




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 Tabataba'i University, Tehran, Iran, m.s.soltani8288@gmail.com

**Seyed Mohammad Ali Khatami Firouzabadi \***

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

**Magsoud Amiri**

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

**Mojtaba Hajian Heidary**

Department of Industrial Management, Faculty of Management and Accounting, Allameh Tabataba'i 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, Machine learning, Omnichannel



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

دریافت: ۱۴۰۱/۱۰/۱۱ پذیرش: ۱۴۰۲/۰۲/۰۵ ص ۱۲۱-۱۴۰



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

(مقاله پژوهشی)

## رویکرد ترکیبی پیش‌بینی تقاضای کانال همه‌جانبه یکپارچه، با استفاده از یادگیری ماشین - خوشه‌بندی سری‌های زمانی با الگوریتم پیش‌بینی زمانی پویا و شبکه‌های عصبی مصنوعی

مریم سلطانی<sup>۱</sup>، سیدمحمدعلی 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.s.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:** پذیرش کانال‌های آنلاین و تجارت الکترونیک، به تغییرات مداوم و پویا در صنعت خرده‌فروشی، به‌عنوان یک توسعه اجتناب‌ناپذیر منجر شده و بسیاری از شرکت‌ها را با چالش انتخاب مناسب‌ترین کانال فروش، برای ارائه یک تجربه یکپارچه به مشتریان خود مواجه کرده است. خرده‌فروشی همه‌جانبه یکپارچه، با مفهوم ادغام همه کانال‌ها، ضمن ایجاد تجربه مذکور، باعث افزایش پیچیدگی فرآیندهای پیش‌بینی و برنامه‌ریزی می‌شود. این پژوهش با هدف کاهش عدم اطمینان تقاضای ناشی از خطای پیش‌بینی، از طریق در نظر گرفتن رفتار خرید مشتریان در پیش‌بینی و به کمک استفاده از روش‌های یادگیری ماشین، روشی دقیق‌تر برای پیش‌بینی تقاضای کانال همه‌جانبه یکپارچه ارائه کرده است. به این منظور، ابتدا داده‌های فروش شرکت مطالعه شده، جمع‌آوری و با استفاده از الگوریتم پیش‌بینی زمانی پویا خوشه‌بندی شد؛ سپس بر هر خوشه یک بار شبکه عصبی اتو رگرسیون غیرخطی و بار دیگر، شبکه عصبی اتو رگرسیون غیرخطی با ورودی برون‌زا اجرا و نتایج حاصل از شبکه‌های عصبی با معیارهای ارزیابی عملکرد  $R^2$  و  $RMSE$  با روش استفاده‌شده در شرکت مطالعه شده، مقایسه شد. مقایسه نتایج نشان داد عملکرد شبکه عصبی اتو رگرسیون غیرخطی، با ورودی برون‌زا بر داده‌های خوشه‌بندی شده به روش پیش‌بینی زمانی پویا، برای کاهش خطای پیش‌بینی تقاضا در کانال همه‌جانبه یکپارچه، نسبت به دو روش دیگر برتری دارد.

**واژه‌های کلیدی:** شبکه‌های عصبی مصنوعی، پیش‌بینی تقاضا، الگوریتم پیش‌بینی زمانی پویا، یادگیری ماشین، کانال همه‌جانبه یکپارچه

خرده‌فروشان در طراحی شبکه توزیع می‌توانند با توجه به کسب و کار خود از بین چندین کانال توزیع مختلف، گزینه‌های بهینه را برای سازمان خود پیدا کنند. این کانال‌ها شامل کانال فیزیکی، کانال آنلاین، کانال تلفن همراه، کاتالوگ و در نهایت ترکیبی از این کانال‌هاست. با تمرکز بر دیدگاه لجستیکی، می‌توان سه استراتژی اصلی کانال توزیع را برشمرد. در رویکرد تک‌کانال، خرده‌فروشان فقط از یک کانال فروش و یک سیستم لجستیک اختصاص داده شده برای این کانال جداگانه استفاده می‌کنند.

در رویکرد چند کانال، خرده‌فروشان چندین کانال 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 کانال وجود ندارد (ورهوف و همکاران<sup>۲</sup>، ۲۰۱۵).

در رویکرد کانال همه‌جانبه یکپارچه<sup>۳</sup> پیشرفته، تنها یک رابط لجستیکی مشترک برای مشتری وجود دارد و سفارش‌های آنلاین نیز می‌تواند از طریق فروشگاه‌ها و همچنین سفارش‌هایی پردازش شود که برای تحویل 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 دهند و خریدشان در زمان و مکان دلخواهشان، به آنها تحویل 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 (کرکانن و همکاران<sup>۶</sup>، ۲۰۰۹). نظر به اینکه اینترنت و رقابت جهانی، الزامات را برای معرفی به موقع محصول، مدیریت زنجیره تأمین و تحویل کانال چندگانه تسریع می‌کنند، پیش‌بینی اهمیت بیشتری پیدا کرده است (فردریک راس<sup>۷</sup>، ۲۰۱۷). رویه رایج در میان خرده‌فروشان کانال‌های چندگانه به‌طور سنتی، برنامه‌ریزی و پیش‌بینی کانال‌های مختلف به‌صورت 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 به‌صورت 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 (هانچلیوگلائی 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 خطا 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 در نتیجه به پیش‌بینی دقیق‌تر تقاضا و به سهم خود، به کسب بینش 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 در نتیجه 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 پیشرفته 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 داده‌هاست (نیازکار و همکاران<sup>۱۵</sup>، ۲۰۲۰). از هوش مصنوعی به‌طور فزاینده‌ای به‌عنوان 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 (ایسای، فرازن و اوپونا<sup>۱۷</sup>، ۲۰۱۵). نظر به اینکه در مدل‌های کلاسیک پیش‌بینی، نظیر سری‌های زمانی یا رگرسیون خطی، به تشخیص صحیح فرم توابع به‌صورت 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 به‌درستی توضیح نمی‌دهند، نمی‌توانند به‌خوبی رفتار مصرف‌کننده را پیش‌بینی کنند؛ در حالی که شبکه‌های عصبی به‌دلیل سازگاری با روندهای غیرخطی، ابزار مناسبی برای تقریب غیرخطی و شرایط پیچیده محسوب می‌شوند (فائزادی و همکاران<sup>۱۸</sup>، ۱۴۰۰).

