

アイテム集合によって信頼できるユーザを選択した 協調フィルタリング手法の提案

高橋 徹[†] 小林 亜樹[†]

[†] 工学院大学工学部

〒163-8677 新宿区西新宿 1-24-2

E-mail: [†]c205067@ns.kogakuin.ac.jp, ^{††}aki@cc.kogakuin.ac.jp

あらまし 単純なユーザベースの推薦手法ではユーザの嗜好は単一のものとして扱われてきたが、実際には一人のユーザに対して複数アイテムのカテゴリの中にある多数の嗜好の集合体であると考えられる。そのため、ユーザがこれまで利用したことのないカテゴリのように嗜好抽出が困難な状況下では推薦精度の低下を招き、システムへの信頼性を低下させる要因だったと考えられる。

そこで本稿では、ターゲットユーザの推薦対象アイテム集合に対する嗜好が抽出困難な状況下ではターゲットユーザによる推薦対象アイテム集合を追加入力とし、その集合に対する信頼できるユーザを自動的に選択する手法を提案する。これにより、関連性のないカテゴリの嗜好ではなくカテゴリ内での評価の正当性が見込まれる他ユーザの情報を元に推薦がなされる。様々な条件下における推薦精度の見積もりを既存推薦手法との比較を交えて分析する。

キーワード 協調フィルタリング, 信頼性, アイテム集合

A Proposal for Collaborative Filtering Method by Reliable Users with Item Set

Toru TAKAHASHI[†] and Aki KOBAYASHI[†]

[†] Faculty of Engineering, Kogakuin University

1-24-2 Nishishinjuku, Shinjuku-ku, Tokyo, 163-8677 Japan

E-mail: [†]c205067@ns.kogakuin.ac.jp, ^{††}aki@cc.kogakuin.ac.jp

Abstract Typical collaborative filtering methods only uses similarities between target user and another user to calculate recommendation. In such method, it does not call into account whether the evaluations by users are accurate or not.. As the result, the recommendation precision is reduced, and it leads to reduction in the reliability of recommendation. In this paper, we proposed a recommendation method based on collaborative filtering that estimates evaluation accuracy from observation density in targeted item set. We have proposed evaluated ratio in targeted item set as a reliability index. Both the index and similarity uses to calculate recommendation. We have showed efficiency of proposed method from comparison experiments by four recommendation techniques.

Key words Collaborative Filtering, Reliability, Item Set

1. はじめに

1.1 研究背景と目的

近年、インターネットの普及に伴いウェブ上には大量の情報が存在している。しかし、大量の情報ゆえにユーザは自分の得たい情報を探すためには、ユーザが情報洪水の問題に対し解決策を講じなければならなくなってしまう。そこで、ユーザが大量の情報の中で得たい情報を効率よく得るための手段の一つとして、情報推薦システムが注目されている。情報推薦システムの

代表例として、Amazon.com の「おすすめ商品」のサービスがある。これはユーザの過去の購買履歴やアンケートなどの情報を用いて嗜好の類似した他のユーザの情報や利用傾向の似た他のアイテム（商品）の情報を用いて商品を推薦するサービスとされている [8]。このようなサービスは協調フィルタリング (Collaborative Filtering, CF) ^(注1) 技術によって機能している

(注1)：多くのユーザの嗜好情報を蓄積し、あるユーザと嗜好の類似した他のユーザの情報を用いて自動的に推薦する技術

とされ、機能性の拡張や、性能向上などさまざまなアプローチで研究が進められている [1]–[6].

