

価値観モデルベース協調フィルタリングのハイブリッド推薦システムへの拡張

三澤遼理 高間康史

首都大学東京

ytakama@tmu.ac.jp

概要 価値観をアイテムの属性に対するこだわりの強さと定義してユーザモデルを構築する手法が提案されており、これをユーザ間類似度の計算に適用した価値観モデルベース協調フィルタリングが研究されている。評価実験によりその有効性が示されているが、その効果はユーザに依存することや、ユーザベース協調フィルタリングよりもアイテム被覆率が低下する問題などが指摘されている。本稿では、価値観モデル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を組み合わせたハイブリッド推薦により、これらの問題を解決することを試みる。複数の統合方法について提案し、テストデータセットを用いた比較実験を行うことで各手法の有効性や性質について考察する。

キーワード 情報推薦、価値観、協調フィルタリング、ハイブリッド推薦

1 はじめに

本稿では、価値観に基づくユーザモデルを利用した協調フィルタリング (Collaborative Filtering, CF) である価値観モデルベース CF を拡張したハイブリッド推薦システムを提案する。

近年、ショッピングサイトなどにおいて、ユーザが購入・閲覧したアイテムの情報からユーザに有用な情報を提示する情報推薦が広く利用されており、CF はその代表的な手法として知られている [1]。しかし、新規ユーザ・アイテムに対する利用履歴の不足から適切な推薦が行えないという cold-start 問題などが課題として指摘されている [2]。

一方、個人の嗜好や消費行動に影響を与える要素として価値観 (personal value) [3] や個性 (personality) [4] があり、これらを情報推薦システムで利用することが研究されている [5, 6]。服部らは、価値観をアイテムの属性に対するユーザのこだわりの強さと定義し、評価一致率という指標でユーザモデルを構築する手法を提案している [7]。我々は、このユーザモデルを CF におけるユーザ間類似度の計算に利用した価値観モデルベース CF を提案しており、低評価値の予測において MAE が低減する結果などが得られている [8]。

しかし、予備実験などの結果、データセットや推薦対象ユーザにより有効性が異なること、通常のユーザベース CF と比較して推薦可能なアイテム数が少なくなる場合があることなどが判明している。本稿ではこの課題に対し、価値観モデルベース CF とユーザベース CF を組み合わせたハイブリッド推薦システムによる解決を試みる。具体的には、価値観モデルベース CF、ユーザベ

ス CF それぞれを用いて作成した推薦リストを統合することにより、推薦可能なアイテム数を増加させる手法や、分類モデルを構築することにより価値観モデルベース CF が有効なユーザを識別し、推薦手法をユーザごとに切り替える手法を提案する。4travel、楽天トラベル、Livedoor グルメ、Yahoo!映画、Hot Pepper Beauty のレビューデータから作成したデータセットを用いて評価実験を行った結果に基づき、提案手法の有効性を検証する。

2 関連研究

2.1 協調フィルタリング

CF は、アイテムのコンテンツに関する情報ではなく、ユーザによる評価の類似度に基づき予測評価値を求める手法であり、ユーザベース [1] とアイテムベース [9] に大別される。ユーザベースは嗜好が類似するユーザが好むものを推薦するのに対し、アイテムベースはユーザが好むアイテムと類似するアイテムを推薦する。また、CF はメモリベース法とモデルベース法にも分けられる [2]。メモリベース法では推薦を行う時点でデータベースにアクセスし、蓄積された嗜好データを利用して推薦を行う。モデルベース法では、事前にユーザのモデルを構築しておき、構築したモデルと推薦を受けるユーザの嗜好データをもとに推薦を行う。

以下では、価値観モデルベース CF のベースとなる、ユーザベース CF について説明する。ユーザベース CF は、近傍ユーザの計算と予測評価値の計算の 2 つのフェーズに大別される。近傍ユーザの計算フェーズでは、ユーザ u_i, u_j の類似度を以下の Pearson 係数 ρ_{ij} で求める。ここで、 $I_{ij} (\subseteq I)$ は u_i, u_j が共に評価したアイテム集合、 r_{ik} はアイテム x_k に対する u_i の評価値、 \bar{r}_i^{ij} は I_{ij}

