

# ユーザの行動履歴に着目した アイテム評価予測に関する基礎的検討

田村 一樹<sup>1,a)</sup> 吉川 大弘<sup>1</sup> 古橋 武<sup>1</sup>

**概要:** 近年、電子商取引 (Electronic Commerce: EC) 市場の規模は拡大を続けている。EC サイトには、膨大な量のアイテムの情報に加え、アイテムに対するユーザの評価・口コミ (ユーザレビュー) などの情報が掲載されている。また、各ユーザの閲覧行動などのログも、大量に蓄積されている場合が多い。EC サイトは、それらの情報を用いて、各ユーザの嗜好を適切に抽出し、能動的にアイテムを推薦することにより、ユーザの購買活動を促進することを試みている。嗜好の抽出手法には、ユーザが直接的に与えた評点などの情報を用いる明示的手法と、アイテムへのアクセス履歴やその時間などを用いる暗黙的手法が存在するが、それらを同時に用いる研究については、これまであまり報告されていない。本稿では、アイテムの内容に関する評価情報であるユーザレビュー履歴に加え、明示的な情報であるアイテム評価履歴と、暗黙的な情報であるアイテム閲覧履歴の情報を用い、ユーザの購買行動を階層ベイズモデルによってモデル化することを試みる。また、オフラインのアイテム評価予測実験を行い、提案モデルの性能について検討を行う。

**キーワード:** 推薦システム, 評価予測, 協調フィルタリング, 明示的フィルタリング, 暗黙的フィルタリング, 階層ベイズモデル, 電子商取引

## A basic study on item rating prediction focusing on behavior history of user

**Abstract:** The market of Electronic Commerce (EC) has been drastically growing in recent years. EC sites contain various types of evaluation information on items such as ratings and reviews by users in addition to the numerous information on items themselves. In addition, browsing history of each user is usually recorded. Recently, a lot of EC sites try to recommend items actively to each user to encourage him/her to purchase more items by abstracting his/her preference based on above information. To abstract preferences, there are the explicit method and the implicit method. The explicit method uses the information such as ratings directly given by users, and the implicit method uses the information such as access histories to items and browsing time. However, the study to combine the explicit information and implicit one is not found. This paper tries to construct a hierarchical Bayesian model to analyze purchasing behavior of a user based on reviews as the information of contents, rating histories as the explicit information, and browsing histories as the implicit information. An off-line experiment predicting the ratings of items is carried out and the performance of the proposed model is discussed.

**Keywords:** recommender system, prediction of ratings, collaborative filtering, explicit filtering, implicit filtering, hierarchical Bayesian model, electronic commerce

### 1. はじめに

近年、電子商取引 (Electronic Commerce: EC) 市場の規模は拡大を続けている。EC 市場の拡大に伴い、Ama-

zon.com<sup>\*1</sup>や楽天市場<sup>\*2</sup>などの EC サイトが扱うアイテムの数も膨大なものとなっている。これによりユーザは、様々なアイテムを比較し、購入できるようになった反面、大量のアイテムの中から、自らの嗜好に合ったアイテムを探し出すことが容易ではなくなっている。そこで EC サイトは、

<sup>1</sup> 名古屋大学

Nagoya University

<sup>a)</sup> tamura@cimplx.cse.nagoya-u.ac.jp

<sup>\*1</sup> <http://www.amazon.com/>

<sup>\*2</sup> <http://www.rakuten.co.jp/>

各ユーザの嗜好を適切に抽出し、能動的にアイテムを推薦することにより、ユーザの購買活動を促進することを試みている [1][2][3].

EC サイトには、膨大な量のアイテムの情報に加え、アイテムに対するユーザの評価・口コミ（ユーザレビュー）などの情報が掲載されている。また、サーバには各ユーザの閲覧行動や購買行動などのログも、大量に蓄積されていることが多い。推薦システムでは、主にそれらの情報を用いることにより、各ユーザの嗜好に合った適切なアイテムの推薦を行うことを目的としている。この推薦システムの手法には、一般的に、内容ベースフィルタリング (content-based filtering) と協調フィルタリング (collaborative filtering) がある [4][5][6]。前者は、推薦するアイテムの内容に基づいて推薦を行う手法であり、後者は、嗜好が類似するアイテム/ユーザを探し、その類似性に基づいてアイテムを推薦する手法である。推薦システムの研究においては、これら二つの手法を組み合わせたハイブリッド手法も数多く報告されており、推薦の精度において高い性能を持つことが示されている [7][8][9].

