

基于双视角纠偏的推荐模型

黄露, 倪蓓, 金澈清

引用本文

黄露, 倪蓓, 金澈清. 基于双视角纠偏的推荐模型[J]. 计算机科学, 2023, 50(9): 152-159.

HUANG Lu, NI Lyu, JIN Cheqing. Rectifying Dual Bias for Recommendation[J].

Computer Science, 2023, 50(9): 152-159.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[面向移动应用评分推荐的多任务图嵌入深度预测模型](#)

Multi-task Graph-embedding Deep Prediction Model for Mobile App Rating Recommendation

计算机科学, 2023, 50(9): 160-167. <https://doi.org/10.11896/jsjcx.220700035>

[基于深度强化学习与程序分析的OJ习题推荐模型](#)

OJ Exercise Recommendation Model Based on Deep Reinforcement Learning and Program Analysis

计算机科学, 2023, 50(8): 58-67. <https://doi.org/10.11896/jsjcx.220600260>

[基于因果推断的图注意力网络](#)

Graph Attention Networks Based on Causal Inference

计算机科学, 2023, 50(6A): 220600230-9. <https://doi.org/10.11896/jsjcx.220600230>

[基于注意力机制的可解释点击率预估模型研究](#)

Study on Interpretable Click-Through Rate Prediction Based on Attention Mechanism

计算机科学, 2023, 50(5): 12-20. <https://doi.org/10.11896/jsjcx.221000032>

[基于图注意力的神经协同过滤社会推荐算法](#)

Neural Collaborative Filtering for Social Recommendation Algorithm Based on Graph Attention

计算机科学, 2023, 50(2): 115-122. <https://doi.org/10.11896/jsjcx.211200019>

基于双视角纠偏的推荐模型

黄露 倪蓓 金澈清

华东师范大学数据科学与工程学院 上海 200062

(1533987824@qq.com)

摘要 近几年,推荐算法快速增长,但大多数研究都重点关注如何利用机器学习模型更好地拟合历史交互数据。然而,推荐系统中的历史交互数据往往是观察性的,而非实验性数据。观测数据存在多种偏差,其中最典型的是流行度偏差。大多数处理流行度偏差的方法采用去除流行度偏差的策略,但是去偏策略本质上难以提升推荐精准性,这是因为推荐算法所引起的偏差会扩大。因此,同时在训练和推断阶段充分利用流行度偏差的纠偏策略更为可行。文中结合因果图分别从用户和物品两个角度来纠偏,提出了一个双偏去混及调整模型(Double Bias Deconfounding and Adjusting, DBDA)。在训练阶段剥离产生不利影响的流行度偏差,并在推断阶段根据流行度的变化趋势,对用户偏好做出更为精准的预测。在3个大规模公开数据集上进行实验,结果表明,相比目前的最优方法,所提方法在各个评价指标上提升了2.48%~19.70%。

关键词: 推荐系统;协同过滤;因果推断;后门调整;流行度偏差

中图法分类号 TP183

Rectifying Dual Bias for Recommendation

HUANG Lu, NI Lyu and JIN Cheqing

School of Data Science and Engineering, East China Normal University, Shanghai 200062, China

Abstract In recent years, a large number of recommendation algorithms have emerged, most of which focus on how to construct a machine learning model to give a good fit to historical interaction data. However, historical interaction data always come from observations rather than experiments in recommendation. Various biases exist in observed data, where the popularity bias is a representative one. Most approaches to dealing with popularity bias use the strategy of removing the popularity bias. But it is actually difficult for these approaches to improve the recommendation accuracy due to bias amplification caused by recommendation algorithms. Thus, the strategy of leveraging the popularity bias both in training and inference stages is more applicable. Combined with the causal graph, a double bias deconfounding and adjusting (DBDA) model is proposed to rectify bias from the perspectives of both user and item. In the training stage, the adverse effects of the popularity bias are removed, and in the inference stage, a more accurate prediction of user preferences is made with the aid of the trend of popularity. Experiments are conducted on three large-scale public datasets to verify that the proposed method produces 2.48%~19.70% higher diverse evaluation metrics than the state-of-art method.

Keywords Recommender system, Collaborative filtering, Causal inference, Back-door adjustment, Popularity bias

1 引言

当今社会是一个信息爆炸的时代,推荐系统的出现有效地缓解了信息过载问题。传统推荐系统的关注点大多在于找到更好的模型来拟合观察数据,但观察数据存在各种各样的偏差,例如选择偏差、暴露偏差、流行度偏差等^[1]。有些偏差会降低推荐的精度,例如选择偏差通常是由用户产生的,用户倾向于评价符合其偏好的物品,于是所观察到的评分并不能代表所有评分,从而降低了模型的预测性能。而对于流行度偏差,其本身并不会降低模型的预测性能,但推荐系统作为

一个循环系统,流行度偏差在每一次推荐中会被扩大。这使得越流行的物品具有越多的曝光机会,而不流行的物品会被当作负样本,从而缺少曝光机会。这不仅会影响用户的个性化体验,还会影响物品提供方的潜在收益。

现有研究流行度偏差的推荐系统算法大都是从物品的角度去考虑,典型的去偏方法可分为以下几类:

(1)逆概率加权(Inverse Propensity Weight, IPW),是去偏方法中非常重要且基础的方法^[2]。它通过改变观察数据中物品的曝光分布,来达到去偏的目的。但基于IPW的方法存在一些明显的缺陷,它不但极度依赖于得分估计的准确性,

到稿日期:2022-09-05 返修日期:2022-12-08

基金项目:上海市青年科技英才扬帆计划项目(22YF1411300)

This work was supported by the Shanghai Sailing Program (22YF1411300).

