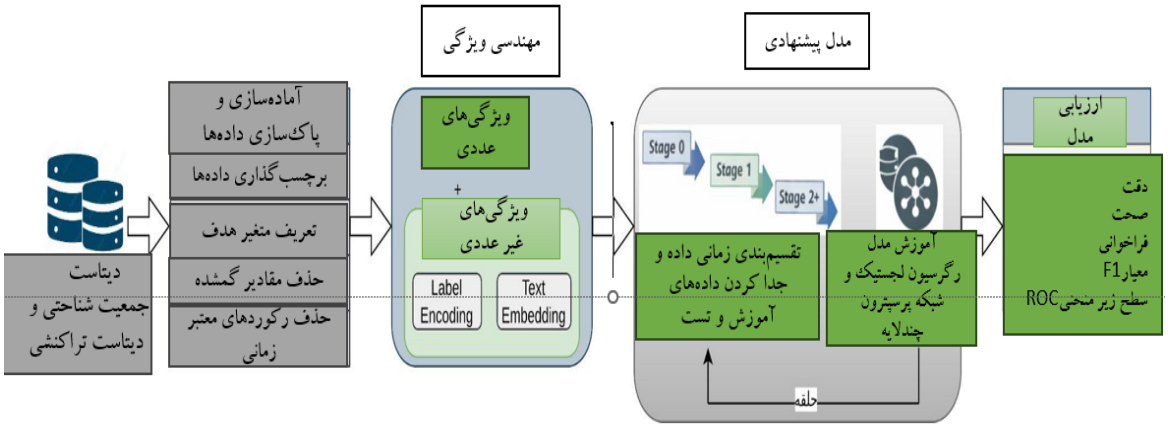
۵.۲. پیشینهٔ تجربی پژوهش

آقاخانی بزدی لنگری و همکاران (۱۴۰۲) با هدف تحلیل و پیش‌بینی روی‌گردانی مشتریان، مدل ترکیبی درخت تصمیم C5.0 و شبکهٔ بیزین را با استفاده از روش‌شناسی CRISP-DM روی داده‌های ۱۰۰۰ مشتری یک فروشگاه زنجیره‌ای در مشهد اجرا کردند. نتایج نشان داد که انتخاب ویژگی پیش‌از مدل‌سازی، دقت درخت تصمیم را به ۹۷.۵۹درصد و شبکهٔ بیزین را به ۹۳.۹۸درصد افزایش داد و مدل درخت تصمیم با سطح زیر منحنی ROC بیشتر به‌عنوان مدل برتر معرفی شد (آقاخانی بزدی لنگری و همکاران، ۱۴۰۲). خدابنده‌لو و زیوری رحمان با توسعهٔ مدل RFM به RFMTSDP ازطریق افزودن پنج متغیر جدید (تعداد اقلام خریداری‌شده، تعداد اقلام مرجوعی، میزان تخفیف، زمان توزیع و تعداد جوایز)، شبکهٔ عصبی مصنوعی را با دقت ۹۷.۹۲درصد به‌عنوان مدل برتر در پیش‌بینی روی‌گردانی در فروشگاه مواد غذایی معرفی کردند (Khodabandehlou & Rahman, 2017). سوه با به‌کارگیری جنگل تصادفی و LightGBM روی داده‌های ۸۴۰۰۰ مشتری در صنعت اجارهٔ لوازم‌خانگی، با استخراج ۵۳ ویژگی مؤثر، مدلی با دقت ۹۰درصد و سطح زیر منحنی ۸۸درصد ارائه داد و «تعداد تماس‌های ورودی مشتری»، «مدل محصول اجاره‌ای» و «تعداد ماه‌های استفاده» را مهم‌ترین عوامل مؤثر گزارش کرد (Suh, 2023). سینگ و همکاران، در صنعت بانکداری با استفاده از مجموعه‌داده‌ای ۱۰۰۰۰ مشتری و الگوریتم‌های مختلف (رگرسیون لجستیک، ماشین بردار پشتیبان، جنگل تصادفی و XGBoost) و به‌کارگیری تکنیک SMOTE برای مواجهه با داده‌های نامتوازن، مدل جنگل تصادفی را با دقت ۷۸.۳درصد و حساسیت ۶۹.۳درصد به‌عنوان مدل بهینه انتخاب کردند (Singh et al., 2024). در صنعت خودرو، سواپنیل و همکاران، با استفاده از داده‌های ترکیبی پرسش‌نامه و سیستم مدیریت ارتباط با مشتری و به‌کارگیری رگرسیون لجستیک و درخت تصمیم، رضایت مشتری و تعداد دفعات خرید را مهم‌ترین پیش‌بین‌کننده‌های روی‌گردانی گزارش کردند

(Chaodhari & Gade, 2025). همچنین، دورسون–جنگیزچی و کابر در صنعت هتلداری با استفاده از داده‌های واقعی مشتریان تکراری و الگوریتم‌های جنگل تصادفی و رگرسیون لجستیک، مدل جنگل تصادفی را با دقت ۸۰درصد و متغیرهای مبتنی‌بر الگوی RFM (تازگی، فراوانی، ارزش پولی) را به‌عنوان مهم‌ترین پیش‌بینی‌کننده‌های روی‌گردانی شناسایی کردند (Dursun-Cengizci & Caber, 2025).

۳. روش پژوهش

در این پژوهش، چارچوب مرحله‌ای و زمان‌محوری (Rolling/Temporal Framework) برای پیش‌بینی روی‌گردانی مشتریان در صنعت خودرو، با بهره‌گیری از رویکرد یادگیری افزایشی ارائه شده است. شکل ۲ چارچوب کلی روش پیشنهادی را به‌صورت سیستماتیک نمایش می‌دهد.



شکل ۲: چارچوب کلی روش پژوهش (منبع: یافته‌های محقق)

Figure 2: General Framework of the Research Method

در گام نخست، دو مجموعه‌داده (Dataset) جمعیت‌شناختی و تراکنشی، براساس شناسهٔ یکتای مشتری با یکدیگر ادغام شدند. ازآنجاکه هدف مدل‌سازی در سطح تراکنش انجام می‌شود، اطلاعات سطح مشتری، مانند سن، جنسیت و سابقهٔ رفتاری به هر رکورد تراکنشی الحاق شد. متغیر هدف «روی‌گردانی مشتری» براساس فاصلهٔ زمانی بین آخرین تراکنش ثبت‌شده هر مشتری و تاریخ اتمام مطالعه تعریف و به‌صورت دودویی (باینری) کدگذاری شد، به‌طوری‌که مقدار «۱» نشان‌دهندهٔ مشتری روی‌گردان و مقدار «۰» مشتری فعال است. همچنین، تمامی تراکنش‌هایی که تاریخ آن‌ها پس‌از تاریخ اتمام مطالعه قرار داشتند حذف شدند تا از بروز نشت اطلاعات زمانی جلوگیری شود. در گام دوم، ویژگی‌های غیرعددی به مقادیر عددی کاربردی در مدل تبدیل شدند. بدین منظور، برای متغیرهای دسته‌ای با تعداد کلاس محدود از روش برچسب‌گذاری (Label Encoding) و برای متغیرهای متنی با کاردینالیتی بالا از روش تعبیه عددی (Embedding) استفاده شد. سپس این ویژگی‌ها با سایر ویژگی‌های عددی ادغام شدند تا بردار نهایی ویژگی‌ها شکل گیرد. در گام سوم، به‌منظور شبیه‌سازی شرایط واقعی کسب‌وکار و با هدف ایجاد محیط یادگیری

افزایشی، داده‌ها به‌صورت زمان‌محور و مرحله‌ای تقسیم‌بندی شدند در این چارچوب، یک مجموعه آموزش اولیه و چندین بازهٔ زمانی متوالی به‌عنوان مجموعه آزمون در نظر گرفته شد، به‌گونه‌ای که در هر مرحله، بخشی از داده‌های آزمایشی به مجموعهٔ آموزش افزوده می‌شود، مدل به یادگیری می‌پردازد و سپس روی داده‌های آزمایشیِ باقی‌مانده ارزیابی می‌شود. در گام نهایی، در هر مرحلهٔ زمانی از یادگیری افزایشی، دو مدل یادگیری ماشین شامل رگرسیون لجستیک (Logistic Regression) و شبکهٔ عصبی پرسپترون چندلایه آموزش داده شدند. عملکرد این مدل‌ها با استفاده از معیارهای دقت (Accuracy)، صحت (Precision)، یادآوری (Recall)، معیار F1 و سطح زیر منحنی ROC ارزیابی و با یکدیگر مقایسه شد.

۳.۱. گردآوری و پیش‌پردازش داده‌ها

انبوهی از داده‌ها در بانک اطلاعاتی سیستم مدیریت ارتباط با مشتریان نمایندگی‌های خودرویی ثبت می‌شود. در این پژوهش از داده‌های یکی از نمایندگی خودرویی در شهر مشهد استفاده شد. هویت برند برای اطمینان از شرایط رقابتی و حریم خصوصی فاش نشد. ازآنجاکه روی‌گردانی، مفهومی وابسته به زمان است، با استناد به دستورالعمل فنی شرکت و مشورت با خبرگان و مدیران فنی نمایندگی‌ها خودرویی آستانهٔ ۱۵۰ روز به‌عنوان معیار تشخیص روی‌گردانی تعیین شد.

