



پیشبینی موجودی انبار مبتنی بر هوش مصنوعی

حمیدرضا حاجعلی

دانشجوی دکتری گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

محمدعلی افشار کاظمی (مسئول مکاتبات)

استاد گروه مدیریت صنعتی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

dr.mafshar@gmail.com

عادل آذر

استاد گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، دانشگاه تربیت مدرس، تهران، ایران

عباس طلوعی اشلقی

استاد گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

رضا رادفر

استاد گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

تاریخ پذیرش: ۱۴۰۳/۱۰/۱۶

تاریخ ارسال: ۱۴۰۳/۰۵/۱۷

چکیده

توسعه هوش مصنوعی در حوزه های گسترده صنعتی و بازرگانی از یک سو، افزایش حجم چشم گیر داده های غیر خطی تولید شده توسط واحد های مختلف سازمان ها از سوی دیگر، نیاز به استفاده از تکنیک های هوش مصنوعی در مدیریت موجودی (IM) را افزوده است. از این رو مدل راهبردی طراحی شده در این مقاله با هدف بهره برداری از روش های یادگیری عمیق حافظه بلند مدت (RNN) و نیز شبکه عصبی حافظه کوتاه مدت طولانی دو جهته (BILSTM) مبتنی بر بکارگیری از روش های متداول کنترل موجودی مانند مقدار اقتصادی سفارش (EOQ) و مدل مقدار اقتصادی تولید (EPQ) و استفاده از امکانات تحلیل ABC جهت بالا بردن اثر بخشی مدل پرداخته است. دستاورد این مقاله رسیدن به مدل راهبردی منحصر به فردی، حاصل از ادغام چارچوب های سنتی کنترل موجودی و هوش مصنوعی می باشد، که دارای عملکرد بالایی به لحاظ سرعت و دقت پیش بینی است. علاوه بر این یافته ها نشان داد، شبکه عصبی بازگشتی RNN با دقت ۸۵ درصد نتایج مطلوبی را حاصل نکرده است. استفاده از رویکرد ترکیبی شبکه عصبی BILSTM بعد از ساخت و آموزش این شبکه با پارامترهای در نظر گرفته شده در راستای هدف مقاله، دقت ۹۳ درصد را تبیین نموده است.

کلمات کلیدی: کنترل موجودی-کلان داده-هوش مصنوعی-یادگیری عمیق-زنجیره تامین

مقدمه:

روند پژوهش های اخیر در خصوص پیش بینی موجودی انبار، توسط بکار گیری داده های غیر خطی افزایش یافته است. محققانی که از سری های زمانی برای پیش بینی موجودی انبار بهره جسته بودند به کاستی هایی در استفاده از همه ظرفیت های بدست آمده در فرآیند جمع آوری داده ها پی برده اند و پیشنهاد هایی در خصوص بهره مندی از روش های یادگیری عمیق داده اند (پاسلاو پادیا^۱، ۲۰۲۱). ویلگس و پترگال، ۲۰۱۸ در مقاله خود با عنوان “سیستم های پشتیبان تصمیم گیری زنجیره تامین مبتنی بر یک روش جدید پیش بینی سلسله مراتبی”، به این نتیجه رسیدند که پیش بینی سری های زمانی نقش مهمی در بسیاری از سیستم های پشتیبان تصمیم گیری و همچنین در مدیریت زنجیره های تامین ایفا می کند؛ ولی در ادامه نیز چنین دریافتند که داده های بسیاری از محصولات که در یک سازمان به عنوان سلسله مراتب پیچیده با سطوح مختلف گرد هم می آیند، اغلب نادیده گرفته می شود. در ادامه (ونگ و همکاران^۲، ۲۰۱۹) برای حل مشکل ناهنجاری در فروش یک شرکت بزرگ خرده فروشی و اتخاذ تصمیمات مناسب برای مواجه شدن با چالش های زنجیره تامین خود از ترکیب الگوریتم های درخت تصمیم که چارچوبی برای رتبه بندی، کلاس بندی است با روش مبتنی بر شبکه حافظه کوتاه مدت طولانی (LSTM) پرداختند. نتایج نشان داد؛ برای بهینه سازی تشخیص ناهنجاری ها روش LSTM بسیار عملکرد مطلوبی در مقایسه با داده های سری زمانی داشته اند. اغلب پیش بینی ها با کمک سری های زمانی بدون توجه به چنین ساختاری تولید می شوند. نظر به اینکه دقت پیش بینی برای بهینه سازی کارایی هر زنجیره تامین ضروری است؛ دقت پیش بینی با در نظر گرفتن داده های غیر خطی بهبود می یابد (شراسستینسی^۳، ۲۰۲۰). بدیهی است استفاده از داده های غیر خطی در مدل های سری زمانی دارای

محدودیت است. لذا نیل تحقیقات به سوی فناوری های نوینی چون هوش مصنوعی، پنجره ای برای استفاده از داده های غیر خطی برای افزایش دقت پیش بینی ها گشوده است. در رویکرد دوسوتوانی سازمانی بطور شایسته ای مدیران را متقاعد میکند، جهت بکارگیری امکاناتی که ابزارهای هوش مصنوعی در کنار ابزارهای سنتی مانند سری های زمانی در اختیار سازمان های نوآور می دهد. مبرهن است استفاده از همه ظرفیت های نوین علمی می تواند قابلیت سازمان های نوآور را افزایش دهد (خمسه و ابراهیمی نژاد، ۱۴۰۰). (یانگ و همکاران، ۲۰۲۰) یافتند دقت پیش بینی از روش ARIMA^۳ که معمولاً از داده های خطی سری های زمانی استفاده میکند کافی نیست. چرا که داده های غیر خطی؛ مناسب استفاده در این نوع مدل ها قرار نمیگیرد. لذا روش هایی مورد نیاز هست، که از داده های غیر خطی نیز بتوان برای پیش بینی استفاده نمود. در ادامه مدل های یادگیری ماشین توسعه داده می شوند که از داده های غیر خطی میتوان برای آموزش به ماشین و در ادامه کاربرد هایی مانند پیش بینی استفاده نمود (کاربونو^۴ و همکاران، ۲۰۰۸) و (حیدر مقصود و همکاران، ۲۰۲۰). در مقاله ای نظر به رشد هوشمندی پیرامونی به لزوم بکار گیری فناوری اینترنت اشیاء جهت کارآفرینی در سال های اخیر پرداخته است. به صورتی که در نمونه های عملی نشان می دهد از ابتدا تمامی ارکان زنجیره تامین و توزیع رادر بستر هوش مصنوعی طراحی و اجرا می نمایند (شهابی و نژاد محمد، ۱۴۰۲). همچنین بسیاری از محققان مانند (سیمی نمینی و توکلی، ۲۰۱۸) با استفاده از شبکه های عصبی بازگشتی (RNN) که اساساً مدل در آن از داده های غیر خطی می آموزد؛ نتیجه گرفتند در مقایسه با نتایج پیش بینی هایی که از مدل ARIMA صورت گرفته است مدل BLSTM بهتر از مدل ARIMA عمل می کند. همچنین حافظه کوتاه مدت (LSTM) در پیش بینی

Average

⁴ Carboneau

¹ Massimo Pacella, Gabriele Papadia

² Massimo Pacella, Gabriele Papadia

³ Auto-Regressive Integrated Moving

در سال ۲۰۲۰ برای پیش بینی موجودی انبار قطعات یدکی سنگین از روش BLSTM استفاده کردند و به نتایج مطلوبی در تعویض بموقع قطعات ماشین های سنگین دست پیدا کردند این راه حل کارآمد برای بهبود عملکرد موجودی خودکار عملکرد زنجیره تامین قطعات را افزایش داده است. پژوهش های دیگری مانند چاندریاح و ناراکانالی، ۲۰۲۱ برای پیش بینی تقاضا قطعات یدکی خودرو در نروژ مدل هایی مبتنی بر روش های LSTM, RNN طراحی کردند. این مدل برای پیش بینی تقاضای فروش در یک دوره زمانی اتخاذ شده است. یافته های این تحقیق نشان داد روش های مبتنی بر یادگیری عمیق چگونه هزینه های انبار داری را کاهش داده و چالش اصلی و مهم در مدیریت کنترل موجودی شرکت را که ارزیابی و پیش بینی تقاضای قطعات یدکی تکراری بود ساماندهی کرده و موجب افزایش ارزش سهام شرکت نیز شد. مجموعه ساختارهایی که از ترکیب شبکه های یادگیری عمیق شکل می گیرند مانند CNN-FNN, LSTM FNN, CNN-BLSTM, RBM-LSTM-FNN همگی برای پیش بینی سری های زمانی چندمتغیره نیز پیشنهاد شده اند. پژوهش های مانند دنگ^۳ و همکاران^۴ ۲۰۲۰؛ همچنین السفن^۵ و همکاران^۶ ۲۰۱۹، سانگ^۷ و همکاران^۸ ۲۰۲۰. آنها روش های FNN^۷ و BLSTM^۷ و RBM^۸ را دارای ساختارهای پیچیده تری یافتند، که دارای عملکرد بهتری در خصوص مورد مطالعاتی که انجام داده اند نشان داده است. همچنین روش مبتنی بر رمزگذار خودکار LSTM منجر به عملکرد بهتر و کاستی کمتر در تشخیص و پیش بینی ناهنجاری مورد مطالعه شده بوده. کاربردهای بینایی کامپیوتر، از دوربین های امنیتی تا ثبت تصاویر توسط وسایل و ابزار هوشمند در حال گسترش است. از این روش شناسایی اجسام نیز به مراتب بهتر از گذشته شده و مشاهده می شود که تصاویر