در این مقاله با هدف کاهش عدم قطعیت تقاضای ناشی از خطای پیش‌بینی و خطای فرآیند تقاضا، از روش ترکیبی خوشه‌بندی و شبکه‌های عصبی مصنوعی استفاده شده است. به‌منظور در نظر گرفتن رفتار خرید مشتریان برای کاهش خطای فرآیند، ابتدا محصولات را با توجه به مقدار و کانال فروش آنلاین، حضوری و خرید آنلاین و دریافت از فروشگاه<sup>۱۹</sup> (BODS) خوشه‌بندی و سپس با استفاده از شبکه‌های عصبی مصنوعی برای کاهش خطای پیش‌بینی، تقاضای محصولات در هر خوشه پیش‌بینی 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 کانال 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 به‌منظور ارزیابی عملکرد نتایج، روش ترکیبی پیشنهادی با روش استفاده‌شده فعلی شرکت مقایسه شده است.

## ۲- پیشینه 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 کانال همه‌جانبه یکپارچه، تعداد پژوهش‌های کمی در این زمینه دیده شد. برای بررسی شکاف تحقیقاتی، نزدیک‌ترین پژوهش‌هایی بررسی شده است که در زمینه خرده‌فروشی کانال 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 را هنگام فروش به مشتریان کانال 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 کنترل 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 یکپارچه‌کردن خوشه‌بندی و یادگیری ماشین، روشی را برای پیش‌بینی تقاضای خرده‌فروشان کانال چندگانه در صنعت خرده‌فروشی لوازم کامپیوتری ارائه دادند. آنها با ترکیب روش خوشه‌بندی کامینز با یادگیری افراطی ماشین<sup>۲۲</sup> و رگرسیون بردار پشتیبان<sup>۲۳</sup> با عنوان KM-ELM و KM-SVR مدلی بر پایه خوشه‌بندی پیشنهاد و با استفاده از داده‌های فروش کانال آنلاین و فیزیکی، مدل را به تفکیک و به‌صورت 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 به‌طور مستقل خوشه‌بندی شود.

پارک و کیم<sup>۲۵</sup> (۲۰۱۸) طبقه‌بندی مصرف‌کنندگان به‌همراه الگوهای خرید و ترجیحات کانال با استفاده از داده‌های نظرسنجی، سفارش رتبه‌بندی از مصرف‌کنندگان کره‌ای 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>۲۷</sup> (۲۰۲۰) به تعیین ذخیره احتیاطی برای یک محیط کانال همه‌جانبه یکپارچه با روش شبیه‌سازی و تحلیل سناریو براساس زمان بازبینی، لیدتایم و ذخیره احتیاطی پرداختند. این مطالعه نشان داد مجموع لیدتایم و زمان بازبینی در تعیین میزان ذخیره احتیاطی، از هرکدام به‌تنهایی مهم‌تر بوده است و تغییرات تقاضا که متأثر از رفتار مشتری است، تعیین‌کننده اصلی برای ذخیره احتیاطی است.

پونیا و همکاران<sup>۲۸</sup> (۲۰۲۰) در پژوهشی، روش جدید پیش‌بینی برای خرده‌فروشی کانال چندگانه را با استفاده از یادگیری عمیق با شبکه‌های حافظه کوتاه‌مدت بلند<sup>۲۹</sup> و جنگل‌های تصادفی<sup>۳۰</sup> ارائه کردند. عملکرد پیش‌بینی روش پیشنهادی در برابر شبکه‌های عصبی، رگرسیون چندگانه و شبکه‌های اریماکس<sup>۳۱</sup> با استفاده از معیارهای پیش‌بینی عملکرد برای اندازه‌گیری سوگیری، دقت و واریانس محک‌زده و شواهد تجربی، نشان داد روش پیشنهادی (از لحاظ آماری) به‌طور درخور توجهی بهتر است.

آوود و گاناپاتی<sup>۳۲</sup> (۲۰۲۰) یک مدل توزیع کانال همه‌جانبه یکپارچه را در صنعت خرده‌فروشی 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.

پیریرا و فرازون<sup>۳۳</sup> (۲۰۲۱) یک رویکرد داده‌محور را برای همگام‌سازی سازگار تقاضا و عرضه در زنجیره‌های تأمین خرده‌فروشی کانال همه‌جانبه یکپارچه ارائه دادند، به‌کارگیری 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 به‌طور 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 خرده‌فروشی هستند.