در این پروژه برای پیش‌بینی روی‌گردانی مشتریان، از دو مجموعه‌داده اصلی استفاده شده است: داده‌های جمعیت‌شناختی و داده‌های تراکنشی. داده جمعیت‌شناختی شامل اطلاعات در سطح مشتری بوده و هر سطر داده از این مجموعه، معرف یک مشتری یکتا است. ویژگی‌های این مجموعه‌داده عبارت‌اند از: ۱. شناسهٔ یکتا (شناسه منحصربه‌فرد هر مشتری)؛ ۲. کد پذیرش (هر مشتری می‌تواند برای دریافت خدمات، یک یا چند بار مراجعه داشته باشد و در نتیجه دارای چند کد پذیرش باشد)؛ ۳. جنسیت مشتری، تاریخ تولد مشتری و سن مشتری. در مرحلهٔ پیش‌پردازش این مجموعه‌داده، مقادیر گمشده (NaN) بررسی شده‌اند. رکوردهایی که مقدار ستون شناسهٔ یکتا در آن‌ها خالی بود، به‌دلیل برقرار نشدن اتصال به مجموعه‌داده تراکنشی و شناسایی نشدن مشتری، از مجموعه‌داده حذف شدند. پس‌از این مرحله، تعداد نمونه‌های معتبر این مجموعه کاهش یافت و مجموعه‌داده نهایی برای ادغام با داده‌های تراکنشی آماده شد؛ در مقابل، داده‌های تراکنشی دربردارندهٔ اطلاعات مربوط به هر تراکنش ثبت‌شده ازسوی مشتریان است؛ به‌گونه‌ای که ممکن است برای هر مشتری چندین رکورد وجود داشته باشد. ویژگی‌های اصلی این مجموعه‌داده عبارت‌اند از: ۱. کد پذیرش؛ ۲. شناسهٔ یکتا؛ ۳. تاریخ ثبت پذیرش؛ ۴. نام خدمت یا کالا؛ ۵. نوع پذیرش؛ ۶. نوع (کالا یا خدمت)؛ ۷. مبلغ نهایی تراکنش؛ ۸. فراوانی مراجعه؛ ۹. وسیله نقلیه. در این مجموعه‌داده نیز ابتدا مقادیر گمشده بررسی و رکوردهای دارای مقادیر NaN در ستون‌های شماره فاکتور شعبه و نمایندگی، حذف شدند؛ زیرا این مقادیر برای تأیید اعتبار تراکنش ضروری بودند. هدف این پروژه پیش‌بینی احتمال روی‌گردانی مشتری است؛ ازاین‌رو، برای برچسب‌گذاری داده‌ها، تعریف دقیق متغیر هدف و برچسب‌گذاری صحیح داده‌ها از اهمیت بسزایی برخوردار است. روی‌گردانی مفهومی وابسته به زمان است و بدون در نظر گرفتن تاریخ مرجع، تعریف آن می‌تواند منجر به نتایج گمراه‌کننده شود. در این پژوهش، تاریخ ۱۴۰۴/۰۸/۳۰ به‌عنوان تاریخ اتمام

مطالعه در نظر گرفته شد. تمام تصمیم‌گیری‌ها دربارهٔ فعال یا روی‌گردان بودن مشتریان، بر مبنای این تاریخ انجام شده است. برای هر مشتری، فاصلهٔ زمانیِ بین آخرین تراکنش ثبت‌شده و تاریخ اتمام مطالعه محاسبه شد. این فاصله به‌عنوان شاخص اصلی سنجش میزان فعالیت مشتری در نظر گرفته شده است. براساس سیاست کسب‌وکار و تحلیل رفتار مشتریان، آستانهٔ ۱۵۰ روز به‌عنوان معیار تشخیص روی‌گردانی تعیین و براین‌اساس، متغیر هدف به‌صورت دودویی کدگذاری شد:

- ✓ مقدار ۱ (روی‌گردان): مشتریانی که فاصلهٔ زمانی آخرین تعامل آن‌ها تا تاریخ اتمام مطالعه بیش از ۱۵۰ روز باشد.
- ✓ مقدار ۰ (فعال): مشتریانی که فاصلهٔ زمانی آخرین تعامل آن‌ها تا تاریخ اتمام مطالعه حداکثر ۱۵۰ روز باشد.

برهمین‌اساس، متغیر دودویی «وضعیت روی‌گردانی مشتری» (۱ = روی‌گردان، ۰ = فعال) به‌عنوان متغیر هدف در مدل پیش‌بینی به کار رفت. در فرایند بررسی داده‌ها مشخص شد که برخی تراکنش‌ها تاریخ‌هایی پس‌از زمان اتمام مطالعه دارند. ازآنجاکه وجود چنین داده‌هایی به نشت اطلاعات زمانی می‌انجامد، این نمونه‌ها به‌طور کامل از مجموعه‌داده حذف شدند. حذف این داده‌ها تضمین می‌کند که: ۱) برچسب‌گذاری مشتریان فقط براساس اطلاعات در دسترس تا تاریخ اتمام مطالعه انجام شده است؛ ۲) مدل پیش‌بینی در شرایطی مشابه سناریوی واقعی کسب‌وکار آموزش داده می‌شود. همچنین، در مرحلهٔ مهندسی ویژگی، متغیری با عنوان «اختلاف تاریخ آخرین تراکنش تا تاریخ اتمام مطالعه» تولید شد؛ بااین‌حال، به‌منظور پیشگیری از نشت اطلاعات زمانی و هم‌راستایی با رویکرد زمان‌محور پژوهش، این ویژگی در مرحلهٔ پیش‌پردازش از مجموعه‌داده‌های ورودی مدل حذف شد. بدین‌ترتیب، مدل هیچ‌گاه به این اطلاعات دسترسی نداشته و نتایج گزارش‌شده، مبتنی‌بر سایر ویژگی‌های جمعیت‌شناختی، تراکنشی و رفتاری است.

جدول ۱ زیر خلاصه‌ای آماری از مجموعه‌داده‌ها را نمایش می‌دهد:

جدول ۱: خلاصهٔ آماری از مجموعه‌داده‌های پژوهش

Table 1: Statistical Summary of the Research Datasets

مجموعه‌داده	تعداد رکورد	تعداد ویژگی
مجموعه‌داده جمعیت‌شناختی		
حجم مجموعه‌داده اولیه	۳،۷۰۸	۵
حجم مجموعه‌داده بعداز حذف مقادیر گمشده در ستون شناسهٔ یکتا	۳،۶۸۴	۵
مجموعه‌داده تراکنشی		
حجم مجموعه‌داده اولیه	۵۰،۵۷۳	۱۶
حجم مجموعه‌داده بعداز حذف مقادیر گمشده دو ستون شماره فاکتور شعبه و شماره فاکتور نمایندگی	۴۹،۸۹۹	۱۶
حجم مجموعه‌داده بعداز حذف تراکنش‌های نامعتبر زمانی	۴۷،۰۸۲	۱۶

منبع: محقق‌ساخته

۳.۲. انتخاب و آماده‌سازی متغیرها (Feature Selection)

در این پژوهش، با توجه به ماهیت مسئلهٔ پیش‌بینی روی‌گردانی مشتری، داده‌ها در دو سطح مشتری و تراکنش مورد استفاده قرار گرفته‌اند. ازآنجاکه رفتار مشتری در طول زمان و ازطریق مجموعه‌ای از تعاملات و تراکنش‌ها شکل می‌گیرد، لازم است الگوی کلی رفتار مشتری استخراج و در مدل لحاظ شود. به همین منظور، ابتدا ویژگی‌ها در سطح مشتری محاسبه و سپس این اطلاعات به مجموعه‌داده تراکنشی منتقل شده‌اند تا هر رکورد تراکنش، نماینده‌ای جامع از وضعیت مشتری در زمان انجام آن تراکنش باشد.

۳.۳. ساخت مجموعه‌داده در سطح مشتری و انتقال ویژگی‌های آن به سطح تراکنش

در گام نخست، یک مجموعه‌داده در سطح مشتری ایجاد شد که هر سطر آن معرف یک مشتری یکتا است. این مجموعه‌داده با تجمیع اطلاعات تراکنشی هر مشتری و ترکیب آن با داده‌های جمعیت‌شناختی ساخته شده است. هدف از این مرحله، خلاصه‌سازی رفتار گذشته مشتری تا زمان انجام هر تراکنش و استخراج شاخص‌هایی بود که شدت، تداوم و ارزش ارتباط مشتری با کسب‌وکار را توصیف می‌کنند. مهم‌ترین متغیرهای این سطح عبارت‌اند از: ۱. شناسهٔ یکتای مشتری؛ ۲. جنسیت مشتری؛ ۳. سن مشتری؛ ۴. وسیله نقلیه مشتری؛ ۵. تعداد کل تراکنش‌های مشتری؛ ۶. مجموع مبلغ پرداختی مشتری؛ ۷. میانگین کیلومتر پیموده‌شدهٔ مشتری؛ ۸. میانگین فاصلهٔ زمانی بین تراکنش‌ها. این ویژگی‌ها نشان‌دهندهٔ ابعاد مختلف رفتار مشتری بوده و امکان تحلیل الگوهای تعامل بلندمدت مشتری را با شرکت فراهم می‌کنند. با توجه به اینکه هدف نهایی مدل، پیش‌بینی روی‌گردانی براساس هر تراکنش ثبت‌شده، است، مجموعه‌داده نهایی در سطح تراکنش تعریف و مجموعه‌داده سطح مشتری ازطریق شناسهٔ یکتای مشتری به مجموعه‌داده تراکنشی متصل شد؛ در نتیجه، هر رکورد تراکنش افزون‌بر اطلاعات اختصاصی همان تراکنش، شامل مجموعه‌ای از ویژگی‌های رفتاری و جمعیت‌شناختی مشتری نیز شد. این رویکرد موجب شد که رفتار گذشته مشتری تا زمان انجام هر تراکنش در مدل لحاظ شود؛ به‌گونه‌ای مدل بتواند تعامل بین ویژگی‌های تراکنشی و ویژگی‌های رفتاری بلندمدت مشتری را یاد بگیرد و در نهایت ساختار داده‌ها شرایط واقعی کسب‌وکار را شبیه‌سازی کند؛ در نتیجه با دریافت تراکنشی جدید، امکان پیش‌بینی وضعیت روی‌گردانی مشتری فراهم شود. پس از انجام مراحل یادشده، متغیرهای ورودی نهایی مدل به چهار دستهٔ کلی تقسیم شدند:

- ✓ متغیرهای تراکنشی: نام خدمت یا کالا، نوع پذیرش، نوع (کالا یا خدمت)، مبلغ نهایی تراکنش و تعداد؛
- ✓ متغیرهای جمعیت‌شناختی مشتری: جنسیت مشتری، سن مشتری و وسیله نقلیه مشتری هستند؛
- ✓ متغیرهای رفتاری استخراج‌شده در سطح مشتری: تعداد کل تراکنش‌های مشتری، مجموع مبلغ پرداختی مشتری، میانگین کیلومتر پیموده‌شدهٔ مشتری، میانگین فاصلهٔ زمانی بین تراکنش‌ها؛
- ✓ متغیر هدف که محدود به متغیر روی‌گردانی مشتری (دودویی) است. دربارهٔ متغیر هدف پژوهش، شایان ذکر است که برچسب روی‌گردانی ابتدا در سطح تراکنش و براساس فاصلهٔ زمانی هر تراکنش تا تاریخ اتمام مطالعه تعریف و سپس با استفاده از تابع تجمیع Max بر روی تراکنش‌های هر مشتری، وضعیت نهایی هر مشتری تعیین شد.

این ساختار چندسطحی داده‌ها باعث شد مدل به‌صورت هم‌زمان از اطلاعات لحظه‌ای هر تراکنش و الگوهای رفتاری بلندمدت مشتری بهره‌مند شود؛ موضوعی که با رویکردهای پیشنهادی در مبانی نظری پیش‌بینی روی‌گردانی مشتری هم‌راستا بوده و موجب افزایش دقت و پایداری مدل می‌شود.

۳.۴. مهندسی ویژگی‌ها (Feature Engineering)

با توجه به تنوع داده‌ها و تفاوت در ماهیت متغیرها، فرایند مهندسی ویژگی‌ها با هدف استخراج بیشترین اطلاعات رفتاری از داده‌ها و آماده‌سازی آن‌ها برای مدل پیش‌بینی انجام گرفت. در این مرحله، متغیرها براساس نوع و میزان تنوع مقادیرشان به چند دسته تقسیم و برای هر دسته روش مناسبی اعمال شد.

متغیرهای عددی (Numerical Features): متغیرهای عددی که ماهیتی کمّی و پیوسته داشتند، در مرحلهٔ پیش‌پردازش با استفاده از روش نرمال‌سازی مین-مکس (Min-Max Normalization) به بازه [۰,۱] تبدیل شدند. این فرایند به‌منظور جلوگیری از تأثیر منفی مقیاس‌های متفاوت بر عملکرد مدل‌ها، به‌ویژه مدل MLP که به مقیاس ورودی‌ها حساس است، انجام شده است؛ بنابراین، پس‌از این نرمال‌سازی، نیازی به تبدیلات ساختاری اضافی احساس نشد. این متغیرها عبارت‌اند از: ۱. مبلغ نهایی تراکنش؛ ۲. تعداد؛ ۳. سن مشتری؛ ۴. تعداد تراکنش‌های مشتری؛ ۲. مجموع مبلغ پرداختی مشتری؛ ۶. میانگین کیلومتر پیموده‌شدهٔ مشتری؛ ۷. میانگین فاصلهٔ زمانی بین تراکنش‌ها. این ویژگی‌ها، اطلاعاتی را دربارهٔ شدت تعامل، ارزش اقتصادی مشتری و الگوی زمانی رفتار وی ارائه می‌دهند و نقش مهمی در تمایز مشتریان فعال از مشتریان روی‌گردان ایفا می‌کنند.

متغیرهای دسته‌ای کم‌کلاس (Low Cardinality Categorical): متغیرهایی که تعداد مقادیر یکتای محدودی داشتند، با استفاده از برچسب‌گذاری، عددی‌سازی شدند. این متغیرها عبارت‌اند از: ۱. جنسیت مشتری؛ ۲. وسیلهٔ نقلیه مشتری.

متغیرهای دسته‌ای پرکلاس (High Cardinality Categorical): برخی متغیرهای دسته‌ای، دارای تعداد فراوانی شناسهٔ یکتا بودند که استفاده از روش‌هایی مانند کدگذاری یکتایی (One-Hot Encoding) به افزایش شدید ابعاد داده و پراکندگی انجامید که عبارت‌اند از: ۱. نام خدمت یا کالا؛ ۲. نوع پذیرش؛ ۳. نوع (کالا یا خدمت). برای این دسته از متغیرها، از تعبیه‌سازی معنایی (Semantic Embedding) مبتنی‌بر مدل‌های زبانی بهره گرفته شد. همچنین، به‌منظور استخراج اطلاعات معنایی نهفته در متغیرهای متنی، مدل ازپیش‌آموزش‌دیدهٔ تبدیلگر جملات (Sentence Transformer) به نام all-MiniLM-L6-v2 به کار رفت. در این روش، هر مقدار متنی به یک بردار عددی با بُعد ۳۸۴ نگاشته شد. هر تراکنش، برای هر متغیر پرکلاس، یک تعبیه مستقل دریافت کرد.

این تعبیه‌ها به‌صورت یک ویژگی برداری (لیست عددی) به مجموعه‌داده اضافه شدند. این رویکرد، امکان یادگیری شباهت‌های معنایی بین خدمات، انواع پذیرش و کالاها را برای مدل فراهم می‌کند؛ به‌طوری که خدمات مشابه حتی با نام‌های متفاوت، نمایش عددی نزدیکی خواهند داشت. ساخت ویژگی‌های نهایی ورودی مدل: پس‌از اعمال مراحل یادشده، بردار ویژگی نهایی هر تراکنش عبارت بودند از: ۱. ویژگی‌های عددی تراکنش؛ ۲. ویژگی‌های عددی رفتاری مشتری؛ ۳. متغیرهای دسته‌ای کم‌کلاس پس‌از کدگذاری برچسب؛ ۴. تعبیه‌های معنایی استخراج‌شده از متغیرهای پرکلاس.

۳.۵. تقسیم‌بندی زمانی داده‌ها

ازآنجاکه مسئلهٔ پیش‌بینی روی‌گردانی مشتری ذاتاً زمان‌محور است، تقسیم‌بندی تصادفی داده‌ها می‌تواند به نشت اطلاعات زمانی و ارزیابی بیش از حد خوش‌بینانهٔ مدل بینجامد. به همین دلیل، در این پژوهش از تقسیم‌بندی زمانی داده‌ها به‌جای تقسیم‌بندی تصادفی استفاده شده است. برای هر مشتری، تاریخ اولین تراکنش به‌عنوان شاخص زمانی ورود مشتری به سیستم در نظر گرفته شد. سپس کل مجموعه‌داده مشتریان براساس این تاریخ به‌صورت صعودی مرتب شد. این کار تضمین می‌کند که ترتیب زمانی ورود مشتریان به‌درستی حفظ شود. در ادامه، تاریخ ۱۴۰۳/۱۰/۱۱ به‌عنوان نقطهٔ مرزی (Cut-off Date) برای تفکیک داده‌های آموزش و آزمون انتخاب شد؛ یعنی مشتریانی که تاریخ اولین تراکنش آن‌ها پیش‌از تاریخ اتمام بوده است، در مجموعه آموزش اولیه قرار گرفتند؛ اما مشتریانی که تاریخ اولین تراکنش آن‌ها پس‌از تاریخ اتمام بوده است، به‌عنوان داده‌های آزمون در نظر گرفته شدند. این روش بازتاب‌دهندهٔ سناریوی واقعی کسب‌وکار است که در آن، مدل فقط به اطلاعات گذشته دسترسی دارد و باید رفتار مشتریان آینده را پیش‌بینی کند. تقسیم‌بندی مرحله‌ای داده‌های آزمون (Rolling/Expanding Window) فقط برای ارزیابی پایداری عملکرد مدل در طول زمان و در محیط یادگیری افزایشی ارائه شده است؛ به این صورت که داده‌های آزمون به ۵ بازهٔ زمانی متوالی تقسیم شده و سپس از راهبرد پنجرهٔ گسترش‌یابنده به‌صورت زیر استفاده شده است. در مرحلهٔ صفر (Stage 0)، مدل ضمن آموزش با داده‌های آموزش اولیه، بر روی داده‌های آزمون اولیه شامل ۲۱,۳۷۲ رکورد ارزیابی شد. در مراحل بعدی، با انتقال هر بازهٔ زمانی جدید به مجموعه آموزش، مدل بر روی داده‌های آزمون باقی‌مانده شامل بازه‌های زمانی بعدی ارزیابی می‌شود. به‌این‌ترتیب، حجم داده‌های آزمون در هر مرحله براساس تعداد بازه‌های زمانی باقی‌مانده تعیین می‌شود. در هر مرحلهٔ بعدی و پس‌از مرحلهٔ صفر، بازهٔ زمانی جدیدی از داده‌های آزمون به مجموعه آموزش افزوده و مدل بار دیگر آموزش داده شد. عملکرد مدل نیز روی داده‌های باقی‌ماندهٔ آینده مورد ارزیابی قرار گرفت. این فرایند تا آخرین بازهٔ زمانی ادامه یافت. این روش ارزیابی چند مزیت بنیادین دارد: ۱. جلوگیری کامل از نشت اطلاعات زمانی (Temporal Data Leakage)؛ ۲. شبیه‌سازی شرایط واقعی استفاده از مدل در محیط عملیاتی؛ ۳. امکان بررسی پایداری و تغییر عملکرد مدل در گذر زمان؛ ۴. ارزیابی توانایی مدل در تطبیق با داده‌های جدید و رفتارهای نوظهور مشتریان. در هر مرحله، چهار دسته اطلاعات زیر ذخیره و گزارش شد:

- ✓ داده‌های آموزشی و آزمون همان مرحله؛
- ✓ برچسب‌های واقعی روی‌گردانی مشتری؛
- ✓ پیش‌بینی‌های مدل و احتمالات خروجی؛
- ✓ معیارهای ارزیابی عملکرد شامل دقت، صحت یادآوری، معیار F1 و سطح زیر منحنی ROC.

در نهایت، عملکرد مدل با محاسبهٔ میانگین معیارها در تمام مراحل زمانی گزارش شد تا تصویری جامع از کارایی مدل در بازه‌های مختلف زمانی ارائه شود.

۳.۶. مدل‌سازی

پس‌از آماده‌سازی داده‌ها، مهندسی ویژگی‌ها و تقسیم‌بندی زمانی مجموعه‌داده‌ها، فرایند مدل‌سازی برای پیش‌بینی روی‌گردانی مشتری صورت گرفت. هدف، برآورد احتمال روی‌گردانی هر تراکنش/مشتری

و طبقه‌بندی آن‌ها به دو کلاس فعال و روی‌گردان بود. در این پژوهش، مدل رگرسیون لجستیک به‌عنوان مدل پایه انتخاب شد؛ ازاین‌رو، این انتخاب براساس ملاحظات زیر صورت گرفت:

۱. تناسب با مسئلهٔ طبقه‌بندی دودویی: رگرسیون لجستیک به‌طور طبیعی برای مسائل پیش‌بینی دودویی طراحی شده و مستقیماً احتمال تعلق هر نمونه به کلاس روی‌گردان را برآورد می‌کند؛

۲. تولید احتمال خروجی تفسیرپذیر: خروجی مدل، احتمال روی‌گردانی مشتری است که می‌تواند به‌راحتی در سیاست‌های بازاریابی، وفادارسازی و مدیریت ارتباط با مشتری استفاده شود؛

۳. قابلیت کار با داده‌های با ابعاد زیاد: با توجه به استفاده از تعبیه‌های متنی (Sentence Transformer)، فضای ویژگی‌ها دارای ابعاد زیادی است. رگرسیون لجستیک با تنظیم مناسب پارامترها (مانند منظم‌سازی ‘regularization’) توانایی یادگیری در این فضا را دارد.

۴. پایداری و سادگی مدل: این مدل در مقایسه با بسیاری از مدل‌های پیچیده‌تر، کمتر مستعد بیش‌برازش (Overfitting) است؛ یعنی، آموزش سریع‌تر و اجرا و نگهداری ساده‌تری دارد.

باید دانست که رگرسیون لجستیک به‌دلیل ساختار خطی و ساده، به مدیران کسب‌وکار کمک می‌کند تا رابطهٔ کلی بین ویژگی‌های مشتری و احتمال روی‌گردانی را درک کنند (Hastie et al., 2009). این ویژگی در کاربردهای عملی مدیریت ارتباط با مشتری که نیاز به شفافیت در تصمیم‌گیری‌های حفظ مشتری وجود دارد، ارزشمند است. این مدل، احتمال وقوع رویداد (که در این پژوهش همان روی‌گردانی مشتری است) را با استفاده از تابع سیگموید برآورد می‌کند. به‌طور خلاصه، مدل، ترکیبی خطی از متغیرهای ورودی را به یک عدد بین صفر و یک تبدیل کرده و آن را به‌عنوان احتمال تعلق به کلاس هدف (روی‌گردان) تفسیر می‌کند (Hastie et al., 2009).

معادله این مدل به‌صورت زیر است:

$$P(y = 1 \mid X) = \frac{1}{1 + e^{-(b_0 + b_1X_1 + b_2X_2 + \ldots + b_nX_n)}}$$

که در آن $P(y=1|X)$ نشان‌دهندهٔ احتمال روی‌گردانی مشتری با توجه به بردار ویژگی‌های X است، b_0 ضریب ثابت (عرض از مبدأ) و $b_1, b_2, \ldots, b$ ضرایب مربوط به هریک از ویژگی‌های ورودی هستند، و e پایه لگاریتم طبیعی را نشان می‌دهد.

افزون‌بر رگرسیون لجستیک، در این پژوهش از شبکهٔ عصبی پرسپترون چندلایه به‌عنوان مدل غیرخطی و پیچیده برای پیش‌بینی روی‌گردانی مشتری استفاده شده است. MLP یکی از پرکاربردترین معماری‌های شبکه‌های عصبی پیشرو است که از یک لایهٔ ورودی، یک یا چند لایهٔ پنهان و یک لایهٔ خروجی تشکیل شده است (Haykin, 2009). در این ساختار، هر نورون لایهٔ پنهان با استفاده از یک تابع فعال‌سازی غیرخطی، ترکیب خطی وزنی ورودی‌های خود را به خروجی غیرخطی تبدیل می‌کند. این قابلیت، MLP را قادر می‌سازد تا روابط پیچیده و غیرخطی بین ویژگی‌های ورودی و احتمال روی‌گردانی مشتری را مدل‌سازی کند (Goodfellow et al., 2016).

به‌منظور تأمین قابلیت بازتولید نتایج پژوهش، تمامی جزئیات اجرای مدل رگرسیون لجستیک و شبکهٔ عصبی پرسپترون چندلایه به‌صورت ساختاریافته و شفاف در جدول ۲ گردآوری شده است که شامل کتابخانه و بستر اجرا، معماری شبکه، پارامترهای بهینه‌سازی، توابع فعال‌سازی، توابع هزینه، تعداد تکرارها، اندازه بَچ، و وضعیت تنظیم ابرپارامترها است.

جدول ۲: جزئیات اجرا و پارامترهای مدل‌های رگرسیون لجستیک و شبکهٔ عصبی پرسپترون چندلایه

Table 2: Implementation Details and Parameters of Logistic Regression and Multi-Layer Perceptron Neural Network Models

ردیف	عنوان پارامتر	مقدار در رگرسیون لجستیک	مقدار در شبکهٔ عصبی MLP
۱	کتابخانه / بستر اجرا	scikit-learn (پایتون)	scikit-learn (پایتون)
۲	معماری شبکه / ساختار	(مدل خطی)	یک لایهٔ پنهان با ۱۰۰ نورون
۳	نوع و ضریب منظم‌سازی	L2 با ضریب C = 1.0	L2 با ضریب alpha = 0.0001
۴	روش بهینه‌سازی	LBFGS	Adam
۵	سطح یادگیری	(روش LBFGS بدون درصد یادگیری صریح است)	0.001
۶	تابع فعال‌سازی لایه‌های پنهان	(بدون لایه پنهان)	ReLU
۷	تابع فعال‌سازی لایهٔ خروجی	Logistic (Sigmoid)	Logistic (Sigmoid)
۸	تابع هزینه	Log Loss	Binary Cross-Entropy
۹	بیشینهٔ تکرار / دوره‌های آموزش	۱۰۰ تکرار	۲۰۰ دوره
۱۰	اندازه بَچ	استفاده از کل داده آموزش (full batch)	خودکار (min 200, n_samples)
۱۱	تنظیم سیستماتیک ابرپارامترها	انجام شده با روش جستجوی شبکه‌ای Grid Search و معیار F1-Score	استفاده از مقادیر پیش‌فرض کتابخانه

منبع: محقق‌ساخته

در هر مرحله از تقسیم‌بندی زمانی (Expanding Window)، فرایند آموزش و ارزیابی مدل به‌صورت زیر انجام شد:

۱. داده‌های آموزشی مربوط به همان مرحله ساخته شدند؛

۲. تعبیه‌های متنی به بردارهای عددی تخت (Flattened Vectors) تبدیل شدند تا با ساختار ورودی مدل رگرسیون لجستیک سازگار باشند؛

۳. مدل رگرسیون لجستیک با استفاده از داده‌های آموزشی آموزش داده شد؛

۴. عملکرد مدل بر روی داده‌های آزمون مربوط به آینده ارزیابی شد؛

در هر مرحله، معیارهای دقت، صحت، یادآوری، معیار F1 و سطح زیر منحنی ROC محاسبه و ذخیره شدند. در نهایت، میانگین عملکرد مدل در تمامی مراحل زمانی به‌عنوان شاخص نهایی کارایی مدل گزارش شد.