また、ユーザの嗜好の抽出方法には、明示的手法と暗黙的手法がある [6]。明示的手法は、アイテムの評価をユーザの採点などの操作を通して直接的に獲得する方法である。一方、暗黙的手法は、アイテムの閲覧行動などからユーザの嗜好を推定し、獲得する方法である。前者はアイテムへの嗜好を正確に捉えることができるものの、アイテムの評価がユーザの手間となるため、一部のアイテムしか評価情報が与えられず、疎なデータとなることが多い。後者ではユーザの行動から大量のデータを随時収集可能であるが、ユーザの明示的な評価は得られないため、適切に嗜好を推定できない場合も多くある。これらは、うまく組み合わせることで、互いの短所を補い、高性能な推薦を行うことが可能になると期待できる [10]。しかし、これまでの嗜好抽出技術は、明示的手法と暗黙的手法それぞれにおいて発展しており、それらを同時に用いた研究はあまり報告されていない。

ここでは、両者の手法を組み合わせ、蓄積される大量の情報を活用し、推薦を行うためのモデルの構築を試みる。特に、アイテムの内容に関する情報であるユーザレビュー履歴に加え、明示的な情報であるアイテム評価履歴と、暗黙的な情報であるアイテム閲覧履歴の情報に着目する。本稿では、それらの情報を用いることにより、ユーザの購買行動を表現する階層ベイズモデルを提案する。また、提案モデルを用いて、未評価のアイテムの評点を予測するオフラインの実験を行い、モデルの性能について定量的な評価を行う。

## 2. 関連研究

推薦システムの研究において、確率的潜在意味解析 (Prob-

abilistic Latent Semantic Analysis: PLSA)[11] や潜在的ディリクレ配分法 (Latent Dirichlet Allocation: LDA)[12] などの確率モデルを用い、次元削減を行う手法が報告されている [13][14][15]。これらのモデルは、データの次元削減を確率の枠組みで行う手法で、ユーザとアイテムの共起性などから、潜在的なクラスタ（類似ユーザ群や類似アイテム群など）を推定することができる。モデルのパラメータ推定は、PLSA が訓練データにおいて最尤推定で行うのに対し、LDA はディリクレ事前分布を導入し、ベイズ推定で行う。特にベイズ推定は、訓練データに含まれないデータの予測において頑健であることが知られている。

アイテムとユーザの共起性に着目した研究には、Li らの手法がある [16]。Li らは、ユーザ × アイテムの評点行列を生成するモデル (Rating-Matrix Generative Model: RMGM) を提案している。RMGM は、ユーザクラスタとアイテムクラスタを仮定し、各クラスタの組み合わせから評点が生成されるとした確率モデルである。文献 [16] では、ユーザかアイテムの一方の情報のみを用いる場合よりも、高性能な推薦が可能であることが示されている。また、複数のドメインにも拡張が可能である点も長所である。しかし、RMGM は最尤推定に基づく手法であり、訓練データに含まれない未知のデータは理論的にはモデル化できない。また、疎なデータにおいては、クラスタの推定において過学習に陥るといった問題もある。

ユーザレビューを用いて評点を予測するモデルも提案されているものの [17]、すべてのアイテムについて十分な量のレビューを集めることは現実的ではない。不足する情報を補うために、ユーザのアイテム閲覧履歴などの暗黙的な情報を用いることが考えられるが、評点やレビューなどの明示的な情報と同時にそれら暗黙的な情報を用いる研究については、これまであまり報告されていない。

## 3. 提案モデル

### 3.1 購買行動のモデル化

本稿では、アイテムの内容に関する情報であるユーザレビュー履歴に加え、明示的な情報であるアイテム評価履歴と、暗黙的な情報であるアイテム閲覧履歴を活用し、推薦を行うためのモデルの構築を試みる。提案モデルは、潜在的なクラスタを仮定し、LDA と同様、ディリクレ事前分布を導入した生成モデルとし、確率的に閲覧アイテム、レビュー、評点を生成する。提案モデルのグラフィカルモデルを図 1 に示す。また、各変数の定義を表 1 に示す。

