

2段階の機械学習予測モデルに基づく季節性のある中古アパレル商品の需要予測に関する一考察

齊藤 美佑^{1,a)} 山下 遥^{2,b)} 佐々木 北都^{3,c)} 後藤 正幸^{1,d)}

受付日 2022年3月11日, 採録日 2022年8月8日

概要: EC サイトなどの普及にともない中古品の流通経路は多様化し, 市場は拡大傾向にある. 特に, 軽量で運搬が容易で“古いからこそ個性的で価値がある”中古アパレル商品がさかんに売買されている. 中古ファッション業界において, 季節性が強く特徴的な需要変動を示す季節性アイテムの在庫・出品管理は非常に重要である. シーズン序盤での過剰出品は, その後の欠品による企業の魅力度および顧客満足度の低下につながってしまう. 一方, 過少出品は, 販売時期逸機による不良在庫の発生につながってしまう. このトレードオフの問題を解決するため, 季節性アイテムは需要を正確に予測し戦略的に出品される必要がある. これに対し従来では, 出品管理者の経験やノウハウに基づき需要を予想し計画・管理されることが多かった. しかし, 従来の判断は属人的で客観性に欠け, 予想が大幅に実績と異なる場合, 問題を解決できていない懸念もある. そこで本研究では, より定量的な判断に基づく確かな出品計画を支援するための需要予測手法を提案する. シーズン前にワンシーズン全体の販売数予測を行う長期予測モデルと, 直近の新たな情報を用いた残差予測による調整を行う短期予測モデルを組み合わせた2段階の手法である. さらに, 提案を実データに適用・分析し, 十分な精度を保持し有用であることを示す. また, 出品数決定の指標とする実証実験を設計し, 実ビジネスで運用することで, 提案手法の有効性を実証的に検証する.

キーワード: 中古アパレル商品, EC サイト, 機械学習, 販売履歴, 需要予測

Machine Learning for Demand Prediction of Seasonal Second-hand Fashion Items Based on Prior and Fine-tuning Prediction Models

FUYU SAITO^{1,a)} HARUKA YAMASHITA^{2,b)} HOKUTO SASAKI^{3,c)} MASAYUKI GOTO^{1,d)}

Received: March 11, 2022, Accepted: August 8, 2022

Abstract: With the proliferation of E-commerce sites etc., distribution channels for second-hand fashion items are diversifying and its market is expanding. In the fashion industry, seasonal items that are in demand in particular seasons are very important. For them, excessive sales can lead to a decline in the attractiveness of the company and customer satisfaction due to subsequent shortages, but under-listing leads to the generation of bad inventory due to missed sales. To solve such trade-off problem, seasonal items need to be strategically listed by accurately predicting demand. Previously, planning and managing inventory, listing, and sales were often based on the experience and know-how of display managers. However, conventional judgments are impersonal and lack objectivity, and there are concerns that they do not solve the problem when the prediction differs from the actual. Therefore, this paper proposes a demand forecasting method that enables accurate planning of seasonal items based on more quantitative judgment. Furthermore, by applying the proposal to real data and analyzing it, we show the usefulness. In addition, we design and operate a demonstration experiment to use the method as an indicator for determining the number of new items to be listed and verify its effectiveness in real business.

Keywords: second-hand fashion item, EC site, machine learning, sales history data, sale prediction

¹ 早稲田大学
Waseda University, Shinjuku, Tokyo 169-8555, Japan
² 上智大学
Sophia University, Chiyoda, Tokyo 102-8554, Japan
³ 株式会社 ZOZO
ZOZO, Inc., Chiba 263-0023, Japan

a) fuyu-saitou@fuji.waseda.jp
b) h-yamashita-1g8@sophia.ac.jp
c) hokuto.sasaki@zozo.com
d) masagoto@waseda.jp

1. はじめに

近年の循環型社会移行への意識増大やコロナ感染症による在宅時間の増加にともない、家中の不要品をECサイトやフリマアプリなど多様な流通経路を介して再販売する人が増加し、リユース市場は拡大傾向にある。経済産業省の電子商取引に関する市場調査によると、リユース業界の市場規模（ECサイト、実店舗を含む）は2020年に2兆5,000億円、さらに2025年には3兆2,500億円に達すると予測されており、リユース利用人口は益々拡大していくと見られている [1]。特に、軽量で運搬がしやすく“古いからこそ個性的で価値がある”という近年の風潮も追い風となり、中古アパレル市場の活性化は顕著である [2]。実際に、日本の最も主要なフリマアプリの1つであるメルカリ [3] の決算情報によると、メルカリにおいて2021年4~6月期で最も売れているのはアパレル商品で、レディースとメンズ合わせて全体の約32%を占める [4]。一方、インターネットを介した売買により、購買・検索などの行動履歴情報など、中古品に関する膨大なデータの蓄積が可能となっている。これらを様々な機械学習手法と合わせて活用し、有効な施策に結び付ける試みも数多くなされており、顧客分析やアイテム推薦などで成果をあげつつある [5]。

一般に、一部のファッションアイテムは季節性を有しており、季節の移り変わりに影響され需要が大きく変動する。このような季節性アイテムが存在することから、一般に中古アパレル商品は、季節性に基づき分類されたアイテム群ごとにシーズン単位で計画的に在庫され出品される。ここで、季節性アイテムをシーズン序盤に過剰に出品してしまうと、在庫が完売してその後に販売可能なアイテムがなくなってしまう、ECサイトの魅力度と顧客の満足度が低下してしまう。一方、アイテムの出品を躊躇し過少になりすぎると、シーズン後半にアイテムを倉庫に保管したまま販売時期を逃してしまい、大量の売れ残り在庫を発生させてしまう。このようなトレードオフの問題を解決するため、季節性アイテムは需要に沿って戦略的に出品されることが必要である。その実現のために従来では、在庫となった季節性アイテムは、シーズンごとに出品管理者の属人的な予想に基づき、出品・販売されることが多かった。しかし、現状の属人的な予想は客観性に欠け、実績と大幅に異なってしまう場合もあり、上述のトレードオフの問題解決につながっていないという懸念もある。以上より、豊富に蓄積されたデータを活用することで、より定量的な判断に基づく確かな季節性アイテムの出品計画を可能とする需要予測モデルの構築を検討する必要がある。

ここで、実ビジネスにおいては、予測時に得られない情報があつたり過去に事例のない施策が行われたりする場合も多いため、外部要因を完全に網羅した予測は困難であるといえる。よって、そのような一部の要因が考慮されてい

ない予測結果をビジネス行動の自動化に結び付けることは非常にリスクが高いと考えられる。そこで、完全に予測モデルのみに頼る自動化を目指すのではなく、予測モデルと出品管理者の協働による意思決定の質向上を試みる。これにより、出品管理者は現場で予測結果を定量的な指標として使い、データ主導で意思決定を行うことができる。なお、この方針を採択することは、現場の出品管理者自身が予測モデルを利用することを意味する。よって、負担の少ないスムーズな導入のために、利用者の要求に十分に応えた従来方法に沿った設計が求められる。

従来の管理方法としては、季節性アイテムは、シーズン前とシーズン中の2段階で需要予想・出品計画されることが一般的であると考えられる。出品管理者により、まずシーズン開始前に長期的なシーズン全体の需要を大まかに予想しアイテムの調達と在庫計画を行う。次にシーズン中のオペレーションとして日々の気象条件などの外部要因や直近の販売状況を確認し短期的に需要変動を予想し、直近の出品計画を策定する。そこで本提案手法も、以上のようなオペレーションに沿う長期予測モデルと短期予測モデルからなる2段階の需要予測手法とすることを考える。

