

# アソシエーションルールを用いた 推薦システムにおける精度と意外性の向上

伊藤 寛明<sup>1,a)</sup> 吉川 大弘<sup>1</sup> 古橋 武<sup>1</sup>

受付日 2014年8月25日, 再受付日 2014年10月17日/2015年1月8日,  
採録日 2015年2月26日

**概要:** 近年, インターネットの普及により, オンラインショップで扱う商品数が増加している. これにより, ユーザの選択肢が広がる一方で, 多くの商品から好きなアイテムを見つける必要がある. そのため, 現在は様々な推薦システムが利用されている. 推薦したアイテム数に対する, ユーザが好んだ/購入したアイテム数の割合である“精度”は, これらの推薦システムにおいて最も重要な指標である. しかしながら近年, ユーザの満足度の観点から, “精度”だけでなく, “意外性”も必要とされている. 本論文では, 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いた協調フィルタリングによるアイテム推薦において, 高い精度を保ちつつ, 意外性を向上させる手法について検討する. また, 意外性の評価指標として用いた“Novelty”と“Personalizability”の妥当性についての検証を行い, “Novelty”, “Personalizability”の向上が意外性の向上に寄与することを示す.

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

## Improvement of Accuracy and Serendipity in Recommendation System Using Association Rule

HIROAKI ITO<sup>1,a)</sup> TOMOHIRO YOSHIKAWA<sup>1</sup> TAKESHI FURUHASHI<sup>1</sup>

Received: August 25, 2014, Revised: October 17, 2014/January 8, 2015,  
Accepted: February 26, 2015

**Abstract:** The number of available items in online shops are increasing by the spread of the Internet recently. Though users have a wide range of choices, they need to find their favorite items from a huge amount of items. Thus, a variety of recommendation systems are currently in use. “Accuracy,” which is the ratio of the number of target user’s favorite or bought items over recommended items, is the most important index in these recommendation systems. However, not only “Accuracy” but also “Serendipity” is said to be needed in terms of user satisfaction recent years. In this paper, we introduce a recommendation method of collaborative filtering based on association analysis which is one of the data mining techniques and try to improve “Serendipity” keeping “Accuracy” high. In addition, we investigate the validness of “Novelty” and “Personalizability” which are used as the evaluation index for “Serendipity” and show that the increase of the value of “Novelty” and “Personalizability” leads high “Serendipity.”

**Keywords:** recommendation system, association rule, Serendipity, collaborative filtering

### 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, それにともない, 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り, 推薦システムの利用が期待されている [1]. 推薦システムを導入している代表的な例として, Amazon.com<sup>\*1</sup>があげられる. 商品ページに他のユーザが

<sup>1</sup> 名古屋大学  
Nagoya University, Nagoya, Aichi 464-8603, Japan  
<sup>a)</sup> itou@cmplx.cse.nagoya-u.ac.jp

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

購入したおすすめ商品を提示し、商品ページを閲覧しているユーザに推薦が行われている。

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1つにアソシエーション分析がある [4]。アソシエーション分析は、関係性の強い組合せをアソシエーションルールとして抽出し、新たな知見を得るために用いられる。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 [5], [6]。

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1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”や“説明性”に対する評価の必要性が指摘され始めている [1], [2], [3], [6], [7], [8]。奥らは、“意外性”の評価に、“新しい興味”や“新たな発見”を導入している [9]。また、アソシエーションルールは条件部と結論部から成り立っているため、ルールを視覚的にとらえることが可能である [10], [11], [12]。そのため、ユーザにアイテムを提示するだけでなく、アソシエーションルールを同時に可視化することによって、推薦理由についての高い説明性が期待される。

推薦システムは、協調フィルタリングとコンテンツベースフィルタリングの大きく2つに分けられる。協調フィルタリングは、推薦を行うユーザ（以降、対象ユーザ）の嗜好と類似したユーザまたはアイテムを評価履歴データから見つけ、推薦を行う。そのため、推薦を行うにはユーザのアイテムに対する評価履歴が必要となる。一方、コンテンツベースフィルタリングは、対象ユーザが好むアイテムの特徴と類似したアイテムを推薦する手法である。コンテンツベースフィルタリングでは、アイテムの特徴の類似性に基づいてアイテムを推薦するため、コンテンツ情報が多いほど、高い精度となることが期待されるが、同じ著者のものや同じ映画監督の作品など、類似コンテンツを持つアイテムを推薦することが多く、“意外性”は低くなりやすい。これに対し、アイテムのコンテンツ情報を用いて“意外性”を高める研究が報告されている [9], [13]。しかし一般的には協調フィルタリングはコンテンツベースフィルタリングに比べ“意外性”が高く [2], [8]、またコンテンツベースフィルタリングでは、推薦候補となるすべてのアイテムのコンテンツ情報が必要となることから、本論文では協調フィルタリングに注目する。協調フィルタリングには、アイテムベース協調フィルタリングとユーザベース協調フィルタリングがあり、先にあげた Amazon.com では、アイテムベース協調フィルタリングにより推薦が行われている [14]。アイテムベース協調フィルタリングで用いられるアイテム間類似度はオフラインで計算可能であり、ユーザベースと同等、またはそれ以上の精度が期待される [15]。また一方で、後述する比較実験により、アイテムベースはユーザベース

と比較して意外性が低くなる結果となった。そこで本論文では、アイテムベース協調フィルタリングを用いて意外性を向上させることを目的とする。

アソシエーションルールに基づく従来の協調フィルタリングにおいては、推薦スコアを求める際に、対象ユーザの評価履歴を条件部に用いる方法が一般的であり、対象ユーザの反対の評価を条件部に持つルールは考慮されていない。本論文では、対象ユーザの反対の評価情報を用いることで、精度を保ちつつ、意外性を向上させる推薦システムを提案する。提案手法では、トレードオフとなる精度と意外性を調整可能なパラメータを導入する。実験により、提案手法での精度を重視することで、従来手法において精度が最も高くなるようパラメータチューニングしたものと比較して、同程度の精度かつ意外性の向上、また、意外性を重視することで、従来手法において最も意外性が高くなるようパラメータチューニングしたものと比較して、同程度の意外性かつ精度の向上が実現できることを示す。さらに提案手法では、推薦初期には精度重視、推薦が進むにつれて徐々に意外性重視とすることや、精度が落ちてきたときに精度重視となるようパラメータを調整するなど、ユーザの評価に応じて動的に精度と意外性のパラメータを調整することが可能である。

また本論文では、意外性の評価指標として用いた“Novelty”と“Personalizability”の妥当性についての検証を行い、“Novelty”、“Personalizability”の向上が意外性の向上に寄与することを示す。

## 2. 推薦システム

### 2.1 想定する推薦システム

本論文では、Amazon.com のように一度に複数のアイテムを推薦するのではなく、音楽推薦のように、アイテムを1つずつ連続的に推薦を行うシステムを想定する。また、推薦されたアイテムに対し、対象ユーザに好きか嫌いかの評価で判定してもらい、その評価情報を評価履歴としてデータベースに蓄積する。さらに前述のとおり、アイテムのコンテンツ情報（映画におけるジャンル、監督、出演俳優など）は用いず、評価履歴のみを用いて推薦を行う。これは、有効となる特徴量やそれらの使い方は、アイテムの種類により異なっており、また、必ずしもすべてのアイテムについてそれらのコンテンツ情報を持つとは限らないためである。