提案モデルにおける各変数の生成過程は以下の通りである。

- (1) Choose  $\theta \sim \text{Dir}(\alpha)$
- (2) Choose  $\phi \sim \text{Dir}(\beta)$
- (3) Choose  $\mu \sim \text{Dir}(\gamma)$
- (4) Choose  $\psi \sim \text{Dir}(\delta)$

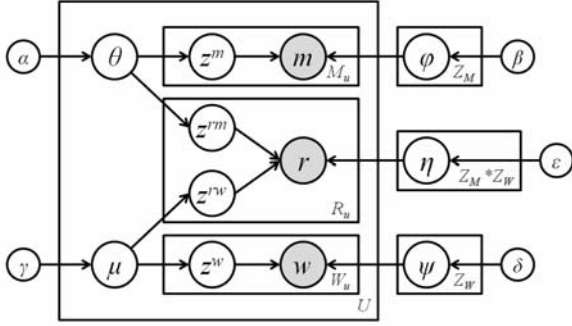


図 1 提案モデルのグラフィカルモデル

Fig. 1 Graphical model of proposed model

表 1 提案モデルにおける各変数の定義

Table 1 Definition of variables in proposed model

$U$	number of users
$M$	number of items
$W$	number of words
$R$	number of variables of ratings
$M_u$	number of items reviewed by user $u$
$W_u$	number of words written by user $u$
$R_u$	number of items rated by user $u$
$C$	number of item-clusters
$T$	number of word-clusters
$m$	reviewed item
$w$	written word
$r$	rating
$z^m, z^{rm}$	item-cluster
$z^w, z^{rw}$	word-cluster
$\theta$	multinomial distribution of latent item-clusters
$\mu$	multinomial distribution of latent word-clusters
$\phi$	multinomial distribution of items specific to item-cluster $z^m$
$\psi$	multinomial distribution of words specific to word-cluster $z^w$
$\eta$	multinomial distribution of ratings specific to topic $z^{rm}$ and $z^{rw}$
$\alpha$	fixed parameters of symmetric Dirichlet priors on distributions of $\theta$
$\beta$	fixed parameters of symmetric Dirichlet priors on distributions of $\phi$
$\gamma$	fixed parameters of symmetric Dirichlet priors on distributions of $\psi$
$\delta$	fixed parameters of symmetric Dirichlet priors on distributions of $\eta$
$\epsilon$	fixed parameters of symmetric Dirichlet priors on distributions of $\eta$

(5) Choose  $\eta \sim \text{Dir}(\epsilon)$

(6) For each of  $N_m$  items  $m_i$ :

(a) Choose an item-cluster  $z_i^m \sim \text{Multinomial}(\theta)$

(b) Choose an item  $m_i \sim \text{Multinomial}(\phi_{z_i^m})$

(7) For each of  $N_w$  items  $w_j$ :

(a) Choose a word-cluster  $z_j^w \sim \text{Multinomial}(\mu)$

(b) Choose a word  $w_j \sim \text{Multinomial}(\psi_{z_j^w})$

(8) For each of  $N_r$  ratings  $r_k$ :

(a) Choose an item-cluster  $z_k^{rm} \sim \text{Multinomial}(\theta)$

(b) Choose a word-cluster  $z_k^{rw} \sim \text{Multinomial}(\mu)$

(c) Choose a rating  $r_k \sim \text{Multinomial}(\eta_{z_k^{rm}, z_k^{rw}})$

### 3.2 推論

提案モデルでは、LDA と同様に Collapsed Gibbs Sampling[18] を用いて推論を行う。初めに、全変数の結合分布を示す。

$$\begin{aligned}
 & p(\mathbf{m}, \mathbf{w}, \mathbf{r}, \mathbf{z}^m, \mathbf{z}^w, \mathbf{z}^{rm}, \mathbf{z}^{rw}, \theta, \phi, \mu, \psi, \eta | \alpha, \beta, \gamma, \delta, \epsilon) \\
 &= p(\mathbf{m} | \mathbf{z}^m, \phi) \cdot p(\mathbf{w} | \mathbf{z}^w, \psi) \cdot p(\mathbf{r} | \mathbf{z}^{rm}, \mathbf{z}^{rw}, \eta) \\
 & \cdot p(\mathbf{z}^m | \theta) \cdot p(\mathbf{z}^w | \mu) \cdot p(\mathbf{z}^{rm} | \theta) \cdot p(\mathbf{z}^{rw} | \mu) \\
 & \cdot p(\phi | \beta) \cdot p(\psi | \delta) \cdot p(\eta | \epsilon) \cdot p(\theta | \alpha) \cdot p(\mu | \gamma) \quad (1)
 \end{aligned}$$

