

動的なトピック分類に基づく Novelty を考慮した推薦アルゴリズムの検討

小川祐樹^{*1}, 諏訪博彦^{*1}, 山本仁志^{*2}, 岡田勇^{*3}, 太田敏澄^{*1}

Recommendation Algorithm for Improving Novelty based on Dynamic Topic Classification

Yuki Ogawa^{*1}, Hirohiko Suwa^{*1}, Hitoshi Yamamoto^{*2}, Isamu Okada^{*3}, Toshizumi Ohta^{*1}

Abstract: 我々は、推薦にユーザの嗜好傾向を反映したトピックの概念を導入することで、ユーザ満足度を向上させる推薦手法を提案する。従来研究において、推薦の有用性は正確さと捉えられていたが、それだけではユーザは満足しないという結果が報告されている。我々は、ユーザの嗜好傾向をトピックと捉え、これをユーザの嗜好行動から抽出し、これを用いた推薦を行うことでユーザの「知らない・好みのアイテム」を推薦することを目的とする。

Keywords: 推薦システム, 協調フィルタリング, Novelty

1. はじめに

近年、インターネットの急速な普及により、膨大な情報を誰でも容易に取得できるようになった。しかしその反面、利用者が本当に望む情報を取得することが非常に難しくなっており、有用な情報をいかに選定するかという情報フィルタリング技術の重要性が高まってきている。そのなかで推薦システムと呼ばれる技術は、多くの情報の中から利用者の望む情報をフィルタリングする有用な技術として、Amazon.comをはじめ⁽¹⁾多くの商用サイトなどで広く用いられ大きな成功をおさめている⁽²⁾。

従来の推薦システム研究において、推薦の有用性は、推薦がいかによりユーザの好みに合っているかという推薦の正確さとして捉えられ、その評価指標である予測精度(精度・再現率, MAE)⁽³⁾の向上が重視されてきた。しかし、最近ではその高い推薦精度が災いして、好みではあるが似たようなアイテムばかり推薦されてしまい、結果的にユーザはそれだけでは満足しないという結果も報告されている⁽⁴⁾。例えば、推薦システムを備えたECサイトにおいて、一旦ジブリ映画作品のDVDを購入したとき、その後しばらくは他のジブリ作品のDVDが積極的に推薦される。これは推薦の正確さという観点では適切な推薦であるが、推薦された作品を既にユーザが見ていた場合、これらの推薦はユーザにと

って退屈な推薦であり、長く続けば推薦への飽きに繋がりがり、結果的にはユーザはそのサイトを利用しなくなるということが考えられる。

今後の推薦システムの課題として、推薦システムの有用性を、従来の正確さの観点だけではなく、ユーザに新たな価値の発見を提供するといった正確さ以外の観点から新たに検討することの重要性が指摘されている⁽⁵⁾⁽⁶⁾。例えば、ユーザにとって目新しさのある推薦を行うことは、既に知っているアイテムが推薦されることによる推薦に対する飽きの問題を解消し、ユーザの新たな嗜好の開拓に繋がると考えられる。

本研究では、推薦の有用性を従来の正確さの観点から捉えるのではなく、推薦の目新しさという観点に注目し、目新しいアイテムを推薦することでユーザ満足度を向上させる推薦手法の構築を目的とする。ここで推薦の目新しさとは、ユーザの「知らない・好みのアイテム」を推薦できること(Novelty)を指す⁽⁷⁾。本研究において我々は、嗜好傾向が類似するアイテムを複数推薦するよりも、嗜好傾向の異なるアイテムを複数推薦する方が、ユーザの知らないアイテムを推薦する可能性が広がるという仮定にもとづき、推薦リストの嗜好傾向の多様化手法により推薦の目新しさ(Novelty)を改善させる手法を新たに提案する。