における u_i の平均評価値である。

$$\rho_{ij} = \frac{\sum_{x_k \in I_{ij}} (r_{ik} - \bar{r}_i^{ij})(r_{jk} - \bar{r}_j^{ij})}{\sqrt{\sum_{x_k \in I_{ij}} (r_{ik} - \bar{r}_i^{ij})^2} \sqrt{\sum_{x_k \in I_{ij}} (r_{jk} - \bar{r}_j^{ij})^2}} \quad (1)$$

推薦対象ユーザ u_t の x_k に対する予測評価値 \hat{r}_{tk} は、近傍ユーザ ($u_j \in U_t$) の x_k に対する予測評価値と、 u_t との類似度に基づいて以下の式により求める。

$$\hat{r}_{tk} = \frac{\sum_{u_j \in U_t} \rho_{tj} r_{jk}}{\sum_{u_j \in U_t} \rho_{tj}} \quad (2)$$

2.2 値値観ベース協調フィルタリング

心理学などの分野において、価値観を構成する要因である Rokeach Value Survey[3] や、個性を構成する要因である Big Five[4] などが知られており、これらに基づきユーザの価値観や個性を分析するアプローチが有名である。しかし、情報推薦への応用を考えた場合、対象アイテムの評価により直結した要素に基づきユーザの価値観や個性をモデル化する方が好ましいと考える。このようなアプローチとして、伊藤らは主成分分析を用いて評価傾向が類似するユーザを求め、推薦に利用する手法を提案している [10]。

また、アイテムの評価に関連する属性に基づき価値観や個性を捉えるアプローチも存在する。Wu らは重要な属性について多様なアイテムを推薦する手法を提案しており、多様性の度合いは、ユーザの個性と多様性に対する要求との関係に基づいて決定している [6]。本稿で採用する価値観モデルベース CF も、このアプローチに該当する。

価値観モデルベース CF[8] では、ユーザベース CF の類似ユーザの計算に、評価一致率 (rate matching rate, RMRate) [7] を用いて構築されるユーザモデルを用いる。この手法では、ユーザのアイテムに対する評価極性 (好評または不評) とアイテムの各属性に対する評価極性を用いて、属性ごとの評価一致率を計算しユーザモデルを作成する。ユーザ u_i のアイテム x_j への評価極性を p_{ij} 、アイテムの属性 a_k への評価極性を p_{ij}^k とすると、 u_i の a_k における評価一致率 RMR_{ik} は式 3 で算出される。 I_i は u_i が評価したアイテム集合、 $\delta(x, y)$ は x と y の値が等しい時 1、異なる時に 0 を返す関数とする。

$$RMR_{ik} = \frac{\sum_{x_j \in I_i} \delta(p_{ij}, p_{ij}^k)}{|I_i|} \quad (3)$$

価値観モデルベース CF では推薦対象ユーザと他のユーザの価値観に基づくユーザモデルの相関係数を計算し、これをユーザ間の類似度として近傍ユーザを求める。通常のユーザベース CF とは、相関係数を求め方が

異なるだけであり、予測評価値の計算は式 2 に基づいて行う。

価値観モデルベース CF を用いることで、低い評価値が付与されている場合の予測精度向上などの結果が得られている [8]。また、ユーザモデルの次元数はアイテムの評価に関する属性数と同じであり、これは一般的なレビューサイトでは数種類と少ない。従って、ユーザ間類似度に利用する行列はユーザ・アイテム行列よりも密な行列となるため、類似度を計算可能なユーザ数が増加するという利点もある。しかし、近傍ユーザが推薦対象ユーザと同じアイテムを評価していることは保証されないため、予測評価値が計算可能なアイテム数が減少する場合がある。

3 提案手法

評価一致率を用いたユーザモデルでは、ユーザが各属性にどれだけこだわって意思決定を行っているかを推定している。しかし、人気アイテムの評価値予測はロングテールアイテムよりも容易であることが報告されている [11, 12, 13] ことから考えても、全てのユーザが強いこだわりを持ってアイテムを評価しているとは限らないと考える。

