

结合注意力 CNN 与 GNN 的信息融合推荐方法*

钱忠胜, 赵畅, 俞情媛, 李端明



(江西财经大学 信息管理学院, 江西 南昌 330013)

通信作者: 钱忠胜, E-mail: changesme@163.com

摘要: 稀疏性问题一直是推荐系统面临的主要挑战, 而信息融合推荐可以利用用户的评论、评分以及信任等信息发掘用户的偏好来缓解这一问题, 从而为目标用户生成相应的推荐. 用户、项目信息的充分学习是构建一个成功推荐系统的关键. 但不同用户对不同项目有不同的偏好, 且用户的兴趣偏好及社交圈是动态变化的. 提出一种结合深度学习与信息融合的推荐方法来解决稀疏性等问题. 特别地, 构建了一种新的深度学习模型——结合注意力卷积神经网络 (attention CNN) 与图神经网络 (GNN) 的信息融合推荐模型 ACGIF. 首先, 在 CNN 中加入注意力机制来处理评论信息, 从评论信息中学习用户和项目的个性化表示. 根据评论编码学习评论表示, 通过用户/项目编码学习评论中用户/项目表示. 加入个性化注意力机制来筛选不同重要性级别的评论. 然后, 利用 GNN 来处理评分和信任信息. 对于每个用户来说, 扩散过程从最初的嵌入开始, 融合相关特性和捕获潜在在行为偏好的自由用户潜在向量. 设计了一个分层的影响传播结构, 以模拟用户的潜在嵌入如何随着社交扩散过程的继续而演变. 最后, 对前两部分得到的用户对项目的偏好向量进行加权融合, 获得最终的用户对于项目的偏好向量. 在 4 组公开数据集上, 以推荐结果的 MAE 和 RMSE 作为评估指标进行了实验验证. 结果表明, 与现有的 7 个典型推荐模型相比, 所提模型的推荐效果和运行时间均占优.

关键词: 推荐系统; 注意力机制; 卷积神经网络; 图神经网络; 信息融合

中图法分类号: TP391

中文引用格式: 钱忠胜, 赵畅, 俞情媛, 李端明. 结合注意力 CNN 与 GNN 的信息融合推荐方法. 软件学报, 2023, 34(5): 2317–2336. <http://www.jos.org.cn/1000-9825/6405.htm>

英文引用格式: Qian ZS, Zhao C, Yu QY, Li DM. Information Fusion Recommendation Approach Combining Attention CNN and GNN. Ruan Jian Xue Bao/Journal of Software, 2023, 34(5): 2317–2336 (in Chinese). <http://www.jos.org.cn/1000-9825/6405.htm>

Information Fusion Recommendation Approach Combining Attention CNN and GNN

QIAN Zhong-Sheng, ZHAO Chang, YU Qing-Yuan, LI Duan-Ming

(School of Information Management, Jiangxi University of Finance and Economics, Nanchang 330013, China)

Abstract: The sparsity has always been a primary challenge for recommendation system, and information fusion recommendation can alleviate this problem by exploiting user preference through their comments, ratings, and trust information, so as to generate corresponding recommendations for target users. Full learning of user and item information is the key to build a successful recommendation system. Different users have different preferences for various items, and users' interest preferences and social circle are changeable dynamically. A recommendation method combining deep learning and information fusion is proposed to solve the problem of sparsity. Particularly, a new deep learning model named information fusion recommendation model combining attention CNN and GNN (ACGIF for short), is constructed. First, attention mechanism is added to the CNN to process the comment information and learn the personalized representation of users and items from the comment information. It learns the comment representation based on comment coding, and learns the user/item representation in the comment through user/item coding. It adds personalized attention mechanism to filter comments with different levels

* 基金项目: 国家自然科学基金 (61762041); 江西省自然科学基金 (20181BAB202009); 江西省教育厅科技重点项目 (GJJ180250)
收稿时间: 2020-08-17; 修改时间: 2020-12-13, 2021-06-03; 采用时间: 2021-06-28; jos 在线出版时间: 2022-07-07
CNKI 网络首发时间: 2022-11-15

of importance. Then, the rating and trust information are processed through the GNN. For each user, the diffusion process begins with the initial embedding, combining the relevant features and the free user potential vectors that capture the potential behavioral preferences. A layered influence propagation structure is designed to simulate how the user's potential embedding evolves as the social diffusion process continues. Finally, the preference vector of the user for the item obtained from the first two parts is weighted and fused to obtain the preference vector of the final user for the item. The *MAE* and *RMSE* of the recommended results are employed as the experimental evaluation indicators on four public data sets. The experimental results show that the proposed model has better recommendation effect and running time compared with the existing seven typical recommendation models.

Key words: recommendation system; attention mechanism; convolutional neural network (CNN); graph neural network (GNN); information fusion

1 引言

近年来,推荐系统几乎在各个行业均有广泛的应用.推荐系统根据用户需求、兴趣等,通过推荐算法从海量数据中挖掘出用户感兴趣的项目,并将结果以个性化列表的形式推荐给用户.个性化推荐是机器学习在电子商务等领域的关键应用之一^[1,2].许多系统使用协同过滤(collaborative filtering, CF)方法^[3]来进行推荐.尽管在推荐领域已经出现了许多推荐算法,但仍然存在一些众所周知的问题,如数据稀疏性和冷启动等.对于这些问题,很多学者提出通过深度学习^[4-6]或者信息融合^[7-9]的方式来帮助建模用户和项目,如卷积神经网络(convolution neural network, CNN),注意力机制,图神经网络(graph neural network, GNN),评论、评分和信任^[10,11]或者地理上下文等方面.

尽管现有的研究提出了信息融合或者深度学习用于推荐的不同方法,但这些推荐算法仍然存在几个关键问题^[12].首先,它们大多采用浅层模型对评分、信任等信息进行建模,忽略了数据间的高阶交互.如何利用深度学习模型从多种信息中学习表示来进行推荐是一个难点问题.其次,一些模型只融合了一两种信息,面临着数据稀疏问题,这可能会限制算法的改进,使利用深度模型从评分、信任等数据中学习高阶信息变得困难.最后,还有一个挑战就是数据稀疏的问题.一些学者使用基于内容的推荐^[13,14]或者混合推荐来缓解数据稀疏问题,但其存在特征提取困难等问题.通过对真实世界数据的分析,我们发现评论信息不仅能够体现项目的属性,而且还能够表达用户的兴趣.基于以上所述,我们决定引入评论信息来解决这个问题.相对于不使用评论信息的模型来说,通过深度神经网络从用户对物品的评论信息中挖掘用户偏好信息,再结合评分和信任信息,可以提取到更多的有效特征表示.

