

基于时间信息表示学习的个性化推荐方法

任秋臻, 陈红梅, 周丽华
(云南大学 信息学院, 云南 昆明 650500)

摘要: 个性化推荐已成为现代智能化服务中的重要技术, 时间信息是影响个性化推荐效果的重要因素。然而现有基于网络表示学习的个性化推荐方法, 有的将事物及其关系抽象为同质网络, 忽视了固有的异质性; 有的虽将事物及其关系建模为异质网络, 但没有较好地利用时间信息。因此, 文中提出一种基于时间信息表示学习的个性化推荐方法 (Time Representation Learning Incorporating into User Collaborative Filtering, TRLIUCF), TRLIUCF 方法综合利用了评论的时间信息、文本信息、评分信息, 获得了较好的推荐结果。首先, 根据评论文本提取评论情绪特征, 并根据时间信息提取评论时间特征, 基于二者提出评论综合情绪-贡献值及其计算方法。然后, 基于评论综合情绪-贡献值和用户评论数据构建用户-商品-评论异质网络, 并采用网络表示学习方法学习节点嵌入向量。最后, 通过用户节点嵌入向量计算用户相似性, 并采用基于用户的协同过滤进行 TOP-N 推荐。在两个不同规模的真实数据集上的实验表明, 与基准方法相比, TRLIUCF 方法提高了推荐精确率和召回率。

关键词: 时间信息; 网络表示学习; 异质网络; 协同过滤; 个性化推荐

中图分类号: TP391

文献标识码: A

文章编号: 1673-629X(2023)01-0034-08

doi: 10.3969/j.issn.1673-629X.2023.01.006

Personalized Recommendation Method Based on Time Representation Learning

REN Qiu-zhen, CHEN Hong-mei, ZHOU Li-hua

(School of Information Science and Engineering, Yunnan University, Kunming 650500, China)

Abstract: Personal recommendations have become an important technology in modern intelligent services, and time information is an important factor affecting the effectiveness of personalized recommendations. However, some existing personalized recommendation methods based on network representation learning abstract things and their relationships as homogeneous networks, ignoring the inherent heterogeneity; some model things and their relationships as heterogeneous networks, but do not make use of time information. Accordingly, we propose a personalized recommendation method based on Time Representation Learning Incorporating into User Collaborative Filtering (TRLIUCF), which integrates temporal information, textual information, and rating information of reviews to obtain better results. Firstly, we extract the comment sentiment features based on the comment text, and extract the comment time features based on the time information, and propose the comment integrated sentiment-contribution value and its calculation method. Then, a user-item-review heterogeneous network is created based on the comment integrated sentiment-contribution value and user review data, and a network representation learning method is used to learn the node embedding vector. Finally, user similarity is calculated by the embedding vector of the user node and TOP-N recommendation is executed using user-based collaborative filtering. Experiments on two real datasets of different sizes show that the TRLIUCF method improves recommendation precision and recall compared to the benchmark method.

Key words: time information; network representation learning; heterogeneous networks; collaborative filtering; personalized recommendation

0 引言

个性化推荐作为缓解信息过载的有效手段, 被广泛运用于各大智能平台, 如电商、图书推荐、影视剧网

站、个性化图像检索等^[1-5]。其中, 用户偏好除了显性特征(评分), 还存在隐性特征(时间特性、评论情绪), 而隐性特征往往能更好地体现用户偏好。关注用户外

收稿日期: 2022-02-19

修回日期: 2022-06-23

基金项目: 国家自然科学基金(62062066, 61966036); 云南省中青年学术和技术带头人后备人才项目(202105AC160067); 云南省应用基础研究计划重点项目(202101AS070056)

作者简介: 任秋臻(1996-), 女, 硕士, 研究方向为数据挖掘、推荐系统; 通信作者: 陈红梅(1976-), 女, 博士, 副教授, CCF 会员(49450M), 研究方向为数据挖掘、空间数据挖掘。