そこで、本稿では価値観モデルベース CF と通常のユーザベース CF のハイブリッド推薦システムを提案する。両手法は共にユーザベースの推薦手法であるため統合は容易であり、かつ異なる情報に基づきユーザ間の類似度を求めるため相補的な効果が期待できる。

ハイブリッド推薦システムは統合の仕方によっていくつかのタイプに分類されるが [14]、本稿では並列型に属する 3 種類の推薦システムを提案する。具体的には、価値観モデルベース CF、ユーザベース CF それぞれを用いて作成した推薦リストを統合するアプローチ、分類モデルを構築することにより価値観モデルベース CF が有効なユーザを識別し、推薦手法をユーザごとに切り替えるアプローチを採用する。

3.1 推薦リスト統合型

推薦リスト統合型では、価値観モデルベース CF とユーザベース CF それぞれで独立に推薦アイテムリストを作成した後、これを統合する。推薦アイテム決定手順は以下のとおりである。

1. 価値観モデルベース CF を用いて推薦対象ユーザに関する予測評価値を求め、降順にソートして推薦アイテムリスト $L_1 = (x_{11}, \dots, x_{1M_1})$ を求める。ここで M_1 は予測評価値の計算が可能であったアイテム数とする。
2. $I - L_1$ に含まれるアイテムに対してユーザベース

CF を適用し、同様に推薦アイテムリスト $L_2 = (x_{21}, \dots, x_{2M_2})$ を求める。ここで M_2 は予測評価値の計算が可能であったアイテム数とする。

3. $L = (x_{11}, \dots, x_{1M_1}, x_{21}, \dots, x_{2M_2})$ を最終的な推薦アイテムリストとする。

本手法では、価値観モデルベース CF による予測結果を優先して推薦するが、ユーザベース CF と組み合わせることにより推薦可能アイテム数の増加が期待できる。

3.2 分類モデルを用いたハイブリッド推薦

この推薦システムでは、以下の手順で分類モデルを構築し、価値観モデルベース CF が有効なユーザを識別する。

1. 与えられた訓練データに対して交差確認を行い、価値観モデルベース CF による各ユーザの予測精度を計算する。
2. (1) の予測精度から、各ユーザを価値観モデルベース CF が有効なユーザ (GOOD), 有効でないユーザ (BAD), 平均的なユーザ (AVERAGE) の 3 クラスに分類する。
3. 各ユーザの価値観に基づくユーザモデルを説明変数、(2) のクラスを目的変数として分類モデルを生成する。

ステップ (2) におけるユーザの分類は、全ユーザの MAE の平均値 Avg , 標準偏差 Std に基づき、以下の基準に従い分類する。ここで、 MAE_i はユーザ u_i の MAE, Th は Std の大きさに従い調整することで、GOOD に分類不能になる事態を回避している。

- GOOD: $0 \leq MAE_i \leq Avg - Th$
- AVERAGE: $Avg - Th < MAE_i \leq Avg + 0.5Std$
- BAD: $Avg + 0.5Std < MAE_i$

$$Th = 0.5Std \cdots Avg > 0.5Std \quad (4)$$

$$0.5Avg \cdots Avg \leq 0.5Std \quad (5)$$

分類モデルとして決定木を用いた場合、価値観ユーザモデルに基づき構築された分類モデルの例を図 1 に示す。

構築した分類モデルを用いて、価値観モデルベース CF が有効と判断されたユーザには価値観モデルベース CF、それ以外にはユーザベース CF を用いて推薦を行う。本稿では、判断基準の異なる以下の 2 種類について評価実験を行う。

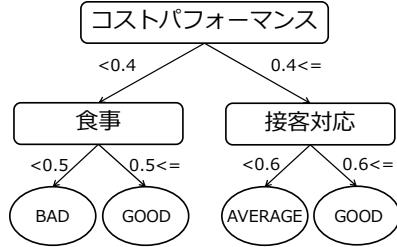


図 1 価値観ユーザモデルを元に構築した決定木の例

- HYB-CG: ユーザが GOOD に分類された場合に価値観モデルベース CF を適用。
- HYB-CGA: ユーザが GOOD, AVERAGE に分類された場合に価値観モデルベース CF を適用。

