

# 共購買情報を用いた多様性のある推薦アルゴリズムの提案 Amazon.co.jpの関連商品ネットワークを用いて

## Algorithm Development for Diversified Recommendation based on Co-purchase Information: Employing Items Similarity Network in Amazon.co.jp

小川祐樹<sup>1</sup>, 諏訪博彦<sup>1</sup>, 山本仁志<sup>2</sup>, 岡田勇<sup>3</sup>, 太田敏澄<sup>1</sup>  
Yuki OGAWA, Hirohiko SUWA, Hitoshi YAMAMOTO, Isamu OKADA,  
Toshizumi OHTA

<sup>1</sup> 電気通信大学大学院 情報システム学研究所 Graduate School of Information Systems University of  
Electro-Communications

<sup>2</sup> 立正大学 経営学部 Faculty of Business Administration, Rissho University

<sup>3</sup> 創価大学 経営学部 Faculty of Business Administration, Soka University

### 概要:

我々は、推薦の正確さと多様性の両立によってユーザ満足度を向上させる推薦アルゴリズムを提案する。既存の推薦アルゴリズムは、正確な反面、意外な推薦が行われにくい。我々は、共購買がされにくいアイテムの組合せを多様性のある推薦と考え、多様性の評価指標とする。本研究では、Amazon.co.jp のレビューを用いて協調フィルタリングによる推薦リストを作成し、共購買情報を用いた多様化アルゴリズムにより、多様性のある推薦リストを生成する。

### 1. はじめに

推薦システムは、Amazon.com など多くの商用サイトで用いられている。協調フィルタリングは、推薦システムを作る際に最もよく使われる手法であり、実用的な手法とされている。従来の協調フィルタリングによる推薦システムの研究では、推薦の正確さ（MAE, 精度, 再現率）の向上を重視しており、推薦の多様性に関する研究は少ない。正確さを重視した推薦システムは、ユーザの嗜好を正確にとらえる反面、推薦されるアイテムが似かよったものばかりになってしまい、意外なアイテムの推薦が行われにくいという問題を抱えている。

本研究では、推薦の正確さをある程度維持し、かつ推薦の多様性を向上させることにより、ユーザの満足度を向上させる推薦アルゴリズムの提案を目指す。

### 2. 先行研究

推薦システムの多様性の問題に対し、Ziegler ら[1]は従来の協調フィルタリングから求められる推薦リストを、リスト内のアイテムトピック（Amazon.com で付与されているジャンル分類）が最も多様になるアイテムの組み合わせに改善する推薦アルゴリズムを提案している。また実験により、推薦に多様性を導入することで、正確さのみを重視した推薦よりも高いユーザ満足度が得られることを示している。清水ら[2]は、ユーザの知らないであろうアイテムを多く推薦させるために、アイテムへの既知・不既知のユーザプロフィールを用いることで発見性を考慮した推薦アルゴリズムを

提案している。

これら先行研究の問題点として、[1]では多様化が人手の静的な分類法に依存しているために、多様化の定義が不十分である点、[2]ではアイテムの評価値以外に、アイテムへの既知・不既知のユーザプロフィールが必要なため、ユーザの労力が大きい点などがあげられる。

本研究では、動的に変化する共購買の情報によって多様化を定義し、評価値以外のユーザプロフィールを用いない推薦アルゴリズムを提案する。

### 3. 正確さと多様性を両立した推薦アルゴリズム

本研究では、正確さと多様性を両立した推薦アルゴリズムの構築を目指す。そこで、推薦の正確さについては、従来の正確さの高い協調フィルタリングアルゴリズムに注目し、そのアルゴリズムを改善させることで推薦の正確さの向上をはかる。また推薦の多様性については、共購買ネットワークを用いた多様化アルゴリズムを用いることで推薦の多様性の向上をはかる。これら 2 つのアルゴリズムについて、以下の節で詳しく述べる。

#### 3.1. 類似ユーザの評価者数を考慮した予測評価値計算

協調フィルタリングによる推薦は、ユーザと好みの似たユーザグループが好きなアイテムをそのユーザに推薦するというものである。手順としては、類似度計算と予測評価値計算の 2 つの手順で行われる。

