

## مدیریت

# ارائه مدل پیشنهاد محصولات بر اساس وفاداری مشتری با استفاده از شبکه‌های عصبی عمیق

P

## Presenting a model for product recommendations based on customer loyalty by deep neural networks

## چکیده

امروزه به علت رشد روزافزون اینترنت و حجم عظیم اطلاعات به سامانه‌هایی نیاز داریم که بتواند مناسب‌ترین خدمات و محصولات را در کوتاه‌ترین زمان و با کیفی‌ترین پیشنهاد را به کاربر توصیه کنند. با توجه به استفاده روزافزون فناوری‌های جدید که هدف آنها کسب سود بیشتر و نهایت کسب رضایت‌مندی افراد است، امروزه روش‌های سنتی مانند دسته‌بندی و خوشه‌بندی محصولات پاسخگوی نیازهای کسب و کارها نیست و بایستی به سمت شخصی‌سازی پیشنهادها با استفاده از روش‌های نو ترکیب جدید پیش رفت (بازاریابی لوکال). در این پژوهش سه ویژگی دسته‌بندی مشتریان و پیشنهاد در قالب تکی و بسته تجمیعی و اجناس نامتجانس بر اساس رتبه‌بندی پیشنهادها مدنظر قرار گرفته است. پژوهش حاضر، باهدف ارائه مدل ترکیبی جدیدی برای پیشنهاد به صورت تجمعی محصول در تجارت الکترونیک بازار ارائه شده که تا کنون در تحقیقات انجام شده از آن استفاده نشده است. این پژوهش از نظر هدف کاربردی است و اهداف آن ارائه سامانه پیشنهاددهنده در کسب و کار الکترونیک مبتنی بر یادگیری ماشین و شبکه عصبی عمیق و بررسی الگوریتم‌ها و تکنیک‌های سامانه پیشنهاددهنده در یادگیری ماشین و شبکه عصبی عمیق و بررسی و مقایسه میزان بهینه‌سازی دقت و تشخیص پیش‌بینی صحیح در استفاده از الگوریتم‌های مورد مطالعه و بکار رفته است. داده‌های پژوهش از پایگاه داده فروشگاه دیجی کالا مورد مطالعه گردآوری شده‌اند، داده‌ها از نوع عددی و گسسته است. این پژوهش از جهت موضوعی در حوزه مدیریت روابط با مشتریان و از جهت مکانی شرکت محدود به فروشگاه دیجی کالا است. نتایج حاکی از آن است که مدل پیشنهادی مسیر جدیدی برای شخصی‌سازی ارائه گروهی محصولات است و مدیران بازاریابی می‌توانند از آن در تصمیم‌گیری‌های خود استفاده کنند. تجزیه و تحلیل داده‌ها با استفاده از کدگذاری در نرم‌افزار متلب انجام شد و خروجی‌های مدل با اثبات فرمول‌های مربوطه ارائه شده است، ارزیابی‌ها نشان می‌دهد که شرکت‌ها می‌توانند با اعمال مدل پیشنهادی، بسته‌بندی محصول با دقت بیشتری تعیین کنند؛ بنابراین، شرکت‌ها می‌توانند مشتریان جدید را جذب کنند، مشتریان فعلی را برای خرید ترغیب کنند و مشتریان ارزشمند را حفظ کنند. نتایج نشان می‌دهد که مدل پیشنهادی با دقت ۹۴٪ بهترین روش برای پیشنهاد محصولات است.

واژگان کلیدی: سامانه پیشنهاددهنده، هوشمندسازی، تجارت الکترونیک، یادگیری ماشین، شبکه عصبی عمیق.

## نوع مقاله: پژوهشی

علی نجفی<sup>۱</sup>، جواد نیک نفس<sup>۲\*</sup>، سندس بهادری<sup>۳</sup>، علیرضا اسفندیاری مقدم<sup>۴</sup>

۱- گروه مدیریت، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران

۲- گروه مدیریت، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران

۳- گروه کامپیوتر، واحد ایلام، دانشگاه آزاد اسلامی، ایلام، ایران

۴- گروه علم اطلاعات و دانش‌شناسی، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران

niknafs@iau.ac.ir

ایمیل نویسندگان و عهده‌دار مکاتبات:

تاریخ دریافت: ۱۴۰۴/۵/۹

تاریخ پذیرش: ۱۴۰۴/۱۱/۱۲

## مقدمه

در گذشته، نیاز به سامانه‌های پیشنهاددهنده به دو دلیل کمتر احساس می‌شد: نخست، جمعیت کمتر بود و افراد معمولاً در محیط‌های مختلف یکدیگر را می‌شناختند؛ در نتیجه، صاحبان کسب‌وکار باتکیه بر شناخت قبلی از مشتریان و ذائقه آن‌ها، اجناس و خدمات موردنیازشان را تأمین می‌کردند و در اختیار افراد قرار می‌داند و روش‌های سنتی کسب‌وکار پاسخگوی نیازهای افراد بود دوم اینکه تنوع محصولات کم بود؛ صاحبان کسب‌وکار نهایتاً دو یا سه برند از هر کالا را در بازار عرضه می‌کردند و مشتریان ناگزیر بودند تنها از همان محصولات انتخاب کنند؛ در واقع، بازار در آن زمان حالتی انحصاری یا نیمه انحصاری داشت؛ اما با افزایش جمعیت و صنعتی‌شدن تولید کالا و خدمات و انفجار تنوع محصولات و افزایش برندهای مختلف اوضاع رقابت در بازار به شدت پیچیده شد؛ لذا به شدت نیاز به سامانه‌های پیشنهاددهنده احساس شد و بازار آزاد به وجود آمد؛ بنابراین در اواسط دهه نود میلادی سامانه‌های پیشنهاددهنده به عنوان شاخه‌ای مستقل در بازاریابی مورد استقبال جامعه علمی و تجاری قرار گرفت. در اواسط دهه نود میلادی مطالعه بر روی سامانه‌های توصیه‌گر به عنوان شاخه مستقل در تحقیقات مطرح شد. آقای گراندی یک کتابدار رایانه‌ای در سال ۱۹۹۶ گام اولیه به سمت سامانه‌های پیشنهاددهنده خودکار برداشت. در اواخر دهه نود میلادی سال ۲۰۰۰-۱۹۹۹ پیاده‌سازی تجاری فناوری توصیه‌گر شروع به ظهور کردند شاید معروف‌ترین آنها شرکت آمازون باشد. این سامانه‌های پیشنهاددهنده را می‌توان به عنوان برنامه‌هایی تعریف کرد که تلاش می‌کنند تا مناسب‌ترین آیتم‌ها (محصولات یا سرویس‌ها) را به کاربران خاصی (افراد) توصیه کنند، بدین شکل که علایق و گرایش کاربر به یک آیتم را بر مبنای اطلاعات مربوط به آیتم‌ها،

کاربران و تعامل بین آیتم‌ها و کاربران پیش‌بینی می‌کنند. توصیه گروهی، روشی مؤثر برای دستیابی به اهداف تجاری در بسیاری از صنایع محسوب می‌شود. (Bobadilla et al., 2013). با پیشرفت سریع علم و فناوری، روزانه مقادیر زیادی داده‌های ساختاریافته، نیمه‌ساختاریافته و بدون ساختار از منابع مختلف تولید می‌شود، 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 موردعلاقه این کاربران ارائه دهد (Nourahmadi, 2024). فروش تجمعی ابزاری تجاری است که در آن دو یا چند محصول در یک بسته با تخفیف به فروش می‌رسد (Kang et al, 2017). هنگامی که در فروش به صورت بسته محصولات با یکدیگر ارتباط دارند، اثربخشی آن بیشتر می‌شود به دلیل اثربخشی باندلینگ، از آن در حوزه‌های گوناگون استفاده شده است (Choi & Chen., 2019). فروش تجمعی محصولات، کالاها و خدمات موضوع پژوهشی مهمی در بازاریابی محسوب می‌شود (Plananska, 2022). فروش در قالب بسته کالاهای مختلف برای مدت چندین سال کاربرد گسترده‌ای داشته است که هدف آن منفعت فروشنده و مشتری بوده است (Chang, 2021). اخیراً دامنه فروش تجمعی صرفاً به باندلینگ محصولات محدود شده است و باندلینگ محصولات با خدمات مختلف از قبیل خدمات هسته‌ای به تدریج متداول شده است (Zhang et al., 2022). فروش تجمعی 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 بسته‌های باندلینگ به منظور پشتیبانی تصمیمات راهبرد هدایت شده به سمت افزایش قدرت بازار سازمان ارائه شوند. بسته‌های باندلینگ همچنین ممکن است برای اهداف افزایش

