

A Hybrid Neural Network–Genetic Algorithm Model for Customer Churn Prediction (Case Study: MCI)

Neda Paravian¹, Ameneh Khadivar^{2*}

1. Ph.D. Candidate, Department of management, Faculty of Social Sciences and Economics Alzahra University, Tehran, Iran.
2. Associate Professor, Department of management, Faculty of Social Sciences and Economics Alzahra University, Tehran, Iran.

Received: 05/02/2026

Accepted: 22/02/2026

Corresponding Author email: a.khadivar@alzahra.ac.ir

Abstract

Research Background: Enhancing customer churn prediction systems in the telecommunications industry is of strategic importance. Customer retention programs achieve their highest level of success when subscribers at risk of churn can be identified with sufficient accuracy before churn actually occurs.

Research Objective: The main objective of this study is to improve the accuracy, efficiency, and practical effectiveness of prediction models for prepaid customer churn, in such a way that the model output demonstrates strong predictive power.

Research Design and Methodology: This study was conducted using field data from 100,000 prepaid subscribers over a one-year period. To preserve practical validity, the data were split in a forward-looking manner. After data cleaning, feature engineering, and controlling for information leakage, a feedforward neural network was designed as the baseline model. Subsequently, key parameters were optimized using a multi-objective genetic algorithm.

Research Findings: The experimental results indicate that the hybrid neural network–genetic algorithm model achieved an improvement of approximately 0.2% on the test set at a practical scale. In addition, the model led to a more balanced distribution of errors between churn and non-churn classes and noticeably improved balanced accuracy compared with the initial model. **Conclusion:** The findings show that even relative improvements in indicators such as recall, when achieved through targeted methods aligned with economic logic, can have a significant impact on the efficiency of retention campaigns and company profitability.

Research Innovation: The main innovation of this study lies in presenting a framework in which, unlike other frameworks, a feedforward neural network is employed to learn nonlinear patterns in subscribers' behavior, while a multi-objective genetic algorithm plays a role not only in tuning the model parameters but also in optimizing the decision threshold, selecting effective features, and improving the network structure. By increasing the identification of actual churn cases and reducing false alarms, this approach enables more precise customer targeting and optimal allocation of marketing resources. Moreover, the model's performance is evaluated not only through statistical metrics but also through practical indicators such as Profit@k and Lift, thereby helping to reduce the gap between statistical prediction and economic decision-making.

Keywords: Customer Churn, Customer Lifetime Value, Genetic Algorithm, Neural Network



نشریه مدیریت تبلیغات و فروش

<https://asm.pgu.ac.ir>

دوره 6، شماره 4، زمستان 1404، پیاپی 24، ص 1-16

شاپا: 3060-8163

شناسه یکتا: 10.22034/asm.2026.2087990.3523



ارائه مدل ترکیبی شبکه عصبی و الگوریتم ژنتیک برای پیش‌بینی ریزش مشتریان (مطالعه موردی: همراه اول)

ندا پروابان¹، آمنه خدیور^{2*}

1. دانشجوی دکترا، گروه مدیریت، دانشکده علوم اجتماعی و اقتصاد دانشگاه الزهراء، تهران، ایران.
2. دانشیار، گروه مدیریت، دانشکده علوم اجتماعی و اقتصاد، دانشگاه الزهراء، تهران، ایران (نویسنده مسئول).

پذیرش: 1404/12/03

دریافت: 1404/11/16

ایمیل نویسنده مسئول: a.khadivar@alzahra.ac.ir

چکیده

زمینه پژوهش: ارتقای سامانه‌های پیش‌بینی ریزش مشتریان در صنعت مخابرات از اهمیت راهبردی برخوردار است. موفقیت برنامه‌های نگهداشت مشتری زمانی به بیشترین سطح خود می‌رسد که بتوان مشتریانی را که در معرض ریزش قرار دارند، با دقت کافی و پیش از وقوع ریزش شناسایی کرد.

هدف پژوهش: هدف اصلی این پژوهش، افزایش دقت، کارایی و اثربخشی عملی مدل‌های پیش‌بینی ریزش مشتریان اعتباری است؛ به گونه‌ای که خروجی مدل قدرت پیش‌بینی بالایی داشته باشد.

طرح و روش‌شناسی پژوهش: این مطالعه بر روی داده‌های میدانی صد هزار مشترک اعتباری طی یک بازه یک‌ساله انجام شده است. برای حفظ اعتبار عملی، تقسیم داده‌ها به صورت آینده‌نگر صورت گرفته است. پس از پالایش داده‌ها، ساخت ویژگی و کنترل نشت اطلاعات، یک شبکه عصبی پیش‌خور به عنوان مدل پایه طراحی شد. سپس با استفاده از الگوریتم ژنتیک چندهدفه، پارامترهای کلیدی بهینه‌سازی شدند.

یافته‌های پژوهش: نتایج تجربی حاکی از آن است که مدل ترکیبی شبکه عصبی-الگوریتم ژنتیک توانسته است در مجموعه آزمون حدود ۰.۲ درصد بهبود در مقیاس عملی ایجاد کند. همچنین، این مدل منجر به توزیع متعادل‌تر خطا میان کلاس‌های ریزش و غیرریزش شده و مقادیر دقت متوازن را نسبت به مدل اولیه به‌طور محسوسه ارتقا داده است. نتیجه‌گیری: یافته‌ها نشان می‌دهد حتی بهبودهای نسبی در شاخص‌هایی نظیر یادآوری، اگر از طریق روش‌های هدفمند و هم‌راستا با منطق اقتصادی حاصل شوند، تأثیر بسزایی بر کارآمدی کمپین‌های نگهداشت و سودآوری شرکت دارند.

نوآوری پژوهش: نوآوری اصلی این پژوهش در ارائه یک چارچوبی است که در آن برخلاف سایر چارچوب‌ها شبکه عصبی پیش‌خور برای یادگیری الگوهای غیرخطی رفتار مشترکین به کار گرفته شده و الگوریتم ژنتیک چندهدفه علاوه بر تنظیم پارامترهای مدل، در بهینه‌سازی آستانه تصمیم، انتخاب ویژگی‌های مؤثر و بهبود ساختار شبکه نیز نقش دارد. این رویکرد با افزایش شناسایی ریزش‌های واقعی، امکان هدف‌گذاری دقیق‌تر مشتریان و تخصیص بهینه منابع بازاریابی را فراهم می‌کند. همچنین عملکرد مدل، علاوه بر معیارهای آماری، با شاخص‌های کاربردی مانند k Profit و Lift ارزیابی شده و به کاهش شکاف میان پیش‌بینی آماری و تصمیم‌گیری اقتصادی کمک می‌کند.

واژه‌های کلیدی: ارزش طول عمر مشتری، الگوریتم ژنتیک، ریزش مشتری، شبکه عصبی

مقدمه

در بازارهای بالغ مخابراتی، ریزش مشتریان یکی از مهم‌ترین عوامل تهدیدکننده سودآوری و پایداری درآمد اپراتورهاست. این مسئله به‌ویژه در میان مشترکین اعتباری برجسته‌تر است؛ زیرا تعهدات قراردادی کوتاه‌مدت، سهولت تغییر اپراتور و حساسیت بیشتر نسبت به قیمت و کیفیت خدمات باعث می‌شود نرخ ریزش در این گروه معمولاً بالاتر باشد (هادن، تیواری، روی، 2007). از سوی دیگر، از آنجا که هزینه جذب مشتری جدید غالباً چندین برابر هزینه نگهداشت مشتریان فعلی است، فقدان مدیریت مؤثر ریزش می‌تواند به کاهش تدریجی ارزش طول عمر مشتریان و در نهایت تضعیف جایگاه رقابتی سازمان منجر شود (لمنز و گوپتا، 2020). بر همین اساس، پیش‌بینی ریزش به‌عنوان یکی از کاربردهای مهم داده‌کاوی و یادگیری ماشین در صنعت مخابرات، توجه زیادی را به خود جلب کرده است.