従来の予測評価値計算では、予測するアイテムの評

価値を、近傍ユーザの類似度の合計値で正規化する手法をとっている。しかし、個人の評価情報を正規化すると、本来気に入ったアイテムを他者に薦めたいと考えてお気に入りアイテムを評価したユーザの情報は、正規化の段階で失われてしまう。また、多くの人が薦めているという情報も評価者数で割ることで失われてしまう。

そこで我々は、評価情報の損失を防ぎ、評価情報を保存した協調フィルタリングアルゴリズムを提案する。

### 3.1.1. 従来の協調フィルタリングによる推薦

類似度計算では、推薦を受けるユーザと似た嗜好を持っているユーザを推定するために、ユーザ間の類似度を計算する。一般的に類似度計算は、相関係数法とベクトルを用いた Cosine 類似度による計算方法とに分別される。本研究では、GroupLens[3]において用いられたピアソン相関係数と、事前実験において高い精度が得られた Adjusted Cosine Similarity による 2 つの類似度計算を用いた。

予測評価値計算では、類似するユーザの評価をもとに、未評価のアイテムに対して、そのアイテムの予測評価値を計算する。この値の上位  $N$  アイテムが、Top- $N$  推薦リストとしてユーザに提示される。本研究では、GroupLens[3]で用いられた Adjusted Weight Sum (1) と、事前実験において高い精度が得られた Weight Sum (2) による 2 つの予測評価値計算を、提案する予測評価値計算式との比較対象として用いた。ユーザ  $u$  の未評価アイテム  $i$  に対する予測評価値  $P_{u,i}$  をそれぞれ以下に示す。

$$P_{u,i}^{AWS} = \bar{r}_u + \frac{\sum_{m \in M} \text{sim}(u, m)(r_{m,i} - \bar{r}_m)}{\sum_{m \in M} \text{sim}(u, m)} \quad (1)$$

$$P_{u,i}^{WS} = \frac{\sum_{m \in M} \text{sim}(u, m) r_{m,j}}{\sum_{m \in M} \text{sim}(u, m)} \quad (2)$$

ここで、 $r_{m,i}$  はユーザ  $i$  のアイテム  $i$  へ投票した評価値、 $\bar{r}_u$  はユーザ  $u$  の投票したすべての評価値の平均、 $m$  はユーザ  $u$  の類似度の高い上位  $M$  人の近傍ユーザとする。

### 3.1.2. 提案する予測評価値計算

我々は、正規化による評価情報の損失を防ぐために、予測評価値計算において、値を類似度の合計値で正規化しない Simple Adjusted Summation 手法 (3) を提案する。

$$P_{u,i}^{SAS} = \bar{r}_u + \sum_{m \in M} \text{sim}(u, m)(r_{m,i} - \text{standard value}) \quad (3)$$

ここで、standard value は、評価値の基準値 (例えば評価値が 1~5 の場合、基準値は 3 となる) とする。上

記の式により、近傍ユーザの多くが高く評価したアイテムほど値が高くなり、推薦リストの上位に現れやすくなることで正確さの向上がはかれると考える。

## 3.2. 共購買ネットワークを用いた推薦の多様化

### 3.2.1. 多様化の定義

本研究で定義する多様性のある推薦とは、共購買がされにくいアイテムの組み合わせのものを推薦することと定義する。この理由として、共購買されるアイテムは同じ著者や同じトピックである場合が多く、内容の近いアイテムであり、逆に共購買されないアイテムは内容の離れたアイテムと考えられるためである。したがって、共購買されにくいアイテム集合を推薦リストとすることで、普段は一緒に買わないアイテムを多く推薦でき、ユーザの現在の興味範囲や、潜在的な興味範囲をより広くカバーできる可能性が高いと考える。

### 3.2.2. 多様化アルゴリズム

多様化アルゴリズムとして、アイテムの共購買のネットワークから求められる指標 (ネットワーク径、次数中心性、PageRank 等) を多様化の指標として用いる。これらの指標をもとに、既存の推薦リストの推薦順位を入れ替えることで、多様化を行った新たな推薦リストを生成する。

