

確率潜在空間モデルに基づく推薦システムに関する研究

1X07C069-0 鈴木健史
指導教員 後藤正幸

1 研究背景

近年、数多くのインターネットショッピングサイトではユーザの嗜好に合うと予測されたアイテムのリストを提示する推薦システムが実装されている。推薦システムの代表的な手法として協調フィルタリング (CF) があり、過去の購買履歴情報を利用し、ユーザ同士の購買履歴の類似性から、ユーザの興味があり購買しそうなアイテムを推薦する方法が基本となっている。

一方、近年ユーザが購買後のアイテムに評価値を付与できるサイトも増加していることから、この評価情報を利用した、未評価のアイテムに対する評価値予測の研究が行われるようになってきている。その中でも確率潜在空間モデルである Flexible Mixture Model (FMM) が評価値を正確に予測できるモデルとして優れている [1]。

推薦するアイテムは、ユーザの購買可能性が高く、興味があるアイテムであることに加え、購買使用後の評価も高いことが望まれる。しかし、購買可能性の視点のみでアイテムを推薦する場合、そのアイテムは購買後の評価が低い可能性があり、予測評価値の視点のみでアイテムを推薦する場合には、興味のないアイテムを推薦してしまう可能性がある。これらの問題は、ユーザの購買可能性と予測評価値という双方の視点を同時に考慮することで解決できると考えられる。

そこで、本研究では、FMM が確率モデルであることを利用してユーザの購買確率と予測評価値を推測し、これら双方が高いアイテムを推薦する手法を提案する。提案手法を TopN 精度 [2] と推薦されたアイテムの平均評価値によって従来手法と比較しその有効性を示す。

2 従来手法

2.1 Flexible Mixture Model

Flexible Mixture Model (FMM) とは、Siら [1] によって提案された未評価アイテムの評価値推定を目的とした確率潜在空間モデルである。I 個のアイテムからなるアイテム集合を $\mathcal{X} = \{x_i : 1 \leq i \leq I\}$ 、J 人のユーザからなるユーザ集合を $\mathcal{Y} = \{y_j : 1 \leq j \leq J\}$ とし、評価値 r は R 段階 ($1 \leq r \leq R$) とする。ここで (x_i, y_j, r) はユーザ y_j がアイテム x_i を利用し、評価値 r を付けたことを表し、FMM ではこの 3 次元の情報のみを扱う。また、アイテムと評価値に対して潜在クラスが存在することを仮定し、その集合を $\mathcal{Z} = \{z_k : 1 \leq k \leq K\}$ とする。一方、ユーザと評価値に対しても潜在クラスが存在するものとし、その集合を $\mathcal{W} = \{w_l : 1 \leq l \leq L\}$ とする。このモデルは、 x_i, y_j, r に対して潜在クラス z_k, w_l を仮定し、同じような嗜好を持つユーザクラスと似たアイテムクラスにより評価値が決定されるというモデルである。また、各ユーザとアイテムは潜在クラスに複数所属するという特徴がある。

FMM では各ユーザとアイテムに潜在クラスを別々に仮定することにより、評価値予測モデルとして優れた予測精度を示す。FMM のグラフィカルモデルを図 1 に示す。また、FMM の確率モデルは式 (1) で表現される。

ここで各パラメータ $P(z_k), P(w_l), P(x_i|z_k), P(y_j|w_l),$

$P(r|z_k, w_l)$ はそれぞれ多項分布に従い、各パラメータは EM アルゴリズムで対数尤度を最大にするパラメータを推定することができる。

$$P(x_i, y_j, r) =$$

$$\sum_{k,l} P(z_k)P(w_l)P(x_i|z_k)P(y_j|w_l)P(r|z_k, w_l) \quad (1)$$




図 1. FMM のグラフィカルモデル

2.2 予測評価値の求め方

EM アルゴリズムによって得られたパラメータより、ユーザ y_j 、未評価のアイテム x_i 、評価値 r の同時確率である推定量 $\hat{P}(x_i, y_j, r)$ を式 (1) から求める。ユーザ y_j によるアイテム x_i に対する予測評価値を $\hat{r}(x_i, y_j)$ とすると、以下の式により求められる。

$$\hat{r}(x_i, y_j) = \sum_r r \frac{\hat{P}(x_i, y_j, r)}{\sum_r \hat{P}(x_i, y_j, r)} \quad (2)$$

3 提案手法

3.1 背景

式 (2) はユーザがアイテムを利用したと仮定したもとの予測評価値であるが、これらの予測評価値はユーザが興味のないアイテムに対しても高くなってしまいう可能性がある。その原因として、少数のユーザしか評価していないアイテムでも、それらの評価値が偏って高い場合、予測評価値が高くなってしまいうことが考えられる。

そこで、購買確率と予測評価値の双方を考慮したアイテムを予測する手法を提案する。FMM が確率モデルであることを利用して、予測評価値に加えてユーザがアイテムを購入する確率を求め、双方が高いアイテムを推薦する。

3.2 推薦リストの作成方法

FMM が確率モデルであることを利用しユーザ y_j によるアイテム x_i の購買確率を $\hat{P}(x_i|y_j)$ とする。式 (2) に加えて、 $\hat{P}(x_i|y_j)$ を考慮することで新たな予測指標 $N(x_i, y_j)$ を計算し推薦リストを作成する。