راندمان و کارایی ارائه شوند که شامل بهبود در کیفیت، صرفه‌جویی در هزینه و کارایی قیمت‌گذاری می‌شوند. اهمیت فزاینده فروش تجمعی محصولات و خدمات به این حقیقت نسبت داده می‌شود که شرکت‌ها در حال ایجاد راهبردهای خود بر اساس این عملکردها هستند (Jena, 2022). اهداف اصلی راهبرد باندلینگ گسترش قدرت انحصاری شرکت در یک بازار به بازار دیگر برای پذیرش تفاوت قیمت‌ها، پیشگیری از ورود یک رقیب به بازار و همچنین ایجاد اتحاد راهبردی است. محصولات مختلفی وجود دارند که مکمل یکدیگر هستند و می‌توان آنها را در یک بسته قرار داد. در عمل، مثال‌هایی مختلفی وجود دارد امروزه استفاده از فروش تجمعی کالا و خدمات در صنایع خدماتی مختلفی از جمله گردشگری، حمل‌ونقل هوایی و مخابرات رواج یافته است (Zhang, 2022). از سوی دیگر در سال‌های اخیر پیشرفتهای بسیار مهمی در حوزه‌های مختلف فناوری به‌ویژه در زمینه هوش مصنوعی و محول شدن تحلیلها و تصمیمگیریهای مهم در حوزه‌های مختلف به این ابزار بسیار قدرتمند، رخ داده است. یکی از این پیشرفتهای مهم و اساسی در زمینه هوش مصنوعی و بینایی ماشین، یادگیری عمیق<sup>۱</sup> است. رشد رقابت جهانی و افزایش تعداد شرکت‌هایی که به تولید کالاها و خدمات می‌پردازند باعث شده است که بازیابان بیش‌ازپیش به مطالعه رفتار مصرف‌کنندگان بپردازند تا علاوه بر شناسایی خواسته آنها، کالاها و خدمات خود را مطابق با آن نیازها تولید کنند و باعث ایجاد وفاداری هر چه بیشتر در مصرف‌کنندگان شود. پیشنهاد به‌صورت بسته به طور گسترده در زمینه کالاها، مصرفی و خدمات به کار می‌رود، زیرا از طریق راهبردهای مدیریت درآمد به درآمدهای بالاتر منجر می‌شود (Yan et al., 2014) و همچنین باعث فروش سریع‌تر و وسیع‌تر، کاربردپذیری خدمات و در نهایت سودآوری می‌شوند. اهمیت این موضوع زمانی بیشتر دیده شد که آقای

مکنزی در آمار منتشره خود عنوان کرد که ۳۵ درصد خرید شرکت آمازون در نتیجه استفاده از پیشنهاددهنده سامانه بوده است. در سال ۲۰۱۶ آمار ارائه شده توسط علی زیلا (Alizila) در شرکت علی‌بابا اعلام کرد که ۲۰ درصد نرخ رشد آن شرکت استفاده از صفحات لندینگ شخصی‌سازی شده توسط سامانه‌های پیشنهاددهنده بوده است؛ لذا محقق قصد دارد در این تحقیق به این سؤال اساسی پاسخ دهد که عملکرد و دقت مدل ترکیبی جدید برای پیشنهاد محصولات در تجارت الکترونیک با استفاده از یادگیری عمیق و شبکه‌های عصبی در فروشگاه دیجی‌کالا چگونه است؟

### مبانی نظری

(Pouyanfar et al., 2018) در سالهای اخیر یکی از جدیدترین متدهایی که به‌منظور انجام فرایند آموزش در یادگیری عمیق بر اساس مفاهیم علم روان‌شناسی ابداع شده است، شبکه عصبی خودسازمان‌ده (SOM) است که بی شک یکی از بهترین و قدرتمندترین شبکه‌های موجود در تحلیل غیرخطی فضاها پیچیده است.

(Afoudi et al., 2021) سامانه پیشنهاددهنده مبتنی بر SOM را معرفی کردند و نتایج آنها کارایی آن را در سامانه‌های پیشنهاددهنده نشان داد و ویژگی‌های داده‌ها را بهتر تشخیص می‌دهد و چون از زیرمجموعه‌ای از نقاط یادگیری استفاده می‌کنند، در نتیجه در مصرف حافظه صرفه‌جویی می‌کنند، همچنین یکی دیگر از روش‌ها، استفاده از ماشین بردار پشتیبان است که توسط (Baskota et al., 2018) در ارتباط با سامانه پیشنهاددهنده، معرفی شد SVM بود، ماشین بردار پشتیبان الگوریتم‌های قدرتمند منعطف یادگیری ماشین تحت نظارت هستند که برای طبقه‌بندی مورد استفاده قرار این الگوریتم برای انواع داده با ابعاد بالا به‌خوبی کار می‌کند. با انتخاب یک تابع کرنل خوب، میزان خطا به‌خوبی کنترل می‌شود، همچنین مرز

1. Deep Learning

جداسازی برای دسته‌بندی کاملاً واضح است. (Suthaharan, ۲۰۱۶)؛ بنابراین، مدل ترکیبی جدیدی را ارائه کردیم که بر اساس متغیرهای مؤثر (قیمت، نوع محصول، تحصیلات، جنسیت، سن، ترکیب کالای باندلینگ، تعداد خرید، میزان خرید، سلیقه و رده‌بندی رضایت برای مشتری) گروه‌بندی شدند. این متغیرها با استفاده از روش دلفی و استفاده از کارشناسان حوزه بازاریابی و روان‌شناسی مصرف استخراج گردید. سپس جدیدترین متدهای بازاریابی بر اساس فاکتورهای اصلی بازار مانند قدرت خرید آن‌ها، تازگی خرید، تنوع خرید مشتریان بر اساس سطح وفاداری آنها با الگوریتم نزدیک‌ترین همسایه (KNN) و از الگوریتم Aprio-ri برای تعیین قوانین ارتباط برای هر بسته محصول به صورت شخصی‌سازی شده به افراد و استخراج الگوی کشف شده جهت پیشنهاد منحصربه‌فرد به هر فرد استفاده می‌شود. مدل الگوریتم ماشین بردار پشتیبان طبقه‌بندی به منظور توصیه گروهی و تجمعی یا عدم باندلینگ به هر مشتری اعمال می‌شود.

### پیشینه پژوهش

(Asnafi et al., 2023) به بررسی و ارائه مدلی برای سامانه‌های پیشنهاددهنده 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 مازول پالایش جستجو صورت گرفته است. در مقوله تعیین میزان آشنایی با سامانه پیشنهاددهنده، سه مقوله آشنایی کامل (۱۷٪)، آشنایی مختصر (۵۰٪) و بدون آشنایی (۳۳٪) شناسایی شد و از لحاظ امکانات موردنیاز سامانه‌های پیشنهاددهنده، زیرمقوله‌های امکانات فنی، سیستمی، و تخصصی (شخصی‌سازی) شناسایی شده و مفاهیم آن تبیین شده است همچنین چالش‌های اضافه‌کردن سامانه پیشنهاددهنده مشخص شده و مقوله مزایای اضافه‌کردن سامانه

پیشنهاددهنده تبیین شده است.

(Ghaffarian et al., 2023) به مطالعه، تحلیل و بررسی کاربرد فن داده‌کاوی در سامانه توصیه‌گر (پیشنهاددهنده) کتابخانه‌های دیجیتال و مراکز اطلاعاتی پرداختند نتایج نشان داد، فنون مختلف داده‌کاوی با کاربرد قوانین انجمنی و اجرای الگوریتم اطلاع‌داری کارایی و دقت بالا بوده و در تجزیه و تحلیل داده‌های کتابخانه‌های دیجیتال و مراکز رسانی برای ایجاد سامانه‌های توصیه‌گر به منظور پیش‌بینی درخواست‌های کاربران و پیشنهاددهی مؤثر، مناسب است.

