

## LDA を用いた多様性を考慮する推薦システムに関する一考察

A study on recommender system considering diversity in recommendation items based on LDA

張 志穎 \*1  
Zhiying Zhang保坂 大樹 \*1  
Taiju Hosaka山下 遥 \*2  
Haruka Yamashita後藤 正幸 \*1  
Masayuki Goto\*1早稲田大学  
Waseda University\*2上智大学  
Sophia University

With the development of information technology, a huge amount of users' action history data has been accumulated on web sites. On such background, recommender system making use of these rich data has become important tool for searching contents or products. Diversifying the recommendation lists in recommender systems could potentially satisfy users' needs. In a previous research, the diversity is raised by the topic diversification method using Latent Dirichlet Allocation, but since the items belonging to the same topic are not diversified, there is a high possibility that they are similar. Therefore, this research proposes a recommendation method considering item diversification. Experimental results on MovieLens datasets demonstrate that our approach keeps accuracy produces more diversified results.

## 1. 研究背景と目的

近年、情報技術の発展に伴い、EC サイト等では膨大な量の購買履歴データや商品（以下、アイテム）に対する評価値データが蓄積されるようになった。このようなデータを分析することで、各ユーザの嗜好を考慮し、推定購買確率が高いアイテムを推薦するシステムが利用されている。

近年、ユーザ満足度の観点から、購買確率以外の尺度も考慮して推薦するアイテムを決定する必要性が指摘されている [McNee 06]。その尺度の一つに「多様性」がある。精度を重視した推薦では、類似したアイテム群が推薦される傾向にある。一方、多様性を考慮した推薦では、ユーザが今まで認知していなかったようなアイテムを推薦することができる可能性があるため、ユーザ満足度を向上させると考えられる [Ziegler 05]。

多様性を考慮した推薦アルゴリズムに関する研究はこれまで多く行われており、Ashkan らは、貪欲法に基づく推薦リストの構築手法をフレームワークとして定義した [Ashkan 15]。このフレームワークにおいて、学習の目的関数は、各アイテムをユーザに推薦することで得られる効用と、推薦リストとアイテムの組み合わせから計算される多様性に分割され、目的関数を最大化するアイテムを逐次的に推薦リストに追加する。

また、Xing らは、Latent Dirichlet Allocation(LDA) [Blei 03] に基づいてアイテムのトピックを抽出し、推薦リストに含まれるアイテムのトピックが多様化されるような推薦リストの構築アルゴリズムを提案した [Xing 17]。この手法は、推薦リスト全体でトピックを多様化している一方で、個々のアイテムの非類似性を保証していない。この特徴が与える影響は、ユーザが複数のトピックを好む場合により顕著に現れる。例えば、映画の推薦システムにおいて、“SF” と “ホラー” の両方のジャンルを好むユーザに 2 つの映画を推薦する場合、このユーザの嗜好に適した推薦として以下の 2 種類が考えられる。

- (a). “SF” と “ホラー” の要素を持つ映画を 2 つ推薦する
- (b). “SF” の要素を持つ映画と “ホラー” の要素を持つ映画を 1 つずつ推薦する

(a) と (b) はどちらもユーザの複数の嗜好を考慮した推薦であるが、個々のアイテムの多様性という観点からは (b) の推薦が望ましいと考えられる。

そこで本研究では、推薦リスト内のアイテム同士の類似度の増加方向に制約を加えた推薦リストの構築アルゴリズムを提案する。これにより、推薦されるアイテムのトピックの多様性だけでなく、個々のアイテムの多様性も高い推薦が可能になる。すなわち、同程度の推薦精度のもとで、より多様性の高い推薦アイテムリストを構成できると期待される。本研究では、ベンチマークデータに提案手法を適用し、精度と多様性の観点から従来手法との比較を行い、その有効性を示す。

