B-03

# POS データを用いた需要予測手法の事前自動判別に関する基礎検討

## Fundamental Study on Prior Automatic Discrimination of Demand Forecasting Method Using POS Data

安田　大誠 †　　吉野　孝 ††　　松山　浩士 †††
Taisei Yasuda　Takashi Yoshino　Koji Matsuyama

## 1. はじめに

店舗経営における重要な問題として，在庫管理が挙げられる [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，品揃えが悪いと評価されることによる顧客減少といった問題が起こる可能性がある．これより，売れる数だけ商品を仕入れる必要があるが，全ての商品に対していくつ売れるのかを人手で予測するのは非常に困難である．そこで，企業によって需要予測システムの開発が行われているが，全ての商品を高精度で予測出来ているわけではない．

関連研究として，POS データを用いた需要予測が挙げられる．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 [2]．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．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 [3]．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．これらの研究において，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．

予備実験として，実際の POS データを用いて予測を行ったが，高精度で予測出来る商品がある一方で，全く予測出来ていない商品があった．そのため，予測に用いる要素や手法，類似商品同士の相関関係などを用いて，予測が当たらない商品の精度向上を図ったが，精度の向上には繋がらなかった [4]．このような予測が出来ない商品を需要予測システムで予測し続けると，頻繁に在庫過多や在庫不足が起こり，逆に店舗にとって不利益となる．POS データは単なるビッグデータとは違い，店舗ごとの特徴が含まれているため，需要予測システムを各店舗ごとに作成する必要がある．しかし，店舗ごとにシステムを作成すると，時間や費用の面でコストがかかってしまう．これより，予測精度が向上しない商品を予測システムに入力する前に発見する必要があるのではないかと考えた．そこで，我々は「予測できない，あるいは予測精度の悪い商品を，あらかじめ発見する」という目的で研究を行っている．機械学習の評価指標で精度判定をし，分類を行い，データ特性を分析することで，最終的には機械学習させる前に予測の可否を判断することを狙っている．

## 2. POS データ 5 分類手法

先行研究 [5] では，評価指標を用いて POS データを 5 分類[*1]にし (以下，5 分類手法と呼ぶ)，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．

### 2.1 一般的な需要予測との差異

一般的に需要予測手法は，データ特性と予測手法（機械学習，統計モデル）を対応づけており，ある程度，商品の特徴ごとに用いる予測手法が決まっている．そして，その予測精度を向上させることが目的になっている．精度で予測の良し悪しを判別するため，一部の商品には予測手法を適用できないという問題が生じる．これに対し，5 分類手法は全ての商品をいずれかの分類に判別するため，事前に予測が当たる，当たらないということが明確になる．店舗における全ての POS データを，いずれかの分類に判別する取り組みはこれまでに研究されておらず，我々が研究する上での新規性となっている．

### 2.2 5 分類手法の概要

ランダムフォレストで需要予測を行い，評価指標により対象商品を分類する．ランダムフォレストを用いた理由は，特徴量の重要度がわかるため，どの要素が予測において重要視されたか比較でき，外れ値や欠損値に強く，POS データを用いた予測手法に適しているためである．評価指標には，決定係数 ($R^2$) と平均絶対誤差 (MAE) の 2 種類[*2] を用いる．理由として，予備実験において決定係数のみを使用していたが，平均二乗誤差が実値の分散より大きい場合，1 日だけ大きく外れているものがあると，その値によって全体の精度が悪く評価されていた．そこで，関連研究 [6][7] にて予測モデルの評価指標として用いられていた平均絶対誤差も使用している．決定係数は値が 1 に近いほど精度が良く，平均絶対誤差は値が 0 に近いほど精度が良い．関連研究において，明確に精度の良し悪しを設定しているものはなかったため，閾値は今後検討する必要があるとされているが，決定係数における「高精度」は 0.7 以上,「低精度」は 0.3 以下，平均絶対誤差における「高精度」は 3.0 以下,「低精度」は 5.0 以上としている．決定係数と平均絶対誤差における閾値は，需要予測において利益が出ると考えた値を「高精度」，不利益となると考えた値を「低精度」として設定している．

予測精度の結果による組み合わせにより，5 分類手法は以下のように分類される．

- パターン A (以下，P_A と呼ぶ)
  - 機械学習 (ランダムフォレスト) を用いた需要予測に適したデータ特性
  - $R^2$ と MAE が共に高精度

† 和歌山大学大学院システム工学研究科，Graduate School of Systems Engineering, Wakayama University
†† 和歌山大学システム工学部，Faculty of Systems Engineering, Wakayama University
††† 株式会社サイバーリンクス，Cyber Links Co.,Ltd

[*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] 評価指標の定義は以下を用いる．

$$R^2 = 1 - \frac{\frac{1}{n}\Sigma_{i=1}^{n}(y^{(i)} - y_{pred}^{(i)})^2}{Var(y)}$$

