

小売店における商品特性の時系列変動パターンと 需要予測精度の関係分析

Analysis of Relationship Between Time Series Variation Patterns of Product Characteristics and Demand Forecast Accuracy in Retail Stores

安田 大誠 *¹ 吉野 孝 *² 松山 浩士 *³

Taisei Yasuda Takashi Yoshino Koji Matsuyama

*¹ 和歌山大学大学院システム工学研究科 Graduate School of Systems Engineering, Wakayama University

*² 和歌山大学システム工学部 Faculty of Systems Engineering, Wakayama University

*³ 株式会社サイバーリンクス Cyber Links Co., Ltd.

要旨: 店舗経営において重要な問題となるのが在庫管理である。既存研究として、消費者の行動やPOSデータを用いて予測を行う研究がなされている。また、企業による需要予測システムの開発も数多く行われているが、全ての商品を高精度で予測出来ているわけではない。そこで、我々は「需要予測に適した商品と適さない商品を、あらかじめ分類する」という目的で研究を行っている。その中で今回は、商品特性の時系列変動パターンに着目し分析を行う。商品の定性的な性質（日常的に売れる・売れない、旬のとき・そうでないとき、値段の高いとき・安いとき）と、我々が提案する商品分類との関係性について検証する。

キーワード: POS データ, 需要予測, 階層クラスタリング

Abstract: Inventory management is an important issue in shop management. In existing research, there are studies on forecasting using consumer behavior and POS data. In addition, many companies have developed demand forecasting systems, but not all products can be forecasted with high accuracy. Therefore, our research aims to classify in advance the products which are suitable for demand forecasting and those which are not. In this study, we focus on the time series variation pattern of product characteristics. We examine the relationship between the qualitative characteristics of products (routinely sold/not routinely sold, in season/not in season, high price/low price) and the product categories we propose.

Keywords: point of sale (POS) data, demand forecasting, hierarchical clustering

1 はじめに

店舗経営において重要な問題となるのが在庫管理である [1]。在庫が増えすぎると管理維持費の負担増加や、売れ残りによる廃棄金額の増加といった問題が発生する。逆に在庫が不足すると販売機会の喪失や、品揃えの悪さによる顧客減少といった問題が起こる可能性がある。ゆえに、売れる数だけ商品を仕入れる必要があるが、全ての商品がいくつ売れるのか人手で予測するのは非常に困難である。企業による需要予測システムの開発が数多く行われているが、全ての商品を高精度で予測出来ているわけではない。そこで、我々は「需要予測に適した商品、あるいは適さない商品を、あらかじめ発見する」という目的で、「POS データ 5 分類手法 (以降、5 分類手法と呼ぶ)」の研究を行っている。5 分類手法は、機械学習による需要予測に向いているデータ、不向きなデータ

を調査することで、機械学習させる前に予測の可否を判断する。5 分類手法の詳細は、次の 2 章で説明する。

本研究では、5 分類手法と、商品の定性的な性質との関係性について分析を行う。定性的な性質とは、日常的に売れる・売れない、旬のとき・そうでないとき、値段の高いとき・安いとき、などの商品が持つ情報のことを指す。例えば、季節によって値段が変動する商品は、旬になればなるほど値段が安くなり、品質も良く、需要が高まる。逆に旬から外れたときほど値段が高くなり、需要も少なくなる。しかし、旬を外れたときにもその商品を食いたいという需要があった場合には、高い値段でも売れる可能性が高い。すなわち、旬などの「定性的な性質」という観点で需要が変化することにより、予測の可否が判断できると考える。以上をふまえ、本稿における分析は次の手順で実施した。各手順の詳細については、4 章で説明する。

