



بهبود عملکرد موجودی مبتنی بر پیش‌بینی تقاضا با خوشه بندی مشتریان

یاسر تقی نژاد

کارشناس ارشد مدیریت صنعتی گرایش OR، دانشکده مدیریت و حسابداری، پردیس فارابی دانشگاه تهران

Email: taghinezhad89@ut.ac.ir

تاریخ دریافت: ۹۶/۲/۲۲ * تاریخ پذیرش: ۹۶/۹/۱

چکیده

مدیریت صحیح و کنترل بهتر موجودی اقلام فروشگاه مواد غذایی، یکی از ضروری ترین و مهم ترین اهداف مدیران فروشگاه‌های مواد غذایی می‌باشد. در این مطالعه تلاش می‌شود تا دانش تقسیم‌بندی مشتریان را بر اساس ویژگی‌های مختلف به عنوان ورودی در پیش‌بینی تقاضای یک خرده‌فروشی ارائه دهد. هدف این مقاله ارائه یک مدل پیش‌بینی برای خرده‌فروشان بر اساس خوشه بندی مشتریان، به منظور بهبود عملکرد موجودی می باشد. خوشه بندی مشتریان با الگوریتم ژنتیک در نرم افزار MATLAB R2016a صورت گرفته است. مدل ارائه شده برای پیش‌بینی تقاضای پنج قلم کالای یک سوپرمارکت در شهر گرگان به کار گرفته شده است. در این مقاله، جهت پیش‌بینی از مدل‌های ARIMA، فصلی، شبکه عصبی پیشخور Mlp و شبکه عصبی GMDH استفاده شده است. مدلسازی این مدل‌ها در نرم افزار متلب صورت گرفته است. نتایج نشان داد که شبکه عصبی GMDH با خوشه بندی مشتریان کمترین خطای پیش‌بینی را دارد. مدل پیش‌بینی ارائه شده با سیاست کنترل دوره ای سطح موجودی منجر به کاهش روزهای مواجه با کمبود و افزایش سطح خدمت به مشتری می‌شود. خرده‌فروشان می‌توانند مدل ارائه شده را برای پیش‌بینی تقاضای اقلام گوناگون به منظور بهبود عملکرد موجودی و سودآوری عملیات مورد استفاده قرار دهند.

کلمات کلیدی: پیش‌بینی، داده‌کاوی، شبکه عصبی، مدیریت موجودی، هوش مصنوعی.

۱- مقدمه

سیستم‌های مدیریت زنجیره تأمین و سیستم‌های هوشمند در دو دهه اخیر رشد قابل ملاحظه‌ای؛ در بهبود مدیریت موجودی انبار با توجه به پیش‌بینی تقاضا، کرده‌اند. هرچند، رشد این دو بیشتر به صورت جداگانه صورت گرفته است (Kumar Bala, 2012). همچنین سیستم‌های فروشگاه‌های زنجیره‌ای با یک دوره تغییرات بی‌سابقه در رابطه با شناسایی تقاضای مشتریان از سیستم‌های دستی کنترل موجودی به سیستم‌های کامپیوتری تغییر یافت (Ghasemi, Taghinezhad & Fani, 2017). در دو دهه قبل، خرده‌فروشی یک تغییرات بی‌سابقه را در رابطه با پیش‌بینی تقاضای محصولات خود از جانب مشتریان داشته و رقابت در صنعت خرده‌فروشی از سیستم‌های دستی کنترل موجودی به سیستم‌های کامپیوتری تحول یافته است. خرده‌فروشان با سیستم‌های کامپیوتری پیچیده برای پیش‌بینی بهتر و بهبود مدیریت موجودی نسبت به دیگران به لحاظ سودآوری حاشیه امنی را ایفا کرده‌اند. در ابتدا، این سیستم‌های پیچیده تنها به وسیله تعداد کمی از سوپرمارکت‌ها مورداستفاده قرار می‌گرفتند. به تدریج سایر خرده‌فروشان آن را برای رقابت در کسب‌وکار خود ضروری یافتند (Bala, 2012). در یک فروشگاه خرده‌فروشی نمونه اقلام خوراکی، موجودی کالا در انبار در حدود چند هزار قلم کالا و در یک سوپرمارکت بزرگ، معمولاً بیش از ۵۰۰۰۰ نوع قلم کالا وجود دارد. خرده‌فروشان این اقلام را از یک تعداد توزیع‌کنندگان عمده و در برخی مواقع مستقیماً از تولیدکنندگان خریداری می‌کنند. برای هر قلم کالا، مدیران موجودی (انبار) در خصوص زمان خرید، مقدار خرید و فروشنده موردنظر تصمیم می‌گیرند. پیش‌بینی کارآمد برای تقاضای آتی کلید موفقیت در مدیریت موجودی می‌باشد (Thall, 1992). تقاضای آتی یک قلم کالا به تعداد زیادی از عوامل بستگی دارد و پیش‌بینی تقاضای آتی، برای خرده‌فروشان یک امر چالشی (مشکل‌ساز) شده است. کار پژوهشی کنونی، یک مدل هوش کسب‌وکار^۱ بر مبنای داده‌کاوی^۲ برای پیش‌بینی تقاضا و کاربرد آن در بهبود و ارتقای عملکرد موجودی اقلام یک خرده‌فروشی در شهر گرگان می‌باشد. این مدل با استفاده از تقسیم‌بندی مشتریان بر اساس خوشه‌بندی^۳، به عنوان یک ورودی برای مدل‌های پیش‌بینی ارائه شده است. تقسیم‌بندی مشتریان در خوشه‌ها با استفاده از تکنیک الگوریتم ژنتیک در نرم‌افزار متلب بر اساس ویژگی‌های جمعیت‌شناختی^۴ مشتریان و سایر جزئیات انجام شده است. بهبود دقت و صحت پیش‌بینی تقاضا می‌تواند منجر به پس‌انداز مالی، رقابت‌پذیری بیشتر، افزایش روابط و رضایت مشتری شود (Moon, 2003). اهمیت پیش‌بینی دقیق فروش برای کارآمد نمودن مدیریت موجودی از دیرباز شناخته شده است (Barksdale & Hilliard, 1975)؛ و همچنین پیش‌بینی دقیق تقاضا نقش حیاتی را در عملیات فروش سودآور ایفا می‌کند و پیش‌بینی ضعیف منجر به کمبود یا مازاد موجودی شده که به‌طور مستقیم سودآوری و موقعیت رقابتی فروش را تحت تأثیر قرار می‌دهد (Thall, 1992). مدیریت موفق موجودی تا حد زیادی به پیش‌بینی دقیق فروش بستگی دارد (Thall, 1992) و (Agrawal & Schorling, 1996). رایج‌ترین کار برای پیش‌بینی تقاضا در برنامه‌ریزی زنجیره تأمین، استفاده از یک سیستم نرم‌افزار آماری است که شامل یک روش پیش‌بینی تک متغیره ساده همچون هموارسازی نمایی^۵ می‌باشد تا یک پیش‌بینی اولیه ارائه دهد (Fildes et al, 2009). یکی از مشکلات کلیدی که در مدل‌های پیش‌بینی فروش محصول جدید با آن روبه‌رو هستیم، وجود تعداد فراوانی از مدل‌های پیش‌بینی است که معیارهای اندکی در انتخاب مؤثرترین آن‌ها برای یک استفاده خاص وجود دارد. احتمالاً هنوز هم انتخاب مدل بیش از هر چیز به ویژگی‌های بازار و محصول وابسته است (Baluni and Raiwani, 2014). شیوه‌های رایج و ادبیات نظری مختلف برای پیش‌بینی شامل تجزیه سری‌های زمانی^۶، هموارسازی نمایی، رگرسیون سری‌های زمانی و مدل‌های میانگین متحرک خود همبسته یکپارچه^۷ می‌باشد. فراتر از این مدل‌ها، مدل ARIMA

