

基于改进的反事实推理框架消除流行度偏差

王磊

天津工业大学软件学院, 天津

收稿日期: 2023年9月20日; 录用日期: 2023年10月18日; 发布日期: 2023年10月25日

摘要

本文将时间因子融入反事实推理框架中, 得到改进的无关模型的反事实推理框架。推荐系统的最终目的是提供给用户个性化的建议, 而不是推荐流行的项目。借助因果关系中的反事实推理法来分析解决流行度偏见问题是一个新颖而基本的视角。流行度偏差是指热门的项目展示相对较多, 系统推荐的时候, 会倾向于推荐热门商品。当前的推荐模型只是考虑用户项目交互对最终评分的影响, 忽略了时间因子对于交互过程的影响, 所以对于流行度偏差消除的结果并不理想。由于用户和项目的匹配度不是一成不变的, 它会随着时间非线性变化, 为了提升模型消除流行度偏差的能力, 本论文将时间因子纳入到了遵循因果推理的反事实推理框架中, 从用户和项目交互的细节出发, 细化了用户项目匹配, 完成了对反事实推理框架的改进。实验使用矩阵分解算法和MovieLens数据集进行实验, 融入时间因子的反事实推理框架对比传统的框架, 命中率、召回率、归一化折损累计增益都有了一定的提高, 提高了推荐算法的去流行度偏差能力。

关键词

推荐算法, 因果推断, 反事实推理, 流行度偏见

Elimination of Popularity Bias Based on Improved Counterfactual Inference Model

Lei Wang

Software College, Tiangong University, Tianjin

Received: Sep. 20th, 2023; accepted: Oct. 18th, 2023; published: Oct. 25th, 2023

Abstract

This paper integrates the time factor into the counterfactual reasoning framework and obtains an improved model-independent counterfactual reasoning framework. The ultimate purpose of the

recommendation system is to provide users with personalized recommendations, rather than recommending popular items. It is a novel and fundamental perspective to analyze and solve the problem of popularity bias with the help of counterfactual reasoning in causal relationships. Popularity bias means that relatively more popular items are displayed, and when the system recommends them, it will tend to recommend popular items. The current recommendation model only considers the impact of user item interaction on the final score and ignores the impact of the time factor on the interaction process, so the results for eliminating the popularity bias are not ideal. Since the matching degree between users and items is not static, it will change non-linearly with time. In order to improve the model's ability to eliminate popularity bias, this paper incorporates the time factor into the counterfactual reasoning framework that follows causal reasoning, from users and Starting from the details of item interaction, user-item matching is refined and the improvement of the counterfactual reasoning framework is completed. The experiment uses the matrix decomposition algorithm and the MovieLens data set. Compared with the traditional framework, the counterfactual reasoning framework that incorporates the time factor has a certain improvement in hit rate, recall rate, and normalized loss cumulative gain, which improves the popularity bias removal ability of the recommendation algorithm.

Keywords

Recommendation Algorithms, Causal Inference, Counterfactual Reasoning, Popularity Bias