### 2.2 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合せ（アソシエーションルール）を見つけ出す手法である。スーパーで頻繁に購入されている商品の組合せを見つけ、それらを商品の陳列に反映することで、売り上げを向上させた例が有名である。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。代表的なアソシエーションルールの評価指標として *confidence* があり、以下の式で計算される。

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

$N(A)$  は条件部  $A$ 、 $N(A \wedge B)$  は条件部  $A$  と結論部  $B$  を同時に満たすデータの件数である。本論文においては、ユーザ数またはアイテム数となる。ただし、*confidence* を推薦に用いる場合に、ゼロ頻度問題に対応するために、式 (1) の計算にはラプラススムージング [16] を行う。ベイジアンネットワーク [17] は、式 (1) においてアソシエーション分析に類似しているが、アソシエーション分析は、*confidence* のほかにも *support* や *lift* といったルールを評価する指標がある。これらの指標を用いることで、対象ユーザに推薦理由を分かりやすく説明することが可能であると考えられる (例「あなたが好きと評価したアイテム  $A$  を好きな人の 80%がこのアイテムを好きと言っています。」)。

$$support_{(A \Rightarrow B)} = \frac{N(A \wedge B)}{N_{all}} \quad (2)$$

$$lift_{(A \Rightarrow B)} = \frac{confidence_{(A \Rightarrow B)}}{support_{(B)}} \quad (3)$$

式 (2) において、 $N_{all}$  は全データを表す。*support* はルールの出現割合を、*lift* は条件部と結論部の独立性を表している。

### 2.3 アイテムベース協調フィルタリング

協調フィルタリングには、アイテムベース協調フィルタリングとユーザベース協調フィルタリングがある。本節ではアソシエーションルールを用いたアイテムベース協調フィルタリングについて説明する。対象ユーザの評価履歴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」をあてる。たとえば、対象ユーザがアイテム  $A$  に対して「Like」と評価し、アイテム  $B$  が未評価であるとき、アイテム  $B$  を評価し、アイテム  $A$  を「Like」と評価したすべてのユーザに対して求められる「アイテム  $A = \text{Like} \Rightarrow$  アイテム  $B = \text{Like}$ 」の  $confidence_{(\text{アイテム } A = \text{Like} \Rightarrow \text{アイテム } B = \text{Like})} (= N(A = \text{Like} \wedge B = \text{Like})/N(A = \text{Like}))$  を、アイテム  $B$  のスコアに加算する。逆に対象ユーザがアイテム  $A$  を「Don't Like」と評価した場合、「アイテム  $A = \text{Don't Like} \Rightarrow$  アイテム  $B = \text{Like}$ 」の  $confidence_{(\text{アイテム } A = \text{Don't Like} \Rightarrow \text{アイテム } B = \text{Like})}$  が加算される。対象ユーザのすべての評価履歴により未評価のアイテムのスコアを求めた後、最もスコアの高いアイテムを推薦する [6]。

### 2.4 ユーザベース協調フィルタリング

アソシエーションルールを用いたユーザベース協調フィルタリングでは、各ユーザの嗜好 (Like/Don't Like) をア

ソシエーションルールの条件部に用いて、結論部には対象ユーザの評価「Like」をあてる。たとえば、対象ユーザがアイテム  $A$  に対して「Like」と評価し、アイテム  $B$  に対して未評価であり、ユーザ 1 がアイテム  $B$  に対して「Like」と評価しているとする、対象ユーザとユーザ 1 の評価履歴に基づいて「ユーザ 1 = Like  $\Rightarrow$  対象ユーザ = Like」というルールに対する  $confidence_{(\text{ユーザ } 1 = \text{Like} \Rightarrow \text{対象ユーザ} = \text{Like})}$  を求める。この値が高ければ、ユーザ 1 が「Like」と評価をしたアイテムは対象ユーザにとっても「Like」となる可能性が高いとして、 $confidence_{(\text{ユーザ } 1 = \text{Like} \Rightarrow \text{対象ユーザ} = \text{Like})}$  をアイテム  $B$  のスコアに加算する。これは、「ユーザ 1 = Don't Like  $\Rightarrow$  対象ユーザ = Like」に対しても計算し、ユーザ 1 が「Don't Like」と評価しているアイテムのスコアに加算する。これをすべてのユーザ、すべての対象ユーザの未評価アイテムについて求め、最もスコアの高いアイテムを推薦する [5]。

### 2.5 関連研究

Sarwar ら [18] と Lin ら [5] は、アソシエーションルールを用いた推薦システムを提案している。Sarwar らは、推薦に用いるアソシエーションルールについて、*confidence* と式 (2) の *support* に下限値を設け、*confidence* の高いアイテムを推薦している。また Lin らは、*support* の下限値を設ける必要のないアルゴリズムを提案している。これらの手法においては、対象ユーザとは異なる評価情報は考慮されていない。具体例として、表 1 にアイテム  $A$ 、 $B$  に対する評価履歴の例を示す。対象ユーザがアイテム  $A$  に「Like」と評価し、 $B$  を推薦候補のアイテムとすると、 $confidence_{(\text{アイテム } A = \text{Like} \Rightarrow \text{アイテム } B = \text{Like})} = \frac{2}{3}$  となる。この *confidence* の値を用いてアイテム  $B$  を推薦するかどうかを判断するとき、ユーザ 4 とユーザ 5 の評価情報は推薦結果に反映されていないことになり、情報の損失が生じている。

また、その他のアイテムベース協調フィルタリングに WeightedSum 法がある [19]。この手法では、ユーザ  $u$  のアイテム  $i$  に対する予測値  $P(u)_i$  を求める。

$$P(u)_i = \frac{\sum_{j \in I} (s_{i,j} \times R_{u,j})}{\sum_{j \in I} |s_{i,j}|} \quad (4)$$

ここで、 $R_{u,j}$  はユーザ  $u$  のアイテム  $j$  に対する評価値を、

表 1 評価履歴

Table 1 Evaluation history.