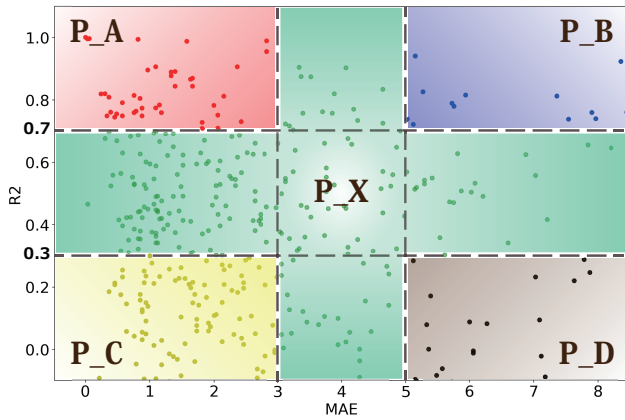


図 1: 5 分類手法の分類境界

1. 商品全体から、ABC 分析により主力商品に対象を絞る。
2. 商品の定性的な性質を、階層クラスタリングにより分類する。
3. 分類された商品の定性的な性質ごとに、5 分類手法により時系列的な評価を行う。

2 POS データ 5 分類手法

先行研究 [2] では、POS データを 5 分類^{*1} し、それが売上個数のばらつきや説明変数の重要度等の影響によるものだという知見が得られている。5 分類手法は、ランダムフォレストで需要予測を行い、評価指標により予測対象を 5 分類する手法である。評価指標には、決定係数^{*2} (以降、 R^2) と平均絶対誤差^{*3} (以降、 MAE) の 2 種類を用いる。 R^2 は予測モデルの当てはまり度を示す指標であり、 MAE は予測値の正確さを表す指標である。これら 2 つの評価指標の組み合わせにより、次のように 5 分類は定義^{*4} される。

パターン A (P_A): R^2 と MAE が共に高精度

パターン B (P_B): R^2 は高精度だが MAE は低精度

パターン C (P_C): R^2 は低精度だが MAE は高精度

パターン D (P_D): R^2 と MAE が共に低精度

パターン X (P_X): 上記の分類に該当しないもの

図 1 に、5 分類手法の分類境界を示す。縦軸は R^2 、横軸は MAE を示している。また、図 1 にプロットされている各点は、本研究で用いた小売店のデータを表している。

^{*1}先行研究で示されていたのは 4 分類であるが、どれにも当てはまらない分類が存在していたため、本研究では 5 分類としている。

^{*2}
$$R^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y^{(i)} - y_{pred}^{(i)})^2}{Var(y)}$$
 Var: 分散

^{*3}
$$MAE = \frac{1}{n} \sum_{i=1}^n |y^{(i)} - y_{pred}^{(i)}|$$

^{*4}損益計算により算出している。 R^2 の高精度は 0.7 以上、低精度は 0.3 以下。 MAE の高精度は 3.0 以下、低精度は 5.0 以上。

3 関連研究

3.1 需要予測に関する研究

今井らは、日用品市場における新製品売上予測モデルを開発した [3]。消費者調査データを元に、経験不足の人材でも新商品の予測を行えるモデルを構築している。Victor らは、ソーシャルメディアを用いた個人消費の予測手法を提案した [4]。ソーシャルメディアによる購入意思と意味ベクトルを用いた回帰モデルを作成し、消費支出を予測する。Xiaotong らは、パーソナリティ分析を用いた購買行動を理解するための計算手法提案した [5]。性格特性、消費嗜好、商品の属性間の相互作用のような購買行動をモデル化している。若林らは、ディープラーニングを用いた顧客の購買行動予測の検討を行った [6]。EC サイト上における顧客のアクセス行動をディープラーニングで学習し、顧客の購買行動を予測する。いずれの研究においても、顧客の属性や行動を用いた需要予測を行っている。本研究では、POS データを用いて需要予測を行い、精度ごとの POS データの特徴を分析する。

