

ارزیابی عملکرد موجودی مبتنی بر پیش‌بینی تقاضا با استفاده از مدل شبکه عصبی MLP

یاسر تقی‌نژاد^{۱*}

^۱ کارشناسی ارشد، گروه مدیریت صنعتی، پردیس فارابی، دانشگاه تهران، تهران، ایران (عهده دار مکاتبات)

تاریخ دریافت: اردیبهشت ماه ۱۳۹۷، اصلاحیه: مهر ماه ۱۳۹۷، پذیرش: آبان ماه ۱۳۹۷

چکیده

مدیریت صحیح و کنترل بهتر موجودی اقلام فروشگاه مواد غذایی، یکی از ضروری‌ترین و مهم‌ترین اهداف مدیران فروشگاه‌های مواد غذایی می‌باشد. هر چه عملکرد موجودی فروشگاه بهبود یابد، افزایش سطح خدمت به مشتری و کاهش روزهای مواجه با کمبود را در پی خواهیم داشت. هدف این مقاله ارائه یک مدل پیش‌بینی برای تقاضای فرآورده‌های گوشتی فروشگاه زنجیره‌ای اتکای گرگان، به منظور بهبود عملکرد موجودی می‌باشد. در این پژوهش از مدل ANNmlp برای پیش‌بینی تقاضای فرآورده گوشتی این فروشگاه استفاده شده است و همچنین برای درک میزان دقت پیش‌بینی، با مدل‌های ARIMA و میانگین متحرک ۱۴ روزه مقایسه شده است. برای این منظور، از کد نویسی این مدل در نرم‌افزار متلب و داده‌های سری زمانی تقاضای فرآورده‌های گوشتی از ابتدای سال ۱۳۹۲ تا هفته ۱۲ سال ۱۳۹۵ که به صورت هفتگی دریافت گردید، استفاده شد. نتایج تحقیق نشان داد که مدل ANN^{۵-۱} بهترین مدل برای پیش‌بینی تقاضای این محصول می‌باشد. مدل پیش‌بینی ارائه شده با سیاست کنترل دوره‌ای سطح موجودی، منجر به کاهش روزهای مواجه با کمبود و افزایش سطح خدمت به مشتری شده است.

واژه‌های اصلی: پیش‌بینی، شبکه عصبی، مدیریت موجودی، هوش مصنوعی.

۱- مقدمه

فروشگاه‌های زنجیره‌ای مجموعه فروشگاه‌هایی هستند که دارای مدیریت واحد و در سطح یک شهر، کشور یا چندین کشور پراکنده‌اند. این فروشگاه‌ها از عنوان تجاری یکسانی بهره می‌برند و معمولاً محصولات مشابه یا تقریباً مشابهی ارائه می‌کنند. در حدود ۷۵ تا ۹۰ درصد کالاهای این فروشگاه‌ها محصولات غذایی می‌باشند که از این مقدار حدود ۲۵ درصد این کالاها جزو کالاهای فاسدشدنی هستند. در حالت کلی کالای فاسدشدنی به کالایی گفته می‌شود که با گذشت زمان ارزش خود را از دست می‌دهند. کالاهایی مانند داروها، سبزیجات، گوشت، محصولات لبنی، کالاهای فصلی و... در راستای کالاهای فاسدشدنی قرار می‌گیرند. در سال‌های اخیر به دلیل پیشرفت در فناوری، بازارهای رقابتی شدید و مشتریان سخت‌گیر تعداد کالاهای فاسدشدنی بسیار بیشتر از قبل شده است [۲]. با وجود چنین بازارهایی یک امر حیاتی برای بنگاه‌های مختلف، تعیین سیاست مناسب مدیریت موجودی کالاهای موردنظر است. سیستم‌های مدیریت زنجیره تأمین و سیستم‌های هوشمند در دو دهه اخیر رشد قابل‌ملاحظه‌ای؛ در بهبود مدیریت موجودی انبار با توجه به پیش‌بینی تقاضا، کرده‌اند. هرچند، رشد این دو بیشتر به صورت جداگانه صورت گرفته است [۱۴]. همچنین سیستم‌های مدیریتی فروشگاه‌های زنجیره‌ای، با یک دوره تغییرات بی‌سابقه در رابطه با شناسایی تقاضای

مشتریان؛ از سیستم‌های دستی کنترل موجودی به سیستم‌های کامپیوتری تغییر یافتند [۶].

فروشگاه‌ها 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 سوپرمارکت‌ها و خرده‌فروشان مورد استفاده قرار می‌گرفتند. به تدریج سایر فروشگاه‌ها آن را برای رقابت در کسب‌وکار خود ضروری یافتند. در یک سوپرمارکت نمونه‌های اقلام خوراکی، تعداد واحدهای نگهداری موجودی^۱ در حدود چند هزار و در یک فروشگاه زنجیره‌ای، معمولاً بیش از ۵۰۰۰۰ نوع قلم کالا است. هر چه میزان دقت پیش‌بینی مدیران و سرپرستان فروشگاه برای تقاضای هر قلم کالا بیشتر باشد، تصمیم‌گیری در خصوص زمان خرید، مقدار خرید و فروشنده موردنظر عاقلانه‌تر صورت می‌گیرد و همچنین پیش‌بینی کارآمد برای تقاضای آتی کلید موفقیت مدیر فروشگاه و انبار می‌باشد [۲۹]. از مهمترین مسائلی که یک فروشگاه مواد غذایی با آن مواجه است، بهبود یافتن عملکرد موجودی کالاها و محصولات به خصوص کالاهای انزال پذیر است؛ که هر چه این منطبق به سمت بهبودی سوق پیدا کند به نسبت ضرر و زیان فروشگاه به طور قابل ملاحظه‌ای کاهش پیدا می‌کند. با توجه به مطالب ذکر شده هدف از نگارش این مقاله

*taghinezhad89@alumini.uni.ac.ir

^۱ Stock Keeping Units

بهبود عملکرد موجودی فرآورده‌های گوشتی فروشگاه زنجیره‌ای اتکای گرگان بر پایه پیش‌بینی تقاضای این محصول با استفاده از مدل شبکه عصبی پرسپترون چند لایه است.