Copyright © 2023 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

推荐系统正在为各类用户提供个性化的服务,在电子商务、新闻网站、内容共享平台和社交媒体等广泛的在线应用中发挥着越来越重要的作用,然而,由于流行度偏差的存在,当前多数推荐系统更倾向于向用户推荐流行的项目,这与个性化推荐是背道而驰的。研究表明,流行偏见会导致推荐中的某些问题,例如随着时间的推移,用户的消费转向更主流的项目,甚至导致不同用户群体的同质化[1]。流行度偏差的出现是由长尾效应导致的,在互动的数据中,受到商品曝光机制、商品质量等因素的影响,多数情况下,频率的分布是不均匀的,整体呈现长尾分布,即少数项目占据了多数的交互,这就导致了推荐模型更偏向于推荐流行的项目。并不是所有的用户都喜欢流行的项目,流行度偏差的存在不仅会阻碍推荐者准确的理解用户偏好,同时也会导致推荐多样性的降低。马太效应[2]就是由流行度偏差所导致的,越受欢迎的物品就越被更多的推荐,变得更加受欢迎。为了缓解流行度偏差,研究人员已经探索了许多的方法,这些方法主要进行的工作就是进行无偏见的学习和排名调整。例如,反向倾向评分(IPS),它重新加权了模型训练的交互,以此来调整数据的分布[3],虽然IPS方法的理论基础已经很成熟了,但是因为它的模型方差和倾向性很难进行估计,在实践中难以实现。排名调整是在得到推荐列表以后进行二次排名[4],这种方法有意提高不太受欢迎的项目的分数,缺乏理论基础。消除流行偏见的关键并不是盲目的将推荐者推到长尾,而是仔细了解物品流行如何影响每次互动[5]。近几年,因果推断作为一个新颖的视角被引入到推荐系统中,从用户-项目交互、用户一致性和项目流行度出发,细粒度地分析并缓解流行度偏差,但是当前利用因果推断进行推荐仍然属于初步的尝试,并没有结合辅助信息。本文在此基础上对因果推理图以及遵循该因果图推理的反事实推理框架做了改进,因为在以往的因果推断过程中并没有考虑时间因素,这会影响用户-项目交互过程,从而影响最终用户对项目的评分,将时间因子纳入到

因果推理图中, 进而得到改进的反事实推理框架, 通过实验证明, 该框架缓解流行度偏差的效果相较于原框架有了一定的提升。

2. 无关模型的反事实推理框架

2.1. 因果推断和反事实推理关键概念介绍

因果推理源于统计学, 它是统计学的重要研究课题, 几十年来在公共政策、经济、计算机科学等许多领域得到了十分广泛的应用[6]。因果推断就是指根据已有的证据或者事实, 推断出某种原因导致某种结果的推理过程。反事实推理是因果推断的一种方法, 它是通过未发生的条件来推理可能的结果。在推荐系统中引入因果推断是必要的, 传统的推荐算法的基础就是从数据中挖掘或学习相关模式, 但是现实世界的应用是由潜在的因果机制驱动的, 单纯的关联学习而不考虑因果关系会导致一些实际的问题[7], 比如就用经典的“啤酒和尿布”举例, 这个事例的潜在机制是年轻的父亲通常会同时购买啤酒和尿布, 如果只是从相关性出发为购买纸尿裤的顾客推荐啤酒, 这回直接造成推荐的混乱, 损害用户的购买体验。所以, 从关联学习迈向因果学习非常有必要。

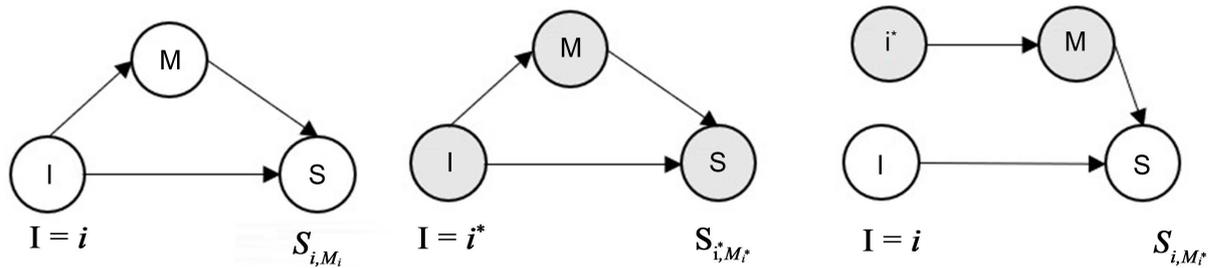


Figure 1. Example of causal graph
图 1. 因果图

因果图是一个有向无环图, 在因果图中大写字母表示一个变量, 而它对应的小写字母表示这个变量的观测值。边表示祖先节点是原因, 而后继节点是结果。如图 1 所示, $I \rightarrow S$ 表示存在 I 到 S 的直接影响。另外, 路径 $I \rightarrow M \rightarrow S$ 意味着 I 通过中介 M 影响 S 。根据因果图, S 的值可以由它的祖先节点的值计算得出, 表达式为:

