

アイテムに係る形容表現を用いたユーザ類似度測定

Measuring similarity of users using sentimental tags for items

中辻 真^{*1} 近藤 光正^{*1} 田中 明通^{*1} 内山 匡^{*1}
Makoto Nakatsuji Mitsumasa Kondo Akimichi Tanaka Tadasu Uchiyama

^{*1}日本電信電話株式会社サイバーソリューション研究所
NTT Cyber Solutions Laboratories

We try to accurately identify, to the active user, novel items that are included in taxonomy classes the active user does not access before. We introduce two types of taxonomy of items. First is a taxonomy of items created by experts in content providers (such as genres and creators) of each item. Second is a mood taxonomy of items created based on sentimental analysis against reviews on items. Then, we measure interests of users using both taxonomies. Especially, by using mood taxonomy, we can identify users who use same adjective words in their reviews with that of the active user though they rate on items in the different classes in the taxonomy. By analyzing items possessed by such identified users, we can predict items to the active user accurately.

1. はじめに

推薦システムは、ユーザにおすすめのアイテムを提示することでアイテムの売上を増やすことができる可能性を持つため、様々なコンテンツプロバイダで採用されている。多くのコンテンツプロバイダでは推薦技術として協調フィルタリングを採用している。協調フィルタリングは“同じアイテムを評価するユーザは類似した興味を持つ”という仮定に基づき、ユーザへおすすめのアイテムを提示する。しかし一般的な協調フィルタリングでは、ユーザの興味を、そのユーザが過去に高く評価したアイテムのみを用い決定し、同じアイテムを高く評価したかどうかを基にユーザ間の類似度を計測する。そのため、現状の推薦エンジンは、結果としてユーザが過去に評価したアイテムと同種のアイテムを推薦しがちである。たとえば、あるユーザがホラー映画のある作品を過去に購買していたとすると、そのユーザに同じ監督、同じ出演者、または、同じホラージャンルのアイテムが多く推薦される。結果として、ユーザにとっては、既知のアイテムであったり、未知のアイテムであったとしても自分自身で簡単に発見し得るアイテムであることが多い。また、推薦されるアイテムが被推薦ユーザにとって、どういう関係にあるのかがわかりにくく、推薦への納得感を与えづらい。

こうした問題に対し Ziegler と McNee は、ユーザに提示する推薦リスト内のアイテムの多様性を増やすアルゴリズムを提案している [Ziegler, & McNee 2005]。多様性はアイテムのタクソノミを用い計算され、リスト内のアイテムが所属するタクソノミ上のクラスがばらつくように設計されている。こうしたアイテムのタクソノミは、サービスプロバイダにより、彼らの顧客が興味あるアイテムにアクセスしやすいように工夫して構築されているものである。彼らのオンライン検証によると推薦の予測精度は落ちるものの、ユーザの満足度は向上することをアンケートで確認をしている。しかし彼らの研究は、“ユーザが過去にアクセスしたことの無いコンセプト(クラス)に所属しているが、興味を持つ可能性の高いアイテム”として定義される Novel アイテム [Nakatsuji, Yoshida, & Ishida 2009] を推薦する試みではない。

本研究では、Web 上のユーザの Review 記事を分析した結

果得られた (1) 同じアイテムを高く評価するユーザであってもアイテムを評価する際に用いる形容表現は多様であり、言い換えると、多様な感性をもってアイテムに接していること、また (2) アイテムの所属するクラスが異なっても同じ形容表現が与えられることが多いこと、という 2 つの知見を基に、ユーザに Novel アイテムを推薦可能とする手法を提案する。具体的には、ユーザ興味を、ユーザが評価したアイテムのみならず、ユーザがそのアイテムに対し与えた形容表現を用いてモデリングする。そして、従来の協調フィルタリングにおけるように、ユーザが評価したアイテムのみからユーザ間の類似度を計算するのではなく、ユーザが評価したアイテムに対し与えた形容表現も用いユーザ間の類似度を計算できるようにすることで、結果として、同じ感性を持つユーザが高く評価するアイテムが、推薦を享受するユーザ(以下、アクティブユーザ)に推薦可能となる。これにより、アクティブユーザに対し今までは推薦できなかった Novelty の高いアイテムが推薦可能になると考えられる。