۲- مبانی نظری

اهمیت پیش‌بینی دقیق فروش برای کارآمد نمودن مدیریت موجودی از دیرباز شناخته شده است [۱۸]. همچنین مدیریت موفق موجودی تا حد زیادی به پیش‌بینی دقیق فروش بستگی دارد [۱۳]. بهبود دقت و صحت پیش‌بینی تقاضا می‌تواند منجر به پس‌انداز مالی، رقابت‌پذیری بیشتر، افزایش روابط و رضایت مشتری شود [۲۹]. همین‌طور پیش‌بینی دقیق تقاضا نقش حیاتی را در سودآوری فروشگاه ایفا می‌کند و تأثیر بسزایی را در بهینه بودن سفارشات اقتصادی می‌گذارد و پیش‌بینی ضعیف منجر به کمبود یا مازاد موجودی شده که به‌طور مستقیم سودآوری و موقعیت رقابتی فروشگاه را تحت تأثیر قرار می‌دهد [۱۸]. همواره بنگاه‌های اقتصادی به دنبال راه‌هایی جهت کاهش موجودی در حال نگهداری می‌باشند. موجودی موجب قفل شدن سرمایه در گردش می‌شود و برگردش وجوه تأثیر می‌گذارد و حتی گاهی موجب تهدید بقای بنگاه‌های اقتصادی می‌شود. همچنین موجودی موجب اشغال فضا می‌گردد و بنگاه‌های اقتصادی جهت نگهداری از آن، نیاز به استخدام افرادی دارند. در هر حال مقدار موجودی نمی‌تواند به صفر تقلیل یابد زیرا شرکت‌ها به مواد اولیه، محصول در حال ساخت و محصول نهایی جهت کارکرد خود نیاز دارند. بنابراین هدف مدیریت موجودی کمینه کردن نگهداری موجودی به‌گونه‌ای است که سطح خدمت به مشتری در حد مطلوب حفظ شود [۲۸].

جهت پیش‌بینی تقاضای محصولات و مدیریت و کنترل موجودی، ایجاد مدل‌های مناسب و کارا می‌تواند مفید واقع شود. در اکثر مدل‌های موجودی مطرح‌شده در ادبیات، فرض بر آن است که اقلام برای مدت نامتناهی می‌تواند در انبار نگهداری شود تا جهت برآورده کردن تقاضای آتی بتوان از آن استفاده نمود؛ اما کالاهای خاصی وجود دارد که زوال‌پذیر هستند و با گذشت زمان زایل یا متروک می‌شوند. لذا این کالاها پس از مدتی قابل استفاده نخواهند بود. بنابراین اگر نرخ زوال به‌اندازه کافی کم نباشد، از تأثیر آن نمی‌توان چشم‌پوشی کرد [۲۴]. اقلام زوال‌پذیر جهت به‌کارگیری رویکرد همکاری بین تأمین‌کننده و خریدار نسبت به اقلام عادی، حساسیت بیشتری دارد؛ زیرا زایل شدن کالاها امری است که موجب نگرانی دوجانبه، هم از سوی تأمین‌کننده و هم از سوی خریدار، می‌شود [۲۴]. در بسیاری از سیستم‌های موجودی، فاسدپذیری اقلام یک پدیده واقعی است. برخی داروها، مایعات فرار، مواد غذایی و بسیاری دیگر از کالاها، دچار پدیده زوال در طول دوره انبارش خود می‌شوند. بنابراین هنگامی که سیاست بهینه موجودی برای این نوع محصولات مدنظر باشد، از دست رفتن این اقلام در اثر پدیده زوال نمی‌تواند مورد چشم‌پوشی قرار گیرد [۲۱]. 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 [۱۷]. یکی از جدیدترین روش‌های پیش‌بینی، رویکرد شبکه‌های عصبی مصنوعی^۱ می‌باشد، که به موازات مدل‌های سنتی وارد ادبیات اقتصاد کاربردی شده است و به‌صورت الگوی غیرخطی سری زمانی می‌باشد. 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 [۱۰].

۳- پیشینه پژوهش

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.

^۱ Artificial Neural Network

روش‌هاست.

۴- شبکه عصبی پیشخور

شبکه عصبی مصنوعی را اولین بار مک کولاک و پیتس^۹ در سال ۱۹۴۳ میلادی معرفی کردند. از این روش برای مدت‌های طولانی استفاده نمی‌شد، اما بعدها با توسعه رایانه‌ها و همچنین ظهور الگوریتم آموزش پس از انتشار خطا برای شبکه‌های پیش‌خور^{۱۰} در سال ۱۹۸۶ میلادی توسط رامهارت^{۱۱} و همکاران، استفاده از شبکه عصبی وارد مرحله‌ای تازه شد [۹]. در سال‌های اخیر شبکه‌های عصبی به‌عنوان رقیبی در مقابل روش‌های سنتی اقتصادسنجی مورد توجه واقع شده‌اند و به سرعت در حال پیشرفت و گسترش می‌باشند. شبکه‌های عصبی مصنوعی مدل‌های ریاضیاتی از مغز انسان هستند [۴]. مدل شبکه‌های عصبی مصنوعی یکی از مدل‌های غیرخطی رایج است که به‌صورت گسترده‌ای برای پیش‌بینی تقاضا استفاده شده است. مدل‌های ANN از 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 [۳۱]. 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 [۱۲]. پردازش‌ها در لایه یا لایه‌های پنهان یا میانی انجام می‌شود و در لایه خروجی، مقادیر خروجی یا پاسخ شبکه تولید می‌شوند. نرون‌ها در هر لایه با اتصالات وزن‌دار، به هم مرتبط هستند و وزن آن‌ها در ابتدا اغلب به‌صورت تصادفی انتخاب شده و سپس بر اساس مطابق الگوریتمی که تمایل به حداقل رساندن خطا دارد (الگوریتم یادگیری) تغییر نموده و تنظیم می‌شوند. به هر نرون در شبکه عصبی دسته‌ای از ورودی‌ها به صورت بردار ورود $X=(x_1, x_2, \dots, x_n)$ و $P=(P_1, P_2, \dots, P_R)$ اعمال می‌شوند. هر ورودی در وزن متناظرش ضرب می‌شود، سپس همه ورودی‌ها با یکدیگر جمع می‌شوند و ورودی خالص نرون حاصل می‌شود.

