

# 季節性を考慮した協調フィルタリング

西村 直樹, 関根 琴美, 高野 祐一, 村木 正昭

## 1. はじめに

情報技術の発達により、現在ではインターネットを利用して誰もが手軽に大量の情報を取得できるようになった。一方で、大量の情報を前にしながら、自分にとって価値のある商品を探し出すことができないといった情報過多の状況も多く生じている。このような背景から、利用者の嗜好を予測して適切な商品を推薦する「推薦システム」の重要性が認識されるようになった [1]。

利用者の嗜好を予測するための代表的な手法として、協調フィルタリングが挙げられる [2~5]。この手法では、過去データから嗜好の類似する利用者を選び出し、それらの嗜好パターンに基づいて（嗜好の類似する利用者として協調して）推薦商品を決定する。協調フィルタリングは、いわゆる「口コミ」の過程を自動化した方法と見なすこともできる。

一方で、協調フィルタリングの欠点として、データの疎性の問題を指摘されることが多い [2, 5~7]。すなわち、多くの利用者は過去にごく少数の商品しか評価（購入）していないために、利用者間の類似度を正確に把握することが難しいという問題である。この問題の解決策としては、特異値分解を用いてデータの次元を縮約する方法が提案されている [7~9]。

本論文では、経営科学系研究部会連合協議会主催の平成 25 年度データ解析コンペティションで提供された、ファッション系通販サイトの購買データを対象として分析を行う。このようなファッション商品のデータを扱ううえでは、季節や流行などの時系列性を考慮することが特に重要となる。

時系列性を考慮した協調フィルタリングの手法とし

て、Xiong et al. [10] は利用者・商品・時間の 3 軸から成るテンソル形式のデータに対してテンソル分解を用いる方法を提案している。テンソル分解は信号処理やデータマイニングなどのさまざまな分野で応用され、近年注目を集めている手法である [11]。しかし、テンソル形式のデータを処理するためには多くの計算量が必要となるために、現時点では大規模なデータを扱うための実用的な方法であるとは言い難い。Koren [12] は時系列性によるバイアス項を追加したバイアス加法型のモデルを提案している。このモデルは 2006 年からアメリカの Netflix 社によって開催された推薦システムのコンテストで利用され、大きな改善効果が見られたことが報告されている [4, 13]。しかし、バイアス加法型モデルでは、二つの要因（利用者の嗜好と時系列性）が同時に働くことで個々の要因がもたらす以上の結果が生じるような相乗効果を表すことができない。

本論文では、時系列性を考慮した協調フィルタリングの新しい手法として、時系列性を表すバイアス項を商品評価値と掛け合わせるバイアス乗法型のモデルを提案する。提案モデルは、テンソル分解を用いた方法 [10] とは異なり、少ない計算量で実装することが可能である。また、バイアス加法型モデル [12] とは対照的に、提案モデルは商品評価値と時系列性の相乗効果に基づいて推薦商品を決定するモデルである。本論文では特に商品の季節性に着目し、特異値分解を用いたバイアス乗法型モデルの有効性を検証する。

本論文は以下のように構成される：2 節では、協調フィルタリングの代表的な手法を紹介する。3 節では、季節性を考慮した協調フィルタリングの既存モデルと提案モデルについて説明する。4 節で計算実験の結果を報告し、最後に 5 節でまとめと今後の課題を述べる。

## 2. 協調フィルタリング

本節では、まず協調フィルタリングの代表的な手法である利用者間型メモリベース法（GroupLens の手法 [14]）について説明する。その後、データの疎性に

にしむら なおき, せきね ことみ, むらき まさあき  
 東京工業大学大学院社会理工学研究科経営工学専攻  
 〒 152-8552 東京都目黒区大岡山 2-12-1  
 たかの ゆういち  
 専修大学ネットワーク情報学部  
 〒 214-8580 神奈川県川崎市多摩区東三田 2-1-1  
 受付 14.7.25 採択 15.3.12

対処するための方法として、特異値分解による次元縮約について説明する。

## 2.1 利用者間型メモリベース法

利用者間型メモリベース法は、推薦対象となる利用者（対象利用者）と他の利用者（標本利用者）との類似度を計算し、類似した標本利用者の商品評価によって対象利用者の商品評価を予測する方法である。以下では、「利用者間の類似度の計算」と「商品評価の予測」に分けて説明する。