協調フィルタリングではユーザ同士の類似度を同じアイテムにつけた評価の相関係数などの類似度によって表し、推薦度の計算に利用することが多い。そのため、協調フィルタリングはアイテムの内容がどのようなものに対してもユーザによる評価が与えられれば利用できるという特徴がある。逆にいえば、評価のない状況では推薦が不可能ということを意味し、Cold start 問題などとして知られる。

さらに、ユーザがそれまで利用したことのないカテゴリのアイテム集合について推薦を受けたい場合、ユーザ間類似度は評価済みのアイテムの情報を参照しているため、この類似度が推薦を受けたいアイテム集合にも適用できるとは限らない。したがって、類似度を用いた既存の協調フィルタリングによる推薦では、推薦精度の低下を招き、システムへの信頼性を低下させることにつながる問題が挙げられる。

そこで本稿では、先に述べたようなターゲットユーザの推薦対象アイテムカテゴリに対する嗜好が抽出困難な状況下で、推薦対象アイテム集合を追加入力とし、そのアイテム集合に対する信頼できるユーザを自動的に選択する手法を提案する。これにより、関連性のないアイテム集合の嗜好情報のみでなく、推薦対象アイテム集合内での評価の正当さ（客観性）が見込まれる、他のユーザの情報を元に推薦がなされる。

一方、単なる推薦精度の向上ゆえに生じる発見性や推薦された内容の多様性に欠ける問題等に対する研究 [7] も報告されている。本研究においては、観測された情報による推薦精度を求めるのではなく、信頼性の高い推薦を目指しており、単なる推薦精度の向上を目安としてきた協調フィルタリングに、同様に新たな価値を与える方式を提案する。

このような観測されていない情報への推薦の信頼性を見積もるためには、実観測データによる評価は困難である。そのため、提案方式の有効性を様々な条件下におけるシミュレーションを用いて評価し、既存の推薦手法との比較を交えて分析する。

本稿の構成は以下の通りである。まず、2 章で協調フィルタリングによる推薦のモデル化について述べる。次に 3 章では提案手法を示し、4 章で検証実験の方法を述べる。5 章で結果と考察を示し、6 章で全体の考察をし、7 章でまとめと今後の課題を述べる。

2. 協調フィルタリングによる推薦のモデル化

2.1 推薦のモデル化

一般に協調フィルタリングによる推薦とはユーザの利用履歴をもとにその利用傾向が似たユーザあるいはアイテムを発見し、それを推薦に利用するという手法を指す。本研究ではこれを次のようにモデル化する。

利用履歴：利用したアイテムへの評価値として $1/0$ の 2 値情報として表現される。推薦値の $1/0$ は、それぞれ利用「するはず」「しないはず」のような利用履歴の予測の意味となる。

一般に、全ユーザ-全アイテムの利用履歴が推薦に利用可能なわけではない。すなわち、未利用（未購入、未閲覧など）の

アイテムについては利用履歴が「ない」という状況であり、潜在的な（将来的な）利用履歴が、例えば、無限時間後に存在すると仮定しても、推薦自体にその情報を利用することはできない。そのため、ユーザ u のアイテム I_k の潜在的な利用履歴を $\text{val}(u, I_k)$ とする。また、観測利用履歴を $\text{obs}(u, I_k)$ とすると、

$$\text{val}(u, I_k) = \begin{cases} 0 \\ 1 \end{cases} \quad (1)$$

$$\text{obs}(u, I_k) = \begin{cases} 0 \\ 1 \\ * \end{cases} \quad (2)$$

であり、 $\text{obs}(u, I_k)$ の $*$ は未観測値である。

ユーザベース：利用履歴をもとにターゲットユーザに対して利用傾向の似たユーザを発見し、推薦に利用するモデルを指す。ターゲットユーザとユーザとの間の利用履歴がどの程度似ているかを判定する類似度関数が用いられる。

ユーザ集合 U ：カテゴリに関係なく存在する全ユーザの集合とする。

アイテム集合 I ： N を総アイテム数とすると、 I はシステム内に存在する全アイテム数となる。

$$I = \{I_0, I_1, \dots, I_{N-1}\} \quad (3)$$

評価値のあるユーザ U_t ：ユーザ集合の中でアイテム I_k に対する評価値のあるユーザのみの集合とする。

$$U_t = \{u | u \in U, \text{obs}(u, I_k) \neq *\} \quad (4)$$

高観測密度ユーザ集合 U_h ：アイテム集合 I において観測数の多いユーザのみによる集合とする。

ターゲットユーザ T ：推薦される対象のユーザ。

T による I_k の利用履歴 $t_k (= 0/1)$ ：ターゲットユーザ T がアイテム I_k に対し与えた評価値。

類似度関数 $\text{sim}(u_i, u_j)$ ： u_i, u_j はそれぞれユーザ。 u_i, u_j 間の利用履歴の類似度を計算する。 $0 \leq \text{sim}(u_i, u_j) \leq 1$ であり、値が大きいくほど似ているとする。