همچنین اگر دسته وزن‌ها به‌صورت بردار: $W'=(w_1, w_2, \dots, w_r)W$ $=(w_1, w_2, \dots, w_n)$ نشان داده شوند، مقدار خالص ورودی همان‌طور که در رابطه (۱) ارائه شده است، از ضرب بردار W و X بعلاوه مقدار بایاس، به دست می‌آید و سپس این مقدار توسط تابع انتقال یا تحریک f پردازش

نتایج مطالعه نشان داد که مدل غیرخطی شبکه عصبی خود رگرسیون (NNAR) در پیش‌بینی قیمت خرده‌فروشی گوجه‌فرنگی دارای عملکرد بهتر نسبت به روش‌های دیگر است. دشتی و محمدی (۱۳۹۰) به پیش-بینی 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 بوساراونگز^۱ (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^۲، فرسی^۳، ساویوزی^۴ و وینسی^۵ (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^۶ (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^۷ (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^۸ (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 قسمت گذاری را برای کالاهای فاسدشدنی غیر آنی 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

¹ ko and Bosarrawongs

² Bagnasco

³ Fresi

⁴ Saviozzi

⁵ Vinci

⁶ Guarnaccia & quartieri

⁷ Padip Kumar Bala

⁸ Demographic

⁹ Maccolac & pits

¹⁰ Fee forward back propagation

¹¹ Ramhart

۶- فرآیند خود رگرسیون میانگین متحرک انباشته

یکی از روش‌های معروف مدل‌سازی و پیش‌بینی سری زمانی، روش خود رگرسیون میانگین متحرک انباشته (ARIMA) است. فرآیند عمومی مدل ریاضی $ARIMA(p,d,q)$ را می‌توان به صورت زیر نوشت [۲۲]

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad \text{رابطه ۳}$$

در فرآیند $ARIMA(p,d,q)$ ؛ p ، d و q به ترتیب بیان‌گر تعداد جملات فرآیند خود رگرسیون، مرتبه انباشتگی و تعداد جملات فرآیند میانگین متحرک هستند. یکی از مسائل مهم در این فرآیند ساکن بودن سری زمانی است. یک سری زمانی در صورتی ساکن است که قدر مطلق ریشه‌های آن بزرگ‌تر از واحد باشند. در صورتی که سری زمانی مورد مطالعه مانا باشد d برابر صفر خواهد بود که در نتیجه فرآیند $ARIMA(p,d,q)$ تبدیل به فرآیند $ARMA(p,q)$ می‌شود. در صورت غیر ساکن بودن سری زمانی، برای مانا کردن آن نیاز به تفاضل‌گیری از سری زمانی است. از آنجاکه اغلب متغیرهای اقتصادی نامانا هستند، برای این متغیرها d برابر تعداد تفاضل‌گیری‌ها می‌باشد. برای تخمین الگوی $ARIMA$ یا $ARMA$ از روش باکس جنکینز استفاده می‌شود که دارای چهار مرحله است [۱]. مرحله اول شناسایی است که در این مرحله مقادیر واقعی p ، d و q باید تعیین می‌شوند. در این مرحله از آزمون‌های متعددی بهره گرفته می‌شود. از جمله این آزمون‌ها می‌توان به نمودار خودهمبستگی^۴ یا نمودار خودهمبستگی جزئی^۵ و آزمون دیککی فولر^۶ تعمیم‌یافته اشاره کرد. همچنین در این مرحله از معیارهای آکائیک و شوارتز نیز زیاد استفاده می‌شود. در مرحله دوم بعد از شناسایی شاخص‌های اصلی و تعداد جملات وقفه AR و MA پارامترهای مدل با استفاده از روش حداقل مربعات برآورد می‌شوند. در این مرحله در بعضی موارد به جای روش حداقل مربعات از روش حداکثر درست‌نمایی استفاده می‌شود. در مرحله سوم پس از انتخاب مدل $ARIMA$ و تخمین پارامترهای آن، دقت و اعتبار الگو مورد بررسی و آزمون قرار می‌گیرد. در این مرحله از آزمون‌های تک‌ و کلی رگرسیون استفاده می‌شود. مرحله چهارم، پیش‌بینی می‌باشد. در این مرحله با استفاده از الگوی برآورد شده به پیش‌بینی سری زمانی در داخل نمونه و یا خارج نمونه اقدام می‌شود [۳۰].

۷- روش تلفیقی مدل $ARIMA$ و ANN


سیستم ترکیبی مدنظر در این مقاله، در واقع ترکیبی از روش شبکه عصبی چندلایه با مدل سری زمانی $ARIMA$ است که چارچوب کلی آن در شکل شماره (۲) ارائه شده است.

می‌شود تا مقدار خروجی یا سیگنال خروجی سلول یا نرون همانطور که در رابطه (۲) ارائه شده، محاسبه شود. این روند از نرون‌های پردازشی در لایه پنهان آغاز و تا محاسبه سیگنال خروجی نرون در لایه خروجی که همان پاسخ شبکه است، ادامه می‌یابد:

$$\text{net} = p \cdot w + \text{bias} = \sum p_i \cdot w_i + \text{bias} \quad \text{رابطه ۱}$$

$$a = f(W_p + b) \quad \text{رابطه ۲}$$

شبکه عصبی مصنوعی نمی‌تواند در مورد کارهایی که انجام می‌دهد، استدلال کند و این مورد ضعف شبکه عصبی مصنوعی به شمار می‌آید؛ بنابراین در حال حاضر، تحقیقات درباره دسته‌ای از سیستم‌های هوشمند مصنوعی با قابلیت یادگیری و سیستم‌های مبتنی بر قاعده با قابلیت توضیح و استدلال انجام می‌شود (کازمی و همکاران، ۱۳۹۰). در تحلیل مسائل پیچیده، به دو دلیل مهم شکل شبکه عصبی مصنوعی عمل کرد بهتری دارد: ۱. با برخورداری از توانایی تشخیص الگو، میان ورودی و خروجی داده‌های پدیده موردنظر رابطه خوبی برقرار می‌کند؛ ۲. در قیاس با دیگر الگوها، حساسیت کمتری به وجود خطا در اطلاعات ورودی نشان می‌دهد [۸].



شکل (۱): نمای کلی لایه‌های شبکه عصبی مصنوعی [۸]

۵- آموزش شبکه

روش‌های یادگیری شبکه MLP بر پایه الگوریتم یادگیری پس از انتشار خطاست. سه روش یادگیری برای این منظور وجود دارد؛ شبکه با ضریب یادگیری ساده^۱، شبکه با ضریب یادگیری متغیر^۲ و شبکه MLP که از الگوریتم لونیبرگ-مارکوارد^۳ استفاده می‌کند. در این پژوهش، از روش MLP و الگوریتم لونیبرگ-مارکوارد استفاده شده است. چرا که این الگوریتم در مقایسه با سایر الگوریتم‌های پس از انتشار خطا دارای سرعت بیشتری است. آنچه در کار با شبکه عصبی اهمیت بسیار دارد، جلوگیری از یادگیری بیش‌ازحد شبکه است، زیرا در این حالت شبکه به جای یادگیری و درک روابط بین پارامترها، شروع به از بردن اطلاعاتی می‌کند که در اختیار آن گذاشته می‌شود [۲۳]. برای جلوگیری از این خطا، باید در تکرارهای مشخصی شبکه را با اطلاعات دیگری آزمون. در اینجا باید با کاهش میزان خطا در مرحله آموزش، میزان خطا در مرحله آزمایش نیز کاهش یابد.

