

程明月¹ 刘淇¹ 李徵¹ 于润龙¹ 高维博¹ 陈恩红¹

多重对级贝叶斯个性化排序算法

摘要

为解决隐式反馈推荐问题,贝叶斯个性化排序(BPR)模型已经成为最具有代表性的对级(Pairwise)排序算法之一.在BPR模型中,存在一个严格的偏序假设:相较于未标记的物品而言,用户更喜欢已经有过标记行为的物品.本文提出了一种多重对级贝叶斯个性化排序(MBPR)推荐算法来进一步提升用户对物品的偏好预测能力.首先,基于BPR模型的排序关系设计了一种改进的多重对级偏序假设.具体地,对于每一用户,本文提出将未标记的反馈集细分为潜在的负反馈集和不确定性反馈集,并基于改进的对级偏序假设,提出了一种新的多重对级排序的优化目标来学习用户与物品之间的相关性.为实现MBPR模型的采样任务,本文设计了一种自适应采样策略来为模型更新动态地选取训练样本.最后,在公开数据集上开展了仿真推荐实验,并与基线算法对比.实验结果表明,MBPR算法能够取得更好的推荐效果.

关键词

推荐系统;隐式反馈;对级排序;协同过滤

中图分类号 TP391

文献标志码 A

收稿日期 2019-05-19

资助项目 国家自然科学基金(61672483)

作者简介

程明月,男,硕士生,主要研究领域为个性化智能推荐、机器学习与数据挖掘.damioncheng@gmail.com

刘淇(通信作者),男,博士,副教授,博士生导师,主要研究领域为数据挖掘与知识发现、机器学习方法与应用.qiliuqi@ustc.edu.cn

0 引言

在大数据时代,互联网上的信息呈现爆炸式增长,导致用户很难方便快捷地获取感兴趣的信息.为解决网络中信息分发问题,推荐系统已经成功地在诸多产品中得到广泛应用^[1-3].在众多个性化推荐方法中,协同过滤方法^[4-6]已经成为运用最广泛、最成功的核心推荐技术之一.协同过滤的基本思想是:分析用户历史的标记行为,向用户推荐可能感兴趣的信息或者物品.根据所处理数据类型不同,协同过滤算法主要可以分为两类:一类是处理显示反馈数据的评分预测模型^[7-9],另一类是处理隐式反馈的排序推荐模型^[10-11].显示反馈通常为一段区间的整数值,如电影的评分记录,一般1~5分,具体的偏好描述如图1所示.而隐式反馈数据通常表现为二值形式,一般“0”被用来表示用户对此物品未发生过标记行为,“1”则表示用户对此物品发生过标记行为.在实际应用中,隐式反馈数据包含多种形式的反馈,比如网页的点击记录、电商平台的购买记录、社交平台的点赞记录.由于隐式反馈数据在现实中更易搜集与获取,所以学者们基于隐式反馈推荐问题开展了广泛研究.值得注意的是,隐式反馈数据只包含用户对物品的正反馈信息,即用户对此物品喜欢的信息,并不包含负反馈信息,即缺少用户对此物品不感兴趣的反馈信息^[11].因为,在隐式反馈数据中模型不能简单地将未标记的物品看作是负反馈,未标记的物品可能是因为尚未曝光给该用户.

	item1	item2	item3	item4		item1	item2	item3	item4
u1	1	5	3	?	u1	?	1	?	?
u2	2	?	4	?	u2	?	?	1	?
u3	?	3	?	2	u3	?	1	?	1
u4	?	4	5	2	u4	?	1	?	?