■利用者間の類似度の計算 利用者  $i \in \mathcal{I}$  の商品  $j \in \mathcal{J}$  に対する評価値を  $r_{ij}$  とする（未評価の場合は欠損値とする）。また、利用者  $a$  と利用者  $i$  が共に評価済みの商品の集合を  $\mathcal{J}_{ai}$  とする。このとき、対象利用者  $a$  と標本利用者  $i$  の類似度  $\rho_{ai}$  は、両者が評価済みの商品に対する評価値の相関係数によって定義する：

$$\rho_{ai} = \frac{\sum_{j \in \mathcal{J}_{ai}} (r_{aj} - \bar{r}_a^{(i)})(r_{ij} - \bar{r}_i^{(a)})}{\sqrt{\sum_{j \in \mathcal{J}_{ai}} (r_{aj} - \bar{r}_a^{(i)})^2} \sqrt{\sum_{j \in \mathcal{J}_{ai}} (r_{ij} - \bar{r}_i^{(a)})^2}}, \quad (1)$$

ただし、 $\bar{r}_a^{(i)}$  は利用者  $a$  と  $i$  が共に評価済みの商品に対する利用者  $a$  の評価値の平均とし、 $\bar{r}_i^{(a)} = (\sum_{j \in \mathcal{J}_{ai}} r_{aj}) / |\mathcal{J}_{ai}|$  と定義する。また、 $\mathcal{J}_{ai} = \emptyset$  の場合は、 $\rho_{ai} = 0$  とする。

■商品評価の予測 利用者  $i$  が評価済みの商品の集合を  $\mathcal{J}_i$  とし、利用者  $i$  の評価値の平均を  $\bar{r}_i = (\sum_{j \in \mathcal{J}_i} r_{ij}) / |\mathcal{J}_i|$  とする。また、商品  $j$  を評価済みの利用者の集合を  $\mathcal{I}_j$  とする。このとき、対象利用者  $a$  の商品  $j$  に対する予測評価値  $\hat{r}_{aj}$  は、対象利用者との類似度によって重み付けられた標本利用者の評価値の和によって計算する：

$$\hat{r}_{aj} = \bar{r}_a + \frac{\sum_{i \in \mathcal{I}_j} \rho_{ai} (r_{ij} - \bar{r}_i^{(a)})}{\sum_{i \in \mathcal{I}_j} |\rho_{ai}|}. \quad (2)$$

## 2.2 特異値分解による次元縮約

利用者間型メモリベース法において商品評価値を精度よく予測するためには、利用者間の類似度を正確に把握することが重要になる。しかし、多くの利用者は過去にごく少数の商品しか評価（購入）していない場合が多い。そのような場合は使用できるデータが少ないために、利用者間の類似度を正確に推定することは難しい。この問題の解決策として、特異値分解を用いてデータの次元を縮約する方法が提案されている [7~9]。

商品評価値  $r_{ij}$  を要素とする行列を  $\mathbf{R} = (r_{ij}; i \in \mathcal{I}, j \in \mathcal{J})$  と定義する。行列  $\mathbf{R}$  の階数を  $r$  としたとき、適当な  $|\mathcal{I}|$  次直交行列  $\mathbf{U}$  と  $|\mathcal{J}|$  次直交行列  $\mathbf{V}$  を選ぶと、行列  $\mathbf{R}$  は以下のように分解できる：

$$\mathbf{R} = \mathbf{U} \mathbf{S} \mathbf{V}^T,$$

ただし、 $|\mathcal{I}| \times |\mathcal{J}|$  行列  $\mathbf{S}$  は以下のような行列とする：

$$\mathbf{S} = \left( \begin{array}{ccc|c} \sigma_1 & & & 0 \\ & \sigma_2 & & \\ & & \ddots & \\ 0 & & & \sigma_r \\ \hline & & & 0 \\ & & & 0 \end{array} \right),$$