2. 関連研究

2.1. 従来の推薦システムの評価

推薦の具体的な評価指標は、推薦の正確さの指標とそれ以外の指標に大別できる。

^{*1} 電気通信大学 大学院情報システム学研究所 社会知能情報学専攻 〒182-8585 東京都調布市調布ヶ丘1-5-1

E-mail: ogawa@ohta.is.uec.ac.jp

^{*2} 立正大学 経営学部

^{*3} 創価大学 経営学部

推薦の正確さは、ユーザの関心のあるアイテムを推薦できるかという点で最低限備えておくべき推薦の規準である⁽¹⁰⁾。従来の推薦の評価では、多くの研究がこの正確さの向上を重視している。正確さの評価指標としては、精度・再現率のような評価指標が用いられる。オンライン評価の精度（ユーザに実際に推薦システムを利用してもらい、推薦が適切かどうかを評価する方法）は、推薦リスト中の好みのアイテム（5段階評価の場合、上位2段階の評価のアイテムなど）の割合として評価する方法である。この指標は、個々の推薦アイテムへの評価を用いた評価指標であるが、推薦リスト全体へのユーザ満足度とも高い相関があり⁽¹⁰⁾、最も基本的な評価指標とされている。オフライン評価の精度・再現率（事前に集めた嗜好のサンプルデータを用いた交差検証法）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。

しかし、現在では正確さの指標だけでは不十分であることが指摘されている⁽⁵⁾⁽⁶⁾。推薦システムにおいて、ユーザの好みのアイテムを推薦するという正確さの観点は重要であるが、好みであってもユーザが既に経験したアイテム（見た、あるいは読んだことがあるアイテム）だけを推薦しても、ユーザにとって本当に有用な推薦とはいえない。このため、正確さ以外の指標について、異なる観点で様々な指標の提案がなされている。代表的な評価指標としては、Noveltyや発見性、Serendipityなどがある。Novelty⁽⁵⁾は、推薦リスト中のユーザの知らない・好みのアイテムの割合であり、推薦の目新しさを評価する指標である。発見性⁽¹¹⁾は、Noveltyが推薦リスト中の知らない・好みのアイテムであったの対し、推薦リスト中の知らないアイテムの割合を評価する指標である。また、Serendipityは、目新しさに、思いがけなさ、予見のできなさ、または意外さの要素が加わった概念として示されている⁽⁸⁾。ただ、Serendipityはユーザの感情的な面に影響される部分が大きいため、定量的に示すことが難しい評価とされている⁽⁶⁾。いくつかの提案指標として、推薦リスト内アイテムの類似性（Intra-List-Similarity）⁽⁴⁾や、評価対象である推薦システムの予測結果とプリミティブな推薦システムの予測結果との差異を意外性として評価した意外性⁽¹²⁾などの指標が考えられている。

2.2. 推薦の正確さ以外の向上を目的とした研究

推薦の正確さ以外の向上を目的とした研究としては、清水ら⁽¹¹⁾とZieglerら⁽⁴⁾の研究がある。

清水ら⁽¹¹⁾は、ユーザの「知らないアイテム」を推薦することを推薦の発見性と捉え、ユーザのアイテムへ

の既知・不既知の情報を用いて協調フィルタリングを行うことにより発見性を向上させる推薦手法を提案した。この結果、既存の協調フィルタリングによる推薦よりも、ユーザの知らない・好みのアイテムを多く推薦できることをオフラインのNovelty精度の評価実験により示した。しかし、実際の運用の場面を考えたとき、知らないアイテムに対してユーザから「知らない」という情報を明示的に得ることは難しいと考えられるため、ユーザ労力の観点においては課題が残る。よりユーザ労力の少ない方法で有効な効果が出せる手法について考える必要がある。また、推薦の評価がオフラインで行われるNovelty精度による評価のみであるため、オンラインでのユーザの直接的な評価によっても推薦手法の有効性を示す必要がある。

Zieglerら⁽⁴⁾は、アイテムに付与しているジャンルや著者などの静的なカテゴリー情報（Amazon.comにおけるカテゴリー分類情報）を利用して、推薦リスト内のアイテム類似度を計算する指標として

Intra-List-Similarityを提案し、この類似度が低くなるように推薦アイテムを選定する多様化の手法を提案した。この結果、ある程度の多様化を行った推薦リストによって最も高いユーザ満足度が得られたことをオンラインでのユーザ満足度の実験で示した。しかし、この手法の問題点として、カテゴリーという既に定義されている静的なカテゴリー情報があることを前提としているため、適用範囲が本やDVDなどのカテゴリー付けが容易なアイテムに限定されてしまう点がある。また他の問題点として、アイテム間には、静的なカテゴリーだけでは捉えきれない類似関係が存在すると考えられる。作品・テーマの類似性という観点でいえば、例えば、同じジブリ作品の映画というカテゴリーであっても、多くの人が好む「となりのトトロ」と、賛否両論分かれる「ゲド戦記」は必ずしも強い類似関係があるとは限らない。また、話題の類似性という観点では、ヒットした映画などにおける認知度の違いなどが考えられ、これらはジャンルという静的なカテゴリーだけでは捉えきれない。話題性は動的に変化し、テーマ・思想などを一人で定義することは分類に恣意性を生じさせる。これらのことから、多様化に用いるカテゴリーについて、テーマ・話題の類似性などを考慮したカテゴリーを人手により設計するには、大きな労力と困難さを有する。

