––Name of Journal–––––––––
Vol(issue), PP.
.atu.ac.ir
DOI:

ATU PRESS

Original Research
Received: Review Accepted:
ISSN: 2821-0964 eISSN:2821-0816

Integrating Self-Organizing Neural Networks to Analyze the Impact of Effective Variables on Store Packaging Systems in Iran: A Study on DigiKala Data

Ali Najafi — PhD Student, Department of Management, Hamedan Branch, Islamic Azad University, Hamedan, Iran

Javad NikNafs * — Assistant Professor, Department of Management, Hamedan Branch, Islamic Azad University, Hamedan, Iran (Corresponding Author)

Sandos Bahadori — Assistant Professor, Computer Department, Ilam Branch, Islamic Azad University, Ilam, Iran

Alireza Isfandiari Moghadam — Professor, Department of Information Science and Knowledge, Hamedan Branch, Islamic Azad University, Hamedan, Iran

Abstract

In the era of hyper-competitive digital markets, e-commerce platforms increasingly face the challenge of information overload, where traditional recommendation systems struggle to maintain precision and relevance. This study addresses the critical limitation of isolated recommender systems, which often fail to account for the multidimensional and non-linear patterns of consumer behavior in the Iranian e-commerce ecosystem. We propose a robust, integrated hybrid framework—utilizing Self-Organizing Maps (SOM), Support Vector Machines (SVM), and the Apriori algorithm—designed to optimize

∗ Corresponding Author: Email Address: niknafs@iau.ac.ir
How to Cite: This article is taken from a doctoral dissertation in the field of Information Technology Management, Islamic Azad University, Hamedan Branch.

product bundling strategies. By effectively segmenting users through unsupervised learning and predicting preferences via supervised classification, our model achieves a prediction accuracy of 93.8%. This research bridges the gap between customer loyalty modeling and actionable product association, providing a scalable solution for retailers to enhance cross-selling performance and streamline the user journey.

1. Introduction

The rapid expansion of online retail in Iran has transformed consumer purchasing behavior into a high-dimensional data environment, where decision-making is increasingly influenced by algorithmic recommendations. Despite the prevalence of standard recommendation engines, many platforms—most notably within the Iranian market—encounter significant friction in creating personalized bundles that resonate with diverse customer segments. Existing literature often relies on monolithic models that either focus strictly on transactional history or demographic profiles, leaving a significant void in models capable of synthesizing structural user segmentation with behavioral prediction.

The primary motivation for this study lies in the “bundle mismatch” phenomenon, where recommended products fail to align with a user’s specific price sensitivity or historical purchasing trajectory. This necessitates a hybrid approach that can discern latent user groups while simultaneously predicting specific product affinity. To address this, our research is guided by three fundamental Research Questions (RQs):

- **RQ1:** How can a hybrid framework integrating SOM and SVM effectively segment heterogeneous customer data within the Iranian e-commerce context?
- **RQ2:** To what extent does the integration of Apriori association rules enhance the precision of personalized product bundling compared to isolated algorithmic approaches?

- **RQ3:** What are the quantitative implications of utilizing RFM-based segmentation for increasing bundle conversion rates?

By answering these questions, this study proposes a paradigm shift from traditional, linear recommendation systems to a more sophisticated, structure-aware architecture. We argue that by prioritizing the synergy between structural clustering and supervised preference modeling, retailers can mitigate the volatility of consumer demand and create more stable, profitable product associations.

1.1.Research Gap and Positioning of the Present Study

The reviewed literature exhibits a clear division of labor that no single study has yet integrated. Economic studies establish that bundling and discounting raise sales (Choi and Chen 2019) but reveal heterogeneous behavioral responses across customer segments (Zhang et al. 2022; Zandi Nasab et al. 2020). Recommender research demonstrates substantial sales impact (Arnotaki et al. 2021; Zhao et al. 2022) yet typically relies on either collaborative filtering or single-technique pipelines. Methodological studies validate SOM-based clustering (Carvalho et al. 2022) and SVM-based classification (Long et al. 2018) in isolation, while Iranian research has examined trust, loyalty, and bundling perception (Ebrahimi et al. 2020) without embedding them in an algorithmic recommendation engine.

The present study fills this gap by proposing a hybrid model for Iranian e-commerce in which the SOM segments customers hierarchically on the basis of loyalty and behavioral variables—price, product type, gender, age, and purchase history; the Apriori algorithm then mines association rules to generate candidate product bundles within each segment; and an SVM classifier selects and recommends the bundle most likely to convert each customer. By uniting segmentation, rule mining, and supervised decision-making, the model operationalizes the segment-level bundling logic that the empirical literature demands, with reported classification accuracy of 94 percent on real transaction data from Digikala.

Methodology

The research employs a multi-stage data mining strategy grounded in the transactional data extracted from Digikala. The methodology is structured into four distinct phases: (1) Preprocessing and Data Transformation: Raw data, including user demographics (age, education) and transactional history, were normalized via Z-score to ensure uniformity. (2) Structural Clustering: We applied Self-Organizing Maps (SOM) to identify optimal customer segments. The Silhouette index was used to validate the model, resulting in three distinct loyalty clusters and seven unique product-scenario clusters (Product Scenario 1: 0.3308; Product Scenario 8: 0.501). (3) Predictive Classification: A Support Vector Machine (SVM) was deployed to classify user preferences and determine the likelihood of bundle acceptance, acting as a "decision hyperplane" for the recommendation engine. (4) Pattern Association: Finally, the Apriori algorithm was utilized to extract significant association rules, identifying high-frequency product combinations that form the basis for effective bundling strategies. All computations were executed within a MATLAB R2024 environment to ensure computational efficiency and validation.

Results

The empirical results underscore the efficacy of the proposed hybrid framework, which achieved an overall predictive accuracy of 93.8%, substantially exceeding the performance of individual SOM (59%) or SVM (48%) models. Data analysis revealed a strong correlation between customer loyalty clusters and specific product categories, particularly within the food and household essentials sector, which accounted for 45% of total purchasing volume. The findings demonstrate that by using SOM-derived clusters as input features for the SVM, the model successfully reduces the noise inherent in sparse transactional data. Furthermore, the application of Apriori rules across the identified clusters demonstrated that bundling strategies are most effective when tailored to specific "loyalty segments," rather than applying a universal bundle recommendation. This confirms that the integration of structural and predictive techniques effectively resolves

the misalignment issues found in traditional systems, providing a clear pathway for optimized cross-selling.

Conclusion

This study demonstrates that the future of e-commerce recommendation lies in the intelligent integration of diverse data mining techniques. Our findings validate that a hybrid framework—specifically one that combines SOM for structure discovery, SVM for classification, and Apriori for association—offers a superior approach to managing the complexity of modern consumer behavior. The results have significant implications for retail management; by implementing this framework, businesses can transition from generic promotional activities to precision-based personalization, thereby reducing customer churn and maximizing revenue. We conclude that institutionalizing such data-driven architectures is not merely a technical upgrade but a strategic imperative for competitive advantage. Future research should focus on extending this model to include real-time sentiment analysis and neural network-based prediction windows to further enhance the adaptability of the bundle recommendation system.

Keywords: Recommender system, self-organizing neural networks, support vector machine, product bundling, machine learning

مقاله پژوهشی

--نام مجله---------
دوره ؟، شماره ؟، نام فصل، سال، ص ص
.atu.ac.ir
DOI:

تاریخ دریافت: بازنگری: تاریخ پذیرش: ۰۰/۰۰/۰۰

ISSN: 2821-0964 eISSN:2821-0816

ادغام شبکه‌های عصبی خودسازمان‌دهنده برای تحلیل تأثیر متغیرهای مؤثر بر سیستم بسته‌بندی فروشگاه‌ها در ایران: مطالعه‌ای بر روی داده‌های دیجی کالا

علی نجفی دانشجوی دکترا، گروه مدیریت ،واحد همدان،دانشگاه آزاد اسلامی،همدان،ایران

جواد نیک نفس * استادیار گروه مدیریت ،واحد همدان،دانشگاه آزاد اسلامی،همدان،ایران(نویسنده مسئول)

سندس بهادری استادیار گروه کامپیوتر،واحد ایلام،دانشگاه آزاد اسلامی،ایلام،ایران

علیرضا اسفندیاری مقدم استاد گروه علم اطلاعات و دانش شناسی، واحد همدان،دانشگاه آزاد اسلامی،همدان،ایران

چکیده

این پژوهش با هدف طراحی و بهینه‌سازی یک سیستم پیشنهاددهنده محصولات در بستر تجارت الکترونیک ایران انجام شده است. در این پژوهش سه ویژگی دسته بندی مشتریان و پیشنهاد در قالب تکی و بسته تجمیعی و اجناس نامتجانس بر اساس رنکینگ پیشنهاد ها مد نظر قرار گرفته است. این پژوهش از نظر هدف کاربردی می‌باشد،داده ها از نوع عددی و گسسته است.هدف این مطالعه ، افزایش درک چگونگی تأثیر متغیرهایی مانند ترجیحات مشتری، ویژگی‌های محصول و پویایی بازار بر استراتژی‌های بسته‌بندی در بازار ایران است . نتایج حاکی از آن است که مدل پیشنهادی مسیر جدیدی برای شخصی‌سازی ارائه گروهی محصولات می‌باشد و مدیران بازاریابی می‌توانند از آن در تصمیم‌گیری‌های خود استفاده کنند. تجزیه و تحلیل داده‌ها با استفاده از کدگذاری در نرم افزار متلب انجام شد و خروجی‌های مدل با اثبات فرمول‌های مربوطه ارائه شده است،ارزیابی ها نشان می‌دهد که شرکت‌ها می توانند با اعمال مدل پیشنهادی، توصیه محصول را با دقت

* نویسنده مسئول: Emali Address : niknafs@iau.ac.ir (ترجیحا سازمانی)

بیشتری تعیین کنند.برای این منظور، از شبکه عصبی خودسازمان‌دهنده (SOM) و الگوریتم ماشین بردار پشتیبان (SVM) جهت خوشه‌بندی داده‌ها و پیش‌بینی ترجیحات کاربران استفاده گردید. داده‌های پژوهش از فروشگاه دیجی‌کالا استخراج و پس از نرمال‌سازی با امتیاز Z، در قالب سناریوهای مختلف مبتنی‌بر متغیرهای تأثیرگذار از جمله سن، جنسیت، تحصیلات،نوع محصول و رضایت مشتری بررسی شد. نتایج نشان داد مدل ترکیبی ارائه‌شده قادر است با دقت ۹۴٪ پیشنهادات محصول را به‌درستی پیش‌بینی کند، که نسبت به روش‌های مقایسه‌ای SOM و SVM به‌ترتیب با دقت ۵۹٪ و ۴۸٪، عملکرد بهتری دارد. استفاده از شاخص سیلوئت برای سنجش کیفیت خوشه‌بندی نشان داد که تعداد خوشه بهینه برابر با ۷ بوده و بیشترین گروه مرتبط به دسته محصولات خوراکی با سهم ۴۵٪ بوده است. این مطالعه مسیر جدیدی برای شخصی‌سازی پیشنهادات محصول در تجارت الکترونیک ارائه می‌دهد.

کلیدواژه‌ها: سیستم توصیه گر،شبکه های عصبی خود سازمان‌ده، ماشین بردار پشتیبان، باندلینگ محصول، یادگیری ماشین

۱.مقدمه

در سال‌های اخیر،سیستم‌های توصیه‌گر(Recommender Systems) نقش محوری در پلتفرم‌های تجارت الکترونیک ایفا می‌کنند.این سیستم‌ها با فیلتر کردن حجم عظیم اطلاعات و ارائه پیشنهادات مرتبط به هر کاربر، تأثیر مستقیمی بر تجربه کاربری، نرخ تبدیل(Conversion Rate) و در نهایت، افزایش درآمد سازمان‌ها دارند. در بازار رقابتی تجارت الکترونیک ایران، جایی که تنوع کالایی روزبه‌روز افزایش می‌یابد، نیاز به مدل‌های هوشمند جهت درک پیچیدگی‌های رفتار مصرف‌کننده ایرانی، بیش از پیش احساس می‌شود.

