

ユーザ間・アイテム間協調フィルタリングの適応的な融合手法

— MovieLens での格付けデータに基づく検証 —

山下 晃弘^{†, ††} 川村 秀憲[†] 鈴木 恵二[†] 大内 東[†]

[†] 北海道大学大学院情報科学研究科

^{††} 日本学術振興会

あらまし 推薦システムとは、個人の興味や嗜好に適応して積極的にアイテムを提示するシステムであり、既にショッピングサイトなどで実用化されている。また、協調フィルタリング (CF) は、ユーザの商品に対する格付けを利用して、既に得た格付けからまだ入力されていない格付けの推定値を計算して推薦アイテムを決定する推薦アルゴリズムである。CF にはユーザ間 CF とアイテム間 CF が存在し、近年その両者で得た推定値を加重平均によって融合し、推薦精度を向上する新たな手法が提案されている。その際、従来手法では融合時の重みは経験則による定数として設定していたが、実際には最適な重みは状況の変化や格付けの数によって動的に変わるはずである。そこで本研究では、既に収集した格付けに基づき、その格付けを用いて逐次適応的に重みを計算して融合する手法を提案する。また提案手法を Movie Lens での実データに適用して検証実験を行いその有効性について検討を行った。

キーワード 推薦システム, ユーザ間協調フィルタリング, アイテム間協調フィルタリング,

Adaptive Fusion of User-based and Item-based Collaborative Filtering

— Empirical Analysis Using MovieLens Dataset —

Akihiro YAMASHITA^{†, ††}, Hidenori KAWAMURA[†], Keiji SUZUKI[†], and Azuma OHUCHI[†]

[†] Graduate School of Information Science and Technology, Hokkaido University

^{††} Japan Society for the Promotion of Science

Abstract In many E-commerce sites, recommender systems, which provide personalized recommendation from among a large number of items, are recently introduced. Collaborative filtering (CF) is one of the most successful algorithms which provide recommendations using ratings of items by the users. There are two approaches such as user-based CF and item-based CF. Additionally an algorithm which improves recommendation accuracy by unifying both of user-based CF and item-based CF was proposed. In the algorithm, a weight for unifying is a constant which obtained empirically. However, because the optimal weight for unifying is actually different by the situation, the algorithm should estimate an appropriate weight dynamically, and use it. In this research, we propose an approach for estimation of the appropriate weight based on collected ratings. Moreover, we discussed the effectiveness by using Movie Lens data.

Key words Recommender Systems, User-based Collaborative Filtering, Item-based Collaborative Filtering

1. はじめに

情報技術の発達に伴い、Web 上には膨大な情報が蓄積され、必要な情報を素早く的確に収集することが困難になりつつある。推薦システムは、多数のアイテム (書籍, 映画, ニュース等) の中から、ユーザの興味や嗜好に合ったアイテムを推定し、積極的に提示するシステムである [1]。既に、Amazon.com^(注1)

や、Ebay^(注2) など、数多くのサイトで導入されている [2]。

推薦アルゴリズムは、アイテム自身の特徴や性質を利用する「内容に基づくフィルタリング」と、ユーザによる「格付け」のみを基準に推薦アイテムを決定する「協調フィルタリング (Collaborative Filtering 本稿では CF と記す)」に大別される。

(注1) : <http://www.amazon.com/>

(注2) : <http://www.half.ebay.com/>

格付けとは、ユーザのアイテムに対する評価であり、好き嫌いといった2段階評価や、星による5段階評価が一般的に用いられる。つまり、CFは、ユーザ-アイテムで表現される「格付け行列」を構築し、既に得た格付けからまだ得ていない格付けを推定し、推定値が高いアイテムを推薦する手法である。内容に基づくフィルタリングとは異なり、CFはアイテム自身の特徴や性質を把握する必要がないため、比較的低いコストで多様なコンテンツに応用できる利点がある。

CFに基づくアルゴリズムは複数提案されているが、中でも一般的に用いられるのが、ユーザ間の類似性を基に格付けの推定を行う「ユーザ間CF」とアイテム間の類似性を基に格付けの推定を行う「アイテム間CF」である。どちらのアルゴリズムも、既に入力された格付けの類似性を利用するため、より多くの格付けを与えることで精度の高い推薦が可能である。しかし、システム運用初期など格付けが十分に得られていない状況では、格付けの推定値が計算できず、精度の高い推薦ができない問題(cold-start problem)が指摘されている[3]。

