

# 最大エントロピー法に基づく推薦システムでのユーザ行動のモデル化 Modeling User Behavior in Recommender Systems based on Maximum Entropy

岩田 具治†  
Tomoharu Iwata

斉藤 和巳†  
Kazumi Saito

山田 武士†  
Takeshi Yamada

## 1. まえがき

推薦システムは、ユーザの利便性を向上させるとともに収益増加につながるため、多くのオンラインストアで用いられている [11]。システムによる推薦によってユーザの購買行動は影響を受ける。一般に、推薦されることによりその商品を買う確率は上昇するだろう。また、その上昇する割合はユーザによって異なると思われる。オンラインストアにとって、ユーザが推薦を受けたときの購買行動の変化を理解することは重要な課題である。例えば、推薦のユーザの購買確率に与える影響度を知ることにより、推薦により売上がどのくらい増加させることができるか予測できる。これまでにオンラインストアでのユーザ行動モデルは数多く提案されており、予測 [3] や情報検索 [1]、推薦 [10] のために用いられている。しかし、これらのユーザ行動モデルでは、推薦されたときに購買行動がどのように変化するかモデル化されていない。

本稿では、推薦システムを導入しているオンラインストアにおけるユーザの購買行動を最大エントロピー法に基づきモデル化する。提案法ではログデータから推薦を受けたときに購買確率が変化する大きさを推定する。この変化の大きさを推薦の影響度と呼ぶ。推薦システムを評価することは難しいと言われている [4]。一般には推薦システムの評価基準として、未知の評点や次に購入する商品を予測する精度が用いられる。しかし、予測精度の高い推薦が必ずしもよい推薦であるとは限らない。例えば、予測精度が高い推薦はありきたりな商品を推薦しがちになる。セレンディピティや新規性など他の基準を推薦システムの評価として用いることも提案されている [12] が、これらを定量的に測ることは困難である。提案法により推定された推薦の影響度は、推薦システムの定量的な評価基準として用いることができる。

また、推薦の影響度はユーザによって異なると考えられる。例えば、あるユーザは他のユーザに比べ推薦された商品を購入されやすいことがあるだろう。節 2.2 で推薦の影響度を各ユーザ毎に推定する手法について述べる。影響度の違いによりユーザをセグメンテーションしたり、異なる商品を推薦したりすることができる。例えば、影響を受けやすいユーザには収益性の高い商品を推薦することや、推薦した商品を購入しないユーザには推薦を行わないなどの戦略が考えられる。

最大エントロピー法は、与えられたデータに関する制約を満たす確率分布のなかでエントロピーが最大となるものを求める手法であり、ユーザモデリング [5, 6] だけでなく、自然言語処理や情報検索 [9] など幅広い応用分野で使用されている。最大エントロピー法の大きな利点は、任意の特徴量をモデルに組み込むことができることである。提案法ではこの利点を生かし、最大エントロピー法

の枠組でユーザの興味に関する情報と推薦された商品に関する情報を統合し、推薦を受けたときある商品を購入する確率を求める。

推薦システムのための手法として、協調フィルタリング [10] やコンテンツフィルタリング [8]、そのハイブリッド方式 [6] など様々なものが提案されている。協調フィルタリングでは、似た嗜好を持つ他のユーザの情報を用いて嗜好を推定する。また、コンテンツフィルタリングでは、商品情報を利用して嗜好を推定する。これらの手法はユーザの興味を推定し推薦に用いるためユーザ行動モデルと関連深い。推薦する商品を決めるための手法であり、推薦を受けたときの行動をモデル化するものではなく、本稿の目的には用いることができない。

## 2. 提案法

### 2.1 推薦されたときのユーザ購買行動モデル

商品集合を  $S = \{s_j\}_{j=1}^V$ 、ユーザ  $u$  に推薦された商品集合を  $r(u) \subset S$  とする。提案法では、商品集合  $r(u)$  を推薦されたときユーザ  $u$  が商品  $s_j$  を購入する確率を最大エントロピー法により推定する。

購入する商品は、推薦された商品集合とユーザの興味に依存すると考えられる。そこでユーザ購買行動をモデル化するために、以下の 2 種類の特徴量を用いる。1 つ目の特徴量は商品  $s_j$  がユーザ  $u$  に推薦されたかどうかを表す特徴量である。

$$z(r(u), s_j) = \begin{cases} 1 & \text{if 商品 } s_j \text{ をユーザ } u \text{ に推薦,} \\ 0 & \text{otherwise,} \end{cases} \quad (1)$$