推薦度関数 $\text{rec}(u, I_k)$ ：ユーザ u のアイテム I_k への推薦度。推薦度関数は類似度関数に依存する。 $0 \leq \text{rec}(u, I_k) \leq 1$ で、値は利用履歴の予測値ともいえる。

このようにすると、 T に対する推薦度関数は一般に、

$$\text{rec}(T, I_k) = \frac{1}{\sum_{u \in U_t} \text{sim}(T, u)} \sum_{u \in U_t} \text{sim}(T, u) \text{val}(u, I_k) \quad (5)$$

類似度を重みとした加重平均としてと書ける。

2.2 評価のモデル化

推薦による結果と、正解として想定するターゲットユーザの潜在的な利用履歴に対するずれとして推薦方式は評価され、これは一般に誤差と呼ばれ、アイテム間での平均をとると誤差平均となり、それぞれ次のようになる。

誤差 $e(T, I_k)$ ： T に推薦されたアイテム I_k の推薦度の実際の

利用履歴との差.

$$e(T, I_k) = |t_k - \text{rec}(T, I_k)| \quad (6)$$

誤差平均 e_T : T への推薦度の誤差の平均.

$$e_T = \frac{1}{|I|} \sum_{I_k \in I} e(T, I_k) \quad (7)$$

3. 提案手法

既存のユーザベースの協調フィルタリングでは、類似度を用いて推薦度が計算される. 利用履歴が(例えば, ある一時点など)固定されているとき, 一般に類似度関数はユーザにのみ依存する. したがって, 式(5)より, 推薦度はターゲットユーザと推薦度の計算対象アイテムだけに依存する. すなわち, ターゲットユーザである利用者は, 計算対象アイテムの推薦度の計算には一切介入することはできない. これは, 協調フィルタリングの考え方が, 類似度関数によって推薦度の計算に必要な情報を自動的に取捨選択する, という思想に基づいているためであり, 利用者が受動的に「おすすめ商品」の情報提供を受けられるなどの大きな利便性をもたらしている.

3.1 協調フィルタリングの持つ問題

しかし, 利用者の立場で考えた場合, 推薦を受けたいアイテムが存在するような積極的に推薦を受けたいときには不満が残る. 人から推薦を受けようとするときのことを考えると, 単にこれまでの利用履歴(嗜好)が似通った人物から推薦を受ければ十分であるとは限らない場合がある. 例えば, 情報推薦に関する勉強をするために書籍の推薦を受けたいと思ったとき, 情報推薦分野の知識をほとんど持たない音楽の嗜好の似た仲間から推薦を受けようとは思わない. むしろ, 情報推薦分野の知識を十分持った人物からの推薦を得ようとするはずであり, その上で, 同じ音楽を好む要素が加われば, なお楽しく読める書籍を推薦してもらえるかもしれない, と推測する. これは, 推薦を受けようとする分野に精通した人は, その分野に対してより客観的な評価を行うことが出来る, という確信に基づく推測である. 裏を返せば, 推薦を受けようとする分野に詳しくない人の評価は信頼できない, という確信である. このように確信する理由は, 例えば, ある分野のアイテムをはじめて評価するときに, 未知の他のアイテムの評価まで勘案して評価値を付与することは不可能なことから明らかである. 一般に当該分野に対する評価を下した, すなわち知っているアイテムの数が増すほど, 全体を通じた評価が可能になると言え, 気分などに依存する評価のぶれも小さくなると考えられる. したがって, 推薦を受けたいときには, 当該分野に詳しい人の情報を重視するべきである. また, それによって推薦の信頼性も増すこととなる.