以上より本研究では、季節性アイテムの実ビジネスにおける定量的な出品計画の支援となる、長期予測モデルと短期予測モデルを組み合わせた2段階の需要予測手法を提案する。そして、提案モデルを実データに適用することで、提案モデルの信頼性と有用性の評価を行う。また、実ビジネスでの実証実験を設計・運用することで、本モデルが出品計画の支援に実際に有効であるかどうかを実証的に検証する。さらに、効果検証の観点から傾向スコア [6] を用いた評価についても結果を示す。

2. 準備

2.1 対象事例と対象データの特徴

本研究では、提案モデルの有効性を実証的に検証するため、ファッション通販サイト ZOZOTOWN 内で古着を販売する ZOZOUSUED における季節性アイテムの需要予測問題を対象事例とする。そのビジネスモデルは、顧客から中古アパレル商品の買取を行い、他の顧客に販売するというECサイトを介した活動である。

ZOZOUSUED では、季節性が弱く需要が通年でほぼ一定である「通年アイテム」と、「春夏アイテム」「秋冬アイテム」と呼ばれる季節性アイテム群を独自に設定している。季節性アイテムの各アイテム群に対する販売数の推移を図1に示す。なお、縦軸の販売数に関しては、非公開情報であるため具体的な数値は伏せて表示している。このように、季節性アイテムは季節性に依りて特徴的な需要変動を示す。したがって、季節性アイテムは買取後すぐに出品されず在庫となり、シーズン単位で出品される。

また、春夏/秋冬アイテムは、さらに詳細にアイテムの特




図 1 2019 年度における販売数の分布

Fig. 1 Distribution of sales figures in fiscal year 2019.

表 1 アイテムカテゴリまとめ

Table 1 Summary of item categories.

	販売数割合	ピーク時期	特徴
春夏-弱	0.06	4月中旬/8月下旬	各ピークに向かって緩やかなカーブを描く
春夏-中	0.63	6月初旬	シーズン通して緩やかなカーブを描く
春夏-強	0.30	6月中旬	やや遅れたピーク、急なカーブを描く
秋冬-弱	0.08	10月初旬	ピークに向かい緩やかなカーブを描く
秋冬-中	0.64	11月初旬	シーズン通して緩やかなカーブを描く
秋冬-強	0.29	12月初旬	やや遅れたピーク、急なカーブを描く

性を考慮して「弱/中/強」に細分化したアイテムカテゴリが設定されている。具体的には、春夏アイテムに関して、スプリングコートやニットカーディガンなどのより春らしいアイテムを「弱」、サンダルやノースリーブシャツなどのより夏らしいアイテムを「強」、それ以外のアイテムを「中」としている。同様に、秋冬アイテムに関して、ジャケットなどのより秋らしいアイテムを「弱」、ダウンコートなどのより冬らしいアイテムを「強」、それ以外のアイテムを「中」としている。これらは、その季節性の強さの違いにより、最も需要の高まるピーク時期やその前後の動向が異なる。各アイテムカテゴリの2019年の各シーズンにおける販売数とその割合、最も販売数が多いピーク時期、需要変動に関する特徴を表1にまとめる。

ここで、需要を的確にとらえ日々適切な量を出品することは、出品過剰に起因した欠品によるECサイトの魅力度および顧客満足度低下の問題と、出品過少に起因する販売時期逸機による売れ残りの問題防止のために非常に重要である。さらに、顧客が求めるアイテムを適切なタイミングと量で出品することで、顧客満足度向上、売上増加、および即時販売による在庫管理コスト削減が期待できる。そこで、ファッションビジネスにおいて重要な存在である季節

性アイテムの出品に対し、出品管理者が、上述のアイテムカテゴリごとで需要が高まるシーズンに以下の2段階からなる手順で需要の傾向に沿うように計画・管理している。

(1) シーズン開始前

過去の経験やノウハウに基づいた予想によりシーズン全体の動向を見据え、シーズン全体の長期的な在庫・出品計画を策定する。

(2) シーズン中

日々の販売状況の動向や外部要因の影響を確認しつつ、過去の経験やノウハウに基づき需要変動を予想し、短期的な出品計画を策定し実行する。

このように、従来の出品計画方法は、出品管理者の属人的な需要の予想に大きく依存するといえる。なお、中古品を取り扱う主なECサイトは、フリーマーケット形式やオークション形式などの顧客と顧客を直接結び付けるビジネスモデルが多く、顧客が商品を管理するので企業は在庫に関する問題を考慮する必要がない。一方、ZOZOUSUEDのビジネスモデルでは顧客から買取・企業での在庫管理のフェーズが存在するため、出品計画は非常にクリティカルな問題であり、この対策としての上述の2段階からなる出品方法は企業特有のものであるといえる。

また、全アイテムに対して売れ残りを防ぐために、出品後一定期間売れなかったアイテムについて出品価格から段階的に値下げを行うシステムを採用している。なお、出品時の価格を出品価格、販売された時点での価格を販売価格と区別している。収益性の観点から、可能な限り値下げせずに販売することが望ましく、適切な出品価格の設定が求められている。また、在庫・管理コストの観点から、可能な限り早く販売することが望ましく、適切な価格保持期間の設定も求められている。

2.2 関連研究

最新技術の発展と顧客行動に関する膨大な量のデータの蓄積により、アパレル業界でも、それらを用いた先進的な研究は多岐にわたっている [7]。特に需要予測に関しては、商品ライフサイクルが短くトレンド性の高い商品を素早く生産・流通させる必要があることから、学術的にも産業的にもいまだ困難な課題とされ、効果的なアプローチを求め世界中で研究がさかんに行われている。Giriら [8] は、衣服の画像を特徴ベクトルに変換し過去の販売データと結合させ、逆伝播ニューラルネットワークモデルを適用することで新商品の需要予測を行った。このモデルは、データセットのサイズが小さいにもかかわらず、かなり良好に動作することが示されている。Xiaら [9] は、過去に観測された少量のデータのみを使用して将来のデータを予測する効果的な時系列予測である Grey Forecasting Model (以下、GFM) [10] を元に季節離散 GFM を提案した。これにより、需要予測における「ファッションアイテムにおける

季節性の考慮」と「限られたデータのみでの分析」という2つの重要な問題を同時に克服した。この他にも、価格最適化や推薦システム、画像生成に関する研究など、幅広い観点から研究が行われている。Kediaら[11]は、複数の需要予測モデル、需要の価格弾力性の概念、線形計画法による最適化手法を組み合わせた個々のアイテムに対する価格の最適化手法を提案した。Raviら[12]は、物体検出やポーズ推定などを駆使し、商品表示ページのモデルが着用している全ファッションアイテムに対応する類似アイテムを推薦する手法ShopLookを提案した。この研究により、1つのアイテムだけではなく全ファッションアイテムに対して推薦することで、クロスセルを促進し収益を上げるだけでなく、顧客体験や顧客エンゲージメントを向上させる利点が得られている。さらにJainら[13]は、Generative Adversarial Networks[14]を用いたファッションパターンに関するテキスト入力を加味したファッションアイテム画像生成手法を提案している。

中古ファッションECサイトを対象事例としたデータ活用としては、主に通年アイテムを対象として「出品価格設定」や「価格保持期間の設定」など、ミクロな視点から個々のアイテムに対する意思決定を支援する研究が行われている。仁ノ平ら[15]は、出品価格の決定を目的とし、アイテムをクラスタリングしたうえで、混合回帰による販売価格予測モデルを提案した。金澤ら[16]は、出品価格を変更した場合の販売価格の予測問題について、価格変更実験で得られたデータを活用した分析モデルを提案した。桑田ら[17]は、アイテムが出品価格のままで購入される範囲での最大価格を推定することで、最も収益性の高い初期出品価格を決定するモデルを提案した。さらに桑田ら[18]は、1点予測ではなく分布予測モデルを導入し、アイテムの売れ残り率を設計値に近づけるように価格保持期間を設定する機械学習モデルも提案している。