¹ trainbp
² trainbpx
³ LMA

⁴ Auto correlation
⁵ Partial auto correlation
⁶ Augmented Dicky Fuller


$$MAPE = \frac{1}{n} \sum_{k=1}^n \left| \frac{X_k - \hat{X}_k}{X_k} \right|, \text{ for } k = 1, 2, \dots, n \quad (\text{رابطه ۶})$$

$$NMSE = \frac{\sum_{k=1}^n (X_k - \hat{X}_k)^2}{\sum_{k=1}^n (X_k - X_0)^2}, \text{ for } k = 1, 2, \dots, n \quad (\text{رابطه ۷})$$

که در روابط ۴ و ۵؛ obs: مقادیر مشاهده‌ای، pre: مقادیر پیش‌بینی شده توسط شبکه مدل و N: تعداد کل داده‌ها و در رابطه ۶ و ۷؛ n: تعداد دوره‌ها، \hat{X}_k : مقدار پیش‌بینی دوره K ام، X_{0k} : مقدار واقعی دوره K ام و X_0 : میانگین مقدار واقعی تمام دوره‌ها در هر مرحله از آزمون‌های آموزش و آزمایش است. 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 [۲۵]. ضریب تعیین، میانگین مربعات خطا و میانگین قدر مطلق خطا در نرم‌افزار MATLAB R2016a در شاخه Neural Network محاسبه شده است.

۹- مدل سازی و پیش‌بینی تقاضا با استفاده از مدل ANN_{mtp}

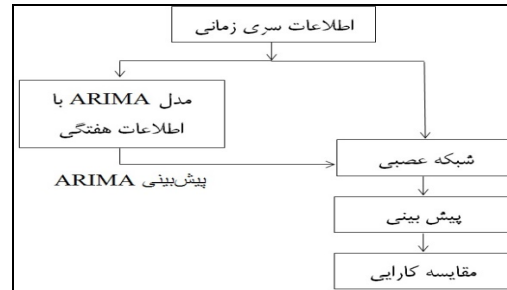
ساختار مورد استفاده برای مدل کردن، پهنه‌بندی شبکه‌هایی با ساختار پیش رو^۵ است و در این تحقیق از شبکه پرسپترون چندلایه (پیشخور)^۶ استفاده شده است. تابع سیگموئید به‌عنوان تابع فعال‌سازی برای هر واحد پردازشگر در شبکه انتخاب شده است. قابل ذکر است، در این شبکه تابع سیگموئید $(f(x) = 1/(1+e^{-x}))$ و تابع همانی $(f(x) = x)$ به ترتیب به عنوان تابع تحریک نرون‌های لایه مخفی و نرون‌های لایه خروجی استفاده شده است. به‌منظور تعیین بهترین ساختار برای شبکه عصبی، تعداد زیادی شبکه عصبی ایجاد شد که در تعداد نرون‌های موجود در لایه پنهان و ضریب یادگیری متفاوت بودند. برای به دست آوردن مقدار بهینه هر پارامتر شبکه، شبیه‌سازی‌های متفاوتی انجام شد که در تمام شبیه‌سازی صورت پذیرفته شاخص متوسط مجذور خطا به‌عنوان شاخص راهنما، بیانگر کارایی شبکه در یادگیری الگوهای موجود است. شکل (۳) نشان‌دهنده تعداد نرون‌های هر لایه می‌باشد.



شکل (۳): تعداد نرون‌های عصبی در هر لایه (منبع: یافته‌های تحقیق)

برای مرحله آموزش شبکه از داده‌های ۱۵۶ هفته طی سال‌های ۱۳۹۲ تا آخر ۱۳۹۴ استفاده شد و داده‌های دوازده هفته باقی‌مانده هم برای آزمایش شبکه و اعتبار سنجی مدل مورد استفاده قرار گرفت. با افزایش

^۵ Feed forward
^۶ MLP



شکل (۲): الگوی ترکیبی روش شبکه عصبی با مدل سری زمانی

3] ARIMA

اولین گام در به‌کارگیری روش ترکیبی، استفاده از الگوی ARIMA برای مدل‌سازی جزء خطی سری زمانی مورد بررسی و به دست آوردن پیش‌بینی‌هایی از آن برای هفته‌های مدنظر است. همان‌طور که بیان شد، الگوی ARIMA مبتنی بر روابط خطی پارامترهای سیستم است و بر این اساس می‌تواند روابط خطی را با عملکرد بالایی پیش‌بینی نماید، اما در حالتی که روابط غیرخطی باشند، این روش دیگر هیچ قابلیت ندارد. در مقابل، ارزیابی شبکه‌های عصبی در مطالعات متعدد حاکی از عملکرد مناسب آن‌ها برای مدل‌سازی روابط غیرخطی است. به همین دلیل، شبکه عصبی در مرحله دوم برای مدل‌سازی جزء غیرخطی سری زمانی مورد مطالعه در این مقاله و همچنین تمامی روابطی که توسط ARIMA توضیح داده نشده است، استفاده می‌شود؛ بنابراین، در گام دوم، پیش‌بینی‌های به‌دست‌آمده از طریق الگوی ARIMA در گام اول و همچنین اطلاعات سری زمانی به‌عنوان ورودی شبکه عصبی مصنوعی منظور می‌گردد. در گام سوم، شبکه عصبی برای پیش‌بینی مقادیر آینده سری زمانی مربوطه به کار گرفته می‌شود.

۸- معیارهای ارزیابی مدل‌ها


به‌منظور ارزیابی و مقایسه نتایج روش‌ها و مدل‌های به‌کاربرده شده در این پژوهش، از شاخص‌های آماری مانند میانگین مربعات مجذور خطا^۱، ضریب تعیین^۲، میانگین قدر مطلق خطا^۳ و نرمال میانگین مربعات خطا^۴ استفاده شده است که به ترتیب:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (obs - pre)^2}{n}} \quad (\text{رابطه ۴})$$

$$R^2 = \frac{\sum_{i=1}^n (obs - \bar{obs})(pre - \bar{pre})}{\sqrt{\sum_{i=1}^n (obs - \bar{obs})^2 \sum_{i=1}^n (pre - \bar{pre})^2}} \quad (\text{رابطه ۵})$$

^۱ Root mean square error
^۲ Random error
^۳ Mean absolute error
^۴ Normalized Mean Square Error

بنابراین، با انتخاب شبکه‌ای با هشت نرون در لایه میانی، همه خطای شبکه برای داده‌های آموزشی در اطراف صفر توزیع پیدا می‌کند و توزیع خطاها بایاس چندانی به‌طرف خاصی ندارد و این نشان‌دهنده عمل کرد بسیار خوب شبکه در تعلیم داده‌های آموزشی^۱ است (شکل ۵).



