

反実仮想機械学習を用いた Cold-Start 問題に関する研究

中央大学大学院 理工学研究科 経営システム工学科 長塚研究室 尾崎 瑛広

2023年3月1日

1 概要

近年、自社メディアや SNS, e-コマース, 動画配信などのサービスにおいて、ユーザに最適化されたコンテンツを提供するためにレコメンドシステムの需要は高まってきている。また、このレコメンドシステムを含む機械学習アルゴリズムに基づく意思決定は、上記の分野に限らず裁判の判決や金融機関の審査、データ高等教育・医療に渡るまで幅広い応用先が今後期待されている。[Narita and Yata, 2020][Dieterich et al., 2016]。レコメンド手法は、一般にコンテンツベースの協調フィルタリングや次元削減法などによって、膨大なアイテムの中から個人に最適な商品を推薦している。しかし、通常の Web サイトなどでは、ユーザは推薦システムにある全ての商品を認知することができないので、ユーザが認知していない商品の評価データが欠落することになる。特に、Cold-Start 問題は、新規ユーザや新商品は、ユーザに認知されていないため、データを収集し適切な推薦を行うことができないという Web マーケティングにおける推薦システムの重要な課題となっている。

Cold-Start 問題を解決するための方法として、コンテンツベースの協調フィルタリング [Herlocker et al., 2004], ユーザクラスタを応用するもの [Shi et al., 2014], 半教師あり学習を用いたもの研究 [Uchida et al., 2018], Deep Learning を用いた手法 [He et al., 2017][Sun et al., 2019] が存在する。しかし、本研究では、Cold-Start 問題を回避した、反実仮想機械学習 (CFML, Counter Factual Machine Learning) を用いたレコメンド手法を提

案する。一般に、CFML は、Off-Policy Evaluation(OPE) と呼ばれ、オフラインでレコメンドアルゴリズムを評価する手法として利用され、いくつもの論文が出版されている [Su et al., 2020]。しかし、提案法は、CFML の反事実を考慮する点に注目し、実際に Web 上で収集されたデータ (事実) とユーザ特徴から推定される仮にユーザがその商品に遭遇していた場合に収集されていたであろうデータ (反事実) の両方を用いて、Cold-Start 問題を回避する手法となっている。

2 従来手法

協調フィルタリングとは、あるユーザ u のアイテム i に対する評価 r で構成されるデータセットを学習し推薦するレコメンド手法である。このような学習データは、収集がしやすいため多くの Web サービスで用いられてきた。しかし、 (u, i, r) のみで学習を行うため、新規ユーザや新規アイテムへの推薦は不可能であり、Cold-Start 問題に対する耐性が低いことが指摘されている。

ここでは、ユーザベースの協調フィルタリングについて紹介する。ユーザー u に類似する k 人の近傍ユーザー集合を抽出し、近傍ユーザ u' の行動 i へのレビュースコアから u の行動 i に対するレビュースコア $\hat{r}_{u,i}$ を推定し、それを推薦スコアとする。近傍ユーザーの抽出に用いられる類似度 $sim(u, u')$ は、ユーザー u, u' によるレビュースコアのベクトル $R_u, R_{u'}$ から計算され、以下のよう

に定義できる.

$$\text{sim}(u, u') = \text{SimilarityFunction}(R_u, R_{u'}) \quad (1)$$

上記の SimilarityFunction には任意の類似度関数を設定でき, 一般的にはコサイン類似度や相関係数などが用いられる. この類似度関数に基づいて, ユーザ u に類似する k 人の最近傍ユーザー u' の集合 K_u を抽出する. 最終的な目的は u の i に対する推薦スコア $s_{u,i}$ を算出することであるため, 最近傍ユーザー集合 K_u には i をレビューしたユーザー u' が含まれているほうが望ましい. そのため K_u を抽出する際に i にレビュースコアをつけたユーザーの中から選ぶようにする場合もある. 最後に, ユーザー u のアイテム i に対する推定スコア $s_{u,i}$ を以下のように類似度に応じたレビュースコアの重み付き平均で計算する. 以下の式の文字を記載する.

