

پیش بینی تقاضای قطعات یدکی براساس یادگیری ماشین مبتنی بر روش های رگرسیون خطی و شبکه عصبی مصنوعی

مهدی محمدی فشارکی^{۱*}، سعید لندران اصفهانی^{۲**}

^{۱*} دانشجوی دکتری مدیریت بازرگانی - بازاریابی دانشگاه آزاد مبارکه

mmf1360@yahoo.com

^{۲**} عضو هیات علمی رسمی دانشگاه آزاد اسلامی مبارکه و استادیار گروه آموزشی مدیریت

landaran_saeid@yahoo.com

خلاصه

پیش بینی تقاضای قطعات یدکی دستگاه های چاپ برای شرکت های چاپ و بسته بندی موضوعی حیاتی است. دستگاه های چاپ باید به طور موثر عمل کنند و باید از میزان دسترسی بالایی در برنامه ریزی خطوط تولید برخوردار باشند. در عملیات تعمیر و نگهداری، قطعات معیوب یا قطعاتی که طول عمر خود را کامل می کنند باید با یک قطعه جدید جایگزین شوند. قطعات یدکی مورد نیاز باید در موجودی ها با مقدار لازم به موقع باشد. در این بخش هزاران قطعه یدکی برای مدیریت وجود دارد. بخش نگهداری و تعمیرات باید به طور موثر عمل کند. برای انجام این امر، پیش بینی دقیق قطعات یدکی مورد نیاز است. در این تحقیق پیش بینی تقاضا با روش های رگرسیون خطی و شبکه های عصبی مصنوعی صورت پذیرفت. مدل پیش بینی توسعه یافته در این مطالعه شامل متغیرهای حیاتی مانند تعداد سفارشات تولید، نوع خرابی، تعداد تعمیر و نگهداری دوره ای، میانگین زمان بین خرابی و مقدار تقاضا در سال های گذشته می باشد. این برنامه با داده های واقعی پنج ساله (۱۳۹۷-۱۴۰۱) انجام شد. از داده های ۱۳۹۷-۱۴۰۰ برای آموزش و داده های ۱۴۰۰ برای آزمایش استفاده شد. در پیش بینی ها مشاهده شده که شبکه عصبی مصنوعی پیش بینی های دقیق تری نسبت به سایر روش ها ایجاد کرد. پیش بینی های شبکه عصبی مصنوعی بالاترین میزان دقت پیش بینی و کمترین انحراف را نشان می دهند.

کلمات کلیدی: پیش بینی تقاضا؛ قطعات یدکی؛ رگرسیون خطی؛ یادگیری ماشین



دریافت مقاله: 1402/12/20

اصلاحیه مقاله:-

پذیرش مقاله: 1403/01/05

انتشار مقاله: 1403/01/06

دوره: چهارم

شماره: یک

آدرس سایت: nrbste.ir

ایمیل: nrbste@gmail.com

مقدمه

اهمیت مدیریت انبار و قطعات یدکی زمانی مشخص می‌شود که نتایج بررسی‌ها نشان می‌دهد یکی از شایع‌ترین علل توقف فعالیت‌های نگهداری و تعمیرات فقدان قطعات یدکی در لحظه نیاز است. حتی برخی مطالعات اصلی‌ترین علت بالا بودن هزینه‌های نگهداری و تعمیرات را مشکلات مرتبط با مدیریت انبار و قطعات یدکی می‌دانند. ایجاد یک انبار بسته و کنترل شده به طوری که بتواند همیشه موجودی قطعات یدکی را در بهینه‌ترین سطح ممکن نگه دارد و در کم‌ترین زمان ممکن قطعات مورد نیاز را در محل تعمیر حاضر کند می‌تواند تا ۳۰ درصد هزینه‌های نگهداری و ۳۳ درصد از زمان توقفات ناشی از خرابی تجهیزات را کاهش دهد. شیوه درست مدیریت انبار و قطعات یدکی پیش از هر چیز نیازمند تغییر چند باور غلط در ذهن مدیران است.

بر اساس گزارشی که موسسه استاندارد نوین (New Standard Institute) بعد از پیاده‌سازی و استقرار چندین انبار تحت کنترل ارائه داد، تنها یک سوم تا نیمی از اقلام ذخیره شده در سطح کارخانه واقعاً نیازمند ذخیره‌سازی هستند. این آمار به وضوح مسأله موجودی بیش از حد را در انبارهای قطعات یدکی نشان می‌دهد. در حالی که در بهترین حالت همان سطح دسترس پذیری با پنجاه درصد موجودی قابل دستیابی است. این تصور اشتباه که موجودی بیشتر قطعاً به معنی دسترس پذیری بالاتر است باعث ایجاد نوعی برآورد تخمینی در محاسبه سطح نگهداری موجودی در انبارها می‌شود. اگر نگهداری یک قطعه یدکی بتواند دسترس پذیری مدنظر ما را فراهم کند نگهداری دومین قطعه تنها هزینه‌ای اضافی برای هیچ چیز است. روش درست مدیریت انبار و قطعات یدکی با استفاده از روش‌های مناسب بهینه‌سازی می‌تواند سطح بهینه بین دسترس پذیری و هزینه را در بهترین نقطه آن نگه می‌دارد. خارج کردن قطعات بیش از حد از انبار در همان ابتدای پروژه بهبود، ۱۰ تا ۱۵ درصد ارزش انبار را کاهش می‌دهد بدون آنکه ریسک دسترس پذیری قطعات کاهش یابد. از طرفی مطالعات نشان می‌دهد آگاهی از زمان درست خرید مجدد اقلام^۱ نیز منجر به کاهش ۳۰ درصدی هزینه‌های نگهداری می‌شود و می‌تواند توقف عملیات را به میزان ۳۳ درصد کاهش دهد (میزرا آقاییک و همکاران، ۱۴۰۰).

نرخ مصرف قطعات یدکی با یکدیگر بسیار متفاوت است. قطعات کلیدی عموماً نرخ مصرف کمی هم دارند. یکی از تصمیمات اشتباه مدیران برای کاهش هزینه‌های انبار خارج کردن قطعاتی است که برای مدت طولانی در انبار مانده‌اند، بدون آنکه تحلیل درستی از هزینه‌های کمبود آن در انبار داشته باشند. بسیار مهم است تنها قطعاتی از انبار خارج شوند که تجهیز مربوط به آن‌ها از رده خارج شده باشد. تفکیک قطعات موجود در انبار بر اساس نرخ مصرف و اهمیت استراتژیک آن‌ها یکی از نکات کلیدی در مدیریت انبار قطعات یدکی است. مدیریت درست انبار تضمین می‌کند که قطعات یدکی در سطوح متفاوتی نگهداری شوند به طوری که با کم‌ترین هزینه بیشترین دسترس پذیری برای هر قطعه با توجه به اهمیت آن به دست آید.

