



## مدل پیش‌بینی تقاضای زنجیره تأمین با تنوع محصولی بالا با استفاده از روش‌های یادگیری ماشین مبتنی بر تقویت گرادیان

محمد رضا فهیمی  
علی رجب زاده قطری\*  
مریم شعار  
مریم خادمی

دانشجوی دکتری مدیریت صنعتی، دانشگاه آزاد اسلامی، واحد تهران شمال، تهران، ایران  
استاد، گروه مدیریت صنعتی، دانشکده مدیریت و اقتصاد، دانشگاه تربیت مدرس، تهران، ایران  
استادیار گروه مدیریت صنعتی، دانشگاه آزاد اسلامی، واحد تهران شمال، تهران، ایران  
دانشیار گروه ریاضی کاربردی، دانشگاه آزاد اسلامی، واحد تهران جنوب، تهران، ایران

تاریخ دریافت: ۱۴۰۲/۰۲/۱۶

### چکیده

پیش‌بینی تقاضای محصولات زنجیره تأمین برای تعیین استراتژی‌ها و تصمیم‌گیری‌ها موضوعی بسیار با اهمیت و پرچالش است. با افزایش تنوع و تعداد محصولات، این چالش‌ها نیز افزایش می‌یابد. ارائه چارچوب‌ها و روش‌هایی که با وجود تنوع محصولی، تفاوت در کاربردها و ویژگی‌ها و حجم داده‌های مختلف، از انعطاف‌پذیری، دقت و مزیت‌های لازم برای پیش‌بینی همه دسته‌های محصولی برخوردار باشد، برای مدیران حیاتی است. در این راستا، دو مدل یادگیری با نظارت، XGBoost و Regressor (XGBR) و Gradient Boosting Regressor (GBR)، بر روی مجموعه داده‌های Global Superstore. در سایت Kaggle پیاده‌سازی شده است. این مجموعه داده شامل ۳۷۸۸ محصول در سه Category محصولی متنوع، هفده Sub Category و ۵۱،۲۹۰ سفارش است. حجم داده‌های محدود محصولات سبب می‌گردد پیش‌بینی بسیاری از محصولات و کسب نتیجه مناسب از روش‌ها میسر و مفید نگردد. با توجه به اینکه در این تحقیق تجربی هدف پیش‌بینی تقاضا، بکارگیری در تصمیمات استراتژیک است، رویکردی تجمیع محصولی برای این مسئله پیشنهاد شده که با توجه به مشابهت در محصولات Sub Categoryها پیش‌بینی آنها به صورت تفکیک‌شده صورت گیرد. به منظور بررسی اثر میزان داده بر عملکرد مدل‌ها، داده‌های مجموعه داده با استفاده از تکنیک Data Augmentation افزایش یافته و با اجرای مجدد مدل‌ها، نتایج پیش‌بینی دو مدل با هم مقایسه شده‌اند. براساس ارزیابی نتایج پیش‌بینی با داده‌های افزایش یافته با دو معیار MSE و MAE، مدل XGBR در کمترین مقدار به ترتیب به ۰/۱۲ و ۰/۱۰، و مدل GBR نیز به مقادیر ۰/۱۳ و ۰/۱۵ دست یافته است. همچنین، نتیجه معیار  $D^2$  Score در مدل XGBR در بیشترین مقدار ۰/۹۷ و در مدل GBR مقدار ۰/۹۶ است. با افزایش داده‌ها، مقادیر معیارهای اندازه‌گیری خطای به صورت چشمگیری و تا بیش از ۸۰ درصد کاهش یافته و در داده‌های با حجم بیشتر، XGBR برتری نسبی دارد. چارچوب و مدل‌های پیشنهادی می‌تواند در صنایع با مسائل مشابه در سطح استراتژی استفاده شود.

واژگان کلیدی: پیش‌بینی تقاضا، تنوع محصولی بالا، Gradient Boosting، XGBoost

طبقه‌بندی JEL: C53, L81, C22, M11

## ۱- مقدمه

استفاده از بسیاری از روش‌های پیش‌بینی را ناممکن می‌سازد. از سویی دیگر تغییرات متعدد و وجود انبوهی از کالاهای مشابه موجب می‌شود پیش‌بینی تک‌تک محصولات ممکن و مفید نباشد. طبعاً پیش‌بینی کلی تقاضا نمی‌تواند مفید به فایده باشد و برای کاربرد استراتژیک پیش‌بینی تقاضا باید به تفکیک سطح مناسبی از سلسله مراتب محصولی صورت پذیرد که ویژگی‌ها و کاربردهای مشابه دارند.

در مطالعات متعددی از جمله پژوهش (Babai et al., 2022) با اشاره به محدودیت‌های داده‌ای و ساختار محصولی محققان پیشنهاد داشته‌اند که جزئیات مورد نیاز برای پیش‌بینی باید براساس نیازهای برنامه‌ریزی و تصمیم‌گیری تعیین شود و تصمیمات استراتژیک زنجیره تامین نیازمند پیش‌بینی در سطوح بالاتر است. در برخی موارد ممکن است دقت پیش‌بینی با تجمیع داده‌ها یا پیش‌بینی در سطوح پایین‌تر یا بالاتر بهبود یابد. از این‌رو استفاده از سلسله مراتب را در پیش‌بینی توصیه نموده‌اند. آنان یکی از روش‌های این تجمیع مقطعی در یک بعد مثلاً محصولات دانسته‌اند که با انتقال پیش‌بینی به سطوح بالاتر یا پایین‌تر میسر می‌گردد.

در این تحقیق، در رویکردی متفاوت برای پیش‌بینی تقاضا، چارچوب تجمیع مقطعی مبتنی بر زیردسته محصول پیشنهاد شده است. این رویکرد با توجه به اهداف تحقیق برای استراتژی‌ها و مشابهت محصولات این سطح با یکدیگر، مناسب است. علاوه بر این با توجه به مسائل مربوط به داده‌های متنوع ناشی از تفاوت محصولات که شرح داده شد، از حیث انتخاب و بکارگیری روش و مدل پیش‌بینی نیز چالش‌هایی وجود دارد. بطوری‌که در شرایط مشروح انتخاب روشی که بتواند با انعطاف مناسب در برابر حجم داده‌های نسبتاً متفاوت با کمترین خطا و با عملکردی یکنواخت همه موارد انتخابی را پیش‌بینی نماید، دچار چالش است. اگرچه برخی محققان روش‌های مختلف برای کسب نتیجه مناسب اقدام نموده‌اند، اما به‌طور معمول پیاده‌سازی آن‌ها موجب تحمیل هزینه و زمان زیادی به

تحقیقات اهمیت مدیریت زنجیره تامین را در پایداری بسیاری از سازمان‌ها، به ویژه در عصر آشفته امروز، ثابت کرده‌است. داده‌های تاریخی پانزده سال اخیر نشان می‌دهد که بسیاری از سازمان‌ها به دلیل عدم شناخت صحیح نشانه‌های بازار و عدم توانایی در همگام شدن با پیشرفت سریع فناوری و رشد سریع تقاضا و انتظارات مصرف‌کنندگان، مجبور به تعطیلی شدند (Amer et al., 2020). پیش‌بینی برای پشتیبانی از اکثر تصمیم‌گیری‌های مدیریت زنجیره تامین ضروری است. از ابعاد اصلی مشخص‌کننده جزئی‌نگری تصمیم‌گیری‌ها، زمان و محصول می‌باشند. پیش‌بینی تقاضا اساس اکثر تصمیمات در مدیریت زنجیره تامین و پیش‌بینی‌های در سطوح بالاتر و در افق‌های طولانی‌تر، برای تصمیم‌گیری‌های استراتژیک زنجیره تامین مورد نیاز است (Babai et al., 2022). با تلاش قابل توجهی برای توسعه و بهبود مدل‌های پیش‌بینی صورت گرفته طی چند دهه گذشته، صنعت خرده‌فروشی شاهد تغییر از تصمیم‌گیری مبتنی بر شهود به تصمیم‌گیری مبتنی بر داده شده است (Fisher & Raman, 2018). عوامل بازار و رقابت که استراتژی خرده‌فروشی را تعیین می‌کنند به طور معمول به پیش‌بینی‌ها وابسته هستند (Levy et al., 2012). از مهم‌ترین انواع خرده‌فروشی‌ها فروشگاه‌های زنجیره‌ای است که از چندین فروشگاه خرده‌فروشی تحت مالکیت مشترک متمرکز تشکیل شده است (Berman et al., 2018).

با توجه به ماهیت برخی فروشگاه‌های زنجیره‌ای در ارائه محصولات متنوع با برندها، کاربردها و ویژگی‌های مختلف، همواره این چالش وجود داشته که برای پیش‌بینی تقاضا برای تعیین استراتژی‌ها چه چارچوب‌ها و روش‌هایی مؤثر است. از سویی تنوع محصولات موجب تفاوت تعداد سفارشات آنها در بازه زمانی و پراکندگی توزیع سفارش و ناکافی بودن داده سری زمانی در محصولات کم فروش می‌گردد و این محدودیت داده

خطای پیش‌بینی را در مقایسه با روش SARIMA به میزان ۵۵/۴۲ درصد و در مقایسه با روش LGBM به میزان ۱۳/۱ درصد کاهش دهد (Islam et al., 2024). مطالعه‌ای در مورد زنجیره تأمین قطعات یدکی بیان داشته است که در این صنعت برای تضمین رضایت مشتری و به حداقل رساندن موجودی کافی، انجام پیش‌بینی تقاضا به دلیل تغییرپذیری بالا در اندازه تقاضا و فواصل زمانی در اثر سفارشات پس از فروش که ناشی از تعمیر و نگهداری است، دچار چالش است. در این مطالعه برای پیش‌بینی مؤثر تقاضا، توسعه فناوری هوشمند مبتنی بر داده را مدنظر داشته و هدف مطالعه را طبقه‌بندی الگوهای تقاضا و توسعه مدل‌های مربوطه از طریق رویکرد انباشت مجموعه‌ای (Stacking ensemble) برای بهبود عملکرد کلی پیش‌بینی بیان داشته است. مدل ترکیبی پیشنهادی این مطالعه مبتنی بر روش‌های مختلفی از جمله XGB است که یک سیستم هشدار برای نظارت بر عملکرد و یک مکانیزم سیستماتیک برای بازآموزی مدل برای حفظ کیفیت تصمیم را توسعه می‌دهد (Chien et al., 2023).

(Lee et al., 2023) در پژوهشی با ضروری دانستن تعیین قیمت بهینه محصولات در صنعت کالاهای مصرفی با گردش سریع، یکی از اثرات چالش‌برانگیز در فروشگاه‌های خرده‌فروشی را اثر جایگزینی می‌داند و معتقد است اثر جایگزینی نیازمند بررسی تعداد زیادی از ترکیب‌های تغییر قیمت و در دسترس بودن سایر محصولات است و برای این موضوع ابزار سیستماتیک پشتیبانی از تصمیم‌گیری قیمت را برای پیش‌بینی تقاضا و بهینه‌سازی قیمت در فروشگاه‌های آنلاین و ثابت با در نظر گرفتن اثر جایگزینی پیشنهاد کرده است. محققان برای مدل‌های پیش‌بینی تقاضا و بهینه‌سازی قیمت، دو روش معرفی کرده‌اند که تغییرات قیمت محصول و ساختار همبستگی تقاضا را منعکس می‌کند. روش اول، روش توسعه‌یافته پیش‌بینی تقاضا با در نظر گرفتن تغییرات قیمت تمام محصولات است که بهترین پیش‌بینی تقاضا

کسب‌وکارها می‌شود و بعضاً موجب مشکلاتی می‌گردد. برای بررسی این چالش مجموعه داده یک فروشگاه زنجیره‌ای با محصولات متنوع و متعدد با خصوصیات لازم از سایت کگل انتخاب شد. برای دستیابی به اهداف تحقیق در ارائه تلفیقی از چارچوب و مدل که بتواند در شرایط داده‌های محدود و تنوع محصولی پیش‌بینی تقاضای مناسبی حاصل نماید، مدل‌هایی بر مبنای روش‌های یادگیری ماشین XGB و Gradient Boosting ارائه و در دو حالت بدون تغییر در داده‌ها و با داده‌های افزایش‌یافته آزمایش شد.