$$S_{i,m} = S(I = i, M = m) \quad (1)$$

因果总效应。 I 对 S 的因果效应是目标变量 S 因祖先变量 I 的变化而发生变化的幅度, 当 $I = i$ 时, 总效应定义为:

$$TE = S_{i, M_i} - S_{i^*, M_i^*} \quad (2)$$

公式(2)表示 $I = i$ 和 $I = i^*$ 这两种假设情况下 S 值之间的差异, $I = i^*$ 通常是指 I 的值与实际值不一致的情况, 这个值通常设置为空。根据图 1 的因果图, TE 可以分解成自然直接效应(Natural Direct Effect, NDE)和间接效应(Total Indirect Effect, TIE), 分别通过直接路径 $I \rightarrow S$ 和间接路径 $I \rightarrow M \rightarrow S$ 表示对评分 S 的影响。NDE 表示在直接路径 $I \rightarrow S$ 上, 随着值从 i^* 变到 i , S 值的改变, 表达式为:

$$NDE = S_{i, M_i^*} - S_{i^*, M_i^*} \quad (3)$$

S_{i, M_i^*} 就是一个反事实推理, 因为它需要相同变量的值 i 在不同路径设置不同的值, 间接效应可以直接通过总效应减去直接因果效应, 表达式为:

$$\text{TIE} = \text{TE} - \text{NDE} = S_{i,M_i} - S_{i,M_i^*} \quad (4)$$

2.2. 推荐系统中的因果图分析

流行性偏见是推荐系统中一个长期存在的挑战：流行的项目被过度推荐，而用户可能感兴趣的不太流行的项目却被推荐不足。这种偏见对用户和商品提供商都产生了不利影响，许多人都致力于研究和解决这种偏见[8]。利用因果关系探讨流行度偏见，如图2所示的因果图描述了推荐过程中的重要因果关系，这与历史互动的生成过程相对应，其中 U 表示用户， I 表示项目， M 表示用户和项目的特征匹配， S 表示排名分数或交互概率。当前交互可能性的主要有三个因素，分别是用户-项目匹配、用户一致性和项目的受欢迎程度。现有的推荐模型主要关注的是用户-项目匹配因素，事实上，另外两个因素对最终的交互概率也有十分重要的影响。假设同一个用户对于两个商品拥有相同的匹配度，那么流行度更高的商品更有可能被推荐给用户并进行购买，这就是从节点 U 到节点 S 边的含义；另外，不同用户受到商品的受欢迎程度的影响也会有所不同，有些用户更倾向于购买流行度高的商品，有些用户则更喜欢一些比较冷门的商品，这是从节点 I 到节点 S 的含义。

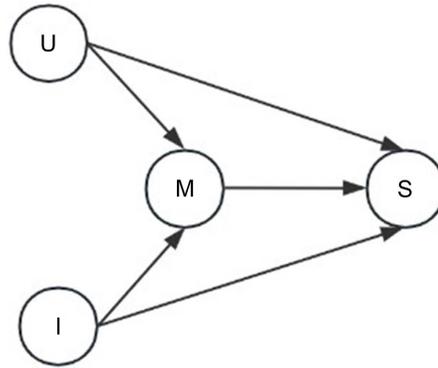


Figure 2. Recommendation system causal inference diagram
图2. 推荐系统因果推断图

2.3. 模型不可知的反事实推理框架

从因果关系的角度来看，项目的流行程度会直接影响最终的推荐得分，所以消除了从物品流行程度到推荐得分的直接影响就可以消除流行度偏差，所以首先需要在训练时建模因果图中的因果效应。反事实推理框架的三个模块分别建模因果图 $U \rightarrow S$ ， $M \rightarrow S$ 和 $I \rightarrow S$ 的因果路径对推荐的影响，并执行多任务学习来进行模型训练。既然是模型不可知的，所以该框架与模型无关，可以实现在现有的协同过滤推荐系统之上，只需要添加用户和物品模块到框架中，这些模块就会将用户和项目融入到推荐分数中。