¹ Business Intelligence

² Data Mining

³ Clustering

⁴ Demographical Profiles

⁵ Exponential smoothing

⁶ Time series decomposition

⁷ Autoregressive and integrated moving average

فصلی است که اغلب به‌عنوان مدل پیش‌بینی بکار می‌رود و منجر به دقت منطقی قابل قبول می‌شود و در بسیاری از کاربردهای عملی با موفقیت مورد آزمون قرار گرفته است. مدل ARIMA جزء روش‌های سنتی هستند و به‌صورت مدل‌های خطی شناخته شده‌اند که روابط بین متغیرهای مستقل و وابسته را به‌صورت خطی در نظر می‌گیرد. این مسئله با استفاده از روش‌های غیرخطی برطرف شده است. یکی از جدیدترین روش‌های پیش‌بینی، رویکرد شبکه‌های عصبی مصنوعی^۸ می‌باشد، که به‌موازات مدل‌های سنتی وارد ادبیات اقتصاد کاربردی شده است و به‌صورت الگوی غیرخطی سری زمانی مباحثه می‌شود. پایه کار شبکه‌های مصنوعی، هوش مصنوعی است. با استفاده از هوش مصنوعی روابط بین متغیرها را هرچند که پیچیده باشند می‌توان توسط رایانه فراگرفت و از آن برای پیش‌بینی مقادیر آتی استفاده نمود. مزیت مهم مدل‌های شبکه عصبی مصنوعی این است که نیازی به فرض‌های آماری خاص در مورد رفتار متغیرها نیست (Mohamadi, 2008). مدل‌های ANN پرسپترون چندلایه‌ای (MLP) که نیاز به فرض ایستا بودن داده‌ها در سری‌های زمانی ندارند استفاده می‌کنند. یک شبکه عصبی، سیستم پردازشگر اطلاعاتی است که از واحدهای پردازش گر متصل به یکدیگر به نام نرون، تشکیل یافته‌اند. این نرون‌ها به‌طور موازی و هم‌زمان کار می‌کنند و می‌توانند نظم و الگوهای موجود درون حجم عظیم ورودی‌های مبهم و به‌ظاهر بی‌نظم را استخراج نمایند (Yao & Lin, 2000). این مدل‌ها می‌توانند آموزش دیده و کار خاصی را بر اساس تجربه و یادگیری خود انجام دهند. نرون، کوچک‌ترین واحد پردازش گر اطلاعات در شبکه است که اساس عملکرد شبکه‌های عصبی را تشکیل می‌دهد. این نرون‌ها در گروه‌هایی کنار هم قرار گرفته و لایه‌ها را تشکیل می‌دهند. در هر شبکه عصبی سه نوع لایه وجود دارد که شامل لایه ورودی، لایه میانی یا پنهان و لایه خروجی است. لایه ورودی فقط نقش معرفی ورودی‌ها به شبکه را دارد (Anandarjan, 1999). ضعف مدل‌های آماری و الگوریتم‌های شبکه عصبی در پیش‌بینی و ارائه مدل مطلوب منجر به ایجاد روش سازمان‌دهی گروهی داده‌ها^۹ (GMDH) شد که روشی جهت آموزش آماری شبکه است. در طراحی شبکه‌های عصبی GMDH هدف جلوگیری از رشد و واگرایی شبکه و نیز مرتبط کردن شکل ساختار شبکه به یک یا چند پارامتر عددی است به‌گونه‌ای که با تغییر این پارامترها ساختار شبکه نیز تغییر کند (Fakhraie, 2007).

قاسمی، تقی‌نژاد و فانی (۱۳۹۶) به پیش‌بینی تقاضای کالای فاسدشدنی در خرده‌فروشی‌ها با استفاده از مدل شبکه عصبی پیش‌خور پرداختند. نتایج این پژوهش نشان داد که مدل شبکه عصبی پیش‌خور از دقت بالاتری نسبت به مدل ARIMA و میانگین متحرک برخوردار است. سیف‌الحسینی و همکاران (۱۳۹۴) به پیش‌بینی پوست و چرم با استفاده از روش‌های شبکه عصبی، ARIMA و روش ترکیبی پرداختند. یافته‌های این پژوهش نشان داد که روش ترکیبی که سری زمانی صادرات را به دو جزء خطی و غیرخطی تجزیه می‌کند، نسبت به دو روش دیگر دقت و کارایی پیش‌بینی بیشتری دارد. کرمی زاده (۱۳۹۳) به ارائه راهکاری برای کاهش ضایعات در فروشگاه مواد غذایی پرداخت. از مدل‌های ANN_{mlp}، شبکه عصبی فازی و مدل سری زمانی ARIMA برای پیش‌بینی تقاضای واقعی محصولات بازار استفاده شد. نتایج نشان داد که مدل شبکه عصبی، برای پیش‌بینی تقاضای واقعی مورد مطالعه، مناسب‌تر بوده است و پس‌از آن مدل شبکه عصبی فازی ANFIS دارای کمترین شاخص‌های خطا می‌باشد و مدل سری زمانی ARIMA دارای بیشترین میزان خطا در پیش‌بینی تقاضای واقعی بازار پگاه تهران از محصولات این شرکت را دارا می‌باشد. کاظم‌نژاد و گیلانپور (۱۳۹۲) به پیش‌بینی مقدار واردات ذرت ایران با استفاده از روش‌های اقتصادسنجی و شبکه‌های عصبی پرداختند. در این مطالعه مقدار واردات ذرت ایران برای دوره ۱۳۸۹ تا ۱۳۹۳ پیش‌بینی شده است. نتایج مطالعه آن‌ها نشان داد که شبکه عصبی پیش‌رو دارای خطای کمتر و عملکرد بهتر در مقایسه با روش اقتصادسنجی ARIMA و هموارسازی نمایی است. محمدی و همکاران (۱۳۹۲) دریافتند که الگوی ARIMA در پیش‌بینی محصولات دامی نظیر شیر، گوشت و... بر روش شبکه عصبی برتری دارد. بریم نژاد و بکشلو (۱۳۹۲) به پیش‌بینی قیمت گوجه‌فرنگی با استفاده از مقایسه روش‌های تلفیقی شبکه عصبی-خودرگرسیون و ARIMA پرداختند. نتایج مطالعه نشان داد که مدل غیرخطی شبکه عصبی خود رگرسیونی (NNAR) در پیش‌بینی قیمت خرده‌فروشی گوجه‌فرنگی دارای عملکرد بهتر نسبت به

