



Artificial Neural Networks in E-Commerce Customer Lifetime Value Prediction: The Role of Key Performance Indicators of Customer Satisfaction

Mohammad Faryabi * 

*Corresponding Author, Associate Prof., Department of Management, Faculty of Economics and Management, Tabriz University, Tabriz, Iran. E-mail: faryabi@tabrizu.ac.ir

Vahid Norouzi 

PhD. Candidate, Department of Strategic Management, Faculty of Economics and Management, Tabriz University, Tabriz, Iran. E-mail: v.norouzi@tabrizu.ac.ir

Abstract

Objective

The rapid advancement of machine learning has enabled innovative applications across various business domains. This research explores the potential of neural networks to enhance customer relationship management by accurately predicting Customer Lifetime Value (CLV). By leveraging key performance indicators, including Net Promoter Score (NPS) and Customer Effort Score (CES), as input features, a neural network model is developed. This model aims to establish a predictive relationship between these metrics and CLV, providing valuable insights for businesses to optimize customer retention and revenue generation strategies. The proposed approach offers a scalable and customizable solution, enabling organizations to tailor the model to their specific needs and leverage the power of AI to drive data-driven decision-making.

Methodology

The data were collected in 2023 from customers of an Iranian e-commerce platform, while ensuring the security of customer privacy and business-competitive confidentiality. The dataset includes 8,000 customer profiles with variables such as Customer Lifetime Value (CLV), Promoter Score (PS), Customer Effort Score (CES), and unique 16-digit

Citation: Faryabi, Mohammad & Norouzi, Vahid (2025). Artificial Neural Networks in E-Commerce Customer Lifetime Value Prediction: The Role of Key Performance Indicators of Customer Satisfaction. *Journal of Business Management*, 17(4), 970-1002. <https://doi.org/10.22059/JIBM.2024.375828.4778> (in Persian)



customer identifiers. The model is a sequential neural network with dense and regularized layers, optimized through hyperparameter tuning. The model's performance is evaluated on a 10% test set and a 10% validation set, using metrics such as Mean Absolute Error (MAE), R^2 (coefficient of determination), and other criteria. Additionally, the performance of the artificial neural network model is compared with two baseline models: linear regression and a decision tree. Cross-validation is employed for model validation. Finally, the model is interpreted using SHAP and PFI methods, analyzing the importance of each variable in explaining Customer Lifetime Value.

Findings

The results indicate that the artificial neural network model, with 2 input neurons in the first layer, 5 hidden neurons in the second layer, 7 hidden neurons in the third layer, and 1 output neuron, effectively captures the complex and nonlinear relationships between Promoter Score (PS), Customer Effort Score (CES), and Customer Lifetime Value (CLV). The model achieves a coefficient of determination (R^2) of 0.934 and a Mean Absolute Error (MAE) of 142.47, alongside several other performance metrics. The stable performance without overfitting, as validated through 10-fold cross-validation over 10 rounds, with an early stopping point around the fifth epoch, highlights the model's generalization capability. This allows for robust prediction of Customer Lifetime Value based on PS and CES. The model's ability to capture nonlinear relationships in the data outperforms baseline models (linear regression and decision tree), demonstrating the strength of the neural network. Furthermore, it was revealed that PS explains more variance in CLV than CES does.

Conclusion

This study demonstrated how effectively artificial neural networks can identify hidden patterns within key performance indicators. It highlights the capability of artificial neural networks to predict Customer Lifetime Value (CLV) in e-commerce, enabling the prediction of CLV using Promoter Score (PS) and Customer Effort Score (CES), along with facilitating precise customer segmentation, resource allocation, and strategic growth. Future research could improve CLV prediction by exploring additional datasets and extending the model, as well as investigating the potential of other machine learning algorithms.

Keywords: Artificial neural network, Customer lifetime value, Promoter score, Customer effort score.

شبکه‌های عصبی مصنوعی در پیش‌بینی ارزش طول عمر مشتریان تجارت الکترونیک: نقش شاخص‌های کلیدی عملکردی رضایتمندی مشتریان

محمد فاریابی*

* نویسنده مسئول، دانشیار، گروه مدیریت، دانشکده اقتصاد و مدیریت، دانشگاه تبریز، تبریز، ایران. رایانامه: faryabi@tabrizu.ac.ir

وحید نوروزی

دانشجوی دکتری، گروه مدیریت راهبردی، دانشکده اقتصاد و مدیریت، دانشگاه تبریز، تبریز، ایران. رایانامه: v.norouzi@tabrizu.ac.ir

چکیده

هدف: یکی از روندهای پُر قدرت سال‌های اخیر که با پیشرفت روزافزون تکنولوژی همراه شده است، کاربردهای شبکه‌های عصبی مصنوعی در مدیریت بنگاه‌های تجاری و کسب‌وکارهاست. ظرفیت‌های این روند، به قدری گسترده است که می‌توان از آن برای تصمیم‌گیری و انتخاب راهبردهای کلان یا خرد در کسب‌وکارها بهره برد. هدف این مطالعه، بررسی تأثیر متقابل بین شاخص‌های عملکردی کلیدی امتیاز ترویج‌کننده و امتیاز تلاش مشتری و تأثیر جمعی آن‌ها بر پیش‌بینی ارزش طول عمر مشتری با رویکرد یادگیری ماشینی (شبکه‌های عصبی مصنوعی) است. افزون بر این، پژوهش حاضر به دنبال ارائه یک مدل جامع شبکه عصبی مصنوعی با فراپارامترهای بهینه شده برای تکرار در سطح کسب‌وکارها و بهره‌برداری تجاری از این شیوه، برای هر کسب‌وکار با داده‌های شخصی خود است.

روش: داده‌ها با حفظ امنیت حریم خصوصی مشتریان و حریم خصوصی تجاری - رقابتی، از مشتریان یک سکو (پلتفرم) تجارت الکترونیک ایرانی در سال ۱۴۰۲ به دست آمده و شامل ۸۰۰۰ پروفایل مشتری با متغیرهایی از جمله ارزش طول عمر مشتری، امتیاز ترویج‌کننده، امتیاز تلاش مشتری و شناسه مشتریان (شناسه‌های ۱۶ رقمی یکتا) است. مدل، یک شبکه عصبی متوالی با لایه‌های متراکم و منظم با فراپارامترهای بهینه‌سازی شده است. عملکرد مدل روی یک مجموعه آزمون ۱۰ درصد و اعتبارسنجی ۱۰ درصد و با استفاده از معیارهای میانگین مطلق خطاها، ضریب تعیین و چند معیار دیگر ارزیابی می‌شود؛ سپس با استفاده از دو مدل پایه رگرسیون خطی و درخت تصمیم، توانایی مدل شبکه عصبی مصنوعی ارزیابی می‌شود. برای اعتبارسنجی مدل، از اعتبارسنجی متقابل چندتایی استفاده می‌شود. در انتها با استفاده از SHAP و PFI مدل تفسیر و اهمیت هر متغیر در توضیح ارزش طول عمر مشتری بررسی می‌شود.

یافته‌ها: نتایج نشان می‌دهد که مدل شبکه عصبی مصنوعی با ۲ نورو و ورودی در لایه اول، ۵ نورو پنهان در لایه دوم، ۷ نورو

استناد: فاریابی، محمد و نوروزی، وحید (۱۴۰۴). شبکه‌های عصبی مصنوعی در پیش‌بینی ارزش طول عمر مشتریان تجارت الکترونیک: نقش شاخص‌های کلیدی عملکردی رضایتمندی مشتریان. مدیریت بازرگانی، ۱۷(۴)، ۹۷۰-۱۰۰۲.

تاریخ دریافت: ۱۴۰۳/۰۲/۰۹

تاریخ ویرایش: ۱۴۰۳/۰۷/۰۱

تاریخ پذیرش: ۱۴۰۳/۰۷/۱۸

تاریخ انتشار: ۱۴۰۴/۰۸/۱۰

doi: <https://doi.org/10.22059/JIBM.2024.375828.4778>

مدیریت بازرگانی، ۱۴۰۴، دوره ۱۷، شماره ۴، صص. ۹۷۰-۱۰۰۲

ناشر: دانشکده مدیریت دانشگاه تهران

نوع مقاله: علمی پژوهشی

© نویسندگان

پنهان در لایه سوم و ۱ نورون خروجی در لایه آخر (خروجی)، روابط پیچیده و غیرخطی امتیاز ترویج کننده و امتیاز تلاش مشتری با ارزش طول عمر مشتری را با ضریب تعیین ۰/۹۳۴ و میانگین مطلق خطاهای ۱۴۲/۴۷ و چند معیار دیگر را به طور مؤثر و قدرتمندی پیش بینی می کند. عملکرد پایدار و بدون برازش بیش از حد با شیوه اعتبارسنجی متقابل در مجموعه های آموزشی و آزمایشی در ۱۰ دور ۱۰ تایی با دور عطف حدود ۵ بر تعمیم پذیری مدل تأکید می کند و این اجازه را می دهد که ارزش طول عمر مشتری را توسط امتیاز ترویج کننده و امتیاز تلاش مشتری پیش بینی کنیم. توانایی مدل در گرفتن روابط غیرخطی داده ها در مقایسه با مدل های پایه (رگرسیون خطی و درخت تصمیم) نیز گویای قدرت شبکه عصبی مصنوعی است. همچنین مشخص شد که امتیاز ترویج کننده نسبت به امتیاز تلاش مشتری، واریانس ارزش طول عمر مشتری را بیشتر توضیح می دهد.

نتیجه گیری: پژوهش حاضر نشان داد که شبکه های عصبی مصنوعی تا چه اندازه در یافتن الگوهای نهان در شاخص های کلیدی عملکرد می توانند مؤثر عمل کنند؛ این مطالعه توانایی شبکه های عصبی مصنوعی در پیش بینی ارزش طول عمر مشتری را در تجارت الکترونیک ارائه می دهد و امکان پیش بینی ارزش طول عمر مشتری را توسط امتیاز ترویج کننده و ارزش تلاش مشتری، تقسیم بندی دقیق مشتریان، تخصیص منابع و رشد استراتژیک را فراهم می کند. در تحقیقات آینده می توان پیش بینی ارزش طول عمر مشتری را از طریق مجموعه داده های دیگر و گسترش مدل بهبود داد و همچنین، ظرفیت سایر الگوریتم های یادگیری ماشینی را بررسی کرد.

کلیدواژه ها: شبکه عصبی مصنوعی، ارزش طول عمر مشتری، امتیاز ترویج کننده، امتیاز تلاش مشتری.

مقدمه

ارزش طول عمر مشتری (CLV)^۱ معیاری است که ارزش کل و سودآوری مشتری را در طول رابطه خود برای یک شرکت پیش‌بینی می‌کند. درک و استفاده از این معیار، برای شکوفایی مشاغل در بازارهای رقابتی بسیار مهم است (محمدی و رضایی، ۱۳۹۴). ارزش طول عمر مشتری، به شرکت‌ها اجازه می‌دهد تا در خصوص هزینه‌های جذب مشتری، مدل‌های قیمت‌گذاری و تقسیم‌بندی مشتری، تصمیمات باکیفیت‌تر و آگاهانه‌تری بگیرند. این امر با تخصیص منابع، به‌منظور پرورش با ارزش‌ترین روابط با مشتریان، به بهینه‌سازی تلاش‌های بازاریابی کمک می‌کند (حسینی روش و مقدم، ۱۴۰۲). استفاده از ارزش طول عمر مشتری، کمپین‌های بازاریابی شخصی‌سازی شده را قادر می‌سازد تا مشتریانی را که احتمالاً به این کمپین‌ها پاسخ می‌دهند، هدف قرار دهند. به‌طور کلی، داشتن درک قوی از ارزش طول عمر مشتری و استفاده استراتژیک از آن، می‌تواند مدیریت ارتباط با مشتری را تا حد زیادی بهبود بخشد، رویکردهای بازاریابی را اصلاح کند، وفاداری و حفظ مشتری را افزایش دهد و در نهایت باعث رشد سودآوری پایدار برای کسب‌وکارها و تجارت شود (کوان، مرکوری و کرایشی^۲، ۲۰۲۳).

شبکه‌های عصبی مصنوعی (ANN)^۳، یک رویکرد دگرگون‌کننده برای افزایش پیش‌بینی ارزش طول عمر مشتری ارائه می‌کنند و کسب‌وکارها از ظرفیت این الگوریتم‌ها برای تشخیص الگوهای پیچیده در داده‌های تاریخی گسترده مشتریان خود استفاده می‌کنند (وو و فنگ^۴، ۲۰۱۸). از طریق توسعه و آموزش مدل‌های شبکه‌های عصبی مصنوعی، کسب‌وکارها این توانایی را به دست می‌آورند که مشتریان با ارزش بالا را شناسایی و امکان سفارشی‌سازی استراتژی‌های بازاریابی را به‌طور خاص برای این افراد فراهم کنند (اشمیدگال و همکاران^۵، ۲۰۲۴). این فناوری، تقسیم‌بندی مشتریان را بر اساس ارزش طول عمر مشتری پیش‌بینی شده آن‌ها تسهیل می‌کند و در نتیجه امکان هدف قرار دادن گروه‌های مشتری متمایز با پیشنهادها و تبلیغات سفارشی را فراهم می‌کند. علاوه‌براین، شبکه‌های عصبی با پیش‌بینی آثار ابتکارهای بازاریابی مختلف روی ارزش طول عمر مشتریان، در اصلاح کمپین‌های بازاریابی نقش محوری دارند و در نتیجه، کارآمدترین استراتژی‌ها را مشخص می‌کنند. استقرار استراتژیک شبکه‌های عصبی در پیش‌بینی ارزش طول عمر مشتریان، نه تنها حفظ مشتری و درآمدزایی را افزایش می‌دهد، بلکه بر کارایی تخصیص منابع بازاریابی نیز می‌افزاید (چن، هوآنگ، ژو و جیانگ^۶، ۲۰۲۰).