通信作者:倪蓓(lni@dase.ecnu.edu.cn)

而且预测结果的稳定性差,尤其对于不流行的物品。

(2) Causal Embedding (CausE), 是利用一小部分的无偏数据来调整模型去学习无偏的权重, 该方法可以消除由数据产生的一系列偏差^[3]。但在实际中, 所需的无偏数据是通过向用户随机推荐物品来得到的, 这会严重影响用户的体验和物品提供方的利益, 导致在实际业务场景中难以获得无偏数据或只能较小规模地获得无偏数据。

(3) 基于因果推断的推荐系统算法, 是当前研究的热点。其主要思想是通过先验知识构建能反映数据生成机制的因果图, 再利用因果推断的技术解决偏差问题。其中具有代表性的算法是 Disentangling Interest and Conformity with Causal Embedding (DICE), 其利用因果导向的数据, 分类用户真实兴趣与其从众心理, 使得推荐结果更稳定且兼具可解释性^[4]。

然而, 上述方法都仅考虑如何去流程度偏差, 实际上, 流程度偏差本身并没有问题, 其核心问题在于推荐系统所导致的流程度偏差的扩大, 也就是说, 上述方法对流行物品的推荐频率常常会超过其在训练集中的频率。相比去偏, 纠偏更注重纠正偏差; 在训练阶段去除偏差, 更精准地捕捉用户的真实兴趣; 在推断阶段调整流程度, 来获得更符合流程度的发展

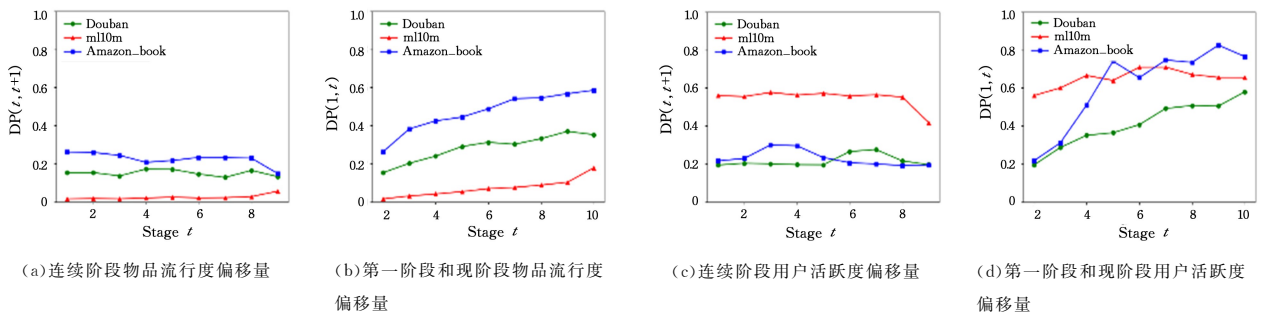


图1 两阶段之间的流程度偏移和活跃度偏移

Fig. 1 Popularity drift and activity drift between two stages

为了探索物品流程度和用户活跃度是如何影响最终用户对物品的点击概率的, 本文采用因果图^[6]来描述推荐系统中数据的生成机制, 如图2所示。图2(a)给出了传统推荐系统的数据生成过程, 将用户 U 和物品 I 分别作为输入, 经过模型训练, 最终输出用户对该物品的点击行为 Y 。用户和物品均会对点击概率造成影响。在图2(b)中, 考虑了物品流程度 M 这个混杂因子的存在, 其本身既会影响点击行为 Y 发生的概率, 又会影响物品 I 对点击行为 Y 造成的影响。而本文所提出的因果图如图2(c)所示, 将物品流程度和用户活跃度两个混杂因子显式地展现出来, 从而达到解耦的效果。这里, M 表示物品的流程度, N 表示用户的活跃度。这两个混杂因子不但会影响点击行为发生的概率, 而且会使得 $I \rightarrow Y \leftarrow U$ 这条路径上产生伪相关, 从而无法通过模型准确地估计用户对物品的真实偏好。

根据数据验证以及数据生成过程的分析, 可以发现, 物品流程度和用户活跃度作为混杂因子, 会影响物品和用户对其点击行为的预测, 从而降低推荐系统算法的准确性。为了在训练阶段消除混杂因子对物品和用户的影响, 即避免物品和用户的曝光分布遭受混杂因子的影响, 推荐算法中需要调整曝光策略, 即随机选取用户并随机给他们推荐物品, 使得所得

趋势。现有研究^[5]仅从物品的角度利用流程度偏差来提升模型的预测性能。本文将创新性地从物品与用户双视角出发, 仅基于用户历史交互数据, 更为精确且全面地考虑了流程度偏差所造成的影响。

为了验证在实际数据中确实存在物品流程度偏差和用户活跃度偏差, 本文利用 Yang 等^[5]提出的流程度偏移量 (Drift of Popularity, PD), 即两个阶段下流程度概率分布的 Jensen-Shannon 散度, 并类似地定义了用户活跃度偏移量, 以此证明不仅物品流程度是随时间动态变化的, 用户活跃度也会随时间动态变化。图1(a)和图1(c)给出了阶段 t 和阶段 $t+1$ 之间的流程度偏移量, 可以看出相邻两阶段之间存在一定的物品流程度和用户活跃度偏移。而图1(b)和图1(d)给出了以第1阶段为参照之后各个阶段与其的流程度偏移量, 不难看出随着时间的变化, 物品流程度偏差总体呈现增长的趋势, 而用户活跃度偏差会出现不同的模式。由图1可知, 物品流程度偏差和用户活跃度偏差确实存在, 而这两者的影响均会随时间发生变化, 且长期看变化更为明显。由此, 验证了数据中确实存在物品流程度偏差和用户活跃度偏差, 下文将具体分析这两种偏差在整个数据生成过程中是如何产生影响的。

到的交互数据免受混杂因子的影响。但是, 在实际中难以获得大量这样的无偏数据。幸运的是, 基于所构建的因果图, 可以利用因果推断中的后门调整技术, 在不重新收集数据的前提下, 去除影响物品和用户分布的混杂因子。具体来说, 就是通过 $P(Y|do(U, I))$ 来切断通向节点 I 和节点 U 的连边, 从而切断混杂因子对物品和用户曝光分布的影响。相比 $P(Y|U, I)$, $P(Y|do(U, I))$ 通过 do-演算^[6]去除了 $I \rightarrow Y$ 和 $U \rightarrow Y$ 之间的伪相关, 能更精准地捕捉用户的真实兴趣。在推断阶段, 利用 $P(Y|do(U, I), do(M))$ 对流程度进行干预, 以获得更符合流程度的发展趋势。经过去偏和调整偏差这两个阶段后做到了双视角纠偏, 从而达到了提升推荐性能的目的。

本文的主要贡献点如下:

(1) 本文利用因果图, 首次从物品和用户两个视角分析偏差对推荐系统的影响, 并利用流程度偏差来缓解数据在训练集和测试集之间非独立同分布的问题, 使得模型更具鲁棒性和可解释性。