しかし, 既存の協調フィルタリングの枠組みが, このような状況に対応できないのは明らかである. 既存の協調フィルタリングの枠組みが, このような状況に対応できないのは明らかである. 結果的に推薦精度は低下し, 推薦システム自体への信頼性の低下にもつながる.

これは, 推薦対象アイテム(集合)が想定されるときに, それらに詳しい他ユーザからの推薦を受けたいというように定

式化され, これらの利用可能な追加情報を利用しない既存の枠組みでは対応できないことに相当する. なぜなら, 既存の協調フィルタリングにおける類似度は, 観測利用履歴に基づくものであり, 本来推薦に用いられるべき, 推薦対象アイテム集合における潜在利用履歴に基づく類似度を特に用いているわけではないためである. ここで, 後の議論のため, 前者の一般的な類似度を観測類似度, 後者の類似度を推薦類似度と定義しておく. この問題を解決するためには, 推薦対象アイテム(集合)に詳しいユーザを同定できればよい. 藤森らは[9], 様々な角度からの推薦を受けられる可視化インタフェースを備えたシステムという本研究とは異なる目的で, 利用者が推薦を受ける基となるユーザ集合を指定する推薦手法を提案している. しかし, 本研究の目的で同様の手法をとることは, 一般には他ユーザの利用履歴を直接知ることは難しく, また, そのような判別を利用者自身が行うのでは, 推薦方式として本末転倒である.

3.2 推薦対象アイテム集合を利用する提案

そこで, 利用可能なもう一方の追加情報である, 利用者の想定した推薦対象アイテム(集合)を利用する方式を提案する. 推薦対象アイテム集合は, 単なるキーワード検索などでおおざっぱに選択すれば良く, 利用者負担は小さい. また, 同種のよく似たアイテム間で, 「どれが結局おすすめなのか?」ということは重大な関心事であり, そのような利用場面は頻繁にあると考えられるため, この情報を利用する. 3.1 節で述べた推薦類似度は直接観測することはできないため, 代替情報として, 推薦対象アイテム集合における観測密度を用いることとする.

提案手法は既存の協調フィルタリングと比べて推薦対象アイテム集合の利用履歴の多いユーザの利用履歴を用いることにより, 推薦対象アイテム集合の推薦結果の信頼性を向上させることを目的とする. 提案手法は, 式(5)に観測類似度による重みづけによる推薦度関数を用いるのではなく, 推薦対象アイテム集合 I_s における観測密度を重みに反映させた式(8)として提案する. ただし, $\text{dense}(u, I_k)$ は観測密度を表し, 式(9)で定義される.

図1に提案手法と既存の協調フィルタリングを比較した図を示す. 図中の T をターゲットユーザ, 他のユーザをそれぞれ A , B とする. また, アイテム集合を A , B としここでは A が音楽 CD, B が参考書のアイテム集合とする. ターゲットユーザはアイテム集合 B の参考書については評価値がないため, 推薦対象はアイテム集合 B となる. 既存手法では, ターゲットユーザとの類似度から推薦が行われるため, ユーザ A , B の情報を用いる. しかし, ここでユーザ A はアイテム集合 B の評価値が少ないため, 参考書について詳しくないユーザであると考えられる. そのため, 推薦結果の信頼性も下がってしまう要因であると考えられる.

そこで提案手法では, アイテム集合内での評価値の多いユーザをそのカテゴリで詳しく信頼できるユーザと仮定し, 詳しいユーザのみを用いる協調フィルタリング手法となっている.

式(8)は I_s 中のアイテムをどの程度利用したか, という要素により重みを修正しており, 前述の I_s について詳しい人を選択する項として働くことが期待される.