مجموعه های زمانی انجام شده بهتر از مدل ARIMA عمل می کند. شایان ذکر است (لیم و زهره، ۲۰۲۰^۱) درخصوص بررسی و مقایسه روش های پیش بینی سری های زمانی با یادگیری عمیق به طور گسترده ای پرداخته اند که نتایج مطالعه قبلی را نیز تایید میکنند. به این ترتیب، یکی از اهداف این پژوهش ارایه مدلی است که هزینه مدیریت موجودی انبار را کاهش دهد. به طور خاص در این تحقیق، فرآیند مدیریت موجودی ابتدا به عنوان یک مدل ریاضی فرموله شده مبتنی بر کلان داده ها است که در آن هدف مشترک به حداقل رساندن هزینه منطقی و به حداکثر رساندن سود با استفاده از روش های یادگیری عمیق خواهد بود. همچنین قابلیت استفاده یا بازآوری محصول یا محصولاتی را که می توانند بر اثر گذشت زمان کیفیت اولیه را از دست بدهند، نیز مدنظر قرار دارد. در این راستا با پیاده سازی رویکرد پیشنهادی این مقاله بررسی مواردی که در مواجه با چالش های کلان داده های صنعتی بر موجودیت هایی که بر اساس سوابق تاریخی، در امر تصمیم گیری موثر هستند در زمانی کوتاه در دسترس قرار بگیرد. لذا مدیریت موجودی با هدف برنامه ریزی، پیش بینی و ارزیابی با استفاده از سه تکنیک مهم در حوزه کنترل موجودی و ادغام آن ها با رویکردهای نوین یادگیری عمیق و شبکه های عصبی، در یک شرکت خرده فروشی صورت گرفته است. درواقع

پیشینه موضوع

از زمانی که برای اولین بار در سال ۱۹۹۷ توسط هوچریتز مقاله ای در خصوص LSTM انتشار یافت آثار نظری و تجربی متعددی در زمینه انواع RNN منتشر شده که نتایج بسیار شگفت انگیزی در طیف گسترده ای از کاربری ها به دست آمده است (شراسیتینسی، ۲۰۱۸). لیاو^۲ و همکاران

^۶ feed-forward neural network

^۷ bi-directional long short-term memory

^۸ restricted Boltzmann machines

^۱ Lim and Zohren

^۲ Weizhi Liao

^۳ Deng

^۴ Ellefsen

^۵ SONG

با سهم شدن در جریان آزاد اطلاعات، به وسیله صحبت کردن با یکدیگر فعالیت می کنند. جریان سریع اطلاعات بین مشتریان، تأمین کنندگان، مراکز عرضه و سیستم های حمل و نقل، شرکت ها را برای توسعه زنجیره تأمین توانا می سازد. در یک زنجیره تأمین توانمند، تأمین کننده ها و مشتریان با اهداف مشابه در کنار هم حضور داشته و همکاری میکنند (آذرومحمملو، ۱۳۸۶). مدیریت مؤثر زنجیره های تأمین نیازمند یکپارچگی مدیریت موجودی انبار در یک سازمان و کل تأمین کنندگان و مشتریان خارجی می باشد. زنجیره تأمین یکپارچه ممکن است به عنوان یک فرآیند تعامل و تشریک مساعی در شرکت هایی که در یک زنجیره تأمین برای رسیدن به نتایجی که برای همه سازمانهای درگیر در زنجیره، مورد قبول و هماهنگ باشد، تعریف شود (نوبلی، ۱۹۹۷).

مفاهیم دانشگاهی اولیه درخصوص تصمیماتی برای مقدار و زمان سفارش خرید در مدیریت موجودی توسط نادور در سال ۱۹۶۱ ارایه شد (ورات، ۲۰۱۴). ولی بعد ها حسب پیچیدگی محیط کسب کار چالش های مدیریت موجودی انبار گسترش یافت. به طور کلی مدیریت موجودی می تواند در تمام حوزه های بهینه سازی موجودی، مدل های مدیریت موجودی، مدیریت موجودی خرده فروشان، بهینه سازی زنجیره تامین، مدیریت لجستیک، لجستیک معکوس و زنجیره های تأمین حلقه بسته، زنجیره تأمین سبز، مدیریت زنجیره تأمین، مدیریت و کنترل سیستم های تولید و لجستیک، روش های Data mining، تجزیه و تحلیل Bigdata در مدیریت موجودی، هوش مصنوعی، اینترنت اشیا، عملیات و مدیریت تدارکات، تولید و مدیریت موجودی، هوش مصنوعی و سیستم خبره، بازاریابی، مدل سازی و شبیه سازی، فناوری اطلاعات، طرح موضوع گردد (شاه و میتال، ۲۰۲۱). تولید و مدیریت موجودی PIM^۲ به معنی طراحی، به کار گیری و کنترل سیستم هایی برای

کالا و یا تصویر گزارش موجودی کالا نیز قابلیت ساختن دیتا ست را نیز دارند یو کینگ و همکاران^۱ (۲۰۱۹).

تحقیقات در حوزه زنجیره تامین در سه محور پژوهش های فرایند محور، مبتنی بر سلسله مراتب، و مبتنی بر چشم انداز طبقه بندی شدند (رضایی و همکاران، ۱۳۹۷، ص ۳۷). همچنین تکنیک های مورد استفاده در موضوعات زنجیره تأمین مشتمل بر تجزیه و تحلیل سلسله مراتبی، تحلیل شبکه ای، تحلیل پوششی داده ها، پیمایش و شبیه سازی شناسایی شدند (رضائی و همکاران، ۱۳۹۷، ص ۳۹). طولانی شدن کانال های زنجیره تأمین توانایی مانور و انعطاف را از سازمان ها سلب کرده و تغییرات با تاخیر زمانی صورت میگیرد (آقای و همکاران، ۱۳۹۳، ص ۵۵). بی تردید هر نوع تأخیر زمانی می تواند ناشی از اختلالات باشد. مدیریت تأمین کارآمد مستلزم آمادگی و پیش بینی هر نوع اختلال و واکنش به آن اختلال می باشد. یکی از راهکارهای برون رفت از اختلال، ارتقاء تاب آوری مدیریت تأمین است. مفهوم اصلی تاب آوری به توانایی سیستم در بازگشت به وضعیت ثبات پس از اختلال برمی گردد. این موضوع مورد توجه رشته های جدیدی مانند مدیریت ریسک زنجیره تأمین و مدیریت زنجیره تأمین پایدار است (مندل، ۲۰۱۲). یک هدف مهم مدیریت زنجیره تأمین، هماهنگ کردن همه فعالیت ها یا محدودیت های مختلف زنجیره با نیاز های پویای مشتریان است، به صورتی که بتوان کالاها را در زمان مورد نیاز در اختیار مشتریان قرار داد. بدیهی است چابکی زنجیره تامین مارا به این مقصود می رساند، که این مهم استوار بر عوامل بازاریابی الکترونیکی میتواند اثربخش باشد (حقیقی نسب و همکاران، ۱۴۰۲). متأسفانه شرکای مختلف در زنجیره تأمین، برای تولید یک محصول یا خدمت همیشه با یکدیگر مشارکت نمی کنند و این وضعیت دشواری را برای مدیریت زنجیره تأمین به وجود می آورد. در مدیریت زنجیره تأمین مؤثر، تأمین کننده ها و مشتریان با هم در یک شیوه هماهنگ،

² Production & Inventory Management

¹ Yuqing

به عنوان معیاری برای دسته بندی در تجزیه و تحلیل ABC به کار روند در پژوهش چن و همکاران ۲۰۰۸، پرداخته شده است. مانند : ارزش سالانه مبادلات کالا، هزینه واحد کالا، درجه کمیابی موارد مورد استفاده در تولید کالا، در دسترس بودن منابع نیروی انسانی و تسهیلات برای تولید کالا، موعد تحویل تولید کالا، نیازهای مربوط به ذخیره سازی کالا و هزینه هر واحد کمبود کالا. روش سفارش خرید اقتصادی^۱ EOQ به معنای مقدار اقتصادی سفارش است. EOQ یکی از روش های مرسوم و پرکاربرد در حوزه مدیریت و کنترل موجودی می باشد. عباسی و همکاران (۲۰۲۲)، در مقاله خود با عنوان "ارائه مدل کمیت سفارش اقتصادی (EOQ) برای کالاهای در حال رشد ناقص با تقاضای تصادفی" بر این باور است که هدف اصلی کنترل موجودی و مشکلات برنامه ریزی تولید بهینه سازی کمیت اقتصادی سفارش یا تعیین اندازه دسته تولید براساس ظرفیت ها و محدودیت های حداقل کردن کل هزینه های مربوط به ترتیب، خرید، نگهداری و تحویل است. برای تعیین اندازه سفارش یا خرید قطعات در سیستم های تولیدی از مدل کمیت سفارش اقتصادی (EOQ) استفاده شده است. که تا لحظه ی دریافت سفارش کمبود ایجاد نشود. EOQ یکی از اصلی ترین و پایه ای ترین مدل های مدیریت و کنترل موجودی است که درک مدل های دیگر را آسان می سازد و مبنای شکل گیری روش های دیگر در این مبحث می شود. اما از طرف دیگر به دلیل مواردی همچون عدم قطعیت در زمان تحویل کالا، احتمالی بودن و یا پویا بودن تقاضا و مواردی از این دست، استفاده از این مدل رಾಮحدود میکند. بنابراین مدل های پیچیده تری نیاز هست که پارامترهای موثر در میزان سفارش را که در دنیای واقعی ثابت نیستند در محاسبات لحاظ کنند. از آنجایی که فرضیات مدل کلاسیک EOQ تمام سیستم های کنترل موجودی را به صورت واقعی پوشش نمی دهد. آنها در مقاله خود با کنار