^۸ Artificial Neural Network

^۹ Group Method of Data Handling

روش‌های دیگر است. دشتی و محمدی (۱۳۹۰) به پیش‌بینی قیمت گوشت مرغ و تخم‌مرغ با استفاده از شبکه عصبی پرداختند. یافته‌های مطالعه نشان‌دهنده برتری کامل الگوی ARIMA در پیش‌بینی قیمت اسمی محصولات منتخب است. کو و بوساراوونگز^{۱۰} (۲۰۱۵) در پیش‌بینی صادرات برنج تایلندی به مقایسه شبکه‌های عصبی مصنوعی با روش‌های ARIMA و هموارسازی نمایی پرداختند. نتایج این پژوهش نشان داد که روش شبکه عصبی بر دو روش دیگر برتری دارد. مصطفی و احمد (۲۰۱۴) یک مدل اقتصادسنجی برای پیش‌بینی صادرات نارنگی در پاکستان کردند. مدل ARIMA مورد استفاده قرار گرفت. نتایج پیش‌بینی نشان داد که در سال‌های آینده تقاضا برای نارنگی افزایش خواهد یافت. باگناسکو^{۱۱}، فرسی^{۱۲}، ساویوزی^{۱۳} و وینسی^{۱۴} (۲۰۱۵) به پیش‌بینی مصرف انرژی الکتریکی در تسهیلات بیمارستان با روش شبکه‌های عصبی پرداختند و به رفتار آماری خطای پیش‌بینی منطقی خطاهای MAPE و RMSE دست پیدا کردند. گوارناسیا و کوارتر^{۱۵} (۲۰۱۵) به پیش‌بینی مصرف انرژی در بخش حمل‌ونقل با به‌کارگیری روش شبکه‌های عصبی و تحلیل سری زمانی پرداختند، با وجود اینکه نتایج مدل شبکه عصبی نسبت به تحلیل سری زمانی از دقت بالاتری برخوردار است؛ نیازمند ورودی‌های بیشتر و محاسبات پیچیده‌تری است. بالا^{۱۶} (۲۰۱۲) در پژوهش خود به ارائه یک مدل پیش‌بینی برای خرده‌فروشان بر اساس تقسیم‌بندی مشتری، به‌منظور بهبود عملکرد موجودی پرداخت. این پژوهش سعی بر این دارد تا دانش تقسیم‌بندی مشتریان را بر اساس ویژگی‌های مختلف به‌عنوان ورودی در پیش‌بینی تقاضای یک فروشگاه خرده‌فروشی کسب کند. تقسیم‌بندی مشتریان در خوشه‌ها با استفاده از نرم‌افزار داده‌کاوی (SPSS-Clementine 12.1) بر اساس ویژگی‌های جمعیت شناختی^{۱۷} (دموگرافی) و سایر جزئیات انجام شده است. این پژوهش با استفاده از مدل ARIMA مبتنی بر خوشه‌بندی مشتریان، منجر به کاهش سطح موجودی و افزایش سطح خدمت به مشتری شده است. یانگ و همکاران (۲۰۰۹) مدل موجودی و قسمت‌گذاری را برای کالاهای فاسدشدنی غیر آبی در نظر گرفتند. تقاضا به‌صورت تابعی خطی وابسته به قیمت و کمبود به‌صورت پاره‌ای پس‌افت فرض شده بود. هاگو و همکاران (۲۰۰۶) به پیش‌بینی صادرات میگو و مواد غذایی منجمد بنگلادش با استفاده از مدل ARIMA و توابع روند خطی و غیرخطی پرداختند. نتایج نشان داد که مدل ARIMA بهترین روش برای پیش‌بینی کوتاه‌مدت نسبت به دیگر روش‌هاست.

۲- مواد و روش

الف) تقسیم‌بندی مشتریان با استفاده از خوشه‌بندی

مدیریت مشتریان به‌عنوان یک دارایی نیازمند اندازه‌گیری و رفتار با آن‌ها بر اساس ارزش حقیقی آن‌هاست (Bala, 2012). شناخت مشتریان و همچنین شناخت نیازهای مشتریان، عمل مؤثری در کسب برتری در ارائه خدمات به مشتری می‌باشد (Tarokh & sharifayan, 2007). بخش‌بندی مشتریان با استفاده از تکنیک‌های خوشه‌بندی مربوط به داده‌کاوی است. برای بخش‌بندی ویژگی‌های مشتریان با استفاده از تکنیک خوشه‌بندی در خرده‌فروشی انجام شده و این ویژگی‌ها شامل مشخصات جمعیت شناختی مشتریان و الگوهای رفتار خرید؛ مانند تعداد خرید، ارزش پولی خرید، نوع اقلام خریداری شده و... می‌باشد. در خرده‌فروشی، معمولاً بخش‌بندی مشتریان برای مدیریت ارتباط با مشتری صورت می‌گیرد (Ngai et al, 2009). این تکنیک برای طراحی پیشنهادات تبلیغاتی، جذب مشتری، حفظ مشتری و توسعه مشتری انجام می‌شود. هورنگ و همکاران^{۱۸} (۲۰۱۱) برای پیش‌بینی ورود ماهیانه توریست‌ها به تایوان، یک مدل پیش‌بینی نوآورانه را برای شناسایی خوشه‌هایی از سیستم که به‌طور صحیح تغییر می‌یابند با کاربرد مدل سری‌های زمانی فازی پیشنهاد کرده است. هورنگ و همکاران (۲۰۰۸) مزایای

¹⁰ ko and Bosarawongs

¹¹ Bagnasco

¹² Fresi

¹³ Saviozzi

¹⁴ Vinci

¹⁵ Guarnaccia & quartieri

¹⁶ Padip Kumar Bala

¹⁷ Demographic

¹⁸ Huarng et al

استفاده از روش خوشه‌بندی K-means (منظور K تا خوشه است) به منظور تجزیه و تحلیل سری‌های زمانی برای تشخیص تغییرات ساختاری (پایین به بالا یا بالا به پایین) در شاخص سهام موزون سرمایه بورس اوراق بهادار تایوان را نشان دادند. چپو و همکاران^{۱۹} (۲۰۰۹) سیستمی را برای بخش‌بندی بازار بر اساس سیستم‌های پشتیبان تصمیم که با روش تحلیل آماری و روش‌های خوشه‌بندی مانند الگوریتم ژنتیک و شبکه عصبی ارائه دادند. الگوریتم‌های ژنتیک (GA) بر اساس گزینش‌های طبیعی یا متعارف و نظریه ژنتیک می‌باشد که می‌توان در این زمینه تحقیقات گسترده و فراوانی را صورت داد (Zhou Ming, 1999). الگوریتم ژنتیک شامل کلیه قوانین و پیشنهادهای بیولوژیکی و وراثت است که دارای مزایای قابل توجهی می‌باشد به طوری که از الگوریتم‌های بهینه‌سازی مجزا می‌گردند (Hongyan, 2007).

ب) ارائه یک مدل پیش‌بینی مبتنی بر خوشه‌بندی

بر اساس مباحث مطرح‌شده در بخش‌های پیشین، یک مدل پیش‌بینی برای کالاهای خرده‌فروشی ارائه شده است. جزئیات مربوط به مشتریان به همراه میزان خرید به‌عنوان پیش‌نیاز تقسیم‌بندی مشتری ثبت شده است. روش به‌کاررفته در مدل پیش‌بینی ارائه شده در قالب گام‌های زیر تشریح می‌گردد:

گام ۱) فهرست جامعی از جزئیات جمعیت شناختی (دموگرافیک: مثل سن، جنسیت، محل زندگی و ...) مشتریان و دیگر جزئیات مربوط به رفتار خرید تهیه شده است. این جزئیات به‌عنوان ویژگی‌هایی برای توصیف مشتریان استفاده می‌شوند. لازم به ذکر است که همه این ویژگی‌ها در توصیف رفتار در نظر گرفته شده مشتری به یک اندازه مهم نیستند.