امروزه فلسفه تامین در لحظه مبحث روز در مدیریت انبار مواد اولیه است. اما آیا انبار قطعات یدکی رفتاری مشابه انبار مواد اولیه دارد؟ نرخ مصرف مواد در انبارهای مواد اولیه به نسبت قابل پیش‌بینی و وابسته به نرخ تقاضا و نرخ تولید است. اما نرخ مصرف قطعات یدکی ماهیتی کاملاً تصادفی داشته و در طیفی وسیع از پرمصرف تا کم‌مصرف متغیر است. از طرفی تعداد زیاد و تنوع بالای اقلام در انبار قطعات یدکی قابل مقایسه با انبار مواد اولیه نیست. بنابراین، این تصور که انبار قطعات یدکی می‌تواند با معیارهای انبار مواد اولیه مدیریت شود یک تصور غلط است.

¹ Reorder Point

پیشینه پژوهش

یک پیش‌بینی تقاضای موفقیت‌آمیز مزایای بسیاری را برای کسب‌وکارها در برنامه‌ریزی تولید، مدیریت موجودی، برنامه‌ریزی مالی و برنامه‌ریزی نیروی کار فراهم می‌کند. پیش‌بینی‌ها به مدیران در تصمیم‌گیری کمک می‌کند. در مدیریت موجودی، اهمیت پیش‌بینی روز به روز بیشتر می‌شود. پیش‌بینی با دقت معینی از قبل، هزینه‌های موجودی بیش از حد و غیر موجودی را کاهش می‌دهد. موجودی شامل مواد اولیه، محصولات نیمه تمام، محصولات نهایی، قطعات یدکی و مواد مصرفی مورد استفاده در محصولات آن می‌باشد. کنترل و نگهداری کافی موجودی‌ها مشکلی حیاتی است که تقریباً همه کسب و کارها تجربه می‌کنند. مدیریت صحیح موجودی‌ها بسیار مهم است، زیرا موجودی‌ها فضای زیادی را اشغال می‌کنند و تولید را بی‌جهت اشغال می‌کنند و به دلیل هزینه‌های زیاد، بار بزرگی بر دوش مشاغل می‌باشد.

هدف اصلی کنترل علمی موجودی، اجرای بدون وقفه تولید با نگهداری مواد اولیه، مواد، قطعات یدکی و سایر ملزومات موجود در بنگاه، نه بیشتر و نه کمتر، بلکه به مقدار کافی است. پیش‌بینی تقاضای قطعات یدکی برای مدیریت موجودی و برنامه‌ریزی حیاتی است. با توجه به ویژگی‌های تقاضای قطعات یدکی، پیش‌بینی تقاضا دشوار است. از این رو، مدیریت موثر قطعات یدکی در بسیاری از صنایع مهم است.

برخی از قطعات یدکی توسط کاربران نهایی مورد استفاده قرار می‌گیرند، در حالی که برخی دیگر در مکان‌هایی مانند تولید و تاسیسات نگهداری استفاده می‌شوند (وندر و همکاران^۱، ۲۰۱۹). بخش‌های نگهداری و تعمیر به قطعات یدکی نیاز دارند تا اطمینان حاصل شود که در زمان خرابی و تعمیرات دوره‌ای، عملکرد مختل نمی‌شود. موجودی قطعات یدکی برای آماده شدن برای نوسانات تقاضا و مشکلات غیرمنتظره ضروری است. در بخش‌های نگهداری و تعمیرات، قطعات یدکی باید با کیفیت، کمیت و زمان مورد نیاز موجود باشد. در غیر این صورت، عدم وجود قطعات یدکی و یا بیش از حد مقدار مورد نیاز منجر به هزینه‌های جدی می‌شود. تعمیر و نگهداری و مدیریت قطعات یدکی یک فرآیند بسیار مهم برای شرکت‌های چاپ و بسته‌بندی است که با تعدد دستگاه و قطعات روبرو هستند (قطعات دستگاه چاپ بالغ بر ۳۵۰۰ قطعه می‌باشد) هزینه نگهداری و قطعات یدکی تقریباً ۱۰ تا ۶۰ درصد از کل هزینه‌ها را شامل می‌شود (هارمن و همکاران^۲، ۲۰۱۷).

در این مطالعه، پیش‌بینی تقاضا برای یک قطعه یدکی حیاتی مربوط به دستگاه‌های چاپ مورد بررسی قرار گرفته است. ابتدا مطالعات در زمینه مرتبط مورد بررسی قرار گرفت.

رینالدی و همکاران^۳ (۲۰۲۳) در پژوهشی با عنوان روشی جدید برای مدیریت موجودی قطعات یدکی در تولید ETO^۴ به بررسی توسعه یک مدل شبیه‌سازی برای مدیریت سطح موجودی قطعات یدکی یک شرکت ETO (مهندسی به سفارش) پرداختند. ابتدا ارقام ناهمگن تجزیه و تحلیل شده و در چهار دسته مختلف طبقه‌بندی شده‌اند. بعداً، یک مدل شبیه‌سازی برای بازتولید سیاست موجودی که در حال حاضر برای نظارت و کنترل آنها استفاده می‌شود، توسعه داده شد. در نهایت، یک روش جدید برای بهبود مدیریت موجودی موجودی فعلی اجرا شده است. نتایج نشان می‌دهد که روش جدید امکان کاهش هزینه کل و حداکثر فضای مورد نیاز برای انبار ارقام را فراهم می‌کند.

فینگ و همکاران^۵ (۲۰۲۳) در پژوهشی با عنوان مدیریت سیستم‌های تولید - موجودی - نگهداری با نظارت بر وضعیت یک سیستم تولید-موجودی-نگهداری (PIM) را مورد مطالعه قرار می‌دهد که در آن یک سازنده به یک پایگاه نصب شده از ماشین‌ها خدمات می‌دهد. هر ماشین حاوی همان جزء حیاتی است که رفتار تخریب آن توسط یک فرآیند مارکوف توصیف شده و از طریق

¹ Vander et al.

² Haarman et al.

³ Rinaldi & et al.

⁴ Engineer to order

⁵ Feng & et al.

نظارت بر شرایط ثبت می شود. هنگامی که وضعیت یک قطعه به آستانه تعویض از پیش تعیین شده می رسد، دستگاه از کار افتاده در نظر گرفته می شود و تا زمان تعمیر دچار جریمه های خرابی می شود. چند سرور تعمیر وجود دارد و دینامیک صف به دنبال مشکل تداخل ماشین (MIP) است. خرابی قطعات و ازدحام سرور اطلاعات تقاضای اولیه را ارائه می دهد که به برنامه ریزی تولید قطعات یدکی در روال آماده سازی کمک می کند. درخواست های برآورده نشده برای قطعات یدکی با پر کردن اضطراری با جریمه های فروش از دست رفته برآورده می شوند.

