



Production and Operations Management

University of Isfahan E-ISSN: 2423-6950

Vol. 14, Issue 1, No. 32, Spring 2023



<https://doi.org/10.22108/pom.2023.136202.1485>

(Research paper)

## Proposing an integrated approach for omnichannel demand forecasting using machine learning-time series clustering with dynamic time warping algorithm and artificial neural networks

Maryam Soltani

Department of Industrial Management, Faculty of Management and Accounting, Allameh Tabatabai University, Tehran, Iran, m.s.soltani8288@gmail.com

Seyed Mohammad Ali Khatami Firouzabadi \*

Department of Industrial Management, Faculty of Management and Accounting, Allameh Tabatabai University, Tehran, Iran, a.khatami@atu.ac.ir

Magsoud Amiri

Department of Industrial Management, Faculty of Management and Accounting, Allameh Tabatabai University, Tehran, Iran, amiri@atu.ac.ir

Mojtaba Hajian Heidary

Department of Industrial Management, Faculty of Management and Accounting, Allameh Tabatabai University, Tehran, Iran, hajianheidary@atu.ac.ir

**Purpose:** The increasing complexity of omnichannel retailing has necessitated retailers to redesign processes and forecasting methods and accept new approaches based on machine learning and artificial intelligence. Improving the accuracy of demand forecasting and managing customer needs from different channels due to reducing demand uncertainty are the most important challenges in omnichannel retailing that retailers should deal with. A better understanding of consumer behaviour patterns leads to more accurate demand forecasting, which in turn helps gain insight into transportation flows, improves distribution management, and enables better planning and execution of supply chain operations. This study aims to reduce the uncertainty of demand in omnichannel retailing by improving the accuracy of demand forecasting by considering customers buying behaviour through using machine learning methods.

**Design/methodology/approach:** In this study to forecast future sales based on customers buying behaviour, a cosmetics retailer's historical data on the monthly sales from February 2020 to June 2022

\* Corresponding author



is used. The ID of eight products has been selected to analyze the performance of proposed methods and the method that the company applied to forecast demand. Clustering has been implemented using the dynamic time-warping algorithm due to the unequal length of the products' time series. Initially, the nonlinear autoregressive neural network (NAR) has been applied to the time series in each cluster and later, the nonlinear autoregressive neural network with exogenous input (NARX) has been applied to the time series. The performance of the methods has been evaluated by testing R-squared and all R-squared coefficients and root mean square error (RMSE) to analyze the accuracy measure.

**Findings:** The forecasting methods comparison, moving average (MA), the nonlinear autoregressive neural network (NAR), and the nonlinear autoregressive neural network with exogenous input (NARX) concerning testing R-squared coefficient, and also all R-squared and RMSE indicated that the nonlinear autoregressive neural network with exogenous input presented a good performance for all the products, so it confirmed that the application of the clustering to identification customers buying behaviour through the sales history of the products, integrated with artificial neural networks, to conduct demand forecasting, could be considered a good method for forecasting demand of omnichannel retailing supply chain products.

**Practical implications:** The proposed method of this study leads to uncertainty reduction in omnichannel retailing by understanding the buying behaviour of customers, identifying patterns and using its analysis in the processes and operations, and its integration with machine learning methods improves distribution management and provides better planning and implementation of supply chain operations. Managers can use the proposed method to accurately predict complex demand patterns in the retailing industry. Using business data in demand planning provides an extra advantage to managers to include important variables based on their judgments.

**Social implications:** Knowing the factors affecting the sale of a specific category of a product helps to effectively design promotions, advertising campaigns, the optimal combination of category displays and optimization of shelf space in retail stores. Also, accurate demand forecasts lead to better ordering policies, thus minimizing the cost of inventory management and optimal distribution and logistics planning to meet future demand.

**Originality/value:** The proposed method presents a predictive approach for an omnichannel retailing supply chain that leads to uncertainty reduction in omnichannel retailing by understanding the buying behaviour of customers, identifying patterns, and using its analysis in the processes and operations and its integration with machine learning methods to improve distribution management, and provides better planning and implementation of supply chain operations.

**Keywords:** Artificial neural networks, Demand forecasting, Dynamic time warping algorithm, Machin learning, Omnichannel



مدیریت تولید و عملیات، دوره ۱۴، شماره ۱، پیاپی ۳۲، بهار ۱۴۰۲

دريافت: ۱۴۰۱/۱۰/۱۱ پذيرش: ۱۴۰۲/۰۵/۰۵ ص ۱۴۰-۱۲۱



<https://doi.org/10.22108/pom.2023.136202.1485>

### (مقاله پژوهشی)

## رويکرد ترکيبی پيش‌بييني تقاضای کانال همه‌جانبه يكپارچه، با استفاده از يادگيري ماشين - خوشبندی سري‌هاي زمانی با الگوريتم پیچش زمانی پویا و شبکه‌های عصبي مصنوعی

مریم سلطانی<sup>۱</sup>، سید محمدعلی خاتمی فیروزآبادی<sup>۲\*</sup>، مقصود امیری<sup>۳</sup>، مجتبی حاجیان حیدری<sup>۴</sup>

۱- دانشجوی دکتری گروه مدیریت صنعتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبائی، تهران، ایران، m.soltani8288@gmail.com

۲- استاد گروه مدیریت صنعتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبائی، تهران، ایران، a.khatami@atu.ac.ir

۳- استاد گروه مدیریت صنعتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبائی، تهران، ایران، amiri@atu.ac.ir

۴- استادیار گروه مدیریت صنعتی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبائی، تهران، ایران، hajianheidary@atu.ac.ir

**چکیده:** پذيرش کانال‌های آنلайн و تجارت الکترونيک، به تغييرات مداوم و پویا در صنعت خردهفروشی، به عنوان یک توسعه اجتناب‌ناپذير منجر شده و بسياري از شركت‌ها را با چالش انتخاب مناسب‌ترین کانال فروش، برای ارائه یک تجربه يكپارچه به مشتريان خود مواجه کرده است. خردهفروشی همه‌جانبه يكپارچه، با مفهوم ادغام همه کانال‌ها، ضمن ايجاد تجربه مذکور، باعث افزایش پیچیدگی فرآيند‌هاي پيش‌بييني و برنامه‌ريزي می‌شود. اين پژوهش با هدف کاهش عدم اطمینان تقاضای ناشی از خطای پيش‌بييني، از طريق در نظر گرفتن رفتار خريد مشتريان در پيش‌بييني و به کمک استفاده از روش‌های يادگيري ماشين، روشي دقيق‌تر برای پيش‌بييني تقاضای کانال همه‌جانبه يكپارچه ارائه کرده است. به اين منظور، ابتدا داده‌های فروش شركت مطالعه شده، جمع‌آوری و با استفاده از الگوريتم پیچش زمانی پویا خوشبندی شد؛ سپس بر هر خوشه يك بار شبکه عصبي اتو رگرسيو غيرخطي و بار دیگر، شبکه عصبي اتو رگرسيو غيرخطي با ورودی بروزرا اجرا و نتایج حاصل از شبکه‌های عصبي با معيارهای ارزیابی عملکرد  $R^2$  و  $RMSE$  با روش استفاده شده در شركت مطالعه شده، مقایسه شد. مقایسه نتایج نشان داد عملکرد شبکه عصبي اتو رگرسيو غيرخطي، با ورودی بروزرا بر داده‌های خوشبندی شده به روش پیچش زمانی پویا، برای کاهش خطای پيش‌بييني تقاضا در کانال همه‌جانبه يكپارچه، نسبت به دو روش دیگر برتری دارد.

**واژه‌های کلیدی:** شبکه‌های عصبي مصنوعی، پيش‌بييني تقاضا، الگوريتم پیچش زمانی پویا، يادگيري ماشين، کانال

همه‌جانبه يكپارچه

## ۱- مقدمه

خردهفروشان در طراحی شبکه توزیع می‌توانند با توجه به کسب و کار خود از بین چندین کanal توزیع مختلف، گزینه‌های بهینه را برای سازمان خود پیدا کنند. این کanal‌ها شامل کanal فیزیکی، کanal آنلاین، کanal تلفن همراه، کatalوگ و درنهایت ترکیبی از این کanal‌هاست. با مرکز بر دیدگاه لجستیکی، می‌توان سه استراتژی اصلی کanal توزیع را برشمرد. در رویکرد تککanal، خردهفروشان فقط از یک کanal فروش و یک سیستم لجستیک اختصاص داده شده برای این کanal جداگانه استفاده می‌کنند.

در رویکرد چند کanal، خردهفروشان چندین کanal با واحدهای جداگانه و سیستم‌های مستقل را برای عملیات و تدارکات ایجاد می‌کنند (هوبنر و همکاران<sup>۱</sup>، ۲۰۱۶). فرآیندها از دیدگاه مشتری یکپارچه نیستند و هیچ رابط عملیاتی یا لجستیکی بین دو کanal وجود ندارد (ورهوف و همکاران<sup>۲</sup>، ۲۰۱۵).

در رویکرد کanal همه‌جانبه یکپارچه<sup>۳</sup> پیشفرته، تنها یک رابط لجستیکی مشترک برای مشتری وجود دارد و سفارش‌های آنلاین نیز می‌تواند از طریق فروشگاه‌ها و همچنین سفارش‌هایی پردازش شود که برای تحويل درب منزل، در فروشگاه قرار می‌گیرد. یک تجربه خرید یکپارچه، مشتریان را قادر می‌کند در هر زمان از هر مکان، شخصاً و یا از طریق دستگاه‌های دیجیتال سفارش دهنده و خریدشان در زمان و مکان دلخواهشان، به آنها تحويل داده شود (چوپرا<sup>۴</sup>، ۲۰۱۸).

پیش‌بینی تقاضا یک جنبه اساسی در مدیریت زنجیره تأمین<sup>۵</sup> است که در تصمیم‌گیری‌های برنامه‌ریزی، ظرفیت و کنترل موجودی، تأثیر چشمگیری دارد (کرکان و همکاران<sup>۶</sup>، ۲۰۰۹). نظر به اینکه اینترنت و رقابت جهانی، الزامات را برای معرفی به موقع محصول، مدیریت زنجیره تأمین و تحويل کanal چندگانه تسريع می‌کنند، پیش‌بینی اهمیت بیشتری پیدا کرده است (فردیک راس<sup>۷</sup>، ۲۰۱۷). رؤیه رایج در میان خردهفروشان کanal‌های چندگانه به‌طور سنتی، برنامه‌ریزی و پیش‌بینی کanal‌های مختلف به صورت جداگانه بوده است، در حالی که نمی‌توان تقاضا را به‌طور واقعی دریافت کرد؛ زیرا خردهفروش از قصد مشتری، که به چنین تقاضایی منجر شده است، آگاه نیست؛ برای مثال، یک مشتری می‌تواند یک محصول را در فروشگاه ببیند و آن را به صورت آنلاین سفارش دهد. این بیشتر به افزایش عدم قطعیت تقاضا منجر می‌شود و پیش‌بینی را به یک کار چالش‌برانگیز تبدیل می‌کند (رودرکرک و کوک<sup>۸</sup>، ۲۰۱۹). با توجه به تجزیه و تحلیل تأثیر موج ناشی از اختلالات در تقاضا، تولید و فرایند توزیع در زنجیره تأمین خردهفروشی و تأثیر مستقیم روش پیش‌بینی تقاضا بر واکنش زنجیره تأمین در اثر شلاقی و اشاره به این نکته که تخفیف‌های قیمت در بازار خردهفروشی آنلاین، عموماً اثر شلاقی را در زنجیره تأمین خردهفروشی آنلاین تقویت می‌کند، به حداقل رساندن عوامل عدم قطعیت در سناریوی خردهفروشی هوشمند و انتخاب بهترین روش پیش‌بینی برای به حداقل رساندن اثر شلاقی در زنجیره تأمین خردهفروشی آنلاین، از اهمیت زیادی برخوردار است و باید برای تحقیقات آینده در این زمینه، در اولویت باشد (گائو و همکاران<sup>۹</sup>، ۲۰۱۷).