ここで、 $\hat{P}(x_i|y_j)$ 、 $N(x_i, y_j)$ は以下の式で求める。

$$\hat{P}(x_i|y_j) = \frac{\sum_r \hat{P}(x_i, y_j, r)}{\sum_{i,r} \hat{P}(x_i, y_j, r)} \quad (3)$$

$$N(x_i, y_j) = \alpha \frac{\hat{r}(x_i, y_j)}{R} + (1 - \alpha) \frac{\hat{P}(x_i|y_j)}{\max \hat{P}(x_i|y_j)} \quad (4)$$

α は両項のどちらを重視するかを決める重みパラメータである。式 (4) では、両項を第 1 項、第 2 項ともに最大が 1 となるように基準化している。また、 $\alpha = 1$ のときは、予測評価値のみを考慮した従来手法となる。 α を変化させることにより第 1 項、第 2 項をバランス良く考慮した推薦リストの提示が可能となると考えられる。提案手法では、 $N(x_i, y_j)$ の値が高いアイテムをランキングすることにより推薦リストを作成する。

4 評価実験

提案手法の有効性を示すため、データセットを用いて評価実験を行った。

4.1 実験条件

本実験では、公開データセット MovieLens[3] を用いた。このデータは 1997 年 9 月から 1998 年 4 月までに集められた映画の評価データである。ユーザ数 $J = 943$ 、映画数 $I = 1682$ 、総データ数 10 万件であり、訓練データ 8 万件とテストデータ 2 万件に分けられている。評価値は $R = 5$ の 5 段階評価である。ユーザはすべてのアイテムのうち最低 20 件以上の評価を付けている。潜在変数のクラス数 K, L は従来手法と同様にそれぞれ 20, 10 とした。

FMM は与える初期値により結果が変化するため、各手法の実験を乱数を用いて 10 回ずつ行い、 α は 0 から 1 まで 0.1 刻みで評価を行う。また、推薦するアイテム数 N を 10, 20, 30 件と変化させた結果を示す。

4.2 評価方法

本研究では推薦システムの評価指標でよく使用されている TopN 精度 [2] を用いて、各手法の評価を行う。TopN 精度は以下の式 (5) によって求められる。ただし、 N は推薦するアイテム数、 G_4 は推薦したアイテムのうちテストデータ中に含まれ、かつ実際の評価値が 4 以上のアイテム数とする。この評価指標により、どの程度ユーザが推薦されたアイテムに興味を持ち、かつ 4 以上の高評価を付与したかを評価できると考えられる。

$$\text{TopN 精度} = \frac{G_4}{NJ} \quad (5)$$

また、本研究では式 (6) に示す平均評価値という新たな評価指標を用いる。これにより、購入後のアイテムに対するユーザの平均評価値を評価できると考えられる。

$$\text{平均評価値} = \frac{S_R}{F} \quad (6)$$

F は推薦されたアイテムでテストデータ中に含まれたアイテム数、 S_R はそれらのアイテムのテストデータ中の評価値を合計した値とする。

4.3 実験結果

図 2 は α を変化させた時の TopN 精度の実験結果である。提案手法の $N=10, 20, 30$ において、それぞれ $\alpha=0.7, 0.5, 0.5$ の時に最も優れた結果を示し、従来手法 ($\alpha=1$) と比較し大幅に精度が向上した。

図 3 は TopN 精度と同様に α と N を変化させたときの平均評価値の実験結果である。提案手法では、 $\alpha \rightarrow$ 大とするほど、つまり予測評価値を考慮するほど平均評価値が上昇するという結果となった。




図 2. Top10, 20, 30 の TopN 精度




図 3. Top10, 20, 30 の平均評価値

4.4 考察

1. 図 2 より、提案手法は、従来手法と比較して、TopN 精度の面で大幅に優れた結果を示した。これは、ユーザの購買確率を考慮することで、興味を示すアイテムの推薦ができたと考えられる。
2. 図 3 より、予測評価値を考慮するほど、平均評価値が上昇している。これにより、予測評価値を考慮することで購入後のアイテムに対する評価値が高くなる傾向があることが示された。
3. 図 2, 3 より、予測評価値と購買確率はトレードオフの関係にあることがわかる。しかし、提案手法では $\alpha=1$ から $0.5 \leq \alpha \leq 0.7$ にすることで平均評価値は 0.2~0.5 ポイント程度の減少であるのに対し、TopN 精度は約 0.20 の大幅な上昇が認められる。この結果、提案手法では $0.5 \leq \alpha \leq 0.7$ とすることで、評価値と購買確率の両方がバランスよく高いアイテムを推薦することが可能であることが示された。

5 まとめと今後の課題

本研究では、予測評価値と購買確率の両方を考慮した推薦手法を提案した。実験結果において、提案手法は TopN 精度と平均評価値の 2 つの指標により有効性が示された。

今後は、予測評価値の精度や購買確率の予測精度を向上させることが課題である。

参考文献

- [1] S. Luo, Z. Chengxiang, and J. Rong, "A Study of Mixture Models for Collaborative Filtering," *Journal of Information Retrieval*, vol. 9, pp. 357-382, 2006.
- [2] B. Sarwar, G. Karypis, J. Konstan, and J. Riedl, "Application of Dimensionality Reduction in Recommender System," *In ACM WebKDD Workshop*, 2000.
- [3] MovieLens. "http://www.movielens.org/".