خان و همکاران^۱ (۲۰۲۳) در پژوهشی با عنوان استفاده از معیارهای عملکرد مرتبط با موجودی در تجزیه و تحلیل یک سیستم تولید انعطاف پذیر تولید/موجودی به شناسایی تأثیر انعطاف پذیری مسیریابی و شرایط بار سیستم بر عملکرد FMS با استفاده از معیارهای عملکرد مربوط به تولید و موجودی پرداختند. برای مدلسازی و مطالعه سیستم از نرم افزار شبیه سازی ARENA استفاده شد. (R, R) سیاست کنترل موجودی در سیستم تولید/موجودی اعمال شد. مشخص شد که با حداکثر بهبود عملکرد در افزایش سطح از صفر به یک. انعطاف پذیری مسیریابی تأثیر قابل توجهی بر تمام پارامترهای عملکرد دارد.

جوزیه و همکاران^۲ (۲۰۲۲) در پژوهشی با عنوان یک چارچوب یادگیری عمیق ترکیبی با CNN^۳ و LSTM دو جهته برای پیش بینی تقاضای کالاهای فروشگاهی به بررسی مجموعه داده های چالش پیش بینی تقاضای مورد فروشگاه از Kaggle برای پیاده سازی چارچوب پیشنهادی خود پرداختند. تازگی اصلی این مطالعه ساخت یک چارچوب CNN-BiLSTM همراه با بهینه ساز Lazy Adam برای پیش بینی دقیق تقاضای محصول از اقلام فروشگاه بود. تکنیک های پیشرفته ی یادگیری ماشین مانند SGD (گرادیان تصادفی کاهش)، رگرسیون خطی، K-نزدیک ترین همسایه، Bagging، جنگل تصادفی، SVR، XgBoost، (تقویت گرادیان) و CNN-LSTM. برای پیش بینی تقاضا اجرا شده و نتایج با مدل پیشنهادی مقایسه شده است. در ارزیابی با معیارهایی از جمله میانگین درصد مطلق خطا (MAPE)، مقدار R-Squared (R2) و میانگین خطای مطلق (MAE)، مشاهده شد که چارچوب پیشنهادی در مقایسه با رویکردهای سنتی دقت بیشتری دارد.

ژئو و همکاران^۴ (۲۰۱۷) در پژوهشی با عنوان یک روش بهبود یافته برای پیش بینی نیازهای قطعات یدکی با استفاده از نظریه ارزش شدید به بررسی روش تجربی را با استفاده از نظریه ارزش افراطی برای مدل سازی دنباله توزیع تقاضای زمان سرب بهبود می دهیم. برای استفاده حداکثری از تعداد محدودی از مشاهدات تقاضا پرداخت. آنها ثابت می کنند که تئوری ارزش شدید را می توان برای دوره های تقاضای زمان پیش بینی که در فواصل زمانی با هم تداخل دارند، اعمال کرد. آنها دو سطح خدمات را در نظر می گیرند: زمان انتظار مورد انتظار و سطح خدمات چرخه. آزمایش های آنها نشان می دهد که روش شان عملکرد موجودی را در مقایسه با روش تجربی بهبود می بخشد و با روش WSS، روش Croston و SBA برای طیف وسیعی از توزیع های تقاضا رقابت می کند.

ژائو و همکاران^۵ (۲۰۱۲) در پژوهشی با عنوان مدل کنترل موجودی چند پله ی چند محصولی با استراتژی بازسازی مشترک بر اساس تحلیل کمبود مطالعات موجود در زمینه کنترل موجودی چند لایه، و با در نظر گرفتن برخی محدودیت ها، استراتژی پر کردن مشترک را اعمال می کند وارد سیستم موجودی شده و یک مدل کنترل موجودی چند مرحله ای چند محصولی ایجاد می کند. سپس از الگوریتمی که توسط الگوریتم ژنتیک (GA) طراحی شده است برای حل مسئله مدل استفاده می شود. در نهایت، به ترتیب مدل را تحت سه استراتژی سفارشی مختلف شبیه سازی گردید. نتیجه شبیه سازی نشان می دهد که مدل ایجاد شده و الگوریتم طراحی شده است توسط GA برتری آشکاری در کاهش هزینه کل چندین محصول چندگانه دارند سیستم موجودی علاوه بر این، امکان سنجی و اثربخشی مدل و روش GA را نشان می دهد.

¹ Khan & et al.

² Joseph & et al.

³ Convolutional Neural Network

⁴ Zhu & et al.

⁵ Zhou & et al.

رگرسیون خطی^۱

رگرسیون خطی نوعی الگوریتم یادگیری ماشینی نظارت شده است که رابطه خطی بین متغیر وابسته و یک یا چند ویژگی مستقل را محاسبه می کند. زمانی که تنها یک ویژگی مستقل وجود داشته باشد به آن رگرسیون خطی تک متغیره گفته می شود و در صورتی که بیش از یک ویژگی مستقل باشد، به آن رگرسیون خطی چندمتغیره می گویند.

هدف الگوریتم خطی یافتن بهترین معادله خطی است که بتواند مقدار متغیر وابسته را بر اساس متغیرهای مستقل پیش بینی کند. این معادله، خط مستقیمی را ارائه می دهد که رابطه بین متغیرهای وابسته و مستقل را نمایش می دهد. شیب خط نشان دهنده تغییر متغیر وابسته برای تغییر واحد در متغیر(های) مستقل است.

رگرسیون خطی در بسیاری از زمینه های مختلف مانند مسائل مالی، اقتصاد و روانشناسی استفاده می شود تا رفتار یک متغیر خاص را درک و پیش بینی کند. به عنوان مثال، در مسائل مالی، رگرسیون خطی ممکن است برای درک رابطه بین قیمت سهام یک شرکت و سود آن یا برای پیش بینی ارزش آتی یک ارز بر اساس عملکرد گذشته اش استفاده شود.

یکی از مهم ترین وظایف یادگیری ماشینی نظارت شده، رگرسیون است. در رگرسیون، مجموعه ای از رکوردها با مقادیر X و Y وجود دارند و این مقادیر برای یادگیری یک تابع استفاده می شوند تا اگر فردی بخواهد Y را از X ناشناخته ای پیش بینی کند، بتواند از این تابع یاد گرفته شده استفاده کند. در رگرسیون، باید مقدار Y را کشف یا پیش بینی نمود، بنابراین به یک تابع نیاز است که در صورت رگرسیون، Y پیوسته ای را با توجه به X به عنوان ویژگی های مستقل پیش بینی کند. در این روش Y به عنوان متغیر وابسته یا متغیر هدف شناخته می شود و X به عنوان متغیر مستقل نامیده می شود که همچنین به عنوان پیش بینی کننده Y شناخته می شود. انواع مختلفی از توابع یا مدل ها وجود دارند که می توانند برای رگرسیون استفاده شوند. تابع خطی ساده ترین نوع تابع است. در اینجا، X ممکن است یک ویژگی تکی یا چندین ویژگی باشد که مسئله را معرفی می کنند.