3. 嗜好傾向の多様化による推薦の多様化手法

本研究では、ユーザのアイテム評価という嗜好行動履歴から動的に変化する嗜好傾向に基づいたカテゴリ

ー（これをトピックと呼ぶ）を自動的に作成し、それに基づく多様化によってユーザの「知らない・好みのアイテム」を推薦する手法を提案する。ユーザの「知らない・好みのアイテム」の推薦（Novelty の高い推薦）を行うことは、ユーザの推薦に対する飽きの問題を解消し、ユーザの新たな嗜好の開拓に繋がると考えられるため、推薦の正確さ以外の観点として重要な要素といえる。

提案する手法において、嗜好傾向の多様化によりユーザの知らないアイテムを推薦するという考えは、特定の嗜好傾向をもったユーザに対して同じ嗜好傾向のアイテムを推薦しても、既にユーザはそのアイテムを知っている可能性が高いという仮定に基づいている。例えば、推薦リスト内のアイテムが特定の嗜好傾向で偏っていたとき（ジブリ作品映画のみの推薦リストの場合など）、ユーザがその推薦アイテムのどれかに興味があり既に見ていた、あるいは知っていた場合、ユーザは推薦リスト内の同じ嗜好傾向を持つその他のアイテムについても知っている可能性が高いと予想できる。そのため、特定の偏った嗜好傾向のアイテムを複数推薦するよりも、異なる嗜好傾向のアイテムを複数推薦する方が、ユーザの知らないアイテムを推薦する可能性が高いと考えられる。

以上の考えのもと、我々は、嗜好傾向の異なる複数のアイテムを推薦リストとしてユーザに提示することにより、ユーザの知らないアイテムを推薦する。また、推薦リストの作成段階において、トピックの選定とトピック内からのアイテムの選定に予測評価値を用いた優先順位を設けることで推薦の正確さを確保する。こ

れにより、ユーザの「知らない、かつ好みのアイテム」を推薦する。

3.1. アルゴリズムの概要

提案する推薦システムの全体図を図1に示す。提案手法は以下の3つのステップに分かれる。

step 1. 嗜好傾向に基づくアイテムのトピック分類

step 2. ユーザごとにパーソナライズされた推薦リストの作成

step 3. トピックを用いた推薦リストの多様化

step 1 では、ユーザの嗜好傾向を反映したトピックを作成する。トピックの作成には、ユーザの嗜好行動を表した全ユーザのアイテム評価履歴を用いる。具体的には、全ユーザのアイテム評価行列から「このアイテムを好んでいるユーザは、このアイテムも好んでいる」といったアイテム間の評価の共起関係をネットワークとして表現し、これをクラスタリングすることにより、嗜好傾向が近いアイテムをトピックとして分類する。

step 2 では、多様化を行う前段階の処理として、あらかじめユーザごとにパーソナライズされた推薦候補となるアイテムを選定しておく。本研究では、既存のユーザベースの協調フィルタリングを用いて、パーソナライズされた推薦リストを作成する。このリストをベースとし、step 3 の多様化の処理においてトピックが多様になるようにアイテムを選定する。

step 3 では、step 1 で得られたアイテムのトピック情報を用いて、step 2 で得られた推薦リストのトピック多様化の処理を行う。具体的には、トピックが複数に及び、かつ step 2 の協調フィルタリングで得られる予




図1 提案する推薦システムの全体図

測評価値が高くなるようなアイテムを選定することで、多様化を行った新たな推薦リストを作成する。

上記の方法によって、ユーザの「知らない、かつ好みのアイテム」を、ユーザのアイテム評価情報という少ない情報のみで実現する。以下の節では、それぞれのstepにおける処理の詳細を述べる。

提案手法は、「step1. 嗜好傾向に基づくアイテムのトピック分類」, 「step2. ユーザごとにパーソナライズされた推薦リストの作成」, 「step3. トピックを用いた推薦リストの多様化」に分かれる。提案する推薦システムの全体図を図1に示す。

3.2. 嗜好傾向に基づくアイテムのトピック分類 (Step 1)