図1 提案手法と既存手法の比較

$$\text{rec}_p(T, I_k, I_s) = \frac{\sum_{u \in U_t} \text{sim}(T, u) \text{dens}(u, I_s) \text{val}(u, I_k)}{\sum_{u \in U_t} \text{sim}(T, u) \text{dens}(u, I_s)} \quad (8)$$

$$\text{dens}(u, I_s) = \frac{|\{I_k | I_k \in I_s, \text{obs}(u, I_k) \neq *\}|}{|I_s|} \quad (9)$$

4. 検証実験

提案手法が、どのような利用履歴を持つユーザ集合によるときに有効であるかを検証する。

そこで、潜在的な利用履歴による利用者モデルを設けた上、ある時点での利用可能な利用履歴の量を表すパラメータとして、観測密度を用いる。すると、ユーザモデルは、潜在利用履歴と、観測密度のパラメータから構成され、どのようなユーザモデルに基づくユーザ集合がどの程度存在するとき（ユーザ集合モデル）、提案手法がどのように機能するか、が本実験による分析の目的となる。

4.1 実験モデル

本実験では、一人の T を想定し、他の多数のユーザ集合 (U) からの推薦度関数による推薦度を計算する。 T の潜在利用履歴に対する誤差 $e(T, I_k)$ が、ユーザ集合モデルによってどのような影響を受けるのかを、既存の推薦手法と提案手法とで比較する。本実験では説明の便宜上、総アイテム数を $2N$ として、

$$I = \{I_k | I_0, I_1, \dots, I_{N-1}, I_N, \dots, I_{2N-1}\} \quad (10)$$

I_0 から I_{N-1} までが T と U の共通の観測アイテムとし、 I_N から I_{2N-1} までは T は別に定める観測密度、 U ではユーザの想定モデルに基づいて観測されたとする。

T の潜在利用履歴は、一般には、 $(0, 1, 0, 1, 1, 0, \dots)$ のように一見無作為な $1/0$ の並びと考えられる。これは一般に、

$$(t_0, t_1, \dots, t_{N-1}, t_N, \dots, t_{2N-1}) \quad t_k = 0 \text{ または } 1 \quad (11)$$

と記述できる。しかし、手法の性能評価を誤差で行うことと、推薦度関数が利用履歴の $1/0$ に対して対称であることから、類似度関数も利用履歴の $1/0$ に対して対称であれば、一般性を失わずに、 $t_k = 0$ とできる。以下、これに沿って説明する。

4.2 ユーザ集合モデル

ユーザは、 T との観測類似度、推薦類似度、観測密度によ

てモデル化される。推薦類似度は、推薦対象アイテム集合 I_s の T とユーザとの潜在利用履歴による類似度である。観測密度 $\text{dens}(I_s)$ は、 I_s のうち利用履歴が実際に利用可能なアイテムの割合を示すことになる。

高精度な推薦のためには、本来は推薦類似度の高いユーザの情報を重視して推薦度を決定することが望まれる。しかし、推薦類似度は潜在的な利用履歴に基づくため観測することは不可能である。そこで、本研究では観測密度と推薦類似度との間に相関があるであろうということを仮定した方式として推薦方式を提案した。したがって、観測密度と推薦類似度が完全に一致している場合には、本提案方式が高い推薦精度を示すであろうことが予測される。実際の観測密度と推薦類似度は完全に一致することは考えられず、一定の相関関係が存在する程度と考えられる。

そこで本実験では、観測密度を主パラメータとして、高い順に $0.9, 0.7, 0.5, 0.3$ のユーザ集合を想定する。各ユーザ集合では、一定の推薦類似度との相関を意識して、この観測密度 d に対して、推薦類似度が $d \sim 1.0$ に一様分布するように定める。

ここで、観測密度の高い $0.9, 0.7$ を記号 d 、低い $0.5, 0.3$ を記号 s で表現し、それぞれの観測密度グループ内で、相対的に推薦類似度の高低を表現する記号として h, l を導入する。すると、例えば、記号 hd のユーザ集合は、観測密度 $d = 0.9$ で、推薦類似度は $0.9 \sim 1.0$ で一様分布するようなユーザ集合として定義される。記号 ls では、観測密度 $d = 0.3$ で、推薦類似度は $0.3 \sim 1.0$ で一様分布する。なお、具体的な一様分布のさせ方は、推薦類似度を 0.05 から 0.95 まで、 0.1 刻みの 10 階級に固定し、定義に含まれる階級に人数が均等となるよう割り当てた。