(Ebrahimi et al., 2020) اقدام به ارائه مدل وفاداری مشتری برای سامانه‌های پیشنهاددهنده تجارت الکترونیک نمودند. در پژوهش آنان نتایج مدل‌سازی معادلات ساختاری نشان داد که عامل اعتماد دارای رابطه مهمی با رضایت مشتری در سامانه‌های پیشنهاددهنده تجارت الکترونیک است. علاوه بر آن، نتایج حاکی از آن است که B2C رضایت از محصولات پیشنهادی، می‌تواند موجب ارتقا وفاداری مشتری در سامانه‌های پیشنهاددهنده شود. (Carvalho et al., 2022) بیان می‌کنند که برای اینکه

شرکت‌ها مزیت رقابتی داشته باشند، باید اطلاعات مربوطه را از داده‌ها استخراج کنند و برای آن، باید داده‌های خود را با سایر منابع داده تکمیل کنند. بازارهای داده پلتفرم‌هایی هستند که ارائه‌دهندگان داده و مصرف‌کنندگان داده بر روی آنها تجارت می‌کنند. با این حال، هر تعامل داده‌ای متحمل هزینه‌های پولی می‌شود؛ بنابراین، مصرف‌کنندگان داده علاقه‌مند به خرید مجموعه‌ای از دیدگاه‌های جالب هستند که متناسب با بودجه (هدف) آنها باشد. نماها اجازه می‌دهند داده‌ها به صورت بصری نمایش داده شوند و کاربران را قادر می‌سازد الگوها و بینش‌ها را درک کنند. علاوه بر امکان کنترل هزینه آسان‌تر، خرید مجموعه‌ای از نماها در کنار هم شانس یافتن آنچه را که مصرف‌کنندگان می‌خواهند نسبت به خرید مشاهده به نمایش آنها افزایش می‌دهد. انتخاب نماهای

فروش روزانه برنامه‌ها است. به طور خاص، نرخ تنزیل و میزان تخفیف قیمت روابط مثبتی با افزایش فروش دارد. (Alzubaidi et al. , 2021) به بررسی نقش سامانه‌های پیشنهاددهنده بر فروش صنعت پوشاک پرداختند. بر اساس نتایج آنان سامانه‌های پیشنهاددهنده بر فروش در صنعت پوشاک به طور متوسط ۱۷ درصد تأثیر دارد که این تأثیر در خرید زنان بیش از مردان مؤثر است. (Plananska et al. , 2022) به بررسی نقش سامانه‌های پیشنهاددهنده در فروش فروشگاه‌ها پرداختند و نتایج تحقیق آنان نشان که سامانه‌های پیشنهاددهنده هم فروش به صورت مجزا و هم فروش به صورت بسته‌ای را افزایش داده است.

### روش‌شناسی پژوهش

این پژوهش از نظر هدف کاربردی است و جامعه آماری از پایگاه داده فروشگاه دیجی کالا مورد مطالعه گردآوری شده‌اند، داده‌ها از نوع عددی و گسسته است، ابتدا محقق به توصیف داده‌ها پرداخته سپس از کلیدهای اصلی سه پایگاه‌های داده‌ها برای ترکیب آن‌ها و دستیابی به یک مجموعه داده یکپارچه و انتخاب ۱۰ متغیر موردنظر با بهره‌گیری از تکنیک دلفی جهت استخراج نظرات کارشناسان حوزه بازاریابی و روان‌شناسی مصرف و تصمیم‌گیری و استخراج متغیرهای کلیدی در فروشگاه‌های آنلاین به صورت هدفمند برای ۱۰۰۰ رکورد استفاده شد. پاک‌سازی داده‌ها با حذف مقادیر نویزی و داده‌های از دست رفته انجام شد. سپس، در مرحله ساخت ویژگی، تعداد تراکنش‌ها و ارزش پولی آن‌ها برای هر مشتری محاسبه شد تا در خوشه‌بندی مشتریان به سطوح مختلف وفاداری به کار گرفته شود. علاوه بر این، تعداد محصولات در هر دسته‌بندی برای هر تراکنش مشتری تعیین شد تا از آن برای خوشه‌بندی محصول استفاده و تجزیه و تحلیل شود، و در نهایت نیز تفسیر و نتیجه‌گیری از تحلیل‌ها صورت می‌گیرد.

مناسب برای ایجاد یک باندلینگ جذاب، به دلیل تعداد زیاد ترکیب‌های نما که به طور بالقوه نیازهای مصرف‌کننده داده را برآورده می‌کنند امری بی‌اهمیت نیست. در این مقاله، آنها 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 ژن‌شناختی برای طراحی باندلینگ تقریباً بهینه پیشنهاد می‌کنند. نتایج تجربی نشان می‌دهد که رویکرد آنها می‌تواند به طور مؤثر به مصرف‌کنندگان داده کمک کند تا باندلینگ نمایش مربوطه را تحت محدودیت‌های بودجه پیدا کنند.

(Zandi Nasab et al. , 2020) اقدام به بررسی تأثیر شیوه باندلینگ اجتماعی درباره تمایل مشتریان برای خرید بسته‌های برخط شرکت همراه اول نمودند. ابزار اصلی گردآوری داده‌ها، پرسش‌نامه بوده است. تجزیه و تحلیل داده‌ها با تکنیک مدل‌سازی معادلات ساختاری و با نرم‌افزار 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 تأثیر مثبت دارد. عدم اطمینان ادراک شده بر ارزش ادراک شده تأثیر منفی ندارد و ارزش ادراک شده بر قصد خرید تأثیر مثبت و عدم اطمینان ادراک شده بر قصد خرید، تأثیر منفی دارد.

(Zheng et al. , 2019) در پژوهشی با عنوان “تأثیر کاهش قیمت (تخفیف) و فروش تجمیعی بر فروش بازی به عنوان یک خدمت” به بررسی تأثیر تخفیف و فروش تجمیعی بر فروش برنامه‌های کاربردی پرداختند. به این منظور پیمایشی با مشارکت تعدادی از برنامه‌های کاربردی صنعت فناوری اطلاعات انجام شد و یافته‌های پژوهش آن‌ها نشان داد که هر دو کاهش قیمت (تخفیف) و بسته‌بندی دارای تأثیر مثبتی بر

استفاده شد که با ساختار بازگشتی خود فیدبک‌های داخلی ایجاد کند و با تمام وزن‌های ورودی همگرا شود، سپس بر اساس چارچوب اولیه سامانه خوشه‌بندی و پیشنهاد گروهی محصولات طراحی می‌گردد. این تحقیق بر مبنای اطلاعات کاربران و امتیاز به محصولات فروشگاه دیجی کالا (نظرسنجی کاربران) و تنوع محصولات فروشگاه دیجی کالا انجام گرفت. برای اطمینان از حفظ پایایی پژوهش از دو راهبرد استفاده شد. اول اینکه استخراج داده‌های پژوهش با استانداردهای پژوهش کمی و رعایت اصول علمی و اخلاقی صورت گرفت و برای نشان دادن متغیرهای مؤثر در فروش بیشتر محصولات در حین پیاده‌سازی و کدگذاری عددی مرور مجدد انجام می‌گرفت تا عامل اساسی و تأثیرگذاری از قلم نیفتد سپس با کدگذاری و انتخاب متغیرهای تأثیرگذار و هدفمند تحلیل و تفسیر انجام گرفت. خوشه‌بندی و دسته‌بندی مشتریان توسط الگوریتم‌های مختلف در نرم‌افزار متلب اجرا و پیاده‌سازی گردید و خروجی مدل نهایی گزارش گردید.

