

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¹ 吉川 大弘¹ 古橋 武¹

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

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り、推薦システムの利用が期待されている [20]。推薦システムを導入している代表的な例として、Amazon.com^{*1} が挙げられる。

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一つにアソシエーション分析がある [1]。アソシエーション分析は、関係性の強い組み

合わ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 [8], [17]。

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 [7], [10], [17], [20], [21], [22]。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 [18]。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 [2], [5], [19]。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

¹ 名古屋大学大学院工学研究科
Graduated School of Engineering Nagoya University, Furocho, Nagoya 464-8601, Japan

^{*1} <http://www.amazon.com>

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二つに分けられる。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、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”は低くなり易い。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 [12], [18]。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 [7], [21]、また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、先に挙げた 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 [9]。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 [11]。そこで本論文では、アイテムベース協調フィルタリングによる推薦を行う。

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、アイテムを一つずつ連続的に推薦し、対象ユーザに好きか嫌いかの評価で判定してもらうことを想定している。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。そこで、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。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。

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。スーパーで頻繁に購入されている商品の組み合わせを見つけ、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。

2.2 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。例えば、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、全ユーザに対して求められる「アイテム $A=Like \Rightarrow$ アイテム $B=Like$ 」の $confidence_{(アイテム A=Like \Rightarrow アイテム B=Like)}$ 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 $A=Don't Like \Rightarrow$ アイテム $B=Like$ 」の $confidence_{(アイテム A=Don't Like \Rightarrow アイテム B=Like)}$ 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 [17]。

2.3 関連研究

Sarwar らと Lin らは、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 [8], [13]。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 $support$ と呼ばれる指標に下限値を設け、 $confidence$ 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、 $confidence_{(アイテム A=Like \Rightarrow アイテム B=Like)} = \frac{2}{3}$ 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 [14]。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.

$$P(u)_i = \frac{\sum_{j \in I} (s_{i,j} * R_{u,j})}{\sum_{j \in I} |s_{i,j}|} \quad (2)$$

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, $s_{i,j}$ 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 (3) 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.

$$s_{i,j} = \frac{\sum_{u \in U_s} (R_{u,i} - \bar{R}_u)(R_{u,j} - \bar{R}_u)}{\sqrt{\sum_{u \in U_s} (R_{u,i} - \bar{R}_u)^2} \sqrt{\sum_{u \in U_s} (R_{u,j} - \bar{R}_u)^2}} \quad (3)$$

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.

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. 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. ただし, どちらのルールの結論部も「推薦候補のアイテム=Like」である. 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 (4) で定義する. d は二つの $confidence$ の差で表される.

$$d = confidence_{(A=R_t \Rightarrow B=Like)} - confidence_{(A=\neg R_t \Rightarrow B=Like)} \quad (4)$$

d が高い場合, アイテム A を R_t と評価したユーザは, 「アイテム $B = Like$ 」の観点から, $\neg R_t$ と評価したユーザと

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

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. 上述の通り, $confidence_{(A=R_t \Rightarrow B=Like)}$ は高い精度に結びつくと考えられる. 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 [4], [15] を意味することになるため, $|d|$ は意外性に結びつく指標であると考えられる. そこで, 提案手法における推薦スコアを d と $confidence_{(A=R_t \Rightarrow B=Like)}$ の積 (式 (5)) により定義する.

$$s_B = \begin{cases} confidence_{(A=R_t \Rightarrow B=Like)}^\alpha * d & \text{if } d \geq 0 \\ confidence_{(A=R_t \Rightarrow B=Don't Like)}^\alpha * d & \text{otherwise} \end{cases} \quad (5)$$

$d \geq 0$ 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, アイテム B の推薦スコアは小さくなる. ($confidence_{(A=R_t \Rightarrow B=Like)} + confidence_{(A=R_t \Rightarrow B=Don't Like)} = 1$)

また α は, $confidence$ の重みパラメータであり, α 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. α 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つくと考えられる.