تولید و توزیع کالاها است. اهداف، سیاست ها و تصمیمات مدیریت تولید و موجودی باید با اهداف کلی سازمان و نیز اهداف بازاریابی، مالی و تولید سازگار باشد. مدیریت موجودی انبار در سه سطح خرده فروشی، عمده فروشی و سطح تولید مطرح می شود مدیریت موجودی در یک سازمان با بکارگیری مجموعه ای از روش ها به نام سیستم مدیریت موجودی اعمال می شود. این سیستم در برگیرنده ی مجموعه ای از قوانین و اصول تصمیم گیری در شرایط مختلف بوده و با استفاده از یک سیستم اطلاعاتی، به اتخاذ تصمیماتی مناسب برای آن شرایط کمک می کند (فنگ و همکاران، ۲۰۲۳). مهدی زاده، ۲۰۲۰ با بکار گیری از تحلیل ABC مدلی برای پیش بینی تقاضا و تصمیمات سفارش در زنجیره تامین قطعات خودرو توسط مشتری در محل فروشنده پیشنهاد کرد. در این پژوهش میزان مسافت پیموده شده شروع و پایان هر دوره توسط خودرو عامل اصلی برای پیش بینی تقاضا در نظر گرفته شده است. بدون تردید تجزیه و تحلیل ABC یکی از اولین مراحل کنترل موجودی است. ویلفردو پارودو دانشمند قرن نوزدهم نخستین کسی بود که اصل ضرورت مدیریت را به عنوان پایه ای برای تجزیه و تحلیل ABC ارایه کرد. دسته بندی کالاهای انبار را برحسب درجه اهمیت آنها از جهت سطح خدمات هزینه موجودی و سود خالص پرداختند و مدلی جهت انجام کنترل های مدیریتی مختلف برای هر گروه متناسب با اهمیت آن ها نیز ارایه کردند (میتشل و همکاران، ۲۰۱۴). حروف ABC معرف ترتیب اهمیت گروه های مختلف موجودی هستند اما لزوما نباید سه گروه را داشته باشیم، بلکه معیارهای دسته بندی باید دشواری کنترل یک کالا و تاثیر آن ها بر هزینه ها و سود را منعکس کنند. اغلب تجزیه و تحلیل ABC با استفاده از ارزش سالانه موجودی ها انجام می شود، ولی این معیار تنها یکی از انواع معیارهایی است که می تواند اهمیت یک کالا را نشان دهد. برخی عوامل بیانگر اهمیت کالاها که می توانند

¹ Economic Order Quantity

متوسط کل کمتری را تحت شرایط خاص ارائه دهد. برای تحقق سیستم های کلان داده ای از زیر ساخت های ناهمگن^۲، پایگاه داده ها^۳، مصور سازی^۴ و ابزارهای تحلیل^۵ در نظر گرفته شده است. کلید بهره برداری مناسب از قدرت سیستم های کلان داده ای در انتخاب درست معماری مورد استفاده است. این ناهمگنی به همراه خود انتخاب های مختلفی برای حل یک مشکل مشابه ارائه می دهد و همچنین ارزیابی مورد نیاز برای تشخیص مناسب بودن این انتخاب ها برای رسیدن به اهداف نیز یکی دیگر از مواردی است که باید در انتخاب از میان این همه ناهمگنی و انتخاب ممکن مورد توجه قرار بگیرد. چارچوب های متن باز^۶، پایگاه داده ها، توزیع هدوپ و ابزارهای مصور سازی و تحلیلی بی شماری در بازار وجود دارند که با توجه به نیاز، مورد استفاده قرار می گیرند (مولوی خایانی، ۱۳۹۷). از این روترکیب استفاده از روش های متداول سنتی کنترل موجودی با روش های یادگیری عمیق جهت رسیدن به تصمیم سازی های اثربخش برای پیشبینی درخواست ها و انتظارات زنجیره تامین کالا از اهداف اصلی این مقاله قرار گرفته است.

روش پژوهش / تحقیق

این مقاله پیش بینی موجودی کالا با رویکرد ترکیبی و پیشنهاد مدلی راهبردی برای افزایش اثربخشی مدیریت موجودی انبار به انجام رسیده است. برای نیل به این مهم در ابتدا از شبکه عصبی بازگشتی (RNN) استفاده شده است. تحلیل کنترل موجودی با استفاده از روش شبکه های عصبی بازگشتی می تواند رویکرد موثری برای مدیریت و پیش بینی موجودی در سیستم های تجاری و تولیدی باشد. از سوی دیگر برای دستیابی به یک آموزش و تست خوب و قابل قبول از شبکه ی عصبی حافظه کوتاه - ماندگار دوطرفه (BILSTM) که فرآیند گذشته و آینده ویژگی ها

گذاشتن برخی از فرضیات^۱ به بهینه سازی و توسعه مدل EOQ می پردازد. نتایج این تحقیق می تواند برای تمامی موارد و واحدهایی که اقلام رو به رشد دارند و به صدور مقادیر صحیح سفارشات کمک کرده و منجر به کاهش هزینه ها و سود بیشتر شود، مفید باشد.

مدل تولید اقتصادی (EPQ) با این هدف که هزینه های نگهداری و هزینه های راه اندازی را برای شما کاهش دهد. وظیفه ی اصلی این مدل تعیین حجم بهینه ی تولیدات می باشد که با آن بتوان مجموع هزینه های موجودی (نگهداری و سفارش گذاری) را به حداقل رساند. در این مدل فرض بر آن است که در مدت زمان تحویل (خرید)، همه مقدار سفارش بصورت کامل تحویل می شود و مدت زمان تحویل مشخص می باشد (لؤپولدو، ۲۰۱۱).

فرض مدل کنترل موجودی EPQ این است که هر سفارشی که توسط تامین کننده به شما تحویل داده می شود، به جای یک محصول کامل در قالب قطعات خواهد بود. در واقع این مدل توسعه یافته مدل EOQ است، اما تفاوت بین این دو مدل این است که مدل EOQ فرض خود را بر این پایه قرار می دهد که تامین کنندگان موجودی را به طور کامل به مشتری یا کسب و کار شما تحویل می دهند. از این رو کلاک و همکاران، ۲۰۱۲ فرض را بر این گرفتند محصولی که در بازار تولید و فروخته می شود، تقاضا به نسبت به قیمت و کیفیت حساس است. لذا ویژگی کیفیت تولید نیز در نظر گرفته می شود. جینلی و همکاران، ۲۰۰۸ در پژوهش خود مبتنی بر روش EPQ میانگین کل هزینه های بهینه در واحد زمان را برای تولید و نگهداری هر محصول نهایی در دو سیستم به تعویق انداخته شده و سیستم بدون تعویق بررسی کردند. با مقایسه میانگین مجموع بهینه هزینه های دو سیستم، تأثیر تعویق را بر سازنده تحت چهار شرایط ارزیابی نمودند. نتایج نشان داد که استراتژی به تعویق انداختن می تواند هزینه

⁴ Visualization

⁵ Analytics Tools

⁶ Open Source Framework


¹ Production Order Quantity Model

² Heterogeneous

³ Databases

عمیق از حوزه یادگیری ماشین، برای پاسخ به سئوالات پژوهش مورد استفاده قرار می گیرد که در قدم بعدی پاسخ داده خواهد شد. استفاده از روند هم زمانی، جهت همگرایی اطلاعات کمی و کیفی جمع آوری شده، مد نظر بوده است. شایان ذکر است دستیابی به نتایج واقعی ودقیق انتخاب زبان برنامه نویسی راز اهمیت ویژه ای برخوردار می سازد. لذا منطبق بر نیاز مدل راهبردی پیشنهاد شده در مقاله وحجم داده ها از زبان برنامه نویسی پایتون در محیط کولب نوشته و اجرا شد.