2 つ目の特徴量はユーザの興味に関連するものである。直前に購入した商品はユーザの短期的な興味を表し (式 (2))、過去に購入した全商品集合は長期的な興味を表す (式 (3)) と考え、以下の特徴量を用いる。

$$y_{a,b}(u, s_j) = \begin{cases} 1 & \text{if ユーザ } u \text{ の最後の購買が商品 } a \\ & \text{かつ } b = s_j, \\ 0 & \text{otherwise,} \end{cases} \quad (2)$$

$$y_{c,d}(u, s_j) = \begin{cases} \text{ユーザ } u \text{ の商品 } c \text{ 購入数} & \text{if } d = s_j, \\ 0 & \text{otherwise.} \end{cases} \quad (3)$$

上記の特徴量を用いるとき、ユーザ  $u$  が商品集合  $r(u)$  を推薦されたときに商品  $s_j$  を購入する確率は、最大エントロピー法より

$$\begin{aligned} & R(s_j|u, r(u)) \\ &= \frac{1}{Z(u, r(u))} \exp\left(\phi z(r(u), s_j)\right) \exp\left(\sum_{f \in F} \alpha_f y_f(u, s_j)\right), \end{aligned} \quad (4)$$

†日本電信電話株式会社 NTT コミュニケーション科学基礎研究所

となる。ここで  $Z(u, r(u))$  は総和を 1 にするための正規化項、 $\alpha = \{\alpha_f\}$  および  $\phi$  は未知パラメータ、 $F = \{(a, b)_{a,b=1}^V, (c, d)_{c,d=1}^V\}$  は式 (2) 式 (3) で定義した全特徴量の集合である。推薦の有無  $z(r(u), s_j)$  により購買確率は  $\exp(\phi)$  されるため、 $\phi$  は推薦の購入確率に与える影響度を表している。

推薦なしの場合の購買ログと推薦ありの場合の購買ログの 2 種類のログがあるとす。まず推薦なしのログを用いて、推薦がないときの購買確率を推定する。次に推薦ありのログを用いて、推薦の影響度を推定する。

推薦がない場合のユーザ  $u$  が商品  $s_j$  を購入する確率は

$$R(s_j|u) = \frac{1}{Z(u)} \exp\left(\sum_f \alpha_f y_f(u, s_j)\right), \quad (5)$$

となる。ここで  $Z(u)$  は正規化項である。推薦なしのログに対する対数尤度

$$\begin{aligned} L(\alpha) &= \sum_n \sum_k \log R(s_k^n | u_k^n) \\ &= \sum_n \sum_k \sum_f \alpha_f y_f(u_k^n, s_k^n) \\ &\quad - \sum_n \sum_k \log \sum_j \exp\left(\sum_f \alpha_f y_f(u_k^n, s_j)\right), \end{aligned} \quad (6)$$

を準ニュートン法 [7] などの最適化法を用いて最大化することにより、未知パラメータ  $\alpha$  を推定できる。ここで  $s_k^n$  はユーザ  $u_n$  の  $k$  番目の購買商品、 $u_k^n$  はユーザ  $u_n$  の  $k$  番目の購買の以前の購買履歴を表す。実験では過学習を防ぐため、未知パラメータの事前分布として平均 0 の正規分布を用いた [2]。

次に推薦ありのログを用いて推薦の影響度  $\phi$  を推定する。ユーザ  $u$  が商品集合  $r(u)$  を推薦されたとき商品  $s_j$  を購入する確率は、推薦なしの場合の購買確率  $R(s_j|u)$  を用いて以下のように書ける。

$$R(s_j|u, r(u)) = \frac{1}{Z(u, r(u))} \exp\left(\phi z(r(u), s_j)\right) R(s_j|u), \quad (7)$$

ここで  $Z(u, r(u))$  は正規化項である。推薦商品に関する特徴量  $z(r(u), s_j)$  を組み込んでも、興味に関する特徴量のパラメータ  $\alpha$  は変化しないものと考え、推薦なしのログを用いて推定した  $\alpha$  を固定し、以下の対数尤度を最大化することで影響度  $\phi$  を推定する。

$$\begin{aligned} L(\phi) &= \sum_n \sum_k \log R(s_k^n | u_k^n, r(u_k^n)) \\ &= \sum_n \sum_k \left( \phi z(r(u_k^n), s_k^n) + \log R(s_k^n | u_k^n) \right. \\ &\quad \left. - \log \left( (\exp(\phi) - 1) \sum_{s_j \in r(u_k^n)} R(s_j | u_k^n) + 1 \right) \right), \end{aligned} \quad (8)$$

推薦なしのログが得られない場合は、推薦ありのログのみを用いて同時に未知パラメータ  $\alpha$  と  $\phi$  を対数尤度を最大化することにより求めることもできる。