دیویس<sup>۱۰</sup> (۱۹۹۳) سه منبع مختلف عدم قطعیت را در زنجیره تأمین تعریف می‌کند: عدم قطعیت عرضه، عدم قطعیت فرآیند و عدم قطعیت تقاضا. عدم قطعیت تقاضا که از تقاضای ناپایدار یا پیش‌بینی‌های نادرست ناشی می‌شود، جدی‌ترین مورد از این سه عدم قطعیت و یک بعد جدایی‌ناپذیر از پویایی محیطی است (هانچلیوگلای و همکاران<sup>۱۱</sup>، ۲۰۱۶). دو منبع عدم قطعیت در فرآیند پیش‌بینی تقاضا وجود دارد: منبع اول، خطای پیش‌بینی است که

با نزدیکتر شدن به روش پیش‌بینی بهینه، می‌تواند کاهش یابد؛ منبع دوم، خطای فرآیند و تغییرات تصادفی در خود فرآیند پیش‌بینی است که این خطای را تنها با تلاش برای مدیریت فرآیند تقاضا، با تلاش برای شناسایی تغییر رفتار مشتریان یا از طریق پیش‌بینی مشارکتی، کاهش می‌دهد (فیلدز و کینگزمن<sup>۱۲</sup>، ۲۰۱۱). درک رفتار مشتریان و استفاده از تحلیل آن در فرایندها و عملیات خرده‌فروشان، به شناسایی الگوهای رفتار مشتریان و در صورت لزوم، برنامه‌ریزی برای تغییر آن کمک می‌کند که این امر در کاهش خطای فرآیند مؤثر است. تشخیص دقیق نیاز و پیش‌بینی صحیح تقاضا، نیازمند دیدگاه مشترک موجودی در همه کانال‌هاست. با توجه به اینکه در کانال همه‌جانبه یکپارچه، تمام اطلاعات مربوط به مشتریان، موجودی کالا، عملیات و تدارکات، همه در یک پلتفرم واحد ضبط و تلفیق می‌شوند، با استفاده از فناوری‌هایی که امکان تجزیه و تحلیل رفتار خرید مشتریان را از کانال‌های مختلف فراهم می‌کند، به خرده‌فروشان در درک بهتر رفتار مصرف‌کننده هر کانال و درنتیجه به پیش‌بینی دقیق‌تر تقاضا و به سهم خود، به کسب بیش درباره جریان حمل و نقل کمک می‌کند (رای و همکاران<sup>۱۳</sup>، ۲۰۱۹)؛ همچنین، مدیریت توزیع را بهبود و امکان برنامه‌ریزی و اجرای بهتر عملیات زنجیره تأمین را فراهم و درنتیجه با کاهش عدم قطعیت، ارائه پیشنهادهای جذاب و ایجاد هزینه‌های تغییر، خرده‌فروشان را در حفظ مشتری توانمند می‌کند (کومار و همکاران<sup>۱۴</sup>، ۲۰۲۰).

دلیل استفاده گسترده از تکنیک‌های پیشرفتی یادگیری ماشین توسط متخصصان زنجیره تأمین، سودآوری بالقوه و افزایش سهولت دسترسی، اجرای مدل‌های پیچیده یادگیری ماشین با تکنیک‌ها و نرم‌افزارهای جدید برای پیش‌بینی و همچنین تسهیل پیش‌بینی از طریق تجمیع و مصورسازی داده‌های داده‌های (نیازکار و همکاران<sup>۱۵</sup>، ۲۰۲۰). از هوش مصنوعی به‌طور فزاینده‌ای به عنوان یک ابزار حل مسئله در تجارت استفاده می‌شود (چوی و همکاران<sup>۱۶</sup>، ۲۰۱۸) و قابلیت‌های یادگیری بی‌نظیر هوش مصنوعی، به مدیریت تقاضا در شرایط اضطراری نیز کمک می‌کند. از مزایای مشخص شده در استفاده از بیگ دیتا و تحلیل کسب و کار در زنجیره تأمین، از دستیابی به قابلیت پیگیری بیشتر عملکرد، نوسانات و روند هزینه‌ها، نظارت بر موجودی، بهینه‌سازی تولید، مدیریت نوسانات تقاضا، طراحی شبکه زنجیره تأمین و حمل و نقل و بهینه‌سازی منابع نام برده می‌شود (ایساسی، فرازن و اوینا<sup>۱۷</sup>، ۲۰۱۵). نظر به اینکه در مدل‌های کلاسیک پیش‌بینی، نظیر سری‌های زمانی یا رگرسیون خطی، به تشخیص صحیح فرم توابع به صورت متغیر مستقل و وابسته نیاز است و داده‌های پرت به تخمین نامناسب پارامترها منجر می‌شود و علاوه بر آن، بیشتر مدل‌های سری‌های زمانی خطی‌اند و روابط غیرخطی را به درستی توضیح نمی‌دهند، نمی‌توانند به خوبی رفتار مصرف کننده را پیش‌بینی کنند؛ در حالی که شبکه‌های عصبی به‌دلیل سازگاری با روندهای غیرخطی، ابزار مناسی برای تقریب غیرخطی و شرایط پیچیده محسوب می‌شوند (فائضی‌راد و همکاران<sup>۱۸</sup>، ۱۴۰۰).

در این مقاله با هدف کاهش عدم قطعیت تقاضای ناشی از خطای پیش‌بینی و خطای فراینده تقاضا، از روش ترکیبی خوشبندی و شبکه‌های عصبی مصنوعی استفاده شده است. به‌منظور در نظر گرفتن رفتار خرید مشتریان برای کاهش خطای فراینده، ابتدا محصولات را با توجه به مقدار و کانال فروش آنلاین، حضوری و خرید آنلاین و دریافت از فروشگاه<sup>۱۹</sup> (BODS) خوشبندی و سپس با استفاده از شبکه‌های عصبی مصنوعی برای کاهش خطای پیش‌بینی، تقاضای محصولات در هر خوش‌بینی شده است. به‌منظور بررسی روش ترکیبی پیشنهادی، مقایسه و ارزیابی عملکرد روش مذکور، از داده‌های شرکتی فعال در صنعت خرده‌فروشی در زمینه محصولات آرایشی و بهداشتی استفاده شده است.

در ادامه، ساختار مقاله به این شرح است: ابتدا پژوهش‌های انجام‌شده در زمینه پیش‌بینی تقاضا در خرده‌فروشی کanal همه‌جانبه یکپارچه بررسی و سپس در بخش روش‌شناسی پژوهش، روش‌های استفاده‌شده به تفکیک شرح و نتایج حاصل از هر مرحله گزارش شده است. در پایان به منظور ارزیابی عملکرد نتایج، روش ترکیبی پیشنهادی با روش استفاده‌شده فعلی شرکت مقایسه شده است.

## ۲- پیش‌بینی پژوهش

با استفاده از روش‌های مختلف یادگیری ماشین، مانند خوشه‌بندی و شبکه‌های عصبی، پژوهش‌های بسیاری در حوزه پیش‌بینی تقاضا انجام شده است؛ اما با وجود پیچیدگی بسیار زیاد پیش‌بینی تقاضای کanal همه‌جانبه یکپارچه، تعداد پژوهش‌های کمی در این زمینه دیده شد. برای بررسی شکاف تحقیقاتی، نزدیک‌ترین پژوهش‌هایی بررسی شده است که در زمینه خرده‌فروشی کanal همه‌جانبه یکپارچه، به مبحث تقاضا و بررسی رفتار مشتریان اشاره کرده‌اند.

یورووا و همکاران<sup>۲۰</sup> (۲۰۱۷) در پژوهش خود، مدلی از رفتارهای فروش تطبیقی راهنمگام فروش به مشتریان کanal همه‌جانبه یکپارچه در سراسر جهان توسعه داده‌اند. رفتارهای فروش تطبیقی در قالب دو بعد، سازگاری غیرتعاملی و تعاملی تعریف شده دارند که اثربخشی این دو نوع رفتار، به نوع محصول (مصرفی، تفریحی) و کترول ادراک‌شده مصرف‌کنندگان همه‌جانبه یکپارچه بر وضعیت خرید بستگی دارد. برای آزمون فرضیه‌ها، داده‌های نظرسنجی از OCC‌های جهانی در چهار کشور مختلف جمع‌آوری و با استفاده از تحلیل مسیر ارزیابی شد.

چن و لو<sup>۲۱</sup> (۲۰۱۷) با یکپارچه کردن خوشه‌بندی و یادگیری ماشین، روشی را برای پیش‌بینی تقاضای خرده‌فروشان کanal چندگانه در صنعت خرده‌فروشی لوازم کامپیوتري ارائه دادند. آنها با ترکیب روش خوشه‌بندی کامپیوتري با یادگیری افراطی ماشین<sup>۲۲</sup> و رگرسیون بردار پشتیبان<sup>۲۳</sup> با عنوانی KM-ELM و KM-SVR مدلی بر پایه خوشه‌بندی پیشنهاد و با استفاده از داده‌های فروش کanal آنلاین و فیزیکی، مدل را به تفکیک و به صورت دو سری زمانی مجزا بررسی کردند.

زو و لین<sup>۲۴</sup> (۲۰۱۷) با توجه به ویژگی‌های جریان داده با ابعاد زیاد در رفتار مشتریان، الگوریتم تولید سیناپس بخش‌بندی مشتریان همه‌جانبه یکپارچه را براساس ارزش مشتری ایجاد کردند. الگوریتم خوشه‌بندی جریان داده تکاملی بخش‌بندی، براساس مدل تضعیف زمان و مدل پنجره کشویی استفاده شد. نتایج آزمایش نشان داد الگوریتم ضمن بهبود کارایی زمانی و مکانی، می‌تواند به طور مستقل خوشه‌بندی شود.

