

# 公開データを活用した疑似的な購買指標に基づく売上予測モデル

津田悠太

Yuta Tsuda

法政大学情報科学部 デジタルメディア学科

yuta.tsuda.9f@stu.hosei.ac.jp

## abstract

Highly accurate purchase forecasting is essential for optimizing marketing strategies and maintaining competitive advantages of companies. Reflecting underlying purchasing motivations of consumers through methods combining search trends and product specifications holds critical value for elucidating mechanisms behind purchasing behaviors. This study validated effectiveness of a demand forecasting model combining Amazon Sales Rank (SR) and Google Trends under constraints where actual purchase data was difficult to obtain. SR was converted into estimated sales by applying Pareto transformation, and a regression model was constructed by incorporating interaction terms between nominal product specifications and corresponding daily search trends. This proposed method was compared with an autoregressive baseline model relying on historical sales dynamics, using digital cameras and washing machines as subjects. Analysis of top 10 products revealed that models incorporating search data and product specifications remained effective only when mean absolute error (MAE) stayed around 0.3 and search weight ratios were maintained between 29.8. Future research aimed to add marketing mix terms using proxy data such as YouTube views and Meta ad library. Additionally, large language models were proposed to generate candidate products demand to establish quantitative indicators for products significantly influenced by product-spec.

## 1 はじめに

EC化の急速な進展に伴い、消費者が購買に至る前のオンライン検索行動は、意思決定プロセスにおける主要な導線となっている。日本のBtoC-EC市場規模は2023年に22.7兆円に達し、前年比9.91%増で拡大を続けている。特に2017年から2022年にかけての小売市場全体において、オフライン市場が年平均0.3%減と微減する一方で、EC市場は年平均7.3%の成長を記録している[2]。このことから、検索ボリュームの時系列データは、消費者の潜在的な需要をリアルタイムに近似できる有用な指標である。中でもGoogle Trendsデータは、入手が容易かつデータの存在する期間が2004年から今にかけての20年分以上と多量にあるため、様々な購買予測の従来研究にて用いられてきた。

また、検索データを用いた購買予測は、広告投下やキャンペーン時期の適正化といったマーケティング戦略の最適化にお

いて有効である。しかし、日本国内において従来研究で扱われてきたPOSデータや市場全体売上などの詳細な売上データを入手することは非常に困難であり、データの制約が従来モデルの再現を阻む課題となっている。

以上の背景から、本研究では入手が容易な公開データのみを用いた購買予測モデルの構築を目的とする。具体的には、売上データの代用としてAmazonのSales Rank(売上ランキング)データを、消費者の検討プロセスの指標としてGoogle Trendsの検索データを使用する。

モデル構築にあたっては、Duらの手法に準拠し、消費者の製品属性への関心を自己回帰モデルに組み込む。具体的には、「解像度」や「価格」といった製品特徴に関連するキーワードを組み合わせた複合クエリを作成し、日次で取得した検索トレンドを製品スペックと相互作用させる形でモデルに投入する[3]。

本研究では、自己回帰項と季節性を考慮したベースラインモデル( $M_0$ )に対し、製品特徴と検索トレンドの相互作用項を導入した提案モデル( $M_1$ )、およびカテゴリ全体の検索トレンドを導入した提案モデル( $M_2$ )の予測精度を平均絶対誤差(MAE)の改善量及び重みの割合を用いて比較評価する。本研究を通じて、限定的なデータ環境下におけるモデルの有効性と、実務的な需要予測における有用性を明らかにする。

## 2 関連研究

検索トレンドを用いた需要予測の有用性については、Choi and Varianによって広く示されている[4]。彼らはGoogle Trendsの検索データを用いることで、自動車や小売売上高などの経済指標を、従来指標のみを用いる場合よりも高い精度で短期予測できることを実証した。この知見は、消費者の潜在的な需要が実行前に先んじて検索行動に現れることを示唆している。

本研究がモデルの軸とするのは、Du et al.の市場反応モデルである[3]。彼らは自動車市場を対象に、製品属性に関連する検索語トレンドを複合クエリとして統合し、自己回帰モデルに組み込む手法を提示した。これにより、単一キーワードでは捉えきれない消費者の多角的な関心を把握し、予測精度を改善できることを示した。

一方で、国内EC市場への適用に際しては、売上データの入手の難しさがやはり課題となる。これに対し、Hollenbeck et al.は、Sales Rankがパレート分布に従う性質を利用し、順位を売上量に比例する指標へと変換する手法を提示している[7]。本来、変換に用いる形状パラメータ $\theta$ は実売上データから推定されるべきものであるが、本研究ではHollenbeck et al.が実データとの適合から導出したカテゴリ別のパラメータ値(例: Camera and Photo カテゴリでは $\theta = 0.713$ )を使用する。このアプローチにより、機密性の高い購買データを持たない制約下でも、Duらの提唱する高度な市場反応モデルの検証が可能