شبکه عصبی در هوش مصنوعی

شبکه های عصبی، که با نام های شبکه عصبی مصنوعی (ANN) یا شبکه های عصبی شبیه سازی شده (SNN) نیز شناخته می شوند، زیرمجموعه ای از یادگیری ماشینی هستند و در قلب الگوریتم های یادگیری عمیق قرار دارند. نام و ساختار آنها از مغز انسان الهام گرفته شده است و از روشی تقلید می کنند که نورون های بیولوژیک به یکدیگر سیگنال می دهند (اوزتملن و همکاران^۲، ۲۰۱۶).

شبکه های عصبی مصنوعی (ANN) از یک لایه گره تشکیل شده اند که شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. هر گره یا نورون مصنوعی به دیگری متصل می شود و دارای وزن و آستانه مرتبط است. اگر خروجی هر گره منفرد بالاتر از مقدار آستانه مشخص شده باشد، آن گره فعال می شود و داده ها را به لایه بعدی شبکه ارسال می کند. در غیر این صورت، هیچ داده ای به لایه بعدی شبکه منتقل نمی شود.

شبکه های عصبی برای یادگیری و بهبود دقت خود در طول زمان به داده های آموزشی متکی هستند. اما زمانی که این الگوریتم های یادگیری برای دقت بالا تنظیم شوند، ابزار قدرتمندی در علوم کامپیوتر و هوش مصنوعی هستند که به ما این امکان را می دهند تا داده ها را با سرعت بالا طبقه بندی و خوشه بندی کنیم. وظایف تشخیص گفتار یا تشخیص تصویر با این شبکه ها چند دقیقه طول می کشد، در حالی که همان کار با شناسایی دستی توسط متخصصان انسانی می تواند ساعت ها طول بکشد. یکی از شناخته شده ترین شبکه های عصبی، الگوریتم موتور جستجوی گوگل است.

¹ Supervised Learning


² Oztemel et al.

مولفه‌ها و ساختار شبکه عصبی

لایه ورودی: این مفهوم همچنین به عنوان گره‌های ورودی شناخته می‌شود، ورودی/اطلاعات دنیای بیرون برای یادگیری و نتیجه‌گیری در اختیار مدل قرار می‌گیرد. گره‌های ورودی، اطلاعات را به لایه بعدی یعنی لایه پنهان منتقل می‌کنند.
لایه پنهان: لایه پنهان مجموعه‌ای از نورون‌ها است که در آن تمام محاسبات روی داده‌های ورودی انجام می‌شود. در یک شبکه عصبی، تعداد زیادی لایه پنهان می‌تواند وجود داشته باشد. ساده‌ترین شبکه از یک لایه پنهان تشکیل شده است.
لایه خروجی: لایه خروجی، همان طور که نام آن نشان می‌دهد، خروجی/نتیجه مدلی است که از تمامی محاسبات انجام شده به دست می‌آید. در لایه خروجی می‌توان گره‌های منفرد یا چندگانه وجود داشته باشد.

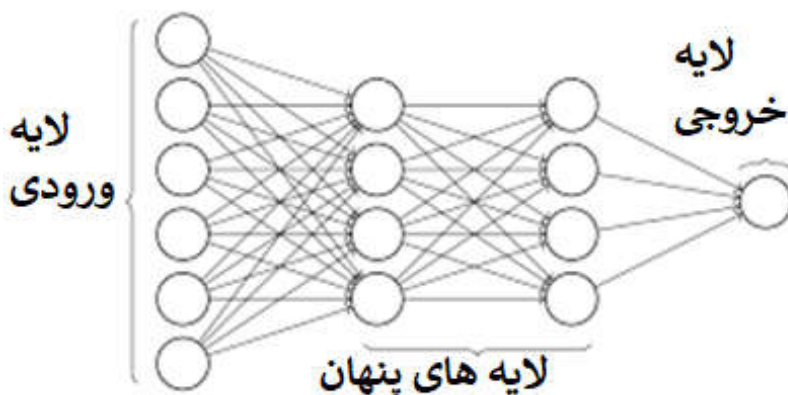
پرسپترون و پرسپترون چندلایه

پرسپترون شکل ساده‌ای از شبکه عصبی است و از یک لایه تشکیل شده است که تمام محاسبات ریاضی در آن انجام می‌شود.



شکل ۱. نمودار ساده شده‌ی شبکه عصبی

اما پرسپترون چندلایه - که به عنوان شبکه‌های عصبی مصنوعی نیز شناخته می‌شود - از بیش از یک ادراک تشکیل شده است که برای تشکیل یک شبکه عصبی چندلایه با هم گروه‌بندی می‌شوند.



شکل ۲. شبکه عصبی در هوش مصنوعی

انواع شبکه‌های عصبی

شبکه‌های عصبی را می‌توان به انواع مختلفی طبقه‌بندی کرد که برای اهداف گوناگونی استفاده می‌شوند. فهرست زیر، لیست کاملی از انواع شبکه‌های عصبی نیست، اما رایج‌ترین انواع شبکه‌های عصبی را معرفی می‌کند که کاربردهای زیادی دارند:

- پرسپترون (perceptron): قدیمی‌ترین شبکه عصبی است که توسط فرانک روزنبلات^۱ در سال ۱۹۵۸ ایجاد شد.
- شبکه‌های عصبی پیش‌خور یا پرسپترون‌های چندلایه (MLPs): این شبکه‌ها از یک لایه ورودی، یک لایه یا لایه‌های پنهان و یک لایه خروجی تشکیل شده‌اند. اگرچه این شبکه‌های عصبی معمولاً به عنوان MLP نیز شناخته می‌شوند، توجه به این نکته مهم است که آنها در واقع از نورون‌های سیگموئید تشکیل شده‌اند، نه پرسپترون‌ها، زیرا اکثر مشکلات دنیای واقعی غیرخطی هستند. معمولاً داده‌ها برای آموزش به این مدل‌ها وارد می‌شوند و این مدل‌ها پایه و اساس بینایی کامپیوتر، پردازش زبان طبیعی و سایر شبکه‌های عصبی هستند.
- شبکه‌های عصبی کانولوشنال (CNN): این شبکه‌ها شبیه شبکه‌های پیش‌خور هستند، اما معمولاً برای تشخیص تصویر، تشخیص الگو و/یا بینایی کامپیوتری استفاده می‌شوند. این شبکه‌ها از اصول جبر خطی، به ویژه ضرب ماتریس، برای شناسایی الگوهای درون یک تصویر استفاده می‌کنند.
- شبکه‌های عصبی بازگشتی (RNN): این شبکه‌ها با حلقه‌های بازخوردشان شناسایی می‌شوند. الگوریتم‌های یادگیری شبکه‌های عصبی بازگشتی در درجه اول هنگام استفاده از داده‌های سری زمانی برای پیش‌بینی نتایج آتی، مانند پیش‌بینی بازار سهام یا پیش‌بینی فروش، استفاده می‌شوند (کالندر و همکاران^۲، ۲۰۱۴).

متدولوژی

سه روش کلی براساس هوش مصنوعی برای انجام محاسبات وجود دارد که در ذیل اشاره‌ای گذرا صورت خواهد گرفت.