上述した目的を達成するため本研究では、まず、ユーザがアイテムに対しどのような形容表現を用い評価をしているかを分析する。本研究では、アイテムの内容をアイテムに与えられているメタデータを基に表現し、ユーザの記述した Review を用い、アイテムのメタデータの属性値に対する sentimental analysis を行うことで、ユーザがアイテムに対しどのような感性を持って評価を下しているかを解析する。それを全ユーザを対象にし実施した上で、形容表現をクラス(以下、感性クラスと呼ぶ。コンテンツプロバイダが提供するタクソノミにおけるクラスとは本研究では区別する。)としアイテム集合を各クラスに分類した、感性を軸としたアイテムのタクソノミ(以下、感性タクソノミと呼ぶ。コンテンツプロバイダが構築したジャンルなどをクラスとして保持するタクソノミとは異なるので注意。)を設計する。形容表現の抽出は、あるサービスドメインに属する全ユーザ/全アイテムの Review 記事を用い実施することとし、結果として、そのドメインで使用される形容表現を網羅的に抽出した上で、感性クラスを持つ感性を軸とした感性タクソノミを、ドメイン毎に一つ設計する。

次に、著者らの先行研究であるタクソノミに基づくユーザ興味モデリング手法 [Nakatsuji, Yoshida, & Ishida 2009] を発展させ、感性タクソノミを用いたユーザ興味モデリングを行

う。ユーザがどのような感性を持ってアイテムに接しがちであるかを分析するために、ユーザがアイテムに与えた評価値をアイテムの所属する感性クラスの評価値として反映する。こうすることで、ユーザ間で共通して評価したアイテムのみでなく、評価の際に用いていた形容表現まで考慮して、ユーザ間の類似度を計測できる。なお、本研究では、ユーザの評価値は、ユーザが用いた形容表現に対応する感性クラス配下のアイテムにのみ反映されることに注意する。アイテムに対する評価のみでなく、アイテムに対し与えた形容表現も共通するユーザを類似ユーザとして取り扱えるため、結果として、“多様なクラスに所属するアイテムを精度よく”ユーザに推薦でき、Novel アイテムの推薦につながると考える。たとえば、図1において、 I_1 と I_3 や、 I_2 と I_4 はプロバイダが提供するタクソノミにおいては、異なるクラスに所属するが感性タクソノミ上では同じ感性クラスに所属するため、これまでのタクソノミを用いた類似度計算手法では類似すると考えることができなかったユーザ u とユーザ v を、アイテムを評価する際に用いた形容表現が同じであることから、類似すると計算することができ、結果として、Noveltyの高いアイテム I_4 をユーザ u へ推薦することができる。また、感性と興味の両面から類似度を計算するため、推薦の精度も向上すると考えている。

実験においては、tabelogのデータセットを用い、ユーザがアイテム(レストラン)に与えた評価値と、ユーザがアイテムを評価する際に与えたReviewを用いたsentimental analysisを元に、アイテムに対しユーザがどのような感性で接したかを分析したデータを利用した。結果として提案手法が、感性タクソノミを用いない従来の協調フィルタリング手法と比べて精度よくユーザの評価値を予測できることを確認した。

2. 関連研究

アイテムのタクソノミを用いることで推薦の予測精度の向上を試みる研究がある[Ziegler, Lausen, & Thieme 2004]。そして、アイテムの評価データが少ない場合、他ユーザの評価との共起が起きにくくユーザ間の類似度の計測が困難となり、結果として推薦精度が落ちてしまう sparsity problem に効果があることを示した。

Noveltyの高いアイテムを推薦する研究として Nakatsujiら[Nakatsuji, Yoshida, & Ishida 2009]は、タクソノミに基づき Noveltyの高いアイテムを推薦する手法を提案している。そしてオンライン検証において、ユーザのクリックが Noveltyの高いアイテムに集中したことを報告している。