そこで近年、ユーザ間CF・アイテム間CFの両手法を融合することで、格付けの推定値をより高い精度で計算する新たな手法が提案されている[4]。この方法は、各々のアルゴリズムで独立に計算した格付けの推定値を、予め定めた割合 λ で足し合わせることで推定精度を高めるものである。

ここで、割合 λ の決定方法が問題となる。従来手法では、あるシステムで得られた格付けをサンプルデータとして最適な割合を計算し、固定値として用いている。しかし、一般的に、CFに基づく推薦の精度は、全体の格付け数の他、ユーザ毎の格付け頻度や、好みのばらつき具合などの環境に依存する。そのため、ユーザ間CFとアイテム間CFを融合する最適な割合は、推薦システムを適用する環境によって異なる。予め推薦システムを適用する環境を推定し、融合する最適な割合を計算することは現実的には困難であり、また融合する割合を固定してしまうと、状況が変化した場合に対応できない。

そこで本研究では、運用によって既に得られた格付けのみを用いて、その時点での適切な融合の割合を逐次計算し、ユーザ間CFとアイテム間CFをより適応的に融合する手法を提案する。

2. ユーザ間・アイテム間CFとその融合

2.1 ユーザ間CF

協調フィルタリング[5]は、1992年にその基本概念が初めて示されて以降、k-nearest neighbor法を初めて導入したGroupLensプロジェクト[6]など、多くの改良、分析、評価がなされてきた[7][8][9]。本節では、CFの中でも基本的なアルゴリズムの一つである、ユーザ間CFについて説明する。

本稿では、ユーザを $u \in U$ 、アイテムを $i \in I$ と記述し、ユーザ u のアイテム i に対する格付けを $r_{u,i}$ と記述する。被推薦者 a のアイテム b に対する格付け $r_{a,b}$ を推定するとき、ユーザ間CFでは、まず被推薦者 a と嗜好が類似しているユーザ(neighbors)を求める。本稿では、ユーザ a のneighborsを $S_a = \{s_{a,1}, \dots, s_{a,N_a}\}$ と記す。次に、 $u \in S_a$ の過去の格付け

に基づき、アイテム b の格付けの推定値を計算し、ユーザ a がまだ格付けしていない全てのアイテムの中で最も推定値が高いアイテムを推薦する(図1)。

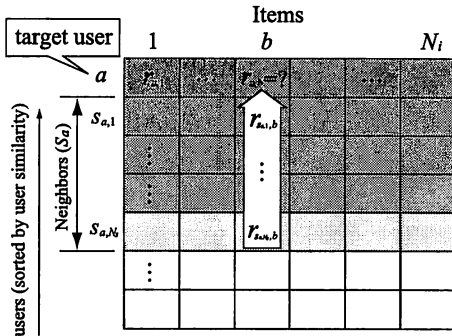


図1 ユーザ間CFに基づく格付けの推定

まず、neighborsの求め方について述べる。 S_a は、被推薦者 a と、その他のユーザ間の「類似度(similarity)」を用いて決定する。類似度の計算手法としては、ピアソン相関係数[6]や、コサイン距離[11]を用いる場合が多いが、本稿では一般的に精度の良いピアソン相関係数を採用する[11]。被推薦者 a と、ユーザ u 間のピアソン相関係数に基づく類似度を本稿では $sim_u(a, u)$ と記し、式(1)で計算される。

$$sim_u(a, u) = \frac{\sum_{i \in I_a \cap I_u} (r_{a,i} - \bar{r}_a)(r_{u,i} - \bar{r}_u)}{\sqrt{\sum_{i \in I_a \cap I_u} (r_{a,i} - \bar{r}_a)^2} \sqrt{\sum_{i \in I_a \cap I_u} (r_{u,i} - \bar{r}_u)^2}}, \quad (1)$$

ただし、 I_a 、 I_u はそれぞれユーザ a 、 u が格付けしたアイテム集合、 \bar{r}_u はユーザ u の格付けの平均値を表す。

neighborsの選択については、類似度の高い k 人のユーザを選択するk-Nearest neighbor法や、予め閾値を設定し、閾値以上の類似度をもつユーザを選択する方法が提案されている[10][12]。本研究では、 $sim_u(a, u) \geq 0.5$ かつ、類似度が高い上位40人を S_a とした。