در پژوهش‌های گذشته، برای شناسایی الگوهای رفتاری که منجر به ریزش مشتری می‌شوند، از روش‌های مختلفی مثل مدل‌های آماری کلاسیک گرفته تا الگوریتم‌های پیشرفته یادگیری ماشین و یادگیری عمیق استفاده شده است؛ (بورز و فن‌دن‌پل، 2009) (عبدالعزیز، بخیت و صلاح، 2025). با وجود تنوع این روش‌ها، در بسیاری از مطالعات، ریزش مشتری عمدتاً به‌عنوان یک مسئله طبقه‌بندی در نظر گرفته شده و ارزیابی مدل‌ها اغلب با معیارهایی مانند دقت یا مساحت زیر منحنی انجام شده است. این شاخص‌ها برای سنجش عملکرد مدل از دیدگاه تحلیلی مفید هستند، اما معمولاً تنها بخشی از تصویر واقعی پیش‌بینی ریزش را نشان می‌دهند. دلیل این موضوع آن است که مدل‌های پیش‌بینی در بسیاری از پژوهش‌ها، پیچیدگی‌های داده‌های واقعی، توزیع نامتوازن کلاس‌ها و ناهمگنی الگوهای رفتاری مشترکان را به‌طور کامل پوشش نمی‌دهند (چن، شو و شیبه، 2024).

نوآوری اصلی این پژوهش در ارائه یک چارچوب تصمیم‌محور برای پیش‌بینی ریزش مشتریان است که در آن، شبکه عصبی پیش‌خور به‌عنوان مدل پایه برای یادگیری الگوهای غیرخطی رفتار مشترکین به‌کار گرفته شده و الگوریتم ژنتیک چندهدفه برای بهینه‌سازی هم‌زمان پارامترهای کلیدی مدل و آستانه تصمیم‌گیری استفاده شده است. برخلاف بسیاری از مطالعات پیشین که صرفاً بر بهبود شاخص‌های طبقه‌بندی تمرکز داشته‌اند، این پژوهش خروجی مدل را به منطق اقتصادی نگهداشت مشتری متصل می‌کند و عملکرد آن را علاوه بر معیارهای آماری، با شاخص‌های عملیاتی مانند Profit@k و Lift نیز ارزیابی می‌نماید. از این‌رو، مقاله حاضر شکاف میان پیش‌بینی آماری و تصمیم‌گیری اقتصادی را هدف قرار داده است.

باید این مسئله را نیز در نظر داشت که ریزش مشتری ذاتاً با نامتوانی کلاس‌ها¹ همراه است؛ یعنی نسبت مشتریان ریزشی در مقایسه با مشتریان وفادار معمولاً کمتر است. در چنین شرایطی، تکیه بر شاخص‌های کلی می‌تواند گمراه‌کننده باشد، زیرا هزینه خطاها معمولاً متقارن نیست؛ از دست دادن تعداد محدودی ریزش واقعی (خطای منفی کاذب) می‌تواند زیانی قابل توجه ایجاد کند، در حالی که تماس یا ارائه پیشنهاد نگهداشت به برخی مشتریان غیرریزش (خطای مثبت کاذب) اغلب هزینه‌ای متفاوت و در بسیاری موارد کمتر دارد (سایتو و هامسامیر، 2015). بنابراین، بهبود پیش‌بینی زمانی ارزشمند است که عملکرد مدل در ناحیه‌های تصمیم‌ساز تقویت شود؛ برای مثال، هنگامی که اپراتور تحت محدودیت ظرفیت ناچار است تنها بخشی از مشتریان را برای اقدام نگهداشت انتخاب کند. در این چارچوب، توجه به معیارهایی مانند مساحت زیر منحنی دقت-یادآوری و نیز معیارهای هزینه‌محور/سودمحور می‌تواند ارزیابی واقع‌بینانه‌تری نسبت به شاخص‌های کلی فراهم کند.

بر این اساس، هدف اصلی این پژوهش توسعه یک رویکرد تصمیم‌محور و اقتصادمحور برای پیش‌بینی ریزش مشترکین اعتباری است؛ به‌گونه‌ای که خروجی مدل بتواند مستقیماً در طراحی اقدامات نگهداشت، از جمله انتخاب مشتریان هدف تحت قیود عملیاتی، به کار گرفته شود. در این پژوهش، ریزش بر اساس تعریف عملیاتی مشخص در افق زمانی تعیین شده (مطابق بخش روش‌شناسی) صورت‌بندی می‌شود و یک مدل ترکیبی مبتنی بر شبکه عصبی و الگوریتم ژنتیک ارائه می‌گردد. در این مدل، الگوریتم ژنتیک برای جست‌وجوی نظام‌مند و بهینه‌سازی مؤلفه‌های کلیدی مدل و سیاست تصمیم‌گیری (مانند تنظیمات مدل و/یا قاعده انتخاب مشتریان) به کار می‌رود تا شناسایی ریزش‌های واقعی در ناحیه‌های تصمیم‌ساز افزایش یابد و هم‌زمان سایر شاخص‌های عملکرد

¹ Class Imbalance

در سطح قابل قبول حفظ شوند. پژوهش حاضر با تکیه بر داده‌های واقعی مشتریان اعتباری همراه اول می‌کوشد پیش‌بینی ریزش را از یک خروجی صرفاً تحلیلی به ابزاری قابل اتکا برای تصمیم‌گیری‌های نگهداشت تبدیل کند.

پیشینه پژوهش

مبانی نظری

1. ارزش طول عمر مشتری¹

ارزش طول عمر مشتری به ارزش فعلی خالص سودهایی اشاره دارد که شرکت انتظار دارد در طول کل دوره رابطه خود با یک مشتری به دست آورد. ارزش طول عمر مشتری یکی از شاخص‌های مهم در مدیریت بازاریابی رابطه‌مند است که برای سنجش سودآوری بلندمدت مشتریان استفاده می‌شود. این مفهوم نشان می‌دهد که هر مشتری چه میزان ارزش اقتصادی برای شرکت در طول کل دوره رابطه خود ایجاد می‌کند. در واقع، ارزش طول عمر مشتری ابزاری است برای ارزیابی اثربخشی استراتژی‌های جذب، نگهداری و توسعه مشتریان و کمک می‌کند تا سازمان‌ها تصمیم بگیرند بر کدام مشتریان تمرکز بیش‌تری داشته باشند. (گوپتا و لهما، 2003)

2. مفهوم ریزش مشتری در صنعت مخابرات

ریزش مشتری در صنعت مخابرات معمولاً به معنای قطع رابطه مشتری با اپراتور یا کاهش معنادار میزان استفاده از خدمات تا حد ترک عملی سرویس و حرکت به سمت گزینه‌های جایگزین است. در ادبیات این حوزه، ریزش به دو شکل مطرح می‌شود: ریزش واقعی که شامل رفتارهای قابل مشاهده مانند غیرفعال شدن خط یا قطع کامل سرویس است و قصد ریزش که به تمایل ذهنی مشتری برای ترک اپراتور در آینده نزدیک اشاره دارد. در بازار تلفن همراه، ریزش اغلب به صورت یک فرایند تدریجی شکل می‌گیرد؛ به این معنا که مشتری به مرور تجربه خود از کیفیت خدمات و ارزش دریافتی را با گزینه‌های جایگزین مقایسه می‌کند و در نهایت تصمیم به ماندن یا ترک اپراتور می‌گیرد. پژوهش‌ها نشان داده‌اند عواملی مانند کیفیت تماس و شبکه، سطح تعرفه‌ها، نوع گوشی و تصویر برند می‌توانند بر احتمال جابه‌جایی اپراتور اثرگذار باشند و حتی ممکن است برخی مشتریان به دلیل وجود هزینه‌های تغییر، با وجود وفاداری واقعی پایین همچنان نزد اپراتور باقی بمانند (کیم و یون، ۲۰۰۴).

3. نظریه تأیید/ناهماهنگی انتظارات و شکل‌گیری رضایت مشتری

یکی از بنیادی‌ترین چارچوب‌های نظری برای توضیح رضایت مشتری، نظریه تأیید یا ناهماهنگی انتظارات است. در مدل شناختی ارائه‌شده توسط (الیور ۱۹۸۰)، رضایت نتیجه مقایسه میان انتظارات پیشین مشتری و عملکرد ادراک‌شده پس از تجربه خدمت است. به بیان دیگر، مشتری پیش از استفاده از یک خدمت استاندارد ذهنی از کیفیت مورد انتظار دارد و تجربه واقعی خود را بر اساس آن ارزیابی می‌کند. اگر عملکرد واقعی مطابق انتظار باشد، تأیید انتظارات رخ می‌دهد و رضایت شکل می‌گیرد؛ اگر عملکرد بهتر از انتظار باشد، ناهماهنگی مثبت ایجاد می‌شود که به افزایش رضایت منجر می‌شود؛ و اگر عملکرد پایین‌تر از انتظار باشد، ناهماهنگی منفی شکل می‌گیرد که معمولاً به نارضایتی می‌انجامد. مطالعات بعدی نیز نشان داده‌اند که سازه‌هایی مانند انتظارات، ادراک عملکرد و میزان ناهماهنگی نقش مهمی در تبیین رضایت مشتری دارند (چرچیل و سورپرنانت، ۱۹۸۲). این چارچوب نظری

¹ CLV

توضیح می‌دهد که چگونه تجربه واقعی خدمت می‌تواند به رضایت یا نارضایتی مشتری منجر شود و در نتیجه بر تداوم یا قطع رابطه با ارائه‌دهنده خدمت تأثیر بگذارد.