3.2 POS データを用いた需要予測に関する研究

Rakesh らは、大規模な購買データの相関ルールの抽出手法を提案した [7]。相関ルールマイニングと剪定関数を組み合わせることで、データベースにおいて 5% 以上存在しているアイテムセットを発見する。宗形らは、推定マーケットデータを用いた消費財系新製品の需要予測手法を提案した [8]。短期間のデータを用いて、製品寿命と累積総需要量から需要予測を行う。石垣らは、購買行動に関する大規模データの融合による顧客行動予測システムを開発した [9]。POS データと顧客へのアンケート結果を用いて、顧客の購買行動を計算モデル化している。Yi らは、統計的学習理論を用いた消費者の購買行動の予測手法を提案した [10]。POS データと RFID による店内行動から、SVM を用いて購買行動を予測する。いずれの研究においても、売上予測は可能であるという結果が示されているが、特定の種類の商品を対象としており、全ての商品に対応できるかはわからない。本研究では、POS データを用いて予測できる商品と予測できない商品にどのような特徴があるか分析を行う。

4 商品特性の時系列変動パターン

4.1 使用データ

分析で用いたデータは、ある小売店（店舗規模は全店で 7 店舗）の 5 店舗分の POS データである。データの期間は、2015 年 11 月 30 日から 2017 年 1 月 3 日（元日は除く）の 400 日分となっている。表 1 に、400 日のデータ期間内において、各店舗で売上が記録された商品

表 2: 使用したデータ項目

データ項目名
日付 (年/月/日)
曜日
客数
売上数量
販売価格
特売価格
予報午前降水確率
予報午前気温
予報午後降水確率
予報午後気温

表 1: 店舗名と取扱品目数

店舗名	品目数
店舗 2	15363
店舗 3	11056
店舗 5	13779
店舗 7	13660
店舗 8	14363

表 3: ABC 分析の結果

店舗名	A ランク	B ランク	C ランク
店舗 2	2401	1963	10999
店舗 3	1819	1464	7773
店舗 5	2103	1777	9899
店舗 7	2258	1779	9623
店舗 8	2344	1974	10045

の品目数を示す。また、表 2 に、使用したデータ項目の一覧を示す。

4.2 ABC 分析

ABC 分析とは、優先的に管理する対象を決めるための分析フレームワークである。^{*5} パレートの法則^{*6} に基づいて、商品の売上高や販売個数、あるいはコストや在庫など重要度が大きい順にランク付けを行う。

本研究では、表 1 に示した各店舗の商品 1 品目ごとに、売上金額を集計した。そして合計売上金額を降順に並び替えたときの、累積比率 80%未満を A ランク、80%以上 90%未満を B ランク、90%以上を C ランクとしてランク付けを行った。表 3 に、ABC 分析の結果を示す。各店舗の A ランク商品は 2000 品目前後となり、このうち 1169 品目が全店舗間において同一商品であった。B ランク商品は 2000 品目弱であり、このうち 185 品目が全店舗間において同一商品であった。ゆえに、A ランク商品は 5 店舗において同一商品が過半数を占めるため、主力商品として捉えることができる。

4.3 階層クラスタリング

本研究では、階層クラスタリングを適用し分類を行うことにより、商品の定性的な性質を見つけ出す。4.2 節

^{*5}重点分析とも呼ばれる。

^{*6}「80:20 の法則」とも呼ばれる。イタリアの経営学者ヴィルフレド・パレート (1848~1923) が提唱した。世の中の様々な事象は決して平均的でなく、偏りがあるという考え方。




図 2: デンドログラム (店舗 2, A ランクの商品, 売上数量)