امتیاز ترویج‌کننده (PS)^۷ وفاداری و رضایت مشتری را اندازه‌گیری می‌کند که از طریق پاسخ‌های داده شده به این سؤال که «در مقیاس ۰-۱۰، چقدر احتمال دارد که شرکت/محصول/خدمات ما را به یک دوست یا همکار توصیه کنید؟»

1. Customer Lifetime Value
2. Cowan, Mercuri & Khraishi
3. Artificial neural networks
4. Wu & Feng
5. Schmidgall et al.
6. Jiang
7. Promoter Score

محاسبه می‌شود. معمولاً این شاخص تحت عنوان خالص امتیاز ترویج‌کننده (NPS)^۱ نیز شناخته می‌شود. نمره‌های بالای امتیاز خالص ترویج‌کننده، نشان‌دهنده مشتریان با ارزش بلندمدت است. تجزیه و تحلیل این رابطه به کسب و کارها کمک می‌کند تا آن‌ها را حفظ و پرورش دهند (آگاک، دورانی، عبدلمعتی، طاهر و عید^۲، ۲۰۲۴). این معیار بازخوردی را برای بهبود تجربه و رضایت مشتریان ارائه می‌دهد که بر ارزش طول عمر مشتری تأثیر می‌گذارد. با این حال، امتیاز ترویج‌کننده باید با معیارهای دیگر برای درک جامع ارزش طول عمر مشتریان مورد استفاده قرار گیرد (اشمیت، میر و سیگرا^۳، ۲۰۱۲).

امتیاز تلاش مشتری (CES)^۴ معیار مهم دیگری در تجارت الکترونیک است که سادگی تعامل مشتریان با پیشنهادهای شرکت را می‌سنجد و به‌طور غیرمستقیم بر ارزش طول عمر مشتری تأثیر می‌گذارد. امتیاز بالای تلاش مشتری، نشان‌دهنده تعامل آسان با مشتری است که به افزایش رضایت مشتری، حفظ و افزایش احتمال توصیه به دیگران منجر می‌شود. این به سهم خود، می‌تواند پایگاه مشتریان را گسترش دهد و با افزایش تعداد و دفعات خرید بر ارزش طول عمر مشتری تأثیر مثبت بگذارد (مولر، سیلر و وولکل^۵، ۲۰۲۴). برعکس، امتیاز پایین تلاش مشتری، ممکن است به نارضایتی و میزان بیشتر ریزش مشتری منجر شود و بر ارزش طول عمر مشتری تأثیر منفی داشته باشد. علاوه بر این، به حداقل رساندن تلاش مشتری می‌تواند هزینه‌های خدمات را کاهش دهد، سودآوری مشتری را افزایش دهد و اعتبار و تمایز برند را تقویت کند. امتیاز تلاش مشتری، به‌طور مستقیم ارزش طول عمر مشتری را اندازه‌گیری نمی‌کند؛ اما در شکل‌دادن به تجربه‌ها و رفتارهای مشتریان نقش مهمی دارد که برای تقویت ارزش طول عمر مشتری حیاتی هستند. شرکت‌هایی که بر کاهش تلاش مشتری تمرکز می‌کنند، می‌توانند به‌طور چشمگیری روابط خود را با مشتری و همچنین ارزش کلی طول عمر مشتریان خود را بهبود بخشند (آگاک و همکاران^۶، ۲۰۲۳؛ داندیس، الحاج عید، رابین و ویرداک^۷، ۲۰۲۲).

استفاده از شبکه‌های عصبی در پیش‌بینی ارزش طول عمر مشتری در تجارت الکترونیک، پتانسیل و ظرفیت امیدوارکننده‌ای را نشان داده است (تسای، هیو، هیونگ و هسو^۸، ۲۰۱۳). با این حال، نیاز به مطالعات جامع‌تری برای بررسی تعامل پیچیده بین ارزش طول عمر مشتری و سایر معیارهای مهم مشتری مانند امتیاز ترویج‌کننده و امتیاز تلاش مشتری وجود دارد. تحقیقات قبلی در وهله نخست، بر بررسی معیارها به صورت جداگانه یا ترکیبات ساده متمرکز شده‌اند و از روابط پیچیده و تأثیر جمعی آن‌ها بر ارزش طول عمر مشتری غفلت کرده‌اند؛ دوم، این قسم از مطالعات به دلیل نیاز به پیچیدگی‌های محاسباتی به شیوه‌های کلاسیک، خروجی چندان مطلوبی به دست نمی‌دهند (گاستزی، رودریگز و

1. Net Promoter Score

2. Agag, Durrani, Abdelmoety, Daher & Eid

3. Schmitt, Meyer & Skiera

4. Customer Effort Score

5. Müller, Seiler & Völkle

6. Hassanein

7. Dandis, Al Haj Eid, Robin & Wierdak

8. Tsai, Hu, Hung & Hsu

کاستیلو^۱، ۲۰۲۴؛ اما این موضوعات سبب نمی‌شود که از چنین مطالعاتی دوری کرد. همچنین بررسی مزایا و محدودیت‌های بالقوه ادغام این معیارها در مدل‌های شبکه عصبی مصنوعی، برای افزایش دقت پیش‌بینی ارزش طول عمر مشتری و توسعه استراتژی‌های بازاریابی مؤثر بسیار مهم است (دای^۲، ۲۰۲۲).

باوجود پیشرفت‌های چشمگیر در استفاده از شبکه‌های عصبی، برای پیش‌بینی ارزش طول عمر مشتری، هنوز کمبودهایی در این حوزه وجود دارد. یکی از اصلی‌ترین ضعف‌ها، کمبود مطالعاتی است که به‌صورت هم‌زمان، به بررسی تأثیر متقابل چندین معیار کلیدی مشتری بپردازند. بیشتر تحقیقات فعلی به تحلیل تک‌بعدی یا ترکیبات ساده از این متغیرها محدود شده‌اند و تعاملات پیچیده بین آن‌ها و تأثیر آن‌ها بر ارزش طول عمر مشتری به‌خوبی بررسی نشده است. علاوه‌براین، ادبیات موجود در خصوص قابلیت تفسیر مدل‌های شبکه عصبی همچنان ناقص است، به‌ویژه در زمینه‌هایی که به ترکیب معیارهایی مانند امتیاز ترویج‌کننده و تلاش مشتری با معیارهای حیاتی مانند ارزش طول عمر مشتری می‌پردازد. تحقیقات بیشتری برای توسعه مدل‌هایی که بتوانند بادقت زیاد و درعین حال با قابلیت تفسیر، این تعاملات پیچیده را شناسایی و توضیح دهند، لازم است.

هدف این مطالعه، پرداختن به تحقیقات محدود قبلی با استفاده از رویکرد جدید محاسباتی یادگیری ماشین، برای بررسی تعامل پیچیده بین امتیاز ترویج‌کننده و تلاش مشتری و تأثیر آن‌ها، بر دقت پیش‌بینی ارزش طول عمر مشتری در تجارت الکترونیک است تا بتواند محدودیت‌های شیوه‌های کلاسیک را تا حدی پشت سر گذارد و همچنین، به‌دنبال یافتن ارتباطات پنهان بین این متغیرهاست که قبلاً مغفول مانده بودند. هدف این پژوهش پُر کردن خلأهای موجود در ادبیات فعلی برای ارزش طول عمر مشتری با استفاده از شبکه عصبی مصنوعی است که در این زمینه، به‌صورت مشترک از نقش امتیاز ترویج‌کننده و امتیاز تلاش مشتری در توضیح ارزش طول عمر مشتری استفاده خواهد شد.

پیشینه نظری پژوهش

ارزش طول عمر مشتری (CLV)

ارزش طول عمر مشتری، شاخص محوری برای شرکت‌هایی است که هدف آن‌ها سنجش سودآوری پایدار مشتریانشان است. این معیار ارزش اقتصادی یک مشتری را برای شرکت، در طول دوره ارتباط خود با همان شرکت را دربرمی‌گیرد (یان و رسنیک^۳، ۲۰۲۴). در محاسبه ارزش طول عمر مشتری، عناصری مانند اندازه متوسط خریدها، دفعات خرید و میزانی که مشتریان حمایت خود را متوقف می‌کنند، برای پیش‌بینی کل درآمدی که مشتری برای یک شرکت به ارمغان می‌آورد، در نظر گرفته می‌شود. علاوه‌براین، ارزش طول عمر مشتری، به‌عنوان ابزاری برای ارزیابی چگونگی تأثیر استراتژی‌های تجربی بر رفتار و وفاداری مصرف‌کننده عمل می‌کند (تودوران، تامسن و توماسن^۴، ۲۰۲۴). از طریق مقایسه ارزش طول عمر مشتری در میان مشتریانی که در معرض کمپین‌ها و برنامه‌های مختلف تجارت الکترونیک قرار

1. Gastuzzi, Rodríguez & Castillo
2. Dai
3. Yan & Resnick
4. Tudoran, Thomsen & Thomsen

دارند، شرکت‌ها می‌توانند بینش‌های ارزشمندی در رابطه با موفقیت تلاش‌های نوسازی خود در ارتقای تجربه مشتری و تقویت ارزش پایدار به‌دست آورند (والنتینی، رودر و کاستران^۱، ۲۰۲۴؛ مرادی، فخرایی و آزاد ارمکی، ۱۴۰۱). محاسبه ارزش طول عمر مشتری، برای شرکت‌ها مزایای متعددی دارد. این امر به تخصیص عاقلانه وجوه بازاریابی کمک می‌کند و با تمرکز بر مصرف‌کنندگان با بیشترین ارزش، بازگشت سرمایه را افزایش می‌دهد. علاوه بر این، در خصوص ماهیت تعاملات و الگوهای مشتری، برای مدیران بینش‌های محوری فراهم می‌کند. این دانش در ابداع تقسیم‌بندی دقیق مشتری که به سهم خود از توسعه رویکردهای بازاریابی که بسیار خاص هستند و همچنین به سفارشی‌سازی محصولات و ساختارهای قیمت‌گذاری، کمک می‌کند (کویکالا، کرالوا و سوچانک^۲، ۲۰۲۴). تجزیه و تحلیل پیش‌بینی‌کننده CLV برای ارزیابی تأثیر خدمات متمرکز بر مشتری، سنجش موفقیت ابتکارها با هدف مدیریت روابط با مشتری و هدایت توزیع منابع بر اساس داده‌های تجربی بسیار ارزشمند است. بینش‌های به‌دست‌آمده از CLV، سازمان‌ها را قادر می‌سازد تا با مشتریان خود پیوندهای قوی‌تری ایجاد کنند، جریان درآمد خود را افزایش دهند و مزیت رقابتی را در چشم‌انداز تجاری پویای امروز حفظ کنند (کوریسکیس، دانگ، جیانگ و اسکار^۳، ۲۰۲۳؛ رحیمی اقدام، فاریابی و عزیزخواه، ۱۳۹۹).

شبکه عصبی مصنوعی (ANN)

مدل‌های شبکه عصبی که از جنبه‌های ساختاری و عملکردی مغز انسان الهام می‌گیرند، الگوریتم‌های یادگیری ماشین را در برمی‌گیرند. این مدل‌ها از شبکه‌ای از واحدها یا گره‌های به‌هم‌پیوسته تشکیل شده‌اند که به آن‌ها نورون‌های مصنوعی گفته می‌شود. این نورون‌ها قادر به پردازش داده‌ها و یادگیری تطبیقی برای اجرای وظایف از طریق اصلاح نقاط قوت اتصالات خود هستند، مشروط به داده‌هایی که با آن‌ها مواجه می‌شوند. در میان انواع مختلف شبکه‌های عصبی، شبکه‌های عصبی رگرسیون، به دلیل توانایی خود در پیش‌بینی نتایج پیوسته، برجسته هستند (اسپچ^۴، ۱۹۹۱). شبکه‌های عصبی رگرسیون که به‌طور خاص برای مرتبط کردن ویژگی‌های ورودی با مقادیر عددی مهندسی شده‌اند، کاربرد گسترده‌ای در پیش‌بینی متغیرهای پیوسته پیدا می‌کنند (کومار، آگاروال و شارما^۵، ۲۰۱۵). این وظیفه شبیه وظایف طبقه‌بندی نیست که با نتایج طبقه‌بندی سروکار دارد؛ شبکه‌های عصبی رگرسیون در پیش‌بینی پدیده‌هایی مانند قیمت‌گذاری، روندهای بازارهای مالی یا سایر خروجی‌های کمی ارزشمند هستند (خدایور، گلستانی و گلشنی، ۱۴۰۲). شبکه‌های عصبی مصنوعی، برای پیش‌بینی ارزش طول عمر مشتری که معیار کلیدی برای سنجش سودآوری بلندمدت مشتری و اصلاح استراتژی‌های مدیریت ارتباط با مشتری است، مزیت شایان توجهی ارائه می‌کنند. مهارت آن‌ها در مدیریت الگوهای پیچیده در مجموعه داده‌های گسترده نهفته است که آن‌ها را به عنوان ابزارهایی قدرتمند برای ثبت پویایی ظریف رفتار مشتری، به‌ویژه در زمینه‌هایی که تعهدهای مشتری غیرقراردادی یا مبتنی بر مدل فریموم است، قرار

1. Valentini, Roederer & Castéran
2. Kvičala, Králová & Suchánek
3. Curiskis, Dong, Jiang & Scarr
4. Specht
5. Kumar, Aggarwal & Sharma

می‌دهد (بوجانوسکا و میلوسز^۱، ۲۰۱۷). در مقایسه با روش‌های مرسوم تخمین CLV، شبکه‌های عصبی عملکرد فوق‌العاده‌ای را ارائه می‌کنند، دقت پیش‌بینی‌ها را افزایش می‌دهند و از تصمیم‌های استراتژیک تجاری آگاهانه‌تر حمایت می‌کنند (صیفا، رونگ، باوخیگ و کلایپر^۲، ۲۰۱۸). شبکه عصبی پرسپترون^۳ (نوعی از شبکه‌های عصبی عمیق) که به دلیل توانایی‌های خود شناخته می‌شود، در طبقه‌بندی غیرخطی و وظایف رگرسیون برتری دارد و به عنوان یک جزء اساسی برای شبکه‌های پیچیده‌تر و دروازه‌ای برای درک محاسبات عصبی عمل می‌کند (کینگ، کیم و یون^۴، ۲۰۲۴). با گسترش این موضوع، شبکه‌های عصبی پرسپترون چندلایه معماری پیچیده‌تری را با حداقل سه لایه، شامل ورودی، یک یا چند لایه پنهان و یک لایه خروجی معرفی می‌کنند که پردازش داده‌های خام را از طریق تبدیل‌های غیرخطی امکان‌پذیر می‌سازد. این شبکه‌ها که قادر به یادگیری توابع غیرخطی پیچیده هستند، علی‌رغم نیازهای محاسباتی‌شان، در کاربردهای مختلف از تشخیص تصویر گرفته تا پردازش زبان طبیعی، حیاتی هستند (راک، راجرز و کابیرسکی^۵، ۱۹۹۰). آن‌ها از طریق یادگیری نظارت شده آموزش می‌بینند که وزن اتصال را بر اساس دقت خروجی اصلاح می‌کند و به تدریج عملکرد داده‌های آموزشی را افزایش می‌دهد (لی، تانگ و چنگ^۶، ۲۰۲۲).