ریاض و همکاران<sup>۳۴</sup> (۲۰۲۱) نقش رفتار مشتری کانال همه‌جانبه یکپارچه را در رابطه بین خرده‌فروشی همه‌جانبه یکپارچه و تجربه مشتری را از طریق نظرسنجی از ۲۶۵ مشتری کانال همه‌جانبه یکپارچه و نیز برندهای خرده‌فروشی مختلف مد را در پاکستان ارزیابی کردند. نتایج مدل‌سازی معادلات ساختاری حداقل مربعات جزئی، نشان داد خرده‌فروشی همه‌جانبه یکپارچه از طریق عوامل تعیین‌کننده کامل‌بودن کانال، انجام سفارش، قابلیت استفاده و یکپارچگی به بهبود تجربه مشتری کمک می‌کند.

ژاو و همکاران<sup>۳۵</sup> (۲۰۲۱) ضمن برشمردن حیاتی‌بودن درک رفتار خرید برای مشتریان آنلاین، برای تجارت کانال همه‌جانبه یکپارچه، از مدل RFM<sup>۳۶</sup> و روش خوشه‌بندی کامینز<sup>۳۷</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 به‌طور هم‌زمان، تحت ۴ سناریوی مختلف انتخاب کند و تعداد آنها را بدون کاهش دقت خوشه‌بندی کاهش دهد.

ون گوین و همکاران<sup>۳۸</sup> (۲۰۲۲)، رفتار تغییر کانال مشتریان کانال همه‌جانبه یکپارچه را در خرده‌فروشی لوازم الکترونیکی بررسی و با اجرای ۲۳ مصاحبه عمیق و چهار گروه متمرکز، دلایل تغییر کانال خرید و عوامل کلیدی

مؤثر بر انتخاب کانال را در هنگام تعویض شناسایی کردند و در پایان، چارچوبی را برای توضیح رفتار تغییر کانال، 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، به‌عنوان متغیرهای ورودی مدل رگرسیون ARIMAX، تقاضا را پیش‌بینی کردند و نشان دادند استفاده از روش مذکور، دقت پیش‌بینی تقاضا را در خرده‌فروشی کانال همه‌جانبه یکپارچه بهبود می‌بخشد. همچنین در پیش‌بینی مشترک کانال‌های آنلاین و فروشگاه‌های و موجودی مشترک بین هر دو کانال، مزایای درخور توجهی وجود دارد. خلاصه پژوهش‌های بررسی شده در جدول ۱ ارائه شده است.

جدول ۱- پیشینه پژوهش

Table 1-Literature review

| ردیف | نویسندگان                | ویژگی‌های پژوهش         |            |  |                                |                   |  |
|------|--------------------------|-------------------------|------------|--|--------------------------------|-------------------|--|
|      |                          | کانال همه‌جانبه یکپارچه | BODS کانال | چند محصولی پیش‌بینی تقاضا رفتار خرید مشتریان | تأثیر متقابل فروش محصولات خوشه | خوشه‌بندی محصولات | مطالعه موردی   |
| ۱    | یوروا و همکاران (۲۰۱۷)   | *                       | -          | -  | *                              | -                 | حدافل مربعات جزئی  |
| ۲    | چن و لو (۲۰۱۷)           | -                       | -          | *  | -                              | *                 | ترکیب روش خوشه‌بندی کامینز، یادگیری افراطی ماشین و رگرسیون بردار پشتیبان                   |
| ۳    | زو و لین (۲۰۱۷)          | *                       | -          | -  | *                              | *                 | الگوریتم خوشه‌بندی جریان داده، بر مبنای کامینز   |
| ۴    | پارک و کیم (۲۰۱۸)        | -                       | -          | -  | *                              | *                 | تحلیل خوشه و کاوش قانون وابستگی ارزیابی فاکتورهای مسیر تا خرید                             |
| ۵    | فام و همکاران (۲۰۲۰)     | *                       | -          | *  | -                              | *                 | شبیه‌سازی و تحلیل سناریو براساس زمان بازیابی، لیدتایم 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 حدافل مربعات جزئی   |
| ۱۰   | ژاوو و همکاران (۲۰۲۱)    | *                       | -          | -  | *                              | *                 | خوشه‌بندی کامینز منظم با L1-norm خوشه‌بندی با جریمه خالص کشسان با تمرکز بر متغیرهای همبسته |
| ۱۱   | ون گوین و همکاران (۲۰۲۲) | *                       | -          | -  | *                              | -                 | مصاحبه عمیق و گروه متمرکز  |



| ردیف | نویسنده‌گان          | ویژگی‌های پژوهش         |            |            |                |                    |                   | روش حل   |
|------|----------------------|-------------------------|------------|------------|----------------|--------------------|-------------------|--|
|      |                      | کانال همه‌جانبه یکپارچه | کانال BODS | چند محصولی | پیش‌بینی تقاضا | رفتار خرید مشتریان | تأثیر متقابل فروش |  |
| ۱۲   | عمر و همکاران (۲۰۲۳) | *                       | -          | -          | *              | -                  | -                 | رویکرد مبتنی بر داده‌های سبد، تئوری گراف و ARIMAX  |
| ۱۳   | پژوهش حاضر           | *                       | *          | *          | *              | *                  | *                 | ترکیب خوشه‌بندی سری‌های زمانی با الگوریتم DTW با شبکه‌های عصبی اتورگرسیو غیرخطی، با و بدون ورودی خارجی |


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 کرده‌اند. پیریرا 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 خوشه‌بندی 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 بررسی‌شده در خرده‌فروشی کانال‌های همه‌جانبه یکپارچه، می‌توان تأیید کرد که در بیشتر پژوهش‌های انجام‌شده 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 خوشه‌بندی به‌دنبال تقسیم‌بندی مشتریان برای شناسایی ویژگی‌های فردی هر خوشه و در نتیجه 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 درج‌شدنی در مطالعه پیش‌بینی تقاضای زنجیره تأمین خرده‌فروشی کانال همه‌جانبه یکپارچه، به‌منظور دستیابی به پیش‌بینی تقاضا با دقت بیشتر و درصد خطای کمتر و در نتیجه 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 خوشه‌بندی، افزودن کانال فروش BODS به کانال‌های فروش و در نظر گرفتن سه کانال آنلاین، آفلاین و BODS به‌طور یکپارچه و هم‌زمان، بررسی تأثیر فروش دیگر محصولات خوشه بر فروش یک محصول (از طریق در

نظر گرفتن عامل خارجی در اتورگرسو غیرخطی) و از نظر روش، ترکیب خوشه‌بندی سری‌های زمانی به روش پیچش زمانی پویا، با شبکه‌های عصبی اتورگرسو غیرخطی دانست.