### روش ارائه شده

در این قسمت به بیان روش ارائه شده طبق شکل ۱ می‌پردازیم. هدف اصلی این فصل پیشنهاد یک مدل جدید برای فروش تکی و تجمعی محصول در فروشگاه دیجیکالا با استفاده از متغیرهای تأثیرگذار استخراج شده و تحلیل وفاداری مشتری است. مدل RFM برای محاسبه وفاداری مشتری استفاده می‌شود. پس از آن، مشتریان بر اساس سطح وفاداری آنها گروه‌بندی می‌شوند. سپس هر گروه بر اساس متغیرهای تأثیرگذار به بخش‌های مختلف تقسیم می‌شود. باندلینگ محصول از طریق الگوریتم‌های خوشه‌بندی تعیین می‌شوند. الگوریتم Apriori همچنین برای تعیین قوانین ارتباط برای هر باندلینگ محصول استفاده می‌شود. مدل SVM به منظور تعیین اینکه کدام باندلینگ محصول باید به هر مشتری توصیه

در ابتدا به بررسی ادبیات موجود در حوزه موضوع پرداخته، سپس از طریق منابع کتابخانه‌ای عوامل مؤثر در سامانه پیشنهاددهنده 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 می‌گردد. باتوجه به اینکه مدل بکار رفته یک مدل چندوجهی است؛ یعنی تلفیق استخراج الگوی شخصی و بازاریابی و استخراج ویژگی‌های روان‌شناسی افراد توسط متغیرهای تأثیرگذار مدنظر است؛ لذا برای یافتن بهترین روش از میان روش‌های بکار گرفته شده شبکه عصبی که بتواند معیارهای مختلفی را پاسخگو باشد به دنبال شبکه‌های عصبی چندلایه MLP رفته تا بتواند در ورودی‌های نورون ساختار را تا کشف بهترین پاسخ تحویل نورون بعدی بدهد رفته، لذا مقایسه‌هایی بین انواع شبکه عصبی صورت گرفت و مشخص شد که مدل شبکه عصبی شعاعی (RBF) الگوهای رفتاری استخراج شده از آن پردازنده را در موقعیت‌های خاصی متمرکز می‌کند که از طریق توابع رادیال مدل‌سازی می‌شوند و پاسخگوی موضوع مورد مطالعه ما نبود در گام بعد به سراغ انواع الگوریتم‌های شبکه عصبی گراف چندمنظوره (GNN) که ایده بیشتر معماری آن پیچیدگی (کانولوشن) گراف است رفته که در آن وزن ورودی‌های مورد مطالعه را به صورت نامنظم در نظر می‌گیرد و در صورت افزودن یک گره به گراف لازم است که مجدد کل شبکه آموزش ببیند، و سرباری شبکه زیاد می‌شد؛ لذا از آنجائی که ما به دنبال پیدا کردن شباهت‌ها در میان انبوهی از دیتاها هستیم و از سوی دیگر به دنبال تلفیق روش‌های بازاریابی RFM (تازگی خرید، تعداد خرید، میزان خرید) با شخصی‌سازی ویژگی‌های منحصر به فرد افراد مانند جنسیت سن تحصیلات و ویژگی‌های روان‌شناسی افراد هستیم تا بتوانیم بر طبق ذائقه وی توصیه انجام گیرد از شبکه عصبی خودسازمان‌دهی

شود، اعمال می‌شود.

از نمایه مشتریان، تراکنش‌ها و محصولات به دست آمده‌اند. صفات این پایگاه‌های داده در جدول ۱ ارائه می‌شود.

جدول ۱: صفات پایگاه‌های داده فروشگاه دیجی کالا

| صفات          | پایگاه داده                                              |
|---------------|----------------------------------------------------------|
| نمایه مشتریان | شناسه مشتری، نام مشتری، جنسیت، نشانی، 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 جدول ۲ ارائه می‌شود.

جدول ۲: 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، تخم‌مرغ، برگر                                 | پروتئین           |
| چیپس، اسنک، بیسکویت، کیک، شکلات، آدامس، کندی                          | هله‌هوله          |
| نگهدارنده‌ها، دستمال، دستمال، خمیردندان، مسواک، شامپو، صابون، کرم دست | سلامت و بهداشت    |
| دستکش شست‌وشو، اسفنج آشپزخانه، کیسه‌فریزر، کیسه آشغال، فویل آلومینیوم | ابزارهای آشپزخانه |

## ۴-۲ توصیف داده

در این پژوهش، فروشگاه منتخب فروشگاه دیجی کالا در حوزه خوراکی، نوشیدنی، پروتئین، محصولات بهداشتی و ابزارهای آشپزخانه است. هدف از این فروشگاه شخصی‌سازی محصولات خود برای مشتریان 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.

## ۴-۳ یکپارچه‌سازی و پاک‌سازی داده‌ها

از کلیدهای اصلی سه پایگاه‌های داده‌ها برای ترکیب آن‌ها و دستیابی به یک مجموعه‌داده یکپارچه طبق ۱۰ متغیر موردنظر



مراحل روش ارائه شده

## ۴-۱ جمع‌آوری داده‌ها

در این مرحله باید داده‌های تراکنش تاریخی را جمع‌آوری کنیم که شامل اطلاعاتی درباره خریدهای مشتری است، مانند محصولاتی که آنها با هم یا متوالی خریده‌اند. در تحقیق حاضر، فروشگاه انتخاب شده، فروشگاه دیجی کالا است که غذا، نوشیدنی، پروتئین، فست‌فود، 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 بازاریابی که به آن تعلق دارند، توصیه کند.

## ۴-۱-۱ معرفی مجموعه‌داده پژوهش

داده‌های این پژوهش فروشگاه دیجی کالا گردآوری شدند. اطلاعات مورد استفاده در مطالعه حاضر از سه پایگاه داده

برای تقسیم‌بندی مشتریان بر اساس تحلیل RFM، باید هر یک از عامل‌های 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 شکل ۳، یعنی در بازه زمانی ۳۰ الی ۶۰ روز گذشته، ۰ الی ۵ بار خرید به ارزش ۱۰ الی ۱۵ میلیون داشته است.

برای ۱۰۰۰ رکورد استفاده شد. فرایند 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.



شکل ۲: تقسیم‌بندی و امتیازدهی به مشتریان با متد RFM

الگوریتم خوشه‌بندی SOM برای خوشه‌بندی مشتریان و محصولات با توجه به متغیرهای قیمت، نوع محصول، تحصیلات، جنسیت، سن، باندینگ، تکرار خرید، میزان خرید، سلیقه، رضایت مشتری استفاده می‌شود تا مشتریان را گروه‌بندی کنند. مشتریان بر اساس متغیرهای تأثیرگذار خوشه‌بندی می‌شوند. آموزش شبکه SOM شامل چندین مرحله برای تنظیم وزن نورون‌ها برای گرفتن الگوهای داده زیربنایی است.


مهم‌ترین متغیرهای مؤثر جهت طراحی سامانه‌های پیشنهاددهنده در فروشگاه دیجی کالا طبق شکل ۳ است

از فرمول امتیاز Z برای نرمال‌سازی داده‌ها استفاده می‌شود. فرمول امتیاز z در معادله ۴-۱ 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.

$$V' = \frac{v - A'}{\sigma_A} \quad (4-1)$$


#### ۴-۴ SOM برای خوشه‌بندی مشتریان

از الگوریتم SOM برای شناسایی خوشه‌ها در مجموعه داده استفاده می‌کنیم که نشان‌دهنده گروه‌هایی از مشتریان است که ویژگی‌های مشابهی را نشان می‌دهند؛ بنابراین از



شکل ۳: متغیرهای مؤثر

نحوه اثرگذاری متغیرهای مؤثر جهت طراحی سامانه‌های پیشنهاددهنده باندینگ مطابق شکل ۴ است.



شکل ۴: نحوه اثرگذاری متغیرهای مؤثر جهت طراحی سامانه‌های پیشنهاددهنده باندینگ

جدول ۳: مقایسه ضریب سیلوئت الگوریتم SOM

| تعداد خوشه‌ها | ضریب سیلوئت |
|---------------|-------------|
| ۲             | ۰.۶۶۱۴      |
| ۳             | ۰.۷۰۹۱      |
| ۴             | ۰.۵۵۴۲      |
| ۵             | ۰.۵۱۶۵      |

#### ۴-۴-۱ خوشه‌بندی مشتری

در این مرحله، از الگوریتم‌های خوشه‌بندی SPSS ، SOM ، دومرحله‌ای و K میانگین روی مقادیر متغیرهای تأثیرگذار و مقدار ضریب سیلوئت برای هر الگوریتم جهت بررسی الگوریتم‌های خوشه‌بندی مختلف محاسبه می‌شود. جدول ۳ نتایج را نشان می‌دهد.