## 4. 推薦リストの評価指標

現在、推薦の評価方法は様々提案されているが、従来の研究で重視されているシステム評価は、推薦へのユーザの直接的な評価ではないという欠点がある。本研究ではこの問題点をふまえ、システム評価ではなくユーザ満足度による評価を重視し、これを向上させるアルゴリズムを目指す。以下に、従来のシステム評価と、本研究で定義するユーザ満足度評価について述べる。

### 4.1. システム評価

精度と再現率は、情報検索システムの評価指標としてよく知られており、協調フィルタリングによる推薦リストの正確さの指標として用いられている[4]。これらの値は交差検証法によって計算される。交差検証法では、各ユーザの評価情報を  $K$  個のブロックに分割する。ここで、 $K-1$  個のブロックはトレーニングセットとされ、残りの 1 ブロックであるテストセットを予測するデータとされる。本研究では、 $K=10$  の  $k$ -folding cross-validation によって以下の指標を計算した。

$$\text{精度} = \frac{|T_i^x \cap L_i^x|}{|L_i^x|} \quad (4)$$

$$\text{再現率} = \frac{|T_i^x \cap L_i^x|}{|T_i^x|} \quad (5)$$

ここで、 $T_i^x$  はユーザ  $i$  のテストセット中の好きなアイ

テム集合,  $|T_i^x|$ はそのアイテム数,  $L_i^x$ はユーザの推薦リスト内のアイテム,  $|L_i^x|$ はそのアイテム数とする.

正確さ以外の指標としては, 推薦が当たり前でないことを表す Novelty という指標が提案されている[5]. Novelty における精度・再現率を以下に示す.

$$\text{精度(Novelty)} = \frac{|C_i^x \cap L_i^x|}{|L_i^x|} \quad (6)$$

$$\text{再現率(Novelty)} = \frac{|C_i^x \cap L_i^x|}{|C_i^x|} \quad (7)$$

$C_i^x$ は, ユーザ*i*のテストセット中の知らない好きなアイテムとする.

この他に, 推薦リスト内に知らないアイテムがどれだけあるかを測定するための指標として, 発見性という指標が提案されている[2].

$$\text{発見性} = \frac{|D_i^x \cap L_i^x|}{|L_i^x|} \quad (8)$$

$D_i^x$ は, ユーザの知らないアイテムとする.

#### 4.2. ユーザ満足度評価

精度や再現率などのシステム評価指標は, ユーザが提供する初期評価アイテムをどれだけ正確に推薦できるかという指標であり, どのアイテムを評価したかということに依存する. よって, システム評価は, 初期に評価したアイテムから分かるユーザモデルに対しての推薦の評価しか考慮されていない. 推薦の評価は, いかにユーザが初期評価したアイテムに近いアイテムが推薦されるかだけではなく, 今まで知らなかったが興味のあるアイテムが推薦できたかという, ユーザの潜在的興味をどれだけ発見できたかということも考慮する必要があると考える.

以上のことより, 我々は推薦への多様性の導入の効果をシステム評価で測るのは難しいと考えるため, 推薦の評価方法として, ユーザの推薦への直接的な評価であるユーザ満足度評価を重視する. また我々は, 推薦の正確さとユーザの潜在的興味を測るユーザ満足度の評価指標として, 適合性(9), 納得性(10), 意外性(11)の3つの指標を提案し, アンケートによってユーザ満足度の評価を行う.

$$\text{適合性} = \frac{\sum_{i \in N} -2|La_i^1| - |La_i^2| + |La_i^4| + 2|La_i^5|}{|N|} \quad (9)$$

$$\text{納得性} = \frac{\sum_{i \in N} -2|Lb_i^1| - |Lb_i^2| + |Lb_i^4| + 2|Lb_i^5|}{|N|} \quad (10)$$

$$\text{意外性} = \frac{\sum_{i \in N} -2|Lc_i^1| - |Lc_i^2| + |Lc_i^4| + 2|Lc_i^5|}{|N|} \quad (11)$$

ここで,  $|N|$ は被験者数,  $|La_i^x|$ はユーザ*i*の推薦アイテム中の, 見たアイテムへの評価値*x*のアイテム数とする. 同じように,  $|Lb_i^x|$ は見えてないけど知っているアイテム,  $|Lc_i^x|$ は知らないアイテムへの評価値*x*のアイテム数とする.

