

ユーザ投票と情報アイテム間類似度を併用した情報推薦システム - 擬似投票方式の提案と評価 -

宇田 隆幸^{†1} 藤井 敦^{†2} 石川 徹也^{†2}

情報推薦システムは、ユーザの嗜好に関する情報を用いて新規情報に対する嗜好を予測し、嗜好に合うアイテムを提示する。協調フィルタリングに基づくシステムは、アイテムの内容解析をせず、他のユーザからの評価（アイテム・ユーザ評価マトリクス）を用いて推薦アイテムを決定する。対象ユーザと嗜好が似たユーザが好むアイテムは優先され、嗜好が異なるユーザが好むアイテムの優先度は下がる。ユーザがアイテムを選ぶたびに嗜好情報が更新されるため、検索キーワードの入力が必要ない。しかし、評価値疎ら問題や再生起問題により、未評価の（推薦対象にならない）アイテムが多く存在する。本研究は、ユーザの評価とアイテム間の類似度を併用して、推薦対象アイテム数を増やす「擬似投票方式」を提案する。新聞記事を対象にした評価実験の結果、本方式によって、推薦精度を落とすことなく推薦対象アイテム数を増やすことができた。

A Recommender System Integrating User Votes and Item-based Similarity: Evaluation of a Pseudo-Voting Method

TAKAYUKI UDA,^{†1} ATSUSHI FUJII^{†2} and TETSUYA ISHIKAWA^{†2}

Recommender systems utilize user profiles to predict his/her preference for unseen information items, and present preferable items. The collaborative filtering (CF) method does not analyze the content of items, but utilizes user rating (an item-user matrix) to determine recommending items. CF-based systems (do not) favor items rated highly by the users whose preference is (not) similar to that of a target user. Users can update their profiles by selecting items and do not need to submit search keywords. However, due to the sparsity and recurring startup problems, many items are not rated and thus cannot be recommended to users. To resolve these problems, we propose "pseudo-voting method", which increases the number of rated items by integrating user rating and content-based item similarity. We show the effectiveness of our method by means of experiments.

1. はじめに

近年の WWW 利用形態を知る目的で、不慣れなユーザ層やモバイル環境での利用に焦点を合わせ「WWW の利用形態」と「求める機能」に関する調査を行った。この調査から「ユーザは有効な情報へ簡単な手段で辿り着きたい」との結果を得た。この背景として、ユーザの情報検索苦手意識が挙げられる。このことに対して、情報推薦システム^{12), 19)}は、キーワード入力が必要であり、欲しいアイテムを選ぶだけで推薦の正確性が向上するので、ユーザの苦手意識を克服できる効果が望める。研究において評価実験が行われているシ

ステム^{3), 5), 12), 15), 10)}や、Amazon.com^{6), 14)}などに代表される電子商取引サイトが中心であり、ユーザ向けの情報を対象としたシステムはまだない。また、WWW は世界中の情報が対象であり、ユーザの行動範囲に的を絞った情報、すなわち地域情報を対象とした情報推薦システムは、著者らが知る限りない。

先行研究^{5), 12)}では、情報推薦システムのアルゴリズムの一つである協調フィルタリング(CF)アルゴリズムが扱われてきた。CFは、推薦アイテムを決定するとき「アイテム・ユーザ評価マトリクス」を参照する。CFの問題点として、情報(アイテム)数およびユーザ数が大規模になるほど、評価値疎ら問題(Sparsity problem)および再生起問題(Recurring startup problem)が深刻になる。その結果、推薦対象アイテム

†1 図書館情報大学・情報メディア研究科
Graduate School of Information Media Studies, University of
Library and Information Science
(株式会社ネオジェイエスケー NEO JSK Corporation)

†2 筑波大学・図書館情報学系
Institute of Library and Information Science, University of
Tsukuba

受託事業につき報告書は未開示。
適切なキーワードの選択が難しい場合や、検索結果件数が多数に
及んだ場合、多くのユーザが苦痛を訴えている。

表1 情報推薦システム（広義）の分類

Table 1 Classification of existing recommender systems.

方式	利用する情報	概要	特徴
チェックボックス方式	ユーザが登録した嗜好情報	ユーザは推薦アイテムを受け取るために、自身の嗜好を前もって登録する。システムは登録された嗜好情報に基づいてアイテムを推薦する。	システムの構築は容易である反面、ユーザに意外性のあるアイテムが推薦される頻度は低い。
ルールベース方式	サイト運営者が登録した推薦ルール	サイトの管理者が、ユーザの評価したアイテム（例：閲覧や購入）と推薦したいアイテムとの対応ルールを作成する。システムは登録されたルールとユーザの評価したアイテムを照合することでアイテムを推薦する。	システムはサイト運営者の意志を反映することができる。ユーザ数やアイテム数が増加すると、ルール作成や保守が困難になる。
狭義の情報推薦方式	ユーザの行動履歴	システムはユーザの行動履歴から個々のユーザの嗜好を推測し、推薦アイテムを自動生成する ^{3), 7), 13), 10), 12)} 。	ユーザの行動履歴やアイテム数が増加すると、推薦アイテムを生成するためのオンライン計算コストが増大する。

表2 情報推薦システム（狭義）の分類

Table 2 Classification of recommender system methods.