(2) 本文基于贝叶斯个性化排序^[7]损失函数, 提出了一种新的损失函数, 可以同时利用物品流程度和用户活跃度信息训练模型。

(3) 在3个大规模真实数据集上进行实验, 验证了双视角

因果分析及本文方法的有效性。




图2 描述推荐系统中数据生成的因果图

Fig. 2 Causal graph to describe the process of data generation in recommender system

2 相关工作

本文利用因果推断中的技术对推荐系统产生的交互数据进行纠偏,首先介绍了基于因果推断的偏差处理方法,然后介绍了现有的对流行度偏差的研究方法。

2.1 基于因果的处理偏差的方法

人工智能领域可解释性弱和稳定性差等问题越来越受到人们的关注。为了深入探索深度学习模型的内在机理,因果推断提供了一种可行的解决方案。推荐系统算法也在寻求与因果推断方法相结合的途径。因此,近年来涌现出了一些利用因果推断技术来解决推荐系统中流行度偏差问题的研究。常用的因果推断技术有3类:(1)前门调整^[8],假设给定变量满足前门准则,即其能够阻断用户或物品对点击行为的影响,因而可以通过前门调整的技术来处理无法测量或无法观测到的混杂因子,然而物品流行度和用户活跃度并不属于这一类变量;(2)反事实推理^[9],物品暴露分布对最终点击概率的直接影响可通过使用中介因子来消除,然而,反事实的数据难以获得,且反事实的假定常常缺乏理论基础;(3)后门调整^[5,10],通过将数据分层可消除混杂因子对数据曝光分布的影响,该方法是基于因果推断进行去偏方法中的核心技术。

2.1 利用流行度偏差的方法

近年来,较多研究者开始关注推荐系统中的可解释性和鲁棒性问题,因为用户的历史交互数据是观察性的,而不是实验性的,所以数据会存在各种偏差。如果不考虑数据的内在偏差而盲目拟合数据,则会造成许多严重的问题。例如,线下评估和线上推荐产生较大差异,既影响用户的满意度又影响相关利益者的收益。近几年已有很多相关人员研究了推荐系统中偏差的影响问题并提出了去偏的策略。从图3^[1]可以看出,推荐系统是一个循环系统,它有3个重要的组成部分:用户、数据和模型^[1]。本文讨论的流行度偏差是在模型→用户阶段产生的,该阶段将模型所产生的推荐结果反馈给用户,以满足用户对信息的需求,这会影响到用户未来的行为和决策。现阶段大多数对流行度偏差的研究都是在研究如何去除交互数据中的流行度偏差,但流行度偏差本身对推荐系统并不一定会产生不利的影 响,真正的影响在于在这样一个循环系统中流行度偏差被进一步扩大,因此本文需要解决的是这一问题,而非仅仅消除流行度偏差让每个物品都被等概率推荐。Yang等^[5]提供了一种“利用”流行度偏差的思路。在训练阶段,与传统的思路一样,先去除流行度偏差对点击概率的影响,而在推断阶段,以期望的流行度来进行干预。除了物品

流行度之外,用户活跃度也是在推荐系统中常见的混杂因子。但在对现有推荐系统算法的文献调研中发现,同时从物品和用户两个视角来纠正偏差问题的推荐系统算法,仍是一个需要进一步探索的研究方向。




图3 在循环系统中各阶段产生的偏差

Fig. 3 Biases occur in different stages in loop system

3 概念和预备知识

3.1 基础符号

本小节将介绍本文中使用的符号。

$U = \{u_1, u_2, \dots, u_{|U|}\}$ 和 $I = \{i_1, i_2, \dots, i_{|I|}\}$ 分别表示全部的用户和物品。其中, $|U|$ 表示用户数, $|I|$ 表示物品数。对于每一个 (u, i) 对的交互标签表示为 $Y \in \{0, 1\}$ 。

$$y_{ui}^t = \begin{cases} 1, & \text{如果 } t \text{ 阶段用户 } u \text{ 和物品 } i \text{ 发生了交互} \\ 0, & \text{否则} \end{cases}$$

$\mathcal{D} = \{\mathcal{D}_1 \cup \dots \cup \mathcal{D}_T\}$ 表示历史数据集,其中 $y_{ui}^t \in \mathcal{D}_t$ 表示沿时间不断积累的数据。基于历史数据,推荐系统希望能够捕捉用户在下一阶段的偏好。由此,分别定义在阶段 t 物品 i 的局部流行度和用户 u 的局部活跃度为:

$$m_i^t = \frac{D_i^t}{\sum_{j \in I} D_j^t} \quad (1)$$

$$n_u^t = \frac{D_u^t}{\sum_{v \in U} D_v^t}$$

其中, D_i^t 表示在 \mathcal{D}_t 中物品 i 可观察到的交互数量, $D_i^t = \sum_{u \in u_i^t} y_{ui}^t$, u_i^t 表示 t 时刻下与物品 i 交互过的用户集合。同理 D_u^t 表示在 \mathcal{D}_t 中用户 u 可观察到的交互数量, $D_u^t = \sum_{i \in i_u^t} y_{ui}^t$, i_u^t 表示 t 时刻下与用户 u 交互过的物品集合。

3.2 因果图

本文根据推荐系统中数据的生成机制构建了一个因果图。首先,如图2(a)所示,构建一个基本的因果图,也就是用户表示和物品表示会最终影响点击概率。在这个基础上,本文考虑到了 $I \rightarrow Y$ 和 $U \rightarrow Y$ 两条路径中产生的混杂因子,分别为物品的流行度 M 和用户的活跃度 N ,最终所构建的因果图如图4(a)所示。这里的因果图是符合直觉并且合理的,因为推荐系统产生的交互数据通常不是通过实验得到的,而是通过观察得到的,所以会存在曝光机制对最终结果产生影响的现象。针对物品和用户的曝光机制,可将其显性地反映在物品流行度和用户活跃度上。对于路径 $I \leftarrow M \rightarrow Y$,物品的流行度越高,说明物品的质量越高,同时由于用户的从众心理,物品流行度还会直接影响最终的点击概率。对于路径 $U \leftarrow N \rightarrow Y$,用户的活跃度越高说明用户本身的点击积极性就越高,同时由于头部效应,活跃用户交互过的物品被点击的概率就会越高,从而影响到最终的点击概率。

