

アソシエーションルールを用いた協調フィルタリングにおける 意外性向上に関する検討

伊藤 寛明^a 吉川 大弘^b 古橋 武^c

名古屋大学

a) itou@cmlx.cse.nagoya-u.ac.jp b) yoshikawa@cse.nagoya-u.ac.jp c) furuhashi@cse.nagoya-u.ac.jp

概要 近年、インターネットの普及による電子商取引の増加により、推薦システムが注目されている。その中で、“精度”は推薦システムにおいて重要な指標であるが、ユーザの満足度の観点から、近年、“意外性”も必要とされている。本稿では、推薦システムの代表的な方法である協調フィルタリングにおいて、データマイニングの一手法であるアソシエーション分析に基づくアイテム推薦手法について検討する。推薦対象となるユーザとは異なる評価をしたユーザの嗜好を用いることで、推薦システムの意外性を向上させることを目的とする。また、推薦に用いるスコアのパラメータを変化させることにより、精度・意外性が調節可能であることを示し、従来手法との比較を行う。

キーワード 推薦システム, 協調フィルタリング, アソシエーションルール, 意外性

1 はじめに

近年、インターネットの普及により電子商取引が増加しており、それに伴いECサイトでは膨大な数の商品を扱うようになってきている。そのため、それらの商品の中から、ユーザの嗜好にあった商品をユーザ自身で探し出すことが困難となることで、推薦システムの利用が期待されている [1]。一方、大量にあるデータの中から、価値のある情報を抽出するデータマイニング手法の一つにアソシエーション分析 [2] がある。この手法をユーザの評価履歴に対して適用し、協調フィルタリングによるアイテム推薦に用いた研究が報告されている [3][4]。また推薦システムにおいて、推薦したアイテムがユーザに好まれた割合を表す“精度”は、最も重要な評価指標の一つである。しかし近年、ユーザ満足度の観点から、精度に加えて、“意外性”に対する評価の必要性が指摘され始めている [1][4]。

従来のアソシエーション分析を適用した協調フィルタリングでは、推薦を行うユーザと同じ評価をしたユーザの嗜好をもとにアイテムを推薦していた。本稿では、協調フィルタリングによる推薦システムにおいて、推薦を行うユーザと異なる評価をしたユーザの嗜好情報を用いることで、推薦システムにおける意外性の向上を図る。

2 推薦システム

2.1 アソシエーション分析

アソシエーション分析とは、データの中から価値のある組み合わせ（アソシエーションルール）を見つけ出す手法である。アソシエーションルールは、 $A \Rightarrow B$ と表され、 A は条件部、 B は結論部と呼ばれる。このルール

は、 A という事象が生じたときに、 B という事象が生じるという意味をもつ。代表的なアソシエーションルールの評価指標として *confidence* がある。

$$confidence_{(A \Rightarrow B)} = \frac{N(A \cap B)}{N(A)} \quad (1)$$

$N(A)$, $N(A \cap B)$ はそれぞれ、条件部 A 、条件部 A と結論部 B を同時に満たすデータの件数（本稿においてはユーザ数）である。

2.2 提案手法

推薦を行うユーザ（以降、“対象ユーザ”と呼ぶ）の評価、またその反対の評価をアソシエーションルールの条件部に用いて、結論部に各アイテムに対する評価「Like」を当てる。対象ユーザの評価履歴を A とし、それを条件部に用いる場合の *confidence* を $confidence_{(A \Rightarrow B)}$ 、同様に反対の評価 \bar{A} を条件部に用いる場合を $confidence_{(\bar{A} \Rightarrow B)}$ とする。 $confidence_{(A \Rightarrow B)}$ が大きく、 $confidence_{(\bar{A} \Rightarrow B)}$ が小さいほど、対象ユーザが B 、つまり推薦候補のアイテムを「Like」と評価することが期待される。

両者の差 d を式 (2) で定義する。

$$d = confidence_{(A \Rightarrow B)} - confidence_{(\bar{A} \Rightarrow B)} \quad (2)$$

$|d|$ が大きいほど、 A と評価した対象ユーザが \bar{A} と評価したユーザと嗜好が異なることを表しているため、この評価履歴の情報量が大きいと考えられる。よって、 $confidence_{(A \Rightarrow B)}$ は精度、 d は対象ユーザに特化した意外な推薦に結びつくと考えられる。

推薦に用いるスコアを式 (3) で定義する。

$$s_B = \begin{cases} confidence_{(A \Rightarrow B)}^\alpha * d & \text{if } d \geq 0 \\ confidence_{(A \Rightarrow \bar{B})}^\alpha * d & \text{otherwise} \end{cases} \quad (3)$$

s_B は $confidence_{(A \Rightarrow B)}$ 、 d が大きいほど高い値となり、 $confidence_{(A \Rightarrow \bar{B})}$ が大きく ($confidence_{(A \Rightarrow B)}$ が小さ

く), d が小さいほど低い値となる. α は精度に対する重みであり, α が 0 の場合に, $s_B=d$ となるため, α が 0 に近いほど意外性のあるアイテムを推薦することができると考えられる (例えば B が全体からの「Like」割合が高い場合, 式 (2) の右辺はどちらの項も値が大きくなるため, d の値は小さくなる). 対象ユーザが条件部のアイテムに対して評価を行い, 結論部のアイテムが未評価であるとき, 全ユーザの評価情報により求められる s_B を, 結論部のアイテム B のスコアに加算する. 対象ユーザのすべての評価履歴をもとに未評価のアイテムのスコアを求め, 最もスコアの高いアイテムを推薦する.