خالص امتیاز ترویج‌کننده (NPS)

خالص امتیاز ترویج‌کننده، معیاری است که برای ارزیابی وفاداری مشتری و سلامت کلی یک سازمان به کار می‌رود و این احتمال را می‌سنجد که مشتریان محصولات یا خدمات، تا چه اندازه یک شرکت را به دیگران توصیه کنند (فیشر و کوردوپلسکی^۷، ۲۰۱۹). خالص امتیاز ترویج‌کننده، مشتریان را به سه بخش ترویج‌کنندگان، منفعلان و مخالفان دسته‌بندی دسته‌بندی می‌کند. مبنای این دسته‌بندی، پاسخ مشتریان به این سؤال است: در مقیاس ۰ تا ۱۰، چقدر احتمال دارد که شرکت / محصول / خدمات ما را به یک دوست یا همکار توصیه کنید؟ در اینجا شرح کوتاهی از این دسته‌بندی‌ها ارائه شده است:

- ترویج‌کنندگان (۹-۱۰): این مشتریان هم وفادار و هم مشتاق هستند، احتمالاً خریدهای تکراری انجام می‌دهند و دیگران را معرفی می‌کنند و در نتیجه به رشد کسب‌وکار کمک شایانی می‌کنند.
 - منفعلان (۷-۸): در حالی که این مشتریان راضی هستند، شور و اشتیاق ندارند و ممکن است به رقبای بی‌اورند.
 - مخالفان (۰-۶): مشتریان ناراضی که می‌توانند از طریق بازخورد منفی به برند آسیب برسانند.
- مقدار خالص امتیاز ترویج‌کننده با کم کردن درصد مخالفان از درصد ترویج‌کنندگان محاسبه می‌شود. به سخی دیگر، ما برای محاسبه خالص امتیاز ترویج‌کننده به امتیازات ترویج‌کننده (PS) نیاز داریم. اگرچه منفعلان به میزان پاسخ

1. Bojanowska & Milosz
 2. Sifa, Runge, Bauckhage & Klapper
 3. Perceptron Neural Network
 4. King, Kim & Yune
 5. Ruck, Rogers & Kabrisky
 6. Li, Tang & Cheng
 7. Fisher & Kordupleski

کلی کمک می‌کنند و بر درصد نسبی ترغیب‌کنندگان و مخالفان تأثیر می‌گذارند؛ اما به‌طور مستقیم بر محاسبه NPS تأثیر نمی‌گذارند. این معیار برای درک وفاداری مشتری و شناسایی زمینه‌های بهبود در ارائه خدمات یا محصول بسیار مهم است (بیتنکورت و همکاران^۱، ۲۰۲۳؛ اوسمانسکی زنک، النریدر، میتلمییر و کلیندر^۲، ۲۰۲۳). گفتنی است که در مطالعه حاضر، امتیاز ترویج‌کننده (PS) بررسی شده است.

امتیاز تلاش مشتری

امتیاز تلاش مشتری، شاخص محوری برای کسب‌وکارها و سازمان‌ها به‌منظور ارزیابی سطح تلاش موردنیاز مشتریان در تعامل آن‌ها با یک نام تجاری است. معیار امتیاز تلاش مشتری بر این اصل بنا شده است که کاهش تلاش مشتریان با افزایش رضایت همراه است و احتمال بیشتری برای ادامه مشارکت، حمایت و توصیه به دیگران ایجاد می‌کند. این شاخص کلیدی عملکرد، از طریق تلاش مشتریان در تکمیل وظایف یا حل مشکلات، پوشش طیف گسترده‌ای از فعالیت‌ها مانند کمک‌گرفتن از پشتیبانی مشتری، خرید، یا ثبت‌نام برای خدمات سنجیده می‌شود. به‌طور معمول در مقیاس عددی نشان می‌دهد که نمره‌های بالاتر، نشان‌دهنده تلاش کمتر و در نتیجه افزایش رضایت مشتری است. سازمان‌ها از CES برای مشخص کردن فرصت‌ها برای افزایش تجربه مشتری و کاهش احساس ناامیدی یا ناراضی استفاده می‌کنند. نظارت بر CES در طول زمان امکان استخراج بینش‌های مهم در عملکرد خدمات مشتری و ابتکارات پشتیبانی، در کنار شناسایی چشم‌اندازهایی برای بهینه‌سازی فرایند و ساده‌سازی تعاملات با مشتری را فراهم می‌کند. چنین پیشرفت‌هایی می‌تواند به تقویت وفاداری مشتری، افزایش سطح رضایت و در نهایت افزایش درآمد و گسترش کسب‌وکار منجر شود. CES در مقیاس لیکرت از ۱ تا ۷ اندازه‌گیری می‌شود که در آن، نمرات کمتر نشان‌دهنده تلاش بیشتر و نمرات بالاتر نشان‌دهنده تلاش کمتر است و برای محاسبه آن، از مشتریان درباره راحتی دسترسی به پلتفرم پرسیده می‌شود (آردلت و بناونت^۳، ۲۰۲۲).

مبانی تجربی و تحلیل شکاف پژوهش

امتیاز ترویج‌کننده با ارزش طول عمر مشتری، هم‌بستگی دخور توجهی بروز می‌دهد. با شواهدی که در مطالعات پیشین ارائه شده است، مشتریانی که مروج هستند (آن‌هایی که رتبه‌بندی PS بالاتری دارند) CLV بیشتری از خود نشان می‌دهند. منطق پشت این ارتباط آن است که مشتریانی که تمایل دارند یک شرکت را توصیه کنند، معمولاً وفاداری و مشارکت بیشتری را از خود بروز می‌دهند که به روابط پایدار و افزایش سودآوری در طول زمان تبدیل می‌شود (اشمیت و همکاران، ۲۰۱۲؛ لی و جیانگ^۴، ۲۰۲۱). بررسی رابطه بین PS و CLV شرکت‌ها را قادر می‌سازد تا مشتریانی را که احتمال ارزش بلندمدت بیشتری را ارائه می‌دهند، شناسایی و روی آن‌ها تمرکز کنند. علاوه‌براین، امتیاز ترویج‌کننده به‌عنوان یک ابزار حیاتی برای جمع‌آوری بازخورد عمل می‌کند که می‌تواند در افزایش تجربه‌ها و سطح رضایت مشتری

1. Bitencourt et al.

2. Osmanski-Zenk, Ellenrieder, Mittelmeier & Klinder

3. Ardelet & Benavent

4. Lee & Jiang

مؤثر باشد و در نتیجه تأثیر مطلوبی بر CLV بگذارد (زیگلر، پیسل و رائیاساید^۱، ۲۰۲۳؛ هاردیانتو و ویجایا^۲، ۲۰۲۳). درحالی‌که مطالعات موجود، هم‌بستگی مثبتی را بین PS و CLV نشان داده‌اند، محدودیت‌هایی وجود دارد. PS یک‌بعدی است، تحت تأثیر عوامل زمانی است و می‌تواند از نظر فرهنگی سوگیری داشته باشد (کریستسن و اسکلیدسن^۳، ۲۰۱۴؛ اوون^۴، ۲۰۱۹). علاوه‌براین، رابطه بین PS و CLV لزوماً خطی نیست (اشمیت و همکاران، ۲۰۱۲).

درک تعامل بین امتیاز تلاش مشتری و ارزش طول عمر مشتری برای شرکت‌ها بسیار مهم است، با توجه به اینکه پیشرفت در CES می‌تواند به‌طور شایان توجهی بر CLV به‌شيوه‌ای مطلوب تأثیر بگذارد. مشاهده شده است که مشتریانی که سطوح تلاش کمتری را تجربه می‌کنند (که در CES بالا منعکس می‌شود) تمایل به نشان‌دادن CLV بالاتری دارند که به دلیل افزایش رضایت و وفاداری آن‌ها نسبت به برند است. این وفاداری نه‌تنها حمایت مداوم را تضمین می‌کند، بلکه ارجاعات مثبت را نیز تقویت می‌کند. برعکس، مشتریانی که در تعاملات خود با یک شرکت با سطوح بالایی از تلاش مواجه می‌شوند (که با CES پایین مشخص می‌شود) تمایل بیشتری به تغییر به سمت رقبا دارند و در نتیجه CLV خود را کاهش می‌دهند (سیمپسون^۵، ۲۰۲۳). برای تقویت رضایت مشتری، تقویت وفاداری و در نهایت بالا بردن CLV، به شرکت‌ها توصیه می‌شود تلاش مشتری را کاهش (امتیاز تلاش مشتری را افزایش) دهند. این را می‌توان با بهینه‌سازی تلاش مشتری، ارائه گزینه‌های سلف سرویس بصری و رفع پیشگیرانه نگرانی‌های مشتری به‌دست آورد (داندیس و همکاران، ۲۰۲۳؛ داندیس و همکاران، ۲۰۲۲). رابطه بین امتیاز تلاش مشتری و ارزش طول عمر مشتری یک رابطه پیچیده است، CES بر تعاملات خاص تمرکز دارد، در حالی که CLV نگاهی کل نگر از سفر مشتری دارد. این بدان معناست که اگر عوامل دیگری مانند ترجیحات رفتاری یا وفاداری به برند در نظر گرفته نشوند، ارزش طول عمر مشتریان، به‌صورت کامل پیش‌بینی نمی‌شود و این ممکن است تأثیر مستقیم تلاش مشتری بر ارزش طول عمر را پنهان کند (ونکاتسان، بلیر، رینارتز و راویشانکر^۶، ۲۰۱۹). علاوه‌براین، هم‌بستگی بین CES و CLV ممکن است در صنایع و بخش‌های مشتریان متفاوت باشد و نتیجه‌گیری جهان‌شمول در مورد رابطه آن‌ها را دشوار می‌سازد. در نهایت، در حالی که CES و CLV هر دو معیارهای ارزشمندی برای درک رفتار مشتری و بهینه‌سازی استراتژی‌های کسب‌وکار هستند، نیازمند ادغام با سایر معیارهای عملکردی مشتریان است (دی‌هان، ورهوف و ویسل^۷، ۲۰۱۵).

استفاده از امتیاز ترویج‌کننده و امتیاز تلاش مشتری، درک جامعی از تجربه و وفاداری مشتری را فراهم می‌کند. این ترکیب بینش‌های تکمیلی را ارائه می‌دهد و به کسب‌وکارها اجازه می‌دهد نقاط اصطکاک خاص و روندهای رضایت کلی را شناسایی کنند. با ادغام هر دو معیار در حلقه‌های بازخورد، سازمان‌ها می‌توانند تصمیمات آگاهانه‌ای برای بهبود تجربه‌های مشتری، تخصیص استراتژیک منابع و در نهایت افزایش نرخ حفظ و حمایت از مشتری اتخاذ کنند. امتیاز

1. Ziegler, Peisl & Raeside

2. Hardianto & Wijaya

3. Kristensen & Eskildsen

4. Owen

5. Simpson

6. Venkatesan, Bleier, Reinartz & Ravishanker

7. De Haan, Verhoef & Wiesel

ترویج‌کننده و تلاش مشتری با هم دیدگاهی جامع از احساسات مشتری ایجاد می‌کنند که از بهبود مستمر در ارائه خدمات و محصولات پشتیبانی می‌کند (گاستری و همکاران، ۲۰۲۴؛ باکوئرو^۱، ۲۰۲۲).

در سوی دیگر، شبکه‌های عصبی توانایی زیادی در شناسایی و استخراج الگوهای پیچیده و غیرخطی از داده‌ها دارند. شبکه‌های عصبی با امکان ترکیب تعداد زیادی از ویژگی‌ها و مدیریت داده‌های با ابعاد بالا، قادر به ایجاد مدل‌هایی هستند که می‌توانند روابط پنهان و پیچیده را بهتر شناسایی کرده و پیش‌بینی‌های دقیق‌تری ارائه دهند. این رویکرد باعث می‌شود که شبکه‌های عصبی نسبت به مدل‌های خطی ساده عملکرد بهتری داشته باشند، به‌ویژه در مواردی که داده‌ها پیچیدگی‌های زیادی دارند یا تعاملات بین متغیرها غیرخطی است (فیرمانسیاه، ماچادو و موریرا^۲، ۲۰۲۴؛ اسدی ایجگردی و کازرونی^۳، ۲۰۲۴).

با وجود این، چالش‌هایی نیز در استفاده از شبکه‌های عصبی وجود دارد. یکی از مشکلات اصلی، خطر برازش بیش از حد است که در آن، مدل به‌جای شناسایی الگوهای کلی داده، جزئیات و نوسان‌های داده‌های آموزشی را به‌خاطر می‌سپارد. این مسئله باعث می‌شود که مدل روی داده‌های جدید و خارج از نمونه‌های آموزشی عملکرد ضعیفی داشته باشد. علاوه بر این، شبکه‌های عصبی به دلیل پیچیدگی خود اغلب با مشکل عدم تفسیرپذیری مواجهند؛ یعنی ممکن است مدل پیش‌بینی‌های دقیقی انجام دهد؛ اما فهمیدن چگونگی و چرایی این پیش‌بینی‌ها برای انسان دشوار است. این عدم شفافیت، در حوزه‌هایی که تصمیم‌گیری‌های تجاری مهمی بر اساس نتایج مدل صورت می‌گیرد، می‌تواند محدودیت‌ساز باشد (بوس و ماهاپاترا^۴، ۲۰۰۱؛ بوسما و ون ویتلوستاین^۵، ۲۰۲۴). علاوه بر این، شبکه‌های عصبی ممکن است به سوگیری سوگیری داده‌ها حساس باشند؛ اگر داده‌های آموزشی ناعادلانه یا نادرست باشند، مدل نیز به همان نسبت نتایج نادرست یا جانب‌دارانه ارائه می‌دهد (کاتون و هاس^۶، ۲۰۲۴).

مطالعات پیشین اغلب این شاخص‌ها را به‌صورت جداگانه یا در ترکیبات محدود بررسی کرده‌اند و نیاز به پژوهش‌های جامع‌تری را که تأثیر ترکیبی این متغیرها بر دقت پیش‌بینی ارزش طول عمر مشتری تحلیل کنند، برجسته ساخته‌اند. افزون بر این، مطالعات قبلی در این زمینه روابط بین شاخص‌های کلیدی عملکردی را خطی در نظر گرفته‌اند و از روابط غیرخطی غافل شده‌اند که این نگاه، بسته در دنیای پیچیده تجارت، می‌تواند نتایج و تحلیل‌های دارای سوگیری و تعصب به وجود بیاورد؛ از این رو در مطالعات پیش‌رو باید از روش‌ها و مدل‌هایی بهره برده شود که توانایی شناسایی روابط غیرخطی را نیز داشته باشند، یادگیری ماشین یکی از توانمندترین روش‌های حال حاضر است؛ اما تحقیقات پیشین نشان می‌دهند که در بهره‌گیری از مدل‌های یادگیری ماشین در حوزه کسب‌وکار، چالش‌های مهمی همچون خاصیت جعبه سیاه، خطر برازش بیش از حد و تفسیرپذیری پایین وجود دارد که از موانع کلیدی هستند. این تحقیقات روی نیاز به یک سازوکار ثابت و توانمند برای پرداختن به این چالش‌ها تأکید کرده‌اند.