پارک و کیم<sup>۲۵</sup> (۲۰۱۸) طبقه‌بندی مصرف‌کنندگان به همراه الگوهای خرید و ترجیحات کanal با استفاده از داده‌های نظرسنجی، سفارش رتبه‌بندی از مصرف‌کنندگان کرمای و آمریکایی در مسیر رفتارهای خریدشان، روش تجزیه و تحلیل خوشه‌ای و کاوش قانون وابستگی<sup>۲۶</sup> برای بخش‌بندی و خصوصیات هر بخش را بررسی کردند. آنها همچنین اهمیت نسبی عوامل مسیر خرید برای تعیین تفاوت‌های مصرف‌کنندگان درباره الگوهای خرید و ترجیحاتشان را ارزیابی کردند و شبکه‌ای از قوانین تفاوت در اولویت خرید و الگوهای مصرف‌کنندگان را در سطوح خرد و کلان به تصویر کشیدند.

فام و همکارانش<sup>۷</sup> (۲۰۲۰) به تعیین ذخیره احتیاطی برای یک محیط کانال همه‌جانبه یکپارچه با روش شبیه‌سازی و تحلیل سناریو براساس زمان بازیبینی، لیدتایم و ذخیره احتیاطی پرداختند. این مطالعه نشان داد مجموع لیدتایم و زمان بازیبینی در تعیین میزان ذخیره احتیاطی، از هر کدام به تنها بی مهمتر بوده است و تغییرات تقاضا که متأثر از رفتار مشتری است، تعیین‌کننده اصلی برای ذخیره احتیاطی است.

پونیا و همکاران<sup>۸</sup> (۲۰۲۰) در پژوهشی، روش جدید پیش‌بینی برای خردۀ فروشی کانال چندگانه را با استفاده از یادگیری عمیق با شبکه‌های حافظه کوتاه‌مدت بلند<sup>۹</sup> و جنگل‌های تصادفی<sup>۱۰</sup> ارائه کردند. عملکرد پیش‌بینی روش پیشنهادی در برابر شبکه‌های عصبی، رگرسیون چندگانه و شبکه‌های اریماکس<sup>۱۱</sup> با استفاده از معیارهای پیش‌بینی عملکرد برای اندازه‌گیری سوگیری، دقت و واریانس محکزده و شواهد تجربی، نشان داد روش پیشنهادی (از لحاظ آماری) به طور درخور توجّهی بهتر است.

آوود و گاناباتی<sup>۱۲</sup> (۲۰۲۰) یک مدل توزیع کانال همه‌جانبه یکپارچه را در صنعت خردۀ فروشی مواد غذایی در آمریکا، از طریق ادغام کانال‌های آنلاین با تابع هدف بهینه‌کردن هزینه‌های عملیاتی توسعه و با روش برنامه‌ریزی غیرخطی عدد صحیح مختلط ارائه دادند. آنها برای بررسی انعطاف‌پذیری و استحکام مدل در زمینه افزایش تقاضا تحت شرایط مختلف، مانند بحران کووید ۱۹، از روش تحلیل سناریو استفاده کردند و همچنین در مطالعه موردی، داده‌های فروش فیزیکی را خارج از حوزه مطالعه در نظر گرفتند.

پیريرا و فرازون<sup>۱۳</sup> (۲۰۲۱) یک رویکرد داده‌محور را برای همگام‌سازی سازگار تقاضا و عرضه در زنجیره‌های تأمین خردۀ فروشی کانال همه‌جانبه یکپارچه ارائه دادند، به کارگیری یادگیری ماشین پیش‌بینی تقاضا را بهبود دادند، از شناسایی قاطع حجم و مکان تقاضا پشتیبانی کردند و با استفاده از بهینه‌سازی مبتنی بر شبیه‌سازی، تعریف کردند که کدام تسهیلات به طور مؤثرتری، به تقاضای شناسایی شده کمک می‌کند. این رویکرد لیدتایم، سفارش‌های عقب‌افتاده ناشی از عرضه و تقاضای ناسازگار محصول و هزینه‌های عملیاتی را کاهش داد؛ گفتنی است که امروزه هر سه، از شاخص‌های کلیدی عملکرد در بازارهای رقابتی خردۀ فروشی هستند.

ریاض و همکاران<sup>۱۴</sup> (۲۰۲۱) نقش رفتار مشتری کانال همه‌جانبه یکپارچه را در رابطه بین خردۀ فروشی همه‌جانبه یکپارچه و تجربه مشتری را از طریق نظرسنجی از ۲۶۵ مشتری کانال همه‌جانبه یکپارچه و نیز برندهای خردۀ فروشی مختلف مد را در پاکستان ارزیابی کردند. نتایج مدل‌سازی معادلات ساختاری حداقل مربعات جزئی، نشان داد خردۀ فروشی همه‌جانبه یکپارچه از طریق عوامل تعیین‌کننده کامل‌بودن کانال، انجام سفارش، قابلیت استفاده و یکپارچگی به بهبود تجربه مشتری کمک می‌کند.

ژاوو و همکاران<sup>۱۵</sup> (۲۰۲۱) ضمن برشمردن حیاتی‌بودن درک رفتار خرید برای مشتریان آنلاین، برای تجارت کanal همه‌جانبه یکپارچه، از مدل RFM<sup>۱۶</sup> و روش خوشبندی کامینز<sup>۱۷</sup>، به ترتیب برای استخراج اطلاعات مشتریان و تقسیم‌بندی مشتریان استفاده کردند. نتایج شبیه‌سازی نشان داد روش پیشنهادی با ارائه نرخ خطای پایین‌تر، نسبت به روش استاندارد کامینز، عملکرد بهتری دارد و می‌تواند متغیرها را به طور همزمان، تحت ۴ سناریوی مختلف انتخاب کند و تعداد آنها را بدون کاهش دقت خوشبندی کاهش دهد.

ون گوین و همکاران<sup>۱۸</sup> (۲۰۲۲)، رفتار تغییر کانال مشتریان کانال همه‌جانبه یکپارچه را در خردۀ فروشی لوازم الکترونیکی بررسی و با اجرای ۲۳ مصاحبه عمیق و چهار گروه مت مرکز، دلایل تغییر کانال خرید و عوامل کلیدی

مؤثر بر انتخاب کanal را در هنگام تعویض شناسایی کردند و در پایان، چارچوبی را برای توضیح رفتار تغییر کanal، تحت نظریه شناختی-اجتماعی ارائه دادند.

عمر و همکارانش<sup>۳۹</sup> (۲۰۲۳) با روش تحلیل داده‌های سبد خرید و تئوری گراف، سه ویژگی درجه، قدرت و حمایت را در محصولات در یک سبد خرید مشتری، با بیش از دو محصول شناسایی و سپس با استفاده از سه ویژگی مذکور، به عنوان متغیرهای ورودی مدل رگرسیون ARIMAX، تقاضا را پیش‌بینی کردند و نشان دادند استفاده از روش مذکور، دقت پیش‌بینی تقاضا را در خرده‌فروشی کanal همه‌جانبه یکپارچه بهبود می‌بخشد. همچنین در پیش‌بینی مشترک کanal‌های آنلاین و فروشگاهی و موجودی مشترک بین هر دو کanal، مزایای درخور توجهی وجود دارد. خلاصهً پژوهش‌های بررسی شده در جدول ۱ ارائه شده است.

جدول ۱- پیشنهاد پژوهش

Table 1-Literature review

ردیف	عنوان	نام و نیزگی‌های پژوهش	ویژگی‌های پژوهش									
			کانال	BODS	محصولات	نمودار						
		کانال	بازبینی									
		روش حل	متغیرهای مورد بررسی									
۱	بوروا و همکاران (۲۰۱۷)	حداقل مربعات جزئی	*	-	-	*	-	-	*	-	-	-
۲	چن و لو (۲۰۱۷)	ترکیب روش خوشبندی کامیز، یادگیری افراطی ماشین و رگرسیون بردار پشتیبان	*	*	-	-	*	*	-	-	-	-
۳	زو و لین (۲۰۱۷)	الگوریتم خوشبندی جریان داده، بر مبنای کامیز	*	*	-	*	-	-	*	-	-	-
۴	پارک و کیم (۲۰۱۸)	تحلیل خوش و کاوشن قانون وابستگی ارزیابی فاکتورهای مسیر تا خرید	*	*	-	*	-	-	-	-	-	-
۵	فام و همکاران (۲۰۲۰)	شبیه‌سازی و تحلیل سناریو براساس زمان بازبینی، لیدتايم و ذخیره احتیاطی	*	*	-	*	-	*	-	*	-	-
۶	پونیا و همکاران (۲۰۲۰)	حافظه طولانی کوتاه-مدت و جنگل تصادفی	*	-	-	*	*	*	-	-	-	-
۷	آوود و گاناپاتی (۲۰۲۰)	برنامه‌ریزی خطی عدد صحیح آمیخته و تحلیل سناریو	*	-	-	-	-	-	*	-	-	-
۸	پیریرا و فرازون (۲۰۲۱)	* یادگیری ماشین و بهینه‌سازی مبتنی بر شبیه‌سازی، با استفاده از الگوریتم ژنتیک	*	-	-	-	*	*	-	*	-	-
۹	ریاض و همکاران (۲۰۲۱)	مدل‌سازی معادلات ساختاری حداقل مربعات جزئی	*	-	-	*	-	-	*	-	-	-
۱۰	ژاوو و همکاران (۲۰۲۱)	خوشبندی کامیز منظم با L1-norm خوشبندی با جرمیمه خالص کشسان با تمرکز بر متغیرهای همبسته	*	-	-	*	-	-	-	*	-	-
۱۱	ون گوین و همکاران (۲۰۲۲)	اصحابه عمیق و گروه متتمرکز	-	-	*	-	-	-	-	*	-	-

روش حل	ویژگی‌های پژوهش										نیزه بیان
	کاتال	محصولات	کاتال	محصولات	کاتال	محصولات	کاتال	محصولات	کاتال	محصولات	
رویکرد مبتنی بر داده‌های سبد، تئوری گراف و ARIMAX	*	-	-	-	*	-	*	-	*	-	۱۲
ترکیب خوشبندی سری‌های زمانی با الگوریتم DTW با شبکه‌های عصبی اتورگرسیو غیرخطی، با و بدون ورودی خارجی	*	*	*	*	*	*	*	*	*	*	۱۳

در پژوهش عمر و همکارانش (۲۰۲۳)، تأثیر رفتار خرید مشتریان و انتخاب کانال‌ها توسط مشتریان در نظر گرفته نشده و از نظر بررسی تأثیر فروش محصولات بر هم، تنها محصولات داخل یک سبد خرید، بررسی شده است. چن و لو (۲۰۱۷) و پونیا و همکارانش (۲۰۲۰)، تقاضا را در محیط کانال چندگانه پیش‌بینی و کانال‌های آنلاین و آفلاین را به صورت مجزا بررسی کردند. پیريرا و فرازون (۲۰۲۱) و عمر و همکارانش (۲۰۲۳)، برای پیش‌بینی تقاضا در کانال همه‌جانبه یکپارچه، فقط کانال‌های آنلاین و آفلاین را در نظر گرفتند و مقوله رفتار خرید مشتریان را در پژوهش‌های خود لحاظ نکردند. همچنین چن و لو از روش k-maen برای خوشبندی استفاده کردند. این روش از فاصله اقلیدسی برای ایجاد خوشه استفاده می‌کند و این در مواردی که طول سری‌های زمانی یکسان نباشد، روش مناسبی نیست.