我々は、ユーザのアイテム評価履歴という嗜好行動履歴からアイテムの共評価関係をネットワーク化し、このネットワークをクラスタリングすることにより嗜好傾向を反映したトピックの作成を行う。

ネットワークのクラスタリングをもとにしたカテゴリズに関する研究として、グラフ分析を用いた文書集合からのトピック抽出⁽¹³⁾や、論文の共著関係からの研究者コミュニティの抽出⁽¹⁴⁾、また、SNSのリンク関係を利用したコミュニティの分析⁽¹⁵⁾など、現在多くの研究が行われている。これらは、潜在的なコミュニティやトピックの発見、また、時事的に変化する情報を組織的に表現できる点で有効な手法である。このことより、我々は、アイテムの共評価関係をネットワークとして表現し、これをクラスタリングする手法が、嗜好傾向にもとづいたトピックを抽出する方法として有効な手法であると考ええる。

以下、3.2.1. にトピック分類に用いる共評価ネットワークの作成方法、3.2.2. にそのネットワークのクラスタリングによるトピック分類方法についての詳細を述べる。

3.2.1. 共評価ネットワーク

トピック分類に用いるネットワークには、アイテムをノード、エッジにアイテム間の共評価の頻度の重みを設けた重み付き無向ネットワーク（以下、共評価ネットワーク）を用いる。

3.2.2. ネットワークのクラスタリングによるトピック分類

トピックの分類は、3.2.1. のアイテムの共評価ネットワークをNewmanらのアルゴリズム⁽¹⁶⁾でクラスタリングすることにより行う。

Newmanらは、クラスタリングの性能を評価するモジュール性 Q という指標を提案し⁽¹⁷⁾、この指標を用いたクラスタリング手法を提案した⁽¹⁶⁾。ここで Q 値が示

すものは、「モジュール内でのノード間にリンクが存在する確率の実測値—ランダムネットワークと仮定した場合のモジュール内におけるリンクの割合の理論値」であり、モジュール内のリンクが密で、かつモジュール間のリンクが疎である場合にこの値は大きくなる。このため、この Q 値はクラスタリングの性能を客観的に評価できる点で有用な指標であり、Newmanらは、この値が0.3程度あると独立したモジュール化構造があることを評価できるとしている。以下に、 Q の計算式(1)を示す。ここで、 C は全クラスタ数、 m はネットワーク全体に存在するエッジ数、 l_i はクラスタ i 内におけるエッジ数、 l_{ij} はクラスタ i とクラスタ j のエッジ数である。

$$Q = \sum_i^C \left(\frac{l_i}{m} - a_i^2 \right) \quad (1)$$

$$a_i = \sum_j e_{ij}$$

$$e_{ij} = \frac{l_{ij}}{2m}$$

この Q 値を用いたNewmanらのクラスタリング手法は、初期状態を1ノード1クラスタとして、 Q 値の増加値 ΔQ が最大となるノードとの合併を続けていく手法である。この手法は、 ΔQ が最大であるクラスタ同士を結合していく貪欲アルゴリズムであり、準最適解を求める手法ではあるが、 $O(nm^2)$ で有効なクラスタリングが行える手法として多く用いられている⁽¹⁵⁾⁽¹⁹⁾。以下にクラスタ i と j を結合したときの Q の増分値 ΔQ_{ij} の式(2)を示す。

$$\Delta Q_{ij} = 2(e_{ij} - a_i a_j) \quad (2)$$

上記の手法は、重みなし無向ネットワークにおけるクラスタリング手法であるが、重み付きネットワークへの応用も可能である⁽¹⁸⁾。また、エッジに重みを設けることでクラスタのサイズが平均化され、クラスタリングの結果が改善されるという結果も示されている⁽¹⁹⁾。

以上より、我々は、エッジにアイテムの共評価の頻度の重みを設けた重み付きネットワークに対し、Newmanらのクラスタリング手法を用いることで、嗜好傾向が類似するアイテムのグループをトピックとして分類することができる考える。

3.3. ユーザごとにパーソナライズされた推薦リストの作成 (Step 2)