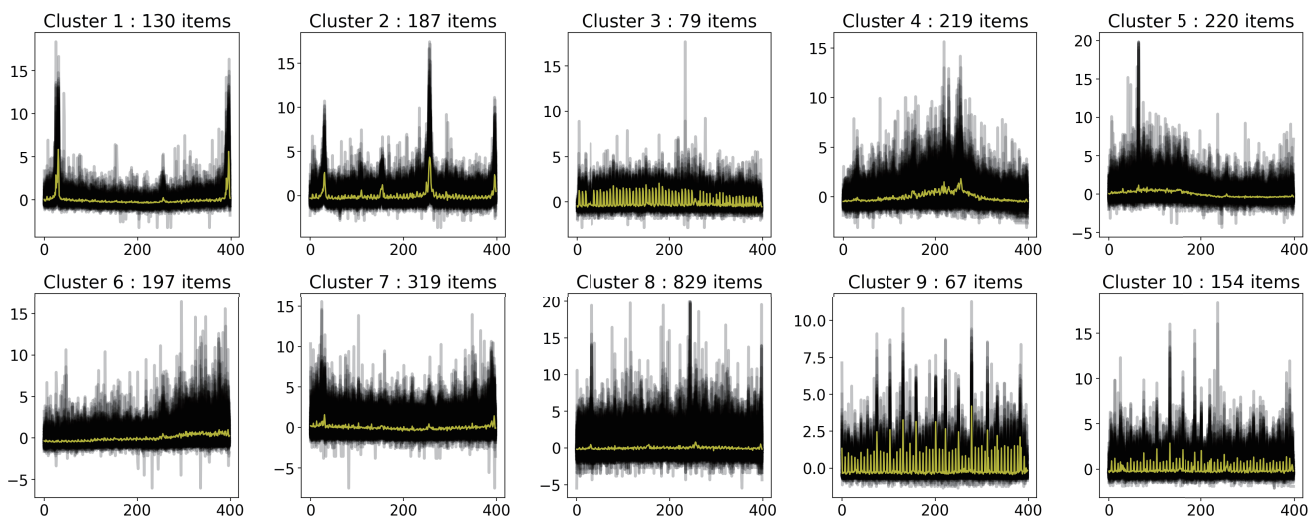


図 3: クラスタ数の評価 (店舗 2, A ランクの商品, 売上数量)

にて A ランクに振り分けられた商品を対象に、階層クラスタリングを実行した。クラスタリングを試みたデータは、「売上数量」および「販売価格」の時系列データである。商品間で扱うデータの大きさ (スケール) が異なるため、クラスタリングを実行する前にデータ全体を正規化している。本研究では平均 0, 分散 1 となる標準化を適用した。

図 2 に、階層クラスタリングの結果であるデンドログラムを示す。縦軸はクラスタ間の距離を、横軸は各商品を表している。クラスタ間の距離にはユークリッド距離を、クラスタ併合における距離の更新方法にはワード法を用いた。

クラスタ数に関しては 2 から 10 までの間で計算を行い、“Silhouette Coefficient”[11] と “Davies-Bouldin Index”[12] により評価した。ここで、“Silhouette Coefficient”は値が高い程良く、“Davies-Bouldin Index”は値が低い程良い。ゆえに、最適なクラスタ数が 2 つ算出されることがあるが、その場合は 2 値のうち大きいクラスタ数を採用する。図 3 に、クラスタ数を 2 から 10 まで変化させたときの “Silhouette Coefficient” と “Davies-Bouldin Index” の値を示す。図 3 は、店舗 2 の A ランクのデータを用いたときのものである。“Silhouette Coefficient”基準では最適クラスタ数が 10 (図 3 赤丸部分)、“Davies-Bouldin Index”基準では最適クラスタ数が 8 (図 3 赤丸破線部分) となるため、最適クラスタ数は 10 と評価した。



※ 縦軸は標準化後の売上数量 (個) を表し、横軸は 400 日分のデータ期間が 0 から 399 に対応している。
また、黒線は各商品の標準化後の時系列売上数量を、黄線はクラスター内データ (全ての黒線) の平均値を表している。

図 4: 各クラスターの標準化データ (店舗 2, A ランクの商品, 売上数量)



図 5: ワードクラウド (店舗 2, A ランクの商品)