2.3 LightGBM

本研究の需要予測モデルでは、予測性能に優れたLight Gradient Boosting Machine (以下、LightGBM) アルゴリズム[19]を用いる。これは、複数の決定木をまとめる高速で効率的なアンサンブル学習であるGradient Boosting Decision Treeモデル[20]を改良した手法で、分類や回帰問題などに多く用いられている。木の分岐を層単位ではなく葉単位で行い、デルタ損失が最大となる葉を選択することで、より効果的に損失を削減でき高速に優れた予測精度を実現する[21]。さらに、Gradient-based One-sided SamplingとExclusive Feature Bundlingという技術により過学習の問題なしに多数のデータインスタンスと特徴量をそれぞれ処理することで計算コストを大幅に軽減できる。

以上のように、LightGBMは予測精度と計算効率に優れており、大規模なデータセットにも適用可能なモデルとい

える。この優れた性質ゆえに実ビジネスへ適用する事例も数多く存在することから、変数重要度[22]に基づき定義された寄与であるImportanceや、協力ゲーム理論のシャープレイ値を応用したSHapley Additive exPlanations (以下、SHAP)[23]といった、なぜその出力結果となったのか人間が容易に解釈できる「解釈性」の向上のための様々な指標の適用も可能である。

3. 提案手法

3.1 問題設定

本研究では、季節性アイテムの出品計画の問題に焦点を当てる。従来の季節性アイテムの出品は、出品管理者の経験やノウハウに基づいた属人的な需要予想により判断されてきた。しかし、この属人的な予想と実績に乖離がある場合、様々な問題が生じる。そこで本研究では、需要予測モデルを構築することで、定量的な根拠に基づく客観的かつ確かな計画立案を支援し、モデルと人間の協働による意思決定の質向上を試みる。なお、ZOZOUSEDでは、ミクロな視点で個別アイテムの意思決定を支援する数多くの機械学習モデルが検討されてきた[15], [16], [17], [18]。これに対し本研究では、これらの先行研究では考えられていなかった、マクロな視点でアイテム群に対する包括的な意思決定への支援に着目した研究を行う。

3.2 提案への着想

本研究は実運用化を想定しているため、現場でモデルを利用する出品管理者の負担を軽減しスムーズな導入を促すことが望まれる。さらに実ビジネスへの適用条件には、リスク防止のため、十分な解釈性・高い精度の保持・迅速な結果の獲得が必須である。以上の理由から、本提案手法はアイテムカテゴリごとに構築された長期予測モデルと短期予測モデルからなる2段階構成とする。このように、従来の2段階からなる出品計画に沿った構成とすることで、出品管理者は大きな変化なく従来どおりに仕事することができ負担が軽減され、スムーズな導入が期待できる。また、アイテムカテゴリごとにモデルを構築することで、季節性の強さの違いに由来する需要変動に関する特徴と要因との関係性をよりの確にとらえられ、予測の精度向上が期待できる。加えて、2段階構成とすることで提案手法は加法モデルとなり、精度と解釈性の向上を両立することも期待できる。

さらに、ZOZOUSEDに蓄積された過去の販売履歴データは、多様かつ膨大であることから、機械学習によるアプローチと相性が良いと考えられる。また、一般に顧客の中古アパレル商品の購入意向に影響を与える要因として、気温や天候などの環境条件や、価格割引率やセールイベントなどのECサイトの条件があげられる。よって、実ビジネスへの適用の必須条件を満たしつつ、これら複数の外部要

因を十分に考慮することも求められる。以上の理由から、本提案手法を構成するモデルの構築は、多種多量な特徴量の考慮・高精度・低計算コストといった本研究の理想を実現する LightGBM アルゴリズムを適用することにより行うことを考える。LightGBM は Gradient Boosting Decision Tree 系のアルゴリズムのうち最も計算速度が速いことが示されており [19], [24], [25], 実運用で結果の出力速度が特に重視すべき観点であることから、本提案手法で用いる予測モデルとして採用した。

3.3 提案手法

提案手法は、シーズン開始前にシーズン全体の需要予測を行う長期予測モデルと、シーズン中に日々のオペレーションで予測値の調整を行う短期予測モデルの 2 段階で構成されている。実運用における各役割および活用の流れは、次に示すとおりである。また、イメージ図を図 2 と図 3 に示す。

長期予測モデル

1 段階目にあたる長期予測モデルでは、シーズン前の計画段階で使える変数より長期的な日別販売数予測を行うことで、その形状からピーク時期やその前後の動向の様子など対象期間の売れ行きの大まかな傾向を把握し、シーズン全体を見据えた長期的な調達・在庫計画の手がかりとすることが期待できる。

短期予測モデル

2 段階目にあたる短期予測モデルでは、シーズン中により多種で新しい情報を用いてより実際に近い販売数に予測値を調整でき、週周期やより具体的な直近の予測値を把握し、大まかな出品計画に対する日々のオペレーションレベルでの実際の出品数の策定・決定の支援が期待できる。




図 2 長期予測モデルのイメージ図

Fig. 2 Diagram of the long-term prediction model.




図 3 短期予測モデルのイメージ図

Fig. 3 Diagram of the short-term prediction model.

すなわち、本提案モデルは、シーズン前のシーズン全体を見据えた長期的な調達・在庫計画と、シーズン中の日々の出品を決定するオペレーションレベルの出品計画の両方の側面で活用できるモデルであるといえる。

結果として提案手法により、用いることのできる情報を無駄なく利用し定量的かつ的確に需要を把握した元で、在庫情報などをふまえて「売れ残りアイテムを極力出さないように」などの戦略的な出品が可能となることが期待できる。また、2 段階構成とすることで提案手法は加法モデルとなり、次のように精度と解釈性の向上を両立するといえる。本研究で対象とする時系列データはトレンドと定常性が組み合わさっており複雑で、その特徴を 1 度でとらえることは困難である。そこで、まず長期予測モデルによりトレンドを分析する。次に、その結果を用いて対象データのトレンドを除去し、定常状態となっているデータについて短期予測モデルにより分析する。このように、対象データをトレンドと定常性で分けて分析することで、とらえるべき特徴がシンプルになり、精度の良いモデルの構築が期待される。さらに、短期予測モデルは長期予測モデルによる予測と実測値とのずれを新たに得られた複数の要因を考慮し調整する役割を担い、予測値に対する解釈性向上が期待できる。たとえば、短期予測モデルがシーズン中の気象情報より負の予測値を出力し下方修正が行われた場合、「シーズン前の予測よりも、雨が多く気温が上がらなかったため、夏物の販売数量が伸びなかった」などの経験的な知識を活用した解釈が可能となる。加えて、モデルの構築に用いた特徴量は予測時にモデルにより自動的に加味されるため、それらの影響を出品計画の際に改めて深く考慮する必要はなく、出品計画の負担軽減につながる事が期待できる。

長期予測モデルと短期予測モデルの構築は、それぞれ LightGBM により行われる。アイテム群ごとの予測モデルに使用された目的変数と説明変数を表 2 と表 3 に示す。これらの変数は、日付情報、気温や天候などの気象情報、

表 2 春夏アイテムに関する予測モデルの目的変数と説明変数
Table 2 Objective and explanatory variables of the prediction model for spring/summer items.