۳.۷. معیارهای ارزیابی مدل

به‌منظور ارزیابی عملکرد مدل پیش‌بینی روی‌گردانی مشتری، از مجموعه‌ای از معیارهای استاندارد طبقه‌بندی دودویی استفاده شد. با توجه به ماهیت مسئله و نبود توازن نسبی بین کلاس‌های «فعال» و «روی‌گردان»، استفاده از یک معیار منفرد، کافی نبوده و ترکیبی از چند شاخص بررسی شده است:

دقت (Accuracy): نسبت تعداد پیش‌بینی‌های صحیح مدل به کل نمونه‌ها را نشان می‌دهد؛

صحت (Precision): نسبت نمونه‌هایی که به‌درستی به‌عنوان روی‌گردان پیش‌بینی شده‌اند به کل نمونه‌هایی که مدل آن‌ها را روی‌گردان تشخیص داده است؛

یادآوری (Recall): توانایی مدل در شناسایی صحیح مشتریان روی‌گردان را اندازه‌گیری می‌کند؛

معیار F1 (F1-score): میانگین هارمونیک Precision و Recall بوده و تعادلی بین این دو معیار ایجاد می‌کند؛

سطح زیر منحنی ROC (ROC-AUC): توانایی کلی مدل را در تفکیک دو کلاس فعال و روی‌گردان، مستقل از آستانهٔ تصمیم‌گیری نشان می‌دهد.

فرمول‌های مربوط به هریک از معیارها در جدول ۳ ارائه شده است:

جدول ۳: معیارهای ارزیابی مدل

Table 3: Model Evaluation Metrics

معیار	فرمول
دقت (Accuracy)	(TP + TN) / (TP + TN + FP + FN)
صحت (Precision)	TP / (TP + FP)
یادآوری (Recall)	TP / (TP + FN)
معیار F1	2 × (Precision × Recall) / (Precision + Recall)
TP: تعداد پیش‌بینی‌های صحیح برای کلاس مثبت (روی‌گردان)	TN: تعداد پیش‌بینی‌های صحیح برای کلاس منفی (فعال)
FP: تعداد پیش‌بینی‌های اشتباه برای کلاس مثبت	FN: تعداد پیش‌بینی‌های اشتباه برای کلاس منفی

منبع: محقق‌ساخته

۴. نتایج و یافته‌ها

جدول ۴، نتایج هر مرحله را برای دو مدل یادگیری ماشین در محیط یادگیری افزایشی با ۵ مرحلهٔ آموزشی نشان می‌دهد. این درحالی است که مرحلهٔ «۰» به مرحلهٔ عادی یادگیری ماشین، یعنی آموزش روی داده‌های آموزشی و آزمایش روی داده‌های آزمایشی، اطلاق می‌شود و دیگر مراحل به‌ترتیب نقش مراحل یادگیری آزمایشی را در محیط واقعی شبیه‌سازی می‌کنند.

جدول ۴: نتایج هر مرحله برای دو مدل یادگیری ماشین (منبع یافته‌های محقق)

Table 4: Experimental Results Across Stages for Two Machine Learning Models

مرحله	دقت	صحت	یادآوری	معیار F1	سطح زیر منحنی ROC
لجستیک رگرسیون					
مرحلهٔ ۰	۷۰۷۸.۰	۳۸۳۷.۰	۹۰۲۱.۰	۵۳۸۴.۰	۹۱۲۴.۰
مرحلهٔ ۱	۸۷۲۱.۰	۷۸۲۵.۰	۹۲۶۹.۰	۸۴۸۶.۰	۹۴۷۸.۰
مرحلهٔ ۲	۹۰۳۴.۰	۸۵۰۳.۰	۹۳۶۹.۰	۸۹۱۵.۰	۹۵۴۶.۰
مرحلهٔ ۳	۹۳۳۳.۰	۹۰۸۶.۰	۹۶۲۱.۰	۹۳۴۶.۰	۹۷۷۰.۰
مرحلهٔ ۴	۹۵۳۷.۰	۹۴۵۰.۰	۹۷۱۱.۰	۹۵۷۹.۰	۹۸۱۵.۰
میانگین نتایج	۸۷۴۱.۰	۷۷۴۰.۰	۹۳۹۸.۰	۸۳۴۲.۰	۹۵۴۷.۰
شبکهٔ پرسپترون چندلایه					
مرحلهٔ ۰	۷۳۸۲.۰	۳۶۰۷.۰	۵۰۰۴.۰	۴۱۹۳.۰	۶۴۸۱.۰
مرحلهٔ ۱	۶۹۵۴.۰	۹۱۵۴.۰	۲۳۳۵.۰	۳۷۲۱.۰	۶۱۲۱.۰
مرحلهٔ ۲	۵۶۴۰.۰	۴۹۲۲.۰	۹۳۷۶.۰	۶۴۵۵.۰	۶۱۳۸.۰
مرحلهٔ ۳	۷۶۷۱.۰	۹۵۹۶.۰	۵۵۳۱.۰	۷۰۱۷.۰	۷۶۹۲.۰
مرحلهٔ ۴	۵۴۱۴.۰	۵۴۱۸.۰	۹۹۸۸.۰	۷۰۲۵.۰	۴۹۹۴.۰
میانگین نتایج	۶۶۱۲.۰	۶۵۳۹.۰	۶۴۴۷.۰	۵۶۸۲.۰	۶۲۸۵.۰

منبع: محقق‌ساخته

نتایج نشان می‌دهد که مدل رگرسیون لجستیک در این مجموعه‌داده با افزایش حجم داده‌های آموزشی، روندی صعودی و پایدار در تمامی معیارهای ارزیابی داشته است:

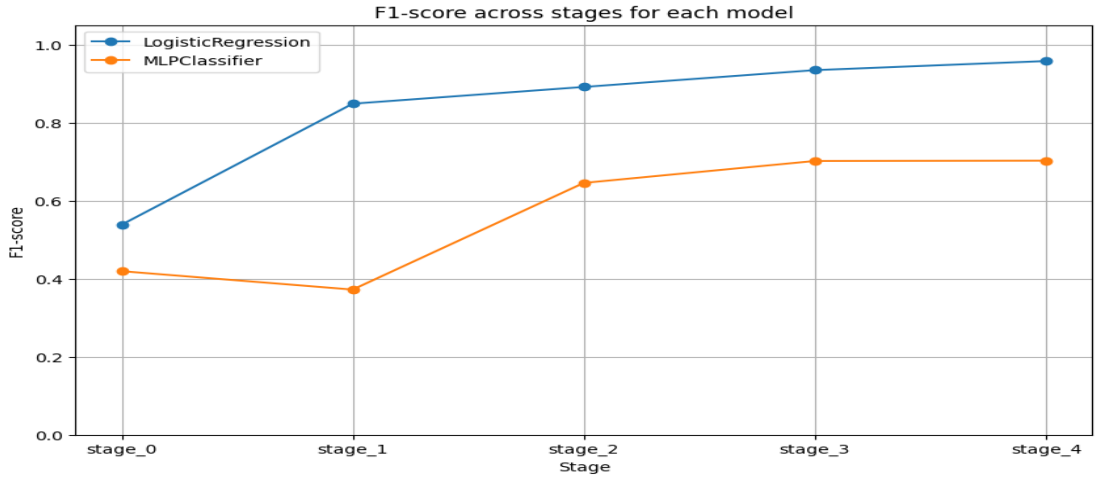
معیار F1-: مقدار ۰.۵۳ در مرحلهٔ صفر به ۰.۹۶ در مرحلهٔ چهارم افزایش یافته است.

سطح زیر منحنی ROC همواره بیشتر از ۰.۹۱ بوده و در مراحل پایانی به بیش از ۰.۹۸ رسیده است. هم‌زمان معیارهای یادآوری و صحت هر دو زیاد و متعادل باقی مانده‌اند که نشان‌دهندهٔ توانایی مدل در تشخیص صحیح مشتریان روی‌گردان بدون افزایش بیش از حد خطای نوع اول است. این رفتار در این مجموعه‌داده خاص نشان می‌دهد که الگوی روی‌گردانی مشتریان ممکن است تقریباً خطی و تفکیک‌پذیر باشد. با افزایش داده‌های وابسته به زمان، مدل لجستیک در این مجموعه‌داده توانسته است مرز تصمیم‌گیری را به‌خوبی یاد بگیرد، هرچند تعمیم این نتیجه نیازمند بررسی بر روی داده‌های متنوع‌تر است. همچنین، مدل ازنظر پایداری عملکرد، برای کاربردهای عملی بسیار مناسب است. در مقابل، عملکرد مدل MLP در مراحل مختلف، نوسان‌دار و ناپایدار بوده است. در برخی مراحل معیار یادآوری بسیار زیادی (حتی نزدیک به ۱) مشاهده می‌شود؛ اما معیار صحت در اغلب مراحل کم بوده که منجر به کاهش معیار F1 شده است. همچنین، مقدار سطح زیر منحنی ROC در تمامی مراحل کمتر از رگرسیون لجستیک بوده و در مرحلهٔ چهارم حتی به حدود ۰.۵ (نزدیک به حد تصادفی) رسیده است. این نتایج نشان می‌دهد که مدل MLP تمایل به بیش‌برازش روی کلاس کمینه دارد. به نظر می‌رسد تنظیم نامناسب ابرپارامترها برای این مدل (مانند تعداد لایه‌ها، میزان یادگیری یا Regularization) یکی از عوامل مؤثر ناپایداری عملکرد در این مجموعه‌داده‌ها بوده است. پیچیدگی زیاد مدل نیز در مقایسه با ساختار داده‌ها، منجر به کاهش قدرت تعمیم‌پذیری شده است.

