

協調フィルタリングにおける閾値とペナルティ項の導入によるトラスト算出法の改良

1X10C019-6 梅沢宏之
指導教員 後藤正幸

1 研究背景と目的

情報技術の進展により、EC サイトで扱われるアイテムは増加の一途を辿っており、個人の嗜好に合うアイテムを推薦する推薦システムが注目を浴びている。その代表的な手法として、ユーザの類似性から被推薦ユーザの好むアイテムを予測する協調フィルタリング (以下 CF) がある。CF には様々な手法が存在するが、あるユーザの評価値のみをもとに被推薦ユーザの評価値を予測したときの精度の良さ (以下トラスト) を CF に適用した研究が存在する [1]。トラストはユーザ間の共通評価アイテムの評価値をもとに算出する必要があるため、通常は共通評価アイテムのないユーザ間のトラストは求めることができない。一方、Local-CF- n と呼ばれる手法 [1] では、共通評価アイテムがないユーザ間のトラストも、共通評価アイテムのある第三ユーザを経由させる (以下伝搬) ことで間接的に算出を可能としている。これにより各ユーザに対する予測評価可能アイテムを増加させることができる。しかし、この手法には問題点が 3 点ある。1 点目は、ユーザ間の共通評価アイテム数が極端に少ない場合、それらの評価値にのみ依存した信頼性の低いトラストをつけてしまう点、2 点目は、第三ユーザを介した伝搬により間接的に算出されるトラストを用いるため、精度の低い他ユーザ間のトラストが混入することの影響が大きい点、3 点目は直接トラストが算出できる場合であっても間接的なトラストを用いるためにトラストの信頼性が低下する点である。

そこで本研究では、トラスト算出時の共通評価アイテム数に対して閾値を設けることで、十分な数の評価値をもとにトラストを算出し、また、トラスト伝搬時にペナルティ項を付与することで、本来トラストが低いユーザ間の値が高く算出されることを防ぐよう調節する。加えて、直接トラストが算出できる場合はその値を用いる手法を提案し、予測精度の向上を図る。これらから、提案手法を推薦システムのベンチマークデータに適用し、その有効性を示す。

2 トラストによる推薦システム

推薦システムとは、ユーザの評価履歴や購買履歴からユーザの嗜好を推定し、嗜好に合うアイテムを推薦するシステムのことである。いま、アイテム集合を $\mathcal{I} = \{I_i : 1 \leq i \leq I\}$ 、ユーザ集合を $\mathcal{U} = \{U_j : 1 \leq j \leq J\}$ 、ユーザ U_j の既評価アイテム集合を \mathcal{D}_j と定義する。また、 $r_{j,i}$ をユーザ U_j によるアイテム I_i の評価値とし、 G 段階評価で g 点の評価をした場合は g 、未評価の場合は欠損値をとるものとする。

従来手法 [1] では、トラスト算出のため、2 ユーザ間の共通評価アイテムに着目し、一方の評価値をもとにした他方の評価値予測を相互に行う。これにより得られた予測値と実測値の差をもとに 2 ユーザ間での直接的なトラスト (以下 d -トラスト) を算出する。さらに、 d -トラストをもとに第三ユーザを経由した間接的なトラスト (以下 p -トラスト) を求める。 d -トラストは用いずに、この p -トラストのみを用いて最終的な予測評価値計算を行う。

まず、共通評価アイテムがあるユーザ間の d -トラストを算出する。ユーザ U_b の評価値をもとにしたユーザ U_a の評価アイテム I_i に対する予測評価値 $p_{a,i}^b$ を次式で算出する。

$$p_{a,i}^b = \bar{r}_a + (r_{b,i} - \bar{r}_b) \quad (1)$$

ただし、 \bar{r}_j はユーザ U_j の平均評価値を表す。なお、この計算は 2 ユーザ間の全共通評価アイテムに対して行われる。こ

こで得られた予測値と実測値との差をもとにして、ユーザ U_a とユーザ U_b 間の d -トラスト $T_{a,b}$ を式 (2) により算出する。

$$T_{a,b} = \frac{1}{H_{a,b}} \sum_{I_i \in \mathcal{D}_a \cap \mathcal{D}_b} \left(1 - \frac{|p_{a,i}^b - r_{a,i}|}{G-1} \right) \quad (2)$$

ただし、 $H_{a,b}$ はユーザ U_a とユーザ U_b の共通評価アイテム数を表す。なお、 d -トラストは $H_{a,b} > 0$ の場合に算出する。

次に式 (2) の情報をもとに、中間に第三ユーザを経由した場合の間接的なトラストを式 (3) の伝搬式により算出する。ユーザ U_a とユーザ U_b が中間ユーザ n 人で接続できる場合、 p -トラスト $T_{a,b}^n$ を式 (3) により算出する。

$$T_{a,b}^n = \frac{1}{Q_{a,b}^n} \sum_{h=1}^{Q_{a,b}^n} \frac{H_{a,m_1^h} T_{a,m_1^h} + H_{m_1^h, m_2^h} T_{m_1^h, m_2^h} + \dots + H_{m_{h-1}^h, m_h^h} T_{m_{h-1}^h, m_h^h}}{H_{a,m_1^h} + H_{m_1^h, m_2^h} + \dots + H_{m_{h-1}^h, m_h^h}} \quad (3)$$