جدول ۵: سناریوهای مختلف بر اساس متغیرهای تأثیرگذار

|                                                                                                                     |
|---------------------------------------------------------------------------------------------------------------------|
| سناریو ۱: بدون استفاده از متغیرهای تأثیرگذار                                                                        |
| سناریو ۲: جنس، سن، تحصیلات                                                                                          |
| سناریو ۳: نوع محصول، قیمت                                                                                           |
| سناریو ۴: نوع محصول، رضایت مشتری، سلیقه                                                                             |
| سناریو ۵: نوع محصول، باندلینگ، میزان خرید، تعداد خرید                                                               |
| سناریو ۶: جنس، تحصیلات، باندلینگ، رضایت مشتری                                                                       |
| سناریو ۷: سن، باندلینگ، رضایت مشتری                                                                                 |
| سناریو ۸: جنس، سن، تحصیلات، سلیقه، رضایت مشتری، قیمت، نوع محصول، ترکیب باندلینگ، تعداد خرید، میزان خرید، تعداد خرید |

#### ۴-۳ خوشه‌بندی محصول

در این مرحله، دسته‌های محصولات برای ۸ سناریوی مشخص‌شده در مرحله قبل تعیین می‌شوند. از الگوریتم‌های خوشه‌بندی SPSS، SOM، دومرحله‌ای، و K میانگین برای تراکنش‌های مشتریان استفاده شده است و مقدار سیلوئت برای الگوریتم محاسبه می‌شود. محصولاتی که معمولاً با الگوی تراکنش یکسانی خریداری می‌شوند با اعمال الگوریتم‌های خوشه‌بندی به تراکنش‌های مشتریان معمولاً در یک خوشه دسته‌بندی می‌شوند. از این‌رو، دسته‌های محصولات می‌تواند در هر یک از ۸ سناریو تعیین شوند. دو وضعیت مختلف که به‌صورت تصادفی انتخاب می‌شوند، برای ارائه مدل در نظر گرفته می‌شوند و نتایج انجام مدل ارائه‌شده را در این وضعیت‌ها نشان می‌دهند. جدول ۶ این وضعیت‌ها را نشان می‌دهد.

جدول ۶: دو وضعیت مختلف مورد استفاده در مدل ارائه‌شده

| جنس  | قیمت                   | ترکیب باندلینگ | وضعیت |
|------|------------------------|----------------|-------|
| مذکر | بیشتر از ۵۰ هزار تومان | کم             | ۱     |
| مؤنث | کمتر از ۵۰ هزار تومان  | متوسط          | ۲     |

در ادامه، مراحل سناریوی ۱ و سناریوی ۸ برای مقایسه دسته‌های محصولات ارائه می‌شوند. از وضعیت ۱ برای بررسی


جدول ۴ ضریب سیلوئت و تعداد خوشه‌ها را برای الگوریتم‌های خوشه‌بندی K میانگین، SPSS دومرحله‌ای، SOM را مقایسه می‌کند تا سطح وفاداری مشتریان را تعیین کند.

جدول ۴: مقایسه الگوریتم‌های خوشه‌بندی برای وفاداری مشتریان

| الگوریتم        | تعداد خوشه‌ها | ضریب سیلوئت |
|-----------------|---------------|-------------|
| SOM             | ۳             | ۰.۷۰۹۱      |
| SPSS دومرحله‌ای | ۴             | ۰.۵۲۴       |
| mesns-K         | ۱۲            | ۰.۴۰۴       |

باملاحظه 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 ۵ 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.



شکل ۵: درصد خوشه‌های وفاداری مشتری


#### ۴-۴-۲ بررسی سناریوهای مختلف

۸ سناریو از باندلینگ محصولات در این پژوهش وجود دارد که در جدول ۵ مشاهده می‌شوند. استخراج متغیرهای تأثیرگذار توسط کارشناسان در جدول ۵ نشان می‌دهد که از آن متغیرهای تأثیرگذار در این سناریوها استفاده شده است.

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

| الگوریتم         | تعداد خوشه‌ها | سیلوئت |
|------------------|---------------|--------|
| SOM              | ۷             | ۰.۳۳۰۸ |
| SPSS دو مرحله‌ای | ۴             | ۰.۲۸۵  |
| means-k          | ۱۳            | ۰.۱۰۲  |

از الگوریتم SOM با ۷ خوشه برای خوشه‌بندی محصولات به ۷ دسته در این سناریو استفاده می‌شود. شکل ۶ 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.



شکل ۶: درصد خوشه‌های محصول برای سناریوی ۱ در موقعیت ۱ جدول ۹، درصد دسته‌های محصول را در هر دسته محصول برای سناریوی ۱ در وضعیت ۱ نشان می‌دهد. در این سناریو، هله و هوله‌ها و محصولات بهداشتی بزرگ‌ترین بخش دسته‌های محصولات را تشکیل می‌دهند.

جدول ۹: درصد دسته‌های محصولات در هر دسته محصول برای سناریوی ۱ در وضعیت ۱

| دسته‌های محصولات | ابزارهای آشپزخانه |                   |        | محصولات سلامت و بهداشت |             |        |
|------------------|-------------------|-------------------|--------|------------------------|-------------|--------|
|                  | پروتئین‌ها (%)    | هله و هوله‌ها (%) | (%)    | خوراکی (%)             | نوشیدنی (%) | (%)    |
| خوشه-۱           | ۳.۹۲۲             | ۴.۷۲۴             | ۳۰.۶۰۶ | ۳۲.۳۴۹                 | ۹.۲۰۵       | ۱۹.۱۹۴ |
| خوشه-۲           | ۵.۶۷۴             | ۶.۵۳۱             | ۲۶.۶۱۵ | ۳۲.۸۵۰                 | ۱۰.۳۹۶      | ۱۷.۹۳۳ |
| خوشه-۳           | ۳.۱۶۰             | ۳.۷۲۲             | ۴۹.۵۳۶ | ۲۰.۶۵۸                 | ۶.۰۱۰       | ۱۶.۹۱۴ |
| خوشه-۴           | ۷.۴۸۰             | ۳.۵۷۰             | ۲۰.۱۹۴ | ۳۵.۲۸۴                 | ۱۴.۴۰۶      | ۱۹.۰۶۵ |
| خوشه-۵           | ۴.۳۶۱             | ۶.۰۰۵             | ۴۱.۹۸۵ | ۲۲.۴۶۸                 | ۷.۱۹۳       | ۱۷.۹۸۸ |
| خوشه-۶           | ۶.۹۰۵             | ۶.۲۸۸             | ۲۰.۰۰۸ | ۳۵.۷۲۰                 | ۱۲.۴۹۸      | ۱۸.۵۸۰ |
| خوشه-۷           | ۴.۳۷۶             | ۱۳.۷۱۱            | ۲۶.۲۰۱ | ۳۰.۳۸۲                 | ۸.۰۷۲       | ۱۷.۲۵۸ |

مدل ارائه شده استفاده می‌شود. سپس نتایج نهایی وضعیت ۲ برای مقایسه آن‌ها با وضعیت ۱ ارائه می‌شوند. جدول ۷ مقادیر سیلوئت را برای تعداد مختلف خوشه‌ها در الگوریتم SOM برای سناریوی ۱ در وضعیت ۱ نشان می‌دهد.

جدول ۷: مقایسه مقادیر سیلوئت برای تعداد خوشه‌های مختلف در الگوریتم

SOM برای سناریوی ۱ در وضعیت ۱

| تعداد خوشه‌ها | سیلوئت |
|---------------|--------|
| ۲             | ۰.۳۲۳۶ |
| ۳             | ۰.۱۸۹۶ |
| ۴             | ۰.۳۱۰۵ |
| ۵             | ۰.۲۸۸۵ |
| ۶             | ۰.۲۷۶۱ |
| ۷             | ۰.۳۳۰۸ |
| ۸             | ۰.۲۲۰۶ |
| ۹             | ۰.۳۰۹۴ |
| ۱۰            | ۰.۲۸۷۴ |


جدول ۸ مقدار سیلوئت و تعداد خوشه‌ها را برای الگوریتم‌های خوشه‌بندی SPSS، SOM دو مرحله‌ای و K میانگین برای وضعیت ۱ در سناریوی ۱ نشان می‌دهد.