Var: 分散

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

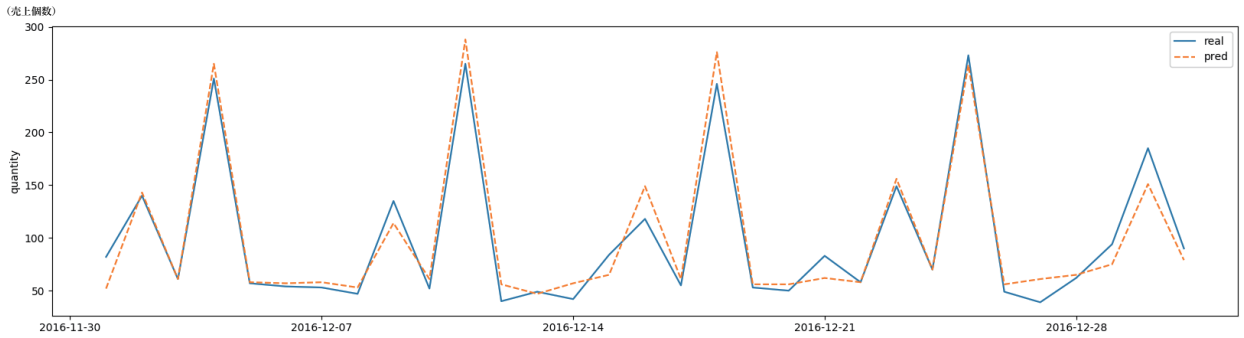


図 1: PB 牛乳の予測値と実値

表 1: 予測モデルに使用した要素一覧

| データ名 |
|---|
| 売上数量 |
| 売価（特売価を含む） |
| 客数 |
| 日付（年 / 月 / 日に分割） |
| 曜日 |
| 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 |

- パターン B (以下，P_B と呼ぶ)
  - 売上個数のばらつきが大きいため，平滑化したものでモデルを作成すると高精度になる可能性
  - $R^2$ は高精度だが MAE は低精度
- パターン C (以下，P_C と呼ぶ)
  - ばらつきが小さいため，機械学習ではなく移動平均などの統計手法を用いる方が高精度に予測できる可能性
  - $R^2$ は低精度だが MAE は高精度
- パターン D (以下，P_D と呼ぶ)
  - 需要予測にはあてはまらないため，今まで通り人手での予測及びセルワンバイワン[*3] と呼ばれる手法で自動発注
  - $R^2$ と MAE が共に低精度
- パターン X (以下，P_X と呼ぶ)
  - 先行研究では分析されていないため，今後分析を行う予定
  - $R^2$ と MAE が共に中精度

## 3. 誤差率に着目した商品の分析

先行研究に引き続き，POS データを用い，商品を 5 分類手法で分類し，それら商品の統計的な特徴分析を行う．本研究では，5 分類に判別された商品群の中で P_B から P_X への分類ではなく，本来 P_A に分類されるべきだったものがあると考え，パターンごとに絞った分析を行う．

[*3] POS データに基づき，売れた数量分だけ自動的に発注する仕組みのこと．

### 3.1 使用したデータ

先行研究及び本研究では，特定の 1 店舗における 55228 商品の POS データを用いている．使用した要素の一覧を表 1 に示す．曜日については，月曜から日曜を 0〜6 としている．使用可能なデータは，元日を除いた 2015 年 11 月 30 日から 2017 年 1 月 3 日の 399 日分である．毎日全ての商品に売上が発生しているわけではなく，売上記録がない日は売上数量が 0 個で記録されている．

### 3.2 分析内容

5 分類手法で評価指標に用いていた平均絶対誤差は，予測と実際の売上個数の差を直接反映した値となっている．特に販売量の多い商品では，売れ行きのばらつきが生じやすく，個数で誤差の評価を行うことが難しい．ゆえに，売上個数の異なる商品群に対し誤差数で評価を行うのは公平でないため，誤差率を用いるべきだと判断した．誤差率の評価指標の代表的なものとして，平均絶対パーセント誤差 (MAPE) [*4] が挙げられる．しかし，MAPE には実値（脚注の $y^{(i)}$）が 0 や 0 に限りなく近い値の場合，$\infty$ または未定義となる欠点がある．30 日以上売上記録がある POS データであれば，検証用である 2016 年 12 月のデータにおいて売上個数が 0 の日が複数日存在するため，頻繁にこの状況が起こりうると考えられる．そこで，この欠点を克服した代替手法である平均アークタンジェント絶対パーセント誤差 (MAAPE) [*5] [8] を用いる．平均アークタンジェント絶対パーセント誤差は，値が $\infty$ や未定義にならない代わりに，0 から $\frac{\pi}{2}$ までの範囲を取る．よって，評価指標は平均絶対誤差 (MAE) に代わり，平均アークタンジェント絶対パーセント誤差 (MAAPE) を用いる．平均アークタンジェント絶対パーセント誤差は値が 0 に近いほど精度が良い．平均アークタンジェント絶対パーセント誤差における「高精度」は 20%以下，「低精度」は 30%以上としている．理由としては，Peter ら [9] が MAPE に関して「予測精度が高く実用上大変有用であると判断される MAPE は 20%未満，実用上許容できる範囲は 30%未満」としていたため，これを参考に閾値として設定した．