となる。

## 2.1 従来研究との相違点

本研究では、公開データのみを用いた分析フレームワークを構築する。従来、高精度な市場反応モデルの構築には機密性の高い実売上データや高価な POS データを用いることが一般的であったが、本研究では Google Trends による検索ボリュームと Amazon の Sales Rank という、いずれも容易に入手可能な公開データのみを組み合わせて分析を行う。これにより、データ取得が困難な個人研究者や中小規模の EC 事業者であっても、実効性のある需要予測が可能であることを示す点に実務的な意義がある。

さらに、パレート変換指標を用いた予測モデルの評価においても独自性がある。Hollenbeck et al. が提示した、Sales Rank を売上量インデックス  $Q$  へと変換する手法は、主にランキングの動態分析を目的としていたが、本研究ではこの  $Q$  を需要予測モデルにおける目的変数として直接採用する [7]。先行研究のパラメータ値を流用して生成した  $Q$  に対し、製品スペックを反映した検索データを統合して回帰モデルを構築し、MAE による予測精度の改善率を算出することで、代替指標を用いた需要予測モデルが実売上の動向をどの程度近似し得るかを定量的に検証している。

## 3 製品属性と検索行動を考慮した需要予測モデルの構成

本研究は、製品特徴に基づき検索語を収集・統合し、取得した検索トレンドとパレート変換を施した SR データを組み合わせることで回帰モデルを構築する。構築の手順を図 1 に記載する。



図 1: モデル構築フロー

### 3.1 対象とする商品カテゴリーの選定

本研究では「デジタルカメラ」および「洗濯機」の 2 種類を分析対象として選定した。これらを選定した理由は、物理的・定量的な製品特徴を複数持つこと、Amazon での購買行動が一定数見込めること、消費者が購入に至るまでに比較検討のプロセスを要する商材であることである。また、商取引における電子商取引 (EC) の浸透度を示す「EC 化率」が非常に高い点も評価した。経済産業省の調査 (令和 5 年度) によれば、物販系 BtoC-EC の中でも、デジタルカメラが含まれる AV 機器や、洗濯機が含まれる生活家電を含む「生活家電・PC・事務用品・AV 機器等」カテゴリーは EC 化率が突出して高く、2023 年度には 42.88% に達している。[8]。

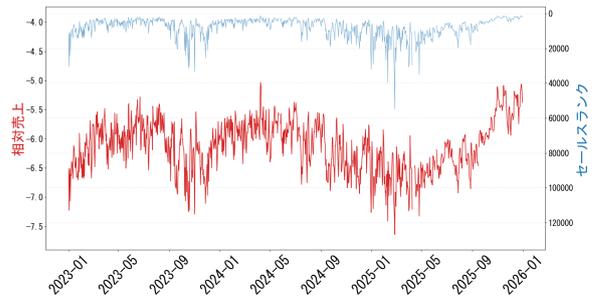


図 2: Sales Rank とパレート変換後の相対売上

選定した 2 カテゴリーは、本研究が提案するモデルの妥当性を検証する上で以下の適性を持っている。まずデジタルカメラは、「解像度」「ズーム倍率」「体積」といった物理的なスペック情報が豊富であり、趣味性の高い商材としてスペックの差異が消費者の関心 (検索行動) に直結しやすい。一方の洗濯機は、「洗濯容量」「自動投入機能の有無」「本体サイズ」といった生活実需に基づいた定量的な特徴を持ち、生活必需品としての安定した需要が存在する。これら 2 つのカテゴリーは、いずれも Amazon 内での取引が活発であり、セールスランク (SR) データが継続的に取得可能である。客観的な数値データとして特徴量を抽出しやすく、かつ EC での購買検討が一般化しているこれらのカテゴリーは、製品スペックと検索トレンドの相互作用をモデル化する本研究において適した分析対象である。

### 3.2 データの取得と整形

検索データは Google Trends の時系列データを用い、購買側のデータとしては Amazon における対象製品の Sales Rank を収集する。

データ取得期間については、2023 年 1 月 1 日から 2025 年 12 月 31 日までの 3 年間と設定した。これは、デジタルカメラ等の製品群において、詳細な履歴データを複数担保しつつ取得可能な限度期間に基づいている。データ粒度は日次での取得を実施した。