با توجه به خلاصه پژوهش‌های بررسی شده در خرده‌فروشی کانال‌های همه‌جانبه یکپارچه، می‌توان تأیید کرد که در بیشتر پژوهش‌های انجام شده در این زمینه، به مقوله پیش‌بینی تقاضا براساس درک الگو و رفتار خرید مشتریان به تفکیک کانال‌های خرید و همچنین در نظر گرفتن کانال BODS توجه لازم نشده است. روش خوشبندی به‌دبالت تقسیم‌بندی مشتریان برای شناسایی ویژگی‌های فردی هر خوشه و درنتیجه درک بهتر ویژگی‌های رفتار خرید مشتریان بوده است. هدف اصلی، درک این موضوع است که چگونه فناوری‌ها و اقدامات، اعم از بازاریابی، پیشنهاد محصول، کیفیت خدمات و روابط با مصرف‌کننده، بر نحوه خرید مصرف‌کننده یا چگونگی تغییر پروفایل خرید مصرف‌کننده در بیش از یک کانال تأثیر می‌گذارد و روش‌های مدیریت و عملیاتی کردن فعالیت‌ها را در شرکت‌ها تغییر می‌دهد؛ بنابراین، انجام مطالعه‌ای که نشان‌دهنده چگونگی ترجمه تحلیل پروفایل رفتار مشتری به صورت درج شدنی در مطالعه پیش‌بینی تقاضای زنجیره تأمین خرده‌فروشی کانال همه‌جانبه یکپارچه، به منظور دستیابی به پیش‌بینی تقاضا با دقت بیشتر و درصد خطای کمتر و درنتیجه کاهش عدم قطعیت ناشی از خطای پیش‌بینی تقاضا در کل زنجیره تأمین باشد، ضروری به نظر می‌رسد؛ از این رو نوآوری‌های این پژوهش از نظر مفهومی، شامل در نظر گرفتن رفتار خرید مشتری در پیش‌بینی تقاضای زنجیره تأمین خرده‌فروشی کانال همه‌جانبه یکپارچه با استفاده از خوشبندی، افزودن کانال فروش BODS به کانال‌های فروش و در نظر گرفتن سه کانال آنلاین، آفلاین و به‌طور یکپارچه و همزمان، بررسی تأثیر فروش دیگر محصولات خوشه بر فروش یک محصول (از طریق در

نظر گرفتن عامل خارجی در اتورگرسیو غیرخطی) و از نظر روش، ترکیب خوشبندی سری‌های زمانی به روش پیچش زمانی پویا، با شبکه‌های عصبی اتو رگرسیو غیرخطی دانست.

### ۳- روش شناسی پژوهش

به منظور بررسی روش پیشنهادی، ابتدا داده‌های مطالعه‌شده جمع‌آوری و به منظور حذف داده‌های پرت، پیش‌پردازش انجام و سپس با استفاده از الگوریتم پیچش زمانی پویا خوشبندی شد؛ سپس بر هر خوشبندی یک بار شبکه عصبی اتو رگرسیو غیرخطی و بار دیگر، شبکه عصبی اتو رگرسیو غیرخطی با ورودی بروزنزا اجرا و نتایج پیش‌بینی تقاضا حاصل از شبکه‌های عصبی براساس معیارهای ارزیابی عملکرد، با روش استفاده شده در شرکت مطالعه‌شده، مقایسه شد. مراحل اجرای پژوهش به شرح شکل ۱ است.



شکل ۱- مراحل اجرای پژوهش  
Fig1-Steps of conducting research

### ۱-۱- آماده سازی داده ها و پیش پردازش

به منظور به حداقل رساندن عدم قطعیت درباره تقاضا و درک بهتر رفتار مصرف‌کننده در سناریوی زنجیره تأمین خرده‌فروشی کanal همه‌جانبی یکپارچه، ابتدا داده‌های اولیه جمع‌آوری و سپس در نرم‌افزار صفحه گسترده (اکسل)، داده‌های نامرتبط شناسایی و حذف شد.

### ۲-۲- خوشبندی سری‌های زمانی با الگوریتم پیچش زمانی پویا

خوشبندی یکی از تکنیک‌های مهم داده‌کاوی است که داده‌ها را با توجه به شباهت آنها، به شکل یک کلاس‌بندی بدون ناظارت دسته‌بندی می‌کند که در آن کلاس‌های از پیش تعریف شده وجود ندارد. اندازه‌گیری فاصله به طور گسترشده برای یافتن شباهت/عدم شباهت بین هر دو سری زمانی استفاده می‌شود. دو معیار شناخته شده، معیار فاصله اقلیدسی و معیار فاصله پیچش زمانی پویا، معیارهای مبتنی بر شکل شناخته شده برای داده‌های سری زمانی‌اند. فاصله اقلیدسی، دو نقطه داده را می‌گیرد و آنها را با یکدیگر مقایسه می‌کند؛ اما هر دو سری زمانی باید طول یکسانی داشته باشند (گویجو رویو و همکاران<sup>۳</sup>). پیچش زمانی پویا، کوچک‌ترین فاصله را بین تمام نقاط محاسبه و این امکان، تطابق یک به چند را فراهم می‌کند. برخلاف تابع فاصله اقلیدسی، پیچش زمانی پویا، محدودیت تراز یک به یک را می‌شکند و از سری‌های زمانی با طول غیرمساوی نیز پشتیبانی می‌کند. با استفاده از تکنیک برنامه‌نویسی پویا، برای یافتن تمام مسیرهای ممکن، مسیری انتخاب می‌شود که حداقل فاصله بین دو سری زمانی را با استفاده از یک ماتریس فاصله ایجاد کند و در آن هر عنصر در ماتریس، یک فاصله تجمعی از حداقل سه

همسایه اطراف است. دنباله  $Q$  و  $C$  دو سری زمانی به صورت روابط ۱ و ۲ هستند. در ماتریس  $n \times m$  تشکیل شده، هر عنصر  $(i,j)$  ماتریس، فاصلهٔ تجمعی عنصر  $(i,j)$  و حداقل سه عنصر همسایه  $(i,j)$  است که در آن روابط ۳ و ۴ را داریم.

$$Q = q_1, q_2, \dots, q_i, \dots, q_n \quad \text{رابطه (۱)}$$

$$C = c_1, c_2, \dots, c_j, \dots, c_m \quad \text{رابطه (۲)}$$

$$0 < i \leq n \quad \text{رابطه (۳)}$$

$$0 < j \leq m \quad \text{رابطه (۴)}$$

می‌توان عنصر  $(i,j)$  را به صورت رابطه ۵ تعریف کرد:

$$e_{ij} = d_{ij} + \min \{ e_{(i-1)(j-1)}, e_{(i-1)j}, e_{i(j-1)} \} \quad \text{رابطه (۵)}$$

که در آن  $d_{ij} = (q_i + c_j)^2$  و  $e_{ij}$  عنصر  $(i,j)$  ماتریس جمع بین مجازور فاصلهٔ  $q_i$  و  $c_j$  و حداقل فاصلهٔ تجمعی سه عنصر اطراف، عنصر  $(i,j)$  است؛ سپس برای یافتن یک مسیر بهینه، باید مسیری را انتخاب کرد که حداقل فاصلهٔ تجمعی را در  $(n, m)$  می‌دهد. فاصلهٔ به صورت رابطه ۶ تعریف می‌شود:

$$D_{DTW}(Q, C) = \min \sqrt{\sum_{k=1}^K d_{w_k}} \quad \forall w \in P \quad \text{رابطه (۶)}$$

که در آن  $P$  مجموعه‌ای از تمام مسیرهای پیچش ممکن و  $w_k$  در  $K$  امین عنصر مسیر پیچش و  $K$  طول مسیر پیچش است.

توجه به این نکته بسیار مهم است که در طول محاسبه DTW در معادله (۱)، ممکن است برخی گره‌ها در انتخاب حداقل مقدار از سه عنصر اطراف وجود داشته باشد. در این مورد، الگوریتم می‌تواند به طور دلخواه هر همسایه‌ای را در گره انتخاب کند؛ بنابراین مسیرهای پیچش بهینه متفاوتی را تولید می‌کند، حتی اگر فاصلهٔ پیچش همیشه یکسان باشد (نیاتراکول و راتاناها تانا<sup>۱</sup>، ۲۰۰۷).

### ۳-۳- شبکه‌های عصبی

شبکه‌های عصبی مصنوعی برای مدل‌سازی سری‌های زمانی، به یادگیری ماشینی متکی بوده و از سه نوع لایه تشکیل شده‌اند: لایهٔ ورودی، پنهان و خروجی. در شبکه‌های عصبی مصنوعی تکلایه، تنها یک لایهٔ خروجی وجود دارد و ورودی‌ها مستقیماً به خروجی وارد می‌شوند؛ در حالی که شبکه‌های عصبی چند لایه، از هر سه نوع لایه تشکیل می‌شوند و نوروون‌ها می‌توانند چندین اتصال در نوروون‌های لایه‌های دیگر داشته باشند (کمیچیک و زنگانا<sup>۲</sup>، ۲۰۲۲). شبکهٔ عصبی و انواع آن، به دلیل توانایی ذاتی برای عملکرد بهتر در شناسایی الگوهای تقاضای پیش‌بینی نشدنی و نامطمئن، بهترین و متداولترین روش استفاده شده برای پیش‌بینی تقاضای نامشخص به شمار رفته است.

### ۳-۱- شبکه عصبی اتو رگرسیو غیرخطی<sup>۴۳</sup>

شبکه های عصبی اتو رگرسیو غیرخطی که به اختصار NAR گفته می شود، برای پیش بینی نمونه هایی اند که در یک سری زمانی یک بعدی مدل می شوند. در بیشتر موارد، کاربرد سری زمانی با تغییرات زیاد و دوره های گذرا مشخص می شود. این واقعیت، مدل سازی سری های زمانی را با استفاده از مدل خطی دشوار می کند؛ بنابراین باید یک رویکرد غیرخطی پیشنهاد شود. یک شبکه عصبی NAR برای پیش بینی سری های زمانی، مدلی گسته، غیرخطی و خود رگرسیون را توصیف می کند که می تواند به صورت رابطه ۷ نوشته شود (ابراهیم و همکاران<sup>۴۴</sup>، ۲۰۱۶):

$$y(t) = h(y(t-1), y(t-2), \dots, y(t-p)) + e(t) \quad \text{رابطه (7)}$$

این فرمول نحوه استفاده از شبکه های عصبی NAR را برای پیش بینی مقدار سری های داده  $y$  در زمان  $t$ ،  $y(t)$  با استفاده از  $p$  مقادیر گذشته سری توصیف می کند. تابع  $h(\cdot)$  از قبل ناشناخته است و هدف آموزش شبکه عصبی، تقریب تابع با استفاده از بهینه سازی وزن شبکه و بایاس نورون است. درنهایت، عبارت  $(t)^p$  مخفف خطای تقریب سری  $y$  در زمان  $t$  است.  $p$  ویژگی  $y(t-1), y(t-2), \dots, y(t-p)$  تأخیر بازخورد نامیده می شود. تعداد لایه های پنهان و نورون ها در هر لایه کاملاً منعطف اند و از طریق یک روش آزمون و خطا بهینه سازی می شوند تا تپولوژی شبکه با بهترین عملکرد، به دست آید (ریوز و همکاران<sup>۴۵</sup>، ۲۰۱۶).