۱,۱.اهمیت سیستم‌های توصیه‌گر در تجارت الکترونیک

سیستم‌های توصیه‌گر سنتی عمدتاً بر فیلتر مشارکتی(Collaborative Filtering) یا فیلتر مبتنی بر محتوا

(Content-Based Filtering)متکی بودند. با این حال، چالش‌هایی نظیر مشکل "شروع سرد" (Cold Start)

و نیاز به مدل‌سازی تعاملات پیچیده بین ویژگی‌های کاربر و آیتم، نیازمند رویکردهای جدیدی مبتنی بر یادگیری ماشین پیشرفته است. سیستم‌های توصیه‌گر مدرن سعی دارند با استخراج الگوهای پنهان در داده‌های رفتاری و جمعیت‌شناختی، توصیه‌های دقیق‌تر و شخصی‌سازی‌شده‌تری ارائه دهند.

۱/۲.هدف پژوهش

هدف اصلی پژوهش حاضر، طراحی و ارزیابی یک چارچوب ترکیبی مبتنی بر شبکه‌های SOM) عصبی خودسازمان‌ده (

برای خوشه‌بندی سلسله‌مراتبی کاربران و SVM) برای طبقه‌بندی و و پیش‌بینی ترجیحات الگوریتم ماشین بردار پشتیبان (

خرید آن‌هاست. تمرکز این مطالعه بر روی داده‌های واقعی استخراج‌شده از یکی از بزرگترین پلتفرم‌های تجارت الکترونیک ایران، یعنی دیجی‌کالا، است تا اطمینان حاصل شود مدل از نظر فرهنگی و رفتاری با بازار داخلی همخوانی دارد.

۲.پیشینه پژوهش

با توجه به استفاده روز افزون ازتکنولوژی‌های جدید که هدف آنها کسب سود بیشتر و نهایتآ کسب رضایت‌مندی افراد است وجود این سامانه‌های توصیه‌گر ضروری می‌باشد.،با پیشرفت سریع علم و فناوری روزانه مقادیر زیادی داده‌های ساختاریافته، نیمه ساختاریافته و بدون ساختار از منابع مختلف تولید می شود،این داده‌ها که توسط کاربران مختلف تولید می‌شوند، اغلب الگوهای رایجی را نشان می‌دهند که می‌توان آنها را فیلتر و تجزیه و تحلیل کرد تا توصیه‌های ارزشمندی برای محصولات یا خدمات مورد علاقه این کاربران ارائه دهد(نوراحمدی،۲۰۲۴). فروش تجمعی محصول روشی مؤثر و معروف برای دستیابی به اهداف تجاری در بسیاری از صنایع محسوب میشود. باندلینگ ابزاری تجاری است که در آن دو یا چند محصول در یک بسته با تخفیف به فروش میرسد (کنگ و همکاران ۲۰۲۱). هنگامی که در باندلینگ محصولات با یکدیگر ارتباط دارند، اثربخشی آن بیشتر می شود به دلیل اثربخشی فروش تجمیعی، از آن در حوزه های گوناگون استفاده شده است(چوی و چن ۲۰۱۹). فروش گروهی محصولات، کالاها و خدمات موضوع پژوهشی مهمی در بازاریابی محسوب می‌شود(پلانانسکا،۲۰۲۲). فروش تجمیعی کالاهای نامتجانس برای مدت چندین سال کاربرد گسترده‌ای داشته است که هدف آن منفعت فروشنده و مشتری بوده است(چانگ،۲۰۲۱). اخیراً دامنه فروش تجمیعی صرفاً به باندلینگ محصولات محدود شده است و باندلینگ محصولات با خدمات مختلف ازقبیل خدمات هسته‌ای به تدریج متداول شده است(سن زو،۲۰۲۲). باندلینگ راهبرد بازاریابی متداولی است که شامل ارائه دو یا چند محصول برای فروش به صورت یک آیتم داده

می‌شود. یک شرکت به چند دلیل درگیر راهبرد باندلینگ می‌شود. ممکن است بسته های باندلینگ به منظور پشتیبانی تصمیمات راهبرد هدایت شده به سمت افزایش قدرت بازار سازمان ارائه شوند. بسته های باندلینگ همچنین ممکن است برای اهداف افزایش راندمان و کارایی ارائه شوند که شامل بهبود در کیفیت، صرفه جویی درهزینه و کارایی درقیمت گذاری می‌شوند. اهمیت فزاینده باندلینگ محصولات و خدمات به این حقیقت نسبت داده می‌شود که شرکت‌ها در حال ایجاد راهبردهای خود براساس این عملکردها هستند(جنا،۲۰۲۲). اهداف اصلی راهبرد باندلینگ گسترش قدرت انحصاری شرکت در یـ ک بازار به بازار دیگر برای پذیرش تفاوت قیمتها، پیشگیری از ورود یک رقیب به بازار و همچنین ایجاد اتحاد راهبردی است. درعمل، محصولات مختلفی وجود دارند که مکمل یکدیگر هستند و می توان آنها را در یک بسته قرار داد. مثال‌هایی از آن شامل ترکیبی از قهوه جوش، شامپو و نرم کننده، رایانه و موارد مشابه می‌شود(زانگ،۲۰۲۲).امروزه استفاده از باندلینگ در صنایع خدماتی مختلفی از جمله گردشگری، حمل و نقل هوایی و مخابرات رواج یافته است. اما شرکت‌ها برای استفاده از باندلینگ می بایست به این نکته توجه کنند که محصولات عرضه شده علاوه بر سود برای شرکت، رضایت مصرف کننده را نیز در اولویت قرار دهند (ژانگ و همکاران ۲۰۲۲). مصرف کنندگان با استفاده از باندلینگ هزینه های خود را کاهش می‌دهند. همچنین، استفاده از باندلینگ در اپراتورهای همراه باعث مزیت رقابتی شرکت در مقایسه با رقبا می‌شود (کنگ و همکاران ۲۰۱۷). هر ساله بازاریابان میلیاردها دلار صرف یافتن تکنیک‌های مناسب برای فروش بسته‌های نرم افزاری می کنند. باتوجه به اهمیت این بسته‌ها، مهم است که مدیران درباره شیوه‌ی طراحی و برقراری ارتباط موثر بسته‌ها آگاه باشند. باندلینگ منوط به یک فرض اساسی است که فروش در بسته‌های مختلف مشتریان را تشویق می کند که بیشتر و زودتر خرید کنند. بر این اساس،این علاقه نسبت به فروش بسته‌های مختلف زمینه ساز کارهای پژوهشی زیادی شده است که هدف آن، درک عوامل تعیین کننده اشتیاق مصرف کنندگان برای خرید بسته های مختلف است. یکی از چالش‌های عمده مرتبط با باندلینگ سنتی این است که مصرف کنندگان باید کالاها و

خدمات غیرضروری را فراتر از نیاز واقعی خود بخرند تا واجد شرایط تخفیف شوند (دوها و همکاران ۲۰۱۷). زمانی که مصرف کننده با تنوع خدمات اپراتورهای همراه مواجه می‌شود، در فرد قصد خرید به وجود می‌آید همچنین امکان استفاده مجدد فرد افزایش می‌یابد (کنگ و همکاران ۲۰۱۷). بنابراین با افزایش تنوع در باندلینگ تمایل به استفاده نیز بیشتر می‌شود (شاو و لی ۲۰۱۹).

لذا باتوجه به وجود پیشرفت‌های تکنولوژیکی بسیار گسترده در سال‌های اخیر در حوزه الکترونیک، سخت‌افزار و هوش مصنوعی، بسیاری از محققین روش‌های یادگیری ماشین را جهت سیستم های پیشنهاددهنده باندلینگ پیشنهاد و ارائه نموده‌اند که می‌توانند با دقت خوبی توصیه هایی را در سیستم های پیشنهاددهنده باندلینگ انجام دهد(ایکسو و همکاران،۲۰۲۳). در واقع یادگیری ماشین می تواند پیچیدگی مساله و داده‌ها را واکاوی کند و بررسی نماید که چگونه هستند که از جمله ویژگی های اصلی روش های یادگیری ماشین به حساب می آید.از سوی دیگر در سال‌های اخیر پیشرفت‌های بسیار مهمی در حوزه‌های مختلف تکنولوژی به‌ویژه در زمینه هوش مصنوعی و محول شدن تحلیل‌ها و تصمیم‌گیری‌های مهم در حوزه‌های مختلف به این ابزار بسیار قدرتمند، رخ داده‌است. یکی از این پیشرفت‌های مهم و اساسی در زمینه هوش مصنوعی و بینایی ماشین، یادگیری عمیق[1] می‌باشد(حسینی و همکاران،۲۰۱۹). یادگیری عمیق یکی از جدیدترین دستاوردهای شگرف بشر می‌باشد که نقش مهمی در نزدیک کردن توانمندی هوش مصنوعی به هوش انسانی ایفا نموده‌است. هم‌اکنون محققان بسیاری در سراسر دنیا در دو حوزه پیشرفت دانش یادگیری عمیق و دیگری پهنه به کارگیری آن در کاربردهای مختلف می‌باشد. در حقیقت یادگیری عمیق نوعی از یادگیری ماشین و هوش مصنوعی است که در واقع از روشی که ذهن انسان برای یادگیری موضوع خاصی به کار می‌گیرد، تقلید می‌کند. این نوع از یادگیری یکی از عناصر مهم در علم داده می‌باشد که شامل آمار و مدل‌سازی پیش‌بینی است. یادگیری عمیق برای دانشمندان داده که وظیفه جمع‌آوری، تجزیه و تحلیل و تفسیر مقادیر زیادی از داده‌ها را

[1] Deep Learning

دارند، بسیار مفید است و این روند را سریعتر و آسان‌تر می‌کند. به نوعی می‌توان گفت یادگیری عمیق در واقع همان یادگیری ماشین است، به گونه‌ای که در سطح کارهای پیچیده، نمایش یا انتزاع، یادگیری را برای ماشین انجام می‌دهد و به این صورت ماشین درک بهتری از واقعیت‌های وجودی پیدا می‌کند و می‌تواند الگوهای مختلف را شناسایی کند. در ساده‌ترین سطح، یادگیری عمیق را می توان راهی برای خودکارسازی تجزیه و تحلیل پیش-بینی‌ها دانست. الگوریتم‌های یادگیری عمیق در سلسله مراتب افزایش پیچیدگی و انتزاع قرار دارند. در حالی که یادگیری ماشین سنتی، بصورت خطی است (حسینی و همکاران،۲۰۱۹).

حال آنکه در سال‌های اخیر یکی از جدیدترین متدهایی که به‌منظور انجام فرآیند آموزش در یادگیری عمیق بر اساس مفاهیم علم روانشناسی ابداع شده‌است، شبکه عصبی خودسازمانده(SOM) است. SOM بی شک یکی از قدرتمندترین شبکه های موجود در جهت داده کاوی و تحلیل غیرخطی فضاهای پیچیده می‌باشند (پویانفر،۲۰۱۸). سیستم پیشنهاددهنده مبتنی بر SOM معرفی کردند و ارزیابی نتایج آنها کارایی SOM را در سیستم های پیشنهاددهنده نشان داد. SOM ویژگی‌های داده‌ها را بهتر تشخیص می دهد و چون از زیرمجموعه‌ای از نقاط یادگیری استفاده می کنند، در نتیجه در مصرف حافظه صرفه جویی می کنند (آفودی و همکاران،۲۰۲۱).