这里构建的因果图是反映推荐系统中数据的生成机制,因此它会启发式地帮助推荐系统模型更好地估计用户的偏好。

3.3 基本概念和定理

本小节将展示图 4(a)是如何通过后门调整变成图 4(b)的,也就是说如何通过后门调整在训练阶段消除物品表征和用户表征的流行度偏差影响。为了达到上述目的,这里给出后门准则(Back-door Criterion)的定义。

定义 1(后门准则)^[6,11] 给定有向无环图中的一对有序变量 (X, Y) ,如果变量集合 Z 满足 Z 中没有 X 的后代节点,且 Z 阻断了 X 与 Y 之间的每条含有指向 X 的路径,则称 Z 满足关于 (X, Y) 的后门准则。

给定一组满足后门准则的变量集,可以识别含有可观察混杂因子的因果效应。从图 4 可以看出,节点 M (非节点 I 的后代)阻断了 $I \rightarrow Y$ 之间的路径,因此节点 M 满足后门准则。同理,节点 N 也满足后门准则。因此 $I \rightarrow Y \leftarrow U$ 的因果效应可以通过修正节点 M 和节点 N 识别出。

引理 1(后门调整)^[6,11] 如果变量集合 Z 满足关于 (X, Y) 的后门准则,那么 X 对于 Y 的因果效应是可识别的,表达式为:

$$P(Y=y|do(X=x)) = \sum_z P(Y=y|X=x, Z=z)P(Z=z)$$

本节介绍了因果图的具体结构,以及因果推断中的后门调整技术。下一节将针对所构建的因果图,运用上文介绍的后门调整技术来进行去混杂因子的操作,从而在训练阶段去除物品流行度偏差和用户活跃度偏差。

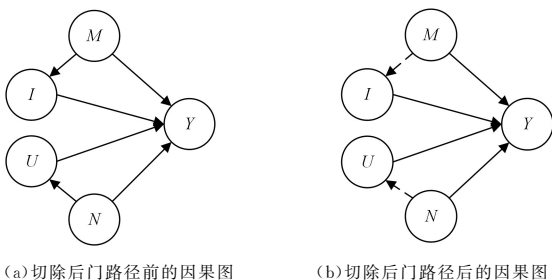


图 4 后门调整对因果图的影响

Fig. 4 Effect of back-door adjustment on causal graph

4 双偏去混及调整方法

本节将从训练和推断两个阶段来构建双视角纠偏的推荐模型。

4.1 训练阶段双视角去偏

训练阶段的目标是去除物品流行度和用户活跃度的影响,从而得到用户对给定物品的“真实”兴趣,也就是说,最终的点击概率只是用户真实兴趣的体现,不应受到其他混杂因子的影响。这里使用 do 算子,采用 $P(Y|do(U, I))$ 代替传统的 $P(Y|U, I)$ 来表示最终的点击概率,利用引理 1 和数据表示 $P(Y|do(U, I))$,即:

$$\begin{aligned} P(Y|do(U, I)) &= \sum_{m,n} P(Y|U, I, m, n)P(m, n) \\ &= \sum_{m,n} P(Y|U, I, m, n)P(m)P(n) \end{aligned} \quad (2)$$

其中, $P(\cdot)$ 是概率, $P(m)$ 是物品流行度的概率, $P(n)$ 是用

户活跃度的概率。注意到等式(2)的第二个等式成立,是因为本文所构建的因果图,如图 4 所示。此时物品流行度和用户活跃度是互相独立的。

下文考虑如何用数据去估计等式(2),首先估计 $P(Y|U, I, M, N)$,再估计 $P(Y|do(U, I))$ 。

4.1.1 估计 $P(Y|U, I, M, N)$

$P(Y|U, I, M, N)$ 表示给定 (u, i) 对以及物品 i 的流行度 $M=m'_i$ 和用户 u 的活跃度 $N=n'_u$ 下点击行为的发生概率。设该条件概率的参数为 θ ,通过历史交互数据集 \mathcal{D} 及 BPR 损失函数来学习未知参数:

$$l = \min_{\theta} \sum_{(u,i,j) \in \mathcal{D}} -\ln(\sigma(P_{\theta}(y=1|u, i, m'_i, n'_u) - P_{\theta}(y=1|u, j, m'_j, n'_u))) \quad (3)$$

其中, j 表示用户 u 对物品的负采样, $\sigma(\cdot)$ 表示 sigmoid 函数。

下文将 $P_{\theta}(y=1|u, i, m'_i, n'_u)$ 参数化,并将其转化成可解决的问题。本文采用最经典的矩阵分解^[12](Matrix Factorization, MF)模型来对数据进行拟合。于是,假定 $P_{\theta}(y=1|u, i, m'_i, n'_u)$ 的参数化形式如下:

$$P_{\theta}(y=1|u, i, m'_i, n'_u) = ELU'(f_{\theta}(u, i)) \times (m'_i)^{\gamma_1} \times (n'_u)^{\gamma_2} \quad (4)$$

其中,超参 γ_1, γ_2 分别是为了刻画物品流行度、用户活跃度的强度和纠偏的程度; $ELU'(\cdot)$ 为指数线性单元^[13](Exponential Linear Unit, ELU)激活函数的一种变体,为了确保匹配函数 $f_{\theta}(\cdot)$ 的值一直为正,有:

$$ELU'(x) = \begin{cases} e^x, & x < 0 \\ x+1, & x \geq 0 \end{cases}$$

其中, $(m'_i)^{\gamma_1}$ 和 $(n'_u)^{\gamma_2}$ 的值均为正数;如果 γ_1 和 γ_2 为零,则表示流行度和活跃度不起作用; γ_1 和 γ_2 越大,则流行度和活跃度的影响也越大。而 $ELU'(\cdot)$ 是一个单调函数,这确保了概率函数的单调性。