提案手法では、多様化を行う前にあらかじめユーザごとにパーソナライズされた推薦候補アイテムを選定しておく。このリストをベースとし、後の多様化の処

理において、このリストからトピックが多様になるようにアイテムを選定する。

本研究では、既存のユーザベース協調フィルタリングを用いて、ユーザごとにパーソナライズされた推薦リストを作成する。

ユーザベースの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手法である。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。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。類似度の計算にはコサイン類似度やピアソン相関係数⁷⁾が用いられる。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 P 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。以下に、ユーザ U_x の未評価アイテム I_a への予測評価値の計算式(3)を示す。

$$P_{x,a} = ave(r_x) + \frac{\sum_{k \in K} sim(x,k)(r_{x,a} - ave(r_k))}{\sum_{k \in K} |sim(x,k)|} \quad (3)$$

ここで、 $ave(r_x)$ はユーザ U_x の投票したすべての評価値の平均値、 $\Delta k \in K$ はユーザ U_x と類似度の高い近傍ユーザとする。

上記のユーザベース協調フィルタリングを用いることにより、ユーザごとにパーソナライズされた推薦リストを作成する。

3.4. トピックを用いた推薦リストの多様化 (Step 3)

我々は、ユーザの「知らない・好みのアイテム」を推薦するために、複数の異なるトピックから推薦アイテムを選定するトピック多様化アルゴリズムを提案する。多様化の手法としては、3.2. で得られたアイテムのトピック情報を用い、3.3. で得られた推薦リストの中からトピックが多様になるようにアイテムを選定する。図2にトピック多様化のアルゴリズムを示す。

ここで、既存の協調フィルタリングから生成されるユーザ i の N アイテムの推薦リスト L_i から、トピックを多様化した X アイテムの推薦リスト L_i^{TD} を作成することを考える($X < N$)。提案アルゴリズムでは、ユーザの「知らない・好みのアイテム」のリストを作成するために、推薦リストに複数の異なるトピックを含ませ、かつ予測評価値の高いトピックを優先したリスト L_i^{TD} を作成する。

まず、多様化前の推薦リスト L_i のアイテムをトピックで分類し($getTopics()$)、 L_i におけるトピックのリスト TP を作成する。次に、各トピックから最も予測評価値の高いアイテムを選定し($getMaxPredictItem()$)、

この予測評価値の高いトピックを優先したリスト $list$ を作成する($sortByPredict()$)。そして、このリストを最終的なリスト L_i^{TD} に追加し($add()$)、元のリスト L_i から削除する($delete()$)。

上記の処理を L_i^{TD} のアイテム数が X になるまで繰り返すことにより、推薦リストが複数の異なるトピックを含み、かつ予測評価値の高いトピックを優先したリスト L_i^{TD} を作成する。

```

procedure TDA( $L_i, X$ ) {
   $L_i^{TD} \leftarrow \{\}$ ;
  while ( $(|L_i^{TD}| < X) \ \&\& \ (|L_i| > X)$ )
     $list \leftarrow \{\}$ ;
     $TP \leftarrow getTopics(L_i)$ ;
    for all  $topic \in TP$  do
       $item \leftarrow getMaxPredictItem(L_i, topic)$ ;
       $add(list, item)$ ;
    end for
     $list \leftarrow sortByPredict(list)$ ;
    for all  $item \in list$  do
       $add(L_i^{TD}, item)$ ;
       $delete(L_i, item)$ ;
      if ( $|L_i^{TD}| \geq X$ ) go to end while;
    end for
  end while
  return  $L_i^{TD}$ ;
}

```

図2 トピック多様化のアルゴリズム
(Topic Diversification Algorithm)

4. 評価実験

提案手法が「ユーザの知らない・好みのアイテム」を推薦できるかを評価するために、従来の協調フィルタリング手法(以後、CF)との比較実験を行った。

4.1. 実験概要

4.1.1. 実験対象

実験は、大学生20人に対して行った。

4.1.2. データセット

本実験では、アイテム集合としてAmazon.co.jpのDVDアイテム1,000個、評価値情報として学生20人とAmazon.co.jpのレビュー者の情報を用いた。データはAmazon API⁽²⁰⁾によって2007/4/18~2007/4/20の間にかけて収集し、DVDアイテム1,000個は、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。1,000アイテムに対するAmazon.co.jpの

レビュー数は、9,102 レビューであり、この内レビュー数が1つしかないユーザーを除き、最終的にユーザー数 1,609 人、レビュー数 5,692 のデータを得た。