	アイテム $A$	アイテム $B$
ユーザ 1	Like	Like
ユーザ 2	Like	Like
ユーザ 3	Like	Don't Like
ユーザ 4	Don't Like	Like
ユーザ 5	Don't Like	Don't Like

$s_{i,j}$  はアイテム  $i$  と  $j$  の調整コサイン類似度を、 $I$  はアイテム  $i$  と類似したアイテム集合を表す。予測値  $P(u)_i$  は、以下の式 (5) で求められるアイテム  $i$  と  $j$  の調整コサイン類似度によって重み付けされている。 $U_s$  はアイテム  $i$  と  $j$  のどちらにも評価したユーザ集合を、 $\bar{R}_u$  はユーザ  $u$  の平均評価値を表す。

$$s_{i,j} = \frac{\sum_{u \in U_s} (R_{u,i} - \bar{R}_u)(R_{u,j} - \bar{R}_u)}{\sqrt{\sum_{u \in U_s} (R_{u,i} - \bar{R}_u)^2} \sqrt{\sum_{u \in U_s} (R_{u,j} - \bar{R}_u)^2}} \quad (5)$$

この手法では、対象ユーザが高い評価をつけたアイテムと類似したアイテムを推薦する。

ユーザベース協調フィルタリングの推薦には GroupLens の手法がある [20]。WeightedSum 法と同様に、予測値  $P(u)_i$  を求めることができる。

$$P(u)_i = \bar{R}_u + \frac{\sum_{x \in U} r_{u,x} \times (R_{x,i} - \bar{R}_x)}{\sum_{x \in U} |r_{u,x}|} \quad (6)$$

ここで、 $r_{u,x}$  はユーザ  $u$  と  $x$  のピアソンの相関係数を、 $U$  はユーザ  $u$  と類似したユーザ集合を表す。ピアソンの相関係数は以下の式 (7) で求められる。 $I_r$  はユーザ  $u$  と  $x$  のどちらにも評価されたアイテム集合を、 $\bar{R}_u$  はユーザ  $u$  の評価値平均を表す。

$$r_{u,x} = \frac{\sum_{i \in I_r} (R_{u,i} - \bar{R}_u)(R_{x,i} - \bar{R}_x)}{\sqrt{\sum_{i \in I_r} (R_{u,i} - \bar{R}_u)^2} \sqrt{\sum_{i \in I_r} (R_{x,i} - \bar{R}_x)^2}} \quad (7)$$

GroupLens の手法では、対象ユーザと評価傾向が類似したユーザが高い評価をしたアイテムを推薦する。

また清水ら [21] は、協調フィルタリングにより発見性を高める試みを行っているが、ユーザの嗜好に加え、アイテムに対する既知・不既知の評価情報を用いている。この既知・不既知をすべてのアイテムに対して回答することにより、ユーザの負担が増加することが予想される。これ以外にも、アイテムのコンテンツ情報を利用して、ユーザの意外性向上を目的とした研究は複数報告されているものの、ユーザの評価情報（評価履歴）のみを用いて意外性を高めようと試みている研究は少ない。しかし 2.1 節で述べたとおり、コンテンツ情報を用いず意外性の向上を試みることは、実用上有意義であると考えられる。

### 3. 提案手法

アソシエーションルールを用いた従来手法では、対象ユーザの評価履歴のみがアソシエーションルールの条件部に用いられている。また、ルールの結論部は「推薦候補のアイテム = Like」である。これに対し提案手法では、対象ユーザの評価履歴だけでなく、その反対の評価を条件部に持つ

アソシエーションルールを同時に用いる。 $R_t$  を対象ユーザの評価、 $\neg R_t$  を反対の評価とする。 $R_t$  と  $\neg R_t$  は「Like」または「Don't Like」となる。もし  $confidence_{(A=R_t \Rightarrow B=Like)}$  の値が高ければ、アイテム  $A$  を  $R_t$  と評価した対象ユーザは、高い確率で結論部のアイテム  $B$  を「Like」と評価することが期待できる。つまり、 $confidence_{(A=R_t \Rightarrow B=Like)}$  の値が高いアイテムが推薦された場合、高い精度が期待される。

次に、 $d$  を式 (8) で定義する。 $d$  は 2 つの  $confidence$  の差で表される。

$$d = confidence_{(A=R_t \Rightarrow B=Like)} - confidence_{(A=\neg R_t \Rightarrow B=Like)} \quad (8)$$

$d$  が高い場合、アイテム  $A$  を  $R_t$  と評価したユーザは、 $\neg R_t$  と評価したユーザとは異なる嗜好を持つと考えられる。これは、対象ユーザの評価履歴「 $A = R_t$ 」が、その他の  $d$  が低いアイテムよりも多くの情報を持っていることを意味する。たとえば、アイテム  $B_1$  と  $B_2$  を推薦候補のアイテムとし、 $confidence_{(A=R_t \Rightarrow B_1=Like)}$  と  $confidence_{(A=R_t \Rightarrow B_2=Like)}$  がともに 0.8 であるとする。2.3 節におけるアイテムベース協調フィルタリングでは、アイテム  $B_1$  と  $B_2$  ともに同じスコアを与えていることとなる。しかしながら、たとえば  $confidence_{(A=\neg R_t \Rightarrow B_1=Like)}$  が 0.2 で、 $confidence_{(A=\neg R_t \Rightarrow B_2=Like)}$  が 0.6 の場合、アイテム  $B_1$  と  $B_2$  における「アイテム  $A = Like$ 」の意味が異なる。 $confidence$  はともに 0.8 であるため、単純には、 $B_1$ 、 $B_2$  ともに期待値 0.8 で対象ユーザから「Like」と評価されると予測される。すなわち、高い精度だけを求めるのであれば、 $confidence$  のみを用いて推薦を行うことに問題はなく、精度の面からは、 $d$  の値を考慮する利点は少ない。しかし、アイテム  $B_1$  はとりわけ、対象ユーザと同じくアイテム  $A$  を  $R_t$  と評価したユーザに「Like」と評価されている。つまり、アイテム  $B_1$  は必ずしも人気のあるアイテムではないながらも、アイテム  $A$  を  $R_t$  と評価したユーザには好まれるアイテムであると考えられる。一方で、アイテム  $A$  を  $\neg R_t$  と評価したユーザの多くも、アイテム  $B_2$  を「Like」と評価しているため、アイテム  $B_2$  は対象ユーザに特化したアイテムではなく、多くのユーザに好まれているアイテムであると考えられる。上述のとおり、 $confidence_{(A=R_t \Rightarrow B=Like)}$  は高い精度に結び付くと考えられる。一方で、 $|d|$  は対象ユーザと他のユーザ間の嗜好の違いを表し、高い  $confidence$  と低い  $|d|$  は Non-Personalized な推薦 [22], [23] を意味することになる。 $|d|$  が大きいアイテムは、多くのユーザには好まれていない、かつ対象ユーザには好まれそうなアイテムを表すため、 $|d|$  は意外性に結び付く指標であると考えられる。そこで、 $d$  と  $confidence_{(A=R_t \Rightarrow B=Like)}$  の積を、式 (9) により  $s_{A \Rightarrow B}$  と定義する。提案手法では、この  $s_{A \Rightarrow B}$  を、2.3 節におけ

表 2 アソシエーションルールを用いた推薦  
Table 2 Recommendation using association rule.