4. 評価指標

実験には以下に示す三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.

$$\frac{1}{N} \sum_{k=1}^N t_k \quad (6)$$

a) Accuracy

$$t_k = \begin{cases} 1 & \text{if } R(i_k) = 1 \\ 0 & \text{otherwise} \end{cases} \quad (7)$$

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 [4]

$$t_k = \begin{cases} 1 & \text{if } R(i_k) = 1 \text{ and } i_k \notin I_{NP} \\ 0 & \text{otherwise} \end{cases} \quad (8)$$

式 (8) における I_{NP} は, Non-Personalized 法 [4], [15] (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 [17]

$$t_k = \begin{cases} \log_2 \frac{1}{P(R(i_k)=1)} & \text{if } R(i_k) = 1 \\ 0 & \text{otherwise} \end{cases} \quad (9)$$

式 (9) 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。

$$P(R(i_k) = 1) = \frac{n(i_k = \text{Like})}{n(i_k = \text{Like}) + n(i_k = \text{Don't Like})} \quad (10)$$

$n(i_k = \text{Like})$ はアイテム i_k に対して「Like」と評価したユーザ数を、 $n(i_k = \text{Don't Like})$ 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 [17]。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 章で挙げた意外性の指標である Novelty, Personalizability に対して、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 年～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 (10) 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。

5.1 Novelty

ここでは、Non-Personalized な推薦を、式 (10) 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。ただし、それぞれの空き時間等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間は被験者ごとに異なり、5 日～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、被験者が「Like」と評価した曲 (全 1389 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 2 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。事前に評価を行ってもらった 11 名の評価を基に Like 割合を求めた場合をオンライン、実験終了後に、被験者を除く計 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 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を求めた。ただし、被験者が「Like」と評価した 1389 曲を対象とした。結果を表 3 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 2 における 8 つの相関係数と、表 3 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、すべてに有意差がみられた。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つくことを確認した。

6. 実験

6.1 使用データ

本章では GroupLens^{*2} で配布されている MovieLens データセット [3] を用いた。MovieLens データセットは Internet Movie Database^{*3} と Rotten Tomatoes movie review system^{*4} に関連付けられている。映画に対する 10 段階の評点

表 2 Novelty と意外性との関係

Table 2 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 3 Personalizability と意外性との関係

Table 3 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

*2 <http://www.grouplens.org>

*3 <http://www.imdb.com>

*4 <http://www.rottentomatoes.com>

(0.5~5.0の0.5刻み)のうち、「Like」と「Don't Like」との数がおよそ同じになるよう、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。また、本データの内、「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。

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一つ選び、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推薦回数を50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[6]。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 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2.3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1と図2に、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、通常の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1(a)より、 $|I|=610$ (精度最大)のとき、 α 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1(b)より、 $|I|=300$ (意外性最大)のとき、 α を小さくすること

で従来手法のNovelty, Personalizabilityを上回った。また、 α 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2においても同様の傾向が見られ、図2(a)より、 $|I|=600$ のとき、 $\alpha=0.5$ から0.7にかけて、図2(b)より、 $|I|=200$ のとき、 α 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。

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 α 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[10]。そのため、推薦の初期では精度を重視(α を大きく)し、推薦が進むにつれて意外性を重視(α 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。

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挙げられる。

参考文献

- [1] Agrawal, R., Srikant, R. et al.: Fast algorithms for mining association rules, *Proc. 20th int. conf. very large data bases, VLDB*, Vol. 1215, pp. 487-499 (1994).
- [2] Appice, A. and Buono, P.: Analyzing multi-level spatial association rules through a graph-based visualization, *Innovations in applied artificial intelligence*, Springer, pp. 448-458 (2005).
- [3] Cantador, I., Brusilovsky, P. and Kuflik, T.: Second workshop on information heterogeneity and fusion in recommender systems (HetRec2011), *RecSys*, pp. 387-388 (2011).
- [4] Chandrashekhar, H. and Bhasker, B.: Personalized recommender system using entropy based collaborative filtering technique, *Journal of Electronic Commerce Re-*