4.1.3. 実験手順

実験の手順を以下に示す。

(1) 初期アイテム評価情報の収集：

ユーザ（学生 20 人）にランダム 30 個の DVD アイテムを提示し、既知・不既知（1：見た，2：見てないけど知っている，3：知らない）と、評価値（1：全く見たくない，2：あまり見たくない，3：どちらでもない，4：やや見たい，5：とても見たい）を入力してもらいアイテム評価のデータを得る。また、評価情報の標本として Amazon のレビュー者の情報を利用する。

(2) トピックの分類：

Amazon.co.jp のレビュー者の情報を用いて、アイテムの共評価ネットワークを作成し、これをクラスタリングしてアイテムをトピックに分類する。

(3) 多様化推薦リストの作成：

(1)のデータの内、ユーザの「知っているアイテム（見た or 見てないけど知っているアイテム）」を用いてユーザベースの協調フィルタリングで推薦候補上位 Top-50 アイテムを選定する。そして、(2)のデータと推薦候補の 50 アイテムを用いて、多様化を行った上位 X アイテムの推薦リスト ($X \in [10,20,30,40,50]$) を作成する。

(4) オンラインでのユーザ満足度評価：

(3)で作成した推薦リストをユーザに提示し、各アイテムに対して、既知・不既知（1：見た，2：見てないけど知っている，3：知らない）と、評価値（1：全く見たくない，2：あまり見たくない，3：どちらでもない，4：やや見たい，5：とても見たい）を入力してもらいユーザ満足度のデータを得る。

(5) オンライン評価分析：

(4)で得たアイテム評価をもとに推薦リストの評価を行う。本論文では、推薦リスト中の「好みのアイテム」の割合を Precision と定義する。さらに、それを知っていたかどうかという観点から、推薦リスト中の「知っている・好みのアイテム」の割合を Accuracy，推薦リスト中の「知らない・好みのアイテム」の割合を Novelty と定義する。

なお、ユーザが知らないアイテムに対しても評価を行えるよう、(1)と(4)でユーザに提示するアイテムは、

Amazon.co.jp で用いられている「タイトル」、「画像」、「商品の紹介文」を共に提示した。

4.2. 実験結果

4.2.1. 初期アイテム評価情報の結果

ユーザに提示したランダム 30 個のアイテムの評価結果を表 1 に示す。

		30 個中の割合	好みのアイテム (評価値 4~5) の割合
知っている	見た	9.0%	7.9%
	見てないけど知っている	26.2%	11.1%
知らない	知らない	64.8%	10.3%

表 1 初期アイテム評価情報の結果

4.2.2. トピック分類の結果

収集したアイテムの初期評価情報より、図 3 のアイテムの共評価ネットワークを作成した。このネットワークをクラスタリングした結果、トピック数 355、1 トピックの平均アイテム数 2.82、クラスタリング性能も $Q=0.29$ とモジュール性を持ったクラスタリング結果を得た。トピックに関しては、アイテムのジャンル、シリーズ、あるいは視聴対象者等で似かよっており、嗜好傾向を反映したトピック分類結果が得られた。




図 3 アイテムの共評価ネットワーク
(ノード数：1,000 エッジ数：9,171)

4.2.3. ユーザ満足度評価の結果

図 4 に、推薦リスト上位 X アイテム中のユーザの「知らない・好みのアイテム（5 段階評価中の上位 2 段階評価のアイテム）」の割合 (Novelty) を示す。対応のある平均値の差の検定の結果、推薦リストの上位 10 位において 1% の有意差、上位 20 位において 5% の有意差が確認されている。この結果より、提案手法が CF よりもユーザの「知らない・好みのアイテム」を多く推薦できていることがわかる。

図 5 に、推薦リストの上位 X アイテム中のユーザの「知っている・好みのアイテム」の割合 (Accuracy)

を示す。対応のある平均値の差の検定の結果、有意な差はみられなかった。この結果より、提案手法がCFと同程度のユーザの「知っている・好みのアイテム」を推薦できていることがわかる。

図6に、推薦リストの上位Xアイテム中のユーザの「好みのアイテム」の割合（Precision）を示す。対応のある平均値の差の検定の結果、有意な差は見られなかった。この結果より、提案手法がCFと同程度のユーザの「好みのアイテム」を推薦できていることがわかる。