評価履歴	アイテム C = Like	アイテム D = Like	アイテム E = Like
アイテム A = Like	$s_{A \Rightarrow C}$	$s_{A \Rightarrow D}$	$s_{A \Rightarrow E}$
アイテム B = Don't Like	$s_{B \Rightarrow C}$	$s_{B \Rightarrow D}$	$s_{B \Rightarrow E}$
推薦スコア	$s_C$ ( $s_{A \Rightarrow C} + s_{B \Rightarrow C}$ )	$s_D$ ( $s_{A \Rightarrow D} + s_{B \Rightarrow D}$ )	$s_E$ ( $s_{A \Rightarrow E} + s_{B \Rightarrow E}$ )

る  $confidence_{(A=R_t \Rightarrow B=Like)}$  の代わりに用いる.

$$s_{A \Rightarrow B} = \begin{cases} confidence_{(A=R_t \Rightarrow B=Like)}^\alpha \times d & \text{if } d \geq 0 \\ confidence_{(A=R_t \Rightarrow B=Don't Like)}^\alpha \times d & \text{otherwise} \end{cases} \quad (9)$$

$d \geq 0$  のとき,  $d$ ,  $confidence_{(A=R_t \Rightarrow B=Like)}$  がともに高くなれば, アイテム B が推薦される可能性が高くなる.  $d < 0$  のときは,  $confidence_{(A=R_t \Rightarrow B=Don't Like)}$  が  $confidence_{(A=R_t \Rightarrow B=Like)}$  の代わりに用いられる.  $confidence_{(A=R_t \Rightarrow B=Don't Like)}$  が大きいほど,  $s_{A \Rightarrow B}$  は小さくなる ( $confidence_{(A=R_t \Rightarrow B=Like)} + confidence_{(A=R_t \Rightarrow B=Don't Like)} = 1$ ).

また  $\alpha$  は,  $confidence$  の重みパラメータであり, 0 以上の値で設定する.  $\alpha$  を導入することで, 精度と意外性のバランスを調整することができる.  $\alpha$  を大きくすることで高い精度, 小さくすることで高い意外性に結び付くと考えられる.

対象ユーザの評価アイテムをアイテム A, アイテム B, 推薦候補のアイテムをアイテム C, アイテム D, アイテム E としたとき (表 2), 提案手法によるアイテム推薦の手順を以下に示す.

- (1) 推薦候補のアイテム・対象ユーザの評価履歴ごと (表 2 の各要素) に, 式 (9) により値を求める (表 2 の例では, アイテム A では  $R_t = Like$ , アイテム B では  $R_t = Don't Like$  となる).
- (2) 推薦候補の列ごとに和をとり, これを各アイテムに対する推薦スコアと定義する (表 2 では  $s_C, s_D, s_E$ ).
- (3) 最も推薦スコアの高いアイテムを推薦する.
- (4) 推薦したアイテムの評価履歴を加え, (1) に戻る.

推薦理由の説明を行うには, 提案手法における  $s_{A \Rightarrow B}$  (式 (9)) の値をそのままユーザに提示するのではなく, 式 (9) における  $confidence$  の値を用いて, 2.2 節の例のように, 「あなたが好きと評価したアイテム A を好きな人の 80% がこのアイテムを好きと言っています。」と提示する方法と, 補助的に図を用いて  $s_{A \Rightarrow B}$  の値の意味 (例「あなたが好きと評価したアイテム A を好きな人の 80%, アイテム A を好きでないと評価した人の 20% がこのアイテムを好きと言っています.」) を説明する方法が考えられる. 図 1 に, 推薦理由の提示例を示す. 図では, アソシエーシ




図 1 推薦理由の提示例

Fig. 1 Example of presentation of recommended reason.

ョンルールの条件部と結論部をノードとし, リンクの太さが  $confidence$  の値を表す. また, リンクの先がアソシエーションルールの結論部に対応する. 対象ユーザが評価したアイテムの文字色を白に, そして赤いノードが「Like」を, 青が「Don't Like」を表す. そのためこの例では, 対象ユーザが評価したアイテム A が「Like」は「アイテム B = Like」が多く, 「Don't Like」は「アイテム B = Like」が少ないことを表している. 図におけるアイテム C, D については, すべての推薦候補を提示するわけではなく, 推薦スコアの高いものや,  $|d|$  の値が小さいものを提示する, または推薦したアイテム (図ではアイテム B) のみを提示する方法が考えられる.

#### 4. 評価指標

実験には以下に示す 3 つの評価指標を用いる. 推薦の合計数を  $n$ , 推薦アイテムの集合を  $\{i_1, i_2, \dots, i_n\}$ , 対象ユーザのアイテム  $i_k$  の評価履歴を  $R(i_k) = 1/-1$  (Like/Don't Like) とする.

$$\frac{1}{n} \sum_{k=1}^n t_k \quad (10)$$

##### a) Accuracy

$$t_k = \begin{cases} 1 & \text{if } R(i_k) = 1 \\ 0 & \text{otherwise} \end{cases} \quad (11)$$

Accuracy (精度) は, 対象ユーザが推薦された  $n$  個のアイテムに対して「Like」と評価した割合である.

##### b) Novelty [22]

$$t_k = \begin{cases} 1 & \text{if } R(i_k) = 1 \text{ and } i_k \notin I_{NP} \\ 0 & \text{otherwise} \end{cases} \quad (12)$$

式 (12) における  $I_{NP}$  は, Non-Personalized 法 [22], [23] (全ユーザにおける Like 割合が高いものから推薦) によって推薦されたアイテム集合であり,  $I_{NP}$  の要素数は  $n$  である. Novelty は, 推薦された  $n$  個のアイテムに対して「Like」と評価され, かつ Non-Personalized な推薦に現れないアイテムの割合である.

c) Personalizability [6]

$$t_k = \begin{cases} \log_2 \frac{1}{P(R(i_k)=1)} & \text{if } R(i_k) = 1 \\ 0 & \text{otherwise} \end{cases} \quad (13)$$

式 (13) における  $P(R(i_k) = 1)$  は, 全ユーザにおけるアイテム  $i_k$  の Like 割合である.

$$P(R(i_k) = 1) = \frac{N(i_k = Like)}{N(i_k = Like) + N(i_k = Don't Like)} \quad (14)$$

$N(i_k = Like)$  はアイテム  $i_k$  に対して「Like」と評価したユーザ数を,  $N(i_k = Don't Like)$  はアイテム  $i_k$  に対して「Don't Like」と評価したユーザ数を表す. ただし, ゼロ頻度問題に対応するために, 式 (1) と同じくラプラススムージングを行う. Personalizability は, 意外性の一面を表す指標として提案されている [6]. Like 割合に基づいた情報量で表され, 推薦されたアイテムが「Like」と評価され, かつ Like 割合が低いほど大きな値をとる.

### 5. 意外性指標の妥当性評価実験

4章であげた意外性の指標である Novelty [22], Personalizability [6] については, 文献において, それぞれ指標として定量化されているものの, 意外性指標としての妥当性に対する評価実験は行われていない. そこで本論文では, これらの意外性指標に対する妥当性の検証実験を行った. 実験には, J-POP, 演歌, アニメソングなどのジャンル, 発表年が 1977~2010 年となる 200 曲の音楽データを用いた. この 200 曲に対し, 事前に 20 代の男女 11 名に 5 段階で評価を行ってもらい, 曲ごとに式 (14) により Like 割合を求めた. ただし, 5 段階評価の 1 から 3 を「Don't Like」, 4 と 5 を「Like」とした. その結果, 全 11 名での「Like」:「Don't Like」の比率は 1 : 1.25 となった. ここでは, この 11 名を「旧被験者」と呼ぶ.