4.4 商品特性の時系列変動パターンとカテゴリ名

図 4 は、4.3 節にて 10 クラスターに分類された各商品 (店舗 2 の A ランク商品) の売上数量に標準化処理を行い、時系列プロットしたものである。図 4 の各グラフの縦軸は標準化後の売上数量を表し、横軸は 4.1 節にて説明した 400 日分のデータ期間を 0 から 399 に対応させたもの、黒線は各商品の標準化後の時系列売上数量を、黄線はクラスター内データ (全ての黒線) の平均値を、タイトルはクラスター番号とそのクラスターに分類された商品数を表示している。クラスター 1 は年末年始に需要の波があることが、クラスター 2 は夏冬両方に需要の波が、クラスター 4 は夏頃のピークが、クラスター 5 とクラスター 6 はそれぞれ右肩下がり と 右肩上がりのトレンドを形成していることが確認できる。クラスター 3 とクラスター 9、クラスター 10 は、クラスター平均の小さな動きから日常的に売れるような商品分類であると推察される。縦軸の標準化後の売上数量をみると、クラスター 3 のみ同程度の大きさの波が繰り返されているのに対し、クラスター 9 とクラスター 10 は 2 種類の大きさの波が組み合わさって繰り返されており、クラスター 9 の方がその傾向は顕著である。829 品目

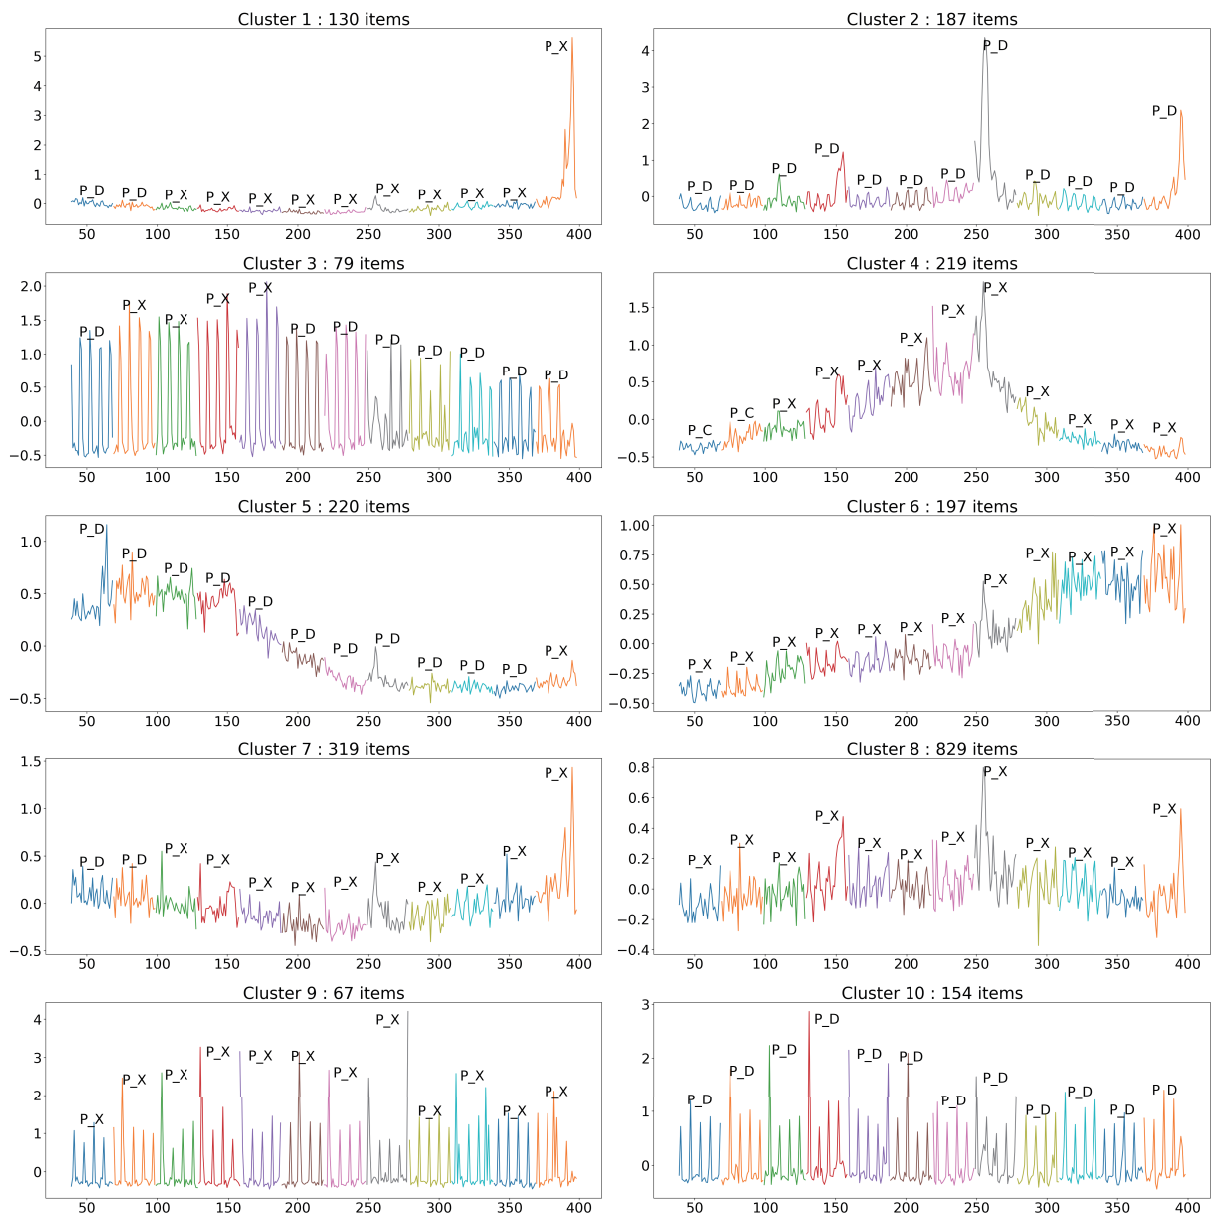
と、最もクラスター内の商品数が多くなったクラスター 8 に関しては、クラスター形成できるほどの特徴や性質を持たない商品分類であると推察される。