#### 3.2.1 購買データ

先に述べた通り、Sales Rank に対してはパレート変換を行う。SR は序数指標であるため、カテゴリー内順位  $r_{it}$  から売上量インデックス  $Q_{it}$  を構成する。

$$Q_{it} = A_c r_{it}^{-\theta_c} \quad (1)$$

ここで  $A_c$  は正規化定数、 $\theta_c$  はロングテールの強さを表す。なお本研究では、Hollenbeck et al. が実際の売上データとの適合から導出したカテゴリーの数値を流用する [7]。

図 2 はデジタルカメラカテゴリーから抜粋したプロダクトの Sales Rank と、その Sales Rank に対してパレート変換を行った結果を可視化したグラフである。

#### 3.2.2 製品特徴データ

本研究では、Amazon における製品の販売需要を予測するための説明変数として、表 1 に示す製品特徴データを収集した。各製品の一意の識別子である ASIN (Amazon Standard Identification Number) を基に、性能や価格に関する主要なスペックを抽出している。

表 1: デジタルカメラの製品特徴データ

ASIN	解像度	価格	体積	ズーム倍率
B09ZRN1N3Z	16	23400	119	5
B07G28MFV5	8	69900	282	40
⋮	⋮	⋮	⋮	⋮
B01C3S7B7G	16	17100	657	40

### 3.2.3 検索データ

取得後は、Google Trends から取得した検索トレンドに対して正規化処理を施す。この処理は、検索ボリュームの絶対値が異なるクエリ間での比較を可能にするとともに、回帰モデルへの投入を容易にすることを目的としている。

検索語の収集手順については、まず製品の特徴の特定に着手する。具体的には従来研究に準拠し、対象製品の性能や競争優位性を端的に示す主要なスペック項目を選定する。次に、特定した各スペックに対して複合クエリの作成を行う。これは、消費者が特定の性能を検索する際に併用する可能性の高い複数の関連語を統合し、一つの指標として扱う手法である。例えば「画素数」というスペックに着目する場合、「画素数」、「ピクセル」、「高画素」といった複数の類義語を組み合わせた複合クエリを構成することで、単一のキーワードでは捉えきれない市場の関心を包括的に集計し、分析に用いる変数としている。なお、クエリ作成の方法は主観性を減らすために、従来研究に準拠し 2 - 3 人の複数人で行う。

検索データの取得にあたっては、自動取得ツールではデータ粒度が週次に制限される課題があったため、日次データの精度を確保する目的で手動による収集を実施した。ただし、Google Trends の仕様上、一括で取得可能な日次データの期間は約 9 ヶ月以内に限定されており、出力される数値は各取得期間内の最大値を 100 とした相対値となる。そのため、分割取得した日次データをそのまま結合しても、期間ごとに基準 (100 の値) が異なるため、年間の季節性や長期トレンドを正しく反映することができない。そこで本研究では、1 年分を網羅した週次データを別途取得し、各期間の日次データの水準を統一することで補正を行っている。これにより、日次データの高い粒度を維持しつつ、マクロな季節性を正確に再現した指標を作成した。

一例として表 2 にデジタルカメラの複合クエリを記載する。

表 2: デジタルカメラの検索カテゴリと検索クエリ

カテゴリ	キーワード・関連用語
解像度	画素数、解像度、高画質、4K、画質比較
価格	安い、価格、値下げ、最安、予算
携帯性	コンパクト、小型、薄型、持ち運び、旅行用
光学ズーム	望遠、光学ズーム、ズーム倍率、遠く、野鳥

図 3 は取得した検索データを可視化したものである。

### 3.3 モデル化

本研究では、パレート変換によって得られた売上量インデックス  $Q$  を目的変数とし、検索トレンドを説明変数とした回帰分析を行う。モデルには、非線形な影響を柔軟に捉えることが可能な一般化加法モデル (GAM) を用いる。

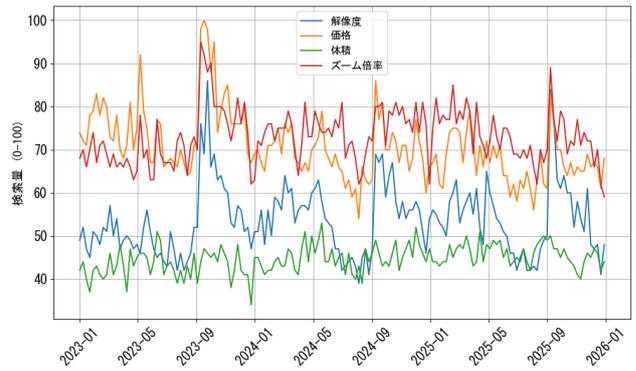


図 3: デジタルカメラの検索トレンド

■  $M_0$ : ベースラインのモデル 比較対象となるベースラインモデルは、過去の売上動態のみに依存する自己回帰モデルであり、次式で定義する。

$$\ln(Q_{it}) = \beta_i + \sum_{n=1}^N \rho_n \ln(Q_{i,t-n}) + \sum_{k \in K} \beta_k \ln(F_t) + \epsilon_{it} \quad (2)$$

