

控制与决策

Control and Decision

基于直觉模糊集的伯努利矩阵分解推荐算法

邓江洲, 郭均鹏

引用本文:

邓江洲, 郭均鹏. 基于直觉模糊集的伯努利矩阵分解推荐算法[J]. *控制与决策*, 2023, 38(10): 2897–2904.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0345>

您可能感兴趣的其他文章

Articles you may be interested in

[自适应直觉模糊相异直方图裁剪的图像增强算法](#)

Adaptive intuitionistic fuzzy dissimilar histogram clipping image enhancement algorithm

控制与决策. 2021, 36(12): 2919–2928 <https://doi.org/10.13195/j.kzyjc.2020.0845>

[概率区间值直觉犹豫模糊Maclaurin对称平均算子及决策方法](#)

Probabilistic interval-valued intuitionistic hesitant fuzzy Maclaurin symmetric mean operators and decision method

控制与决策. 2021, 36(5): 1249–1258 <https://doi.org/10.13195/j.kzyjc.2019.1370>

[乘型一致性毕达哥拉斯模糊偏好关系](#)

Multiplicative consistent Pythagorean fuzzy preference relation

控制与决策. 2021, 36(4): 1010–1016 <https://doi.org/10.13195/j.kzyjc.2019.0967>

[乘型一致性毕达哥拉斯模糊偏好关系](#)

Multiplicative consistent Pythagorean fuzzy preference relation

控制与决策. 2021, 36(4): 1010–1016 <https://doi.org/10.13195/j.kzyjc.2019.0967>

[考虑时间序列的动态大群体应急决策方法](#)

Dynamic large group emergency decision-making method considering time series

控制与决策. 2020, 35(11): 2609–2618 <https://doi.org/10.13195/j.kzyjc.2019.0088>

基于直觉模糊集的伯努利矩阵分解推荐算法

邓江洲, 郭均鹏[†]

(天津大学 管理与经济学部, 天津 300072)

摘要: 现有的基于矩阵分解的协同过滤推荐算法主要从定量的角度, 利用用户的评分信息评估模型表现, 而并未从定性的角度描述用户的不确定偏好信息. 鉴于此, 从用户偏好模糊概率的角度提出一种基于直觉模糊集的伯努利矩阵分解推荐算法为目标用户进行 Top- n 推荐. 首先, 根据用户偏好特征和直觉模糊集定义, 将用户评分矩阵划分为隶属度矩阵、非隶属度矩阵和犹豫度矩阵; 然后, 借助伯努利矩阵分解模型对矩阵并行拟合, 得到最优的潜在特征向量对, 并将其内积按比例划分, 从而获得目标用户对未评分项目偏好程度的直觉模糊数; 最后, 根据直觉模糊数排序规则确定最终推荐列表. 在公开数据集上的实验结果显示, 所提出方法在项目排序指标上均优于其对比方法, 能够有效提高推荐质量.

关键词: 直觉模糊集; 伯努利分布; 矩阵分解; 推荐算法

中图分类号: TP391 文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0345

引用格式: 邓江洲, 郭均鹏. 基于直觉模糊集的伯努利矩阵分解推荐算法[J]. 控制与决策, 2023, 38(10): 2897-2904.

Intuitionistic fuzzy sets based Bernoulli matrix factorization recommendation algorithm

DENG Jiang-zhou, GUO Jun-peng[†]

(College of Management and Economics, Tianjin University, Tianjin 300072, China)

Abstract: Existing matrix factorization based collaborative filtering recommendation algorithms mainly utilize users' ratings to evaluate model performance from a quantitative perspective, and never describe users' uncertain preference information from qualitative perspective. Therefore, this paper proposes a Bernoulli matrix factorization recommendation model based on intuitionistic fuzzy sets (IFSs) to make Top- n recommendations for active users from the perspective of fuzzy probability of user preferences. Firstly, the user-item rating matrix is divided into the membership matrix, non-membership matrix and hesitancy matrix according to user preference features and the definition of IFS. Subsequently, the Bernoulli matrix factorization (BeMF) is adopted to fit these matrices in parallel to obtain the optimal latent feature vectors, and their inner products are divided proportionally to get the intuitionistic fuzzy number (IFV) of the active users' preference degree for unrated items. Finally, the recommendation lists are determined according to the ranking rule of the IFV. Experimental results on several benchmark datasets show that the proposed model outperforms other methods in terms of item ranking metrics and effectively improves the recommendation quality.

Keywords: intuitionistic fuzzy sets; Bernoulli distribution; matrix factorization; recommendation algorithm

0 引言

决策作为人们日常生活中各方面都涉及的重要活动, 通常根据相应的决策标准对备选方案进行排序或者选择最感兴趣的方案^[1]. 然而, 随着决策复杂性的增加, 个人根据自身经验做出既可靠又满意的决定的频率逐渐降低. 尤其是数字内容平台, 如 YouTube、Netflix 和网易音乐等, 可以实时为在线用户推送一系

列其可能感兴趣的视频、电影和音乐等内容, 极大地缩短了用户的搜索成本和决策难度, 提高了用户体验. 这主要归功于推荐系统 (recommender system, RS) 的兴起, 它能够从超载信息中尽可能地选择出最合适的产品或服务来支持在线用户的决策^[2]. 一个有效的推荐系统可以极大地提高用户的满意度和购买体验, 同时增强他们对平台的黏性, 进而增加平台的

收稿日期: 2022-03-06; 录用日期: 2022-06-10.

