

پیش‌بینی تقاضا بر اساس روشهای یادگیری ماشین با تأکید بر محصولات جایگزین در صنعت نساجی

نوید نیکی^۱، رویا محمدعلی پوراهری^۲، هادی شیرویه زاد^۳

گروه مهندسی صنایع، واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران ۱۴۰۳

* Royahari@iau.ac.ir

چکیده

پیش‌بینی تقاضا با دقت بالا باعث کاهش هزینه های انبارداری، بهبود تنوع موجودی و افزایش شاخص تحویل به موقع خواهد شد. محصولات جایگزین به طور معمول در فرآیند تولید به دلیل کمبود محصول اصلی مطرح هستند و لذا پیش‌بینی تقاضا باید به طور مؤثری این جایگزینی‌ها را لحاظ کند. در این تحقیق محصولات جایگزین ابتدا در یک گروه قرار گرفته و پیش‌بینی تقاضا با استفاده از روش‌های ANN, AR, ARIMA, SARIMA, SARIMAX, LSTM بر روی گروه محصول انجام می‌شود با این روش خطای پیش‌بینی حداقل شده و اثر محصولات جایگزین نیز در مدل لحاظ خواهد شد. در ادامه، با استفاده از روش تخصیص متناسب و بر اساس سهم تاریخی فروش هر محصول، تقاضای پیش‌بینی شده برای هر گروه، به طور منطقی بین محصولات درون آن گروه توزیع می‌گردد. در صنعت نساجی، جایگزینی محصول به دلیل کمبود محصول اصلی پر تکرار است لذا در پیش‌بینی تقاضا شناسایی محصولات جایگزین ضروری است. برای این منظور، با استفاده از داده‌های موجود و ویژگی‌های محصولات جایگزین، گروه‌بندی محصولات از طریق الگوریتم‌های یادگیری ماشین^۱ انجام خواهد شد. سپس، پیش‌بینی تقاضا به صورت جداگانه برای هر گروه، با بهره‌گیری از مدل‌هایی که پیش‌تر معرفی شدند، صورت می‌گیرد تا دقت پیش‌بینی افزایش یابد و تأثیر جایگزینی محصولات در فرآیند تقاضا به طور مؤثری لحاظ شود. مراحل پژوهش در یک مطالعه موردی در صنعت نساجی و در شرکت ظریف مصور، پیاده‌سازی شده و اثرات استفاده از پیش‌بینی تقاضا با گروه‌بندی محصولات جایگزین مورد بررسی قرار خواهد گرفت و با توجه به نتایج حاصل از معیار سیلوئت^۲، دسته‌بندی ۲۲۵۳ محصول در ۳۰ خوشه به عنوان ساختار بهینه خوشه‌بندی انتخاب شد، در نهایت نتایج عددی حاصل از پیاده‌سازی مدل نشان می‌دهد که در نظر گرفتن ساختار جایگزینی محصولات، باعث کاهش خطای پیش‌بینی MAPE از ۱۳٫۲٪ به ۶٫۷۲٪ شده است.

واژه‌های کلیدی

پیش‌بینی تقاضا، یادگیری ماشین، محصول جایگزین

۱-مقدمه

پیش‌بینی تقاضا در سیستم‌های زمان‌بندی تولید یکی از چالش‌های اساسی در صنایع مختلف است، زیرا ورودی اصلی هر سیستم برنامه‌ریزی تولید، سفارشات فروش محصولات است. ویژگی‌های فصلی و غیرایستا تقاضا، یک چالش بزرگ در برآورد دقیق تقاضا به شمار می‌روند و نیازمند مدل‌های پیش‌بینی پیچیده و کارآمد هستند. ایجاد یک مدل پیش‌بینی مؤثر که بتواند این چالش‌ها را برطرف کند، از اهمیت زیادی برخوردار است (دانگ و همکاران^۳، ۲۰۲۳) در این راستا، محصولات جایگزین نیز می‌توانند تأثیر زیادی بر پیش‌بینی تقاضا بگذارند. زمانی که محصول اصلی در دسترس نیست، مشتریان معمولاً به خرید محصولات جایگزین روی می‌آورند که خود بر رفتار تقاضا تأثیر می‌گذارد (راجارام و تانگ^۴،