図 5 に、4.3 節にて分類された各クラスターに対しワードクラウドを適用した結果を示す。図 5 のクラスターは、図 4 のクラスターとそれぞれ対応している。なお、ワードクラウド生成に用いた文字列は具体的な商品名を避けるため、各クラスターで重複するものはあるが、各商品の最も詳細なカテゴリ名を用いている。日常的に売れるような商品分類であると推察したクラスター 3 とクラスター 9、クラスター 10 は、「魚介類」「揚物」「清酒」「和生菓子」「牛乳」というようなカテゴリ名が確認できる。また、季節のトレンドがみられたクラスター 5 とクラスター 6 では、それぞれ「バナナ」と「トマト」という特徴的なカテゴリ名を確認した。

5 5 分類手法を用いた時系列分析

5.1 分析方法

我々が取り組む 5 分類手法と、4 章にて分類した商品特性の時系列変動パターンとの関係性を分析する。分析



※ 縦軸は標準化後の売上数量 (個) を表し、横軸は 400 日分のデータ期間が 0 から 399 に対応している。
 また、グラフはクラスタ内データの平均値を、グラフの各色は左から順に 1 月度の検証から 12 月度の検証までをそれぞれ表している。

図 6: 分析結果 (店舗 2, A ランクの商品)

目的は、商品特性パターンの時系列変動が確認された各クラスタにおける、需要予測精度との共通した関係性の有無を明らかにすることである。分析方法としては、時系列データを約 1 か月ごとに分割^{*7}し、各月の需要予測を行う処理に対して、各クラスタの商品内で 4 分割交差検証を行う。需要予測は、2 章の 5 分類手法と同様、ランダムフォレストを用いた。学習データは 1 分割目から順に 1 分割ずつ増やし、検証データは学習データに続く分割データを使用することで、12 か月分の検証を行った。

^{*7}2015 年 11 月 30 日から 2017 年 1 月 3 日までのデータ期間 (元日は除く) であったため、2015 年 12 月度から 2016 年 12 月度までの 13 か月とみなし、400 日を 13 分割した。Python のオープンソース機械学習ライブラリである scikit-learn に用意された分割関数を用いたところ、最初の分割が 35 日、残りの 12 分割が 28 日となった。