为了同时考虑多种数据信息,并进行有效地融合,本文提出了一种结合注意力 CNN 与 GNN 的信息融合推荐模型 ACGIF (information fusion recommendation model combining attention CNN and GNN).在这个模型中,尝试从两个角度对用户偏好进行建模:基于评论信息的表示、基于评分和信任数据的表示.该模型在 CNN 中加入注意力机制来处理评论信息,通过 GNN 来处理评分和信任信息.对于前两部分得到的用户对项目的偏好向量进行加权融合,得到最终的用户对于项目的偏好向量.该模型可充分利用文本评论信息,结合稀疏的评分矩阵和信任矩阵,对输入进行更有效的初始化,从而有效改善了数据稀疏等问题^[15].此外,该模型将多种数据信息通过深度学习模型进行有效融合,这也是本文提出的模型与目前已有典型模型的较大区别.

为解决存在的信息融合少以及模型层次浅的问题,实现数据间的高阶交互,从多个方面对现有的模型进行了改进.主要做了如下工作.

(1) 提出了一个新的深度学习模型——结合注意力 CNN 与 GNN 的信息融合推荐模型 ACGIF.这个模型综合考虑用户和项目两方面,从评分、信任和评论数据中学习用户偏好,实现了信息融合.

(2) 在 CNN 中加入注意力机制来处理评论信息,从评论信息中学习用户和项目的个性化表示,能够筛选不同重要性级别的评论.

(3) 利用 GNN 来处理评分和信任信息,设计了一个分层的影响传播结构,以模拟用户的潜在嵌入如何随着社交扩散过程的继续而演变.

(4) 在 4 个数据集上展开实验来比较本文模型和其他 7 种典型推荐模型.结果表明,ACGIF 模型更优,可更好地利用用户之间的信任信息以及用户对项目的评论信息,在面临数据稀疏问题时效果更佳.

本文第 2 节介绍了深度学习与信息融合的相关工作, 包括 CNN、注意力机制、GNN, 以及评论、评分、信任等信息. 第 3 节介绍了多种数据信息分析以及深度学习模型, 提出了一种结合注意力 CNN 与 GNN 的信息融合推荐模型 ACGIF, 构建了该模型的整体框架. 第 4 节展开实验并分析讨论了实验结果对比情况. 第 5 节是全文总结以及下一步工作.

2 相关工作

这一节主要从两个方面对 ACGIF 模型的相关工作进行讨论, 分别是基于深度学习 (主要包括 CNN、注意力机制、GNN) 的推荐和基于信息融合的推荐.

2.1 基于深度学习的推荐

近几年, 深度学习技术在计算机视觉和自然语言处理领域得到了迅速发展, 同时也带来了一个问题: 怎样把深度学习技术引入到推荐系统中. 如今人们对这个问题的关注度越来越高, 在推荐系统领域, 该问题也已成为一个热点话题.

针对该问题, 人们已经做了大量工作^[4,6,12,15-17], 大致可以分为 3 类, 分别是: 基于 CNN 的方法、基于注意力机制的方法以及基于 GNN 的方法.

Kim 等人^[6]提出卷积矩阵因子分解模型 ConvMF. 该模型通过 CNN 来得到项目描述文本中的上下文信息, 进一步提升了评分预测精度. ConvMF 解决了词袋模型的局限性, 能同时利用评分和项目描述文档将 CNN 整合到 PMF 中, 有利于提升推荐系统的准确性. 但是, ConvMF 模型中只考虑 CNN 来处理文本信息, 模型较为单一.

Huo 等人^[15]提出卷积降噪自编码器-矩阵分解模型 CDA-MF, 其使用 CNN 模型处理文本辅助信息, 同时将结果结合其对应的用户或项目向量, 一同输入 DAE 中, 生成用户或项目的密集估计. 该模型可充分利用文本辅助信息, 结合稀疏的评分矩阵, 对输入进行更有效地初始化操作. 但是 CDA-MF 模型没有考虑信任信息, 无法有效利用用户之间的关系来进行更加准确的推荐.

Lu 等人^[18]利用基于注意力的循环神经网络从评论中提取主题信息, 并将文本特征集成到概率矩阵分解中以提高推荐性能. Liu 等人^[19]提出了分层个性化注意力模型 (NRPA), 从评论文本中学习用户和项目的个性化表示. 该模型主要包含 3 部分, 分别是用户网络、项目网络以及评分预测模块. 通过注意力模型的加入, 可以重点学习有效评论, 提高效率. 但是 NRPA 模型没有考虑用户之间的信任信息, 推荐精度有待提高.

最近, Kipf 等人^[20]设计一种用于图数据半监督学习的图卷积网络 GNN, 该网络受到谱图卷积网络^[21-23]的启发. GNN 的核心思想是以一种信息传递或信息扩散的方式生成节点嵌入的图形, 以更低的计算成本改进基于光谱的模型.

Wu 等人^[24]提出深度影响传播模型 (DiffNet) 来建模社交推荐中的递归动态社交扩散过程. 主要设计了一个 layer-wise 影响扩散部分来建模用户的潜在偏好如何被他信任的用户递归地影响. 他们在 DiffNet 的基础上提出了基于神经影响和兴趣扩散网络的社交推荐模型 (DiffNet++)^[25]. 该模型不仅考虑用户-用户社交网络, 同时考虑用户-项目兴趣网络, 通过设计 GNN 和多层注意力网络来更好地学习用户、项目的潜在表示.

这些深度模型可以在一定程度上提高推荐的性能. 然而, 上述相关工作大多数利用深度模型仅从一两种等少数信息中学习表示, 比如: 评论、评分以及信任等. 实际上, 已经有许多工作被提出从不同方面来学习多种特征^[7-9].

2.2 基于信息融合的推荐

近年来, 信息融合推荐算法在提高推荐质量方面显示出了巨大的潜力.

戴琳等人^[7]提出一种新的餐馆推荐模型 RRMIF. 该模型考虑时间、地理、餐馆以及用户等信息, 采用 K-means 聚类方法将一天分为 4 个时间段, 基于地理上下文、餐馆属性信息构建了两种餐馆相似关系矩阵, 基于用户人口统计信息构建了用户相似关系矩阵, 从而对用户产生餐馆推荐列表.