ここで、 $\beta_0$  は製品固定効果、 $\rho_n$  は任意の自己回帰係数を表す。

■  $M_1$ : 製品特徴を含む提案モデル 提案モデル  $M_1$  は、ベースラインモデルに製品スペックに関連する検索トレンド変数を追加したものであり、次式で定義する。

$$\ln(Q_{it}) = \beta_i + \sum_{n=1}^N \rho_n \ln(Q_{i,t-n}) + \sum_{k \in K} \beta_k \ln(F_t) + \sum_{k \in K} \gamma_k (\ln(f_{ik}) \cdot \ln(z_{it,k})) + \epsilon_{it} \quad (3)$$

■  $M_2$ : カテゴリ検索を含む提案モデル 提案モデル  $M_2$  は、ベースラインモデルにカテゴリ全体の検索トレンド変数を追加したものであり、次式で定義する。

$$\ln(Q_{it}) = \beta_i + \sum_{n=1}^N \rho_n \ln(Q_{i,t-n}) + \sum_{k \in K} \beta_k \ln(F_t) + \sum_{k \in K} \gamma_k (\ln(Z_{k,t})) + \epsilon_{it} \quad (4)$$

$M_1$  及び  $M_2$  における各変数の定義は以下の通りである。まず、目的変数である  $\ln(Q_{it})$  は、製品  $i$  の時点  $t$  における販売ランキングをパレート変換によって算出した推定販売量  $Q_{it}$  の対数値である。モデルの基盤として、製品ごとのブランド力といった個体差を制御するため、ASIN ごとのダミー変数である製品固定効果  $\alpha_i$  を導入している。時間的な依存関係については、過去  $n$  日間の販売量に対する自己回帰係数  $\rho_n$  を用いてモデル化した自己回帰項と季節性を考慮するための  $F_t$  を用いることで時系列的な慣性を制御している。

$M_1$  の説明変数は、製品スペック  $k$  の公称値である  $f_{ik}$  と、それに対応する時点  $t$  の検索トレンド値  $z_{it,k}$  から構成される。これらは、市場全体の関心の高まりが売上のベースラインを押し上げる効果を示す検索トレンドの重み  $\beta_k$ 、および検索の盛り上がり製品特徴の重要性を変化させる効果を示す相互作用係数  $\gamma_k$  によって重み付けされる。

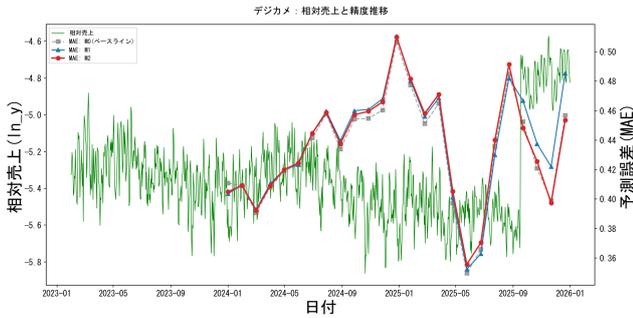


図 4: デジタルカメラカテゴリにおいて取得した商品すべてを対象とした検証結果

$M_2$ の説明変数は、製品スペック項の部分にカテゴリ全体の検索トレンド値  $Z_{k,t}$  を採用した。

#### 4 評価

予測性能の評価には、ベースラインモデル ( $M_0$ ) に対する MAE (平均絶対誤差) の改善率 (Improvement) を用いる。

$$\text{Improvement} = \frac{\text{MAE}_{M_0} - \text{MAE}_{M_1 \text{ or } M_2}}{\text{MAE}_{M_0}} \quad (5)$$

また、各モデルにおける外部変数の寄与度を測る指標として、自己回帰項の係数に対する「検索の重みの合計 (絶対値)」の割合を算出する。Du らの従来研究における基準値 (平均 MAE : 0.331、MAE 改善量 : 10.3%、自己回帰項に対する検索重み : 94.0%) [1] を一つのベンチマークとし、本研究のモデルの妥当性を判定する。

本研究の実行環境は、Python (Pandas, NumPy, statsmodels, matplotlib) を用いて前処理・可視化およびモデリングを行い、Windows 11 上の Intel Core i7 / 16 GB RAM 環境で実施した。