(۱) **روش‌های مبتنی بر رگرسیون:** رگرسیون خطی چند متغیره (MLR)، رگرسیون غیرخطی چند متغیره (NMLR)، رگرسیون فرآیند گاوسی (GPR)، رگرسیون افزایشی (AR)، رگرسیون با اختیار (RBD) و رگرسیون بردار پشتیبان (SVR).

(۲) **روش‌های مبتنی بر قانون:** جدول تصمیم‌گیری (DT)، قانون (M5).

(۳) **روش‌های مبتنی بر درخت:** جنگل تصادفی (RF)، درخت تصادفی (RT)، درخت هرس با خطای کاهش یافته (REPTree) و شبکه‌های عصبی مصنوعی (ANN).

در پیش‌بینی‌ها، SVR در بین روش‌های مبتنی بر رگرسیون، DT در میان روش‌های مبتنی بر قانون، M5P در بین روش‌های مبتنی بر درخت بهترین نتایج را به دست می‌دهد. مشاهده شده است که روش ANN پیش‌بینی‌های دقیق‌تری نسبت به سایر روش‌ها ایجاد می‌کند. پیش‌بینی‌های ANN بیشترین دقت پیش‌بینی و کمترین انحراف را ارائه می‌دهند.

روش ABC

ABC رایج‌ترین روش مورد استفاده در طبقه بندی موجودی است. ایده روش ABC در سال ۱۹۵۱ توسط فورد دیک^۳ مطرح شد. همچنین به عنوان اصل پارتو شناخته می‌شود و بر اساس قانون پارتو است که می‌گوید ۸۰ درصد از کل هزینه ۲۰ درصد اقلام را پوشش می‌دهد.

اصل پارتو براساس مشاهدات ویلفردو پارتو است که بخش بسیار زیادی از کل درآمد ملی بر درصد کمی از جمعیت متمرکز است. اساس روش ABC طبقه بندی و کنترل طیف گسترده‌ای از موجودی‌ها با توجه به هزینه‌های آنها است (سرهات اوگلو و همکاران^۴، ۲۰۱۹).

در برنامه ABC، ابتدا دو قانون باید در نظر گرفته شود: الف) اقلام موجودی با ارزش کم هزینه نگهداری پایین تری دارند، ب) مقدار

¹ Frank Rosenblatt

² Kalender et al.

³ Ford Dickie

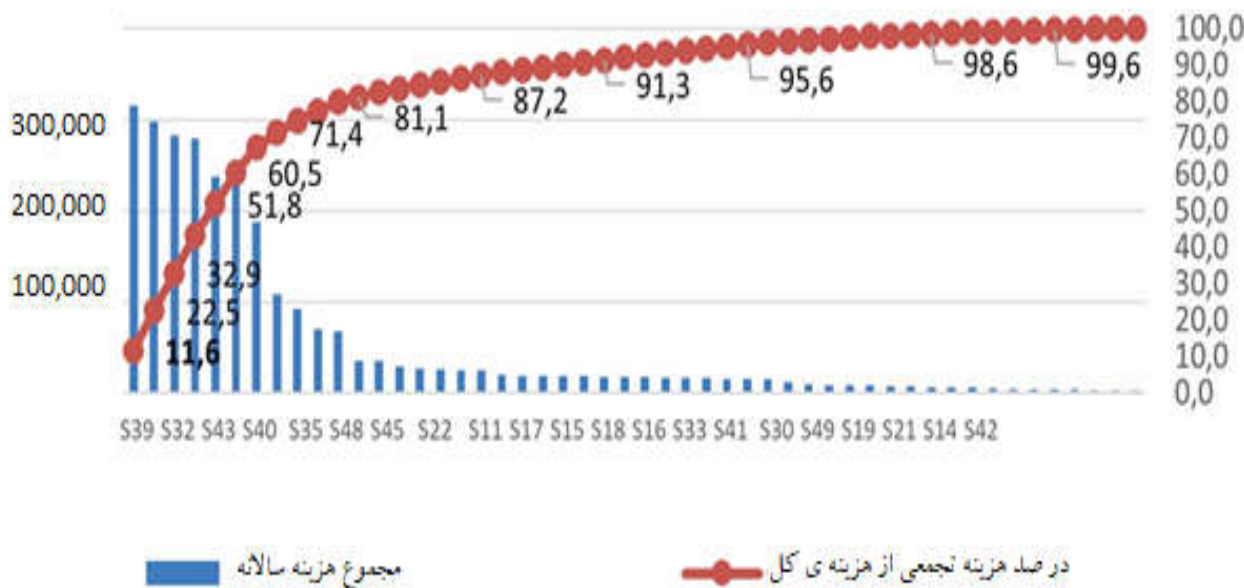
⁴ Serhatoglu et al.

اقدام موجودی با ارزش بالا باید کم نگه داشته شود و دفعات کنترل باید افزایش یابد (تنریوردی و همکاران¹، ۲۰۱۰). با توجه به هزینه های موجودی ها در کلاس A، برای شرکت ها اهمیت زیادی دارند، به منظور کاهش هزینه ها باید روی مدیریت و کنترل موجودی ها این گروه کار کرد. اگرچه کلاس A در کل ۱۰ تا ۲۰ درصد از کل موجودی های را تشکیل می دهد، لیکن از بعد هزینه ای ۷۰ تا ۸۰ درصد از کل هزینه های مربوط به موجودی را تشکیل می دهد. موجودی های کلاس B شامل موجودی هایی با اهمیت و هزینه متوسط است. همچنین این طبقه اگر چه ۳۰ تا ۴۰ درصد از کل موجودی های موجودی موجودی در کلاس B را تشکیل می دهد، اما ۱۰ تا ۱۵ درصد از کل هزینه ی مربوط به موجودی را تشکیل می دهد. موجودی ها در کلاس C برای شرکت ها اهمیت چندانی ندارند و موجودی های کم هزینه هستند.

اگرچه ۴۰ تا ۵۰ درصد از کل موجودی های م در کلاس C طبقه بندی می شوند، اما ۵-۱۰ درصد از هزینه های مربوط به موجودی ها را شامل می شود. پس از مشورت با خبرگان و مصاحبه با مهندسان و مدیران تعمیر و نگهداری، جمع بندی گردید که روش ABC با این نظر اتخاذ شد که پیش بینی تقاضای قطعات یدکی که بیشترین درصد را در کل هزینه های موجودی دارند، کمک بیشتری به شرکت خواهد کرد.

نرم افزار تحلیل ABC برای ۵۰ قطعه یدکی تعیین شده توسط مهندسان و مدیران تعمیر و نگهداری انجام شد و براساس نظر آنها و جمع بندی داده ها قطعه یدکی S39 با اکثریت قریب به اتفاق به عنوان قطعه مورد مطالعه انتخاب شد. از این رو، مجموع این تفکیک های خاص به صورت سالانه به عنوان یک متغیر تعریف می شود.