在行为数据(评分等)和内在行为特征(评论情绪等)可以有效提升个性化推荐效果,增加推荐项目的精确率、召回率等^[6-7]。

传统推荐算法缺乏对辅助信息的利用^[8-9],为了提升推荐效果,充分利用多种上下文信息使数据价值最大化是当前推荐系统亟待解决的问题之一^[10]。李宇琦等^[11]研究表明,用户偏好与时间相关,可以通过用户的历史购买信息和商品的低维空间向量表示获得用户在某一时间点的偏好。时间信息对于打算购买商品的用户来说,具有很强的即时意义。如果不考虑时间因素,可能会出现在冬天推荐体恤,在夏天推荐棉袄,从而降低了推荐效果。此外,用户对于商品的兴趣也会呈现明显的季节特性,例如用户A和用户B在去年夏季购买了多种类似的商品,且发表了相似的评论,在今年夏季用户A想要购买一套游泳装备,而该类商品用户B曾经在夏季购买并给过好评,根据系统推荐的商品列表,用户A查看该时间段的购买评分、评论,可能会选择用户B购买过的这套商品。因此,时间信息在个性化推荐中是一个重要的影响因素。

此外,现有基于网络表示学习的个性化推荐方法中,有的方法将现实生活中的事物及其关系抽象成为同质网络(如用户-用户网或商品-商品网)^[11],忽视了事物及其关系的异质性;而有的方法虽然将事物及其关系建模成为异质网络(如用户-商品网)^[12-13],但没有较好地利用时间信息及隐性特征。因此,该文研究基于时间信息表示学习的个性化推荐,主要工作包括:

(1)分析用户评论数据,提取评论情绪特征,并根据时间信息提取评论时间特征,基于这两种隐性偏好特征,提出综合情绪-贡献值及其计算方法。

(2)基于综合情绪-贡献值,将用户的评论、评分数据抽象为用户-商品-评论异质网络,采用网络表示学习方法获取用户节点的嵌入向量,结合基于用户的协同过滤方法进行TOP-N推荐。

在两个真实数据集 Amazon Electronics Review Data 和 Amazon Fine Food Reviews 上进行实验,评估所提出的推荐方法。实验结果表明,与基准方法相比,所提方法提升了推荐结果的精确率、召回率。

1 相关工作

现有的利用辅助信息(如评分、文本、时间等)提高推荐结果的方法可以分为两类。

第一类,结合网络表示学习方法^[14-17]进行推荐。李宇琦等基于商品-商品网络,提出了PGE模型,并与用户的动态偏好相结合,进行个性化商品推荐^[11]。詹娜娜等将电商评分等关系型数据构建成为异构网络,设

计了个性化异构网络采样方法并学习节点向量,将其融入到神经网络中进行优化^[12]。李可等引入深层语义特征挖掘模型,挖掘评论的深层语义特征和用户情感偏好,并结合SVD模型来提升推荐效果^[18]。傅魁等引入LSTM网络对深度Q网络进行改进,融入正负反馈数据集和商品购买的时序性,提出了基于改进的深度Q网络结构的商品推荐模型^[19]。张金柱等构建融合了多种图书特征信息的图书异构网络,并基于网络表示学习方法从语义相关角度设计了图书推荐方法,提升了推荐结果^[2]。

第二类,协同过滤方法结合网络表示学习方法^[10,20-23]。王旭等提出MetaStruct-CF算法,通过元结构利用异构网络中的丰富信息来提高推荐性能^[24]。梁仕威等基于矩阵分解的协同过滤算法,结合表示学习方法学习带有语义信息的用户和文档的表示向量,以解决新闻推荐的冷启动问题^[25]。陈嘉颖等基于文本信息结合知识图谱进行语义特征分析,将特征向量整合到协同过滤推荐中进行学习,根据学习结果进行推荐^[26]。

网络结构能直观展现人、物关系,并且能够融入上下文信息等多种特征信息。受结合网络嵌入和协同过滤的推荐方法^[20]、基于用户的协同过滤技术^[27]的启发,提出基于时间信息表示学习的个性化推荐方法,即基于用户与项目之间的显性偏好(评分关系)及隐性偏好(评论时间特征、情绪特征),进行异质网络构建和推荐,有效提升推荐结果的精确率、召回率。

2 基于时间信息表示学习的个性化推荐

该文所提基于时间信息表示学习的个性化推荐模型如图1所示。具体地,首先,进行评论信息特征抽取,采用TextBlob工具提取评论情绪特征;考虑到商品的售卖具有季节性特征,因此按时间信息将用户评论进行年-季度的划分提取评论时间特征,基于两个特征计算评论综合情绪-贡献值。其次,根据用户评论、用户评分和评论综合情绪-贡献值构建用户-商品-评论网络。然后,采用Node2vec方法学习网络的节点