## 2. 準備

## 2.1 Latent Dirichlet Allocation(LDA)

LDA は代表的なトピックモデルの一つであり、自然言語処理分野だけでなく、マーケティングデータにも応用がなされている。一般に、多様なユーザの購買履歴データや評価履歴データは、嗜好が全く異なるユーザによる行動履歴の集まりと仮定することが自然であり、学習データは統計的性質の異なるグループから成り立っていると考えられる。LDA などのトピックモデルでは、これらの統計的性質が異なるグループを一つのトピックとして表現する。LDA を購買履歴データへ適用すると、各ユーザにトピックの出現確率の分布、各トピックにアイテムの出現確率の分布が仮定される。ユーザによるアイテムの購買を、潜在変数であるトピックを介して表現することで、購買・被購買の関係のないユーザとアイテムの組み合わせについてもその関係性を推定することが可能となる。

$M$  人のユーザ集合を  $\mathcal{U} = \{u_1, \dots, u_M\}$ 、 $N$  個のアイテム集合を  $\mathcal{V} = \{v_1, \dots, v_N\}$ 、 $K$  個のトピック集合を  $\mathcal{Z} = \{z_1, \dots, z_K\}$  をそれぞれ仮定する。また、顧客  $u_m \in \mathcal{U}$  のもとでトピック  $z_k \in \mathcal{Z}$  が出現する確率を  $\theta_{m,k}$  とし、そのトピック分布を  $\boldsymbol{\theta}_m = (\theta_{m,1}, \dots, \theta_{m,K})^\top$  と表記する。また、トピック  $z_k$  のもとでアイテム  $v_n \in \mathcal{V}$  が出現する確率を  $\phi_{k,n}$  とし、そのアイテム分布を  $\boldsymbol{\phi}_k = (\phi_{k,1}, \dots, \phi_{k,N})^\top$  と表記する。 $\boldsymbol{\theta}_m$ 、 $\boldsymbol{\phi}_k$  に対して、それぞれ  $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_K)^\top$ 、 $\boldsymbol{\beta} = (\beta_1, \dots, \beta_N)^\top$  をパラメータとするディリクレ事前分布を仮定する。このとき、ユーザ  $u_m$  がアイテム  $v_n$  を購買する確率  $P(v_n|u_m)$  は式

連絡先: 張 志穎, 早稲田大学, 東京都新宿区 169-8555,  
zhangzhiyingwsd@gmail.com

(1) で表現される。

$$P(v_n|u_m) = \sum_{k=1}^K \int \int \theta_{m,k} P(\theta_{m,k}|\alpha) \phi_{k,n} P(\phi_{k,n}|\beta) d\theta_{m,k} d\phi_{k,n} \quad (1)$$

## 2.2 Xing らの研究

通常の LDA に基づく推薦では、ユーザ  $u_m$  に対して推定購買確率が高くなるようなアイテムを推薦する。ここで、アイテム  $v_n$  のもとでトピック  $z_k$  が出現する確率を  $\pi_{n,k}$ 、そのトピック分布を  $\pi_n = (\pi_{n,1}, \dots, \pi_{n,K})^\top$  と表記すると、LDA に基づく推薦は、 $\theta_m^\top \pi_n$  を最大化するようなアイテムを逐次的に推薦リストに追加していると解釈することができる。このとき、推薦されるアイテムはユーザの好むトピックに依存して決定され、それぞれ類似したトピック分布を持つ傾向がある。

このような推薦は、ユーザの好みのトピックに応じたアイテムを推薦できているが、ユーザがまだ認知していないトピックの存在を考慮すれば、推薦リストのトピックを多様にするによって、ユーザにとってさらに魅力的なアイテムを推薦できる可能性がある。

これに対し、Xing らは、LDA に基づく推薦リストの構築アルゴリズムを拡張し、推薦の精度をある程度維持しながら多様なトピックのアイテムを推薦する手法を提案した。この手法では、既に推薦されたアイテムのトピックに対して効用を相対的に減少させる項を、推定購買確率に加算することで、ユーザの嗜好を考慮したうえで推薦リストの多様化を実現している。