## ۲- پیشینه تحقیق

مطالعات بسیاری در خصوص استفاده از روش‌های یادگیری ماشین از جمله روش‌های بکاررفته در این تحقیق برای پیش‌بینی تقاضای زنجیره‌های تأمین با محصولات با تنوع بالا، خرده‌فروشی‌ها، فروشگاه‌های زنجیره‌ای و موارد مشابه صورت گرفته است. در این بخش برخی از جدیدترین آنها با ذکر جزئیات منعکس گردیده و در نهایت در بخش نتیجه‌گیری از مناظر داده‌های مورد آزمایش، چارچوب و هدف پیش‌بینی در زنجیره تقاضا و مدل مورد مقایسه قرار گرفته است.

در تحقیقی در زنجیره تأمین، یک چارچوب راه‌حل سه‌مرحله‌ای را برای حل مشکلات با انتخاب تأمین‌کننده و برنامه‌ریزی تخصیص سفارش پیشنهاد می‌کنند. در اولین مرحله تحقیق آنان، یک تکنیک جدید پیش‌بینی یادگیری عمیق رابطه‌ای اصلاح شده برای پیش‌بینی خواسته‌های محصولات ایجاد شده است و کارایی این تکنیک اصلاح شده با دو تکنیک پیش‌بینی معروف SARIMA و Light - Gradient Boosted Machine (LGBM) مقایسه می‌شود. آنان چارچوب توسعه‌یافته پیشنهادی خود را با استفاده از یک مجموعه داده واقعی از صنعت گوشت کانادا مورد بررسی قرار داده‌اند. محققان براساس نتایج مدل‌های پیش‌بینی، ادعا داشته‌اند که شبکه یادگیری عمیق توسعه‌یافته می‌تواند

استفاده شده برای پیش‌بینی خرده‌فروشی، را با بهبود قابل توجه در معیارهای دقت به همراه کاهش کمبود کالا و موجودی انبار، پشت سر می‌گذارد و از سطح بالایی از اتوماسیون متناسب برای خرده‌فروشان برخوردار است.

در پژوهشی دیگر، (Joseph et al., 2022) پیش‌بینی تقاضای محصولات در اپراتورهای خرده‌فروشی را مدنظر قرار داده‌اند تا با تصمیم‌گیری از طریق تجزیه و تحلیل داده‌ها به ساختن استراتژی و دستیابی به اهداف تجاری کمک بگیرند. آنان از مجموعه داده‌های چالش پیش‌بینی تقاضای یک فروشگاه از سایت Kaggle برای پیاده‌سازی چارچوب پیشنهادی خود استفاده کرده‌اند. نوآوری اصلی آنان ساخت یک چارچوب CNN-BiLSTM همراه با بهینه‌ساز Lazy Adam برای پیش‌بینی دقیق تقاضای محصول از اقلام فروشگاه است. محققان تکنیک‌های پیشرفته‌ی یادگیری ماشین SGD, CNN-LSTM, SVR, Knn, XGBoost RF, Bagging, و Linear Regression را در پیش‌بینی تقاضا اجرا و نتایج آنها را با مدل پیشنهادی خود مقایسه نموده‌اند. ارزیابی نتایج روش‌ها با معیارهایی از جمله MAPE, MAE و R-Squared نشان می‌دهد که چارچوب پیشنهادی محققان در مقایسه با رویکردهای سنتی دقت بیشتری دارد. بجز فروشگاه‌های زنجیره‌ای و خرده‌فروشی‌ها استفاده از روش‌های یادگیری ماشین از جمله روش‌های خانواده Gradient Boosting برای پیش‌بینی تقاضا در سایر صنایع و خدمات با تنوع محصولی نیز مورد استفاده قرار گرفته، که از جمله آنها می‌توان به تحقیقات (Kwon et al., 2024) در فرآورده‌های خونی کره‌جنوبی، (Abolghasemi et al., 2023) در زنجیره تأمین خون بیمارستان‌ها و (Song & Hu, 2023) در تقاضای شارژ خودروی برقی اشاره کرد.

### ۳- مبانی نظری

زمان و محصول دو بعد اصلی مشخص‌کننده جزئیات تصمیمات زنجیره تأمین هستند. از بعد محصول

برای محصول از بین سری‌های زمانی و روش‌های مختلف یادگیری ماشین با تنظیم فرآپارامترها برمی‌گزینند. و روش دوم، رویه‌ی توسعه‌یافته‌ی بهینه‌سازی قیمت، یک مسئله‌ی برنامه‌ریزی با قیود است که براساس بازه‌ی زمانی یک هفته و گردآوری سطح دسته‌بندی محصول عمل می‌کند و قادر است حداکثر سود را از بین ترکیبات مختلف قیمت به دست آورد. محققان روش‌های مختلفی شامل MLR, Extra Tree, ARIMA, RF, GBM, K-Neighbours, LightGBM, DecisionTree, Seasonal-Naïve, NaïveBayes, HistGBM, XGB, Simple-Average و Simple-Median را برای پیش‌بینی مقایسه کرده‌اند (Chien et al., 2023).

همچنین (Andrade & Cunha, 2023) با در نظر گرفتن پیش‌بینی تفکیک‌شده برای اطمینان از سودآوری به‌عنوان پشتیبان تصمیمات دقیق در رابطه با موجودی کالا و در نتیجه جلوگیری از کمبود کالا یا مازاد موجودی و ضررهای مرتبط با آن، در تحقیق خود به موضوع پیش‌بینی تقاضا در خرده‌فروشی‌ها با کالاهای متنوع پرداخته‌اند. آنان معتقدند تعداد زیاد فروشگاه‌ها و محصولات خرده‌فروشان مدرن و استراتژی‌های پیچیده‌ی بازاریابی و تبلیغاتی بر تقاضای مشتری مؤثر است و با توجه به اثرات متقابل بین محصولات، مدل‌سازی همه‌ی آنها پیچیده است. محققان برای حل این مسائل، مدل XGB را پیشنهاد کرده‌اند. آنان از مدل ترکیبی غیرخطی و غیرپارامتری به‌عنوان الگوریتم یادگیری مرکزی و یک روش اصلاح تغییر ساختاری برای در نظر گرفتن تغییرات ناگهانی در رفتار مصرف‌کننده ناشی از عوامل خارجی استفاده کرده‌اند. همچنین رویکردی شامل رویه‌های پاکسازی داده‌ها برای اصلاح مشاهدات فروش در روزهای کمبود کالا و مغایرت‌های موجودی منطقی و فیزیکی داشته‌اند. نتایج مطالعه آنان که براساس داده‌های واقعی یک مجموعه داده‌ی عمومی از یک خرده‌فروش بزرگ انجام شده است، نشان می‌دهد که مدل پیشنهادی آنان روش‌های مدل Base-Lift، یک مدل معیار بسیار

یادگیری ماشین زیرمجموعه‌ای از هوش مصنوعی است که در آن الگوریتم یادگیری ماشین می‌تواند به‌طور خودکار از داده‌های خام گذشته یاد بگیرد تا براساس الگوریتم‌های از پیش طراحی‌شده، مدل‌های پیش‌بینی ایجاد کند. به‌طور کلی، دو نوع الگوریتم یادگیری وجود دارد: یادگیری با نظارت و یادگیری بدون نظارت. الگوریتم‌های یادگیری ماشین با نظارت، از داده‌های برچسب‌گذاری‌شده شامل ورودی و خروجی یاد می‌گیرند. این الگوریتم مسئول یافتن رابطه بین ورودی و خروجی است و زمانی که به سطح عملکرد قابل قبولی برسد، یادگیری متوقف می‌شود. یادگیری ماشین شامل الگوریتم‌های مختلفی از جمله شبکه‌های عصبی مصنوعی، ماشین‌های بردار پشتیبان، جنگل‌های تصادفی، رگرسیون، درختان تصمیم و الگوریتم‌های *k-means* است. هر یک از این الگوریتم‌ها برای پیاده‌سازی در هر کسب و کار، مزایا و معایب خاص خود را دارد (Aamer et al., 2020). الگوریتم‌های یادگیری با نظارت و بدون نظارت عمدتاً برای چهار نوع وظیفه به کار گرفته می‌شوند: رگرسیون، طبقه‌بندی، خوشه‌بندی و وابستگی (Kone & Karwan, 2011) یکی از کاربردهای مختلف یادگیری ماشین، ساخت مدل رگرسیون یا طبقه‌بندی غیرپارامتری از داده‌ها است. ساختن یک مدل پیش‌بینی‌کننده قوی، از متداول‌ترین رویکردهای مدل‌سازی داده‌محور است (Natekin & Knoll, 2013). تحقیقات بسیاری در استفاده از یادگیری ماشین در زنجیره تأمین صورت گرفته است. (Mafakheri & Seyedan, 2020) معتقدند تلاش‌های صورت‌گرفته در استفاده از الگوریتم‌های یادگیری ماشین و تحلیل داده با هدف برآوردن تقاضای مشتری و به حداقل رساندن هزینه‌های زنجیره تأمین، می‌تواند منجر به تسهیل در پیش‌بینی دقیق (مبتنی بر داده) تقاضا شود و فعالیت‌های زنجیره تأمین را با این پیش‌بینی‌ها همسو سازد تا کارایی و رضایت مشتری بهبود یابد.