4 評価実験

4.1 実験の概要

表 1 データセットの概要

データセット	ユーザ数	アイテム数	評価データ数	密度
4travel	5,079	7,295	64,137	0.0017
楽天トラベル	2,277	1,679	68,694	0.0180
Livedoor グルメ	906	5,473	19,785	0.0040
Yahoo! 映画	498	551	57,517	0.2096
Hot Pepper Beauty	1,701	1,220	5,969	0.0029

提案手法の有効性を検証するために、予測精度とユーザ・アイテムの被覆率を指標とする評価実験を行った。実験に用いたデータセットの概要を表 1 に示す。

4travel は、ホテルや旅館のクチコミサイトであり、複数の評価項目への評価値付きのレビューが投稿されている。評価属性はアクセス、料理・味、サービス、雰囲気、コストパフォーマンス、観光客向け度、バリアフリーの 7 種類であり、総合評価も含め最小値 1 から最大値 5 の間で 0.5 刻みで評価する。楽天トラベルもホテルや旅館のクチコミサイトであり、評価属性はサービス、立地、部屋、設備・アメニティ、風呂、食事の 6 種類、評価は最小値 1 から最大値 5 までの 5 段階である。

Livedoor グルメはレストランのクチコミサイトであるが、すでにサービスを終了している。料理、サービス、雰囲気、コストパフォーマンスの 4 属性あり、総合評価も含め最小値 1 から最大値 5 までの 5 段階で評価する。

Yahoo!映画は映画のクチコミサイトであり、物語、配役、演出、映像、音楽の5属性である。このデータセットも1から5までの5段階評価となる。Hot Pepper Beautyは美容院、ヘアサロンなどのクチコミサイトであり、雰囲気、接客サービス、技術・仕上がり、メニュー・料金の4属性について1から5までの5段階で評価する。

表1に示すデータは、元のレビューデータから、評価件数の少ないユーザおよびアイテム、評価値が特定の値に偏っているユーザ及びアイテムを削除することで作成している。各データセットについて設定した各種閾値について表2に示す。ここで、 N_u はユーザ当たりの最小評価件数、 N_i はアイテム当たりの最小評価件数であり、特定の評価値が占める割合が D_u 以上のユーザ、 D_i 以上のアイテムを削除している。

表2 データセット作成に用いた閾値

データセット	N_u	N_i	D_u	D_i
4travel	3	2	0.9	0.9
楽天トラベル	20	20	0.9	0.9
Livedoor グルメ	3	2	0.9	0.9
Yahoo!映画	65	65	0.9	0.9
Hot Pepper Beauty	3	2	0.9	0.9

評価実験では、以下に示す6種類の推薦手法について実験を行い、比較する。UBは、価値観に基づくユーザモデルの効果を検証するためのベースラインとして、PVは分類モデルによるユーザ識別の効果をみるために実験を行う。分類モデルには、WekaによるRandomForestを利用した。また、PVDTはGOODと識別された場合のみ価値観モデルベースCFを適用し、それ以外のユーザには推薦を行わない手法である。PVDTでは推薦可能ユーザ数が減少することが予想できるが、HYB_I, HYB(CG, HYB_CGAとの比較により、ハイブリッド推薦の効果を確認することができる。

- ユーザベース CF (UB) (2.1節)
- 価値観モデルベース CF (PV) (2.2節)
- 分類モデルを用いた価値観モデルベース CF (PVDT) (3.2節)
- HYB_I (3.1節)
- HYB(CG (3.2節)
- HYB_CGA (3.2節)

提案手法では、HYB_Iを除き分類モデルを構築する必要があるため、評価実験では10分割交差検証を行う。

具体的な手順は以下のとおりである。ここで、 R_i はユーザ u_i が下した総合評価、属性評価の集合、 $R_i(j)$ は u_i が下した総合評価、属性評価のうち、アイテム x_j に対する評価を除いた集合とする。また、決定木を利用しない推薦手法の場合はステップ(2-1)を行わない。