جهت پیاده سازی شبکه های عصبی و مدلسازی داده ها از کتابخانه های معتبر وشناخته شده ای مانند pandas مورد استفاده از مجموعه داده ها و عملیات مختلف ، کتابخانه numpy جهت استفاده از آرایه ها و محاسبات مختلف و عملیات ماتریسی، کتابخانه seaborn نیز برای مصورسازی داده ها، کتابخانه matplotlib جهت نمایش داده ها به شکل گرافیکی و همچنین از کتابخانه scikit learn که یکی از معتبرترین و پر استفاده ترین کتابخانه های داده کاوی و یادگیری ماشین در پایتون است، برای بکارگیری از الگوریتم های پیش پردازش، طبقه بندی، خوشه بندی و کاهش ابعاد مورد استفاده قرار گرفته است. در انتها از imblearn جهت کار با داده های نامتوازن و کتابخانه OS نیز برای هماهنگی و تعامل بیشتر با سیستم استفاده گردیده شد. شایان ذکر است برای بخش آماده سازی داده ها با رویکرد ارزیابی مجموعه داده ها، از نمودارهای متغیر عددی با تخمین چگالی هسته و هیستوگرام استفاده شد و نتایج با استفاده از ماتریس اغتشاش نیز بررسی گردید. فرآیند کلی برای انتخاب روش شبکه عصبی مناسب در شکل ۱ نشان داده شده است.




شکل ۱: فرآیند کلی طی شده برای انتخاب نوع روش

را به طور کامل می تواند منعکس کند، استفاده شده است. علت استفاده از آنها به منظور جلوگیری از مشکل وابستگی طولانی مدت در شبکه است.

اساس و مدل مفهومی پژوهش طبق هدف کلی پژوهش مبنی بر "پیش بینی موجودی انبار مبتنی بر روش های هوش مصنوعی" با رویکرد راهبردی، در قدم اول بر طراحی الگویی برای شناسایی ابعاد، عناصر، مؤلفه ها و شاخص های اصلی جهت همگرایی تحلیل داده های غیر خطی و خطی پرداخته است و در ادامه پیش بینی نقطه بهینه سفارش انبار متمرکز گردید. رهیافت و پارادایم این پژوهش ضمن بررسی رویکرد اثبات گرایانه که با نگاه از بیرون در قالب اعداد و ارقام، تئوری ها و معروف ترین مدل های هوش مصنوعی، با رویکرد تفسیرگرایی، از طریق تحلیل روابط داده ای به رویداد گرایی مبتنی بر معنا بخشی به واقعیات، و همچنین در همگرایی با موضوع پژوهش، به ایجاد و توسعه فرضیات و مدل های تئوریک ناشی از ساخت های پنهان و فرآیندها خواهد پرداخت. لذا، به سبب فقدان پژوهش یا نظریه ای در بکارگیری از ابزار های یادگیری عمیق وروش های متداول مدیریت موجودی برای پیش بینی موجودی انبار مبتنی بر استفاده از کلان داده های صنعتی، نیاز به گزینش پارادایمی بود که ضمن دارا بودن نظریه و مدل های هوش مصنوعی، از روش اکتشافی به مطالعه پدیده نیز بپردازد. در همین راستا، در این پژوهش از متا پارادایم پراگماتیسم استفاده خواهد شد. نظر به مطالب یاد شده ، این پژوهش با به کارگیری یک رویکرد ابتکاری ترکیبی هوش مصنوعی در زمینه کنترل موجودی انجام شده است. در نهایت مدل رویکرد ترکیبی پیشنهادی بر روی داده های محیط واقعی پیاده سازی شده است. رویکرد پژوهشی، از نوع روش شناسی / رهیافت کمی کیفی یا ترکیبی خواهد بود، لذا لازم است هر دو نوع داده کمی و کیفی جمع آوری شود. تحلیل داده های کیفی برگرفته از پیشینه کاوی، پس از کدگذاری بر اساس علم آمار، و تحلیل داده های کمی با استفاده از روش یادگیری

استفاده شده است. با توجه به این تحلیل، شرکت می تواند ببیند کدام محصولات باعث مشکلاتی مانند تنش در موجودی انبار و یا ضعف در سودآوری شده اند. از این رو می تواند اقداماتی را برای بهبود مدیریت موجودی انبار خود انجام دهد و در تعیین سطح سفارشدهی به محصولات خود دقیق تر عمل کند. بعد از مرحله پردازش داده ها با کیفیت و کمیت مورد نظر آن ها را وارد مرحله آموزش به سیستم یادگیری ماشین می نمایم درنهایت از بین دو روش یادگیری عمیق حافظه بلند مدت^۳ (RNN) و شبکه عصبی حافظه کوتاه مدت طولانی دو جهته^۴ (BiLSTM) روشی که دارای دقت کافی برخوردار است را انتخاب خواهیم کرد. در ادامه جریان کاری را که در حین ساخت و آموزش مدل یادگیری عمیق استفاده می شود، در شکل زیر نمایش می دهیم. هدف از آموزش مدل یادگیری عمیق، شناسایی موجودی انبار و خروجی یک تصویر RGB است که می توان به عنوان یک بردار مقادیر پیکسلی آن را نمایش داد. بعد از تعریف مسئله باید معماری شبکه عصبی را برای حل آن توسعه داد.



شکل ۲: جریان کار تفصیلی برای آموزش و ارزیابی مدل یادگیری عمیق

همانطور که در شکل نشان داده شده است روش های متداول مدیریت موجودی مانند مقدار اقتصادی سفارش (EOQ)^۱ و مدل مقدار اقتصادی تولید (EPQ)^۲ و تحلیل ABC برای برآزش بهتر دیتاست در نظر گرفته شده است تا اثربخشی نتایج نهایی حاصل از خروجی روش های یادگیری عمیق دقیق تر باشد. مهمترین هزینه های سیستم کنترل موجودی هزینه های سفارش دهی و هزینه های نگهداری هستند. لذا در این مقاله، به منظور حداقل کردن هزینه انبارداری اقلام از یک سو و به منظور حداقل کردن خطر کمبود آن از سوی دیگر، به کمک تکنیک مقدار اقتصادی سفارش (EOQ) می توان مقدار اقتصادی سفارش این اقلام را برآورد کرد. در واقع این مدل، مقدار سفارشی است که هزینه کل نگهداری و سفارش دهی را برای طول دوره کمینه می سازد. حتی اگر تمامی مفروضات به درستی تحقق نیابند، همچنان معیار خوبی برای تشخیص این که آیا تعداد سفارش فعلی معقول است یا خیر، می باشد. از طرفی، مدل مقدار اقتصادی تولید (EPQ) یک مدل ریاضی در زمینه مدیریت موجودی در یک سیستم تولید موجودی است. این مدل را می توان توسعه ای از مدل مقدار اقتصادی سفارش EOQ دانست که با در نظر گرفتن نرخ تولید ثابت در مدل مقدار اقتصادی سفارش حاصل شده است. در صورتی که به جای خرید کالاهای مورد نیاز از تأمین کنندگان دیگر، در داخل شرکت به تولید آنها پردازیم، غالباً از مدل مقدار اقتصادی تولید برای تعیین اندازه دسته های بهینه تولید استفاده می کنیم. این مدل تاکنون به منظور انطباق با بخش عملیاتی شرکت ها با در نظر گرفتن حالت های مختلفی از جمله تولید محدود شده و ظرفیتهای انبار، تولید چند سطحی، تقاضای تصادفی، تولید تک ماشینی، انجام دوباره کاری روی محصول معیوب، در نظر گرفتن موجودی در جریان ساخت و توسعه داده شده است. همچنین، در راستای شناسایی نقاط قوت و ضعف در مدیریت موجودی از تحلیل (ABC)

^۳ Recurrent Neural Network

^۴ Bidirectional Long Short-Term Memory

^۱ Economic Order Quantity


^۲ Economic Production Quantity

عصبی به طور موثری از انطباق بیش از حد جلوگیری می نماید. جهت جمع آوری داده و آماده سازی دیتابیس و در نهایت تجزیه و تحلیل داده از مجموعه داده های موجود در سایت گوگل کولب که در خصوص کنترل موجودی یک خرده فروشی است و برای استفاده در پروژه های تحقیقاتی در اختیار عموم پژوهشگران قرار داده شده، استفاده گردیده است. لازم به ذکر است این مجموعه داده در تاریخ ۱۳ اکتبر ۲۰۲۳ بروزرسانی شده است. به طور کلی، از این مجموعه داده می توان برای تجزیه و تحلیل و مدیریت موجودی محصولات مختلف استفاده کرد. اطلاعاتی در مورد تاریخچه فروش، نوع بازاریابی، جزئیات انتشار و قیمت ارائه می دهد. با استفاده از این داده ها، مدیران بخش کنترل موجودی می توانند تصمیمات آگاهانه ای در مورد ذخیره سازی محصول، استراتژی های قیمت گذاری و شناسایی محصولات محبوب بر اساس داده های فروش بگیرند. از این رو، هدف کلی آن بررسی بخش های موجودی و شناسایی تغییرات و به روزرسانی آن ها و نهایتاً ارسال داده های جدید است. لازم به ذکر است، فرآیند به روزرسانی مجموعه داده به طور خودکار روزانه همگام سازی می شود، اما داده های زیربنایی به صورت دستی در طول سال در صورت نیاز تغییر می کنند. همچنین، تفسیر تاریخ در این مجموعه داده شامل ۲ تاریخ است. تاریخ اضافه شدن، یعنی زمانی که مجموعه داده به خود موجودی اضافه می شود و تاریخ اولین انتشار، یعنی پرتال داده باز به طور خودکار تاریخ ایجاد مجموعه داده را ثبت می کند. شکل زیر نمایی از داده های استفاده شده را نمایش می دهد در این مرحله، فواصل تکرار نوع بازار، فواصل تکرار نوع محصول، فواصل تکرار شونده محصول جدید، فواصل تکرار نوع محصول و وضعیت محصولات فعال و هم چنین محصولات غیر فعال مشخص و نمودارهای متغیر عددی با تخمین چگالی هسته و هیستوگرام با اندازه