基金项目: 国家自然科学基金项目 (72171165); 教育部人文社科研究项目 (21YJA630021); 天津市哲学社会科学规划项目 (TJGL17-011).

责任编辑: 徐泽水.

[†]通讯作者. E-mail: guojp@tju.edu.cn.

影响力。目前,协同过滤^[3](collaborative filtering, CF)是推荐系统中使用最为广泛的技术之一,其基本思想是利用“群体智慧”对系统中大量信息进行过滤筛选,以产生一系列目标用户可能感兴趣的项目推荐。通常分为基于内存(memory-based)和基于模型(model-based)的协同过滤推荐算法^[4]。基于内存的方法主要依靠相似性度量方法预测目标用户在未评分项目上的偏好^[5],但该方法因效率低、内存消耗大且扩展性差而无法适用于大型稀疏数据环境。基于模型的方法利用用户评分信息建立学习预测模型,借助机器学习和其他技术识别用户复杂的偏好特征,然后进行偏好预测^[6],该模型具有良好的可扩展性。基于矩阵分解的推荐算法^[7]是当前最流行且高效的基于模型的协同过滤方法,本文在此基础上展开深入研究。

在实际决策过程中,因获取特定和精准定量信息的成本较高,人们通常更倾向于用语言定性地表达他们的意见或偏好^[8]。然而,在大多数使用推荐系统的平台上,用户需要利用打分的方式表达他们对项目的偏好程度,其目的是方便平台对用户偏好进行标准化评估。以往研究中,学者多是从定量的角度利用用户评分信息进行预测推荐,未从定性的角度描述用户的不确定决策信息以及借助相关知识实现更好的推荐质量。

鉴于此,本文首次从用户偏好模糊概率的角度提出一种基于直觉模糊集的伯努利矩阵分解推荐算法(IFS-BeMF)为目标用户进行Top- n 推荐。首先,借助直觉模糊集的相关理论知识,将用户评分矩阵转化为3个二值模糊矩阵,即隶属度矩阵、非隶属度矩阵和犹豫矩阵;其次,利用伯努利矩阵分解模型并行拟合0-1矩阵,以得到最佳的潜在特征向量对;接着,将不同矩阵的特征向量内积按比例划分,以确定目标用户对未评分项目偏好程度的直觉模糊数;最后,根据直觉模糊数的比较规则,对目标用户的直觉模糊数集进行重排序,取排名靠前的 n 个项目作为其推荐列表。

1 相关工作

1.1 矩阵分解

矩阵分解^[9](matrix factorization, MF)作为一种最常见且有效的降维技术或因子分析技术,因其具有较好的预测能力和可扩展性,已成功应用于推荐系统中。将高维的用户-项目评分矩阵拆解为若干低秩矩阵的乘积,常见的分解方式有三角分解、满秩分解和奇异值分解等,通过不断训练模型实现对评分矩阵中缺失部分的预测。基于矩阵分解的推荐算法其基本原理是^[10]:将用户和项目信息映射到同一个 d 维联合

潜在特征空间上,若在该空间内,目标用户的潜在因子向量与某个项目的潜在因子向量高度匹配,则认为该用户对这个项目有极大的兴趣偏好。由于系统中的用户和项目都能用隐含特征向量表示,矩阵分解又称为隐含因子模型(latent factor model, LFM)。

对于用户-项目评分矩阵 $R^{m \times n}$, m 和 n 分别为用户和项目数量, R 为非零用户-项目对的评分集合。假设 U_i 和 V_j 分别为用户 i 和项目 j 的潜在特征向量,则用户 i 在项目 j 上的评分 $R_{i,j}$ 可近似为这两个潜在向量的内积,数学表达式如下:

$$R_{i,j} \approx \widehat{R}_{i,j} = \langle U_i, V_j \rangle = U_i^T V_j. \quad (1)$$

为了训练潜在因子矩阵 U_i 和 V_j ,需要最小化正则化平方误差得到最优值,即

$$\min_{U,V} \sum_{(i,j) \in \Omega} (R_{i,j} - \widehat{R}_{i,j})^2 + \lambda(\|U_i\|^2 + \|V_j\|^2). \quad (2)$$

其中: Ω 为用户-项目对 (i,j) 的集合; $R_{i,j}$ 为可观测到的用户评分; $\|\cdot\|^2$ 为矩阵的Frobenius范数; λ 为调节变量,用来控制正则化强度,以防止评分过度拟合。

目前,各种矩阵分解技术,如奇异值分解^[11](SVD)、概率矩阵分解^[12](PMF)、非负矩阵分解^[13](NMF)等,在推荐领域中得到广泛应用。基于矩阵分解的推荐算法主要采用两方面评价指标评估其有效性,即项目评分预测和项目排序推荐^[14]。两者侧重点不同:前者侧重于评估预测值与真实值间的均方根误差(RMSE),后者侧重于评估所推荐项目的前后顺序,评估指标通常为归一化折损累计增益(NDCG)。Koren等^[10]在Netfilx Prize竞赛中首次利用基于最小二乘法(ALS)的矩阵分解技术MF提高个性化推荐效果。Cui等^[15]利用基于双层推荐模型的矩阵分解同时优化4种推荐目标。Chen等^[14]通过将隐式反馈作为辅助信息融合到矩阵分解模型中以提高推荐系统的性能,但该方法只考虑了用户的交互信息(是否评分),忽略了用户的偏好信息(是否喜欢)。Shen等^[16]提出了一种基于情感分析的矩阵分解推荐方法来将评论信息引入到概率矩阵分解模型中,并考虑了用户反馈信息,以获得更加准确的预测结果,但该方法不适用于只有评分信息的推荐系统。Ortega等^[17]提出了一种基于伯努利分布的矩阵分解模型(BeMF)预测具有可靠性概率的离散评分值,剔除可靠性较低的预测评分以提高预测准确性,但该方法只是简单地将用户评分矩阵按不同评分值转化为若干个子矩阵,未考虑用户评分偏好对推荐结果的影响。Kuo等^[18]设计了基于泊松分解的个性化排序框架克服传统矩阵分解方法对异常值的敏感度,以确保预测评分与用户