1. Baquero

2. Firmansyah, Machado & Moreira

3. Asadi Ejgerdi & Kazerooni

4. Bose & Mahapatra


5. Bosma & Witteloostuijn

6. Caton & Haas

مطالعه حاضر باهدف پُرکردن این شکاف‌ها، از شبکه‌های عصبی مصنوعی قابل‌تفسیر برای پیش‌بینی ارزش طول عمر مشتری استفاده می‌کند که در آن، امتیاز ترویج‌کننده و امتیاز تلاش مشتری ادغام شده‌اند. این رویکرد امکان تحلیل روابط غیرخطی بین این متغیرها را فراهم می‌آورد و شفافیت و تفسیرپذیری را نیز ارائه می‌کند؛ ویژگی‌هایی که معمولاً در شبکه‌های عصبی سنتی نادیده گرفته می‌شوند. علاوه‌براین، تمرکز بر امتیاز ترویج‌کننده و امتیاز تلاش مشتری به ما اجازه می‌دهد تا دیدگاه‌های دقیق‌تری از رفتار مشتری و ارزش بلندمدت آن‌ها ارائه کنیم و به محدودیت‌های مطالعات موجود که این شاخص‌ها را به‌طور جداگانه تحلیل کرده‌اند، غلبه کنیم. این پژوهش همچنین به‌دنبال توسعه چارچوبی قدرتمند و پایدار برای تفسیرپذیری مدل‌های یادگیری ماشین در حوزه کسب‌وکار است.

روش‌شناسی پژوهش

شکل ۱، یک نمودار شماتیک از روش گردش کار پیشنهادی برای پیش‌بینی ارزش طول عمر مشتری در تجارت الکترونیک با استفاده از مدل‌های شبکه عصبی با امتیاز ترویج‌کننده و امتیاز تلاش مشتری ارائه می‌کند. این نمودار به‌عنوان فرایند کلی استفاده از یادگیری ماشینی برای مسائل رگرسیونی به‌شیوه اعتبارسنجی متقاطع استفاده می‌شود که در زیر به تفصیل توضیح داده شده است.



شکل ۱. جریان کار پژوهش



گردآوری و پیش‌پردازش داده‌ها

مجموعه داده مورداستفاده در این مطالعه، از یک پلتفرم تجارت الکترونیک ایرانی به‌دست‌آمده است و شامل داده‌های ثانویه (محاسبه شده توسط خود کسب‌وکار) در مورد ۸۰۰۰ مشتری در سال ۱۴۰۲ است. داده‌ها به‌صورت تصادفی و بدون مقادیر از دست رفته^۱ جمع‌آوری شد تا به ۸۰۰۰ نقطه داده رسید. متغیرهای مجموعه داده که توسط خود کسب‌وکار محاسبه می‌شود، عبارت‌اند از: شناسه مشتری، ارزش طول عمر مشتری، امتیاز تلاش مشتری و امتیاز ترویج‌کننده. جمع‌آوری داده‌ها برای محافظت از حریم خصوصی مشتریان کاملاً ناشناس بود و هویت پلتفرم تجارت الکترونیک و برند آن برای اطمینان از حریم خصوصی تجاری و رقابتی فاش نشد. برای استفاده از داده‌های مشتریان یک اجازه رسمی در وبگاه پلتفرم منتشر شد و مشتریان با تأیید آن اجازه استفاده از داده‌های خود را به‌صورت مکتوب و رسمی صادر کردند. این مجموعه داده از طریق یک درگاه آنلاین امن قابل دسترسی و به‌طور کامل تمیز و از قبل پردازش شده بود تا اطمینان حاصل شود که در طول تجزیه و تحلیل امکان نشت اطلاعات مشتریان وجود نداشته باشد. با توجه به نکات ذکر

1. Missing Data

شده، داده‌های کلان را برای اهداف پژوهشی با احترام و مسئولیت حفظ حریم خصوصی به دست آوردیم. خلاصه‌ای از آمار توصیفی و توزیع داده‌های امتیاز ترویج‌کننده (PS) و امتیاز تلاش مشتری (CES) در جدول ۱ ارائه شده است.

جدول ۱. آمار توصیفی و نمودار توزیع

معیار	امتیاز ترویج‌کننده (PS)	امتیاز تلاش مشتری (CES)
اندازه نمونه	۸۰۰۰ (بدون داده گمشده)	۸۰۰۰ (بدون داده گمشده)
میانه	۷	۲
مد	۸	۱
حدود	۰ - ۱۰	۱ - ۷
نمودار توزیع		

نکته حائز اهمیت که نباید از یاد برد، پیش‌پردازش امتیاز تلاش مشتری است؛ زیرا در این متغیر حدود داده‌ها، بین ۱ تا ۷ به دست می‌آیند و این سبب می‌شود که در هنگام مدل‌سازی در شبکه عصبی مصنوعی دچار خطا شویم؛ از این‌رو در پژوهش حاضر، پیش از ساختن مدل، داده‌های امتیاز تلاش مشتری را با روش «رمزگذاری ترتیبی»^۱ به مقادیری تبدیل می‌کنیم که برای مدل فهم‌پذیر باشد. داده‌های امتیاز تلاش مشتری، بعد از این پیش‌پردازش، به مقادیر بین ۰ تا ۶ تغییر یافت تا موقع مدل‌سازی دچار مشکل نشویم. همچنین با توجه به ماهیت داده‌های مربوط به امتیاز ترویج‌کننده نیازی به پیش‌پردازش در این متغیر وجود نداشت.

مدل‌سازی و آموزش مدل

مدل مورد بحث با استفاده از «رابط برنامه‌نویسی کاربردی متوالی کراس»^۲ ساخته شده است که روشی ساده و انعطاف‌پذیر برای ساخت شبکه‌های عصبی در زبان برنامه‌نویسی پایتون است. مدل ما چهار لایه دارد که به ترتیب، یک لایه ورودی، دو لایه پنهان و یک لایه خروجی آن را تشکیل می‌دهند. لایه ورودی، یک لایه متراکم با دو نورون است که با تعداد ویژگی‌هایی که مدل به عنوان ورودی نیاز دارد، مطابقت می‌کند. اولین لایه پنهان نیز یک لایه متراکم با پنج نورون است و از تابع فعال‌سازی «واحد خطی اصلاح‌شده»^۳ و منظم‌سازی «الاستیک نت»^۴ با فرآیندهای $L_1 = 0.2$ و $L_2 = 0.2$ به ترتیب استفاده می‌کند. لایه پنهان دوم، یک لایه متراکم با هفت نورون است و همان عملکردهای فعال‌سازی و


1. Ordinal Encoding

2. Keras Sequential API

3. Rectified Linear Unit (ReLU)

4. ElasticNet

منظم‌سازی لایه پنهان اول را دارد. لایه خروجی، یک لایه متراکم با یک نورون منفرد است که برای مسائل رگرسیونی مناسب است. مدل با «تابع زیان خطای میانگین مربع»^۱ و بهینه‌ساز «آدام»^۲ اجرا شده است. تابع زیان خطای میانگین مربع برای ارزیابی عملکرد مدل استفاده می‌شود. تنظیم فرایارامتر الاستیک نت، برای جلوگیری از برازش بیش از حد و بهبود تعمیم به لایه‌های پنهان اعمال می‌شود. تابع فعال‌سازی واحد خطی اصلاح‌شده در لایه‌های پنهان استفاده می‌شود تا غیرخطی بودن را معرفی کند و به مدل اجازه دهد تا روابط پیچیده‌تری بین ویژگی‌های ورودی و خروجی بیاموزد. همان‌طور که ذکر شد، این مدل با تابع زیان خطای میانگین مربع و بهینه‌ساز آدام ساخته شده است که نوعی الگوریتم «نزولی گرادیان تصادفی»^۳ است و از نرخ‌های یادگیری تطبیقی استفاده می‌کند. نمای شماتیک مدل ساخته شده در شکل ۲ مشاهده می‌شود.



شکل ۲. مدل شبکه عصبی مصنوعی پژوهش

بهینه‌ساز آدام (تخمین لحظه تطبیقی)^۴ یک الگوریتم محبوب است که برای بهینه‌سازی مبتنی بر گرادیان در مدل‌های یادگیری ماشین استفاده می‌شود. این روش مزایای دو بهینه‌ساز پُرکاربرد دیگر، یعنی ریشه میانگین مربع انتشار^۵ و گرادیان تطبیقی^۶ را ترکیب می‌کند. آدام نرخ‌های یادگیری تطبیقی را برای هر پارامتر، بر اساس لحظه‌های اول و دوم گرادیان‌ها (میانگین و واریانس) محاسبه می‌کند. این باعث می‌شود که برای مدیریت داده‌های پُرسروصدا و شیب‌های پراکنده کارآمد باشد؛ زیرا به صورت پویا، نرخ یادگیری را برای هم‌گرایی سریع‌تر و دقیق‌تر تنظیم می‌کند. آدام

1. Mean Squared Error Loss Function
2. Adam
3. Stochastic Gradient Descent
4. Adaptive Moment Estimation
5. RMSProp
6. AdaGrad

به دلیل توانایی در مدیریت مجموعه داده های بزرگ و فضاهای فرارامتری، در یادگیری عمیق و یادگیری ماشین مفید است و آن را برای بهینه سازی مدل های پیچیده، مانند شبکه های عصبی مناسب می کند.

«برازش بیش از حد»^۱ چالش بسیار مهم و رایجی در یادگیری ماشین است. در این شرایط، یک مدل به طور استثنایی روی داده های آموزشی خوب عمل می کند؛ اما موقع تعمیم مؤثر روی داده های جدید (آزمایشی) و نادیده، مشکل اساسی دارد. این پدیده زمانی رخ می دهد که مدل نویز یا نوسان های تصادفی در داده های آموزشی را به جای الگوهای زیربنایی به خاطر می سپارد و در مواجهه با داده های جدید (آزمایشی) در عمل کارایی خود را از دست می دهد. تکنیک های مختلفی را می توان برای پرداختن به این موضوع به کار گرفت. یک رویکرد عملی، استفاده از کال بک ها^۲ در کراس است که چارچوب محبوبی برای مقابله با برازش بیش از حد محسوب می شود.

یکی از کال بک های پُرکاربردی که می تواند به جلوگیری از برازش بیش از حد کمک کند، «توقف زودهنگام»^۳ است. این کال بک، بر مقادیر از دست رفته اعتبارسنجی^۴ نظارت می کند و در صورت عدم بهبود افت اعتبار پس از تعداد مشخصی از دوره ها، روند آموزش را متوقف می کند. توقف زودهنگام آموزش، از تطبیق بیش از حد مدل با داده های آموزشی جلوگیری می کند.

کال بک مفید دیگر «زمانی که یک معیار دیگر بهبود نیافت، نرخ یادگیری را کاهش دهید»^۵ است که مقادیر از دست رفته اعتبارسنجی را کنترل می کند و در صورت عدم بهبود مقادیر از دست رفته اعتبارسنجی پس از تعداد معینی از دوره ها، نرخ یادگیری را با یک عامل (میزان) مشخص کاهش می دهد. کاهش نرخ یادگیری می تواند به مدل در فرار از حداقل های محلی و یافتن راه حل بهتر کمک کند.

علاوه بر این ها، کال بک «بازرسی (چک پوینت) مدل»^۶ نیز در جلوگیری از برازش بیش از حد نقش مهمی دارد. هر زمان که معیار نظارت شده (در این مورد، مقادیر از دست رفته اعتبارسنجی) بهبود یابد، وزن مدل را در یک فایل ذخیره می کند. این تضمین می کند که یک نسخه از مدل با بهترین عملکرد در داده های اعتبارسنجی در دسترس است که می تواند به کاهش ریسک برازش بیش از حد کمک کند. با استفاده از این کال بک ها، می توان عملکرد مدل را به طور مؤثر در حین آموزش کنترل کرد و اقدامات مناسبی را برای جلوگیری از برازش بیش از حد انجام داد.

توجه به این نکته مهم است که کال بک ها ابزار ارزشمندی برای رفع برازش بیش از حد هستند؛ اما تنها راه حل نیستند. علاوه بر کال بک ها و تکنیک های ذکر شده در بالا، منظم سازی الاستیک نت، رویکرد قدرتمند و انعطاف پذیری برای کاهش بیشتر تطابق بیش از حد ارائه می دهد. الاستیک نت جریمه های منظم سازی L_1 و L_2 را ترکیب می کند و از نقاط قوت هر دو روش منظم سازی لاسو^۷ (L_1) و ریدج^۸ (L_2) استفاده می کند که فرمول آن در رابطه ۱ آمده است.

1. Overfitting

2. Callbacks

3. Early Stopping

4. Validation Loss

5. Reduce learning rate when a metric has stopped improving (ReduceLROnPlateau)

6. Model Checkpoint

7. Lasso

8. Ridge

$$\text{رابطه ۱)} \quad \text{Min}_{\beta_0, \beta} \left[\frac{1}{2n} \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j \right) + \lambda_1 \sum_{j=1}^p |\beta_j| + \lambda_2 \sum_{j=1}^p (\beta_j)^2 \right]$$

که در آن، n تعداد نمونه‌ها و p تعداد ویژگی‌ها را نشان می‌دهد. متغیر y_i تغییر متغیر هدف برای نمونه i ام است و β_0 عبارت ره‌گیری است. ضرایب هر ویژگی با β_j نشان داده می‌شود و x_{ij} نشان‌دهنده ارزش ویژگی j برای نمونه i است. علاوه‌براین، λ_1 میزان جریمه لاسو را کنترل می‌کند، در حالی که λ_2 مقدار جریمه ريج را کنترل می‌کند. این رویکرد ترکیبی، امکان انتخاب خودکار ویژگی‌ها و کاهش ضرایب را فراهم می‌کند که می‌تواند تعمیم مدل را با جلوگیری از برازش بیش از حد به هر ویژگی یا مجموعه‌ای از ویژگی‌ها، به‌طور چشمگیری بهبود بخشد. قبلاً به نحوه و مقادیر استفاده از الاستیک نت در مدل اشاره کرده‌ایم.