a. 显示反馈

b. 隐式反馈

图1 显示反馈和隐式反馈形式描述

Fig. 1 Comparison between explicit feedback and implicit feedback

为解决隐式反馈数据的推荐,此前的模型主要归为两类:一类是点级回归模型,另一类是对级排序模型.点级回归模型^[3]通过最小化

¹ 中国科学技术大学 大数据分析与应用安徽省重点实验室,合肥,230027

预测评分与实际评分之间的误差来训练模型.比如,文献[12]指出对于有标记的用户-物品对 (u, i) ,表明用户 u 对物品 i 之间有着更高的相关性.考虑到用户在实际场景中的决策行为,对级排序模型将隐式反馈看作是相对偏好而非点级回归模型中绝对偏好假设.由于此类模型的假设更符合用户实际购买的决策习惯,文献[13]指出对级排序模型已经成为解决隐式反馈数据推荐的主流方法.借助对级排序假设,文献[12]提出了一种基于贝叶斯个性化排序(Bayesian Personalized Ranking, BPR)模型.其核心思想是将用户-物品对偏序关系看成基础训练单元,然后最大化用户对有标记物品和未标记物品的最大似然估计.由于该算法在隐式反馈问题中具有精度高、易于扩展等优点,诸多研究者以此算法为基线开展了很多拓展研究^[14-16].尽管许多基于BPR模型的改进算法在一定程度上进一步提升了推荐效果,但这些方法都继承了BPR的对级偏序假设,即在排序过程中严格地遵循有标记物品应排在未标记的物品之前.但是,在实际场景中,在有标记的物品集中也可能存在用户不喜欢的物品.对应地,对于未标记的物品集,一般可以归结为两方面原因:一是用户不喜欢这个物品,另一方面是用户目前还未观察到此物品.因此,在实际用户决策过程中,BPR模型中采用的对级偏序假设太过于严格.

为解决以上的问题,本文提出了一种多重对级贝叶斯个性化排序(Multi-pair Bayesian Personalized Ranking, MBPR)推荐算法.首先,考虑到此前BPR模型中偏序假设过于严格,本文进一步松弛了BPR模型中的对级偏序假设,并且提出了一种新的多重对级偏序假设.具体地,本文提出每一用户中未标记的反馈集可能包含两部分反馈:潜在负反馈和不确定性反馈.因此,对于每一用户,全体反馈集可以细分为以下三类反馈集:1)正反馈集;2)不确定性反馈集;3)潜在负反馈集.基于改进的对级偏序假设,本文提出了一种新的多重对级排序的优化目标来进一步探索用户与未标记物品的相关性关系.值得注意的是,相较于BPR模型中的对级偏序假设,多重对级排序的优化目标还能够优化同一物品集中的物品相互之间的偏序关系.为实现给MBPR模型更新动态地选取训练,本文利用协同过滤模型中间用户和物品隐式特征向量设计了一种自适应采样策略,为推荐模型能够动态地从有序候选集为模型选取训练样本.特别地,本文中提出的自适应采样策略并不会

增加太多的时间复杂度.最后,本文在3个公开数据集上开展了仿真推荐实验,结果验证了MBPR算法相较于BPR算法能够取得更加精准的推荐效果.

1 多重对级贝叶斯个性化排序推荐算法

在松弛传统对级偏序假设基础之上,本章首先介绍了一种新的多重对级偏序假设;然后,本章描述了基于多重对级偏序关系的模型构建与模型迭代更新学习过程.为实现文中模型的采样任务,紧接着介绍了一种自适应采样策略.

1.1 多重对级偏序假设

在隐式反馈数据中,对于同一用户,未标记的反馈物品数远远大于有标记反馈物品数,即存在严重的样本不均衡问题.为解决此问题,BPR模型将整个样本空间静态地划分为:正样本集和负样本集.然后,BPR模型将物品对看作基础训练单元,进而在排序学习过程中最小化有标记物品排在未标记物品前的分类误差.值得注意的是,在未标记物品集中,也有可能包含用户潜在喜欢的物品.因为,未标记的物品集可以主要归结为两方面原因:1)用户不喜欢;2)尚未曝光给用户.因此,不能简单地将未标记物品看作是负反馈.同样地,用户中有标记的物品中也可能包含着一些噪声类样本,即包含用户可能不喜欢的物品.不难发现,基于BPR模型的对级偏序假设仅仅考虑了有标记物品和未标记物品之间的排序关系,却尚未探索同一样本集中物品相互之间的排序关系.比如,用户对于同一样本集中物品 q 和 q' 的偏好可能有一定的差异,其中样本 $q, q' \in I \setminus I_u^+$,式中 I 代表整体物品集, I_u^+ 代表用户有过标记行为的物品集.同样地,用户也可能对同属于有标记的样本集中物品 p 和 p' 偏好程度不同,其中物品 $p, p' \in I_u^+$.但是,此前采用的基本偏序假设尚未体现出优化以上相同物品集中的排序关系.因此,基于BPR模型中的对级排序偏序假设,本文提出了一种新的多重对级偏序假设.首先,本文提出未标记的物品集中可能包含着用户潜在喜欢的物品,于是进一步将未标记反馈集划分成不确定性反馈集和潜在负反馈集.因此,对于每一个用户,整体样本空间包含以下3种反馈集:

1) 有标记样本集 I_u^+ :用户已经有过标记行为的样本集,譬如用户已经购买或者点击过的样本集;

2) 不确定性样本集 I_u^* :用户可能感兴趣的样本集,譬如用户有着一定的兴趣,但是尚未购买的样本组成的样本集;

3) 潜在负样本集 I_u^- : 用户很可能不喜欢的样本集,譬如用户已经观察到却尚未产生购买行为的样本集.

具体地,多重对级偏序假设和 BPR 算法中的对级偏序假设对比如图 2 所示.




图 2 BPR 模型中对级偏序假设(a)与改进的对级偏序假设(b)

Fig. 2 Pairwise preference assumption in BPR (a) and improved pairwise assumption(b)

在下文中,“1”用来表示用户喜欢的反馈信号,“?”用来表示用户偏好不确定的反馈信号,“-”用来表示用户很大程度上不喜欢的反馈信号.于是,用户对物品的偏好 r_u 可以进一步表示为 $r_{ui} = r_{up} = r_{up'} = 0$,其中物品 i, p, p' 表示从有标记的物品集中随机选取的正样本,即物品 $i, p, p' \in I_u^+$.类似地, $r_{uq'} = r_{uj} = 0$,其中物品 q', j 表示从未标记物品集中选取的潜在负样本,即物品 $j, q' \in I_u^-$.同样地, $r_{uq} = ?$,其中物品 q 表示从未标记物品集中选取的不确定性样本,即物品 $q \in I_u^*$.在此,本文提出用户在正样本 i 与潜在负样本 j 之间的偏好差值不小于用户对不确定性样本 q 和潜在负样本 q' 之间的偏好差值.由于用户对样本 p, p' 都表达了感兴趣的信息,因此本文用户对此样本对之间的偏好差值小于对用户样本 q, q' 之间的偏好差值.基于此,本文提出了以下多重对级排序优化关系不等式:

$$r_{uij} > r_{uqq'} > r_{upp'}, \quad (1)$$

式中: $r_{uij} = r_{ui} - r_{uj}$, $r_{uqq'} = r_{uq} - r_{uq'}$, $r_{upp'} = r_{up} - r_{up'}$.式(1)一方面探索了用户对于有标记的样本 i 和未标记物品 j 之间的排序关系,另一方面探索了用户对于同一物品集中的物品排序关系,如未标记物品集中的样本 q, q' 之间的排序关系、有标记物品集中样本 p, p' 的排序关系.基于多重对级偏序假设,本文将相应的多重对级排序的优化目标进一步表示为

$$\rho(r_{uij} - r_{uqq'}) + (1 - \rho)(r_{uqq'} - r_{upp'}), \quad (2)$$

式中: ρ 用来权衡以上两部分不等式优化结构的参数,该参数具体的值可以根据模型推荐效果在验证集上的验证情况来确定.在此,我们将以上的多重对级优化目标表示成 $r_{>u}$.