偏好的排序一致。Pujahari等^[19]提出了一种使用偏好关系的概率矩阵分解模型实现高效的项目排序。He等^[20]从深度神经网络的角度,将基于线性的矩阵分解模型与基于非线性的多层感知器(MLP)整合在一起,设计了一个基于神经网络的协同过滤算法(NCF)学习用户和项目的潜在特征,进一步提高推荐系统性能。随后,Xue等^[21]利用神经网络方法提出一种深度矩阵分解模型(DMF)将用户和项目映射到同一低维空间。这两方法同样未考虑用户的偏好信息。

综上所述,大多数基于矩阵分解的推荐算法都是从定量的角度,利用用户的评分信息进行后续推荐,较少从定性的角度描述用户的不确定偏好信息。因此,在基于矩阵分解的推荐算法研究中,借助模糊理论的相关知识进行用户偏好预测尤为重要。

1.2 直觉模糊集

在决策过程中,人们通常会对既模糊又复杂的客观事物做出不确定的判断,模糊集^[22]的概念就是用来表征不确定的决策信息。然而,该模糊集只考虑隶属度,忽视了人们在决策过程中经常会存在不确定性或犹豫的行为^[1]。为了全面反映人类认知表现的3种特性:肯定、否定和犹豫,Atanassov^[23]在1986年对模糊集概念进行拓展和改进,提出了直觉模糊集(intuitionistic fuzzy set, IFS)理论来描述决策者的偏好信息。

定义1^[23] 假设论域 X 是一个非空集合,则 X 上的直觉模糊集 I 可表示为

$$I = \{ \langle x, u_I(x), v_I(x) \rangle | x \in X \}, \quad (3)$$

其中 $u_I(x)$ 和 $v_I(x)$ 分别为论域 X 中元素 x 属于 I 的隶属度(membership degree)和非隶属度(non-membership degree),即

$$u_I(x) : X \rightarrow [0, 1], x \in X \rightarrow u_I(x) \in [0, 1]; \quad (4)$$

$$v_I(x) : X \rightarrow [0, 1], x \in X \rightarrow v_I(x) \in [0, 1]. \quad (5)$$

同时应满足:对于任意元素 x ,有 $u_I(x) + v_I(x) \leq 1$ 和 $\pi_I(x) = 1 - u_I(x) - v_I(x)$,其中 $\pi_I(x)$ 为元素 x 属于 I 的犹豫度(hesitancy degree)^[24]。

$\alpha = (u_\alpha, v_\alpha)$ 为直觉模糊数(intuitionistic fuzzy number, IFN)^[25],其物理解释可用投票原理进行说明。例如,推选小明同学为班长的直觉模糊数为(0.7, 0.2),这意味着班级中有70%的同学支持小明当班长,有20%的同学持反对意见,另外有10%的同学投了弃权票。从投票例子中可以看出,一个直觉模糊集IFS的隶属度可以表示赞成比例,非隶属度可以表示反对比例,而犹豫度为不确定候选人是否有能力担任班长职务的学生比例,可以视为弃权。

定义2 假设 $\alpha_i = (u_{\alpha_i}, v_{\alpha_i}) (i = 1, 2)$ 是两个直

觉模糊数, $s(\alpha_i) = u_{\alpha_i} - v_{\alpha_i}$ 和 $h(\alpha_i) = u_{\alpha_i} + v_{\alpha_i}$ 分别为 α_i 的记分函数和精确函数,则有如下规则^[24]:

1) 若 $s(\alpha_1) < s(\alpha_2)$,则直觉模糊数 α_2 优于 α_1 。

2) 若 $s(\alpha_1) = s(\alpha_2)$,而 $h(\alpha_1) < h(\alpha_2)$,则直觉模糊数 α_2 优于 α_1 ;若 $h(\alpha_1) > h(\alpha_2)$,则直觉模糊数 α_1 优于 α_2 ;若 $h(\alpha_1) = h(\alpha_2)$,则直觉模糊数 α_1 与 α_2 具有相同的偏好信息,排序相同。

同样地,推荐系统也会根据用户与项目间的历史交互信息,为目标用户提供不确定的决策,如打高分表示喜欢,打低分表示不喜欢或未评分表示偏好未知。这与直觉模糊集的概念高度一致,因此有理由认为直觉模糊集的相关概念和定义能应用于推荐系统,为目标用户推荐其感兴趣的项目^[26]。例如,在电影推荐系统中,“泰坦尼克号”影片的直觉模糊数为(0.8, 0.1),说明在评分区间为1~5的打分区间内,80%用户给该电影打分超过3分,10%用户打分低于3分,另外有10%用户未对电影进行评分。值得注意的是,这10%未评分用户不仅包括观看了该电影却未评分的,还包括从未观看过该电影的人。然而,由于无法从单一评分信息中区分出用户是否看了电影却未评分,为了方便处理,本研究假定未评分的用户均为未观看过该电影的人群。在基于直觉模糊集的推荐系统中,隶属度可表示为用户喜欢某个项目的比例,非隶属度则表示用户不喜欢该项目的比例,而犹豫度表示不确定用户是否喜欢该项目的比例,即未知偏好。