- (1) ユーザ集合 U を10個の部分集合 $\{U_1, \dots, U_{10}\}$ に分割
- (2) 全ての U_i について以下を実施
 - (2-1) $U - U_i$ を用いて決定木を構築
 - (2-2) 全てのユーザ $u_t \in U_i$ について以下を実施
 - (2-2-1) u_t による全ての評価 r_{tj} について以下を実施
 - (2-2-1-1) $R^t = \cup_{u_k \in U - U_i} R_k \cup R_t(j)$ を用いて推薦リスト L_{tj} を作成

評価指標としては、以下の3指標を用いる。なお、上記ステップ(2-2-1-1)で、1件のアイテムも予測評価値を計算できなかった場合は推薦リストの作成に失敗したとみなす。

- MAE (平均絶対誤差)：予測評価値 \hat{r}_{tj} が L_{tj} に含まれる場合、 $|r_{tj} - \hat{r}_{tj}|$ を求め、全評価データの平均値を求める。
- UC (ユーザ被覆率)：全ユーザに占める、推薦リストを作成できたユーザの割合を求める。
- IC (アイテム被覆率)：推薦リストの上位20件に含まれたアイテムを推薦されたアイテムとみなし、全アイテムに占める、1回以上推薦されたアイテムの割合を求める。

4.2 実験結果

表3～7に、各データセットの実験結果(MAE, UC, IC)を示す。MAEは値が小さいほど特性が良く、UCとICは値が大きいほど特性が良い。なお、計算時間の関係から、前節で述べた交差検証をLivedoor グルメは50回、Hot Pepper Beautyは100回、それ以外のデータセットでは10回ずつ行い、平均を求めている。また、表中の括弧内の数値は6手法で比較した場合の順位を示している。比較を容易にするために、各手法の順位をまとめたものを図2-4に示す。

MAEに関しては、5つのデータセット中 PVDTが3つ、UBが2つで最小となっているが、UBは残る3データセットで最下位となっている他、Hot Pepper Beautyでは予測評価値を計算可能であったのが2件のみであった。従って、UBの性能は高くないと見える。また、PVとUBの比較では、Hot Pepper BeautyとLivedoor グルメを除いてPVのMAEが小さくなっている、価値観モデルベースCFが有効であると言える。また、PVDT

表 3 実験結果 (4travel:4T)

推薦手法	MAE	UC	IC
UB	0.601(6)	0.484(6)	0.473(3)
PV	0.456(2)	0.999(1)	0.363(5)
PVDT	0.411(1)	0.840(5)	0.298(6)
HYB_I	0.560(5)	0.999(1)	0.543(1)
HYB(CG)	0.538(4)	0.919(4)	0.501(2)
HYB_CGA	0.488(3)	0.974(3)	0.461(4)

表 4 実験結果 (楽天トラベル:RT)

推薦手法	MAE	UC	IC
UB	0.646(6)	1.000(1)	1.000(1)
PV	0.632(2)	1.000(1)	1.000(1)
PVDT	0.603(1)	0.494(6)	0.988(6)
HYB_I	0.645(5)	1.000(1)	1.000(1)
HYB(CG)	0.644(4)	1.000(1)	1.000(1)
HYB_CGA	0.633(3)	1.000(1)	1.000(1)

と PV を比較すると, Livedoor グルメを除き PVDT の方が良い結果となっていることから, 分類モデルによるユーザの識別は予測精度向上に効果があると言える.

ハイブリッド推薦の 3 手法は, Hot Pepper Beauty の場合を除き, MAE の値が全て UB と PVDT の間になっている. ハイブリッド推薦は UB, PV の組み合わせであるため, この結果は想定通りと言える. 3 手法間の比較では, データセットにより優劣が異なっているが, 特に HYB(CG) と HYB_CGA は, Hot Pepper Beauty 以外では性能差は少なくなっている.

PV とハイブリッドを比較すると, 4travel では PV の MAE が一番小さくなっているが, 手法によって同等か上回るもののが存在する. 後述する様に, ハイブリッド推薦では PV よりも IC が向上する傾向が見られることからも有効性といえる.

UC に関しては, 楽天トラベルと Yahoo!映画では PVDT 以外全ての手法で 1.000 となっている. これは, 両データセットとも他よりも密度が高いことが原因と考えられる. また, UB では密度の高い楽天トラベルと Yahoo!映画を除いて最低となっており, sparsity 問題に弱いことが確認できる.