	説明変数	目的変数
長期予測モデル	-日付 (月/日/曜日/週番号) -序盤/終盤フラグ -オフ率構成比 (0, 10, 20, ..., 90(%)) -気温 -気温過去 5 日分の分散 -前日気温差	販売数
短期予測モデル	-日付 (月/日) -気温実測値 -気温過去平均 -天候概要フラグ (晴_日中/雨_夜間, ... など) -過去平均気温と実測値との差 -セール強度 -気温 5 日連続 t 度以上/以下フラグ ($t = 0, 10, 20$) -オフ率構成比 (0, 10, 20, ..., 90(%))	長期予測モデルの残差

表 3 秋冬アイテムに関する予測モデルの目的変数と説明変数
Table 3 Objective and explanatory variables of the prediction model for autumn/winter items.

	説明変数	目的変数
長期予測モデル	-日付 (月/日/曜日/週番号) -出品数 -序盤/終盤フラグ -オフ率構成比 (0, 10, 20, ..., 90(%)) -気温 -気温過去 5 日分の分散 -前日気温差 -休日フラグ -Prophet から得た週周期 -気温の 7 日分ラグ変数 -出品数の 7 日分ラグ変数 -出品数過去 7 日分平均	販売数
短期予測モデル	-日付 (月/日) -気温実測値 -気温過去平均 -天候概要フラグ (晴_日中/雨_夜間, ... など) -過去平均気温と実測値との差 -セール強度 -気温 5 日連続 t 度以上/以下フラグ (t = 0, 10, 20) -オフ率構成比 (0, 10, 20, ..., 90(%))	長期予測モデルの残差

オフ率やセールイベントなどの EC サイトの様子といった、季節性アパレル商品の販売数に影響を与える主な外部要因から特徴量エンジニアリング [26] により様々な変数を作成し、探索的に最適な変数の組合せを手動で選択したものである。なお、春夏アイテムに関する実験を終えて秋冬のモデルを作成する際に、春夏と同じ変数で予測変数を作ろうとしたところあてはまりが非常に悪く改善の必要があると判断した。また、現場の経験的な知識としても、販売数の要因になると思われる変数は大きく異なることが分かっている。そこで、秋冬のモデルを作成する際によりあてはまりが良くなるような変数を選択しモデルを作成した。表 2 と表 3 における、「フラグ」はダミー変数として入力していることを、「ラグ変数」は過去の実績値を現時点の特徴量として使用していることを示している。「序盤/終盤フラグ」は対象期間のうち運営上販売数の動向が若干異質となってしまうような期間に対応する。具体的には、シーズン開始直後の販売数の動向を探る期間に序盤フラグを、シーズンの終わりを意識して在庫状況をふまえ意図的に出品数を操作する期間に終盤フラグを立てる。また、「オフ率構成比」は、システムにより行われる段階的な値下げについて、その日の販売アイテムの値下げ率の状況を構成比として示している。「セール強度」は、ZOZO の社内で定義されている指標であり、全イベントを考慮した総合的なセール活動の活発さを表したものとなっている*1。日付情報のうち「月」「日」「曜日」は順番を考慮したいため数値データとして入力した。長期予測モデルの入力変数である出品数と気温については、学習時には実測値を用い、予測時にはシーズン前に現場で設計された予定出品数と過去のデータから算出

*1 「セール強度」の詳細な定義式については非公開情報であるため、本論文ではその意味のみの記載に留める。

した平均気温を用いた。具体的な予測の流れは、長期予測モデルにより大まかなワンシーズンの販売数を予測し、短期予測モデルにより直近の新たに得た情報を用いて残差を予測し、長期予測モデルによる予測値と足し合わせることで販売数予測値を調整する。この 2 段階の手順で日別の販売数を予測する。

4. 実データ分析

4.1 概要

本章では、提案モデルを実データに適用し得られた結果について分析し、各モデルが実運用で期待できる役割を果たせるか否かについて、モデルの有用性を評価する。具体的には、以下の各モデルに対する 2 つの分析を行う。

分析 1. 長期予測モデルの基本的な精度を評価するために、最も回帰問題によく用いられている手法の 1 つである重回帰分析と、Facebook (現・Meta) により開発された加法モデルに基づき時系列データをトレンド関数・周期関数・イベント関数に分解して表現する時系列予測手法である Prophet [27] により構築したモデルと精度を比較する。

分析 2. 短期予測モデルによる予測値の調整について評価するために、過去の一定期間について調整を行い精度の変化を観察する。

4.2 分析条件

対象データとして、ZOZOUSSED に蓄積されている販売履歴データと、国土交通省気象庁により記録されている気象データ [28] を用いる。販売履歴データは、買取日が 2015/12/01 以降かつ販売日が 2016/01/01 以降の、春夏/秋冬アイテムに関するデータを抽出する。ここで、高級ブランド商品は希少性が高く、場合によってはヴィンテージと称され価値が上がるものもあり、人気が高い。ゆえに、ZOZOUSSED ではサイトの魅力度向上のため買取後なるべく早く出品し、顧客は商品を出品後まもなく競って購入する傾向がある。つまり、季節関係なく出品・販売され販売数推移に季節性はなく季節性アイテムと異なる挙動を示し、本提案モデル構築においては外れ値となってしまう。以上より、高級ブランドに相当するアイテムは除いたデータを使用する。また、気象データは東京における情報を取得する。LightGBM では、長期予測モデルは、予測対象年以前の用いることのできる全月の観測データを学習データとして用いることで構築する。さらに短期予測モデルは、任意の調整対象日前日までの実績を用いて、長期予測モデルによる予測値と実績データとの残差を算出し目的変数として用いて構築する。そして、2020 年度の各シーズンにおける調整対象期間の残差を短期予測モデルにより予測し、長期予測モデルの予測値に足し合わせることで調整する。以上のイメージ図を図 4、図 5 に示す。各予測モデルには




図 4 2020 年度を対象とした場合の長期予測モデルのイメージ図
 Fig. 4 Diagram of the long-term prediction model in the case of predicts covering FY2020.




図 5 2020/02/29~2020/03/13 を調整対象期間とした場合の短期予測モデルのイメージ図
 Fig. 5 Short-term prediction model diagram with 2020/02/29 to 2020/03/13 as the period subject to adjustment.

LightGBM を用い、パラメータは Optuna [29] により最適化された値に設定した。なお、各アイテム群の対象シーズンは、春夏アイテムは 2 月から 8 月末まで、秋冬アイテムは 8 月中旬から翌年の 2 月末までとする。これにより、各手法が学習および予測に使用したデータのレコード総数・次元数・入力データ長は、以下のとおりとなった。

重回帰

- 春夏 (学習：816 個・21 次元・207 KB, 予測：273 個・21 次元・69 KB)
- 秋冬 (学習：729 個・21 次元・212 KB, 予測：304 個・21 次元・88 KB)

Prophet

- 春夏 (学習：1,096 個・1 次元・66 KB, 予測：365 個・1 次元・22 KB)
- 秋冬 (学習：729 個・1 次元・46 KB, 予測：304 個・1 次元・19 KB)

LightGBM (2019 年度)

- 春夏 (学習：640 個・38 次元・66 KB, 予測：211 個・38 次元・22 KB)
- 秋冬 (学習：712 個・64 次元・46 KB, 予測：305 個・64 次元・19 KB)

LightGBM (2020 年度)

- 春夏 (学習：1,004 個・38 次元・397 KB, 予測：212 個・38 次元・84 KB)
- 秋冬 (学習：1,078 個・64 次元・453 KB, 予測：272 個・64 次元・114 KB)

なお、学習は企業で契約をしている Google Cloud Platform に搭載されている Vertex AI [30] により行う。

本提案モデルの予測精度に対する評価において、社会情

表 4 長期予測モデルの機械学習アルゴリズム別予測誤差 (標準偏差)
 Table 4 Prediction error of the long-term prediction model trained by each machine learning algorithm (Standard deviation).