各ユーザに推薦するアイテムの数を  $L$ 、ユーザ  $u_m$  が購買していないアイテム集合を  $\mathcal{I}_m$ 、ユーザ  $u_m$  に推薦するアイテム集合を  $\mathcal{S}_m$  とする ( $\mathcal{S}_m \subseteq \mathcal{I}_m$ )。このとき、推薦アイテム集合  $\mathcal{S}_m$  にアイテム  $v_n$  を加えた場合の推薦の良さ  $f(v_n|\mathcal{S}_m)$  は以下の式 (2) で計算される。

$$f(v_n|\mathcal{S}_m) = P(v_n|u_m) + \lambda \sum_{k=1}^K \theta_{m,k} \pi_{n,k} \prod_{v_s \in \mathcal{S}_m} (1 - \pi_{s,k}) \quad (2)$$

ただし、 $\lambda$  は多様化の度合いを決定するパラメータである。また、 $u_m$  に対する推薦リストの構築アルゴリズムを以下に示す。

**Step1)**  $l = 1$ ,  $\mathcal{S}_m = \left\{ \arg \max_{v \in \mathcal{I}_m} P(v|u_m) \right\}$  とする。

**Step2)** 式 (3) を計算して、推薦の良さを最大化するアイテム  $v^*$  を求める。

$$v^* = \arg \max_{v \in \mathcal{I}_m \setminus \mathcal{S}_m} f(v|\mathcal{S}_m) \quad (3)$$

**Step3)**  $l \leftarrow l + 1$ ,  $\mathcal{S}_m \leftarrow \mathcal{S}_m \cup \{v^*\}$  とする。

**Step4)**  $l < L$  ならば Step2 へ。  $l = L$  ならば終了。

Xing らの研究では、多様性の指標も定義している。多様性は以下の式 (4) で計算される。

$$\text{diversity} = \frac{1}{M} \sum_{m=1}^M \left( 1 - \frac{\sum_{v_i \in \mathcal{S}_m} \sum_{v_j \in \mathcal{S}_m \setminus \{v_i\}} \text{sim}(v_i, v_j)}{L(L-1)} \right) \quad (4)$$

ただし、 $\text{sim}(v_i, v_j)$  は  $\pi_i, \pi_j$  間のコサイン類似度とする。

Xing らが提案したアルゴリズムによる推薦では、LDA による推薦と比較して精度が落ちる。一方で、多様性については LDA による推薦よりも優れた結果が得られる。Xing らの研究では、評価実験を通じて、精度と多様性のトレードオフの関係が示されている。推薦アルゴリズムのユーザは、多少の推薦精度の劣化を許容することで、推薦アイテムリストの多様性を高めることができる。

## 3. 提案手法

### 3.1 概要

Xing らの研究では、多様なトピックの推薦が可能となっている一方で、個々のアイテム間の非類似性は保証されていない。例えば、多くのトピックのもとで出現する複数個のアイテムを推薦した場合、推薦リストに含まれるトピックは多様であるが、推薦されるアイテム間の類似度が高くなり、ユーザの観点からの多様性が失われてしまう可能性がある。例えば、二つのトピック A とトピック B を併せ持つアイテムが複数推薦されたとしても、ユーザには類似のアイテムが推薦されているように見えてしまう。これに対し、トピック A を持つアイテムとトピック B を持つアイテムが推薦されれば、これらはユーザからもトピックの異なるアイテムが推薦されていると認識されるため、推薦アイテムリストの多様性が高いと見なされるはずである。