4.1.2 基于双视角的损失函数改进

根据等式(2)可知,物品流行度和用户活跃度是相互独立的。将等式(4)代入等式(3)后,容易发现物品流行度和用户活跃度解耦了,于是在用 BPR 损失函数进行参数训练时,用户活跃度在减号两边取值相同,导致无法对训练产生影响。换句话说,这样直接构造的损失函数因为没有利用到用户活跃度的信息,所以无法达到对用户活跃度去偏的目的。因此,为解决这一问题,我们对等式(3)中所定义损失函数进行了改进,代替原本的参数训练方法,即利用物品流行度和用户活跃度的信息分别构建了两个损失函数:

$$l_1 = \min_{\theta} \sum_{(u,i,j) \in \mathcal{D}} -\ln(\sigma(P_{\theta}(y=1|u, i, m'_i) - P_{\theta}(y=1|u, j, m'_j))) \quad (5)$$

$$l_2 = \min_{\theta} \sum_{(u,v,i) \in \mathcal{D}} -\ln(\sigma(P_{\theta}(y=1|u, i, n'_u) - P_{\theta}(y=1|v, i, n'_v))) \quad (6)$$

$$l = l_1 + l_2 + \lambda \cdot \|\theta\|^2 \quad (7)$$

其中,等式(5)利用物品流行度训练给定用户 u 对不同物品的偏好程度,等式(6)利用用户活跃度训练不同用户对给定物品 i 的偏好程度。等式(5)和等式(6)中的 $P_{\theta}(\cdot)$ 是由等式(4)所定义的。等式(7)是完整的损失函数, λ 是 L_2 正则项

系数,用于控制过拟合的。通过最小化损失函数 l 来确定参数 Θ 。

4.1.3 估计 $P(Y|do(U,I))$

下文介绍如何估计干预的概率 $P(Y|do(U,I))$ 。这里需要对物品流行度 m 和用户活跃度 n 进行求和,但其空间十分庞大,难以遍历。但根据等式(4),物品流行度和用户活跃度已经解耦,因此我们可以推导出:

$$\begin{aligned} P(Y|do(U,I)) &= \sum_{m,n} P(Y|U,I,m,n)P(m)P(n) \\ &= \sum_{m,n} ELU'(u \cdot i) \cdot (m_i^t)^{\gamma_1} \cdot (n_u^t)^{\gamma_2} \cdot \\ &\quad P(m) \cdot P(n) \\ &= ELU'(u \cdot i) \cdot \left(\sum_m (m_i^t)^{\gamma_1} \cdot P(m) \right) \cdot \\ &\quad \left(\sum_n (n_u^t)^{\gamma_2} \cdot P(n) \right) \\ &= ELU'(u \cdot i) \cdot E(M^{\gamma_1}) \cdot E(N^{\gamma_2}) \end{aligned}$$

其中 $E(\cdot)$ 表示期望,而期望通常被认为是一个常数。在推荐问题中,最终的任务通常是一个对物品的排序任务,我们更关注点击概率的相对值,而非绝对值。因此,可以直接用 $ELU'(u \cdot i)$ 来代替 $P(Y|do(U,I))$ 的估计。

综上,本文用 $P_\Theta(y=1|u,i,m_i^t,n_u^t)$ 拟合了历史交互数据,用改进版 BPR 损失函数训练含有参数的 $P_\Theta(y=1|u,i,m_i^t,n_u^t)$,使得物品流行度和用户活跃度在训练过程中均能得到利用,最后用 $ELU'(u \cdot i)$ 进行排序任务,得到所有用户的推荐排序列表 L_k 。我们将该方法命名为双偏去混(Double Bias Deconfounding, DBD),该算法的流程详见算法 1。

4.2 推断阶段调整流行度偏差

在训练阶段采用 $P(Y|do(U,I))$ 是为了避免流行度偏差的积累。然而,在推断阶段,我们希望利用流行度偏差来找出在测试集上潜在受欢迎的物品,从而提升推荐性能。值得注意的是,这里无需对用户活跃度进行干预,因为在排序任务中,对用户活跃度进行干预并不会改变点击概率的相对值,也就是说并不会改变推荐列表的顺序。因此,推断阶段仅对流行度进行干预。

$$\begin{aligned} P(Y|do(U,I),do(M),do(N)) &= P_\Theta(y=1|u,i,\tilde{m}_i,\tilde{n}_u) \\ &\propto P_\Theta(y=1|u,i,\tilde{m}_i) \end{aligned}$$

其中, \tilde{m}_i 表示测试集上的流行度。根据后门调整技术,干预的概率可直接等于条件概率,这是因为 Y 和 M 以及 Y 和 N 之间没有后门路径。本文采用数学公式预测 \tilde{m}_i 。第一种预测公式如下:

$$\tilde{m}_i = m_i^T$$

其中, m_i^T 表示训练集中最后一阶段的流行度。即利用训练集中最后一阶段的流行度作为测试集中物品流行度的预测。第二种预测公式如下:

$$\tilde{m}_i = m_i^T + \alpha(m_i^T - m_i^{T-1})$$

其中, m_i^T 表示训练集中最后一阶段的流行度。 α 是一个超参,用于控制流行度偏移量。我们将该方法命名为双偏去混及调整(DBDA),训练阶段与 DBD 方法一致,测试阶段需要调整流行度,该算法的流程如算法 1 所示。

算法 1 DBD/DBDA

输入:训练样本 $\mathcal{Q}=\{(u,i,j,v)\}$ (其中 j,v 是通过负采样得到的),超参 γ_1, γ_2 和正则项系数 λ ,物品流行度 $\{m_i^t, \tilde{m}_i\}_{i \in 1}$,用户活跃度

$$\{n_u^t, \tilde{n}_u\}_{u \in U}, \text{mode:DBD 或 DBDA}$$

输出:物品 topK 的排序列表 L_k

1. Randomly initialize parameter Θ ;
2. while not converged do
3. for each training sample $s \in \mathcal{Q}$ do // training stage
4. Lookup the user indexes u, v and item indexes i, j in Θ ;
5. Update model parameter Θ by minimizing the proposed loss function Equation(7);
6. end for
7. if mode == DBD then validate model with $ELU'(f_\Theta(u, i))$ // inference stage;
8. else validate model with Equation(8);
9. end while
10. if mode == DBD then recommend items using $ELU'(f_\Theta(u, i))$ // predict on testing set
11. else recommend items using Equation(8).
12. return L_k

该方法依然用等式(7)进行训练,在推断阶段利用流行度偏差对预测结果进行调整。

$$\begin{aligned} P(Y|do(U,I),do(M),do(N)) &\propto P_\Theta(y=1|u,i,\tilde{m}_i) \\ &= ELU'(u \cdot i) \cdot (\tilde{m}_i)^{\gamma_1} \end{aligned} \quad (8)$$