4. رضایت، وفاداری و تداوم رابطه با مشتری

در ادبیات بازاریابی، رضایت مشتری یکی از عوامل اصلی در شکل‌گیری وفاداری و کاهش احتمال ریزش محسوب می‌شود. پژوهش‌ها نشان داده‌اند که رضایت مشتری با رفتارهایی مانند تداوم استفاده از خدمات، قصد خرید مجدد و حفظ رابطه با ارائه‌دهنده خدمت ارتباط مستقیم دارد. برای مثال، (اندرسون و سالیوان ۱۹۹۳) نشان دادند که رضایت مشتری می‌تواند احتمال تکرار خرید را افزایش دهد و (بولتون، ۱۹۹۸) نیز بیان می‌کند که رضایت می‌تواند با مدت زمان تداوم رابطه مشتری با ارائه‌دهنده خدمت مرتبط باشد. در صنعت مخابرات، انتظارات مشتریان معمولاً حول محورهایی مانند کیفیت و پوشش شبکه، پایداری اینترنت، شفافیت تعرفه‌ها، کیفیت خدمات دیجیتال و پاسخ‌گویی پشتیبانی شکل می‌گیرد. بنابراین هرگاه تجربه واقعی مشتری در این ابعاد پایین‌تر از انتظارات او باشد، احتمال شکل‌گیری نارضایتی و در نهایت تمایل به ترک اپراتور افزایش می‌یابد.

5. نقش هزینه‌های تغییر در تصمیم به ماندن یا ترک

با وجود اهمیت رضایت مشتری، تحقیقات نشان می‌دهد که رضایت به‌تنهایی قادر به توضیح کامل رفتار ریزش نیست؛ زیرا ممکن است برخی مشتریان با وجود نارضایتی همچنان به دلیل وجود موانع یا هزینه‌های تغییر در رابطه باقی بمانند. برنهام، (فرلز و ماهجان، ۲۰۰۳) هزینه‌های تغییر را به سه دسته اصلی تقسیم می‌کنند: هزینه‌های رویه‌ای که شامل زمان و تلاش لازم برای تغییر ارائه‌دهنده خدمت است، هزینه‌های مالی که به هزینه‌های مستقیم تغییر مانند از دست دادن امتیازات یا پرداخت هزینه‌های جدید اشاره دارد، و هزینه‌های رابطه‌ای که شامل ناراحتی روانی ناشی از قطع رابطه با ارائه‌دهنده خدمت یا از دست دادن پیوندهای اجتماعی است. همچنین (جونز، مادرزیا و بیٹی، ۲۰۰۰) نشان داده‌اند که موانع تغییر می‌توانند نقش تعدیل‌گر در رابطه میان رضایت و قصد ماندن داشته باشند؛ به این معنا که در شرایط نارضایتی، هزینه‌های تغییر می‌توانند مانع خروج مشتری شوند، در حالی که در شرایط رضایت بالا، تأثیر آن‌ها بر تصمیم ماندن کمتر می‌شود.

6. نظریه تعهد در روابط مشتری و ارائه‌دهنده خدمت

در چارچوب بازاریابی رابطه‌مند، تعهد یکی از عوامل کلیدی در حفظ و تداوم روابط بلندمدت میان مشتری و سازمان محسوب می‌شود. (مورگان و هانت، ۱۹۹۴) در نظریه بازاریابی رابطه‌مند بیان می‌کنند که اعتماد و تعهد دو عنصر اساسی برای ایجاد روابط پایدار میان طرفین هستند. تعهد به حالتی روان‌شناختی اشاره دارد که تمایل فرد برای ادامه رابطه با یک سازمان یا برند را نشان می‌دهد. برای تبیین دقیق‌تر این مفهوم، (مایر و آلن، ۱۹۹۱) مدل سه‌بعدی تعهد را ارائه کرده‌اند که شامل تعهد عاطفی، تعهد مستمر و تعهد هنجاری است. تعهد عاطفی به ماندن در رابطه به دلیل دلبستگی و علاقه اشاره دارد، تعهد مستمر ناشی از درک هزینه‌های ترک رابطه است، و تعهد هنجاری به احساس وظیفه یا الزام اخلاقی برای ادامه رابطه مربوط می‌شود. در زمینه خدمات مخابراتی، این چارچوب می‌تواند توضیح دهد که چرا مشتریانی با سطح نارضایتی مشابه ممکن است رفتارهای متفاوتی نشان دهند؛ به‌گونه‌ای که مشتریانی با تعهد مستمر یا هزینه‌های تغییر بالا احتمالاً ترک اپراتور را به تعویق می‌اندازند، در حالی که مشتریانی با تعهد پایین سریع‌تر به سمت گزینه‌های جایگزین حرکت می‌کنند.

جدول 1 جمع‌بندی چارچوب نظری

منابع نظری	نقش در مدل مفهومی	سازه کلیدی
(الیور، 1980)، (چرچیل و سورپرانت، 1982)	ایجاد رضایت/نارضایتی	انتظارات و عملکرد ادراک‌شده
(اندرسون و سالیوان، 1993)، (بولتون، 1998)	اثر مستقیم بر تداوم رابطه	رضایت مشتری
(برنهام، فرلز و ماهاجان، 2003)، (جونز و بینی، 2000)	اثر مستقیم و تعدیل‌گر بر قصد ریزش	هزینه‌های تغییر
(کیم و یون، 2004)	کاهش احتمال ریزش از طریق اعتماد	وفاداری و هویت برند
(مورگان و هانت، 1994)، (مایر و آن، 1991)	نیرو نگه‌دارنده در تصمیم ماندن	تعهد رابطه‌ای

پیشینه تجربی

بررسی مطالعات تجربی در صنعت مخابرات نشان می‌دهد که موفقیت در پیش‌بینی ریزش مشتری بیش از هر چیز به کیفیت داده‌های ورودی، تعریف دقیق عملیاتی از مفهوم ریزش و مهندسی هوشمندانه ویژگی‌ها بستگی دارد. شواهد حاکی از آن است که وقتی داده‌های رفتاری و تعاملی مانند الگوی مصرف، روند تغییرات استفاده، جزئیات تماس و دیتا، و اطلاعات صورت‌حساب با داده‌های مربوط به شکایت‌ها و تعامل با پشتیبانی ترکیب و به‌صورت زمان‌مند مهندسی می‌شوند، قدرت تفکیک مدل‌ها به‌طور معناداری افزایش می‌یابد. در این راستا، پژوهش‌های حوزه تلکام گزارش داده‌اند که ویژگی‌های استخراج‌شده از جزئیات تماس¹ و صورت‌حساب، به‌ویژه با در نظر گرفتن پنجره‌های زمانی دقیق، در مقایسه با ویژگی‌های ایستای جمعیت‌شناختی، کارایی بسیار بالاتری در شناسایی مشتریان در معرض ریزش دارند (هوانگ، کچادی و باکلی، ۲۰۱۲). همچنین مرورهای جدیدتر تأکید می‌کنند که برترین الگوها معمولاً از ترکیب داده‌های چندمنبعی و ویژگی‌های پویا بهره می‌برند، هرچند چالش‌هایی نظیر نویز داده‌ها و پیچیدگی یکپارچه‌سازی آن‌ها همچنان از محدودیت‌های اصلی این حوزه به شمار می‌روند (ایمانی، جودکی، بیک‌محمدی، ۲۰۲۵). پژوهش‌های پیشین نشان می‌دهند که افزایش نرخ ریزش، هزینه جذب مشتریان جدید را بالا برده و موجب از دست رفتن درآمد حاصل از مشتریان فعلی می‌شود؛ از این‌رو، کاهش ریزش مشتری به‌عنوان یکی از اولویت‌های اساسی صنایع مختلف به‌ویژه صنعت مخابرات مطرح است که عاملی مهم در تحلیل رفتار مشتری و طراحی راهبردهای نگهداشت مشتری مورد توجه قرار گرفته است. (زرندی، عطاری، روحانی، 2026)