そこで本研究では、個々のアイテムの非類似性を考慮し、より多様な推薦リストを構築するためのアルゴリズムを提案する。提案手法では、貪欲法に基づく従来手法のフレームワークを用いて、推薦リストに含まれるアイテムとの非類似度が高くなるようなアイテムを逐次的に推薦リストに追加する。提案手法において、推薦アイテム集合  $\mathcal{S}_m$  にアイテム  $v_n$  を加えた場合の推薦の良さ  $g(v_n|\mathcal{S}_m)$  は以下の式 (5) で計算される。ただし、 $\gamma$  は多様化の度合いを決定するパラメータである。

$$g(v_n|\mathcal{S}_m) = P(v_n|u_m) + \gamma \min_{v_s \in \mathcal{S}_m} (1 - \text{sim}(v_n, v_s)) \quad (5)$$

これは、Xing らの手法の式 (2) におけるトピック多様性を考慮するための右辺第 2 項を、リスト内のアイテム多様性で置き換えた式となっている。アイテム間の類似度  $\text{sim}(v_n, v_s)$  はトピック分布のコサイン類似度となっているため、トピック多様性を考慮した推薦リストを作成できると期待される。すなわち、提案手法により構築された推薦リストは、トピックに関して多様化されているだけでなく、アイテムに関しても多様化されていると考えられる。

### 3.2 提案アルゴリズム

**Step1)**  $l = 1$ ,  $\mathcal{S}_m = \left\{ \arg \max_{v \in \mathcal{I}_m} P(v|u_m) \right\}$  とする。

**Step2)** 式 (6) を計算して、推薦の良さを最大化するアイテム  $v^*$  を求める。

$$v^* = \arg \max_{v \in \mathcal{I}_m \setminus \mathcal{S}_m} g(v | \mathcal{S}_m) \quad (6)$$

Step3)  $l \leftarrow l + 1$ ,  $\mathcal{S}_m \leftarrow \mathcal{S}_m \cup \{v^*\}$  とする.

Step4)  $l < L$  ならば Step2 へ.  $l = L$  ならば終了.

## 4. 評価実験

提案手法の有効性を示すために、ベンチマークデータセットを用いた実験を行う。

### 4.1 実験概要

データセットとして、映画の評価履歴データとして公開されている MovieLens データセットを用いる。対象データのユーザ数は  $M = 6,040$ 、映画数は  $N = 3,706$  であり、総評価件数は 1,000,209 である。学習データとテストデータの構築およびモデルの評価は 5 分割交差検証法に基づき、ユーザごとにランダムにデータを 5 分割した。また、交差検証の各学習を行う前に、学習データ内の各ユーザの平均評価値未満のアイテムを学習データおよびテストデータから除外する。これにより、各ユーザが比較的高い平均評価値を付与するアイテム、すなわち、各ユーザの満足度が高いアイテムを推薦できるかどうかという問題設定になる。

LDA で抽出するトピック数を  $K = 10$  とし、ディリクレ分布のパラメータをそれぞれ  $\alpha_k = 1/K$  ( $1 \leq k \leq K$ ),  $\beta_n = 1/N$  ( $1 \leq n \leq N$ ) とした。また、パラメータの学習は変分ベイズ法 [Beal 03] に基づいて行った。

LDA のみによる推薦 (提案手法で  $\gamma = 0$  とすることに相当)、Xing らの手法による推薦と比較して提案手法の有効性を検討する。

### 4.2 評価指標

本研究では、Xing らの研究に準じて、二つの評価指標を用いる。まず、推薦システムに重要な評価指標として精度を評価指標とする。テストデータ内でユーザ  $u_m$  が評価を行っているアイテム集合を  $\mathcal{T}_m$  とすると、推薦の精度は以下の式 (7) で計算される。

$$\text{precision} = \frac{1}{M} \sum_{m=1}^M \frac{|\mathcal{S}_m \cap \mathcal{T}_m|}{N} \quad (7)$$