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0.$$

この分解は行列  $\mathbf{R}$  の特異値分解と呼ばれ、 $\sigma_1, \sigma_2, \dots, \sigma_r$  は行列  $\mathbf{R}$  の特異値と呼ばれる。ここで、 $k < r$  とし、大きいほうから順に  $k$  個の特異値を残して、

$$\mathbf{S}_k = \left( \begin{array}{ccc|c} \sigma_1 & & & 0 \\ & \sigma_2 & & \\ & & \ddots & \\ 0 & & & \sigma_k \\ & & & \\ & & & \end{array} \right)$$

とする。また、行列  $\mathbf{U}$  と  $\mathbf{V}$  の  $k+1$  列以降を削除して、 $|\mathcal{I}| \times k$  行列  $\mathbf{U}_k$  と  $|\mathcal{J}| \times k$  行列  $\mathbf{V}_k$  を作成する。このとき、行列  $\mathbf{R}$  は以下のように近似することができる：

$$\mathbf{R} \approx \mathbf{R}_k = \mathbf{U}_k \mathbf{S}_k \mathbf{V}_k^T.$$

行列  $\mathbf{R}_k$  を予測評価値としてそのまま使用する方法もあるが、本論文では行列  $\mathbf{U}_k$  を用いて利用者間の類似度を計算する（詳しくは、論文 [7] などを参照）。行列  $\mathbf{U}_k$  の各行は縮約された  $k$  次元空間における各利用者  $i \in \mathcal{I}$  の特徴を表すベクトルとなっている。よって、行列  $\mathbf{U}_k = (u_{is}; i \in \mathcal{I}, s = 1, 2, \dots, k)$  とし、縮約された  $k$  次元空間における利用者間の類似度を以下のように計算する：

$$\rho_{ai} = \frac{\sum_{s=1}^k (u_{as} - \bar{u}_a)(u_{is} - \bar{u}_i)}{\sqrt{\sum_{s=1}^k (u_{as} - \bar{u}_a)^2} \sqrt{\sum_{s=1}^k (u_{is} - \bar{u}_i)^2}}, \quad (3)$$

ただし、 $\bar{u}_i = (\sum_{s=1}^k u_{is}) / k$  とする。

行列  $\mathbf{R}$  が欠損値を含む不完全データの場合は、適当に数値を補完してから特異値分解を行う必要がある。また、不完全データの行列分解のための方法として、EM アルゴリズム [15]、確率的勾配法 [13]、交互最小 2 乗法 [13] などが提案されている。

### 3. 季節性の考慮

本論文で対象とするようなファッション商品の売上は、季節や流行に大きく左右される。よって、推薦商品を決定する際にこのような時系列性を考慮することは重要である。本節では商品の季節性を考慮するための手法として、まず Koren [12] によって提案されたバイアス加法型モデルを紹介し、次に本論文の提案モデルであるバイアス乗法型モデルを説明する。最後に、二つのモデルの簡単な比較例を述べる。

#### 3.1 既存モデル：バイアス加法型モデル

Koren [12] は、商品の時系列性を考慮するための方法として、行列分解に基づく商品評価値に、商品  $j \in \mathcal{J}$  の期間  $t \in \mathcal{T}$  のバイアス項  $b_j(t)$  を加えるバイアス加法型のモデルを提案している<sup>1</sup>。バイアス加法型モデルでは、期間  $t$  における対象利用者  $a$  の商品  $j$  に対する予測評価値は以下のように表される：

$$\hat{r}_{aj}(t) = \hat{r}_{aj} + b_j(t). \quad (4)$$

#### 3.2 提案モデル：バイアス乗法型モデル

本論文では、以下のバイアス乗法型モデルを提案する：

$$\hat{r}_{aj}(t) = \hat{r}_{aj} \cdot b_j(t). \quad (5)$$

バイアス加法型モデル ((4) 式) では、利用者の嗜好  $\hat{r}_{aj}$  と季節性  $b_j(t)$  の和によって商品評価値を予測しているが、バイアス乗法型モデル ((5) 式) では、利用者の嗜好  $\hat{r}_{aj}$  と季節性  $b_j(t)$  の積 (相乗効果) によって商品評価値を予測している。たとえば、期間  $\mathcal{T}$  を季節： $\mathcal{T} = \{ \text{春, 夏, 秋, 冬} \}$  や一か月： $\mathcal{T} = \{ 1 \text{月}, 2 \text{月}, \dots, 12 \text{月} \}$  と定義することで、これらのモデルは季節性を加味した予測が可能となる。