李琳等人^[8]提出融合评分和评论的推荐模型 DTMF. 该模型同时将用户和商品的评论文本的潜在主题与矩阵

分解的潜在因子进行映射, 进而进行参数的求解.

吴宾等人^[9]致力于整合多源异构数据来实现数据价值最大化, 通过为不同数据选择不同的建模方法, 融合多源异构数据来缓解数据稀疏问题. 同时设计算法 MSRA 来求解模型参数.

Zhang 等人^[26]提出了联合表示学习框架 JRL 用于 top-N 推荐. 在这个框架中, 评论、评分、图像等每类信息源都被用来学习相应的用户和项目表示, 这些表示都基于深度表示学习结构. 不同来源的表示被整合到一个额外层来获得用户和项目的联合表示. 最后, 每个源和联合表示都被训练成一个整体, 并且使用成对学习来对 top-N 推荐进行排序.

Koren 等人^[27]提出模型 SVD++, 整合了显式和隐式反馈, 构建了一个同时考虑邻居和因子信息的模型. Guo 等人^[28]提出基于信任的推荐模型 TrustSVD. 该模型在 SVD++模型的基础上进行改进, 同时考虑了评分数据和信任数据中的显式和隐式影响. 这确保可从信任信息中学习用户特定向量.

然而, 这些方法大多数都是利用浅层次的数据, 忽略了信息融合关系非常复杂的因素. 要从这些数据中学习高阶信息, 一个很大的挑战是数据非常稀疏, 不足以支持深度模型.

针对上面的问题, 本文提出利用注意力 CNN 和 GNN 两个深度学习模型, 从评论、评分、信任等信息中学习用户偏好, 主要在 3 个方面进行了改进: (1) 与以往模型相比, 融入了丰富的评论信息, 相对于评分和信任数据来说, 它包含更为充分的信息, 能更有效地缓解评分和信任稀疏性的问题, 从而更好地反映用户的兴趣偏好; (2) 在 CNN 中加入注意力机制来处理评论信息, 有利于筛选不同重要性级别的评论; (3) 通过 GNN 来处理评分和信任信息, 有利于捕获用户的动态社交变化信息.

3 利用注意力 CNN 与 GNN 的信息融合推荐模型

这部分首先基于 4 个数据集 (它们的相关介绍见第 4.1 节) 阐述需融合的各种信息及相关方法. 数据信息包括评分、信任和评论, 深度学习模型包括 CNN、注意力机制、GNN. 然后在 CNN 中加入注意力机制来处理评论信息, 得到基于评论的用户对项目的偏好向量. 通过 GNN 来处理评分和信任信息, 获得基于信任的用户对项目的偏好向量. 最后, 对于前两部分得到的用户对项目的偏好向量进行加权融合, 获得最终的用户对于项目的偏好向量.

在本文的推荐系统中, 我们假设有 M 个用户组成的集合 $U=\{u_1, u_2, \dots, u_M\}$ 和 N 个项目组成的集合 $I=\{i_1, i_2, \dots, i_N\}$. 评分、信任以及评论数据通常隐含了用户的潜在偏好信息, 是推荐算法采用的主要数据. 用户-项目评分矩阵 $R_{M \times N} = \{r_{u,i}\}$ 表示所有用户对所有项目的评分, 其中 $r_{u,i}$ 表示用户 u 对项目 i 的评分. 用户-用户信任矩阵 $T_{M \times M} = \{t_{u,v}\}$ 表示用户两两之间的信任值, 其中 $t_{u,v}$ 表示用户 u 对用户 v 的信任值, 值为 1 表示信任, 值为 0 表示不信任. 用户-项目评论矩阵 $X_{M \times N} = \{x_{u,i}\}$ 表示所有用户对所有项目的喜好程度值^[29].

3.1 多种数据信息分析

本小节主要介绍融合的 3 种信息: 评分、信任和评论. 因文中要用到的 4 个数据集的信息形式类似, 故这里仅以 Epinions 数据集为例进行说明.

3.1.1 评分信息

评分的分数为 1 到 5 之间的整数, 其中 1 表示“不喜欢”, 5 表示“喜欢”. 在预处理过程中, 为了对模型进行简化, 对评分数量小于 5 的用户和项目进行过滤, 同时在信任数据中也只保留相对应的用户.

在 Epinions 数据集中, 评分信息数据的形式如后文表 1 所示.

每一行都表达了用户对项目的评分值, 比如, 第 1 行表示用户 daleb 对项目 pr-Sony_KV_36FS12_Standard_Televisions 的评分为 4.

3.1.2 信任信息

这里直接利用社交网络的二值信任关系, 即取值只能为 1 或 0, 分别对应“信任”或“非信任”关系^[30,31].

在 Epinions 数据集中, 信任信息数据的形式如表 2 所示.

每一行都表达了源用户对目标用户的信任关系. 比如, 第 1 行表示用户 mattsgirl 信任 simmsgirl. 在此数据集中, 对于信任数据, 均用 1 表示其信任值, 默认用 0 表示其他用户间的信任值.

表 1 Epinions 数据集评分数据形式

用户	项目	评分值
daleb	pr-Sony_KV_36FS12_Standard_Televisions	4
jstroud	auto_Make-2002_Toyota_Highlander	5
pulsev2	huawei-technologies-m835-cell-phone	1
mejensen1	Toshiba_Satellite_M35X_S161_PSA72U2JX 00U_PC_Notebook	2
jspencerg	iRobot_5900_Scooba_Vacuum	1
...

表 2 Epinions 数据集信任数据形式

源用户	目标用户	信任值
cherylswisher	mommy4life	1
mattsgirl	simmsgirl	1
mrpoetryman	taurusmoon	1
Rocket1	jaysonrun	1
rdavisunr	alkaiser	1
...

3.1.3 评论信息

文本信息包括两种, 一种是用户对物品的评论信息, 从这种信息中可以分析用户的购买和评分行为; 另一种是物品的简介信息, 从这种信息中可以分析物品的特征和属性. 为了简单起见, 本文采用第一种文本信息, 即用户对物品的评论信息.

在 Epinions 数据集中, 评论的项目不仅包括书籍, 还包括汽车、电影、电子产品以及软件等. 为了研究简便, 我们首先从数据集中剔除与电子产品无关的信息. 评论信息数据的形式如表 3 所示.