همانگونه که گردش کار در شکل ۲ نشان داده شده زمینه برای شروع یادگیری گرادیان کاهشی فراهم می گردد. مدل را با مجموعه آموزشی خود و برای یک دوره زمانی آموزش می دهیم. در پایان هر دوره باید این اطمینان حاصل شود که خطاها در مجموعه آموزشی و مجموعه اعتبار سنجی در حال کاهش است. زمانی که در یکی از این موارد پیشرفتی حاصل نگردید، باید کار را متوقف کرد و از عملکرد مدل در داده های آزمون شده اطمینان حاصل کرد. در صورت عدم رضایت از عملکرد مدل باید پیرامون معماری تدبیر کرد و در نظر گرفت که آیا داده های جمع آوری شده حاوی اطلاعات لازم برای تشخیص می باشد یا خیر. در صورت داشتن رضایت از عملکرد مدل در داده های آموزشی باید آن را در داده های آزمون شده بررسی نمود. در صورت عدم رضایت نیز باید داده بیشتری را در مجموعه اطلاعات خود داشته باشیم، زیرا مجموعه آزمون شامل انواع نمونه هایی است که در مجموعه آموزشی به خوبی نشان داده شده اند. در طول فرآیند آموزش، روش هایی وجود دارند که برای جلوگیری از انطباق بیش از حد پیشنهاد می شوند. یکی از روش های جلوگیری از انطباق بیش از حد تحت عنوان نظام سازی^۱ شناخته می شود. این روش تابع هدفی را تغییر می دهد که با اضافه نمودن موارد اضافی که وزن های اضافی را حذف می کند، به حداقل مقدار ممکن کاهش می یابد. ترک عضو یک روش بسیار متفاوت برای جلوگیری از انطباق بیش از حد در شبکه های عصبی عمیق محسوب می شود. در طول فرآیند آموزش، این روش فقط با فعال نگه داشتن یک نورون با چند احتمال P (یک فرایارامتر) یا صفر انجام می شود. این روش باعث می شود که شبکه حتی در زمان عدم وجود اطلاعات مطمئن، صحت خود را حفظ نماید. روش ترک عضو مانع از وابستگی شدید شبکه به هر یک از نورون ها می شود. بر اساس یافته ها می توان اذعان نمود که با استفاده از یک روش تقریباً ترکیبی ترک عضو در بسیاری از معماری های شبکه


¹ Regularization

پلات، یک مشاهده پرت^۱ بیشتر از ۱.۵ وجود دارد که نمایانگر یک مقدار خیلی بالای "عامل قدرت" است.



شکل ۵: تشخیص نقاط پرت تک متغیره عامل قیمت


محور X (افقی): نشان دهنده ویژگی قیمت گذاری^۲ است که مربوط به تنظیم قیمت تعیین شده محصول می باشد. محور Y (عمودی): نشان دهنده مقدار یا میزان قیمت تنظیم شده است. محور Y بازه مقادیر این ویژگی را نمایش می دهد. در این پلات نیز چند مشاهده پرت بیشتر از ۳۵۰۰ وجود دارد که نشان دهنده مقادیر بسیار بالای قیمت گذاری غیرمتناسب می باشد.



شکل ۶: تشخیص نقاط پرت تک متغیره سال انتشار


محور X (افقی): نشان دهنده ویژگی خاص سال انتشار و یا رونمایی از محصول است که به سال عرضه محصول مربوط می شود. محور Y (عمودی): نشان دهنده سال انتشار محصول است. که یک پراکندگی گسترده از سال ۱۹۵۰ به بعد در عرضه محصولات را نمایش می دهد. در مرحله بعدی، مساحت ویژگی عملکرد گیرنده برای هر کلاس محاسبه می گردد و خروجی آن با استفاده از نمودار مشخصه عملکرد^۳ ROC جهت بررسی و ارزیابی عملکرد دسته بندی دو دویی

دادگان به صورت خودکار تعیین می گردد. بطور مثال در شکل زیر وضعیت محصولات فعال را مشاهده میکنید.



شکل ۳: فواصل تکرار با محصولات فعال

محور X (افقی): نشان دهنده نوع بازاریابی با وضعیت فعال است. در این قسمت دو نوع دسته بازاریابی وجود دارد متمرکز و دیگری پراکنده. محور Y (عمودی): نشان دهنده فراوانی یا تعداد هر نوع از بازاریابی با وضعیت فعال است. یعنی محور Y نشان می دهد که هر یک از این دو نوع بازاریابی چقدر تکرار شده است در مجموعه داده. بر اساس پلات، نوع بازاریابی پراکنده بیشترین فراوانی را دارد. همچنین، نقاط پرت تک متغیره برای تجزیه و تحلیل در ویژگی های عددی مجموعه داده صورت می گیرد. در شکل های ۴ و ۵، نتایج برخی از عامل ها نشان داده شده است.



شکل ۴: تشخیص نقاط پرت تک متغیره عامل قدرت


محور X (افقی): نشان دهنده ویژگی "عامل قدرت" است. این متغیر نشان دهنده یک ویژگی مهم محصول است. محور Y (عمودی): نشان دهنده مقدار یا میزان قدرت عامل است. محور Y بازه مقادیر این ویژگی را نمایش می دهد. در این

^۳ Receiver Operating Characteristic

^۱ outlier


^۲ price regulation

باکس پلات یک پراکندگی گسترده در سال های انتشار محصولات را نمایش می دهد.



شکل ۹: نمودارهای متغیر عددی با تخمین چگالی هسته و هیستوگرام تعداد محصولات

محور X (افقی): نشان دهنده تعداد محصولات. محور Y (عمودی): نمایش دهنده محدوده تعداد محصولات که از ۰ تا حدود ۱۵۰۰ را پوشش می دهد. این باکس پلات پراکندگی و محدوده وسیعی در تعداد محصولات را به تصویر می کشد.



شکل ۹: نمودارهای متغیر عددی با تخمین چگالی هسته و هیستوگرام قیمت خالص محصولات


محور X (افقی): مربوط به قیمت خالص پایین محصولات. محور Y (عمودی): نشان دهنده محدوده قیمت خالص پایین که از ۰ تا حدود ۲۰۰۰۰ را پوشش می دهد. این باکس پلات پراکندگی و دامنه وسیعی در قیمت خالص پایین محصولات را به تصویر می کشد.

۷ بحث و ارزیابی مدل پیشنهادی

بعد از پیش پردازش داده ها، باید یک شبکه عصبی بازگشتی طراحی نمود. شبکه RNN می تواند شامل لایه ها و چگالی نورون های هر لایه که قابلیت حفظ حافظه طولانی مدت را دارند و برای مدلسازی دنباله های زمانی مناسب هستند.

پس از طراحی شبکه، باید آن را بر روی داده های آموزشی آموزش داد. در این مرحله، معمولاً از تکنیک های بهینه سازی مانند پس انتشار خطا و الگوریتم های کاهش میزان یادگیری^۳ استفاده می شود. همچنین مدل را بر روی مجموعه های آموزش و اعتبارسنجی ارزیابی خواهیم کرد و از روش های انتخاب مدل مانند early stopping استفاده میکنیم تا با دقت

نمایش داده می شود.



شکل ۷: خروجی منحنی ROC

نمودار مشخصات عملکردی گیرنده:

این نمودار نشان دهنده رابطه بین نرخ حساسیت (True Positive Rate) و نرخ مثبت کاذب (False Positive Rate) است. منحنی آبی نشان دهنده عملکرد مدل است و خط قرمز خط پایه (baseline) را نشان می دهد. این نمودار به ارزیابی عملکرد کلی مدل کمک می کند.

نمودارهای متغیر عددی با تخمین چگالی هسته و هیستوگرام با اندازه bin به طور خودکار تعیین می شود، بنابراین برای رسم نمودارهای توزیع عددی^۱ با استفاده از تخمین چگالی هسته ای^۲ و هیستوگرام نمایش داده می شوند. این نمودارها برای بررسی توزیع متغیرهای عددی در دیتاست استفاده می شوند. برخی از خروجی ها در شکل های ۹، ۸ و ۱۰ ارایه شده است.