در مطالعات بررسی شده در ادبیات، نشان داد که کار محدودی بر روی پیش بینی تقاضای قطعات یدکی در زمینه نگهداری و تعمیرات صورت گرفته است. این پژوهش به کاربرد پیش بینی تقاضا براساس سیستم تعمیر و نگهداری و تعمیرات در حوزه ی دستگاه های چاپ حوزه ی شرکت های چاپ و بسته بندی کمک خواهد کرد. در این پژوهش رگرسیون خطی چند متغیره با روش شبکه های عصبی مصنوعی مورد بررسی قرار گرفت. براین اساس در ابتدا روش های طبقه بندی موجودی برای انتخاب قطعه یدکی حیاتی مورد بررسی قرار گرفت. حیاتی ترین قطعه یدکی که باید تخمین زده شود با آنالیز ABC تعیین شد.



¹ Tanrıverdi et al.



فصلنامه علمی تخصصی پژوهش های نوین بین رشته ای علوم پایه و فنی و مهندسی
Specialized Scientific Quarterly of New Interdisciplinary Researches in
Basic Science and Technical and Engineering
« E-ISSN:2980-9061 »

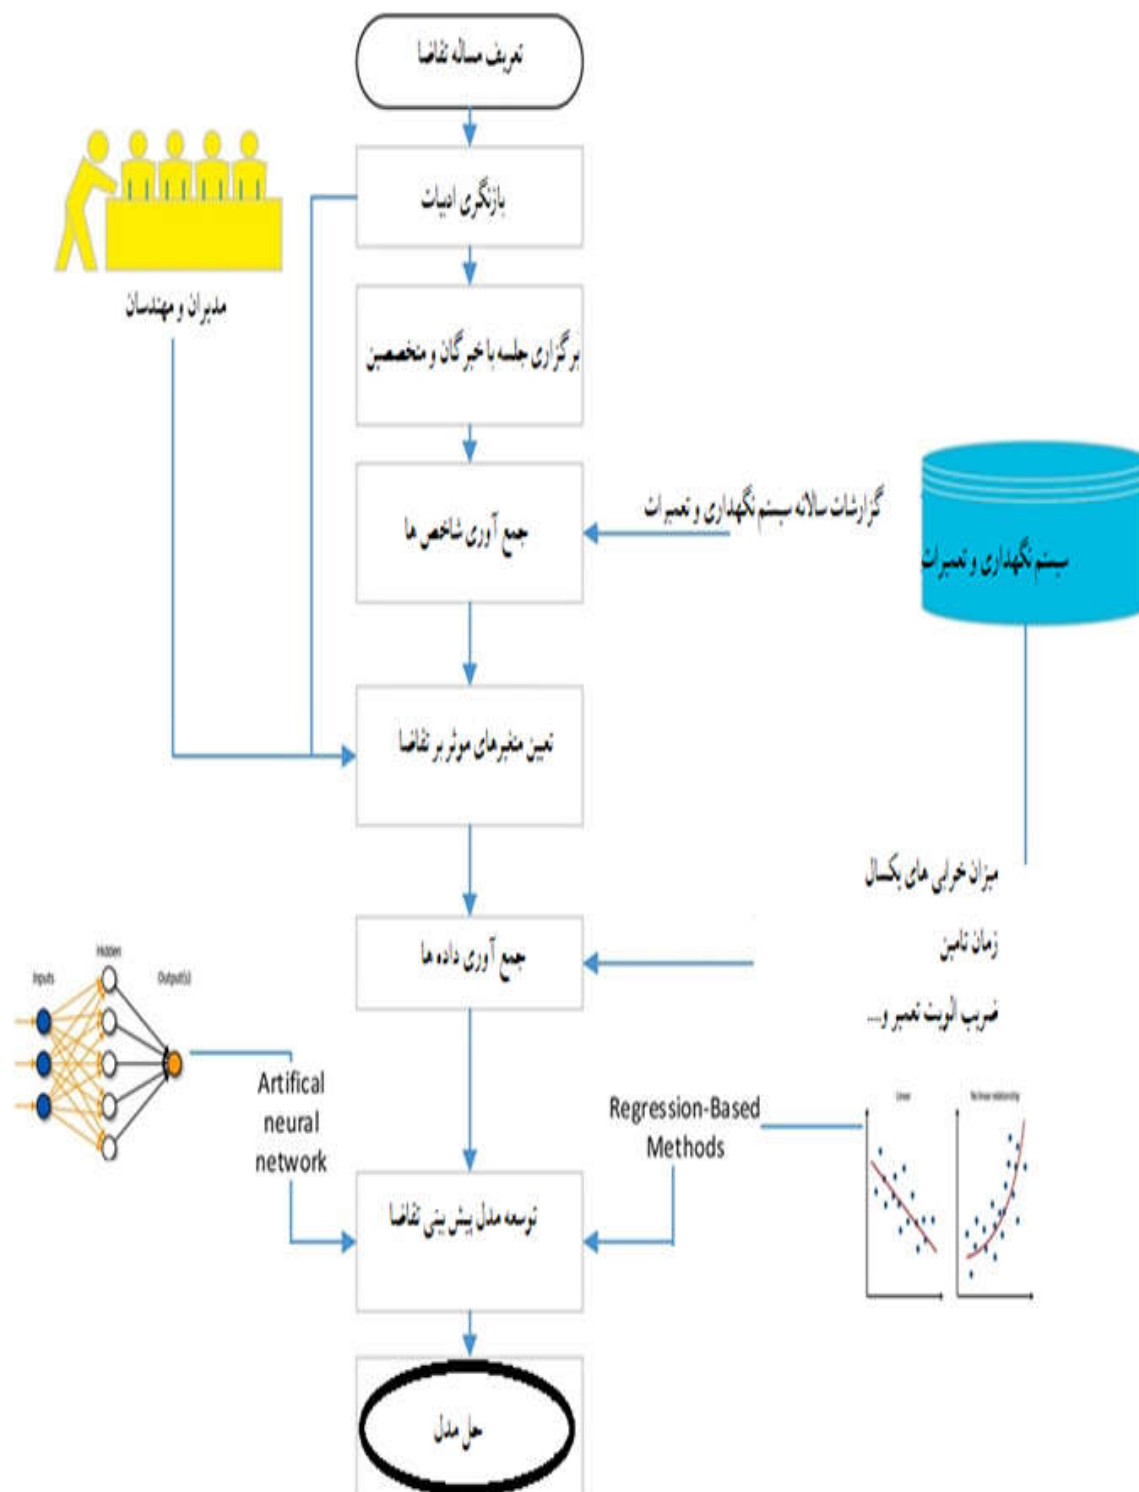
نمودار ۱: نمودار پارتو هزینه قطعات یدکی

حیاتی ترین قطعات یدکی با استفاده از تحلیل ABC و برگزاری جلسات با مهندسان و مدیران تعمیر و نگهداری تعیین شد. لذا ابتدا از بین قطعات یدکی، لیست قطعات یدکی گرید A با استفاده از تحلیل ABC استخراج شد. سپس با توجه به نظرات مهندسان و مدیران تعمیر و نگهداری و مطالعات ادبیات مربوطه بر روی بالاترین قطعه از لحاظ امتیاز شاخص ها صحت گذاری گردید و بیان گردید که چه شاخص هایی در برآورد پیش بینی آن مهم هستند. در گام بعد داده های مربوط به شاخص های مهم جمع آوری شد. داده های جمع آوری شده به دو بخش آموزش و آزمون تقسیم شدند.