### ۳-۲- شبکه عصبی اتورگرسیو غیرخطی با ورودی های برونزا<sup>۴۶</sup>

شبکه های اتورگرسیو غیرخطی با ورودی های برونزا که به اختصار NARX گفته می شود، سری های زمانی چند بعدی را با استفاده از اطلاعات خارجی، برای افزایش عملکرد پیش بینی سری های زمانی توسعه می دهند. شبکه عصبی NARX سری  $y(t)$  را با توجه به  $p$  مقدار گذشته سری  $y$  و یک سری خارجی دیگر  $x(t)$  پیش بینی می کند و می تواند تک یا چند بعدی باشد. معادله ای که رفتار شبکه عصبی NARX را برای پیش بینی سری های زمانی مدل می کند، در رابطه ۸ نشان داده شده است.

$$y(t) = h(x(t-1), x(t-2), \dots, x(t-k), y(t-1), (y(-2), \dots, y(t-p)) + e(t) \quad \text{رابطه (8)}$$

شبکه عصبی NARX یک مدل غیرخطی است که مقادیر آینده سری زمانی را بر اساس آخرین خروجی ها و داده های خارجی آن تخمین می زند. شبکه عصبی NARX با یک ورودی برای سری های زمانی مطالعه شده در زمان  $t-1$ ،  $y(t-1)$  و ورودی دیگر با داده های برونزا در زمان  $t-1$ ،  $x(t-1)$  را برای ارائه استفاده می کند. یک داده خروجی واحد  $y(t)$ ، مربوط به متغیر مطالعه شده است و تنها تفاوت در ورودی می باشد (ریوز و همکاران، ۲۰۱۶).

### ۴- پیش بینی

برای تحلیل فروش محصولات بر اساس کanal فروش و مقایسه روش کنونی استفاده شده شرکت با روش پیشنهادی، ابتدا تقاضا بر اساس روش استفاده شده کنونی شرکت و سپس با روش پیشنهادی برای یک دوره شش ماهه پیش بینی شد. به این منظور، محصولات بر اساس کanal فروش به سه دسته آنلاین، حضوری و BODS تقسیم شدند؛

سپس با استفاده از نرم‌افزار صفحه گسترده (اکسل)، پیش‌بینی فروش محصولات با روش میانگین متحرک<sup>۴۷</sup> به تفکیک در هر کanal، انجام شد؛ سپس برای پیش‌بینی به روشن پیشنهادی تقاضای محصولات با استفاده از شبکه عصبی NAR و NARX درون هر خوشبینی شد.

### ۳-۵- ارزیابی عملکرد

بهمنظور ارزیابی عملکرد برای مشاهده تطبیق معادله پیش‌بینی، از ضریب تعیین  $R^2$  و برای تجزیه و تحلیل دقیق از RMSE استفاده شد. بهترین روش در تجزیه و تحلیل روش‌ها براساس ضریب تعیین  $R^2$ ، روشی خواهد بود که به بالاترین مقدار، نزدیک به ۱ برسد و در تحلیل براساس RMSE روشی است که کمترین مقادیر RMSE را ارائه می‌دهد؛ از این رو در این مقاله، عملکرد روش پیش‌بینی استفاده شده کنونی شرکت مطالعه شده با عملکرد روش پیشنهادی براساس معیارهای مذکور مقایسه شد.

### ۴- مطالعه کاربردی و یافته‌ها

مطالعه موردی در این پژوهش، یک شرکت فروش لوازم آرایشی و بهداشتی با بیش از ۲۰۰۰۰ محصول از حدود ۵۰۰ برنده است که چندین سال فروش فیزیکی داشته و در سال‌های اخیر، فروش اینترنتی و اپلیکیشن را نیز به کanal‌های فروش خود افزوده است و حالا به صورت کanal چندگانه فعالیت می‌کند و به دنبال تغییر سیستم توزیع به کanal همه‌جانبه یکپارچه است. بهمنظور ارزیابی روش پیشنهادی، پنج دسته کلی محصول، متشکل از ۱۴۹۱ نوع محصول انتخاب و داده‌های مربوط به فروش ۳۱ ماه از دی‌ماه ۱۳۹۸ لغایت تیرماه ۱۴۰۱ به تفکیک کanal فروش جمع‌آوری شده است. به دلیل محیط رقابتی و حفظ امانت و به درخواست شرکت، از ذکر نام آن خودداری شد. در ادامه، نتایج کسب شده در هر مرحله، طبق نمودار شکل ۱، به ترتیب ارائه و شرح داده خواهد شد.

### ۴-۱- خوشبندی

با استفاده از خوشبندی سری‌های زمانی با الگوریتم پیچش زمانی پویا در پایتون، داده‌ها به سه خوشبندی تقسیم شدند. خوشبندی یک با ۳۸۱۳ عضو، بزرگ‌ترین و خوشبندی دو با ۱۳ عضو، کوچک‌ترین خوشبندی است. خوشبندی یک و سه محصولات فروش‌رفته در هر سه کanal فروش و خوشبندی دو، محصولات فروش‌رفته در کanal‌های آنلاین و حضوری را دارد. نتایج خوشبندی به‌طور خلاصه در جدول ۲ ارائه شده است.

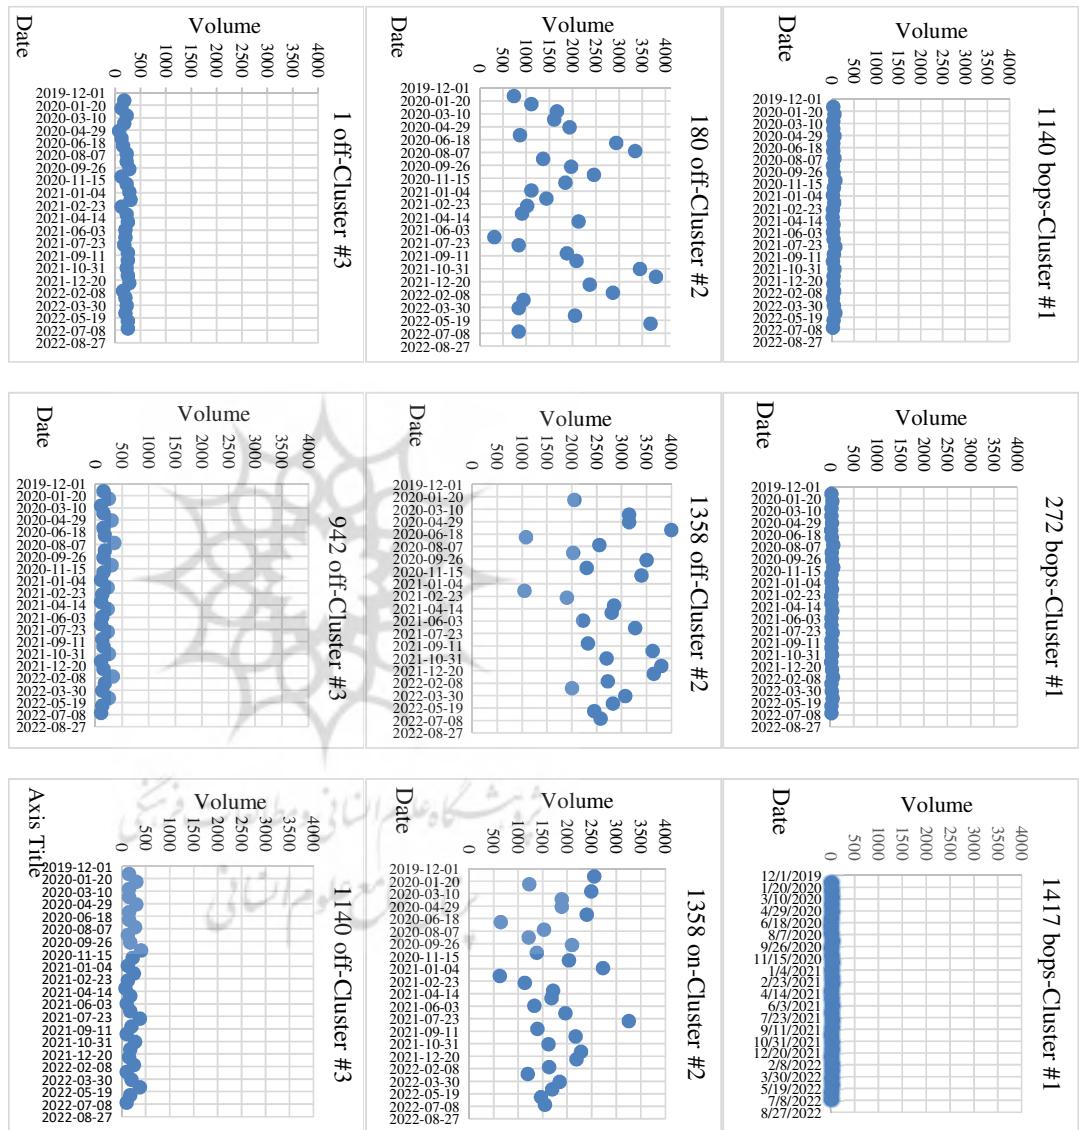
جدول ۲- خلاصه نتایج خوشبندی محصولات

Table2- brief results of clustering

ردیف	خوشبندی کanal فروش			ردیف
	خوشبندی سه	خوشبندی دو	خوشبندی یک	
۱	۱۳	۰	۱۴۷۸	BODS
۲	۴۲۷	۷	۱۰۵۷	حضوری
۳	۲۰۷	۶	۱۲۷۸	آنلاین
	۶۴۷	۱۳	۳۸۱۳	مجموع

نمودار خوشبینی برای محصولات مستحب در نمودار به تکیک خوشه بر اساس میزان فروش برای مقابله\*

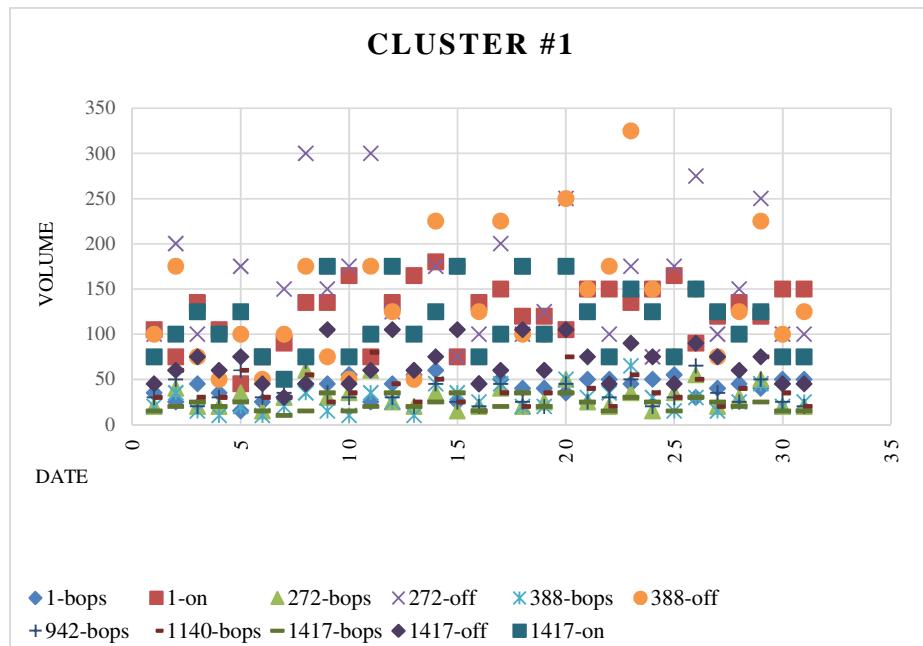
خوشه‌ها در شکل ۲ نشان داده شده است.