3. 改进后的无关模型反事实推理框架

3.1. 时间因子

目前的推荐算法能够引入的计算因子主要包括用户社会关系、用户信誉度以及时间因子等[5]。用户在使用系统的过程中，他每次行为的时间往往会被准确的记录下来，推荐算法的首要目的就是要找出目标用户当前最有可能感兴趣的项目，目标用户最近的行为数据才是最具有价值的的数据[9] [10]，引入时间因子的合理之处就在于它可以更好的划分不同数据的价值，拥有了时间因子的参与，用户和项目的匹配度可以更加精准，可以进一步帮助消除流行度偏差。用户 u 对项目 i 评分的时间权重可以定义为：

$$TW(u,i) = e^{-\gamma \frac{T_i - T_f}{L_u}} \tag{5}$$

T_f 表示用户首次进行项目评价的时间, T_i 表示用户对项目 i 评分时对应的的时间, L_u 表示用户 u 使用推荐系统的总时长, 同时利用艾宾浩斯遗忘规律进一步改进, 每一个不同时间点的评分项都有一个不同的时间权重, 距离当前时间越近的评分时间权重越大。

3.2. 融合时间因子的因果图

将时间因子融入到因果图中, 用户 - 项目 - 时间共同决定了用户和项目的匹配程度, 时间因子的加入使得用户和项目的匹配更加细粒度化, 通过模型训练可以进一步消除流行度偏差

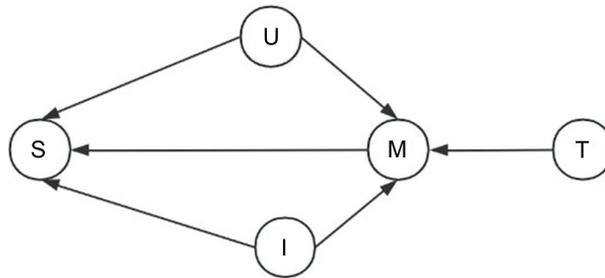


Figure 3. Causal inference graph integrating time factors
图 3. 融合时间因子的因果推断图

3.3. 改进的反事实推理框架

图 4 所示为改进的反事实推理框架, 它的实现遵循图 3 的因果图, 一共分为了三个模块, 分别是用户 - 项目 - 时间段匹配模块、项目模块以及用户模块。在用户 - 项目 - 时间段匹配模块中, 匹配分数可以表示为 $\hat{s}_m = S_m(M(U = u, I = i, T = t))$, 它反映了在某一段时间内, 用户和项目的匹配程度; 项目模块得分可以表示为 $\hat{s}_i = S_i(I = i, T = t)$, 反映了在某一段时间内, 项目受欢迎程度的影响, 受欢迎程度越高的项目得分越高; 用户模块的分可以表示为 $\hat{s}_u = S_u(U = u, T = t)$, 反映了在某一段时间内, 用户 u 和项目交互的程度。由于考虑到随机向两个用户推荐同一个项目, 其中一个用户可能会因为从众性更强或者偏好更广而点击这个项目, 这类用户更容易收到项目流行度的影响, 因而评分也会更高。将这三个分支汇总为最终预测分数如下所示:

$$\hat{S}_{ui} = \hat{S}_m * TW(u,i) * \partial(\hat{S}_i) * \partial(S_u) \tag{5}$$

公式中 $\partial(\cdot)$ 是一个 s 型的函数, 它的作用就是依赖用户 - 项目的匹配程度来恢复历史的交互记录。

本论文以 BCE 损失函数来监督和恢复历史交互, 如下所示:

$$L_o = \sum_{(u,i) \in D} - \left[s_{ui} \log(\partial(\hat{s}_{ui})) + (1 - s_{ui}) \log(1 - \partial(\hat{s}_{ui})) \right]$$

$$L_U = \sum_{(u,i) \in D} - \left[s_{ui} \log(\partial(\hat{s}_u)) + (1 - s_{ui}) \log(1 - \partial(\hat{s}_u)) \right]$$

$$L_I = \sum_{(u,i) \in D} - \left[s_{ui} \log(\partial(\hat{s}_i)) + (1 - s_{ui}) \log(1 - \partial(\hat{s}_i)) \right]$$