最后用等式(8)进行排序任务,得到所有用户的推荐排序列表 L_k 。

5 实验

本节将通过实验来展现所提方法在真实数据集上是如何工作的,同时与传统去偏方法进行对比,验证 DBDA 方法的有效性。下文分别描述所采用的数据集、对比方法、实验实施和评价指标,并给出本文的实验结果、分析过程和分析结论。

5.1 数据描述

我们在 3 个大规模公开的数据集上进行实验。

(1) Douban_movie, 其是从国内豆瓣网站上收集到的数据,它包含了 10 年内用户对电影的评分^[14],简称为 douban。我们选取 2010 年之后的数据,将所有有评分的交互作为正样本。过滤掉交互量小于 10 的物品和用户,最终得到的交互量为 7174218,用户数为 47890,物品数为 26047。

(2) MovieLens-10M, 其是从 MovieLens 网站上收集到的评分数据,它包含了 14 年内用户对电影的评分,简称为 ml10m。我们选取最近 5 年的数据,将所有评分数据作为正样本。过滤掉交互量小于 10 的物品和用户,最终得到的交互量为 3349945,用户数为 16593,物品数为 8015。

(3) Amazon_book, 其是从 Amazon Review Datasets 上收集到的数据,它包含了 18 年内用户对书籍的评分,简称为 amazon。我们选取 2012—2014 年的最新数据,将其所有有评分的交互数据作为正样本。过滤掉交互量小于 10 的物品和用户,最终得到的交互量为 2796571,用户数为 101792,物品数为 71481。

本文将数据分为 10 个时间阶段,每个阶段都有相同的时间间隔,最后一个阶段随机将 30% 用户的交互数据作为验证

集,70%用户的交互数据作为测试集。仅在最后一个阶段出现的用户和物品不纳入本实验。

5.2 对比方法

为验证所提出的 DBD 和 DBDA 方法的有效性,我们将以下基础模型作为对比方法。

(1)BPRMF^[12]。该模型用 BPR 损失函数来优化 MF 模型。

(2)PD^[5]。其只在训练阶段去除掉物品的流行度偏差。由于在文献[5]中已与其他经典的流行度去偏方法进行过对比,例如 xQuAD 和 DICE,因此在此我们只与 PD 方法进行对比。值得注意的是,本文提到的 douban 数据集也是文献[5]中 PD 方法所使用的,并且本文的数据处理方式和文献[5]中的数据处理方式是一致的。

(3)PDA^[5]。其是本文主要对比的方法。它也是在训练阶段去除物品流行度,在推断阶段利用物品流行度来提升模型的性能。文献[5]还提出了 BPRMF-A 和 DICE-A 的方法,

就是在推断阶段注入流行度偏差。已有实验证明 PDA 的方法优于 BPRMF-A 和 DICE-A 方法,于是后两者方法不作为本文的对比方法。

5.3 实验实施

为了公平起见,除了涉及到用户的采样方式和损失函数外,其他参数等细节的设置均与 PDA 方法中的设置保持一致。具体来说,模型中均采用 Adam^[15]的优化器,批大小设置为 2048,学习率默认为 0.001,嵌入向量的维数为 64。

在训练阶段,我们对于给定的 (u, i) 对,会随机采样一个用户 u 没有交互过的物品 j 和一个没有交互过物品 i 的用户 v 作为负样本,形成一个四元组 (u, v, i, j) 。

5.4 评价指标

本文用 Top K 的推荐任务来评估模型,并使用 Recall, NDCG, Precision, Hit Ratio (HR) 这 4 个广泛使用的评价指标。表 1 列出了 $K=20$ 和 $K=50$ 时 5 种方法在上述 4 种评价指标上的推荐性能结果。

表 1 3 个数据集上的推荐性能

Table 1 Recommendation performance on three datasets

Dataset	Method	Top 20				Top 50				
		Recall	Precision	HR	NDCG	Recall	Precision	HR	NDCG	
douban	BPRMF	0.0279	0.0333	0.2950	0.0406	0.0578	0.0288	0.4286	0.0475	
	PD	0.0430	0.0430	0.3819	0.0564	0.0811	0.0348	0.5153	0.0648	
	DBD	0.0474	0.0485	0.3998	0.0649	0.0868	0.0378	0.5282	0.0722	
	PDA	(a)	0.0558	0.0549	0.4436	0.0728	0.1071	0.0435	0.5832	0.0835
		(b)	0.0551	0.0525	0.4405	0.0700	0.1019	0.0397	0.5773	0.0784
	DBDA	(a)	0.0586	0.0584	0.4546	0.0783	<u>0.1088</u>	0.0452	<u>0.5855</u>	0.0879
		(b)	0.0585	<u>0.0569</u>	<u>0.4541</u>	<u>0.0770</u>	0.1096	<u>0.0438</u>	0.5898	<u>0.0867</u>
	ml10m	BPRMF	0.0682	0.1076	0.5905	0.1290	0.1267	0.0878	0.7128	0.1333
PD		0.0980	0.1425	0.6973	0.1719	0.1833	0.1137	0.8142	0.1804	
DBD		0.1108	0.1596	0.7347	0.2001	0.1975	0.1223	0.8267	0.2040	
PDA		(a)	0.1142	0.1590	0.7401	0.2033	0.2051	0.1231	0.8332	0.2089
		(b)	0.1215	0.1651	0.7531	0.2104	0.2106	0.1256	0.8356	0.2147
DBDA		(a)	<u>0.1367</u>	<u>0.1796</u>	0.7834	<u>0.2325</u>	<u>0.2215</u>	<u>0.1334</u>	<u>0.8493</u>	<u>0.2328</u>
		(b)	0.1421	0.1818	<u>0.7822</u>	0.2379	0.2284	0.1339	0.8564	0.2379
amazon		BPRMF	0.0468	0.0090	0.1382	0.0266	0.0879	0.0069	0.2344	0.0379
	PD	0.0572	0.0108	0.1646	0.0326	0.1049	0.0080	0.2695	0.0457	
	DBD	0.0592	0.0109	0.1686	0.0345	0.1018	0.0079	0.2635	0.0464	
	PDA	(a)	0.0720	<u>0.0130</u>	0.1994	0.0421	0.1230	0.0092	0.3079	0.0560
		(b)	0.0716	0.0127	0.1975	0.0421	0.1213	0.0090	0.3057	0.0557
	DBDA	(a)	<u>0.0770</u>	0.0138	<u>0.2098</u>	<u>0.0464</u>	<u>0.1287</u>	0.0098	<u>0.3196</u>	<u>0.0607</u>
		(b)	0.0777	0.0138	0.2120	0.0472	0.1289	<u>0.0097</u>	0.3204	0.0613