表 3 Epinions 数据集评论数据形式

用户	项目	评论
cruiser36	Hoover_SteamVac_V2_6_Brush_Widepath_F 7426_900_Vacuum	i just bought my machine and the little door where the little brush goes was broke at the hinge
srauhala	Cambridge_Soundworks_Newton_Series_T50 0_Speaker	i first want to say i have been a fan of cambridge soundworks for years now for several reasons
bikeboard	Cambridge_Soundworks_Newton_Series_T50 0_Speaker	i have had these for quite awhile now and i must say for the money
...

每一行都表达了用户对项目的评论情况, 比如, 第 1 行表示用户 cruiser36 对项目 Hoover_SteamVac_V2_6_Brush_Widepath_F7426_900_Vacuum 的评论为“i just bought my machine and the little door where...”.

3.2 深度学习模型

下面对本文模型中用到的 CNN 及 GNN 等进行简单介绍.

CNN 模型普遍用于计算机视觉开发^[32]. 但目前很多学者已开始将 CNN 应用于信息检索^[33]、自然语言处理^[29,34]以及推荐系统领域^[6,15].

CNN 模型强大的卷积操作, 可有效地提取输入文本的隐藏特征, 一定程度上提高了推荐系统的性能. CNN 模型^[15]由两部分组成: 一部分是生成局部特征的卷积层; 另一部分是将卷积层产生的特征进行 pooling(max/min/average) 的池化层, 即选择最大、最小或平均的局部特征作为输入数据的最终表示. 因此 CNN 模型通过过滤函数, 以并行的方式沿着固定大小的滑动窗口处理输入序列, 最终输出序列的隐藏特征矩阵, 再经过池化层输出具有代表性部分的隐藏特征向量. 由于 CNN 模型是并行处理输入序列的, 因此该模型可以隐藏一部分处理时延, 处理效果较好. 卷积层可以有效地提取连续 ws 个相邻词的特征 (ws 表示滑动窗口的大小), 这一操作在处理输入序列时是并行的, 因此 CNN 具有良好的处理效率.

注意力机制的灵感来自对人类视觉的研究. 在人类视觉的研究过程中, 发现人眼处理信息的能力是有限的. 在任何时候, 视网膜上只有少量信息可被处理并用于控制行为, 对任何一个目标的关注都会减少对其他目标的关注. 总结起来, 注意力机制主要有两个方面: 决定需要关注输入的部分; 给重要的部分分配有限的信息处理资源.

一些研究者把这种机制运用到深度神经网络中. 最早注意力机制主要用在聚焦视频区域的任務上. 一种更著名的应用是将注意力机制用于提升机器翻译模型在长文本中的准确性. 在翻译问题中, 由于一些词的翻译和原始句子中一部分有关, 因此注意力机制在翻译某些词时, 通过给原始句子中不同词以不同权重来选择性地关注原始

句子中的一部分. 注意力机制这种强大的性能, 使它很快就流行开来.

近年来, 人们对深度学习方法在图上的扩展越来越感兴趣. 在多方因素的成功推动下, 研究人员借鉴了卷积网络、循环网络和深度自动编码器的思想, 生成了 GNN, 可用于处理图数据.

GNN 是一种连接模型, 其图节点之间通过传递消息来获取图的依赖性. 不同于标准的神经网络, GNN 保留了可表示来自其邻域的具有任意深度信息的状态. 尽管原始的 GNN 很难训练, 但是网络结构、并行计算和优化技术的最新进展让它们有效地学习不成问题.

3.3 本文模型

为了更好地融合评分、信任以及评论信息, 提高推荐精度, 本文提出了结合注意力 CNN 与 GNN 的信息融合推荐模型 ACGIF. 该节对提出的模型 ACGIF 进行了详细描述. 主要分为以下几步: 首先, 简要描述了 ACGIF 模型的整体结构, 并相应说明了涉及的重点概念. 然后, 介绍了 ACGIF 的注意力 CNN 模型, 详细描述了如何通过注意力 CNN 模型来处理输入的评论信息, 从而生成基于评论的用户对于项目的偏好向量. 接着, 介绍了 ACGIF 的 GNN 模型, 详细描述了如何通过 GNN 模型来处理评分和信任信息, 从而生成基于信任的用户对于项目的偏好向量. 最后, 对于前两部分得到的用户对项目的偏好向量进行加权融合, 得到最终的用户对于项目的偏好向量.

3.3.1 ACGIF 模型结构

本文 ACGIF 模型的结构如图 1 所示. 在该图中, 以一个用户 u 的推荐为例来进行说明. 模型图主要包括两部分, 上半部分为注意力 CNN 模型, 用于处理评论信息, 包括用户评论文本和项目评论文本; 下半部分为 GNN 模型, 用于处理信任和评分信息, 其中用户模块用来模拟社交信任信息的传递, 项目模块对评分信息进行处理.