شکل ۲- نمودار تطبی خوشها به تکیک خوشه برای محصولات منتخب

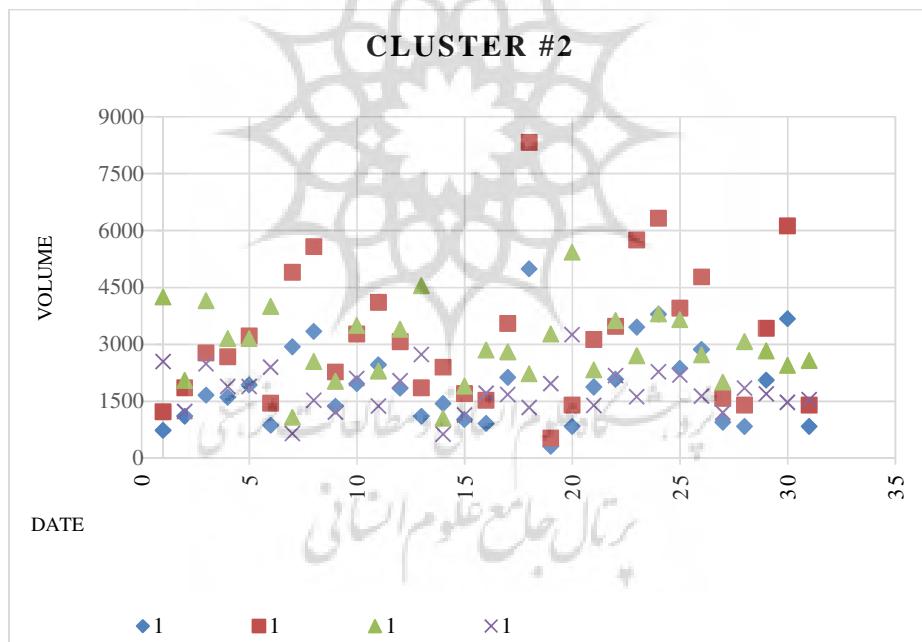
Figure 2- Scatter chart of clusters in order to selected products by clusters

نمودار میزان فروش محصولات مستحب به تکیک خوشه در شکل های ۴، ۳ و ۵ نشان داده شده است.



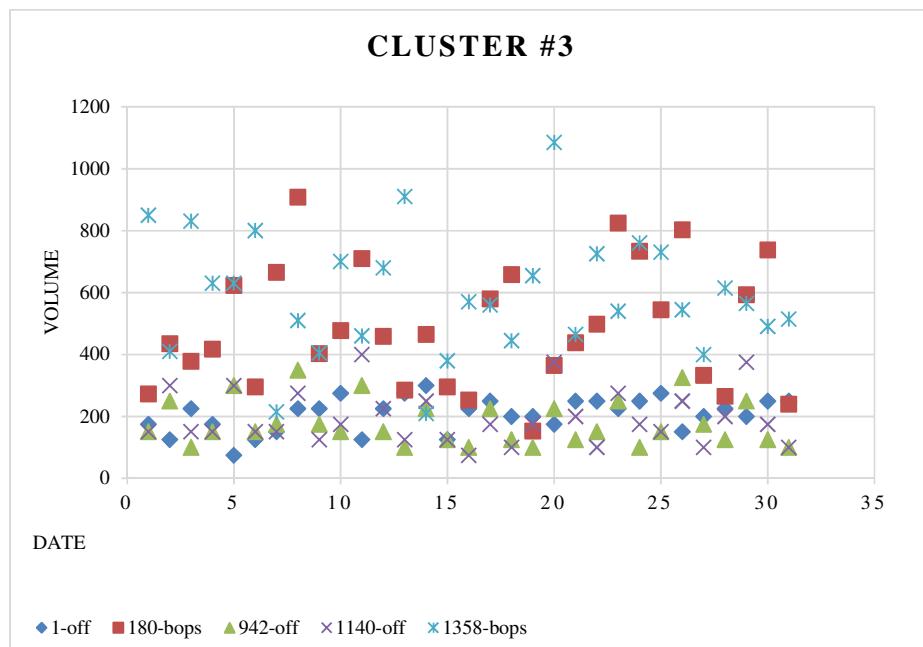
شکل ۳- نمودار فروش محصولات منتخب خوشة یک

Figure 3- Sales chart of selected product in cluster #1



شکل ۴- نمودار فروش محصولات منتخب خوشة دو

Figure 4- Sales chart of selected product in cluster #2



شکل ۵- نمودار فروش محصولات منتخب خوش سه

Figure 5- Sales chart of selected product in cluster #3

#### ۲-۴- شبکه عصبی

به منظور توسعه شبکه عصبی مصنوعی، جعبه ابزار Matlab2018 ntstool از استفاده و برای ارزیابی وجود تأثیر مثبت محصولات درون یک خوش بر پیش‌بینی محصولات دیگر، ۸ محصول انتخاب شد تا عملکرد شبکه عصبی با و بدون متغیر برونزا مقایسه شود. در ابتدا، شبکه عصبی بدون استفاده از متغیر برونزا به سری‌های زمانی محصول، NAR و سپس شبکه عصبی با استفاده از متغیر برونزا و شبکه عصبی NARX اعمال شد. محصولات منتخب برای بررسی شامل سه محصول ۲۷۲، ۳۸۸ و ۱۴۱۷ از خوشیک که فروش از هر سه کانال در همان خوش است، سه محصول ۹۴۲، ۱۱۴۰ و ۱۸۰ که فروش آنلاین و BODS آنها در خوش دو و فروش حضوری آنها در خوش سه و دو محصول ۱۳۵۸ و ۱۸۰ است که فروش آنلاین و حضوری آنها در خوش دو و فروش آنلاین آنها در خوش سه قرار دارد.

داده‌ها با ترکیب ۸۰ درصد آموزش و ۲۰ درصد آزمون، برای تجزیه و تحلیل تقسیم شدند. برای توسعه شبکه عصبی برای پیش‌بینی هر محصول، تعداد لایه‌های پنهان با لایه‌های ۱، ۵، ۱۰ و ۱۵ حاوی همان تعداد نورون ورودی و خروجی آزمایش شد. در NAR یک لایه ورودی و شبکه استاندارد NARX یک شبکه پیشخور دو لایه با تابع انتقال سیگموئید در لایه پنهان و یک تابع انتقال خطی در لایه خروجی در نظر گرفته شد. مقادیر تأخیر ورودی و بازخورد از ۱ تا ۱۲ برای نمایش دوره یک ساله آزمایش و برای آموزش الگوریتم لونبرگ مارکوارت<sup>۴۸</sup> انتخاب شد. متغیر برونزا در این مورد، سری‌های زمانی محصولات دیگر در نظر گرفته شد.

### ۴-۳-۴- اعتبار سنجی

ساختار نتایج براساس بهترین مقدار برای  $R^2$  تست و  $R^2$  کل، کمترین مقدار میانگین مجاز خطا (MSE) و کمترین مقدار ریشه میانگین مجاز خطا (RMSE) برای هر محصول در جدول ۳ گزارش شده است.

جدول ۳- مقایسه نتایج روش‌های پیش‌بینی محصولات منتخب

Table3-Comparison of forecasting method for selected products

کد	$R^2$		RMSE	MSE			تغییر بازخورد	تغییر درودی	فرودن‌های لایه‌های غفبان	روش	نامه محصول
	کل	آذین		کل	آذین	آوزش					
-	-	-	۲۵	-	-	-	-	-	-	MA	۱
۰/۸۰۷	۰/۹۰۸	۰/۶۶۹	۹/۴	۸۸	۷۹	۱۰۴	۱	۱	۱۰	NAR	۱
۰/۹۴۷	۰/۹۴۳	۰/۹۶۱	۹	۸۲	۸۲	۸۵	۱	۱۲	۱۵	NARX	۱
-	-	-	۱۱۹/۳	-	-	-	-	-	-	MA	۱۸۰
۰/۹۳۸	۰/۹۴۵	۰/۶۸۴	۷/۸	۶۰	۴۵	۴۳	۱۲	۱۲	۱۰	NAR	۱۸۰
۰/۹۸۹	۰/۸۹۵	۰/۹۰۹	۷/۴	۵۵	۵۴	۵۲	۱	۱۲	۱۵	NARX	۱۸۰
-	-	-	۴۴/۵	-	-	-	-	-	-	MA	۲۷۲
۰/۸۴۶	۰/۹۰۹	۰/۷۴۱	۸/۵	۷۲	۸۰	۶۱	۱۲	۱	۵	NAR	۲۷۲
۰/۹۴	۰/۹۰۴	۰/۸۶۶	۸/۴	۷۱	۱۰۴	۹۶	۱	۱	۱۵	NARX	۲۷۲
-	-	-	۳۲	-	-	-	-	-	-	MA	۳۸۸
۰/۷۸۶	۰/۹۴۴	۰/۹۸۳	۹/۶	۹۲	۹۰	۹۵	۱	۱۲	۱۰	NAR	۳۸۸
۰/۸۹۴	۰/۹۱۵	۰/۹۴۵	۸	۷۶	۶۳	۷۶	۱۲	۱	۱۰	NARX	۳۸۸
-	-	-	۴۸/۷	-	-	-	-	-	-	MA	۹۴۲
۰/۷۰۳	۰/۹۴۸	۰/۷۸۸	۸/۵	۷۲	۶۱	۷۴	۱۲	۱۲	۱۰	NAR	۹۴۲
۰/۸۱۹	۰/۹۶۹	۰/۹۷۹	۳/۶	۱۳	۱۴۵	۱۱۶	۱	۱	۱۵	NARX	۹۴۲
-	-	-	۱۷/۴	-	-	-	-	-	-	MA	۱۱۴۰
۰/۸۳۵	۰/۹۱۳	۰/۶۶۶	۶/۹	۴۸	۶۶	۳۵	۱۲	۱۲	۱۰	NAR	۱۱۴۰
۰/۷۷۹	۰/۹۹۳	۰/۹	۷	۴۹	۳۸	۵۴	۱	۱	۵	NARX	۱۱۴۰
-	-	-	۳۰۰/۱	-	-	-	-	-	-	MA	۱۳۵۸
۰/۸۱۵	۰/۹۰۹	۰/۸۷۵	۵/۹	۲۵	۳۳	۳۵	۱	۱	۵	NAR	۱۳۵۸
۰/۸۷۶	۰/۹۱	۰/۹۲۵	۲/۳	۱۱	۲۹	۳۷	۱	۱۲	۵	NARX	۱۳۵۸
-	-	-	۱۵/۳	-	-	-	-	-	-	MA	۱۴۱۷
۰/۸۳	۰/۹۷۲	۰/۸۷۳	۶/۸	۴۶	۴۱	۴۶	۱	۱	۱۵	NAR	۱۴۱۷
۰/۹۷۲	۰/۹۷۴	۰/۹۵۶	۶/۵	۴۲	۴۱	۴۱	۱۲	۱۲	۱۰	NARX	۱۴۱۷