5.2 分析結果と考察

図 6 に、分析結果を示す。図 6 の各グラフの縦軸と横軸とタイトルはそれぞれ、図 4 と同様に標準化後の売上数量と、400 日分のデータ期間を 0 から 399 に対応させたものと、クラスタ番号とそのクラスタに分類された商品数を表している。色付けされたグラフは、クラスタ内データの平均値を表しており、各色は 5 分類手法が適用された期間を表している。各色のグラフの上部には、5 分類手法におけるパターン分類が記されている。結果として、P_C, P_D, P_X の 3 パターンに分類され、P_A と P_B に分類されることはなかった。時系列変動に併せてパターンが変化するクラスタは、クラスタ 1, クラスタ 3, クラスタ 4, クラスタ 5, クラスタ 7 の 5 つであった。

表 4: 5 分類手法の詳細 (R^2/MAE)

検証月	クラスタ 1	クラスタ 2	クラスタ 3	クラスタ 4	クラスタ 5	クラスタ 6	クラスタ 7	クラスタ 8	クラスタ 9	クラスタ 10
1 月度	-0.07/6.15	-1.21/6.74	-0.54/8.02	-0.18/2.58	-0.77/6.54	0.13/4.08	-2.07/5.55	-3.38/3.68	0.53/1.70	-0.54/14.90
2 月度	-0.44/5.45	-0.47/6.31	0.33/5.62	0.18/2.82	-0.49/6.43	0.19/4.14	-1.80/5.26	-2.04/3.94	0.61/1.70	-1.31/15.07
3 月度	-0.69/4.94	-0.16/6.25	0.31/6.18	0.19/3.08	-1.76/7.19	0.22/4.44	-1.54/4.79	-2.32/4.00	0.61/1.56	-3.36/15.90
4 月度	-0.61/4.75	0.06/6.39	0.35/7.12	0.23/3.87	-1.9/7.18	0.34/4.11	-2.40/4.92	-2.97/4.39	0.64/1.58	-2.27/15.57
5 月度	-2.65/4.67	-0.36/5.97	0.39/6.08	0.27/4.69	-4.2/7.08	0.15/4.56	-0.42/4.43	-2.96/4.21	0.63/1.58	-1.44/16.36
6 月度	-1.53/4.38	-0.51/6.23	-0.01/6.19	0.36/5.21	-10.32/6.68	0.05/4.39	-7.22/4.69	-5.01/4.12	0.63/1.53	-3.4/15.32
7 月度	-0.81/3.87	-0.05/6.27	0.19/6.85	0.47/5.15	-10.21/6.1	0.11/4.37	-2.35/4.2	-1.59/3.87	0.57/1.45	-6.98/15.85
8 月度	-0.10/4.12	0.16/8.80	-1.80/8.88	0.56/4.63	-9.27/6.33	0.25/4.67	-2.25/4.21	-2.13/4.62	0.64/1.81	-3.52/16.29
9 月度	0.31/4.27	-0.27/6.36	-3.63/9.85	-0.01/3.59	-7.72/5.93	0.34/5.71	0.23/3.73	-2.25/4.19	0.33/1.69	-3.55/14.32
10 月度	0.28/4.72	-0.46/6.12	-5.65/11.47	-3.25/4.22	-6.86/5.56	0.41/6.75	-0.50/4.28	-3.99/4.33	0.68/1.45	-3.83/15.71
11 月度	0.49/4.88	-0.75/6.28	-5.47/11.06	-3.80/4.11	-6.41/5.56	0.47/6.98	-0.08/4.29	-4.28/3.87	0.50/1.55	-1.61/15.74
12 月度	0.35/7.54	-0.01/7.07	-1.02/7.62	-5.03/3.96	-3.83/3.87	0.52/7.00	0.37/4.47	-1.01/3.89	0.52/1.76	-4.97/17.77