方式	概要	特徴
内容ベース方式 ¹⁵⁾	ユーザの評価したアイテムや閲覧したアイテムが与えられると、それと類似する検索式を自動生成することにより推薦対象アイテムを探し出す。このため、検索ベースアルゴリズムとも呼ばれる。	評価履歴が少ない間は容易に検索式を生成できる反面、評価履歴数が増加すると検索式の生成が困難となる。他のユーザの意見を参考にしないので、意外性のある情報の推薦は難しい。ただし、意味的学習辞書を構築することで意外性のある情報を推薦するアルゴリズムも研究されている ¹³⁾ 。
協調フィルタリング方式 (CF方式)	推薦対象アイテムを提示するとき、嗜好が類似するまたは正反対である他のユーザによる評価履歴を参考にする。CFを分類すると、(a)相関係数法、(b)クラスタモデル、(a)(b)の組み合わせ型や(a)(b)の亜種 ^{2), 3), 10)} が存在する。	(a)(b)いずれの場合も、評価履歴の蓄積量が少ない間、ユーザによる評価履歴が疎らであるため、推薦可能なアイテムやユーザの網羅性に欠ける。または、推薦アイテムを提示できる場合でも、推薦予測の正確性は低い。
	(a)相関係数法 ^{12), 15)} N次元の「アイテム - ユーザ」評価マトリクスを用いてユーザ間の嗜好類似度に基づいて推薦対象アイテムを計算する。	計算量は、(a)に比べ(a)が優位である。 推薦予測の正確性は、(b)に比べ(a)が優位である ⁶⁾ 。
	(b)クラスタモデル ^{4), 16)} 類似するユーザを多数のセグメントに分類し、同じセグメントに属する他のユーザの意見を参考にして推薦アイテムを計算する。	(b)固有の問題として、ユーザの分類問題が研究されている。 (a)(b)いずれの場合も、オンラインでの計算量を減少させるため、可能な限りオフラインで事前計算を行っている。
ハイブリッド方式	内容ベース方式とCF方式の短所を補いつつ長所を生かす目的で、両方式を結合したタイプ ^{3), 10)} 。ユーザの評価履歴が少ない間は内容ベース方式を用いて推薦アイテムを提示し、評価履歴蓄積量が閾値を越えるとCF方式で推薦アイテムを提示する。	推薦対象ユーザや推薦対象アイテムの網羅性が高い。長所短所は、内容ベースフィルタ方式とCF方式のいずれもあわせ持つ。そのため、両方式の結合技法、すなわち最適な切替タイミング（閾値）は、ユーザやアイテム固有の特性によって変化するので、閾値調整問題がある。

や推薦対象ユーザの網羅性が低下する。

このような背景から、本研究ではCFのかかえる評価値疎ら問題と再生起問題を解消させるため、擬似投票方式を提案し、ユーザによるアイテムへの評価投票履歴と実際のアイテム（地域情報）を用いて評価実験を行う。

以下、2章で先行研究について説明し、3章で本研究の特長の1つである擬似投票アルゴリズムを提示し、4章で評価実験および考察を行う。

2. 先行研究

2.1 利用する情報による分類

情報推薦システムは、一般のユーザを対象とし、Webサイトで既に稼働していて、電子商取引では売上促進

に効果が出ている⁶⁾。推薦情報を生成するときの利用する情報に着目すると表1に分類できる¹⁸⁾。各方式は、単独で実装されることや、各々の長所を生かし短所を補う目的で複数の方式を組み合わせ実装されることがある。

表1の各方式を検討すると、狭義の情報推薦方式は、以下の点で他の方式より優れている。

- ・ マーケティング専門家によって手動で行われる準備作業が不要である（最小限度人的資源対応）
- ・ ユーザ数やアイテム数の増加に追従できる（拡張性）
- ・ 意外性のあるアイテムを推薦できる（有効情報推薦対応）

- ・ 推薦アイテムの予測計算を自動で行える（運用コストが低い）

以降は、狭義の情報推薦方式を情報推薦システムと同義で扱う。

2.2 アルゴリズムによる分類

情報推薦システムはフィルタリングアルゴリズムを利用する。推薦アイテムを提示するとき利用する情報に着目すると、フィルタリングアルゴリズムは表 2 のように分類できる。

表 2 の各方式を検討すると 相関係数法を用いた CF 方式は、以下の点で他の方式より優れている。

- ・ システム側の事由で(例. 計算量過多の防止) 予測精度を低下させない^{3), 8)} (ユーザ指向)
- ・ 意外性のあるアイテムを推薦できる (有効情報の推薦)
- ・ ユーザはマウスクリックするだけでよくキー入力が必要である (簡易操作性)