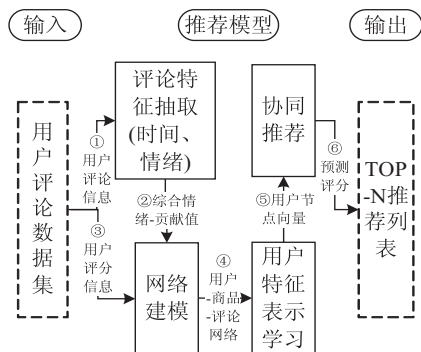


图1 基于时间信息表示学习的个性化推荐模型

式中, π_{ex} 为从当前节点 e 到下一节点 x 的未归一化转移概率, Z 为归一化常数, $\text{Neighbor}(e)$ 为当前节点 e 的邻居节点集。 $\alpha_{pq}(k, x)$ 为由超参数 p 和 q 控制的有偏转移策略, 超参数 p 控制访问刚刚访问过的顶点的概率, q 控制在随机游走时向外还是向内游走, 若 $q > 1$ 则倾向于向内游走即广度优先搜索, 若 $q < 1$ 则倾向于向外游走即深度优先搜索。 w_{ex} 为节点 e 与节点 x 间的边权, d_{kx} 为刚刚访问过的节点 k 与节点 x 间的最短路径。

最后, 采用基于用户的协同过滤方法向用户进行 Top-N 商品推荐, 其中根据用户节点特征向量及余弦相似性度量, 计算用户相似性。

3 实验结果与分析

3.1 实验设置

数据集: 采用两个不同规模的亚马逊数据集: Amazon Electronics Review Data (AERD) 和 Amazon Fine Food Reviews (AFFR)。数据预处理过程如下: ①提取所需数据列; ②删除评论文本为空和为无意义标点符号的评论; ③将用户的评论次数少于 15 次, 多于 300 次的数据删除; ④按 8 : 2 比例划分训练集和测试集。最终的数据集描述如表 1 所示。

表 1 数据集

数据集	用户数	商品数	评论数
AERD	25 900	144 976	657 261
AFFR	3 297	21 892	89 793

对比方法: 为评估所提方法 TRLIUCF, 选用了两个基准方法: 基于用户的协同过滤推荐方法 UCF^[27] 和结合网络嵌入和协同过滤的推荐方法 NUCF^[20]。NUCF 与 TRLIUCF 的主要区别是: NUCF 基于用户与项目之间的显性偏好(评分关系)进行同质网络建模和推荐, 而 TRLIUCF 则是基于用户与项目之间的显性偏好(评分关系)及隐性偏好(评论的情绪特征和时间特征), 进行异质网络构建和推荐。NUCF 方法构建的用户-用户同质网的边权设置为共同评分的项目中评分相同的项目数量。而 TRLIUCF 方法构建的用户-商品-评论异质网的边权设置如 2.2 节中的介绍。

参数设置: UCF、NUCF、TRLIUCF 方法在计算预测评分时有参数“相似用户数量 K ”, 在计算 TOP-N 推荐列表时, 有参数“推荐商品数量 N ”; NUCF 和 TRLIUCF 方法在进行节点向量学习时, 有参数“随机游走步长 walk_length ”和“随机游走超参数 p 、 q ”。默认情况下, $K = 100$, $N = 5$, $\text{walk_length} = 10$, $p = 0.5$, $q = 4$ 。

评价指标: 除了常用的公式(4)和(5)所示的精

率(Precision)和召回率(Recall)之外, 为了更好地评估推荐模型, 该文还采用了公式(6)所示的 F1 值。

$$\text{Precision} = \frac{\sum_{u \in U} |R(u) \cap T(u)|}{\sum_{u \in U} |R(u)|} \quad (4)$$

$$\text{Recall} = \frac{\sum_{u \in U} |R(u) \cap T(u)|}{\sum_{u \in U} |T(u)|} \quad (5)$$

其中, $R(u)$ 为用户 u 的推荐商品列表, $T(u)$ 为用户 u 购买的商品列表。

$$\text{F1} = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (6)$$

3.2 实验结果分析

参数对推荐效果有着重要影响, 因此, 分析相似用户数量 K 、随机游走步长 walk_length 、随机游走超参数 p 和 q 以及推荐商品数量 N 对推荐效果的影响。