1.2 多重对级贝叶斯排序模型构造

基于多重对级排序的优化目标 $r_{>u}$, 本文提出了新的对级排序模型并命名为多重对级贝叶斯个性化排序(MBPR)算法.对应地,所有用户和样本的整体最大似然式可以表示为

$$\text{MBPR}(u) = \Pr(r_{uij} > r_{uqq'} > r_{upp'}). \quad (3)$$

与 BPR 模型类似,为了平滑目标函数使其可微,本文使用 $\sigma(x)$ 来近似概率 $\Pr(\cdot)$, $\sigma(x)$ 是一个 Logistics 函数,其定义为

$$\sigma(x) = \frac{1}{1 + e^{-x}}, \quad (4)$$

然后本文采用以下的近似技巧,即

$$\Pr(r_{>u}) [1 - \Pr(-r_{>u})] = \sigma(r_{>u}) [1 - \sigma(-r_{>u})] = \sigma(r_{>u})^2.$$

MBPR 模型中的目标优化函数可以表示如下:

$$\min_{\Theta} \frac{1}{2} \ln \text{MBPR} + \frac{1}{2} R(\Theta), \quad (5)$$

其中 Θ 是一组模型学习的参数表示, $R(\Theta)$ 正则化用来抑制模型的过拟合现象,可以表示为 $\sum_{u \in U} \sum_{i \in S} [\alpha_u \| U_u \cdot \|^2 + \alpha_v \| V_i \cdot \|^2 + \beta_v \| b_i \|^2]$, $S = \{i, p, p', q, q', j\}$ 表示一组训练样本.在计算用户对物品的评分时,本文使用了矩阵分解模型^[6].具体地,我们考虑了物品的偏置项 b 对物品评分预测的影响,具体计算公式表示如下:

$$r_{ui} = U_u \cdot V_i + b_i, \quad (6)$$

式中 U_u 描述用户的隐式特征向量, V_i 描述样本的隐式特征向量, b_i 表示样本 i 的偏置.基于式(2)中多重对级排序优化目标 $r_{>u}$, MBPR 模型的对数似然估计表示为

$$\ln \text{MBPR} = \sum_{u \in U} \sum_{i, p, p' \in I_u^+} \sum_{j, q' \in I_u^-} \sum_{q \in I_u^*} 2 \ln \sigma(\lambda(r_{uij} - r_{uqq'}) + (1 - \lambda)(r_{uij} - r_{upp'})). \quad (7)$$

与此对应, MBPR 模型中的优化目标函数可以表示为

$$f(u, S) = \ln[1 + \exp(-r_{>u})] + \frac{\alpha_u}{2} \| U_u \cdot \|^2 + \frac{\alpha_v}{2} \| V_i \cdot \|^2 + \frac{\beta_v}{2} \| b_i \|^2. \quad (8)$$

1.3 模型学习过程

为优化式(8)中的 MBPR 模型目标函数,本文采用随机梯度下降(Stochastic Gradient Descent, SGD)算法.以上优化目标函数在每个参数 θ 的梯度表示如下:

$$\frac{\partial f(u,S)}{\partial U_u} = \frac{\partial f(u,S)}{\partial r_{>u}} \times (\rho(V_{i\cdot} - V_{j\cdot} - V_{q\cdot} + V_{q'\cdot}) + (1-\rho)(V_{q\cdot} - V_{q'\cdot} - V_{p\cdot} + V_{p'\cdot})), \quad (9)$$

$$\frac{\partial f(u,S)}{\partial V_{j\cdot}} = \frac{\partial f(u,S)}{\partial r_{>u}} \times (-\rho U_{u\cdot}) + \alpha_v V_{j\cdot}, \quad (10)$$

$$\frac{\partial f(u,S)}{\partial V_{i\cdot}} = \frac{\partial f(u,S)}{\partial r_{>u}} \times \rho U_{u\cdot} + \alpha_v V_{i\cdot}, \quad (11)$$

$$\frac{\partial f(u,S)}{\partial b_{j\cdot}} = \frac{\partial f(u,S)}{\partial r_{>u}} \times (-\rho) + \beta_v b_{j\cdot}, \quad (12)$$

$$\frac{\partial f(u,S)}{\partial b_{i\cdot}} = \frac{\partial f(u,S)}{\partial r_{>u}} \times \rho + \beta_v b_{i\cdot}, \quad (13)$$

式中: $\frac{\partial f(u,S)}{\partial r_{>u}} = -\frac{1}{1 + \exp(r_{>u})}$, 并且样本 p, p', q, q' 的梯度更新规则类似于样本 i, j 中的更新规则. 得到以上目标优化函数在每个参数处的梯度之后, 模型沿着梯度方向进行参数更新, 模型的参数更新公式具体表示如下:

$$\theta = \theta - \gamma \frac{\partial f(u,S)}{\partial \theta}, \quad (14)$$

式中: γ 表示每次模型参数迭代的步长. 训练模型参数时, 首先随机地从用户集中随机地选择用户 u , 然后选择对应的反馈集 S 作为训练样本来更新模型参数, 直至模型收敛, 最后返回参数. 根据得到的参数对未标记样本进行评分预测, 将排序靠前的物品个性化地推荐给用户.