通过以上文献回顾可知,极少有相关文献将直觉模糊集的概念引入到矩阵分解模型中为目标用户进行偏好预测和推荐。本文从用户偏好模糊概率的角度,借助矩阵分解技术学习用户和项目的潜在特征。考虑到在基于直觉模糊集的推荐系统中隶属度、非隶属度以及犹豫度的重要性,首先将用户-项目评分矩阵转为3个模糊矩阵表示用户对项目的偏好信息(喜欢、不喜欢和未知);然后利用伯努利矩阵分解模型BeMF分别对这些矩阵进行并行拟合,以得到用户对项目偏好程度的直觉模糊数;最后对求得的直觉模糊数按相应规则进行排序,将排名靠前的 n 个可能感兴趣的项目推送给目标用户。

2 所提模型

图1显示了所提出模型IFS-BeMF的框架结构。首先,在基于直觉模糊集的推荐系统中需要根据用户对项目的偏好程度(喜欢、不喜欢以及未知偏好)确定直觉模糊集的隶属度、非隶属度和犹豫度。这里假定:若用户 i 在某个项目 j 上的评分大于其平均评分,

则表示用户 i 喜欢该项目 j , 其隶属度为 1; 否则表示不喜欢该项目, 其非隶属度为 1. 若用户与项目间有交互, 但其偏好未知, 则犹豫度为 1. 由此可以将用户-项目评分矩阵 R 转化为 3 个相互独立且值只含 0 和 1 的直觉模糊矩阵, 即隶属度矩阵 M 、非隶属度矩阵 N 和犹豫度矩阵 H . 然后, 利用后续第 2.1 节的 BeMF 模型对 3 个模糊矩阵并行拟合, 直到模型收敛, 得到最终的用户和项目潜在特征向量 U 和 V . 最后, 将 3 个不同的特征向量内积按比例划分, 以确定用户 i 对项目 j 偏好程度的直觉模糊数.

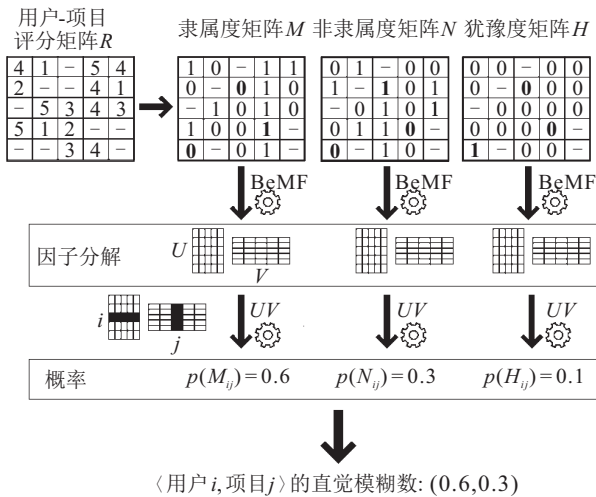


图 1 IFS-BeMF 模型框架

注意到, 在所有未评分项目中(符号“-”表示), 通常包含以下几种情况: 1) 用户喜欢某个项目, 但未对其评分; 2) 用户不喜欢该项目, 未对其评分; 3) 用户无法确定对其偏好, 表示犹豫, 且未进行评分; 4) 用户未与该项目有任何交互. 因此, 在构建模糊矩阵时, 采用如下方式对部分缺失评分进行填充, 使其更符合实际情况: 对于随机选定的用户 i 的未评分项目 j , 若项目的平均评分大于等于 3.5 分(评分区间为 1~5), 则隶属度设置为 1; 若项目的平均评分小于 3 分, 则非隶属度为 1; 若介于两者之间, 则犹豫度为 1. 具体如图 1 所示.

2.1 BeMF

BeMF 是基于伯努利分布的矩阵分解模型, 首先从概率的角度构建服从伯努利分布的二值矩阵中非空白单元的质量函数; 然后利用贝叶斯推导得到二值矩阵所分解出的两个低维度潜在特征向量的(对数)后验概率; 最后采用梯度下降算法找到使得目标函数局部最优的潜在特征向量对, 并用其内积填充矩阵中的空白单元. 具体实现如下.

假设在推荐系统中用户和项目的数量分别为 m 和 n , 用户 $i \in [1, m]$ 和项目 $j \in [1, n]$ 在 d 维因子空间

的潜在特征向量分别为 U_i 和 V_j , 二值 0-1 矩阵 B 服从伯努利分布, 则随机变量 $B_{i,j}$ 的质量函数为

$$p(B_{i,j}|U_i, V_j) = \begin{cases} g(U_i^T V_j), & B_{i,j} = 1; \\ 1 - g(U_i^T V_j), & B_{i,j} = 0. \end{cases} \quad (6)$$

其中 $g(x) = 1/(1 + e^{-x})$ 为逻辑函数, 其取值范围在 $[0, 1]$ 之间. 由此可得, 二值矩阵 B 的条件概率为

$$p(B|U, V) = \prod_{i=1}^m \prod_{j=1}^n p(B_{i,j}|U_i, V_j) = \left(\prod_{B_{i,j}=1} g(U_i^T V_j) \right) \left(\prod_{B_{i,j}=0} 1 - g(U_i^T V_j) \right). \quad (7)$$

为了防止模型过度拟合, 假设用户 i 和项目 j 的特征矩阵 U 、 V 均服从均值为 0 方差分别为 σ_U 、 σ_V (σ_U 、 $\sigma_V > 0$) 的高斯分布, 且每个观测值 U_i 和 V_j 都是独立同分布, 其条件概率为

$$p(U|\sigma_U^2) = \prod_{i=1}^m \mathcal{N}(U_i|0, \sigma_U^2 I), \quad (8)$$

$$p(V|\sigma_V^2) = \prod_{j=1}^n \mathcal{N}(V_j|0, \sigma_V^2 I). \quad (9)$$

其中 I 为指示函数, 当二值矩阵中 $B_{i,j}$ 值存在时, 其值为 1, 否则为 0.