گام ۲) ایجاد کلاس‌هایی (دسته‌هایی) از مشتریان برای اقلام در نظر گرفته شده برای پیش‌بینی تقاضا انجام شده است. به‌منظور پیش‌بینی تقاضا، کلاس‌ها بر اساس واحدهای خرید برای هر قلم کالا شرح داده می‌شوند.

گام ۳) بر اساس کلاس‌های تشکیل‌شده در گام ۲، انتخاب ویژگی بر روی پایگاه داده به‌منظور انتخاب چند ویژگی غالب‌تر (مهم‌تر) به‌منظور بخش‌بندی مشتریان انجام شده است.

گام ۴) بر اساس ویژگی‌های مهم حاصل‌شده از انتخاب ویژگی (گام ۳)، خوشه‌بندی مشتریان از طریق الگوریتم ژنتیک انجام شده است.

گام ۵) پایگاه داده اصلی بر اساس تقسیم‌بندی حاصل‌شده از خوشه‌ها تفکیک شده است. هر خوشه به‌عنوان یک پایگاه داده جداگانه به نمایندگی از یک بخش منحصر به فرد فرض می‌شود.

گام ۶) برای هر بخش از مشتریان، مدل‌های ARIMA، فصلی، شبکه عصبی پیش‌خور MLP و شبکه عصبی GMDH با متغیرها و شاخص‌های پیشگویی تعیین‌شده برای پیش‌بینی استفاده می‌شوند. این شاخص‌های پیشگویی برای پیش‌بینی روزانه و هفتگی به‌صورت جداگانه شناسایی شده و در بخش بعدی مقاله به آن اشاره شده است.

گام ۷) برای پیش‌بینی تقاضای اقلام ذکرشده فروشگاه، پیش‌بینی صورت گرفته هر مدل برای بخش‌های مختلف با یکدیگر جمع می‌شوند.

مدل‌های ارائه‌شده برای پیش‌بینی تقاضای پنج قلم کالا (برنج، گوشت، لوبیا، عدس، قند) در یک سوپرمارکت واقع در شهر گرگان به‌کاررفته است. مدل ارائه‌شده بر اساس خوشه‌بندی مدل‌های ARIMA، فصلی (با در نظر گرفتن فصلی بودن تقاضا)، شبکه عصبی پیش‌خور MLP و شبکه عصبی GMDH به کار گرفته شده است. شیوه موجود برای پیش‌بینی در این فروشگاه، تکنیک میانگین متحرک ۱۴ روزه برای پیش‌بینی تقاضای روزانه اقلام استفاده می‌باشد. فروشگاه خرده‌فروشی در موارد مکرر با کمبود و همچنین بالعکس؛ با میانگین بالای سطح موجودی روزانه مواجه شده بود. تجزیه و تحلیل پیش‌بینی تقاضا برای هر یک از کالاها بدین صورت می‌باشد:

- هر ۱۰ کیلوگرم برنج معادل یک واحد در نظر گرفته شده است.
- هر ۵ کیلوگرم گوشت معادل یک واحد در نظر گرفته شده است.
- هر ۱ کیلوگرم لوبیا معادل یک واحد در نظر گرفته شده است.

- هر ۲ کیلوگرم عدس معادل یک واحد در نظر گرفته شده است.
- هر ۰/۵ کیلوگرم قند معادل یک واحد در نظر گرفته شده است.

برای بررسی کارایی و ارزیابی پیش‌بینی روزانه و پیش‌بینی هفتگی با مدل‌های پیش‌بینی ذکر شده، با یکدیگر مورد بررسی قرار گرفته است. هم برای پیش‌بینی روزانه و هم برای پیش‌بینی هفتگی، مدل‌های طراحی شده مقایسه می‌شوند. برای پیش‌بینی تقاضای روزانه، مدل‌های زیر استفاده شده‌اند. کد مربوط به مدل‌ها در بخش بعدی مقاله در داخل براکت نمایش داده می‌شوند.

- میانگین متحرک ۱۴ روزه [DM-0]
- بهترین ARIMA با شاخص‌های پیش‌بینی [DM-1]
- بهترین ARIMA فصلی با شاخص‌های پیش‌بینی [DM-2]
- شبکه عصبی Mlp با شاخص‌های پیش‌بینی [DM-3]
- شبکه عصبی GMDH با شاخص‌های پیش‌بینی [DM-4]
- شبکه عصبی Mlp مبتنی بر خوشه‌بندی با شاخص‌های پیش‌بینی [DM-5]
- شبکه عصبی GMDH مبتنی بر خوشه‌بندی با شاخص‌های پیش‌بینی [DM-6]

برای پیش‌بینی تقاضای هفتگی، مدل‌های زیر استفاده شده‌اند. کد مربوط به مدل‌ها در بخش بعدی مقاله در داخل براکت نمایش داده می‌شوند.

- بهترین ARIMA با شاخص‌های پیش‌بینی [WM-1]
- بهترین ARIMA فصلی با شاخص‌های پیش‌بینی [WM-2]
- شبکه عصبی Mlp با شاخص‌های پیش‌بینی [WM-3]
- شبکه عصبی GMDH با شاخص‌های پیش‌بینی [WM-4]
- شبکه عصبی Mlp مبتنی بر خوشه‌بندی با شاخص‌های پیش‌بینی [WM-5]
- شبکه عصبی GMDH مبتنی بر خوشه‌بندی با شاخص‌های پیش‌بینی [WM-6]

مدل‌های پیش‌بینی (DM-5، DM-6، WM-5، WM-6)، بر اساس مدل‌های پیش‌بینی مبتنی بر خوشه‌بندی ارائه شده‌اند. سایر مدل‌ها بر اساس روش‌های موجود در ادبیات نظری ارائه شده‌اند. شایان ذکر است که مدل میانگین متحرک ۱۴ روزه، مدل استفاده شده در این سوپرمارکت می‌باشد. در مجموع ۱۳ ویژگی برای مشتریان فروشگاه شناسایی به عمل آمد که غالب‌ترین این ویژگی‌ها مشخص شدند. کلاس‌ها (دسته‌ها) نیز به صورت زیر پیش‌تعریف شدند:

- کلاس ۱. افرادی که یک واحد خرید می‌کنند؛
- کلاس ۲. افرادی که دو واحد خرید می‌کنند؛
- کلاس ۳. افرادی که سه واحد خرید می‌کنند.
- کلاس ۴. افرادی که چهار واحد یا بیش از چهار واحد خرید می‌کنند.

با توجه به این کلاس‌ها، برای انتخاب ویژگی غالب‌تر مشتریان فروشگاه، با برقراری آزمون دوجمله‌ای^{۲۰} مبتنی بر داده‌ها جمع-آوری شده، در نرم‌افزار SPSS Clementine 12.1 صورت گرفت. غالب‌ترین ویژگی برای طبقه‌بندی و دسته‌بندی مشتریان تعیین شدند:

جنسیت: اشاره به جنسیت مشتری دارد. "M" مربوط به مرد و "F" مربوط به زن می‌باشد.
 درآمد: اشاره به درآمد ماهیانه (به تومان) هر مشتری دارد.
 تعداد فرزندان: اشاره به تعداد فرزندان مشتریان دارد. متغیر تعیین شده باید یک عدد صحیح باشد.