3.2.1 相似用户数量 K 对方法效果的影响


本节评估相似用户数量 K 对基准方法 UCF、NUCF 和所提方法 TRLIUCF 推荐效果的影响, 实验结果如图 3 所示。其中, 除相似用户数量 K 以外, 其他参数设为默认值, 图 3(a)、(b)、(c) 为在 AERD 数据集上的实验结果; 图 3(d)、(e)、(f) 为在 AFFR 数据集上的实验结果。

从图 3(a)、(b)、(c) 可以看出, 在 AERD 数据集上, UCF 方法的召回率和精确率都随着 K 的增加而增加; NUCF 方法和 TRLIUCF 方法的召回率和精确率都随着 K 的增加而减少。从 F1 值来看, K 值对 UCF 方法的影响较小, 对 NUCF 和 TRLIUCF 方法的影响稍大, 但 TRLIUCF 方法能够有效提升推荐的召回率和精确率, 其中, TRLIUCF 方法的召回率比 UCF、NUCF 方法分别提升了 125% ~ 220%、8.33% ~ 20%。TRLIUCF 方法的精确率比 UCF、NUCF 方法分别提升了 115.79% ~ 223.53%、10.81% ~ 22.22%。

从图 3(d)、(e)、(f) 可以看出, 在数据集 AFFR 上, UCF、NUCF 和 TRLIUCF 方法的召回率和精确率都随着 K 的增加而缓慢减少。从 F1 值来看, UCF 和 NUCF 方法受 K 值影响较小相对稳定, TRLIUCF 方法受 K 值影响明显, 但 TRLIUCF 方法能够有效提升推荐的召回率和精确率, 其中, TRLIUCF 方法的召回率比 UCF、NUCF 方法分别提升了 344.59% ~ 369.33%、13.84% ~ 19.73%。TRLIUCF 方法的精确率比 UCF、NUCF 方法分别提升了 345.45% ~ 370.79%、13.95% ~ 19.71%。

3.2.2 随机游走步长 walk_length 对方法效果的影响


本节评估随机游走步长 walk_length 对基准方法 NUCF 和所提方法 TRLIUCF 推荐效果的影响, 实验结

图 3 相似用户数量 K 对推荐效果的影响

果如图 4 所示。其中,除随机游走步长 $walk_length$ 以外,其他参数设为默认值,图 4(a)、(b)、(c) 为在 AERD 数据集上的实验结果;图 4(d)、(e)、(f) 为在 AFFR 数据集上的实验结果。

从图 4(a)、(b)、(c) 可以看出,在 AERD 数据集

上,NUCF 方法的召回率和精确率都随 $walk_length$ 的增加而增加,而 TRLIUCF 方法的召回率和精确率都随 $walk_length$ 的增加而减少。从 F1 值来看, $walk_length$ 的增加对 NUCF 方法影响较大,而 TRLIUCF 方法相对稳定。当 $walk_length=10$ 时,TRLIUCF 方法明显优于

图 4 随机游走步长 $walk_length$ 对推荐效果的影响

NUCF方法,但随着 walk_length 的增加,TRLIUCF 方法的优势减弱,但依然优于 UNCF 方法。其中,TRLIUCF 方法的召回率比 NUCF 方法提升了 2.17% ~ 20%;TRLIUCF 方法的精确率比 NUCF 方法提升了 1.89% ~ 22.22%。

从图 4(d)、(e)、(f)可以看出,在 AFFR 数据集上,NUCF 和 TRLIUCF 方法的召回率和精确率都随 walk_length 的增加而增加。从 F1 值来看,walk_length 对 NUCF 和 TRLIUCF 方法的影响相对稳定。与 NUCF 方法相比,TRLIUCF 方法有效提升推荐的召回

率和精确率。其中,TRLIUCF 方法的召回率比 NUCF 方法提升了 19.73% ~ 20%;TRLIUCF 方法的精确率比 NUCF 方法提升了 19.71% ~ 20.23%。

3.2.3 随机游走超参数 p 、 q 对方法效果的影响

本节评估随机游走超参数 p 、 q 对基准方法 NUCF 和所提方法 TRLIUCF 推荐效果的影响,实验结果如图 5 所示。其中,除随机游走超参数 p 、 q 以外,其他参数设为默认值,图 5(a)、(b)、(c)为在 AERD 数据集上的实验结果;图 5(d)、(e)、(f)为在 AFFR 数据集上的实验结果。