2 自适应采样策略

为了更新 MBPR 模型, 每步需要选取样本 $S = \{i, p, p', q, q', j\}$ 来训练模型梯度更新. 考虑到用户对正反馈集中样本表达了感兴趣的信息, 因此本文提出将样本 i, p, p' 从正反馈集 I_u^+ 中随机选取. 考虑到用户对大多数未反馈物品集中的物品感兴趣的物品占据少量比例^[12], 因此本文提出随机地从未标记物品集 I_u^+ 中选取潜在负样本 j, q' . 此外, 一些非均匀采样策略^[17-18] 已经被提出来实现对级排序采样任务中负样本采样, 但是这些采样策略一方面效率受到很大限制, 另一方面主要针对于负样本采样任务. 在此基础之上, 设计了一种自适应采样策略来为 MBPR 模型梯度更新动态地选择不确定性训练样本. 不失一般性, 本文自适应采样的核心思想是: 从有序的候选样本列表中按照一定的概率选取评分较高的未标记物品. 一般说来, 排序靠前的物品有很大可能性被选到, 而其物品的预测评分可能仅仅是微不足道的差异. 因此, 将候选物品 l 的位置 r_q 作为采样

时的重要标准, 而非选择样本的预测得分. 具体地, 本文采用几何分布辅助选择样本, 具体如下:

$$\Pr(l | u) \propto \exp\left(-\frac{r_q}{\lambda}\right), \quad (15)$$

式中: λ 用来控制选取样本的位置. 取值越小的 λ 将会使得排序靠前位置 r_l 有更大概率被选取为训练样本. 为了产生有序候选列表, 直觉上可以采用式(6)对物品进行评分预测. 于是, 整个采样算法可以总结为以下几步:

- 1) 通过式(6)生成有序候选物品列表 L ;
- 2) 根据式(15)生成采样位置 r_q ;
- 3) 从有序候选列表 L 中选取位置 r_q 的样本.

考虑到以上的采样步骤, 需要计算所有的候选样本. 对于每一步梯度更新的采样任务而言, 此任务的时间复杂度为 $O(d|I|\log|I|)$. 很明显, 此规模的时间复杂度在实际算法应用时不切合实际. 因此, 我们提出了一种更加快速高效的采样算法.

用户 u 对候选物品 l 的预测评分函数可以等价地表示为

$$r_{uq} = \sum_{f=1}^d v_{uf} v_{lf} = \sum_{f=1}^d |v_{uf}| |v_{lf}|. \quad (16)$$

基于式(16), 本文提出使用以下公式来计算用户与物品之间的相似度:

$$r_{uq}^* \propto |v_{uf_q}| |v_{lf_q}|. \quad (17)$$

从式(17)不难发现, 对于给定的用户隐式向量表征, 用户对于物品的偏好评分近似于物品的隐式向量表征的值. 因此, 本文将采样策略更新为以下几步:

- 1) 从 k 维隐式向量中随机选取维度 f_q ;
- 2) 采样位置 $r_q (1 \leq r \leq N)$, 每个位置采取的概率服从几何分布, 即 λ 是用来调节概率密度的超参数;

3) 根据物品的隐式特征向量 $v_{\cdot f_q}$ 对所有物品进行排序, 并得到候选物品列表 L ;

4) 观察用户的特征向量的值, 观察表征值 U_{u, f_q} 的正负符号, 如果符号为正 ($U_{u, f_q} \geq 0$), 表示用户 u 对 f_q 维的特征持有积极 s 态度, 返回位置为 r_q 的物品; 如果符号为负 ($U_{u, f_q} < 0$), 表示用户 u 对 f_q 维的特征持有消极态度, 则返回位置 $|I| - r_q - 1$ 的物品.