L_o, L_U, L_I 均为推荐损失, 最终的训练损失函数为:

$$L = L_o + \alpha * L_I + \beta * L_U \tag{6}$$

消除人气偏差的关键就是通过路径 $I \rightarrow S$ 从排名分数中将直接影响剔除，其中 θ 是超参数，表示的是直接因果效应， TW 表示时间因子。公式如下：

$$\hat{s}_k * \partial(\hat{s}_i) * \partial(\hat{s}_u) * TW(u, i) - \theta * \partial(\hat{s}_i) * \partial(\hat{s}_u) * TW(u, i) \tag{7}$$

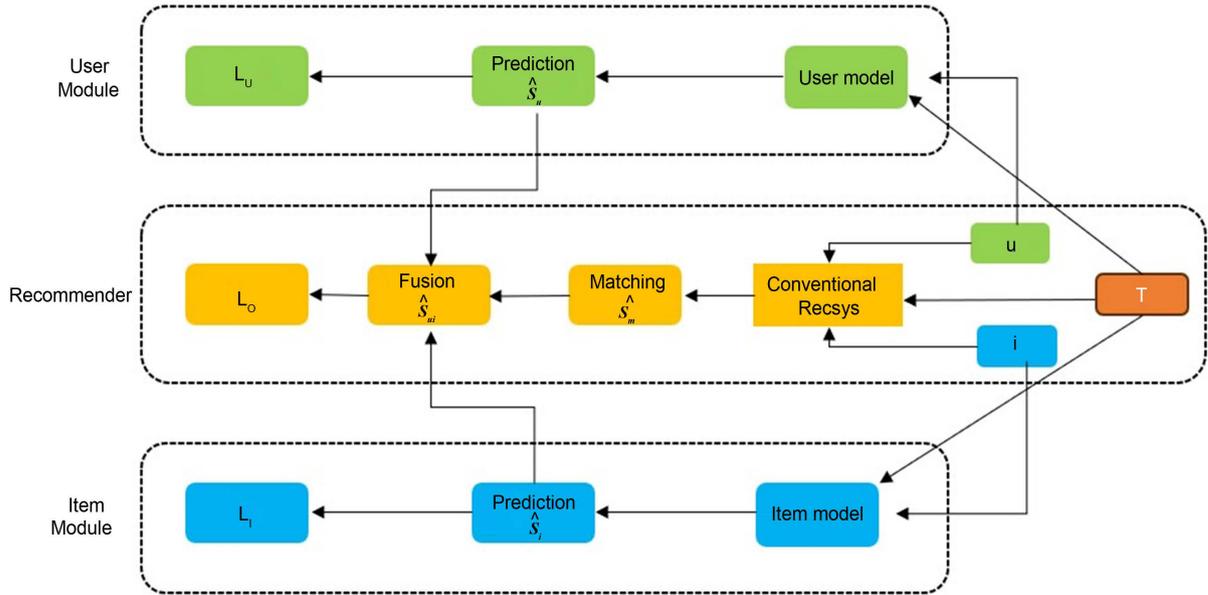


Figure 4. Improved counterfactual reasoning framework
图 4. 改进的反事实推理框架

4. 实验结果分析

4.1. 评价指标

命中率(Hit Ratio, 简称命中率): 命中率强调的是模型推荐的准确性, 即用户感兴趣的项目是否包含在模型的推荐项中, 可以表示为:

$$HR = \frac{1}{S} \sum_{i=1}^S hit(i)$$

S 为样本的数目, 可以理解为用户的需求项的数目。Hit(i)用于表述第 i 项需求项是否包含在模型推荐的项目列表中。若在, 则其值为 1; 否则为 0。

归一化折损累计增益(Normalized Discounted Cumulative Gain, 简称 NDCG): NDCG 强调的是用户的需求项在模型推荐列表中的位置, 越靠前越佳, 可以表示为:

$$NDCG = \frac{1}{S} \sum_{i=1}^S \frac{1}{\log_2(p_i + 1)}$$

S 为样本的数目, 可以理解为用户的需求项的数目。 $P(i)$ 为第 i 项需求项在模型推荐的项目列表中的位置。若第 i 个需求项不在推荐列表中, 则 $\frac{1}{\log_2(p_i + 1)}$ 为 0。