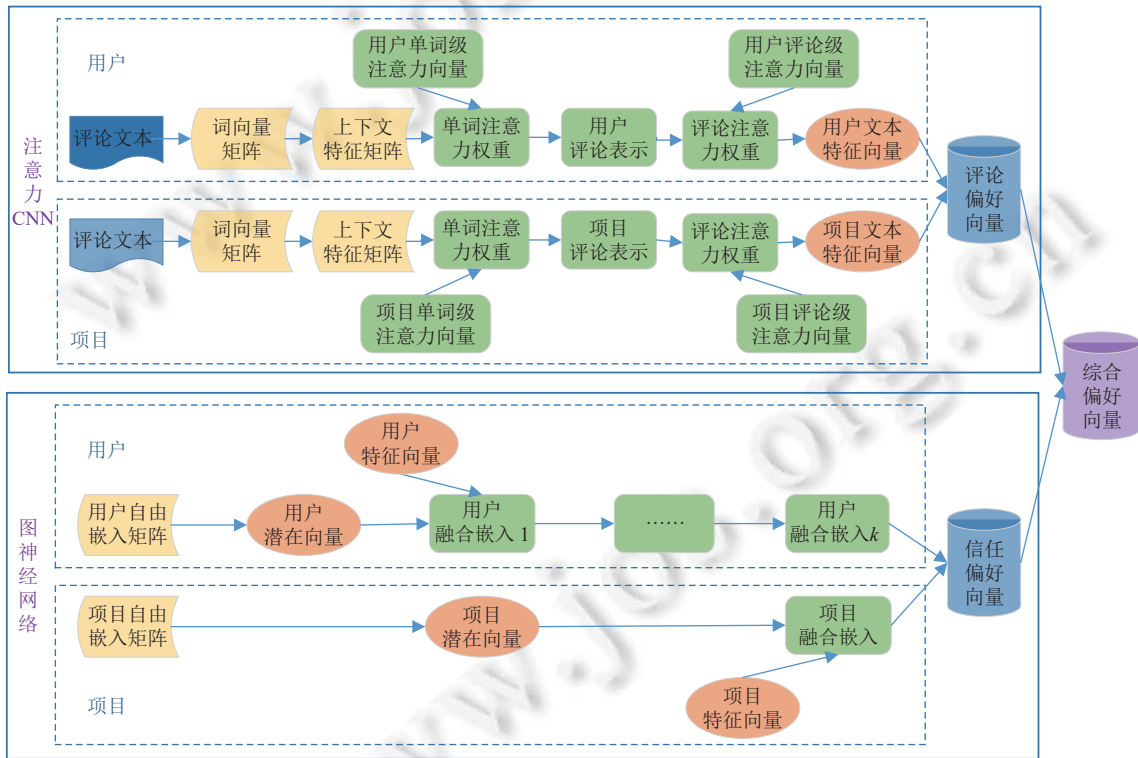


图 1 结合注意力 CNN 与 GNN 的信息融合推荐模型 ACGIF

关于注意力 CNN 模型, 主要描述用户部分, 项目部分类似. 其中 D 表示用户 u 对项目 i 的评论文本, X 表示用户 u 对项目 i 的评论文本转化成的词向量矩阵, F 是卷积之后特征向量组成的特征矩阵, γ 、 β 分别是单词注意力权重和评论注意力权重, $d_{u,i}$ 为评论表示, \bar{p}_u 为用户特征向量, v_w^u 、 v_r^u 分别为个性化单词级注意力向量以及个性化

评论级注意力向量, $X_{u,i}$ 为基于评论的用户对项目的偏好向量. 关于 GNN 模型, P 、 Q 分别表示用户、项目自由嵌入矩阵, p_u 、 q_i 分别表示用户、项目潜在向量, x_u 、 y_i 分别表示用户、项目特征向量, e_u^0 表示用户潜在嵌入, g_i 表示项目嵌入, $T_{u,i}$ 表示基于信任的用户对项目的偏好向量. $R_{u,i}$ 为最终的用户对项目的偏好向量. 涉及的主要符号及其含义如表 4 所示.

表 4 模型参数的符号及含义

符号	含义	符号	含义
U	M 个用户组成的集合	I	N 个产品组成的集合
$R_{M \times N}$ 、 $T_{M \times M}$ 、 $X_{M \times N}$	用户-产品评分矩阵、用户-用户信任矩阵、用户-产品评论矩阵	$r_{u,i}$ 、 $x_{u,i}$	用户 u 对产品 i 的评分及喜好程度值
$t_{u,v}$	用户 u 对用户 v 的信任值	D	评论文本
X	词向量矩阵	d	词向量的维度
l	评论的长度	F	特征矩阵
γ 、 β	单词注意力权重和评论注意力权重	$d_{u,i}$	评论表示
\tilde{p}_u 、 \tilde{q}_i	用户、项目特征向量	v_w^u 、 v_r^u	个性化单词级注意力向量及个性化评论级注意力向量
P 、 Q	用户、项目自由嵌入矩阵	p_u 、 q_i	用户、项目潜在向量
x_u 、 y_i	用户、项目特征向量	e_u^0	用户潜在嵌入
g_i	项目嵌入	$X_{u,i}$	基于评论的用户对项目的偏好向量 (评论偏好向量)
$T_{u,i}$	基于信任的用户对项目的偏好向量 (信任偏好向量)	$R_{u,i}$	最终用户对于项目的偏好向量 (综合偏好向量)

3.3.2 ACGIF 的注意力 CNN 模型

ACGIF 的注意力 CNN 模型的目标是, 在 CNN 中加入注意力机制来处理评论信息, 从评论信息中学习用户和项目的个性化表示. 通过评论编码学习评论表示, 通过用户/项目编码学习评论中用户/项目表示. 加入个性化注意力机制来筛选不同重要性级别的评论. 最终得到用户对项目的偏好向量. 本文的注意力 CNN 模型一共包含 4 层, 分别为: 嵌入层, 卷积层, 池化层以及预测层.

(1) 嵌入层

首先, 嵌入层把一个用户 u 对一个项目 i 的评论文本 D 转化成数字矩阵, 方便下一步卷积层的操作. 由于评论文本是由一串单词组成的, 因此通过连接评论中的词向量来把文本表示为一个矩阵. 其中词向量是用预训练的词嵌入模型 (如: GloVe^[35]) 来进行初始化. 生成的初始化词向量矩阵为 $X = \{x_1, x_2, \dots, x_l\}$, 其中 $X \in R^{d \times l}$, $x_i \in R^d$ 表示词向量, d 为词向量的维度, l 为评论的长度. 若遇到未包含的词, 则赋予 d 维正态分布的随机向量. 其中 x_i 表示输入的文本中第 i 个词的词向量.

(2) 卷积层

接下来, 卷积层用来提取文本特征. 文本信息本质上不同于信号处理或者计算机视觉. 因此, 我们使用文献 [24,36] 中提到的卷积结构来对评论文本进行分析.

将评论信息的词嵌入矩阵 X 传入到卷积层, 用来提取输入文本的上下文特征. 假设输入文本中第 i 个词的上下文特征表示为 $f_i^j \in R$, 则该特征值是通过卷积层中滑动窗口内的第 j 个共享权重参数 $W_f^j \in R^{d \times ws}$ 计算获得的, 其中 ws 表示滑动窗口的大小, 该值决定了 CNN 模型在提取第 i 个词的特征时, 其上下文中所包含词的数量. 卷积层的工作方式如公式 (1) 所示:

$$f_i^j = h(W_f^j * X_{(i,i+ws-1)}) + b_f^j \tag{1}$$

其中, $*$ 表示在卷积层计算中的卷积操作, 即滑动窗口内的第 j 个过滤函数对其在窗口内的 ws 个词向量进行非线性并行处理; $b_f^j \in R$ 为偏置向量; h 函数表示一个非线性激活函数. 非线性激活函数有 Sigmoid 函数, tanh 函数以及 ReLU 函数, 我们使用 ReLU 来避免梯度消失的问题, 但却造成了优化收敛慢, 且可能产生一个效果不好的局部最小值^[37,38].