تصمیمات از سطح کالای خاص (SKU) منفرد، مانند کنترل موجودی، تا سطح تمام SKUها و برنامه‌ریزی ظرفیت کل متغیرند. از بعد زمان، تصمیمات عملیاتی در سطوح روزانه یا هفتگی اتخاذ می‌شوند، در حالی که تصمیمات تاکتیکی و استراتژیک در سطوح ماهانه و سالانه گرفته می‌شوند. در سطح استراتژیک، مدیران زنجیره تأمین به‌طور فزاینده‌ای با ظرفیت نامشخص و افزایش تغییرات بازار و فناوری مواجه‌اند. این موضوع آن‌ها را تحت فشار قرار می‌دهد تا هنگام مدیریت ظرفیت و تصمیم‌گیری در مورد کانال‌های توزیع (آنلاین، فروشگاه یا همه-کاناله)، کل سبد محصولات ارائه شده به آن بازارها را در نظر بگیرند. هم‌خوانی بین برنامه‌ها و تصمیمات استراتژیک، تاکتیکی و عملیاتی در افق‌های بلندمدت، میان‌مدت و کوتاه‌مدت لازم است و میزان جزئیات پیش‌بینی، چه از نظر مقطعی و چه زمانی، باید بر اساس الزامات برنامه‌ریزی و تصمیم‌گیری تعیین شود. لذا پیش‌بینی، جزئیات بسیاری دارد و ملاحظات این‌چنینی به این پرسش پاسخ می‌دهند که چه چیزی را باید پیش‌بینی کرد. در پاسخ به سؤالات متعدد باید در نظر گرفت که راه‌حل‌ها و روش‌های پیش‌بینی می‌توانند با استفاده از داده‌ها یا پیش‌بینی‌ها در هر سطح سلسله مراتب مورد بررسی قرار گیرند. بنابراین پیش‌بینی‌ها می‌توانند بنا بر اهداف با استفاده از روش‌های پایین به بالا یا بالا به پایین به دست آیند (Babai et al., 2022). در هر سطح از زنجیره تأمین، تعداد بسیار زیادی محصول هستند که همه آن‌ها به‌صورت جداگانه یا ترکیبی با یکدیگر، سلسله مراتب طبیعی مقطعی را تشکیل می‌دهند. تقاضا باید در این سطوح سلسله مراتبی مختلف جمع‌آوری شود تا فرایند تصمیم‌گیری در طیف وسیعی از سطوح سازمانی و عملکردی را مشخص کند (Syntetos et al., 2016).

Quantifying The Quality of Predictions, Pedregosa et al., ) مقاله در کتابخانه

“Scikit-learn: Machine Learning in Python” (2011) با عنوان

$$D^2(y, \hat{y}) = 1 - \frac{\text{dev}(y, \hat{y})}{\text{dev}(y, y_{\text{null}})} \quad \text{رابطه (۳)}$$

روش درخت رگرسیون تقویت شده با گرادیان (Gradient Boosting) از تکنیک‌های قدرتمند یادگیری ماشین مبتنی بر تقویت گرادیان است که توسط (Friedman, 2001) مطرح شده و در طیف وسیعی از کاربردهای عملی موفقیت قابل توجهی را نشان داده است. در مدل Gradient Boosting فرایند یادگیری به طور متوالی مدل‌های جدیدی را برای ارائه برآورد دقیق تری از متغیر پاسخ تطبیق می‌دهد. ایده اصلی پشت این الگوریتم، ساخت یادگیرنده‌های پایه جدید است به گونه‌ای که حداکثر همبستگی را با گرادیان منفی تابع زیان مرتبط با کل مجموعه داشته باشند. توابع زیان قابل اعمال می‌توانند دلخواه باشند، اما برای درک بهتر موضوع، اگر تابع خطای کلاسیک حداقل مربعات باشد، فرایند یادگیری منجر به برازش خطای متوالی می‌شود. به طور کلی، انتخاب تابع زیان بر عهده‌ی پژوهشگر است و این روش قابلیت تطبیق پذیری بالایی با نیازهای خاص هر کاربرد دارد، مانند اینکه می‌تواند با توجه به توابع زیان مختلف آموزش داده شود (Natekin & Knoll, 2013) این روش برای دستیابی استراتژیک به بهترین ترکیب درختان به صورت متوالی مدل‌های پایه را از نسخه‌ی وزنی شده داده‌های آموزشی تولید می‌کند. هدف از اضافه کردن هر مدل پایه جدید، تصحیح اشتباهات مدل‌های پایه قبلی است. بنابراین، این روش پتانسیل ارائه‌ی پیش‌بینی‌های دقیقی دارد (Zhang, & Haghani, 2015).

از جمله روش‌های دیگر مطرح یادگیری ماشین، الگوریتم XGB، از خانواده روش‌های مبتنی بر تقویت گرادیان یا Gradient Boosting است که توسط (Chen & Guestrin, 2016) از دانشگاه واشنگتن

در این تحقیق نیز دو مدل پیشنهادی براساس روش‌های یادگیری ماشین مبتنی بر تقویت گرادیان XGBoost و Gradient Boosting برای وظیفه رگرسیونی پیش‌بینی مقدار تقاضا در زنجیره تأمین در بازه زمانی مجموعه داده منتخب بکارگیری شده است. ورودی مدل‌ها ویژگی‌های مرتبط با هر سفارش شامل تاریخ سفارش، قیمت، تخفیف و غیره است که در مجموعه داده منتخب تحقیق موجود است و خروجی حاصل مقدار تقاضای پیش‌بینی شده هریک از Sub Categoryها در محور زمان است. عملکرد مدل در پیش‌بینی تقاضا با معیارهای آماری زیر ارزیابی می‌شود:

الف- معیار ارزیابی میانگین خطای مطلق یا MSE (Mean Squared Error) از معیارهای خطا که از رابطه (۱) محاسبه می‌شود و هرچه مقدار آن به صفر نزدیکتر باشد مطلوب‌تر است.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad \text{رابطه (۱)}$$

ب- معیار ارزیابی میانگین خطای مطلق یا MAE (Mean Absolute Error) از معیارهای خطا که از رابطه (۲) محاسبه می‌شود و هرچه مقدار آن به صفر نزدیکتر باشد مطلوب‌تر است.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad \text{رابطه (۲)}$$

ج- معیار D2 Score نسبت تبیین شده واریانس را محاسبه می‌کند. این امتیاز تعمیمی از  $R^2$  است که در آن در آن مجذور خطا تعمیم داده شده و با یک تبیین دلخواه  $\text{dev}(y, \hat{y})$  مانند (تویدی، میانگین خطای مطلق و پین‌بال) جایگزین می‌شود. همانند  $R^2$  بهترین امتیاز برای این معیار رسیدن به ۱ است و در شرایطی که مدل بد عمل کند می‌تواند منفی گردد. این معیار در برخی از کتابخانه‌های مختص کارهای آمار و یادگیری ماشین زبان برنامه‌نویسی Python از جمله کتابخانه scikit-learn مورد استفاده قرار می‌گیرد و از رابطه (۳) محاسبه می‌شود (3.3. Metrics And Scoring:

فعالیت می‌کند و طیف گسترده‌ای از محصولات از جمله میلمان، لوازم الکترونیکی، لوازم اداری و غیره را به فروش می‌رساند. این داده‌ها ۵۱,۲۹۰ سفارش محصولات از سوی مشتریان از تاریخ ۱ ژانویه ۲۰۱۱ تا ۳۱ دسامبر ۲۰۱۴ در سراسر جهان است.

ارائه شده است. آنان اظهار داشته‌اند که تقویت درختی یک روش یادگیری ماشین بسیار مؤثر و پرکاربرد است و XGB یک سیستم تقویت درختی مقیاس‌پذیر و جامع است که توسط دانشمندان داده برای دستیابی به نتایج پیشرفته در بسیاری از چالش‌های یادگیری ماشین مورد استفاده قرار گرفته است. همچنین الگوریتم XGB با در نظر گرفتن داده‌های کم‌تراکم و استفاده از تکنیک Quantile sketch weighted یادگیری تقریبی درخت ارائه می‌دهد. مهم‌تر از همه اینکه محققان بینش‌هایی در مورد الگوهای دسترسی به حافظه نهان، فشرده‌سازی داده‌ها و پارتیشن‌بندی برای ساخت یک سیستم تقویت درختی مقیاس‌پذیر ارائه کرده‌اند که با ترکیب این بینش‌ها، XGB با استفاده از منابع بسیار کمتری نسبت به سیستم‌های موجود، به میلیاردها نمونه داده مقیاس پیدا می‌کند. بطور کلی مدل XGB از الگوریتم‌های رایج در مسائل پیش‌بینی است که برای ساختن یک رگرسیون قوی مجموعه‌ای از درختان تصمیم‌گیری (DT) را به کار می‌گیرد. این روش یادگیری ماشین در مقیاس بزرگ، برای اعمال خودکار موازی‌سازی چند رشته‌ای به منظور تسریع زمان اجرا مناسب است. جریمه‌های تنظیمی، یعنی عمق درخت و وزن گره‌های نهایی، بخشی از تابع هدف XGB هستند. بنابراین، فرآیند تکرار کاهش یافته و عملکرد ساخت درختان بهبود می‌یابد. در این روش برای کاهش پیچیدگی مدل، از تکنیک رشد درخت تصمیم‌گیری سطح به سطح استفاده می‌شود (Chen & Guestrin, 2016).

#### ۴- روش تحقیق

مجموعه داده این تحقیق تجربی، با عنوان Global Superstore Orders<sup>۱</sup> در سایت Kaggle منتشر شده که مربوط به شرکت Global Superstore یک شرکت خرده‌فروشی معروف است که در سراسر جهان

جدول ۱ - تعداد محصولات و سفارشات دسته‌بندی‌ها و زیردسته‌های مجموعه داده

Category	Sub Category	محصولات				سفارشات				متوسط سفارش هر محصول
		تعداد		درصد از کل		درصد از کل		درصد از کل		
Technology	Accessories	۲۶۳	۸۷۶	%/۹۴	%۲۳/۱۳	۳۰۷۵	۱۰،۱۴۱	%/۶۰۰	%۱۹/۷۷	۱۱/۶۹
	Machines	۱۷۹		%/۴۷۳		۱۴۸۶		%/۲۹۰		۸/۳۰
	Phones	۳۰۵		%/۸۰۵		۳۳۵۷		%/۶۱۵۵		۱۱/۰۱
	Copiers	۱۲۹		%/۳۴۱		۲۲۲۳		%/۴۳۳		۱۷/۲۳
Furniture	Bookcases	۱۶۶	۸۴۱	%/۴۳۸	%۲۲/۲۰	۲۴۱۱	۹،۸۷۶	%/۴۷۰	%۱۹/۲۶	۱۴/۵۲
	Chairs	۲۰۴		%/۵۳۹		۳۴۳۴		%/۶۷۰		۱۶/۸۳
	Furnishings	۳۰۱		%/۷۹۵		۳۱۷۰		%/۶۱۸		۱۰/۵۳
	Tables	۱۷۰		%/۴۴۹		۸۶۱		%/۱۶۸		۵/۰۶
Office Supplies	Appliances	۲۱۲	۲،۰۷۱	%/۵۶۰	%۵۴/۶۷	۱۷۵۵	۳۱،۲۷۳	%/۳/۴۲	%۶۰/۹۷	۸/۲۸
	Art	۲۷۲		%/۷۱۸		۴۸۸۳		%/۹۵۲		۱۷/۹۵
	Binders	۳۲۶		%/۸۱۶۱		۶۱۵۲		%/۱۱/۹۹		۱۸/۸۷
	Envelopes	۱۵۹		%/۴۲۰		۲۴۳۵		%/۴/۷۵		۱۵/۳۱
	Fasteners	۱۲۷		%/۳۳۵		۲۴۲۰		%/۴/۷۲		۱۹/۰۶
	Labels	۱۸۵		%/۴۸۸		۲۶۰۶		%/۵/۰۸		۱۴/۰۹
	Paper	۳۹۲		%/۱۰/۳۵		۳۵۳۸		%/۶/۹۰		۹/۰۳
	Storage	۲۴۷		%/۶/۵۲		۵۰۵۹		%/۹/۸۶		۲۰/۴۸
	Supplies	۱۵۱		%/۳/۹۹		۲۴۲۵		%/۴/۷۳		۱۶/۰۶
جمع		۳،۷۸۸		%/۱۰۰		۵۱،۲۹۰		%/۱۰۰		-

در این تحقیق، مدل XGBR که به‌طور خاص برای کارهای رگرسیون طراحی شده است، با فرآیندهای زیر مقداردهی اولیه می‌شود:

پارامتر "max\_depth" به مقدار ۸ تنظیم شده که حداکثر عمق هر درخت را در مجموعه کنترل نماید. این به کنترل پیچیدگی مدل و جلوگیری از بیش‌برازش کمک می‌کند. پارامتر "n\_estimators" روی مقدار ۱۰۰۰ تنظیم شده که تعداد درختانی که باید در مجموعه ساخته شوند را مشخص می‌نماید. درختان بیشتر می‌توانند عملکرد مدل را بهبود دهند اما زمان محاسبه را نیز افزایش می‌دهند. پارامتر "subsample" روی مقدار ۰،۸ تنظیم شده، که نشان می‌دهد هر درخت روی یک نمونه فرعی تصادفی از ۸۰٪ از داده‌های آموزشی آموزش داده شده است. این امر با ایجاد تصادفی بودن در فرآیند آموزش به کاهش بیش‌برازش کمک می‌کند.