予測対象	重回帰	Prophet	LightGBM	
	2020 年度	2020 年度	2019 年度	2020 年度
春夏_弱	53.89 (76.10)	60.82 (109.47)	16.78 (20.84)	29.27 (38.18)
春夏_中	26.05 (200.01)	39.66 (57.13)	15.02 (12.04)	15.62 (14.45)
春夏_強	36.40 (379.70)	53.72 (125.05)	24.51 (16.37)	16.45 (40.39)
秋冬_弱	35.77 (95.29)	43.99 (87.28)	28.13 (23.75)	20.39 (31.44)
秋冬_中	29.60 (228.46)	50.19 (137.49)	15.51 (38.58)	16.24 (15.54)
秋冬_強	56.11 (200.83)	56.27 (231.05)	18.13 (30.31)	16.24 (17.07)



図 6 春夏アイテムに関するアイテムカテゴリ別長期予測値の推移
 Fig. 6 Long-term forecasting.

勢や社内トラブルなど、予期しないイベントの影響により明らかに予測不可能な販売数の変動は評価の対象外とする。そこで、予測精度に対する評価指標は、外れ値の影響を受けにくい各データに対する Absolute Percentage Error (以下、APE) の中央値により行う。なお、 n 番目のデータに対する APE は以下の式 (1) で算出する。ただし、 N 個のデータにおける n 番目の実測値を y_n 、予測値を \hat{y}_n とする。

$$APE_n = \left| \frac{\hat{y}_n - y_n}{y_n} \right| \tag{1}$$

なお、過去の運用実績から、実運用への適用に対して十分に信頼性があると判断できる基準は、APE の中央値 30% 以下とされている。

4.3 結果と考察

4.3.1 分析 1

まず初めに、分析 1 に関する結果と考察について述べる。表 4 は、複数の機械学習アルゴリズムを用いて予測モデルを構築した場合の 2020 年度の対象シーズンにおける予測誤差とその標準偏差である。なお、提案モデルについては 2019 年度の結果も示す。さらに、本提案モデルに該当する LightGBM により構築された予測モデルによる、春夏アイテムにおける各アイテムカテゴリでの予測値の推移を図 6 に示す。

表 4 に示される各アルゴリズムで学習した 2020 年度の結果を見ると、提案モデルに該当する LightGBM により構築されたモデルが予測誤差が最小で、かつ APE の中央値が 30%以下となっていることから、十分に信頼性があると判定できる。さらに、学習データに含まれる 2019 年度の結果と比較しても極端に 2019 年度の方が精度が良いということもなく、テストデータである 2020 年度の方が良い場合も存在する。このことは、提案モデルは過学習を起しているとはいえないことを示している。また、その平均学習時間（各 90 回学習）は、2019 年度では春夏 123.78 秒・秋冬 118.85 秒、2020 年度では春夏 160.33 秒・秋冬 167.74 秒となった。これにより、提案手法における長期予測モデルは出力速度の観点から十分に実務に耐えうるものであるといえる。さらに図 6 より、各アイテムカテゴリでピークやその前後の動向をうまくとらえられていることが分かる。以上より、長期予測モデルは的確に傾向を把握し、シーズン前に行うシーズン全体の調達・在庫計画の支援となる役割を果たすことができる。よって、長期予測モデルは実運用に有用であることが示された。

4.3.2 分析 2

次に、分析 2 に関する結果と考察について述べる。表 5 は、対象シーズンの任意の一定期間を対象として、長期予測モデルによる予測値と長期予測に短期予測モデルの予測値を足し合わせることで調整した後の予測値に対し、予測誤差とその標準偏差を評価した結果である。なお、調整前と調整後で比較し予測誤差が小さく精度が良い方を太字で示している。

表 5 の結果、短期予測モデルを用いた修正によって、ほとんどの場合で精度が向上していることが分かる。また、その平均学習時間（各 90 回学習）は、春夏 2020/02/29～2020/03/13 のとき 135.58 秒、秋冬 2020/10/22～2020/11/04 のとき

表 5 短期予測モデルによる予測誤差の変化（標準偏差）

Table 5 Change in forecast error by short-term forecasting model (Standard deviation).

		長期予測モデル (調整前)	長期予測モデル +短期予測モデル (調整後)
2020/02/29 ～	春夏-弱	7.59(11.68)	5.39(12.79)
	春夏-中	18.84(11.61)	12.67(20.36)
2020/03/13	春夏-強	36.01(53.09)	680.10(247.88)
2020/07/13 ～	春夏-弱	105.22(69.35)	70.11(53.51)
	春夏-中	15.81(14.54)	13.56(15.46)
2020/07/26	春夏-強	24.68(17.39)	13.30(14.09)
2020/10/22 ～	秋冬-弱	12.66(7.74)	10.25(10.65)
	秋冬-中	6.20(7.39)	5.37(5.95)
2020/11/04	秋冬-強	18.33(6.66)	10.26(8.44)
2021/01/06 ～	秋冬-弱	28.15(12.51)	21.86(12.74)
	秋冬-中	24.24(15.22)	10.61(10.63)
2021/01/19	秋冬-強	17.43(13.03)	16.59(8.90)

101.59 秒などようになった。これにより、提案手法における短期予測モデルは出力速度の観点から十分に実務に耐えうるものであるといえる。なお、2020/02/29～2020/02/13 のアイテムカテゴリ春夏-強については調整後大幅に精度が悪化しているが、この場合のようなシーズン序盤は販売数自体が少ないため、 \hat{y}_n と実測値 y の差がわずかであっても式 (1) における分母の小ささにより APE の中央値が大きく計算されてしまうことが原因となっている。本論文では企業との秘密協定により具体的な数量は示すことができないが、担当者との合議により実際に実測値との差は企業に莫大な損失を与えるほど大きくはなく、深刻な問題ではないことを確認している。以上より、短期予測モデルは、より豊富な情報を用いてより実績に近い方向へ予測値を調整する役割を果たすことが期待できる。よって、短期予測モデルは実運用に有用であることが示された。

5. ビジネスでの実運用による実証実験

5.1 概要

本章では、提案手法の実ビジネスにおける信頼性と有効性を実証的に検証するために、提案手法によって得られた販売数予測値を、ZOZOUSED で新規出品されるアイテムに対する出品計画策定の際の新たな指標として利用する実証実験を行う。さらに、販売実績の分析と考察を行うことで、実運用における提案手法の有効性を検証する。具体的には、ZOZOUSED の季節性アパレル商品を対象に、出品管理者の協力の元、各アイテム群に対して以下のように実施する。

- (1) シーズン前に、出品管理者に長期予測モデルの予測によりシーズン全体の需要を大まかに把握し、出品開始時期の妥当性や在庫が十分あるかなどを確認してもらう。
- (2) シーズン中は、短期予測モデルを最新のデータを用いて学習し、直近の需要を予測する。この予測値をベースとして、出品管理者にその先 1 週間で出品するアイテム数を決定してもらう。
- (3) (2) を週次で繰り返し行い、最終的にシーズン末に得られた実績について、精度と有効性を評価する。

5.2 分析条件

実証実験の実施期間は、春夏アイテムについては 2021/01/28 から 2021/07/31 まで、秋冬アイテムについては 2021/08/15 から 2022/02/28 までである。毎週火曜日にモデルの学習および予測を行い、出品管理者により水曜日からその先 1 週間の出品計画の策定をしてもらう。精度評価は、式 (1) で表される予測誤差 APE の中央値により行い、実務上は 30%以下であることが望ましい。有効性評価は、出品後一定日数連続で掲載されていても売れないアイテムを売れ残りアイテムとした場合の、出品数のうち