Collapsed Gibbs Sampling では、解析的に求めることのできない潜在分布  $\theta, \phi, \mu, \psi, \eta$  を積分消去する。このため、式(1)を以下のように変形する。

$$\begin{aligned}
 & p(\mathbf{m}, \mathbf{w}, \mathbf{r}, \mathbf{z}^m, \mathbf{z}^w, \mathbf{z}^{rm}, \mathbf{z}^{rw} | \alpha, \beta, \gamma, \delta, \epsilon) \\
 &= \int p(\mathbf{z}^m | \theta) \cdot p(\mathbf{z}^{rm} | \theta) \cdot p(\theta | \alpha) d\theta \\
 & \times \int p(\mathbf{z}^w | \mu) \cdot p(\mathbf{z}^{rw} | \mu) \cdot p(\mu | \gamma) d\mu \\
 & \times \int p(\mathbf{m} | \mathbf{z}^m, \phi) \cdot p(\phi | \beta) d\phi \\
 & \times \int p(\mathbf{w} | \mathbf{z}^w, \psi) \cdot p(\psi | \delta) d\psi \\
 & \times \int p(\mathbf{r} | \mathbf{z}^{rm}, \mathbf{z}^{rw}, \eta) \cdot p(\eta | \epsilon) d\eta \quad (2)
 \end{aligned}$$

ディリクレ分布と多項分布の共役性から、式(2)は各変数を用いて以下のように表される。

$$\begin{aligned}
 &= \left( \frac{\Gamma(C\alpha)}{\Gamma(\alpha)^C} \right)^U \prod_{u=1}^U \frac{\prod_{c=1}^C \Gamma(N_{u(\cdot)c}^M + N_{u(\cdot)c}^{RM} + \alpha)}{\Gamma(N_{u(\cdot)(\cdot)}^M + N_{u(\cdot)(\cdot)}^{RM} + C\alpha)} \\
 & \times \left( \frac{\Gamma(T\gamma)}{\Gamma(\gamma)^T} \right)^U \prod_{u=1}^U \frac{\prod_{t=1}^T \Gamma(N_{u(\cdot)t}^W + N_{u(\cdot)t}^{RW} + \gamma)}{\Gamma(N_{u(\cdot)(\cdot)}^W + N_{u(\cdot)(\cdot)}^{RW} + T\gamma)} \\
 & \times \left( \frac{\Gamma(M\beta)}{\Gamma(\beta)^M} \right)^C \prod_{c=1}^C \frac{\prod_{i=1}^M \Gamma(N_{(\cdot)ic}^M + \beta)}{\Gamma(N_{(\cdot)(\cdot)c}^M + M\beta)} \\
 & \times \left( \frac{\Gamma(W\delta)}{\Gamma(\delta)^W} \right)^T \prod_{t=1}^T \frac{\prod_{j=1}^W \Gamma(N_{(\cdot)jt}^W + \delta)}{\Gamma(N_{(\cdot)(\cdot)t}^W + W\delta)} \\
 & \times \left( \frac{\Gamma(R\epsilon)}{\Gamma(\epsilon)^R} \right)^E \prod_{e=1}^E \frac{\prod_{k=1}^R \Gamma(N_{(\cdot)ke}^R + \epsilon)}{\Gamma(N_{(\cdot)(\cdot)e}^R + R\epsilon)} \quad (3)
 \end{aligned}$$

ここで、 $E$  はアイテムとレビューの2つのクラスタの組み合わせであり、 $E = C \times T$  である。また、 $N_{uic}^M, N_{ujt}^W, N_{uke}^R, N_{uke}^{RM}, N_{ukt}^{RW}$  は、それぞれ添え字三つの組のカウントを表し、 $(\cdot)$  は対応する添え字の総和を示す。

表 2 各カウントの添え字の定義  
Table 2 Definition of indexes

$u$	user
$i$	item
$j$	word
$k$	rating
$c$	item-cluster
$t$	word-cluster
$e$	pair of clusters ( $c, t$ )