برای یافتن مقادیر مناسب فرایارامترها، از شیوه «جست‌وجوی تصادفی»^۱ استفاده کردیم که روشی ساده است و در عین حال، به طرز شگفت‌انگیزی برای بهینه‌سازی فرایارامترها در مدل‌های یادگیری ماشین مؤثر است. برخلاف «جست‌وجوی شبکه‌ای»^۲ که به‌طور کامل تمام ترکیبات ممکن از فرایارامترها را امتحان می‌کند، جست‌وجوی تصادفی ترکیب‌ها را به‌طور تصادفی انتخاب می‌کند. این رویکرد، یک مزیت کلیدی دارد: می‌تواند پیکربندی‌های خوب را سریع‌تر کشف کند؛ زیرا زمان را برای ارزیابی مناطق نامطلوب فضای پارامتر تلف نمی‌کند. با تخصیص امکان ثابتی از آزمایش‌ها، جست‌وجوی تصادفی می‌تواند طیف گسترده‌ای از مقادیر را برای هر پارامتر کشف کند و به‌طور بالقوه مدل‌هایی با عملکرد بالا را که ممکن است توسط رویکردهای سیستماتیک نادیده گرفته شوند، آشکار کند. علاوه‌براین، به‌دلیل سادگی، پیاده‌سازی جست‌وجوی تصادفی آسان است و به‌خوبی در فضاهای با ابعاد بالا مقیاس‌بندی می‌شود و آن را به ابزاری ارزشمند برای بهبود عملکرد مدل تبدیل می‌کند، به‌ویژه زمانی که منابع محاسباتی محدود هستند یا زمانی که فضای فرایارامتری به‌خوبی درک نشده است؛ از این‌رو برای مطالعات مدیریتی که در آن یادگیری ماشین وسیله‌ای است برای یافتن مفاهیم مدیریتی، این شیوه یافتن فرایارامترها توصیه می‌شود. در این مطالعه جست‌وجوی تصادفی روی ۴۰۰ فضای فرایارامتری تنظیم شد تا اطمینان حاصل شود که بررسی و تنظیم دقیق فرایارامترها به بهترین نحو انجام شود. در این مطالعه، مدل حداکثر برای ۱۰ دوره^۳ آموزش داده شد؛ یعنی کل مجموعه داده آموزش ۱۰ بار در طول فرایند آموزش آموزش از طریق شبکه ارسال می‌شود. وزن‌های مدل پس از هر دوره بر اساس گرادیان‌های خطای محاسبه شده به روز می‌شوند. آموزش برای چند دوره به مدل اجازه می‌دهد تا به‌طور مکرر یاد بگیرد و عملکرد خود را بهبود بخشد. برای اندازه دسته^۴ از مقدار ۳۲ در طول آموزش استفاده می‌شود. این نشان می‌دهد که داده‌های آموزشی به دسته‌هایی تقسیم می‌شوند که هر کدام شامل ۳۲ نمونه است. این مدل یک دسته را در یک زمان پردازش می‌کند، شیب‌ها را محاسبه می‌کند و وزن‌ها را بر اساس میانگین خطا در سرتاسر دسته به‌روزرسانی می‌کند. استفاده از اندازه دسته‌ای ۳۲ تعادلی بین کارایی محاسباتی و توانایی تعمیم خوب ایجاد می‌کند. تمامی فرایارامترهای استفاده شده در این پژوهش در جدول ۲

1. Random Search
2. Grid Search
3. Epochs
4. Batch Size

مشاهده می‌شود. مجموعه داده‌ها در ابتدا به مجموعه‌های آموزشی و آزمایشی تقسیم می‌شود که ۱۰ درصد از داده‌ها را به مجموعه آزمایشی اختصاص می‌دهد. متعاقباً، مجموعه آموزشی تحت یک تقسیم ثانویه به یک مجموعه اعتبارسنجی با ۱۰ درصد از داده‌های آموزشی نیز تقسیم می‌شود. برای اطمینان از ارزیابی مدل قوی، «اعتبارسنجی متقابل چندتایی»^۱ با تقسیم‌های ۱۰ تایی را پیاده‌سازی و حالت تصادفی را روی ۴۲ برای تکرارپذیری در سراسر تکرارها تنظیم می‌کنیم. این رویکرد دقیق برای دسته‌بندی و اعتبارسنجی داده‌ها، به توسعه و ارزیابی مؤثر مدل‌های یادگیری ماشین کمک می‌کند.

جدول ۲. فرآیند پارامترهای مدل

Model Architecture	• 2 inputs with 2 input neurons • The first hidden layer ◦ 5 neurons and ElasticNet (0.2, 0.2) and actuator (ReLU) • Second hidden layer ◦ 7 neurons and ElasticNet (0.2, 0.2) and actuator (ReLU) • 1 output with 1 output neurons
Optimization	Adam
Loss Function	Mean Squared Error (MSE)
Early Stopping	Monitor = val_loss, Patience = 5
Learning Rate Reduction	Monitor = val_loss, Factor = 0.5, Patience = 5, Min_delta = 0.0001
Model Checkpoint	Monitor = val_loss, Save_Best_Only = True, Mode = min
Training Parameters	Epochs = 10, Batch_Size = 32
Data Splitting	• Train Data Size of Original Data = 90% • Test Data Size of Original Data = 10% • Train Data Size of Train Data = 90% • Validation Data Size of Train Data = 10%

معیارهای ارزیابی مدل

برای ارزیابی دقت و قابلیت اطمینان مدل، مجموعه‌ای از معیارهای عملکرد استفاده می‌شود، از جمله میانگین خطای مطلق، ریشه میانگین مربع خطا، ضریب تعیین، امتیاز واریانس توضیح داده شده، خطای مطلق میانه، میانگین مربعات خطای لگاریتمی و میانگین درصد مطلق خطا. این معیارها میانگین بزرگی خطاها، نسبت واریانس در متغیر وابسته را که می‌توان از متغیر(های) مستقل پیش‌بینی کرد و میانگین اختلاف مطلق بین مقادیر پیش‌بینی‌شده و واقعی را به‌عنوان درصدی از مقادیر واقعی اندازه‌گیری می‌کنند. همچنین از روش‌های محلی و جهانی که به افزایش شفافیت این مدل‌ها کمک می‌کند نیز استفاده شده است که در ادامه به تفصیل در مورد آن‌ها توضیح می‌دهیم.

میانگین مطلق خطاها (MAE)^۲ یک معیار محبوب است که برای ارزیابی عملکرد مدل‌های رگرسیون در یادگیری ماشین استفاده می‌شود. میانگین بزرگی خطاها را بدون در نظر گرفتن جهت آن‌ها (مثبت یا منفی) اندازه‌گیری می‌کند. فرمول محاسبه MAE به شرح زیر است:

1. K-Fold Cross Validation
2. Mean Absolute Error

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad \text{رابطه ۲}$$

ریشه میانگین مربعات خطاها (RMSE)^۱، یکی دیگر از معیارهای پرکاربرد برای ارزیابی عملکرد مدل‌های رگرسیون در یادگیری ماشین است. جذر میانگین اختلاف مجذور بین مقادیر پیش‌بینی‌شده و مقادیر واقعی را اندازه می‌گیرد. فرمول محاسبه RMSE به شرح زیر است:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad \text{رابطه ۳}$$

R^2 ، همچنین به‌عنوان ضریب تعیین^۲ شناخته می‌شود، یک معیار آماری است که نسبت واریانس در متغیر وابسته را نشان می‌دهد که از متغیر(های) مستقل در یک مدل رگرسیونی پیش‌بینی می‌شود. فرمول R^2 به‌صورت زیر است:

$$R^2 = 1 - \frac{SSR}{SST} \quad \text{رابطه ۴}$$

امتیاز واریانس توضیح داده شده (EVS)^۳، معیاری است که در آمار و یادگیری ماشین برای ارزیابی عملکرد مدل‌های رگرسیون استفاده می‌شود. نسبت کل واریانس در متغیر وابسته را که توسط متغیرهای مستقل در مدل می‌توانند توضیح دهند کمیت می‌کند. فرمول EVS بدین گونه است:

$$EVS = 1 - \frac{Var(y - \hat{y})}{Var(y)} \quad \text{رابطه ۵}$$

میانه مطلق خطاها (MedAE)^۴، یک معیار قوی برای ارزیابی دقت پیش‌بینی مدل ساخته شده، در یادگیری ماشین و مدل‌سازی آماری است. MedAE برای نمایش بزرگی خطای معمولی مناسب‌تر است؛ به‌ویژه زمانی که توزیع خطا منحرف یا حاوی مشاهدات تأثیرگذار است. فرمول MedAE این گونه است:

$$MedAE = median(|y_i - \hat{y}_i|) \quad \text{رابطه ۶}$$

میانگین مربعات خطای لگاریتمی (MSLE)^۵ لگاریتم پیش‌بینی‌ها و مقادیر واقعی را محاسبه می‌کند، بنابراین کمتر برآوردها را بیشتر از برآوردهای بیش از حد جریمه می‌کند و آن را برای کارهایی مانند پیش‌بینی تقاضا یا سطوح موجودی که دقت در مقیاس‌های مختلف بسیار مهم است، ایده‌آل می‌کند. این معیار از فرمول زیر پیروی می‌کند:

$$MSLE = \frac{1}{n} \sum_{i=1}^n (\log(y_i + 1) - \log(\hat{y}_i + 1))^2 \quad \text{رابطه ۷}$$

-
1. Root Mean squared error
 2. Coefficient of Determination
 3. Explained variance score
 4. Median Absolute Error
 5. Mean Squared Logarithmic Error

درصد مطلق میانگین خطاها (MAPE)^۱، معیار آماری دیگری است که برای ارزیابی دقت مدل‌های پیش‌بینی استفاده می‌شود. میانگین تفاوت مطلق بین مقادیر واقعی و پیش‌بینی‌شده را محاسبه می‌کند که به‌صورت درصدی از مقادیر واقعی بیان می‌شود. فرمول MAPE بدین شرح است:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (\text{رابطه ۸})$$

هنگام تفسیر مدل‌های جعبه سیاه، مانند شبکه‌های عصبی مصنوعی، دو ابزار ارزشمند عبارت‌اند از SHAP^۲ و PFI^۳ که اهداف متفاوتی را دنبال می‌کنند و مزایای متمایزی ارائه می‌دهند. SHAP تجزیه و تحلیل دقیق و در سطح ردیف از اهمیت ویژگی را ارائه می‌دهد، نتایج پیش‌بینی‌شده را به ویژگی‌های فردی نسبت می‌دهد و نشان می‌دهد که چگونه مقادیر مختلف ویژگی بر پیش‌بینی‌ها تأثیر می‌گذارد. در مقابل، PFI تأثیر یک ویژگی را بر عملکرد مدل با تغییر تصادفی آن اندازه‌گیری می‌کند که محاسبه آن ساده‌تر است. در حالی که PFI برای شناسایی اهمیت محلی متغیرهای مستقل در مدل مفید است، SHAP بینش‌های دقیق‌تری را در مورد تأثیر ویژگی جهانی ارائه می‌دهد. ترکیب هر دو روش می‌تواند درک جامعی از رفتار مدل ارائه دهد، توضیحات محلی و جهانی را از فرایند تصمیم‌گیری آن ارائه دهد و مشکل جعبه سیاه در شبکه‌های عصبی را تا حدود قابل قبولی برطرف می‌کند. برای محاسبه مقادیر SHAP و PFI به ترتیب از روابط ۹ و ۱۰ استفاده می‌شود:

$$SHAP: \phi_i(f, x) = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|! \cdot (|N| - |S| - 1)!}{|N|!} [f_x(S \cup \{i\}) - f_x(S)] \quad (\text{رابطه ۹})$$

$$PFI: I_j = \frac{1}{n} \sum_{i=1}^n (L(f(x), y) - L(f(x_{pre(j)}), y)) \quad (\text{رابطه ۱۰})$$

یکی دیگر از فرایندهای ارزیابی در مدل‌های یادگیری ماشینی، استراتژی‌هایی برای ردیابی و مقابله با برآزش بیش از حد است؛ یعنی همان‌طور که پیش‌تر ذکر شد، زمانی که یک مدل یادگیری ماشینی بسیار نزدیک به داده‌های آموزشی خود تطبیق داده می‌شود، مانع عملکرد مطلوب آن مدل در داده‌های جدید می‌شود. با بررسی «منحنی‌های یادگیری»^۴ که دقت مدل را در آموزش، مقابل داده‌های اعتبارسنجی در چرخه‌های آموزشی متعدد نشان می‌دهند، می‌توان هرگونه اختلاف شایان توجهی را شناسایی و اصلاح کرد. این تضمین می‌کند که مدل به‌جای حفظ کردن داده‌ها، روندهای واقعی داده‌ها را یاد می‌گیرد که توانایی آن را برای عملکرد خوب روی داده‌هایی که قبلاً ندیده است، بهبود می‌بخشد. در این منحنی‌ها باید همه دفعاتی که در اعتبارسنجی متقابل مدل ساخته و ارزیابی می‌شود از یک منحنی کمابیش مشابهی


1. Mean Absolute Percentage Error
2. Shapley Additive Explanations
3. Permutation Feature Importance
4. Learning Curves

پیروی کنند و همچنین هر بار که مدل ساخته می‌شود باید از حوالی یکی از دوره‌ها مدل به بهینگی دست‌یافته باشد، تا بتوان ادعا کرد که مدل ساخته شده در کنار سایر معیارها، از توانایی مطلوبی برای پیش‌بینی برخوردار است یا نه؟ با ترکیب و تلفیق این معیارها و ابزارها، این پژوهش به دنبال یافتن بهترین روش برای محاسبه و پیش‌بینی ارزش طول عمر مشتریان است و تمام یافته‌های پژوهش حاضر در بخش بعدی مورد بحث قرار خواهند گرفت.

بحث

منحنی یادگیری در شکل ۳، کاهش پیوسته‌ای را هم در «مقادیر از دست‌رفته آموزش»^۱ و هم «مقادیر از دست‌رفته اعتبارسنجی»^۲ در طول دوره‌ها نشان می‌دهد. این نشان می‌دهد که مدل به‌طور مؤثر از داده‌های آموزشی یاد می‌گیرد و به‌خوبی به داده‌های اعتبارسنجی نادیده تعمیم می‌یابد. این رفتار در تمام دوره‌ها حفظ می‌شود، بدون واگرایی قابل توجهی بین دو منحنی، این یک علامت مثبت است. این نشان می‌دهد که مدل، صرفاً داده‌های آموزشی را به‌خاطر نمی‌سپارد، بلکه الگوهای نهان را نیز شناسایی می‌کند و می‌تواند از برازش بیش از حد جلوگیری کند.