売れ残りアイテムの占める割合で定義される、売れ残り率により行う。ここで、提案手法の有効性の評価を行うためには明確な従来手法との比較が必要で、本来、可能であれば同年度でまったく同じ条件のもと人の感覚だけですべてを調整した場合と比較すべきである。しかし、営利目的で活動している企業が、ビジネス上の利益を犠牲にして単に検証評価だけの目的でワンシーズンの出品を実験的に行うということは現実的には難しい。すなわち、従来方法と提案手法の両手法で出品計画を実施して、結果を比較することは大きなコストと損失が生じるリスクが懸念される。これに加えて、本研究は季節性商品のシーズンの需要量を予測して出品数を計画する問題を対象としているため、同期間の需要予測と出品計画に対して従来方法を適用すると、提案法を適用した結果が観測できないという反実仮想の問題が生じ、2つの異なる手法を適用して比較するという実験が本質的に実施できない問題設定である。以上より、本研究では、提案法で出品を行った2021年度と過去最も平均的な出品をした2019年度の実績を比較することによって評価を行うこととした。2019年度の従来法の実績よりも、2021年度に売れ残り率が減少していれば提案モデルが有効であると考えられる。

ただし、気象情報やECサイトの様子など、背景要因が比較対象の2019年度と提案手法を実運用した2021年度で異なり、この膨大な組合せを考慮すると各年度の環境がかなり異なることも考えられる。すなわち、単純に全実績を集計し得られた売れ残り率の変化は、提案手法の効果ではなく各年度の環境の違いによるものである懸念がある。そこで、傾向スコアを用いて、全実績から環境をできる限り揃えるよう、マッチング [31], Inverse Probability Weighting (以下, IPW) [32] を適用し、効果検証の観点からも売れ残り率を比較検証する。なお、傾向スコア推定モデルはLightGBMを用いて構築した。また、共変量として用いた背景要因と、春夏アイテムにおける平均値の差、差の標準偏差、 t 値、 P 値を、環境の違いの例として表 6 に示す。

5.3 結果と考察

5.3.1 精度評価

予測誤差を各週で計算した結果を図 7, 図 8 に示す。ここで、長期予測モデルによる調整前の結果を青線、短期予測モデルによる調整後の結果を赤線、目標値を黄線で示している。また、右の数字は対象期間すべてのデータに対する予測精度である。ここで、長期予測モデルと短期予測モデルのみでは考慮できない要素が存在する。その1つとして、在庫操作の困難性があげられる。在庫である中古品は主に顧客からの買取によって補充するので、数量とタイミングを指定して入荷するなどの確実な手段をとれず、操作が困難である。予期せず突発的に在庫が増減することもあり、その場合、出品数による調整が必要となる。よって、

表 6 共変量とその違い ($P < 0.05^*$, $P < 0.01^{**}$)

Table 6 Covariates and their differences.

背景要因	平均値の差	差の標準誤差	t 値	P 値
曜日 (カテゴリ)	0.0166	0.2107	0.0786	0.9374
週末 (フラグ)	0.0055	0.0476	0.1162	0.9076
祝日 (フラグ)	0.0110	0.0241	0.4590	0.6465
セール強度 (1~4)	-0.6961	0.0710	-9.8111	0.0000**
気温 (連続値)	-1.2144	0.6933	-1.7516	0.0807
気温分散 (連続値)	0.3028	0.0928	3.2615	0.0012**
午前快晴 (フラグ)	-0.0552	0.0280	-1.9726	0.0493*
午前晴 (フラグ)	-0.0276	0.0516	-0.5350	0.5930
午前曇 (フラグ)	0.0773	0.0450	1.7177	0.0867
午前雨 (フラグ)	-0.0166	0.0491	-0.3378	0.7357
午前雪 (フラグ)	0.0166	0.0095	1.7418	0.0824
午前霰 (フラグ)	-0.0055	0.0055	-1.0000	0.3180
午前雷 (フラグ)	-0.0221	0.0134	-1.6483	0.1002
午後快晴 (フラグ)	-0.0387	0.0285	-1.3550	0.1763
午後晴 (フラグ)	0.0166	0.0522	0.3173	0.7512
午後曇 (フラグ)	0.0221	0.0437	0.5055	0.6135
午後雨 (フラグ)	0.0331	0.0496	0.6685	0.5043
午後雪 (フラグ)	0.0166	0.0095	1.7418	0.0824
午後霰 (フラグ)	0.0055	0.0055	1.0000	0.3180
午後霰 (フラグ)	0.0055	0.0055	1.0000	0.3180
午後雷 (フラグ)	-0.0221	0.0155	-1.4302	0.1535




図 7 春夏アイテムに関する各週の精度評価値

Fig. 7 Accuracy evaluation values for spring/summer for each week.




図 8 秋冬アイテムに関する各週の精度評価値

Fig. 8 Accuracy evaluation values for autumn/winter items for each week.

当実証実験期間中、出品管理者が出品するアイテム数を決定する際は、提案手法による予測結果から、その時点での在庫状況を確認し、過剰となりつつあるならば在庫コストを考慮し増加させ、過少となりつつあるならばその後の買取数を見据えて今シーズンの必要量を保持するように減少させるという修正を実施した。ただし、基本的には長期予測モデルおよび短期予測モデルでの結果のみで出品数を決定している。具体的にはシーズンを通した販売数予測値に対する実際の出品数は、春夏は 14.06%・秋冬は 16.57%の

差があり、その差が出品管理者による修正の程度を表す値となっている。

図 7, 図 8 より、提案モデルは目標値より低い値をおおよそシーズンを通して保っていることが分かる。すなわち、実ビジネスにおいても十分な精度を持続でき信頼性があるといえる。また、短期予測モデルによる調整を行うことで精度がほぼすべての週で改善されており、短期予測モデルが期待どおりの効果を示していることが分かる。一方、短期予測モデルによる調整を行うことで精度が悪化してしまう場合も少々存在する。この原因として、以下の例として示すように本研究では加味しきれなかった要因の影響が考えられる。ZOZOUSED は他の多様な EC サイトや SNS などと提携し販売活動の場を広げており、ZOZOUSED が直運営する EC サイト以外の媒体を通じて顧客は ZOZOUSED のアイテムを閲覧・購入可能である。ここで、他の媒体でセールイベントなどが行われ集客が行われた場合、これによって集まった多くの顧客に ZOZOUSED が認知され、ZOZOUSED 自体の EC サイトへの顧客流入が期待できる。本研究の短期予測モデルでは、ZOZOUSED 内で実施されるセールイベントに関する情報はセール強度により十分に考慮されているといえる。しかし、上述のような他の媒体での ZOZOUSED の販売数に間接的に影響を与えるような施策に関する情報は、すべて確実に取得し考慮することは困難である。よって、これらの影響が大きい場合、予測精度が悪化してしまうことがある。この問題に対して、販売数に影響を与える要因を、提携している EC サイトや SNS の状態など、より広い視点を持ちより多くの観点から改めて考える必要があるといえる。なお、実データよりコロナ感染症の蔓延にともなう消費者意識の躍動的な変化による影響が確認され、精度悪化の一因として懸念された。一方、企業の方針転換による販売方式の変更など、他の様々な要因からの影響も大きいことが分かった。そこで、ZOZOUSED と考えられる影響について包括的に議論した結果、2019 年度と 2021 年度では販売データとしての大きな違いは生じず、評価実験に与える影響について問題はないことを確認した。

5.3.2 有効性評価

各月の売れ残り率を 2019 年度と 2021 年度で算出し比較した結果を、2019 年度の初月の売れ残り率を 1.000 とした場合の指数として図 9, 図 10 に示す。また、シーズン全体での売れ残り率の平均値の差、傾向スコアによるマッチングおよび IPW を適用した結果を表 7 に示す。

図 9, 図 10 より、ほぼすべての月で売れ残り率は減少しており、また表 7 より、全シーズン通しても減少することが分かる。さらに、傾向スコアによるマッチングおよび IPW を適用し、より厳格に計算を行った際でも売れ残り率は減少と評価された。よって、実ビジネスにおいても売れ残り率減少に貢献し、出品計画の支援に有効であるといえ




図 9 春夏アイテムの月別売れ残り率

Fig. 9 Monthly unsold rate of summer/spring item.