متعاقباً متغیرهای مؤثر بر تقاضای قطعات یدکی تعیین شدند. تعداد دستگاه های چاپ در خط تولید، میانگین زمان بین خرابی (MTBF)^۱، تعداد تعمیر و نگهداری دوره ای و تعداد خرابی ورودی های این مطالعه است (کوهی و همکاران^۲، ۲۰۲۰). تعداد دستگاه های چاپ در خط تولید، تعداد دستگاه های فعال چاپ در ماه را نشان می دهد، MTBF زمان بین دو خرابی را بیان می کند. تعداد تعمیر و نگهداری دوره ای به تعداد دستگاه های موجود در خط تولید اشاره دارد که به صورت دوره ای در یک ماه سرویس می شوند و تعداد خرابی ها به تعداد خرابی هایی اشاره دارد که باعث تغییر قطعه می شود. خروجی مدل مقادیر تقاضا است.

¹ Mean Time Between Failure

² Chohi



شکل ۱. روش مورد استفاده در این مطالعه

براساس متد تعریف شده،

در نهایت متغیرهای موثر بر تقاضا استخراج گردید. این متغیرها عبارتند از: ورودی ها تعداد دستگاه های چاپ فعال در خط تولید، تعداد تعمیر و نگهداری دوره ای، تعداد خرابی ها و MTBF، ساعت کارکرد، میزان سفارش، تعداد رنگ سفارشات، افزودنی های ترکیبی، مترائزچاپ، جنس چاپ بوده و خروجی فقط مقدار تقاضای واقعی است. در این مطالعه، از داده های ۱۳۹۵ تا ۱۴۰۱ برای آموزش و داده های شش ماه اول ۱۴۰۲ برای آزمایش استفاده شد.

جدول ۱: متغیرها و نمونه ها تعریف شده

سال	تعداد دستگاه های چاپ فعال در خط	تعداد تعمیرات دوره ای	تعداد توقفات	فاصله ی بین دو توقف	تقاضای واقعی
۱۳۹۵	۱۲۱۵	۱۳۳	۳۹	۱.۰۰	۳۴
۱۳۹۶	۱۲۲۸	۱۴۱	۴۹	۱.۲۷	۳۲
۱۳۹۷	۱۳۱۴	۱۴۹	۳۹	۰.۹۴	۲۸
۱۳۹۸	۱۳۳۸	۱۴۴	۷۴	۰.۴۳	۴۷
۱۳۹۹	۱۳۷۴	۱۵۶	۴۴	۰.۸۴	۳۲
۱۴۰۰	۱۴۰۲	۱۶۳	۵۳	۰.۴۸	۴۰
۱۴۰۱	۱۴۱۵	۱۶۸	۵۶	۱.۵۰	۳۷

براساس اطلاعات و متغیرهای مشترک پیش بینی براساس دو روش رگرسیون خطی و شبکه های عصبی مصنوعی مدل گردید و خروجی آنها استخراج گردید که در قالب جداول ذیل ارائه گردیده است.

جدول ۲: نتایج پیش بینی انجام شده با رگرسیون چندخطی

سال	تقاضای واقعی	مقادیر پیش بینی شده	میانگین درصد مطلق خطا	دقت پیش بینی	انحراف
۱۳۹۵	۳۴	۳۵	۲.۸۵۷	۹۷.۱۴۳	۱
۱۳۹۶	۳۲	۳۴	۵.۸۰۰	۹۴.۲۰۰	۲
۱۳۹۷	۲۸	۳۶	۲۲.۲۰۰	۷۷.۸۰۰	۸
۱۳۹۸	۴۷	۴۵	۴.۲۵۵	۹۵.۷۴۵	۲
۱۳۹۹	۳۲	۳۲	۰.۰۰۰	۱۰۰.۰۰۰	۰
۱۴۰۰	۴۰	۳۸	۵.۰۰۰	۹۵.۰۰۰	۲
۱۴۰۱	۳۷	۳۶	۲.۷۰۲	۹۷.۲۹۸	۱
میانگین			۶.۱۱۶	۹۳.۸۸۴	۲.۲۸۶

نتایج پیش بینی روش رگرسیون خطی در جدول ۲ نشان داده شده و با مقادیر تقاضای واقعی مقایسه شده است. مقادیر اعشاری نتایج پیش بینی به نزدیک ترین عدد گرد می شوند تا یک عدد صحیح باشد. درصد MAPE بین مقادیر پیش بینی و واقعی ۶.۱۱۶ درصد و دقت پیش بینی با ۹۳.۸۸۴ است.

جدول ۳: نتایج پیش بینی انجام شده با شبکه های عصبی

سال	تقاضای واقعی	مقادیر پیش بینی شده	میانگین درصد مطلق خطا	دقت پیش بینی	انحراف
۱۳۹۵	۳۴	۳۶	۵.۵۵۵	۹۴.۴۴۵	۲
۱۳۹۶	۳۲	۳۲	۰.۰۰۰	۱۰۰.۰۰۰	۰
۱۳۹۷	۲۸	۲۹	۳.۴۴۸	۹۶.۵۵۲	۱
۱۳۹۸	۴۷	۴۵	۴.۲۰۰	۹۵.۸۰۰	۲
۱۳۹۹	۳۲	۳۳	۳.۰۳۰	۹۶.۹۷۰	۱
۱۴۰۰	۴۰	۴۰	۰.۰۰۰	۱۰۰.۰۰۰	۰
۱۴۰۱	۳۷	۳۸	۲.۶۰۰	۹۷.۴۰۰	۱
میانگین					۱

بهترین معماری ANN از یک لایه ورودی، دو لایه پنهان و یک لایه خروجی تشکیل شده است. چهار نرون در لایه ورودی، بیست نرون در هر دو لایه پنهان اول و دوم، یک نرون در لایه خروجی وجود دارد. فعال سازی در هر دو لایه مخفی خطی بوده و Trainoss به عنوان تابع آموزشی انتخاب شد.

میزان یادگیری ۰.۵ تعیین شد. نتایج پیش بینی ANN در جدول ۳ نشان داده شده و با مقادیر تقاضای واقعی مقایسه شده است. مقادیر اعشاری نتایج پیش بینی به نزدیک ترین عدد گرد می شوند تا یک عدد صحیح باشد. درصد MAPE بین مقادیر پیش بینی و واقعی ۲.۶۹۰ درصد و دقت پیش بینی با ۹۷.۳۱۰ است.