以下、相関係数法を用いた CF 方式 (CF アルゴリズム) について説明する。

2.3 CF アルゴリズム

CF 方式は、嗜好の類似するまたは嗜好が逆である他のユーザの評価投票値を参考にして推薦アイテムを予測計算するために「アイテム - ユーザ」評価マトリクスを持つ。CF アルゴリズムを図 1 に示す。図 1 において、 m はユーザ数、 n はシステムが蓄積しているアイテム数である。全ユーザを $U = \{u_1, u_2, \dots, u_m\}$ とし、全アイテムを $I = \{i_1, i_2, \dots, i_n\}$ とする。ユーザ u_j が評価投票したアイテム集合を I_{u_j} とする。ユーザ u_j の評価投票したアイテム k に対する評価投票値を $r_{j,k}$ とする。ユーザに対して推薦を行う場合、CF を行うとは、ユーザ $\{u_1, u_2, \dots, u_m\}$ のアイテム $\{i_1, i_2, \dots, i_n\}$ に対する評価 $r_{j,k}$ から、アイテム $i_j \notin I_{u_j}$ (ユーザ u_j が評価投票していないアイテム) の評価 $r_{j,k}$ の予測値 $P_{i,k}$ を算出することである。ただし、ユーザ u_j に対して推薦されるアイテムは予測値の中で嗜好度の高い上位 N アイテムとする。代表的な $P_{i,k}$ の算出法は、式 1 である。

$$P_{i,k} = r_i + \frac{\sum_m sim(u_i, u_m) \cdot (r_{m,k} - \bar{r}_m)}{\sum_m sim(u_i, u_m)} \quad (1)$$

ここで、 $P_{i,k}$ はユーザ u_i に対するアイテム k への嗜好度合い予測値、 r_i はユーザ u_i が行った全ての評価投票の平均投票値、 \bar{r}_m はアイテム k へ評価投票を行ったユーザ集合 $sim(u_i, u_m)$ はユーザ u_i とユーザ u_m の嗜好の類似度 (式 2)、 $r_{m,k}$ はユーザ u_m がアイテム k へ行った評価

評価投票値は、ユーザが閲覧したアイテムに対する嗜好度を数値化したものである。本研究では、嗜好度が高いアイテムに投票値 3、中程度のアイテムに 2、好まないアイテムに 1 を割り当てた。

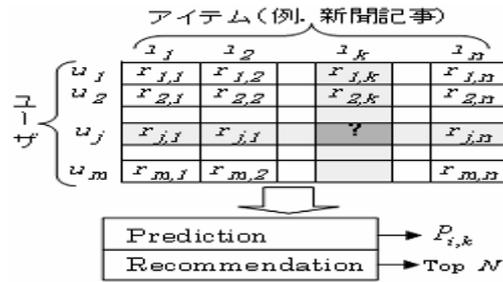


図 1 協調フィルタリングの概念図

Fig. 1 Overview of collaboration filtering.

投票値、 \bar{r}_m はユーザ u_m が行った全ての評価投票の平均投票値とする。

ユーザ間の類似度 $sim(u_i, u_m)$ は式 2 を用いる。

$$sim(u_i, u_m) = \frac{\sum_j (r_{i,j} - \bar{r}_i) \cdot (r_{m,j} - \bar{r}_m)}{\sqrt{\sum_j (r_{i,j} - \bar{r}_i)^2 \cdot (r_{m,j} - \bar{r}_m)^2}} \quad (2)$$

ここで、 j はユーザ u_i とユーザ u_m の双方が評価投票を行っているアイテム集合、 $r_{i,j}$ はユーザ u_i がアイテム j へ行った評価投票値、 $r_{m,j}$ はユーザ u_m がアイテム j へ行った評価投票値である。

2.4 CF アルゴリズムの問題点

CF アルゴリズムは、先行研究において表 3 に示す問題点が指摘されている。

評価値疎ら問題と再生起問題は、推薦アイテムの予測計算で使用する (式 1, 2) に現れる集合 (Σ_m や Σ_j) を狭める点で問題が指摘されている。これら問題の悪影響として、評価実験 (後述) で示した通り、推薦対象ユーザと推薦対象アイテムの網羅性が低下する。

3. 提案する手法

3.1 評価値疎ら問題と再生起問題の解消

問題点の項で前述した通り、評価値が疎らであると相関係数を用いて嗜好の類似度を計算することができないので、表 3 の問題点 1 が発生する。また、新規登録された直後のアイテムへは、どのユーザも評価投票を行っていないので、問題点 2 が発生する。本研究において当 2 つの問題点の解決方法を提案する。

(1) 評価値疎ら問題の解消法

評価値疎ら問題は、評価値が疎らであるため、ユーザ間の嗜好度の類似性 (相関計数) を計算できない。そこで、この問題を解決するために、ユーザが評価投票を行ったとき、システムは、投票されたアイテムと類似するアイテムを見つけだし、見つかったセル (図 3 SV-1) がユーザによって評価投票されていない場合、そのセルにユーザ投票値と同じ値を投票する。この処理を「擬似投票」と呼ぶことにする。換言する

表 3 協調フィルタリングの問題点

Table 3 Problems on collaboration filtering algorithm.