经过分析, 每步梯度更新需要 $O(k|I| + |I|\log|I|)$ 时间复杂度. 很明显, 这样对于实际的算法更新不切合实际. 实际过程中, 步骤 1、2、4 消耗的时间复杂度为 $O(1)$. 第 3 步时间复杂度为

$O(|I|\log|I|)$.在模型训练过程中,在一定的更新步数内,模型的参数可能只发生轻微的改变.因此,不一定需要每一步都更新候选物品列表集,这里提出按照一定的更新间隔($|I|\log|I|$)来更新物品列表.这样,每一步的时间复杂度仅增加 $O(k)$.更进一步,以上自适应采样算法展示如算法1所示.

算法1:自适应采样算法

输入: The observed item set
The latent vectors of users and items: U, V
The hidden dimensions: k

输出: The training item set S

1. Randomly pick a user u ;
2. Randomly pick three positive items, $(i, p, p' \in I_u^+)$;
3. Randomly pick two positive negative items, $(i, q' \in I_u^+)$;
4. Randomly pick a hidden factor $f_q (1 \leq f_q \leq k)$;
5. Sort the ranking list according to $v_{i,q}$;
6. Pick a rank $r_q \propto \exp\left(-\frac{r_q}{\lambda}\right)$;
7. If $\text{sgn}(u_{i,q'}) \geq 0$ then
8. $q \leftarrow \text{index}(r_q | u, f_q)$;
9. else;
10. $q \leftarrow \text{index}(|I| - r_q - 1 | u, f_q)$;

3 实验

本章将对本文中提出的 MBPR 模型在 3 个公开数据集上进行仿真推荐实验.首先介绍了数据集,其次介绍了评价算法的评估指标,最后分析了实验结果.

3.1 数据集

本文选取了典型的隐式反馈公开数据集 Last.fm.隐式反馈数据在实际场景中是非常普遍的,但是目前这样的公开数据集还不多.因此,我们选择了公开的数据集 MovieLens 来模拟隐式反馈数据.此外,本文处理项目没有隐含的反馈作为未被观察到的反馈,未观察到的反馈远远大于观察到的反馈.其中,对于 MovieLens100K 和 Netflix,采取预处理步骤,将评分区间 4~5 的记录置为有标记的反馈,评分 1~3 的记录置为未标记的反馈.这 3 个静态数据集具体描述如表 1 所示.对于所有 3 个数据集,观察到用户项被随机分成 2 个相等的部分,即一个用作训练数据,另一个用作测试数据.与此同时,从中为每个用户随机抽样一个用户-项目对训练数据以构建验证集.重复上述操作程序 10 次,最终的结果取 10 次结果的平均值.

表 1 数据集描述

Table 1 Description of the experimental datasets

数据集	物品数	用户数	反馈样本数	训练样本密度
MovieLens	943	1 682	100 000	0.017 45
Netflix	5 000	5 000	155 972	0.003 12
Last.fm	2 100	18 745	92 834	0.001 18

3.2 评价指标

为比较 MBPR 算法和基线算法的推荐性能,本文采用了几种常用的推荐系统评价指标^[19].实验中共选取了 4 种标准评价指标:准确率(Precision)、召回率(Recall)、平均准确率(Mean Average Precision, MAP)、归一化折损累计增益(Normalized Discounted Cumulative Gain, NDCG).准确率描述了在给用户推荐的物品中,有多少比例是用户真正喜欢的物品.召回率描述了给推荐列表中包含的用户喜欢的物品占据用户喜欢的所有物品的比例.在实际推荐场景中,用户更关心推荐物品排在靠前的物品,对排在后面的物品并不是特别关心.因此,有学者提出了排序位置敏感的指标来评价算法的推荐性能,包括平均准确率指标和归一化累计增益指标.平均准确率指标描述的是每个相关物品排序位置的平均值,推荐列表中用户喜欢的排序越靠前,MAP 值就越大.归一化累计增益指标的核心思想是将推荐系统中用户喜欢的物品分成了多个不同的等级,相较于相关度低的物品,相关度高的物品能够为用户带来更大的价值,因此会被赋予更大的权值.对于平均准确率指标而言,用户对物品的偏好呈现二元关系,而 NDCG 对物品的偏好分成了不同的等级.