3. 協調フィルタリング

従来の協調フィルタリングにおいてユーザ間の類似度を計測する際には、Cosine ベースアプローチ[Breese, Heckerman, & Kadie 1998]と Pearson correlation アプローチ[Resnick, Iacovou, & Suchak 1994]を用いることが多い。Pearson correlation アプローチでは、アクティブユーザ a とあるユーザ u の間の類似度 $S(a, u)$ は、両方のユーザが評価を与えているアイテム数を M とし、ユーザ u のアイテム I_i に対する評価値を r_{u, I_i} とすると、以下の式であらわされる。

$$S(a, u) = \frac{\sum_i^M (r_{a, I_i} - \bar{r}_a)(r_{u, I_i} - \bar{r}_u)}{\sqrt{\sum_i^M (r_{a, I_i} - \bar{r}_a)^2} \sqrt{\sum_i^M (r_{u, I_i} - \bar{r}_u)^2}} \quad (1)$$

ここで \bar{r}_u は、ユーザ u のアイテムへの評価値の平均値を示す。Cosine ベースアプローチでは、上式の \bar{r}_a , \bar{r}_u に0を代

入することで類似度を計算できる。最終的に N をアクティブユーザ a と類似度の高いユーザの数とすると、 a のアイテム I_i に対する予測値 P_{a, I_i} は、以下の式2で与えられる。

$$P_{a, I_i} = \bar{r}_a + \frac{\sum_u^N (r_{u, I_i} - \bar{r}_u) S(a, u)}{\sum_u^N S(a, u)} \quad (2)$$

4. 提案手法

まず、ユーザの感性の傾向を踏まえユーザ興味モデリングを行い、次にユーザ間の類似度計測法について述べる。

4.1 ドメイン内での形容表現の抽出

まず、あるドメイン \mathcal{D} において、アイテムを評価するのに用いる形容表現 s のセットを $S_{\mathcal{D}} = (s_1, \dots, s_n)$ と表す。 n は \mathcal{D} における形容表現の数である。ユーザが \mathcal{D} 内に存在するアイテムに対し持ち得る感性を過不足なく持つことが、そのドメインにおけるユーザ興味を詳細に表現することにつながるため、 \mathcal{D} において利用される形容表現は網羅的に準備されている必要がある。一方、各サービスプロバイダは、自身の提供するサービスに対するReviewをユーザに記述してもらうことで、それを見たユーザのアイテムに対する関心を引き付けることを狙い、ユーザにReviewを記述してもらうことが多くなっている。食べログやamazonなどのサイトでは、こうしたReviewが非常に多く記述されるようになっている。Reviewが大量に存在する場合、Reviewからアイテムに対する形容表現を抜き出せば、網羅性は担保できる。

Reviewからのsentimental analysisについては、本稿におけるメインピックではないため、簡潔に説明する。詳細な内容は、[中辻, 吉田, & 平野 2007]を参照頂きたい。sentimental analysisを行う際、我々はサービスプロバイダがアイテムに与えているメタデータを用い、アイテムのみでなく、アイテムに与えられたメタデータに対し形容表現が関連付けられたかどうかを分析する。例えば、映画に対しては、メタデータとして、タイトル、役者、監督、脚本、製作国、製作年などがプロバイダから与えられている情報としてある。また、グルメに関しては、店舗名、メニュー、住所などがある。このうち、例えばタイトルや役者、監督および、店舗名やメニューは、レビューにおいて話題となりうる対象であるため、それらに対する形容表現の解析を実施した。製作国、製作年および住所は、それ自身が話題になることは少ないと考え解析対象から外した。その上で、具体的な関連付けの分析は、文献[中辻, 吉田, & 平野 2007]の方法を用い、最終的に、アイテムに結びつく複数メタデータに対する解析結果からアイテムに対し紐づけられる感性表現を抽出した。特に今回の解析対象は、Blogではなく、Reviewということもあり、ユーザの記述対象であるアイテムの揺れを考慮する必要がないことから、解析の精度は非常によく、約90%程度の適合率を持つ。こうして得られた形容表現をセットとして対象ドメイン \mathcal{D} における形容表現 s のセットを $S_{\mathcal{D}} = (s_1, \dots, s_n)$ を構築した。

4.2 アイテムの感性タクソノミ構築

アイテムの感性タクソノミとしては、 $S_{\mathcal{D}} = (s_1, \dots, s_n)$ 内の形容表現を感性クラスととらえ、その配下に対応する形容表現に關係付けられたアイテムを分類していくことで、感性タクソノミを構築できる。また、 $S_{\mathcal{D}} = (s_1, \dots, s_n)$ をさらに階層化することで、ユーザの持ち得る感性の傾向をより詳細に解析することもできる。