²⁰ Binomial test

سطح تحصیلات: اشاره به سطوح مختلف تحصیلات خریدار دارد. مقدار ۱ اشاره به کسانی دارد که سطح تحصیلاتشان کمتر از فوق‌دیپلم است، مقدار ۲ سطح تحصیلاتشان بین فوق‌دیپلم و کارشناسی و مقدار ۳ نیز کارشناسی ارشد و بالاتر تعریف شده است. استان محل سکونت: اگر مشتری متعلق به استانی باشد که سوپرمارکت در آنجا واقع شده باشد، ورودی مربوطه «بله» و در غیراینصورت ورودی مربوطه «خیر» می‌باشد.

بر اساس پنج ویژگی بالا، خوشه‌بندی با استفاده از الگوریتم ژنتیک در نرم‌افزار Matlab R2016a انجام شد. خوشه‌بندی داده‌های معامله فروش بر اساس مجموع شش ورودی «پنج ورودی از انتخاب ویژگی در بالا و نیز تعداد واحدهای خریداری شده (در هر قلم) صورت گرفته است». بهینه‌ترین حالت دسته‌بندی مشتریان توسط الگوی الگوریتم ژنتیک رخ داده و سه خوشه به‌دست‌آمده در زیر ارائه شده است:

خوشه - ۱

(۱۰۱۳ رکورد یا گزارش) (در هر متغیر، مقدار غالب با _ مشخص شده است)

۱- جنسیت: مرد (۷۸/۲۳٪)؛ زن (۲۱/۷۷٪)

۲- درآمد: کمتر از ۱ میلیون (۲۹/۵۶٪)؛ ۱ تا ۲ میلیون (۶۹/۳۰٪)؛ بیشتر از ۲ میلیون (۱/۱۴٪)

۳- تعداد فرزندان: ۳ یا بیشتر (۸/۸۶٪)؛ ۲ فرزند (۶۶/۷۸٪)؛ ۱ فرزند (۱۰/۵۴٪)؛ بدون فرزند (۱۳/۸۲٪)

۴- سطح تحصیلات: ۱ (۴۲/۶۶٪)؛ ۲ (۵۰/۲۵٪)؛ ۳ (۷/۰۹٪)

۵- استان محل زندگی: بله (۴۱/۹۳٪)؛ خیر (۵۸/۰۷٪)

۶- تعداد واحدهای خریداری‌شده: ۴ (۳/۳۳٪)؛ ۳ (۹/۷۴٪)؛ ۲ (۵۲/۸۷٪)؛ ۱ (۳۴/۰۶٪)

خوشه - ۲

(۴۷۲۵ رکورد)

۱- جنسیت: مرد (۲۶/۸۹٪)؛ زن (۱۱/۷۴٪)

۲- درآمد: کمتر از ۱ میلیون (۸۹/۶۷٪)؛ ۱ تا ۲ میلیون (۸/۴۰٪)؛ بیشتر از ۲ میلیون (۱/۰۳٪)

۳- تعداد فرزندان: ۳ یا بیشتر (۱۰/۳۳٪)؛ ۲ فرزند (۷۸/۷۱٪)؛ ۱ فرزند (۱۸/۴۶٪)؛ بدون فرزند (۰/۳۳٪)

۴- سطح تحصیلات: ۳ (۸۶/۱۱٪)؛ ۲ (۱۰/۳۵٪)؛ ۱ (۳/۵۴٪)

۵- استان محل زندگی: بله (۱۳/۰۱٪)؛ خیر (۸۶/۹۹٪)

۶- تعداد واحدهای خریداری‌شده: ۴ (۳/۶۱٪)؛ ۳ (۸۲/۱۳٪)؛ ۲ (۱/۵۴٪)؛ ۱ (۲/۷۱٪)

خوشه - ۳

(۳۸۲۳ رکورد)

۱- جنسیت: مرد (۳۴/۲۱٪)؛ زن (۶۵/۶۹٪)

۲- درآمد: کمتر از ۱ میلیون (۴۱/۲۴٪)؛ ۱ تا ۲ میلیون (۴۹/۳۵٪)؛ بیشتر از ۲ میلیون (۹/۴۱٪)

۳- تعداد فرزندان: ۳ یا بیشتر (۵/۹۵٪)؛ ۲ فرزند (۳۹/۳۹٪)؛ ۱ فرزند (۵۰/۴۷٪)؛ بدون فرزند (۴/۱۹٪)

۴- سطح تحصیلات: ۱ (۶۸/۷۲٪)؛ ۲ (۲۸/۸۸٪)؛ ۳ (۲/۴۰٪)

۵- استان محل زندگی: بله (۶۱/۸۷٪)؛ خیر (۳۹/۱۳٪)

۶- تعداد واحدهای خریداری‌شده: ۴ (۰/۵۲٪)؛ ۳ (۱۱/۴۸٪)؛ ۲ (۱۸/۷۰٪)؛ ۱ (۶۹/۳۰٪)

با توجه به پنج ویژگی مشخص‌شده برای خوشه‌بندی، بر اساس پایگاه داده‌ها که شامل ۹۵۶۱ گزارش بوده خوشه‌بندی مشتریان فروشگاه در سه خوشه تفکیک شده بالا صورت پذیرفت. پیش‌بینی در هر خوشه به‌طور جداگانه توسط مدل‌های پیشنهاد شده در طرح‌های پیشنهادی [WM-5، DM-6، WM-5، DM-6] انجام شد. در این تحقیق؛ متغیرها و شاخص‌های ورودی مدل با مصاحبه چندین تن از مدیران و سرپرستان فروشگاه‌ها و خبره‌ها در این زمینه مشخص شد. اهمیت این شاخص‌ها از این جهت است

که در زمان وقوع این شاخص‌ها میزان عرضه و تقاضای محصولات این فروشگاه افزایش یا کاهش می‌یابد. متغیرهای استفاده‌شده در این مطالعه برای ورودی مدل‌های پیش‌بینی روزانه و هفتگی مطابق با آنچه در زیر آمده شناسایی شده‌اند:

- شاخص روز پرداخت حقوق (روز اول، دوم و آخرین روز از ماه)
- شاخص روز تعطیلی (شامل آخر هفته)
- شاخص روز اعیاد مذهبی
- شاخص روزهای ماه محرم
- شاخص روزهای ماه رمضان
- شاخص تعطیلی مدرسه (تابستان)
- شاخص روزهای عید نوروز
- شاخص روز پرداخت یارانه

ج) معیارهای ارزیابی مدل‌ها

به‌منظور ارزیابی و مقایسه نتایج روش‌ها و مدل‌های به‌کاربرده شده در این پژوهش، از شاخص‌های آماری مانند میانگین مربعات مجذور خطا^{۲۱}، ضریب تعیین^{۲۲}، میانگین قدر مطلق خطا^{۲۳} و نرمال میانگین مربعات خطا^{۲۴} استفاده شده است که به ترتیب:

$$RMSE = \sqrt{\sum_{i=1}^n \left(\frac{(obs - pre)}{n} \right)^2} \quad \text{رابطه (۱)}$$

$$R^2 = \frac{\sum_{i=1}^n (obs - \overline{obs})(pre - \overline{pre})}{\sqrt{\sum_{i=1}^n (obs - \overline{obs})^2 \sum_{i=1}^n (pre - \overline{pre})^2}} \quad \text{رابطه (۲)}$$

$$MAPE = \frac{1}{n} \sum \left| \frac{X_k - X_{ok}}{X_k} \right|, \text{ for } k = 1, 2, \dots, n \quad \text{رابطه (۳)}$$

$$NMSE = \frac{\sum (X_k - X_{ok})^2}{\sum (X_k - X_0)^2}, \text{ for } k = 1, 2, \dots, n \quad \text{رابطه (۴)}$$