表 1: 推薦なしのモデルの平均対数尤度。

最大エントロピー法	-3.190 ± 0.022
マルコフモデル	-3.565 ± 0.011
多項分布	-4.005 ± 0.010

## 2.2 ユーザ個別の推薦影響度の推定

推薦の影響度はユーザによって異なると考えられるため、前節で述べたモデルに影響度がユーザ毎に異なるモデルに拡張する。最大エントロピー法により、商品集合  $r(u_n)$  が推薦されたときユーザ  $u_n$  が商品  $s_j$  を購入する確率は

$$\begin{aligned} R_u(s_j|u_n, r(u_n)) \\ = \frac{1}{Z_u(u_n, r(u_n))} \exp\left(\phi_n z(r(u_n), s_j)\right) R(s_j|u_n), \end{aligned} \quad (9)$$

となる。ここで  $Z_u(u_n, r(u_n))$  は正規化項、 $\phi_n$  はユーザ  $u_n$  に対する推薦の影響度を表す。

もしユーザが少数の商品しか購入していない場合、個別の影響度  $\phi_n$  の推定は過学習を起こす可能性が高い。過学習を防ぐため、 $\phi_n$  の事前分布として平均  $\bar{\phi}$ 、分散  $1/\eta$  の正規分布を用いた。ここで  $\bar{\phi}$  は式 (8) を最大化することにより推定した、全ユーザで平均した推薦の影響度を表す。このとき最大化すべき目的関数は

$$L_u(\phi_n) = \sum_k \log R_u(s_k^n | u_k^n, r(u_k^n)) - \frac{\eta}{2} (\bar{\phi} - \phi_n)^2, \quad (10)$$

となる。

## 3. 実験

携帯電話用漫画配信サイトのログデータを用い提案法を評価した。このオンラインストアでは各漫画配信ページに 5 つの他の漫画が推薦される。1 つの漫画が複数巻あるものは同一の商品として扱った。

### 3.1 推薦なしの場合のモデルの評価

推薦なしの場合のユーザ購買行動モデル  $R(s_j|u)$  の評価を行った。用いた推薦なしログデータのユーザ数は 28,026、商品数は 126、購買数は 222,903 であった。ここで連続して同一商品を購入した場合のデータは省いた。提案モデルである最大エントロピー法と、マルコフモデル、多項分布を比較した。マルコフモデルでは直前に購入した商品のみから次の購買を予測する。多項分布では全体的な人気度のみから購買を予測する。

評価尺度として平均対数尤度を用いた。高い平均対数尤度は高い予測精度を示す。表 1 に 10 重交差検定の結果得られた各モデルの平均対数尤度を示す。最大エントロピー法の平均対数尤度が最も高く、短期的興味と長期的興味の特徴量を用いることにより、より正確に購買行動を予測できることを示している。

### 3.2 推薦ありの場合のモデルの評価

推薦されたときの購買確率  $R(s_j|u, r(u))$  を評価を行った。まず推薦なしの購買確率  $R(s_j|u)$  を前節の実験で用

表 2: 推薦ありのモデルの平均対数尤度.

個別影響モデル	-3.775 ± 0.015
一様影響モデル	-3.807 ± 0.015
無影響モデル	-3.808 ± 0.015

いたログから推定し、推薦ありのログを用いて推薦の影響度を推定した。  $R(s_j|u)$  の学習に用いたユーザのデータを学習データとし、テストデータは各ユーザの最後に購入した商品とした。ここで連続して同一商品を購入した場合のデータは省いた。このときのデータはユーザ数 8,538, 購買数 230,047 であった。以下の 3 種類の手法での購買確率  $R(s_j|u, r(u))$  を比較した。

- 個別影響モデル: 推薦の購買確率に与える影響度がユーザ毎に異なるモデル
- 一様影響モデル: 推薦の影響度が全てのユーザで一律なモデル
- 無影響モデル: 推薦が購買確率に影響を与えないモデル

個別影響モデルにおけるハイパーパラメータは  $\eta = 1$  とした。


表 2 に 10 重交差検定の結果得られた各モデルの平均対数尤度を示す。個別影響モデルの平均対数尤度が最も高く、一様影響モデルと無影響モデルの性能はほぼ変わらない。この結果は、推薦システムでの購買行動を予測するためには、ユーザ毎に推薦の影響度を推定することが重要であることを示唆する。全ユーザの購買履歴から推定された推薦の影響度は  $\bar{\phi} = 0.119 \pm 0.013$  であった。つまり、購買確率は推薦により  $1.127 (= \exp(0.119))$  倍されており、推薦が購買確率の向上につながっていることが示している。