### ۳- روش شناسی پژوهش

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



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

### ۳-۱- آماده‌سازی داده‌ها و پیش‌پردازش

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

### ۳-۲- خوشه‌بندی سری‌های زمانی با الگوریتم پیچش زمانی پویا

خوشه‌بندی یکی از تکنیک‌های مهم داده‌کاوی است که داده‌ها را با توجه به شباهت آنها، به شکل یک کلاس‌بندی بدون نظارت دسته‌بندی می‌کند که در آن کلاس‌های از پیش تعریف شده وجود ندارد. اندازه‌گیری فاصله به‌طور گسترده 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 زمانی اند. 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>۴</sup>، ۲۰۲۱). 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، فاصله 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 عنصر  $(i,j)$  ماتریس جمع بین مجذور فاصله  $q_i$  و  $c_j$  و حداقل فاصله تجمعی سه عنصر اطراف، عنصر  $(i,j)$  است؛ سپس برای یافتن یک مسیر بهینه، باید مسیری را انتخاب کرد که حداقل فاصله تجمعی را در  $(n, m)$  می‌دهد. فاصله 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 پیش‌مکن و  $w_k$  در  $(i,j)$  در  $k$  امین عنصر مسیر پیش‌مکن و  $K$  طول مسیر پیش‌مکن 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 به‌طور دلخواه هر همسایه‌ای را در گره انتخاب کند؛ بنابراین مسیرهای پیش‌مکن بهینه متفاوتی را تولید می‌کند، حتی اگر فاصله پیش‌مکن همیشه یکسان باشد (نیناتراکول و راتاناماهاتانا<sup>۴۱</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: لایه ورودی، پنهان و خروجی. در شبکه‌های عصبی مصنوعی تک‌لایه، تنها یک لایه 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 نورون‌ها می‌توانند چندین اتصال در نورون‌های لایه‌های دیگر داشته باشند (کمپچیک و زنگانا<sup>۴۲</sup>، ۲۰۲۲). شبکه عصبی و انواع آن، به دلیل توانایی ذاتی برای عملکرد بهتر در شناسایی الگوهای تقاضای پیش‌بینی‌نشده و نامطمئن، بهترین و متداولترین روش استفاده‌شده برای پیش‌بینی تقاضای نامشخص به شمار رفته است.

۳-۳-۱- شبکه عصبی اتورگرسیو غیرخطی<sup>۴۳</sup>

شبکه‌های عصبی اتورگرسیو غیرخطی که به اختصار NAR گفته می‌شود، برای پیش‌بینی نمونه‌هایی اند که در یک سری زمانی یک بعدی مدل می‌شوند. در بیشتر موارد، کاربرد سری زمانی با تغییرات زیاد و دوره‌های گذرا مشخص می‌شود. این واقعیت، مدل‌سازی سری‌های زمانی را با استفاده از مدل خطی دشوار می‌کند؛ بنابراین باید یک رویکرد غیرخطی پیشنهاد شود. یک شبکه عصبی NAR برای پیش‌بینی سری‌های زمانی، مدلی گسسته، غیرخطی و خود رگرسیون را توصیف می‌کند که می‌تواند به صورت رابطه<sup>۷</sup> نوشته شود (ابراهیم و همکاران<sup>۴۴</sup>، ۲۰۱۶):

$$y(t) = h(y(t-1), y(t-2), \dots, y(t-p)) + e(t) \quad (\text{رابطه } ۷)$$

این فرمول نحوه استفاده از شبکه‌های عصبی NAR را برای پیش‌بینی مقدار سری‌های داده<sup>۷</sup> در زمان  $t$ ،  $y(t)$  با استفاده از  $p$  مقادیر گذشته سری توصیف می‌کند. تابع  $h(\cdot)$  از قبل ناشناخته است و هدف آموزش شبکه عصبی، تقریب تابع با استفاده از بهینه‌سازی وزن شبکه و بایاس نورو است. در نهایت، عبارت  $e(t)$  مخفف خطای تقریب سری  $y$  در زمان  $t$  است.  $p$  ویژگی  $y(t-1)$ ،  $y(t-2)$ ، ...،  $y(t-p)$  تأخیر بازخورد نامیده می‌شود. تعداد لایه‌های پنهان و نوروها در هر لایه کاملاً منعطف‌اند و از طریق یک روش آزمون و خطا بهینه‌سازی می‌شوند تا توپولوژی شبکه با بهترین عملکرد، به دست آید (ریوز و همکاران<sup>۴۵</sup>، ۲۰۱۶).