#### 3.3 モデルの比較例

商品  $j$  を T シャツ、期間  $t$  を夏とし、夏の T シャツの購入数を予測することを考える。利用者  $i = 1$  は T シャツを比較的多く購入する利用者とし、 $\hat{r}_{1j} = 2$  とする。利用者  $i = 2$  は T シャツをほとんど購入しない利用者とし、 $\hat{r}_{2j} = 0.1$  とする。T シャツの夏のバイアス

項を  $b_j(t) = 3$  とすると、バイアス加法型モデル ((4) 式) では、 $\hat{r}_{1j}(t) = 2 + 3 = 5$ 、 $\hat{r}_{2j}(t) = 0.1 + 3 = 3.1$  となり、T シャツをほとんど購入しない利用者  $i = 2$  でも夏に T シャツを 3 枚程度購入するという予測になる。

一方でバイアス乗法型モデル ((5) 式) では、 $\hat{r}_{1j}(t) = 2 \cdot 3 = 6$ 、 $\hat{r}_{2j}(t) = 0.1 \cdot 3 = 0.3$  となり、利用者  $i = 1$  の購入数は大きく増えるが、利用者  $i = 2$  は夏でも T シャツを購入しない可能性が高いという予測になる。このように季節性による影響の大きさが利用者の嗜好によって異なるような場合には、バイアス加法型モデル ((4) 式) よりもバイアス乗法型モデル ((5) 式) のほうが有効であると考えられる。

## 4. 計算実験

本節では、提案モデルの有効性を計算実験を通して検証する。

### 4.1 分析データ

本論文では、経営科学系研究部会連合協議会主催の平成 25 年度データ解析コンペティションで提供されたデータを対象として分析を行う。このデータは、ファッション系通販サイトの 2011 年 9 月～2013 年 4 月の顧客属性、注文履歴、商品情報から構成されている。

本論文では、「利用者間の類似度の計算」と「商品評価の予測」の際に異なる形式のデータセットを使用した。

■利用者間の類似度の計算のためのデータセット 利用者間の類似度の計算に使用したデータセットの概要を図 1 に示す。このデータセットは、各利用者の性別 (男性, 女性)、年代 (10 代, 20 代, ..., 80 代)、購入した商品の小分類 (215 種類：ポロシャツ, パンツ, ソックス, サンドルなど)、ブランド (2,631 種類) から構成されている<sup>2</sup>。性別と年代については 0 または 1、商品小分類とブランドについては商品の購入数が入力されている。このように、商品評価 (購買) データに加えて、利用者の属性データ (性別や年齢) を使用した協調フィルタリングはハイブリッド法と呼ばれ、特に商品評価データの疎性が強い場合に有効な方法である [5]。利用者間の類似度を計算する際には、このデータセットを行列  $\mathbf{R}$  として使用する。

■商品評価の予測のためのデータセット 図 2 に示すように、本論文では、商品小分類とブランドの組合せ

<sup>1</sup> 論文 [12] では利用者の時系列性もモデルに取り入れているが、本論文では商品の季節性に着目して比較を行うため、利用者の時系列性については考慮しない。

<sup>2</sup> 性別、年代については、基準となる水準を除外する (たとえば、女性と 80 代の列を削除する) ことも考えられる。

利用者	性別		年代				商品小分類				ブランド			
	男性	女性	10代	20代	...	80代	1	2	...	215	1	2	...	2631
1	0または1						商品の購入数							
2														
3														
⋮														

図1 利用者間の類似度の計算のためのデータセットの概要

利用者	商品小分類															
	1			2			3			215						
	ブランド			ブランド			ブランド			ブランド						
1	1	2	3	...	1	2	3	...	1	2	3	...	1	2	3	...
2	商品の購入数															
3																
⋮																