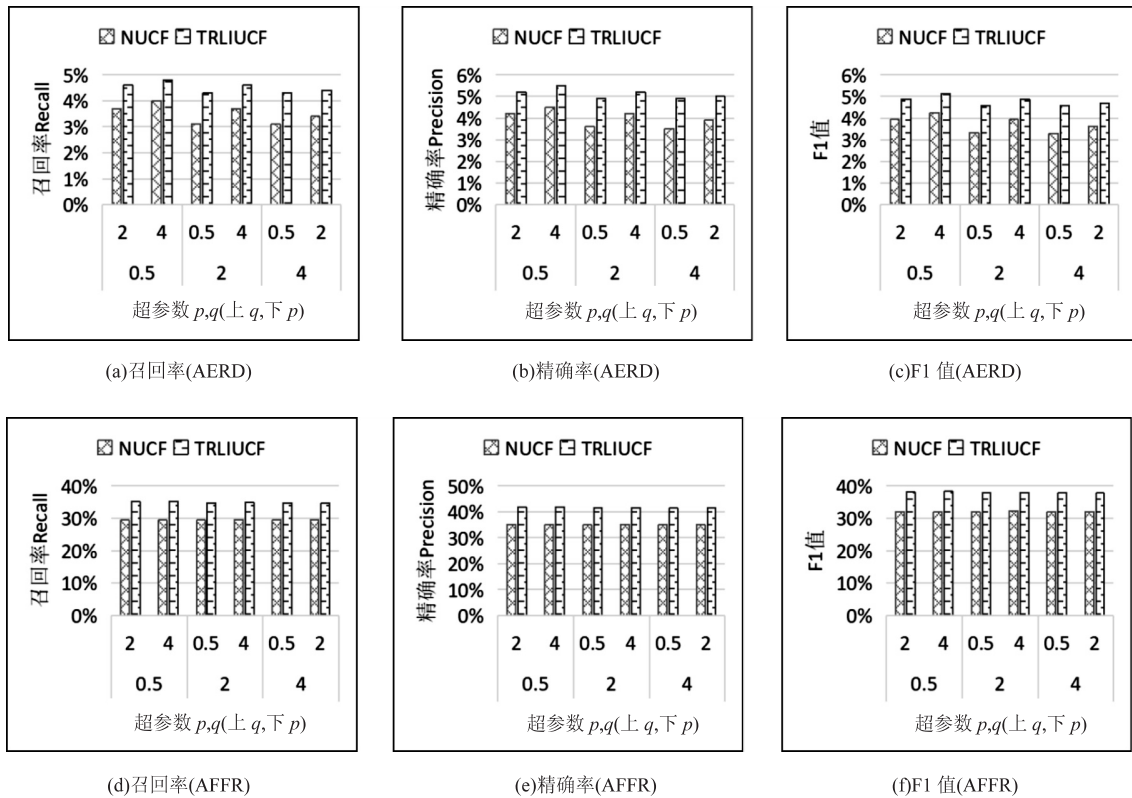


图5 随机游走超参数对推荐效果的影响

从图 5(a)、(b)、(c)可以看出,在 AERD 数据集上, p 一定时,NUCF 和 TRLIUCF 方法的召回率、精确率随着 q 的增加而增加; q 一定时,NUCF 和 TRLIUCF 方法的召回率、精确率随着 p 的增加而减小。从 F1 值来看,NUCF 与 TRLIUCF 方法受每对 p 、 q 值的影响较明显,但 TRLIUCF 方法明显优于 NUCF 方法,能有效提升推荐的精确率和召回率。其中,TRLIUCF 方法的召回率比 NUCF 方法提升了 20% ~ 38.71%。TRLIUCF 方法的精确率比 NUCF 方法提升了 22.22% ~ 40%。

从图 5(d)、(e)、(f)可以看出,在 AFFR 数据集上,超参数 p 、 q 的变化使得 NUCF 和 TRLIUCF 方法都呈现波动状态且变化缓慢。 p 一定时,NUCF 方法的召回率随着 q 的增加先不变后增加然后趋于稳定,精确率随着 q 的增加先保持不变然后增加最后缓慢减