۳-۳-۲- شبکه عصبی اتورگرسیو غیرخطی با ورودی‌های برون‌زا<sup>۴۶</sup>

شبکه‌های اتورگرسیو غیرخطی با ورودی‌های برون‌زا که به اختصار NARX گفته می‌شود، سری‌های زمانی چند بعدی را با استفاده از اطلاعات خارجی، برای افزایش عملکرد پیش‌بینی سری‌های زمانی توسعه می‌دهند. شبکه عصبی NARX سری  $y(t)$  را با توجه به  $p$  مقدار گذشته سری  $y$  و یک سری خارجی دیگر  $x(t)$  پیش‌بینی می‌کند و می‌تواند تک یا چند بعدی باشد. معادله‌ای که رفتار شبکه عصبی NARX را برای پیش‌بینی سری‌های زمانی مدل می‌کند، در رابطه<sup>۸</sup> نشان داده شده است.

$$y(t) = h(x(t-1), x(t-2), \dots, x(t-k), y(t-1), y(t-2), \dots, y(t-p)) + e(t) \quad (\text{رابطه } ۸)$$

شبکه عصبی NARX یک مدل غیرخطی است که مقادیر آینده سری زمانی را براساس آخرین خروجی‌ها و داده‌های خارجی آن تخمین می‌زند. شبکه عصبی NARX با یک ورودی برای سری‌های زمانی مطالعه شده در زمان  $t-1$ ،  $y(t-1)$  و ورودی دیگر با داده‌های برون‌زا در زمان  $t-1$ ،  $x(t-1)$  را برای ارائه استفاده می‌کند. یک داده خروجی واحد  $y(t)$ ، مربوط به متغیر مطالعه شده است و تنها تفاوت در ورودی می‌باشد (ریوز و همکاران، ۲۰۱۶).

## ۳-۴- پیش‌بینی

برای تحلیل فروش محصولات براساس کانال فروش و مقایسه روش کنونی استفاده شده شرکت با روش پیشنهادی، ابتدا تقاضا براساس روش استفاده شده کنونی شرکت و سپس با روش پیشنهادی برای یک دوره شش ماهه پیش‌بینی شد. به این منظور، محصولات براساس کانال 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 کانال، انجام شد؛ سپس برای پیش‌بینی به روش پیشنهادی تقاضای محصولات با استفاده از شبکه عصبی NAR و NARX درون هر خوشه پیش‌بینی شد.

### ۳-۵- ارزیابی عملکرد

به منظور ارزیابی عملکرد برای مشاهده تطبیق معادله پیش‌بینی، از ضریب تعیین  $R^2$  و برای تجزیه و تحلیل دقت 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 استفاده‌شده کنونی شرکت مطالعه‌شده 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 برند است که چندین سال فروش فیزیکی داشته و در سال‌های اخیر، فروش اینترنتی و اپلیکیشن را نیز به کانال‌های فروش خود افزوده است و حالا به صورت کانال چندگانه فعالیت می‌کند و به دنبال تغییر سیستم توزیع به کانال همه‌جانبه یکپارچه است. به منظور 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 کانال فروش جمع‌آوری شده است. به دلیل محیط رقابتی و حفظ امانت و به درخواست شرکت، از ذکر نام آن خودداری شد. در ادامه، نتایج کسب‌شده در هر مرحله، طبق نمودار شکل ۱، به ترتیب ارائه و شرح داده خواهد شد.

### ۴-۱- خوشه‌بندی

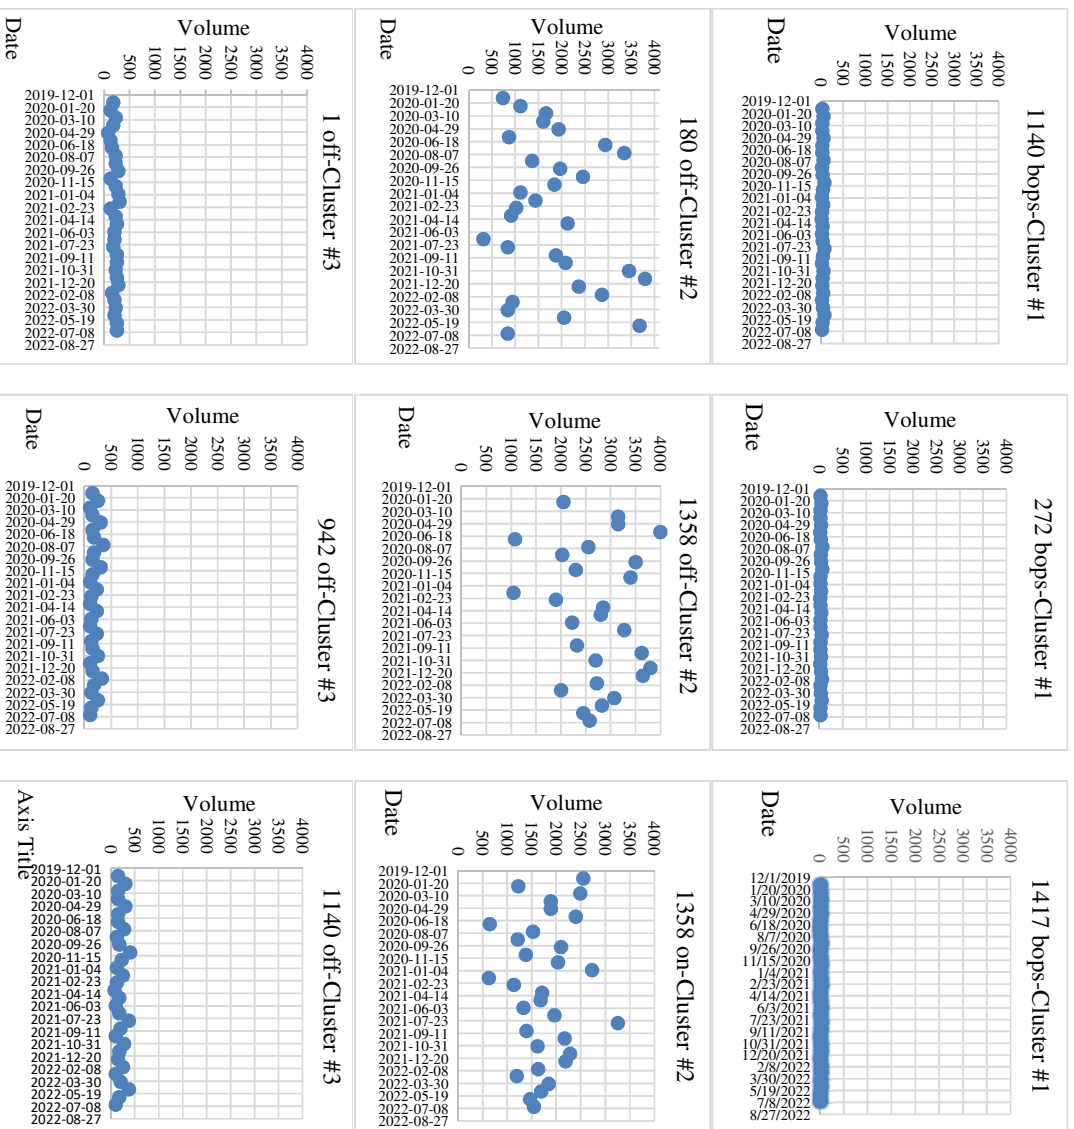
با استفاده از خوشه‌بندی سری‌های زمانی با الگوریتم پیش‌بینی زمانی پویا در پایتون، داده‌ها به سه خوشه تقسیم شدند. خوشه یک با ۳۸۱۳ عضو، بزرگ‌ترین و خوشه دو با ۱۳ عضو، کوچک‌ترین خوشه است. خوشه یک و سه محصولات فروش‌رفته در هر سه کانال فروش و خوشه دو، محصولات فروش‌رفته در کانال‌های آنلاین و حضوری را دارد. نتایج خوشه‌بندی به طور خلاصه در جدول ۲ ارائه شده است.