از منظر سیر تحول روش‌شناسی، موج اول پژوهش‌ها عمدتاً بر روش‌های کلاسیک مانند رگرسیون لجستیک و درخت تصمیم متمرکز بود. این مدل‌ها به‌دلیل سرعت آموزش بالا و قابلیت تفسیر مناسب برای مدیران، کاربرد گسترده‌ای یافتند (کیم و یون، ۲۰۰۴)؛ اما با پیچیده‌تر شدن داده‌های واقعی در صنعت مخابرات و وجود روابط غیرخطی، این روش‌ها به سقف توانمندی خود رسیدند و نیاز به مدل‌های منعطف‌تر احساس شد (هاددن و همکاران، ۲۰۰۷). در موج دوم، با ظهور کلان‌داده‌ها، روش‌های انبوه‌ساز و تقویتی مانند جنگل تصادفی و الگوریتم‌های تقویت‌گرادیانی در کنار معماری‌های یادگیری عمیق وارد ادبیات ریزش شدند. یافته‌ها نشان می‌دهد که این روش‌های پیشرفته، به‌ویژه در معیارهای تفکیک‌پذیری و رتبه‌بندی ریسک، بهبود محسوسی ایجاد می‌کنند، مشروط بر اینکه با قیود عملیاتی سازمان مانند هزینه نگهداشت و سرعت تصمیم‌گیری متوازن شوند (ایمانی، جودکی، بیک‌محمدی، ۲۰۲۵).

یکی از چالش‌های کلیدی که در مطالعات اخیر بر آن تأکید شده، مسئله «جعبه سیاه» بودن مدل‌های پیچیده است؛ چراکه مدیران کسب‌وکار برای طراحی کمپین‌های نگهداشت، نیازمند درک علل ریزش هستند. به همین سبب، ادبیات جدید به سمت

¹ CDR

تبیین‌پذیری^۱ حرکت کرده است. استفاده از رویکردهایی مانند تبیین‌های محلی مستقل از مدل^۲ و ارزش‌های شاپلی^۳ به پژوهشگران این امکان را داده است تا پیش‌بینی‌های پیچیده را به بینش‌های قابل اقدام تبدیل کنند و محرک‌های کلیدی ریزش را برای تصمیم‌گیران شفاف سازند (ریبیرو، سینگ و گوئسترن، ۲۰۱۶؛ لاندبرگ و لی، ۲۰۱۷).

علاوه بر دقت پیش‌بینی، لایه دیگری از مطالعات تجربی بر نحوه ارزیابی و اثرگذاری اقتصادی مدل‌ها تمرکز کرده است. مرور شواهد نشان می‌دهد که بهبود معیارهای آماری (مانند سطح زیر منحنی) لزوماً به معنای افزایش سودآوری سازمان نیست. رویکرد سودمحور پیشنهاد می‌کند که مدل‌ها باید بر اساس بیشینه‌سازی سود کمپین‌های نگهداشت ارزیابی شوند. در همین راستا، تحقیقاتی نشان داده‌اند که هم‌راستا کردن هدف یادگیری مدل با سود واقعی کمپین، می‌تواند نتایج اقتصادی بهتری نسبت به مدل‌های صرفاً ریسک‌محور ایجاد کند (لمنز و گوپتا، ۲۰۲۰). همچنین، برخی پژوهش‌ها از این فراتر رفته و بر نوع مداخله تأکید دارند؛ به طوری که نشان می‌دهند هدف‌گیری دقیق (مثلاً تمرکز بر شبکه اجتماعی مشتری) می‌تواند اثربخشی متفاوتی در مدیریت پیش‌دستانه ریزش داشته باشد (دِ ماتوس، فریرا و بلو، ۲۰۱۸).

در نهایت، ادبیات مربوط به استقرار مدل‌ها هشدار می‌دهد که موفقیت واقعی به یکپارچگی زنجیره «داده-مدل-اقدام» وابسته است. به دلیل پویایی رفتار مشتریان در بازار مخابرات، مدل‌ها به مرور دچار افت عملکرد می‌شوند. لذا، مطالعات جدید بر ضرورت اعتبارسنجی زمان‌مند (به‌جای تقسیم‌بندی تصادفی)، پایش مستمر و توجه به تأخیرهای واقعی در داده‌ها تأکید دارند تا مدل در شرایط عملیاتی پایدار بماند (بوگاچف و آپیشکینا، ۲۰۲۵). بر این اساس، برای پژوهش در بستر همراه اول، ضروری است که تعریف ریزش منطبق بر واقعیت کسب‌وکار باشد، از ویژگی‌های رفتاری زمان‌مند استفاده شود و خروجی مدل نه فقط به‌عنوان یک پیش‌بینی، بلکه به‌عنوان ابزاری برای تصمیم‌گیری سودمحور و تبیین‌پذیر در اختیار مدیران قرار گیرد (لمنز و گوپتا، ۲۰۲۰) (بوگاچف و آپیشکینا، ۲۰۲۵).

روشناسی پژوهش

این پژوهش بر مبنای چارچوب استاندارد «کریسپ-دی‌ام» طراحی و اجرا شده است. هدف اصلی آن انتقال مسئله ریزش مشتری از سطح یک تحلیل صرفاً پیش‌بینانه به سطح تصمیم‌گیری اجرایی و مبتنی بر ارزش اقتصادی است. در این چارچوب، مدل پیش‌بینی باید به‌طور مشخص به سه پرسش عملیاتی پاسخ دهد:

نخست، تعیین این‌که کدام دسته از مشتریان در اولویت مداخله قرار دارند؛ دوم، مشخص‌سازی بازه زمانی مناسب برای انجام مداخله؛ و سوم، تعریف منطق بهینه برای اولویت‌بندی تماس‌ها یا اقدامات نگهداشت.

نقطه عزیمت پژوهش، هم‌راستا کردن فرآیند تحلیل داده با الزامات و محدودیت‌های واقعی کسب‌وکار از جمله نسبت هزینه انواع خطاها، ارزش طول عمر مشتری، محدودیت‌های بودجه‌ای، و ظرفیت عملیاتی واحد تماس یا پیگیری بوده است. بدین ترتیب، رویکرد پژوهش نه تنها بر تولید یک مدل پیش‌بینی، بلکه بر طراحی یک سازوکار تصمیم‌یار و ارزش‌محور متمرکز بوده است.

داده‌های این مطالعه شامل 100,000 مشترک اعتباری حقیقی در یک افق 12 ماهه است که در مجموع حدود 1.2 میلیون رکورد را دربر می‌گیرد. برای کاهش ناهمگنی رفتاری و افزایش دقت تحلیل، مشترکان دائمی و حقوقی از دامنه مطالعه کنار گذاشته شدند و تمرکز بر کاربران دارای سیمکارت اعتباری و گوشی هوشمند قرار گرفت تا استخراج الگوهای مصرفی و رفتاری در محیطی همگن‌تر انجام شود. متغیرهای پژوهش در هشت خوشه اصلی سامان‌دهی شدند که عبارت بودند از ویژگی‌های دموگرافیک، مشخصات سرویس/دستگاه، شاخص‌های مصرف و ترافیک، شاخص‌های درآمدی، رفتار شارژ/پرداخت، تعاملات بین‌شبکه‌ای،

¹ Explainability

² LIME

³ SHAP

متغیرهای زمانی و برجسب هدف. در همین چارچوب، برجسب ریزش با قاعده سه ماه متوالی فعال=1 تعریف شد تا از نوسانات کوتاه مدت عبور شود و تمرکز بر الگوهای پایدار رفتار مشتری حفظ گردد.