دسته‌بندی و تعداد محصولات به شرح جدول (۱) است. با توجه به محدود بودن داده‌ها و به منظور درک و بررسی تأثیر افزایش داده‌ها بر نتایج مدل‌ها تصمیم گرفته شد تا مجموعه داده تحقیق حاضر با استفاده از تکنیک SMOTE<sup>۱</sup> از روش‌های افزایش داده افزایش یابد. نهایتاً نتایج پیاده‌سازی مدل‌ها در هر دو حالت داده‌های اولیه و داده‌های افزایش یافته بررسی شده است. مدل‌های یادگیری ماشین بکارگیری شده در این تحقیق، بر مبنای دو روش XGBoost Regressor و Gradient Boosting Regressor (XGBR) (GBR) با زبان برنامه نویسی Python و کتابخانه‌های مربوط پیاده‌سازی شده و نتایج اجرای آنها در پیش‌بینی مقدار تقاضا مورد بررسی قرار گرفته است. مدل‌های پیاده‌سازی شده با مشخصات زیر طراحی و تنظیم شده است:

<sup>۱</sup>- Synthetic Minority Oversampling Technique



پرداخته و منابع، نیازمندی‌ها و محدودیت‌های موجود در آنها را شناسایی کردیم.

مرحله دوم (شناخت داده‌ها): در این مرحله به توصیف و بررسی داده‌ها، اعتبارسنجی کیفیت داده‌ها و یکپارچه‌سازی و قالب‌بندی مناسب داده‌ها پرداختیم.

مرحله سوم (آماده‌سازی داده‌ها): در این مرحله به پیش‌پردازش و پاک‌سازی داده‌ها پرداخته، و سپس داده‌های مفقوده، پرت و نویزدار را حذف و اصلاح نمودیم. و در نهایت مرتبط‌ترین ویژگی‌ها را برای مدل پیشنهادی انتخاب کرده و با ایجاد بالقوه و مهندسی ویژگی‌های جدید سعی در بهبود عملکرد مدل پیشنهادی در مراحل بعدی خواهیم نمود.

مرحله چهارم (مدل‌سازی): در این مرحله با تقسیم داده‌ها برای آموزش، آزمایش و تست، به پیاده‌سازی مدل‌های دسته‌بندی (یادگیری ماشین با نظارت) پرداختیم.

مرحله پنجم (ارزیابی و اعتبارسنجی): پس از مدل‌سازی جهت ارزیابی نتایج معیارهای خطا، دقت، صحت، فراخوانی و  $F$  امتیاز را محاسبه نمودیم.

مرحله ششم (توسعه): در این مرحله دورنمایی از توسعه طرح را بیان و سرانجام گزارش و نتایج نهایی از پروژه را به صورت جداول و نمودارها ارائه کردیم.

#### ۵- یافته‌های تحقیق

پس از اجرای مدل‌های پیشنهادی و نتایج پیش‌بینی تفکیکی هر یک از Sub Category ها، به منظور ارزیابی نتایج از منظر خطا، دو معیار  $MSE$  و  $MAE$  مورد استفاده قرار گرفت. نتایج مربوط به اجرای مدل XGBR در جدول (۲) و نتایج مدل GBR در جدول (۳) آورده شده است. همچنین نتایج ارزیابی مدل‌ها با معیار  $D^2$  Score در جدول (۴) آمده است. نتایج مدل‌ها روی داده‌های اصلی و داده‌های افزایش‌یافته همراه با تغییرات حاصل‌شده آورده شده است.

پارامتر "Random\_state" روی مقدار ۴۲ تنظیم شده، که تکرارپذیری نتایج را تضمین می‌کند. مدل XGBR با این فرآیندها قصد دارد مجموعه‌ای از درختان تقویت‌کننده گرادیان را برای رگرسیون بسازد که با خصوصیات ذکر شده نتایج پایدار را تضمین کند. در این تحقیق، مدل GBR، که یک روش یادگیری گروهی برای وظایف رگرسیون است، با فرآیندهای زیر مقداردهی اولیه می‌شود:

پارامتر "max\_depth" روی مقدار ۸ تنظیم شده که حداکثر عمق هر درخت رگرسیون فردی را در گروه کنترل می‌نماید. این پارامتر پیچیدگی هر درخت را محدود و به جلوگیری از بیش‌برازش کمک می‌کند. مدل GBR مجموعه‌ای از درختان رگرسیون را به صورت متوالی می‌سازد. هر درخت بعدی برای تصحیح خطاهای انجام شده توسط درختان قبلی آموزش داده می‌شود. این مدل به تدریج پیش‌بینی‌های خود را با به حداقل رساندن یک تابع ضرر، معمولاً با استفاده از بهینه‌سازی گرادیان نزول، بهبود می‌بخشد.

با تنظیم پارامتر "max\_depth" به مقدار ۸، مدل به هر درخت رگرسیون در مجموعه اجازه می‌دهد حداکثر عمق ۸ سطح داشته باشد. این پیچیدگی مدل را کنترل و به تعادل بین بیش‌برازش و عدم‌برازش کمک می‌کند. مدل GBR با فرآیندهای مشخص شده قصد دارد مجموعه‌ای از درختان رگرسیون را برای وظایف رگرسیون بسازد. رویکرد گروهی و فرآیند آموزشی تکراری به مدل امکان می‌دهد تا روابط پیچیده را بیاموزد و پیش‌بینی‌های دقیقی برای داده‌های دیده نشده انجام دهد.

در این پژوهش جهت پیاده‌سازی مدل‌های پیشنهادی بر روی مجموعه داده منتخب از قوی‌ترین روش‌شناسی در زمینه اجرا و پیاده‌سازی پروژه‌های داده‌کاوی CRISP به شرح مراحل زیر استفاده شده است:

مرحله اول (شناخت کسب و کار): در این مرحله براساس اهداف پروژه، به بررسی وضعیت موجود در داده‌ها

### نتایج و یافته‌های اجرای مدل XGBR

مدل پیشنهادی XGBR با مشخصات ذکر شده توانسته است بر روی داده‌های اصلی مجموعه داده در معیار MSE به اعدادی بین ۱/۷۲ تا ۴/۱۶ دست یابد که فقط دو مورد از آنها بالای ۴ است. اما به کارگیری مدل بر روی داده‌های افزایش یافته موجب بهبود قابل توجهی گردیده است که MSE را به بازه ۰/۱۲ تا ۰/۵۷ کاهش داده است. با افزایش داده‌ها، به طور متوسط MSE در Sub Category ها به میزان ۲/۶ کاهش یافته است که بهبودی به میزان ۸۷ درصدی را موجب گردیده است. همچنین مدل XGBR بر روی داده‌های اصلی مجموعه داده به MAE بین ۰/۸۵ تا ۱/۴ در پیش‌بینی Sub Category ها دست یافته است و به کارگیری مدل بر روی داده‌های افزایش یافته موجب بهبود قابل توجهی گردیده است که MAE را به بازه ۰/۱ تا ۰/۲۵ کاهش داده است. با افزایش داده‌ها، به طور متوسط MAE در Sub Category ها به میزان ۰/۹۷ کاهش یافته است که بهبودی به میزان متوسط ۸۳٪ را موجب گردیده است. همچنین کمترین میزان معیار MAE در نتایج کسب شده از اجرای مدل برای پیش‌بینی تقاضای Sub Category ها در داده‌های اصلی در هر Chairs, Machines و Envelopes مربوط به داده‌های افزایش یافته Furnishings, Machines و Envelopes است. در معیار  $D^2$  Score که همانند معیار  $R^2$  مقادیر نزدیک‌تر به ۱ مطلوب‌تر است. در اجرای مدل XGBR بر روی داده‌های اصلی مجموعه داده،  $D^2$  Score به دست آمده بین ۰/۱۵ تا ۰/۵۱ است.

## جدول (۲) - نتایج ارزیابی خطای پیاده‌سازی مدل XGB Regressor

Category	Sub Category	نتایج داده‌های اصلی		نتایج داده‌های افزایش یافته		تغییرات با افزایش داده‌ها		درصد تغییرات با افزایش داده‌ها	
		MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE
Technology	Accessories	۱/۳۴۶۲	۳/۵۳۶۸	۰/۴۴۷۲	۲/۹۶۵۱	۱/۰۹۹	۲/۸۱۶۴	٪۸۳/۸۴	٪۸۱/۶۴
	Machines	۱/۰۲۷۴	۲/۵۱۷۱	۰/۱۶۶۷	۲/۱۶۰۷	۰/۸۶۰۷	٪۸۳/۷۷	٪۸۵/۸۴	٪۸۳/۷۷
	Phones	۱/۲۲۲۸	۳/۳۸۸۸	۰/۴۸۰۱	۲/۹۰۸۷	۰/۹۸۸۹	٪۸۰/۸۷	٪۸۵/۸۳	٪۸۰/۸۷
	Copiers	۱/۲۵۳۲	۲/۸۹۴۸	۰/۳۶۴۷	۲/۵۳۰۱	۱/۰۴۸۵	٪۸۳/۶۷	٪۸۷/۴۰	٪۸۳/۶۷
Furniture	Bookcases	۱/۳۳۵۴	۳/۷۳۶۷	۰/۵۷۱۳	۳/۱۶۵۴	۱/۱۰۲۸	٪۸۲/۵۸	٪۸۴/۷۱	٪۸۲/۵۸
	Chairs	۰/۸۵۱۴	۱/۸۲۵۳	۰/۲۵۴۴	۱/۵۷۰۹	۰/۶۷۳	٪۷۹/۰۵	٪۸۶/۰۶	٪۷۹/۰۵
	Furnishings	۰/۸۸۹۳	۲/۰۰۹۵	۰/۱۱۹۸	۱/۸۸۹۷	۰/۷۸۶۵	٪۸۸/۴۴	٪۹۴/۰۴	٪۸۸/۴۴
	Tables	۱/۴۰۱۸	۴/۰۸۳۷	۰/۵۳۸۵	۳/۵۴۵۲	۱/۱۷۵۷	٪۸۳/۸۷	٪۸۶/۸۱	٪۸۳/۸۷
Office Supplies	Appliances	۰/۹۸۹۹	۲/۲۸۱۷	۰/۳۳۳۰	۱/۹۴۸۷	۰/۷۹۸۷	٪۸۰/۶۸	٪۸۵/۴۱	٪۸۰/۶۸
	Art	۱/۳۱۶۷	۴/۱۶۴۵	۰/۴۸۷۱	۳/۶۷۷۴	۱/۱۰۶۸	٪۸۴/۰۶	٪۸۸/۳۰	٪۸۴/۰۶
	Binders	۱/۰۸۷۳	۲/۷۰۳۱	۰/۳۶۷۴	۲/۳۳۵۷	۰/۸۹۳۵	٪۸۲/۱۸	٪۸۶/۴۱	٪۸۲/۱۸
	Envelopes	۰/۸۵۹۲	۱/۷۱۵۰	۰/۱۲۵۱	۱/۵۸۹۹	۰/۷۵۸۵	٪۸۸/۲۸	٪۹۲/۷۱	٪۸۸/۲۸
	Fasteners	۱/۳۳۴۴	۳/۶۱۷۲	۰/۴۸۵۳	۳/۱۳۱۹	۱/۱۰۳	٪۸۶/۵۸	٪۸۲/۶۶	٪۸۶/۵۸
	Labels	۱/۳۳۴۴	۳/۶۱۷۲	۰/۴۸۵۳	۳/۱۳۱۹	۱/۱۰۳	٪۸۲/۶۶	٪۸۶/۵۸	٪۸۲/۶۶
	Paper	۱/۲۵۳۱	۳/۱۴۱۳	۰/۵۴۹۱	۲/۵۹۲۲	۱/۰۰۱۵	٪۷۹/۹۲	٪۸۲/۵۲	٪۷۹/۹۲
	Storage	۱/۲۶۴۴	۳/۷۷۳۶	۰/۴۵۵۶	۳/۳۱۸	۱/۰۵۴۸	٪۸۳/۴۲	٪۸۷/۹۳	٪۸۳/۴۲
	Supplies	۱/۰۵۵۶	۲/۳۱۶۸	۰/۲۵۶۱	۲/۰۶۰۷	۰/۸۸۵۸	٪۸۳/۹۱	٪۸۸/۹۵	٪۸۳/۹۱
	میانگین	۱/۱۷۰۴	۳/۰۰۳۵	۰/۳۹۶۴	۲/۶۰۷۱	۰/۹۷۳۰	٪۸۷/۱۰	٪۸۳/۲۰	٪۸۷/۱۰

