

ユーザの評価傾向と潜在クラスを考慮した推薦手法に関する研究

1X07C032-1 大森 悠矢
指導教員 大野 高裕

1 研究背景と目的

近年、インターネットの普及により Amazon 等のインターネット通販サイトが増加してきている。その売上を増加させるため、ユーザの嗜好に合うと予測されるアイテムを提示する推薦システムが数多く導入されている。推薦システムは、ユーザの購買履歴とアイテムのメタデータを利用して未購買アイテムに対しての予測評価値を求め、それを利用して推薦するアイテムを決定する。したがって、正確に評価値を予測することが重要であり、そのための研究が盛んに行われている [1]。その代表的な評価値予測モデルの 1 つに Latent Interest Semantic Map(LISM) がある [2]。LISM の特徴は、観測変数の背後に潜在変数を仮定し、類似しているアイテム同士、ユーザ同士をセグメント分けする潜在クラスを用いて、アイテムの評価値を予測する点にある。しかし、同じアイテムを好むユーザ同士であっても、全体的に高い評価値をつけるユーザや全体的に低い評価値をつけるユーザなど、評価の基準はユーザによって偏りが生じる方が一般的である。本来、同じ嗜好を持つユーザは同じ潜在クラスに所属すべきであるが、これらは異なる評価値分布をもつため LISM では別の潜在クラスに所属する可能性がある。そのため、パラメータの推定値にも悪影響を及ぼし、評価値の予測精度低下に結びついていると考えられる。

そこで本研究では評価値の偏りを考慮した推薦手法を提案し、シミュレーション実験による評価から提案手法の有効性を示す。

2 LISM を用いた推薦手法

LISM とはユーザとアイテムにそれぞれ潜在クラスを設け、未購買アイテムに対しての購買確率とその予測評価値を求めるモデルである。アイテムの集合を $D = \{d_i : 1 \leq i \leq I\}$ 、ユーザの集合を $U = \{u_j : 1 \leq j \leq J\}$ 、アイテムクラスの集合を $Z = \{z_k : 1 \leq k \leq K\}$ 、ユーザクラスの集合を $C = \{c_l : 1 \leq l \leq L\}$ 、ユーザ u_j に対するアイテム d_i の評価値 v は 1 から 5 の 5 段階とする。 I は総アイテム数、 J は総ユーザ数、 K は総アイテムクラス数、 L は総ユーザクラス数を示す。また、アイテムクラス、ユーザクラスはそれぞれ潜在クラスであり、ユーザは複数のユーザクラスに、アイテムは複数のアイテムクラスに確率的に所属することが可能である。LISM ではユーザとアイテムに同じ潜在クラスを設けるのではなく、より現実的な分類を行うため、ユーザとアイテムにそれぞれ別の潜在クラスを仮定している。LISM のグラフィカルモデルを図 1 に示す。LISM の確率モデルは次式で表現される。

$$P(d_i, v|u_j) = \sum_{c_l \in C} \sum_{z_k \in Z} P(v|d_i, z_k)P(d_i|z_k) \times P(z_k|c_l)P(c_l|u_j). \quad (1)$$

ここで各パラメータ $P(v|d_i, z_k)$ 、 $P(d_i|z_k)$ 、 $P(z_k|c_l)$ 、 $P(c_l|u_j)$ はそれぞれ、アイテムクラス z_k においてアイテム d_i が v と評価される確率、アイテムクラス z_k がアイテム d_i を含む確率、ユーザクラス c_l がアイテムクラス z_k を選択する確率、ユーザ u_j がユーザクラス c_l に所属する確率を

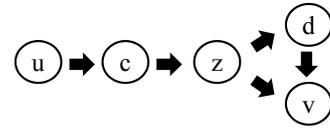


図 1: LISM のグラフィカルモデル

表す。LISM の各パラメータは EM アルゴリズム [3] で推定する。EM アルゴリズムで求めたパラメータを利用し、次式でユーザ u_j に対してのアイテム d_i の予測評価値 $\hat{v}_{u_j d_i}$ を求めることができる。

$$\hat{v}_{u_j d_i} = \sum_v \sum_{c_l \in C} \sum_{z_k \in Z} v P(v|d_i, z_k) \times P(z_k|c_l)P(c_l|u_j). \quad (2)$$