## ۵- بحث

خوشبندی محصولات با روش پیچش زمانی پویا انجام شد که ویژگی‌های خوشها به شرح ذیل است. در خوشبندی، حداقل تعداد فروش محصولات، ۵ و حدکثر ۴۵۰ واحد بوده و محصولات این خوش در هر سه کانال آنلاین، حضوری و BODS فروش رفته است و میانگین کل فروش محصولات ۶۹ واحد است. در خوشبندی دو، حداقل تعداد فروش محصولات، ۲۵۰ و حدکثر ۸۳۲۵ واحد بوده و محصولات این خوش در هر دو کانال آنلاین و حضوری فروش رفته است و میانگین کل فروش محصولات ۲۲۹۸ واحد است. در خوشبندی سه حداقل تعداد فروش محصولات ۱۵ و حدکثر ۲۰۵۰ واحد بوده و محصولات این خوش در هر سه کانال آنلاین، حضوری و BODS فروش رفته است و میانگین کل فروش محصولات ۲۵۹ واحد است.

پیش‌بینی تقاضا به سه روش میانگین متحرک، شبکه عصبی NARX و NAR اجرا شد. عملکرد پیش‌بینی تقاضا با NARX برای محصولات ۱، ۹۴۲ و ۱۱۴۰ با در نظر گرفتن مقادیر  $R^2$  تست برتر و به ترتیب مقادیر  $R^2$  برای محصولات ۰/۹۹۳، ۰/۹۶۹، ۰/۹۷۴ و ۰/۹۷۴ بوده است که نشان‌دهنده تطبیق بالا بین مقادیر واقعی استفاده شده برای آزمایش با مقادیر پیش‌بینی شده است. در هنگام تجزیه و تحلیل محصولات ۱۸۰، ۲۷۲، ۳۸۸ و ۱۳۵۸ با در نظر گرفتن مقادیر  $R^2$  تست، به ترتیب ۰/۹۴۵، ۰/۹۴۴، ۰/۹۵۹ و ۰/۹۵۹ می‌توان مشاهده کرد که NAR بهترین عملکرد را داشته است. با وجود این، شایان ذکر است که NAR در  $R^2$  تست خیلی بهتر از NARX عمل نکرده است و با در نظر گرفتن  $R^2$  کل و پایین‌تر بودن مقدار RMSE می‌توان ادعا کرد NARX نتایج بهتری را برای محصولات ۱۸۰، ۲۷۲، ۳۸۸ و ۱۳۵۸ با مقادیر ۰/۸۹۵، ۰/۹۱۵ و ۰/۹۱۰ ارائه کرده است؛ بنابراین توصیه می‌شود از NARX برای پیش‌بینی تقاضای محصولات استفاده شود و بر این نکته تأکید می‌شود که NARX عملکرد خوبی را برای همه محصولات ارائه کرده است؛ بنابراین استفاده از خوشبندی، برای شناسایی الگوی مصرف مشتریان از طریق فروش گذشته محصولات، همراه با شبکه‌های عصبی، روش خوبی برای پیش‌بینی تقاضا برای محصولات زنجیره تأمین خرده‌فروشی کانال همه‌جانبه یکپارچه در نظر گرفته می‌شود.

نظر به اینکه در شبکه عصبی NARX برای پیش‌بینی تقاضای هر محصول، فروش دیگر محصولات آن خوش به عنوان ورودی خارجی در نظر گرفته شده است، استنباط می‌شود که فروش محصولات درون یک خوش، متأثر از فروش یکدیگرند؛ بهخصوص برای محصولاتی که در تمام معیارهای ارزیابی، نتایج بهتری را نسبت به روش NAR کسب کرده‌اند. به بیان دیگر، محصولات مذکور را می‌توان به عنوان محصولات همراه در سبد خرید مشتری در نظر گرفت. استفاده مناسب خرده‌فروشان از این دانش، در طراحی تخفیفات و ترویجات فروش و ارائه بسته‌های پیشنهادی و سفارش محصولات، بسیار مهم و سودآور است.

گفتنی است نزدیک‌ترین پژوهش‌ها به پژوهش حاضر، پونیا و همکاران (۲۰۲۰) و چن و لو (۲۰۱۷) است. هرچند پژوهش‌های ذکر شده از نظر گستردگی و یکپارچگی کانال توزیع بررسی شده است و همچنین نوع روش‌های خوشبندی و یادگیری ماشین به کار گرفته شده، تفاوت‌هایی با پژوهش کنونی دارد؛ اما با توجه به نتایج پژوهش‌های ذکر شده، می‌توان گفت استفاده از ترکیب روش‌های خوشبندی و یادگیری ماشین، به خطای پیش‌بینی کمتر و نتایج دقیق‌تری منجر شده است که این موضوع در پژوهش حاضر نیز تأیید می‌شود و نتایج پژوهش هم راستا با پژوهش‌های یادشده است.

## ۶- نتیجه گیری

با افزایش تعداد کانال‌های فروش، خردهفروشان باید درباره پیش‌بینی تقاضای محصولات خود به منظور کاهش عدم قطعیت، نه تنها فرایندهای خود، کل زنجیره تأمین کانال همه‌جانبه یکپارچه را نیز بازنگری کنند؛ از این رو درک رفتار مشتریان و استفاده از تحلیل آن در فرایندها و عملیات خردهفروشان مهم است و درنتیجه باید روش‌هایی برای پیش‌بینی اتخاذ شود که شناسایی الگوهای را با روش‌های پیش‌بینی ترکیب می‌کند. پیش‌بینی تقاضا برای خردهفروشان کانال همه‌جانبه یکپارچه، نیازمند ترکیب تجزیه و تحلیل الگوهای رفتار خرید مشتریان با روش‌های پیش‌بینی برای بهبود دقت پیش‌بینی است که به کاهش عدم قطعیت زنجیره تأمین خردهفروشی کانال همه‌جانبه یکپارچه منجر می‌شود. در این راستا، این مقاله یک رویکرد پیش‌بینی کننده را برای زنجیره تأمین خردهفروشی کانال همه‌جانبه یکپارچه، با استفاده از الگوریتم خوشبندی و شبکه عصبی مصنوعی، به منظور کاهش عدم قطعیت‌های مربوط به تقاضا، با در نظر گرفتن رفتار خرید مشتری ارائه و از طریق استفاده از روش در یک خردهفروش محصولات آرایشی و بهداشتی، عملکرد آن را تحلیل کرد. به این منظور ابتدا داده‌های فروش شرکت مطالعه شده جمع‌آوری و سپس خوشبندی شد، در هر خوش، یک بار شبکه عصبی NAR و بار دیگر شبکه عصبی NARX اجرا و تقاضا پیش‌بینی شد. بررسی و تحلیل نتایج حاصل از پیش‌بینی شبکه‌های عصبی با روش پیش‌بینی استفاده شده شرکت براساس معیارهای ارزیابی، برترین شرکت شبکه عصبی NARX در پیش‌بینی تقاضای کانال همه‌جانبه یکپارچه را نشان داد.

نتایج به دست آمده می‌تواند چندین کاربرد عملی را به مدیران صنعت خردهفروشی ارائه دهد. مدیران می‌توانند از روش پیشنهادی برای پیش‌بینی دقیق الگوهای پیچیده تقاضا استفاده کنند. استفاده از داده‌های کسب و کار در برنامه‌ریزی تقاضا، مزیت افرودهای را برای مدیران فراهم می‌کند تا متغیرهای مهم را براساس قضاوت خود لحاظ کنند. علاوه بر این، شناخت عوامل مؤثر بر فروش یک دسته خاص از محصول، به طراحی مؤثر رویدادهای تبلیغاتی هدفمند، ترکیبی بهینه از نمایش دسته‌بندی‌ها و بهینه‌سازی فضای قفسه در فروشگاه‌های خردهفروشی کمک می‌کند. علاوه بر این، پیش‌بینی‌های دقیق تقاضا به سیاست‌های سفارش بهتر و درنتیجه به حداقل رساندن هزینه مدیریت موجودی و توزیع بهینه و برنامه‌ریزی لجستیک برای برآوردن تقاضای آتی منجر می‌شود. محدودیت‌هایی در پژوهش حاضر وجود دارد که می‌توان آنها را با تحقیقات آتی برطرف کرد. از نظر روش‌شناسی، شبکه‌های عصبی جدید و پیشرفته‌تر مانند یک شبکه عصبی کانولوشن (CNN)، می‌تواند برای مشکلات پیش‌بینی سری زمانی تطبیق داده شود. همچنین مقایسه عملکرد شبکه‌های عصبی اتورگرسیو غیرخطی با شبکه‌های عصبی یادگیری، به طور عمیق بررسی شدنی خواهد بود. به منظور پیشرفت بیشتر در پیش‌بینی تقاضا در زمینه خردهفروشی کانال همه‌جانبه یکپارچه، باید داده‌های بیشتری را درباره کانال‌های فروش مختلف مانند سفارش آنلاین و ارسال به فروشگاه، سفارش آنلاین و جمع‌آوری از فروشگاه، خرید آنلاین و بازگشت به فروشگاه و غیره جمع‌آوری کرد. با انجام این کار، روش پیشنهادی باید بر الگوهای تقاضای تولیدشده توسط این کانال‌های جدید آزمایش شود. علاوه بر این، زمانی که تقاضا و منابع از کانال‌های متعدد به طور یکپارچه ادغام می‌شوند، ممکن است مدل‌های پیش‌بینی یکسان غالب نباشند و به این ترتیب، این موضوع مهمی برای تحقیقات آینده خواهد بود. برای تعمیم بیشتر در آینده، کاربرد تکنیک‌های یادگیری عمیق باید گسترش یابد و بر داده‌های حوزه‌های دیگر مانند مراقبت‌های بهداشتی، اقتصاد، حمل و نقل و صنایع مختلف آزمایش شود.