تا ۰/۸۲ کاهش داده است. با افزایش داده‌ها، به‌طور متوسط MSE در Sub Category ها به میزان ۲/۲۹ کاهش یافته است که بهبودی به میزان ۸۳٪ را موجب گردیده است. همچنین مدل GBR بر روی داده‌های اصلی مجموعه داده به MAE بین ۰/۸۵ تا ۱/۳۷ در پیش‌بینی Sub Category ها دست یافته است و به‌کارگیری مدل بر روی داده‌های افزایش یافته موجب بهبود قابل توجهی گردیده است که MAE را به بازه ۰/۱۵ تا ۰/۵۳ کاهش داده است. با افزایش داده‌ها، به‌طور متوسط MAE در Sub Category ها به میزان ۰/۷۹ کاهش یافته است که موجب بهبود به میزان ۷۰ درصدی گردیده است. کمترین میزان معیار MSE در نتایج کسب‌شده از اجرای مدل برای پیش‌بینی تقاضای Sub Category ها در داده‌های اصلی در هر Category مربوط به Chairs، Machines و Envelopes و در داده‌های افزایش یافته Machines، Furnishings و Envelopes است. همچنین کمترین میزان معیار MAE در نتایج کسب شده از اجرای مدل برای پیش‌بینی تقاضای Sub Category ها در داده‌های اصلی در هر

اما به‌کارگیری مدل بر روی داده‌های افزایش یافته موجب بهبود قابل توجهی گردیده است و  $D^2$  Score را به بازه ۰/۹۲ تا ۰/۹۷ افزایش داده است. با افزایش داده‌ها، به‌طور متوسط  $D^2$  Score در Sub Category ها به میزان ۰/۶۳ افزایش یافته است که بهبودی به میزان متوسط ۲۴۲ درصدی را موجب گردیده است. این افزایش در  $D^2$  Score در کمترین میزان ۹۶ درصد و در بیشترین میزان ۵۲۳ درصد است. همچنین بیشترین میزان معیار  $D^2$  Score در نتایج کسب‌شده از اجرای مدل برای پیش‌بینی تقاضای Sub Category ها در داده‌های اصلی در هر Category مربوط به Machines، Furnishings و Envelopes و در داده‌های افزایش یافته نیز به همان ترتیب است

## نتایج و یافته‌های اجرای مدل GBR

مدل پیشنهادی GBR با مشخصات ذکر شده توانسته است بر روی داده‌های اصلی مجموعه داده در معیار MSE به اعدادی بین ۱/۶۴ تا ۳/۷۶ دست یابد. اما به‌کارگیری مدل بر روی داده‌های افزایش یافته موجب بهبود قابل توجهی گردیده است که MSE را به بازه ۰/۱۳

### مقایسه نتایج مدل های XGBR و GBR

مقایسه نتایج دو مدل XGBR و GBR نشان می دهد پیش بینی Sub Category ها در مدل GBR با متوسط MSE برابر ۲/۷۷ و MAE برابر ۱/۱۲ نسبت به مدل XGBR با متوسط MSE برابر ۳/۰۰ و MAE برابر ۱/۱۷ دارای خطای کمتری بوده است. اما با افزایش داده ها با تکنیک Data Augmentation، نتایج مدل XGBR با کاهش چشمگیر متوسط MSE و MAE به ۰/۳۹۶۴ و ۰/۱۹۷۴ از روش GBR با مقادیر ۰/۴۸۰۶ و ۰/۳۳۵۲ بهتر بوده است. با افزایش داده ها، میزان و درصد کاهش هر دو معیار در روش XGBR بیشتر از روش GBR است. همچنین مقایسه نتایج معیار  $D^2$  Score در دو مدل نشان می دهد پیش بینی Sub Category ها در مدل GBR با متوسط ۰/۳۴ به نسبت مدل XGBR با متوسط ۰/۳۱ اندکی بیشتر و بهتر بوده است. اما با افزایش داده ها اگرچه هر دو روش در این معیار افزایش چشمگیری داشته و بهبود یافته اند، اما نتایج روش XGBR با متوسط  $D^2$  Score به ۰/۹۴ از روش GBR با مقادیر ۰/۹۰ بهتر بوده است. با افزایش داده ها، میزان و درصد افزایش این معیار در روش XGBR بیشتر از روش GBR است.

Category مربوط به Chairs, Machines و Envelopes و در داده های افزایش یافته Machines, Furnishings و Envelopes است. ارزیابی نتایج مدل GBR با معیار  $D^2$  Score بر روی داده های اصلی مجموعه داده نشان دهنده کسب مقادیر بین ۰/۲۱ تا ۰/۵۲ است. به کارگیری مدل بر روی داده های افزایش یافته موجب بهبود قابل توجهی گردیده و  $D^2$  Score را به بازه ۰/۸۵ تا ۰/۹۶ افزایش داده است. با افزایش داده ها، به طور متوسط  $D^2$  Score در Sub Category ها به میزان ۰/۵۶ افزایش یافته است که موجب بهبود به میزان متوسط ۱۹۰ درصد گردیده است. این افزایش در  $D^2$  Score در کمترین میزان ۷۹ درصد و در بیشترین میزان ۳۴۹ درصد است. همچنین بیشترین میزان معیار  $D^2$  Score در نتایج کسب شده از اجرای مدل برای پیش بینی تقاضای Sub Category ها در داده های اصلی در هر Category مربوط به Chairs, Machines, Furnishings و Envelopes و داده های افزایش یافته Accessories, Envelopes و Furnishings است.

جدول (۳) - نتایج ارزیابی خطای پیاده سازی مدل Gradient Boosting Regressor

درصد تغییرات با افزایش داده ها	تغییرات با افزایش داده ها		نتایج داده های افزایش یافته		نتایج داده های اصلی		Sub Category	Category	
	MSE	MAE	MSE	MAE	MSE	MAE			
%۷۵/۴۷	%۸۴/۱۲	۰/۹۴۴۸	۲/۷۰۸۵	۰/۳۰۷۱	۰/۵۱۱۴	۱/۲۵۱۹	۳/۲۱۹۹	Accessories	Technology
%۷۰/۷۶	%۸۲/۹۱	۰/۷۳۳۵	۲/۰۲۸۶	۰/۳۰۳۱	۰/۴۱۸۱	۱/۰۳۶۶	۲/۴۴۶۷	Machines	
%۵۸/۰۷	%۷۵/۸۷	۰/۶۹۶۳	۲/۳۴۴۶	۰/۵۰۲۸	۰/۷۴۵۷	۱/۱۹۹۱	۳/۰۹۰۳	Phones	
%۷۰/۱۱	%۸۱/۹۰	۰/۸۰۰۹	۲/۰۱۳۹	۰/۳۴۱۴	۰/۴۴۵۱	۱/۱۴۲۳	۲/۴۵۹	Copiers	
%۶۴/۲۴	%۷۸/۳۶	۰/۸۰۸۸	۲/۶۰۷۱	۰/۴۵۰۳	۰/۷۱۹۹	۱/۲۵۹۱	۳/۳۲۷	Bookcases	Furniture
%۶۷/۹۹	%۸۴/۷۴	۰/۵۴۲۶	۱/۴۷۹۱	۰/۲۵۵۵	۰/۲۶۶۴	۰/۷۹۸۱	۱/۷۴۵۵	Chairs	
%۷۹/۶۲	%۹۲/۷۷	۰/۶۹۳۷	۱/۸۱۱۴	۰/۱۷۷۶	۰/۱۴۱۲	۰/۸۷۱۳	۱/۹۵۲۶	Furnishings	
%۷۱/۲۰	%۸۳/۴۶	۰/۹۵۲۳	۳/۰۴۳۸	۰/۳۸۵۲	۰/۶۰۳۳	۱/۳۳۷۵	۳/۶۴۷۱	Tables	Office Supplies
%۶۱/۸۸	%۷۸/۲۱	۰/۶۲۴۴	۱/۶۹۷۵	۰/۳۸۴۷	۰/۴۷۲۹	۱/۰۰۹۱	۲/۱۷۰۴	Appliances	
%۵۹/۱۵	%۷۸/۰۵	۰/۷۷۲۹	۲/۹۳۸۹	۰/۵۳۳۷	۰/۸۲۶۳	۱/۳۰۶۶	۳/۷۶۵۲	Art	
%۷۰/۴۲	%۸۱/۹۳	۰/۶۸۹۹	۱/۹۲۰۹	۰/۲۸۹۸	۰/۴۲۳۷	۰/۹۷۹۷	۲/۳۴۴۶	Binders	
%۸۱/۸۴	%۹۲/۰۸	۰/۶۹۸۳	۱/۵۱۷	۰/۱۵۴۹	۰/۱۳۰۵	۰/۸۵۳۲	۱/۶۴۷۵	Envelopes	
%۷۰/۰۴	%۸۵/۴۸	۰/۹۰۹۹	۲/۹۵۶۸	۰/۳۸۹۳	۰/۵۰۲۳	۱/۲۹۹۲	۳/۴۵۹۱	Fasteners	
%۷۲/۳۵	%۷۹/۲۸	۰/۸۷۴۶	۲/۴۴۱	۰/۳۳۴۲	۰/۶۳۷۸	۱/۲۰۸۸	۳/۰۷۸۸	Labels	
%۶۷/۰۸	%۸۱/۷۳	۰/۸۱۷۵	۲/۸۰۲۲	۰/۴۰۱۲	۰/۶۲۶۴	۱/۳۱۸۷	۳/۴۲۸۶	Paper	
%۷۳/۹۸	%۸۶/۷۳	۰/۷۳۸۳	۱/۷۷۹۷	۰/۲۵۹۷	۰/۲۷۲۴	۰/۹۹۸	۲/۰۵۲۱	Storage	