مقادیر از دست‌رفته آموزشی و اعتبارسنجی هر دو تمایل دارند پس از یک نقطه خاص تثبیت شوند که اغلب به‌عنوان نقطه عطف نامیده می‌شود که در این مدل در حوالی دوره ۵ این اتفاق رخ می‌دهد. این نشانه خوبی است که مدل داده‌های آموزشی را به‌خاطر نمی‌سپارد، بلکه الگوهای معنادار را یاد می‌گیرد و توانایی مدل در پیش‌بینی داده‌های دیده نشده را ثابت می‌کند. در دوره‌های بعدی، میزان کاهش مقادیر از دست‌رفته آموزشی و اعتبارسنجی تدریجی‌تر می‌شود. این پدیده با نزدیک شدن مدل به عملکرد بهینه خود انتظار می‌رفت که همان‌گونه نیز شد. به‌طور خلاصه، منحنی یادگیری شواهدی را ارائه می‌دهد که مدل برازش بیش از حد نمی‌کند و قادر به تعمیم مؤثر به نمونه‌های غیرقابل مشاهده است.



شکل ۳. منحنی یادگیری مدل شبکه عصبی مصنوعی پژوهش

1. Training Loss
2. Validation Loss

خروجی مدل، عملکرد مدل شبکه عصبی مورد استفاده برای پیش‌بینی ارزش طول عمر مشتری در تجارت الکترونیک را بر اساس دو عامل کلیدی امتیاز ترویج‌کننده و امتیاز تلاش مشتری نشان می‌دهد (جدول ۳). این معیارهای ارزیابی، بینش ارزشمندی را درخصوص توانایی مدل برای تعمیم و پیش‌بینی دقیق ارائه می‌دهند. به‌منظور تفسیر و توضیح کامل این خروجی، در زیر به هر یک از معیارها و پیامدهای آن برای اثربخشی مدل خواهیم پرداخت.

جدول ۳. ارزیابی مدل شبکه عصبی مصنوعی ساخته شده در پژوهش

معیار	اعتبارسنجی داده‌های آزمایشی	اعتبارسنجی داده‌های آموزشی
MAE	۱۴۲/۴۷۵	۱۴۳/۶۶۷
RMSE	۱۷۵/۳۵۰	۱۷۵/۷۱۴
R^2	۰/۹۳۴	۰/۹۳۳
EVS	۰/۹۳۴	۰/۹۳۳
MedAE	۱۲۷/۴۶۹	۱۲۸/۴۹۴
MSLE	۰/۰۱۱	۰/۰۱۰
MAPE	۰/۰۸۰	۰/۰۷۸

مدل شبکه عصبی مورد بحث این مطالعه، معیارهای مختلف ارزیابی از جمله MAE، RMSE، R^2 ، EVS، MedAE، MSLE و MAPE را به‌منظور سنجش دقت و قابلیت تعمیم‌پذیری پیش‌بینی‌ها در برآورد ارزش طول عمر مشتری مورد استفاده قرار می‌دهد. MAE و RMSE نشان می‌دهند که مدل توانسته است دقت خوبی در پیش‌بینی‌ها داشته باشد؛ زیرا مقادیر اعتبارسنجی آزمایشی کمی، کمتر از مقادیر اعتبارسنجی آموزشی است که به معنای عملکرد بهتر مدل در داده‌های جدید و دیده‌نشده است. امتیازهای بالای R^2 و EVS نیز حاکی از آن است که مدل قدرت توضیحی بالایی دارد و ویژگی‌های انتخاب شده، به‌خوبی تغییرپذیری ارزش طول عمر مشتری را توضیح می‌دهند.

علاوه بر این، MAPE و MedAE نشان‌دهنده سازگاری بسیار خوب مدل در داده‌های مختلف است و نتایج MSLE تأیید می‌کند که مدل به‌جای حفظ داده‌ها، الگوهای اساسی آن‌ها را یاد گرفته است. این معیارها در کنار هم نشان می‌دهند که مدل نه تنها در آموزش، بلکه در ارزیابی داده‌های جدید عملکرد ثابتی و موفقی دارد و این امر به اطمینان در برآورد دقیق و استحکام مدل کمک می‌کند.


همان‌طور که پیش از این ذکر شد، شبکه‌های عصبی مصنوعی به‌دلیل قابلیت استخراج الگوها و روابط پیچیده و غیرخطی در داده‌ها، توجه بسیاری را به خود جلب کرده‌اند. در این پژوهش با هدف ارزیابی عملکرد شبکه‌های عصبی مصنوعی در پیش‌بینی ارزش طول عمر مشتری، مقایسه‌ای جامع بین مدل شبکه عصبی مصنوعی و مدل‌های آماری پایه (رگرسیون خطی و درخت تصمیم) نیز صورت گرفته است. نتایج این مقایسه که در جدول ۴ ارائه شده است، نشان‌دهنده برتری درخور توجه شبکه عصبی مصنوعی در این زمینه است.

جدول ۴. مقایسه مدل شبکه عصبی مصنوعی با مدل‌های پایه

معیار	شبکه عصبی مصنوعی	رگرسیون خطی	درخت تصمیم
MAE	۱۴۲/۴۷۵	۲۱۲/۳۸۲	۱۵۸/۲۷۹
RMSE	۱۷۵/۳۵۰	۳۶۲/۲۶۴	۳۴۸/۵۰۵
R^2	۰/۹۳۴	۰/۷۳۱	۰/۷۵۰
EVS	۰/۹۳۴	۰/۷۳۱	۰/۷۵۰
MedAE	۱۲۷/۴۶۹	۱۴۶/۵۱۷	۱۳۰/۰۲۳
MSLE	۰/۰۱۱	۰/۰۷۱	۰/۰۴۴
MAPE	۰/۰۸۰	۰/۱۳۹	۰/۰۹۷


نتایج جدول ۴ نشان می‌دهد که شبکه عصبی مصنوعی در مقایسه با رگرسیون خطی و درخت تصمیم، در پیش‌بینی ارزش طول عمر مشتری عملکرد بهتری دارد. شبکه عصبی مصنوعی، به دلیل توانایی خود در گرفتن روابط غیرخطی بین ویژگی‌ها و متغیر هدف، کمترین مقادیر MAE (۱۴۲/۴۷۵) و RMSE (۱۷۵/۳۵۰) را دارد که نشان‌دهنده دقت بیشتر و خطای کمتر در پیش‌بینی‌هاست. علاوه بر این، مقادیر بالای R^2 و EVS (هر دو برابر با ۰/۹۳۴) برای شبکه عصبی مصنوعی، بیانگر قدرت توضیحی بالای این مدل و توانایی آن در توضیح دادن تغییرات ارزش طول عمر مشتری است. در مقابل، رگرسیون خطی و درخت تصمیم به دلیل محدودیت در مدل‌سازی روابط غیرخطی، عملکرد ضعیف‌تری با R^2 و EVS حدود ۰/۷۳ و ۰/۷۵ دارند. همچنین، شبکه عصبی مصنوعی کمترین MSLE (۰/۰۱۱) و MAPE (۰/۰۸۰) را دارد که نشان می‌دهد این مدل دقت بیشتری در پیش‌بینی خطاهای درصدی داشته و توانسته است الگوهای پیچیده‌تری را از داده‌ها بگیرد. MedAE نیز برای ANN کمتر است که این سازگاری بیشتر در پیش‌بینی‌ها را تقویت می‌کند.

در این پژوهش با هدف شناسایی عوامل کلیدی مؤثر بر ارزش طول عمر مشتری، مدلی بر پایه شبکه‌های عصبی طراحی شد. در این مدل، دو شاخص کلیدی امتیاز ترویج‌کننده و امتیاز تلاش مشتری به عنوان ورودی در نظر گرفته شدند. با بهره‌گیری از روش‌های تفسیر مدل SHAP و PFI، تلاش شد تا به درک عمیق‌تری از تأثیر این شاخص‌ها بر پیش‌بینی ارزش طول عمر مشتری دست یابیم. نتایج حاصل از این تحلیل‌ها، بینش‌های ارزشمندی را در خصوص رفتار مشتریان و اهمیت نسبی هر یک از شاخص‌ها ارائه می‌دهد. یافته‌های این دو روش در شکل ۴ نمایش داده شده است. تحلیل‌های SHAP و PFI در شکل ۴، هر دو نشان می‌دهند که امتیاز ترویج‌کننده، بر پیش‌بینی ارزش طول عمر مشتری در مقایسه با امتیاز تلاش مشتری تأثیر مهم‌تری دارد. امتیاز ترویج‌کننده با میانگین مقدار SHAP بالاتر (۲۱۱/۶) در مقابل ۱۵۸ برای امتیاز تلاش مشتری) و نمره PFI بیشتر (۰/۷۲۵) در مقابل ۰/۶۳۴ برای امتیاز تلاش مشتری)، به عنوان ویژگی مهم‌تر در توضیح تغییرات ارزش طول عمر مشتری شناخته می‌شود. با این حال، امتیاز تلاش مشتری همچنان یک عامل مهم است که نشان می‌دهد در حالی که امتیاز ترویج‌کننده بیشترین سهم را از قدرت پیش‌بینی دارد، این متغیر نیز به طور معناداری، به پویایی مدل ساخته‌شده کمک می‌کند. این اهمیت دوگانه با انتظارات در رفتار مشتری مطابقت دارد، جایی که ترویج‌کنندگی و سهولت تعامل می‌تواند به طور چشمگیری بر ارزش طول عمر تأثیر بگذارد.



شکل ۴. مقادیر SHAP (Mean) و PFI برای شبکه عصبی مصنوعی

همچنین با توجه به شکل ۵، به نظر می‌رسد که امتیاز ترویج‌کننده، روی خروجی، در هر دو جهت منفی و مثبت مدل تأثیرهای نوسان‌دار می‌گذارد که نشان‌دهنده نقش پیچیده این متغیر در مدل است. با این حال، در نگاه کلی می‌توان بیان کرد که مقادیر بالای (قرمز) این متغیر مستقل تمایل دارند که بر خروجی مدل تأثیر مثبتی بگذارند. در مقابل، برای امتیاز تلاش مشتری، بخش عمده‌ای از نقاط در سمت چپ صفر (منفی) قرار دارند که نشان می‌دهد مقادیر بالای امتیاز تلاش مشتری، ممکن است بر افزایش پیش‌بینی ارزش طول عمر مشتری تأثیر کمتری داشته باشند یا حتی تأثیر منفی بگذارند؛ اما همچنان نقاطی با تأثیرهای مثبت مشاهده می‌شوند که نشان‌دهنده تأثیرهای متفاوت این متغیر در شرایط مختلف است.



شکل ۵. مقادیر SHAP برای متغیرهای مستقل در شبکه عصبی مصنوعی

با ترکیب دو شاخص کلیدی عملکرد (KPI) امتیاز ترویج‌کننده و امتیاز تلاش مشتری در یک چارچوب پیش‌بینی که توسط شبکه‌های عصبی تأمین می‌شود، کسب‌وکارها می‌توانند به بینش عمیق‌تری از رفتارهای مشتری دست یابند؛ این رویکرد به توسعه استراتژی‌های دقیق باهدف افزایش ارزش طول عمر مشتری و پرورش روابط پایدار با مشتریان کمک می‌کند. یافته‌ها نشان می‌دهد که مدل مبتنی بر شبکه عصبی در تعمیم پیش‌بینی CLV با استفاده از شاخص‌های ذکر شده برتری محسوسی دارد. کارایی مدل با عملکرد آن در چندین معیار آماری، مانند میانگین خطای مطلق، میانگین مربعات خطای ریشه، ضریب تعیین، امتیاز واریانس توضیح داده شده، میانه مطلق خطاها مشهود است. میانگین مربعات

خطای لگاریتمی و میانگین مطلق درصد خطاها که نتایج ثابت و قابل‌اعتمادی را نشان می‌دهند، بیشتر توانایی این مدل را به رخ می‌کشند. با وجود تفاوت‌های بسیار جزئی مشاهده شده بین مجموعه داده‌های اعتبارسنجی آموزش و آزمایش، دقت کلی مدل نشان‌دهنده توانایی آن در تشخیص دقیق الگوها و روندهای اساسی در داده‌هاست. این نتیجه درخور توجه است و نشان می‌دهد که رویکرد شبکه عصبی، می‌تواند به‌طور مؤثر در بخش تجارت الکترونیک برای پیش‌بینی CLV استفاده شود. با این دانش، کسب‌وکارها در موقعیت بهتری برای اصلاح تلاش‌های بازاریابی خود، افزایش حفظ مشتری و تحریک رشد پایدار قرار می‌گیرند.

نتیجه‌گیری

در دنیایی که تجارت الکترونیک در حال تکامل یافتن است، توانایی پیش‌بینی ارزش طول عمر مشتری اهمیت بسیار زیادی دارد. این شاخص برای همه کسب‌وکارهای تجارت الکترونیک ضروری است؛ زیرا توسعه تاکتیک‌های تعامل با مشتری را هدایت می‌کند، وفاداری را تقویت می‌کند و استفاده کارآمد از منابع را تضمین می‌کند. استفاده از مدل‌های شبکه عصبی برای پیش‌بینی طول عمر مشتری نشان‌دهنده ایده‌ای نو و تکنیکی پیشرفته است که از ظرفیت‌های یادگیری ماشین، به‌خصوص شبکه‌های عصبی مصنوعی، نهایت بهره را می‌برد.

یان و رسنیک (۲۰۲۴) معتقدند که مدل‌سازی ارزش طول عمر مشتری زیربنای تحلیل‌های بازاریابی مدرن است و امکان توسعه استراتژی‌های مدیریت ارتباط با مشتری بر اساس ارزش پیش‌بینی‌شده آینده مشتریان را فراهم می‌کند؛ اما در مطالعه خود از روش جنگل تصادفی برای طبقه‌بندی مشتریان بر حسب ارزش طول عمر مشتری استفاده می‌کنند. فیرمانسیاه و همکاران (۲۰۲۴) در مطالعه خود که کاربردهای یادگیری ماشین در پیش‌بینی ارزش طول عمر مشتری را با بررسی مطالعات متعدد به چالش کشیده‌اند، معتقدند که به شیوه نوینی برای پیش‌بینی این معیار مهم در استراتژی‌های بازاریابی و مدیریت روابط با مشتری نیاز است؛ از این رو پیشنهاد می‌دهند که الگوریتم‌های جدیدتر نیز باید بررسی شوند؛ اما بوسما و ویتلوستوین (۲۰۲۴) اذعان می‌کنند که الگوریتم‌های جدیدتر یادگیری ماشین، من جمله شبکه‌های عصبی مصنوعی، در تمام موارد به‌سان جعبه سیاه عمل می‌کنند و متغیرهای مستقل مورداستفاده در مدل‌ها را بدون شناسایی اهمیت و وزن‌هایشان به خروجی تبدیل می‌کنند که این در تجارت و کسب‌وکار، می‌تواند کیفیت تصمیم‌های درست را کاهش دهد؛ از این رو به روشی جامع در این قسم از مطالعات نیاز است که خاصیت جعبه سیاهی الگوریتم‌های جدیدتر را تا حد مقبولی تعدیل کند.