#### 4.1 売上上位 10 個体における有効性の境界条件

実験を始めるにあたり、当初は取得した商品すべてのデータを対象として実験を行った。結果は図 4 である。これと対象とするカテゴリ内の商品の年間 Sales Rank の平均を順位付けし、上位 10 個体を選別したときの平均 MAE を比較した。その結果、平均 MAE がそれぞれ 0.4356、0.371 となり、14.8% 程度上位 10 個体を選別した時に有意な結果となった。よって本節では、取得した商品内における Sales Rank 上位 10 個体を対象としたロールウィンドウ方式による検証結果を述べ、モデルが有効に機能するための境界条件を特定する。

##### 4.1.1 デジタルカメラカテゴリでの精度検証結果

デジタルカメラの TOP10 製品における検証結果を図 5 に示す。

デジタルカメラの TOP10 製品における検証結果を確認すると、2024 年度は改善率が  $-5.38\%$  と悪化した一方で、2025 年度はモデル  $M_1$  において  $+1.63\%$  の改善を達成しており、年度によって有効性が反転する現象が確認された。2025 年度は自己回帰項の係数が前年度より上昇しており、基調となる需要予測の安定性が外部変数の寄与を補助していることを示唆している。

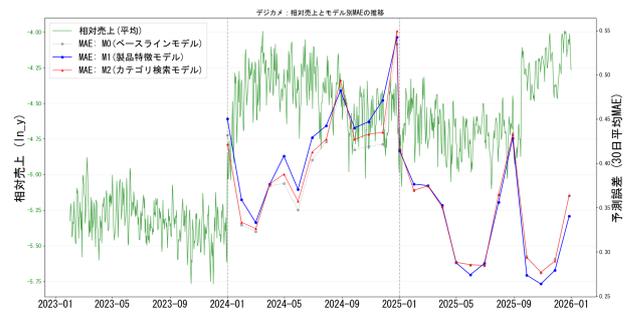


図 5: 相対売上と MAE 推移：デジタルカメラ



図 6: 相対売上と MAE 推移：洗濯機

#### 4.1.2 洗濯機カテゴリでの精度検証結果

洗濯機カテゴリの TOP10 製品における検証結果を図 6 に示す。

洗濯機カテゴリの TOP10 製品における検証結果を見ると、デジタルカメラ同様、年次によって外部変数の説明力が大きく変質する結果となった。2024 年度評価では、 $M_1$  が  $+2.80\%$ 、 $M_2$  が  $+0.63\%$  とともに精度改善を達成した。しかし、2025 年度評価では一転して大幅な精度悪化を記録している。図 6 を確認すると、2025 年度は相対売上上の振幅が極めて大きく、MAE も  $0.5165$  と非常に高い水準で推移している。この時期は従来の需要パターンから逸脱した傾向が発生しており、外部変数が予測のシグナルとしてではなく、かえってノイズとして作用した可能性が高い。

#### 4.1.3 結果

前節までの検証結果を踏まえ、本研究ではモデルの有効性を規定する要因として以下の 2 点を考察した。第一に、導入する外部変数の性質と予測精度の相関についてである。具体的には、MAE (平均絶対誤差) の平均改善率が正の値を示す局面、すなわち予測精度が向上する条件下では、具体的なスペックを反映した「製品特徴モデル ( $M_1$ )」が高い優位性を示す。一方で、改善率が負に転じるような予測困難な局面においては、広範な需要トレンドを捉える「カテゴリ検索モデル ( $M_2$ )」の方が、精度の悪化を最小限に留める傾向が見られた。このことから、市場の安定性やデータの性質に応じて、参照すべき外部変数の最適解が異なる可能性が示唆される。なお、予測精度の妥当性を判断する閾値については、Du らによる先行研究の成果に基づき、MAE の上限を  $33\%$  に設定し、これをモデルの有用性を評価する一律の基準とする [3]。第二に、時系列予測におけるラグ設定の妥当性についてである。先行研究が月次データを基盤としていた点、および本研究で使用可能なデータ期間が最

大2年間という制約下にある点を考慮すると、過度に長いスパンのラグを設定することは自由度の低下や過学習を招く恐れがある。したがって、本モデルにおけるラグの上限は30日として固定し、日次データの特性を維持しつつ、月次の季節性までを内包する設計が適切であると考えられる。以上の考察から生まれた仮説を検証するため、ラグの初期値を動的に変化させる追加実験を実施する。本実験の目的は、ラグの範囲を2日から14日まで幅広く設定することで、MAEが先行研究の基準値である33%に最も近似する最適な時間的パラメータを特定することにある。同時に、市場環境の変動（改善率の正負）に関わらず、「精度改善局面では製品特徴モデルが、精度悪化局面ではカテゴリ検索モデルが優位である」という傾向が通時的に成立するかを検証し、提案モデルの頑健性と有効境界を明確化する。