図 10 秋冬アイテムの月別売れ残り率

Fig. 10 Monthly unsold rate of autumn/winter item.

表 7 売れ残り率の変化

Table 7 Change in unsold rate.

	春夏アイテム (%)	秋冬アイテム (%)
平均値の差	-2.34	-12.27
マッチング	-3.08 (169 ペア)	-7.83 (152 ペア)
IPW	-5.19	-14.96

る。以上より、提案手法の有効性が示された。

6. 考察

6.1 提案手法の有用性と有効性に関する考察

4 章の実データを用いた分析により、提案手法を構成する長期予測モデルは、比較手法で構築したモデルよりも販売数予測の予測精度の観点から優位であることが示された。また、提案手法を構成する短期予測モデルについても、販売数予測値の調整によりほとんどの場合で予測精度が向上し、その有用性が示された。さらに、5 章での議論により、提案手法を実ビジネスに導入した場合でも、実際の予測精度の保持および売れ残り率の減少に貢献したことを確認し、その有効性を実証した。以上より、提案手法は、非常に信頼性が高く、ZOZOUSED における出品計画立案の支援に効果的で有用であるといえる。

この結果より、本提案手法は、2 章で述べた研究目的である、需要に沿った戦略的な季節性のある中古アパレル商品の出品を可能とする。たとえば、モデルが予想以上の需要があると予測し、かつ在庫が潤沢にある場合、出品管理担当者は迷わず安心して需要に沿うように出品数を増量するようになる。これにより、出品管理担当者の心理的負担の削減と、売り上げ向上や売れ残り防止が期待できる。さらに、提案手法による予測値は、出品計画策定の際に定量

的な根拠の1つとしても利用可能である。たとえば、会議での議論で周囲の賛同を得るために、信頼性と有効性が十分示された本提案手法による予測値を、自身の主張を補強する定量的な根拠として示すことができる。これにより、より円滑な議論を実現することが期待できる。

6.2 提案手法の拡張性

需要を的確に把握することは、仕入れ・生産・販売・人員配置・設備投資・資金調達などに対する計画策定を大きく左右し、ビジネス活動の根幹に関わるきわめて重要な業務である。すなわち、本研究で対象とした小売業の他に製造・医療・金融など、多くの業界においても主要な課題であり、この解決が期待できる需要予測がいずれの業界においても強く求められている。

本提案手法では、中古アパレル商品の需要を直接示す販売数の予測を行ったが、実データと相性の良い技術を十分に盛り込んでおり、売上や人流、エネルギー量など、その他のデータにも広く適用できる。よって、他業界で望まれている需要予測に対しても、本研究と同様に高精度で低計算コストな予測モデルを構築することができ、実ビジネスで活用できる場は多く、本提案手法の拡張性は高いといえる。

さらに、構築したモデルは2段階構成となっており、対象期間全体を見据えた長期的な準備・計画と、対象期間中の日々のオペレーションレベルでの計画の、両方の側面での活用が可能である。よって、対象期間前から余裕を持った行動が実現でき、さらに対象期間中では得られる情報を余すことなく有効活用し、より確実な施策の実行に結び付けることができる。このような特性はいずれの業界においても強く求められ、この観点からも本提案手法の拡張性は高いといえる。

6.3 さらに問題設定

本研究は、予測モデルと出品管理者の協働による意思決定の質向上を試みるという方針のもと行った。つまり、実運用ではあくまで本提案手法で得られた予測値を指標として用いるのみで、出品管理者により出品計画は立てられる。したがって、本研究で、提案手法により定量的な根拠を新たに獲得でき、より戦略的な出品が可能となることが示されたが、やはり最終的な意思決定は出品管理者による属人的な判断に基づくため、確実性は完全ではないといえる。

そこで、本提案手法により予測した販売数に対する最適な出品数を定量的に求めることが次の問題設定としてあげられる。これにより、ビジネス行動の完全にモデルに頼った自動化に結び付けることができると期待できる。

7. 結論と今後の課題

本研究では、中古ファッション EC サイトの季節性アイテムを対象とし、出品計画において需要と供給のバランス

がとれた最適な意思決定を実現する、実運用を想定した機械学習ベースの需要予測モデルからなる手法を提案した。具体的には、シーズン開始前にシーズン全体の需要予測を行う長期予測と、シーズン中に新たに得た情報を用いた残差予測による予測値の調整を行う短期予測の、2つの販売数予測モデルからなる2段階構成の手法を提案した。さらに、過去の販売履歴データに適用し、分析結果を通じて提案手法の有用性を示した。加えて、提案の予測値を、新規出品のための新たな指標として加えた元で決定した出品数を実行する実証実験を設計・実施することで、実証的に提案手法の信頼性と有効性が示された。また、効果検証の観点からも有効性が確認できた。以上より、当 EC サイトにおいて、出品計画立案の支援となる有用なモデルを構築することができた。

今後の課題としては、提案手法に用いる機械学習モデルの拡張があげられる。本提案モデルの構築には1点予測を行う LightGBM を用いたが、NGBoost [33] やベイズ推定 [34] など確率分布を推定する手法も提案されている。これらを用いることで、日別販売数を分布として予測することが可能となり、出品管理者はより柔軟な意思決定が可能となることが期待できる。

謝辞 本研究は、日本学術振興会 (JSPS) 科学研究費 No.21H04600 の助成を受けたものです。

参考文献

- [1] 経済産業省：令和2年度電子商取引に関する市場調査 (2021), 入手先 (https://www.meti.go.jp/policy/it_policy/statistics/outlook/ie_outlook.html).
- [2] Turunen, L.L.M. and Pöyry, E.: Shopping with the Resale Value in Mind: A Study on Second-hand Luxury Consumers, *International Journal of Consumer Studies*, Vol.43, No.6, pp.549–556 (2019).
- [3] 株式会社メルカリ：メルカリ - 日本最大の売れるフリマサービス (2021), 入手先 (<https://jp.mercari.com/>).
- [4] 株式会社メルカリ：FY2021.6 4Q 決算説明会資料 (2021), 入手先 (<https://pdf.irpocket.com/C4385/bygc/EKBN/Y2jG.pdf>).
- [5] Goto, M., Mikawa, K., Hirasawa, S., Kobayashi, M., Suko, T. and Horii, S.: A New Latent Class Model for Analysis of Purchasing and Browsing Histories on EC Sites, *Industrial Engineering and Management Systems*, Vol.14, No.4, pp.335–346 (2015).
- [6] Rosenbaum, P.R. and Rubin, D.B.: The Central Role of the Propensity Score in Observational Studies for Causal Effects, *Biometrika*, Vol.70, No.1, pp.41–55 (online), DOI: 10.1093/biomet/70.1.41 (1983).
- [7] Liu, N., Ren, S., Choi, T.-M., Hui, C.-L. and Ng, S.-F.: Sales Forecasting for Fashion Retailing Service Industry: A Review, *Mathematical Problems in Engineering*, Vol.2013 (2013).
- [8] Giri, C., Thomassey, S., Balkow, J. and Zeng, X.: Forecasting New Apparel Sales Using Deep Learning and Nonlinear Neural Network Regression, *2019 International Conference on Engineering, Science, and Industrial Applications (ICESI)*, pp.1–6 (online), DOI: 10.1109/ICESI.2019.8863024 (2019).