図 1 に個別影響モデルで推定された推薦の影響度  $\phi_n$  のヒストグラムを示す。  $\phi_n = 0$  付近と  $\phi_n = 0.7$  付近に 2 つの山があり、推薦に影響をあまり受けないユーザ群 ( $\phi_n = 0$  付近) と、推薦に影響されやすいユーザ群 ( $\phi_n = 0.7$  付近) の 2 タイプのユーザがいることが分かる。

#### 4. 応用例：収益を最大化するリコメンデーション法

提案モデルの応用例として、収益を最大化するためのリコメンデーション法を提案する。オンラインストアは収益性の高い商品を購入することをユーザに望む。推薦システムはオンラインストアにとってユーザ行動に影響を与える 1 つの方法であり、提案モデルを用いて、推薦されたときに期待収益が最も高くなる商品を推薦することを考える。商品  $s_j$  が売れたときの収益を  $F(s_j)$  とする。商品  $s_i$  を推薦したときの期待収益は

$$K(s_i) = \sum_j F(s_j) R(s_j|u, r(s_i)), \quad (11)$$

図 1: 個別影響モデルにおける推薦の影響度  $\phi_n$  のヒストグラム.

#### Algorithm 1 ユーザ行動シミュレーションアルゴリズム.

```

1: Set  $u \leftarrow NONE$ ,  $J \leftarrow 0$ 
2: for  $k = 0$  to  $MaxItemNum$  do
3:   if  $u = NONE$  then
4:     Sample  $s_j \sim Multinomial(R(s_j))$ 
5:   else
6:      $\hat{i} \leftarrow \arg \max_i K(s_i)$ 
7:     Sample  $s_j \sim Multinomial(R(s_j|u, r(s_i)))$ 
8:   end if
9:   Set  $u \leftarrow u_{+s_j}$ ,  $J \leftarrow J + F(s_j)$ 
10: end for
11: Output  $J$ 

```

となる。ここで  $r(s_i)$  は商品  $s_i$  が推薦されたという事象を表す。従来リコメンデーション法は一般に各商品の収益を考慮せず、購入される確率が最も高い商品を推薦する。

実ログデータから学習した提案モデルを用いて、収益最大化リコメンデーション法の効果を試算した。Algorithm 1 にユーザから得られる収益をシミュレーションするためのアルゴリズムを示す。ここで  $u$  は購買履歴、 $NONE$  は空の購買履歴、 $J$  は総収益、 $MaxItemNum$  は最大購買商品数、 $Multinomial(\psi)$  は  $j$  番目の要素の成功確率が  $\psi_j$  の多項分布、 $u_{+s_j}$  は新たに商品  $s_j$  を購入したときの更新された購買履歴を表す。はじめに購入する商品は確率  $R(s_j)$  に従って決定される (行 4)。すでに商品を購入しているユーザには、収益を最大化する商品を推薦し (行 6)、購入される商品は確率  $R(s_j|u, r(s_i))$  に従って決定される (行 7)。購買数が  $MaxItemNum$  に達した時点でシミュレーションを終了する。