شکل (۵): عمل کرد شبکه (منبع: یافته‌های تحقیق)

سیستم‌های عصبی مصنوعی قوانین مختلف یادگیری دارند که یکی از آن‌ها، قانون یادگیری پس از انتشار خطاست که در این تحقیق از آن استفاده شده است. در این قانون، بین نرون‌های یک‌لایه هیچ ارتباطی وجود ندارد؛ ولی خروجی هر نرون به ورودی نرون‌های لایه بعد متصل می‌شود. زمانی که مقادیر معلوم در مسئله (X_i) به لایه‌های ورودی ارائه می‌شود، در وزن اتصال‌های بین لایه ورودی و لایه بعد (W_{ij}) ضرب و به نرون‌های لایه بعد منتقل می‌شود. در لایه بعدی، تمام ورودی‌های هر نرون باهم جمع می‌شوند رابطه (۸)؛ ضمن اینکه می‌توان مقدار ثابتی به‌عنوان بایاس (W_0) به این مقدار اضافه کرد و مجموعه به‌دست‌آمده از تابعی به نام فعالیت می‌گذرد تا خروجی نرون به دست آید [۲۰].


$$F(\text{net}_j) = f\left(\sum_{i=1}^n W_{ij}X_i + W_0\right) \quad \text{رابطه ۸}$$

پس از عرضه نمونه‌های آموزشی به شبکه، وزن شبکه (پارامترهای آزاد) به‌گونه‌ای اصلاح می‌شوند که تفاوت پاسخ مطلوب و خروجی واقعی شبکه کمینه شود. این فرآیند با نمونه‌های ورودی تکرار می‌شود تا اینکه شبکه به حالت پایدار برسد و تغییر زیادی در وزن‌ها رخ ندهد [۹]. با مقایسه مقادیر خروجی که توسط شبکه تخمین زده می‌شود با مقادیر مطلوب که به شبکه ارائه شده است میزان خطا تعیین شده، به لایه‌های قبل هم تعمیم داده می‌شود تا در تنظیم وزن‌ها مورد استفاده قرار گیرد.

^۱. Train data


تعداد لایه‌های اطلاعاتی تا حد معینی، میزان توانایی شبکه برای پیش‌بینی افزایش می‌یابد. در این تحقیق؛ متغیرها و شاخص‌های ورودی مدل با مصاحبه چندین تن از مدیران و سرپرستان فروشگاه‌ها و خبره‌ها در این زمینه مشخص شده است. اهمیت این شاخص‌ها از این جهت است که در زمان وقوع این شاخص‌ها میزان عرضه و تقاضای محصولات گوشت فروشگاه افزایش یا کاهش می‌یابد. این متغیرها عبارت‌اند از: شاخص روزهای ماه مبارک رمضان، شاخص روزهای ماه محرم، شاخص روز پرداخت حقوق مشتری روزهای ۲۹،۳۰،۱ هرماه و روز ۳۱ در شش ماه اول سال، شاخص روز تعطیلی (آخر هفته‌ها) و شاخص روز عید نوروز؛ بنابراین لایه ورودی شامل پنج نرون است که تعداد عوامل مؤثر را نشان می‌دهد و در هر شبکه با افزایش تعداد لایه‌ها، خروجی به مقادیر واقعی نزدیک‌تر شده، عملکرد شبکه برای تعداد نرون‌های مختلف موردبررسی قرار گرفت و در نهایت در بهینه‌ترین حالت با انتخاب هشت نرون در لایه میانی، بهترین خروجی دریافت می‌شود و شبکه در لایه پنهان از نرون هشتم به بعد با کاهش دقت در خروجی همراه می‌شود و در هر شبکه، خروجی با میانگین مجذور خطا و برازش رگرسیون کنترل می‌شود. **سرانجام لایه خروجی شامل یک نرون است.**

شبکه با هشت نرون در لایه میانی و در تکرار ششم با مقدار $MSE = 1.075$ بهترین عملکرد را دارد (شکل ۴). فرآیند یادگیری شبکه به این صورت است که ابتدا رکوردهای مربوط به یادگیری به شبکه وارد می‌گردد. وزنه‌های اولیه اتصالات بین نرون‌ها به‌صورت تصادفی توسط شبکه تنظیم می‌گردند. پس از بارگذاری داده‌های مجموعه یادگیری و تنظیم وزن‌های شبکه، اولین رکورد داده به‌عنوان ورودی به شبکه اعمال شده و خروجی شبکه با استفاده از توابع و الگوریتم یادگیری محاسبه شده و با خروجی مطلوب مقایسه می‌گردد. در اینجا شبکه با استفاده از خطای حاصله وزن‌های شبکه را تغییر می‌دهد. این عملیات برای کل داده‌های آزمایش اعمال می‌گردد. پس از اعمال هر ورودی وزن‌های شبکه به‌هنگام می‌گردند و هر بار تکرار فرآیند فوق برای کل داده‌های آموزش یک سیکل یا epoch نام دارد. بعد از هر epoch میانگین مربعات خطا محاسبه شده و با MSE هدف مقایسه می‌شود. در صورتی که خطا بزرگ‌تر از خطای هدف باشد دوباره epoch دیگر شروع می‌شود. در اینجا شرط توقف یادگیری، رسیدن به خطای هدف می‌باشد.



شکل (۴): برازش تعداد دفعات تکرار در شبکه عصبی (عملکرد اعتبار سنجی شبکه بهینه)

مقادیر واقعی و پیش‌بینی نیز در شکل (۷) نمایش داده شده است که در مدل شبکه عصبی با توجه به داده‌های هفتگی از ابتدای سال ۱۳۹۲ تا هفته ۱۲ سال ۱۳۹۵ در نرم‌افزار متلب به دست آمده است. همان‌طور که ملاحظه می‌شود مقادیر پیش‌بینی شده خیلی نزدیک به مقادیر واقعی می‌باشند. البته بعضی قسمت‌ها مقادیر پیش‌بینی، کمی از مقادیر واقعی فاصله گرفته است زیرا در شبکه عصبی ساختار بهینه‌ای وجود ندارد و بهترین عملکرد شبکه در همین حد می‌باشد و نباید انتظار فراتر از شبکه داشت.