#### 5.1 Novelty

ここでは, Non-Personalized な推薦を, 式 (14) で求められる Like 割合の高い順に推薦することと定義する. 上記の 11 名とは異なる 20 代の男女 16 名に協力してもらい, 音楽 200 曲をランダムに配信し, 各曲に対して意外性・嗜好を 5 段階で評価してもらった. この 16 名を「新被験者」と呼ぶ. それぞれの空き時間などを使って評価を行ってもらったため, 全 200 曲に対する評価を行うのにかかった時

表 3 Novelty と意外性との関係

Table 3 Relation between Novelty and Serendipity.

X	オンライン		オフライン	
	相関係数	P 値	相関係数	P 値
25	0.145	6.28e-08	0.215	5.87e-16
50	0.205	1.29e-14	0.207	7.33e-15
75	0.238	2.14e-19	0.225	2.14e-17
100	0.246	1.59e-20	0.231	3.04e-18

表 4 Personalizability と意外性との関係

Table 4 Relation between Personalizability and Serendipity.

オンライン		オフライン	
相関係数	P 値	相関係数	P 値
0.264	1.40e-23	0.248	6.49e-21

間は新被験者ごとに異なり, 5~22 日であった.

被験者の意外性の評価と Novelty との関係を検証するために, 意外性の 5 段階評価と Novelty (0/1) とのピアソンの相関係数 (式 (7)) を求めた. Novelty の値は対象ユーザが「Like」と評価したアイテムにのみ加算されるため, 本実験においても, 新被験者が「Like」と評価した曲 (全 1,389 曲) を対象にした. ユーザが「Like」と評価し, かつ Like 割合の高い上位  $X$  位に入っていない曲の Novelty の値 ( $t_k$ ) は 1 となり, 上位  $X$  位に入っていれば 0 となる.

結果を表 3 に示す. 表において, オフラインとオンラインの違いは, Like 割合の求め方にある. 11 名の旧被験者の評価を基に Like 割合を求めた場合をオンライン, 実験終了後に, 旧被験者と新被験者の評価情報を合わせ, それぞれ対象となる被験者 1 名を除く計 26 名の評価を基に Like 割合を求めた場合をオフラインと定義した. Like 割合の高い上位  $X$  位を決める際, 同順位があった場合には, 対象となる曲の中から必要分をランダムに選んだ. 本実験結果から, Novelty と意外性には正の相関が見られた.

#### 5.2 Personalizability

Personalizability に関しても, 5.1 節と同様の検証を行う. ここでは, 意外性の 5 段階評価と, Personalizability の ( $\log_2 \frac{1}{P(R(i_k)=1)}$ ) とのピアソンの相関係数 (式 (7)) を求めた. ただし, 新被験者が「Like」と評価した 1,389 曲を対象とした. 結果を表 4 に示す. 相関係数がオンラインでは 0.264, オフラインでは 0.248 となり, Personalizability と意外性の間には正の相関が見られた.

表 3 における 8 つの相関係数と, 表 4 における 2 つの相関係数において無相関検定を行ったところ, すべてに有意差が見られた. これにより, Novelty と意外性, Personalizability と意外性の間には正の相関が見られ, Novelty や Personalizability の向上が意外性の向上に結び付くことを確認した.

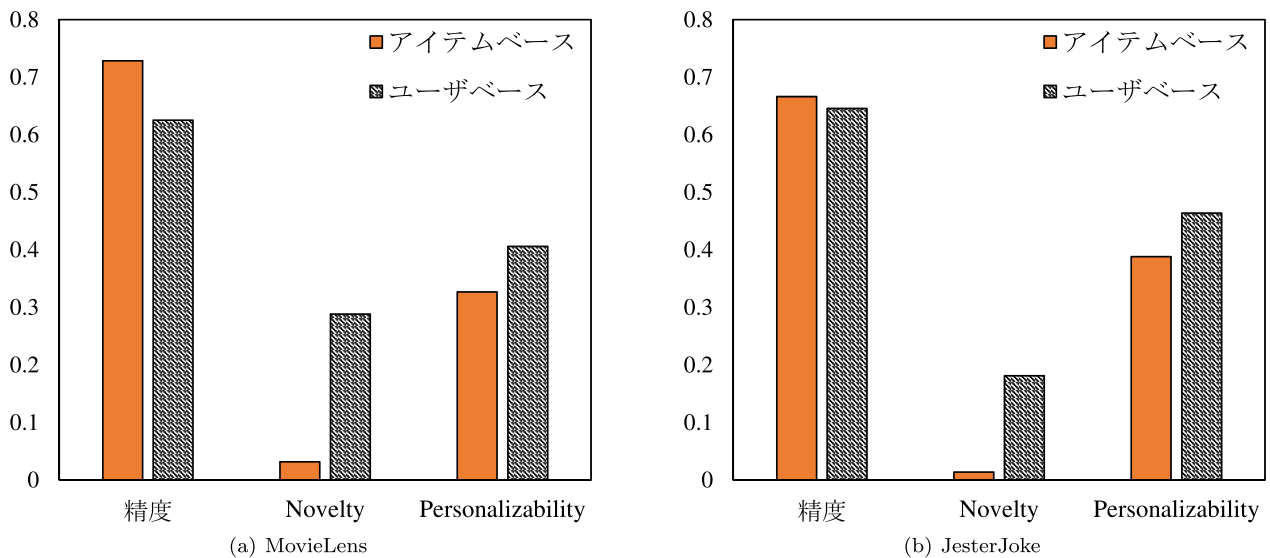


図 2 アイテムベースとユーザベースの比較  
 Fig. 2 Comparison between item-based CF and user-based CF.

## 6. 実験

### 6.1 使用データ

本章では GroupLens<sup>\*2</sup>で配布されている MovieLens データセット [24], および JesterJoke [25] を用いた. MovieLens データセットは Internet Movie Database<sup>\*3</sup>と Rotten Tomatoes movie review system<sup>\*4</sup>に関連付けられている. 映画に対する 10 段階の評点 (0.5~5.0 の 0.5 刻み) のうち, 「Like」と「Don't Like」との数がおおよそ同じとなるよう, 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. ここで「Like」と「Don't Like」との数を おおよそ同じとなるようにしたのは, 手法の性能を平等に比較, 評価するためである. これはたとえば評点が「Like」に偏っている場合, ランダムにアイテムを推薦したとしても, 高い確率で対象ユーザに「Like」と評価されることにより, 精度の面で差がつかず, 手法間の有効性の評価が行いにくくなるためである. また, 本データのうち, 「Like」と「Don't Like」をそれぞれ 51, 50 回以上評価したユーザ 1,118 名, 300 名以上に評価された 611 のアイテムを対象とした. JesterJoke データセットでは, 上述と同様, ジョークに対する評点 (-10.00~10.00) のうち, 2.00 未満を「Don't Like」, 2.00 以上を「Like」として実験を行った. ただし, 「Like」と「Don't Like」をそれぞれ 31, 30 回以上評価したユーザ 7,114 名, 300 名以上に評価された 100 のアイテムを対象とした.