本研究では, この指標の「適合性」と「納得性」を推薦リストの正確さの指標, また「意外性」をユーザの潜在的興味をどれだけ発見できたかという指標として捉え, ユーザ満足度の評価指標とする. これらの指標の値は, 値が大きいほどユーザ満足度の高い推薦であることを表す.

#### 4.3. 多様化度評価

本研究では, 推薦リストの多様化度を測る指標として, 共購買ネットワークから計算される PageRank[6]というネットワーク指標を用いる. PageRank とは, 「多くの良質なページからリンクされているページは, やはり良質なページである」という再帰的な関係をもとに全てのページの重要度を判定したものであり, Google などのページの検索順位の計算などにも用いられている指標である. 本研究では, この PageRank を用いて, アイテムの多様化度を判断し, 推薦リストの多様化の評価指標とする.

共購買ネットワークにおける PageRank の高いアイテムとは, 色々なアイテムと一緒に購買されているメジャーなアイテムであると考えられる. また逆に, PageRank の低いアイテムとは, 一緒に購買されることが少ないマイナーなアイテムであるともいえる. 推薦されるアイテムがメジャーなアイテムである場合, ユーザは既にそのアイテムを知っている可能性が高いため, ユーザの知らないアイテムを推薦するといった推薦の意外さは小さくなってしまふと考えられる. これとは逆に, マイナーなアイテム, つまり PageRank の低いアイテムの推薦は, ユーザの知らないアイテムである可能性が高く, ユーザの潜在的興味を発見につながる可能性が高いと考える.

以上のことをふまえ, 我々は, PageRank の小さいアイテムが推薦リスト中に多く含まれているほど, その推薦リストは多様化度が高いとリスト考える. そこで, 本研究では推薦リストの多様化度評価の方法として, 以下の方法を用いる.

1. 近傍ユーザが評価した推薦候補アイテム集合に対し, 予測評価値の降順の推薦順位を計算
2. 近傍ユーザが評価した推薦候補アイテム集合に対し, アイテムの PageRank の昇順で推薦順位を計算
3. 1.の順位と2.の順位との順位相関係数を計算

本研究では, 3.で計算される順位相関係数の値を推薦

リストの多様化の評価指標とする。

## 5. 評価実験

正確さと多様性を両立した推薦アルゴリズムの事前実験として、「類似ユーザの評価者数を考慮した予測評価値計算」による正確さを向上させるアルゴリズムの評価実験を行った。実験の手順を以下に示す。

### 5.1. 実験概要

1. Amazon.co.jp の売上 Top1000 の DVD アイテムを全集合とし、各ユーザ（学生 12 人）にランダム 32 個のアイテムを提示する。
2. ユーザは提示された各アイテムに対し、アイテム知識（見た、見てないけど知っている、知らない）と、嗜好の評価値 1~5（1:最低, 5:最高）を入力する。
3. これらの評価値情報をもとに、それぞれのアルゴリズムで予測評価値を計算し、推薦リスト（予測評価値の上位 Top10 アイテム）を生成する。
4. 各アルゴリズムで生成した推薦リスト内のアイテムの和集合をランダムでユーザに提示し、ユーザは各アイテムに対して、アイテム知識と評価値を入力する。

手順 1 における Top1000 アイテムは、Amazon.co.jp の全 DVD アイテム数に対する各ジャンルのアイテム数の割合を考慮し、各ジャンルでの売上上位のアイテムを選定した。手順 4 におけるアルゴリズムは、類似度計算アルゴリズムとして Adjusted Cosine Similarity（ACS）、ピアソン相関係数（Pe）を用い、それに対応する予測評価値計算アルゴリズムとして、既存手法の Weight Sum（WS）、Adjusted Weight Sum（AWS）と、提案手法である Simple Adjusted Summation（SAS）を用いた。この他、推薦アイテムをランダムに選ぶアルゴリズム（Ra）を比較対象として用いた。