شکل (۷): مقادیر واقعی و پیش‌بینی شده (منبع: یافته‌های تحقیق)

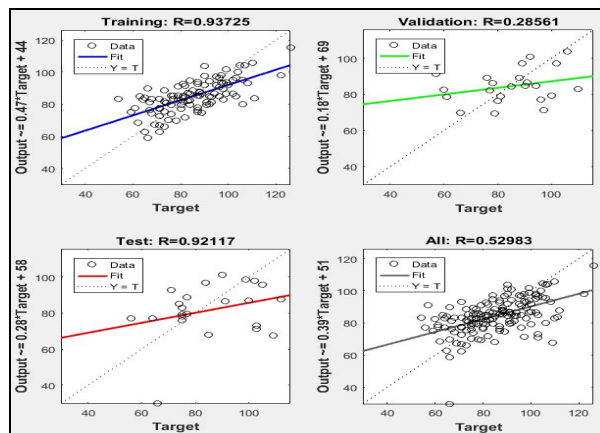
۱۰- مقایسه نتایج پیش‌بینی

چهار مدل ارائه شده ANN_{mlp} ، روش ترکیبی، ARIMA و میانگین متحرک ۱۴ روزه، مبتنی بر عملکرد مجموعه داده‌های آموزشی ۱۵۶ هفته و مجموعه داده‌های آزمایشی ۱۲ هفته باهم مقایسه شده‌اند. مقایسه پیش‌بینی هفتگی در جدول (۱) به صورت جداگانه نشان داده شده است. مشخص شده است که پیش‌بینی شبکه عصبی مصنوعی پرسپترون چندلایه (پیشخور)، از دقت بسیار بالاتری نسبت به دیگر مدل‌های ارائه شده برخوردار است. نکته حائز اهمیت در این پژوهش این است که روش ترکیبی شبکه عصبی و ARIMA خطای بیشتری را نسبت به مدل شبکه عصبی به طور جداگانه داشته است. در صورتی که در بیشتر پژوهش‌های گذشته در زمینه‌های مختلف، روش ترکیبی دقت بالاتری را نسبت به مدل‌های دیگر داشته است. همان‌طور که در این جدول مشاهده می‌شود، مقادیر خطای شبکه عصبی و روش ترکیبی بسیار بهم نزدیک‌اند و شبکه عصبی با اندکی اختلاف از دقت بالاتر پیش‌بینی برخوردار است.

جدول (۱): مقایسه مدل‌های پیش‌بینی به صورت هفتگی (مأخذ: یافته‌های تحقیق)

مدل‌های پیش‌بینی	Training set			Test set			Training set	Test set
	NMSE	MAPE	RMSE	NMSE	MAPE	RMSE	R ²	R ²
14-Day Moving Average	۳۷/۹	۴۳/۱۵	۴/۶۱۳	۴۱/۱	۵۲/۳۸	۴/۷۴	۰/۳۷۶	۰/۳۲۴
ARIMA	۱۶/۲	۲۱/۴۸	۱/۹۲۲	۱۷/۵	۲۶/۶۴	۲/۴۷	۰/۸۹۲	۰/۸۴۱
روش تلفیقی ARIMA و ANN	۱۲/۳۱	۱۸/۸۴	۱/۴۳۱	۱۴/۱۷	۲۳/۵۸	۱/۵۹	۰/۹۱۳	۰/۹۰۶
ANN_{mlp}	۱۱/۵	۱۶/۹۹	۱/۰۷۰	۱۲/۳	۱۹/۷۳	۱/۲۲	۰/۹۳۷	۰/۹۲۱

به تعبیری دیگر، وزن‌ها در تمام لایه‌ها تغییر می‌کنند و در فرآیند یادگیری تعیین می‌شوند. با تغییر تعداد نرون‌های میانی و تغییر وزن‌ها به صورت سعی و خطا، مناسب‌ترین مدل شبکه عصبی برای مسئله موردنظر به دست می‌آید. مدل بهینه زمانی حاصل می‌شود که شبکه عصبی بهترین پردازش را با کمترین خطا و بهترین برازش بین خروجی شبکه و مقادیر اندازه‌گیری شده را انجام دهد. با بررسی پاسخ‌های خروجی شبکه عصبی مصنوعی در مرحله آزمایش مشخص شد که شبکه عصبی ایجاد شده قادر است تقاضای محصولات فروشگاه زنجیره‌ای اتکا را با دقت ۹۳ درصد درستی گزارش دهد که نشان‌دهنده حساسیت تشخیص معادل ۰/۹۳۷ و نیز توانایی زیاد این روش در شبیه‌سازی تقاضای محصولات این فروشگاه است. در شکل (۶) مقادیر خطا برای هر یک از داده‌های آموزشی، آزمایشی و اعتبار سنجی و مجموع کل داده‌ها نشان داده شده است.



شکل (۶): دقت شبکه عصبی مصنوعی جهت پیش‌بینی در مرحله آموزشی

۱۱- ارزیابی عملکرد موجودی مبتنی بر نتایج مدل‌های پیش‌بینی

برای بررسی و تحلیل سیاست مدیریت دوره‌های سطح موجودی، چهار مدل پیش‌بینی با توجه به دو شاخص عملکرد^۱ با یکدیگر مقایسه شده‌اند:

- بررسی میزان سطح موجودی^۲ محصول در روزهای بدون کمبود (به‌صورت: موجودی / میانگین فروش روزانه^۳)؛ و

- خدمت به مشتری^۴ (درصد روزهایی که فروشگاه با کمبود مواجه است و نمی‌تواند به مشتری خدمت رسانی کند «درصد روزهای شکست فروش^۵». درواقع، سطح خدمت به مشتری به‌صورت معکوس با «درصد روزهایی که فروشگاه منجر به عدم فروش شده» متناسب است. در سیاست مدیریت دوره‌های سطح موجودی با استفاده از پیش‌بینی روزانه، مرور سطوح موجودی برای محصولات هر P روز انجام می‌شود و سفارش خرید باید حداقل L روز^۶ (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^۷ است. هم میانگین تقاضای (m₀) 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 زنجیره‌ای اتکا دریافت گردید برای بررسی میزان حجم مرور دوره‌های سطح موجودی محصولات استفاده شد. سطح موجودی در شرایط کمبود غیرمجاز با استفاده از مدل‌های ارائه‌شده مورد بررسی قرار گرفت و شبیه‌سازی انجام‌شده و برای پیش‌بینی هفتگی، داده‌های زیر استفاده شده‌اند:

- P برابر ۳ هفته
- L برابر ۱ هفته
- سطح خدمت برابر ۹۰٪

جدول (۲): روابط محاسبه سطح موجودی مطلوب [14].