۰/۲۲۸۵	۲/۸۴۷۶	۱/۱۳۹۳	۰/۸۳/۲۹	۰/۴۲۶۷	۱/۳۶۷۸	۳/۲۷۴۳	Supplies	
۰/۳۳۵۲	۲/۲۹۰۵	۰/۷۹۰۵	۰/۸۳/۲۱	۰/۴۸۰۶	۱/۱۲۵۷	۲/۷۷۱۱		میانگین

### نتایج کلی پیش‌بینی تقاضا با اجرای مدل‌ها

پیش‌بینی مقدار تقاضای محصولات در زنجیره‌های تأمین با محصولات متنوع، پرتعداد و با کاربردهای مختلف از جمله فروشگاه‌های زنجیره‌ای و خرده‌فروشی‌ها همواره با چالش‌هایی در انتخاب چارچوب مناسب زنجیره تأمین برای تعیین سطوح و جزئیات پیش‌بینی و انتخاب روش و مدل مناسب مواجه است. از حیث چارچوب و ساختار تعیین‌کننده مسائل و جزئیات زنجیره تأمین برای سطح پیش‌بینی، در این تحقیق با هدف برنامه‌ریزی در سطح استراتژیک سطح Sub Category ها که محصولاتی با ویژگی‌های مشابه دارند انتخاب شده است.

از حیث چارچوب و ساختار تعیین‌کننده مسائل و جزئیات زنجیره تأمین برای سطح پیش‌بینی، در این تحقیق با هدف برنامه‌ریزی در سطح استراتژیک سطح استراتژیک Sub Category ها که محصولاتی با ویژگی‌های مشابه دارند انتخاب شده است؛ زیرا در زنجیره‌های تأمین با محصولات متنوع و متعدد، پیش‌بینی تقاضای کلی نمی‌تواند مفید به‌فایده باشد و برای انجام یک پیش‌بینی مفید و موثر ابتدا باید موضوع پیش‌بینی بصورت دقیق مورد بررسی قرار گرفته و چارچوب مناسبی برای حصول اهداف تعیین‌گردد که ضمن مفید بودن قابلیت اجرایی داشته باشد. از سوی دیگر برخی محققان از جمله (Sweeney et al., 2022) در تحقیق خود بیان داشته‌اند که برخلاف نتایج به دست آمده در محیط‌های تولیدی یا توزیعی، تنوع محصول اثر منفی نوسانات تقاضا بر موجودی را تعدیل می‌کند و خرده‌فروشان می‌توانند از طریق افزایش تنوع محصول برای محصولاتی با نوسانات تقاضای زیاد، به بهبود عملکرد موجودی خود کمک کنند و این امر به احتمال زیاد به دلیل رفتارهای جایگزینی محصول رخ می‌دهد و این استدلال انتخاب سطح پیش‌بینی این تحقیق را منطقی می‌نماید. لذا طبعاً پیش‌بینی باید به صورت تفکیک‌شده

براساس محصول، دسته‌ها یا زیرمجموعه‌ها صورت گیرد تا بتواند در تصمیم‌گیری‌ها و استراتژی‌ها مورد استفاده قرار گیرد. این انتخاب منجر شد برای پیش‌بینی تقاضا با در نظر گرفتن مطالعات پیشین به تجمیع محصولی در یک زنجیره تأمین دارای سلسله‌مراتب در سطح منتخب اقدام گردد.

بررسی ویژگی‌ها و کاربردهای محصولات نشان دهنده تناسب این انتخاب است. این چارچوب شامل سطح و جزئیات، با مقاصد تحقیق مطابقت دارد و با توجه به مقرون به صرفه بودن پیش‌بینی تک‌تک محصولات و مسائل و محدودیت‌های داده‌ای، اجرای آن مفید و میسر است.

از حیث داده‌های تحقیق، وجود تنوع، تعداد بالا و کاربردهای مختلف محصولات، در دامنه زمانی بعضاً طولانی موجب تفاوت در میزان و تعداد سفارشات و پراکندگی داده‌های سفارش می‌گردد و این امر محدودیت‌هایی را در داده‌های تقاضا و کار با آنها ایجاد می‌کند. در نتیجه استفاده موفق از بسیاری از روش‌های پیش‌بینی در شرایط واقعی بدون گزینش داده‌ها را ناممکن می‌سازد. به علاوه باید در نظر گرفت که در شرایط کار بر روی داده‌های واقعی با حجم متفاوت و بعضاً محدود انتخاب روشی که بتواند با این تنوع متفاوت و بعضاً محدود انتخاب روشی که بتواند با این تنوع محصولی به‌طور همزمان انعطاف لازم را برای پیش‌بینی دقیق و یکنواخت انواع محصولات، دسته‌بندی‌ها و زیرمجموعه‌ها داشته باشد، نیز امری مشکل است.

در این پژوهش، پیش‌بینی مقادیر تقاضای محصولات زنجیره تأمین با محصولاتی متنوع و پرتعداد، اما داده‌های تقاضای محدود، در مجموعه داده "Global Superstore Orders 2016" مربوط به یک شرکت خرده‌فروشی با محدوده فعالیت جهانی صورت گرفته است. داده‌های مورد آزمایش، شامل ۵۱،۲۹۰ سفارش ثبت شده

نیازهای و محدودیت‌های داده‌ای تحقیق باشد. در همین راستا و با اطلاعاتی که از تجزیه و تحلیل داده‌های اکتشافی مجموعه داده ارائه شد، مشخص می‌شود که امکان پیاده‌سازی یا دستیابی به نتیجه مناسب در برخی روش‌ها میسر نیست و محدودیت‌هایی در انتخاب روش‌ها وجود داشته است. لذا پس از بررسی و آزمایش مجموعه‌ای از الگوریتم‌های یادگیری ماشین، یادگیری عمیق و روش‌های آماری و سری‌زمانی نهایتاً با توجه به نیازها، امکان پیاده‌سازی و خصوصیات دو روش XGBoost Regressor و Gradient Boosting Regressor انتخاب شدند. این مدل‌ها برای وظایف رگرسیونی با معماری و تنظیمات ذکر شده و انجام مجموعه‌ای از مراحل آنالیز داده و مهندسی ویژگی‌ها برای پیش‌بینی تقاضا بکارگیری شده است. به منظور بررسی اثر افزایش داده بر عملکرد مدل‌ها، از تکنیک افزایش داده استفاده و نتایج مدل‌ها با داده‌های اصلی و افزایش یافته با یکدیگر مقایسه شده است.

نتایج به دست آمده پیاده‌سازی مدل‌های پیشنهادی نشان می‌دهد به رغم تنوع Sub Category محصول و تفاوت در کاربردها و ویژگی‌های آنها که موجب محدودیت داده‌ها گردیده است نتایج قابل قبولی به دست آمده است. این موضوع با خصوصیات ذکر شده که XGB توسط پدید آورندگان (Chen & Guestrin, 2016) مبنی بر تناسب مدل با داده‌های با تراکم کم همخوانی دارد. علاوه بر این مدل XGBR با افزایش داده‌ها نیز بهبود قابل توجهی داشته و خواص مقیاس پذیری بیان شده توسط (Chen & Guestrin, 2016) را اثبات می‌کند. موفقیت روش XGB در کار با داده‌های محدود به نحوی است که در مطالعه (Sugiharti et al., 2021) نیز محققان با اشاره به چالش‌های روش‌های یادگیری عمیق در کار با داده‌های کم، روش یادگیری انتقالی ترکیبی مبتنی XGB و CNN را برای افزایش دقت پیشنهاد داده‌اند.

۳۷۸۸ محصول مختلف بدون هرگونه داده‌های تبلیغات و نظر مشتریان در بازه زمانی حدود چهار ساله ۲۰۱۱ تا ۲۰۱۴ است که شامل ۱۴۶۱ روز یا ۴۸ ماه می‌باشد. این محصولات با کاربردهای مختلف در سه دسته اصلی (Category) شامل لوازم الکترونیکی، لوازم اداری و مبلمان و ۱۷ Sub Category تقسیم‌بندی شده که دارای تنوع بالایی است. با وجود این تعداد سفارش محدود در بازه زمانی مجموعه داده، تعداد متوسط سفارش برای هر محصول فقط ۵ تا ۲۰ سفارش است که بسیار اندک است. همچنین تعداد سفارش Sub Category‌ها بین ۱۲۷ تا ۳۹۲ با متوسط ۱۷۷ سفارش است. به عبارتی به طور متوسط هر Sub Category در هر سال فقط ۴۴ سفارش داشته و در هر ماه ۳/۶ سفارش و در هر هفته به طور متوسط حتی یک سفارش نیز نداشته است. باید در نظر گرفت که این متوسط سفارش است و قطعاً در برخی از موارد از این مقدار نیز کمتر بوده است. این محدودیت داده و ویژگی‌های محدود موجب گردیده است عملاً امکان پیاده‌سازی موفق بسیاری از روش‌ها و الگوریتم‌های پیش‌بینی میسر نگردد. باید اشاره شود که تا زمان نگارش این تحقیق، مطالعه دیگری با مجموعه داده حاضر برای پیش‌بینی تقاضا مشاهده نگردیده است. اگرچه برخی محققان در سایر تحقیقات با افزودن بر پیچیدگی مدل‌ها و الگوریتم‌ها و ترکیب روش‌های مختلف برای کسب نتیجه مناسب اقدام نموده‌اند، اما به‌طور معمول پیاده‌سازی آنها نیاز به تجهیزاتی دارد که موجب تحمیل هزینه و زمان مضاعف به کسب‌وکارها می‌شود و بعضاً موجب تاخیر و خلل در کارها و کاهش انعطاف‌پذیری و چابکی تصمیم‌گیری‌ها می‌گردد. بعلاوه که بطور معمول آن‌ها در تحقیقات خود نسبت به گزینش داده‌ها و انتخاب محصولات یا دوره زمانی خاص اقدام نموده‌اند. لذا در این تحقیق مجموعه‌ای از چالش‌ها و مسائل ناشی از کار با داده‌های واقعی، بدون گزینش وجود داشته است.