通过简单的贝叶斯推导, 可得到潜在特征矩阵 U 和 V 的后验概率为

$$p(U, V|B, \sigma_U^2, \sigma_V^2) \propto p(B|U, V)p(U|\sigma_U^2)p(V|\sigma_V^2) = \left(\prod_{B_{i,j}=1} g(U_i^T V_j) \right) \left(\prod_{B_{i,j}=0} 1 - g(U_i^T V_j) \right) \times \prod_{i=1}^m \mathcal{N}(U_i|0, \sigma_U^2 I) \times \prod_{j=1}^n \mathcal{N}(V_j|0, \sigma_V^2 I). \quad (10)$$

对式(10)取对数, 可得

$$\ln p(U, V|B, \sigma_U^2, \sigma_V^2) = \sum_{B_{i,j}=1} \ln g(U_i^T V_j) + \sum_{B_{i,j}=0} \ln(1 - g(U_i^T V_j)) - \frac{1}{2\sigma_U^2} \sum_{i=1}^m U_i^T U_i - \frac{1}{2\sigma_V^2} \sum_{j=1}^n V_j^T V_j + C, \quad (11)$$

其中 C 为不影响模型训练的常数.

最大化具有超参数 (σ_U^2, σ_V^2) 的特征向量 U 和 V 的后验对数等价于最小化平方和误差的目标函数 Φ , 即

$$\min_{U, V} \Phi = - \sum_{B_{i,j}=1} \ln g(U_i^T V_j) - \sum_{B_{i,j}=0} \ln(1 - g(U_i^T V_j)) + \frac{\lambda_U}{2} \|U\|^2 + \frac{\lambda_V}{2} \|V\|^2. \quad (12)$$

其中: $\lambda_U = 1/\sigma_U^2, \lambda_V = 1/\sigma_V^2$.

为了得到目标函数的局部最小值,分别对潜在特征矩阵 U 和 V 使用梯度下降算法进行迭代更新. U 和 V 的更新方式如下:

$$U_i \leftarrow U_i - \eta \frac{\partial \Phi}{\partial U_i}, \quad (13)$$

$$V_j \leftarrow V_j - \eta \frac{\partial \Phi}{\partial V_j}. \quad (14)$$

其中

$$\frac{\partial \Phi}{\partial U_i} = - \sum_{\{j|B_{i,j}=1\}} (1 - g(U_i^T V_j)) V_j + \sum_{\{j|B_{i,j}=0\}} g(U_i^T V_j) V_j + \lambda_U U_i, \quad (15)$$

$$\frac{\partial \Phi}{\partial V_j} = - \sum_{\{i|B_{i,j}=1\}} (1 - g(U_i^T V_j)) U_i + \sum_{\{i|B_{i,j}=0\}} g(U_i^T V_j) U_i + \lambda_V V_j. \quad (16)$$

2.2 IFS-BeMF

利用前文提及的伯努利矩阵分解 BeMF 分别对隶属度矩阵 M 、非隶属度矩阵 N 和犹豫度矩阵 H 进行并行拟合求解,得到每个矩阵的最佳潜在特征向量对分别为 (U^M, V^M) 、 (U^N, V^N) 和 (U^H, V^H) . 考虑到求得的3个特征向量对的內积和可能不等于1,需对其和进行归一化处理,再按比例划分贡献,得出用户 i 对项目 j 偏好程度的直觉模糊数为

$$\alpha_{i,j} = (u_i(j), v_i(j)) = \left(\frac{g(U_i^M V_j^M)}{\sum_{B \in \{M,N,H\}} g(U_i^B V_j^B)}, \frac{g(U_i^N V_j^N)}{\sum_{B \in \{M,N,H\}} g(U_i^B V_j^B)} \right). \quad (17)$$

相似地,可以得到用户 i 在所有未评分项目上的直觉模糊数. 进而根据定义2对直觉模糊数进行内部排序,并为目标用户 i 进行 Top- n 推荐.

3 实验结果及分析

3.1 数据集描述

本文采用两个不同规模的 MovieLens (ML) 电影数据集 (ML-100K 和 ML-1M) 和一个稀疏度更低的 Yahoo Music (YM) 音乐数据集进行对比实验,具体数据见表1. 为了评价所提出模型的有效性,将每个数据集划分为训练集和测试集两部分. 其中,训练集由通过从每个用户所评项目中随机抽取80%的数据确定,用来模型学习;剩余20%数据为测试集,用来验证训练效果. 为了保证所有实验结果的可靠性和稳定性,共进行5次重复训练,对结果进行平均从而得到最终评估结果.

表1 实验数据集描述

数据集	用户数量	项目数量	评分数量	评分区间	稀疏度/%
ML-100K	943	1682	100000	[1~5]	6.3
ML-1M	6040	3952	1000209	[1~5]	4.2
YM	15400	1000	365704	[1~5]	2.3

3.2 评估指标

由于所提出方法更侧重于 Top- n 推荐,在实验过程中只使用项目排序推荐的相关指标评估模型的性能.