### 6.2 実験方法

10-fold cross-validation, すなわちデータセットの 10 分

の 1 をテストユーザに, 残りをトレーニングユーザとして評価指標を求め, 次に別の 10 分の 1 をテストユーザにすることを 10 回繰り返すことを 1 試行とし, この 10-fold cross-validation を 10 試行行って各指標の平均値を求めた. 本実験では, 各テストユーザを対象ユーザとして扱った. 元のデータにおいて, 対象ユーザが「Like」と評価したアイテムをランダムに 1 つ選び, それを最初の評価履歴とした. これは, 最初の推薦アイテムは, ユーザにより選択してもらい, 以降推薦システムによりアイテム推薦を行うことを想定している. その他のアイテムは未評価アイテムとして扱い, それぞれの対象ユーザにおいて MovieLens データセットでは推薦回数を 50 回, JesterJoke データセットでは 30 回とした.

ユーザは全アイテムの一部にしか評価を行わないため, 推薦に用いられるユーザ・アイテムの評価値行列は一般的にスパースである [26]. そのため, トレーニングユーザの評価値をランダムに消し, 疎性を 0.9 (データ密度 10%) としたデータを用いた実験もあわせて行う.

### 6.3 アイテムベース協調フィルタリングとユーザベース協調フィルタリングの比較

2.3, 2.4 節で述べた, アイテムベース協調フィルタリングとユーザベース協調フィルタリングの比較結果を図 2, 図 3 に示す. データの種類, 疎性にかかわらず, アイテムベース協調フィルタリングの精度はユーザベース協調フィルタリングよりも高く, 意外性の評価指標である Novelty や Personalizability は低い結果となった. アイテムベース協調フィルタリングでは, 対象ユーザの評価履歴を直接アソシエーションルールの条件部にあてているため, ユーザの嗜好を反映しやすく, 精度が高くなったと考えられる. 一方で, 直接的なアイテムの類似性ではなくユーザの類似

<sup>\*2</sup> GroupLens <http://www.grouplens.org>  
<sup>\*3</sup> IMDb <http://www.imdb.com>  
<sup>\*4</sup> Rotten Tomatoes <http://www.rottentomatoes.com>

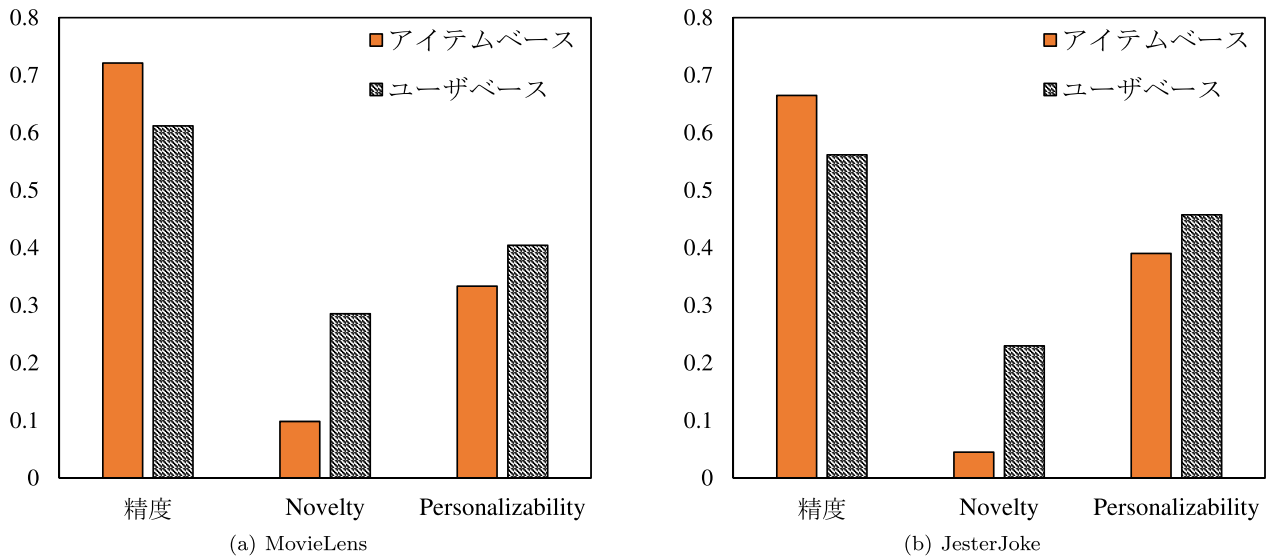


図 3 アイテムベースとユーザベースの比較 (密度 10%)

Fig. 3 Comparison between item-based CF and user-based CF (density 10%).

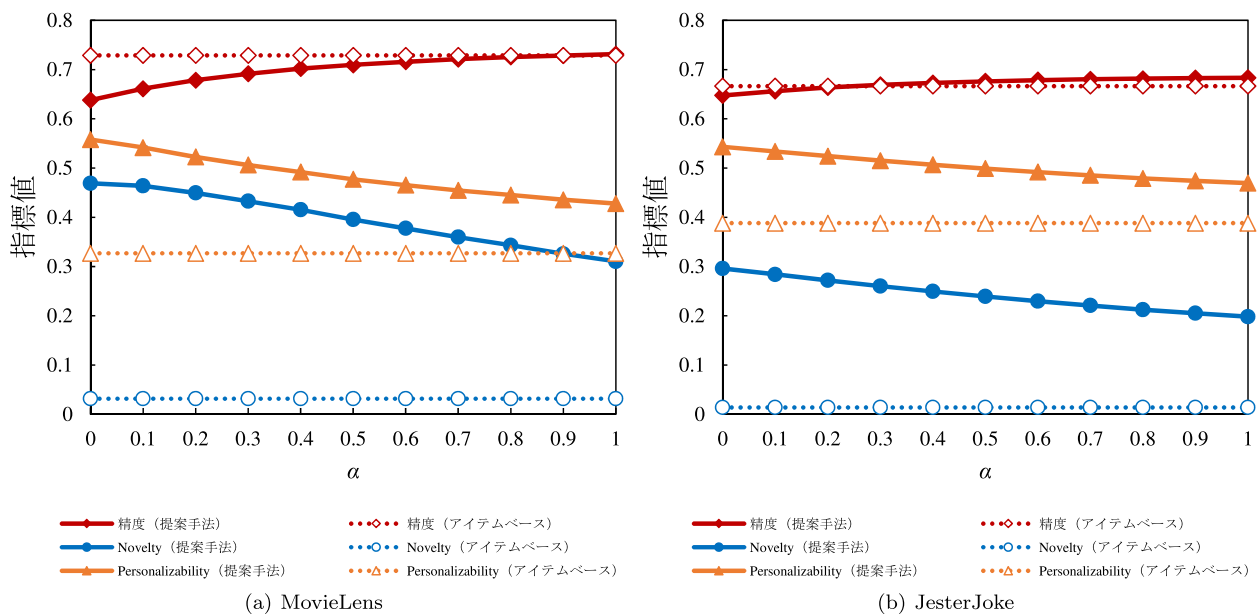


図 4 提案手法とアイテムベースの比較

Fig. 4 Comparison between proposed method and item-based CF.