ユーザにとっても、プロバイダが構築しているジャンルなどを軸としたアイテムのタクソノミと同じく、ユーザ自身の興味




図 1: ユーザ興味モデリング例

あるアイテムに容易にアクセスするための一手段を提供できるため、重要な試みであると考えられる。こうした感性表現を階層化する試みとしては、サービスレベルですでに始まって来ており、allmusic^{*1}においては、そうした感性タクソノミに基づくアイテム検索手段をユーザに提供している。しかし、こうした感性タクソノミの構築は、感性自身がユーザ毎に揺れの大きい対象であるため、妥当な体系を構築するための指針が提示されていないのが現状である。

4.3 感性を考慮したユーザ興味のモデリング

ユーザの興味が感性タクソノミに沿ってモデリングする。具体的には、アイテムに対するユーザの評価値をそのアイテムを含む感性クラスに対する評価値に反映させる。その際、ユーザがそのアイテムに対して用いた形容表現に対応する感性クラス配下のそのアイテムのみに評価値を反映することに注意する。 \mathcal{I} を感性クラス C_i に対応する形容表現を用いて、ユーザ u が評価を行ったアイテムセットとすると、クラスに対する評価値 r_{u,C_i} は、 $\sum_{I_i \in \mathcal{I}} r_{u,I_i}$ として計算される。たとえば図1において、ユーザ u がアイテム I_1 を感性クラス C_4 に対応する形容表現を用いてReviewを記述しつつ評点4.0をつけ、同様にしてアイテム I_2 に評点4.5をつけてるとすると、クラス C_4 に対する u の評点は4.0、クラス C_5 に対する u の評点は4.5となる。感性クラスの親クラスに対する評価値は、各アイテムに対する評価値の変わりに各クラスに対する評価値を用いることで同様にして計算される。これは、感性タクソノミの階層が(Rootを1階層目として)3階層以上の場合においてであるが、我々の検証や図1の例では、階層が2階層しかないため、各クラスに対する評価値を親クラスに反映させる必要はない。

一方、プロバイダが構築しているタクソノミもユーザ興味のモデリングに用いる。様々なコンテンツプロバイダが、自身の提供するアイテムのタクソノミを構築し始めている。たとえば、音楽、映画、ゲームなどのアイテムのタクソノミは、上述したallmusicなどにおいて構築済みである。こうしたタクソノミはユーザがアイテムを自身の興味に沿って検索しやすいように、クラスの粒度や分岐数を適切に研究して設計されているため、このタクソノミを用いてユーザ興味をモデリングするのは合理的なアプローチであると我々は考える。そこで、感性タクソノミ以外にプロバイダ提供のタクソノミも用いユーザ興味をモデリングする。

アプローチとしてはあるアイテムに興味を持つユーザは、そのアイテムを含むクラスにも興味を持ちうるという考えに基づき、アイテムに対するユーザの評価値をそのアイテムを含むクラスに対する評価値に反映させる。アイテムに対する評価値は

アイテムへのユーザのアクセス頻度に沿って潜在的な評価値として割り当てられる場合と、ユーザ自身によって明示的に与えられる場合がある。

\mathcal{I} をクラス C_i におけるアイテムセットとすると、クラスに対する評価値 r_{u,C_i} は、 $\sum_{I_i \in \mathcal{I}} r_{u,I_i}$ として計算される。たとえば図1において、ユーザ u がアイテム I_1 に評点4.0をつけ、アイテム I_2 に評点4.5をつけてるとすると、クラス C_2 に対する u の評点は8.5となる。親クラスに対する評価値は、各アイテムに対する評価値の変わりに各クラスに対する評価値を用いることで同様にして計算される。

本研究では、感性タクソノミに基づくユーザ興味と、プロバイダタクソノミに基づくユーザ興味は、双方の親クラス(図1の例では、Rootクラス)でマージすることとする。これにより、ユーザ毎の感性を考慮した興味をモデリングできる。