最後に、ここまでで得られた 4 つのユーザ集合それぞれについて、観測類似度が高い、記号 H と、低い L の 2 種類となるように推薦対象でないアイテム集合の評価値を組み合わせることで、都合 8 通りのユーザ集合を生成する。

検証実験では、これらのユーザ集合のシステム内における存在比率が異なる場合について各方式の推薦精度を比較することで、システム規模やシステムに登録 (参加) しているユーザの傾向が異なる場合において、各方式の性能評価を行う。

4.3 検証推薦手法

次の 4 つの推薦方式を比較した。

- (1) 協調フィルタリングによる推薦
- (2) 人気順による推薦
- (3) 高観測密度ユーザ集合のみによる人気順
- (4) 提案方式

表1に上記の推薦方式 (1), (2), (3), (4) と推薦度の計算において重視されるユーザ集合との対応表を示した。表中の $+$, $-$ は協調フィルタリングによる推薦において重視するユーザ集合を $+$ 、重視しないユーザ集合を $-$ として表記した。

4.3.1 類似度関数、推薦度関数

類似度関数には Jaccard 係数を用いた。

4.3.2 人気順による推薦

人気順による推薦度関数を $\text{ran}(T, I_k)$ とする。

表 1 各推薦に用いるユーザ集合のパラメータ対応表

類似度		観測	略号	(1)	(2)	(3)	(4)
観測	推薦	密度					
高 H	高 h	密 d	Hhd	+	○	○	+
高 H	低 l	密 d	Hld	+	○	○	+
高 H	高 h	疎 s	Hhs	+	○		-
高 H	低 l	疎 s	Hls	+	○		-
低 L	高 h	密 d	Lhd	-	○	○	-
低 L	低 l	密 d	Lld	-	○	○	-
低 L	高 h	疎 s	Lhs	-	○		-
低 L	低 l	疎 s	Lls	-	○		-

$$\text{ran}(T, I_k) = \frac{1}{|U_t|} \sum_{u \in U_t} \text{val}(u, I_k) \quad (12)$$

$$\text{ran}_d(T, I_k) = \frac{1}{|U_h|} \sum_{u \in U_h} \text{val}(u, I_k) \quad (13)$$

推薦方式 (1) は式 (5), 推薦方式 (2) は式 (12), 推薦方式 (3) は式 (13), 推薦方式 (4) は式 (8) をそれぞれ用いた.

5. 結果と考察

本章の図では, 縦軸が 0 に近いほど推薦精度が良い.

5.1 Lhd, Lld, Lhs, Lls の人数比の違い

一般に観測類似度が高いユーザより低いユーザのほうが多いと考えられる. そのため, まず Lhd, Lld, Lhs, Lls (低観測類似度ユーザ集合) の Hhd, Hld, Hhs, Hls (高観測類似度ユーザ集合) に対する人数比 (L/H Ratio) を変化させ, 各推薦に及ぼす影響の検証を行った. その他の各パラメータの値は以下に, 結果を図 2 に示す.

- T の観測密度: 0.5
- H : 0.8
- L : 0.2
- hd の観測密度: 0.9
- ld の観測密度: 0.7
- hs の観測密度: 0.5
- ls の観測密度: 0.3

図 2 より人数比が 50 を超える領域で Lhd, Lld, Lhs, Lls の人数比が誤差に及ぼす影響が小さくなっている. この結果より協調フィルタリングを用いた推薦は人気順による推薦よりもユーザ数が増え, システムの規模が大きくなっても良い精度で推薦できることがわかる.