5.5 结果与讨论

5.5.1 与基本模型进行比较

表 1 列出了在 3 个数据集上针对 5 种不同方法推荐性能的比较结果。前 3 种方法是在训练阶段去除流行度偏差,后 2 种方法是在推断阶段利用流行度偏差对排序进行调整,这里给出两种流行度预测方法,一种是用前一阶段的流行度作为测试阶段流行度的预测值,对应表 1 中的方法(a),另一种是在 2.3 节提出的等式(10),对应表 1 中的方法(b)。

对于每一种评价指标,表中加粗部分表示最优结果,下划线表示次优结果。先看每个数据集的前 3 种方法,可以看出本文方法在各指标上都要优于其他方法;再看后 2 种方法,本文方法也是全面优于对比方法 PDA。特别是在 NDCG@K 评价指标下,本文方法的效果要远好于 PDA,3 个数据集上 Recall@20 指标的提升值分别为 5.02%,19.70%,6.94%,

NDCG@20 指标的提升值分别为 7.55%,14.36%,10.21%。由于 NDCG 指标的主要思想是用户喜欢的物品被排在推荐列表前面比排在后面会更大程度地增加用户的体验,因此本文方法对用户喜欢程度排前面的物品预测得更准,这也更符合推荐的要求。

通过比较不同流行度预测公式对结果的影响可知:无论是 PDA,还是 DBDA,对于预测流行度公式的敏感程度都很大。对于 DBDA,在 douban 数据集上,预测公式(a)的效果更好,而在 ml10m 和 amazon 数据集上,预测公式(b)的效果更好。

5.5.2 不同 K 值对结果的影响

K 值的选取往往依赖于推荐任务本身,选取不同的 K 值对评价指标的影响也很大。我们选取 K 在不同取值时比较各个评价指标的性能。这里选取 K 为 5,10,20,30,40,50。

为进一步比较本文方法 DBDA 对 PDA 的提升,本文计算了相对提升量(Relative Improvement, RI),即:

$$RI = \frac{\text{DBDA 的评价指标} - \text{PDA 的评价指标}}{\text{PDA 的评价指标}}$$

这个量可以描述为,相比 PDA,DBDA 在相应评价指标上的相对提升比例。

如图 5 所示,当 K 值相对较小时,本文方法具有较为明显的优势。随着 K 值的增加,虽然 DBDA 的优势会减弱,但仍明显地优于 PDA。同时,预测公式(b)的预测效果更好,受 K 值的影响较弱。

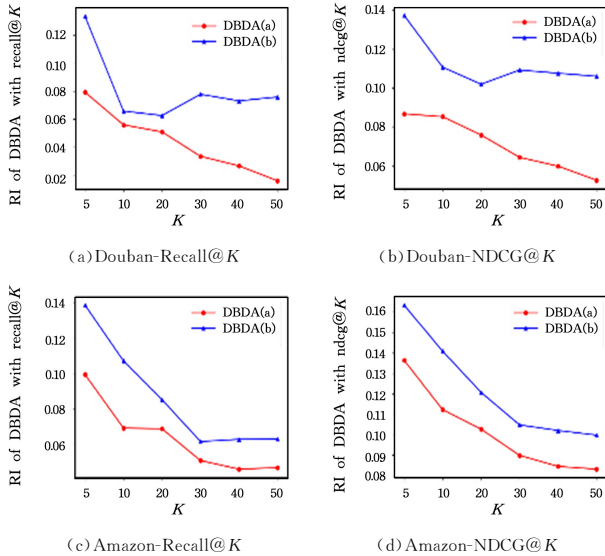


图 5 不同 K 值的 RI 值

Fig. 5 Relative improvement at different K values

5.5.3 用户视角下的归因分析

为了探究用户视角下“头部用户”对最终推荐性能的影响,考虑头部用户的影响程度(Impact of Top Users, ITU),即从训练集中取出最活跃的 K 个用户交互过的物品,以这些物品在测试集中被推荐的次数为指标。我们在 amazon 数据集上进行分析,这里选取前 20 个用户交互过的物品进行统计,如图 6 所示。




图 6 不同 K 值的 ITU 值

Fig. 6 ITU at different K values

由图 6 可知,在不同 K 值下,DBDA 的 ITU 值均高于 PDA。这表明本文方法对于较活跃用户交互过的物品捕捉能力较强。在其他两个数据集上可得到类似结论。由于 amazon 数据集中的数据非常稀疏,因此“头部效应”更为凸显,进一步印证了本文方法的优势。

5.5.4 DBDA 方法的相对提升效果

为定量分析 DBDA 方法的优势,本文将 DBDA 方法和

PDA 方法进行预测性能的对比。表 2 列出了在 3 个数据集上,两种方法在 4 个评价指标上的相对提升值。这里只看各指标上 top20 的提升值。由表 2 可以看出,DBDA 在 ml10m 数据集的 NDCG 指标上的相对提升值可以达到 14.36%,在 Recall 和 NDCG 指标上最少也有 5.02%和 7.55%的提升,在 Precision 和 HR 指标上最少也有 6.15%和 2.48%的提升。从结果可以看出,DBDA 方法是全面优于 PDA 方法的,特别是在划分和处理都相同的 douban 数据集上,且 PDA 方法在文献[5]中已验证是优于其他传统去偏方法的。因此,基于双视角纠偏对于提升推荐系统的性能十分有效。

表 2 DBDA 方法的相对提升值
Table 2 Relative improvements of DBDA

Dataset		Top 20			
		Recall	Precision	HR	NDCG
douban	a	5.02	6.38	2.48	7.55
	b	6.17	8.38	3.09	10.00
ml10m	a	19.70	12.96	5.85	14.36
	b	16.95	10.12	3.86	13.07
amazon	a	6.94	6.15	5.22	10.21
	b	8.52	8.66	7.34	12.11

5.5.5 稳健性分析

为了验证本文方法是显著最优的,我们在 3 个数据集上对 DBDA 和对比方法 PDA 进行了 5 次重复实验。结果如图 7 所示,图 7 中横坐标为上文所述的两种流行度预测方法,纵坐标为评价指标的值。