$$s_{u,u'} = \hat{r}_{u,i} = \frac{\sum_{u' \in K_u} \text{sim}(u, u') r_{u',i}}{\sum_{u' \in K_u} |\text{sim}(u, u')|} \quad (2)$$

次にオフラインで評価する標準的な方法として, Direct Method (DM), Inverse Probability Weighting (IPW), Doubly Robust (DR) がある. ここでは DM について説明する. DM は, 過去に蓄積されたデータ D を使って特徴量 x と行動 a から目的変数 Y の期待値を推定する以下のモデルを得る. $t \in T$ で, t は, あるのユーザーを表す.

$$D = \{(x_t, a_t, Y_t)\}_{t=1}^T \quad (3)$$

$$\hat{r}(x, a; D) \approx \mathbb{E}[Y(a) | X = x] \quad (4)$$

\hat{r} には, リッジ回帰やランダムフォレストなどよく知られた機械学習の手法を用いることができる. 次に \hat{r} を用いて次の式のように π の性能を推定する.

$$\hat{V}_{DM}(\pi_e; \hat{r}) := \frac{1}{n} \sum_{i=1}^n \sum_{a \in \mathcal{A}} \pi_e(a | x_i) \hat{r}(x_i, a) \quad (5)$$

$\hat{V}_{DM}(\pi_e; \hat{r})$: DM による評価値

$\pi_e(a | x_i)$: ユーザ特徴 x_i を持つユーザーが行動 a を行う確率

$\hat{r}(x_i, a)$: ユーザ特徴 x_i を持つユーザーが行動 a を行なった時の報酬

DM の精度の推定は, \hat{r} の精度に大きく依存する. [Su et al., 2020] などでは, DM は $\mathbb{E}[Y(a) | X = x]$ をよく推定することは, 難しい場合が多いとされている.

3 提案手法

本研究では, 事実データと反事実データの両方を用いた CFML によってレコメンドを行う方法を提案する. 概要を以下の図 1 に示す. はじめに, 提案法のアルゴリズムで使用する変数について説明する.

表 1: 提案手法に使用する変数の説明

| 記号 | 意味 |
|--------------------|---|
| i, j | ユーザー id |
| x_i | ユーザー id が i のユーザー特徴 |
| x | ユーザー特徴 ($x \in (x_1, x_2, \dots)$) |
| a | ユーザーが実際にとった行動 |
| a' | ユーザーがとっていない行動 |
| A | ユーザーが取りうる行動 ($A = a + a'$) |
| $r(x_i, a)$ | ユーザー特徴 x_i のユーザーが行動 a を行った時の報酬 |
| $\hat{r}(x_i, a')$ | ユーザー特徴 x_i のユーザーが行動 a' を行った時の報酬の推定値 |
| $R(x_i, A)$ | ユーザー特徴 x_i のユーザーが取りうる行動 A をとった時の報酬 |
| f | 反事実を推定する関数 |

ここで, $a' = \bar{a}$ とする.

まず初めに, ユーザ特徴 x_i を持つユーザー i が実際にとった行動 a に対して, どのような報酬 $r(x_i, a)$ を得ているかのデータを使って, 関数 f を学習する.

次に, ユーザ特徴 x_i を持つユーザー i が行動 a' をとったときの報酬 $\hat{r}(x_i, a')$ を次式 (6) で推定する.

$$\hat{r}(x_i, a') = f(x_i, a') \quad (6)$$

また, 本研究では, 関数 f は, ロジスティック回帰を使用し, 実装では Python ライブラリ の scikit-learn にある LogisticRegression を用いた.

ここまでの手順で, ユーザ特徴 x , 行動 a , $r(x, a)$ のデータ (事実データ) からユーザー特徴 x




図 1: 提案手法

を持つユーザが行動 a' を行った時の報酬 $\hat{r}(x, a')$ (反事実データ) の生成を行った。また、報酬 $\hat{r}(x_i, a)$ と推定した報酬 $\hat{r}(x_i, a')$ のベクトルを合計すると、取りうる行動 A に対する報酬 $R(x_i, A)$ と表すことができる。

$$R(x_i, A) = r(x_i, a) + \hat{r}(x_i, a') \quad (7)$$

次に、ユーザ特徴 x_i 、実際に観測されて報酬 $r(x_i, a)$ と先ほど求めた報酬 $\hat{r}(x_i, a')$ のデータから協調フィルタリングを使って、ユーザに推薦するアイテムを決定する。