مطالعه حاضر با استفاده از رویکرد شبکه‌های عصبی مصنوعی (پرسپترون چندلایه) تفسیرپذیر نشان داد که با استفاده از SHAP و PFI، می‌توان مدل‌های شبکه عصبی مصنوعی را تا حد مقبولی تفسیرپذیرتر کرد و از خاصیت جعبه سیاهی آن کاست. تحلیل نتایج نشان داد که مدل شبکه عصبی مصنوعی، با برتری چشمگیر نسبت به مدل‌های رگرسیون خطی و درخت تصمیم، توانایی بیشتری در پیش‌بینی ارزش طول عمر مشتریان دارد. این برتری حدود ۱۸ درصد در ضریب اطمینان، مؤید وجود روابط پیچیده و غیرخطی میان متغیرهای مؤثر بر ارزش طول عمر مشتری است. مدل‌های سنتی به دلیل ماهیت خطی خود، از شناسایی و مدل‌سازی این روابط پیچیده عاجز می‌مانند. ارزیابی دقیق

عملکرد مدل شبکه عصبی با استفاده از چندین معیار، نشان داد که این مدل به طور قابل اعتمادی قادر است که ارزش طول عمر مشتریان را پیش بینی کند. تطابق بسیار خوب مدل با داده های مختلف و توانایی تعمیم نتایج به داده های جدید، از جمله ویژگی های بارز شبکه عصبی مصنوعی مورد استفاده در مطالعه است. این امر نشان می دهد که مدل شبکه عصبی می تواند به عنوان ابزاری قدرتمند برای پیش بینی ارزش مشتریان در شرایط مختلف و تصمیم گیری های استراتژیک در حوزه مدیریت ارتباط با مشتریان مورد استفاده قرار گیرد. در مجموع، نتایج این پژوهش تأکید می کند که مدل های یادگیری ماشین، به ویژه شبکه های عصبی مصنوعی، برای بهبود دقت پیش بینی ارزش طول عمر مشتری در حوزه های مختلف کسب و کار، از جمله مدیریت ارتباط با مشتریان، پتانسیل خوبی دارند.

مطالعات پیشین از جمله زیگلر و همکاران (۲۰۲۳)، آردلت و بناونت (۲۰۲۲)، بیتنکورت و همکاران (۲۰۲۳) و دانیس و همکاران (۲۰۲۲) بر محدودیت های استفاده از شاخص های امتیاز ترویج کننده و تلاش مشتری، به طور جداگانه تأکید کرده اند. افزون بر این، گاستزی و همکاران (۲۰۲۴) با تفکیک بین وفاداری کلی (سنجیده شده توسط امتیاز ترویج کننده) و سهولت تعامل (سنجیده شده توسط امتیاز تلاش مشتری)، بر اهمیت ترکیب این دو شاخص برای درک جامع تر از رضایت مشتری تأکید می کنند. باکوئرو (۲۰۲۲) نیز با ارائه رویکردی تحلیلگرانه تر، پیشنهاد می کند که تجزیه و تحلیل مشترک این دو شاخص می تواند به کسب و کارها در شناسایی ریشه های نارضایتی، اولویت بندی اقدامات بهبود و در نهایت افزایش رضایت و وفاداری بلندمدت مشتری کمک شایانی کند.

یافته های مطالعه حاضر نیز این ادعاها و پیشنهادها را تأیید می کنند. با ادغام شاخص های امتیاز ترویج کننده و تلاش مشتری، مدل مورد استفاده در مطالعه توانست به سطح بالایی از پیش بینی ارزش طول عمر مشتری دست یابد. تحلیل های عمیق تر با استفاده از روش های تفسیرگر مدل شبکه عصبی مصنوعی نشان داد که امتیاز ترویج کننده به عنوان قوی ترین پیش بین ارزش طول عمر مشتری عمل می کند. با این حال، امتیاز تلاش مشتری نیز در توضیح واریانس متغیر هدف (ارزش طول عمر مشتری) سهم بزرگی داشت. در انتها، پژوهش حاضر توانست شکاف مطالعات قبلی را با ادغام شاخص های کلیدی عملکردی مشتریان، استفاده از یادگیری ماشین و شبکه های عصبی مصنوعی تفسیرپذیر به خوبی پر کند و نشان داد که امتیاز ترویج کننده و تلاش مشتری با رویکردی غیرخطی، ارزش طول عمر مشتریان را به خوبی پیش بینی می کنند.

این پژوهش با ارائه رویکردی نوآورانه در پیش بینی ارزش طول عمر مشتری، در حوزه تحلیل داده های مشتریان گامی مهم برداشت. استفاده از شبکه های عصبی مصنوعی تفسیرپذیر، به همراه شاخص های کلیدی عملکردی مشتری (مانند امتیاز ترویج کننده و امتیاز تلاش مشتری) به مدل اجازه می دهد تا روابط پیچیده پنهان و غیرخطی بین متغیرها را به طور دقیق شناسایی کند و پیش بینی های دقیق تری ارائه دهد. این رویکرد نه تنها به بهبود تصمیم گیری های استراتژیک در کسب و کار کمک می کند؛ بلکه شفافیت بیشتری را در مورد عوامل مؤثر بر ارزش طول عمر مشتری فراهم می آورد. به عبارت دیگر، این مطالعه با ترکیب قدرت یادگیری ماشین و قابلیت تفسیر مدل ها، ابزاری قدرتمند برای درک عمیق تر رفتار مشتریان و بهبود استراتژی های بازاریابی ارائه می دهد.

با توجه به چارچوب‌ها و روش‌های ارائه شده در این مطالعه، می‌توان از این مدل‌ها برای تقسیم‌بندی مشتریان، توسعه استراتژی‌های بازاریابی هدفمند و بهینه‌سازی عملیات خدمات مشتری برای بهبود حفظ مشتری و به حداکثر رساندن ارزش طول عمر مشتری استفاده کرد. از این رو می‌توان گفت که خروجی این مطالعه، در افزایش تعامل مشتری، بهینه‌سازی توزیع منابع و در نهایت افزایش سودآوری کسب‌وکارها می‌تواند نقش مهمی ایفا کند. این تحقیق تأثیر تحول‌آفرین تجزیه و تحلیل پیشرفته در درک رفتار و ارزش مشتری در تجارت الکترونیک را برجسته کرد.

این مطالعه همچنین بر نیاز استراتژیک کسب‌وکارها به گنجاندن مدل‌های پیچیده شبکه عصبی در جعبه ابزار تحلیلی خود تأکید می‌کند که امکان تصمیم‌گیری بهتر و ایجاد استراتژی‌های مشتری‌محور را فراهم می‌آورد. شواهد ارائه شده، توانایی مدل‌ها را برای بهبود دقت پیش‌بینی و مشارکت آن‌ها در فرهنگ تعالی مبتنی بر داده را تأیید می‌کند و کسب‌وکارها را قادر می‌سازد تا به‌طور مؤثرتری در چشم‌انداز تجارت الکترونیک حرکت کنند و روابط قوی‌تر و پایدارتر با مشتریان خود ایجاد کنند.

با استفاده از این مدل‌ها، کسب‌وکارهای تجارت الکترونیک می‌توانند بینش عمیق‌تری نسبت به رفتارها و ترجیحات مشتری به‌دست آورند و محصولات و خدمات خود را برای برآورده کردن نیازهای مخاطبان خود سفارشی‌تر کنند. ادغام تجزیه و تحلیل پیشرفته در تصمیم‌گیری استراتژیک، نشان‌دهنده جهش روبه‌جلو در نوآوری و کارایی است. شواهد به نقش حیاتی شبکه‌های عصبی مصنوعی در تجزیه و تحلیل رفتار مشتری اشاره می‌کنند که چشم‌انداز پیچیده‌ای را برای مدیران برای مشاهده چرخه عمر مشتری فراهم می‌کند. با استفاده از مدل‌های پیش‌بینی برای ارزش طول عمر مشتری و تمرکز بر شاخص‌های کلیدی عملکرد، کسب‌وکارها نه تنها می‌توانند مشتریان سودآور و وفادار را شناسایی کنند، بلکه می‌توانند روابط خود را نیز تقویت کنند. بهبود مستمر استراتژی‌های بازاریابی از طریق پیش‌بینی شبکه‌های عصبی، تضمین می‌کند که کسب‌وکارها نسبت به تغییر ترجیحات و رفتارهای مشتری پاسخ‌گو خواهند بود. استفاده استراتژیک از این بینش‌ها، فراتر از جذب و حفظ مشتری است و تغییر در نحوه تخصیص منابع و ارائه خدمات را نشان می‌دهد. با شناسایی تقسیم‌بندی‌های مشتریان با ارزش بالا، مدیران می‌توانند بودجه‌ها را به‌طور مؤثرتری تخصیص دهند، طرح‌هایی را که بیشترین بازدهی را به همراه دارند، هدف قرار دهند و تلاش‌های جذب و حفظ را بهینه کنند. این تخصیص مجدد استراتژیک منابع، کارایی کمپین‌های بازاریابی را افزایش می‌دهد و تجربه را برای باارزش‌ترین مشتریان بهبود می‌بخشد. پذیرش شبکه‌های عصبی و تجزیه و تحلیل الگوهای رفتاری متوالی، دقت پیش‌بینی مدل را افزایش می‌دهد و بهبود مستمر و همکاری بین توابع را ارتقا می‌دهد. پتانسیل تجسم‌های تعاملی برای متحد کردن بخش‌های مختلف، ماهیت تحول‌آفرین این رویکرد را بیشتر برجسته می‌کند و یک استراتژی واحد، بینش‌افزا و عملی را ممکن می‌سازد.

محدودیت‌ها و پیشنهادهایی برای پژوهش‌های آتی

این مطالعه، به‌سان هر پژوهش دیگری، چندین محدودیت دارد که به برخی از آن‌ها اشاره شده است. استفاده از شبکه‌های عصبی مصنوعی، به‌طور ذاتی به داده‌های زیادی نیاز دارد و در مواقعی که حجم داده‌ها کم باشد، از کارایی مطلوبی برخوردار نخواهد بود. استفاده از الگوریتم‌های پیچیده یادگیری ماشین، به منابع پردازشی قدرتمندی نیاز دارد که

این محدودیت برای داده‌های بزرگ‌تر، بیشتر می‌شود. در مواقعی الگوریتم‌های دیگر مثل الگوریتم‌های گروهی (جنگل تصادفی، گرادیان تقویتی) از روش‌های پیچیده‌تر مثل شبکه‌های عصبی مصنوعی بهتر عمل می‌کنند که پژوهشگران باید یک مطالعه مقایسه‌ای بین الگوریتم‌ها انجام دهند تا به بهترین الگوریتم برسند.

افزون‌براین‌ها، مطالعه حاضر زمینه‌ای را برای ترکیب معیارهای کلیدی مشتری در مدل‌های شبکه عصبی برای پیش‌بینی ارزش طول عمر مشتری (CLV) ایجاد می‌کند؛ با این حال، کارهای علمی آینده، به رفع محدودیت‌های این تحقیق و گسترش چارچوب نظری و روش‌شناختی نیاز دارند. مبنای تجربی این مطالعه، به یک مجموعه داده تجارت الکترونیک محدود می‌شود و به گنجاندن مجموعه داده‌های متنوع از بخش‌های مختلف برای افزایش اعتبار خارجی و قابلیت تعمیم نیاز دارد، این بدین معنا است که مدل‌های یادگیری ماشینی، شاید در صنایع یا بازارهای گوناگون، خروجی متفاوت‌تری داشته باشند؛ از این رو و با توجه به این محدودیت مطالعه فعلی، یکی از زمینه‌های بسیار جذاب برای پژوهش‌های آینده، می‌تواند صنایع دیگر یا مناطق جغرافیایی (کشورهای دیگر) یا تجارت الکترونیک‌های بین‌المللی یا چندملیتی، به عنوان جامعه مورد مطالعه باشد. به علاوه، در این مطالعه به دلیل محدودیت‌های طبیعی هر پژوهش، متغیرهای پیش‌بینی‌کننده به امتیاز ترویج‌کننده (PS) و امتیاز تلاش مشتری (CES) محدود می‌شوند و سایر ویژگی‌های مشتریان که می‌توانند دقت پیش‌بینی را بهبود بخشند، نادیده گرفته شده‌اند. افزون‌براین‌ها، عوامل روان‌شناختی مانند اعتماد، وفاداری به برند و درگیری عاطفی، در حفظ مشتری و ارزش طول عمر نقش مهمی دارند. ادغام این متغیرها می‌تواند جامعیت و دقت مدل را بهبود بخشد. پس یکی دیگر از پیشنهادهایی که برای مطالعات پیش‌رو می‌توان داد، این است که از متغیرهای دیگری مثل میانگین تراکنش هر مشتری، نرخ ریزش مشتریان و نرخ تبدیل نیز می‌توان بهره برد. از منظر روش‌شناختی، کاوش تکنیک‌های بهینه‌سازی پیشرفته، الگوریتم‌های یادگیری ماشین جابگزین و روش‌های تجویزی برای بهینه‌سازی استراتژی‌های حفظ مشتری از طریق مداخلات بازاریابی، می‌تواند به طور چشمگیری به این زمینه کمک کند و پژوهشگران آتی نیز می‌توانند از الگوریتم‌های دیگری به جای شبکه‌های عصبی مصنوعی استفاده کنند.