感性タクソノミとプロバイダ提供のタクソノミに基づくユーザ興味を組み合わせることで、ある感性の傾向を持つユーザは、あるジャンルを好む傾向がある、という情報を取ることができる。また感性情報を用いることで、プロバイダ提供タクソノミにおけるクラスを跨った興味の関連を見付けることができ、1章でも説明したように、Novelなアイテム推薦に繋がると考える。たとえば、図1の例において、アイテム I_1 や I_2 に興味を持つユーザ u はプロバイダ提供のタクソノミでは、同一のクラス C_2 にしか興味を持っていないため、類似ユーザの計算の際に、 C_2 に興味を持つユーザが多く結果として出力され、推薦結果としても C_2 配下のアイテムが多く推薦されがちになってしまうが、感性タクソノミを加えることで、たとえば感性クラス C_4 や C_5 を介して(アイテム I_1 と I_2 がそれぞれ感性クラス C_4 と C_5 に所属しているため)、ユーザ v と興味が類似することになり、結果として、ユーザ v が興味を持つクラス C_3 に属するアイテム I_3 や I_4 も、ユーザ u への推薦対象に加わることになる。

4.4 ユーザ間の類似度計測

次に、ユーザ a と u の類似度計測法を説明する。まず提案手法のアプローチを説明し、次に提案アルゴリズムを説明する。提案手法のアプローチ提案手法のアプローチを説明する。

- まず、ユーザ a と u のクラス C_i に対する興味の一致度 $S(a, u, C_i)$ を計算する。このスコアは、 r_{a,C_i} と r_{u,C_i} の内、小さい方の値を基に計算する。これにより興味の一致度の計算の際に、 C_i に対する興味が a より低いユーザのスコアを下げるができる。
- 次に a と u の間での、クラスに対する評価行為の類似度 $S_C(a, u)$ を $S(a, u, C_i)$ を用い計算する。その際Jaccard coefficientの考え方をを用いる。このJaccard coefficientアプローチは“ユーザ a と u のどちらかのみが評価を与えているクラス集合”の内、“両方が評価を与えているクラス集合”がどれだけの割合を占めているかを計算できる。これは言い換えると、タクソノミのクラス階層の中(例では、 C_i の子クラスの中)での、ユーザの興味の“幅”の類似度を考慮しているといえる。これによりアクティブユーザ a がそれほど多くのクラスに評価を割り当てていない場合、多くのクラスに評価を割り当てているユーザ u を、 a から分離することができる。
- 次に、 a と u の間でのアイテムに対する評価行為の類似度 $S_I(a, u)$ を前手順と同様に計算する。

*1 <http://www.allmusic.com/>

- 最後に、上述した2つの類似度 $S_C(a, u)$ と $S_I(a, u)$ を組み合わせ、ユーザ間のクラス、アイテムに対する評価行為の類似度を計算する。

アルゴリズム提案手法のアルゴリズムを以下に説明する。本アルゴリズムにおいては、 $C_i(a)$ をユーザ a が評価したクラス C_i の子クラス集合として定義する。

- まずユーザ a と u のクラス C_i に対する興味の一致度 $S(a, u, C_i)$ を、 $\min(r_{a,C_i}, r_{u,C_i})$ とする。
- 次に、クラスに対するユーザ間の評価行為の類似度 $S_C(a, u)$ を以下の式により計算する。

$$S_C(a, u) = \sum_C \frac{\sum_{C_j \in \{C_i(a) \cap C_i(u)\}} S(a, u, C_j)}{|C_i(a) \cup C_i(u)|} \quad (3)$$

- また、アイテムに対するユーザ間の評価行為の類似度 $S_I(a, u)$ を、前手順と同様にして計算する。クラス C 内のサブクラスの変わりにアイテムを対象に、上式を適用すればよい。
- そして、 $S_C(a, u)$ と $S_I(a, u)$ を全ユーザ集合を母集合としガウス分布に正規化をした上で、ユーザ間の類似度 $S(a, u)$ を $S_C(a, u) + S_I(a, u)$ として計算する。

5. 検証実験

今回用いたのは、グルメサイト食べログ^{*2}における2010年1月2日までに蓄積された、東京、埼玉、神奈川の1都2県の74,031件のレストランに対する44,165ユーザの495,919のReviewを用いた。今回は、食べログから提供されたデータとして、各Reviewの先頭100文字のみしか利用できなかったため、Sentiment analysisもその範囲で行っている。結果として、全評価の中で、獲得できた形容表現は318個である。特に今回の検証では全Reviewの中で、形容表現を3回以上、アイテム評価の際に用いているユーザ1015人へのみ絞り検証を実施した。なお、その場合でも、Review全体の中で、2.9%のみに形容表現は紐づく。今回の実験では、感性タクソノミの効果を測ることを目的としているため、プロバイダ提供のジャンルに基づくタクソノミは利用していない。