جدول ۱۰، مقادیر سیلوئت را برای تعداد مختلف خوشه‌ها در الگوریتم SOM برای سناریوی ۸ در وضعیت ۱ نشان می‌دهد

جدول ۱۰: مقایسه مقادیر سیلوئت برای تعداد خوشه‌های مختلف در الگوریتم SOM برای سناریوی ۸ در وضعیت ۱

| تعداد خوشه‌ها | ۲      | ۳     | ۴     | ۵      | ۶      | ۷      | ۸      | ۹      | ۱۰     |
|---------------|--------|-------|-------|--------|--------|--------|--------|--------|--------|
| سیلوئت        | ۰.۴۴۲۹ | ۰.۵۰۱ | ۰.۴۵۶ | ۰.۴۴۳۲ | ۰.۳۴۰۷ | ۰.۳۵۴۷ | ۰.۳۲۴۱ | ۰.۳۱۸۳ | ۰.۳۲۶۸ |

۱ است. اغلب الگوهای خرید مشتریان در این وضعیت مطابق با شکل ۷ به خوشه ۱ اختصاص داده می‌شوند؛ بنابراین، خوشه ۱ مهم‌ترین دسته محصول برای سناریوی ۸ در وضعیت ۱ است.



شکل ۷: درصد خوشه‌های محصول برای سناریوی ۸ در موقعیت

جدول ۱۲، 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 ۱۲: درصد طبقه‌بندی‌های محصول در هر دسته محصول برای سناریوی ۸ در وضعیت ۱

| نوشیدنی (%) | خوراکی (%) | سلامت و بهداشت (%) | هله‌هوله (%) | ابزارهای آشپزخانه (%) | پروتئین (%) | دسته محصولات |
|-------------|------------|--------------------|--------------|-----------------------|-------------|--------------|
| ۲۹.۶۵۳      | ۴۱.۲۰۲     | ۲.۶۱۴              | ۲۶.۲۱۹       | ۰.۰۰۰                 | ۰.۳۱۲       | خوشه ۱       |
| ۲۵.۱۲۶      | ۵۸.۲۷۴     | ۲.۹۲۶              | ۸.۰۲۲        | ۵.۰۹۶                 | ۰.۵۵۵       | خوشه ۲       |
| ۱۳.۹۷۰      | ۲۰.۰۷۸     | ۱.۱۰۵              | ۱۵.۰۱۰       | ۴۹.۷۷۳                | ۰.۰۶۵       | خوشه ۳       |

جدول ۱۳، بیشترین مقدار سیلوئت K میانگین، SPSS دومرحله‌ای و الگوریتم‌های SOM را برای سناریوهای مورد بررسی در وضعیت ۱ نشان می‌دهد. سناریوی ۸ در جدول ۱۳ مدل ارائه شده در این مطالعه است و سناریوهای دیگر شبیه مدل‌های


جدول ۱۱، مقدار سیلوئت و تعداد خوشه‌ها را برای الگوریتم‌های دسته‌بندی SPSS، SOM دومرحله‌ای و K-میانگین برای سناریوی ۸ در وضعیت ۱ نشان می‌دهد.

جدول ۱۱: مقایسه الگوریتم‌های خوشه‌بندی در سناریوی ۸ در وضعیت ۱


| سیلوئت | تعداد خوشه‌ها | الگوریتم        |
|--------|---------------|-----------------|
| ۰.۵۰۱  | ۳             | SOM             |
| ۰.۴۴۹  | ۲             | SPSS دومرحله‌ای |
| ۰.۲۳۸  | ۹             | means-k         |

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. شکل ۸ درصد هر خوشه از خوشه‌های محصولات را برای سناریوی ۸ در وضعیت ۱ نشان می‌دهد. این خوشه‌ها دسته‌های محصول برای سناریوی ۸ در وضعیت

باملاحظه 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.



شکل ۸: مقایسه مقادیر سیلوئت الگوریتم SOM برای هر هشت



شکل ۹: مقایسه مقادیر سیلوئت الگوریتم SOM برای هر هشت

سناریو در وضعیت ۲ بیشترین مقدار سیلوئت به سناریوی ۸ تعلق دارد؛ بنابراین، متمایزترین دسته محصول می‌تواند با استفاده از ترکیب باندلینگ و قیمت به دست آید. برای بررسی اعتبار این مدل، وضعیت ۲ هم برای تعیین دسته‌های محصول در نظر گرفته شد. شکل ۹ مقادیر سیلوئت الگوریتم K میانگین را برای سناریوهای مورد بررسی در وضعیت ۲ نشان می‌دهد. در این وضعیت، مانند وضعیت ۱، بالاترین مقدار سیلوئت به سناریوی ۸ تعلق دارد.

#### ۴-۴-۴ تعیین قواعد انجمنی

از الگوریتم Apriori برای تعیین قواعد انجمنی بین محصولات و کشف محصولاتی استفاده شد که معمولاً به همراه هم خریداری می‌شوند. این قواعد انجمنی به فروشگاه در انتخاب بهترین اقلام محصولات برای قراردعی در یک باندلینگ کمک می‌کنند. جدول ۱۴، پنج قاعده انجمنی اول را برای سناریوی ۱ در وضعیت ۱ نشان می‌دهد که مطابق با مقدار اطمینان مرتب می‌شوند.

موجود در پیشینه پژوهش است. بیشترین مقدار سیلوئت در هر سناریو با استفاده از الگوریتم SOM به دست می‌آید. از این رو، الگوریتم SOM برای خوشه‌بندی محصول در مدل ارائه شده به کار می‌رود. شکل ۸ مقادیر سیلوئت الگوریتم SOM را برای سناریوهای مورد بررسی در وضعیت ۱ نشان می‌دهد.

جدول ۱۳: مقایسه الگوریتم‌های خوشه‌بندی برای تمامی ۸ سناریو در وضعیت ۱

| سناریو | الگوریتم        | تعداد خوشه‌ها | سیلوئت |
|--------|-----------------|---------------|--------|
|        | SOM             | ۷             | ۰.۳۳۰۸ |
| ۱      | SPSS دومرحله‌ای | ۴             | ۰.۲۸۵  |
|        | means-k         | ۱۳            | ۰.۱۰۲  |
|        | SOM             | ۷             | ۰.۴۰۳۹ |
| ۲      | SPSS دومرحله‌ای | ۴             | ۰.۳۸۵  |
|        | means-k         | ۱۲            | ۰.۱۷۵  |
|        | SOM             | ۴             | ۰.۴۱۸۴ |
| ۳      | SPSS دومرحله‌ای | ۳             | ۰.۴۰۸  |
|        | means-k         | ۱۲            | ۰.۱۰۹  |
|        | SOM             | ۵             | ۰.۴۱۰۷ |
| ۴      | SPSS دومرحله‌ای | ۴             | ۰.۳۶۱  |
|        | means-k         | ۱۲            | ۰.۱۶۰  |
|        | SOM             | ۴             | ۰.۴۴۹۸ |
| ۵      | SPSS دومرحله‌ای | ۳             | ۰.۴۳۹  |
|        | means-k         | ۱۲            | ۰.۱۹۸  |
|        | SOM             | ۴             | ۰.۴۲۱۳ |
| ۶      | SPSS دومرحله‌ای | ۳             | ۰.۴۰۹  |
|        | means-k         | ۱۲            | ۰.۱۶۱  |
|        | SOM             | ۴             | ۰.۴۴۰۸ |
| ۷      | SPSS دومرحله‌ای | ۳             | ۰.۳۹۶  |
|        | means-k         | ۹             | ۰.۲۵۱  |
|        | SOM             | ۳             | ۰.۵۰۱  |
| ۸      | SPSS دومرحله‌ای | ۲             | ۰.۴۴۹  |
|        | means-k         | ۹             | ۰.۲۳۸  |

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. در ادامه، راندمان این سناریو برای توصیه دسته محصولات به مشتریان ارزیابی می‌شود.