که در روابط ۱ و ۲؛ obs: مقادیر مشاهده‌ای، pre: مقادیر پیش‌بینی شده توسط شبکه مدل و N: تعداد کل داده‌ها و در رابطه ۳ و ۴؛ n: تعداد دوره‌ها، X_k : مقدار پیش‌بینی دوره K ام، X_{ok} : مقدار واقعی دوره K ام و X_0 : میانگین مقدار واقعی تمام دوره‌ها در هر مرحله از آزمون‌های آموزش و آزمایش است (Makridakis et al, 1998). هرچه مقدار RMSE به صفر و مقدار ضریب تعیین به یک نزدیک‌تر باشد، نشان‌دهنده نزدیک بودن مقادیر مشاهده و پیش‌بینی شده به یکدیگر و دقیق‌تر بودن جواب‌ها در هر مرحله است (Ho & Min & Thong, 2002). ضریب تعیین، میانگین مربعات خطا و میانگین قدر مطلق خطا در نرم‌افزار MATLAB R2016a در شاخه Neural Network محاسبه شده است.

۳- نتایج و بحث

مدل‌های ارائه‌شده در ادبیات نظری همراه با مدل موجود در فروشگاه با یکدیگر مقایسه شده‌اند. عملکرد مجموعه داده‌های آموزشی ۳۶ ماه و مجموعه داده‌های آزمایشی ۱۲ ماه نمایش داده شده است. مقایسه پیش‌بینی روزانه و هفتگی به ترتیب در

²¹ Root mean square error

²² Random error

²³ Mean absolute error

²⁵ Normalized Mean Square Error

جدول ۱ و ۲ به صورت جداگانه نشان داده شده است. مشخص شده است که هم در پیش‌بینی‌های روزانه و هم در پیش‌بینی‌های هفتگی، مدل‌های شبکه عصبی Mlp مبتنی بر خوشه‌بندی و مدل شبکه عصبی GMDH مبتنی بر خوشه‌بندی از سایر مدل‌ها بهتر عمل می‌کنند. در حالت کلی، مقادیر نتایج پیش‌بینی‌های هفتگی بهتر از پیش‌بینی‌های روزانه بوده است.

جدول شماره (۱): مقایسه نتایج مدل‌های پیش‌بینی روزانه (منبع: یافته‌های تحقیق)

مدل‌های پیش‌بینی	شرح مدل پیش‌بینی	(مجموعه داده‌های آموزشی)				(مجموعه داده‌های آزمایشی)			
		RMSE	NMSE	MAPE	R ²	RMSE	NMSE	MAPE	R ²
DM-0	میانگین متحرک ۱۴ روزه	۵/۷۸	۰/۹۰۱۲	۵۴/۱۵	۰/۴۳۶	۵/۹۶	۰/۹۶۳۳	۵۹/۴۶	۰/۳۹۶
DM-1	بهترین ARIMA	۵/۳۴	۰/۱۸۹۹۷	۵۱/۱۶	۰/۶۲۷	۵/۴۵	۰/۹۰۰۴	۵۲/۴۴	۰/۶۰۱
DM-2	بهترین ARIMA فصلی	۴/۶۶	۰/۱۸۳۲۵	۴۵/۶۵	۰/۷۴۶	۴/۸۹	۰/۸۶۳۳	۴۸/۳۴	۰/۷۱۵
DM-3	شبکه عصبی Mlp	۳/۸۵	۰/۶۲۲۱	۴۱/۷۶	۰/۸۰۱	۳/۹۸	۰/۶۷۲۵	۴۴/۲۳	۰/۷۹۱
DM-4	شبکه عصبی GMDH	۳/۳۷	۰/۵۷۹۶	۴۰/۳۶	۰/۸۵۳	۳/۵۷	۰/۵۹۳۷	۴۲/۵۶	۰/۸۳۲
DM-5	شبکه عصبی Mlp مبتنی بر خوشه‌بندی	۲/۵۲	۰/۳۷۴۰	۳۷/۴۱	۰/۹۰۴	۲/۷۹	۰/۳۹۱۲	۳۹/۵۶	۰/۸۸۹
DM-6	شبکه عصبی GMDH مبتنی بر خوشه‌بندی	۱/۷۷	۰/۲۵۶۴	۲۸/۶۷	۰/۹۲۸	۱/۹۵	۰/۲۷۳۹	۳۱/۸۷	۰/۹۱۴

جدول شماره (۲): مقایسه نتایج مدل‌های پیش‌بینی هفتگی (منبع: یافته‌های تحقیق)

مدل‌های پیش‌بینی	شرح مدل پیش‌بینی	(مجموعه داده‌های آموزشی)				(مجموعه داده‌های آزمایشی)			
		RMSE	NMSE	MAPE	R ²	RMSE	NMSE	MAPE	R ²
WM-1	بهترین ARIMA	۵/۰۲	۰/۷۹۶۸	۴۹/۷۶	۰/۶۴۵	۵/۲۴	۰/۸۱۰۴	۵۱/۳۴	۰/۶۱۴
WM-2	بهترین ARIMA فصلی	۴/۳۶	۰/۷۴۵۸	۴۳/۶۷	۰/۷۶۴	۴/۶۶	۰/۷۸۳۱	۴۴/۳۰	۰/۷۲۳
WM-3	شبکه عصبی Mlp	۳/۷۶	۰/۶۰۸۷	۳۸/۷۹	۰/۸۱۳	۳/۷۹	۰/۶۳۰۵	۴۱/۲۲	۰/۸۰۶
WM-4	شبکه عصبی GMDH	۳/۱۵	۰/۵۵۹۸	۳۷/۰۶	۰/۸۶۷	۳/۲۱	۰/۵۷۳۱	۳۹/۰۶	۰/۸۴۵
WM-5	شبکه عصبی Mlp مبتنی بر خوشه‌بندی	۲/۲۷	۰/۳۲۴۶	۳۱/۳۲	۰/۹۱۱	۲/۳۷	۰/۳۵۶۲	۳۳/۲۶	۰/۹۰۲

WM-6	شبکه عصبی GMDH مبتنی بر خوشه‌بندی	۰/۹۷	۰/۱۹۸۷	۲۱/۵۶	۰/۹۳۴	۱/۳۱	۰/۲۲۰۴	۲۶/۸۴	۰/۹۲۲
------	--------------------------------------	------	--------	-------	-------	------	--------	-------	-------

(د) ارزیابی عملکرد موجودی مبتنی بر نتایج مدل‌های پیش‌بینی

برای بررسی و تحلیل سیاست کنترل دوره‌ای سطح موجودی، سه مدل پیش‌بینی با توجه به دو شاخص عملکرد^{۲۵} با یکدیگر مقایسه شده‌اند:

۱. بررسی میزان سطح موجودی^{۲۶} محصول در روزهای بدون کمبود (به‌صورت: موجودی / میانگین فروش روزانه^{۲۷})؛ و
۲. خدمت به مشتری^{۲۸} (درصد روزهایی که فروشگاه با کمبود مواجه است و نمی‌تواند به مشتری خدمات‌رسانی کند «درصد روزهایی شکست فروش^{۲۹}»).