式 (2) で求めた予測評価値の高いアイテムをユーザ u_j に推薦する。

3 提案手法

3.1 背景

未購買アイテムの評価値を予測する際、正確な予測評価値を求めるためには実際のユーザの特性を考慮してクラス分けを行う必要がある。特に、ユーザの潜在クラスはユーザの嗜好をもとにクラス分けを行うことが主旨であるため、ユーザの嗜好を正しく判別することが重要である。しかし、LISM による潜在クラスのモデル化では、評価値そのものを使って確率モデルが構成されているため、全体的に高い評価値をつけるユーザや低い評価値をつけるユーザといったユーザの評価傾向の差異が考慮されていない。したがって、同じ嗜好を持つユーザ同士が別の潜在クラスに所属する可能性があり、正確な予測評価値を算出できていないと考えられる。

そこで、本研究では全体として高めの評価をつけるユーザと低めの評価をつけるユーザが混在するという仮定の元で、ユーザの評価値の偏りを考慮した評価値予測手法を提案する。

3.2 評価値の偏りを考慮した推薦手法

図 2 にユーザのアイテムに対する評価値の一例を示す。

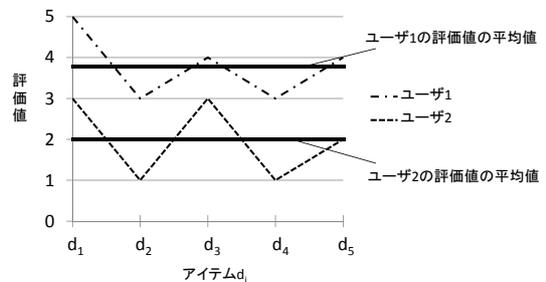


図 2: 評価値 $v_{u_j d_i}$ の偏りの例

図 2 では、ユーザ 1, 2 は同じアイテムに対し異なった評価値を付与している。LISM では、ユーザ同士の評価値の値が近いほど同じ潜在クラスに所属しやすいため、ユーザ 1、

2 は別の潜在クラスに所属する．しかし，ユーザ 1, 2 は共にアイテム 2, 4 に比べ，アイテム 1, 3, 5 を好んでいることがわかる．すなわち，ユーザ 1, 2 は同じ嗜好を持つユーザであると考えられ，同じ潜在クラスに所属すべきである．一方，ユーザごとのアイテムに対しての嗜好の傾向は，ユーザの全アイテムに対する評価値の平均値を計算し，アイテムの評価値との差を測ることにより把握することができる．評価値の平均値は整数値である必要があるため，四捨五入した値を利用する．嗜好の傾向は以下の式 (3) で表さる．

$$\tilde{v}_{u_j d_i} = v_{u_j d_i} - \bar{v}_{u_j} . \quad (3)$$

\bar{v}_{u_j} ($1 \leq \bar{v}_{u_j} \leq 5$) はユーザ u_j の評価値の平均値を表し， $\tilde{v}_{u_j d_i}$ ($-4 \leq \tilde{v}_{u_j d_i} \leq 4$) はユーザ u_j のアイテム d_j に対する評価値 $v_{u_j d_i}$ とユーザ u_j の平均評価値を四捨五入した値 \bar{v}_{u_j} との差を表す．例として，図 2 のデータに対しての $\tilde{v}_{u_j d_i}$ を以下の図 3 に示す．

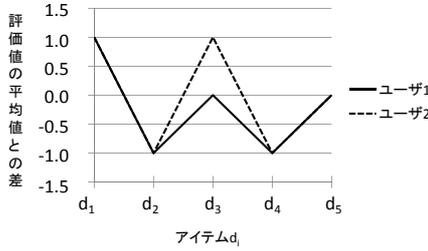


図 3: 評価値の平均値との差 ($\tilde{v}_{u_j d_i}$)

また，確率モデルは式 (4) で表わされる． \tilde{v} は -4 から 4 までの 9 段階である．

$$P(d_i, \tilde{v}|u_j) = \sum_{c_l \in \mathcal{C}} \sum_{z_k \in \mathcal{Z}} P(\tilde{v}|d_i, z_k) P(d_i|z_k) \times P(z_k|c_l) P(c_l|u_j) . \quad (4)$$