性に基づいて推薦を行っていることで、ユーザベース協調フィルタリングではユーザにとって意外なアイテムが推薦され、意外性の指標が高くなったと考えられる。

#### 6.4 提案手法とアイテムベース協調フィルタリングの比較

提案手法とアイテムベース協調フィルタリングとの比較結果を図 4, 図 5 に示す. 式 (9) における  $\alpha$  を大きくしたとき精度が向上し,  $\alpha$  を小さくしたときには Novelty, Personalizability が向上していることが分かる. 3 章で述べたとおり, 提案手法において,  $\alpha$  を調整することにより, 精度と意外性とのバランスを調整可能であることが確認できた.

図 4 では, どちらのデータセットにおいても,  $\alpha$  を大き

くすることにより, 精度を保ったまま高い Novelty, Personalizability が得られている. 一方, 密度が低い場合, MovieLens データセットを用いた図 5 (a) では,  $\alpha$  が 0 から 2 の間では, 提案手法は Novelty, Personalizability は高いものの, 精度ではアイテムベース協調フィルタリングの精度には届かない結果となった. ただし JesterJoke データセットを用いた図 5 (b) では,  $\alpha$  を大きくすることで, 精度を保ちながらも, 高い Novelty, Personalizability が得られていることが分かる.

#### 6.5 提案手法とユーザベース協調フィルタリングの比較

提案手法とユーザベース協調フィルタリングとの比較結果を図 6, 図 7 に示す. 6.3 節において, アイテムベース協






図 5 提案手法とアイテムベースの比較 (密度 10%)

Fig. 5 Comparison between proposed method and item-based CF (density 10%).




図 6 提案手法とユーザベースの比較

Fig. 6 Comparison between proposed method and user-based CF.

調フィルタリングの Novelty や Personalizability は、ユーザベース協調フィルタリングのものを下回っていた。しかしながら提案手法では、MovieLens, JesterJoke データセットともに、 $\alpha = 1$  付近、図 7(a) では  $\alpha = 0.5$  付近で、ユーザベース協調フィルタリングの Novelty, Personalizability を実現しながら、高い精度が得られていることが分かる。

### 6.6 提案手法と従来手法の比較

本節では、提案手法と、従来手法として 2.5 節で示した WeightedSum 法との比較を行う。ユーザ  $u$  がアイテム  $j$  に「Like」と評価した場合、 $R_{u,j}$  を 1 に、「Don't Like」と

評価した場合、 $R_{u,j}$  を  $-1$  とする。

図 8 と図 9 に、MovieLens データセットを用いた場合の提案手法と従来手法との比較結果を示す。従来手法におけるパラメータ  $|I|$  を、100 刻みごとに变化させて実験を行ったところ、通常データを用いた実験では、従来手法は  $|I| = 610$  で最も精度が高く、 $|I| = 300$  で Novelty, Personalizability が最も高い結果となった。また、密度 10% のデータを用いた実験では、従来手法は  $|I| = 600$  で最も精度が高く、 $|I| = 200$  で Novelty, Personalizability が最も高い結果となった。そこで、従来手法のパラメータ  $|I|$  をこれらの値としたときの比較を行った。




図 7 提案手法とユーザベースの比較 (密度 10%)

Fig. 7 Comparison between proposed method and user-based CF (density 10%).




図 8 提案手法と従来手法の比較 (MovieLens データセット)

Fig. 8 Comparison between proposed method and conventional method (MovieLens data set).

図 8(a) より,  $|I| = 610$  (精度最大) のとき,  $\alpha$  を大きくすることで従来手法の精度を上回った. また,  $\alpha = 0.2$  から 0.4 にかけて, 従来手法よりも高い精度, かつ高い Novelty, Personalizability を確認できた. また図 8(b) より,  $|I| = 300$  (意外性最大) のとき,  $\alpha$  を小さくすることで従来手法の Novelty, Personalizability を上回った. また,  $\alpha$  が 0.3 を下回った場合, 従来手法よりも高い精度, かつ高い Novelty, Personalizability を確認できた. 密度 10% のデータを用いた図 9 においても同様の傾向が見られ, 図 9(a) より,  $|I| = 600$  のとき,  $\alpha = 0.5$  から 0.7 につ

て, 図 9(b) より,  $|I| = 200$  のとき,  $\alpha$  が 0.3 を下回った場合, それぞれ従来手法よりも高い精度, かつ高い Novelty, Personalizability を確認できた.

図 10 と図 11 に, JesterJoke データセットを用いた場合の提案手法と従来手法との比較結果を示す. 従来手法におけるパラメータ  $|I|$  を, 5 刻みごとに変化させて実験を行ったところ, 通常のデータを用いた実験では, 従来手法は  $|I| = 99$  で最も精度が高く,  $|I| = 40$  で Novelty, Personalizability が最も高い結果となった. 密度 10% のデータを用いた実験では, 従来手法は  $|I| = 99$  で最も精度が高




図 9 提案手法と従来手法の比較 (MovieLens データセット, 密度 10%)

Fig. 9 Comparison between proposed method and conventional method (MovieLens data set, density 10%).




図 10 提案手法と従来手法の比較 (JesterJoke データセット)

Fig. 10 Comparison between proposed method and conventional method (JesterJoke data set).

く,  $|I| = 25$  で Novelty, Personalizability が最も高い結果となった. 提案手法において, データ密度にかかわらず,  $\alpha$  の大小により精度と Novelty, Personalizability の調整ができていくことが分かる. また,  $\alpha$  を大きくすることで, 従来手法において精度の最も高かった場合と比較しても提案手法の精度が上回っていた. 一方,  $\alpha$  を小さくすることで, 従来手法で Novelty, Personalizability の最も高かった場合と比較してもそれらを上回っていた. また, WeightedSum 法において推薦理由を説明する場合, 「あなたが好きと評価

したアイテム A と 80%類似したアイテムです.」のような形になる. しかしこの“80%”は, アイテムのコンテンツではなく, 評価履歴での類似度合いであるため, 対象ユーザーにとっては直感的には分かりにくい説明となってしまふ.

本実験では, すべての推薦を終えるまで精度と意外性の調整パラメータである  $\alpha$  を固定し, 精度や Novelty, Personalizability を求めているが, 推薦システムを利用し始めたユーザーにとって, 評価の高いアイテムは推薦システムとの信頼関係構築のためには重要である [7]. そのため, 推薦




図 11 提案手法と従来手法の比較 (JesterJoke データセット, 密度 10%)

Fig. 11 Comparison between proposed method and conventional method (JesterJoke data set, density 10%).