Algorithm 1 に示した収益最大化リコメンデーション法 **K-Rec** と、以下の 4 つのリコメンデーション法を比較した。

- **FR-Rec** リコメンデーションなしの場合の期待収益が最も高くなる商品を推薦する。行 6 を以下のよ

うに変更する。

$$\hat{i} \leftarrow \arg \max_i F(s_i)R(s_i|u). \quad (12)$$

この手法はリコメンデーションしたとき、ユーザの購買確率が必ず上昇すると仮定している。

- **F-Rec** 購入されたとき収益が最大となる商品を推薦する。

$$\hat{i} \leftarrow \arg \max_i F(s_i). \quad (13)$$

この手法はユーザの興味を考慮しない。

- **R-Rec** 購入される確率が最も高い商品を推薦する。

$$\hat{i} \leftarrow \arg \max_i R(s_i|u). \quad (14)$$

この手法は従来リコメンデーション法と同じく、各商品の収益性は考慮しない。

- **No-Rec** 何も推薦しない。行6を省き、行7を以下のように変更する。

$$\text{Samples}_j \sim \text{Multinomial}(R(s_j|u)), \quad (15)$$

この手法ではユーザは自身の興味のみに従って購入商品を決める。

各リコメンデーション手法を用いた場合の8,538人のユーザの収益をシミュレーションにより生成した。ここで未知パラメータ  $\alpha$  と各ユーザの推薦の影響度  $\phi_n$  は前節で述べた実ログデータから学習したものをを用いた。各商品の収益  $F(s_j)$  は0から  $V-1$  のいずれかの整数をランダムに割り当てた。ここで  $V$  は全商品数である。また、最大購買商品数を  $\text{MaxItemNum} = 10$  とし、確率  $R(s_j)$  は全商品で一定とした。図2に各手法で商品を購入したときの平均収益を示す。K-Rec は最も収益を伸ばすことができている。FR-Rec も同じく収益を伸ばしているが、その効果はK-Rec に比べて小さい。これは推薦された商品を購入しないユーザ ( $\phi_n < 0$ ) の場合、FR-Rec は収益を下げてしまうためである。F-Rec は、ユーザの興味を考慮していないため、購入される確率がない商品も推薦してしまう可能性があり、収益を高めることはできていない。R-Rec は収益性が低い商品でも推薦してしまうので平均収益は下がっている。

本節では、提案したユーザ行動モデルを用いることにより、収益を最大化するためのリコメンデーション法を実現できることを示した。K-Rec が収益を高めることができたのは、各ユーザの推薦の影響度をモデルに取り込んでいるためである。収益性の高い商品等、ある性質をもった商品をリコメンデーションによって購入してもらうためには、推薦の影響度をモデルに組み込む必要がある。

## 5. おわりに

推薦システムでのユーザ行動モデルを提案し、実ログデータによりその有効性を確認した。また提案モデルが収益を高めるためのリコメンデーション法に適用できることを示した。実験では単純な特徴量を用いたが、今後はユーザ属性や商品情報もユーザモデルに組み込み発展させていきたい。

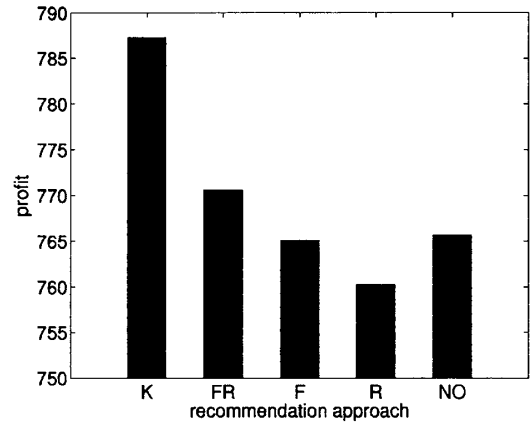


図2: シミュレーションによる平均収益。

## 参考文献

- [1] D. Billsus and M. J. Pazzani. A hybrid user model for news story classification. In *Proc. of the seventh international conference on User modeling*, pp. 99–108, 1999.
- [2] S. F. Chen and R. Rosenfeld. A gaussian prior for smoothing maximum entropy models. Technical report, CMUCS-99-108, 1999.
- [3] E. H. Chi, P. Pirolli, K. Chen, and J. Pitkow. Using information scent to model user information needs and actions and the web. In *Proc. of the SIGCHI conference on Human factors in computing systems*, pp. 490–497, 2001.
- [4] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl. Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems*, 22(1):5–53, 2004.
- [5] T. Iwata, K. Saito, and T. Yamada. Recommendation methods for extending subscription periods. In *Proc. of the ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pp. 574–579, 2006.
- [6] X. Jin, Y. Zhou, and B. Mobasher. A maximum entropy web recommendation system: combining collaborative and content features. In *Proc. of the ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pp. 612–617, 2005.
- [7] D. C. Liu and J. Nocedal. On the limited memory bfgs method for large scale optimization. *Math. Programming*, 45(3):503–528, 1989.
- [8] R. J. Mooney and L. Roy. Content-based book recommending using learning for text categorization. In *Proc. of the Fifth ACM Conference on Digital Libraries*, pp. 195–204, 2000.
- [9] K. Nigam, J. Lafferty, and A. McCallum. Using maximum entropy for text classification. In *Proc. of IJCAI-99 Workshop on Machine Learning for Information Filtering*, pp. 61–67, 1999.
- [10] D. Y. Pavlov and D. M. Pennock. A maximum entropy approach to collaborative filtering in dynamic, sparse, high-dimensional domains. In *Advances in Neural Information Processing Systems*, pp. 1441–1448, 2002.
- [11] J. B. Schafer, J. A. Konstan, and J. Riedl. E-commerce recommendation applications. *Data Mining and Knowledge Discovery*, 5:115–153, 2001.
- [12] C.-N. Ziegler, S. M. Mcnee, J. A. Konstan, and G. Lausen. Improving recommendation lists through topic diversification. In *Proc. of the 14th international conference on World Wide Web*, pp. 22–32, 2005.