図2 商品評価の予測のためのデータセットの概要

表1 データセットの基礎集計

検証期間	利用者数	商品数	総購入数
9月	9,484	27,630	29,578
10月	9,890	28,208	29,376
11月	11,777	28,956	33,810
12月	14,128	30,222	40,612
1月	18,159	31,075	65,430
2月	12,226	31,075	36,295
3月	12,877	32,193	38,950
4月	12,619	33,137	37,004

を商品  $j \in \mathcal{J}$  として定義する。ただし、商品小分類ごとに存在するブランドは異なり、一つの商品小分類に対して購入履歴が存在するブランドは平均して190種類程度であった。また、商品評価値  $r_{ij}$  は利用者  $i$  が期間中に商品  $j$  を購入した数とした。利用者  $i$  が期間中に商品  $j$  を購入していない場合は  $r_{ij} = 0$  となり、商品評価値に欠損値は存在しない。商品評価の予測の際には、このようにして作成した商品評価値の行列  $\mathbf{R} = (r_{ij}; i \in I, j \in \mathcal{J})$  を使用し、「どの商品小分類のどのブランドを推薦するか」を決定する。

#### 4.2 予測精度の評価方法

分析データ（2011年9月～2013年4月の1年8か月）を学習期間と検証期間に分けて予測精度を検証する。検証期間は1か月間とし、1年間の学習期間を確保するために検証期間は2012年9月、10月、...、2013年4月の8通りとした。季節性を考慮した予測をするためには、1年前の1か月間を学習期間とすることも考えられるが、データ量が少なくなり疎性が悪化するうえに、1年前の商品しか推薦できないモデルになってしまうなどの欠点もある。本研究では、学習期間の長さを揃えたうえで複数の検証期間で予測精度を評価するために、学習期間を直前の1年間で統一し

た。学習期間と検証期間の両方で購入履歴が存在する利用者を抽出し、データセットを作成した。データセットの基礎集計を表1に示す。

推薦商品は、利用者ごとに予測評価値の高い  $N$  個の商品（トップ  $N$  推薦）とする。また、予測精度の評価指標として「実際に購入した商品をどれだけ予測できたか」を表す指標である再現率を用いる。利用者  $i \in I$  が検証期間に実際に購入した商品の集合を  $\mathcal{J}_i^{\text{Buy}}$  とし、学習期間のデータを用いて決定した推薦商品の集合を  $\mathcal{J}_i^{\text{Rec}}$  とする。このとき、全利用者の再現率を  $(\sum_{i \in I} |\mathcal{J}_i^{\text{Buy}} \cap \mathcal{J}_i^{\text{Rec}}|) / (\sum_{i \in I} |\mathcal{J}_i^{\text{Buy}}|)$  とし、モデルの比較を行う。

#### 4.3 バイアス項の定義

Koren [12] は行列分解と同時にバイアス項を推定する最適化モデルを提案している。一方で、本論文では市場反応分析の線形モデルと積乗型モデル（たとえば、文献 [16], 5.2.2 節などを参照）を参考に、以下のように加法型モデルと乗法型モデルのバイアス項を定義した。検証期間を  $t$  月とし、学習期間の同じ月（1年前の  $t$  月）を  $(t-12)$  月と表記する。バイアス加法型モデル ((4) 式) のバイアス項  $b_j(t)$  は以下のように定義する：

$$b_j(t) = \alpha \cdot \left( \frac{\text{【商品 } j \text{ の } (t-12) \text{ 月の売上個数】}}{\text{【商品 } j \text{ の } 1 \text{ カ月の平均売上個数】}} \right) / |I|, (6)$$

ただし、 $\alpha (\geq 0)$  は季節効果のパラメータとする。

バイアス乗法型モデル ((5) 式) では、商品  $j$  が属する小分類を  $c(j)$  とし、商品小分類の季節性に基づく以下のバイアス項  $b_j(t)$  を用いた：

$$b_j(t) = \left( \frac{\text{【小分類 } c(j) \text{ の } (t-12) \text{ 月の売上個数】}}{\text{【小分類 } c(j) \text{ の } 1 \text{ カ月の平均売上個数】}} \right)^\beta, (7)$$