در مرحله آماده سازی داده، اطلاعات خام از طریق Impala استخراج و در یک فضای تحلیلی مشترک ذخیره شد. سپس یکپارچه سازی نام گذاری متغیرها، همسان سازی فرمت ها، اصلاح نوع داده ها و حذف رکوردهای نامعتبر انجام گرفت. برای حفظ ترتیب زمانی و پیشگیری از هرگونه نشت اطلاعات، داده ها بر اساس ym_key به صورت صعودی مرتب شدند. در پیش پردازش، برای متغیرهای عددی از میانه گذاری مقادیر گمشده و استانداردسازی استفاده شد و برای متغیرهای رده ای، برحسب کاردینالیتی، رمزگذاری یک دویی یا کدگذاری مبتنی بر فراوانی به کار رفت. همچنین کنترل هم خطی متغیرها و مدیریت نامتوازی کلاس ها از طریق وزن دهی کلاسی انجام شد. نکته کلیدی آن بود که همه تبدیلات داده محور ابتدا فقط روی بخش آموزش برازش داده شدند و سپس همان پارامترها بدون بازبرازش روی مجموعه های اعتبارسنجی و آزمون اعمال گردیدند تا اعتبار بیرونی نتایج حفظ شود. طراحی تقسیم داده به صورت آینده نگر انجام شد تا شرایط واقعی تصمیم گیری سازمان بازنمایی شود. در چینه اصلی، 9 ماه برای آموزش الگوه، 2 ماه برای اعتبارسنجی و تنظیم پارامترها/آستانه ها، و 1 ماه پایانی برای آزمون بیرونی در نظر گرفته شد. در شرایطی که تعداد ماه های یکتای قابل اتکا کاهش یابد، سناریوی پشتیبان 75، 15، 10 قابل اعمال است. این راهبرد زمانی باعث می شود ارزیابی مدل به تصمیم های ماهانه نزدیک شود و خوش بینی مصنوعی ناشی از درهم ریختگی زمانی در نمونه گیری کاهش یابد.

در بخش مدل سازی، یک شبکه عصبی پیش خور به عنوان خط پایه به کار گرفته شد که با تابع فعال سازی واحد خطی یکسوسازی شده¹، منظم سازی L2، نرخ حذف تصادفی و بهینه ساز Adam آموزش دید. در کنار آن، مدل پیشنهادی با حفظ ساختار کلی شبکه، از بهینه سازی ژنتیک چندهدفه برای تنظیم ابرپارامترها بهره گرفت. الگوریتم ژنتیک چندهدفه، نوعی الگوریتم تکاملی مبتنی بر جمعیت است که برای بهینه سازی هم زمان چندین تابع هدف متضاد به کار می رود (Deb, 2001). برخلاف روش های کلاسیک که تنها یک تابع هدف را بهینه می کنند، الگوریتم ژنتیک چند منظوره مجموعه ای از راه حل های بهینه پارتو² را تولید می کند تا تصمیم گیرنده بتواند میان اهداف مختلف تعادل برقرار نماید. این الگوریتم از مفاهیم انتخاب طبیعی و ژنتیک داروینی الهام گرفته است. هر راه حل ممکن یک فرد از جمعیت است و با اعمال عملگرهای ژنتیکی مانند ترکیب³ و جهش⁴ در نسل های متوالی تکامل می یابد. معیار ارزیابی هر فرد در الگوریتم بر اساس رتبه پارتو و تراکم جمعیت محاسبه می شود تا جواب ها هم بهینه و هم متنوع باشند.

مراحل اجرای الگوریتم ژنتیک با مرتب سازی غیرغالب نسخه دوم با تولید یک جمعیت اولیه به صورت تصادفی شامل تعدادی فرد آغاز می شود. در مرحله بعد، تمامی این راه حل ها بر اساس توابع هدف مورد نظر ارزیابی شده و مقادیر آن ها محاسبه می گردد. سپس الگوریتم وارد فرآیند مرتب سازی پارتو می شود که در آن افراد بر اساس مفهوم تسلط، رتبه بندی شده و در جبهه های مختلف پارتو قرار می گیرند. برای حفظ پراکندگی و تنوع پاسخ ها، معیاری به نام فاصله تراکم برای هر فرد محاسبه می شود تا از تجمع بیش از حد راه حل ها در یک نقطه جلوگیری شود. در مرحله انتخاب والدین، از روش تورنمنتی استفاده شده است که در آن اولویت با افرادی است که رتبه پارتوی بهتر (کمتر) و فاصله تراکم بیشتری دارند. پس از انتخاب، عملگرهای ژنتیک شامل ترکیب و جهش روی والدین اعمال می شوند تا جمعیت فرزندان تولید شود. در نهایت، جمعیت والدین و فرزندان با هم ادغام شده و از میان آن ها، فرد برتر بر اساس رتبه و تراکم برای نسل بعدی انتخاب می شوند؛ این چرخه تا زمان رسیدن به معیار توقف یا همگرایی به مجموعه پارتوی نهایی تکرار می گردد. نوآوری اصلی ما استفاده از شبکه عصبی پیش خور برای یادگیری الگوهای غیرخطی رفتار

¹ ReLU

² Pareto-optimal solutions

³ Crossover

⁴ Mutation


مشترکین بوده است، به گونه‌ای که علاوه بر تنظیم پارامترهای کلیدی، برای بهینه‌سازی آستانه تصمیم‌گیری، انتخاب ویژگی‌های مؤثر و بهبود ساختار شبکه نیز استفاده شده است.

منطق تصمیم‌گیری در این پژوهش دو سطح دارد: سطح آماری و سطح اقتصادی. در سطح آماری، آستانه‌ای انتخاب می‌شود که توازن مناسبی بین دقت¹ و نرخ بازخوانی ایجاد کند و کیفیت طبقه‌بندی قابل اتکا فراهم آورد.

برای ارزیابی جامع، مجموعه‌ای از شاخص‌های آماری شامل F1، دقت، نرخ بازخوانی، صحت²، نرخ منفی درست³، دقت متوازن⁴ محاسبه شد تا عملکرد مدل از زوایای مختلف بررسی شود. با توجه به نامتوازن بودن کلاس‌ها، تفسیر نتایج با تأکید بیشتر بر نرخ فراخوانی واف انجام شد. در سطح اقتصادی نیز Profit@k و منحنی‌های Lift/Profit به کار رفتند تا مشخص شود تمرکز بر دسیل‌های بالای ریسک تا چه اندازه به افزایش سود تجمعی منجر می‌شود. برای تقویت وثوق نتایج، فاصله اطمینان بوت‌استرپ مورد استفاده قرار گرفته است.

یافته‌های پژوهش

مقایسه‌ی عملکرد مدل‌ها در مرحله‌ی اعتبارسنجی نشان می‌دهد که هر دو مدل از نظر شاخص دقت-یادآوری نتایج نسبتاً مشابهی حاصل کرده‌اند. شبکه‌ی عصبی ساده با آستانه‌ی تصمیم 0/89، مقدار $F1=0/603$ را به دست آورده است، در حالی که مدل ترکیبی شبکه‌ی عصبی و الگوریتم ژنتیک با آستانه‌ی 0/88، مقدار $F1=0/608$ را نشان می‌دهد. این تفاوت اندک در مقدار F1 بیانگر تعادل مشابه در عملکرد کلی دو مدل است. با این حال، تفاوت اصلی در شاخص بازخوانی مشاهده می‌شود؛ جایی که مدل ترکیبی، توانایی بالاتری در شناسایی نمونه‌های مثبت واقعی از خود نشان می‌دهد. این ویژگی حاکی از آن است که به کارگیری الگوریتم ژنتیک در بهینه‌سازی پارامترهای شبکه‌ی عصبی، به بهبود شناسایی الگوهای مرتبط و در نتیجه افزایش پوشش نمونه‌های مثبت منجر شده است، بی‌آنکه دقت مدل به طور قابل توجهی کاهش یابد. شبکه‌ی عصبی ساده مقدار یادآوری 0/8646 را به دست آورد، در حالی که همانطور که در شکل دو نشان داده می‌شود، ترکیب شبکه‌ی عصبی و الگوریتم ژنتیک مقدار یادآوری به 0/8833 رسید.



شکل 1 نمودار مقایسه شاخص‌های کلیدی دو روش

1 Precision

2 Accuracy

3 Specificity

4 Balanced Accuracy

جدول 2 مقایسه شاخص‌های کلیدی دو مدل

مدل	آستانه	F1	دقت	بازخوانی	دقت	اختصاصیت	دقت
شبکه عصبی ساده	0/89	0/599	0/4586	0/8646	0/9733	0/9759	0/9202
شبکه عصبی و الگوریتم ژنتیک	0/88	0/595	0/4482	0/8833	0/9722	0/9743	0/9288

بر اساس جدول ۳، مدل ترکیبی شبکه عصبی و الگوریتم ژنتیک در مقایسه با شبکه عصبی ساده توانسته است ۰/۰۱۸۷ واحد نرخ یادآوری بالاتری ارائه کند. از میان ۲۲۹۷ مورد مثبت واقعی، مدل ترکیبی ۲۰۲۹ مورد را به‌درستی شناسایی کرده و تنها ۲۶۸ مورد را از دست داده است؛ در حالی که شبکه عصبی ساده ۱۹۸۶ مورد مثبت واقعی را شناسایی کرده و ۳۱۱ مورد را از دست داده است. بنابراین، مدل ترکیبی توانسته است در همان حجم داده، ۴۳ مورد ریزش واقعی بیشتر را شناسایی کند. البته این بهبود با افزایش تعداد هشدارهای کاذب همراه بوده است؛ به‌طوری‌که تعداد موارد غیرریزش که به‌اشتباه به‌عنوان ریزش پیش‌بینی شده‌اند، در مدل ترکیبی ۲۴۹۸ مورد و در شبکه عصبی ساده ۲۳۴۵ مورد بوده است. به عبارت دیگر، هزینه شناسایی ۴۳ ریزش واقعی بیشتر، تولید ۱۵۳ هشدار کاذب اضافی است. همچنین، دقت پیش‌بینی کلاس مثبت در شبکه عصبی ساده برابر با ۰/۴۵۹ و در مدل ترکیبی برابر با ۰/۴۴۸ است که نشان‌دهنده کاهش جزئی در این شاخص است.