命中率 HR: 用来衡量模型预测推荐的能力,有

$$HR@k = \frac{1}{M} \sum_{i=1}^M \text{hits}(i). \quad (18)$$

其中: M 为用户数量, $\text{hits}(i)$ 为第 i 个用户前 k 个预测推荐项目在实际推荐项目集合中的比例. 这里规定: 若目标用户的实际或预测评分大于评分区间中值,则该项目被加入待推荐列表中. 由于本文方法无法得到预测评分,假定若目标用户在未评分项目上的预测隶属度大于非隶属度,则该项目被视为待推荐项目.

归一化折扣累积增益 NDCG: 用来衡量在推荐列表中待推荐项目排名的质量,有

$$NDCG@k = \frac{DCG@k}{IDCG@k}, \quad (19)$$

$$DCG@k = \sum_{p=1}^k \frac{2^{\text{rel}_p} - 1}{\log_2^{p+1}}, \quad (20)$$

$$IDCG@k = \sum_{p=1}^{|\text{REL}|} \frac{2^{\text{rel}_p} - 1}{\log_2^{p+1}}. \quad (21)$$

其中: $DCG@k$ 和 $IDCG@k$ 分别为位于排序列表前 k 个项目的折扣累积增益和 DCG 的理想值; rel_p 为位置 p 处目标用户对推荐项目的偏好程度.

3.3 对比方法

为了验证所提出模型的有效性,与4个基于矩阵分解的推荐模型进行性能比较. 对比方法描述如下:

1) matrix factorization (MF)^[10]: 是最基础的基于模型的方法,主要利用最小二乘法 ALS 优化目标函数,用于验证所提出方法是否有效.

2) probabilistic matrix factorization with implicit feedback (PMF+IF)^[14]: 一个扩展的概率矩阵分解模型,考虑了隐式反馈对模型的影响,用于验证引入不同辅助信息的方法的性能表现.

3) neural matrix factorization (NeuMF 或 NCF)^[20]: 一个经典的基于神经网络的矩阵分解模型,通过利用多层感知机 MLP 学习用户与项目间的交互信息,用于测试线性方法与非线性方法的性能对比.

4) Bernoulli matrix factorization (BeMF)^[17]: 一个


基于伯努利分布的矩阵分解模型,按照评分值划分子矩阵,可预测出具有可靠性概率的离散评分,用于验证使用不同的评分矩阵划分方法对系统性能的影响.

实验中,通过网格搜索的方式设置不同模型的最佳参数,所有方法的最大迭代次数为50次.对于所提出的IFS-BeMF方法,模型训练的学习率和潜在特征向量的 L_2 正则化均为 10^{-3} .对于MF方法,其潜在矩阵的 L_2 正则化为 10^{-3} .对于PMF+IF方法,模型的学习率为 10^{-3} ,用户和项目潜在特征矩阵的 L_2 正则化为 10^{-2} ,展示隐含因子矩阵的 L_2 正则化为 10^{-3} ,隐式反馈对目标函数的贡献度为0.2,缺失评分的权重为1.对于NeuMF方法,利用优化器Adam对其训练,初始学习率为 10^{-3} ,批尺寸为128,MLP的隐藏层层数为3.对于BeMF方法,其学习率和潜在矩阵的 L_2 正则化均为 10^{-2} ,可靠性阈值设置为0.38,以确保80%以上的预测评分是可靠的.


3.4 实验结果与分析

在所提出模型中,填充部分缺失评分是否能进一步提升模型的推荐性能是测试的关键性环节.对每个用户随机选择[100, 200, 300]个未评分项目进行偏好填充.由图2可见,随着填充数量 f 的增加,本文方法两指标先提升然后急剧下降,在 $f = 100$ 时,本文方法获得最佳的推荐性能,且优于其他对比方法.这表明预先对评分矩阵中的空白区域进行适当填充,能够在一定程度上提高所提出方法的推荐质量.而且相比于未填充的IFS-BeMF,最佳的IFS-BeMF的HR@5和NDCG@5分别提升了4.6%和1%,这结果在ML-100K数据集上显示填充数量对HR指标影响更大.表明有效地填充评分能为推荐算法提供更多额外潜在有价值的信息进而提高推荐结果的准确性.因此,为了获得所提出模型的最佳表现,在后续对比实验中将固定模型的填充数量为100.

潜在因子数量 d 作为矩阵分解模型中的重要参数,测试了不同潜在因子数量[10, 20, 30, 40]对所有对比模型的性能影响,结果如图3所示.从图3可以明显发现,所提出方法的两指标结果基本不受潜在因子数量的影响,尤其在NDCG指标上尤为平稳,这表明所提出模型具有很好的稳定性,且在较少的因子数量下也能得到较好的推荐结果.同时发现,传统MF方法的结果会随 d 值的增加而逐渐变差,特别是HR指标,其推荐性能在所有对比方法中表现最差.图3(a)中,PMF+IF方法在 $d = 20$ 时得到最好的HR@5结果,为0.548;其次是NCF方法,在 $d = 30$ 时获得HR@5结果为0.547;本文方法在 $d = 30$ 时最佳的HR@5为0.545.这三个结果都相差不大,表明在模型