5.1 検証基準

検証を実施するにあたり、まずユーザのアイテムに対する評価データセット D を、ランダムに訓練用データセット T と予測先データセット P に分離した。結果として、 T においては評価を与えられていないクラスを P には持つユーザが得られる。そして、4.で提案した方法に従い訓練用データセット T を用い、ユーザの興味をモデリングし、ユーザ間の類似度を計測し、式2を用い最終的なユーザ毎へのアイテムの予測値を計算した。なお、 T の作成において $\frac{T}{D}$ が、0.5となるように訓練用データを設定し結果を検証した。

一般的に協調フィルタリングの検証において用いられている検証基準を採用し、本論文では P 内のアイテムに対する予測値と実際の評価値との誤差を示す指標である Mean Absolute Error (MAE) を用いる。この指標は $MAE = (\sum_{i=1}^n |P_i - R_i|) / n$ とあらわされる。ここで、 n は P 内のエントリの数であり、 P_i

表 1: 映画データセットに対する MAE

| | Pearson | Cosine | Our method |
|-----|---------|--------|------------|
| MAE | 0.528 | 0.540 | 0.515 |

と R_i は、それぞれ、各エントリ i に対する予測値と実際の評価値である。

その上で、提案手法を Pearson correlation coefficient (Pearson) と Cosine-based approach (Cosine) とで比較した。

5.2 精度に対する検証結果

まずユーザ数 N を変え検証を実施した。その結果、 N を40以上にしても精度はそれほど変わらず徐々に悪くなる傾向があったため、 N を上述した値に設定をした。表1にMAEを示す。これより、提案手法は、Pearson や Cosine に比較し、精度良くアイテムを推薦できていることが分かる。これにより、ユーザがアイテムを評価する際に用いる形容表現まで考慮し、ユーザ類似度を計測することは、より良い精度でアイテムの推薦を行える可能性を示すことができた。

今後の課題として、提案手法では、アイテムが一致していても、感性クラスが一致しない限り、ユーザ間の類似度を計算できないことから、類似するユーザ数が少なくなる、という問題に取り組む必要がある。それは、従来の Pearson と提案する感性クラスに基づく類似度計測法を組み合わせることで解決できると考えられる。また、本研究の目的である、Novelty の高いアイテムの推薦効果の検証はまだ出来ていないことから、継続的に検証を続ける。

6. まとめ

協調フィルタリングは、同一アイテムを評価したユーザは、興味類似すると仮定し、類似ユーザを分析し、アイテムの推薦値を計算するが、同種のアイテムが推薦され novel なアイテム推薦が難しい。本研究は、アイテムを評価する際に記述する Review 上での、アイテムにかかる形容表現の頻度を分析し、評価アイテムに係る形容表現の傾向も考慮し、ユーザ類似度を計算し、novelty の高いアイテムの推薦実現性を分析する。食べログのデータを用いた評価実験により、形容表現まで考慮した類似度計算を行うことで、推薦精度が改善されること、Novelty の高いアイテムが推薦に含まれる割合が増えることを確認した。

参考文献

- Breese, J. S., Heckerman, D. and Kadie, C.: Empirical Analysis of Predictive Algorithms for Collaborative Filtering, In *Proc. UAI '98*, pp. 43–52 (1998).
- Nakatsuji, M., Yoshida, M. and Ishida, T.: Detecting innovative topics based on user-interest ontology, *J. Web Sem.*, Vol. 7, No. 2, pp. 107–120 (2009).
- Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P. and Riedl, J.: GroupLens: An Open Architecture for Collaborative Filtering of Netnews, In *proc. CSCW '94*, pp. 175–186 (1994).
- Ziegler, C. N. and McNeel, S. M.: Improving recommendation lists through topic diversification, In *proc. WWW '05*, pp. 22–32 (2005).
- 中辻真, 吉田誠, 平野美貴: 話題対象のクラス知識を活用した CGM からの感性解析技術, In *proc. DBSJ Letters*, Vol. 6, No. 1 (2007).

*2 <http://tabelog.com>