各添え字の意味を表 2 に示す。Collapsed Gibbs Sampling では、式 (3) から各クラスターの更新式を導出することができる。導出される更新式を以下に示す。

$$\begin{aligned}
 & p(z_i^m | \mathbf{z}^m \setminus l, \mathbf{z}^w, \mathbf{z}^{rm}, \mathbf{z}^{rw}, \mathbf{m}, \mathbf{w}, \mathbf{r}) \\
 & \propto \frac{p(\mathbf{m} | \mathbf{z}^m) p(\mathbf{z}^m, \mathbf{z}^{rm})}{p(\mathbf{m} \setminus l | \mathbf{z}^m \setminus l) p(\mathbf{z}^m \setminus l, \mathbf{z}^{rm})} \\
 & = \frac{N_{(\cdot)ic}^{M \setminus l} + \beta}{N_{(\cdot)(\cdot)c}^{M \setminus l} + M\beta} \cdot \frac{N_{u(\cdot)c}^{M \setminus l} + N_{u(\cdot)c}^{RM} + \alpha}{N_{u(\cdot)(\cdot)}^{M \setminus l} + N_{u(\cdot)(\cdot)}^{RM} + C\alpha} \quad (4)
 \end{aligned}$$

$$\begin{aligned}
 & p(z_i^w | \mathbf{z}^w \setminus l, \mathbf{z}^m, \mathbf{z}^{rm}, \mathbf{z}^{rw}, \mathbf{m}, \mathbf{w}, \mathbf{r}) \\
 & \propto \frac{p(\mathbf{w} | \mathbf{z}^w) p(\mathbf{z}^w, \mathbf{z}^{rw})}{p(\mathbf{w} \setminus l | \mathbf{z}^w \setminus l) p(\mathbf{z}^w \setminus l, \mathbf{z}^{rw})} \\
 & = \frac{N_{(\cdot)jt}^{W \setminus l} + \delta}{N_{(\cdot)(\cdot)t}^{W \setminus l} + W\delta} \cdot \frac{N_{u(\cdot)t}^{W \setminus l} + N_{u(\cdot)t}^{RW} + \gamma}{N_{u(\cdot)(\cdot)}^{W \setminus l} + N_{u(\cdot)(\cdot)}^{RW} + T\gamma} \quad (5)
 \end{aligned}$$

$$\begin{aligned}
 & p(z_i^{rm}, z_i^{rw} | \mathbf{z}^{rm} \setminus l, \mathbf{z}^{rw} \setminus l, \mathbf{z}^m, \mathbf{z}^w, \mathbf{m}, \mathbf{w}, \mathbf{r}) \\
 & \propto \frac{p(\mathbf{r} | \mathbf{z}^{rm}, \mathbf{z}^{rw}) p(\mathbf{z}^m, \mathbf{z}^{rm}) p(\mathbf{z}^w, \mathbf{z}^{rw})}{p(\mathbf{r} \setminus l | \mathbf{z}^{rm} \setminus l, \mathbf{z}^{rw} \setminus l) p(\mathbf{z}^m, \mathbf{z}^{rm} \setminus l) p(\mathbf{z}^w, \mathbf{z}^{rw} \setminus l)} \\
 & = \frac{N_{(\cdot)ke}^{R \setminus l} + \epsilon}{N_{(\cdot)(\cdot)e}^{R \setminus l} + T\epsilon} \cdot \frac{N_{u(\cdot)c}^M + N_{u(\cdot)c}^{RM \setminus l} + \alpha}{N_{u(\cdot)(\cdot)}^M + N_{u(\cdot)(\cdot)}^{RM \setminus l} + C\alpha} \\
 & \quad \cdot \frac{N_{u(\cdot)t}^{RW} + N_{u(\cdot)t}^{RW \setminus l} + \gamma}{N_{u(\cdot)(\cdot)}^{RW} + N_{u(\cdot)(\cdot)}^{RW \setminus l} + T\gamma} \quad (6)
 \end{aligned}$$

なお上式における  $\setminus l$  は、 $l$  番目の要素を除いた場合のカウントを表す。式 (4)、式 (5)、式 (6) に基づくサンプリングを順番に十分回数実行することにより、各潜在クラスターが推定される。また  $\theta, \phi, \mu, \psi, \eta$  の各分布は、最終的に得られたサンプルの集合から MAP 推定によって求められる。