次に格付けの推定方法について述べる。被推薦者 a のアイテム b に対するユーザ間CFに基づく格付けの推定値 $\hat{r}_{a,b}$ は、式(2)で計算する。

$$\hat{r}_{a,b} = f_u(a, b) = \bar{r}_a + \frac{\sum_{u \in U_b \cap S_a} sim_u(a, u)(r_{u,b} - \bar{r}_u)}{\sum_{u \in U_b \cap S_a} |sim_u(a, u)|}, \quad (2)$$

ただし、 U_b はアイテム b を格付けしたユーザ集合である。

最後に格付けの推定値 $\hat{r}_{a,b}$ が最大のアイテムを推薦する。

2.2 アイテム間CF

アイテム間CFは、格付けを基にアイテム間の類似性を計算し推薦するアイテムを決定する手法である[13]。アイテム間CFに基づいて、格付け $r_{a,b}$ を推定する場合、まずアイテム b と類似しているアイテム(neighbors)を求める。本稿では、ア

アイテム b の neighbors を $S_b = \{s_{b,1}, \dots, s_{b,N_s}\}$ と記す。次に、 $i \in S_b$ に対する過去の格付けに基づき、 $r_{a,b}$ を推定し、ユーザ a がまだ格付けしていない全てのアイテムの中で最も推定値が高いアイテムを推薦する (図 2)。

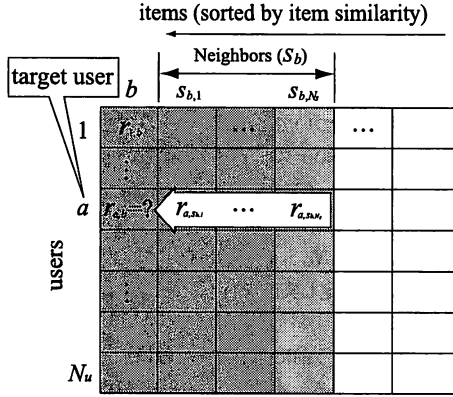


図 2 アイテム間 CF に基づく格付けの推定

S_b は、アイテム b とその他のアイテム間の類似度を用いて決定する。一般的に、ユーザ間類似度と同様にピアソン相関係数やコサイン距離が用いられるが、本研究ではピアソン相関係数を用いた。アイテム b とアイテム i のアイテム間 CF に基づく類似度 $sim_i(b, i)$ は、式 (3) で計算される。

$$sim_i(b, i) = \frac{\sum_{u \in U_b \cap U_i} (r_{u,b} - \bar{r}_b)(r_{u,i} - \bar{r}_i)}{\sqrt{\sum_{u \in U_b \cap U_i} (r_{u,b} - \bar{r}_b)^2} \sqrt{\sum_{u \in U_b \cap U_i} (r_{u,i} - \bar{r}_i)^2}}, \quad (3)$$

ただし、 U_b 、 U_i はそれぞれアイテム b 、 i を格付けしたユーザ集合、 \bar{r}_i は、アイテム i の格付けの平均値を表す。

neighbors の選択については、ユーザ間 CF と同様、本研究では $sim(b, i)$ が 0.5 以上であり、かつ類似度が高い上位 40 アイテムを neighbors とした。つまり、 $S_b = \{i | sim(b, i) \geq 0.5, rank(sim(b, i)) \leq 40\}$ とした。

被推薦者 a のアイテム b に対するアイテム間 CF に基づく格付けの推定値 $\hat{r}_{a,b}$ は式 (4) で計算される。

$$\hat{r}_{a,b} = f_i(a, b) = \frac{\sum_{i \in I_a \cap S_b} sim_i(b, i)(r_{a,i})}{\sum_{i \in I_a \cap S_b} |sim(b, i)|} \quad (4)$$

最後に、格付けの推定値 $\hat{r}_{a,b}$ が最大のアイテムを推薦する。

2.3 推薦精度

協調フィルタリングの有効性を表す指標として、正解率 (accuracy)、精度 (precision)、再現率 (recall)、平均絶対値誤差 (MAE) などの推定精度が用いられることが多い。本稿では、多数の先行研究で用いられている MAE を推定精度とし、MAE が小さいほど効果的な推定手法であるとする。MAE を計算する際は、まず全ての格付けサンプルに N_{training} 個の訓練