علاوه بر چارچوب و سطح پیش‌بینی که در خصوص آن توضیح داده شد روش پیش‌بینی نیز باید متناسب با

بررسی چالش‌هایی که توسط سایت رقابت یادگیری ماشین Kaggle برگزار می‌شود نشان می‌دهد در میان ۲۹ راه‌حل برنده چالش‌های برگزار شده که در وبلاگ Kaggle در طول سال ۲۰۱۵ منتشر شده، در ۱۷ راه‌حل از XGB استفاده شده است. در میان این راه‌حل‌ها، هشت راه‌حل صرفاً از XGB برای آموزش مدل استفاده کردند، در حالی که اکثر راه‌حل‌های دیگر XGB را با شبکه‌های عصبی در آنسامبل‌ها ترکیب کردند. همچنین مقایسه نشان می‌دهد، در دومین روش محبوب، شبکه‌های عصبی عمیق، در ۱۱ راه‌حل استفاده شده است. موفقیت این روش در KDD Cup 2015 نیز مشهود بود، جایی که XGB توسط هر تیم برنده در ۱۰ تیم برتر مورد استفاده قرار گرفت. علاوه بر این، تیم‌های برنده گزارش دادند که روش‌های آنسامبل تنها با مقداری کم از XGB با پیکربندی مناسب عملکرد بهتری دارند. آنان که مسائلی این راه‌حل‌ها در آنها برنده شده اند شامل: پیش‌بینی فروش فروشگاه؛ طبقه‌بندی متن وب؛ پیش‌بینی رفتار مشتری؛ تشخیص حرکت؛ پیش‌بینی نرخ کلیک تبلیغات؛ طبقه‌بندی بدافزار؛ دسته‌بندی محصول؛ پیش‌بینی ریسک خطر؛ پیش‌بینی نرخ ترک تحصیل دوره‌های آنلاین می‌باشد. آنان معتقدند علی‌رغم اینکه تحلیل داده مبتنی بر حوزه و مهندسی ویژگی نقش مهمی در این راه‌حل‌ها دارند، اما این واقعیت که XGB انتخاب اجماعی یادگیرنده است، تأثیر و اهمیت سیستم و تقویت درخت را نشان می‌دهد. همچنین آنان اظهار داشته‌اند که مهم‌ترین عامل موفقیت XGB مقیاس‌پذیری آن در همه سناریوها است و این سیستم بیش از ده برابر سریع‌تر از راه‌حل‌های محبوب موجود بر روی یک ماشین اجرا می‌شود و در تنظیمات توزیع‌شده یا با حافظه محدود به میلیاردها نمونه مقیاس می‌یابد و مقیاس‌پذیری XGB به دلیل چندین بهینه‌سازی مهم سیستم و الگوریتمی است.

همچنین به رغم تفاوت در تعداد، مقدار، زمان و تراکم سفارشات Sub Category های مختلف سه اصلی Category Technology, Furniture و Supplies مدل‌های پیشنهادی نتایج قابل قبولی داشته‌اند و با مزیت انعطاف‌پذیری مناسب توانسته‌اند یک پیش‌بینی با خطای نسبتاً یکنواختی را برای همه Sub Category ها ارائه دهند. لذا می‌توان نتیجه گرفت به رغم محدودیت‌های داده ذکر شده مدل‌های مذکور در مقایسه با سایر مطالعات و مدل‌های پیشنهادی محققان دیگر که به صورت ترکیبی یا همراه با پیچیدگی‌های خاصی ارائه گردیده، عملکرد قابل قبولی در پیش‌بینی Sub Category های محصولات فروشگاه زنجیره‌ای با تنوع بالا داشته‌اند.

با توجه به داده‌های تحقیق حاضر از جنس جدول، شامل سفارشات محصولات با سلسله مراتب دسته‌بندی‌های محصولی است، تحقیقات پیشین برای انتخاب روش‌های فوق برای پیش‌بینی تقاضای زنجیره تأمین با ساختار داده جدولی مورد بررسی قرار گرفت و این روش‌ها در مطالعات مشابهی نیز مورد استفاده قرار گرفته است. از جمله آنها می‌توان مطالعه (et al., 2018) (Yang) که بیان می‌دارد شبکه‌های عصبی عمیق در پردازش داده‌های حسی مانند تصاویر و صدا کارآمدی خود را ثابت کرده‌اند. با این حال، برای داده‌های جدولی، مدل‌های مبتنی بر درخت محبوب‌تر هستند. یکی از ویژگی‌های خوب مدل‌های مبتنی بر درخت، قابل تفسیر بودن طبیعی آن‌ها است. همچنین (Malioutov et al., 2017) معتقدند این مدل‌ها به طور مکرر فضای بردار ورودی را تقسیم‌بندی کرده و امتیازاتی را به گره‌هایی اختصاص می‌دهند. مدل‌های مبتنی بر درخت نه تنها عملکرد را در داده‌های جدولی تقویت می‌کنند بلکه قابلیت تفسیر سیستم را نیز افزایش می‌دهند که کاربرد آن را در سناریوهای تجاری بهبود می‌بخشد و نیز در مطالعه (Chen & Guestrin, 2016) براساس اطلاعات kdd cup competition اشاره شده که

جدول (۴) - نتایج معیار  $D^2$  Score مدل‌های XGBR و GBR

Category	Sub Category	نتایج داده‌های اصلی		نتایج داده‌های افزایش یافته		تغییرات با افزایش داده‌ها		درصد تغییرات با افزایش داده‌ها
		GBR	XGBR	GBR	XGBR	GBR	XGBR	
Technology	Accessories	۰/۲۰۹۳	۰/۱۴۷۹	۰/۹۳۲۶	۰/۹۱۶۲	۰/۷۸۲۹	۰/۷۰۷۰	%۵۲۳
	Machines	۰/۴۱۰۰	۰/۴۱۵۳	۰/۹۵۰۸	۰/۹۱۰۵	۰/۵۳۵۵	۰/۵۰۰۵	%۱۲۹
	Phones	۰/۲۸۳۸	۰/۲۶۹۷	۰/۹۳۳۱	۰/۸۵۶۲	۰/۶۶۳۴	۰/۵۷۲۴	%۲۴۶
	Copiers	۰/۳۳۳۶	۰/۲۶۹۰	۰/۹۴۱۴	۰/۹۰۲۳	۰/۶۷۲۵	۰/۵۶۸۷	%۲۵۰
Furniture	Bookcases	۰/۲۵۴۱	۰/۲۰۸۹	۰/۹۳۰۸	۰/۸۶۶۰	۰/۷۲۱۹	۰/۶۱۱۹	%۳۴۶
	Chairs	۰/۵۱۶۱	۰/۴۸۳۸	۰/۹۴۷۲	۰/۹۲۴۳	۰/۴۶۳۴	۰/۴۰۸۲	%۹۶
	Furnishings	۰/۵۲۴۶	۰/۵۱۴۸	۰/۹۶۹۶	۰/۹۴۷۴	۰/۴۵۴۸	۰/۴۲۲۸	%۸۸
Office Supplies	Tables	۰/۲۳۶۴	۰/۱۹۹۷	۰/۹۳۵۳	۰/۸۸۹۹	۰/۷۳۵۶	۰/۶۵۳۴	%۳۶۸
	Appliances	۰/۴۱۹۱	۰/۴۳۰۱	۰/۹۴۶۰	۰/۸۹۱۳	۰/۵۱۵۸	۰/۴۷۲۲	%۱۲۰
	Art	۰/۲۷۰۱	۰/۲۶۴۴	۰/۹۴۱۴	۰/۸۵۰۹	۰/۶۷۷۰	۰/۵۸۰۸	%۲۵۶
	Binders	۰/۴۰۰۹	۰/۳۳۵۱	۰/۹۴۰۰	۰/۹۱۰۲	۰/۶۰۴۹	۰/۵۰۹۴	%۱۸۱
	Envelopes	۰/۴۹۸۸	۰/۴۹۵۳	۰/۹۷۰۸	۰/۹۵۵۱	۰/۴۷۵۵	۰/۴۵۶۲	%۹۶
	Fasteners	۰/۲۴۸۵	۰/۲۲۸۱	۰/۹۳۰۷	۰/۸۸۳۴	۰/۷۰۲۵	۰/۶۳۴۹	%۳۰۸
	Labels	۰/۲۵۶۷	۰/۲۲۹۵	۰/۹۰۰۴	۰/۹۰۰۴	۰/۶۹۵۵	۰/۶۴۳۷	%۳۰۳
	Paper	۰/۲۹۹۳	۰/۲۷۳۰	۰/۹۴۰۲	۰/۸۸۵۵	۰/۶۶۷۲	۰/۵۸۶۲	%۲۴۴
	Storage	۰/۴۰۷۸	۰/۳۷۳۷	۰/۹۲۹۱	۰/۹۲۹۱	۰/۵۸۰۰	۰/۵۲۱۳	%۱۵۵
	Supplies	۰/۲۰۷۹	۰/۱۸۳۹	۰/۹۴۰۶	۰/۹۳۳۹	۰/۷۵۶۷	۰/۷۲۶۰	%۴۱۱
میانگین		۰/۳۳۹۸	۰/۳۱۳۲	۰/۹۴۲۹	۰/۹۰۳۱	۰/۶۲۹۷	۰/۵۶۳۳	%۲۴۲

## ۶- نتیجه‌گیری و پیشنهاد

تحقیق حاضر از جنبه‌های مختلف با تحقیقات مورد اشاره در ادبیات تحقیق قابل مقایسه است.

پژوهش (Islam et al., 2024) مربوط به سه نوع گوشت قرمز زنجیره تأمین گوشت تعدادی از کارخانه‌های کانادا با حجم عظیمی از داده برای تعداد محصولات محدود است که از حیث تنوع، مقدار سفارش و حجم داده محصولات با داده‌های تحقیق حاضر تفاوت قابل توجهی وجود دارد و در تحقیق آنان چالش پیش‌بینی در شرایط تنوع محصولات و داده‌های محدود وجود ندارد. چارچوب آنان شامل سه مرحله برای حل مشکلات، بهینه‌سازی فرآیند و انتخاب تأمین‌کننده و برنامه‌ریزی تخصیص سفارش است که فقط گام اول آن پیش‌بینی تقاضای محصول نهایی است. آنان مدل‌های-ensemble LSTM اصلاح‌شده، LSTM، ARIMA و LGBM را با یکدیگر مقایسه کرده‌اند. با توجه به حجم انبوه داده‌ها اجرای مدل یادگیری عمیق ترکیبی LSTM اصلاح شده موفق بوده اعلام شده که روش پیشنهادی آنان توانسته نسبت به روش LGBM خطای پیش‌بینی را کاهش دهد.

اما در مطالعه حاضر با حجم داده‌ها محدود اجرای چندین مدل بر پایه LSTM و سایر روش‌های مشابه یادگیری عمیق نتایج مطلوبی نداشته و نتیجتاً از روش‌های XGBR و GBR استفاده شده است.