شکل ۸: نمودارهای متغیر عددی با تخمین چگالی هسته و هیستوگرام سال انتشار

محور X (افقی): نمایش دهنده سال انتشار محصولات. محور Y (عمودی): نشان دهنده محدوده سال های انتشار محصولات که از ۱۹۶۰ تا حدود ۱۹۵۰ را در بر می گیرد. این

³ Learning Rate Decay

¹ Numeric Variable Plots

² Kernel Density Estimate

محاسبه معیارهای دقت: با استفاده از مقادیر موجود در ماتریس درهم‌ریختی، معیارهای دقت، حساسیت، دقت و امتیاز F1 محاسبه می‌شوند و چاپ می‌شوند.

```
Epoch 1/10 [=====] - 75s 4ms/step - loss: 0.0235
- accuracy: 0.8459 - val_loss: 0.0235 - val_accuracy: 0.8454
Epoch 2/10 [=====] - 75s 4ms/step - loss: 0.0098
- accuracy: 0.8491 - val_loss: 0.0098 - val_accuracy: 0.8487
Epoch 3/10 [=====] - 75s 4ms/step - loss: 0.0086
- accuracy: 0.8499 - val_loss: 0.0086 - val_accuracy: 0.8495
Epoch 4/10 [=====] - 80s 4ms/step - loss: 0.0072
- accuracy: 0.8512 - val_loss: 0.0072 - val_accuracy: 0.8508
Epoch 5/10 [=====] - 80s 4ms/step - loss: 0.0062
- accuracy: 0.8524 - val_loss: 0.0062 - val_accuracy: 0.8519
Epoch 6/10 [=====] - 77s 4ms/step - loss: 0.0054
- accuracy: 0.8536 - val_loss: 0.0054 - val_accuracy: 0.8532
Epoch 7/10 [=====] - 75s 4ms/step - loss: 0.0049
- accuracy: 0.8543 - val_loss: 0.0049 - val_accuracy: 0.8539
Epoch 8/10 [=====] - 78s 4ms/step - loss: 0.0042
- accuracy: 0.8559 - val_loss: 0.0042 - val_accuracy: 0.8556
Epoch 9/10 [=====] - 78s 4ms/step - loss: 0.0039
- accuracy: 0.8571 - val_loss: 0.0039 - val_accuracy: 0.8567
Epoch 10/10 [=====] - 81s 4ms/step - loss: 0.0021
- accuracy: 0.8582 - val_loss: 0.0021 - val_accuracy: 0.8579
```

شکل ۱۰: صحت دقت شبکه عصبی

همانطور که می‌دانیم، ماتریس سردرگمی یک ابزار ارزیابی است که استفاده می‌شود تا عملکرد یک مدل دسته‌بندی را بر اساس پیش‌بینی‌های آن بررسی کند. این ماتریس بر اساس تعداد نمونه‌هایی که به درستی یا به اشتباه توسط مدل تشخیص داده شده‌اند، ساخته می‌شود. در ماتریس سردرگمی داده شده، ماتریس دو در دو به شکل زیر است:

Confusion Matrix:
[[38806 0]
[978 0]]

Classification Report:				
	precision	recall	f1-score	support
0	0.85	1.00	0.91	38806
1	0.83	0.92	0.87	978
accuracy			0.85	39784
macro avg	0.84	0.96	0.89	39784
weighted avg	0.84	0.99	0.90	39784

شکل ۱۱: مقادیر ماتریس سردرگمی

Macro Avg و Weighted Avg این مقادیر میانگین precision، recall و F1-Score برای هر کلاس را محاسبه می‌کنند. در این حالت، مقادیر macro avg برابر با ۰.۸۴ است که نشان می‌دهد میانگین precision، recall و F1-Score بین دو کلاس قابل قبول است. مقادیر weighted avg برابر با ۰.۸۳ برای precision، ۰.۹۲ برای recall و ۰.۸۷ برای F1-Score است که نشان

بیشتر و کاهش خطاهای احتمالی در روند پردازش داده‌ها بهترین نتایج حاصل شود. با اجرای این مراحل و بهبود مدل بر اساس نتایج، می‌توان به یک مدل کنترل موجودی با استفاده از شبکه عصبی بازگشتی رسید که عملکرد خوب و قابل قبولی در آموزش و تست داشته باشد. در ادامه توضیحات و نتایج استفاده از این شبکه توضیح داده شده است.

ایجاد مدل شبکه عصبی: با استفاده از Sequential و Dense، یک مدل شبکه عصبی با لایه‌های مخفی و تعداد نورون‌های مشخص ایجاد می‌شود.

کامپایل مدل: مدل با استفاده از compile و بهره‌برداری از الگوریتم بهینه‌سازی "adam" و تابع هزینه "binary_crossentropy" کامپایل می‌شود.

آموزش مدل: با استفاده از fit مدل بر روی داده‌های آموزشی آموزش داده می‌شود. تعداد تکرار (اپوک) ۱۰ و اندازه دسته‌ها (بچ‌سایز) ۸ است.

ارزیابی مدل: با استفاده از ارزشیابی عملکرد مدل بر روی داده‌های آزمون ارزیابی می‌شود. مقادیر هزینه (loss) و دقت (accuracy) در متغیرهای loss و accuracy ذخیره می‌شوند و نمایش داده می‌شوند. پیش‌بینی برچسب‌ها برای داده‌های آزمون: با استفاده از predict برچسب‌ها برای داده‌های آزمون پیش‌بینی می‌شوند و در متغیر y_pred قرار می‌گیرند. مقایسه برچسب‌های پیش‌بینی شده با برچسب‌های واقعی: با استفاده از argmax برچسب‌های پیش‌بینی شده و واقعی به صورت دسته‌بندی شده مقایسه می‌شوند و در متغیرهای y_test_labels و y_pred_labels قرار می‌گیرند.

محاسبه معیارهای ارزیابی: با استفاده از confusion-matrix و classification_report ماتریس درهم‌ریختی و گزارش دسته‌بندی محاسبه می‌شوند و نمایش داده می‌شوند.

بازیابی^۲: برای هر کلاس، بازیابی نسبت نمونه‌هایی است که به درستی تشخیص داده شده‌اند. برای کلاس ۰، بازیابی برابر است با ۱، که نشان می‌دهد مدل تمام نمونه‌های کلاس ۰ را به درستی تشخیص داده است. برای کلاس ۱، بازیابی برابر با ۰.۹۲ است، که نشان می‌دهد مدل ۹۲ درصد نمونه‌ها را به درستی به عنوان کلاس ۱ تشخیص داده است.


F1-Score: F1-Score معیاری است که ترکیبی از صحت و بازیابی است و برای هر کلاس محاسبه می‌شود. F1-Score برای کلاس ۰ برابر است با ۰.۹۱ که نشان می‌دهد تعادل خوبی بین صحت و بازیابی در کلاس ۰ وجود دارد. برای کلاس ۱، F1-Score برابر با ۰.۸۷ است به دلیل تشخیص صحیح نمونه‌های این کلاس توسط مدل را برای این تحقیق آشکار می‌سازد.

Support: تعداد واقعی نمونه‌های هر کلاس در داده است. در اینجا، تعداد نمونه‌های کلاس ۰ برابر با ۳۸۸۰۶ و تعداد نمونه‌های کلاس ۱ برابر با ۹۷۸ است.

دقت: دقت نسبت نمونه‌هایی است که به درستی تشخیص داده شده‌اند به تعداد کل نمونه‌ها. در اینجا، دقت برابر است با ۰.۸۵ که نشان می‌دهد ۸۵ درصد از نمونه‌ها به درستی تشخیص داده شده‌اند.

در کل، مدل در تشخیص نمونه‌های کلاس ۰ نسبتاً دقیق‌تر عمل کرده است، و همچنین در تشخیص نمونه‌های کلاس ۱ عملکردی نزدیک را مشاهده می‌نماییم. دقت مدل برای کل داده‌ها برابر است با ۰.۸۵ که به نظر می‌رسد مدل عملکرد متوسطی داشته است، آموزش شبکه‌های عصبی بازگشتی به دلیل مشکل محو شدگی گرادیان دشوار است. مشکل محو شدگی گرادیان هنگامی رخ می‌دهد که گرادیان تابع هزینه با توجه به پارامترهای شبکه عصبی بازگشتی در طول زمان بسیار کوچک می‌شود. این امر باعث می‌شود که شبکه عصبی

می‌دهد وزن‌دهی به تعداد نمونه‌ها در محاسبه مقادیر میانگین انجام شده است.



شکل ۱۲: گزارش طبقه بندی مدل

این ماتریس دو کلاس (۰ و ۱) را نشان می‌دهد. در اینجا، درایه‌های قطری از بالا به پایین و چپ به راست نشان می‌دهد که مدل چه تعداد نمونه را به درستی تشخیص داده است. بنابراین، در اینجا مدل ۳۸۸۰۶ نمونه را به درستی به عنوان کلاس ۰ تشخیص داده است و هیچ نمونه‌ای را به عنوان کلاس ۱ تشخیص نداده است.

درایه‌های غیرقطری ماتریس سردرگمی نشان می‌دهند که مدل چه تعداد نمونه را به اشتباه تشخیص داده است. در اینجا، مدل ۹۷۸ نمونه را به اشتباه به عنوان کلاس ۰ تشخیص داده است و هیچ نمونه‌ای را به عنوان کلاس ۱ تشخیص نداده است.

حال به Classification Report می‌پردازیم:

صحت^۱: برای هر کلاس، صحت نسبی پیش‌بینی‌های درست است. برای کلاس ۰، صحت برابر است با ۰.۸۵، که نشان می‌دهد ۸۵ درصد از نمونه‌های تشخیص داده شده به درستی به عنوان کلاس ۰ تشخیص داده شده‌اند. برای کلاس ۱، صحت برابر با ۰.۸۳ است که نشان می‌دهد مدل هیچ نمونه‌ای را به درستی به عنوان کلاس ۱ تشخیص نداده است.