جدول 3 ماتریس آشفتگی دو مدل

شبکه عصبی	پیش‌بینی 1	پیش‌بینی 0	شبکه عصبی و الگوریتم ژنتیک	پیش‌بینی 1	پیش‌بینی 0
0 واقعی	2498	94636	0 واقعی	2345	94789
1 واقعی	2029	268	1 واقعی	1986	311

بنابراین، می‌توان نتیجه گرفت که مدل ترکیبی با پذیرش مقدار اندکی افزایش در هشدارهای کاذب، توانسته است پوشش بهتری از موارد ریزش واقعی فراهم کند. از این رو، برتری اصلی مدل ترکیبی در افزایش نرخ شناسایی مشتریان در معرض ریزش است؛ موضوعی که در کاربردهای بازاریابی و کمپین‌های نگهداشت مشتری می‌تواند اهمیت عملی بالایی داشته باشد.

تحلیل هزینه-فایده نشان می‌دهد مدل ترکیبی با کاهش ۴۳ مورد خطای منفی، توانسته مثبت‌های واقعی بیشتری را شناسایی کند. در مقابل، تنها ۱۵۳ مورد هشدار کاذب به خطاهای مدل افزوده شده است. اگر این مبادله از منظر هزینه-فایده بررسی شود، مرز بی‌تفاوتی زمانی رخ می‌دهد که هزینه هر مثبت از دست‌رفته حدود ۳/۵۶ برابر هزینه هر هشدار کاذب باشد. در بسیاری از حوزه‌های عملیاتی، مانند کشف تقلب، پیشگیری از ریزش مشتری و مدیریت ریسک‌های نادر، چنین نسبتی به‌راحتی برقرار است؛ بنابراین، انتخاب مدل ترکیبی از منظر اقتصادی نیز توجیه‌پذیر است.

در بخش شاخص‌های تکمیلی عملکرد، افزون بر امتیاز اف، یک و یادآوری، شاخص‌های دیگری نیز بررسی شدند. دقت متوازن که میانگین حساسیت و ویژگی است، برای شبکه عصبی ساده ۰/۹۲۰ و برای مدل ترکیبی ۰/۹۲۹ به‌دست آمد؛ یعنی حدود ۰/۰۹ واحد درصد بهبود. همچنین، ارزش پیش‌بینی منفی برای شبکه عصبی ساده ۹۹/۶۷ درصد و برای مدل ترکیبی ۹۹/۷۷

درصد بود. این نتایج نشان می‌دهد مدل ترکیبی با وجود حساس تر شدن (یادآوری بالاتر)، همچنان موارد منفی اعلام شده را با اطمینان بسیار بالا و به درستی شناسایی می‌کند.

نتایج مرحله اعتبارسنجی و آزمون نیز هم‌راستایی مطلوبی را نشان می‌دهد؛ نزدیکی مقادیر امتیاز اف، یک در این دو مرحله بیانگر آن است که مدل ترکیبی از نظر تعمیم‌پذیری پایدار بوده و احتمال بیش‌برازش در آن پایین است. با این حال، باید به چند محدودیت مهم نیز اشاره کرد که می‌تواند بر پیاده‌سازی و نگهداشت مدل اثرگذار باشد. نخست، پیچیدگی محاسباتی مدل ترکیبی بیشتر است؛ به گونه‌ای که اجرای الگوریتم ژنتیک به زمان و منابع پردازشی بیشتری نیاز دارد. دوم، پیاده‌سازی و نگهداشت این مدل برای تیم‌های عملیاتی غیرتخصصی دشوارتر است، زیرا ترکیب دو مدل یادگیری، فرایند بهره‌برداری را پیچیده‌تر می‌کند. همچنین، با وجود آنکه افزایش هشدارهای کاذب نسبتاً محدود است (حدود ۰/۲ واحد درصد)، در محیط‌هایی با محدودیت نیروی انسانی یا حساسیت بالا نسبت به هشدارهای نادرست، این افزایش باید با سیاست‌های کنترلی مناسب مدیریت شود.

با توجه به داده‌های موجود و نتایج دیده‌شده، می‌توان نتیجه گرفت که مدل ترکیبی انتخاب بهتری برای استقرار است. این مدل با حفظ قدرت تفکیک بالا و اف یک تقریباً مشابه مدل ساده، توانسته تعداد مثبت‌های کشف شده را افزایش دهد و نرخ از دست رفتن موارد مثبت را از ۱۳/۵ درصد به ۱۱/۷ درصد کاهش دهد. هزینه‌ی این بهبود، تنها افزایش ۱۵۳ هشدار کاذب در کل داده‌ها است که نسبت به سود عملیاتی حاصل از کشف مثبت‌های بیشتر بسیار ناچیز به نظر می‌رسد. همچنین، امکان تنظیم آستانه در مدل ترکیبی وجود دارد؛ بنابراین سازمان می‌تواند متناسب با قیود کسب‌وکار یا محدودیت منابع انسانی، توازن بهینه‌ای بین دقت و یادآوری برقرار کند.

تحلیل معناداری آماری و پایداری نتایج

به منظور اطمینان از اینکه بهبودهای حاصل شده در مدل ترکیبی شبکه عصبی و الگوریتم ژنتیک نسبت به مدل پایه فراتر از نوسانات تصادفی است، از روش بازنمونه‌گیری بوت‌استرپ^۱ با ۱۰۰۰ تکرار برای محاسبه فواصل اطمینان ۹۵ درصد استفاده شد. همچنین برای مقایسه مستقیم عملکرد دو مدل بر روی داده‌های آزمون، آزمون مک‌نمار^۲ که برای مقایسه دقت طبقه‌بندی‌های جفت‌شده مناسب است، به کار گرفته شد. در جدول 4، مقادیر شاخص‌های کلیدی به همراه فاصله اطمینان آن‌ها گزارش شده است.

جدول 4 مقایسه عملکرد مدل‌ها به همراه فاصله اطمینان ۹۵ درصد

مدل	فاصله اطمینان ۹۵٪ یادآوری	شاخص یادآوری	فاصله اطمینان ۹۵٪ اف 1	شاخص اف 1
شبکه عصبی پایه	[0/859 , 0/870]	0/8646	[0/598 , 0/608]	0/603
مدل ترکیبی	[0/878 , 0/889]	0/8833	[0/604 , 0/612]	0/608

¹ Bootstrap

² McNemar's Test

در مجموع، نتایج نشان می‌دهند که استفاده از مدل ترکیبی شبکه‌ی عصبی و الگوریتم ژنتیک رویکردی مطمئن و ارزشمند است. این مدل نه تنها کارایی علمی از نظر FI و سطح زیر منحنی را حفظ می‌کند، بلکه سود عملیاتی قابل توجهی در کشف مثبت‌ها فراهم می‌آورد و به‌طور مستقیم با اهداف راهبردی سازمان هم‌راستا است.