用データと、 N_{test} 個のテスト用に分け、訓練用の格付けを用いて協調フィルタリングにより格付けの推定値を計算する。その後、得られた推定値とテスト用の実際の格付けとの誤差の平均値を計算する。つまり、テスト用の格付けサンプルを R_{test} とすると、MAE は式 5 で計算される。

$$MAE = \sum_{r_{u,i} \in R_{\text{test}}} |r_{u,i} - \hat{r}_{u,i}| \quad (5)$$

ただし、CF に基づく格付けの推定値 $\hat{r}_{a,i}$ は実数値として得られるが、実際の格付けは 5 段階の離散化されたデータであるため、MAE を計算する際には予め推定値を四捨五入により離散化し、計算する。

2.4 従来手法によるユーザ間・アイテム間 CF の融合

Wang ら [4] は、ユーザ間 CF とアイテム間 CF を確率的に融合するフレームワークを提案し、推薦精度の向上を実現している。その基本的なアイデアは、ユーザ間 CF に基づいて格付けの推定値を計算する関数 $f_u(a, b)$ と、アイテム間 CF に基づいて格付けの推定値を計算する関数 $f_i(a, b)$ の λ による加重平均によって、格付けの推定値 $\hat{r}_{a,b}$ を計算する (式 (6))

$$\hat{r}_{a,b} = \lambda f_u(a, b) + (1 - \lambda) f_i(a, b) \quad (6)$$

従って、ユーザ a の類似ユーザによる格付けと、アイテム b の類似アイテムに対する格付けの両方を用いて推定値 $\hat{r}_{a,b}$ を計算する (Fig.3)。

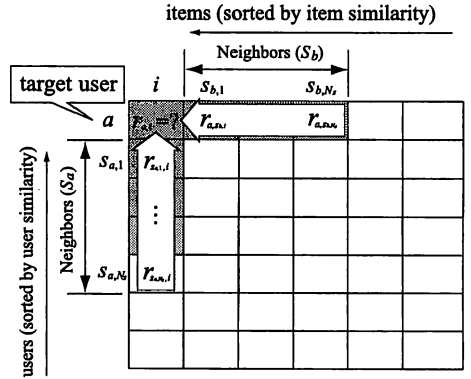


図 3 ユーザ間・アイテム間 CF の融合による格付けの推定

ここで、 λ は、ユーザ間 CF とアイテム間 CF の融合のバランスを決定するパラメータであり、本稿では MAE が小さいほど効果的な推薦であることから、MAE を最小化する λ が最適な値である。しかし、実運用では、既に得られた全ての格付けに基づいて推定を行うため、 R_{test} は存在せず、MAE は計算できない。従って、予め何らかの方法で適切な λ の値を決定しなければならない。

Wang らは、 λ による融合手法の有効性検証として、実システムから得た格付けサンプルにおいて、 λ を様々な値で与えた時の MAE の変化について実験を行っている。しかし、実際に運用中のシステムにおいて λ をどのように決定すべきかについては言及しておらず、経験的な定数によって与える方法しか提

案していない。

一般的に CF に基づく格付けの推定精度は、ユーザの嗜好のばらつき具合やユーザ毎の格付け頻度のばらつき具合、得られている格付けの数など、様々な要因に依存すると考えられる。我々が過去に行ったエージェントモデルに基づくシミュレーション [14] によれば、協調フィルタリングの有効性はユーザ全体の嗜好のばらつき具合や格付けの集まり具合に影響されることが明らかとなっている。

さらに、同様のモデルを用いて様々な λ を与えた時の MAE を測定したシミュレーション [15] において、適切な λ の値も、好みのばらつき具合や格付けの集まり具合によって変化することも明らかになっている。従って、実運用においてより推薦精度を高めるためには、その状況に適応した λ の値を決定する必要がある。また、格付け行列は徐々に埋まっていく状況においてその都度適切な λ を設定すべきである。

そこで次節では、既に得られている格付けからその時点における適切な λ を逐次推定することで、より適応的にユーザ間 CF とアイテム間 CF を融合する手法について議論する。

3. 適応的な融合手法の提案

ユーザ間 CF とアイテム間 CF を λ による加重平均として融合する場合、より推定精度を向上させるためには、逐次 λ を適切な値に設定する必要がある。本稿では、既に得られた格付けのみを使用して適切な λ を推定する手法について述べる。提案手法では、次の 5 つのステップで λ を推定する。