² Recall

¹ Precision

کالایی در یک منطقه فقط یک فروش در طول یک سال داشته باشد و همان کالا نیاز هر روزه مشتریان در منطقه ای دیگر باشد، پس در این شرایط عامل منطقه دارای وزن بالایی در خصوص این کالا می باشد. لذا نیازمند سیستمی هوشمند هستیم تا به مدیریت کمک کند علاوه بر نظارت دقیق در روند فروش، تعیین کند که کدام محصولات از موجودی خود را برای فروش نگه دارند و محصولاتی را که فروش کمتری دارند کنار بگذارد. این امر می تواند در راستای رشد و ارتقاء شرکت و ایجاد تمایز محصولات و مهم تر از همه کسب مزیت رقابتی در بازار موثر واقع شود. رویکرد این مقاله قابلیت استفاده یا بازآوری محصول یا محصولاتی را که می توانند بر اثر گذشت زمان کیفیت اولیه را از دست بدهند، مدنظر بوده است. در این راستا با پیاده سازی رویکرد پیشنهادی، دستاوردهای مدیریت بر کنترل موجودی در خصوص پیشبینی تقاضا، بهینه سازی موجودی و مدیریت تخفیفات و تبلیغات توفیق حاصل شد.

از سوی دیگر، مطالعه تجربی برای یافتن بهترین رویکرد نشان داد، جهت هوشمند سازی زنجیره تامین در صنایع مختلف، استفاده از تکنیک های یادگیری عمیق با شبکه های عصبی بازگشتی، برای پیش بینی سری های زمانی و همچنین ادغام با چارچوب های سنتی دارای عملکرد بالایی به لحاظ سرعت و کاهش هزینه هستند. در این راستا، بعد از انجام طراحی مدل و انجام فرآیندهای مربوط به آموزش و تست، شبکه عصبی بازگشتی RNN با دقت ۸۵ درصد نتایج مطلوب را حاصل نکرد. در نهایت با توجه به محدودیت های این شبکه و ماهیت این پژوهش، استفاده از رویکرد ترکیبی شبکه عصبی BILSTM پیشنهاد شد. شبکه های عصبی بازگشت پذیر دوطرفه BILSTM هنگامی که نیاز به اطلاعات متن داده ی ورودی داریم مورد استفاده قرار می گیرد. با استفاده از دو جهت در زمان بر خلاف شبکه های بازگشت پذیر استاندارد در شبکه های بازگشت پذیر دوطرفه اطلاعات می تواند به

بازگشتی نتواند «وابستگی های طولانی مدت^۱» را در داده ها بیاموزد، که این امر، برای وظایفی مانند ترجمه ماشینی و تولید متن بسیار مهم است.

هم چنین معایبی از جمله آموزش سخت شبکه و تکرار پارامترها و یکسان بودنشان و از همه مهم تر عدم توانایی یادآوری اطلاعات از لایه های اول به دلیل تنها حافظه کوتاه مدت، این نوع شبکه ها را از نظر محاسباتی گران میسازد لذا با توجه به ماهیت این پژوهش و نیاز به داده های تاریخی حاصل از میزان فروش محصولات در بازه های زمانی، شبکه BILSTM میزان دقت بالاتری را در مقایسه با شبکه عصبی بازگشتی RNN نشان داد.

در این راستا، داده های حاصل از مرحله جهت یادگیری در شبکه عصبی بروزرسانی شده و پیش پردازش داده ها بر اساس محاسبات آنالیز قانون پارتو صورت گرفته است. همچنین، حذف مقادیر بسیار بزرگ با استفاده از تکنیک Mask انجام شده است و نهایتاً نرمالسازی ویژگی ها با استفاده از کمیت بیشینه و کمینه صورت پذیرفته است. بعد از ساخت مدل BILSTM و آموزش این شبکه ها با پارامترهای تعیین شده، در راستای هدف پژوهش، دقت ۹۳ درصد حاصل گردید.

```
Epoch 1/10 [=====] - 34s 2ms/step - loss: 0.1979 - accuracy: 0.9345
Epoch 2/10 [=====] - 32s 2ms/step - loss: 0.1744 - accuracy: 0.9352
Epoch 3/10 [=====] - 32s 2ms/step - loss: 0.1718 - accuracy: 0.9357
Epoch 4/10 [=====] - 32s 2ms/step - loss: 0.1706 - accuracy: 0.9359
Epoch 5/10 [=====] - 32s 2ms/step - loss: 0.1702 - accuracy: 0.9359
Epoch 6/10 [=====] - 32s 2ms/step - loss: 0.1696 - accuracy: 0.9362
Epoch 7/10 [=====] - 32s 2ms/step - loss: 0.1695 - accuracy: 0.9361
Epoch 8/10 [=====] - 32s 2ms/step - loss: 0.1691 - accuracy: 0.9359
Epoch 9/10 [=====] - 32s 2ms/step - loss: 0.1689 - accuracy: 0.9359
Epoch 10/10 [=====] - 32s 2ms/step - loss: 0.1686 - accuracy: 0.9362
keras.callbacks.History at 0x7ee9f70de930
```

شکل ۱۴: صحت دقت مدل BILSTM

نتیجه گیری

در راستای انجام فرایند پیش بینی کنترل موجودی هر مدل موجودی دارای رویکرد متفاوت و مخصوص به خود است و به ما کمک می کند تا بدانیم چه مقدار موجودی باید در انبار داشته باشیم. بدیهی است میزان زمانی که کالاها در فروشگاه قرار می گیرند تا خریداری شوند متفاوت است. عامل های بسیاری در این زمان نقش دارند. ممکن است

¹ Long Term Dependency

بازگشت‌پذیر دوطرفه اطلاعات می‌تواند به صورت همزمان هم از آینده و هم از گذشته در استیت فعلی دریافت شود. شبکه‌های عصبی بازگشت‌پذیر دوطرفه همانند شبکه‌های عصبی بازگشت‌پذیر استاندارد می‌توانند آموزش داده شوند. این اتفاق به سبب اینکه دو جهت در زمان هیچ تعاملی با هم ندارند محقق می‌شود و به صورت مستقل می‌توانند آموزش داده شوند. تنها تفاوت در زمان پسانتشار در زمان باید پردازش‌های اضافه‌ای هم انجام دهیم. به دلیل اینکه به‌روزرسانی خروجی‌ها و ورودی‌ها به صورت همزمان امکان انجام ندارد.

پیشنهاد برای تحقیقات آتی

از آنجا که یادگیری ماشین پتانسیل نوآوری صنایع و مدل‌های کسب‌وکار آن‌ها را دارد بنابراین، پیاده‌سازی یادگیری ماشین در اینترنت صنعتی اشیا می‌تواند مزایای زیادی از جمله، پیش‌بینی تقاضای مصرف‌کننده در صنایع، تعدیل زنجیره تامین، نگهداری و پیش‌بینی، کنترل کیفیت و افزایش توان عملیاتی تولید برای صنایع مختلف داشته باشد لذا پژوهشگران می‌توانند جهت کارهای آتی این پژوهش را در صنایع دیگر با استفاده از چارچوب‌های منبع باز برای توسعه مدل یادگیری ماشین در محیط صنعتی انجام دهند.

صورت همزمان هم از آینده و هم از گذشته در استیت فعلی دریافت شود.

شبکه‌های عصبی بازگشت‌پذیر دوطرفه همانند شبکه‌های عصبی بازگشت‌پذیر استاندارد می‌توانند آموزش داده شوند. این اتفاق به سبب اینکه دو جهت در زمان هیچ تعاملی با هم ندارند محقق می‌شود و به صورت مستقل می‌توانند آموزش داده شوند. تنها تفاوت در زمان پسانتشار در زمان باید پردازش‌های اضافه‌ای هم انجام دهیم. به دلیل اینکه به‌روزرسانی خروجی‌ها و ورودی‌ها به صورت همزمان امکان انجام ندارد. نهایتاً، شبکه پیشنهادی با دقت ۹۳ درصد نتیجه رضایت بخشی را در راستای اهداف این پژوهش حاصل کرد.

بطور کلی، این پژوهش نشان می‌دهد که رویکرد سنتی با سایر رویکردهای یادگیری عمیق و بهینه‌سازی، معماری‌های منحصربه‌فردی ایجاد می‌کند، که عملکرد یادگیری را برای وظایف پیچیده تجزیه و تحلیل کلان داده‌ها بهبود می‌بخشد. مقایسه بین روش پیشنهادی و سایر کارهای تحقیقاتی موجود عملکرد بهتری را در مسائل پیش‌بینی سریهای زمانی نشان می‌دهد. استفاده از روش استخراج ویژگی قدرتمند از یک طرف و به کارگیری یک مدل عمیق برای یادگیری الگوهای مصرف از طرف دیگر، روش پیشنهادی را متمایز کرده است. در این پژوهش پس از ارزیابی‌های فراوان، شبکه عمیق پیشنهادی به مقدار خطای قابل قبولی رسیده است. در نهایت، به منظور نمایش عملکرد شبکه، نتیجه ارزیابی دقت شبکه عمیق بر روی داده‌ها به شکل عددی و نموداری مقایسه شد. این سیستم نتایج یکنواخت و امیدوارکننده‌ای را برای پیش‌بینی نیازهای حوزه مربوطه به منظور کنترل میزان تولید براساس تئوری عرضه و تقاضا ارائه کرده است.