نتیجه‌گیری و پیشنهادها

نتایج پژوهش حاضر نشان می‌دهد که در مدل‌سازی ریزش مشترکین، صرفاً توجه به دقت مدل راهبرد مناسبی نیست؛ بلکه اهمیت زمانی موقعی پدیدار می‌شود که خروجی مدل به فهرست‌های عملیاتی و با توجیه اقتصادی ترجمه گردد. رویکرد ترکیبی شبکه عصبی پیش‌خور و بهینه‌سازی ژنتیک چندهدفه، ضمن حفظ تعادل شاخص‌های کلی، حساسیت را در نواحی تصمیم‌ساز افزایش داد و مدیریت هشدارهای کاذب با تنظیم آستانه و تماس‌های مرحله‌ای به خوبی انجام شد. این اثر در مشترکین اعتباری ملموس‌تر بود، زیرا هر مثبت واقعی از دست‌رفته، کاهش درآمد و تضعیف وفاداری را به دنبال دارد. نتیجه عملی این است که می‌توان در چارچوب بودجه و ظرفیت تماس، پوشش مثبت‌های واقعی را افزایش داد بدون آن‌که تعادل تصمیم خدشه جدی ببیند؛ جایی که خروجی مدل، از امتیاز صرف به تصمیم اقتصادی قابل اجرا ارتقاء می‌یابد.

برتری روش پیشنهادی در هماهنگی ساختار مدل و آستانه تصمیم با هدف اقتصادی نهفته است. بهینه‌سازی ژنتیکی چندهدفه به جای تمرکز بر تنها یک معیار، به صورت همزمان معیارهای کلیدی مانند فراخوانی و امتیاز اف یک و همچنین حجم هشدار را وارد فرآیند می‌کند و ترکیب‌های مناسب از لایه‌ها، نرخ یادگیری و منظم‌سازی را برمی‌گزیند؛ این انتخاب‌ها با ظرفیت واقعی تماس هماهنگ هستند. همچنین آستانه تصمیم، ابتدا بر اساس بیشینه‌سازی امتیاز اف یک و سپس با رویکرد سودمحور و با لحاظ نسبت هزینه خطاها و ارزش عمر مشتری کالیبره شد. این روند موجب شد شکاف رایج بین پیش‌بینی و اقدام کاهش یابد؛ مدل نه تنها علامت زدن صحیح را انجام می‌دهد، بلکه اولویت‌بندی و محدودیت اقدام را نیز تعیین می‌کند.

در مقایسه با مدل‌های پایه و روش‌های مشابه، رویکرد ترکیبی ما در شرایط واقعی تصمیم‌گیری یعنی جایی که محدودیت بودجه و ظرفیت تماس وجود دارد، عملکرد بهتری دارد. این مدل، با افزایش اندک هشدارهای کاذب، در ماه آزمون مشترکین ریزشی بیشتری را شناسایی کرد و هزینه اجرایی در محدوده قابل کنترل باقی مانده است. این دقیقاً همان چیزی است که ادبیات بازاریابی سودمحور توصیه می‌کند: تمرکز بر سود و بازده کمین به جای صرفاً بهبود شاخص‌های کلی.

هنگام تحلیل در نواحی تصمیم‌ساز و به‌ویژه در سطوح بالای ریسک^۱، همسو با ظرفیت تماس، مدل ما فراخوانی، بالابری و سود بالاتری ارائه می‌دهد. نمودارهای دهکی نیز نشان می‌دهند که سود تجمعی در دهک‌های بالای ریسک بیشتر است. درحالی‌که بسیاری از پژوهش‌ها فقط به مشخصه عملکرد گیرنده^۲ و سطح زیر منحنی بسنده کرده‌اند، ما تفسیر را حول سنج‌های اقتصادی و خانواده دقت-فراخوانی شکل داده‌ایم و قیدهای عملیاتی را در فرآیند مدل وارد کرده‌ایم.

از منظر اقتصادی، وقتی هزینه از دست دادن یک مشتری ریزشی از هزینه هشدار کاذب بزرگ‌تر باشد (مثلاً 3/6 برابر)، چارچوب پیشنهادی سود خالص بالاتری تولید می‌کند و به سمت پوشش بیشتر ریزش‌های واقعی هدایت می‌شود. در مقابل، در شرایط بازارهای خاص با ظرفیت تماس محدود یا تغییر نسبت هزینه‌ها، با تنظیم آستانه و محدودکردن اقدام، می‌توان تعادل را حفظ کرد.

محدودیت پژوهش

¹ Top k
² ROC

با وجود نتایج امیدوارکننده، یافته‌های این پژوهش با چند محدودیت همراه است. داده‌های مورد استفاده عمدتاً به مشترکین اعتباری و کاربران تلفن همراه هوشمند محدود بوده و تعمیم نتایج به سایر بخش‌های بازار نیازمند ارزیابی‌های تکمیلی است. همچنین، به دلیل ماهیت پویای رفتار مشتریان، مدل پیشنهادی در معرض رانش مفهومی قرار دارد و پایداری بلندمدت آن مستلزم پایش و بازکالیبراسیون دوره‌ای است. افزون بر این، به‌کارگیری الگوریتم ژنتیک چندهدفه اگرچه به بهبود فراخوانی و سود عملیاتی منجر شده، اما پیچیدگی محاسباتی و هزینه پیاده‌سازی بالاتری نسبت به مدل پایه دارد. از سوی دیگر، بخشی از بهبود عملکرد ناشی از تنظیم آستانه تصمیم است که در صورت تغییر نسبت هزینه‌ها یا ظرفیت تماس، نیازمند بازتنظیم خواهد بود. همچنین، تحلیل اقتصادی مبتنی بر نسبت هزینه خطاها بوده و نبود آزمایش‌های میدانی کنترل‌شده، ارزیابی قطعی اثر علی مداخلات نگهداشت را محدود می‌کند.

پیشنهاد پژوهش‌های آتی

بر این اساس، پژوهش‌های آینده می‌توانند با تمرکز بر آستانه‌گذاری پویا و سیاست‌های اقدام انطباقی، مدل را متناسب با تغییرات ظرفیت تماس و شرایط اقتصادی به‌صورت بلادرنگ تنظیم کنند. استفاده از روش‌های مقابله با رانش مفهومی، یادگیری افزایشی و بازآموزی دوره‌ای، می‌تواند پایداری مدل را در بلندمدت تضمین نماید. همچنین، غنی‌سازی داده‌ها با شاخص‌های تجربه مشتری، سیگنال‌های رفتاری دیجیتال و متغیرهای احساسی، ظرفیت پیش‌بینی و ارزش عملیاتی مدل را افزایش خواهد داد. انجام آزمایش‌های میدانی کنترل‌شده برای سنجش اثر علی مداخلات نگهداشت، مقایسه با مدل‌های پیشرفته‌تر یادگیری عمیق، و تعمیم چارچوب پیشنهادی به سایر بخش‌های بازار، از دیگر مسیرهای مهم پژوهشی است که می‌تواند اثربخشی و قابلیت تعمیم رویکرد حاضر را تقویت کند.

References

- AbdelAziz, N. M., Bekheet, M., Salah, A., El-Saber, N., & AbdelMoneim, W. T. (2025). A comprehensive evaluation of machine learning and deep learning models for churn prediction. *Information*, 16(7): 537. <https://doi.org/10.3390/info16070537>
- Ahn, J. H., Han, S. P., & Lee, Y. S. (2006). Customer churn analysis: churn determinants and mediation effects of partial defection in the Korean mobile telecommunications service industry. *Telecommunications Policy*, 30(10–11): 552–568. <https://doi.org/10.1016/j.telpol.2006.09.006>
- Alotaibi, M. Z., & Haq, M. A. (2024). Customer churn prediction for telecommunication companies using machine learning and ensemble methods. *Engineering, Technology & Applied Science Research*, 14(3): 14572–14578. <https://doi.org/10.48084/etasr.7480>
- Anderson, E. W., & Sullivan, M. W. (1993). The antecedents and consequences of customer satisfaction for firms. *Marketing Science*, 12(2): 125–143. <https://doi.org/10.1287/mksc.12.2.125>
- Ascarza, E., & Hardie, B. G. S. (2013). A joint model of usage and churn in contractual settings. *Marketing Science*, 32(4): 570–590. <https://doi.org/10.1287/mksc.2013.0786>
- Asif, D., & Arif, M. S. (2025). A data-driven approach with explainable artificial intelligence for customer churn prediction in the telecommunications industry. *Results in Engineering*, 26: 104629. <https://doi.org/10.1016/j.rineng.2025.104629>
- Becker, H. S. (1960). Notes on the concept of commitment. *American Journal of Sociology*, 66(1): 32–40.