また、どれだけ多様なアイテムを推薦できているかを測る指標として、式 (4) に示した多様性指標を併せて、評価指標として用いる。

## 5. 実験結果

### 5.1 各手法における精度と多様性の関係

$L = 10$  としたときの、各手法における精度と多様性の関係を図 1 に示す。ただし、提案手法では  $1.0 \times 10^{-4} \leq \gamma \leq 1.0$ 、Xing らの手法では  $1.0 \times 10^{-3} \leq \lambda \leq 1.0$  を満たす複数のパラメータで実験を行い、その結果を全てプロットした。

図 1 を見ると、LDA による推薦が最も高い精度を示していることがわかる。一方、提案手法と Xing らの手法では、パラメータを変化させることで、多様性を考慮した推薦リストを得ることができる。すなわち、パラメータの設定によって、多様性を向上させると、精度的には劣化するため、図の左側に移動




図 1: 各手法における精度と多様性の関係

すると共に、多様性が向上し、点が左上に移動する。 $\lambda$  や  $\gamma$  の値が小さいときは、多様化の効果も小さく、LDA による推薦と同程度の結果を示しているが、これらのパラメータの値が大きくなるにつれて、推薦の精度が低下し、多様性が増加する傾向が見られた。

ここで、同じ精度では提案手法が Xing らの手法よりも高い多様性を示していることが読み取れる。提案手法は、精度の劣化に対して、多様性が向上するのが Xing らの手法よりも早く、全体として右上側のゾーンに位置している。すなわち、提案手法では Xing らの手法と同等の推薦精度を保ちながら、より多様性の高いアイテムリストをユーザに推薦することができると解釈できる。

### 5.2 推薦アイテム数と精度・多様性の関係

$\lambda = 0.0040$ ,  $\gamma = 0.0004$  としたときの、各手法における推薦アイテム数  $L$  に対する精度の変化を図 2、多様性の変化を図 3 に示す。

図 2 を見ると、推薦アイテム数  $L$  が増加したとき、全ての手法で精度が悪化していることがわかる。これは、テストデータ数は固定であるため、推薦するアイテム数が増えると、推薦リスト中で、ユーザが評価しているアイテム数が頭打ちとなり、必然的に精度が低下するためである。特に提案手法では、推薦アイテム数の増加に対する精度の低下率が他手法と比較して大きい。これは、提案手法は推薦リストの多様性を求めるため、リストのサイズが大きくなってくると、リスト内に様々なトピックの異なるアイテムが入ってくるようになり、ユーザの嗜好から外れていくためである。

また、図 3 を見ると、比較手法では、推薦アイテム数の増加に伴う多様性の変動が小さいことがわかる。対して、提案手法では、推薦アイテム数の増加に伴って多様性が増加することを確認した。提案手法では、推薦アイテムリスト内の多様性を維持するようなアルゴリズムになっているため、リストサイズが大きくなると、それに併せて多様性も向上していく性質がある。

以上の結果から、提案手法は推薦アイテム数の変化に伴って精度と多様性が大きく変動するといえる。これは、提案手法が個々のアイテムの類似度に対して制約を設けているため、推薦アイテム数を増加させた場合に、制約が過度に強くなってしまいうことに起因する。すなわち、推薦リスト内の多様性をあまり

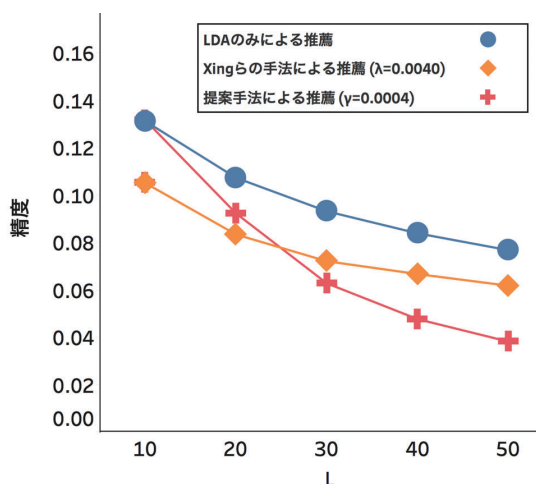


図 2: 推薦アイテム数と精度の関係




図 3: 推薦アイテム数と多様性の関係

大きくし過ぎることなく、推薦アイテム数を増加させたい場合には、 $\gamma$  の値を小さくとり、提案手法の制約を緩和させる必要がある。

## 6. 結論と今後の課題

本研究では、個々のアイテムの非類似性を考慮することで、精度を保ちながら多様性のある推薦を行うための推薦リスト構築アルゴリズムを提案した。また、ベンチマークデータに提案手法を適用し、その有効性を示した。