درواقع، سطح خدمت به مشتری به‌صورت معکوس با «درصد روزهایی که فروش شکست‌خورده» متناسب است. در سیاست کنترل دوره‌ای سطح موجودی با استفاده از پیش‌بینی روزانه، مرور سطوح موجودی برای محصولات فسادپذیر هر P روز انجام می‌شود و سفارش خرید باید حداقل L روز^{۳۰} (همان زمان سفارش دهی کالا) پیش‌از تاریخ تحویل فرستاده شود. سطح موجودی مطلوب (T) باید هر دوره از طریق معادله $T = m_0 + Z_s$ محاسبه شود که m_0 میانگین تقاضا در طول (P + L) روز است، Z از جدول توزیع نرمال استاندارد به‌دست‌آمده که به سطح خدمت مطلوب بستگی دارد و S انحراف معیار تقاضا در طول (P + L) روز است. (P + L) به‌عنوان دوره نگهداری و S_s ذخیره احتیاطی^{۳۱} است. هم میانگین تقاضای (m_0) و هم انحراف معیار (S) بر اساس مدل‌های پیش‌بینی استفاده‌شده برای پیش‌بینی تقاضا برآورد شده‌اند. با استفاده از داده‌های فروش از هفته اول تیر سال ۱۳۹۴ تا هفته آخر خرداد سال ۱۳۹۵ به مدت ۵۲ هفته که از فروشگاه دریافت گردید برای بررسی میزان حجم مرور دوره‌ای سطح موجودی محصولات فسادپذیر استفاده شد. سیاست کنترل دوره‌ای سطح موجودی در شرایط کمبود غیرمجاز با استفاده از مدل‌های ارائه‌شده مورد بررسی قرار گرفت و شبیه‌سازی انجام‌شده و مبتنی بر پیش‌بینی هفتگی، داده‌های زیر استفاده‌شده‌اند:

- P برابر ۸ هفته
- L برابر ۴ هفته
- سطح خدمت برابر ۹۰٪

جدول شماره (۳): روابط محاسبه سطح موجودی مطلوب (Kumar Bala, 2012).

رابطه ۵) میانگین تقاضای روزانه = میانگین تقاضای هفتگی تقسیم بر ۷
رابطه ۶) انحراف معیار تقاضای روزانه = انحراف معیار تقاضای هفتگی تقسیم بر $\sqrt{7}$
رابطه ۷) انحراف معیار تقاضای (P+L) روز = انحراف معیار تقاضای روزانه $\times \sqrt{(P + L)}$
رابطه ۸) ذخیره احتیاطی = Z \times [انحراف معیار تقاضای (P+L) روز]
رابطه ۹) سطح موجودی مطلوب یا هدف (T) = میانگین تقاضای روزانه \times (P+L) + ذخیره احتیاطی
رابطه ۱۰) مقدار سفارش (Q) = سطح موجودی - T

با توجه به مقادیر پیش‌بینی مدل‌های بکار گرفته‌شده نسبت به تقاضای محصولات انزال پذیر در طول دوره جاری، مقادیر شاخص‌های عملکرد موجودی به دست آمد. مقادیر به‌دست‌آمده حاکی از آن است که مدل جاری فروشگاه؛ میانگین متحرک ۱۴ روزه، عملکرد ضعیف‌تری را نسبت به دو مدل دیگر در پی داشته است و اگرچه هم مدل ARIMA و هم مدل ANN_{mlp} نسبت به مدل جاری فروشگاه موفقیت بیشتری را داشته‌اند اما مدل پیش‌بینی شبکه عصبی پرسپترون چندلایه، بهبود

²⁵ Key Performance Indicators(KPIs)

²⁶ Inventory Level

²⁷ Daily sales average

²⁸ Customer service

²⁹ Percentage of days with sales failure

³⁰ Lead time

³¹ Safety stock

قابل‌ملاحظه‌ای را در عملکرد موجودی کالاهای انزال پذیر این فروشگاه نسبت به مدل ARIMA و میانگین متحرک ۱۴ روزه؛ داشته است جدول (۴).

جدول شماره (۴): عملکرد کنترل دوره‌ای سطح موجودی (منبع یافته‌های تحقیق)

مدل	شرح مدل	شاخص‌های عملکرد موجودی		سطح موجودی مطلوب (میانگین موجودی روزانه / فروش روزانه)	
		هفته‌های مواجهه با کمبود	درصد هفته‌های خدمت‌رسانی		
مدل فروشگاه (یافته‌های واقعی)	DM-0	میانگین متحرک چهارده‌روزه	۳۶ هفته	۳۰/۷۷٪	۱۸۴/۲۳ واحد
نتایج شبیه‌سازی شده	DM-5	شبکه عصبی MLP مبتنی بر خوشه‌بندی	۲۹ هفته	۴۴/۲۴٪	۹۷/۰۸ واحد
	DM-6	شبکه عصبی GMDH مبتنی بر خوشه‌بندی	۲۵ هفته	۵۱/۹۳٪	۸۴/۴۶ واحد
	WM-5	شبکه عصبی MLP مبتنی بر خوشه‌بندی	۱۶ هفته	۶۹/۲۴٪	۷۱/۳۳ واحد
	WM-6	شبکه عصبی GMDH مبتنی بر خوشه‌بندی	۱۲ هفته	۷۶/۹۷٪	۶۲/۲۳ واحد

نتایج شاخص‌های عملکرد موجودی در جدول شماره (۴) نمایان شده‌اند. همان‌طور که در این جدول مشاهده می‌شود، تعداد هفته‌هایی که فروشگاه با کمبود مواجه شده؛ در زمان استفاده از مدل جاری فروشگاه «میانگین متحرک ۱۴ روزه»، برابر ۳۶ هفته از ۵۲ هفته می‌باشد. این بدین معنی است که این فروشگاه فقط ۱۶ هفته توانسته نیازهای مشتریان را تأمین کند و به مدت ۱۶ هفته با کمبود مواجه شده است. همچنین در ادامه مدل WM-6، توانسته به‌طور قابل چشم‌گیری این کمبود را کاهش دهد و به ۱۲ هفته برساند. همچنین اعدادی که در قسمت سطح موجودی مطلوب به‌دست‌آمده نمایانگر این است که در زمان استفاده از مدل میانگین متحرک چهارده‌روزه میزان حجم محصولات باقیمانده به‌طور میانگین در انتهای هفته ۱۸۴/۲۳ واحد، در مدل DM-5 این میزان به مقدار ۹۷/۰۸ واحد، در مدل DM-6 این میزان به مقدار ۸۴/۴۶، در مدل WM-5 این میزان به مقدار ۷۱/۳۳ واحد و در مدل WM-6 این میزان به مقدار ۶۲/۲۳ واحد کاهش یافته است.