PVDT の UC は他よりもかなり低いことがわかるが, これは全ユーザに推薦を行わないため当然の結果といえる. ハイブリッド推薦手法では UC が向上していることから, その効果が確認できる.

IC に関しては, 密度の高い楽天トラベル, Yahoo!映画では UC と同様に, 手法によらずほぼ全てのアイテムが推薦可能となっている. また, UB と PV の比較では,

表 5 実験結果 (Livedoor グルメ:LG)

推薦手法	MAE	UC	IC
UB	0.700(1)	0.257(6)	0.292(3)
PV	0.740(4)	0.984(1)	0.213(5)
PVDT	0.820(6)	0.689(5)	0.166(6)
HYB_I	0.701(2)	0.984(1)	0.382(1)
HYB(CG)	0.720(3)	0.778(4)	0.306(2)
HYB_CGA	0.749(5)	0.914(3)	0.243(4)

表 6 実験結果 (Yahoo!映画:YM)

推薦手法	MAE	UC	IC
UB	0.840(6)	1.000(1)	1.000(1)
PV	0.824(2)	1.000(1)	1.000(1)
PVDT	0.813(1)	0.488(6)	1.000(1)
HYB_I	0.824(2)	1.000(1)	1.000(1)
HYB(CG)	0.832(5)	1.000(1)	1.000(1)
HYB_CGA	0.825(4)	1.000(1)	1.000(1)

Hot Pepper Beauty で UB が極端に低いことを除けば PV の方が低くなっていることから, 予備実験と同様の傾向が確認できる.

ハイブリッド推薦手法に関しては, HYB_I が全て最良の結果となっている. これは, 二つの手法による推薦リストを統合しているので当然の結果といえる. HYB(CG), HYB_CGA も, PVDT よりも同等か良い結果が得られるのは当然であるが, Hot Pepper Beauty 以外のデータセットでは PV よりも良くなっていることから, データセットによって IC が低くなるという PV の欠点を補完できていることがわかる.

以上より, PV の予測精度 (MAE) は UB よりも良い場合が多いが, 分類モデルを用いることで精度がさらに向上する結果が得られている. また, 推薦対象ユーザを制限することによる UC の低下はハイブリッド推薦により補完できることが示された. さらに, データセットによって IC が低くなるという PV の課題も, ハイブリッド推薦により改善できることがわかる.

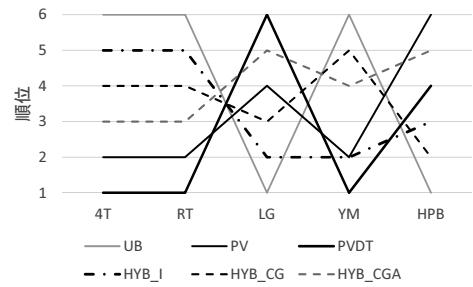


図 2 各推薦手法の順位の比較 (MAE)

表 7 実験結果 (Hot Pepper Beauty:HPB)

推薦手法	MAE	UC	IC
UB	0.000(1)	0.005(6)	0.001(6)
PV	1.041(6)	0.952(1)	0.109(1)
PVDT	0.931(4)	0.755(5)	0.079(4)
HYB_I	0.873(3)	0.952(1)	0.109(1)
HYB_CG	0.805(2)	0.756(4)	0.079(4)
HYB_CGA	1.033(5)	0.903(3)	0.099(3)

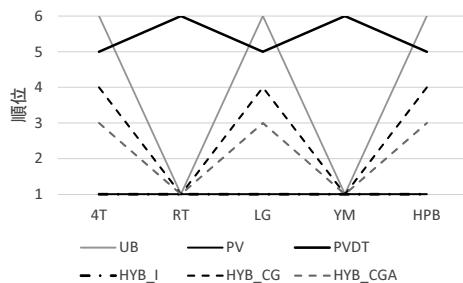


図 3 各推薦手法の順位の比較 (UC)