همچنین در ارتباط با سیستم پیشنهاد دهنده، یکی دیگر از روش‌ها، ماشین بردار پشتیبان(SVM) است که توسط (یانگ و همکاران،۲۰۲۳) پیشنهاد شد. ماشین های بردار پشتیبانی (SVM) الگوریتم‌های قدرتمند و منعطف یادگیری ماشین تحت نظارت هستند که برای طبقه‌بندی مورد استفاده قرار می گیرند، SVM برای انواع داده با ابعاد بالا به‌خوبی کار می‌کند. با انتخاب یک تابع کرنل خوب میزان خطا به‌خوبی کنترل می شود،همچنین مرز جداسازی برای دسته بندی کاملا واضح است(شان،۲۰۱۶) .

لذا در راستای مطالب ارائه شده در بالا، باتوجه به اینکه مهمترین هدف سیستم‌های باندلینگ فروش بیشتر محصولات به کاربران است، ما نیازداریم که بهترین روش پیشنهاد را برای هر

کاربر تعیین کرده و رضایت وی از این روش را اندازه گیری و تخمین بزنیم. بنابراین، مدل ترکیبی جدیدی را ارائه می کنیم که مشتریان بر اساس سطح وفاداری آنها با الگوریتم SOM بر اساس متغییرهای موثر(قیمت، نوع محصول، تحصیلات،جنسیت، سن، ترکیب کالای باندلینگ، تعداد خرید، میزان خرید، سلیقه و رده بندی رضایت مشتری) گروه بندی می شوند. الگوریتم Apriori همچنین برای تعیین قوانین ارتباط برای هر بسته محصول استفاده می شود.مدل طبقه‌بندی SVM به منظور توصیه باندلینگ یا عدم باندلینگ به هر مشتری اعمال می‌شود.در این پژوهش،مدل ترکیبی جدیدی برای باندلینگ محصول در تجارت الکترونیک بازار ارائه می‌شود که شرکت‌ها می توانند با در نظر گرفتن سطوح مختلف وفاداری مشتری و ویژگی های هر بخش بازار، بازاریابی مستقیم انجام دهند و باندلینگ محصول مناسب را به مشتریان خود توصیه کنند. آنها همچنین می توانند انواع مختلفی از تبلیغات مانند تخفیف و کوپن را به مشتریان ارائه دهند. بنابراین، شرکت ها می توانند مشتریان جدید را جذب کنند، مشتریان فعلی را برای خرید ترغیب کنند و مشتریان ارزشمند را حفظ کنند.

۲/۱. کارهای مرتبط

اصنافی و همکارانش، به بررسی و ارائه مدلی برای سیستم‌های پیشنهاد دهنده منابع اطلاعاتی در نرم‌افزارهای کتابخانه‌ای ایران پرداختند.در پژوهش آنان در مقوله راهبردهای فعلی نرم‌افزارهای کتابخانه‌ای برای توصیه، بهره‌گیری از روش سنتی توصیه، تعریف ارتباط میان رکوردها،موضوعات،واژگان، و تعریف ماژول پالایش جستجو صورت گرفته است. در مقوله تعیین میزان آشنایی با سیستم پیشنهاد دهنده، سه مقوله آشنایی کامل (۱۷ ٪)، آشنایی مختصر(۵۰٪) و بدون آشنایی (۳۳٪) شناسایی شد و از لحاظ امکانات مورد نیاز سیستم‌های پیشنهاد دهنده، زیرمقوله های امکانات فنی، سیستمی، و تخصصی (شخصی‌سازی) شناسایی شده و مفاهیم آن تبیین شده است همچنین چالش‌های اضافه کردن سیستم پیشنهاد دهنده مشخص شده و مقوله مزایای اضافه کردن سیستم پیشنهاد دهنده تبیین شده است(اصنافی و

همکاران ،۲۰۲۲). ابراهیمی و همکارانش اقدام به ارائه مدل وفاداری مشتری برای سیستمهای پیشنهاد دهنده تجارت الکترونیک نمودند.در پژوهش آنان نتایج مدلسازی معادلات ساختاری نشان داد که عامل اعتماد دارای رابطه مهمی با رضایت مشتری در سیستمهای پیشنهاد دهنده تجارت الکترونیک است. علاوه بر آن، نتایج حاکی از آن است که رضایت از محصولات پیشنهادی، می‌تواند موجب ارتقاء وفاداری مشتری در سیستم‌های پیشنهاد دهنده B2C[1] شود(ابراهیمی و همکاران،۲۰۲۰).لانگ و همکاران، رویکردی برای پیکربندی سیستم خدمات محصول پیشنهاد دادند که در آن نیازهای مشتری ابتدا به عنوان نیازهای عملکردی و نیازهای ادراکی تقسیم می‌شوند که عموماً توسط مشتریان از طریق کلمات خودشان بیان می‌شوند سپس توصیفات معرف نیازهای ادراک با تحلیل عاملی استخراج می شود بر اساس آن، یک مدل ماشین بردار پشتیبان چند کلاسه(SVM) برای سیستم خدمات محصول نیازهای مشتری را برآورده می کند، ساخته شده است. نتایج نشان می‌دهد که این روش مؤثر است. (لانگ و همکاران،۲۰۱۸).کاراهو و همکارانش، به مشکل پیشنهاد باندلینگ نمایش در بازارهای داده می‌پردازند که در آن کاربرد باندلینگ به تعامل بین دیدگاه‌های کاندید بستگی دارد. آنها استفاده از SOM را به عنوان وسیله‌ای برای محاسبه این تعامل و استفاده از الگوریتم ژنتیک برای طراحی باندلینگ تقریباً بهینه پیشنهاد می کنند. نتایج تجربی نشان می‌دهد که رویکرد آنها می‌تواند به طور موثر به مصرف‌کنندگان داده کمک کند تا باندلینگ نمایش مربوطه را تحت محدودیت‌های بودجه پیدا کنند(کارواهو و همکاران،۲۰۲۲).زندی نصب و همکارانش،اقدام به بررسی تاثیر شیوه باندلینگ اجتماعی درباره تمایل مشتریان برای خرید بسته های آنلاین شرکت همراه اول نمودند. ابزار اصلی گردآوری داده ها، پرسشنامه بوده است. تجزیه و تحلیل داده ها با تکنیک مدلسازی معادلات ساختاری و با نرم افزار LISREL و SPSS انجام شده است. نتایج پژوهش آن‌ها نشان می‌دهد باندلینگ اجتماعی بر کنترل ادراک شده، ارزش ادراک شده و عدم اطمینان ادراک شده تأثیر مثبت و کنترل ادراک شده بر ارزش ادراک شده و قصد خرید تاثیر مثبت دارد. عدم اطمینان ادراک شده بر ارزش ادراک شده تاثیر منفی ندارد و ارزش ادراک شده بر

[1] Business-to-consumer

قصد خرید تاثیر مثبت و عدم اطمینان ادراک شده بر قصد خرید، تاثیر منفی دارد(زندی نصب و همکاران،۲۰۲۰).چوی و چن،به بررسی تاثیر تخفیف و باندلینگ بر فروش برنامه های کاربردی پرداختند. به این منظور پیمایشی با مشارکت تعدادی از برنامه های کاربردی صنعت فناوری اطلاعات انجام شد و یافته های پژوهش آنها نشان داد که هردو کاهش قیمت (تخفیف) و بسته‌بندی دارای تاثیر مثبتی بر فروش روزانه برنامه‌ها است.به طور خاص، نرخ تنزیل و میزان تخفیف قیمت روابط مثبتی با افزایش فروش دارد(چوی و چن ،۲۰۱۹).آرنوتاکی و همکارانش، به بررسی نقش سیستم‌های پیشنهاد دهنده بر فروش صنعت پوشاک پرداختند. بر اساس نتایج آنان سیستم‌های پیشنهاد دهنده بر فروش در صنعت پوشاک به طور متوسط ۱۷ درصد تاثیر دارد که این تاثیر در خرید زنان بیش از مردان موثر است(پیانا و همکاران ،۲۰۲۱).ژانو و همکارانش، به بررسی نقش سیستم‌های پیشنهاد دهنده در فروش فروشگاه‌ها پرداختند و نتایج تحقیق آنان نشان که سیستم‌های پیشنهاد دهنده هم فروش به صورت مجزا و هم فروش به صورت بسته ای را افزایش داده است(ژائو و همکاران ،۲۰۲۲). ژانگ و همکارانش،دو رویکرد تجربی را به کار بردند: یک آزمایش طراحی بین آزمودنی برای مطالعه تأثیر نوع بسته‌بندی ضروری بر تمایل خرید ، و یک آزمایش انتخابی برای شناسایی نوع بسته ترجیحی بخش‌های مشتری منفرد. آن‌ها دریافتند که بسته‌بندی خدمات و شارژ، تمایل خرید را در پاسخ دهندگان با دانش قبلی کمی از خودروهای برقی افزایش می‌دهد. آنها در امتیازات اهمیت و ابزارهای ارزش بخشی که به سطوح ویژگی های فردی و ترجیحات بسته کلی می دهند متفاوت هستند. بر اساس این نتایج، توصیه‌هایی را برای سیاست و عمل در مورد نحوه ترویج و استفاده از بسته‌ها برای تقویت خرید خودروهای الکتریکی در میان گروه‌های بعدی از پذیرندگان ارائه دادند و راه‌هایی را برای تحقیقات بیشتر پیشنهاد کردند(ژانگ و همکاران،۲۰۲۲).

۳.روش شناسی پژوهش

در ابتدا به بررسی ادبیات موجود در حوزه موضوع پرداخته،سپس از طریق منابع کتابخانه ای عوامل موثر در سیستم پیشنهاد دهنده اجتماعی بر پایه علوم مهندسی و یادگیری عمیق در این خصوص مورد بررسی قرار گرفت، سپس با استفاده از این یافته‌ها و مرور ادبیات تحقیق،عوامل و ویژگی‌های اصلی شناسایی و چارچوب اولیه طراحی گردید.برای یافتن بهترین روش از میان روش‌های بکار گرفته شده شبکه عصبی که بتواند

معیارهای مختلفی را پاسخگو باشد،به دنبال شبکه‌های MLPرفته تا بتواند در ورودی‌های عصبی چند لایه

نورون ساختار را تا کشف بهترین پاسخ تحویل نورون بعدی بدهد رفتیم، لذا مقایسه‌هایی صورت گرفت و RBFبین انواع شبکه عصبی)الگوهای رفتاری استخراج شده از آن، مشخص شد که مدل شبکه عصبی شعاعی(

پردازنده در موقعیت های خاصی متمرکز می‌شوند و از طریق توابع رادیال مدل‌سازی می شوند که پاسخگوی

نیازهای مدل ارائه شده ما نیست. در مرحله بعد بدنبال انواع الگوریتم‌های شبکه عصبی گراف چند منظوره

) که ایده بیشتر معماری آن‌ها بر پیچیدگی(کانولوشن) گراف متمرکز می‌باشد وزن (GNNورودی‌های مورد