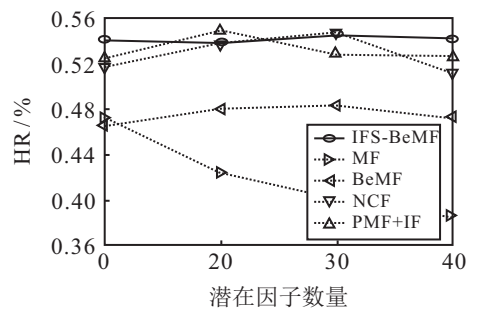


(a) 填充数量 f 与HR@5




(b) 填充数量 f 与NDCG@5

图2 数据集ML-100K上的推荐性能对比($d = 10$)



(a) 潜在因子数量 d 与HR@5



(b) 潜在因子数量 d 与NDCG@5

图3 数据集ML-100K上的推荐表现对比($f = 100$)

中引入辅助信息且考虑用户的偏好行为能获得较好的推荐效果.图3(b)中,BeMF方法在潜在因子数超过20时,NDCG指标有明显提升且后续保持稳定,其结果也与本文方法基本一致;但BeMF方法在HR指标上表现欠佳,远不如本文方法.这是因为BeMF方法只是简单地将评分矩阵按评分值划分子矩阵来并行预测评分存在一定不足,使得在不同指标上模型的鲁棒性较差.本文方法则是通过借助直觉模糊集理论,按照用户兴趣偏好划分评分矩阵,使得推荐结果更加准确和可靠,这也表明了矩阵分解模型中考虑

用户偏好信息的重要性和优势. 因此, 综合两指标看, 本文方法优于其他对比的模型.

推荐数目 k 同样也是衡量模型推荐质量的重要因素. 实验中根据图3的综合结果选择每个方法的最佳参数进行性能比较, 如图4所示. 由图4可知, 随着推荐数量的增加, 所有方法的HR和NDCG指标均呈上升趋势, 本文方法在所有对比方法中实现了最好的推荐效果, 充分表明了所提出方法的有效性. 由图4(a)可见, NCF方法依然是次优方法, 结果与本文方法相近. 图4(b)中, PMF+IF方法表现不佳, 尤其是推荐数目大于7后, NDCG结果增加幅度较小, 且低于MF方法. 原因可能是该方法易受隐式反馈信息的影响, 导致项目的推荐顺序变动较大. BeMF方法在NDCG指标上效果较好, 仅次于本文模型, 表明使用BeMF模型拟合矩阵在特定指标上是有效的, 同时由于本文方法考虑了用户兴趣偏好, 使得推荐效果更佳.

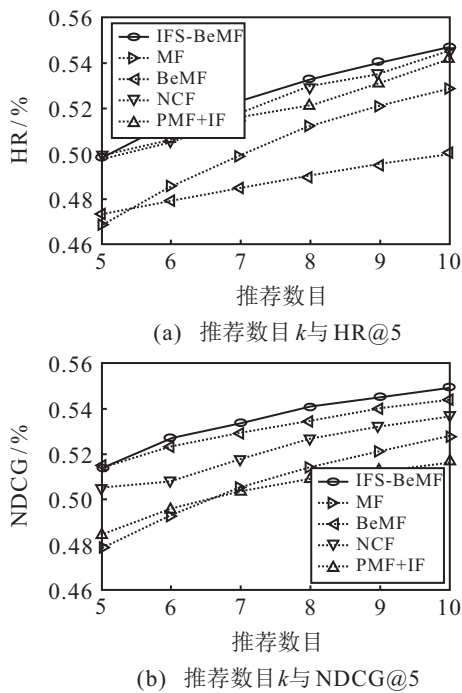


图4 数据集ML-100K上不同推荐个数的性能对比

相似地, 在同等参数条件下, 所有方法在ML-1M和YM数据集进行性能对比, 结果见表2. 从表2可以看出, 所提出方法无论在推荐质量上还是在模型训练时间上均优于其他对比方法, 这表明本文方法能够很好地兼顾推荐准确性和系统运行效率. 在ML-1M数据集上, 本文方法相比NCF方法在HR和NDCG指标上性能提升了3.6%和5.3%, 这显示在模型中考虑用户偏好信息能够更加准确地预测出用户感兴趣的项目; 在YM数据集上本文方法性能提升幅度相对较小, 但表现依然优于其他方法. 综上所述, 本文提出的

IFS-BeMF模型在项目排序指标上均优于其对比方法, 能有效提高推荐系统的质量.

表2 在数据集(ML-1M, YM)上的推荐表现比较

对比方法	HR@5	NDCG@5	训练总时间/min
MF	(0.498, 0.522)	(0.478, 0.516)	(41.9, 26.1)
BeMF	(0.519, 0.411)	(0.507, 0.416)	(31.5, 11.2)
NCF	(0.526, 0.562)	(0.512, 0.551)	(74.9, 35.1)
PMF+IF	(0.523, 0.545)	(0.511, 0.534)	(24.5, 8.4)
IFS-BeMF	(0.545, 0.565)	(0.539, 0.564)	(23.9, 4.9)

4 结论

本文从用户偏好模糊概率的角度发出, 提出了一种基于直觉模糊集的伯努利矩阵分解推荐模型进行Top- n 推荐. 相比于利用用户绝对评分值的矩阵分解方法, 所提出方法能够从定性的角度描述用户的不确定决策信息, 通过将用户偏好特征以及直觉模糊集概念融合到伯努利矩阵分解模型中, 预测用户对项目的偏好程度的直觉模糊数, 并将排名靠前的项目推送给目标用户. 在3个公开数据集上的实验结果表明, 所提出方法相比于主流的基于矩阵分解的推荐模型, 在推荐项目排序指标上都具有较好的性能表现, 这有效地提高了系统的推荐效果.