※ 1 月度から 12 月度の検証月は、図 6 の各色のグラフへ左から順に対応している。

表 4 に、5 分類手法の精度値を示す。図 6 に記した 5 分類手法のパターン表記では変化は少なかったが、精度値であれば時系列的な変化を確認することができた。全体を通して、 MAE の変化はわずかであった。これは、クラスターリングにより時系列変動が似ているものが同クラスタとして分類されているため、予測の誤差も変化しにくいことが考えられる。一方、 R^2 に関しては、クラスタ 4 が興味深い変化をみせた。クラスタ 4 では、2 月度から 8 月度まで R^2 が単調増加している。これは、図 6 の右肩上がりのトレンドと一致している。9 月度から右肩下がりのトレンドに転じていると、それに呼応するように今度は R^2 が単調減少している。一部ではあるが、商品特性と需要予測精度の関係性を確認することができた。

6 おわりに

本研究では、我々が取り組んでいる 5 分類手法と、商品の定性的な性質との関係性について分析を行った。階層クラスターリングを用いた分類により、商品特性の時系列変動パターンを確認し、商品カテゴリをワードクラウドで可視化することで、各クラスタに特徴的な商品が含まれることが分かった。そして分類されたクラスタ内の商品全体を対象に 5 分類手法を適用し、商品特性の時系列変動パターンとの関係性を分析した結果、商品特性クラスタの全体と需要予測精度との関係性が一部確認できた。しかし、中程度の分類である P_X に分類される箇所が非常に多かったため、カテゴリ内の個別商品に絞って再分析を行うことで詳細が明らかになると考える。今後は、クラスタ内の個別の商品に対し 5 分類手法を適用するなど、より詳細な分析を行っていく。

文 献

- [1] 柳沢滋：在庫管理のはなし，日科技連出版社 (1988).
- [2] 渡邊小百合，吉野孝，松山浩士，平野隼己：需要予測精度の向上しない POS データの統計的特徴の分析，情報処理学会研究報告グループウェアとネットワークサービス (GN)，Vol.2019-GN-106，No.16，pp.1-6 (2019).
- [3] 今井秀之，山岡俊樹：日用品市場における新製品売上予測モデルの構築，日本感性工学学会論文誌，Vol.10，No.2，pp.63-71 (2011).
- [4] Victor Pekar, Jane Binner: Forecasting Consumer Spending from Purchase Intentions Expressed on Social Media, Proceedings of the 8th Workshop on Computational Approaches to Subjectivity, Sentiment and Social Media Analysis, pp.92-101 (2017).
- [5] Xiaotong Liu, Anbang Xu, Rama Akkiraju, Vibha Shinha: Understanding Purchase Behavior through Personality-driven Traces, CHI EA '17 Proceedings of the 2017 CHI Conference Extended Abstracts on Human Factors in Computing Systems, pp.1837-1843 (2017).
- [6] 若林憲人，生田目崇：ディープラーニングを用いた購買予測の研究，日本ソーシャルデータサイエンス論文誌，Vol.1，No.1，pp.48-57 (2017).
- [7] Rakesh Agrawal, Tomasz Imielinski, Arun Swami: Mining Association Rules between Sets of Items in Large Databases, SIGMOD '93 Proceedings of the 1993 ACM SIGMOD international conference on Management of data, pp.207-216 (1993).
- [8] 宗形聡，齋藤邦夫，樋地正浩：推定マーケットデータを使用した消費財系新製品の需要予測手法，情報処理学会研究報告情報システムと社会環境 (IS)，pp.1-8 (2004).
- [9] 石垣司，竹中毅，本村陽一：日常購買行動に関する大規模データの融合による顧客行動予測システム 実サービス支援のためのカテゴリマイニング技術，人工知能学会論文誌，Vol.26，No.6，pp.670-681 (2011).
- [10] Yi Zuo, A B M Shawkat Ali, Katsutoshi Yada: Consumer Purchasing Behavior Extraction Using Statistical Learning Theory, 18th International Conference on Knowledge-Based and Intelligent Information & Engineering Systems - KES2014, pp.1464-1473 (2014).
- [11] Peter J. Rousseeuw: Silhouettes: a Graphical Aid to the Interpretation and Validation of Cluster Analysis. Computational and Applied Mathematics, Vol.20, pp.53-65 (1987).
- [12] Davies David L., Bouldin Donald W.: A Cluster Separation Measure, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-1, Vol.2 pp.224-227 (1979).