ステップ 1 初期値として $\lambda = 0$ とする。

ステップ 2 既に得られている格付けの中から 1 つをランダムに選択し、それを格付け行列から抜き出して、まだ得られていないものとして扱う。その上で抜き出した格付けの推定値を計算し、実際の格付けとの誤差を求める。

ステップ 3 ステップ 2 を t 回繰り返し、その時の MAE を計算する。

ステップ 4 λ が 1 より小さければ刻み幅 δ を加え、ステップ 2 に戻る。

ステップ 5 最も MAE が小さかった時の λ を実際に用いる値として決定する。

この方法は、実運用で既に得た格付けデータから λ を推定するため、これまでの格付けデータの傾向に近い将来においても継続すると仮定すれば、実際の運用状況に適応した λ が設定できる。また、格付けが蓄積されると、ユーザ間 CF とアイテム間 CF の推定精度は変化するため、その状況に応じた λ を逐次設定することで、より推定精度を高めることができると考えられる。ただし、 λ を適切に推定するためにはステップ 2 を繰り返す回数 t を一定以上にすると必要だと考えられるが、 t を増やすと計算時間が必要となるため、適切な値を設定する必要がある。

4. Movie Lens での格付けデータを用いた検証

4.1 Movie Lens での格付けデータ

本稿では MovieLens によって得られた格付けデータを用い

て、提案手法の有効性検証を行った。MovieLens は、映画を対象とした推薦システムであり、そこで得られたデータはインターネット上で公開されている^(注3)。各データは 5 段階の格付けであり、ユーザ数 943、アイテム数 1682 の、10 万個の格付けデータである。また、各ユーザは少なくとも 20 アイテムを格付けしている。

まず、全格付けデータのうち N_{training} 個を訓練データ、残りの N_{training} 個をテストデータとする。その後、訓練データと推薦アルゴリズムに基づいて各テストデータに対する格付けの推定値を計算し、実際のテストデータの値との MAE を計算して検証する。一般的に、CF では訓練データ数 N_{training} が多いほど推薦精度は高くなる。本稿では、 $N_{\text{training}} = 5000$ (サンプル全体の 5%) から $N_{\text{training}} = 40000$ (サンプル全体の 40%) まで 5000 刻みで設定し実験を行った。

4.2 実験 1

まず λ の推定を行う前に、予備実験として λ と MAE の関係について明らかにする。本稿では、 λ の刻み幅 $\delta = 0.05$ とし、それぞれの訓練データ数 N_{training} において各々の λ を設定した時の MAE の変化について実験を行った。ただし、訓練データは格付けサンプル全体からランダムで選択し、MAE を計算する際は全てのテストデータを用いて計算を行った。また、実験結果は 60 回試行した時の平均値である。実験結果を図 4 に示す。




図 4 各 λ における MAE

図 4 において、横軸は λ の設定値、縦軸は MAE である。式 6 から明らかなように、グラフの左端 ($\lambda = 0$) での値はアイテム間 CF のみで推定した結果と等しく、右端 ($\lambda = 1$) での値はユーザ間 CF のみで推定した結果と等しい。最も MAE が低くなる λ がその実験設定での最適値である。

図 4 において、格付け行列の密度が高くなるにつれて MAE が低くなっている。CF による推薦では、一般的に、与えられる格付けの数が多くなるほど推定精度が高くなるため、MAE

(注3) : <http://www.grouplens.org/node/73#attachments>

は低くなる。 $N_{\text{training}} = 5000$ では、 λ によらず $\text{MAE} = 1$ 付近であり、これはほぼランダムな推定での MAE に等しいが、 $N_{\text{training}} = 40000$ では、 $\text{MAE} = 0.75$ 付近まで下がっており、推定精度が良くなっている。

また、 $\lambda = 0$ でのアイテム間 CF のみによる推定や $\lambda = 1$ のユーザ間 CF のみによる推定よりは、 $\lambda = 0.5$ 付近での両者を融合した推定の方が MAE が低い値になっている。グラフによると、 $\lambda = 0.5$ 付近で MAE が最小になることが比較的多いことが読み取れる。過去に行ったシミュレーション [15] によれば、 MAE が最小となる λ はユーザ全体の嗜好のばらつき具合や格付けの数にも依存すると予測される。つまり、本実験で $\lambda = 0.5$ 付近が MAE を最も低くするという結果は、用いた格付けサンプルに依存した結果であり必ずしも一般的であるとは言えない。