通过卷积层操作, 生成了输入文本的上下文特征向量 $f^j \in \mathbb{R}^{s-ws+1}$, $f^j = \{f_1^j, f_2^j, \dots, f_{s-ws+1}^j\}$ 经过卷积层的 W_f 的加权计算, 最终生成一个特征矩阵 $F \in \mathbb{R}^{n_f \times (s-ws+1)}$, 其中, n_f 表示卷积层中共享权重参数的数量, 也就是滑动窗口内过滤函数的数量 (即, $W_f^j, j=1, 2, \dots, n_f$).

尽管经过卷积层生成了输入文本的特征矩阵 F , 但其不能作为文本的最终表示. 主要有两方面原因^[6]. 一方面是由于在卷积层中的每一个 W_f^j 权重都将对文本进行处理, 从而生成了上下文特征向量 f^j , 即对文本特征的提取是重复的, 而其中大多数上下文特征对模型性能的提高不能起到很大的作用. 另一方面是由于文本长度不固定, 使得 CNN 模型生成的上下文特征向量的长度也不固定, 这将对输入文本的隐藏特征的后续应用造成困难. 因此需要利用池化操作对卷积层的输出做进一步的处理, 从而生成具有代表性的文本特征向量.

(3) 池化层

然后, 在池化层分别引入单词水平的注意力机制和评论水平的注意力机制. 这主要是因为并不是所有评论文本中的单词都有同等的重要性, 从单词和评论两方面来运用注意力机制, 这样既考虑了局部又兼顾了整体, 将两者的结果进行综合, 从而提升推荐结果的准确性.

对于单词级的注意力机制, 首先为用户生成能够体现个性化的注意力向量 v_w^u . 因为每个用户或项目都具有唯一的 id 特征, 所以我们先通过基于 id 的嵌入层将所有用户和项目表示为低维向量. 给定用户 u 的 id 嵌入, 利用多层感知器 (MLP) 生成用户 u 的个性化注意力向量, 如公式 (2) 所示:

$$v_w^u = \text{ReLU}(W_1 u_{id} + b_1) \quad (2)$$

其中, W_1 是 MLP 的权重矩阵, b_1 是偏置项, u_{id} 为用户 u 的嵌入 ID. 然后为用户生成特定的注意力向量, 过程如公式 (3)、公式 (4) 所示:

$$z_k = v_w^u A_w f_k \quad (3)$$

$$\gamma_k = \frac{\exp(z_k)}{\sum_{j=1}^T \exp(z_j)}, \quad \gamma_k \in (0, 1) \quad (4)$$

其中, A_w 为注意力和谐矩阵, v_w^u 为用户 u 特有的注意力向量, f_k 为第 k 个词的表示, γ_i 为评论中第 i 个单词的注意力权重. 类似地, 项目 i 在项目网络中有唯一的注意力向量表示为 v_w^i . 通过对所有单词的特征向量进行聚合得到用户 u 的第 i 次评论表示如公式 (5) 所示:

$$d_{u,i} = \sum_{j=1}^T \gamma_j f_j \quad (5)$$

对于评论级的注意力机制, 首先为用户生成能够体现个性化的注意力向量. 基于用户 id 的嵌入 u_{id} , 利用另一个 MLP 层为用户 u 生成个性化的评论级注意力向量, 如公式 (6) 所示:

$$v_r^u = \text{ReLU}(W_2 u_{id} + b_2) \quad (6)$$

其中, ReLU 为激活函数, W_2 为权值矩阵, b_2 为偏置项. 然后为用户生成特定的注意力向量. 给定评论集合 $d_u = \{d_{u,1}, d_{u,2}, \dots, d_{u,N}\}$, 应用注意力机制突出重要的评论, 计算第 i 个用户的第 j 个评论的权重 β_j , 如公式 (7)、公式 (8) 所示:

$$h_j = v_r^u A_r d_{u,j} \quad (7)$$

$$\beta_j = \frac{\exp(h_j)}{\sum_{k=1}^N \exp(h_k)}, \quad \beta_j \in (0, 1) \quad (8)$$

其中, A_r 为注意力矩阵, v_r^u 是用户 u 的查询向量, 每个用户有唯一的注意力向量来寻找有效评论. 通过聚合所有的评论根据权重获得用户 u 的文本特征为 \tilde{p}_u , 如公式 (9) 所示:

$$\tilde{p}_u = \sum_{j=1}^N \beta_j d_{u,j} \quad (9)$$

同样, 可以得到项目 i 的特征表示为 \tilde{q}_i .

(4) 预测层

最后, 在预测层, 建模用户 u 对项目 i 的预测评分, 如公式 (10) 所示:

$$X_{u,i} = \tilde{p}_u^T \tilde{q}_i \quad (10)$$

预测评分为用户特征与项目特征的内积形式.

最终, 将 CNN 对评论文本的处理过程可以表示为 cnn 函数, 因此用户 u 对项目 i 的预测评分的计算可以表示成公式 (11).

$$X_{u,i} = cnn(D) \quad (11)$$

其中, D 表示用户 u 对项目 i 的评论文本, $X_{u,i}$ 表示用户 u 对项目 i 的预测评分. 每个用户对每个项目的预测评分值可组合成所有用户对所有项目的预测评分值矩阵.

实现注意力 CNN 模型的完整过程如算法 1 所示.

算法 1. 注意力 CNN 模型的构造.

输入: M 个用户组成的集合 $U = \{u_1, u_2, \dots, u_M\}$, N 个项目组成的集合 $I = \{i_1, i_2, \dots, i_N\}$, 用户 u , 项目 i , 评论文本 D ;
输出: 基于评论的用户对项目的偏好向量 $X_{u,i}$.