1. Sparsity Problem: 評価値疎ら問題 ^{10), 17)} 多くの情報領域において、アイテム数は利用頻度の高いユーザにおいても吸収でき得ないほど存在しており、全ての情報の評価を含む「アイテム - ユーザ」評価マトリクスは巨大になる反面、その評価値のセルはスパースになる。相対的に密集したフィルタリング領域でも、98~99%が抜け、CF 予測の基礎を形成するために必要となる十分な情報を見つけることが難しくなる。
2. Recurring Startup Problem: 再生起問題 ¹⁷⁾ 新聞記事のように毎日発行される新着アイテムは、評価の対象とならないアイテムが多出し「アイテム - ユーザ」評価マトリクスのアイテム列を占有する。このようなアイテムは、ユーザによるアイテムへの評価値を参考にできないので推薦対象アイテムからはずれる。
3. Cold Start / New User Problem: 評価値無し問題 ^{10), 17)} 評価値の存在しない間、そのアイテムに対する予測値は提供できない。特に初期の時点においては、予測の基礎となる評価値がわずかしかないので、しばしば不正確な予測がされることになる ¹⁾ 。長期間稼働中のシステムでさえ、新規ユーザに対しては予測値を提供することもできない。コールドスタート問題の極端なケースとして、CF システムが稼働した直後、全てのユーザは全てのアイテムに対してこの問題による悪影響を受ける。
4. Gray sheep Problem: 迷える子羊問題 ^{10), 11)} ユーザの嗜好が、他のユーザの嗜好傾向グループの境界領域に存在する場合、システムから推薦アイテムを受け取れないユーザが発生する。このようなユーザは、きわめてまれにしか予測アイテムを受理できない。
5. Scalability Problem: 拡張性問題 ^{2), 6)} 大規模な「アイテム - ユーザ」評価マトリクスの場合、メモリベース手法では、計算量過多が生じ計算できない。評価投票数の多いユーザの場合、類似する嗜好を持つ他のユーザを瞬時に探すことは困難である。

と、アイテムの内容に基づく類似性を利用した擬似投票は、欠損値補足である。

Sarwar らは、評価値疎ら問題を解消させるためにアイテムに基づく CF を提案している²⁾。この方式は、ユーザ投票値を利用してアイテム間の類似度を計算している。この結果を推薦アイテム予測計算に利用しているため、アイテムの内容の類似度は対象にしていない。この結果、意外性のあるアイテムは推薦されない。

擬似投票は、

「あるアイテムを嗜好するユーザは、内容的に類似する他のアイテムも同じように嗜好する」という仮説に基づいている。

擬似投票アルゴリズムを以下に示す。

```

擬似投票(UserId, ItemId_U, RealVoteVal) {
  For each(システムに蓄積されている全アイテム:ItemId_S) {
    If (類似判定(ItemId_U, ItemId_S, 類似閾値) == 類似
      && ユーザが過去に評価していない(ItemId_S) == YES) {
      擬似投票値記録(ItemId_S, RealVoteVal);
    }
  }
}

```

擬似投票の基礎をなすアイテム間の類似判定は、「アイテムの内容が類似しているか」に着目する必要があるため、アイテム内の語の出現頻度に基づいて⁹⁾、Dice 係数を利用してアイテム間の類似度を計算する(式 3)。

$$S_{i_1, i_2} = \frac{2 \sum_{t \in T_{i_1, i_2}} (f_{i_1, t} \cdot f_{i_2, t})}{f_{i_1}^2 + f_{i_2}^2} \quad (3)$$

ここで、 S_{i_1, i_2} はアイテム i_1 とアイテム i_2 間の類似度、 $t \in T_{i_1, i_2}$ はアイテム i_1 とアイテム i_2 の両方に含まれる索引語の集合、 f_{i_1} はアイテム i_1 に含まれる索引語の出現頻度、 f_{i_2} はアイテム i_2 に含まれる索引語の出現頻度、 $f_{i_1, t}$ はアイテム i_1 に含まれる索引語 t の出現頻度、 $f_{i_2, t}$ はアイテム i_2 に含まれる索引語 t の出現頻度である。

擬似投票では 2 つのアイテムの類似判断のために、類似度計算結果に基づく閾値を設定する必要がある。閾値を高く設定すると「アイテム - ユーザ」評価マトリクスのスパース性は解消される反面、擬似投票ノイズが増加し、かつ、推薦アイテム計算処理量が激増する関係がある。

本研究において、閾値は、以下のいずれの条件も満たす場合に類似すると仮定した。

- 条件 1 あるアイテムと他のアイテムによるアイテムペア集合の上位 25% を対象
- 条件 2 アイテムペア内で 1 つ以上の同じ語が出現すること

上記の類似条件が満たされる場合、ユーザによる現実の投票 1 回につき自動投票が行われ、複数アイテムに対して自動投票されることもある。ただし、擬似投票を行うことにより、推薦アイテム予測計算時にノイズが発生する。このノイズ除去を行う機構として、推薦アイテムの計算処理後、上位 N アイテムを推薦するためにアイテムを並べ替える。並べ替え処理では、擬似