3.3 实验结果与分析

本次实验主要将 BPR 算法作为基线算法来对比 MBPR 算法,实验结果如图 3 所示.从实验结果看,相较于 BPR 算法,MBPR 算法在 MAP、NDCG、Precision、Recall 4 个指标上均取得了显著的效果提升.

首先,对于排序位置敏感的评价指标,如实验中的评价指标 NDCG@5 和 MAP,这些评价指标在实际推荐中,能够进一步对用户的决策行为更真实地进行评价.在实验结果中,可以发现,MBPR 模型在此种类型的 2 种指标下表现优于 BPR 模型的排序推荐效果.此种提升,很大程度上归因于 MBPR 模型中的多重对级排序优化目标能够进一步探索用户对于同一反馈集内的物品排序,因此进一步提升了个性化推荐效果.值得注意的是,由于 MBPR 算法进一步




图3 MBPR模型和基准模型在公开数据集上的推荐效果对比

Fig. 3 Recommender performance of MBPR and baseline methods in three public datasets

探索了用户对未标记反馈集的探索,MBPR 算法能够在稀疏性较高的数据中取得更显著的效果提升.此结果很大程度上验证了 MBPR 模型更加有效地利用了大量未标记样本的有效性.综上所述,以上实验结果可以充分说明松弛此前的最初 BPR 采用的对级偏好假设并且优化多重对级排序优化目标能够提升隐式反馈问题的推荐效果.

4 结论

本文主要研究了基于隐式反馈数据的对级排序推荐算法.在传统贝叶斯个性化排序推荐算法基础之上,本文提出了一种多重对级贝叶斯个性化排序推荐算法来进一步挖掘用户对大量隐式反馈物品的偏好关系.基于 BPR 模型中的基础偏序假设,本文提出一个改进的多重对级偏序假设.具体地,本文将未标记反馈物品集进一步细化分为潜在负反馈集和不确定反馈集,然后提出了一种多重对级优化目标来学习用户与物品之间的相关性关系.此外,为实现 MBPR 模型的采样任务,本文中提出的自适应采样策略能够动态地从候选列表为模型选取训练不确定性反馈训练样本.最后,通过在 3 个数据集上开展实验,结果表明通过优化文中提出的多重对级排序目标能够提升推荐的准确性.

参考文献

References

[1] Liu Q, Ge Y, Li Z, et al. Personalized travel package rec-

ommendation[C] // 2011 IEEE 11th International Conference on Data Mining. IEEE, 2011: 407-416

[2] Liu Q, Xiang B, Chen E, et al. Influential seed items recommendation[C] // Proceedings of the Sixth ACM Conference on Recommender Systems. ACM, 2012: 245-248.

[3] Li Z, Zhao H, Liu Q, et al. Learning from history and present: next-item recommendation via discriminatively exploiting user behaviors[C] // Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. ACM, 2018: 1734-1743

[4] Wu L, Liu Q, Chen E H, et al. Relevance meets coverage [J]. ACM Transactions on Intelligent Systems and Technology, 2016, 7(3): 1-30

[5] Koren Y, Bell R, Volinsky C. Matrix factorization techniques for recommender systems [J]. Computer, 2009, 42(8): 30-37

[6] Rennie J D M, Srebro N. Fast maximum margin matrix factorization for collaborative prediction [C] // Proceedings of the 22nd International Conference on Machine Learning. ACM, 2005: 713-719

[7] Liu Q, Zhao H K, Wu L, et al. Illuminating recommendation by understanding the explicit item relations[J]. Journal of Computer Science and Technology, 2018, 33(4): 739-755

[8] Liu Q, Chen E H, Xiong H, et al. Enhancing collaborative filtering by user interest expansion via personalized ranking[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B(Cybernetics), 2012, 42(1): 218-233