まず、ユーザ特徴 x_i を持つユーザ i の行動 A に対する報酬 $R(x_i, A)$ とユーザ特徴 x_j を持つユーザ j の行動 A に対する報酬 $R(x_j, A)$ を用いて、ユーザ i とユーザ j の類似度 $sim(i, j)$ を以下の式のように求める。

$$sim(i, j) = \frac{1}{\sqrt{\sum_{k=i}^m (R(i, A) - R(j, A))^2}} \quad (8)$$

次に、ユーザ i に推薦する候補の行動 a' に対する疑似的な報酬スコア $s(i, a')$ を求める。また、 j を i 以外の他のユーザとする。 ($j \neq i$)

$$s(i, a') = \frac{\sum_{A=1}^n sim(i, j) \cdot R(x_j, a')}{\sum_{j=1}^n sim(i, j)} \quad (9)$$

上記の式より、ユーザ i に推薦する各行動 a' の疑似的な報酬スコア $s(i, a')$ は、 k 次元の特徴ベクトル $\mathbf{s}(i)$ ($i = 1, \dots, n$) で表現される。

$$\mathbf{s}(i) = (s(i, 1), s(i, 2), \dots, s(i, k)) \quad (10)$$

最後に、 $\mathbf{s}(i)$ を降順にソートし、上位 N 件を抽出する。

上記の手順を行うことで、ユーザ i にある行動 k を N 件推薦することができる。

本研究で提案するユーザ i に対して N 件の映画を推薦する方法を以下にまとめる。

提案手法のアルゴリズム

1. 実際に集計されたユーザ特徴 x と評価値 $r(x, a)$ から、反事実を推定する関数 f を求める。
2. 関数 f を用いてユーザ特徴 x が、Web サイト上で行ってない行動 a' に対して、反事実の評価値 $\hat{r}(x, a')$ を推定する。
3. 実際に集計された評価値と、2. で推定した反事実の評価値を合わせた $R(i, j)$ を用いて、類似度 $sim(i, j)$ を求める。
4. 類似度 $sim(i, j)$ と $R(i, j)$ を用いて、ユーザ i に推薦するスコア $\mathbf{s}(i)$ を求める。
5. $\mathbf{s}(i)$ のスコアを降順にソートし、先頭から N 件推薦する。

4 使用するデータについて

提案法の有効性を確認するために、MovieLens[Harper and Konstan, 2015] の映画の評価サイト (<https://movielens.org>) の 100K のデータセットを使用した。このデータセットは、20 本未満しか視聴していないユーザやユーザ属性情報を持たないユーザは事前に削除されている。使用したデータセットの概要を以下にまとめた。

表 2: MovieLens のデータセットの概要

| Movielens | |
|-----------|---------------------------------|
| 対象期間 | 1997 年 9 月 19 日~1998 年 4 月 22 日 |
| 映画 ID 数 | 1682 本 |
| ユーザ ID 数 | 943 人 |
| 評価数 | 100000 件 |
| ユーザ特徴 | 過去視聴した映画の各ジャンルの頻度 |

5 結果

本研究の結果、視聴映画数が 20 本から 50 本のユーザの新規ユーザにおいて従来手法より提案手法が各指標において良い結果を得ることができた。この新規ユーザに対して、実際の Web サイトを想定し、5 本、10 本、20 本の映画を推薦したときの各指標の結果を以下に示す。

表 3: 新規ユーザに 5 本の映画を推薦した結果

| 手法 | 適合率 | 再現率 | MRR |
|-----------|---------------|---------------|---------------|
| 協調フィルタリング | 0.0311 | 0.0523 | 0.0606 |
| 提案手法 | 0.0470 | 0.0719 | 0.0872 |

表 4: 新規ユーザに 10 本の映画を推薦した結果

| 手法 | 適合率 | 再現率 | MRR |
|-----------|---------------|---------------|---------------|
| 協調フィルタリング | 0.0383 | 0.1116 | 0.0856 |
| 提案手法 | 0.0454 | 0.1368 | 0.1078 |