شبکه‌های عصبی بازگشت‌پذیر دوطرفه BILSTM هنگامی که نیاز به اطلاعات متن داده‌ی ورودی داریم مورد استفاده قرار می‌گیرد. با استفاده از دو جهت در زمان بر خلاف شبکه‌های بازگشت‌پذیر استاندارد در شبکه‌های

W. Liao, G. Ye, Y. Yin, W. Yan, Y. Ma and D. Zuo, "The Inventory of Spare Parts Prediction based on LSTM for Large Data and a Short Replacement Cycle," 2020 IEEE/ACS 17th International Conference on Computer Systems and Applications (AICCSA), Antalya, Turkey, 2020, pp. 1-5.

Zhang, G. P. (2003). Time series forecasting using a hybrid arima and neural network model. *Neurocomputing*, 50, 159–175.

Real Carbonneau, Kevin Laframboise, Rustam Vahidov Application of machine learning techniques for supply chain demand forecasting; *European Journal of Operational Research* Volume 184, Issue3; Pages 1140-1154, 2008

Maqsood, H., Mehmood, I., Maqsood, M., Yasir, M., Afzal, S., Aadil, F., Selim, M. M., & Muhammad, K. (2003). A local and global event sentiment based efficient stock.

Haider Maqsood, Irfan Mehmood, Muazzam Maqsood, Muhammad Yasir, Sitara Afzal, Farhan Aadil, Mahmoud Mohamed Selim, Khan Muhammad A local and global event sentiment based efficient stock exchange forecasting using deep learning, *International Journal of Information Management* Volume 50, 2020, Pages 432-451.

Yang, R., Yu, L., Zhao, Y., Yu, H., Xu, G., Wu, Y., & Liu, Z. (2020). Big data analytics for financial market volatility forecast based on support vector machine. *International Journal of Information Management*, 50, 452–462.

Ellefsen, A. L., Bjørlykhaug, E., Æsøy, V., Ushakov, S., & Zhang, H. (2019). Remaining useful life predictions for turbofan engine degradation using semi-supervised deep architecture. *Reliability Engineering & System Safety*, 183, 240–251.

Deng, K., Zhang, X., Cheng, Y., Zheng, Z., Jiang, F., Liu, W., & Peng, J A remaining useful life prediction method with long-short term feature processing for aircraft engines. *Applied Soft Computing*, 106344. (۲۰۲۰).

منابع

—خمسه، عباس؛ ابراهیمی نژاد، فتاح (۱۴۰۰). شناسایی تاثیر دوسوتوانی سازمانی بر قابلیت نوآوری (مطالعه موردی: شرکت های مستقر در پارک فناوری پردیس). فصلنامه دانش کارآفرینی، دوره ۱، شماره ۱، زمستان ۱۴۰۰.

—رضایی، حامد؛ علیاحمدی، علیرضا؛ امینی، محمدتقی؛ رحمانی، زینالعابدین (۱۳۹۷). ارائه الگوی ارزیابی عملکرد زنجیره تأمین با بهره‌گیری از مدل کارت امتیازی متوازن در یکی از سازمانهای خرید نظامی. فصلنامه علمی-پژوهشی مدیریت منابع در نیروی انتظامی، دوره ۶، شماره ۴، صص ۳۵-۵۸.

—آقایی، اصغر؛ صالحی صدقیانی، جمشید؛ قربانزاده، وجه...؛ میکائیلی، فتاح؛ آقایی، میلاد (۱۳۹۳). الگوی زنجیره تأمین چابک ناجا. فصلنامه علمی-پژوهشی مدیریت منابع در نیروی انتظامی، دوره ۲، شماره ۲، صص ۵۱-۷۲.

—شهابی، رویا؛ نژاد محمد ناقتی، احسانه (۱۴۰۲). مروری بر کارآفرینی در اکوسیستم اینترنت اشیا. فصلنامه دانش کارآفرینی، دوره ۳، شماره ۷، تابستان ۱۴۰۲.

—طهماسبی نسب، سیروس؛ حقیقی نسب، منیژه؛ زمانی مقدم، افسانه (۱۴۰۲). تدوین مدلی جامع جهت ارزیابی عوامل بازاریابی الکترونیکی موثر بر زنجیره تأمین چابک با رویکرد QFD در اپراتوری همراه اول ایران. فصلنامه دانش کارآفرینی، دوره ۳، شماره ۶، بهار ۱۴۰۲.

—مولوی خایانی، امیر (۱۳۹۷). کلان داده ها معماری و کاربرد ها. نشر موسسه فرهنگی هنری دیباگران تهران.

—آذر، ع. علی محمدلو، م. (۱۳۸۶). طراحی مدل ریاضی مدیریت موجودی در زنجیره تأمین. مجله مدرس. دوره ۱، شماره ۳.

Weng T., Liu W., Xiao J.

Supply chain sales forecasting based on lightGBM and LSTM combination model

Industrial Management and Data Systems, 120 (2019), pp. 265-279.

Noble, M.A. (1997). "Manufacturing competitive priorities and productivity: an empirical study" Operations & Production Management, Vol. 17, No.1.

-Abbasi, R., Sedaghati, H. R., & Shafiei, S. (2022). Proposing an Economic Order Quantity (EOQ) model for imperfect quality growing goods with stochastic demand. Research in Production and Operations Management, 13(1), 105-127. doi: 10.22108/jpom.2022.127914.1356.

Mandal, S. (2012). "An empirical investigation into supply chain resilience", The IUP Journal of Supply Chain Management, Vol. 9 No. 4, pp. 46-61.

Naddor E (1966) Inventory systems. Wiley, New York

Vrat, P. (2014). Basic Concepts in Inventory Management. In: Materials Management. Springer Texts in Business and Economics. Springer, New Delhi. https://doi.org/10.1007/978-81-322-1970-5_2

Haofang Feng, Sheng Hao Zhang, Yong Zhang, 2023. Managing production-inventory-maintenance systems with condition monitoring, European Journal of Operational Research, Volume 310, Issue 2, 2023, Pages 698-711, ISSN 0377-2217, <https://doi.org/10.1016/j.ejor.2023.03.043>.

Mehdizadeh M (2020) Integrating ABC analysis and rough set theory to control the inventories of distributor in the supply chain of auto spare parts. Comput Ind Eng 139:105673

Mitchell A. Millstein, Liu Yang, Haitao Li, Optimizing ABC inventory grouping

Siarni-Namini, S., Tavakoli, N., & Namin, A. S. (2018). A comparison of arima and LSTM inforecasting time series. 2018 17th IEEE international conference on machine learning and applications (ICMLA), 1394-1401.

Lim, B., & Zohren, S. (2020). Time series forecasting with deep learning: A survey. arXiv preprint arXiv:2004.13408.

Xia, T., Song, Y., Zheng, Y., Pan, E., & Xi, L. (2020). An ensemble framework based on convolutional bi-directional LSTM with multiple time windows for remaining useful life estimation. Computers in Industry, 115, 103182.

Villegas, M. A., & Pedregal, D. J. (2018). Supply chain decision support systems based on a novel hierarchical forecasting approach. Decision Support Systems, 114, 29-36.

Chandriah, K.K., Naraganahalli, R.V. RNN / LSTM with modified Adam optimizer in deep learning approach for automobile spare parts demand forecasting. Multimed Tools Appl 80, 26145-26159 (2021).

A. Sherstinsky, Fundamentals of Recurrent Neural Network (RNN) and

Long Short-Term Memory (LSTM) network, Physica D (2020)

Sepp Hochreiter and Jürgen Schmidhuber. Long Short-Term memory. Neural computation, 9(8):1735-1780, 1997.

Alex Sherstinsky. Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network,

2018. cite arxiv:1808.03314 Comment: 39 pages, 10 figures, 66 references.

Guna sekaran, A., Papadopoulos, T., Dubey, R., Wamba, S.F., Childe, S.J., Hazen, B., Akter, S., 2017. Big data and predictive analytics for supply chain and organizational performance. J. Bus. Res. 70, 308-317. <http://dx.doi.org/10.1016/j.jbusres.2016.08.004>.

decisions, International Journal of Production Economics, Volume 148, 2014, Pages 71-80,

Y. Chen, K. W. Li and S. -f. Liu, "A comparative study on multicriteria ABC analysis in inventory management," 2008 IEEE International Conference on Systems, Man and Cybernetics, Singapore, 2008, pp. 3280-3285, doi: 10.1109/ICSMC.2008.4811802.

Jian Li, Shouyang Wang, T.C. Edwin Cheng, Analysis of postponement strategy by EPQ-based models with planned backorders, Omega, Volume 36, Issue 5, 2008, Pages 777-788.

Leopoldo Eduardo Cárdenas-Barrón, The derivation of EOQ/EPQ inventory models with two backorders costs using analytic geometry and algebra, Applied Mathematical Modelling, Volume 35, Issue 5, 2011, Pages 2394-2407, ISSN 0307-904X

Glock, C.H., Jaber, M.Y. and Searcy, C. (2012), "Sustainability strategies in an EPQ model with price- and quality-sensitive demand", The International Journal of Logistics Management, Vol. 23 No. 3, pp. 340-359. <https://doi.org/10.1108/09574091211289219>

Yuqing Peng, Xuan Liu, Weihua Wang, Xiaosong Zhao, Ming Wei, Image caption model of double LSTM with scene factors, Image and Vision Computing, Volume 86, 2019, Pages 38-44, ISSN 0262-8856.