召回率(Recall, 简称 Rec): 召回率是推荐系统在召回阶段常用的评价指标。在其他的领域也经常看到 Recall 作为评价指标, 其含义为正样本中由多少预测为真。在推荐系统中, Recall 可以表示为:

$$\text{recall}_u = \frac{|R(u) \cap T(u)|}{|T(u)|}$$

其中 u 为用户, $R(u)$ 为模型预测出的需要推荐的 item 的集合, $T(u)$ 表示真实的测试集中被推荐的集合。对每一个用户求得 recall 后求平均就可以得到整个数据集上的 recall。

4.2. 实验结果比较

本实验使用 MovieLens 10M 数据集作为实验数据集, 使用经典的 MF 算法来实现改进以后的反事实推理框架 TMACR, 已探索 TMACR 框架如何提高推荐的性能。实验将本论文的方法和 MF 推荐算法以及 MACR_MF 算法两个基线进行比较, 利用命中率、归一化折损累计增益、召回率来作为实验的评价指标。它们的比较结果分别如图 5, 图 6, 图 7 所示, MF 算法均低于 MACR_MF 和 TMACR_MF, 说明反事实推理框架可以帮助矩阵分解算法缓解流行度偏差, 同时本论文提出的改进的反事实推理框架 TMACR 缓解流行度偏差的效果要好于原框架, 证明了本论文方法的有效性。