アイテムに基づく CF とは、図 1 のマトリクスにおいて、列方向に着目した投票値の相関からアイテム間の類似度を計算し、推薦アイテムを提示する手法である。これに対して、行方向すなわちユーザ間の投票値の相関に着目する方式をユーザに基づく CF と言う。一般に、評価値が疎らである場合、推薦対象アイテムの網羅性は、アイテムに基づく CF の方が優位である。索引語は、[名詞]、[名詞 - 接尾]が連続する場合、名詞を結合する処理を行うことで特徴語に近づくような配慮を施した。

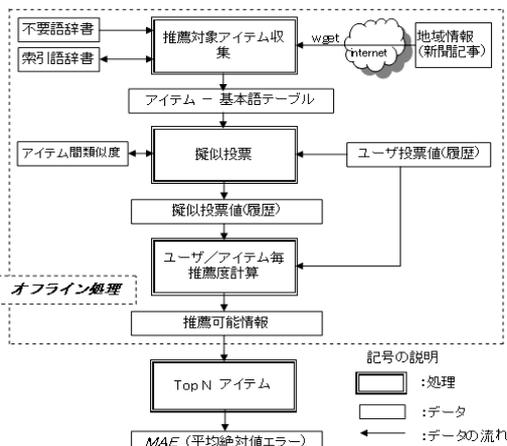


Fig 2 System overview.

投票履歴も併用参照して推薦されたアイテムの優先度を下げた。

(2) 再生起問題の解消法

CF は、アイテムを推薦するとき、嗜好の類似する他のユーザの意見（アイテムへの投票値）を参考にするので、新しいアイテムなど、評価値の与えられていないアイテムへの推薦はされない。しかし、本研究システムでは、擬似投票を行うことによって、新聞記事のように日々生成される新しいアイテムに対しても擬似投票が行われるので、再生起問題も解消している。

3.2 拡張性の確保

CF では、推薦アイテムの予測計算時に完全な「アイテム - ユーザ」評価マトリクスを使用する。そのため、その計算量は $O(User_{max} \times Item_{max})$ の空間サイズに比例して増大する。しかし実際は、評価マトリクスは非常にスパースであるため $O(User_{max} + Item_{max})$ に近似する。ところが、擬似投票を行うため、本研究における空間サイズは、 $O(User_{max} \times Item_{max})$ に近づく。そこで、ユーザ u_i に対するアイテム k への嗜好度合い予測値 P_{ik} の計算と、上位 N アイテムの選択処理を分離することにした。具体的には前者をオフラインで実行し、後者をオンラインで実行する。この結果、特に計算処理量過多の前者をオンライン計算（メモリベース計算）から切り離せるので、応答速度の高速化とスケーラビリティを確保できる方式になっている。

3.3 実装

提案方式における推薦アイテム予測計算の正確性を実証するためにシステムを構築した。処理手順は図 2 に示す通りである。図 2 の擬似投票処理を実施すると、図 3 に示すように「アイテム - ユーザ」評価マトリクスのスパース性がある程度解消される。図 2 のユーザ

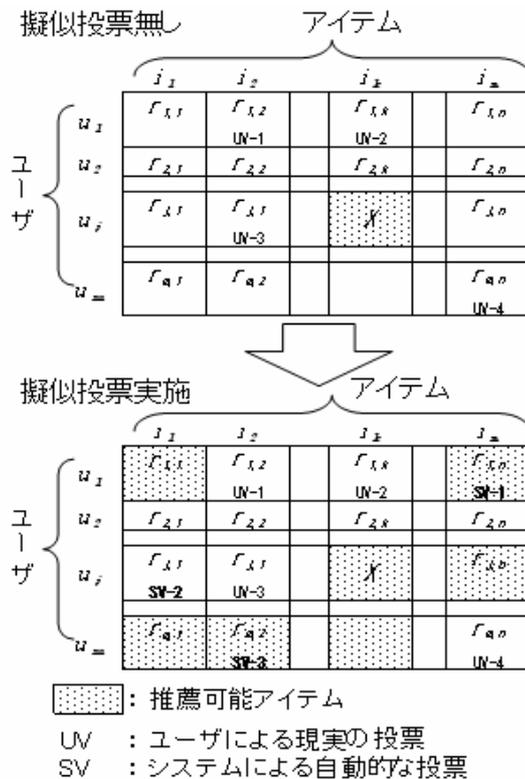


Fig 3 Effectiveness of pseudo voting method.

ノアイテム毎の推薦度合い計算処理は、式 1 で示したアルゴリズムを用いて計算する。計算量を減少させる目的で、アイテム数に着目した次元減少を行っている。具体的には、推薦対象ユーザの居住地に基づいて、日刊新聞のエリア版に特定地域の記事が掲載されると同様、居住地外のアイテムは推薦しない。そして、あるユーザに対して上位 N アイテムを選択する処理のみがオンラインで動作する。本研究では、上位 N を 100 アイテムに設定した。

4. 評価実験

4.1 研究データ（評価実験の準備）

(1) アイテムの標本

評価実験用データは、図 4 で示すサイトに蓄積さ

サンケイリビング新聞社が提供している地域情報サイト「えるこみ」。同サイトでは、女性のために生活情報が提供されている。評価実験で使用したアイテムの種類は、イベント・教養&カルチャー・生涯学習・グルメなどの地域情報である。地域新聞紙と同様に、それぞれのアイテムはそのアイテムの発生地と広域性に依りて、1つ以上の地域に配信されている。同サイトにおけるアイテムの配信地域は、首都圏エリアが 18 地区、大阪神戸エリアが 13 地区、国内のその他地域を 42 地区にそれぞれセグメント化されている。 <http://www.lcomi.ne.jp/>

表 4. 実験結果
Table 4 Experimental results.