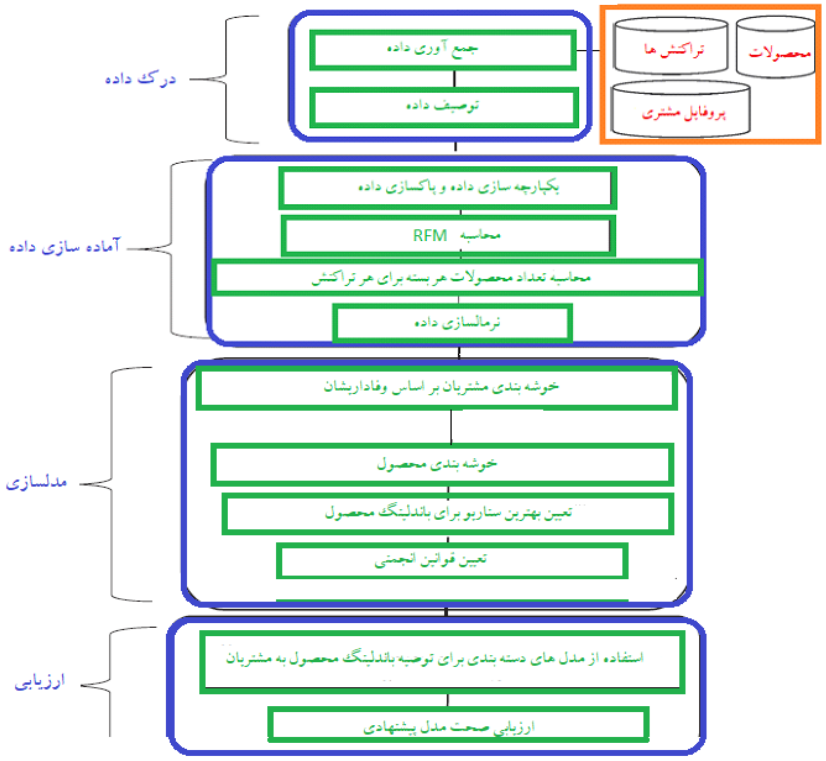
مطالعه را به صورت نامنظم در نظر می گیرند و در صورت افزودن یک گره به گراف لازم است که مجدد کل شبکه آموزش ببیند،از آنجائیکه ما به‌دنبال پیدا کردن شباهت‌ها در میان انبوهی از دیتاها می‌باشیم و از سوی ((تازگی خرید، تعداد خرید ، میزان خرید)با دیگر به‌دنبال تلفیق روش های بازاریابی RFMشخصی‌سازی

ویژگی‌های منحصر بفرد افراد مانند جنسیت سن تحصیلات و ویژگی‌های روانشناسی افراد هستیم تا بتوانیم بر طبق ذائقه آن‌ها توصیه انجام گیرد از شبکه عصبی خود سازمانده استفاده شد که با ساختار بازگشتی خود فیدبک‌های داخلی ایجاد کند و با تمام وزن های ورودی همگرا شود، سپس بر اساس چارچوب اولیه سیستم خوشه‌بندی و پیشنهاد گروهی محصولات طراحی می گردد.این پژوهش بر مبنای اطلاعات کاربران و امتیاز به محصولات فروشگاه دیجی کالا(نظر سنجی کاربران)و تنوع محصولات فروشگاه دیجی کالا انجام گرفت.برای اطمینان از حفظ پایایی پژوهش از دو استراتژی استفاده شد.اول اینکه استخراج داده‌های پژوهش با استانداردهای پژوهش کمی و رعایت اصول علمی و اخلاقی صورت گرفت و برای نشان دادن متغییرهای موثر در فروش بیشتر محصولات در حین پیاده سازی و کد گذاری عددی مرور مجدد انجام می‌گرفت تا عامل اساسی و تاثیرگذاری از قلم نیفتد سپس با کد گذاری و انتخاب متغیرهای تاثیر گذار و هدفمند تحلیل و تفسیر انجام گرفت.خوشه بندی و دسته بندی مشتریان توسط الگوریتم‌های مختلف در نرم افزار متلب اجراء و پیاده سازی گردید و خروجی مدل نهایی گزارش گردید.

۴.روش ارائه شده

در این قسمت به بیان روش ارائه شده طبق شکل۱ می‌پردازیم. هدف اصلی پژوهش ارائه یک مدل جدید برای توصیه محصول در فروشگاه دیجی‌کالا با استفاده از متغیرهای تاثیرگذار و تحلیل وفاداری مشتری است. مدل RFM برای محاسبه وفاداری مشتری استفاده می شود. پس از آن، مشتریان بر اساس سطح وفاداری آنها گروه‌بندی می‌شوند. سپس هر گروه بر اساس متغیرهای تاثیرگذار به بخش‌های مختلف تقسیم می شود. باندلینگ محصول از طریق الگوریتم‌های خوشه‌بندی تعیین می‌شوند. الگوریتم Apriori همچنین برای تعیین قوانین ارتباط برای هر باندلینگ محصول استفاده می شود. در نهایت مدل SVM به منظور تعیین اینکه کدام بسته سفارشی‌سازی شده محصول باید به هر مشتری توصیه شود اعمال می‌شود،که در ادامه به نحوه اجراء گام به

گام مراحل کار پرداخته می‌شود.



شکل۱: مراحل روش ارائه شده

شکل۲ مراحل مدل ارائه شده نشان می‌دهد.



شکل۲: مدل ارائه شده

۱-٤- جمع آوری داده ها

در این مرحله داده‌های تراکنش تاریخی را جمع‌آوری کردیم که شامل اطلاعاتی درباره خریدهای مشتری است، مانند محصولاتی که آنها با هم یا متوالی خریده‌اند. در پژوهش حاضر، فروشگاه انتخاب شده، فروشگاه دیجی‌کالا است که غذا، نوشیدنی، پروتئین، فست فود، محصولات بهداشتی و ابزار آشپزخانه را می‌فروشد. هدف این فروشگاه شخصی‌سازی بسته‌های محصول خود برای مشتریان است. این فروشگاه همچنین قصد دارد بسته‌های محصول را با تخفیف‌های متفاوت به مشتریان خود بر اساس سطح وفاداری و بخش بازارهایی که به آن تعلق دارند، توصیه کند.

۲-٤- توصیف داده

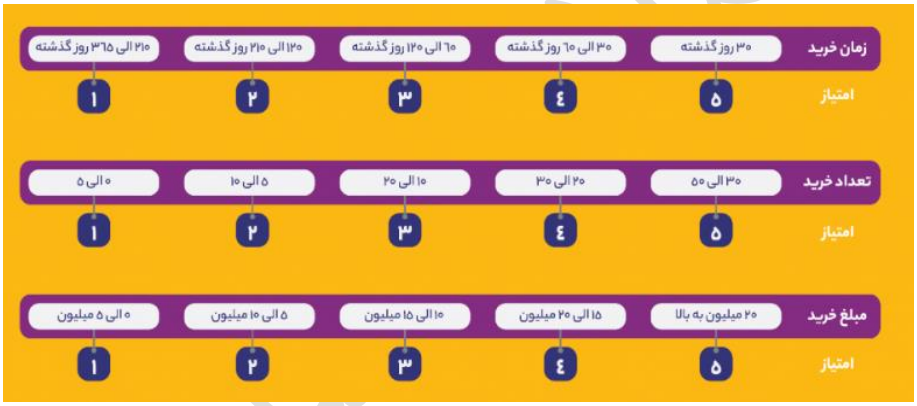
در این پژوهش، فروشگاه منتخب در حوزه خوراکی، نوشیدنی، پروتئین، محصولات بهداشتی و ابزارهای آشپرخانه است. هدف از این فروشگاه شخصی‌سازی محصولات خود برای مشتریانش است. این فروشگاه همچنین قصد دارد که محصولاتی با تخفیف‌های مختلف را بر اساس میزان وفاداری‌شان و بخشی از بازار که به آن تعلق دارند توصیه کند.

۳-٤- یکپارچه سازی و پاکسازی داده ها

از کلیدهای اصلی سه پایگاه‌های داده‌ها مطابق جدول۲ برای ترکیب آن‌ها و دستیابی به یک مجموعه داده یکپارچه طبق ده متغیر تاثیر گذار (خروجی مناسب و هدفمندی را با کشف الگوهای رفتاری توسط پیاده‌سازی الگوریتم‌های بکار گرفته شده استخراج و استنتاج گردید.شکل۴) برای ۱۰۰۰ رکورد به صورت تصادفی استفاده شد. فرآیند پاکسازی داده‌ها با حذف مقادیر نویزی و از دست رفته انجام شد. در مرحله ساخت صفت، تعداد و ارزش پولی از تراکنش‌های هر مشتری محاسبه شد تا از آن در خوشه‌بندی مشتریان به سطوح وفاداری مختلف استفاده شود. علاوه بر این، تعداد محصولات در هر دسته‌بندی برای هر تراکنش مشتری تعیین شد تا از آن برای خوشه‌بندی محصول استفاده شود. برای مثال، برای

یک تراکنش مشتری دو قلم از لبنیات و روغن از دسته‌بندی خوراکی وجود دارند. بعد از محاسبه مقادیر RFM و تعداد محصولات در هر دسته، باید آن‌ها را قبل از استفاده در الگوریتم‌های خوشه‌بندی نرمالسازی کرد.

برای تقسیم‌بندی مشتریان بر اساس تحلیل RFM ،باید هر یک از پارامترهای زمان، تعداد و مبلغ خرید را به ۵ دسته تقسیم کنیم و از ۱ تا ۵ به هر کدام امتیاز دهیم. امتیاز ۵ مربوط به دسته‌ای است که ارزش بیشتری داشته و عدد ۱ به دسته‌ای که کمترین ارزش را دارد، تعلق می‌گیرد. با این کار برای هر مشتری به یک عدد ۳ رقمی می‌رسیم که هرچه بالاتر باشد در گروه بالاتری قرار می‌گیرد. برای مثال اگر مشتری عدد ۴۱۳ بگیرد، طبق شکل۳، یعنی در بازه زمانی ۳۰ الی ۶۰ روز گذشته، ۰ الی ۵ بار خرید به ارزش ۱۰ الی ۱۵ میلیون داشته است.



شکل۳: تقسیم بندی و امتیازدهی به مشتریان با متد RFM

از فرمول امتیاز Z برای نرمالسازی داده‌ها استفاده می‌شود. فرمول امتیاز z در معادله (۱) نشان داده می‌شود. در این فرمول، مقدار (v) یک صفت (A) بر اساس میانگین 'A و انحراف معیار صفت A به صورت زیر به یک مقدار جدید 'V نرمالسازی می‌شود.

$$V' = \frac{v - A'}{\sigma_A} \qquad (۱)$$

۱-٤-٤- سناریوی بکار رفته بر اساس متغییرهای تاثیر گذار

۸ سناریو از باندلینگ محصولات در این پژوهش وجود دارد که در جدول ۱ مشاهده می‌شود.

جدول ۱: سناریوهای مختلف بر اساس متغیرهای تاثیرگذار

سناریو ۱: بدون استفاده از متغییرهای تاثیرگذار
سناریو۲: جنس،سن، تحصیلات
سناریو۳: نوع محصول ، قیمت
سناریو۴: نوع محصول، رضایت مشتری، سلیقه
سناریو۵: نوع محصول، باندلینگ، میزان خرید، تعداد خرید
سناریو۶: جنس، تحصیلات، باندلینگ، رضایت مشتری
سناریو۷ : سن، باندلینگ، رضایت مشتری
سناریو۸: جنس، سن،تحصیلات، سلیقه،رضایت مشتری، قیمت، نوع محصول، ترکیب باندلینگ،تعداد خرید،میزان خرید،تعداد خرید

۲-٤-٤- بررسی سناریوهای مختلف

۸ سناریو از باندلینگ محصولات در این پژوهش وجود دارد که در جدول ۱ نشان داده شدند.

برای یافتن بهترین سناریو، از پارامتر سیلوئت جهت کشف کارایی خوشه بندی استفاده می کنیم.