#### ۴-۵ نتایج

در ارزیابی ارائه شده عامل سیلوئت برای خوشه‌بندی مختلف جهت کارایی خوشه‌بندی پیشنهادی را ارزیابی کردیم.

سیلوئت<sup>۱</sup>: کیفیت الگوریتم‌های خوشه‌بندی را می‌توان با توجه به ضریب سیلوئت ارائه شده در معادله ۴-۲ به دست آورد. در این معادله A میانگین فاصله اشیای درون یک خوشه از یکدیگر و B حداقل میانگین فاصله اجسام درون خوشه از سایر خوشه‌ها است.

$$Silhouette = \frac{(B - A)}{\max(A, B)} \quad (4-2)$$

مقدار ضریب سیلوئت بین [-۱, ۱] است. ۱ نشان‌دهنده بالاترین کیفیت خوشه‌بندی و -۱ نشان‌دهنده پایین‌ترین کیفیت خوشه‌بندی است. برای اندازه‌گیری کیفیت یک الگوریتم خوشه‌بندی، می‌توان از میانگین مقدار ضریب سیلوئت در مجموعه داده استفاده کرد.

ماتریس confusion برای روش ارائه شده را با روش‌های SOM، SVM و مقالات کار شده نشان داده شده است. همان‌طور که در (شکل ۱۰) مشخص است نتایج روش SOM نشان می‌دهد که این روش توانسته است که به ۵۹/۴ درصد پیش‌بینی‌ها را از روی داده‌های آزمون و آموزش شبکه عصبی خودسازمانده و تشخیص صحیح آن، الگوی ماتریس به‌گونه‌ای طراحی شد که درصد پیش‌بینی‌های صحیح با رنگ سبز، درصد پیش‌بینی‌های نادرست با رنگ قرمز و نتایج نهایی طبقه‌بندی‌ها در سطر و ستون پایانی ماتریس با رنگ آبی مشخص گردید.

جدول ۱۴: قواعد انجمنی برای سناریوی ۱ در وضعیت ۱

| پشتیبانی<br>قاعده (%) | اطمینان<br>(%) | پیامد (کد<br>محصول) | سابقه (کد محصول) |
|-----------------------|----------------|---------------------|------------------|
| ۲.۱۰۴                 | ۸۹.۴۵          | ۲۲۶۹۷               | ۲۲۶۹۸            |
|                       |                |                     | ۲۲۶۹۹            |
| ۲.۱۰۴                 | ۸۴.۷۸۳         | ۲۲۶۹۹               | ۲۲۶۹۸            |
|                       |                |                     | ۲۲۶۹۷            |
| ۱.۶۸۳                 | ۸۳.۴۲۲         | ۲۲۶۹۹               | ۲۲۶۹۷            |
|                       |                |                     | ۲۲۴۲۳            |
| ۲.۴۸۲                 | ۸۲.۷۳۴         | ۲۲۶۹۷               | ۲۲۶۹۸            |
| ۲.۳۵۲                 | ۷۸.۴۱۷         | ۲۲۶۹۹               | ۲۲۶۹۸            |


جدول ۱۵ نشان می‌دهد که ۵ قاعده اول برای سناریوی ۸ در وضعیت ۱ که در آن از متغیرهای تأثیرگذار و میزان وفاداری مشتریان استفاده شد، مطابق با میزان اطمینان مرتب می‌شوند.

جدول ۱۵: قواعد انجمنی برای سناریوی ۸ در وضعیت ۱

| پشتیبانی<br>قاعده | اطمینان | پیامد کد<br>محصول | سابقه کد<br>محصول |
|-------------------|---------|-------------------|-------------------|
| ۲۸.۸              | ۹۱.۱۳۹  | ۲۲۶۹۷             | ۲۲۶۹۸             |
|                   |         |                   | ۲۲۶۹۹             |
| ۴.۰               | ۹۰.۹۰۹  | ۲۲۷۲۷             | ۲۲۶۲۹             |
|                   |         |                   | ۲۲۷۲۶             |
| ۲۸.۸              | ۹۰.۰    | ۲۲۶۹۹             | ۲۲۶۹۸             |
|                   |         |                   | ۲۲۶۹۷             |
| ۳.۶               | ۹۰.۰    | ۲۲۶۹۹             | ۲۲۱۹۷             |
|                   |         |                   | ۲۲۶۹۸             |
| ۳.۶               | ۹۰.۰    | ۲۲۶۹۷             | ۲۲۱۹۷             |
|                   |         |                   | ۲۲۶۹۸             |

جدول ۱۵ نشان می‌دهد که مقادیر پشتیبانی و اطمینان در سناریوی ۸ در یک وضعیت بالاتر از سناریوی ۱ است؛ بنابراین، محصولات در سناریوی ۸ به‌صورت بهتری دسته‌بندی می‌شوند. مراحل قبلی نشان می‌دهند که اگر از متغیرهای تأثیرگذار استفاده شود، دسته‌بندی بهتری برای


مقایسه ماتریس confusion روش ارائه شده در مقایسه با روش‌های دیگر نشان می‌دهد که روش ارائه شده (شکل ۱۳) نتایج حاصل از طبقه‌بندی را بهتر در مقایسه با سایر روش‌ها انجام داده است و توانسته است ۹۳/۸ درصد پاسخ صحیح دهد.



شکل ۱۳: روش کار شده


## ۵. نتیجه‌گیری

در مدل پیشنهادی مسیر جدیدی برای شخصی‌سازی پیشنهاد گروهی محصول است و مدیران بازاریابی می‌توانند از آن در تصمیم‌گیری‌های خود استفاده کنند. با اعمال مدل پیشنهادی، باندلینگ محصول با صحت بیشتری تعیین می‌شوند، پیرامون این پژوهش سامانه پیشنهاد باندلینگ محصول که شامل خوشه‌بندی مشتریان و محصولات با نگاشت خودسازماندهی (SOM) و طبقه‌بندی با ماشین بردار پشتیبان (SVM)، یک رویکرد جامع برای ایجاد توصیه‌های شخصی شده را پیشنهاد کردیم. ارزیابی نتایج نشان داد که روش ارائه شده با صحت نزدیک ۹۴ درصد بهترین روش نسبت به سایر روش‌ها است. باتوجه به نتایج پژوهش پیشنهادی‌های زیر ارائه گردید: روش سامانه پیشنهاد باندلینگ محصول با استفاده از نقشه‌های خودسازماندهی (SOM) برای خوشه‌بندی مشتری و محصول، همراه با ماشین بردار پشتیبانی (SVM) برای طبقه‌بندی، یک رویکرد امیدوارکننده است. با این حال، چندین راه بالقوه برای تحقیقات آینده و بهبود در این زمینه وجود دارد. مهندسی و انتخاب ویژگی: ویژگی‌های مختلفی را کاوش و آزمایش کنید




شکل ۱۰: روش SOM

همان‌طور که در (شکل ۱۱) مشخص است، نتایج روش SVM نشان می‌دهد که این روش توانسته است که به ۴۸/۷ درصد پیش‌بینی‌ها را از روی داده‌های آزمون درست تشخیص دهد



شکل ۱۱: روش SVM

همان‌طور که در (شکل ۱۲) مشخص است، نتایج روش تکنیک مورد استفاده آقای لئو و همکاران در سال ۲۰۲۲ حاکی از آن است که این روش توانسته است که به ۵۶/۴ درصد پیش‌بینی‌ها پاسخ صحیح دهد.