#### 4.1.4 ラグの初期値 2-14 での検証

本節では、モデルが有効に機能するための時間的境界条件を特定するため、過去の売上データを参照する起点となるラグの初期値 (Start Lag) を2日から14日まで変化させた追加検証の結果を述べる。検証結果を整理した各表において、Start Lagは予測日を基準として何日前までの実績をモデルの入力から除外するかを示しており、M1\_Imp および M2\_Imp はベースモデル (M0) に対する製品特徴モデル (M1) およびカテゴリ検索モデル (M2) の MAE (平均絶対誤差) の改善率をパーセンテージで表している。また、AvgProposed MAE は提案手法を用いた際の予測誤差の平均値であり、これが低いほど高い予測精度を意味する。M1 および M2 の Weight Ratio は、モデルが自己回帰項という過去の売上実績に対して、外部変数の重みをどの程度の比率で割り当てたかを示す統計量であり、モデルが外部情報にどの程度依存して予測を生成したかを測る指標となる。

デジタルカメラカテゴリのラグ別サマリーを確認すると、2024年度(表3)と2025年度(表4)でモデルの有効性が対照的な挙動を示していることが分かる。2024年度においては、ラグの初期値を2日から14日まで広げるに従い、AvgProposed MAEが0.3314から0.4826へと一貫して上昇しており、予測精度はラグの設定に関わらず悪化傾向にある。これに対し、2025年度はすべてのラグ設定において改善率が正の値を維持しており、特にラグ7を設定した際にMAEが0.3334と、Duらの先行研究における基準値33.1%に最も近似する結果が得られた。このことは、市場が安定している状況下ではラグ7という設定が予測精度と説明力の均衡点であることを示唆している。また、改善率がプラスを維持する2025年度においてM1の改善率がM2を一貫して上回っている事実は、予測が有効に機能する局面では抽象的な検索キーワードよりも具体的な製品スペックの方が高い説明力を有することを示している。

洗濯機カテゴリにおいても、デジタルカメラと同様に年度ごとの需要の質がモデルの精度を左右する結果となった。2024年度(表5)の検証では、ラグの初期値を広げるほどM1モデルの改善率が向上する傾向が見られ、特にラグ13において最大4.11%の精度改善が確認された。MAEの推移に着目すると、ラグ6からラグ7の間で先行研究の基準値である33%を跨いでおり、この範囲が実用的な予測を行える境界条件の一つであ

表 3: デジカメカテゴリのラグ別サマリー (2024)

Start Lag	M1_Imp (%)	M2_Imp (%)	AvgProposed MAE	M1_Weight Ratio (%)	M2_Weight Ratio (%)
2	-7.1670	-1.1381	0.3314	55.4683	6.9834
3	-4.9122	-1.3276	0.3550	109.3011	12.3484
4	-2.9191	-1.4628	0.3708	148.1293	18.6729
5	-2.8399	-1.5053	0.3845	198.1078	23.8290
6	-3.3412	-1.6806	0.3975	232.4884	28.1427
7	-5.3836	-1.7489	0.4123	218.8873	23.4303
8	-7.0216	-1.8021	0.4312	281.2951	27.0635
9	-6.8192	-1.8382	0.4443	423.6135	41.1430
10	-6.6906	-1.8256	0.4533	581.9603	58.0175
11	-6.5731	-1.8453	0.4599	847.4824	85.0435
12	-6.2741	-1.8701	0.4642	874.1730	93.1892
13	-6.4985	-1.8525	0.4693	419.2119	43.4586
14	-7.6528	-1.8992	0.4826	302.3087	30.7397

表 4: デジカメカテゴリのラグ別サマリー (2025)

Start Lag	M1_Imp (%)	M2_Imp (%)	AvgProposed MAE	M1_Weight Ratio (%)	M2_Weight Ratio (%)
2	0.7963	0.0198	0.2616	19.5555	1.1552
3	1.9311	0.0476	0.2873	30.4970	1.6912
4	2.2538	0.0391	0.3019	56.0319	2.0715
5	2.1929	0.0455	0.3132	81.2162	2.8120
6	2.0297	0.0708	0.3231	85.4830	3.9297
7	1.6301	0.0969	0.3334	75.5218	4.4198
8	1.1944	0.0921	0.3455	88.7729	4.7678
9	1.5650	0.0871	0.3561	133.7602	6.8264
10	1.9089	0.0913	0.3628	155.9140	7.3740
11	2.1360	0.0932	0.3686	198.8659	8.6560
12	2.5062	0.0856	0.3734	247.2578	10.2259
13	2.3919	0.0923	0.3783	163.8902	7.0483
14	2.1538	0.1148	0.3862	110.6689	5.5072