中間ユーザとしてどのユーザを経由するかのパターンは複数考えられるため、そのパターン数を $Q_{a,b}^n$ で表す。また、 m_j^h を h 番目の経由パターンの j 人目の中間ユーザとする。式 (3) より、中間ユーザを経由することで算出できる間接的なトラストの全経由パターンの平均値を p -トラストとする。

p -トラストを用いて、アイテム I_i に対するユーザ U_a の予測評価値 $\hat{p}_{a,i}$ を式 (4) により算出する。

$$\hat{p}_{a,i} = \bar{r}_a + \frac{\sum_{U_k \in \mathcal{F}_a} (r_{k,i} - \bar{r}_k) T_{a,k}^n}{\sum_{U_k \in \mathcal{F}_a} T_{a,k}^n} \quad (4)$$

ただし、 \mathcal{F}_j はユーザ U_j との間に p -トラストが算出されているユーザ集合を表す。

3 提案手法

3.1 従来手法の問題点

予測精度を向上させるためには信頼性の高いトラストの付与が必要であるが、従来手法には次の 3 点の問題がある。

1. トラストの算出時に、ユーザ間の共通評価アイテムが極端に少ない場合でも、それらの評価値にのみ依存した信頼性の低いトラストを式 (2) により直接算出してしまふ。これは、共通評価アイテムが偶然大気アイテムであり 2 ユーザ間の評価値が近い場合、その他のアイテムに評価がされていない場合、高いトラストを付与してしまうようなケースを指す。
2. 伝搬時に本来トラストが高くないユーザ間に高いトラストが付与されてしまう可能性がある。例えば、ユーザ U_a 、 U_b 、 U_c の三者間でのトラスト算出を考えた場合、ユーザ U_a と U_c 間のトラストが低い場合でも、ユーザ U_c と U_b 間のトラストが非常に高い場合、式 (3) の構造上、ユーザ U_a と U_b 間のトラストも相対的に高い値をとってしまう。付与するトラストの信頼性が低下するという問題である。
3. d -トラストが算出できるユーザ間に対しても p -トラストを用いている。 d -トラストにより直接ユーザ間の関係を考慮できるにも関わらず、 p -トラストを用いることで信頼性の低いトラストを付与してしまうことが問題である。

3.2 提案手法の概要

提案手法では、上記の問題に対し、 d -トラスト算出時の共通評価アイテム数の閾値の設定と伝搬による p -トラスト算出時のペナルティ項の付与を行う。

d -トラスト算出時の問題に対しては、提案手法では共通評価アイテム数に閾値を設定し、閾値以上の共通評価アイテムがあるユーザ間のみで d -トラストを算出する。十分な数の評価情報をもとにトラストを算出することで、トラストの信頼性が高まる。なお、閾値に満たないユーザ間に対しては、伝搬により閾値以上の共通評価をしているユーザのみを経由することで信頼性の高いトラストを間接的に算出できると考えられる。

伝搬の問題に対しては、伝搬により算出された p -トラストに対してペナルティ項を付与することで、中間ユーザの影響を受ける信頼性の低い p -トラストが低く算出されるように調節する。加えて、従来手法では全ユーザ間に対して p -トラストを用いているが、伝搬の際に、中間ユーザの影響により信頼性の低い p -トラストが付与される可能性がある。このため、提案手法では閾値以上の共通評価アイテムがあるユーザ間で d -トラストが算出できる場合には第三ユーザを経由した伝搬を行わずに d -トラストを利用する。

3.3 提案手法の手順

提案手法では、共通評価アイテム数 $H_{a,b}$ と閾値 μ によってユーザ U_a とユーザ U_b 間のトラストの求め方が異なる。 $H_{a,b} \geq \mu$ の場合は式 (1) により予測を行った後に、ユーザ U_a とユーザ U_b 間でトラストを直接算出し、 $H_{a,b} < \mu$ の場合はトラストを直接算出せずに、伝搬によりトラストを間接的に算出する。

まず、式 (5) により、共通評価アイテム数が閾値 μ 以上の場合のみ d -トラストを算出し、閾値未満の場合には d -トラストを 0 とする。

$$T_{a,b}^0 = \begin{cases} \frac{1}{H_{a,b}} \sum_{I_i \in \mathcal{D}_a \cap \mathcal{D}_b} \left(1 - \frac{|p_{a,i}^b - r_{a,i}|}{G-1} \right) & (H_{a,b} \geq \mu) \\ 0 & (H_{a,b} < \mu) \end{cases} \quad (5)$$