5.2 推薦アイテム集合の観測密度の違い

次に, アイテム集合の観測密度が各推薦の精度にどれほど影響するのかを検証した. 5.1 節の結果を踏まえ, ユーザ集合の人数比は Hhd, Hld, Hhs, Hls (高観測類似度ユーザ集合) を各 100 人の計 400 人, Lhd, Lld, Lhs, Lls (低観測類似度ユーザ集合) を各 5000 人の計 20000 人とした. また変化させるパラメータは観測密度とし, Hhd, Hld, Lhd, Lld (高観測密度ユーザ集合) の観測密度を 0.5, Hhs, Hls, Lhs, Lls (低観測密度ユーザ集合) の観測密度を 0.1 とした. それ以外の各パラメータは 5.1 節と同様である. 結果を図 3 に示す.




図 2 Lhd, Lld, Lhs, Lls の人数比の違い

図 3 より観測密度と推薦精度は比例関係となっていることがわかる. 協調フィルタリングによる推薦では観測密度と精度は観測率の上昇とともに良くなっていくのに対し, 人気順による推薦では逆に精度が悪くなっていってしまう. この結果により, 観測数が多いユーザのアイテムの評価を協調フィルタリングで用いると精度が良くなることがわかる.




図 3 推薦アイテム集合の観測密度の違い

5.3 Hhd, Hld 以外の人数的違い

5.1 節で観測類似度が高いユーザより低いユーザの方が多い場合の検証を行ったが, また一方で一般的には観測密度が密なユーザよりも疎なユーザの方が多数であるとも考えられる. そこで, とともに少数派といえる Hd (Hhd, Hld) に対する他のユーザ集合の人数比 (多数ユーザ比: Majority User Ratio) を変化させた. Hhd, Hld を各 100 人の計 200 人とした. 他のパラメータは 5.2 節と同様である. 結果を図 4 に示す.

図 4 より Hhd, Hld 以外の人数的増加で, 既存の協調フィルタリングでは精度が悪くなっていく. そのため, 観測類似度のみを用いた既存の協調フィルタリングによる推薦では, ユーザ数が増えシステムの規模が大きくなるほど徐々に精度が悪くなっていくといえる. 提案方式は多数ユーザ比によらず, 安定した精度を保っている.

5.4 Hhs, Hls, Lhs, Lls の人数比の違い

類似度とは無関係に, 観測数が多いユーザは観測数が少ないユーザに対して少ないとされる. そこで最後に, このような状況下において, 提案手法の有用性を検証する. この状況は Long Tail 現象で説明されるような現実に近いモデルである. Hhd, Hld, Lhd, Lld (高観測密度ユーザ集合) に対して Hhs, Hls, Lhs, Lls (低観測密度ユーザ集合) の人数比を変化させ検証を




図4 Hhd, Hld 以外の人数比の違い

行った. Hhd, Hld, Lhd, Lld (高観測密度ユーザ集合) を各 100 人の計 400 人とした. 本研究における提案手法の有用性を検証するため, T の観測密度を 0.1 とした. 他のパラメータは 5.3 節と同様とした. 結果を図 5 に示す.

結果より, 観測類似度の高い Hhd, Hld, Hhs, Hls の中でも Hhs, Hls は推薦に悪い影響を及ぼしてしまうということがわかる. つまり T の評価が少ない推薦アイテム集合の観測数の少ないユーザは観測類似度が高い場合においても, 推薦の精度を下げてしまう. そのため, 既存の協調フィルタリングを用いた推薦よりも, 推薦アイテム集合の観測数の多いユーザによる協調フィルタリングを用いた提案手法の方が, 精度の高い推薦を行えることが確かめられた. この結果より, T が評価値の少ない推薦アイテム集合においても精度の高い推薦を実現するには, 既存の協調フィルタリングよりも提案手法の方が有効であるといえる.