## 4. 実験

提案モデルの性能を評価するため、オフラインのアイテム評価予測実験を行った。実験では、あらかじめデータセットを構築した。ランダムに訓練データとテストデータに分け、訓練データでモデルの学習を行い、学習したモデルを用いてテストデータの評点を予測し、予測の精度や誤差を性能の指標とした。

### 4.1 適用データ

提案モデルは、アイテムの閲覧情報、評点、レビューテ

キストの情報を用いたモデルである。本稿では、楽天技術研究所が公開\*3する、「みんなのレビュー・口コミ情報」のデータを用い、実験用データセットを構築した。公開されているデータベースには、楽天市場のアイテムに対する 1~5 の評点やレビューテキスト、投稿者の属性情報などが含まれている。このうち、カテゴリ「食品」に含まれるデータから、各評点のデータ数が均一になるようにデータを抽出した。これは、実際のデータでは、各評点のデータ数に少なからず偏りが生じているため、単に頻度の高い評点に予測することが著しく有利になり、モデル間の性能比較が難しくなるためである。本稿では各評点 2,360 件ずつ、合計 11,800 件のデータを用いた。このとき、ユーザの異なり数は 3,971、アイテムの異なり数は 2,383、レビューに用いられる単語の異なり数は 11,022 であり、ユーザ × アイテムの行列における評点の密度は 0.06% であった。なお、アイテムの閲覧履歴はデータベースには含まれていないため、半数のデータに対して、それらの評点やレビューの情報を用いず、閲覧履歴とみなして実験を行った。

### 4.2 実験方法

従来モデルとして、RMGM[16] を設定し、提案モデルとの性能比較を行った。評価指標には、文献 [16] と同様に、平均絶対誤差 (Mean Absolute Error: MAE) を用いた。MAE は式 (8) で定義され、値が小さいほど性能が高いことを示す指標である。

$$\text{MAE} = \frac{1}{|T|} \sum_{i \in T} |r_{0i} - \tilde{r}_i| \quad (7)$$

なお、 $T$  はテストデータ集合、 $r_{0i}$ 、 $\tilde{r}_i$  はそれぞれ、アイテム  $i$  の真の評点、モデルによって予測された評点である。提案手法における評点の予測式  $f(r)$  を以下に示す。

$$\begin{aligned}
 p(r | m, \mathbf{w}, u) &= \sum_{c,t} \{p(r | z_c^m, z_t^w) p(z_c^m | m, u) p(z_t^w | \mathbf{w}, u)\} \\
 f(r) &= \sum_{r \in R} r p(r | m, \mathbf{w}, u) \quad (8)
 \end{aligned}$$

実験では、テストデータとして事前に 100 件ランダムに抽出し、残りを訓練データとしてモデルを構築することを 1 試行とした。MAE は 50 試行の平均を用いて比較を行った。なお、提案モデルの各変数のうち、 $\alpha, \beta, \gamma, \delta, \epsilon$  のすべてのハイパーパラメータは 0.1 に固定した。また、従来モデル、提案モデル共に、イテレーション回数は 100 回とし、クラスター数のみを変化させて比較を行った。

### 4.3 結果と考察

初めに、従来モデルにおけるユーザクラスター  $C_u$  とアイテムクラスター  $C_v$ 、提案手法におけるアイテムクラスター  $C$  と単語クラスター  $T$  について、それぞれのクラスター数を変化

\*3 <http://rit.rakuten.co.jp/rdr/>

表 3 従来モデルにおける各クラスターの評点予測性能

Table 3 Performance of rating prediction of each cluster in conventional model

(a) ユーザクラスター				(b) アイテムクラスター			
$C_u$	$C_v$	MAE	(S.D.)	$C_u$	$C_v$	MAE	(S.D.)
1	1	1.204	0.080	1	1	1.204	0.080
5	1	1.237	0.096	1	5	1.237	0.086
10	1	1.260	0.111	1	10	1.229	0.073
20	1	1.266	0.086	1	20	1.225	0.093
30	1	1.268	0.103	1	30	1.217	0.082
40	1	1.251	0.090	1	40	1.233	0.093
50	1	1.277	0.098	1	50	1.222	0.096
60	1	1.291	0.104	1	60	1.220	0.096
80	1	1.279	0.123	1	80	1.213	0.063
100	1	1.245	0.101	1	100	1.254	0.098