### 5.2. データセット

本実験では、協調フィルタリングにおいて標本となる評価値情報、またアイテムの共購買の情報として、Amazon.co.jp の DVD アイテムのデータを用いた。これらのデータは、Amazon.com が提供する Amazon API [7]によって取得し、評価値情報としてユーザ数 3,108 人（1 ユーザあたりの平均評価アイテム数 3.2 個、平均評価値 4.2）のデータを得た。

### 5.3. 評価方法

本実験では、推薦リストの評価方法として、評価値情報のみから求めることができるシステム評価と、実際の推薦リストに対するユーザ満足度評価、生成される推薦リストの多様化度評価の 3 つによる評価を行う。

### 5.4. 実験結果

表 1 は、推薦された Top10 アイテムにおける、アイ

テム知識別のアイテム数の割合である。

表 1： 推薦された Top10 アイテムにおけるアイテム知識の内訳（単位：アイテム数）

	類似度計算 & 予測評価値計算	ACS & SAS	ACS & WS	ACS & AWS	Pe & SAS	Pe & WS	Pe & AWS	Ra
アイテム知識	見た	3.6	0.6	1.6	4.2	1.2	0.8	0.6
	見てないけど知っている	2.6	2.4	2.8	3.4	2.8	3.0	2.0
	知らない	3.8	7.0	6.2	2.4	6.0	6.2	7.4

表 1 より、ACS 類似度と Pe 類似度の両方の SAS 手法において、他の予測評価計算手法よりも、見たアイテムが多く推薦されていることが分かる。また、その影響で推薦リスト中の知らないアイテムが推薦される割合は低くなっている。

表 2 は、初期アイテムの評価値情報から求められる従来のシステム評価（精度・再現率、Novelty、発見性）の計算結果である。

表 2： システム評価（精度・再現率、Novelty、発見性）

類似度計算アルゴリズム & 予測評価値計算アルゴリズム	ACS & SAS	ACS & WS	ACS & AWS	Pe & SAS	Pe & WS	Pe & AWS	Ra
精度	.00017	.00100	.00033	.00092	.00167	.00118	.00041
再現率	.00105	.00875	.00208	.00833	.01243	.00868	.00234
精度 (Novelty)	.00000	.00000	.00000	.00000	.00067	.00000	.00025
再現率 (Novelty)	.00000	.00000	.00000	.00000	.00444	.00000	.00248
発見性	.00058	.00275	.00183	.00033	.00150	.00076	.00165

表 2 の精度・再現率において、SAS 手法では他の予測評価値計算手法よりも値が低くなった。また、精度（Novelty）・再現率（Novelty）において、Pe 類似度 & WS 手法とランダム手法以外の計算結果が 0 となった。これについては、推薦するアイテム数を上位 10 アイテムと少ない数に設定したことと、表 2 より、SAS 手法は知らないアイテムが推薦される数が少ないために、このような結果になったと考えられる。発見性については、表 2 の結果と対応した結果となった。

表 3 に推薦リストの多様化度評価の結果を示す。表は被験者別、類似度計算別の推薦候補アイテムリスト（近傍ユーザの評価したアイテム）における、多様化推薦順位（PageRank の昇順）と、通常の推薦順位（予測評価値の降順）との順位相関係数の計算結果である。

表 3：多様化度評価（多様化推薦順位と通常の推薦順位との順位相関係数）

推薦候補アイテムリスト 被験者	ACS & SAS	ACS & WS	ACS & AWS	Pe & SAS	Pe & WS	Pe & AWS
被験者A	-0.066	0.058	0.053	-0.057	0.147	0.101
被験者B	-0.108	-0.029	0.022	-0.061	0.044	0.009
被験者C	-0.018	-0.051	-0.153	-0.082	0.019	0.004
被験者D	-0.180	-0.067	-0.102	-0.141	-0.022	0.017
被験者E	-0.264	-0.057	-0.025	-0.134	0.097	0.076
被験者F	0.033	0.075	0.098	-0.024	0.070	-0.096
被験者G	-0.140	-0.110	-0.059	-0.145	-0.063	-0.043
被験者H	-0.076	-0.002	-0.039	-0.160	-0.015	-0.098
被験者I	-0.086	0.052	0.071	-0.066	0.024	-0.047
被験者J	0.000	0.064	-0.016	-0.195	-0.023	0.035
被験者K	0.147	0.131	0.060	-0.159	-0.151	-0.191
被験者L	-0.045	0.010	-0.045	-0.067	0.105	0.106