図4 Novelty: 推薦リストの上位Xアイテム中における「知らない・好みのアイテム」の割合




図5 Accuracy: 推薦リストの上位Xアイテム中における「知っている・好みのアイテム」の割合




図6 Precision: 推薦リストの上位Xアイテム中における「好みのアイテム」の割合

5. 考察

本研究で目指す推薦は、Noveltyの高い推薦、つまりユーザの「知らない・好みのアイテム」を推薦するこ

とである。提案手法においては、上位50位までの推薦アイテムの並べ替えを行っているため、アイテム数が多くなるほど差はなくなることは当然である。ユーザは推薦リストの上位より閲覧するため、推薦リストの上位において有意な差が出るのが、効果を測定する上で重要となる。図4の対応のある平均値の差の検定結果において、推薦リストの上位10位で1%の有意差、上位20位で5%の有意差が確認されている。このことから、トピックの多様化と予測評価値を用いて優先度の設定する提案手法が、ユーザの「知らない・好みのアイテム」を推薦するうえで有効な手法であるといえる。

一方、ユーザの「知っている・好みのアイテム」を推薦することに関しては、対応のある平均値の差の検定結果より、提案手法がCFと同程度ユーザの「知っている・好みのアイテム」を推薦できていることが示されている。提案手法では、予測評価値の高いアイテムを優先しながらトピックを多様化しているため、トピック多様化によるAccuracyの低下が抑制できたといえる。なお、有意差はないものの、提案手法において値が低い理由としては、提案手法では全てのトピックを網羅するように推薦リストを作成するために、アイテムの嗜好傾向の幅が広くなり、結果的に知っているアイテムが推薦される可能性が減ったことが原因と考えられる。

ユーザの「好みのアイテム」を推薦することに関しては、対応のある平均値の差の検定結果より、提案手法がCFと同程度ユーザの「好みのアイテム」を推薦できていることが示されている。なお、提案手法の方がCFよりも高い結果を得たが有意な差は見られなかった理由として、図5におけるユーザの「知っている・好みのアイテム」の結果において、提案手法がCFよりも値が低かったことが原因となっているためと考えられる。

ユーザの「知っているアイテム」の推薦と、ユーザの「知らないアイテム」を推薦することはトレードオフの関係であるが、ユーザの「知っている・好みのアイテム」を推薦することと、ユーザの「知らない・好みのアイテム」を推薦することは、必ずしもトレードオフの関係になるとは限らない。その点において、提案手法は、Accuracyを維持しながらNoveltyを向上させることができていることから、CFよりも有効な推薦手法であるといえる。

以上より、推薦リスト内におけるトピックの多様化手法が、ユーザの「知らない・好みのアイテム」を推薦する有効な推薦手法であることが実験より示された。

ただし、現状の研究の制約として、対象がDVDアイテムのみであること、被験者が学生のみであること、比較アルゴリズムがユーザベースの協調フィルタリングのみであることがある。そのため、今後多くの異なる被験者、アイテム、アルゴリズムによって提案手法の有効性を検証する必要があるだろう。

6. まとめ

本研究では、推薦の目新しさという観点に注目し、目新しいアイテムを推薦することでユーザ満足度を向上させる推薦手法の構築を目的とした。我々は、嗜好傾向が類似するアイテムを複数推薦するよりも、嗜好傾向の異なるアイテムを複数推薦する方が、ユーザの知らないアイテムを推薦する可能性が広がるという仮定にもとづき、推薦リストの嗜好傾向の多様化により推薦の目新しさ (Novelty) を改善させる手法を新たに提案した。具体的には、まず、ユーザのアイテム評価情報をもとに、共評価が行われているアイテム同士をエッジで繋いだネットワークを生成する。つぎに、これをクラスタリングすることにより、嗜好傾向の類似するアイテムをトピックとして分類し、そのトピックが複数に及ぶようにアイテムを選定することで嗜好傾向の多様化を実現する。実験として、Amazon.co.jp のDVDアイテムを用いて多様化を行った推薦リストをユーザに提示し、ユーザ満足度のアンケートを行った。実験結果より、提案手法が既存のユーザベースの協調フィルタリング手法よりも、多くの「ユーザの知らない・好みのアイテム」を推薦できることを確認した。

7. 今後の課題

今後の課題として、一つめはユーザベースの協調フィルタリング以外でもトピックの多様化が有効であるかを検証することがある。協調フィルタリング手法の欠点として、評価されるアイテムに偏りが生じる「評価値疎ら問題」や、それにより運用の初期段階ではユーザの満足する推薦が得られないといった「cold-start問題」があげられる。そこで、今後はアイテムベースの協調フィルタリングや、あるいはコンテンツベースフィルタリングなどの協調フィルタリング以外を用いたときにも本手法が適用可能かどうかを比較検討していきたい。二つめとしては、正確さと目新しさ (Novelty) のトレードオフの問題についてより詳細な分析を行うことである。今回は、提案手法によりユーザの「知らない・好みのアイテム」を多く推薦できたが、その分、推薦の正確さ (ユーザの「知っている・好みのアイテム」の推薦) を犠牲にしている。今後、