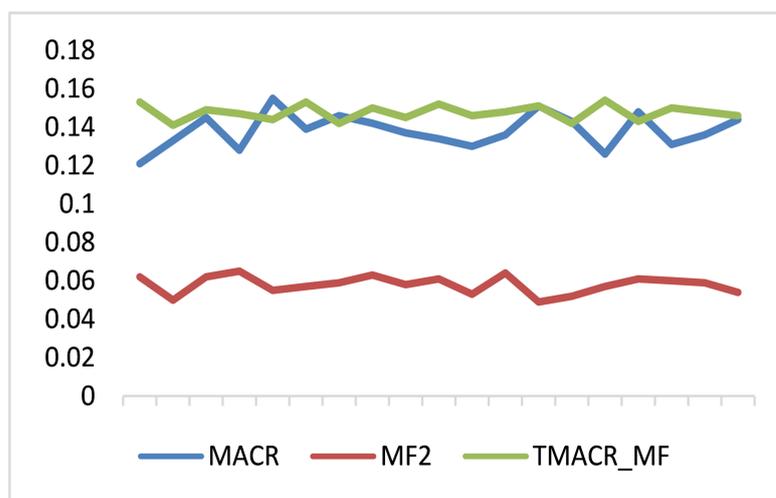


Figure 5. Comparison of hit rates of different algorithms

图 5. 不同算法的命中率对比

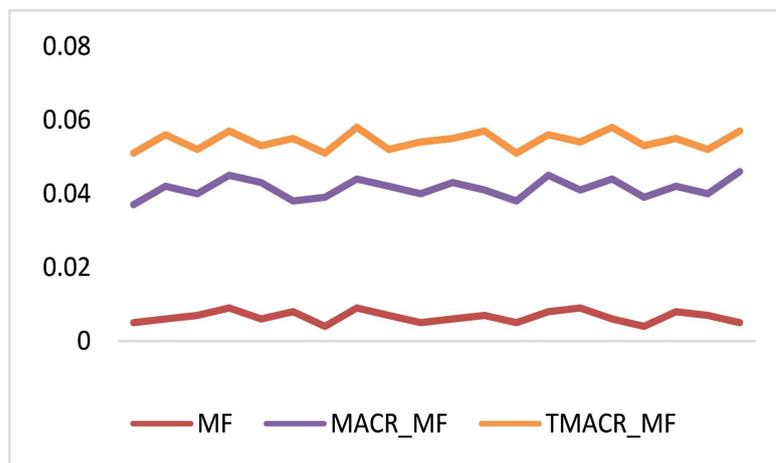


Figure 6. Comparison of normalized loss cumulative gain of different algorithms

图 6. 不同算法的归一化折损累计增益对比

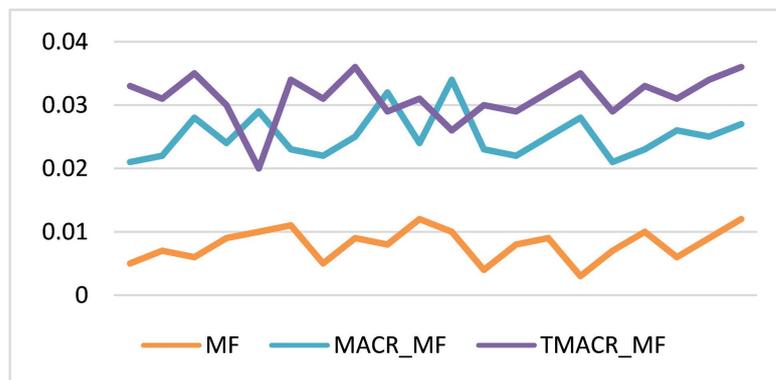


Figure 7. Comparison of recall rates of different algorithms
图 7. 不同算法的召回率对比

5. 结束语

本文提出的改进的反事实推理框架由于融入了时间因子，这使得框架更偏向于通过用户最近的行为来进行推荐，针对项目流行度和用户一致性也将时间因素考虑在内，通过反事实推理消除了项目流行度和用户一致性对与用户项目交互的影响，所以在消除流行度偏差的效果相较于原框架有所提升。

参考文献

- [1] Abdollahpouri, H., Mansoury, M., Burke, R., et al. (2020) The Connection between Popularity Bias, Calibration, and Fairness in Recommendation. *Proceedings of the 14th ACM Conference on Recommender Systems*, New York, 22-26 September 2020, 726-731. <https://doi.org/10.1145/3383313.3418487>
- [2] Perc, M. (2014) The Matthew Effect in Empirical Data. *Journal of the Royal Society Interface*, **11**. <https://doi.org/10.1098/rsif.2014.0378>
- [3] Gruson, A., Chandar, P., Charbuillet, C., McInerney, J., Hansen, S., Tardieu, D. and Carterette, B. (2019). Offline Evaluation to Make Decisions About Playlist Recommendation Algorithms. *Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining*, New York, 11 February 2019, 420-428. <https://doi.org/10.1145/3289600.3291027>
- [4] Abdollahpouri, H., Burke, R. and Mobasher, B. (2019) Managing Popularity Bias in Recommender Systems with Personalized Re-Ranking.
- [5] Wei, T., Feng, F., Chen, J., et al. (2021) Model-Agnostic Counterfactual Reasoning for Eliminating Popularity Bias in Recommender System. *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, New York, 7 June 2021, 1791-1800. <https://doi.org/10.1145/3447548.3467289>
- [6] Zhang, Y., Feng, F., He, X., et al. (2021) Causal intervention for leveraging popularity bias in recommendation. *Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*, New York, 13 May 2021, 11-20. <https://doi.org/10.1145/3404835.3462875>
- [7] Zheng, Y., Gao, C., Li, X., et al. (2021) Disentangling User Interest and Conformity for Recommendation with Causal Embedding. *Proceedings of the Web Conference 2021*, New York, 19-23 April 2021, 2980-2991. <https://doi.org/10.1145/3442381.3449788>
- [8] Zhu, Z., He, Y., Zhao, X., et al. (2021) Popularity Bias in Dynamic Recommendation. *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, New York, 14-18 August 2021, 2439-2449. <https://doi.org/10.1145/3447548.3467376>
- [9] 张凯辉, 周志平, 赵卫东. 结合 CFDP 与时间因子的协同过滤推荐算法[J]. 计算机工程与应用, 2020, 56(15): 6.
- [10] 张帅, 高旻, 文俊浩, 等. 基于自监督学习的去流行度偏差推荐方法[J]. 电子学报, 2022, 50(10): 2361.