表 4 提案モデルにおける各クラスターの評点予測性能

Table 4 Performance of rating prediction of each cluster in proposed model

(a) アイテムクラスター				(b) 単語クラスター			
$C$	$T$	MAE	(S.D.)	$C$	$T$	MAE	(S.D.)
1	1	1.210	0.072	1	1	1.210	0.072
5	1	1.238	0.078	1	5	1.089	0.086
10	1	1.220	0.068	1	10	1.057	0.072
20	1	1.233	0.080	1	20	1.033	0.058
30	1	1.247	0.066	1	30	1.034	0.091
40	1	1.234	0.073	1	40	1.038	0.079
50	1	1.226	0.088	1	50	1.061	0.101
60	1	1.204	0.073	1	60	1.057	0.083
80	1	1.209	0.083	1	80	1.044	0.076
100	1	1.224	0.075	1	100	1.056	0.085

させたときの評点予測性能を比較した。得られた MAE の平均値と標準偏差 (S.D.) を表 3, 表 4 にそれぞれ示す。なお、斜体は各表内における MAE の最良値を表している。

表 3(a)(b), 表 4(a) の結果は、いずれもランダムに評点予測を行った場合の期待値 (MAE = 1.20) と大差なく、評点予測に貢献するクラスターを抽出できていないことが確認できた。一方、表 4(b) の結果から、レビューテキストについては、十分ではないものの、提案モデルにより評点予測に貢献するクラスターが抽出できていることがわかる。

次に、各クラスターを組み合わせることで、評点予測性能にどのような影響があるかを確認した。クラスターの組み合わせ数は  $O(n^2)$  となるため、本稿では対称なクラスター数でのみ実験を行った。実験結果を表 5 に示す。

表 5(a) の従来モデルについては、各クラスターを独立に変化させた表 3 の結果と比べて、僅かながら性能が向上した。一方、表 5(b) の提案モデルについては、単語クラスターのみを変化させた場合よりもやや性能が下回る結果となった。共に性能があまり向上しなかった原因の一つとして、適用したデータセットの性質が挙げられる。ユーザ、アイ

表 5 従来モデルと提案モデルの評点予測性能の比較

Table 5 Performance comparison of rating prediction between conventional model and proposed model

(a) 従来モデル				(b) 提案モデル			
$C_u$	$C_v$	MAE	(S.D.)	$C$	$T$	MAE	(S.D.)
1	1	1.204	0.080	1	1	1.195	0.071
5	5	1.252	0.114	5	5	1.095	0.095
10	10	1.217	0.105	10	10	1.099	0.092
15	15	1.219	0.105	15	15	1.101	0.085
20	20	1.229	0.097	20	20	1.100	0.092
30	30	1.187	0.103	30	30	1.080	0.094
40	40	1.194	0.095	40	40	1.096	0.069
50	50	1.204	0.112	50	50	1.107	0.083

テム共に極めて疎なデータであることで、他のユーザやアイテムの情報からクラスターを推定する両モデルにとって、手掛かりが少ない中で学習をしており、十分なモデリングができなかった可能性が考えられる。特に従来モデルにおいては、文献 [16] において報告されているような性能が発揮できなかったことから、異なるデータセットを用いて評価実験を行う必要があると考えられる。

また、提案モデルでは、データの疎性を補うために、アイテム閲覧履歴などの暗黙的な情報を用いることを試みているが、その効果については本実験では確認できなかった。従来モデルによる予測が適切に行えるようなデータセットにおいて実験を行い、提案モデルの効果について今後検証していく必要がある。

## 5. おわりに

本稿では、アイテムの内容に関する情報であるユーザレビュー履歴に加え、明示的な情報であるアイテム評価履歴と、暗黙的な情報であるアイテム閲覧履歴を活用し、ユーザへの推薦を行うためのモデルの構築を試みた。LDA と同様に、潜在的なクラスターを仮定した階層ベイズモデルを想定し、確率的に閲覧アイテム、レビュー、評点を生成するモデルを提案した。また提案モデルにおいて、Collapsed Gibbs Sampling を用いて潜在的なクラスターを推定する方法を導出した。提案モデルの性能について定量的な評価を行うため、未評価のアイテムの評点を予測するオフラインの実験を行った。実験結果から、レビューに関するクラスターは一定の評価傾向を抽出できたものの、他のクラスターについてはランダムな評点予測と大差のない結果となった。今後は、別の実験データへの適用などを行い、提案モデルの評価を進めていく必要がある。

## 参考文献

- [1] 神島敏弘：推薦システムのアルゴリズム (1), 人工知能学会誌, Vol. 22, No. 6, pp. 826-837 (2007).
- [2] 神島敏弘：推薦システムのアルゴリズム (2), 人工知能学会誌, Vol. 23, No. 1, pp. 89-103 (2008).