- [9] Xia, M. and Wong, W.: A seasonal discrete grey forecasting model for fashion retailing, *Knowledge-Based Systems*, Vol.57, pp.119–126 (online), DOI: 10.1016/j.knosys.2013.12.014 (2014).
- [10] Deng, J.-L.: Control problems of grey system, *Systems and Control Letters*, Vol.1, No.5, pp.288–294 (1982).
- [11] Kedia, S., Jain, S. and Sharma, A.: Price Optimization in Fashion E-commerce, arXiv preprint arXiv:2007.05216 (2020).
- [12] Ravi, A., Repakula, S., Dutta, U.K. and Parmar, M.: Buy Me That Look: An Approach for Recommending Similar Fashion Products, *2021 IEEE 4th International Conference on Multimedia Information Processing and Retrieval (MIPR)*, pp.97–103 (online), DOI: 10.1109/MIPR51284.2021.00022 (2021).
- [13] Jain, A., Modi, D., Jikadra, R. and Chachra, S.: Text to Image Generation of Fashion Clothing, *2019 6th International Conference on Computing for Sustainable Global Development (INDIACom)*, pp.355–358 (2019).
- [14] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A. and Bengio, Y.: Generative Adversarial Nets, *Advances in Neural Information Processing Systems*, Vol.27 (2014).
- [15] 仁ノ平将人, 三川健太, 後藤正幸: 販売履歴データに基づく中古ファッションアイテムの販売価格予測モデルに関する一考察, *情報処理学会論文誌*, Vol.60, No.4, pp.1151–1161 (2019).
- [16] 金澤真平, 楊添 翔, 後藤正幸: 中古ファッション EC サイトにおける出品条件と販売価格の関係分析モデルに関する一考察, *経営情報学会誌*, Vol.30, No.1, pp.47–64 (2021).
- [17] 桑田 和, 杉崎智哉, 三川健太, 後藤正幸: 販売履歴データに基づく中古ファッションアイテムの出品価格推定モデルの提案, *情報処理学会論文誌*, Vol.62, No.2, pp.796–808 (2021).
- [18] 桑田 和, 三川健太, 佐々木北都, 後藤正幸: 機械学習アプローチに基づく中古ファッションアイテムの価格保持期間適正化モデルの提案と実証的效果検証, *情報処理学会論文誌*, Vol.63, No.1, pp.218–230 (2022).
- [19] Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q. and Liu, T.-Y.: LightGBM: A Highly Efficient Gradient Boosting Decision Tree, *Advances in Neural Information Processing Systems*, Vol.30, pp.3146–3154 (2017).
- [20] Friedman, J.H.: Greedy Function Approximation: A Gradient Boosting Machine, *Annals of Statistics*, Vol.25, No.5, pp.1189–1232 (2001).
- [21] Shi, Y., Li, J. and Li, Z.: Gradient Boosting with Piece-wise Linear Regression Trees, arXiv preprint arXiv:1802.05640 (2018).
- [22] Breiman, L.: Random Forests, *Machine Learning*, Vol.45, No.1, pp.5–32 (2001).
- [23] Shapley, L.S.: *17. A Value for n-person Games*, Princeton University Press (2016).
- [24] Liu, J., Gao, Y. and Hu, F.: A fast network intrusion detection system using adaptive synthetic oversampling and LightGBM, *Computers and Security*, Vol.106, No.C, 102289 (online), DOI: 10.1016/j.cose.2021.102289 (2021).
- [25] Rufo, D.D., Debelee, T.G., Ibenhal, A. and Negera, W.G.: Diagnosis of diabetes mellitus using gradient boosting machine (LightGBM), *Diagnostics*, Vol.11, No.9, 1714 (2021).
- [26] Heaton, J.: An Empirical Analysis of Feature Engineering for Predictive Modeling, *SoutheastCon 2016*, pp.1–6 (online), DOI: 10.1109/SECON.2016.7506650 (2016).
- [27] Taylor, S.J. and Letham, B.: Forecasting at Scale, *The American Statistician*, Vol.72, No.1, pp.37–45 (2018).
- [28] 国土交通省気象庁: 国土交通省気象庁 過去の気象データ (2021), 入手先 (<http://www.data.jma.go.jp/obd/stats/etrn/index.php>).
- [29] Akiba, T., Sano, S., Yanase, T., Ohta, T. and Koyama, M.: Optuna: A Next-generation Hyperparameter Optimization Framework, *Proc. 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, pp.2623–2631 (2019).
- [30] Google Cloud: Introduction to AI Platform (2022), available from (<https://cloud.google.com/ai-platform/docs/technical-overview?hl=ja>).
- [31] Caliendo, M. and Kopeinig, S.: Some Practical Guidance for the Implementation of Propensity Score Matching, *Journal of Economic Surveys*, Vol.22, No.1, pp.31–72 (2008).
- [32] Austin, P.C. and Stuart, E.A.: Moving Towards Best Practice when Using Inverse Probability of Treatment Weighting (IPTW) Using the Propensity Score to Estimate Causal Treatment Effects in Observational Studies, *Statistics in Medicine*, Vol.34, No.28, pp.3661–3679 (2015).
- [33] Duan, T., Anand, A., Ding, D.Y., Thai, K.K., Basu, S., Ng, A. and Schuler, A.: Ngboost: Natural Gradient Boosting for Probabilistic Prediction, *International Conference on Machine Learning*, PMLR, pp.2690–2700 (2020).
- [34] Friedman, J., Hastie, T., Tibshirani, R., et al.: *The Elements of Statistical Learning*, Vol.1, No.10, Springer Series in Statistics New York (2001).



齊藤 美佑

1998年生。2020年早稲田大学創造理工学部経営システム工学科卒業。2022年同大学大学院創造理工学研究科経営システム工学専攻修士課程修了。機械学習を用いたデータ分析に関する研究とその実応用に興味を持つ。



山下 遥

1987年生。2010年東京理科大学理工学部経営工学科卒業。2012年度慶應義塾大学大学院修士課程修了。2015年同大学院博士課程修了。博士(工学)。2015年早稲田大学創造理工学部助手。2017年より上智大学理工学部助教。

品質管理, 統計学, 情報工学を融合させた新たなデータ解析方法に関する研究に従事。応用統計学会, 日本経営工学会, 日本品質管理学会等各会員。



佐々木 北都

1984年生。2010年青山学院大学経営学部二部経営学科卒業。2012年同大学大学院国際マネジメント研究科国際マネジメント専攻修士課程修了。経営管理修士(MBA)。2017年株式会社クラウンジュエル(現ZOZO)入社。

データサイエンティストとして主にアパレルリユース事業のビジネス課題の解決、および機械学習プロダクトの開発に従事。



後藤 正幸 (正会員)

1969年生。1994年武蔵工業大学大学院修士課程修了。2000年早稲田大学大学院理工学研究科博士課程修了。博士(工学)。1997年同大学理工学部助手。2000年東京大学大学院工学研究科助手。2002年武蔵工業大学環境情報学部助教授。2008年早稲田大学創造理工学部経営システム工学科准教授。2011年同大学教授。情報数理応用とデータサイエンス、ならびにビジネスアナリティクスの研究に従事。著書に、『入門パターン認識と機械学習』コロナ社(2014)、『ビジネス統計—統計基礎とエクセル分析』オデッセイコミュニケーションズ(2015)等。IEEE, INFORMS, 電子情報通信学会, 人工知能学会, 日本経営工学会, 経営情報学会等各会員。

2008年早稲田大学創造理工学部経営システム工学科准教授。2011年同大学教授。情報数理応用とデータサイエンス、ならびにビジネスアナリティクスの研究に従事。著書に、『入門パターン認識と機械学習』コロナ社(2014)、『ビジネス統計—統計基礎とエクセル分析』オデッセイコミュニケーションズ(2015)等。IEEE, INFORMS, 電子情報通信学会, 人工知能学会, 日本経営工学会, 経営情報学会等各会員。