جدول ۴: میانگین میزان دقت پیش بینی روش های اعمال شده

روش	اختلاف (عددی)	دقت پیش بینی (درصد)	میانگین درصد مطلق خطا
رگرسیون چندخطی	۲.۲۸۶	۹۳.۸۸۴	۶.۱۱۶
شبکه های عصبی مصنوعی	۱	۹۷.۳۱۰	۲.۶۹۰

با توجه به نتایج بدست آمده روش مبتنی بر شبکه های عصبی مصنوعی با میانگین اختلاف عددی ۱ و میانگین پیش بینی دقت ۹۷.۳۱۰ در مقابل اختلاف عددی ۲.۲۸۶ و میانگین ۹۳.۸۸۴ روش شبکه های عصبی مصنوعی پیش بینی دقیق تری از خود ارائه نموده است.

نتیجه

در بخش تعمیر و نگهداری، قطعات یدکی مورد استفاده در تعمیرات دوره ای یا خرابی باید به مقدار لازم در دسترس باشد. با این حال، هزاران قطعه یدکی وجود دارد که بخش تعمیر و نگهداری باید آنها را مدیریت کند. کمبود قطعات یدکی منجر به هزینه جدی و نارضایتی مشتریان می شود زیرا خودروها وظایف خود را انجام نمی دهند. مازاد بر مقدار مورد نیاز منجر به هزینه های نگهداری می شود. این هزینه نگهداری شامل هزینه های مختلفی از جمله هزینه های نگهداری، بیمه، هزینه های جابجایی می باشد. به این دلایل، پیش بینی تقاضای قطعات یدکی یک فرآیند حیاتی برای بخش های تعمیر و نگهداری است. در این مطالعه، پیش بینی تقاضا برای یک قطعه یدکی حیاتی در شرکت چاپ و بسته بندی انجام شد. ابتدا مطالعات در زمینه مرتبط مورد بررسی قرار گرفت. سپس روش های طبقه بندی موجودی برای انتخاب قطعه یدکی حیاتی مورد بررسی قرار گرفت. یک قطعه یدکی برای پیش بینی تقاضا توسط تجزیه و تحلیل ABC انتخاب شد.

متغیرهای مورد استفاده در پیش بینی تقاضا عبارتند از ورودی ها تعداد دستگاه های چاپ فعال در خط تولید، تعداد تعمیر و نگهداری دوره ای، تعداد خرابی ها و MTBF، ساعت کارکرد، میزان سفارش، تعداد رنگ سفارشات، افزودنی های ترکیبی، مترآزچاپ، جنس چاپ بوده و خروجی فقط مقدار تقاضای واقعی است.

مشاهده شده است که روش ANN پیش بینی های دقیق تری نسبت به روش رگرسیون خطی ایجاد می کند. پیش بینی ANN بیشترین دقت پیش بینی و کمترین انحراف را نشان می دهد. در نتیجه از آنجایی که دقت پیش بینی بالا است، شرکت می تواند با استفاده از این اطلاعات در هنگام سفارش قطعات یدکی، هزینه ها را کاهش دهد. در مطالعات آتی، عملکردها را می توان با استفاده از روش های دیگر پیش بینی مقایسه کرد. علاوه بر این، دقت پیش بینی را می توان با بررسی متغیرهای جدیدی که بر تقاضا تأثیر می گذارند افزایش داد.

مراجع

- میرزاآقابیک، حسن & عباس پور اسفدن، قنبر. (۱۴۰۰). رتبه بندی عوامل موثر بر کیفیت قطعات مکانیکی خودرو (موتور) از طریق رویکرد MCDM با استفاده از تکنیک DEMATEL. مدیریت کسب و کار. 13(50), 564-578.
- Choi, B., & Suh, J. H. (2020). Forecasting Spare Parts Demand of Military Aircraft: Comparisons of Data Mining Techniques and Managerial Features from the Case of South Korea. In Sustainability (Vol. 12, Issue 15, p. 6045). MDPI AG. <https://doi.org/10.3390/su12156045>
- Hamzaçebi, C. (2007). Forecasting of Turkey's net electricity energy consumption on sectoral bases. In Energy Policy (Vol. 35, Issue 3, pp. 2009–2016). Elsevier BV. <https://doi.org/10.1016/j.enpol.2006.03.014>
- Khan, R. H., Ali, M., Farooque, P., & Ullah Khan, W. (2023). Using inventory related performance measures in the analysis of a production/inventory flexible manufacturing system. In Materials Today: Proceedings. Elsevier BV. <https://doi.org/10.1016/j.matpr.2023.04.254>
- Joseph, R. V., Mohanty, A., Tyagi, S., Mishra, S., Satapathy, S. K., & Mohanty, S. N. (2022). A hybrid deep learning framework with CNN and Bi-directional LSTM for store item demand



فصلنامه علمی تخصصی پژوهش های نوین بین رشته ای علوم پایه و فنی و مهندسی
Specialized Scientific Quarterly of New Interdisciplinary Researches in
Basic Science and Technical and Engineering
« E-ISSN:2980-9061 »

forecasting. In *Computers and Electrical Engineering* (Vol. 103, p. 108358). Elsevier BV. <https://doi.org/10.1016/j.compeleceng.2022.108358>

- E. Oztemel, *Yapay Sinir Ağları* (2016)(Artificial Neural Networks), 4.Edition, Papatya Publishing House, Istanbul.
- Rinaldi, M., Fera, M., Macchiaroli, R., & Bottani, E. (2023). A new procedure for spare parts inventory management in ETO production: a case study. In *Procedia Computer Science* (Vol. 217, pp. 376–385). Elsevier BV. <https://doi.org/10.1016/j.procs.2022.12.233>
- Serhatoglu, F.(2019). The importance of inventory management in health institutions: sample application in oral and dental health center. M.Sc. thesis, Istanbul Arel University, Istanbul, Turkey.
- Tanrıverdi, Y. (2010). Supply chain and application on stock management. M.Sc. thesis, Pamukkale University, Denizli, Turkey.
- Van der Auweraer, S, Boute, R. (2019), Forecasting spare part demand using service maintenance information, *Int. J. Prod. Econ.* 213 (2019) 138–149.
- Yuzuk, F., 2019. Multiple regression analysis and neural networks with Turkish energy demand forecast. M.Sc.thesis, Sivas Cumhuriyet University, Sivas, Turkey.
- Zhou, W.-Q., Chen, L., & Ge, H.-M. (2013). A multi-product multi-echelon inventory control model with joint replenishment strategy. In *Applied Mathematical Modelling* (Vol. 37, Issue 4, pp. 2039–2050). Elsevier BV. <https://doi.org/10.1016/j.apm.2012.04.054>
- Zhu, S., Dekker, R., van Jaarsveld, W., Renjie, R. W., & Koning, A. J. (2017). An improved method for forecasting spare parts demand using extreme value theory. In *European Journal of Operational Research* (Vol. 261, Issue 1, pp. 169–181). Elsevier BV. <https://doi.org/10.1016/j.ejor.2017.01.053>