図5 Hhs, Hls, Lhs, Lls の人数比の違い

6. 考 察

5.1 節では観測類似度における一般的なモデルを検証し, 5.2 節では観測密度が各推薦に及ぼす影響を検証した. また, 5.3 節で 5.1 節の状況をより一般化して検証を行い, 5.4 節で提案手法の有用性を検証した. それぞれ 5.1 節では協調フィルタリングの有用性, 5.2 節で観測数と推薦精度の関係, 5.3 節では協調フィルタリングの精度が悪化する状況, 5.4 節では現実に近い状況下における提案手法の有用性を示した.

5.4 節の結果を実際のサービスに置き換えて考えた場合, ターゲットユーザが新たに興味をもったアイテムカテゴリにおいて, 既存の協調フィルタリングでは過去の履歴による推薦がなされるために信頼性の低い情報が推薦されてしまう可能性が高い.

しかし, 提案手法を用いることにより, 興味を持ったアイテムカテゴリにおける評価値の多いユーザによる推薦のため信頼性の高い情報が推薦されることが可能となる. 同時に協調フィルタリングでの課題である, 意外性, 発見性という可能性も含んだ推薦ができると考えられる.

7. おわりに

本稿では, アイテム集合によって信頼できるユーザを選択した協調フィルタリング手法の提案を行った. ターゲットユーザのアイテムカテゴリ内で観測数が少ない状況下において, 既存の協調フィルタリングを用いた推薦, 人気順による推薦, 高観測密度ユーザ集合による人気順を用いた推薦, 提案手法である高観測密度ユーザ集合のみを用いた協調フィルタリングの 4 つの推薦方式を比較分析し推薦精度に及ぼす影響とその分析結果, ならびに提案手法の有効性を述べた.

提案方式では Jaccard 係数を評価式として用いた場合における協調フィルタリングの検証のみを行ったため, 今後は協調フィルタリングにおける代表的な評価式である Simpson 係数, cos 尺度などを用いた時の検証, 評価値を多値評価法にした場合についての検証を進めていく予定である.

謝 辞

本研究の一部は, 科学研究費補助金 基盤研究 (A)20240072, 基盤研究 (B)18360178 による. ここに記して謝意を表します.

文 献

- [1] 土方嘉徳, 神畠敏弘, 市川裕介, 河合由起子, 村上知子, 小野智弘, 本村陽一, 麻生英樹, 乾孝司, 奥村学, 金山博, “利用者の好みをとらえ活かす-嗜好抽出技術の最前線-, ” 情処学誌, vol.48, no.9, pp.955-1007, 2007.
- [2] 川前徳章, 山田武士, “ユーザの網羅性を反映したランキング手法の提案, ” 信学技報, vol.106, no.586(20070308), pp.81-86, 2007
- [3] 川前徳章, 鈴木英明, 水野修, “情報・知識共有を支援する協調フィルタリングに関する研究-協調フィルタリングの適用箇所拡大に向けた方法の提案-, ” 信学技報, vol.103, no.391(20031016), pp.37-42, 2003
- [4] 川前徳章, “ユーザの潜在嗜好モデルに基づいた協調フィルタリング手法-ユーザの評価からユーザの嗜好の抽出-, ” 信学技報, vol.103, no.104(20030526), pp.23-28, 2003
- [5] 井上光平, 浦浜喜一, “品目間相関に基づく協調フィルタリング, ” 信学技報, vol.101, no.432(20011109), pp.15-20, 2001
- [6] 岩田具治, 山田武士, 上田修功, “購買順序を効率的に用いた協調フィルタリング, ” 情処研報, vol.2007, no.128(20071220), pp.17-20, 2007
- [7] 清水拓也, 土方嘉徳, 西田省吾, “発見性を考慮した協調フィルタリングアルゴリズム, ” 信学論, vol.91, no.3(2008/3), pp.538-550, 2008
- [8] G. Linden, B. Smith, and J. York, “Amazon.com recommendations: Item-to-item collaborative filtering, ” IEEE Internet Comput., vol.4, no.1, 2003.
- [9] 藤森洋昌, 土方嘉徳, 西田正吾, “協調フィルタリングにおける近傍グループの可視化, ” 情処研報, vol.2004, no.45, pp.59-66, 2004.