رابطه (۹) میانگین تقاضای روزانه = میانگین تقاضای هفتگی تقسیم‌بر ۷
رابطه (۱۰) انحراف معیار تقاضای روزانه = انحراف معیار تقاضای هفتگی تقسیم‌بر ۷ ^۷
رابطه (۱۱) انحراف معیار تقاضای (P+L) روز = انحراف معیار تقاضای روزانه × $\sqrt{(P+L)}$
رابطه (۱۲) ذخیره احتیاطی = Z × انحراف معیار تقاضای (P+L) روز
رابطه (۱۳) سطح موجودی مطلوب یا هدف (T) = میانگین تقاضای روزانه × (P+L) + ذخیره احتیاطی
رابطه (۱۴) مقدار سفارش (Q) = سطح موجودی - T

با جای‌گذاری مقادیر تقاضای پیش‌بینی شده محصول گوشت از مدل-های شبیه‌سازی شده و دیگر مقادیر معلوم، در رابطه‌های جدول (۲)؛ مقادیر مجهول نظیر انحراف معیار تقاضای روزانه، ذخیره احتیاطی و در نهایت سطح موجودی مطلوب (هدف) به دست می‌آید.

مقادیر شاخص‌های عملکرد موجودی به‌دست‌آمده حاکی از آن است که مدل جاری فروشگاه "میانگین متحرک ۱۴ روزه"، عملکرد ضعیف‌تری را نسبت به سه مدل دیگر در پی داشته است و اگرچه هم مدل ترکیبی، هم ARIMA و هم مدل ANN_{mlp} نسبت به مدل جاری فروشگاه موفقیت بیشتری را داشته‌اند اما مدل شبکه عصبی پرسپترون چند لایه، بهبود قابل‌ملاحظه‌ای را در عملکرد موجودی محصول فرآورده گوشتی این فروشگاه نسبت به سه مدل دیگر داشته است جدول (۳).

جدول (۳): عملکرد سطح موجودی (منبع یافته‌های تحقیق)

مدل / روزه موجود	شرح مدل	شاخص عملکرد موجودی		
		تعداد هفته‌های مواجه با شکست فروش	درصد هفته‌های مواجه با شکست فروش	سطح موجودی مطلوب (میانگین موجودی روزانه / فروش روزانه)
مدل فروشگاه (یافته‌های واقعی)	میانگین متحرک ۱۴ روزه	۱۶ هفته	۳۰/۷۶ درصد	(kg)۱۷۸/۲۱
نتایج شبیه‌سازی شده	مبتنی بر مدل ARIMA	۱۲ هفته	۲۳/۰۷ درصد	(kg)۹۴/۰۴
	مبتنی بر مدل ترکیبی	۸ هفته	۱۵/۳۸ درصد	(kg)۴۲/۹۴
	مبتنی بر مدل ANN _{mlp}	۷ هفته	۱۳ درصد	(kg)۳۲/۳۶

¹ Key Performance Indicators (KPIs)

² Inventory Level

³ Daily sales average

⁴ Customer service

⁵ Percentage of days with sales failure

⁶ Lead time

⁷ safety stock

نتایج شاخص‌های عملکرد موجودی در جدول شماره (۳) نمایان شده‌اند. همان‌طور که در این جدول مشاهده می‌شود، تعداد هفته‌هایی که فروشگاه زنجیره‌ای اتکا با کمبود محصول گوشت مواجه شده؛ در زمان استفاده از مدل جاری فروشگاه "میانگین متحرک ۱۴ روزه"، برابر ۱۶ هفته از ۵۲ هفته می‌باشد. این بدین معنی است که این فروشگاه فقط ۳۶ هفته توانسته نیازهای مشتریان را در محصول گوشت تأمین کند و به مدت ۱۶ هفته با کمبود مواجه شده است. همچنین در ادامه مدل شبکه عصبی شبیه‌سازی شده به‌طور قابل چشم‌گیری این کمبود را کاهش دهد و به ۷ هفته برساند. همچنین اعدادی که در قسمت سطح موجودی مطلوب به‌دست آمده نمایانگر این است که در زمان استفاده از مدل میانگین متحرک میزان حجم گوشت باقیمانده به‌طور میانگین در انتهای هفته ۱۷۸،۲۱ کیلوگرم، در مدل ARIMA این میزان به مقدار ۹۴/۰۴ کیلوگرم، در مدل ترکیبی ۴۳/۹۴ کیلوگرم و در مدل ANN به ۳۲/۳۶ کیلوگرم کاهش یافته است. در فروشگاه‌های مواد غذایی فسادپذیری کالای انزال پذیر به‌ویژه گوشت از اهمیت بسزایی برخوردار است، زیرا هر چه مدت‌زمان بیشتری از تولید این محصولات بگذرد احتمال فسادپذیری افزایش یافته و به عمر انزال خود نزدیک‌تر می‌شوند.

۱۲- نتیجه‌گیری

در این مطالعه سیستم هوش تجاری^۸ ارائه شده 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 مواجه با کمبود (سفرارش 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 این پژوهش، نسبت به تحقیقات پیشین محسوب می‌شود. بررسی میزان سطح موجودی، دلالت بر کاهش سطح موجودی محصول در حالت کمبود دارد و همین‌طور کاهش روزهای شکست فروش نشان‌دهنده افزایش سطح خدمت می‌باشد. عملکرد مدل ارائه شده شبکه عصبی مصنوعی پیش‌خور 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 باگناسکو و همکاران (۲۰۱۵)، گوارناسیا و کوآرت (۲۰۱۵)، جنگ کو و همکاران (۲۰۱۴)، قاسمی، تقی‌نژاد و فانی (۱۳۹۶)، سیفال‌حسینی و همکاران (۱۳۹۴)، ... اشاره کرد. همچنین در پژوهش کاماربالا (۲۰۱۲) که به ارائه یک مدل پیش‌بینی برای خرده‌فروشان بر اساس تقسیم‌بندی مشتری، به‌منظور بهبود عملکرد

منابع و مأخذ

- [۱] ابریشمی، حمید، غنیمی‌فرد، حجت‌الله، احراری، مهدی، رضایی، منیژه، (۱۳۸۹)، پیش‌بینی قیمت گازوئیل خلیج فارس، مبتنی بر تحلیل تکنیکی و شبکه‌های عصبی، فصلنامه مطالعات اقتصاد انرژی، سال هفتم، شماره ۲۴، ص ۱۷۱-۱۹۲.
- [۲] تقی‌نژاد، یاسر، (۱۳۹۶)، بهبود عملکرد موجودی مبتنی بر پیش‌بینی تقاضا با خوشه‌بندی مشتریان، فصلنامه مدیریت صنعتی دانشگاه سمنان، دوره ۱۲، شماره ۴۱، صفحه ۱۳۳-۱۴۶.
- [۳] جهرمی، غلامی، (۱۳۹۵)، ترکیب مدل شبکه عصبی با الگوی ARIMA برای پیش‌بینی مالیات بر ارزش افزوده در مصرف گاز در ایران، مجله تحقیقات اقتصادی (توسعه پایدار)، شماره دوم، صفحات ۹۹-۱۶۶.
- [۴] امینی، امیر، علی‌نژاد، علیرضا، (۱۳۹۵)، بهینه‌سازی سبدسهم چندهدفه با استفاده