提案手法では，あるアイテムに対しての評価値とそのユーザの平均評価値との差が類似しているユーザ同士が同じ潜在クラスに所属し易くなる．図 2 の例ではユーザ 1, 2 は同じ潜在クラスに所属する可能性が高くなる．すなわち，LISM に比べ，ユーザの評価値の偏りを無くすることができるため，ユーザの嗜好がより正確に反映されると考えられる．また，各パラメータは LISM と同様に EM アルゴリズムで推定し，予測評価値は次式で求めることができる．

$$\hat{v}_{u_j d_i} = \bar{v}_{u_j} + \sum_{\tilde{v}} \sum_{c_l \in \mathcal{C}} \sum_{z_k \in \mathcal{Z}} \tilde{v} P(\tilde{v}|d_i, z_k) \times P(z_k|c_l) P(c_l|u_j) . \quad (5)$$

式 (5) で求めた予測評価値の高いアイテムをユーザ u_j に推薦する．

4 シミュレーションによる評価および考察

提案手法の有効性をシミュレーションにより評価し，さらにその結果について考察した．

4.1 実験条件と評価方法

ここでは 1997 年 9 月から 1998 年 4 月までの MovieLens[4] のデータを用いる． $J = 943$ ， $I = 1682$ ，評価値の総データ数は 10 万件であり，訓練データ 8 万件とテストデータ 2 万件に分けられている．ユーザは全ての映画の中から，最低

20 件以上の評価をアイテムに付けている．実験は $(K, L) = (8, 10)$ ， $(9, 9)$ ， $(10, 9)$ の場合で行った．モデルの評価指標はテストデータに対する MAE (平均絶対誤差) を用いた．

$$MAE = \frac{1}{IJ} \sum_{u_j \in \mathcal{U}} \sum_{d_i \in \mathcal{D}} |\hat{v}_{u_j d_i} - v_{u_j d_i}| \quad (6)$$

MAE の値は予測評価値と実際の評価値とのずれを表しているため，MAE が低いほど手法として優れているといえる．

4.2 実験結果

図 4 にユーザクラス数，アイテムクラス数を変化させたときの従来手法と提案手法の MAE を示す．

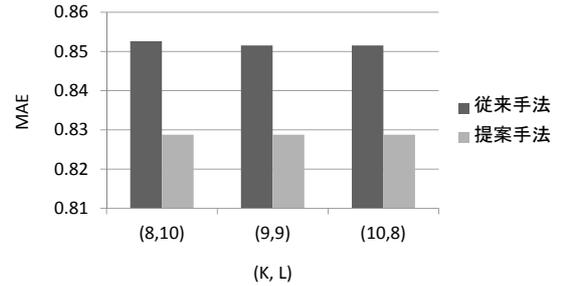


図 4. クラス数ごとの MAE の変化

4.3 考察

提案手法の $(K, L) = (8, 10)$ ， $(9, 9)$ ， $(10, 8)$ の全ての場合において精度が向上した．従来手法に比べ，MAE を減少させることで正確な評価値を予測することができ，ユーザの嗜好に適したアイテムを推薦することが可能となった．本研究では，ユーザによる評価値の偏りを考慮することで，従来研究では別の潜在クラスに所属していた図 2 のようなユーザが同じ潜在クラスに所属する可能性が高まる．そのため，ユーザの嗜好をよりモデルに反映したクラス分けを可能とし，結果としてモデルの精度が向上したと考えられる．

5 まとめと今後の課題

本研究では，ユーザのアイテムに対する評価値とユーザの全アイテムに対する評価値の平均値の差をとることでユーザごとの評価傾向を求め，それを用いてユーザの潜在クラスを仮定した．その結果，嗜好が類似しているユーザ同士が同じ潜在クラスに所属し，評価値を予測する上でより現実に沿った潜在クラスを仮定することができた．また，提案手法によるシミュレーションの結果からその有効性を示した．今後の課題は，最適なユーザクラス数，アイテムクラス数をモデル選択基準を使って決めることである．

参考文献

- [1] T. Kamishima, "Nantonac collaborative filtering: recommendation based on order responses," in *Proc. of The 9th International Conference on Knowledge Discovery and Data Mining*, pp. 583–588, Aug., 2003.
- [2] 川前徳章, 高橋克己, 山田武士, "ユーザの興味とオブジェクトのトピックに着目した情報検索モデル," *電子情報通信学会論文誌*, Vol.J90-D, No.10, pp. 2746–2754, 2007 年 10 月.
- [3] 宮川雅巳, "EM アルゴリズムとその周辺," *応用統計学*, Vol.16, No.1, pp. 1–21, 1987 年 6 月.
- [4] MovieLens. "http://www.movielens.org/".