در این مطالعه سیستم هوش تجاری^{۳۳} ارائه‌شده برای پیش‌بینی تقاضا ثابت کرد که پیش‌بینی دقیق‌تری از تقاضای آینده در مقایسه با مدل‌ها و روش‌های موجود در سوپرمارکت‌ها و فروشگاه‌های زنجیره‌ای ارائه می‌دهد. این امر به مدیران فروشگاه و سرپرستان موجودی (انبار) کمک می‌کند تا با کاهش هم‌زمان روزهای مواجهه با کمبود (سفارش دهی محصول) و افزایش سطح خدمت به مشتری (درصد روزهای شکست فروش)، به بهبود عملکرد موجودی محصولات فروشگاه دست یابند که این امر جزء نوآوری پژوهش محسوب می‌شود. بررسی میزان سطح موجودی دلالت بر کاهش سطح موجودی در حالت کمبود و کاهش روزهای شکست فروش نشان‌دهنده افزایش سطح خدمت می‌باشد. عملکرد مدل ارائه‌شده شبکه عصبی مصنوعی GMDH در این پژوهش بهتر از مدل‌های دیگر بوده است. پژوهش‌های متعددی در بخش‌های مختلف در خصوص پیش‌بینی با به‌کارگیری روش‌های شبکه‌های عصبی و سری‌های زمانی از جمله ARIMA انجام شده است و نتایج این مطالعات نشان‌دهنده این بوده که شبکه‌های عصبی برای پیش‌بینی‌های بلندمدت و کوتاه‌مدت از دقت بالاتری نسبت به سایر روش‌ها برخوردار است. از جمله این پژوهش‌ها می‌توان به پژوهش‌های قاسمی، تقی‌نژاد و فانی (۱۳۹۶)، سیف‌الحسینی و همکاران (۱۳۹۴)، باگناسکو و همکاران (۲۰۱۵)، گوارناسیا و کوارتر (۲۰۱۵)، جنگ کو و همکاران (۲۰۱۴) و ... اشاره کرد. همچنین در پژوهش کامارابالا (۲۰۱۲) که به ارائه یک مدل پیش‌بینی برای خرده‌فروشان بر اساس تقسیم‌بندی مشتری، به‌منظور بهبود عملکرد موجودی پرداخته و برخلاف نتایج این پژوهش، به این نتیجه دست یافت که مدل ARIMA مبتنی بر خوشه‌بندی مشتریان، از دقت بالاتری در پیش‌بینی

برخوردار بوده و منجر به کاهش سطح موجودی و افزایش سطح خدمت به مشتری شده است؛ ارتقای مدیریت موجودی با استفاده از مدل‌های ARIMA و ANN_{mip} پس از شناسایی متغیرها و شاخص‌ها، یک کاربرد مازاد برای افزایش سودآوری عملیات خواهد بود (Bala, 2012). با توجه به شاخص‌ها و متغیرهای تعیین‌شده؛ مشخص شد که برای کالاهای این فروشگاه، شاخص روزهای ماه مبارک رمضان، شاخص روزهای ماه محرم، شاخص روز پرداخت حقوق مشتری، شاخص روز پرداخت یارانه، شاخص روز تعطیلی آخر هفته‌ها، شاخص تعطیلی مدارس، شاخص روز عید نوروز و شاخص روزهای اعیاد مذهبی بر میزان تقاضای این محصولات از جانب مشتریان این خرده‌فروشی تأثیرگذار می‌باشند. با توجه به نتایج این مطالعه، مدل پیش‌بینی تقاضای شبکه عصبی GMDH مبتنی بر خوشه‌بندی نسبت به مدل جاری فروشگاه و همین‌طور مدل‌های ARIMA، ARIMA فصلی و شبکه عصبی Mlp بهینه‌تر تشخیص داده شد؛ که به سرپرستان این فروشگاه پیشنهاد می‌شود که جهت بهبود کارایی و عملکرد موجودی اقلام، از این مدل در فروشگاه استفاده نمایند.

۴- منابع

1. Aburto, L., & Weber, R. (2007). Improved supply chain management based on hybrid demand. *Applied Soft Computing*, 7 (1), 136-44.
2. Agrawal, D., & Schorling, C. (1996). Market share forecasting: an empirical comparison of. *Journal of Retailing*, 72 (4).
3. Anandarjan, M., & Anandarjan, A. (1999). A Comparison of Machine Learning Techniques with a Qualitative Response Model for Auditors Going Concern Responding. *Experts Sestems with Application*, 16.
4. Bala, P. (2009). A data mining model for investigating the impact of promotion in retailing. *Proceedings of IEEE International Advance Computing Conference*, Patiala, India, March 6-7, pp. 670-4.
5. Bala, P. (2012). Data mining for retail inventory management. in Ao, S.I. and Gelman, L. (Eds), *Advances in Electrical Engineering and Computational Science, LNEE Series*, 39, Springer, New York, NY, pp. 587-98.
6. Bala, P., Sural, S., & Banerjee, R. (2010). Association rule for purchase dependence in multi-item inventory. *Production Planning & Control*, 21 (3), 274-85.
7. Baluni, P., & Raiwani, Y. (2014). Vehicular accident analysis using neural network. *International Journal of Emerging Technology and Advanced Engineering*, 4(9), 161-164.
8. Barksdale, H., & Hilliard, J. (1975). A cross-spectral analysis of retail inventories and sales. *Journal of Business*, 48 (3), 365-82.
9. Fakhraei, H. (2006). *Comparison Water Demand forecast by using Structural patterns, time series and neural networks* Faculty of Economics, . University of Tehran. (in persian).
10. Fildes, R., Goodwin, P., Lawrence, M., & Nikolopo, K. (2009). Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning. *International Journal of Forecasting*, 25 (1), 3-23.
11. Ghasemi, A. R., Taghinezhad, Y., & Fani, R. (2017). Using multi-layer perceptron neural network approach In anticipation of the request Perishable commodity In retail stores. *First Conference on Modern Management Studies*, 214- 234.
12. Ho, S., Min, X., & Thong Ngee, G. (2002). A Comparative Study of Neural Network and Box-Jenkins ARIMA Modeling in Time Series Prediction. *Computers and Industrial Engineering*, 371- 375.
13. Hongyan, D., Fang, W., & Chang, Y. (2007). *The Spatial Analysis of Clustering based on Genetic Algorithms. Institute of surveying and Mapping*. China.: University Zhengzhou.
14. Huarng, K., & Yu, T. (2006). The application of neural networks to forecast fuzzy time series. *Physica A: Statistical Mechanics and its Applications*, Physica A: Statistical Mechanics and its Applications.

15. Huarng, K., Yu, T., & Kao, T. (2008). Analyzing structural changes using clustering techniques. *International Journal of Innovative Computing Information and Control*, 4 (5), 1195-201.
16. Huarng, K., Yu, T., & Sole Parellada, F. (2011). An innovative regime switching model to forecast Taiwan tourism demand. *The Service Industries Journal (Special Issue on Tourism Services)*, 31 (10), 1603-12.
17. Makridakis, S., S. C. W., & R. J. H. (1998). *Forecasting: Methods and Applications*. 3rd ed: John Wiley, Hoboken, N.j.
18. Mohammadi. (2007). Compare the predictive power of ANN with other forecasting methods. *Ecology of Crop Plants*, 14 (13), 85-100. (in persian).
19. Moon, M. (2003). Conducting a sales forecasting audit. *International Journal of Forecasting*, 19 (1), 5-25.
20. Ngai, E., Xiu, L., & Chau, D. (2009). Application of data mining techniques in customer relationship management: a literature review and classification. *Expert Systems with Applications*, 36 (2), 2592-602 (Part-2).
21. Tarokh, & sharifiyan. (2006). Application of Data Mining At Customer relationship. *Quarterly Industrial Management Studies*, Sixth year. No. 17, pp: 153-181.(in persian).
22. Thall, N. (1992). Neural forecasts: a retail sales booster. *Discount Merchandiser*, 23 (10).
23. ZHOU, M., & Sun, Z. (1999). *Genetic Algorithms Theory and Applications*. China: Beijing.