سیلوئت[1]: کیفیت الگوریتم های خوشه بندی را می توان با توجه به ضریب سیلوئت ارائه شده در معادله(۲) به دست آورد. در این معادله A میانگین فاصله اشیاء درون یک خوشه از یکدیگر و B حداقل میانگین فاصله اجسام درون خوشه از سایر خوشه ها است.

$$Silhouette = \frac{(B - A)}{\max(A, B)} \qquad (۲)$$

[1] *Silhouette*

مقدار ضریب سیلوئت بین [−۱, ۱] است. ۱ نشان دهنده بالاترین کیفیت خوشه بندی و ۱− نشان دهنده پایین ترین کیفیت خوشه بندی است. برای اندازه‌گیری کیفیت یک الگوریتم خوشه‌بندی، می‌توان از میانگین مقدار ضریب سیلوئت در مجموعه داده استفاده کرد.

در ادامه، مراحل سناریوی ۱ و سناریوی ۸ برای مقایسه دسته‌های محصولات ارائه می‌شوند. از وضعیت ۱ برای بررسی مدل ارائه‌شده استفاده می‌شود. سپس نتایج نهایی وضعیت ۲ برای مقایسه آن‌ها با وضعیت ۱ ارائه می‌شوند. جدول ۲ مقادیر سیلوئت را برای تعداد مختلف خوشه‌ها در الگوریتم SOM برای سناریوی ۱ در وضعیت ۱ نشان می‌دهد.از ترکیب شبکه عصبی خود سازمانده با الگوریتم میانگین فاصله دسته‌ها در روش ارائه شده به دسته‌بندی‌های زیر دست پیدا کردیم و مقادیر میزان صحت دسته بندی‌ها برای سناریوهای مختلف به تفکیک آورده شده است.همان‌طور که در جدول۳ مشخص است بهترین وضعیت برای تقسیم کردن خوشه‌ها با مقدار سیلوئیت بالاتر متعلق به تعداد خوشه ردیف ۷ با میزان ضریب سیلوئیت ۰,۳۳۰۸ می‌باشد.

جدول ۲: مقایسه مقادیر سیلوئت برای تعداد خوشه‌های مختلف در الگوریتم SOM برای سناریوی ۱ در وضعیت۱

تعداد خوشه‌ها	سیلوئت
2	0.3236
3	0.1896
4	0.3105
5	0.2885
6	0.2761
7	0.3308

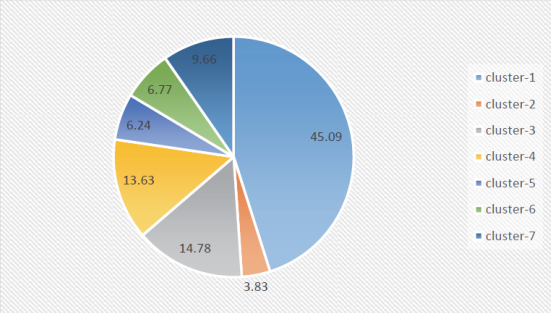
8	0.2206
9	0.3094
10	0.2874

جدول ۳ مقدار سیلوئت و تعداد خوشه‌ها را برای الگوریتم‌های خوشه‌بندی SOM ، SPSS دومرحله‌ای و K میانگین برای وضعیت ۱ در سناریوی ۱ نشان می‌دهد.همان‌طور که مشخص است روش ارائه شده با ضریب سیلوئیت بالاتر خوشه‌های محصولات را به ۷ دسته تقسیم می‌شود گه بیشترین درصد آن مربوط به خوراکی‌ها با ۴۵,۰۹ درصد در شکل ۴ مشخص شده است.

جدول ۳: مقایسه الگوریتم‌های خوشه‌بندی برای سناریوی ۱ در وضعیت ۱

الگوریتم	تعداد خوشه‌ها	سیلوئت
SOM	7	0.3308
SPSS دومرحله‌ای	4	0.285
k-means	13	0.102

از الگوریتم SOM با ۷ خوشه برای خوشه‌بندی محصولات به ۷ دسته در این سناریو استفاده می‌شود. شکل ۴ درصد هر خوشه از خوشه‌های محصول را برای سناریوی در وضعیت ۱ نشان می‌دهد. این خوشه‌ها دسته‌های محصول برای سناریوی ۱ در وضعیت ۱ است.



شکل۴: درصد خوشه های محصول برای سناریوی ۱ در موقعیت ۱

جدول ۴، مقادیر سیلوئت را برای تعداد مختلف خوشه‌ها در الگوریتم SOM برای سناریوی ۸ در وضعیت ۱ نشان می‌دهد.با بدست آوردن میزان سیلوئیت در تمام وضعیت‌های سناریوهای تعریف شده بهترین عملکرد جهت خوشه‌بندی محصولات و مشتریان کشف می گردد.

جدول ۴: مقایسه مقادیر سیلوئت برای تعداد خوشه‌های مختلف در الگوریتم SOM برای سناریوی ۸ در وضعیت ۱

تعداد خوشه ها	2	3	4	5	6	7	8	9	10
سیلوئت	0.4429	0.501	0.456	0.4432	0.3407	0.3547	0.3241	0.3183	0.3268

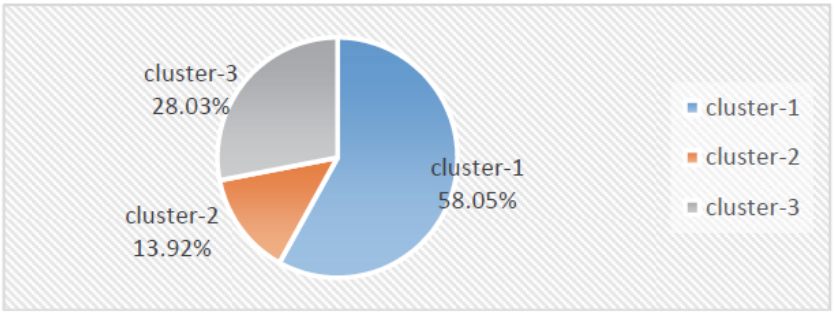
جدول ۵، مقدار سیلوئت و تعداد خوشه‌ها را برای الگوریتم‌های دسته‌بندی SOM ، SPSS دومرحله‌ای و K–میانگین برای سناریوی ۸ در وضعیت ۱ نشان می‌دهد.

جدول ۵: مقایسه الگوریتم‌های خوشه‌بندی در سناریوی ۸ در وضعیت ۱

الگوریتم	تعداد خوشه‌ها	سیلوئت
SOM	3	0.501
SPSS دومرحله‌ای	2	0.449

k-means	9	0.238

الگوریتم SOM با سه خوشه دارای بیشترین مقدار سیلوئت برای سناریوی ۸ در وضعیت ۱ است. بنابراین، از الگوریتم SOM با سه خوشه برای خوشه‌بندی محصولات در دسته‌های محصول در این سناریو استفاده می‌شود. شکل۸درصد هر خوشه از خوشه‌های محصولات را برای سناریوی ۸ در وضعیت ۱ نشان می‌دهد. این خوشه‌ها دسته‌های محصول برای سناریوی ۸ در وضعیت ۱ است. اغلب الگوهای خرید مشتریان در این وضعیت مطابق با شکل ۸به خوشه ۱ اختصاص داده می‌شوند. بنابراین، خوشه ۱ مهم‌ترین دسته محصول برای سناریوی ۸ در وضعیت ۱ است.



شکل۵: درصد خوشه های محصول برای سناریوی ۸ در موقعیت ۱

جدول ۶، طبقه‌بندی‌های محصول را در هر دسته محصول برای سناریوی ۸ در وضعیت ۱ نشان می‌دهد. در این سناریو، غذاها و ابزارهای آشپزخانه بزرگترین بخش دسته‌های محصول را نشان می‌دهند. طبقه خوراکی‌ها هم دارای بیشترین دسته در دسته محصولات خوشه ۱ هستند. بنابراین، این فروشگاه باید اهمیت این باندلینگ را در این دسته‌ها در سناریوی ۸ در وضعیت ۱ در نظر بگیرد.

جدول ۶: درصد طبقه‌بندی‌های محصول در هر دسته محصول برای سناریوی ۸ در وضعیت

دسته محصولات	پروتئین(%)	ابزاهرای آشپزخانه (%)	هله هوله(%)	سلامت و بهداشت(%)	خوراکی (%)	نوشیدنی (%)
1-خوشه	0.312	0.000	26.219	2.614	41.202	29.653
2-خوشه	0.555	5.096	8.022	2.926	58.274	25.126
3-خوشه	0.065	49.773	15.010	1.105	20.078	13.970

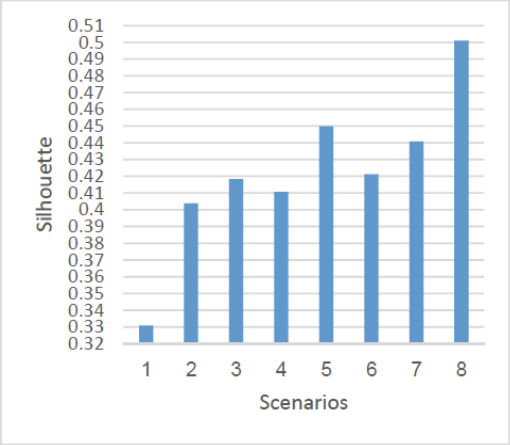
با ملاحظه نتایج بالا، اگر از ترکیب باندلینگ و متغیرهای تقسیم‌بندی مانند قیمت استفاده شود، تعداد دسته‌های محصولات در هر بخش بازار، محصولات در هر دسته محصولات، و درصد طبقه‌بندی محصولات در هر دسته محصول تغییر خواهد کرد.

جدول ۷، بیشترین مقدار سیلوئت K میانگین، SPSS دومرحله‌ای و الگوریتم‌های SOM را برای سناریوهای مورد بررسی در وضعیت ۱ نشان می‌دهد. از این رو، الگوریتم SOM برای خوشه‌بندی محصول در مدل ارائه‌شده به کار می‌رود. شکل ۶ مقادیر سیلوئت الگوریتم SOM را برای سناریوهای موردبررسی در وضعیت ۱ نشان می‌دهد.

جدول ۷::مقایسه الگوریتم‌های خوشه‌بندی برای تمامی ۸ سناریو در وضعیت ۱

سناریو	الگوریتم	تعداد خوشه‌ها	سیلوئت
1	SOM	7	0.3308
	SPSS دومرحله‌ای	4	0.285
	k-means	13	0.102
2	SOM	7	0.4039
	SPSS دومرحله‌ای	4	0.385

	k-means	12	0.175
3	SOM	4	0.4184
	SPSS دومرحله‌ای	3	0.408
	k-means	12	0.109
4	SOM	5	0.4107
	SPSS دومرحله‌ای	4	0.361
	k-means	12	0.160
5	SOM	4	0.4498
	SPSS دومرحله‌ای	3	0.439
	k-means	12	0.198
6	SOM	4	0.4213
	SPSS دومرحله‌ای	3	0.409
	k-means	12	0.161
7	SOM	4	0.4408
	SPSS دومرحله‌ای	3	0.396
	k-means	9	0.251
8	SOM	3	0.501
	SPSS دومرحله‌ای	2	0.449
	k-means	9	0.238



شکل۶: مقایسه مقادیر سیلوئت الگوریتم SOM برای هر هشت سناریو در وضعیت ۱

بیشترین مقدار سیلوئت به سناریوی ۸ تعلق دارد. بنابراین، متمایزترین دسته محصول می‌تواند با استفاده از ترکیب باندلینگ و قیمت به دست آید.

٤-٤- معرفی مجموعه داده پژوهش

داده‌های این پژوهش فروشگاه دیجی‌کالا گردآوری شدند. اطلاعات مورداستفاده در مطالعه حاضر از سه پایگاه داده از نمایه مشتریان، تراکنش‌ها و محصولات به دست آمده‌اند. صفات این پایگاه‌های داده در جدول ۸ ارائه می‌شود.