ると考えられる。一方で、2025年度(表6)の結果は極めて特異であり、ラグ3以降で改善率が急激にマイナスへと転じ、ラグ13では-11.7%という大幅な精度悪化を記録した。この期間のMAEは最小でも0.2117、最大で0.7361と極めて激しく変動しており、需要の振幅が従来の予測モデルの受容範囲を大幅に超えている。このような非定常なショックが発生している局面では、過去の情報を参照するためのラグを増やすほど、モデルが不規則な変動を過剰に学習し、結果として予測の誤差を増幅させる可能性が示唆された。

表 5: 洗濯機カテゴリのラグ別サマリー (2024)

Start Lag	M1_Imp (%)	M2_Imp (%)	AvgProposed MAE	M1_Weight Ratio (%)	M2_Weight Ratio (%)
2	-0.1009	-0.0297	0.2111	3.3961	0.6425
3	0.4798	0.0577	0.2495	4.3548	1.3008
4	1.4495	0.2134	0.2787	17.3955	2.3864
5	2.0381	0.6835	0.3020	28.2181	6.8333
6	2.7967	0.8361	0.3204	33.5500	7.7674
7	2.8041	0.6283	0.3389	29.7816	5.3447
8	2.2633	0.5648	0.3572	24.3469	4.6285
9	2.7908	0.6289	0.3706	44.5986	7.4042
10	3.4431	0.8453	0.3809	54.7963	10.5668
11	3.6222	1.0737	0.3889	56.0602	12.6628
12	3.9204	1.1644	0.3960	75.9717	17.4005
13	4.1070	1.2527	0.4026	82.0164	16.9947
14	3.9321	1.1312	0.4098	96.8885	18.0517

#### 4.1.5 考察

本研究における一連の検証により、予測モデルの精度と実務上の有用性の間には明確なトレードオフが存在することが明らかとなった。図7に示される通り、ラグを拡大させるほど全ての条件下でMAEは増大する傾向にある。また、別途行った週次、月次での検証結果である表7が示すように、週次や月次といった集計粒度の変更は一時的に改善率を向上させる可能性はあるものの、MAEの絶対値を先行研究の実用基準値である33%から悪化させる結果を招く。特にラグ2から14までの検証結果を横断的に分析した結果、ラグ7が実務におけるリード

表 6: 洗濯機カテゴリのラグ別サマリー (2025)

Start Lag	M1_Imp (%)	M2_Imp (%)	AvgProposedMAE	M1_Weight Ratio (%)	M2_Weight Ratio (%)
2	6.3245	0.0221	0.2117	5.6344	0.0297
3	2.5698	-1.4153	0.2851	9.1009	2.6592
4	-5.6740	-1.7151	0.3564	7.1831	4.4019
5	-11.3461	-2.0625	0.4209	15.6962	7.2526
6	-11.8457	-1.9908	0.4686	17.6636	7.8634
7	-7.4347	-1.5085	0.5022	13.0585	6.1467
8	-4.2222	-1.1969	0.5362	10.3975	5.5515
9	-5.6736	-1.3196	0.5791	15.0956	7.8342
10	-6.8620	-1.4421	0.6165	22.1008	11.2573
11	-7.7236	-1.5529	0.6477	27.2342	14.0433
12	-10.4395	-1.6268	0.6847	40.3883	18.2291
13	-11.7015	-1.5841	0.7134	41.2189	17.2032
14	-11.2326	-1.4247	0.7361	40.6151	15.4893

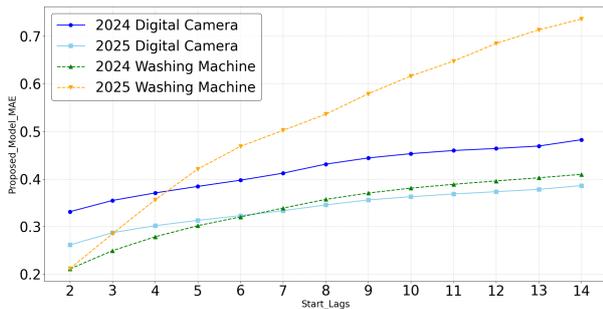


図 7: ラグごとの MAE

表 7: 分析粒度別の平均精度比較

分析単位	M0 MAE	M1 MAE	M2 MAE	M1	M2
				改善率 (%)	改善率 (%)
週次	0.4109	0.4411	0.4057	-8.97	+1.81
月次	0.5137	0.5717	0.5221	-19.12	-0.48