期間 ID	観察期間	投票件数			スパース性			MAE		
		ユーザ	擬似	増加率	ユーザ投票	擬似投票	解消率	ユーザ投票	擬似投票	差分
1	～ 1 週間	91	7,327	8,051	99.9506%	96.3756%	3.5750	35.6	38.0	-2.4
2	～ 2 週間	160	13,733	8,583	99.9499%	96.0661%	3.8838	28.7	32.5	-3.8
4	～ 4 週間	351	54,796	15,611	99.9479%	92.4985%	7.4493	22.6	26.3	-3.7
8	～ 8 週間	654	55,084	8,423	99.9487%	96.1186%	3.8300	21.1	24.7	-4.6
12	～12 週間	941	992,415	105,464	99.9486%	50.5866%	49.3619	18.2	23.4	-5.2

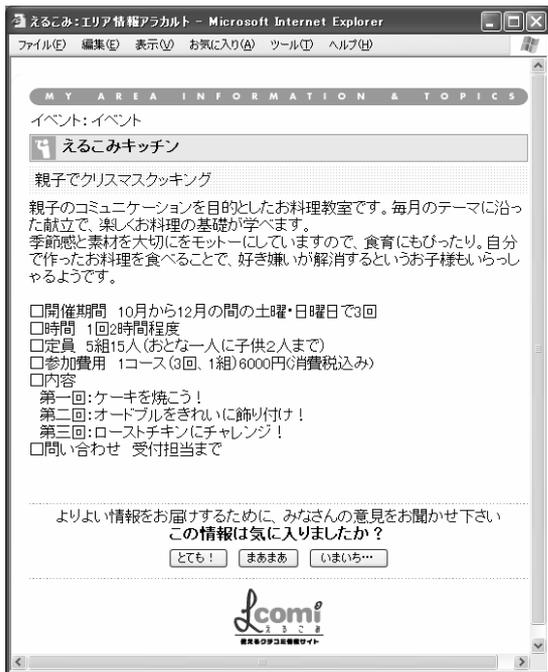


図 4. アイテムページの例
Fig 4 Example item page.

れているアイテムのうち、2002 年 10 月 27 日～2003 年 2 月 15 日（12 週間）の間 1 回以上表示されたアイテムを対象として、その内 6 % を標本化した。上記期間中、各アイテムは、1 つ以上の地域に配信されていて、各ユーザに閲覧される可能性がある。アイテムの標本数は、2,424 である。

(2) ユーザ評価投票履歴の標本

研究用ユーザ評価投票履歴データは、図 4 で示すページで、ユーザによって直接評価投票された履歴のうち、2002 年 10 月 27 日～2003 年 2 月 15 日（12 週間）に評価投票のあった 17,869 である。その後、アイテムの標本化に伴い、評価実験対象外となったアイテムへの投票も除外したので、アイテム標本に存在するアイテムに対するユーザ評価投票履歴数は 1,344 件である。

なお、評価実験に先立ち、ユーザ評価投票の正規化を行っている。正規化方法は「同一ユーザによる同一

表 5. アイテム集合要素数と投票者ペア数
Table 5 Numbers of item sets and user pairs.

期間 ID	アイテム集合の要素数	投票者ペア数	
		ユーザ投票のみ	擬似投票含む
1	1	75	24
1	2	3	42
1	3～10	0	524
1	11～100	0	2,052
1	101 以上	0	200
1	合計	78	2,842
2	1	313	7
2	2	4	16
2	3～10	0	193
2	11～100	0	1,330
2	101 以上	0	224
2	合計	317	1,770
期間 ID 4, 8 の記述は省略。			
1 2	1	7,984	1,357
1 2	2	77	2,250
1 2	3～10	4	29,518
1 2	11～100	0	215,273
1 2	101 以上	0	34,841
1 2	合計	8,065	283,239

アイテムへの評価投票」は、第一印象を重視して、初回の評価投票値を履歴として残し、他の評価投票値は除いた。正規化後のユーザ評価投票履歴数は、1,275 である（以降、ユーザ評価投票履歴の標本数と呼ぶ）。なお、標本化前の投票者ユニーク数は 1,001 人で、ユーザ評価投票履歴標本における投票者の異なり数は 756 人である。

(3) 実験データ観察期間

ユーザ評価投票履歴の標本数は、時間経過と共に増加する。標本数が増加すると、嗜好度の相関係数が計算可能になるユーザペア数が増加する。また、ユーザペア内でどちらも評価している平均アイテム数も増加する。同時に、情報推薦システムで利用されている性能評価指標の MAE 値も変化する。そこで、MAE と「アイテム - ユーザ」評価マトリクスのスパース率の変化を観察するために、観察期間を分割した（表 4）。擬似投票によって「アイテム - ユーザ」評価マトリク