MovieLens データセットを用いた評価実験では、従来手法と比較して、提案手法が同程度の精度でより高い多様性を示した。すなわち、提案手法を用いることで、推薦精度を維持しつつ、推薦リストの多様性を高めることができ、ユーザ満足度のさらなる向上を見込むことができる。しかしながら、提案手法は、推薦アイテム数の変化に対して精度および多様性が大きく変動し、その性能が不安定であることも確認した。そのため、実際に提案手法を用いる際には推薦アイテム数に応じてパラメータを調整する必要があるといえる。今後は、パラメータを調整するためのコストを考慮した評価を行うことが課題として挙げられる。

また、今後の課題として、実際の推薦システムに提案手法を組み込んで、AB テストなどの手法を用いてその効果を定量的に評価することが必要である。精度のみではなく、多様性を考慮した提案手法では、実際の推薦によるモデルの評価は特に重要である。さらに、被評価回数のないアイテムに関して、購買確率や類似度を精度よく推定することも必要である。例えば、映画のテキスト情報を、LDA や Doc2vec[Le 14] といった手法により解析することで、新規の映画に対してもその類似度を精度良く推定することができる可能性がある。

## 7. 謝辞

本研究を進めるに当たり、早稲田大学 創造理工学部 経営システム工学科教授後藤正幸先生からは多大な助言を賜りました。厚く感謝を申し上げます。また、本論文を作成するにあたり、ご指導いただきました上智大学理工学部 情報理工学科助教山下遥先生にも心より御礼申し上げます。更に、様々な議論やサポートをしていただいた早稲田大学 創造理工研究科 修士課程 張笑エン氏、保坂大樹氏、大堀祐一氏には丁寧かつ熱心

なご指導を賜りました。ここに深く感謝の意を表します。

## 参考文献

- [Ashkan 15] Ashkan, A., Kveton, B., Berkovsky, S. and Wen, Z.: Optimal Greedy Diversity for Recommendation, *In Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence*, pp.1742-1748 (2015).
- [Blei 03] Blei, D. M., Ng, A. Y. and Jordan, M. I.: Latent Dirichlet Allocation, *Journal of Machine Learning Research*, Vol.3, pp.993-1022 (2003).
- [McNee 06] McNee, S. M., Riedl, J. and Konstan, J. A.: Being accurate is not enough: how accuracy metrics have hurt recommender systems, *In Proceedings of International Conference on Human Factors in Computing Systems*, pp.1097-1101 (2006).
- [Le 14] Le, Q. and Mikolov, T.: Distributed Representations of Sentences and Documents, *In Proceedings of Thirty-First International Conference on Machine Learning*, pp.1188-1196 (2014).
- [Xing 17] Xing, X., Sha, C. and Niu, J.: Improving Topic Diversity in Recommendation Lists: Marginally or Proportionally?, *In Proceedings of APWeb-WAIM 2017*, pp.142-150 (2017).
- [Ziegler 05] Ziegler, C. N., McNee, S. M., Konstan, J. A. and Lausen, G.: Improving recommendation lists through topic diversification, *In Proceedings of Association for Computing Machinery on World Wide Web*, pp. 22-32 (2005).
- [Beal 03] Beal, M. J.: Variational Algorithms for Approximate Bayesian Inference, PhD thesis, Gatsby Unit, University College London (2003).