/* 嵌入层 */

1. **FOR** 从 u_1 到 u_M

2. **FOR** 从 i_1 到 i_N

3. 词向量矩阵 $X =$ 词嵌入模型 (D)

4. **END FOR**

5. **END FOR**

/* 卷积层 */

6. **FOR** 从 u_1 到 u_M

7. **FOR** 从 i_1 到 i_N

8. 特征矩阵 $F =$ 卷积模型 (X) // 见公式 (1)

9. **END FOR**

10. **END FOR**

/* 池化层 */

11. **FOR** 从 u_1 到 u_M

12. **FOR** 从 i_1 到 i_N

13. 计算个性化单词级注意力向量 v_w^u // 见公式 (2)

14. 计算单词注意力权重 γ // 见公式 (3)、公式 (4)

15. 计算评论表示 $d_{u,i}$ // 见公式 (5)

16. 计算个性化评论级注意力向量 v_r^u // 见公式 (6)

17. 计算评论注意力权重 β // 见公式 (7)、公式 (8)

18. 计算用户、项目特征向量 \tilde{p}_u 、 \tilde{q}_i // 见公式 (9)

19. **END FOR**

20. **END FOR**

/* 预测层 */

21. **FOR** 从 u_1 到 u_M

22. **FOR** 从 i_1 到 i_N

23. 计算基于评论的用户对项目的偏好向量 $X_{u,i}$ // 见公式 (10)

24. END FOR

25. END FOR

26. RETURN $X_{u,i}$

3.3.3 ACGIF 的 GNN 模型

GNN 模型的总体结构如图 1 下半部分所示. 初始输入为用户-项目对, 输出为用户 u 对项目 i 的喜好概率. GNN 模型包含 4 部分, 分别为: 嵌入层、融合层、图传递层以及预测层. 这里选择 GNN 来处理信任信息, 主要是由于 GNN 保留了来自其邻域的具有任意深度信息的状态, 这个特点与信任信息的传递非常契合, 可准确地模拟社交动态变化过程.

(1) 嵌入层

设 $P \in R^{D \times M}$ 、 $Q \in R^{D \times N}$ 表示用户和项目的自由嵌入. 这些自由嵌入可捕获用户和项目的协同潜在表示. 给定用户 u 和项目 i 的 one-hot 表示, 嵌入层执行索引操作, 从用户自由嵌入矩阵 P 和项目自由嵌入矩阵 Q 中输出自由用户潜向量 p_u 和自由项目潜向量 q_i .

(2) 融合层

对于每个用户 u , 融合层以 p_u 及其相关特征向量 x_u 作为输入, 输出一个用户融合嵌入 e_u^0 , 该用户融合嵌入 e_u^0 从不同类型的输入数据中获取用户的初始兴趣. 本文将融合层建模为单层全连接神经网络, 表示成公式 (12):

$$e_u^0 = g(W^0 \times [x_u, p_u]) \quad (12)$$

其中, W^0 是一个变换矩阵, $g(x)$ 是一个非线性函数. 为了便于标记, 省略了全连接神经网络中的偏置项.

同样, 对于每一个项目 i , 融合层建模项目嵌入 v_i 作为自由潜向量 q_i 与特征向量 y_i 之间的非线性变换为, 表示成公式 (13):

$$g_i = \sigma(F \times [q_i, y_i]) \quad (13)$$

(3) 图传递层

对于图传递层, 只需要考虑用户部分. 图传递层建模了用户潜在偏好在社交网络中扩散的动态变化. 该部分为多层结构, 每层输入前一层的用户嵌入, 输出社交扩散过程结束后的用户的更新嵌入. 递归循环, 直到社交递归过程达到稳定.

对于每个用户 u , e_u^k 表示其第 k 层的潜在嵌入. 通过将第 k 层的输出输入到 $k+1$ 层, $k+1$ 层的影响扩散操作将每个用户 u 的潜在嵌入更新为 e_u^{k+1} . 更新后的嵌入 e_u^{k+1} 由两部分组成, 分别为: k 层的潜在嵌入 e_u^k 以及信任用户的影响扩散嵌入集合 $e_{S_u}^{k+1}$, 表示成公式 (14):

$$e_u^{k+1} = s^{k+1}(W^k \times [e_{S_u}^{k+1}, e_u^k]) \quad (14)$$

其中, $s^k(x)$ 是非线性转变函数, $e_{S_u}^{k+1}$ 表示成公式 (15):

$$e_{S_u}^{k+1} = Pool(e_b^k | b \in S_u) \quad (15)$$

其中, 池函数可以被理解为一个平均池, 对所有可信用户在第 k 层的潜在嵌入执行平均操作.

(4) 预测层

在这一层, 用户 u 对项目 i 的预测评分可以表示成公式 (16):

$$T_{u,i} = g_i^T e_u^k \quad (16)$$

预测评分为用户嵌入与项目嵌入的内积形式.

实现 GNN 模型的完整过程如算法 2 所示.

算法 2. GNN 模型的构造.

输入: 用户-项目评分矩阵 R , 用户-用户信任矩阵 T , 用户、项目自由嵌入矩阵 P 、 Q , 用户、项目特征向量 x_u 、 y_i ;
输入: 基于信任的用户对项目的偏好向量 $T_{u,i}$.

```

/* 嵌入层 */
1. 计算用户、项目潜在向量  $p_u$ 、 $q_i$ 
/* 融合层 */
2. 计算用户潜在嵌入  $e_u^0$  //见公式 (12)
3. 计算项目嵌入  $g_i$  //见公式 (13)
/* 图传递层 */
4. 计算用户潜在嵌入  $e_u^1 \cdots e_u^k$  //见公式 (14)
/* 预测层 */
5. 计算基于信任的用户对项目的偏好向量  $T_{u,i}$  //见公式 (16)
6. RETURN  $T_{u,i}$ 

```

3.3.4 融合模型

通过合并方式对用户 u 进行相应的推荐. 常见的合并方式有串联、平均以及加权^[20]. 本文采用加权的方式, 主要是由于这种合并方式可以对评论和信任信息设置权重, 通过调节权重大小来寻找两种信息的最佳组合比例, 从而获得更好的推荐效果.

对于注意力 CNN 得到的基于评论的用户对项目的偏好向量 $X_{u,i}$ (简称评论偏好向量) 以及 GNN 得到的基于信任的用户对项目的偏好向量 $T_{u,i}$ (简称信任偏好向量) 进行加权融合, 得到最终的用户对于项目的偏好向量 $R_{u,i}$ (简称综合偏好向量), 可表示为公式 (17):

$$R_{u,i} = \alpha X_{u,i} + (1 - \alpha) T_{u,i} \quad (17)$$

其中, α 是平衡 $X_{u,i}$ 、 $T_{u,i}$ 之间的影响的超参数.