少;TRLIUCF 方法的召回率随着 q 的增加先增加后减小,精确率随着 q 的增加先增加后保持稳定。 q 一定时,NUCF 方法的召回率随着 p 的增加先增加后减小,精确率随着 p 的增加先保持不变然后增加;TRLIUCF 方法的召回率、精确率都随着 p 的增加先减小然后趋于稳定。从 F1 指标来看,超参数 p 、 q 变化对 NUCF 和 TRLIUCF 方法的影响相对稳定。TRLIUCF 方法依然明显优于 NUCF 方法,其中,TRLIUCF 方法的召回率比 NUCF 方法提升了 17.63% ~ 19.73%。TRLIUCF 方法的精确率比 NUCF 方法提升了 17.90% ~ 19.71%。

3.2.4 推荐商品数量 N 对方法效果的影响

本节评估推荐商品数量 N 对基准方法 UCF、NUCF 和所提方法 TRLIUCF 推荐效果的影响,实验结果如图 6 所示。其中,除推荐商品数量 N 以外,其他参

数设为默认值,图6(a)、(b)、(c)为在 AERD 数据集上的实验结果;图6(d)、(e)、(f)为在 AFFR 数据集上的实验结果。

从图6可以看出,在 AERD 和 AFFR 数据集上,UCF、NUCF 和 TRLIUCF 方法的推荐效果变化趋势一样,即召回率随着 N 的增加而增加,精确率随着 N 的增加而减小。从 F1 值来看,随着 N 的增加,三种方法的整体性能都呈下降趋势,但 TRLIUCF 方法的整体性

能依旧优于 UCF 和 NUCF 方法。其中,在 AERD 数据集上,TRLIUCF 方法的召回率比 UCF、NUCF 方法分别提升了 161.76% ~ 220%、20% ~ 34.85%;精确率分别提升了 150% ~ 223.53%、22.22% ~ 31.58%。在 AFFR 数据集上,TRLIUCF 方法的召回率比 UCF、NUCF 方法分别提升了 369.33% ~ 395.56%、19.73% ~ 23.20%;精确率分别提升了 370.79% ~ 396.30%、19.71% ~ 24.07%。




图6 推荐商品数量 N 对推荐效果的影响

从上述实验结果来看,将生活中的具体事物进行抽象,表达为一个网络结构,能更加清晰地表现事物之间的关联。传统的 UCF 方法因用户数量的限制,其推荐有一定的局限性,能利用的辅助信息也较少。而 NUCF 方法在传统的 UCF 方法上利用网络表示学习方法优化了相似度计算,并利用了部分辅助信息。进一步,所提方法 TRLIUCF 在前两者的基础上融入了时间信息,使用户时间偏好有所表达,加强了网络节点之间的随机转移,选择更好的邻居节点,提升了推荐效果,实现了提高召回率和精确率的目标。

4 结束语

针对现有基于网络表示学习的个性化推荐方法没有较好地考虑网络的异质性或时间信息的问题,提出了融入时间信息的网络表示学习个性化推荐方法。首先,根据评论文本和时间信息,提出评论综合情绪-贡献值及其计算方法。其次,基于评论综合情绪-贡献

值和用户评论数据构建用户-商品-评论异质网络,并采用网络表示学习方法学习节点嵌入向量。最后,通过用户节点嵌入向量计算用户相似性,并采用基于用户的协同过滤进行 TOP- N 推荐,有效地提升了推荐召回率和精确率。在下一步的研究工作中,将探索诸如时间粒度、其他上下文信息等,进一步挖掘网络的异质结构和语义,进而提升推荐效果。

参考文献:

- [1] LIU H M, WANG R P, SHAN S G, et al. Learning multi-functional binary codes for personalized image retrieval[J]. International Journal of Computer Vision, 2020, 128 (8): 2223-2242.
- [2] 张金柱, 蒋霖琪, 王 玥, 等. 基于异构网络表示学习的相关图书推荐研究[J/OL]. 计算机工程与应用: 1-10 [2022-01-29]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20210416.1500.024.html>.
- [3] 黄立威, 江碧涛, 吕守业, 等. 基于深度学习的推荐系统研