جدول ۸: صفات پایگاه‌های داده فروشگاه دیجی کالا

پایگاه داده	صفات
نمایه مشتریان	شناسه مشتری، نام مشتری، جنسیت، آدرس، شماره تماس

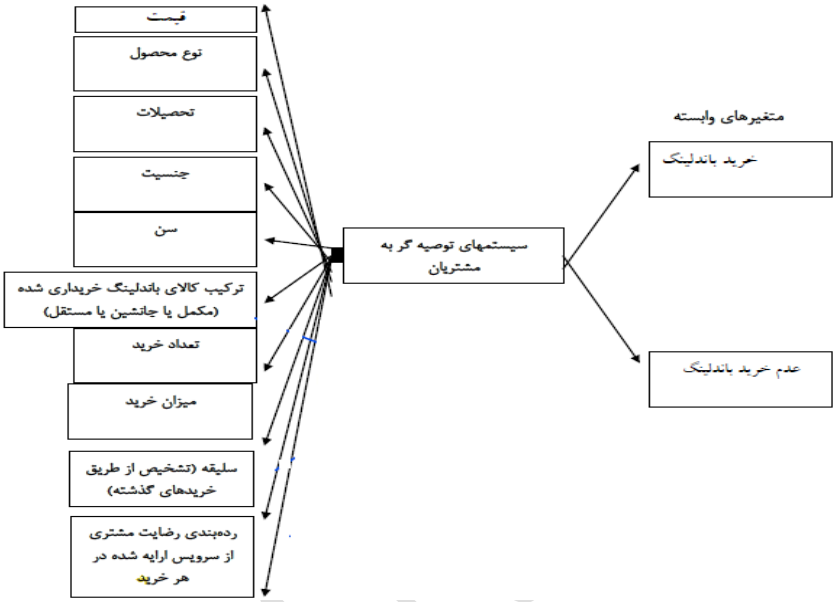
محصولات	کد محصول، نام محصول، قیمت، دسته‌بندی
تراکنش‌ها	شماره فاکتور، کد محصول، شناسه مشتری، تعداد، تاریخ تراکنش

دسته‌بندی‌های محصولات فروشگاه و چند نمونه از محصولات متعلق به هر دسته‌بندی محصول در جدول۹ ارائه می‌شود.

جدول ۹: دسته‌بندی‌های محصولات

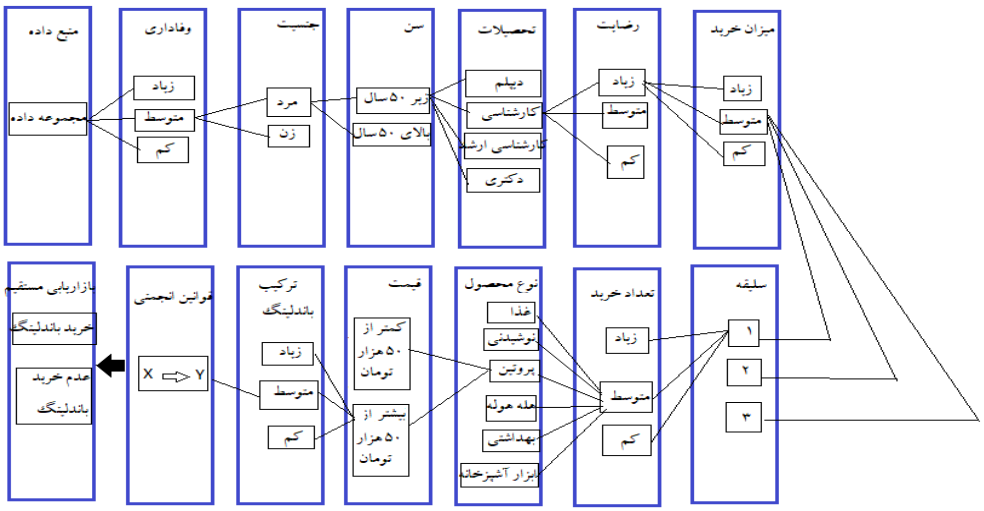
محصولات	دسته‌بندی
لبنیات، روغن، دانه‌های روغنی، جو، برنج، شکر، سس، کنسرو، کمپوت، سوپ	غذاها
آب، نوشیدنی انرژی‌زا، چای، قهوه	نوشیدنی
گوشت، مرغ، ماهی، سوسیس، تخم مرغ، برگر	پروتئین
چیپس، اسنک، بیسکوییت، کیک، شکلات، آدامس، کندی	هله هوله
نگه‌دارنده‌ها، دستمال، دستمال، خمیردندان، مسواک، شامپو، صابون، کرم دست	سلامت و بهداشت
دستکش شست و شو، اسفنج آشپزخانه، کیسه فریزر، کیسه آشغال، فویل آلومینیوم،	ابزارهای آشپزخانه

مهمترین متغییرهای موثر جهت طراحی سیستمهای پیشنهاد دهنده باندلینگ در فروشگاه دیجی کالا طبق شکل۷ است.



شکل ۷: متغییرهای موثر

نحوه اثرگذاری متغییرهای موثر جهت طراحی سیستمهای پیشنهاد دهنده باندلینگ مطابق شکل۸ است.



شکل۸: نحوه اثرگذاری متغییرهای موثر جهت طراحی سیستمهای پیشنهاد دهنده باندلینگ

۵-٤- SOM برای خوشه بندی مشتریان

از الگوریتم SOM برای شناسایی خوشه‌ها در مجموعه داده استفاده می کنیم که نشان دهنده گروه‌هایی از مشتریان است که ویژگی‌های مشابهی را نشان می‌دهند. بنابراین از الگوریتم خوشه‌بندی SOM برای خوشه‌بندی مشتریان و محصولات با توجه به متغیرهای قیمت، نوع محصول، تحصیلات،جنسیت،سن، باندلینگ، تکرار خرید، میزان خرید، سلیقه، رضایت مشتری استفاده می‌شود تا مشتریان را گروه‌بندی کنند. مشتریان بر اساس متغییرهای تاثیرگذار خوشه بندی می‌شوند. آموزش شبکه SOM شامل چندین مرحله برای تنظیم وزن نورون ها برای گرفتن الگوهای داده زیربنایی است.

۱-۵-٤- خوشه بندی مشتری

در این مرحله، از الگوریتم‌های خوشه‌بندی SOM ، SPSS دومرحله‌ای و Kمیانگین روی مقادیر متغیرهای تاثیرگذار و مقدار ضریب سیلوئت برای هر الگوریتم جهت بررسی الگوریتم‌های خوشه‌بندی مختلف محاسبه شدند. جدول ۱۰ نتایج را نشان می‌دهد.همان‌طور

که در جدول ۱۰ مشخص است روش ارائه شده با ضریب سیلوئیت ۰,۷۰۹۱ بالاترین ضریب مشتریان را به ۳ دسته خوشه‌بندی می کند.

جدول ۱۰: مقایسه ضریب سیلوئت الگوریتم SOM

تعداد خوشه‌ها	ضریب سیلوئت
2	0.6614
3	0.7091
4	0.5542
5	0.5165

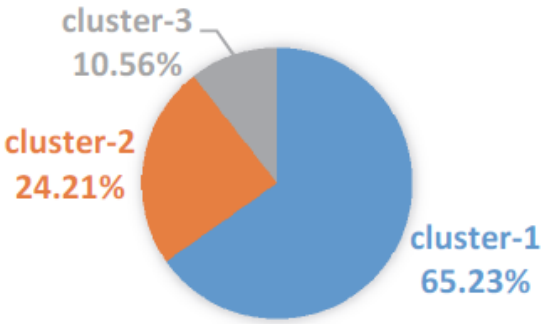
جدول ۱۱ ضریب سیلوئت و تعداد خوشه‌ها را برای الگوریتم‌های خوشه‌بندی K میانگین، SPSS دو مرحله‌ای، SOM را مقایسه می کند تا سطح وفاداری مشتریان را تعیین کند.

جدول ۱۱: مقایسه الگوریتم‌های خوشه‌بندی برای وفاداری مشتریان

الگوریتم	تعداد خوشه‌ها	ضریب سیلوئت
SOM	3	0.7091
SPSS دومرحله‌ای	4	0.524
K-mesns	12	0.404

با ملاحظه جدول بالا، می‌توان مشاهده کرد که الگوریتم SOM با سه خوشه دارای بیشترین مقدار سیلوئت است. بنابراین، از الگوریتم SOM با سه خوشه برای خوشه‌بندی مشتریان به گروه‌های سطح وفاداری‌شان استفاده می‌شود.

شکل ۹ درصد هر خوشه از خوشه‌های وفاداری مشتریان را نشان می‌دهد. این خوشه‌ها سطوح وفاداری مشتریان به فروشگاه هستند. خوشه ۱، خوشه ۲ و خوشه ۳ به ترتیب سطح وفاداری متوسط، پایین و بالای مشتریان را نشان می‌دهند. اغلب مشتریان به سطح وفاداری متوسط تعلق دارند.



شکل۹: درصد خوشه های وفاداری مشتری

٦-٤- SOM برای خوشه بندی محصول

فروشگاه مورد مطالعه ده متغییر تاثیرگذار را در پایگاه داده خود نگه می‌دارد. ۸ سناریو از باندلینگ محصولات در این پژوهش وجود دارد که در جدول ۱ مشاهده شدند.

در این مرحله، دسته‌های محصولات برای ۸ سناریوی مشخص‌شده در مرحله قبل تعیین می‌شوند. از الگوریتم خوشه‌بندی SOM برای تراکنش‌های مشتریان استفاده شده است. محصولاتی که معمولا با الگوی تراکنش یکسانی خریداری می‌شوند با اعمال الگوریتم SOM به تراکنش‌های مشتریان معمولا در یک خوشه دسته‌بندی می‌شوند. از این رو، دسته‌های محصولات در هر یک از ۸ سناریو تعیین شدند.

١-٦-٤- خوشه‌بندی محصول

در این مرحله، دسته‌های محصولات برای ۸ سناریوی مشخص‌شده در مرحله قبل تعیین می‌شوند. از الگوریتم‌های خوشه‌بندی SOM ، SPSS دومرحله‌ای، و K میانگین برای تراکنش‌های مشتریان استفاده شده است و مقدار سیلوئت برای الگوریتم محاسبه شد. محصولاتی که معمولا با الگوی تراکنش یکسانی خریداری می‌شوند با اعمال الگوریتم‌های خوشه‌بندی به تراکنش‌های مشتریان معمولا در یک خوشه دسته‌بندی می‌شوند. از این رو، دسته‌های محصولات می‌تواند در هر یک از ۸ سناریو تعیین شوند. دو وضعیت مختلف، که به صورت تصادفی انتخاب می‌شوند، برای ارائه مدل در نظر گرفته می‌شوند و نتایج انجام مدل ارائه‌شده را در این وضعیت‌ها نشان می‌دهند. جدول ۱۲ این وضعیت‌ها را نشان می‌دهد.

جدول ۱۲: دو وضعیت مختلف مورداستفاده در مدل ارائه‌شده

جنس	قیمت	ترکیب باندلینگ	وضعیت
مذکر	بیشتر از ۵۰ هزار تومان	کم	1
مونث	کمتر از ۵۰ هزار تومان	متوسط	2

۷-۴- الگوریتم Apriori برای استخراج قانون انجمنی

از الگوریتم Apriori برای تعیین قواعد انجمنی بین محصولات و کشف محصولاتی استفاده شد که معمولا به همراه هم خریداری می‌شوند.

آ. داده‌های تراکنش را در قالب مجموعه آیتم‌ها یا یک ماتریس باینری نمایش می دهیم.

ب حداقل آستانه پشتیبانی را برای شناسایی مجموعه آیتم های مکرر که از آستانه مشخص شده فراتر می روند، تنظیم می‌شود.