- [3] 神島敏弘：推薦システムのアルゴリズム (3), 人工知能学会誌, Vol. 23, No. 2, pp. 248–263 (2008).
- [4] Lewis, D. D., Schapire, R. E., Callan, J. P. and Papka, R.: Training algorithms for linear text classifiers, *Proceedings of the 19th annual international ACM SIGIR conference on Research and development in information retrieval*, SIGIR '96, ACM, pp. 298–306 (1996).
- [5] Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P. and Riedl, J.: GroupLens: an open architecture for collaborative filtering of netnews, *Proceedings of the 1994 ACM conference on Computer supported cooperative work*, CSCW '94, ACM, pp. 175–186 (1994).
- [6] 土方嘉徳：1. 嗜好抽出と情報推薦技術 (嗜好抽出・情報推薦の基礎理論, 特集; 利用者の好みをとらえ活かす-嗜好抽出技術の最前線-), 情報処理, Vol. 48, No. 9, pp. 957–965 (2007).
- [7] Balabanović, M. and Shoham, Y.: Fab: content-based, collaborative recommendation, *Commun. ACM*, Vol. 40, No. 3, pp. 66–72 (1997).
- [8] Popescul, A., Pennock, D. M. and Lawrence, S.: Probabilistic models for unified collaborative and content-based recommendation in sparse-data environments, *Proceedings of the Seventeenth conference on Uncertainty in artificial intelligence*, UAI'01, San Francisco, CA, USA, Morgan Kaufmann Publishers Inc., pp. 437–444 (2001).
- [9] Basilico, J. and Hofmann, T.: Unifying collaborative and content-based filtering, *Proceedings of the twenty-first international conference on Machine learning*, ICML '04, ACM, pp. 65–72 (2004).
- [10] Robillard, M., Walker, R. and Zimmermann, T.: Recommendation Systems for Software Engineering, *Software, IEEE*, Vol. 27, No. 4, pp. 80–86 (2010).
- [11] Hofmann, T.: Probabilistic latent semantic analysis, *Proceedings of the Fifteenth conference on Uncertainty in artificial intelligence*, UAI'99, Morgan Kaufmann Publishers Inc., pp. 289–296 (1999).
- [12] Blei, D. M., Ng, A. Y. and Jordan, M. I.: Latent dirichlet allocation, *J. Mach. Learn. Res.*, Vol. 3, pp. 993–1022 (2003).
- [13] Hofmann, T. and Puzicha, J.: Latent Class Models for Collaborative Filtering, *Proceedings of the 16th International Joint Conference on Artificial Intelligence*, pp. 688–693 (1999).
- [14] Hofmann, T.: Latent semantic models for collaborative filtering, *ACM Trans. Inf. Syst.*, Vol. 22, No. 1, pp. 89–115 (2004).
- [15] Krestel, R., Fankhauser, P. and Nejdl, W.: Latent dirichlet allocation for tag recommendation, *Proceedings of the third ACM conference on Recommender systems*, RecSys '09, ACM, pp. 61–68 (2009).
- [16] Li, B., Yang, Q. and Xue, X.: Transfer learning for collaborative filtering via a rating-matrix generative model, *Proceedings of the 26th Annual International Conference on Machine Learning*, ICML '09, ACM, pp. 617–624 (2009).
- [17] Wang, C. and Blei, D. M.: Collaborative topic modeling for recommending scientific articles, *Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining*, KDD '11, ACM, pp. 448–456 (2011).
- [18] Griffiths, T. L. and Steyvers, M.: Finding scientific topics, *Proceedings of the National academy of Sciences of the United States of America*, Vol. 101, No. Suppl 1, pp. 5228–5235 (2004).