MAE (Mean Absolute Error) : ユーザによる評価投票値と予測値間の平均絶対値エラー。これは、統計的精度測定基準 (Statistical accuracy metrics) の一種で、テストデータセットにおける数値的推薦スコアと、「アイテム - ユーザ」評価マトリクスにおける実際のユーザ評価値とを比較することによってシステムの正確さを評価する。

スの欠損値が設定され、その結果、表 4 の「スパース性」欄から、同マトリクスのスパース性が解消されていることが確認できる。同列の「ユーザ投票」および「擬似投票」欄は、「アイテム - ユーザ」評価マトリクスのセルに投票値が設定されていない割合を示している。

4.2 実験結果

(1) 問題点の解消度合い

擬似投票の効果を示すため、ユーザによる現実の投票数と擬似投票数との比較を表 4 の「スパース性」欄に示した。同欄の「解消率」は、「擬似投票」から「ユーザ投票」を減じた値を示しており、この値が擬似投票処理による効果である。

ところで、式 2 の j は、ユーザ u_i とユーザ u_m の双方が評価投票を行っているアイテム集合を指す。このアイテム集合数（ユーザペア数）が増加するほど、推薦可能なユーザ数が増加する。また、このアイテム集合の平均要素数が増加すると、ユーザ間の嗜好の類似度計算結果において、その正確性が向上する。式 2 の j の集合要素数が擬似投票によって増加したことは、表 5 に示した。

(2) 推薦予測精度

表 4 の「MAE」欄に、ユーザによる評価投票値のみの場合と、擬似投票も行った場合との（MAE）比較を示した。表 4 の「MAE」欄から、システムによる擬似投票処理を行っても、情報推薦システムの最終評価、すなわち推薦アイテムの予測の正確性は、大きく低下しないことを確認した。MAE は式 4 にて算出した。

$$MAE = \frac{\sum_{i=1}^N |rating_i - prediction_i|}{N} \quad (4)$$

式 4 では、 $rating$ がユーザによる評価値を示し、 $prediction$ がシステムによる推薦スコアを示し、 N が $rating$ と $prediction$ のペア数を指す。

(3) 考察

表 4 の「投票件数 - 増加率」欄に示した通り、システムによる擬似投票処理によって、その処理を行わない場合と比較して、8K ~ 105K % のアイテムに対して評価値を与えることができた。この結果、表 5 に示した通り、ユーザペアに対する嗜好の類似度を計算するとき、擬似投票処理によって共通するアイテムへの評価投票数が増加することを確認できた。この結果、嗜好の類似度を計算可能となるユーザ数が増加し、推薦可

能なユーザの網羅性と推薦可能なアイテムの網羅性が高まった。

また、擬似投票処理を実行することで「アイテム - ユーザ」評価マトリクスのスパース性は、3.58 ~ 49.36% の範囲で解消することが確認できた。この解消率のばらつきは、システム稼働期間の長短と、長文のアイテムが出現することにより類似と判断されるアイテム数が増加したためである。稼働期間によっては解消率に若干のゆれを伴う。その原因は、(1)新規蓄積アイテム数と新規ユーザ数の増加率、(2) 新規蓄積アイテムに含まれる特徴語の分布に左右される。しかし、稼働期間が長期に及ぶほど、解消率が向上する傾向が示されることを確認できた。

一方、システムによる擬似投票処理を実施した場合でも、表 4 に示した通り、情報推薦システムの性能評価指標として広く用いられている MAE の劣化は微小であることを確認できた。これは、擬似投票を実施することによって得られる効果（評価値疎ら問題と再生起問題の解消）と失う効果と比較した場合、得られる効果が大きいことを示している。

5. 結論

「あるアイテムを嗜好するユーザは、内容的に類似する他のアイテムも同じように嗜好する」という仮説の妥当性が、評価実験により証明された。この仮説成立を前提条件とした「システムによる擬似投票アルゴリズム」は、CF における推薦可能アイテムと推薦可能ユーザの両方に対して、予測の網羅性を高めることができた。そして、同アルゴリズムを搭載することで表面化する大規模化の困難性に関しても、大部分の処理をオフラインで処理できるので、Web ページ閲覧時の応答速度において問題は発生しない。

今後は、性能評価値（MAE）をさらに向上させるために、以下の点の研究を行い、現実社会のユーザに対して、より質の高いアイテムを短時間で推薦できるシステムを構築する。

- ユーザペアの嗜好度合い類似計算の精度向上を目指し、アイテム評価投票値以外の説明変数の探究
- MAE を低下させる悪影響因子を発見し、推薦アイテムの予測計算時に悪影響因子に関連する説明変数の重みを減少させるアルゴリズムの探究
- 擬似投票の正確性向上を目指し、アイテム間の類似度計算方式の探究