شکل ۱۲: مقاله پایه (لیو و همکاران، ۲۰۲۲)

که می‌تواند ترجیحات مشتری و ویژگی‌های محصول را به طور مؤثر جلب کند. مهندسی ویژگی را برای استخراج ویژگی‌های معنی‌دار از داده‌هایی که تأثیر قابل‌توجهی بر توصیه‌های بسته‌بندی محصول دارند، انجام دهید. از تکنیک‌های انتخاب ویژگی برای شناسایی مرتبط‌ترین ویژگی‌ها و کاهش ابعاد استفاده کنید و کارایی سامانه توصیه را افزایش دهید. همچنین مدل‌های ترکیبی: بررسی پتانسیل ادغام سایر الگوریتم‌های خوشه‌بندی یا مدل‌های طبقه‌بندی با SOM و SVM برای ایجاد مدل‌های ترکیبی قدرتمندتر. رویکردهای ترکیبی می‌توانند از

نقاط قوت الگوریتم‌های مختلف استفاده کنند که منجر به بهبود دقت و استحکام در خوشه‌بندی مشتریان و طبقه‌بندی محصول می‌شود. همچنین پیشنهاد بلادرنگ: مکانیزم‌هایی را برای فعال کردن پیشنهادهای بلادرنگ در باندلینگ محصول ایجاد کنید. پیاده‌سازی روش‌های یادگیری آنلاین را در نظر بگیرید که می‌تواند مدل پیشنهاد را بر اساس ترجیحات مشتری پویا و تغییرات در فهرست محصول تطبیق داده و به‌روز کند. این تضمین می‌کند که سامانه پیشنهاد به‌روز می‌ماند و پیشنهادهای باندلینگ به‌موقع و مرتبط را ارائه می‌دهد.

## منابع

- Afoudi, Y., Lazaar, M., & Al Achhab, M. (2021). Hybrid recommendation system combined content-based filtering and collaborative prediction using artificial neural network. *Simulation Modelling Practice and Theory*, 113, 102375. <https://doi.org/10.1016/j.simpat.2021.102375>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., et al. (2021). Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8, 53. <https://doi.org/10.1186/s40537-021-00444-8>
- Asnafī, A. R., Rezaeifard, S., Haji Zeinalabedini, M., & Nashati, M. (2023). Providing a model for information resource recommender systems in Iranian library software. *Library & Information Science*, 26(2), 25–46. <https://doi.org/10.30481/lis.2021.261249.1782>
- Baskota, A., & Ng, Y.-K. (2018). A graduate school recommendation system using the multi-class Support Vector Machine and KNN approaches. 2018 IEEE International Conference on Information Reuse and Integration (IRI), 277–284. <https://doi.org/10.1109/IRI.2018.00050>
- Bobadilla, J., Ortega, F., Hernando, A., & Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-Based Systems*, 46, 109–132. <https://doi.org/10.1016/j.knosys.2012.10.011>
- Chang, J., GAO, C., He, X., Jin, D., & Li, Y. (2021). Bundle recommendation and generation with graph neural networks. *IEEE Transactions on Knowledge and Data Engineering*. <https://doi.org/10.1109/TKDE.2021.3114586>
- 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.
- De Carvalho, T. B. A., Martins, D. M. L., De Lima Neto, F. B., & Vossen, G. (2022). Recommending view bundles in data marketplaces. 2022 IEEE International Conference on Systems, Man, and Cybernetics (SMC), 3403–3408. <https://doi.org/10.1109/SMC53654.2022.9945110>
- Ebrahimi, L., Mirabi, V. R., Ranjbar, M. H., & Hassanpour, E. (2020). Customer loyalty model for recommender systems in e-commerce. *Intelligent Business Management Studies*, 8(29), 143–170. <https://doi.org/10.22054/ims.2019.10379>
- Ghaffarian, S., Bab Al-Hawaeji, F., Jalali, F., Hariri, M., & Khademi, M. (2023). Application of data mining in digital library recommendation systems based on association rules (case study of Astan Quds Razavi Library). *Library Studies and Information Organization*, 2, 39–66.

- Jena, S. K., & Ghadge, A. (2022). Product bundling and advertising strategy for a duopoly supply chain: A power-balance perspective. *Annals of Operations Research*, 315, 1729–1753. <https://doi.org/10.1007/s10479-020-03861-9>
- Kang, D., Park, M. J., Lee, D. H., & Rho, J. J. (2017). Mobile services with handset bundling and governmental policies for competitive market. *Telematics and Informatics*, 34(1), 323–337. <https://doi.org/10.1016/j.tele.2016.07.005>
- Nourahmadi, M. (2024). Financial insights: Harnessing recommender system through bibliometric analysis. *Journal of Knowledge Economy Studies (JKES)*, 1(1), 93–116.
- Plananska, J., & Gamma, K. (2022). Product bundling for accelerating electric vehicle adoption: A mixed-method empirical analysis of Swiss customers. *Renewable and Sustainable Energy Reviews*, 154, 111760. <https://doi.org/10.1016/j.rser.2021.111760>
- Pouyanfar, S., Sadiq, S., Yan, Y., Tian, H., Tao, Y., & Reyes, M. P. (2018). A survey on deep learning: Algorithms, techniques, and applications. *ACM Computing Surveys*, 51(5), 1–36. <https://doi.org/10.1145/3234150>
- Suthaharan, S. (2016). *Machine learning models and algorithms for big data classification* (Vol. 36). CRC Press.
- Yan, R., Myers, C., Wang, J., & Ghose, S. (2014). Bundling products to success: The influence of complementarity and advertising. *Journal of Retailing and Consumer Services*, 21(1), 48–53. <https://doi.org/10.1016/j.jretconser.2013.08.003>
- Zandi Nasab, M., Jafari, S. M. B., & Farmani, M. (2020). 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. <https://doi.org/10.22108/nmrj.2019.116526.1711>
- Zhang, Q., & Zheng, Y. (2022). Pricing strategies for bundled products considering consumers' green preference. *Journal of Cleaner Production*, 344, 130962. <https://doi.org/10.1016/j.jclepro.2022.130962>
- 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*, 29, 247–273. <https://doi.org/10.1111/itor.12626>
- Zheng, P., Wang, Z., Chen, C. H., & Khoo, L. P. (2019). A survey of smart product-service systems: Key aspects, challenges and future perspectives. *Advanced Engineering Informatics*, 42, 100973. <https://doi.org/10.1016/j.aei.2019.100973>

***IRM***

# P Presenting a model for product recommendations based on customer loyalty by deep neural networks

Ali Najafi<sup>1</sup>, Javad Niknafs<sup>\*2</sup>, Sandes Bahadori<sup>3</sup>, Alireza Esfandiari-Moghaddam<sup>4</sup>

1 Department of Management, Hamedan Branch, Islamic Azad University, Hamedan, Iran

2 \*Department of Management, Hamedan Branch, Islamic Azad University, Hamedan, Iran

3 Department of Computer Engineering, Ilam Branch, Islamic Azad University, Ilam, Iran

4 Department of Information Science and Knowledge Studies, Hamedan Branch, Islamic Azad University, Hamedan, Iran

Corresponding author Email: [niknafs@iau.ac.ir](mailto:niknafs@iau.ac.ir)

## Abstract

Today, due to the increasing growth of the Internet and the huge volume of information, we need systems that can recommend the most appropriate services and products to the user in the shortest time and with the highest quality offer. Given the increasing use of new technologies that aim to gain more profit and ultimately achieve individual satisfaction, it is necessary. Today, traditional methods such as product classification and clustering do not meet the needs of businesses and we must move towards personalizing offers using new recombining methods (local marketing). In this study, three features of customer classification and recommendation in the form of single and aggregated packages and heterogeneous goods based on the ranking of recommendations have been considered. The present study aims to present a new hybrid model for cumulative product recommendations in the e-commerce market, which has not been used in previous research. This study is applied in terms of its purpose and its objectives are to present a recommender system in e-business based on machine learning and deep neural networks, to examine the algorithms and techniques of the recommender system in machine learning and deep neural networks, and to examine and compare the degree of optimization of accuracy and correct prediction detection in the use of the algorithms studied and used. The research data were collected from the database of the Digikala store under study. The data is numerical and discrete. This study is in the field of customer relationship management in terms of subject matter and the company is limited to the Digikala store in terms of location. The results indicate that the proposed model is a new path for personalizing group product offerings and marketing managers can use it in their decision-making. Data analysis was performed using coding in MATLAB software and the model outputs are presented with proof of the relevant formulas. Evaluations show that companies can determine product packaging more accurately by applying the proposed model. Therefore, companies can attract new customers, encourage current customers to buy, and retain valuable customers. The results show that the proposed model is the best method for product recommendation with an accuracy of 94%

**Keywords:** : Recommender System, Intelligence, E-commerce, Machine Learning, Deep Neural Network