タイムの確保と誤差の抑制を両立させる閾値である。以上のことから、実用面においては製品特徴モデル ( $M_1$ ) を日次粒度かつラグ 7 日の設定で運用することが、需要を予測する十分なリードタイムを確保しつつ、在庫や販促の最適化といったマーケティング上の意思決定に寄与する最も有用な構成である。

## 5 おわりに

本研究では、実購買データの取得が困難な制約下において、Google Trends の検索データと Amazon の Sales Rank (SR) に対するパレート変換を組み合わせた需要予測モデルを提案し、その有効性を検証した。検証の結果、デジタルカメラカテゴリにおいては、2024 年度の改善率が  $-5.38\%$  と悪化した一方で、2025 年度にはモデル  $M_1$  において  $+1.63\%$  の精度改善を達成した。また、洗濯機カテゴリにおいても、2024 年度は  $M_1$  で  $+2.80\%$ 、 $M_2$  で  $+0.63\%$  の改善が見られたが、売上の振幅が激しい非正常な局面となった 2025 年度には、一転して改善率が  $-7.43\%$ 、MAE が  $0.5165$  と大幅に悪化する結果となった。これらの定量的な推移から、提案モデルの有効境界が特定された。具体的には、予測精度の基準 (MAE) が先行研究の指標である  $33\%$  ( $0.33$ ) 前後を維持できている定常的な市場環境においてのみ、外部変数の導入が有効に機能することが明らかになった。

今後の展望としては、予測の頑健性をさらに高めるために、現在の外部変数に加えてマーケティング・ミックスの要素をより多角的に取り込む必要がある。具体的には、YouTube の動

画再生数や Meta 広告ライブラリから取得できる広告出稿状況などの代用データを導入することで、消費者の認知から購買に至るまでのプロセスをより精密にモデル化し、自社の施策が必要に与える影響を動的に把握することが期待される。また、プロダクトの性質や製品特徴の抽出プロセスにおいて、大規模言語モデル (LLM) を活用したアプローチの導入も重要である。EC サイトの利用率や生活需要の切迫度といった定性的なコンテキストを前提条件として入力し、LLM を用いて潜在的な重要特徴量を生成・特定することで、モデルの入力変数を高度化できる。このような検証を繰り返すことにより、どのようなカテゴリのプロダクトが、どのような製品特徴の変化によって最も強く需要を喚起されるのかという、製品特性と外部変数の相関を示す定量的な指標を確立することが可能となる。

## 参考文献

- [1] 経済産業省, 「電子商取引に関する市場調査」, 2023. <https://c-portal-connect.com/info/2023ec>
- [2] Agriculture and Agri-Food Canada, “Sector Trend Analysis – E-Commerce market trends in Japan,” 2023. <https://agriculture.canada.ca/en/international-trade/market-intelligence/reports-and-guides/sector-trend-analysis-e-commerce-market-trends-japan>
- [3] Du, R. Y., Hu, Y., Damangir, S. (2015). Leveraging trends in online searches for product features in market response modeling. *Journal of Marketing*, 79(1), 29–43. <https://doi.org/10.1509/jm.13.0495>
- [4] Choi, H., Varian, H. (2012). Predicting the present with Google Trends. *Economic Record*, 88(S1), 2–9. <https://doi.org/10.1111/j.1475-4932.2012.00809.x>
- [5] Chevalier, J. A., Mayzlin, D. (2006). The effect of word of mouth on sales: Online book reviews. *Journal of Marketing Research*, 43(3), 345–354. <https://doi.org/10.1509/jmkr.43.3.345>
- [6] Andersen, A. L., Hansen, E. T., Johannesen, N., Sheridan, A. (2020). Pandemic, shutdown and consumer spending: Lessons from Scandinavian policy responses. *Proceedings of the National Academy of Sciences*, 117(34), 17209–17214. <https://doi.org/10.1073/pnas.2012145117>
- [7] He, Sherry, and Brett Hollenbeck (2020). Sales and Rank on Amazon.com. SSRN Working Paper. <https://doi.org/10.2139/ssrn.3728281>
- [8] よむよむカラーミー編集部 (2024). 日本の EC 化率は? 国内のジャンル別 EC 化率や世界の状況も解説! . よむよむカラーミー. <https://shop-pro.jp/yomyom-colorme/97178>