معیار یادآوری زیاد در هر دو مدل نشان می‌دهد که شناسایی مشتریان روی‌گردان (کلاس ۱) به‌خوبی انجام شده است؛ اما معیار صحت کم در MLP به معنای هشدارهای کاذب زیاد است؛ یعنی شمار بسیاری از مشتریان فعال به‌اشتباه به‌عنوان روی‌گردان پیش‌بینی شده‌اند. رگرسیون لجستیک موفق شده است بین این دو معیار تعادل برقرار کند که این موضوع در مقدار بیشینه F1-score منعکس شده است. با توجه به نتایج به‌دست‌آمده:

۱. در این مجموعه‌داده خاص، مدل رگرسیون لجستیک عملکرد عددی بهتری نسبت به MLP نشان داد و از پایداری بیشتری در طول مراحل یادگیری افزایشی برخوردار بود؛

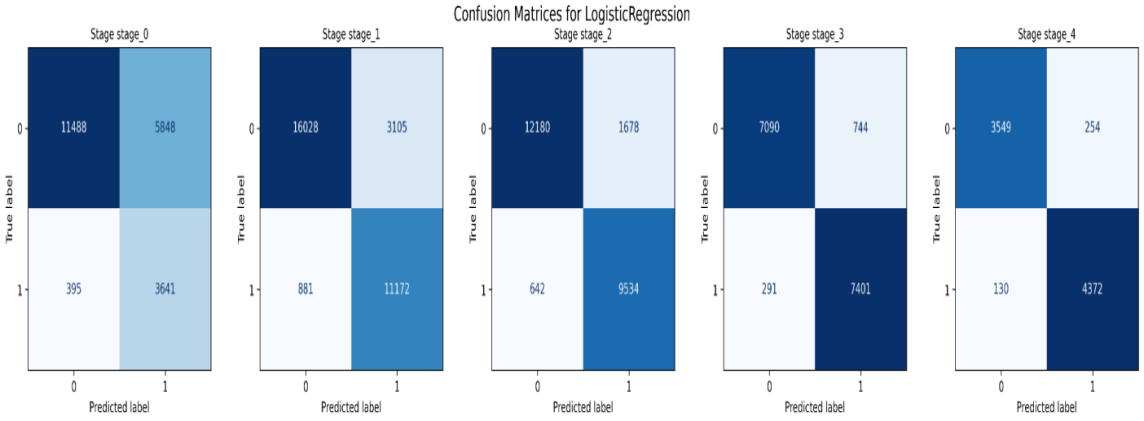
۲. مدل MLP باوجود پیچیدگی زیادتر، نتوانسته است مزیت معناداری نسبت به مدل ساده‌تر ایجاد کند و نیازمند تنظیم دقیق‌تر و داده‌های بیشتر است. شکل ۳، تغییرات معیار F1-score را برای دو مدل رگرسیون لجستیک و MLP در مراحل مختلف زمانی نشان می‌دهد.



شکل ۳: تغییرات معیار F1-score (منبع: یافته‌های محقق)

Figure 3: F1-Score Trends Across Stages

همان‌طور که مشاهده می‌شود، مدل رگرسیون لجستیک با افزایش حجم داده‌های آموزشی، روندی صعودی و پایدار در F1-score دارد که نشان‌دهندهٔ بهبود هم‌زمان دقت و یادآوری است. در مقابل، مدل MLP نوسانات چشمگیری را در مراحل مختلف نشان می‌دهد و باوجود عملکرد مناسب در برخی مراحل، پایداری کمتری نسبت به مدل لجستیک دارد. این موضوع نشان‌دهندهٔ حساسیت بیشتر MLP به ساختار داده و توزیع نمونه‌ها در سناریوی داده‌های زمانی است. شکل ۴ مقدار ماتریس درهم‌ریختگی را در مراحل مختلف برای مدل رگرسیون لجستیک نشان می‌دهد.



شکل ۴. مقدار ماتریس درهم‌ریختگی (منبع یافته‌های محقق)

Figure 4: Confusion Matrix Across Stages

براساس نتایج ماتریس‌های درهم‌ریختگی به‌دست‌آمده در مراحل مختلف، عملکرد مدل در تشخیص مشتریان روی‌گردان (کلاس ۱) به‌صورت معناداری بهبود یافته است. در مرحلهٔ صفر، تعداد خطاهای طبقه‌بندی برای مشتریان روی‌گردان نسبتاً زیاد است که نشان می‌دهد مدل در ابتدای فرایند یادگیری

افزایشی هنوز توانایی کافی برای تفکیک دقیق مشتریان فعال (کلاس ۰) و روی‌گردان را ندارد؛ بااین‌حال، با ورود داده‌های جدید در مراحل بعدی، تعداد پیش‌بینی‌های صحیح برای کلاس روی‌گردان افزایش یافته و هم‌زمان میزان پیش‌بینی‌های اشتباه کاهش پیدا کرده است، به‌ویژه در مراحل ۳ و ۴ که تعادل مناسبی بین شناسایی صحیح مشتریان روی‌گردان و کاهش خطای طبقه‌بندی مشتریان فعال مشاهده می‌شود.

ازآنجاکه هدف اصلی این پژوهش، تشخیص مشتریان روی‌گردان است -یعنی مشتریانی که فاصلهٔ زمانی آخرین تعامل آن ها تا تاریخ اتمام مطالعه بیش از ۱۵۰ روز باشد (کلاس ۱)- نتایج نشان می‌دهد که مدل به‌مرور زمان توانسته الگوهای رفتاری منجر به روی‌گردانی را بهتر شناسایی کند. کاهش خطای منفی کاذب (شناسایی نشدن مشتریان واقعاً روی‌گردان) در مراحل پایانی اهمیت ویژه ای دارد؛ زیرا این دسته از خطاها مستقیماً باعث از دست رفتن فرصت‌های پیشگیرانه برای حفظ مشتری می‌شوند. در مقابل، افزایش دقت در تفکیک مشتریان فعال (کلاس ۰)، یعنی افرادی با فاصلهٔ تعامل حداکثر ۱۵۰ روز، نشان می‌دهد که پایداری و قابلیت اتکای مدل در محیط یادگیری، افزایشی و پویا است.

۵. بحث و نتیجه‌گیری

حفظ مشتریان در صنعت خودرو که پیتر دراکر آن را «صنعتِ صنعت‌ها» نامیده است (هاشمی و همکاران، ۱۳۸۹)، برای برندها از اهمیت بسزایی برخوردار است. در یک فضای به‌شدت رقابتی مانند صنعت خودرو، پیش‌بینی به‌هنگام روی‌گردانی مشتریان به ضرورتی راهبردی تبدیل شده است. این پژوهش با به‌کارگیری چارچوب یادگیری افزایشی، درصدد برطرف کردن دو خلأ مهم در پیشینهٔ موجود برآمد: نخست، تمرکز بر صنعت خودروی ایران با ویژگی‌های رفتاری و رقابتی منحصربه‌فرد آن، که در مطالعات پیشین کمتر بدان توجه شده بود (Chaodhari & Gade, 2025)؛ دوم، رفع چالش وابستگی زمانی داده‌ها و نشت اطلاعات ازطریق تقسیم‌بندی زمان‌محور و استفاده از پنجرهٔ گسترش‌یابنده، رویکردی که در بسیاری از پژوهش‌های پیشین نادیده گرفته شده بود (Alboukaey et al., ; Bergmeir & Benítez, 20122020).