表 4：通常の推薦順位の上位 30 アイテム中，多様化推薦順位の上位 30 アイテムが含まれている個数（単位：平均アイテム個数）

推薦候補アイテムリスト 被験者	ACS & SAS	ACS & WS	ACS & AWS	Pe & SAS	Pe & WS	Pe & AWS
被験者A	5.300	7.021	5.939	1.567	7.031	5.870
被験者B	7.694	10.000	11.000	5.390	8.684	7.158
被験者C	8.214	5.000	6.842	5.148	6.102	4.500
被験者D	5.039	6.207	7.620	2.875	4.853	5.047
被験者E	2.000	3.750	3.222	2.273	6.573	5.581
被験者F	7.143	7.674	7.841	5.862	8.000	7.500
被験者G	9.231	8.000	10.290	3.529	4.054	4.952
被験者H	5.644	6.094	6.453	4.419	4.898	5.133
被験者I	4.778	6.600	6.000	3.453	6.000	5.000
被験者J	9.857	12.000	12.000	4.000	5.571	9.113
被験者K	9.346	8.824	10.771	7.290	6.563	7.273
被験者L	8.556	9.600	8.000	5.455	6.353	9.000

表 3 では，AWS 類似度と Pe 類似度の両方の SAS 手法において，既存の手法よりも多様化推薦順位との関係が負の値で大きい傾向にある．これは，SAS 手法で生成される推薦リストは，既存の手法に比べて推薦リストの多様化が行われていないことを示している．

表 3 では，推薦候補アイテムのすべての順位で多様化の度合いを評価した．しかし，現実的には，実際にユーザに推薦されるアイテムは，推薦候補アイテムのいくつかのアイテムに限られている．そのため，すべてのアイテムの順位の評価ではなく，実際に推薦される上位アイテムに対する評価の方が重要になると考えられる．そこで表 4 に，上位 30 アイテムに対する多様化度の評価として，推薦候補アイテムリストにおける，通常の推薦順位の上位 30 アイテム中，多様化推薦順位

の上位 30 アイテムが何個含まれているかの割合を分析した結果を示す．

表 4 より，ACS 類似度と Pe 類似度の両方の SAS 手法において，多様化推薦順位の上位アイテムが推薦リストに含まれる数は少ない傾向になった．この結果は，表 3 との結果に対応している．

表 5 は，推薦リストに対し，ユーザが直接評価するユーザ満足度評価の結果である．

表 5：ユーザ満足度評価（適合性，納得性，意外性）

類似度計算 & 予測評価値計算	ACS & SAS	ACS & WS	ACS & AWS	Pe & SAS	Pe & WS	Pe & AWS	Ra
	適合性	4.6	1.5	2.3	2.6	0.5	
納得性	3.8	2.3	1.9	1.0	0.4	0.6	1.0
意外性	0.8	-1.8	-3.1	0.3	-0.7	-2.3	-2.0
合計	9.1	2.1	1.1	3.9	0.3	-1.4	-0.4

表 5 では、適合性において、提案した SAS 手法が高い値を示している。これは、SAS 手法が見たアイテムをより多く推薦できたことを示している。また、SAS 手法が意外性の項目において唯一プラスの値となっている。

### 5.5. 考察

表 1 より、SAS 手法では、ユーザが実際に見たことがアイテムが多く推薦され、知らないアイテムが推薦される割合は小さくなった。しかし、表 5 のユーザ満足度の結果において「意外性」の値が高いことから、SAS 手法は、推薦リスト中、知らないアイテムが推薦される割合は少ないが、知らないアイテムを推薦されたときには、そのアイテムの多くは高く評価されているといえる。