## References

- Aouad, W., & Ganapathi, N. (2020). An omnichannel distribution model to better serve online customers. *dspace.mit.edu*. <https://dspace.mit.edu/handle/1721.1/126384>.
- Chen, IF., Lu, CJ. (2017). Sales forecasting by combining clustering and machine-learning techniques for computer retailing. *Neural Comput & Applic* 28, 2633–2647 <https://doi.org/10.1007/s00521-016-2215-x>
- Chopra, S. (2018). The evolution of omni-channel retailing and its impact on supply chains. *Transportation research procedia*, 30, 4-13. <https://doi.org/10.1016/j.trpro.2018.09.002>
- Chui, M., Manyika, J., Miremadi, M., Henke, N., Chung, R., Nel, P., & Malhotra, S. (2018). Notes from the AI frontier: Insights from hundreds of use cases. *McKinsey Global Institute*, 2. <https://www.mckinsey.com/westcoast/~media/McKinsey/Featured%20Insights/Artificial%20Intelligence/Notes%20from%20the%20AI%20frontier%20Applications%20and%20value%20of%20deep%20learning/Notes-from-the-AI-frontier-Insights-from-hundreds-of-use-cases-Discussion-paper.pdf>.
- Faezirad, M., Pooya, A., Naji-Azimi, Z. & Amir Haeri, M. (2021). Demand Prediction in University Booking Systems to Reduce Food Waste Using Neural Networks Including Weighted Error Function. *Industrial Management Journal*, 13(2), 170-193. (In Persian). <https://doi.org/10.22059/IMJ.2021.318760.1007821>
- Fildes, R., & Kingsman, B. (2011). Incorporating demand uncertainty and forecast error in supply chain planning models. *Journal of the Operational Research Society*, 62(3), 483-500. <https://doi.org/10.1057/jors.2010.40>
- Frederick Ross, David (2017). *Distribution Planning and Control: Managing in the Era of Supply Chain Management*. Third edition. Springer.
- Gao, D., Wang, N., He, Z. & Jia, T. (2017). The Bullwhip Effect in an Online Retail Supply Chain: A Perspective of Price-Sensitive Demand Based on the Price Discount in E-Commerce. *IEEE Transactions on Engineering Management*, 64(2), 134–148. <https://doi.org/10.1109/TEM.2017.2666265>
- Guijo-Rubio, D., Durán-Rosal, A. M., Gutiérrez, P. A., Troncoso, A., & Hervás-Martínez, C. (2021). Time-series clustering based on the characterization of segment typologies. *IEEE transactions on cybernetics*, 51(11), 5409-5422. <https://doi.org/10.1109/TCYB.2019.2962584>.
- Hançerlioğulları, G., Şen, A., & Aktunç, E. A. (2016). Demand uncertainty and inventory turnover performance: An empirical analysis of the US retail industry. *International Journal of Physical Distribution & Logistics Management*, 46(6/7), 681-708. <https://doi.org/10.1108/IJPDLM-12-2014-0303>
- Hübner, A., Wollenburg, J. & Holzapfel, A. (2016). Retail logistics in the transition from multi-channel to omni-channel. *International Journal of Physical Distribution & Logistics Management*, 46 (6/7), 562-583. <https://doi.org/10.1108/IJPDLM-08-2015-0179>
- Ibrahim, M., Jemei, S., Wimmer, G., & Hissel, D. (2016). Nonlinear autoregressive neural network in an energy management strategy for battery/ultra-capacitor hybrid electrical vehicles. *Electric Power Syst. Res*, 136, 262–269. <https://doi.org/10.1016/j.epsr.2016.03.005>
- Isasi, N. K. G., Frazzon, E. M., & Uriona, M. (2015). Big data and business analytics in the supply chain: a review of the literature. *IEEE Latin America Transactions*, 13(10), 3382-3391. <https://doi.org/10.1109/TLA.2015.7387245>
- Kerkkänen, A., Korpela, J., & Huiskenen, J., (2009). Demand forecasting errors in industrial context: Measurement and impacts. *International Journal of Production Economics*, 118 (1), 43–48. <https://doi.org/10.1016/j.ijpe.2008.08.008>
- Kmiecik, M., & Zangana, H. (2022). Supporting of manufacturing system based on demand forecasting tool. *LogForum*, 18(1), 33-48. <https://doi.org/10.17270/J.LOG.2022.637>

- Kumar, A., Shankar, R., & Aljohani, N. R. (2020). A big data driven framework for demand-driven forecasting with effects of marketing-mix variables. *Industrial marketing management*, 90, 493-507. <https://doi.org/10.1016/j.indmarman.2019.05.003>
- Niazzkar, M., Eryilmaz Türkkan, G., Niazzkar, H. R., & Türkkan, Y. A. (2020). Assessment of three mathematical prediction models for forecasting the COVID-19 outbreak in Iran and Turkey. *Computational and mathematical methods in medicine*, (2020). Article ID 7056285. <https://doi.org/10.1155/2020/7056285>
- Niennattrakul, V., & Ratanamahatana, C. A. (2007). On clustering multimedia time series data using k-means and dynamic time warping. In *2007 International Conference on Multimedia and Ubiquitous Engineering (MUE'07)*. Seoul, Korea (South), pp. 733-738. <https://doi.org/10.1109/MUE.2007.165>
- Omar, H., Klibi, W., Babai, M. Z., & Ducq, Y. (2023). Basket data-driven approach for omnichannel demand forecasting. *International Journal of Production Economics*, 257, 108748. <https://doi.org/10.1016/j.ijpe.2022.108748>
- Park, J., & Kim, R. B. (2018). A new approach to segmenting multichannel shoppers in Korea and the U.S. *Journal of Retailing and Consumer Services*, 45, 163-178. <https://doi.org/10.1016/j.jretconser.2018.09.007>
- Pereira, M. M., & Frazzon, E. M. (2021). A data-driven approach to adaptive synchronization of demand and supply in omni-channel retail supply chains. *International Journal of Information Management*, 57, 102165. <https://doi.org/10.1016/j.ijinfomgt.2020.102165>
- Pham, T. N., Tan, A., & Ang, A. (2020). Determining safety stock for an omni-channel environment. *International Journal of Information Systems and Supply Chain Management (IJISSCM)*, 13(2), 59-76. <https://doi.org/10.4018/IJISSCM.2020040104>
- Punia, S., Nikolopoulos, K., Singh, S. P., Madaan, J. K., & Litsiou, K. (2020). Deep learning with long short-term memory networks and random forests for demand forecasting in multi-channel retail. *International journal of production research*, 58(16), 4964-4979. <https://doi.org/10.1080/00207543.2020.1735666>
- Rai, H. B., Mommens, K., Verlinde, S., & Macharis, C. (2019). How does consumers' omnichannel shopping behaviour translate into travel and transport impacts? Casestudy of a footwear retailer in Belgium. *Sustainability (Switzerland)*, 11(9), 2534. <https://doi.org/10.3390/su11092534>
- Riaz, H., Baig, U., Meidute-Kavaliauskienė, I., & Ahmed, H. (2021). Factors effecting omnichannel customer experience: evidence from fashion retail. *Information*, 13(1), 12. <https://doi.org/10.3390/info13010012>
- Rooderkerk, R. P., Kök, A. G. (2019). Omnichannel assortment planning. *Operations in an Omnichannel World*, Springer. 51-86. [https://doi.org/10.1007/978-3-030-20119-7\\_4](https://doi.org/10.1007/978-3-030-20119-7_4)
- Ruiz, L. G. B., Cuéllar, M. P., Calvo-Flores, M. D., & Jiménez, M. D. C. P. (2016). An application of non-linear autoregressive neural networks to predict energy consumption in public buildings. *Energies*, 9(9), 684. <https://doi.org/10.3390/en9090684>
- Van Nguyen, A. T., McClelland, R., & Thuan, N. H. (2022). Exploring customer experience during channel switching in omnichannel retailing context: A qualitative assessment. *Journal of Retailing and Consumer Services*, 64, 102803. <https://doi.org/10.1016/j.jretconser.2021.102803>
- Verhoef, P. C., Kannan, P. K., & Inman, J. J. (2015). From multi-channel retailing to omni-channel retailing: introduction to the special issue on multi-channel retailing. *Journal of retailing*, 91(2), 174-181. <https://doi.org/10.1016/j.jretai.2015.02.005>
- Xue, H., & Lin, Y. (2017). The omni-channel consumer segmentation method based on consumption data stream mining. In *2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA)*: 233-238. IEEE. Beijing, China, pp. 233-238, <https://doi.org/10.1109/ICBDA.2017.8078814>.

Yurova, Y., Rippé, C. B., Weisfeld-Spolter, S., Sussan, F., & Arndt, A. (2017). Not all adaptive selling to omni-consumers is influential: The moderating effect of product type. *Journal of Retailing and Consumer Services*, 34, 271-277. <https://doi.org/10.1016/j.jretconser.2016.01.009>

Zhao, H. H., Luo, X. C., Ma, R., & Lu, X. (2021). An Extended Regularized K-Means Clustering Approach for High-Dimensional Customer Segmentation with Correlated Variables. *IEEE Access*, 9, 48405-48412. <https://doi.org/10.1109/ACCESS.2021.3067499>.

<sup>1</sup> Hübner et al.

<sup>2</sup> Verhoef et al.

<sup>3</sup> Omni-channel

<sup>4</sup> Chopra

<sup>5</sup> Supply Chain Management (SCM)

<sup>6</sup> Kerkkänen et al.

<sup>7</sup> Frederick Ross

<sup>8</sup> Rooderkerk & Kök

<sup>9</sup> Gao et al

<sup>10</sup> Davis

<sup>11</sup> Hançerlioğulları et al.

<sup>12</sup> Fildes & Kingsman

<sup>13</sup> Rai et al.

<sup>14</sup> Kumar et al.

<sup>15</sup> Niazkar et al.

<sup>16</sup> Chui et al

<sup>17</sup> Isasi, Frazzon & Uriona

<sup>18</sup> Faezirad et al.

<sup>19</sup> Buy Online Delivery at Store (BODS)

<sup>20</sup> Yurova et al.

<sup>21</sup> Chen and Lu

<sup>22</sup> Extreme Learning Machines (ELMs)

<sup>23</sup> Support Vector Regression (SVR)

<sup>24</sup> Xue and Lin

<sup>25</sup> Park and Kim

<sup>26</sup> Association Rule Mining (ARM)

<sup>27</sup> Pham et al.

<sup>28</sup> Punia et al.

<sup>29</sup> Long Short-Term Memory (LSTM)

<sup>30</sup> Random Forest (RF)

<sup>31</sup> Auto Regressive Integrated Moving Average with Exogeneous Input (ARIMAX)

<sup>32</sup> Aouad & Ganapathi

<sup>33</sup> Pereira & Frazzon

<sup>34</sup> Riaz et al.

<sup>35</sup> Zhao et al.

<sup>36</sup> Recency, Frequency, Monetary (RFM)

<sup>37</sup> K-means

<sup>38</sup> Van Nguyen et al.

<sup>39</sup> Omar et al.

<sup>40</sup> Guijo- Rubio et al.

<sup>41</sup> Niennattrakul & Ratanamahatana

<sup>42</sup> Kmiecik & Zangana

<sup>43</sup> Nonlinear Autoregressive Network (NAR)

<sup>44</sup> Ibrahim et al.

<sup>45</sup> Ruiz et al.

<sup>46</sup> Nonlinear Autoregressive Network with Exogenous Inputs (NARX)

<sup>47</sup> Moving Average (MA)

<sup>48</sup> Levenberg-Marquardt