ただし、 $\beta (\geq 0)$  は季節効果のパラメータとする。

予備実験の結果、バイアス加法型モデルは商品の（一人当たりの）売上個数によって、バイアス乗法型モデルは商品小分類の売上個数によってバイアス項を定義することで予測精度が高くなることを確認したために、上記のようにバイアス項を定義した。また、バイアス加法型モデル ((4) 式) とバイアス乗法型モデル ((5) 式) は、それぞれ  $\alpha = 0, \beta = 0$  の場合に季節性を考慮しないモデルと一致する。

#### 4.4 季節性の影響の検証

本節では、商品小分類215種類に対してWard法によるクラスター分析を行い、季節性が商品の売上に与える影響を確認する。「商品小分類 × 12か月」のバイ






図3 商品小分類のデンドログラム




図4 各クラスターのバイアス項 ((7) 式) の平均値

アス項 ((7) 式,  $\beta = 1$ ) のデータを利用し, 商品小分類間の距離はユークリッド距離の2乗とした. なお, バイアス項 ((7) 式,  $\beta = 1$ ) は, 平均売上個数と比較して各月の売上個数が何倍に増える(減る)のかを表している.

図3はWard法によって作成した商品小分類のデンドログラムであり, 商品小分類を3種類のクラスターに分類した. なお, クラスター1は50種類, クラスター2は16種類, クラスター3は149種類の商品小分類によって構成されている. 図4は, 各クラスターのバイアス項 ((7) 式,  $\beta = 1$ ) の平均値を示している. クラスター1は「イヤーマフ」「ネックウォーマー」「ダウンジャケット」など, 11月~1月に売上が増加する商品群である. クラスター2は「扇子/うちわ」「ポロシャツ」「サンダル」など, 6月~8月に売上が大きく増加する商品群である. クラスター3は季節性による影響が比較的小さい商品群であるが, 1月と7月に売上が微増するという特徴が見られる. 以上の分析結果から, 季節性は商品の売上に影響を与えており, その影響は決して小さくないということが確認できる.

#### 4.5 特異値分解の効果の検証

本節では, 特異値分解による次元縮約の効果を検証する. 具体的には, 2.1節で説明した利用者間型メモリベース法において, 相関係数 ((1) 式) を用いた場合 (特異値分解なし) と, 次元縮約を施した相関係数




図5 特異値分解による再現率の変化 (2012年9月)

((3) 式) を用いた場合 (特異値分解あり) とを比較する. なお, 予備実験の結果,  $k = 450 \sim 600$  として次元を縮約した場合に予測精度が最も改善することを確認しており, ここでは  $k = 500$  の場合の結果を示す. 図5は, 2012年9月を検証期間とし, 推薦商品数が5, 10, 20の場合の再現率を示している. データの疎性を解消する特異値分解によって, 再現率が1.7倍程度に向上していることが確認できる. よって, 以降では特異値分解後の相関係数 ((3) 式,  $k = 500$ ) を用いた利用者間型メモリベース法 ((2) 式) を基本モデルとする.

#### 4.6 各モデルの予測精度の比較

以降では, 以下の3種類のモデルの予測精度を比較する:

- 基本モデル** 特異値分解後の相関係数 ((3) 式,  $k = 500$ ) を用いた利用者間型メモリベース法 ((2) 式)
- 加法型モデル** 基本モデルの商品評価値にバイアス項 ((6) 式) を加えたバイアス加法型モデル ((4) 式)
- 乗法型モデル** 基本モデルの商品評価値にバイアス項 ((7) 式) を掛け合わせたバイアス乗法型モデル ((5) 式)

季節効果のパラメータの値は10水準とし, 加法型モデルは  $\alpha = 0.0001, 0.0002, 0.0004, 0.0008, \dots, 0.0512$  とし, 乗法型モデルは  $\beta = 0.1, 0.2, 0.3, 0.4, \dots, 1.0$  とした. これらの値は, 水準の範囲内に再現率の最大値が存在するように, 予備実験を通して決定した.

図6, 7, 8は, それぞれ推薦商品数を5, 10, 20とした場合の基本モデル, 加法型モデル ( $\alpha$ :最適値), 乗法型モデル ( $\beta = 0.6$ ), 乗法型モデル ( $\beta$ :最適値) の再現率を示している. 季節効果のパラメータの最適値は月ごとに異なるが, すべての月で一定の値としても乗法型モデルは十分な改善が得られるかを調べるために,  $\beta = 0.6$  の結果を掲載している.