推薦リスト全体への評価など、評価方法についても検討し、ユーザは推薦にどの程度の Novelty を求めるのか検証していきたい。

文 献

- (1) Linden, G., Smith, B. and York, J.: Amazon.com Recommendations: Item-to-Item Collaborative Filtering, IEEE Internet Computing, Vol.7, No.1 (2003)
- (2) Schafer, J., Konstan, J.A. and Riedl, J.: E - Commerce recommendation applications, Data Mining and Knowledge Discovery, Vol.5, pp.115- 153 (2001)
- (3) Sarwar, B., Karypis, G., Konstan, J. and Riedl, J.: Application of dimensionality reduction in recommender system, Proc. of ACM WebKDD Workshop (2000)
- (4) Ziegler, C., NcNee, S.M., Konstan, J.A. and Lausen, G.: Improving Recommendation Lists through Topic Diversification, Proc. of WWW2005, pp.22-32 (2005)
- (5) Herlocker, J., Konstan, J. and Riedl, J.: Evaluating collaborative filtering recommender systems, ACM Trans. Information Systems, Vol.22, No.1, pp.5-53 (2004)
- (6) McNee, S.M., Riedl, J. and Konstan, J.: Being accurate is not Enough: How Accuracy Metrics have hurt Recommender Systems, A Work-In-Progress paper in the Extended Abstracts of the 2006 ACM Conf.on Human Factor in Computing Systems (ACM SIGCHI), pp.1097-1101 (2006).
- (7) Resnick, P., Iacovou, N., Suchak, M., Bergstorm, P. and Riedl, J.: GroupLens: an open architecture for collaborative filtering of netnews, Proc. of ACM Conf. on Computer Supported Cooperative Work, pp.175-186 (1994)
- (8) Sarwar, B., Karypis, G., Konstan, J. and Reidl, J.: Item-based collaborative filtering recommendation algorithms, Proc. 10th International World Wide Web Conf. (ACM), pp.285-296 (2001)
- (9) 神鷹敏弘：推薦システムのアルゴリズム(1), 人工知能学会誌, Vol.22, No.6, pp.826-837 (2007)
- (10) Swearingen, K. and Sinha, R.: Beyond Algorithms: An HCI Perspective on Recommender Systems, ACM SIGIR Workshop on Recommender Systems (2001)
- (11) 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, 電子情報通信学会論文誌, Vol.93-D, No.3, pp.538-550 (2008)
- (12) 村上知子, 森紘一郎, 折原良平：推薦結果の意外性を評価する指標の提案, 人工知能学会全国大会 (第 21 回) 論文集, 2C5-2 (2007)
- (13) 戸田浩之, 北川博之, 藤村考, 片岡良治：グラフ分析を利用した文書集合からの話題構造マイニング, 電子情報通信学会論文誌, Vol.90-D, No.2, pp.292-310 (2007)
- (14) 松尾豊, 友部博教, 橋田浩一, 中島秀之, 石塚満：Web上の情報からの人間関係ネットワークの抽出, 人工知能学会論文誌, Vol.20, No.1E, pp.46-56 (2005)
- (15) 湯田聰夫, 小野直亮, 藤原義久：ソーシャル・ネットワークサービスにおける人的ネットワークの構造, 情報処理学会論文誌, Vol.47, No.3, pp.865-874 (2006)
- (16) Newman, M.E.J.: Fast algorithm for detecting community structure in networks, Phys. Rev. E, Vol.69, 066133 (2004)
- (17) Newman, M.E.J.: Detecting community structure in networks, Eur. Phys. J. B38, pp.321-330 (2004)
- (18) Newman, M.E.J.: Analysis of weighted networks, Phys. Rev. E70, 056131 (2004)
- (19) 安藤潤, 吉井伸一郎：WWWナビゲーション向けコミュニティ分割手法に関する一考察, 情報処理学会研究会報告, Vol.2006, No.2, pp.115-122 (2006)
- (20) Amazon Web Services:
<http://www.amazon.com/gp/aws/landing.html>