表 2 のシステム評価において、SAS 手法での精度・再現率が低い理由としては、SAS 手法では近傍ユーザの中で評価数が多いアイテム、つまり一般的にレビュー数が高いものが推薦リストの上位にきたために、ユーザごとのパーソナライズされた推薦アイテムの順位が相対的に下がったのではないかと考えられる。これに関しては、推薦リストとするアイテムの数を増やした場合での、精度・再現率の変化について今後分析が必要と考える。

表 3 と表 4 の結果より、SAS 手法で生成される推薦リストは、既存の予測評価値計算手法よりも多様化の度合いが少ないリストとなる傾向になることが分かった。この結果は、表 1 において、SAS 手法では見たアイテムが多く推薦され、知らないアイテムの推薦される割合は少ないという結果とも一致している。よって、多様化度評価の方法は、推薦リストにおけるユーザの知らないアイテムの割合を推測するのに効果的な評価方法であるといえる。

表 5 のユーザ満足度評価では、SAS 手法による推薦リストは、多様化度が低いにもかかわらず、既存の予測評価値計算手法よりも意外性の値が高い結果となった。この結果より、多様化度の向上が直接ユーザ満足度の向上につながるわけではないということがいえる。よって、どの程度の多様化がユーザ満足度を最も大きくするかについては、今後さらに検討していく必要があると考える。

### 6. まとめ

本研究では、推薦の正確さと多様性を両立した推薦アルゴリズムの提案を目指し、正確さの向上のために、

類似ユーザの評価者数を考慮したアルゴリズム、また多様性の向上のために、共購買ネットワークを用いた多様化アルゴリズムを提案した。さらに、推薦の多様化の度合いを測る方法として、PageRank による多様化推薦順位との比較による多様化度評価の方法を対案した。評価実験として、正確さの向上のための提案アルゴリズムである「類似ユーザの評価者数を考慮した予測評価値計算」について焦点をあて、既存の推薦アルゴリズムとの比較調査を行った。この結果、提案した予測評価値計算手法では、推薦リストの多様化の度合いは低くなったが、ユーザ満足度評価において高い適合性と意外性の値を得た。

### 7. 今後の課題

本研究では、提案手法により適合性の高い推薦リストの作成が実現できた。しかし、見たアイテムばかりが推薦されてしまうと、推薦アイテムが当たり前すぎてユーザはその推薦に興味を持たなくなってしまうことが考えられる。このため、推薦リストでの、適合性・納得性・意外性のバランスにおいても検討する必要があると考える。また、Amazon.co.jp の共購買ネットワークを用いた多様化についても、多様化の度合いをパラメータによって変化させることができるアルゴリズムとして構築したいと考える。また多様化の導入の効果についても、今後実験を行い検証する予定である。

### 参考文献

- 1) Ziegler, C., McNee, S.M., Konstan, J.A. and Lausen, G., "Improving Recommendation Lists Through Topic Diversification", WWW2005, pp.22-32, 2005.
- 2) 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に関する基礎検討", 情報処理学会研究報告 データベース・システム研究会報告, vol.2006, No.59, pp.53-60, 2006.
- 3) P. Resnick, N. Iacovou, M. Suchak, P. Bergstrom, and J. Riedl, "GroupLens: An Open Architecture for Collaborative Filtering of Netnews", In *Proc. ACM Conf. on Computer Supported Cooperative Work*, Chapel Hill, NC, pp.175-186, 1994.
- 4) Sarwar, B., Karypis, G., Konstan, J., and Riedl, J.: "Application of dimensionality reduction in recommender system", In *ACM WebKDD Workshop*, 2000.
- 5) Herlocker, J., Konstan, J., Terveen, L., and Riedl, J.: "Evaluating collaborative filtering recommender systems", *ACM Transactions on Information Systems*, Vol.22, No.1, pp.5-53, 2004.
- 6) L.Page, S.Brin, R.Motwani, and T.Winograd, "The PageRank Citation Ranking: Bringing Order to the Web", Technical Report, Computer Science Department, Stanford University, 1998
- 7) Amazon Web Services:  
<http://www.amazon.com/gp/aws/landing.html>.