- 究综述[J]. 计算机学报, 2018, 41(7): 1619–1647.
- [4] 金丹, 张娇娇, 李依玲, 等. 一种改进的协同过滤算法研究——以电影推荐系统为例[J]. 国际商务(对外经济贸易大学学报), 2020(1): 128–141.
- [5] 王兴芬, 杜惠英. 基于买家评论文本分析的 C2C 电子商务推荐信任研究[J]. 中国流通经济, 2018, 32(11): 22–30.
- [6] 刘君良, 李晓光. 个性化推荐系统技术进展[J]. 计算机科学, 2020, 47(7): 47–55.
- [7] 刘凯, 王伟军, 黄英辉, 等. 个性化推荐系统理论探索: 从系统向用户为中心的演进[J]. 情报理论与实践, 2016, 39(3): 52–56.
- [8] 窦羚源, 王新华, 孙克. 融合标签特征和时间上下文的协同过滤推荐算法[J]. 小型微型计算机系统, 2016, 37(1): 48–52.
- [9] 蒋宗礼, 金益斌. 结合点评情感分析的推荐算法研究[J]. 计算机应用研究, 2016, 33(5): 1312–1314.
- [10] 郝志峰, 廖祥财, 温雯, 等. 基于多上下文信息的协同过滤推荐算法[J]. 计算机科学, 2021, 48(3): 168–173.
- [11] 李宇琦, 陈维政, 闫宏飞, 等. 基于网络表示学习的个性化商品推荐[J]. 计算机学报, 2019, 42(8): 1767–1778.
- [12] 詹娜娜, 刘伟, 陈新波, 等. 基于异构网络表示学习的评分预测模型[J]. 北京航空航天大学学报, 2021, 47(5): 1077–1084.
- [13] ZHAO W X, HUANG J, WEN J R. Learning distributed representations for recommender systems with a network embedding approach[C]//Asia information retrieval symposium. Beijing: Springer, 2016: 224–236.
- [14] XU C, LOUCA R, NI K. Contextual matching via graph representation learning with side information[C]//Applications of machine learning 2021. San Diego: SPIE, 2021.
- [15] YANG Z, DING M D, ZHOU C, et al. Understanding negative sampling in graph representation learning[C]//Proceedings of the 26th ACM SIGKDD international conference on knowledge discovery & data mining. New York: Association for Computing Machinery, 2020: 1666–1676.
- [16] ZHANG C X, JIANG M, ZHANG X L, et al. Multi-modal network representation learning [C]//Proceedings of the 26th ACM SIGKDD international conference on knowledge discovery & data mining. New York: Association for Computing Machinery, 2020: 3557–3558.
- [17] 赵金龙, 赵中英. 基于异质信息网络表示学习与注意力神经网络的推荐算法[J]. 计算机科学, 2021, 48(8): 72–79.
- [18] 李可, 陈光平. 基于文本深层语义特征的亚马逊商品推荐[J]. 计算机科学, 2020, 47(2): 65–71.
- [19] 傅魁, 梁少晴, 李冰. 基于改进的深度 Q 网络结构的商品推荐模型[J]. 计算机应用, 2020, 40(9): 2613–2621.
- [20] 金思源. 结合网络嵌入和协同过滤的推荐方法[D]. 上海: 上海财经大学统计与管理学院, 2020.
- [21] 刘琼昕, 覃明帅. 基于知识表示学习的协同矩阵分解方法[J]. 北京理工大学学报, 2021, 41(7): 752–757.
- [22] 苏静, 许天琪, 张贤坤, 等. 基于图卷积与外积的协同过滤推荐模型[J]. 计算机应用研究, 2021, 38(10): 3044–3048.
- [23] 刘峰, 王宝亮, 潘文采. 基于网络表示学习与深度学习的推荐算法研究[J]. 计算机工程, 2021, 47(8): 54–61.
- [24] 王旭, 庞巍, 王喆. 异构信息网络中基于元结构的协同过滤算法[J]. 计算机科学, 2019, 46(S1): 397–401.
- [25] 梁仕威, 张晨蕊, 曹雷, 等. 基于协同表示学习的个性化新闻推荐[J]. 中文信息学报, 2018, 32(11): 72–78.
- [26] 陈嘉颖, 于炯, 杨兴耀. 一种融合语义分析特征提取的推荐算法[J]. 计算机研究与发展, 2020, 57(3): 562–575.
- [27] HERLOCKER J L, KONSTAN J A, BORCHERS A, et al. An algorithmic framework for performing collaborative filtering[J]. ACM SIGIR Forum, 1999, 51(2): 227–234.
- [28] FARHA N, SAYYADA H B. Sentiment analysis to predict election results[C]//Proceedings of the second international conference on inventive systems and control. [s. l.]: Springer, 2019: 1259–1262.
- [29] GROVER A, LESKOVEC J. node2vec: scalable feature learning for networks [C]//ACM SIGKDD international conference on knowledge discovery & data mining. New York: Association for Computing Machinery, 2016: 855–864.