今回の分析対象は，P_B に分類された商品 30 個とする．分析対象を P_B に絞った理由は，誤差率を用いた効果について検証するため，決定係数がともに高精度で同条件である P_A と P_B とを比較する．

[*4] 評価指標の定義は以下を用いる．

$$MAPE = \frac{1}{n}\Sigma_{i=1}^{n}|\frac{y^{(i)} - y^{(i)}_{pred}}{y^{(i)}}|$$

[*5] 評価指標の定義は以下を用いる．

$$MAAPE = \frac{1}{n}\Sigma_{i=1}^{n} arctan(|\frac{y^{(i)} - y^{(i)}_{pred}}{y^{(i)}}|)$$

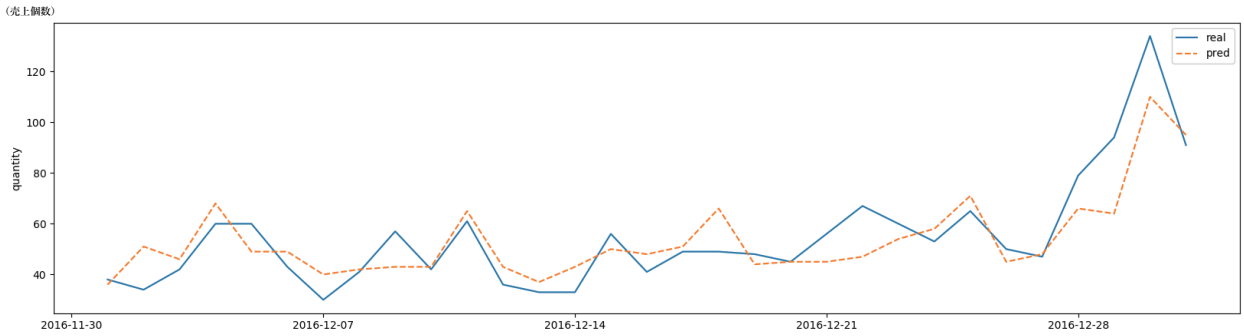


図 2: BR 牛乳の予測値と実値

### 3.3 分析結果と考察

図 1 と図 2 にそれぞれ，P_B に分類された，PB 牛乳と BR 牛乳の予測値と実値のグラフを示す．青が実値，オレンジの破線が予測値を示している．PB 牛乳の評価指標は決定係数が 0.95，平均絶対誤差が 12.13 個，平均アークタンジェント絶対パーセント誤差が 13.93%であり，BR 牛乳の評価指標は決定係数が 0.73，平均絶対誤差が 8.39 個，平均アークタンジェント絶対パーセント誤差が 15.04%であった．PB 牛乳の予測は，図 1 に示すように，大きな予測の山を外している箇所はなく，売上数量は約 50 個から約 270 個の間で推移している．平均絶対誤差が約 12 個となっているため，P_B に分類される商品ではあるが，誤差率の観点では約 13%となっており，高精度であるため，P_A に近い P_B であると考えられる．

また，P_B に分類された 30 個の商品のうち，平均アークタンジェント絶対パーセント誤差が 20%以下のものは，4 個だけであった．この 4 個に見受けられた特徴は，図 1 のように予測の山を当てているものと，図 2 に示すように予測の山を外しているが，予測をプラスで外した日とマイナスで外した日があり，結果的にバランスがとれているものの，2 種類のみであった．後者は機会ロスと廃棄ロスが起こっている状態であり，理想的な需要予測とはいえない．この違いに決定係数の差が考えられ，PB 牛乳と BR 牛乳では，その値が 0.22 ポイント異なる．このことから，決定係数が需要予測精度における決定的な評価指標であることが分かる．P_B 商品を P_A 商品に分類できる可能性があるが，P_B 内での決定係数の閾値を検討する必要性がある．

## 4. おわりに

本研究では，先行研究に引き続き，POS データを用いて商品を需要予測精度で分類し，それら商品の統計的な特徴分析を行った．平均絶対誤差の，売上数量の多い商品と少ない商品とで不公平な評価となる問題点に対し，平均アークタンジェント絶対パーセント誤差を適用することで，先行研究では P_B となっていた商品を P_A 商品に分類できる可能性があることが分かった．今後はより詳細な分析を行い，適切な閾値の調査を行う予定である．

## 参考文献

[1] 柳沢滋：在庫管理のはなし，日科技連出版社 (1988).

[2] 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 1 巻第 1 号, pp.48–57 (2017).

[3] 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).

[4] 渡邉小百合，吉野孝，平野隼己，松山浩士：POS データを用いた商品の需要予測の検討，2018 年電子情報通信学会, p.97 (2018).

[5] 渡邉小百合，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).

[6] 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).

[7] 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).

[8] Sungil Kim, Heeyoung Kim: A New Metric of Absolute Percentage Error for Intermittent Demand Forecasts, International Journal of Forecasting, Vol.32, pp.669–679 (2016).

[9] Peter S. Fader, Bruce G. S. Hardie, Chun-Yao Huang: A Dynamic Changepoint Model for New Product Sales Forecasting, Marketing Science, Vol. 23, pp.50–65 (2004).