4.3 実験 2

実験 1 は、テストデータを用いて λ を各値で設定した時の MAE を計算したが、実運用ではテストデータは存在しないため、それを利用して MAE を計算することはできない。つまり、既に得られている格付けデータのみを用いて、いかに MAE を低くする λ を推定できるかが課題である。本節では、 λ の推定とその時の MAE について述べるが、実験 1 において MAE を最も低くした λ が最適な λ であり、推定値を評価する際の基準となる。ただし、図 4 は 60 回試行した平均値であり、最適な λ は訓練データの選択の仕方によって変わるため、試行毎に変化していることに注意が必要である。本稿では、最適な λ を設定した時の MAE と、推定した λ を設定した時の MAE の誤差率 (式 (7)) によって、推定値の有効性を検証する。

$$\text{誤差率} \epsilon = \frac{\text{推定した}\lambda\text{による MSE} - \text{最適な}\lambda\text{による MSE}}{\text{最適な}\lambda\text{による MSE}} \quad (7)$$

従って、推定した λ が最適な λ と等しければ、誤差率 $\epsilon = 0$ となり、離れるほど誤差率は大きくなる。図 5 は各々の訓練データ数 N_{training} において、 λ を推定した際の MAE の誤差率である。ただし、「3. 適応的な融合手法の提案」で述べたステップ 2 の繰り返し回数 $t = \{100, 500, 1000\}$ のそれぞれで設定し実験を行った。




図 5 最適な λ における MAE と推定した λ における MAE の誤差率

図 5 において、横軸は繰り返し回数 t 、縦軸は誤差率 ϵ である。

N_{training} をいずれの値で設定しても、 t が増えるほど誤差率 ϵ は減少傾向であり、 λ の推定の精度が向上していることがわかる。ただし、 $N_{\text{training}} = 5000$ では、他に比べて誤差率 ϵ が低い値になっている。これは、図 4 に示した通り、訓練データ数が少ないことが原因でいずれの λ でも MAE の値が高く、その差が小さいことが原因であると考えられる。

ϵ の値を見てみると、 $t = 1000$ とした場合では N_{training} がいずれの設定においてもおよそ 0.005 付近かそれ以下となっており、ほぼ最適な λ を選択した場合に近い値が得られていることがわかる。例えば、図 4 を見ると、 $N_{\text{training}} = 15000$ において最適な λ は 0.5 付近であることが読み取れ、その時の MAE の平均値はおよそ 0.83 である。このとき、誤差率 ϵ が 0.005 であるとする、 $0.83 \times 0.005 = 0.00415$ となり、推定値の λ による MAE は $0.83 + 0.00415 = 0.83415$ となる。この値を図 4 と比較してみると、 λ の推定値は 0.4 から 0.6 の間に収まることからわかる。つまり、誤差率が 0.005 以下であれば、 λ の推定値を用いた時の推薦結果は、 λ の最適値を用いた時の推薦結果に近いものになると考えられる。

t を増やすことで誤差率 ϵ をさらに減らすことができると考えられるが、実運用では計算量との兼ね合いで検討する必要がある。

5. 結論

協調フィルタリング (CF) は、推薦システムを実現する代表的なアルゴリズムであり、現在商用サイトなど多くのシステムで実用化されている。CF には、ユーザ間 CF とアイテム間 CF という 2 つの基本的なアルゴリズムが存在し、Wang らはその両者を加重平均を用いて融合することで、より精度の高い推定手法を提案した。実際に両手法を融合するためには、融合のバランスを決定するパラメータである λ を適切に定める必要があり、従来は、実システムで得られたサンプルデータなどに基いて経験的な定数を設定していた。

しかし、我々が行った先行研究によれば、ユーザ間 CF 及びアイテム間 CF の推定精度は、ユーザ全体の嗜好のばらつき具合や、ユーザ毎の格付け頻度のばらつきなどに依存し、また格付けの収集具合にも影響を受けるため、最適な λ を予め一概に決めておくことはできない。従って、 λ はシステムの運用状況に応じて適応的に設定される必要がある。

そこで本研究では、既に得られた格付けから逐次的に適切な λ を推定することで、より適応的にユーザ間 CF とアイテム間 CF を融合する手法を提案した。これにより、特定の実システムに依存することなく、常に運用状況に応じた適切な λ を用いて両手法を融合し、推薦が可能になった。また、MovieLens による実データを用いて提案手法の有効性について検証を行った結果、最適な λ を用いた場合の MAE と比較して、誤差率 0.005 程度またはそれ以下で推薦が可能であることを示した。