図6では, 僅差の場合もあるが乗法型モデル ( $\beta$ :最適値) は3月以外のすべての月で, 基本モデルと加法型




図 6 各モデルの再現率 (推薦商品数: 5)




図 7 各モデルの再現率 (推薦商品数: 10)




図 8 各モデルの再現率 (推薦商品数: 20)

モデルの再現率を上回っている。特に、11月と12月は乗法型モデルによる改善が大きく、パラメータを一定値  $\beta = 0.6$  とした場合でも十分な改善効果が見られる。図 7 では各モデルの再現率の差が大きくなり、乗法型モデル ( $\beta = 0.6$ ,  $\beta$ : 最適値) はすべての月で、基本モデルと加法型モデルの再現率を上回っている。特に10月~12月は乗法型モデルによる改善が大きい。図 4 で示したように、10月~12月は夏物商品の売上が落ち込み、冬物商品の売上が大きく増加していく時期である。このような季節性を考慮することで、乗法型モデルは10月~12月の再現率を向上させていると考えられる。図 8 でも図 7 とほぼ同様の傾向が見られる。

以上のことから、乗法型モデルは推薦商品数を 10 以上とした場合にすべての月で他のモデルの再現率を上回り、季節効果のパラメータを一定値とした場合でも十分な改善効果が見られることがわかった。推薦商品数が多い場合は予測評価値が低い商品も推薦せざるを得ない。よって、このような場合は季節性などのより多くの情報を加味して推薦商品を決めることが有効だと言える。

表 2 は、乗法型モデルにおいて、基本モデルと比較して推薦回数が大きく増加/減少した商品小分類をまとめたものである。たとえば、12月は「マフラー・ショール」「手袋」など冬物商品の推薦回数が増加し、「ポロ

表2 乗法型モデルにおいて推薦回数が増加/減少した商品小分類

推薦回数が増加した商品小分類			
10月	12月	2月	4月
ブーツ	福袋・福箱	ワンピース・ドレス	Tシャツ・カットソー
ニット・セーター	ニット・セーター	ニット・セーター	シャツ・ブラウス
カーディガン	ブーツ	カーディガン	カーディガン
パーカー	マフラー・ショール	パーカー	スニーカー
その他アウター	手袋	トートバッグ	サンダル
デニムパンツ	その他アウター	ブーツ	ワンピース・ドレス
ダッフルコート	ダッフルコート	スカート	テラードジャケット
スウェット	ソックス	トランクス	トートバッグ
ブルゾン	モッズコート	パンプス	デニムパンツ
腕時計	ビーコート	その他アウター	フィギュア
推薦回数が減少した商品小分類			
10月	12月	2月	4月
スニーカー	ワンピース・ドレス	ブレスレット	モッズコート
福袋・福箱	ブレスレット	タンクトップ	ビーコート
ブレスレット	トートバッグ	福袋・福箱	その他アウター
ブラ	タンクトップ	ニットキャップ・ビーニー	福袋・福箱
タンクトップ	ショーツ	ショーツ	ダッフルコート
ショーツ	ポロシャツ	ブラ	ショーツ
ポロシャツ	サンダル	サンダル	ブーツ
サンダル	パンツ	ポロシャツ	ブラ
シャツ・ブラウス	シャツ・ブラウス	シャツ・ブラウス	ニットキャップ・ビーニー
Tシャツ・カットソー	Tシャツ・カットソー	Tシャツ・カットソー	ニット・セーター

シャツ」「サンダル」などの夏物商品の推薦回数が減少している。10月と2月も同様の傾向が見られるが、推薦回数が増加した商品には「デニムパンツ」「腕時計」「トートバッグ」「スカート」「トランクス」など、季節を選ばないタイプの商品が含まれている。一方で、4月に推薦回数が減少した商品は冬物商品が中心となっており、推薦回数が増加した商品には「Tシャツ・カットソー」「サンダル」などの夏物商品が含まれる。これらの結果から、乗法型モデルが季節性を考慮して推薦商品を決定的にしていることがわかり、このことが予測精度の改善につながっていると考えられる。