ج مجموعه آیتم‌های مکرر را با استفاده از الگوریتم Apriori با استفاده از مراحل تکراری تولید کاندید و شمارش پشتیبانی ایجاد می کنیم.

د قوانین ارتباط را از مجموعه آیتم های مکرر،با در نظر گرفتن معیارهایی مانند اطمینان و افزایش برای اندازه گیری قدرت و اهمیت قوانین استخراج می‌شود.

ه. قوانین مرتبط را بر اساس معیارهای خاص، مانند حداقل اطمینان، فیلتر کرده تا از توصیه‌های قانون معنادار و مرتبط اطمینان حاصل شود.

ف. از قوانین انجمن مشتق شده برای پیشنهاد باندیلنگ محصول به مشتریان بر اساس سابقه خرید و اقلام فعلی سبد خرید استفاده می‌شود.

با دنبال کردن این مراحل، الگوریتم Apriori می تواند به طور موثر مجموعه آیتم های مکرر را کشف می‌کند و قوانین ارتباطی را برای باندلینگ محصول ایجاد می‌کند. قوانین خروجی بینش‌هایی را در مورد الگوهای همزمانی اقلام ارائه می دهد و امکان شناسایی باندلینگ را برای مشتریان فراهم می کند.

۱-۷-۴- تعیین قواعد انجمنی از الگوریتم Apriori برای تعیین قواعد انجمنی بین محصولات و کشف محصولاتی استفاده شد که معمولا به همراه هم خریداری می‌شوند. این قواعد انجمنی به فروشگاه در انتخاب بهترین اقلام محصولات برای قراردهی در یک باندلینگ کمک می‌کنند. جدول ۱۳ نشان می‌دهد که مقادیر پشتیبانی و اطمینان در سناریوی ۸ در یک وضعیت بالاتر از سناریوی ۱ است. بنابراین، محصولات در سناریوی ۸ به صورت بهتری دسته‌بندی می‌شوند. مراحل قبلی نشان می‌دهند که اگر از متغیرهای تاثیرگذار استفاده شود، دسته‌بندی بهتری برای مدل به دست می‌آیند. بنابراین، سناریوی ۸ بهترین سناریو برای باندلینگ محصولات است. دسته‌های محصولاتی که در این سناریو تعیین شده‌اند، به مشتریان فروشگاه توصیه می‌شوند. جدول ۱۳ نشان می‌دهد که ۵ قاعده اول برای سناریوی ۸ در وضعیت ۱ که در آن از متغیرهای تاثیرگذار و میزان وفاداری مشتریان استفاده شد، مطابق با میزان اطمینان مرتب می‌شوند لذا سناریو ۸ بهترین وضعیت است.

جدول ۱۳: قواعد انجمنی برای سناریوی ۸ در وضعیت ۱

پشتیبانی قاعده	اطمینان	پیامد	سابقه
		کد محصول	کد محصول
28.8	91.139	22697	22698 22699
4.0	90.909	22727	22629 22726
28.8	90.0	22699	22698 22697
3.6	90.0	22699	22197 22698
3.6	90.0	22697	22197 22698

از روش SVM برای تشخیص اینکه کدام دسته محصول باید به مشتریان توصیه شود استفاده می‌شود. شماره‌های دسته محصولات به دست آمده از مرحله خوشه‌بندی محصول هم به عنوان برچسب کلاس در این مدل دسته‌بندی در نظر گرفته می‌شود.تراکنش‌های هر مشتری به مدل‌های دسته‌بندی داده می‌شوند و خروجی این مدل‌های دسته‌بندی برچسب کلاس دسته محصول خواهند بود که بیشترین شباهت را به الگوی تراکنش مشتریان دارد. ماشین بردار پشتیبان مرزی است که دسته محصولات را به بهترین وجه از یکدیگر جدا می‌کند.

۵- ارزیابی نتایج

را با ۴ تکرار به عنوان تخصیص داده آموزش و آزمایش برای مجموعه داده فروشگاه دیجی‌کالا روش KFOLD انتخاب

شد.شیوه انتخاب داده‌ها هم به صورت تصادفی است.روش اعتبارسنجی متقابل انجام شد.این

روش معمولاً در یادگیری ماشین برای ارزیابی عملکرد مدل‌های پیش‌بینی‌کننده، از جمله سیستم‌های پیشنهاد دهنده استفاده می‌شود. روش مزبور تضمین می کند که داده های موجود به طور کامل برای آموزش و آزمایش استفاده می شود. هر نمونه در مجموعه داده فرصتی برای حضور در مجموعه های آموزشی و آزمایشی در تکرارهای مختلف پیدا می کند. این به گرفتن طیف گسترده‌تری از الگوها و تغییرات موجود در داده‌ها کمک می‌کند و در نتیجه ارزیابی‌های قوی‌تر و دقیق‌تر انجام شده مقایسه شده است.برای ارزیابی روش ارائه شده را با روش های SVM، SOM شده و معیارهای ارزیابی محاسبه گردیده است. برای صحت مدل، ابتدا لازم است داده‌های موجود را به سه بخش آموزش، آزمایش و اعتبارسنجی تقسیم کردیم. داده‌های بخش آموزش را تولید می‌کنند و داده‌های بخش آزمایش با کمک تعدادی رکورد، داده‌ها را تست نمایند. داده‌های بخش اعتبارسنجی نیز صحت مدل تولید شده را بررسی کرد. شاخص‌های مختلفی برای ارزیابی صحت وجود دارد که میتوان حساسیت شـفافیت، دقت، و صحت را نام برد. میزان صحت یک روش بر روی مجموعه داده‌های آموزشی، درصد مشاهداتی از مجموعه آموزش است که بـه درستی توسـط روش مورد استفاده دسته‌بندی شده اسـت. برای محاسبه این شاخص داده‌های آزمون استفاده میشوند. همچنین میتوان نرخ خطا یا دسته بندی نادرست را بر اساس confusionشاخص صحت محاسبه کرد برای محاسبه میزان صحت مدل می‌توان از ماتریس استفاده کرد(جدول۱۴). این ماتریس ابزاری مفید برای تحلیل چگونگی عملکرد روش دسته بندی در تشخیص داده‌ها یا مشاهدات دسته‌های مختلف است.

confusionجدول۱۴. ماتریس

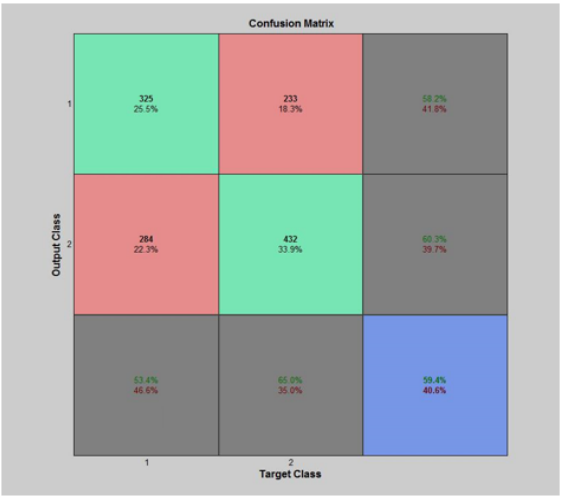
		Actual	
		Defect	Not Defect
Predicted	Defect	TP	FP
	Not Defect	FN	TN

، تعداد ماژولهای دارای خطا، که به درستی مستعد خطا پیش بینی شده‌اند، TPکه در آن
، تعداد ماژولهای فاقد خطا، که به اشتباه مستعد خطا پیش بینی شده‌اند، FPمیباشد؛
، تعداد ماژولهای فاقد خطا، که به درستی غیرمستعد خطا پیش بینی شده‌اند، TNاست؛
نیز تعداد ماژولهای دارای خطا، که به اشتباه غیرمستعد خطا پیش FNمی‌باشد و در نهایت بینی شده‌اند، می باشد.

از تکنیک اصل پارتو(قانون نسبت ۸۰ درصد آموزش به ۲۰ درصد تست استاندارد) برای

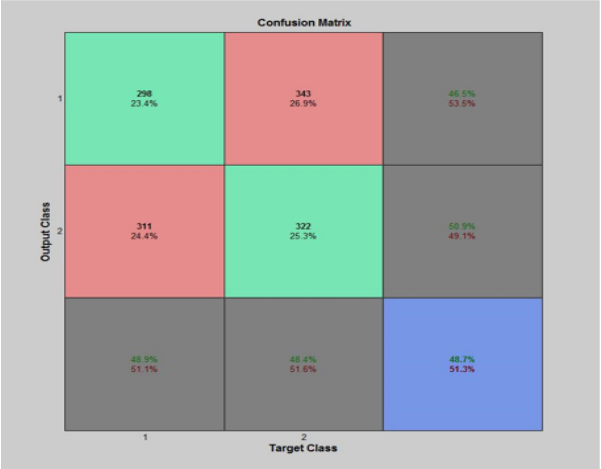
آزمایش داده های آموزش و تست انجام گرفت، برای نشان دادن عملکرد پیش بینی داده‌ها و میزان کارائی شبکه آموزش دیده از شاخص رند استفاده می شود:به منظور ارزیابی نتایج خوشه‌بندی از معیارهای متفاوتی کمک گرفته می‌شود، ممکن است از قبل برچسب خوشه ها مشخص باشد،اگر بخواهیم کارائی الگوریتم را با توجه به مقایسه برچسب های واقعی و حاصل از خوشه بندی اندازه‌گیری کنیم در این حالت شاخص ارزیابی بیرونی بهترین راهنما و معیاری برای تشخیص صحت نتایج خوشه بندی محسوب می‌شوند معمولاً به این برچسب استاندارد طلائی می گویند که از محبوبیت خاصی برخوردار است و بیشتر برای الگوریتم‌های نظارت شده مورد استفاده قرار می گیرد از طرف دیگر اگر هیچ اطلاعات اولیه از ساختار و دسته بندی مشاهدات وجود نداشته باشد(الگوریتم‌های غیر نظارت شده)فقط ملاک ارزیابی می تواند اندازه‌هائی باشند که میزان شباهت درون خوشه‌ها و یا عدم شباهت یا فاصله‌های بین خوشه‌ها را اندازه‌گیری کند، بنابراین برای انتخاب بهتر و موثرترین روش خوشه بندی از میزان شباهت درون خوشه‌ها و شباهت بین خوشه‌ها استفاده می شود،روشی که دارای میزان شباهت بین خوشه‌ای کم و شباهت درون خوشه‌ای زیاد باشد مناسب ترین روش خواهد بود.این معیار را به عنوان شاخص ارزیابی درونی می شناسیم،شاخص نیم رخ (سیلوئیت)یکی از این معیارهاست که شاخصی برای سنجش مناسب بودن تعلق هر مشاهده به خوشه اش را ارائه می‌دهد به این ترتیب معیاری برای اندازه گیری کارائی الگوریتم خوشه بندی بدست آورد.معیارهای درونی بدون در نظر گرفتن برچسب عمل می کند و فقط ویژگیهای اصلی بهینه برای خوشه ها را در نظر می گیرد. در سطر اول،ستون اول ماتریس پیش بینی شاخص،تشخیص داده‌هایی که درست شناسائی شده را نمایان می کند و در سطر اول،ستون دوم شاخص تشخیص داده‌هائی را که اشتباه شناسائی شده است را نشان می‌دهد و در سطر اول، ستون سوم ماتریس برآیند تشخیص ارائه می‌گردد.در سطر دوم، ستون اول ماتریس پیش بینی میزان حساسیت پیش بینی مشخص می‌گردد یعنی میزان حساسیت و دقت داده ها را نمایان می کند و نشان‌دهنده میزان اینکه داده به اشتباه رد شده است می‌باشد. در سطر دوم،ستون دوم ماتریس پیش بینی نشان می‌دهد که داده به درستی رد شده است را بررسی می کند. در سطر دوم ستون، سوم ماتریس برآیند دقت مشخص می گردد و نهایتاً در سطر سوم ،ستون اول ماتریس پیش بینی میزان درصد تشخیص صحیح و در سطر سوم ،ستون دوم میزان درصد دقت و حساسیت پیش‌بینی و در سطر سوم، ستون سوم ماتریس پیش‌بینی برآیند کلی پیش‌بینی استنباط و و SVM، SOM برای روش ارائه شده را با روش های confusionاستخراج می گردد. ماتریس مقالات کار شده نشان داده شده است.همانطور که در (شکل۱۰) مشخص است نتایج روش نشان می دهد که این روش توانسته است که به ۵۹/۴ درصد پیش بینی ها را از روی SOM

داده های آزمون و آموزش شبکه عصبی خود سازمانده درست تشخیص دهد. که درصد پیش بینی های صحیح را با رنگ سبز و درصد پیش بینی اشتباه را با رنگ قرمز و نتایج نهایی کلاسه بندیها در سطر و ستون نهایی ماتریس با رنگ آبی در الگوی ماتریس مشخص گردید.