2. Wang and Meng
3. Aburto and Weber
4. Zheng et al

8. Business Intelligence

- از رویکرد جدید بهینه‌سازی کرم میوه، دوره ۱۱، شماره ۳۶، صفحه ۵۹-۷۶.
- [۵] حنفی‌زاده، پیام، جعفری، ابوالفضل، (۱۳۸۹)، مدل ترکیبی شبکه های عصبی مصنوعی پیش خور و خود سازمانده کوهونن برای پیش بینی قیمت سهام، فصل- نامه مطالعات مدیریت صنعتی، دوره ۸، شماره ۱۹، صفحه ۱۶۵-۱۸۷.
- [۶] قاسمی، احمدرضا، تقی نژاد، یاسر، فانی، رضا، (۱۳۹۶)، استفاده از هیات شبکه عصبی پرسپترون چند لایه در پیش‌بینی تقاضای کالای فاسدشدنی در خرده فروشی‌ها، اولین کنفرانس ملی مطالعات نوین مدیریت، تابستان، ص ۲۱۴-۲۳۴.
- [۷] کاظمی، مهدی، نیک نفس، علی اکبر، رنجبر، وحید، (۱۳۹۰)، کاربرد شبکه های عصبی در پیش بینی فرایندهای تجاری و مدیریتی و مقایسه با مدل های غیر خطی مطالعه موردی: صنعت چوب ایران، فصل‌نامه مطالعات مدیریت صنعتی، دوره ۹، شماره ۲۲، صفحه ۱۹۱-۲۰۸.
- [۸] تقی‌زاده مهرجردی، روح الله، فتاحی اردکانی، احمد، طهاری، محمد حسین، بابایی، حمید، (۱۳۹۴)، پیش‌بینی مصرف انرژی بخش کشاورزی ایران با استفاده از مدل ترکیبی الگوریتم ژنتیک و شبکه‌های عصبی مصنوعی، تحقیقات اقتصاد کشاورزی، جلد ۷، شماره ۱۳، ص ۱۶۶-۱۴۹.
- [۹] مهدی زاده، محمداقبار، (۱۳۸۳)، شبکه‌های عصبی مصنوعی و کاربردهای آن در مهندسی عمران، انتشارات عبادی. چاپ اول.
- [۱۰] محمدی، حمید، کفیل زاده، فرشید، محمد، نقشینه فرد، پیش‌بین، سیامک (۱۳۸۷)، مقایسه قدرت پیش‌بینی روش شبکه عصبی با سایر روش‌های پیش‌بینی، بوم شناسی گیاهان زراعی، دوره ۱۴، ش ۱۳، ص ۸۵ تا ۱۰۰.
- [11] Aburto, L., Weber, R., (2007), **Improved Supply Chain Management Based on Hybrid Demand**, Applied Soft Computing, Vol. 7 No. 1, pp: 136-44
- [12] Anandarjan, M., Anandarjan, A., (1999), **A Comparison of Machine Learning Techniques with a Qualitative Response Model for Auditors Going Cancer Responding**, Experts Systems with Application, No. 16.
- [13] Adhikari, R., (2015), **A Neural Network Based Linear Ensemble Framework for Time Series Forecasting**, Neuro computing, 157(25), 231-242.
- [14] Bala, P., (2012), **Improving Inventory Performance with Clustering Based Demand Forecasts**, Journal of Modelling in Management, Vol. 7 No. 1, pp. 23-37.
- [15] 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.
- [16] Bala, P., Sural, S., Banerjee, R., (2010), **Association Rule for Purchase Dependence in Multi-Item Inventory**, Production Planning&Control, Vol. 21 No. 3, pp: 274-85.
- [17] Baluni, P., Raiwani, YP, (2014), **Vehicular Accident Analysis Using Neural Network**, International Journal of Emerging Technology and Advanced Engineering, 4(9): 161-164.
- [18] Barksdale, H., Hilliard, J., (1975), **A Cross-Spectral Analysis of Retail Inventories and Sales**, Journal of Business, Vol. 48 No. 3, pp: 365-82.
- [19] Chaaben, K., Zied, J., Stefan, M., (2015), **A Lost Sales (r, Q) Inventory Control Model for Perishables with Fixed Lifetime and Lead Time**, International Journal of Production Economics, Volume 168, Pages 143-157.
- [20] Adebisi, A. A., Adewumi, A.O., Ayo, C. K., (2014), **Comparison**
- of ARIMA and Artificial Neural Networks Models for Stock Price Prediction**, Journal of Applied Mathematics, 2014, 1-7.
- [21] Dye, C.Y., (2007), **Joint Pricing and Ordering Policy for a Deteriorating Inventory with Partial Backlogging**, Omega, Vol. 35, pp. 184-189.
- [22] Green W.H., (2000), **Econometric Analysis**, 3th edition, Prentice Hall, Englewood Cliffs, New Jersey.
- [23] Gomez, H., Kavzoglu, T., Mather, P., (2002), **Artificial Neural Network Application in Landslide Hazard Zonation in the Venezuelan Andes**, in Abstracts of 15th International Conference on Geomorphology, Tokyo, Japan, 23-28.
- [24] Goyal, S.K., Giri, B.C., (2001), **Recent Trends in Modeling of Deteriorating Inventory**, European Journal of Operational Research. 134(1-16)
- [25] Ho, S.L., Min, X., Thong Ngee, G., (2002), **A Comparative Study of Neural Network and Box-Jenkins ARIMA Modeling in Time Series Production**, Computers and Industrial Engineering, pp: 371- 375.
- [26] Jose, R., Marco, A., (2015), **Demand Forecasting and Inventory Control: A Simulation Study on Automotive Spare Parts**, International Journal of Production Economics, Volume 161, Pages 1-16.
- [27] Lin, J., (2010), **Empirical Study of Gold Price Based on ARIMA and GARCH Models**, Stockholm's universities.
- [28] Mangan, J., Lalwani, C., Fynes, B., (2008), **Port-Centric Logistics**, The International Journal of Logistics Management, 19(1), 29-41.
- [29] Moon, M., (2003), **Conducting a Sales Forecasting Audit**, International Journal of Forecasting, Vol. 19 No. 1, pp: 5-25.
- [30] Nicholas, j., Ken, k., (2015), **Using R and Rstudio for Data Management, Statistical Analysis, and Graphics**, CRC Press, Taylor & Francis Group. Second Edition. International Standard Book Number, 13: 978-1-4822-3737-5.
- [31] Yao, J., Y. Li., Tn Lin, C., (2000), **Option Price Forecasting Using Neural Network**, Omega.