## 5. おわりに

本論文では、利用者の嗜好と季節性の相乗効果に基づく、新しい協調フィルタリングのモデルを提案した。計算実験の結果、提案するバイアス乗法型モデルは既存のバイアス加法型モデルを上回る予測精度をもつことがわかった。また、提案モデルは推薦商品数が10以上の場合に、より有効であることを確認した。

本論文で扱ったファッション商品などの売上は、季節や流行に大きく影響される。よって、本論文で提案するような手法を活用することで、通販サイトは利用者の嗜好と季節に合わせて適切な商品を推薦することが可

能となる。また、推薦商品を用いた服装のコーディネーターなどを紹介することで、顧客が商品に対してさらに興味をもつような販売促進を実行することもできる。

今後の課題としては、Koren [12]と同様に利用者の時系列性をモデルに取り入れることや、行列分解と同時にバイアス項を推定する方法と予測精度を比較することが考えられる。また、テンソル分解を用いたモデル [10]と予測精度を比較することも今後の課題となる。

**謝辞** 貴重なデータを提供していただいたデータ解析コンペティション関係者の皆様に、心より感謝申し上げます。

## 参考文献

- [1] 神鷹敏弘, “推薦システムのアルゴリズム (1),” 人工知能学会誌, **22**, pp. 826–837, 2007.
- [2] 神鷹敏弘, “推薦システムのアルゴリズム (2),” 人工知能学会誌, **23**, pp. 89–103, 2008.
- [3] 神鷹敏弘, “推薦システムのアルゴリズム (3),” 人工知能学会誌, **23**, pp. 248–263, 2008.
- [4] Y. Koren and R. Bell, “Advances in collaborative filtering,” *Recommender Systems Handbook*, F. Ricci, L. Rokach, B. Shapira and P. B. Kantor (eds.), Springer, pp. 145–186, 2011.
- [5] X. Su and T. M. Khoshgoftaar, “A survey of collaborative filtering techniques,” *Advances in Artificial Intelligence*, Article ID 421425, 2009.

- [6] A. I. Schein, A. Popescul, L. H. Ungar and D. M. Pennock, “Methods and metrics for cold-start recommendations,” In *Proceedings of the 25th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp. 253–260, 2002.
- [7] B. Sarwar, G. Karypis, J. Konstan and J. Riedl, “Application of dimensionality reduction in recommender system—A case study,” In *Proceedings of the ACM Web KDD Workshop*, 2000.
- [8] D. Billsus and M. M. Pazzani, “Learning collaborative information filters,” In *Proceedings of the International Conference on Machine Learning*, pp. 46–54, 1998.
- [9] A. Paterek, “Improving regularized singular value decomposition for collaborative filtering,” In *Proceedings of the KDD Cup and Workshop*, pp. 39–42, 2007.
- [10] L. Xiong, X. Chen, T. K. Huang, J. Schneider and J. G. Carbonell, “Temporal collaborative filtering with Bayesian probabilistic tensor factorization,” In *Proceedings of the SIAM International Conference on Data Mining*, pp. 211–222, 2010.
- [11] T. G. Kolda and B. W. Bader, “Tensor decompositions and applications,” *SIAM Review*, **51**, pp. 455–500, 2009.
- [12] Y. Koren, “Collaborative filtering with temporal dynamics,” *Communications of the ACM*, **53**, pp. 89–97, 2010.
- [13] Y. Koren, R. Bell and C. Volinsky, “Matrix factorization techniques for recommender systems,” *Computer*, **42**, pp. 30–37, 2009.
- [14] P. Resnick, N. Iacovou, M. Suchak, P. Bergstrom and J. Riedl, “GroupLens: An open architecture for collaborative filtering of netnews,” In *Proceedings of the ACM Conference on Computer Supported Cooperative Work*, pp. 175–186, 1994.
- [15] 井上光平, 浦浜喜一. “データ行列の特異値分解に基づく協調フィルタリング,” 電子情報通信学会論文誌, **J84-D-I**, pp. 116–119, 2001.
- [16] 岡太彬訓, 守口剛, 木島正明 (編), 『マーケティングの数理モデル』, 朝倉書店, 2001.