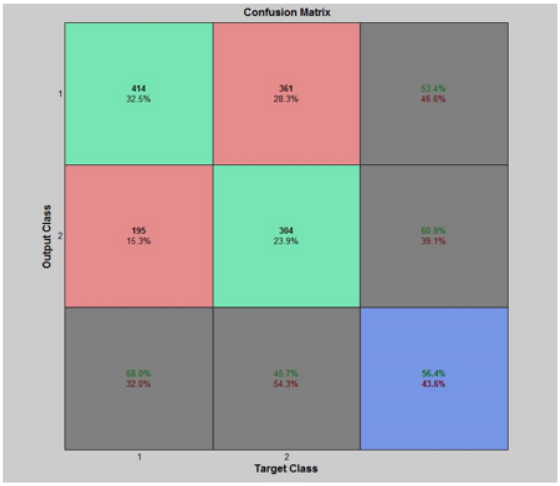
شکل۱۰: روش SOM

دهد که این روش توانسته است که به ۴۸/۷ درصد پیش بینی ها را SVMهمانطور که در (شکل۱۱) مشخص است، نتایج روش ه های آزمون درست تشخیص دهد.



شکل۱۱: روش SVM

ه در (شکل۱۲)مشخص است،نتایج روش تکنیک مورد استفاده آقای لیو و همکاران در سال ۲۰۲۲ حاکی از آن است که این روش
ت که به ۵۶/۴ درصد پیش بینی ها پاسخ صحیح دهد.



شکل۱۲: مقاله پایه(لیو و همکاران،۲۰۲۲)

ریس confusion روش ارائه شده در مقایسه با روش های دیگر نشان می دهد که روش ارائه شده(شکل۱۳) نتایج حاصل

ی را بهتر در مقایسه با سایر روش ها انجام داده است و توانسته است ۹۳/۸ درصد پاسخ صحیح دهد.



شکل۱۳: روش کار شده

۵- بحث و نتیجه گیری

نتایج به دست آمده این فرضیه را تائید می‌کنند که ترکیب روش‌های بدون نظارت (SOM)برای درک ساختار پنهان

داده‌ها و روش‌های نظارت شده (SVM) برای پیش‌بینی دقیق،یک استراتژی کارآمد در سیستم‌های توصیه گر بومی

تجارت الکترونیک است.دقت ۹۴٪ بدست آمده،نشان‌دهنده یک گام بزرگ نسبت به روش‌های سنتی است.دلیل عملکرد برتر مدل ترکیبی را می‌توان در دو نکته دانست:۱.بهینه سازی فضای ویژگی:SOM داده‌های پیچیده کاربران را به خوشه هائی با کمترین انحراف داخلی(تائید شده توسط سیلوئت ۰,۳۳۰۸)نگاشت کرد۲. افزایش قدرت تفکیک SVM:SVM بر روی این خوشه‌ها تمیز و سازماندهی شده،توانست ابر صفحه‌های تصمیم‌گیری دقیق‌تری برای پیش‌بینی ترجیحات بین خوشه‌ها ایجاد کند،در حالی که SVM بر روی داده‌های خام با نویز،عملکرد ضعیف‌تری داشت(۴۸٪).روش سیستم پیشنهاد باندلینگ محصول با استفاده از SOM برای مشتری و خوشه‌بندی محصول، همراه با SVM برای طبقه‌بندی، یک رویکرد توصیه شخصی ایجاد می‌کند. شناسایی بخش‌های مشتری و خوشه‌های محصول، طبقه‌بندی اولویت‌های مشتری و تولید پیشنهادهایی باندلینگ متناسب را امکان‌پذیر می‌سازد. این روش شخصی‌سازی را افزایش می‌دهد، رضایت مشتری را بهبود می‌بخشد و احتمال خرید باندل موفق را افزایش می‌دهد. مجموعه داده پژوهش هم فروشگاه دیجی‌کالا بود که ارزیابی نتایج بر اساس آن انجام شد و کارایی روش پیشنهادی در مقابل روش های دیگر ثابت شد. با این حال، چندین راه بالقوه برای تحقیقات آینده و بهبود در

این زمینه وجود دارد. ۱. استفاده از مدل‌های یادگیری عمیق مبتنی بر گراف(Graph Neural Networks)برای مدل‌سازی تعاملات کاربر -محصول به صورت شبکه‌ای پیچیده‌تر.۲. به کارگیری مدل‌های تولیدی (Generative Adversarial Networks – GANs) برای تولید داده‌های مصنوعی در جهت رفع مشکل کمبود داده‌های مربوط به سناریوهای نادر خرید. ۳. ادغام معیارهای زمانی پویا(Dynamic Time-Series)به جای استفاده از ویژگی‌های تجمعی در مدل‌سازی رفتار.

سپاسگزاری

از اساتید راهنما و مشاور و تمام کسانی که در راه نشر علم و دانش کمک و راهنمایی می کنند کمال تشکر و قدردانی را دارم

منابع

[1] Nourahmadi, M. (2024). Financial insights: harnessing recommender system through bibliometric analysis. Journal of knowledge Economy studies ,1(1),93-116

[2] Kang, D., Park, M. J., Lee, D. H., & Rho, J. J. (2021). Mobile services with handset bundling and governmental policies for competitive market. Telematics and Informatics, 34(1), 323-337.

[3] Choi, H. S., & Chen, C. (2019). The effects of discount pricing and bundling on the sales of game as a service: An empirical investigation. Journal of Electronic Commerce Research, 20(1), 21-34.

[4] Jana Plananska, Karoline Gamma,Product bundling for accelerating electric vehicle adoption: A mixed-method empirical analysis of Swiss customers,Renewable and Sustainable Energy Reviews,olume 154,2022,111760,ISSN 1364-0321,https://doi.org/10.1016/j.rser.2022.111760.

[5] Liang Chen, Yang Liu,(2021), Matching User with Item Set: Collaborative Bundle Recommendation with Deep Attention Network, Proceedings of the

Twenty-Eighth International Joint Conference on Artificial Intelligence (IJCAI-19)
[6] Jinze Bai, Chang Zhou,Junshuai Song, Personalized Bundle List Recommendation, WWW '19: The World Wide Web ConferenceMay 2022 Pages 60–1https://doi.org/10.1145/3308558.3313568
[7] Jena, S.K., Ghadge, A. Product bundling and advertising strategy for a duopoly supply chain: a power-balance perspective. *Ann Oper Res* 315, 1729–1753 (2022). https://doi.org/10.1007/s10479-020-03861-9
[8] Zhang, Z., Luo, X., Kwong, C. K., Tang, J & ,.Yu, Y. (2022). Return and refund policy for product and core service bundling in the dual-channel supply chain .International Transactions in Operational Research.247-223
[9] Doha, A., Ghasemaghaei, M., & Hassanein, K. (2017). Social bundling: A novel method to enhance consumers' intention to purchase online bundles. Journal of Retailing and Consumer Services, 35, 106-117.
[10] Shao, L., & Li, S. (2019). Bundling and product strategy in channel competition. International Transactions in Operational Research, 26(1), 248-269.
(2003). Market bundling strategies in the horizontal portal industry. International Journal of Electronic Commerce, 7(4), 37-54.
[11] D. Xu, C. Ruan, J. Cho, E. K¨orpeoglu, S. Kumar, and K. Achan, "Knowledge-aware complementary product representation learning," in WSDM, 2023, pp. 681–689.
[12] Hosseini, M.-P., et al., Deep Learning Architectures, in Deep Learning: Concepts and Architectures. 2019, Springer International Publishing. p. 1-24.
[13] Samira Pouyanfar, Saad Sadiq, Yilin Yan, Haiman Tian, Yudong Tao, Maria Presa Reyes,(2018), A Survey on Deep Learning: Algorithms, Techniques, and Applications, ACM Computing SurveysVolume 51Issue 5Article No.: 92pp 1–36https://doi.org/10.1145/3234150
[14] Yassine Afoudi, Mohamed Lazaar, Mohammed Al Achhab, Hybrid recommendation system combined content-based filtering and collaborative prediction using artificial neural network,Simulation Modelling Practice andTheory,Volume113,2021,102375,ISSN1569-190X, https://doi.org/10.1016/j.simpat.2021.102375.
[15] Liang Chen, Yang Liu,(2023), Matching User with Item Set: Collaborative Bundle Recommendation with Deep Attention Network, Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence (IJCAI-19)
[16] Shan Suthaharan,Machine Learning Models and Algorithms for Big Data Classification, 2016, Volume 36 ,ISBN : 978-1-4899-7640-6
[17] Amir Reza Asnafi and ET all, DESIDOC Journal of Library & Information Technology 2022, Volume 36
[18] Ebrahimi, Leila, Mirabi, Vahid Reza, Ranjbar, Mohammad Hossein and Hassanpour, Esmaeil. (2020). Customer Loyalty Model for Recommender

Systems in E-Commerce. Intelligent Business Management Studies, 8(29), 143-170. doi: 10.22054/ims.2019.10379
[19] H.J. Long, L.Y. Wang, Product service system configuration based on support vector machine considering customer perception,2018, https://doi.org/10.1080/00207543.2013.778432
[20] T. B. A. De Carvalho, D. M. L. Martins, F. B. De Lima Neto and G. Vossen, "Recommending View Bundles in Data Marketplaces," 2022 IEEE International Conference on Systems, Man, and Cybernetics (SMC), Prague, Czech Republic, 2022, pp. 3403-3408, doi: 10.1109/SMC53654.2022.9945110.
[21] Zandi Nasab, Mustafa, Jafari, Seyed Mohammad Bagher and Farmani, Mehdi. (2019). The effect of social bundling on encouraging consumers to buy online packages; A study of combined packages with mobile first. Modern Marketing Research, 9(1), 145-162. doi: 10.22108/nmrj.2019.116526.1711
[22] Pai Zheng, Zuoxu Wang, Chun-Hsien Chen, Li Pheng Khoo,A survey of smart product-service systems: Key aspects, challenges and future perspectives,Advanced Engineering Informatics,Volume 42,2019,100973,ISSN 1474-0346
[23] Lopez Pinaya, W.H., et al., Chapter 10 - Convolutional neural networks, in Machine Learning, A. Mechelli and S. Vieira, Editors. 2021, Academic Press. p. 173-191.
[24] Q. Guo et al., "A Survey on Knowledge Graph-Based Recommender Systems," in IEEE Transactions on Knowledge and Data Engineering, vol. 34, no. 8, pp. 3549-3568, 1 Aug. 2022, doi: 10.1109/TKDE.2020.3028705.
[25] Qing Zhang, Yini Zheng,Pricing strategies for bundled products considering consumers' green preference,Journal of Cleaner Production,Volume 344,2022,