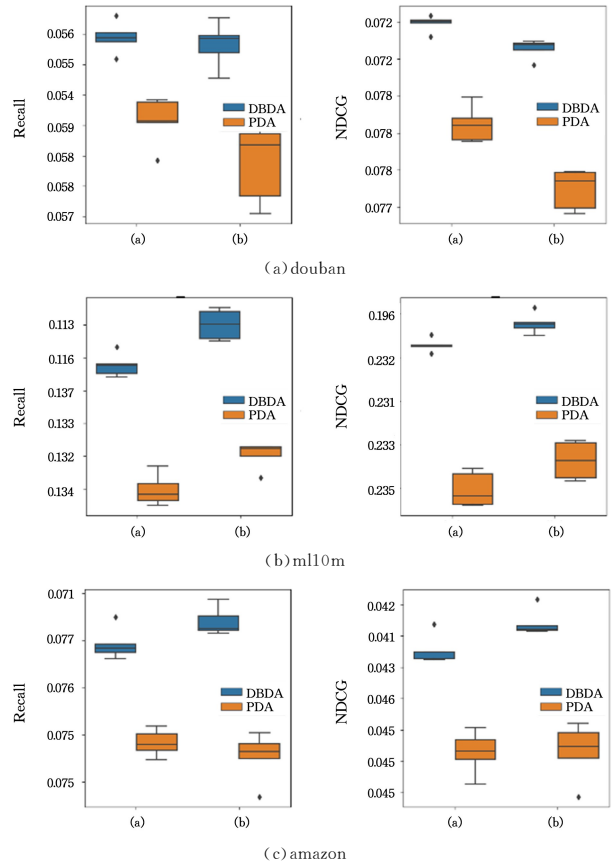


图 7 比较 DBDA 和 PDA 在 Recall@20 和 NDCG@20 上的稳健性

Fig. 7 Robustness comparisons between DBDA and PDA on

Recall@20 and NDCG@20

由图7可知,在3个数据集上,DBDA方法的Recall@20和NDCG@20指标全面优于PDA方法。虽然预测方法不同会导致结果有小幅波动,但没有影响DBDA方法整体的有效性。且由箱线图可直观看出,本文方法在5次重复实验下波动更小,而PDA方法在3个数据集上均比DBDA方法的波动大,尤其是在douban数据集上。

结束语 本文研究了在推荐系统中如何利用物品和用户两种视角来更好地分析推荐的生成过程。通过因果图的分析发现,物品流行度以及用户活跃度是两个混杂因子,它们会造成传统推荐模型中 $P(Y|U, D)$ 的估计偏差。与现有的专注于物品流行度偏差的研究不同,为了更精准地预测结果,本文提出了一种新的方法——双偏去混及调整(DBDA)。同时在3个公开且大规模的数据集上进行了实验,验证了DBDA的有效性。


本文的研究仍存在问题值得进一步探索和改进。一方面,现有因果图的构造往往依赖于先验知识与专家经验,如何通过数据自学习因果图的结构以及如何验证所提出的因果图符合数据生成过程值得进一步研究。另一方面,本文所使用的流行度预测公式简单易行且具有较强的可解释性,但不同的数据集对流行度预测方式较为敏感。对于不同的特征分布,提出了一种更加稳健、高精度的流行度预测方式,是未来可供研究的一个方向。

参 考 文 献

- [1] CHEN J W, WANG X, FENG F L, et al. Bias issues and solutions in recommender system: Tutorial on the RecSys 2021 [C]//Proceedings of the 15th ACM Conference on Recommender Systems. Amsterdam, New York: ACM, 2021: 825-827.
- [2] SCHNABELT, SWAMINATHAN A, SINGH A, et al. Recommendations as treatments: debiasing learning and evaluation [C]//Proceedings of the 33rd International Conference on Machine Learning. New York: ACM, 2016: 1670-1679.
- [3] BONNER S, VASILE F. Causal embeddings for recommendation [C]//Proceedings of the 12th ACM Conference on Recommender Systems. New York: ACM, 2018: 104-112.
- [4] ZHENG Y, GAO C, LI X, et al. Disentangling user interest and conformity for recommendation with causal embedding [C] // Proceedings of the Web Conference 2021. New York: ACM, 2021: 2980-2991.
- [5] ZHANG Y, FENG F L, HE X N, et al. Causal intervention for leveraging popularity bias in recommendation [C]//Proceedings of the 44th ACM SIGIR Conference on Research and Development in Information Retrieval, 2021. New York: ACM, 2021: 11-20.
- [6] PEARL J. Causality (2nd ed) [M]. New York: Cambridge univer-

sity press, 2009: 65-106.

- [7] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: bayesian personalized ranking from implicit feedback [C]//Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence, 2009. AUAI, 2009: 452-461.
- [8] XU S Y, TAN J T, HEINECKE S, et al. Deconfounded causal collaborative filtering [J]. arXiv: 2110. 07122, 2021.
- [9] WEI T X, FENG F L, CHEN J W, et al. Model-agnostic counterfactual reasoning for eliminating popularity bias in recommender system [C]//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, Virtual Event, 2021. New York: ACM, 2021: 1791-1800.
- [10] WANG W J, FENG F L, HE X N, et al. Deconfounded recommendation for alleviating bias amplification [C]//Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, 2021. New York: ACM, 2021: 1717-1725.
- [11] GLYMOUR M, PEARL J, JEWELL N. PCausal inference in statistics: a primer [M]. New York: John Wiley & Sons, 2016.
- [12] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems [J]. the IEEE Computer Society, 2009, 42(8): 30-37.
- [13] CLEVERT D A, UNTERTHINER T, HOCHREITER S. Fast and accurate deep network learning by exponential linear units (elus) [C]//Proceedings of the 4th International Conference on Learning Representations, 2016. OpenReview. net, 2016.
- [14] SONG W P, XIAO Z P, WANG Y F, et al. Session-Based social recommendation via dynamic graph attention networks [C] // Proceedings of the 12th ACM International Conference on Web Search and Data Mining, 2019. New York: ACM, 2019: 555-563.
- [15] KINGMA D P, BA J. Adam: a method for stochastic optimization [J]. arXiv: 1412. 6980, 2014.



HUANG Lu, born in 1997, postgraduate. Her main research interests include recommendation and causal inference.



NI Lyu, born in 1991, Ph.D, lecturer, is a member of China Computer Federation. Her main research interests include big data analysis and its application, and data science & engineering.

(责任编辑:喻黎)