[9] Zhao H K, Wu L, Liu Q, et al. Investment recommendation in p2p lending: a portfolio perspective with risk management [C] // 2014 IEEE International Conference on Data Mining. IEEE, 2014: 1109-1114

[10] Pan R, Zhou Y, Cao B, et al. One-class collaborative filtering[C] // 2008 Eighth IEEE International Conference on Data Mining. IEEE, 2009

- [11] Hu Y F, Koren Y, Volinsky C. Collaborative filtering for implicit feedback datasets [C] // 2008 Eighth IEEE International Conference on Data Mining, December 15-19, 2008. Pisa, Italy. New York, USA: IEEE, 2008: 263-272
- [12] Rendle S, Freudenthaler C, Gantner Z, et al. BPR: Bayesian personalized ranking from Implicit feedback [C] // Conference on Uncertainty in Artificial Intelligence. AUAI Press, 2009
- [13] Zhong H, Pan W K, Xu C F, et al. Adaptive pairwise preference learning for collaborative recommendation with implicit feedbacks [C] // Proceedings of the 23rd ACM International Conference on Conference on Information and Knowledge Management-CIKM '14, November 3-7, 2014. Shanghai, China. New York, USA: ACM Press, 2014: 1999-2002
- [14] Pan W K, Chen L. GBPR: group preference based Bayesian personalized ranking for one-class collaborative filtering [C] // IJCAI, 2013: 2691-2697
- [15] Yu R L, Zhang Y Z, Ye Y Y, et al. Multiple pairwise ranking with implicit feedback [C] // Proceedings of the 27th ACM International Conference on Information and Knowledge Management-CIKM '18, October 17-26, 2018. Torino, Italy. New York, USA: ACM Press, 2018: 1727-1730
- [16] Song D J, Meyer D A, Tao D C. Efficient latent link recommendation in signed networks [C] // Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining-KDD '15, August 10-13, 2015. Sydney, NSW, Australia. New York, USA: ACM Press, 2015: 1105-1114
- [17] Rendle S, Freudenthaler C. Improving pairwise learning for item recommendation from implicit feedback [C] // Proceedings of the 7th ACM International Conference on Web Search and Data Mining-WSDM '14, February 24-28, 2014. New York, New York, USA. New York, USA: ACM Press, 2014: 273-282
- [18] Zhang W N, Chen T Q, Wang J, et al. Optimizing top- n collaborative filtering via dynamic negative item sampling [C] // Proceedings of the 36th International ACM SIGIR Conference on Research and Development in Information Retrieval-SIGIR '13, July 28-August 1, 2013. Dublin, Ireland. New York, USA: ACM Press, 2013: 785-788
- [19] Liu Q, Chen E H, Xiong H, et al. Enhancing collaborative filtering by user interest expansion via personalized ranking [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2012, 42(1): 218-233

Multi-pair Bayesian personalized ranking

CHENG Mingyue¹ LIU Qi¹ LI Zhi¹ YU Runlong¹ GAO Weibo¹ CHEN Enhong¹

¹ Anhui Province Key Laboratory of Big Data Analysis and Application, University of Science and Technology of China, Hefei 230027

Abstract To solve the implicit recommendation problems, Bayesian Personalized Ranking (BPR) algorithm has become one the most representative pairwise methods. Generally, BPR assumes that users keep higher preference on observed items than unobserved items. In this paper, we introduce Multi-pair Bayesian Personalized Ranking (MBPR), a novel pairwise method to further investigate the preference about the large number of unobserved feedbacks. First, we propose an enhanced pairwise assumption based on the traditional pairwise assumption adopted by BPR. Specifically, we divide the large unobserved item set into two parts: uncertain item set and possibly negative item set for each user. Based on this, a new multi-pair pairwise objective function is proposed to learn users' preference. To solve the sampling task in MBPR, an adaptive sampling strategy is then proposed to dynamically draw uncertain feedbacks from unobserved item set. Finally, empirical studies show that our algorithms can improve the ranking performance of BPR.

Key words recommender systems; implicit feedback; pairwise ranking; collaborative filtering