جدول ۲- خلاصه نتایج خوشه‌بندی محصولات

Table2- brief results of clustering

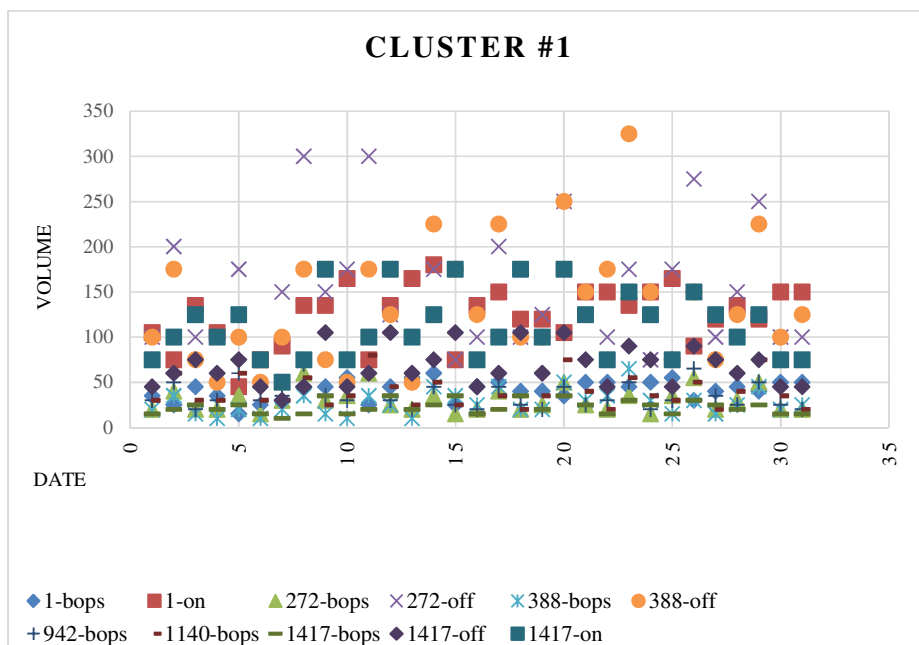
| ردیف | خوشه    |         |         |
|------|---------|---------|---------|
|      | خوشه سه | خوشه دو | خوشه یک |
| ۱    | ۱۳      | ۰       | ۱۴۷۸    |
| ۲    | ۴۲۷     | ۷       | ۱۰۵۷    |
| ۳    | ۲۰۷     | ۶       | ۱۲۷۸    |
|      | ۶۴۷     | ۱۳      | ۳۸۱۳    |
|      |         |         | مجموع   |

نمودار خوشه‌بندی برای محصولات منتخب در نمودار، به تفکیک خوشه براساس میزان فروش برای مقایسه خوشه‌ها در شکل ۲ نشان داده شده است.




شکل ۲- نمودار نقطه‌ای خوشه‌ها به تفکیک خوشه برای محصولات منتخب  
Figure 2- Scatter chart of clusters in order to selected products by clusters

نمودار میزان فروش محصولات منتخب به تفکیک خوشه، در شکل‌های ۳ و ۴ نشان داده شده است.