برای تحقق این هدف، پژوهش حاضر با رویکردی نوآورانه جهت بررسی ویژگی‌های متنی، افزون‌بر ویژگی‌های عددی مشتریان از چارچوب یادگیری افزایشی با راهبرد پنجرهٔ گسترش‌یابنده بهره گرفت. در این چارچوب، پژوهشی مقایسه‌ای میان دو الگوریتم پایهٔ یادگیری ماشین صورت پذیرفت: رگرسیون لجستیک به‌عنوان نماینده‌ای از مدل‌های خطی، و شبکهٔ عصبی پرسپترون چندلایه به‌عنوان نماینده‌ای از مدل‌های غیرخطی و پیچیده. یافته‌های عددی نشان داد که در این مجموعه‌داده خاص، مدل رگرسیون لجستیک با میانگین معیار F1 معادل ۰.۸۳۴ و سطح زیر منحنی ROC معادل ۰.۹۵۵، عملکرد عددی بهتری نسبت به MLP با میانگین F1 معادل ۰.۵۶۸ و ROC معادل ۰.۶۲۹ در چارچوب یادگیری افزایشی داشت؛ باوجوداین، نظر به ماهیت و روش به‌کاررفته در پژوهش حاضر، این نتایج را نمی‌توان به‌عنوان برتری مطلق مدل تعبیر کرد و تعمیم آن به سایر داده‌ها نیازمند بررسی‌های بیشتر است. این یافته‌ها با پژوهش‌های پیشین همسو است؛ برای نمونه، در صنعت خودرو، سواپنیل و همکاران (Chaodhari & Gade, 2025) به کارایی مدل‌های ساده‌تری، مانند رگرسیون لجستیک و درخت تصمیم در پیش‌بینی روی‌گردانی مشتریان اشاره

کرده‌اند؛ اما با حجم و گستردگی بیشتر داده‌های رفتاری واقعی و به‌کارگیری چارچوب یادگیری افزایشی، از آن متمایز می‌شود. همچنین یافته‌های پژوهش حاضر همسویی آشکاری با مطالعهٔ آقاخانی بزدی لنگری و همکاران (۱۴۰۲) در حوزهٔ خرده‌فروشی دارد؛ آن‌ها نیز نشان دادند که مدل درخت تصمیم C5.0 به‌عنوان مدلی تفسیرپذیر، عملکردی برتر از شبکهٔ بیزین دارد. هر دو پژوهش بر این نکته تأکید دارند که گاهی در برخی از حوزه‌های کسب‌وکار، مدل‌های ساده‌تر می‌توانند جایگزین مناسبی برای مدل‌های پیچیده‌تر باشند؛ بااین‌حال، تمایز اساسی پژوهش حاضر در به‌کارگیری چارچوب یادگیری افزایشی با راهبرد پنجرهٔ گسترش‌یابنده است که امکان شبیه‌سازی محیط عملیاتی پویا و جلوگیری از نشت اطلاعات زمانی را فراهم کرده است؛ درحالی‌که پژوهش آقاخانی بزدی لنگری و همکاران (۱۴۰۲) از رویکردی ایستا و ارزیابی متقاطع تصادفی بهره گرفته است.

ازسوی‌دیگر، خدابنده‌لو و زیوری رحمان (Khodabandehlou & Zivari Rahman, 2017) با گسترش مدل RFM به RFMTSDP و افزودن ۵ ویژگی جدید، نشان دادند که غنی‌سازی مجموعهٔ ویژگی‌ها می‌تواند دقت پیش‌بینی را افزایش دهد. پژوهش حاضر نیز با استخراج طیف وسیعی از ویژگی‌های جمعیت‌شناختی، تراکنشی و رفتاری بلندمدت و خاص صنعت خودرو، این اصل را در حوزهٔ خودرو به کار بسته است. باوجوداین همسویی درزمینهٔ غنای ویژگی‌ها، عملکرد مدل شناسایی‌شده در این پژوهش (رگرسیون لجستیک) با یافته‌های مطالعاتی مانند خدابنده‌لو و زیوری رحمان (Khodabandehlou & Zivari Rahman, 2017) (که شبکهٔ عصبی را برتر دانسته‌اند) یا سینگ و همکاران (Singh et al., 2024) (که به برتری جنگل تصادفی رسیده‌اند) متفاوت است. این تفاوت می‌تواند از ماهیت متمایز رفتار مشتریان در صنعت خودرو در مقایسه با صنایعی مانند کالاهای تندمصرف یا خدمات پرتراکنش نشئت گرفته باشد.

از جنبهٔ روش‌شناختی، این مطالعه، کارایی یادگیری افزایشی را در شبیه‌سازی محیط عملیاتی پویای کسب‌وکار به نمایش گذاشت و بر لزوم حرکت از ارزیابی‌های ایستا به‌سمت چارچوب‌های تطبیقی و زمان‌محور در مسائل پیش‌بینی رفتاری تأکید کرد. رویکرد ارائه‌شده امکان شناسایی به‌هنگام مشتریان در آستانهٔ ریزش را فراهم می‌سازد که می‌تواند مبنایی برای طراحی مداخلات هدفمند حفظ مشتری قرار گیرد. درمجموع، این مطالعه نشان داد که اجرای چارچوب یادگیری افزایشی مبتنی‌بر پنجرهٔ گسترش‌یابنده با به‌کارگیری مدل رگرسیون لجستیک تفسیرپذیر، راه‌حلی عملی و مؤثر برای پیش‌بینی به‌هنگام روی‌گردانی مشتریان در صنعت خودرو است. این رویکرد، بینش مبتنی‌بر داده‌ای را در اختیار مدیران قرار می‌دهد که می‌تواند مبنایی برای طراحی مداخلات هدفمند حفظ مشتری و تخصیص بهینهٔ منابع بازاریابی و خدمات پس‌ازفروش باشد.

این پژوهش با ارائه رویکردی نوآورانه در پیش‌بینی روی‌گردانی مشتریان در صنعت خودرو، بینشی ارزشمند برای مدیران فراهم می‌آورد تا با استفاده از خروجی مدل، منابع بازاریابی و خدمات را به‌صورت هدفمند به‌سمت مشتریان پرخطر هدایت و کمپین‌های ارتباطی شخصی‌سازی‌شده طراحی کنند. این راهبرد مبتنی‌بر شواهد، افزون‌بر افزایش درصد حفظ مشتری، با کاهش هزینه‌های جذب مشتریان جدید و تقویت وفاداری، به افزایش سودآوری و تحکیم موقعیت رقابتی برندهای خودرویی در بازار پویای ایران کمک

می‌کند. در این زمینه، پیشنهاد می‌شود نمایندگی‌های خودرویی از چنین سیستم‌های پیش‌بینی‌کننده‌ای به‌عنوان سرمایه‌گذاری راهبردی در جهت تقویت برنامه‌های بازاریابی نسل ششم خود بهره ببرند.

۵.۱. محدودیت‌ها و پیشنهادهایی برای پژوهش‌های آینده

این مطالعه، مانند هر پژوهش دیگری، چندین محدودیت دارد. نخست، داده‌ها به یک نمایندگی در شهر مشهد محدود بوده و ممکن است نتایج به سایر مناطق تعمیم‌پذیر نباشد. همچنین، براساس نظر مدیران نمایندگی، «مراجعه نکردن مشتری در بازهٔ ۱۵۰ روز» به دو دلیل، شاخصی قابل‌قبول برای روی‌گردانی و رفتن به‌سوی نمایندگی‌های رقیب است: نخست، مدت گارانتی ازلحاظ قطعات اصلی و هزینه برای مشتری اطمینان‌بخش است و او را در این بازه به مراجعهٔ دوره‌ای ترغیب می‌کند؛ دوم، تعداد نمایندگی‌های مجاز یک برند در یک شهر محدود است و ازاین‌رو احتمال مراجعهٔ مشتری به نمایندگی دیگر همان برند کم است. بااین‌همه، ممکن است موقعیت زیارتی مشهد یا عواملی نظیر فروش خودرو، کاهش میزان رانندگی مشتری (به‌گونه‌ای که در بازهٔ ۱۵۰ روز به استاندارد ۵۰۰۰ کیلومتر نرسد) و تغییر مکان جغرافیایی نیز در مراجعه نکردن مشتری در این بازه نقش داشته باشند. پیشنهاد می‌شود پژوهش‌های آینده با داده‌های چندین نمایندگی از شهرهای مختلف، به این موضوع بپردازند؛ دوم، این محدودیت به دورهٔ مشاهده مشتریان بازمی‌گردد. در این پژوهش براساس مشورت با مدیران و کارشناسان فنی نمایندگی، مدت‌زمان گارانتی ایجاب می‌کند که مشتریان حتی در روزهای پایانی دورهٔ مطالعه نیز پتانسیل مراجعه داشته باشند؛ ازاین‌رو، ۳۲,۴۸۵ رکورد که آخرین تراکنش آن‌ها کمتر از ۱۵۰ روز پیش‌از تاریخ اتمام مطالعه ثبت شده بود، در مجموعه‌داده حفظ شدند تا اطلاعات ارزشمند در آستانهٔ اتمام گارانتی از دست نرود؛ البته ممکن است برخی از این مشتریان دورهٔ مشاهده ناقص داشته باشند. در این راستا، پژوهش‌های آینده می‌توانند با تحلیل بقا یا حذف این مشتریان، به ارزیابی دقیق‌تری از عملکرد مدل بپردازند؛ سوم، با توجه به اینکه یکی از نوآوری‌های این پژوهش، به‌کارگیری تعبیه‌های معنایی برای داده‌های متنی بوده است که هر مقدار متنی را به یک بردار عددی با ابعاد ۳۸۴ تبدیل می‌کند، فضای ویژگی‌ها به‌طور چشمگیری گسترش یافته است؛ بااین‌حال، با توجه به تعداد فراوان ویژگی‌های ایجادشده، بررسی ضرایب مدل به‌منظور شناسایی متغیرهای مؤثر بر روی‌گردانی، در چارچوب هدف اصلی این پژوهش قرار نداشته است. پژوهش‌های آینده می‌توانند با استفاده از روش‌های مناسب، به تحلیل علّی عوامل مؤثر بر روی‌گردانی در فضای این ویژگی‌های گسترده پرداخته و اولویت‌بندی متغیرها را مورد بررسی قرار دهند؛ چهارم، مقایسهٔ مدل‌ها به دو الگوریتم پایه‌ای (لجستیک و MLP) محدود بود و الگوریتم‌های پیچیده‌تر دیگر بررسی نشدند. پیشنهاد می‌شود پژوهش‌های آینده بر سایر الگوریتم‌ها، مانند جنگل تصادفی متمرکز شوند؛ پنجم، ازآنجاکه در این پژوهش، وضعیت مشتری براساس تراکنش‌های او تعریف شده است تا شرایط عملیاتی کسب‌وکار شبیه‌سازی شود، مشتریان پرتراکنش با تعداد رکورد بیشتری در مجموعه‌داده حضور دارند؛ مسئله‌ای که ممکن است به وزن‌دهی بیشتر به این دسته از مشتریان در فرایند آموزش مدل بینجامد. پیشنهاد می‌شود پژوهش‌های آینده با استفاده از روش‌های نمونه‌برداری سطح مشتری یا وزن‌دهی معکوس براساس تعداد