¹ Machine learning

² Silhouette Score

³ Dong et al

⁴ Rajaram & Tang

(۲۰۰۱) برآورد تقاضای سازمان در برنامه‌ریزی و کاهش هزینه‌های سازمان بسیار تاثیرگذار است. زیرا با تغییر میزان تقاضا، هزینه تغییر برنامه تولید، انبارداری و هزینه‌های سازمان افزایش زیادی خواهد داشت. (دانگ و همکاران، ۲۰۲۳) سازمان‌ها به دلیل تغییرات زیاد در تقاضا، نوع محصول و یا شرایط غیرمنتظره نظیر تغییرات نیاز مشتریان و مسائل مربوط به تأمین مواد اولیه، با چالش‌های فراوانی در برنامه‌ریزی و زمان‌بندی تولید محصولات روبه‌رو هستند. (ملایی، ۱۳۹۵) ایجاد گروه‌های محصولات جایگزین در سازمان بسیار حائز اهمیت است زیرا در بسیاری از مواقع می‌توان با تغییر و هدایت تقاضای مشتری به سوی محصولات جایگزین تقاضا در یک محصول را کاهش و تقاضای محصول جایگزین را در جهت کاهش هزینه‌های سازمان افزایش داد (بیرچال و همکاران، ۲۰۲۴).

پیش‌بینی تقاضا به تحلیل الگوهای مصرف در بازار پرداخته و نقش مهمی در کاهش عدم قطعیت و بهبود تصمیم‌گیری‌های تولید دارد (چا و همکاران، ۲۰۲۴). تغییرات متغیرهای محیطی می‌تواند تفاوت زیادی میان پیش‌بینی و فروش واقعی ایجاد کند (دانگ و همکاران، ۲۰۲۳). یادگیری ماشین با قابلیت پردازش داده‌های پیچیده، امکان ارائه پیش‌بینی‌های دقیق‌تری را فراهم می‌سازد. (شریفانی و امینی، ۲۰۲۳) الگوریتم‌هایی مانند LSTM، ANN، ARIMA و SARIMA از جمله روش‌هایی هستند که در مطالعات پیشین برای پیش‌بینی به کار رفته‌اند (امامی جوانمرد و قادری، ۲۰۲۳). همچنین، محصولات جایگزین که معمولاً از نظر ویژگی‌های اصلی مشابه هستند، می‌توانند در صورت نیاز جایگزین یکدیگر شوند و اثر قابل توجهی بر رفتار تقاضا دارند (موناردو، ۲۰۲۱).

تحقیقات پیشین در این زمینه عمدتاً بر پیش‌بینی تقاضا تمرکز داشته‌اند و کمتر به ویژگی‌های جایگزینی محصولات پرداخته‌اند. برای نمونه، امامی جوانمرد و قادری (۲۰۲۳)، در تحقیق خود مصرف انرژی را با استفاده از روش‌های یادگیری ماشین به دست آوردند. دوگان و همکاران^{۱۰} (۲۰۲۴) تکنیک‌های شبکه عصبی کانولوشن (CNN) و حافظه کوتاه‌مدت (LSTM) را که هر دو تکنیک‌های یادگیری عمیق هستند، برای برآورد تقاضای بار الکتریکی ترکیب نمودند. سلطانی و همکاران (۱۴۰۲) به کاهش عدم قطعیت تقاضا از طریق افزایش دقت پیش‌بینی با ترکیب روش‌های خوشه‌بندی و شبکه‌های عصبی پرداخته‌اند. پژوهش‌های انجام‌شده پیش از این عمدتاً بر پیش‌بینی تقاضا تمرکز داشته‌اند، اما در آن‌ها به موضوع تعیین ویژگی‌های جایگزینی محصولات و دسته‌بندی کالاهای جایگزین توجهی نشده است. در حالی که در عمل، در صورت نبود محصول اصلی، مشتریان اغلب به خرید محصول جایگزین روی می‌آورند. این رفتار مصرف‌کننده تأثیر مستقیم بر روند تقاضا و دقت پیش‌بینی دارد و نادیده گرفتن آن می‌تواند منجر به بروز خطا در برآورد تقاضا شود. هدف تحقیق حاضر پیش‌بینی تقاضا با دقت بالا و لحاظ نمودن اثر جایگزینی محصولات می‌باشد از این رو ابتدا گروه بندی محصولات در صنعت نساجی با رویکرد تعریف محصولات جایگزین انجام خواهد شد سپس با استفاده از روش‌های یادگیری ماشین پیش‌بینی تقاضا در دو حالت با و بدون در نظر گرفتن محصول جایگزین انجام و اعتبارسنجی خواهد شد.