- search, Vol. 12, No. 3, pp. 214–237 (2011).
- [5] Hahsler, M. and Chelluboina, S.: Visualizing association rules: Introduction to the R-extension package arulesViz, *R project module* (2011).
 - [6] Herlocker, J. L., Konstan, J. A., Borchers, A. and Riedl, J.: An algorithmic framework for performing collaborative filtering, *Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval*, ACM, pp. 230–237 (1999).
 - [7] Herlocker, J. L., Konstan, J. A., Terveen, L. G. and Riedl, J. T.: Evaluating collaborative filtering recommender systems, *ACM Transactions on Information Systems (TOIS)*, Vol. 22, No. 1, pp. 5–53 (2004).
 - [8] 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).
 - [9] Linden, G., Smith, B. and York, J.: Amazon.com recommendations: Item-to-item collaborative filtering, *Internet Computing, IEEE*, Vol. 7, No. 1, pp. 76–80 (2003).
 - [10] 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*, ACM, pp. 1097–1101 (2006).
 - [11] Mobasher, B., Jin, X. and Zhou, Y.: Semantically enhanced collaborative filtering on the web, *Web Mining: From Web to Semantic Web*, Springer, pp. 57–76 (2004).
 - [12] Murakami, T., Mori, K. and Orihara, R.: Metrics for evaluating the serendipity of recommendation lists, *New frontiers in artificial intelligence*, Springer, pp. 40–46 (2008).
 - [13] Sarwar, B., Karypis, G., Konstan, J. and Riedl, J.: Analysis of recommendation algorithms for e-commerce, *Proceedings of the 2nd ACM conference on Electronic commerce*, ACM, pp. 158–167 (2000).
 - [14] Sarwar, B., Karypis, G., Konstan, J. and Riedl, J.: Item-based collaborative filtering recommendation algorithms, *Proceedings of the 10th international conference on World Wide Web*, ACM, pp. 285–295 (2001).
 - [15] Schickel-Zuber, V. and Faltings, B.: Inferring user's preferences using ontologies, *AAAI*, Vol. 2006, pp. 1413–1418 (2006).
 - [16] Yin, X. and Han, J.: CPAR: Classification based on Predictive Association Rules., *SDM*, Vol. 3, SIAM, pp. 369–376 (2003).
 - [17] Yoshikawa, T., Mori, T. and Furuhashi, T.: Proposal of a New Recommendation System that Addresses 'Personalizability', *JACIII*, Vol. 17, No. 2, pp. 167–175 (2013).
 - [18] 奥 健太, 服部 文夫: セレンディビティ指向情報推薦のためのフェュージョンベースアプローチのユーザ評価, *DEIM Forum*, pp. A1–3 (2012).
 - [19] 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*, Vol. 26, No. 0, pp. 157–157 (2010).
 - [20] 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).
 - [21] 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).
 - [22] 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).

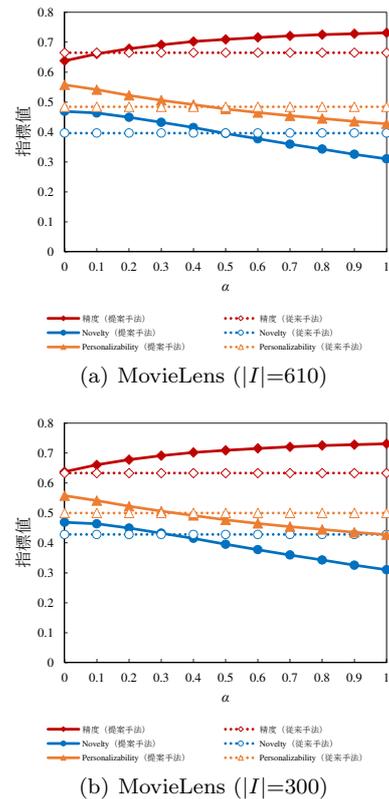


図 1 提案手法と従来手法の比較 (MovieLens データセット)
Fig. 1 Comparison between proposed method and conventional method (MovieLens data set)

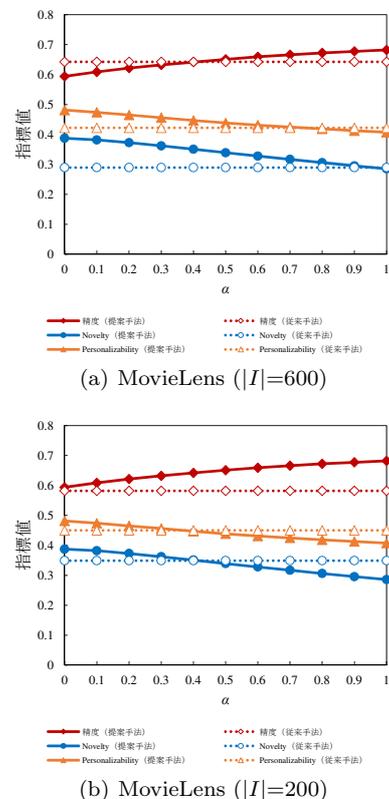


図 2 提案手法と従来手法の比較 (MovieLens データセット, 密度 10%)
Fig. 2 Comparison between proposed method and conventional method (MovieLens data set, density 10%)