ユーザ間 CF は、被推薦者と似たユーザの格付けを基に推薦アイテムを決定し、アイテム間 CF は被推薦者による似たアイテムに対する格付けを基に推薦アイテムを決定する。Wang らは、ユーザ間 CF とアイテム間 CF を融合する手法を提案した論文 [4] において、単純にユーザ間 CF に基づく推定値と、アイテム間 CF に基づく推定値を融合するだけではなく、「被推薦者と似たユーザが、推薦候補と似たアイテムに対して行った格付け」という今まで格付けの推定に用いられていなかった格付けも確率的に統合して利用する方法を提案している。本稿で提案した λ の推定手法は、この部分の統合においても応用できると考えており、今後の課題にしたいと考えている。

文 献

- [1] P. Resnick, and H. Varian: Recommender Systems, Comm. of the ACM, Vol.40, No.3, pp.56-58 (1997).

- [2] J. B. Schafer, J. A. Konstan, and J. Riedl: E-Commerce recommendation applications. *Data Mining and Knowledge Discovery*, Vol.5, pp.115-153 (2001).
- [3] A. I. Schein, A. Popescul, L. H. Ungar, D. M. Pennock: Methods and Metrics for Cold-Start Recommendations, In *Proc. of the 25th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR '02)*, pp.253-260 (2002).
- [4] J. Wang, A. P. Vries, M. J. T. Reinders: Unifying User-based and Item-based Collaborative Filtering Approaches by Similarity Fusion, In *Proc. of 29th ACM SIGIR Conference on Information Retrieval*, pp. 501-508 (2006).
- [5] D. Goldberg, D. Nichols, B. M. Oki and D. B. Terry: Using Collaborative Filtering to Weave an Information Tapestry, *Communications of the ACM*, Vol. 35, No. 12, pp.61-70, 1992.
- [6] P. Resnick, N. Iacovou, M. Suchak, P. Bergstrom and J. Riedl: GroupLens: An Open Architecture for Collaborative Filtering of Netnews In *CSCW '94: Conference on Computer Supported Cooperative Work (Chapel Hill, 1994)*, ACM, pp. 175-186 (1994).
- [7] J. L. Herlocker, J. A. Konstan, L. G. Terveen, and J. T. Riedl :Evaluating Collaborative Filtering Recommender Systems, *ACM Transactions on Information Systems*, Vol.22, No.1, pp.5-53 (2004).
- [8] J. L. Herlocker, J. A. Konstan, A. Borchers and J. Riedl: An algorithmic framework for performing collaborative filtering, *Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information retrieval*, pp.230-237, August 15-19, (1999).
- [9] 平山巧馬, 小柳 滋: 協調フィルタリングにおける相関係数法の予測性能向上, *電子情報通信学会論文誌*, Vol.J90-D, No.2, pp.223-232 (2007).
- [10] J. L. Herlocker, J. A. Konstan, J. Riedl: An Empirical Analysis of Design Choices in Neighborhood-Based Collaborative Filtering Algorithms, *Information Retrieval*, Vol.5 No.4, pp.287-310 (2002).
- [11] J. S. Breese, D. Heckerman and C. Kadie: Empirical Analysis of Predictive Algorithms for Collaborative Filtering, In *Proc. of the 14th Conference on Uncertainty in Artificial Intelligence (UAI'98)*, pp.43-52 (1998).
- [12] H. Ma, I. King, and M. R. Lyu: Effective missing data prediction for collaborative filtering, In *Proc. of 30th Annual International ACM SIGIR Conference on Information Retrieval*, pp.39-46 (2007).
- [13] B. Sarwar, G. Karypis, J. A. Konstan and J. Riedl: Item-based Collaborative Filtering Recommendation Algorithms, *Proc. of WWW' 01*, pp.285-295 (2001).
- [14] 山下晃弘, 川村秀憲, 飯塚博幸, 大内東: 推薦と格付けの相互作用に基づく推薦アルゴリズムの性能評価, *情報処理学会論文誌, 数理モデル化と応用 (採録済)*
- [15] 山下晃弘, 川村秀憲, 鈴木恵二, 大内東: 推薦システムにおけるユーザ間・アイテム間協調フィルタリングの適応的な融合手法の提案, *情報処理北海道シンポジウム 2008 予稿集, 稚内 (2008)*.