تراکنش‌ها، این محدودیت را مدیریت کنند؛ ششم، با توجه به هدف اصلی پژوهش، تنظیم سیستماتیک ابرپارامترها فقط برای مدل رگرسیون لجستیک انجام گرفت و برای مدل MLP از مقادیر پیش‌فرض کتابخانه استفاده شد. پژوهش‌های آینده می‌توانند با تنظیم سیستماتیک ابرپارامترهای هر دو مدل، مقایسه‌ای منصفانه‌تر ارائه دهند.

منابع

آقاخانی بزدی لنگری، عاطفه، و حسنی، علی اکبر (۱۴۰۲). تحلیل روی‌گردانی مشتریان مبتنی‌بر رویکرد داده‌کاوی: الگوریتم ترکیبی درخت تصمیم و شبکهٔ بیزین (مورد مطالعه: فروشگاه‌های زنجیره‌ای). *تحقیقات بازاریابی نوین*، ۱۳(۲)، ۱-۲۲. https://doi.org/10.22108/nmrj.2023.135756.2797

سید هاشمی، محمد، و ممدوحی، امیررضا (۱۳۸۹). تحلیل خوشه‌ای موانع اجرای استراتژی‌های بازاریابی در صنعت خودروسازی (مطالعه‌ی موردی: شرکت ایران‌خودرو). *مدیریت بازرگانی*، ۲(۴). https://jibm.ut.ac.ir/article_22119.html

عباف‌ها، محمد مهدی، و فضلی، صفر (۱۴۰۲). پیش‌بینی میزان فروش با بهره‌برداری از روش یادگیری متا (مورد مطالعه: فروش آلومینیوم در بورس کالای ایران). *تحقیقات بازاریابی نوین*، ۱۳(۳)، ۱۳۲-۱۱۳.. https://doi.org/10.22108/nmrj.2023.138364.2929

References

Alboukaey, N., Joukhadar, A., & Ghneim, N. (2020). Dynamic behavior-based churn prediction in mobile telecom. *Expert Systems with Applications*, *162*. https://doi.org/10.1016/j.eswa.2020.113779

Abbabafha, M., & Fazli, S. (2023). Sales forecasting using meta-learning method (Case study: Aluminum sales in Iran's commodity exchange). *New Marketing Research Journal*, *13*(3), 113-132. https://doi.org/10.22108/nmrj.2023.138364.2929 [In Persian]

Aghakhani Bazdi Langari, A., & Hasani, A. (2023). Customer churn analysis based on data mining approach: Hybrid algorithm of decision tree and Bayesian network (Case study: Chain stores). *New Marketing Research Journal*, *13*(2), 1-22. https://doi.org/10.22108/nmrj.2023.135756.2797 [In Persian]

Bergmeir, C., & Benítez, J. M. (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences*, *191*, 192–213. https://doi.org/10.1016/j.ins.2011.12.028

Boozary, P., Sheykhan, S., GhorbanTanhaei, H., & Magazzino, C. (2025). Enhancing customer retention with machine learning: A comparative analysis of ensemble models for accurate churn prediction. *International Journal of Information Management Data Insights*, *5*(1). https://doi.org/10.1016/j.jjimei.2025.100331

Chaodhari, S. P., & Gade, A. (2025). A study on customer churn rate prediction analysis at NPL Bluesky Automotive Pvt Ltd Nagpur. *International Journal of Innovation Studies*, *9*(1), 373–382. https://www.keaipublishing.com/en/journals/international-journal-of-innovation-studies/.

Dursun-Cengizci, A., & Caber, M. (2025). Using machine learning methods to predict future churners: an analysis of repeat hotel customers. *International Journal of Contemporary Hospitality Management*, *37*(1), 36–56. https://doi.org/10.1108/IJCHM-06-2023-0844

Ehsani, F., & Hosseini, M. (2025). Customer churn analysis using feature optimization methods and tree-based classifiers. *Journal of Services Marketing*, *39*(1), 20–35. https://doi.org/10.1108/JSM-04-2024-0156

Geiler, L., Affeldt, S., & Nadif, M. Geiler, L., Affeldt, S., & Nadif, M. (2022). A survey on machine learning methods for churn prediction. *International Journal of Data Science and Analytics*, *14*(3), 217-242. https://doi.org/10.1007/s41060-022-00312-5

Gepperth, A., & Hammer, B. (2016). *Incremental learning algorithms and applications*. European Symposium on Artificial Neural Networks. Bruges, Belgium. https://hal.science/hal-01418129v1

Goodfellow, Ian, Yoshua Bengio, & Aaron Courville. (2016). *Deep learning*. The MIT Press.

Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*. OTexts.

Hu, L., & Basiglio, A. (2023). A multiple-case study on the adoption of customer relationship management and big data analytics in the automotive industry. *TQM Journal*, *36*(9), 1–21. https://doi.org/10.1108/TQM-05-2023-0137

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer. https://doi.org/10.1007/978-0-387-84858-7

Haykin, S. (2009). *Neural Networks and Learning Machines* (3rd ed.). Pearson Education India.

Khodabandehlou, S., & Zivari Rahman, M. (2017). Comparison of supervised machine learning techniques for customer churn prediction based on analysis of customer behavior. *Journal of Systems and Information Technology*, *19*(1–2), 65–93. https://doi.org/10.1108/JSIT-10-2016-0061

Klepac, G., Kopal, R., & Mršić, L. (Eds.). (2015). *Developing Churn Models Using Data Mining Techniques and Social Network Analysis*. IGI Global. https://doi.org/10.4018/978-1-4666-6288-9

Lalwani, P., Mishra, M. K., Chadha, J. S., & Sethi, P. (2022). Customer churn prediction system: a machine learning approach. *Computing*, *104*(2), 271–294. https://doi.org/10.1007/s00607-021-00908-y

Lappeman, J., Franco, M., Warner, V., & Sierra-Rubia, L. (2022). What social media sentiment tells us about why customers churn? *Journal of Consumer Marketing*, *39*(5), 385–403. https://doi.org/10.1108/JCM-12-2019-3540

Manzoor, A., Atif Qureshi, M., Kidney, E., & Longo, L. (2024). A Review on Machine Learning Methods for Customer Churn Prediction and Recommendations for Business Practitioners. *IEEE Access*, *12*, 70434–70463. https://doi.org/10.1109/ACCESS.2024.3402092

Nanji, U. O., Benjamin, L. B., Eyo-Udo, N. L., & Etukudoh, E. A. (2024). A review of strategic decision-making in marketing through big data and analytics. *Magna Scientia Advanced Research and Reviews*, *11*(1), 084-091. https://pdfs.semanticscholar.org/b2dc/e746351da62cd92c6dd1bcbc542ccf73a731.pdf

Saleh, S., & Saha, S. (2023). Customer retention and churn prediction in the telecommunication industry: a case study on a Danish university. *SN Applied Sciences*, *5*(7). https://doi.org/10.1007/s42452-023-05389-6

Sanches, H. E., Possebom, A. T., & Aylon, L. B. R. (2025). Churn prediction for SaaS Company with machine learning. *Innovation and Management Review*, *22*(2), 130–142. https://doi.org/10.1108/INMR-06-2023-0101

Seyed Hashemi, M., & Mamdouhi, A. (2010). Cluster analysis of barriers to marketing strategy implementation in the automotive industry (Case study: Iran Khodro Company). *Journal of Business Management*, *2*(4). https://jibm.ut.ac.ir/article_22119.html [In Persian]

Singh, P. P., Anik, F. I., Senapati, R., Sinha, A., Sakib, N., & Hossain, E. (2024). Investigating customer churn in banking: A machine learning approach and visualization app for data science and management. *Data Science and Management*, *7*(1), 7–16. https://doi.org/10.1016/j.dsm.2023.09.002

Suh, Y. (2023). Machine learning based customer churn prediction in home appliance rental business. *Journal of Big Data*, *10*(41). https://doi.org/10.1186/s40537-023-00721-8

Van de Ven, G. M., Tuytelaars, T., & Tolias, A. S. (2022). Three types of incremental learning. *Nature Machine Intelligence*, *4*(12), 1185–1197. https://doi.org/10.1038/s42256-022-00568-3