続いて、式 (6) により中間ユーザが n 人のときの伝搬を行う。ここでは、 $H_{a,b} < \mu$ の場合のみ伝搬によりトラストを算出する。ユーザ U_a とユーザ U_b が中間ユーザ n 人で接続できる場合、 p -トラスト $T_{a,b}^n$ を式 (6) により算出する。

$$T_{a,b}^n = \begin{cases} \frac{\frac{1}{Q_{a,b}^n} \sum_{h=1}^{Q_{a,b}^n} \rho \times (H_{a,m_1^h} T_{a,m_1^h}^0 + H_{m_1^h, m_2^h} T_{m_1^h, m_2^h}^0 + \dots + H_{m_n^h, b} T_{m_n^h, b}^0)}{H_{a,m_1^h} + H_{m_1^h, m_2^h} + \dots + H_{m_n^h, b}} & (T_{a,b}^{n-1} = 0) \\ T_{a,b}^{n-1} & (T_{a,b}^{n-1} \neq 0) \end{cases} \quad (6)$$

ただし、閾値以上の共通評価をしているユーザを経由したパターン数を $Q_{a,b}^n$ 、 h 番目の経由パターンの j 人目の中間ユーザを m_j^h とする。また、 $\rho (0 < \rho \leq 1)$ はペナルティ項を示す。なお、 $T_{a,b}^{n-1} \neq 0$ の場合にはその値をそのまま $T_{a,b}^n$ として採用しているのは、伝搬により信頼性の低いトラストが付与される可能性を削減させるためである。

式 (6) により算出されたトラストを用いて、式 (7) により予測評価値を算出する。

$$\hat{p}_{a,i} = \bar{r}_a + \frac{\sum_{U_k \in \mathcal{F}_a} (r_{k,i} - \bar{r}_k) T_{a,k}^n}{\sum_{U_k \in \mathcal{F}_a} T_{a,k}^n} \quad (7)$$

4 実験

4.1 実験条件と評価方法

実験には、MovieLens の映画評価データを用いた。ユーザ数 $J = 943$ 、アイテム数 $I = 1682$ 、 $G = 5$ 、総データ数 10 万件である。また、ユーザは最低 20 件以上のアイテムを

評価している。データセットはランダムに学習データ 8 万件、テストデータ 2 万件に分割したものを 5 セット利用した。これらに各手法を適用し、未評価アイテムに対する予測評価値を算出し、推薦システムの評価指標である MAE (平均絶対誤差) によって評価を行う。MAE は次の式 (8) で表される。

$$MAE = \frac{1}{W} \sum_{j=1}^J \sum_{i=1}^I \delta_{j,i} |r_{j,i} - \hat{p}_{j,i}| \quad (8)$$

ただし、 W はテストデータ数とし、 $\delta_{j,i}$ はテストデータ $r_{j,i}$ が存在する場合は 1、存在しない場合は 0 を示すインジケータ関数である。MAE は予測評価値と実際の評価値との誤差を表すため、MAE の値が低いほど精度が高いことを示す。

実験 1 では、提案手法に対して、予備実験で得られた最良のペナルティ項 $\rho = 0.85$ 、中間ユーザ数 $n = 1$ を適用し、閾値 μ による MAE の差異を検証する。実験 2 では、提案手法に対して、さらに、実験 1 で得られた最良の閾値 $\mu = 4$ を適用し、CF の一般的な手法である相関係数法、従来手法との比較を行った。

4.2 実験結果と考察

図 1 に閾値 μ と MAE の関係、図 2 に提案手法と比較手法を MAE で比較した結果を示す。




図 1. 閾値と MAE




図 2. MAE の比較

図 1 より閾値 μ により MAE が変化することがわかる。 $\mu = 4$ で予測精度が最良になっているのは、閾値を低くし過ぎると人気アイテムなどに影響を受け、ユーザ間のトラストの信頼性が低下する一方、高くし過ぎるとトラスト算出に必要な評価情報が減ってしまうためと考えられる。

図 2 より提案手法は評価値予測精度の面で従来手法よりも優れた結果を示すことがわかる。これは、閾値の導入により、十分な数の評価値をもとにした信頼性の高い d -トラストを算出でき、ペナルティ項の導入により、本来はトラストの高くないユーザ間の p -トラストが高く算出されることを防ぎ、信頼性の高い p -トラストを付与できたためと考えられる。

また、実験 2 において提案手法では d -トラストを算出できたユーザの割合は全体の 66.2% であった。このことから、従来手法では評価値予測の際に全く用いられていなかった d -トラストを p -トラストに優先して用いたことの効果も大きかったと考えられる。

5 まとめと今後の課題

本研究ではトラストを用いた CF において、共通評価アイテム数の閾値を設け、伝搬時にペナルティ項を付与した手法を提案し、実験によりその有効性を示した。今後の課題として、データに合わせた最適なペナルティ項の決定アルゴリズムの提案が挙げられる。

参考文献

[1] C. Hwang and Y. Chen, "Using Trust in Collaborative Filtering Recommendation," *IEA/AIE 2007 LNAI 4570*, pp.1052-1060, 2007.