- Bhattacharjee, A. (2001). Understanding information systems continuance: A Theory. *MIS Quarterly*, 25(3): 351–370. <https://doi.org/10.2307/3250921>
- Bolton, R. N. (1998). A dynamic model of the duration of the customer's relationship with a continuous service provider: The role of satisfaction. *Marketing Science*, 17(1): 45–65. <https://doi.org/10.1287/mksc.17.1.45>
- Borbora, Z., Srivastava, J., Hsu, K. W., & Iams, D. W. (2011). Churn prediction in MMORPGs using player motivation theories and an ensemble approach. In *2011 IEEE International Conference on Privacy, Security, Risk and Trust and IEEE International Conference on Social Computing (PASSAT and SocialCom)* (pp. 157–164). <https://doi.org/10.1109/PASSAT.SocialCom.2011.122>
- Bugajev, A., & Epishkina, A. (2025). Investigating concept drift using a sliding-window approach. *Applied Sciences*, 15(3): 1599. <https://doi.org/10.3390/app15031599>
- Burez, D., & Van den Poel, D. (2009). Handling class imbalance in customer churn prediction. *Expert Systems with Applications*, 36(3): 4626–4636. <https://doi.org/10.1016/j.eswa.2008.05.027>
- Burnham, T. A., Frels, J. K., & Mahajan, V. (2003). Consumer switching costs: A typology, antecedents, and consequences. *Journal of the Academy of Marketing Science*, 31(2): 109–126. <https://doi.org/10.1177/0092070302250897>
- Chen, W., Xu, Y., Xie, H., & Zhou, Z. (2024). A survey on imbalanced learning: latest research developments and future directions. *Artificial Intelligence Review*, 57: 1–72. <https://doi.org/10.1007/s10462-024-10759-6>
- Churchill, G. A., Jr., & Surprenant, C. (1982). An investigation into the determinants of customer satisfaction. *Journal of Marketing Research*, 19(4): 491–504. <https://doi.org/10.1177/002224378201900410>
- De Bock, K. W., & Van den Poel, D. (2012). Reconciling performance and interpretability in customer churn prediction using ensemble learning based on generalized additive models. *Expert Systems with Applications*, 39(8): 6816–6826. <https://doi.org/10.1016/j.eswa.2012.01.014>
- Deb, K., Pratap, A., Agarwal, S., & Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2), 182–197. <https://doi.org/10.1109/4235.996017>
- de Matos, M. G., Ferreira, P., & Belo, R. (2018). Target the ego or target the group: Evidence from a randomized experiment in proactive churn management. *Marketing Science*, 37(5): 793–811. <https://doi.org/10.1287/mksc.2018.1099>
- Gao, L. (X.), de Haan, E., Melero-Polo, I., & Sese, F. J. (2023). Winning your customers' minds and hearts: Disentangling the effects of lock-in and affective customer experience on retention. *Journal of the Academy of Marketing Science*, 51(2): 334–371. <https://doi.org/10.1007/s11747-022-00898-z>
- Gupta, S., Lehmann, D. R., & Stuart, J. A. (2004). Valuing customers. *Journal of Marketing Research*, 41(1), 7–18. <https://doi.org/10.1509/jmkr.41.1.7.25084>
- Hadden, J., Tiwari, A., Roy, R., & Ruta, D. (2007). Computer assisted customer churn management: State-of-the-art and future trends. *Computers & Operations Research*, 34(10): 2902–2917. <https://doi.org/10.1016/j.cor.2005.11.007>
- He, C. G., & Ding, C. H. Q. (2024). A novel classification algorithm for customer churn prediction based on hybrid ensemble fusion model. *Scientific Reports*, 14: 71168. <https://doi.org/10.1038/s41598-024-71168-x>
- Hermawan, D., Wijaya, E., & Daniawan, F. (2022). Customer churn prediction using hybrid sampling and machine learning techniques. *Journal of Business Analytics*, 15(3): 220–236. <https://doi.org/10.1080/2573234X.2022.1875432>

- Imani, M., Joudaki, H., Beikmohamadi, M., & Arabnia, H. (2025). Deep learning–based explainable customer churn prediction: integrating interpretability into AI decision-making. *Journal of Artificial Intelligence Research*, 79: 214–233. <https://doi.org/10.1613/jair.1.14103>
- Jones, M. A., Mothersbaugh, D. L., & Beatty, S. E. (2000). Switching barriers and repurchase intentions in services. *Journal of Retailing*, 76(2): 259–274. [https://doi.org/10.1016/S0022-4359\(00\)00024-5](https://doi.org/10.1016/S0022-4359(00)00024-5)
- Khattak, A., F., & Ahmad, S. (2023). Customer churn prediction using a composite deep learning technique (BiLSTM-CNN). *Neural Computing and Applications*, 35(12): 8635–8651. <https://doi.org/10.1007/s00521-023-08352-1>
- Kim, H., & Yoon, C. (2004). Determinants of subscriber churn and customer loyalty in the Korean mobile telephony market. *Telecommunications Policy*, 28(9–10): 751–765. <https://doi.org/10.1016/j.telpol.2004.05.013>
- 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>
- Lemmens, A., & Gupta, S. (2020). Managing churn to maximize profits. *Marketing Science*, 39(5): 956–973. <https://doi.org/10.1287/mksc.2020.1229>
- Meyer, J. P., & Allen, N. J. (1991). A three-component conceptualization of organizational commitment. *Human Resource Management Review*, 1(1): 61–89. [https://doi.org/10.1016/1053-4822\(91\)90011-Z](https://doi.org/10.1016/1053-4822(91)90011-Z)
- Morgan, R. M., & Hunt, S. D. (1994). The commitment-trust theory of relationship marketing. *Journal of Marketing*, 58(3): 20–38. <https://doi.org/10.1177/002224299405800302>
- Oliver, R. L. (1980). A cognitive model of the antecedents and consequences of satisfaction decisions. *Journal of Marketing Research*, 17(4): 460–469. <https://doi.org/10.2307/3150499>
- Palli, A. S., Jaafar, J., Md Saad, M. H., Mokhtar, A. A., Gomes, H. M., Soomro, A. A., & Gilal, A. R. (2025). Smart adaptive ensemble model for multiclass imbalanced non-stationary data streams. *Scientific Reports*, 15(1): 5122. <https://doi.org/10.1038/s41598-025-05122-w>
- Peng, K., & Peng, Y. (2022). Research on telecom customer churn prediction based on GA-XGBoost and SHAP. *Journal of Computer and Communications*, 10(11): 107–120. <https://doi.org/10.4236/jcc.2022.1011008>
- Poudel, S. S., Pokharel, S., & T. M. (2024). Explaining customer churn prediction in telecom industry using tabular machine learning models. *Machine Learning with Applications*, 9: 100567. <https://doi.org/10.1016/j.mlwa.2024.100567>
- Ranieri, A., Di Bernardo, I., & Mele, C. (2024). Serving customers through chatbots: positive and negative effects on customer experience. *Journal of Service Theory and Practice*, 34(2): 191–215. <https://doi.org/10.1108/JSTP-01-2023-0015>
- Ribeiro, H., Barbosa, B., Moreira, A. C., & Rodrigues, R. (2023). A closer look at customer experience with bundled telecommunication services and its impacts on satisfaction and switching intention. *Journal of Marketing Analytics*. <https://doi.org/10.1057/s41270-023-00222-w>
- Ribeiro, H., Barbosa, B., Moreira, A. C., & Rodrigues, R. G. (2024). Determinants of churn in telecommunication services: a systematic literature review. *Management Review Quarterly*, 74(3): 1327–1364. <https://doi.org/10.1007/s11301-023-00335-7>
- Saito, T., & Rehmsmeier, M. (2015). The precision–recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLOS ONE*, 10(3): e0118432. <https://doi.org/10.1371/journal.pone.0118432>
- Shahabikargar, M., Beheshti, A., & Zhang, X. (2025). A comprehensive survey on customer churn analysis studies. *Journal of Information and Telecommunication*, 9(3): 1–39. <https://doi.org/10.1080/24751839.2025.2528440>
- Taheri, M. H., & Hamdi, K. (2021). Investigating the effect of brand identity on brand evaluation and creation of customer loyalty. *Rahyafti Scientific Quarterly in Business Management*, 2(4): 1. (in Persian)

-
- Weeratunge, H., Robe, D. M., & Hajizadeh, E. (2025). Interpretable SHAP-bounded Bayesian optimization for underwater acoustic metamaterial coating design. *Structural and Multidisciplinary Optimization*, 68(9): 175. <https://doi.org/10.1007/s00158-025-04104-w>
 - Zarandi, M., Attari, A., & Rouhani, S. (2026). Presenting a retention marketing strategy with a customer credit determination approach using neural network data mining. *Journal of Value Creating in Business Management*, 5(4), 380–403. <https://doi.org/10.22034/jvcbm.2025.547114.1634>