予測(prediction)は、上位 100 アイテムを対象にしている。

表 4 で MAE は最大 5.2%劣化している。これは、100 個のアイテムを推薦した場合、擬似投票によって平均 5.2 個の嗜好に合わないアイテムの推薦が増加することを意味する。

謝辞 評価実験用データを貸与していただきました
サンケイリビング新聞社の皆様に感謝します。

参 考 文 献

- 1) Anuja Gokhale and Mark Claypool: Thresholds for More Accurate Collaborative Filtering: *In Proc. of the IASTED International Conference on Artificial Intelligence and Soft Computing*, Honolulu, Hawaii, USA, August9-12(1999).
- 2) Badrul Sarwar, George Karypis, Joseph Konstan, and John Riedl : Item-Based Collaborative Filtering Recommendation Algorithms: *In Proc. the 10th International World Wide Web Conference (WWW10), Hong Kong*, pp.285-295, May 1-5(2001).
- 3) Balabanovic, Marko., Shoham, Yoav. : Fab: Content-Based, Collaborative Recommendation. *In ACM*. Vol.40, No.3 pp.66-72 (1997).
- 4) Basu, C., Hirsh, H., and Cohen, W : Recommendation as Classification: Using Social and Content-based Information in Recommendation: *in Proc. Recommender System Workshop1998*, pp.11-15(1998).
- 5) Goldberg, David., Nichols, David., Oki, Brian M., and Terry, Douglas. : Using Collaborative Filtering to Weave an Information Tapestry. *In ACM*. Vol.35, No.12(1992).
- 6) Greg Linden, Brent Smith, and Jeremy York: Amazon.com Recommendations: Item-to-Item Collaborative Filtering: *in Proc. of February 2003 issue of IEEE Internet Computing*(2003). <http://dsonline.computer.org/0301/d/w1lind.htm>
- 7) Hirooka, Y., Terano, T. and Otsuka, Y. : Extending Content-Based Recommendation by Order-Matching and Cross-Matching Methods: *In Bauknecht, K. et al. eds.: Electronic Commerce and Web Technologies - 1st Int. Conf. EC-Web 2000*, Springer Verlag, LNCS 1875, pp.177-190, (2000).
- 8) John S. Breese, David Heckerman and Carl Kadie : Empirical Analysis of Predictive Algorithms for Collaborative Filtering: *In Proc. of the 14th Conference on Uncertainty in Artificial Intelligence, Madison, WI*, pp.43-52, July 1998. Morgan Kaufmann Publisher(1998).
- 9) Justin Zobel and Alistair Moffat: Exploring the Similarity Space: *In the ACM SIGIR FORUM*, vol.32 no.1, Spring(1998).
- 10) Mark Claypool, Anuja Gokhale, Tim Miranda, Pavel Murnikov, Dmitry Netes and Matthew Sartin : Combining Content-Based and Collaborative Filters in an Online Newspaper: *in Proc. Recommender Systems Workshop at ACM SIGIR*(1999).
- 11) Paolo Viappiani, Pearl Pu and Boi Faltings : Acquiring User Preferences for Personal Agents: *In Proc. of AAAI Fall Symposium 2002, North Falmouth, MA*, (2002). <http://hci.epfl.ch/website/publication-doc/a3iSymposium.pdf>
- 12) Paul, R. , Neophytos I. , Mitesh S. , Peter B. and J. Riedel. :GroupLens: an open architecture for collaborative filtering of netnews, *Proc. of the CSCW 1994, New York*, pp.175-186, ACM (1994).
- 13) Polcicova, G., Navrat, P.: Semantic Similarity in Content-based Filtering : *In Advances in Databases and Information Systems, 6th East European Conference, ADBIS 2002, Bratislava, Slovakia, September 8-11, 2002, Proceedings. Lecture Notes in Computer Science 2435 Springer 2002*, ISBN 3-540-44138-7, pp.80-85(2002).
- 14) Schafer, J.B., Konstan, J.A. and Reidl, J. : E-Commerce Recommendation Applications : *in Proc. Data Mining and Knowledge Discovery, Kluwer Academic Publishers*, pp.115-153(2001).
- 15) Shardanand, U. and Pattie Maes : Social Information Filtering: Algorithm for Automating "Word of Mouth". *In CHI '95 Conference Proceedings*, pp.210-217(1995).
- 16) Ungar, L. H., and Foster, D. P. : Clustering Methods for Collaborative Filtering: *In Workshop on Recommender Systems at the 15th National Conference on Artificial Intelligence 1998*(1998).
- 17) Wee Sun Lee : Collaborative learning for recommender systems: *In Proc. 18th International Conf. on Machine Learning*, pp.314-321. Morgan Kaufmann, San Francisco, CA, (2001).
- 18) 寺野隆雄, "情報推薦システム,"eビジネスの理論と応用, 北村泰彦, 山田誠二(編), 第3章, 東京電機大学出版局, 東京, (2003).
- 19) 山西健司: Web マイニングと情報論的学習理論, 電子情報通信学会 情報論的学習理論 時限研究専門委員会 第5回情報論的学習理論ワークショップ 招待講演, Information-Based Induction Science: ISBS2002, (2002). <http://www.ieice.org/~ibis-tg/>