شکل ۳- نمودار فروش محصولات منتخب خوشه یک

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



شکل ۴- نمودار فروش محصولات منتخب خوشه دو

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



شکل ۵- نمودار فروش محصولات منتخب خوشه سه  
Figure 5- Sales chart of selected product in cluster #3

#### ۲-۴- شبکه عصبی

به منظور توسعه شبکه عصبی مصنوعی، جعبه ابزار ntstool از Matlab2018 استفاده و برای ارزیابی وجود تأثیر مثبت محصولات درون یک خوشه 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 خوشه یک که فروش از هر سه کانال در همان خوشه است، سه محصول ۱، ۹۴۲ و ۱۱۴۰ که فروش آنلاین و BODS آنها در خوشه دو و فروش حضوری آنها در خوشه سه و دو محصول ۱۸۰ و ۱۳۵۸ است که فروش آنلاین و حضوری آنها در خوشه دو و فروش آنلاین آنها در خوشه 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- اعتبارسنجی

ساختار نتایج براساس بهترین مقدار برای  $R^2$  تست و  $R^2$  کل، کمترین مقدار میانگین مجذور خطا (MSE) و کمترین مقدار ریشه میانگین مجذور 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

| شناسه محصول | روش  | نوردهای لایه پنهان | تأخیر ورودی | تأخیر بازخورد | MSE |        |       | R <sup>2</sup> |        |       |       |
|-------------|------|--------------------|-------------|---------------|-----|--------|-------|----------------|--------|-------|-------|
|             |      |                    |             |               | کل  | آزمایش | آموزش | کل             | آزمایش | آموزش |       |
| ۱           | MA   | -                  | -           | -             | -   | -      | -     | -              | -      | -     | ۲۵    |
| ۱           | NAR  | ۱۰                 | ۱           | ۱             | ۸۸  | ۷۹     | ۱۰۴   | ۰/۸۰۷          | ۰/۹۰۸  | ۰/۶۶۹ | ۹/۴   |
| ۱           | NARX | ۱۵                 | ۱۲          | ۱             | ۸۲  | ۸۲     | ۸۵    | ۰/۹۴۷          | ۰/۹۴۳  | ۰/۹۶۱ | ۹     |
| ۱۸۰         | MA   | -                  | -           | -             | -   | -      | -     | -              | -      | -     | ۱۱۹/۳ |
| ۱۸۰         | NAR  | ۱۰                 | ۱۲          | ۱۲            | ۶۰  | ۴۵     | ۴۳    | ۰/۹۳۸          | ۰/۹۴۵  | ۰/۶۸۴ | ۷/۸   |
| ۱۸۰         | NARX | ۱۵                 | ۱۲          | ۱             | ۵۵  | ۵۴     | ۵۲    | ۰/۹۸۹          | ۰/۸۹۵  | ۰/۹۰۹ | ۷/۴   |
| ۲۷۲         | MA   | -                  | -           | -             | -   | -      | -     | -              | -      | -     | ۴۴/۵  |
| ۲۷۲         | NAR  | ۵                  | ۱           | ۱۲            | ۷۲  | ۸۰     | ۶۱    | ۰/۸۴۶          | ۰/۹۵۹  | ۰/۷۴۱ | ۸/۵   |
| ۲۷۲         | NARX | ۱۵                 | ۱           | ۱             | ۷۱  | ۱۰۴    | ۹۶    | ۰/۹۴           | ۰/۹۵۴  | ۰/۸۶۶ | ۸/۴   |
| ۳۸۸         | MA   | -                  | -           | -             | -   | -      | -     | -              | -      | -     | ۳۲    |
| ۳۸۸         | NAR  | ۱۰                 | ۱۲          | ۱             | ۹۲  | ۹۰     | ۹۵    | ۰/۷۸۶          | ۰/۹۴۴  | ۰/۹۸۳ | ۹/۶   |
| ۳۸۸         | NARX | ۱۰                 | ۱           | ۱۲            | ۷۶  | ۶۳     | ۷۶    | ۰/۸۹۴          | ۰/۹۱۵  | ۰/۹۴۵ | ۸     |
| ۹۴۲         | MA   | -                  | -           | -             | -   | -      | -     | -              | -      | -     | ۴۸/۷  |
| ۹۴۲         | NAR  | ۱۰                 | ۱۲          | ۱۲            | ۷۲  | ۶۱     | ۷۴    | ۰/۷۰۳          | ۰/۹۴۸  | ۰/۷۸۸ | ۸/۵   |
| ۹۴۲         | NARX | ۱۵                 | ۱           | ۱             | ۱۳  | ۱۴۵    | ۱۱۶   | ۰/۸۱۹          | ۰/۹۶۹  | ۰/۹۷۹ | ۳/۶   |
| ۱۱۴۰        | MA   | -                  | -           | -             | -   | -      | -     | -              | -      | -     | ۱۷/۴  |
| ۱۱۴۰        | NAR  | ۱۵                 | ۱۲          | ۱۲            | ۴۸  | ۶۶     | ۳۵    | ۰/۸۳۵          | ۰/۹۱۳  | ۰/۶۶۶ | ۶/۹   |
| ۱۱۴۰        | NARX | ۵                  | ۱           | ۱             | ۴۹  | ۳۸     | ۵۴    | ۰/۷۷۹          | ۰/۹۹۳  | ۰/۹   | ۷     |
| ۱۳۵۸        | MA   | -                  | -           | -             | -   | -      | -     | -              | -      | -     | ۳۰۰/۱ |
| ۱۳۵۸        | NAR  | ۵                  | ۱           | ۱             | ۳۵  | ۳۳     | ۳۵    | ۰/۸۱۵          | ۰/۹۵۹  | ۰/۸۷۵ | ۵/۹   |
| ۱۳۵۸        | NARX | ۵                  | ۱۲          | ۱             | ۱۱  | ۲۹     | ۳۷    | ۰/۸۷۶          | ۰/۹۱   | ۰/۹۲۵ | ۳/۳   |
| ۱۴۱۷        | MA   | -                  | -           | -             | -   | -      | -     | -              | -      | -     | ۱۵/۳  |
| ۱۴۱۷        | NAR  | ۱۵                 | ۱           | ۱             | ۴۶  | ۴۱     | ۴۶    | ۰/۸۳           | ۰/۹۷۲  | ۰/۸۷۳ | ۶/۸   |
| ۱۴۱۷        | NARX | ۱۰                 | ۱۲          | ۱۲            | ۴۲  | ۴۱     | ۴۱    | ۰/۹۷۲          | ۰/۹۷۴  | ۰/۹۵۶ | ۶/۵   |