の初期では精度を重視 ( $\alpha$  を大きく) し, 推薦が進むにつれて徐々に意外性を重視 ( $\alpha$  を小さく) することで, より対象ユーザにとって満足度の高い推薦が行えると考えられる. また,  $\alpha$  を小さくする方向だけでなく, それにより精度が下がってきた際には, 再び  $\alpha$  を大きくすることで, 精度を重視した推薦を行うなど, 推薦の結果をフィードバックした調整方法も可能である.

## 7. おわりに

本論文では, アソシエーションルールに基づく協調フィルタリングにおいて, 対象ユーザの評価履歴を条件部に用いたアソシエーションルールだけでなく, 従来, 推薦に反映されていなかった対象ユーザの反対の評価情報を条件部に持つアソシエーションルールを考慮することで, 精度を保ちつつ, 意外性の向上が可能な推薦システムを提案した. 精度と意外性の調整パラメータを導入することで, 精度と意外性のバランスを調整可能であることを示した. また, 意外性の評価指標として用いた “Novelty”, “Personalizability” の妥当性についての検証を行った. 被験者のアイテムに対する意外性の評価と, Novelty, Personalizability の間にはそれぞれ正の相関が見られ, Novelty, Personalizability の向上が意外性の向上に寄与することを示した. 今後の課題としては, 本実験において, 推薦されたアイテムのコンテンツそのものに意外性を感じるという意見も被験者から得られたため, アイテムのコンテンツ情報を利用した意外性の評価があげられる.

## 参考文献

- [1] 神鳥敏弘: 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] 神鳥敏弘: 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] 神鳥敏弘: 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] Agrawal, R. and Srikant, R.: Fast algorithms for mining association rules, *Proc. 20th Int. Conf. Very Large Data Bases, VLDB*, Vol.1215, pp.487-499 (1994).
- [5] Lin, W., Alvarez, S. 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).
- [6] 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 (数理モデル化と応用 Vol.6, No.1), 情報処理学会論文誌 論文誌トランザクション, Vol.2012, No.2, pp.111-118 (2013).
- [7] McNee, S.M., Riedl, J. and Konstan, J.A.: Being accurate is not enough: How accuracy metrics have hurt recommender systems, *CHI '06 Extended Abstracts on Human Factors in Computing Systems*, pp.1097-1101 (2006).
- [8] Herlocker, J.L., Konstan, J.A., Terveen, L.G., et al.: Evaluating collaborative filtering recommender systems, *ACM Trans. Information Systems (TOIS)*, Vol.22, No.1, pp.5-53 (2004).
- [9] 奥 健太, 服部文夫: セレンディピティ指向情報推薦のためのフュージョンベースアプローチのユーザ評価, *DEIM Forum*, pp.A1-3 (8 pages) (2012)
- [10] Hahsler, M. and Chelluboina, S.: Visualizing association rules: Introduction to the R-extension package arulesViz, R project module (2011).
- [11] Appice, A. and Buono, P.: Analyzing multi-level spatial association rules through a graph-based visualization, *Innovations in Applied Artificial Intelligence*, pp.448-458 (2005).
- [12] 伊藤 晃, 吉川大弘, 古橋 武, 池田龍二, 加藤孝浩:

アソシエーション分析における可視化を用いた興味深い  
ルールの探索, 日本知能情報ファジィ学会ファジィシス  
テムシンポジウム講演論文集, pp.684-689 (2010).

- [13] Murakami, T., Mori, K. and Orihara, R.: Metrics for evaluating the serendipity of recommendation lists, *New Frontiers in Artificial Intelligence*, pp.40-46 (2008).
- [14] Linden, G., Smith, B. and York, J.: Amazon.com recommendations: Item-to-item collaborative filtering, *IEEE Internet Computing*, Vol.7, No.1, pp.76-80 (2003).
- [15] Mobasher, B., Jin, X. and Zhou, Y.: Semantically enhanced collaborative filtering on the web, *Web Mining: From Web to Semantic Web*, pp.57-76 (2004).
- [16] Yin, X. and Han, J.: Classification based on Predictive Association Rules, *SDM*, Vol.3, pp.369-376 (2003).
- [17] Pearl, J.: Probabilistic reasoning in intelligent systems: Networks of plausible inference, Morgan Kaufmann (1988).
- [18] Sarwar, B., Karypis, G., Konstan, J., et al.: Analysis of recommendation algorithms for e-commerce, *Proc. 2nd ACM Conference on Electronic Commerce*, pp.158-167 (2000).
- [19] Sarwar, B., Karypis, G., Konstan, J., et al.: Item-based collaborative filtering recommendation algorithms, *Proc. 10th International Conference on World Wide Web*, pp.285-295 (2001).
- [20] Resnick, P., Iacovou, N., Suchak, M., et al.: An open architecture for collaborative filtering of netnews, *Proc. 1994 ACM Conference on Computer Supported Cooperative Work*, pp.175-186 (1994).
- [21] 清水拓也, 土方嘉徳, 西田正吾: 発見性を考慮した協調フィルタリングアルゴリズム, 電子情報通信学会論文誌 D, Vol.91, No.3, pp.538-550 (2008).
- [22] Chandrashekar, H. and Bhasker, B.: Personalized recommender system using entropy based collaborative filtering technique, *Journal of Electronic Commerce Research*, Vol.12, No.3, pp.214-237 (2011).
- [23] Schickel-Zuber, V. and Faltings, B.: Inferring user's preferences using ontologies, *AAAI*, Vol.2006, pp.1413-1418 (2006).
- [24] Cantador, I., Brusilovsky, P. and Kuflik, T.: Second workshop on information heterogeneity and fusion in recommender systems (HetRec2011), *RecSys*, pp.387-388 (2011).
- [25] Gupta, D., Digiovanni, M., Narita, H., et al.: Jester 2.0 (poster abstract): Evaluation of a new linear time collaborative filtering algorithm, *Proc. 22nd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp.291-292 (1999).
- [26] Herlocker, J., Konstan, J., Borchers, A., et al.: An algorithmic framework for performing collaborative filtering, *Proc. 22nd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, pp.230-237 (1999).



伊藤 寛明

2013年3月名古屋大学工学部電気電子・情報工学科卒業。2015年3月名古屋大学大学院工学研究科博士課程前期課程計算理工学専攻修了。同年東日本旅客鉄道株式会社入社。在学中は主として情報推薦に関する研究に従事。



吉川 大弘 (正会員)

1997年名古屋大学大学院博士課程修了。同年カリフォルニア大学バークレー校ソフトコンピューティング研究所客員研究員。1998年三重大学工学部助手。2005年名古屋大学大学院工学研究科 COE 特任准教授。2006年10月同研究科准教授, 現在に至る。主としてソフトコンピューティングとその応用に関する研究に従事。博士(工学)。IEEE, 人工知能学会, 電子情報通信学会, 日本知能情報ファジィ学会, 進化計算学会各会員。



古橋 武

1985年名古屋大学大学院工学研究科博士後期課程電気系専攻修了。工学博士。2004年名古屋大学大学院工学研究科計算理工学専攻教授, 現在に至る。ソフトコンピューティング, 感性工学に関する研究に従事。1996年日本ファジィ学会論文賞受賞。IEEE, 日本知能情報ファジィ学会, 電気学会等各会員。