5まとめ

本稿では、価値観モデルベースCFの予測精度やアイテム被覆率の向上を目的とした拡張手法を提案した。実際のレビューサイトに関する5種類のデータセットを用いて、交差検証による評価実験を行った結果、分類モデル利用により予測精度向上の効果があること、ハイブリッド推薦によってユーザ被覆率の低下を抑制し、アイテム被覆率を向上させる効果が得られることを示した。

本稿では、計算可能な予測評価値全てについてMAEを求め、評価したが、今後は実際の評価値ごとのMAEや人気アイテム、ロングテールアイテムごとのMAEなどについて分析することで、価値観モデルベースCFの特性をより明らかにすることが期待される。また、データセットを利用したオンライン実験では、ユーザが実際に評価したアイテムに基づく精度評価しか行えないが、評価アイテムの共起関係によらない価値観モデルベースCFの特性を生かすためには、未知のアイテムに対する推薦精度をユーザ実験により評価することも必要と考える。

謝辞

本研究はJSPS科研費16K12535の助成を受けたものです。また、評価実験には楽天データセット、Livedoor Tech Blog、リクルートデータセットで提供されたデータセットを利用しています。

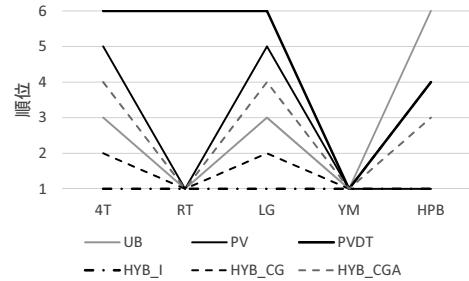


図 4 各推薦手法の順位の比較 (IC)

参考文献

- [1] Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., Riedl, J., “GroupLens: An Open Architecture for Collaborative Filtering of Netnews,” Proc. of CSCW, pp.175–186, 1994.
- [2] 神嶌敏弘, 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] Rokeach, M., “The nature of human values,” New York: The Free Press, 1973.
- [4] Costa, P. T., McCrae, R. R., “Revised NEO Personality Inventory (NEO-PI-R) and NEO Five-Factor Inventory (NEO-FFI),” Psychological Assessment Resources, 1992.
- [5] Nunes, M. A. S. N., Hu, R., “Personality-based recommender systems: an overview,” RecSys’12, pp. 5–6, 2012.
- [6] Wu, W., Chen, L., He, L., “Using Personality to Adjust Diversity in Recommender Systems,” 24th ACM Conf. on Hypertext and Social Media, pp. 225–229, 2013.
- [7] Hattori, S., Takama, Y., “Recommender System Employing Personal-value-based User Model,” JACIII, Vol. 18, No. 2, pp.157–165, 2014.
- [8] 三澤遼理, 服部俊一, 高間康史, 価値観に基づくユーザモデルによる協調フィルタリングの拡張手法の提案, 第28回人工知能学会全国大会 (JSAI2014), 1H4-NFC-01a-5, 2014.
- [9] Linden, G., Smith, B., York, J., “Amazon.com recommendations: item-to-item collaborative filtering,” IEEE Internet Computing, Vol.7, No.1, pp. 76–80, 2003.
- [10] 伊藤ゆかり, 波多野賢治, 松本尚宏, 商品の価値とユーザの嗜好を考慮した商品推薦システムの提案, 電子情報通信学会第二種研究会技術報告, vol. WI2-2010-27, pp.101–106, 2010.
- [11] Cremonesi, P., Koren, Y., Turrin, R., “Performance of Recommender Algorithms on Top-N Recommendation Tasks,” RecSys’10, pp. 39–46, 2010.
- [12] Park, Y.-J., Tuzhilin, A., “The long tail of recommender systems and how to leverage it,” RecSys’08, pp. 11–18, 2008.
- [13] Shardanand, U., Maes, P., “Social Information Filtering: Algorithms for Automating ‘Word of Mouth’,” SIGCHI Conference on Human Factors in Computing Systems, pp. 210–217, 1995.
- [14] Burke, R., “Hybrid recommender systems: survey and experiments, User-Modeling and User-Adapted Interactions,” User modeling and user-adapted interaction, Vol. 12, No.4, pp. 331–370, 2002.