3 実験

3.1 使用データ

実験には, GroupLens[5]が公開している MovieLens[6]の映画に対する評価データを用いた [7][8]. 映画に対する 10 段階の評点 (0.5~5.0 の 0.5 刻み) のうち, 0.5 から 3.5 を「Don't Like», 4 から 5 を「Like」として実験を行った. ただし, 「Like」と「Don't Like」をそれぞれ 51, 50 回以上評価したユーザ 1118 人, 300 人以上に評価された 611 のアイテムを対象とした.

3.2 推薦システムの評価

本実験では, 対象ユーザにおける評価履歴「Like」のアイテムの中から, ランダムに選択された 1 つを評価済みアイテムとして与えた状態から, その他の評価済みアイテムを「未評価」とみなしてアイテムの推薦を 50 回行った. 10-fold cross-validation を 10 試行行ったときの平均値を求めた. 推薦システムの評価指標 ($= \frac{1}{N} \sum_{i=1}^N t_i$) を以下に示す [4]. 推薦回数を N , 推薦アイテムの集合を $I=\{I_1, I_2, \dots, I_N\}$, I_i に対する評価履歴を $e(I_i)=1/-1$ (Like/Don't Like) とする.

a) 精度

精度は, 対象ユーザが推薦されたアイテムに対して「Like」と答えた割合である.

$$t_i = \begin{cases} 1 & \text{if } e(I_i) = 1 \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

b) Novelty

式 (5) で, I_{NP} は Non-Personalized 法における推薦アイテムの集合であり, Novelty は推薦アイテムが「Like», かつ Non-Personalized な推薦には現れない割合である.

$$t_i = \begin{cases} 1 & \text{if } e(I_i) = 1 \text{ and } I_i \notin I_{NP} \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

c) Personalizability[4]

式 (6) において, $P(e(I_i) = 1)$ は, 全ユーザにおけるアイテム I_i に対する「Like」割合である. Personalizability は, 推薦アイテムの「Like」の割合の低さを情報量にし

たもので, 推薦されたアイテムが「Like», かつそのアイテムの「Like」割合が小さいほど大きな値をとる.

$$t_i = \begin{cases} \log_2 \frac{1}{P(e(I_i)=1)} & \text{if } e(I_i) = 1 \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

b), c) は, 従来研究において意外性の指標として提案されている. これらの指標をもとに, 従来手法である Weighted Sum 法 [9] と提案手法を比較した. 従来手法におけるアイテムの近傍数は, 精度が最も高くなった 610 とした. 図 1 に結果を示す. α が 0 に近いときは, 提案手法は従来手法よりも意外性が高く, 1 に近い場合は精度が高いことを確認できた. また, α が 0.2 から 0.4 で精度・意外性共に提案手法が上回る結果となった.

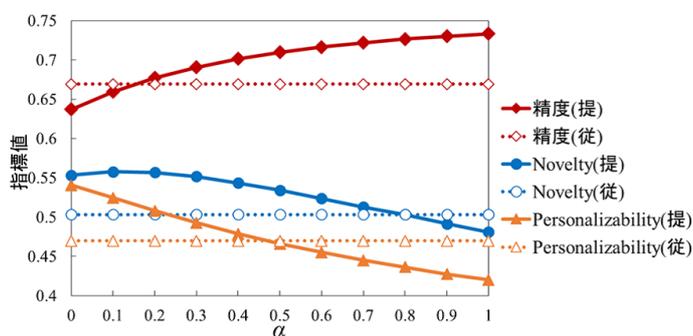


図 1 α による精度・意外性の変化

4 おわりに

本稿では, アソシエーションルールを用いた推薦手法において, 対象ユーザとは異なる評価をしたユーザの嗜好情報を用いることで, 推薦システムの意外性を向上させることができること, また調整項 α により, 精度と意外性との重みを調整できることを示した.

参考文献

- [1] 神尾 敏弘: 推薦システムのアルゴリズム (1)~(3), 人工知能学会誌, Vol.22, No.6~Vol.23, No.2, 2007-2008
- [2] Agrawal, R., Srikant, R.: Fast algorithms for mining association rules in large databases, 20th VLDB, pp.487-499, 1994
- [3] Lin, W., Alvarez, S. A. and Ruiz, C.: Efficient adaptive-support association rule mining for recommender systems, Data Mining and Knowledge Discovery, Vol.6, No.1, pp.83-105, 2002
- [4] 吉川大弘, 森貴章, 古橋武: Personalizability を考慮した推薦システムの提案, 情報処理学会誌 数理モデル化と応用, Vol.6, No.1, pp.111-118, 2013
- [5] the original MovieLens dataset from GroupLens research group: <http://www.grouplens.org>
- [6] Cantador, I., Brusilovsky, P. and Kuflik, T.: 2nd workshop on information heterogeneity and fusion in recommender systems (HetRec 2011), 5th ACM RecSys, pp.387-388, 2011
- [7] IMDb website: <http://www.imdb.com>
- [8] Rotten Tomatoes website: <http://www.rottentomatoes.com>
- [9] Sarwar, B., Karypis, G. Konstan, J., et al.: Item-based collaborative filtering recommendation algorithms, 10th WWW, pp.285-295, 2001