表 5: 新規ユーザに 20 本の映画を推薦した結果

| 手法 | 適合率 | 再現率 | MRR |
|-----------|---------------|---------------|---------------|
| 協調フィルタリング | 0.0358 | 0.1994 | 0.0994 |
| 提案手法 | 0.0374 | 0.2121 | 0.1189 |

6 結論と今後の課題

本研究では、Cold-Start 問題を回避することを目的として、CFML を用いた手法の提案を行った。CFML を用いることで、より多くのユーザ情報を考慮した推薦が可能となった。また、MovieLens において、新規ユーザに対して従来の協調フィルタリングより、提案手法が各指標において良い結果を示し、提案手法の有効性が確認できた。映画を 100 本以上見たユーザ (ユーザ情報が集まった状態) では、協調フィルタリングの方が各指標全て上回ったことから、実用上では、新規ユーザに対しては提案手法を用いて、ユーザ情報が集まってきた段階で、協調フィルタリングによるレコメンド手法に切り替える必要があることがわかった。

今後の課題として、1 つ目が他の従来手法と比較し、提案法の総合的な評価を行うこと、また、従来手法にも反事実を考慮したデータセットを使用し、更なる改善が期待できるかの検証を行うこと。2 つ目が本研究で用いたデータセットは、MovieLens のデータセットでのみの結果のため、(1) ユーザ特徴と評価に関して因果関係が見られるデータセット (2) クリックやコンバージョンを観測したデータセット (3) [Dieterich et al., 2016] の例など被告人を保釈すべきかといった Web 以外の分野に関するデータセットを適用し、提案法の有効性を検証する。3 つ目が反事実を推定する IPW や DR を用いて比較検証を行うため、複数の Policy の推薦システムとユーザ特徴を含んだデータセットの収集をすることが挙げられる。

参考文献

- [1] Yue Shi, Martha Larson and Alan Hanjalic, "Collaborative Filtering beyond the User-Item Matrix: A Survey of the State of the Art and Future Challenges", ACM Computing Surveys, Vol.47, Issue 1, No.3, pp.1-45, (2014)
- [2] Takumi Uchida, Kei Nakagawa and Kenichi Yoshida, "Combining Semi-Supervised Learning and Singular Value Decomposition to Cold-Start Problem", The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, (2018)
- [3] Yi Su, Maria Dimakopoulou, Akshay Krishnamurthy and Miroslav Dudik, "Doubly robust off-policy evaluation with shrinkage", ICML '20: Proceedings of the 37th International Conference on Machine Learning, No. 850, pp. 9167-9176, (2020)
- [4] F. Maxwell Harper and Joseph A. Konstan, "The MovieLens Datasets: History and Context", ACM Transactions on Interactive Intelligent Systems, Vol.5, Issue 4, Article No. 19, pp.1-19, (2015)
- [5] Xiangnan He, Lizi Liao, Hanwang Zhang, Liqiang Nie, Xia Hu and Tat-Seng Chua, "Neural Collaborative Filtering", WWW '17: Proceedings of the 26th International Conference on World Wide Web, pp.173-182, (2017)
- [6] Yuta Saito, Shunsuke Aihara, Megumi Matsutani, Yusuke Narita, "Open Bandit Dataset and Pipeline: Towards Realistic and Reproducible Off-Policy Evaluation", 35th Conference on Neural Information Processing Systems, (2021)
- [7] Fei Sun, Jun Liu, Jian Wu, Changhua Pei, Xiao Lin, Wenwu Ou, and Peng Jiang, "BERT4Rec: Sequential Recommendation with Bidirectional Encoder Representations from Transformer", CIKM '19: Proceedings of the 28th ACM International Conference on Information and Knowledge Management, pp.1441-1450, (2019)
- [8] Yusuke Narita and Kohei Yata, "Almost All Machine Learning Algorithms Are A/B Tests", The 34th Annual Conference of the Japanese Society for Artificial Intelligence, (2020)
- [9] William Dieterich, Christina Mendoza and Tim Brennan, "COMPAS Risk Scales: Demonstrating Accuracy Equity and Predictive Parity", Northpoint Inc., (2016)