منابع

- حسینی روش، سید محمدحسین و مقدم، امیر. (۱۴۰۲). پیش‌بینی تخمین ارزش طول عمر مشتری بر مبنای کیفیت خدمات ارائه شده در باشگاه‌های بدن‌سازی مشهد. *پژوهش‌های کاربردی در علوم ورزش و سلامت*، ۲(۲)، ۱۹-۳۶.
- خدیور، آمنه؛ گلستانی، مریم و گلشنی، فهیمه (۱۴۰۲). پیش‌بینی قصد خرید اخلاقی محصولات پایدار در مدل کسب‌وکار دایره‌ای از طریق رفتار مشتریان / گردشگران با استفاده از شبکه عصبی مصنوعی (ANN). *فصلنامه مطالعات مدیریت گردشگری*، ۱۸(۶۲)، ۲۰۳-۲۴۰.
- رحیمی اقدم، صمد؛ فاریابی، محمد و عزیزخواه آلانق، سعیده (۱۳۹۹). تأثیر بازاریابی رابطه‌مند بر ارزش طول عمر مشتری. *بررسی‌های بازرگانی*، ۱۸(۱۰۵)، ۷۱-۸۴.

محمدی، اسفندیار و رضایی، زهرا (۱۳۹۴). بررسی ارتباط بین مدیریت ارتباط با مشتری با کیفیت رابطه و ارزش طول عمر مشتری در صنعت هتلداری (مورد مطالعه: شهر ایلام). *برنامه‌ریزی و توسعه گردشگری*، ۴(۱۵)، ۶۲-۷۹.

مرادی، زینب؛ فخرایی، محمود و آزاد ارمکی، امیر (۱۴۰۱). بررسی تأثیر مدیریت دانش مشتری بر ارزش طول عمر مشتری با میانجیگری چابکی سازمانی (مورد مطالعه: شرکت فرسگال پالست). *فصلنامه پژوهش‌های علوم مدیریت*، ۴(۱۰)، ۱۸۹-۲۰۹.

References

- Agag, G., Durrani, B. A., Abdelmoety, Z. H., Daher, M. M. & Eid, R. (2024). Understanding the link between net promoter score and e-WOM behaviour on social media: The role of national culture. *Journal of Business Research*, 170, 114303. <https://doi.org/10.1016/j.jbusres.2023.114303>
- Agag, G., Durrani, B. A., Shehawy, Y. M., Alharthi, M., Alamoudi, H., El-Halaby, S., Hassanein, A. & Abdelmoety, Z. H. (2023). Understanding the link between customer feedback metrics and firm performance. *Journal of Retailing and Consumer Services*, 73, 103301. <https://doi.org/10.1016/j.jretconser.2023.103301>
- Ardelet, C. & Benavent, C. (2022). Does making less effort entail satisfaction? A large empirical study on client relationship services. *International Journal of Market Research*, 65(1), 83-99. <https://doi.org/10.1177/14707853221113953>
- Asadi Ejgerdi, N. & Kazerooni, M. (2024). A stacked ensemble learning method for customer lifetime value prediction. *Kybernetes*, 53(7), 2342-2360. <https://doi.org/10.1108/K-12-2022-1676>
- Baquero, A. (2022). Net promoter score (NPS) and customer satisfaction: relationship and efficient management. *Sustainability*, 14(4), 2011. <https://doi.org/10.3390/su14042011>
- Bitencourt, V. N., Crestani, F., Peuckert, M. Z., Andrades, G. R. H., Krauzer, J. R. M., Cintra, C. de C., Cunha, M. L. da R., Eckert, G. U., Girardi, L., Santos, I. S. & Garcia, P. C. R. (2023). Net Promoter Score (NPS) as a tool to assess parental satisfaction in pediatric intensive care units. *Jornal de Pediatria*, 99(3), 296-301. <https://doi.org/https://doi.org/10.1016/j.jped.2022.11.013>
- Bojanowska, A. & Milosz, M. (2017). Application of neural networks in CRM systems. In *ITM Web of Conferences* (Vol. 15, p. 04001). EDP Sciences. <https://doi.org/10.1051/itmconf/20171504001>
- Bose, I. & Mahapatra, R. K. (2001). Business data mining—a machine learning perspective. *Information & management*, 39(3), 211-225. [https://doi.org/10.1016/S0378-7206\(01\)00091-X](https://doi.org/10.1016/S0378-7206(01)00091-X)
- Bosma, B. & van Witteloostuijn, A. (2024). Machine learning in international business. *Journal of International Business Studies*, 1-27. <https://doi.org/10.1057/s41267-024-00687-6>

- Caton, S. & Haas, C. (2024). Fairness in machine learning: A survey. *ACM Computing Surveys*, 56(7), 1-38. <https://doi.org/10.1145/3616865>
- Chen, S., Huang, Y., Xu, D.-L. & Jiang, W. (2020). *A two stage machine learning approach for Modeling Customer Lifetime Value in the Chinese Airline Industry* (S. Blanchard, A. Epp & G. Mallapragada (eds.); Vol. 31, pp. 1018–1021). American Marketing Association (AMA).
- Cowan, G., Mercuri, S. & Khraishi, R. (2023). *Modelling customer lifetime-value in the retail banking industry*. <https://doi.org/10.48550/arXiv.2304.03038>
- Curiskis, S., Dong, X., Jiang, F. & Scarr, M. (2023). A novel approach to predicting customer lifetime value in B2B SaaS companies. *Journal of Marketing Analytics*, 11(4), 587–601. <https://doi.org/10.1057/s41270-023-00234-6>
- Dai, X. (2022, May). Customer Lifetime Value Analysis Based on Machine Learning. In *Proceedings of the 6th International Conference on Information System and Data Mining* (pp. 13-17). <https://doi.org/10.1145/3546157.3546160>
- Dandis, A. O., Al Haj Eid, M. B., Robin, R. & Wierdak, N. (2022). An empirical investigation of the factors affecting customer lifetime value. *International Journal of Quality & Reliability Management*, 39(4), 910–935. <https://doi.org/10.1108/IJQRM-12-2020-0412>
- Dandis, A. O., Al Haj Eid, M., Griffin, D., Robin, R. & Ni, A. K. (2023). Customer lifetime value: the effect of relational benefits, brand experiences, quality, satisfaction, trust and commitment in the fast-food restaurants. *The TQM Journal*, 35(8), 2526–2546. <https://doi.org/10.1108/TQM-08-2022-0248>
- De Haan, E., Verhoef, P. C. & Wiesel, T. (2015). The predictive ability of different customer feedback metrics for retention. *International Journal of Research in Marketing*, 32(2), 195-206. <https://doi.org/10.1016/j.ijresmar.2015.02.004>
- Firmansyah, E. B., Machado, M. R. & Moreira, J. L. R. (2024). How can Artificial Intelligence (AI) be used to manage Customer Lifetime Value (CLV)—A systematic literature review. *International Journal of Information Management Data Insights*, 4(2), 100279. <https://doi.org/10.1016/j.jjime.2024.100279>
- Fisher, N. I. & Kordupleski, R. E. (2019). Good and bad market research: A critical review of Net Promoter Score. *Applied Stochastic Models in Business and Industry*, 35(1), 138-151. <https://doi.org/10.1002/asmb.2417>
- Gastezzi, C. E. B., Rodríguez, M. M. F. & Castillo, A. (2024). Theoretical foundations on Customer Experience (customer experience, NPS, CSAT, CES, Service Balcony, Journey Map). *Journal of business and entrepreneurial studie*, 8(2). <https://doi.org/10.37956/jbes.v8i2.364>
- Hardianto, B. & Wijaya, S. (2023). Analysis of the impact of Net Promoter Score on financial performance with customer loyalty as mediation. *International Journal of Social Service and Research*, 3(6), 1478-1488. <https://doi.org/10.46799/ijssr.v3i6.401>

- Hosseini Ravesh, S.M.H. & Moghadam, A. (2023). An Estimation of Customer Lifetime Value Based on Quality of Services in Mashhad Body Building Gyms. *Applied Research in Sports Science and Health*, 2(2), 19-36. <https://civilica.com/doc/1783925>. (in Persian)
- Khadivar, A., Golestani, M. & Golshani, F. (2023). Predicting the ethical purchase intention of sustainable products in the circular business model through the behavior of customers/tourists using artificial neural network (ANN). *Tourism Management Studies*, 18(62), 203 - 240. (in Persian)
- King, M., Kim, B.J. & Yune, C.-Y. (2024). Prediction model of undisturbed ground temperature using artificial neural network (ANN) and multiple regressions approach. *Geothermics*, 119, 102945. <https://doi.org/10.1016/j.geothermics.2024.102945>
- Kristensen, K. & Eskildsen, J. (2014). Is the NPS a trustworthy performance measure? *The TQM Journal*, 26(2), 202-214. <https://doi.org/10.1108/TQM-03-2011-0021>
- Kumar, R., Aggarwal, R. K. & Sharma, J. D. (2015). Comparison of regression and artificial neural network models for estimation of global solar radiations. *Renewable and Sustainable Energy Reviews*, 52, 1294-1299. <https://doi.org/10.1016/j.rser.2015.08.021>
- Kvíčala, D., Králová, M. & Suchánek, P. (2024). The impact of online purchase behaviour on customer lifetime value. *Journal of Marketing Analytics*, 1-18. <https://doi.org/10.1057/s41270-024-00328-9>
- Lee, H. F. & Jiang, M. (2021). A hybrid machine learning approach for customer loyalty prediction. In *Neural Computing for Advanced Applications: Second International Conference, NCAA 2021*, Guangzhou, China, August 27-30, 2021, Proceedings 2 (pp. 211-226). Springer Singapore. https://doi.org/10.1007/978-981-16-5188-5_16
- Li, X., Tang, X. & Cheng, Q. (2022). Predicting the clinical citation count of biomedical papers using multilayer perceptron neural network. *Journal of Informetrics*, 16(4), 101333. <https://doi.org/10.1016/j.joi.2022.101333>
- Mohammadi, E. & Rezaei, Z. (2014). An Examination of Relation between Management of Customer Relationship with Quality of Relationship and Customers' Lifetime Value in Hotel Industry (Case study: City of Ilam). *Journal of Tourism Planning and Development*, 4(15), 62-79. <https://civilica.com/doc/1617905>. (in Persian)
- Moradi, Z. & Fakhraei, M. & Azad Aramaki, A. (1401). Investigating the effect of customer knowledge management on customer lifetime value with the mediation of organizational agility (case study: Farsgal Plast Company). *Journal of management Science Research*, 4(10), 189-209. (in Persian)
- Müller, S., Seiler, R. & Völkle, M. (2024). Should Net Promoter Score be supplemented with other customer feedback metrics? An empirical investigation of Net Promoter Score and emotions in the mobile phone industry. *International Journal of Market Research*, 66(2-3), 303-320. <https://doi.org/10.1177/14707853231219648>

- Osmanski-Zenk, K., Ellenrieder, M., Mittelmeier, W. & Klinder, A. (2023). Net Promoter Score: a prospective, single-centre observational study assessing if a single question determined treatment success after primary or revision hip arthroplasty. *BMC Musculoskeletal Disorders*, 24(1), 849. <https://doi.org/10.1186/s12891-023-06981-y>
- Owen, R. (2019). Net Promoter Score and Its Successful Application. In: *Kompella, K. (eds) Marketing Wisdom. Management for Professionals*. Springer, Singapore. https://doi.org/10.1007/978-981-10-7724-1_2
- Rahimiaghdam, S., Faryabi, M. & Azizkhah Alanagh, S. (2021). The Impact of Relationship Marketing on Customer Lifetime Value with the Mediating Role of Relationship Quality. *Commercial Surveys*, 18(105), 71-84. (in Persian)
- Ruck, D. W., Rogers, S. K. & Kabrisky, M. (1990). Feature selection using a multilayer perceptron. *Journal of neural network computing*, 2(2), 40-48.
- Schmidgall, S., Ziaei, R., Achterberg, J., Kirsch, L., Hajiseyedrazi, S. & Eshraghian, J. (2024). Brain-inspired learning in artificial neural networks: a review. *APL Machine Learning*, 2(2). <https://doi.org/10.1063/5.0186054>
- Schmitt, P., Meyer, S. & Skiera, B. (2012). An Analysis of the Link between Customers' Intention to Recommend a Firm and the Lifetime Value of its Customers. *Recherche et Applications En Marketing (English Edition)*, 27(4), 121–142. <https://doi.org/10.1177/205157071202700405>
- Sifa, R., Runge, J., Bauckhage, C. & Klapper, D. (2018). Customer Lifetime Value Prediction in Non-Contractual Freemium Settings: Chasing High-Value Users Using Deep Neural Networks and SMOTE. *Hawaii International Conference on System Sciences*. <https://doi.org/10.24251/HICSS.2018.115>
- Simpson, T. (2023). Impact of Financial and Nonfinancial Constructs on Customer Lifetime Value (CLV): U.S. Retailer's Perspective. *Journal of Relationship Marketing*. <https://doi.org/10.1080/15332667.2023.2197769>
- Specht, D. F. (1991). A general regression neural network. *IEEE transactions on neural networks*, 2(6), 568-576.
- Tsai, C. F., Hu, Y. H., Hung, C. S. & Hsu, Y. F. (2013). A comparative study of hybrid machine learning techniques for customer lifetime value prediction. *Kybernetes*, 42(3), 357-370. <https://doi.org/10.1108/03684921311323626>
- Tudoran, A. A., Thomsen, C. H. & Thomasen, S. (2024). Understanding consumer behavior during and after a Pandemic: Implications for customer lifetime value prediction models. *Journal of Business Research*, 174, 114527. <https://doi.org/10.1016/j.jbusres.2024.114527>
- Valentini, T., Roederer, C. & Castéran, H. (2024). From redesign to revenue: Measuring the effects of servicescape remodeling on customer lifetime value. *Journal of Retailing and Consumer Services*, 77, 103681. <https://doi.org/10.1016/j.jretconser.2023.103681>

- Venkatesan, R., Bleier, A., Reinartz, W. & Ravishanker, N. (2019). Improving customer profit predictions with customer mindset metrics through multiple overimputation. *Journal of the Academy of Marketing science*, 47, 771-794. <https://doi.org/10.1007/s11747-019-00658-6>
- Wu, Y. C. & Feng, J. W. (2018). Development and application of artificial neural network. *Wireless Personal Communications*, 102, 1645-1656. <https://doi.org/10.1007/s11277-017-5224-x>
- Yan, Y., & Resnick, N. (2024). A high-performance turnkey system for customer lifetime value prediction in retail brands: Forthcoming in quantitative marketing and economics. *Quantitative Marketing and Economics*, 22(2), 169-192. <https://doi.org/10.1007/s11129-023-09272-x>
- Ziegler, A., Peisl, T. & Raeside, R. (2023). Improving service quality through customer feedback – the case of NPS in IBM's training services. *International Journal of Quality and Service Sciences*, 15(2), 190–203. <https://doi.org/10.1108/IJQSS-09-2022-0106>