所提出方法的局限性在于: 首先, 该方法只能预测出目标用户对未评分项目偏好程度的直觉模糊数进行项目排序推荐, 无法预测出项目的具体评分值, 使得无法验证推荐系统的预测准确性; 其次, 该方法只适用于有用户评分信息的推荐系统, 对于只有其他交互信息(如浏览、点击或购买等行为)的系统不太适用.

参考文献(References)

- [1] Xu Z S, Zhao N. Information fusion for intuitionistic fuzzy decision making: An overview[J]. Information Fusion, 2016, 28: 10-23.
- [2] Bag S, Kumar S, Awasthi A, et al. A noise correction-based approach to support a recommender system in a highly sparse rating environment[J]. Decision Support Systems, 2019, 118: 46-57.
- [3] Goldberg D, Nichols D, Oki B M, et al. Using collaborative filtering to weave an information tapestry[J]. Communications of the ACM, 1992, 35(12): 61-70.
- [4] Cacheda F, Carneiro V, Fernández D, et al. Comparison of collaborative filtering algorithms: Limitations of current techniques and proposals for scalable, high-performance recommender systems[J]. ACM Transactions on the Web, 2011, 5(1): 2.

- [5] Valcarce D, Parapar J, Barreiro Á. Finding and analysing good neighbourhoods to improve collaborative filtering[J]. Knowledge-Based Systems, 2018, 159: 193-202.
- [6] Hofmann T. Latent semantic models for collaborative filtering[J]. ACM Transactions on Information Systems, 2004, 22(1): 89-115.
- [7] Koren Y, Bell R. Advances in collaborative filtering[M]. Recommender Systems Handbook. Boston: Springer, 2015: 77-118.
- [8] Zadeh L A. Fuzzy logic computing with words[J]. IEEE Transactions on Fuzzy Systems, 1996, 4(2): 103-111.
- [9] Jenatton R, Roux N, Bordes A, et al. A latent factor model for highly multi-relational data[J]. Advances in Neural Information Processing Systems, 2012, 25: 3176-3184.
- [10] Koren Y, Bell R, Volinsky C. Matrix factorization techniques for recommender systems[J]. Computer, 2009, 42(8): 30-37.
- [11] Koren Y. Factorization meets the neighborhood: A multifaceted collaborative filtering model[C]. Proceedings of the 14th ACM SIGKDD international Conference on Knowledge Discovery and Data mining. Las Vegas: AMC, 2008: 426-434.
- [12] Liu J T, Wu C H, Liu W Y. Bayesian probabilistic matrix factorization with social relations and item contents for recommendation[J]. Decision Support Systems, 2013, 55(3): 838-850.
- [13] Févotte C, Idier J. Algorithms for nonnegative matrix factorization with the β -divergence[J]. Neural Computation, 2011, 23(9): 2421-2456.
- [14] Chen S L, Peng Y X. Matrix factorization for recommendation with explicit and implicit feedback[J]. Knowledge-Based Systems, 2018, 158: 109-117.
- [15] Cui Z H, Zhao P, Hu Z M, et al. An improved matrix factorization based model for many-objective optimization recommendation[J]. Information Sciences, 2021, 579: 1-14.
- [16] Shen R P, Zhang H R, Yu H, et al. Sentiment based matrix factorization with reliability for recommendation[J]. Expert Systems with Applications, 2019, 135: 249-258.
- [17] Ortega F, Lara-Cabrera R, González-Prieto Á, et al. Providing reliability in recommender systems through Bernoulli matrix factorization[J]. Information Sciences, 2021, 553: 110-128.
- [18] Kuo L Y, Chou C K, Chen M S. The framework of personalized ranking on Poisson factorization[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 33(1): 287-301.
- [19] Pujahari A, Sisodia D S. Pair-wise preference relation based probabilistic matrix factorization for collaborative filtering in recommender system[J]. Knowledge-Based Systems, 2020, 196: 105798.
- [20] He X N, Liao L Z, Zhang H W, et al. Neural collaborative filtering[C]. Proceedings of the 26th International Conference on World Wide Web. Perth: ACM, 2017: 173-182.
- [21] Xue H J, Dai X, Zhang J, et al. Deep matrix factorization models for recommender systems[C]. Proceedings of the 26th International Joint Conference on Artificial Intelligence. Melbourne: IJCAI, 2017, 17: 3203-3209.
- [22] Zadeh L A. Fuzzy sets[J]. Information and Control, 1965, 8(3): 338-353.
- [23] Atanassov K T. Intuitionistic fuzzy sets[J]. Fuzzy Sets and Systems, 1986, 20(1): 87-96.
- [24] Xu Z S, Yager R R. Some geometric aggregation operators based on intuitionistic fuzzy sets[J]. International Journal of General Systems, 2006, 35(4): 417-433.
- [25] Xu Z S. Intuitionistic fuzzy aggregation operators[J]. IEEE Transactions on Fuzzy Systems, 2007, 15(6): 1179-1187.
- [26] Guo J P, Deng J Z, Wang Y. An intuitionistic fuzzy set based hybrid similarity model for recommender system[J]. Expert Systems with Applications, 2019, 135: 153-163.

作者简介

邓江洲(1993—),男,博士生,从事推荐系统、智能决策与优化等研究, E-mail: dengjz114@163.com;

郭均鹏(1973—),男,教授,博士生导师,从事推荐系统、智能决策与优化等研究, E-mail: guojp@tju.edu.cn.