پژوهش (Lee et al., 2023) که بر روی مجموعه داده‌های سه‌ساله ۲۰۰۹ تا ۲۰۱۱ تراکنش‌فروش محصولات در زنجیره‌های سوپرمارکت‌های ایالات متحده انجام شده، اما محققان با محدود کردن داده‌ها، از بین چهار دسته‌بندی محصول به دلایلی شامل خریدهای مکرر، تعداد مناسب زیرمجموعه‌ها، دامنه وسیعی از تخفیفات، مصرفی بودن کالاها و تاثیر کمتر زمان از سری‌های زمانی، صرفاً دسته‌بندی غلات سرد را برای آزمایش انتخاب کرده‌اند. حتی در این دسته نیز برخی برندها و محصولات را حذف و زمان نیز محدود به ۱۰۴ هفته شده است و تنها یک فروشگاه با حجم نسبتاً زیاد تراکنش فروش را به عنوان نمونه انتخاب کرده‌اند. با توجه به این‌گزینه‌ها عملاً بسیاری از چالش‌های تنوع محصولات و تفاوت دفعات سفارش را نادیده گرفته شده و به ۱۲ محصول خاص پرتراکنش محدود شده‌اند. لذا آنان چالش



(Chien et al., 2023) با هدف طبقه‌بندی الگوهای تقاضا در یک سازنده قطعات خودرو، مدل‌های پیشنهادی خود را بر روی چهار الگوی تقاضا شامل ۸۴۹ محصول آزمایش کرده‌اند. شرکت خدماتی با محصولات متنوع در سراسر جهان ارائه می‌دهد. داده‌های شرکت به دلیل محرمانگی تغییر شکل داده شده و منتشر نشده است. بنابراین با تحقیق حاضر از حیث مسائل کار با داده واقعی و محدود تمایز دارد. آنان با در نظر داشتن چالش‌های تعمیر و نگهداری صنعت قطعات یدکی، هدف مطالعه خود را طبقه‌بندی الگوهای تقاضا و توسعه مدل‌های مربوطه از طریق رویکرد انباشت مجموعه‌ای (Stacking ensemble) برای بهبود عملکرد کلی پیش‌بینی قرار داده‌اند. همچنین برای توانمندسازی یکپارچه زنجیره ارزش مبتنی بر داده و با هدف توسعه چارچوبی پیش‌بینی تقاضا برای ارتقاء تاب‌آوری زنجیره تأمین، چارچوب شش مرحله‌ای UNISON را براساس یادگیری ترکیبی پیشنهاد کرده‌اند و رویکردی متفاوت با تحقیق حاضر داشته‌اند. مدل پیشنهادی آنان بصورت ترکیب XGB با روش‌های دیگر با طراحی خاص و پیچیده است که ارزیابی نتایج آن نشان دهنده خطای کمتر مدل ترکیبی از سایر روش‌های انفرادی بکارگیری شده است. اما در تحقیق حاضر مدل‌های XGBR و GBR بدون ترکیب با یکدیگر یا سایر روش‌ها بکارگیری و با معیارهای منتخب ارزیابی شده است که نتایجی با خطای کم و یکنواخت، همبستگی بالا و انعطاف‌پذیری عملکرد قابل قبول دارد.

پژوهش (Joseph et al., 2022) پیش‌بینی تقاضای محصولات اپراتورهای خرده‌فروشی روی مجموعه داده‌های چالش پیش‌بینی تقاضای یک فروشگاه از سایت Kaggle است. این مجموعه داده شامل داده‌های فروش ۵۰ قلم کالا برای پنج سال (۲۰۱۳ تا ۲۰۱۷) در ۱۰ فروشگاه است. هدف از این چالش، پیش‌بینی فروش برای سه ماه بعدی بود. این مجموعه داده فقط شامل چهار ویژگی و ۹۱۳،۰۰۰ ردیف داده فروش است. در این

مشابه تحقیق حاضر نداشته‌اند. اقدامات گزینشی آنان در چارچوب سلسله مراتب یا انواع تجمیع نیست و در تحقیق خود به دنبال بررسی رابطه قیمت با تقاضا بوده‌اند. آنان به دنبال طراحی روشی برای انتخاب بهترین روش پیش‌بینی تقاضا محصول از بین سری‌های زمانی و روش‌های مختلف یادگیری ماشین هستند. آنان مجموعه‌ای از روش‌های مختلف را برای پیش‌بینی تقاضای محصول بکارگیری کرده‌اند. ارزیابی نتایج تحقیق آنان با معیار RMSPE نشان می‌دهد که مدل‌های Gradient، Extra Trees، Boosting و XGB با فاصله اندک به ترتیب بهترین نتایج را کسب نموده‌اند. با توجه به تشابه دو مطالعه با یکدیگر نتایج موفق روش‌های تحقیق حاضر در تحقیق آنان گواه انتخاب صحیح روش در تحقیق حاضر است.

تحقیق (Andrade & Cunha, 2023) بر روی مجموعه داده واقعی یک خرده‌فروشی بزرگ مواد غذایی در اکوادور شامل ۵۴ فروشگاه بزرگ و ۴۰۳۶ آیتم از سال ۲۰۱۳ تا ۲۰۱۷ است. این مجموعه داده اطلاعات جامعی از تبلیغات و بازاریابی محصولات نیز دارد. اما با گزینش، محصولات با کمترین حجم فروش حذف و با قانون پارتو نهایتاً ۱۶۲۳ محصول انتخاب شده و محصولات خاص با مدت کوتاه فروش و محصولاتی با میزان فروش بسیار پایین حذف شده‌اند. اما در تحقیق حاضر، بدون حذف محصول و داده‌های بازاریابی، چارچوب پیش‌بینی از طریق Sub Categoryها ارائه شده، که آن را متمایز می‌سازد. همچنین آنان با توجه به دامنه و هدف تحقیق خود سطوح تجمیع را در ابعاد محصول، زنجیره تأمین و زمان، به ترتیب سطح SKU، فروشگاه و هفتگی اعلام و در پیش‌بینی از داده‌های تبلیغات بازاریابی نیز استفاده کرده‌اند. لذا با توجه به سطوح تجمیع، انتخاب کل زنجیره و بازه زمانی برای اهداف استراتژیک در تحقیق حاضر، این دو تحقیق با یکدیگر متفاوت‌اند. تحقیق آنان با داده‌های قابل توجه و امتیازاتی در اطلاعات از روش XGB استفاده کرده و از این حیث روش با تحقیق حاضر مشابه است.

- learning for satisficing operational decision making: A case study in blood supply chain. *International Journal of Forecasting*.
- Andrade, L. A. C., & Cunha, C. B. (2023). Disaggregated retail forecasting: A gradient boosting approach. *Applied Soft Computing*, 141, 110283.
- Babai, M. Z., Boylan, J. E., & Rostami-Tabar, B. (2022). Demand forecasting in supply chains: a review of aggregation and hierarchical approaches. *International Journal of Production Research*, 60(1), 324-348.
- Berman, B., Evans, J. R., & Chatterjee, P. (2018). *Retail management-A strategic approach*. 13th eds.
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794).
- Chien, C. F., Ku, C. C., & Lu, Y. Y. (2023). Ensemble learning for demand forecast of After-Market spare parts to empower data-driven value chain and an empirical study. *Computers & Industrial Engineering*, 185, 109670.
- Fisher, M., & Raman, A. (2018). Using data and big data in retailing. *Production and Operations Management*, 27(9), 1665-1669.
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189-1232.
- Islam, S., Amin, S. H., & Wardley, L. J. (2024). A supplier selection & order allocation planning framework by integrating deep learning, principal component analysis, and optimization

پژوهش، تنها مجموعه داده آموزشی ارائه شده در رقابت کگل در نظر گرفته شده است. آنان برای پردازش کارآمد داده، ساختار مجموعه داده به گونه‌ای تغییر داده‌اند که دارای ویژگی‌هایی باشد که داده‌های فروش هر فروشگاه و کالا را در طول دوره‌ی ۵ ساله نشان دهد. آنان مجموعه‌ای از تغییرات را بر روی داده‌ها انجام داده‌اند و تحقیق آنان از نظر حجم داده در شرایط بهتری داشته و استفاده از مدل یادگیری عمیق CNN-BiLSTM توانسته نتایج بهتری از روش‌های سنتی کسب نماید.

از چالش‌های مطالعات پیش‌بینی تقاضا در زنجیره تامین، فقدان مجموعه داده مناسب و با حجم کافی است که به دلیل عدم همکاری بسیاری از شرکت‌ها و عدم ارائه مجموعه داده بسیاری از مقالات مشابه رخ داده است. با توجه به محدودیت‌های تحقیق حاضر پرداختن به مبحث تناسب و ساختار مجموعه داده و تحلیل آن و کشف الگوهای مناسب و الزامات و نیازهای روش‌های پیش‌بینی از موضوعات مهم است که می‌تواند برای تحقیقات آینده مناسب واقع گردد. همچنین ارائه مدل‌ها و چارچوب‌هایی برای چالش پیش‌بینی در شرایط محدودیت داده‌ها، تنوع دسته‌بندی‌ها و محصولات می‌تواند برای تحقیقات آتی مفید باشد.

#### سپاسگزاری

از معاونت محترم پژوهشی دانشگاه آزاد اسلامی تهران شمال به خاطر حمایت مالی و معنوی و همکاری در اجرای پژوهش حاضر سپاسگزاری می‌شود.

#### ۷- منابع

- Aamer, A., Eka Yani, L., & Alan Priyatna, I. (2020). Data analytics in the supply chain management: Review of machine learning applications in demand forecasting. *Operations and Supply Chain Management: An International Journal*, 14(1), 1-13.
- Abolghasemi, M., Abbasi, B., & HosseiniFard, Z. (2023). Machine

- Journal of machine Learning research*, 12, 2825-2830.
- Seyedan, M., & Mafakheri, F. Predictive big data analytics for supply chain demand forecasting: methods, applications, and research opportunities. *J Big Data* 7, 53 (2020).
- Song, Y., & Hu, X. (2023). Learning-based demand-supply-coupled charging station location problem for electric vehicle demand management. *Transportation Research Part D: Transport and Environment*, 125, 103975.
- Sugiharti, E., Arifudin, R., Wiyanti, D. T., & Susilo, A. B. (2021, June). Convolutional neural Network-XGBoost for accuracy enhancement of breast cancer detection. In *Journal of Physics: Conference Series* (Vol. 1918, No. 4, p. 042016). IOP Publishing.
- Sweeney, K., Riley, J., & Duan, Y. (2022). Product variety in retail: the moderating influence of demand variability. *International Journal of Physical Distribution & Logistics Management*, 52(4), 351-369.
- Syntetos, A. A., Babai, Z., Boylan, J. E., Kolassa, S., & Nikolopoulos, K. (2016). Supply chain forecasting: Theory, practice, their gap and the future. *European Journal of Operational Research*, 252(1), 1-26.
- Yang, Y., Morillo, I. G., & Hospedales, T. M. (2018). Deep neural decision trees. *arXiv preprint arXiv:1806.06988*.
- Zhang, Y., & Haghani, A. (2015). A gradient boosting method to improve travel time prediction. *Transportation Research Part C: Emerging Technologies*, 58, 308-324.
- techniques. *Expert Systems with Applications*, 235, 121121.
- 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 forecasting. *Computers and Electrical Engineering*, 103, 108358.
- Kone, E. R., & Karwan, M. H. (2011). Combining a new data classification technique and regression analysis to predict the Cost-To-Serve new customers. *Computers & Industrial Engineering*, 61(1), 184-197.
- Kwon, H. J., Park, S., Park, Y. H., Baik, S. M., & Park, D. J. (2024). Development of blood demand prediction model using artificial intelligence based on national public big data. *Digital Health*, 10, 20552076231224245.
- Lee, K. H., Abdollahian, M., Schreider, S., & Taheri, S. (2023). Supply chain demand forecasting and price optimisation models with substitution effect. *Mathematics*, 11(11), 2502.
- Levy, M., & Grewal, D. (2023). *Retail management*. McGraw-Hill.
- Malioutov, D. M., Varshney, K. R., Emad, A., & Dash, S. (2017). Learning interpretable classification rules with boolean compressed sensing. *Transparent Data Mining for Big and Small Data*, 95-121.
- Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in neurorobotics*, 7, 21.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *the*

3.3. *Metrics and scoring: quantifying the quality of predictions.* (n.d.). Scikit-learn

[https://scikitlearn.org/stable/modules/model\\_evaluation.html#d2-scor](https://scikitlearn.org/stable/modules/model_evaluation.html#d2-scor)