۲- روش تحقیق

پژوهش حاضر از نوع بنیادی و کاربردی بوده و برای حل یک مسئله واقعی در صنعت نساجی طراحی شده است. مراحل تحقیق به صورت زیر است:

۱،۲. شناسایی عوامل مؤثر بر جایگزینی محصولات: در گام نخست، با بررسی ویژگی‌های فنی و ظاهری محصولات، عواملی نظیر وزن، جنس، نوع محصول، گروه محصول، رنگ، عرض، ارتفاع پایل و قیمت فروش به عنوان معیارهای اصلی برای سنجش شباهت بین محصولات استخراج شد.

⁵ Birchall and et al

⁶ Chae et al

⁷ Sharifani & Amini

⁸ Emami javanmard & ghaderi

⁹ Monardo

¹⁰ Doğan et al.


۲,۲. خوشه‌بندی محصولات جایگزین با الگوریتم $K-Means$: با استفاده از داده‌های تاریخی فروش و ویژگی‌های استخراج‌شده، الگوریتم خوشه‌بندی $K-Means$ جهت گروه‌بندی محصولات مشابه به کار گرفته شد. انتخاب تعداد خوشه‌ها بر مبنای شاخص Silhouette انجام شد (نمودار شماره ۱)، تا همگنی درون گروهی و تفکیک‌پذیری بین گروه‌ها به حداکثر برسد.

۳,۲. پیش‌بینی تقاضای گروه‌های محصول: پس از خوشه‌بندی، داده‌های مربوط به هر گروه به‌طور جداگانه وارد مدل‌های پیش‌بینی شامل AR , ANN , $SARIMA$, $SARIMAX$ و $LSTM$ شد. برای ترکیب خروجی این مدل‌ها، یک مدل بهینه‌سازی طراحی گردید که در آن وزن هر مدل به‌صورت پویا بر اساس دقت پیش‌بینی تعیین می‌شد. این مدل ترکیبی بر پایه پژوهش امامی جوانمرد و قادری (۲۰۲۳) توسعه داده شد.

۴,۲. تخصیص تقاضای پیش‌بینی‌شده به محصولات داخل هر گروه: در گام نهایی، تقاضای پیش‌بینی‌شده برای هر گروه، با استفاده از روش تخصیص متناسب و بر اساس سهم تاریخی فروش محصولات، به‌صورت منطقی بین اعضای گروه توزیع گردید.

۳- یافته‌های تحقیق

در این بخش، برای تحلیل داده‌ها از روش خوشه‌بندی $KMeans$ استفاده شد. داده‌ها شامل ۸ ویژگی اصلی، وزن، جنس، گروه محصول، نوع محصول، رنگ، عرض، ارتفاع پایل و قیمت فروش محصولات مختلف بودند که پس از پیش‌پردازش و تبدیل مقادیر کیفی به عددی، با استفاده از الگوریتم خوشه‌بندی به دسته‌های همگن تقسیم شدند اگر محصولات از نظر این ۸ ویژگی به هم نزدیک بودند از نظر مشتری قابلیت جایگزینی با یکدیگر را داشتند. جهت تعیین تعداد بهینه خوشه‌ها، از معیار Silhouette Score استفاده گردید. همان‌طور که در نمودار شماره ۱ مشاهده می‌شود، افزایش تدریجی تعداد خوشه‌ها موجب بهبود شاخص سیلوئت گردیده و در نتیجه، ساختار خوشه‌بندی مناسبی برای گروه‌بندی محصولات ایجاد می‌کند. محصولات موجود در هر خوشه قابلیت جایگزینی با یکدیگر را از نظر مشتریان دارند زیرا ویژگی‌های آنها شبیه به یکدیگر است.



نمودار شماره ۱: تغییرات امتیاز سیلوئت با افزایش تعداد خوشه‌ها

در نمودار ۲، نتایج خوشه‌بندی نشان می‌دهد که داده‌ها به‌صورت متمایز در خوشه‌های مختلف قرار گرفته‌اند که بیانگر عملکرد مناسب الگوریتم در تفکیک نمونه‌ها می‌باشد.