## ۵- بحث

خوشه‌بندی محصولات با روش پیچش زمانی پویا انجام شد که ویژگی‌های خوشه‌ها به شرح ذیل است. در خوشه یک، حداقل تعداد فروش محصولات، ۵ و حداکثر ۴۵۰ واحد بوده و محصولات این خوشه در هر سه کانال آنالین، حضوری و BODS فروش رفته است و میانگین کل فروش محصولات ۶۹ واحد است. در خوشه دو، حداقل تعداد فروش محصولات، ۲۵۰ و حداکثر ۸۳۲۵ واحد بوده و محصولات این خوشه در هر دو کانال آنالین و حضوری فروش رفته است و میانگین کل فروش محصولات ۲۲۹۸ واحد است. در خوشه سه حداقل تعداد فروش محصولات ۱۵ و حداکثر ۲۰۵۰ واحد بوده و محصولات این خوشه در هر سه کانال آنالین، حضوری و BODS فروش رفته است و میانگین کل فروش محصولات ۲۵۹ واحد است.

پیش‌بینی تقاضا به سه روش میانگین متحرک، شبکه عصبی NAR و NARX اجرا شد. عملکرد پیش‌بینی تقاضا با NARX برای محصولات ۱، ۹۴۲، ۱۱۴۰ و ۱۴۱۷ با در نظر گرفتن مقادیر  $R^2$  تست برتر و به ترتیب مقادیر ۰/۹۴۳، ۰/۹۶۹، ۰/۹۹۳ و ۰/۹۷۴ بوده است که نشان‌دهنده تطبیق بالا بین مقادیر واقعی استفاده‌شده 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، ۰/۹۵۹، ۰/۹۴۴ 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، ۰/۹۵۴، 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 خوشه‌بندی، 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 خوشه به‌عنوان ورودی خارجی در نظر گرفته شده است، استنباط می‌شود که فروش محصولات درون یک خوشه، 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 به‌عنوان محصولات همراه در سبد خرید مشتری در نظر گرفت. استفاده مناسب خرده‌فروشان از این دانش، در طراحی تخفیفات و ترویجیات 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 ذکرشده از نظر گستردگی و یکپارچگی کانال توزیع بررسی شده است و همچنین نوع روش‌های خوشه‌بندی و یادگیری ماشین به کار گرفته شده، تفاوت‌هایی با پژوهش کنونی دارد؛ اما با توجه به نتایج پژوهش‌های ذکرشده، می‌توان گفت استفاده از ترکیب روش‌های خوشه‌بندی 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- نتیجه‌گیری

با افزایش تعداد کانال‌های فروش، خرده‌فروشان باید دربارهٔ پیش‌بینی تقاضای محصولات خود به‌منظور کاهش عدم قطعیت، نه‌تنها فرایندهای خود، کل زنجیرهٔ 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 در نتیجه باید روش‌هایی برای پیش‌بینی اتخاذ شود که شناسایی الگوها 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 زنجیرهٔ تأمین خرده‌فروشی کانال همه‌جانبه یکپارچه منجر می‌شود. در این راستا، این مقاله یک رویکرد پیش‌بینی‌کننده را برای زنجیرهٔ تأمین خرده‌فروشی کانال همه‌جانبه یکپارچه، با استفاده از الگوریتم خوشه‌بندی و شبکهٔ عصبی مصنوعی، به‌منظور 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 مطالعه‌شده جمع‌آوری و سپس خوشه‌بندی شد، در هر خوشه، یک بار شبکهٔ عصبی NAR و بار دیگر شبکهٔ عصبی NARX اجرا و تقاضا پیش‌بینی شد. بررسی و تحلیل نتایج حاصل از پیش‌بینی شبکه‌های عصبی با روش پیش‌بینی استفاده‌شده شرکت براساس معیارهای ارزیابی، برتر بودن شبکهٔ 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 کسب‌وکار در برنامه‌ریزی تقاضا، مزیت افزوده‌ای 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 در نتیجه 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 شبکهٔ عصبی کانولوشن (CNN)، می‌تواند برای مشکلات پیش‌بینی سری زمانی تطبیق داده شود. همچنین مقایسهٔ عملکرد شبکه‌های عصبی اتورگرسیو غیرخطی با شبکه‌های عصبی یادگیری، به‌طور عمیق بررسی‌شدنی خواهد بود. به‌منظور پیشرفت بیشتر در پیش‌بینی تقاضا در زمینه خرده‌فروشی کانال همه‌جانبه یکپارچه، باید داده‌های بیشتری را دربارهٔ 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 به‌طور 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., & Huiskonen, 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>
- Niazkar, M., Eryılmaz Türkkkan, G., Niazkar, H. R., & Türkkkan, 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-Kavaliauskiene, 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/10.1007/978-3-030-20119-74>
- 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> Haçerlioğulları 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