نمودار شماره ۲: نمایش خوشه‌بندی داده‌ها با استفاده از PCA

پس از پیاده سازی مدل پیشنهادی، عملکرد آن در دو حالت با و بدون گروه بندی محصولات جایگزین مقایسه شد. نتایج نشان داد که در حالت دسته بندی شده، دقت پیش بینی به طور قابل توجهی افزایش یافته و مقدار خطای MAPE از ۱۳٫۲ درصد به ۶٫۷۲ درصد کاهش یافته است. این کاهش بیانگر تأثیر مثبت لحاظ کردن ساختار جایگزینی محصولات در بهبود دقت پیش بینی تقاضا است.

۴- نتیجه گیری

پیش بینی دقیق تقاضا یکی از ارکان اصلی موفقیت در زنجیره تأمین و برنامه ریزی تولید به شمار می رود، به ویژه در صنایعی نظیر نساجی که با نوسانات بالا در سفارشات و محدودیت های تأمین مواجه هستند. پژوهش حاضر با تمرکز بر اثر محصولات جایگزین، مدلی ترکیبی مبتنی بر یادگیری ماشین ارائه نموده که با بهره گیری از خوشه بندی، گروه بندی محصولات جایگزین را انجام داده و سپس از الگوریتم های پیشرفته پیش بینی برای تحلیل تقاضا استفاده کرده است. یافته های تحقیق نشان داد که در نظر گرفتن ساختار جایگزینی میان محصولات، تأثیر چشمگیری بر کاهش خطای پیش بینی دارد. به طور خاص، در حالت بدون گروه بندی محصولات جایگزین، میزان خطای پیش بینی برابر با ۱۳٫۲ درصد بود، در حالی که در حالت مدل پیشنهادی، این مقدار به ۶٫۷۲ درصد کاهش یافت. این بهبود دقت، نشان دهنده اهمیت لحاظ نمودن رفتار مصرف کننده در انتخاب محصولات جایگزین در فرآیند پیش بینی تقاضا می باشد. با توجه به نتایج، گسترش مدل برای صنایع دیگر و ادغام مدل پیش بینی با سیستم های برنامه ریزی تولید، می توانند به عنوان پیشنهادهایی برای تحقیقات آینده مطرح شوند.

۵- مراجع

- [1] سلطانی، مریم؛ خاتمی فیروزآبادی؛ امیری، سیدمحمدعلی؛ حاجیان، مقصود و حیدری، مجتبی. ۱۴۰۲. رویکرد ترکیبی پیش بینی تقاضای کانال همه جانبه ی یکپارچه، با استفاده از یادگیری ماشین: خوشه بندی سری های زمانی با الگوریتم پیچش زمانی پویا و شبکه های عصبی مصنوعی. مدیریت تولید و عملیات، ۱۴(۱)، ۱۴۰-۱۲۱. doi: 10.22108/pom.2023.136202.1485
- [2] Birchall, C., Mohapatra, D., & Verboven, F. 2024. Estimating substitution patterns and demand curvature in discrete-choice models of product differentiation. *The Review of Economics and Statistics*, 9(1), 1–40. doi: 10.1162/rest_a_01463.
- [3] Chae, B. K., Sheu, C., & Park, E. O. 2024. The value of data, machine learning, and deep learning in restaurant demand forecasting: Insights and lessons learned from a large restaurant chain. *Decision Support Systems*, 184(1), 114291. doi: 10.1016/j.dss.2024.114291.
- [4] Emami Javanmard, M., & Ghaderi, S. F. 2023. Energy demand forecasting in seven sectors by an optimization model based on machine learning algorithms. *Sustainable Cities and Society*, 95(1), 104623. doi: 10.1016/j.scs.2023.104623.
- [5] Monardo, J. 2021. Measuring substitution patterns with a flexible demand model. *SSRN Electronic Journal*. doi: 10.2139/ssrn.3921601.
- [6] Rajaram, K., & Tang, C. S. 2001. The impact of product substitution on retail merchandising. *European Journal of Operational Research*, 135(2), 582–601. doi: 10.1016/S0377-2217(01)00021-2.
- [7] Sharifani, K., & Amini, M. 2023. Machine learning and deep learning: A review of methods and applications. *SSRN Electronic Journal*. doi: 10.2139/ssrn.4458723.
- [8] Yıldız Doğan, G., Aksoy, A., & Öztürk, N. 2024. A hybrid deep learning model to estimate the future electricity demand of sustainable cities. *Sustainability*, 16(15), 6503. doi: 10.3390/su16156503.