4 实验设计与分析

4.1 实验数据集及环境

为了验证本文方法的有效性, 并便于与其他方法作对比, 使用了 4 个流行的公开数据集, 分别是: Epinions (<http://www.trustlet.org/epinions.html>)、Yelp 2014 (<https://www.yelp.com/dataset/challenge>)、Flickr (<http://www.flickr.com>) 以及 MovieLens 10M (<http://grouplens.org/datasets/movielens/>). 前两种数据集都包括用户的评分数据、信任数据以及评论数据.

Epinions 是著名的大众消费点评网站, 主要市场在美国和欧洲^[12]. 在这个网站上, 不仅有用户对商品的评分和评论, 还有用户与信任好友建立的社交关系网络. Yelp 是包含 2014 年发布的餐厅评论信息的大规模数据集. 该数据集为 JSON 格式, 有用户和商家的信息, 涉及他们的 ID、用户对商家的评论及评分、信任关系等. 评论和评分信息被用来分析用户和商家的偏好及特征^[39]. 此数据集的最新版本为 Yelp 2019, 这里为更好地与对比模型 NRPA 进行比较, 选取与 NRPA 模型相同的数据集版本 Yelp 2014. Flickr 是一个很受欢迎的网站, 是用户分享图片和视频的社交网络. 用户关注其他用户, 并将他们对图片的偏好分享给他们的社交粉丝. 在此数据集中, 每一个节点都是 Flickr 中的用户, 每一条边都是用户之间的好友关系. 另外, 每一个节点都有标签, 用于标识用户的兴趣小组. MovieLens 10M 数据集主要包含评分信息, 没有评论和信任信息.

在本文实验中, 需要对原始数据进行初步的处理. 首先, 过滤掉无关项, 只保留用户、项目、评分、信任值以及评论信息. 然后, 将用户和项目名称转换为对应的数字, 方便后续处理. 最后, 采用与 Wang 等人^[26]类似的预处理方法, 即对评分数量小于 5 的用户和项目进行过滤, 并在其信任数据中也仅对相应的用户进行保留. 这样处理主要是由于现有的数据集都非常稀疏, 为了防止模型无法训练, 因此剔除信息较少的用户和项目, 有利于进行更加准确的推荐.

经过数据预处理后, 剩下的数据可进行模型学习. 最终版本的 Epinions 数据集包含了 21 358 个用户, 274 552 个项目, 有 898 766 组评分评论信息和 286 265 个用户之间的社交关系 (本文表示为信任关系). Yelp 数据集包含了

45 113 个用户和 81 254 个项目, 有 1 322 135 组评分评论信息和 352 636 个用户之间的社交关系. Flickr 数据集包含了 7925 个用户和 78 561 个项目, 有 285 449 组评分信息和 162 328 个用户之间的社交关系. MovieLens 10M 数据集包含了 73 256 个用户和 12 315 个项目, 有 9 525 411 组评分评论信息.

对于处理后的 4 种数据集, 各项统计信息如表 5 所示.

表 5 数据集的各项统计信息

特征	数据集			
	Epinions	Yelp	Flickr	MovieLens
用户数量	21 358	45 113	7 925	73 256
项目数量	274 552	81 254	78 561	12 315
评分记录数	898 766	1 322 135	285 449	9 525 411
信任记录数	286 265	352 636	162 328	—
用户平均评分数量	42	29	36	130
项目平均评分数量	3	16	4	773
用户平均信任数量	13	8	20	—
评分稀疏度 (%)	99.985	99.964	99.954	98.944
信任稀疏度 (%)	99.937	99.983	99.974	—

从表 5 中可以看到, 对于用户数量, 数据集 Yelp 中的是 Epinions 中的近 2 倍, 而对于项目数量, 数据集 Epinions 中的是 Yelp 中的约 3.5 倍, 这可能导致模型在数据集 Yelp 中的推荐效果要比 Epinions 中的更优.

本文实验环境为: Windows10 操作系统, 32 GB 内存, CPU 为 AMD R7 3700X 3.6 GHz, GPU 为 Nvidia GeForce RTX 2080Ti, 采用 Python 语言开发.

4.2 文本预处理及相关设置

本文使用 Python 语言及 Keras 库实现 ACGIF 模型. 为了训练 CNN 的权值, 使用基于 RMSprop 的 mini-batch, 每个 mini-batch 包含 128 个训练项.

与文献 [17] 和文献 [40] 类似, 对数据集中的评论文本按照如下方式进行预处理.

- (1) 设置每条评论文本的最大长度为 300;
- (2) 去除停用词;
- (3) 计算每个单词的 TF-IDF 值;
- (4) 去除特定语料库中文本频率高于 0.5 的停用词;
- (5) 选择前 8 000 个不同的单词作为一个单词表;
- (6) 为了使 ACGIF 能处理所有用户和项目, 所有数据集的训练集中都至少包含每个用户和项目的一个评分.

对于 CNN 结构, 使用以下设置.

- (1) 在卷积层中, 使用不同的窗口大小 (3、4、5) 作为共享权值, 以考虑周围单词的不同长度, 每个窗口大小使用 100 个共享权值;
- (2) 使用 dropout 将与 CNN 的权值相关的 L2 正则化器进行替换, 并把 dropout rate 设置为 0.2, 以防止 CNN 过拟合.

本文将数据集按一定比例分为训练集 (80%)、验证集 (10%) 和测试集 (10%). 训练集主要用于拟合模型数据, 学习推荐模型中的参数; 验证集主要用于调整模型的超参数, 对模型进行初步评估; 测试集主要用于验证模型的推荐效果. 为保证结果的可靠性, 重复进行 5 次数据切分过程.

4.3 评价指标

本文算法的任务之一是预测用户对产品的评分, 通常希望算法越精确越好. 为了评估本文算法的性能, 选择两种流行的精确度指标^[41], 即, 平均绝对误差 (mean absolute error, MAE) 和均方根误差 (root mean squared error, RMSE). MAE 和 RMSE 适合于预测的场景, 反映了算法预测评分的准确度. 在只考虑准确度的情况下, 它们的值越

小, 算法的性能越好.

平均绝对误差 MAE 的计算公式为公式 (18):

$$MAE = \frac{1}{N} \sum_{(u,i) \in I} |\hat{R}_{u,i} - R_{u,i}| \quad (18)$$

其中, N 表示预测评分的数量, I 表示所有测试集的数据, $\hat{R}_{u,i}$ 表示预测评分, $R_{u,i}$ 表示真实评分.

相应地, 均方根误差 $RMSE$ 的计算公式为公式 (19):

$$RMSE = \sqrt{\frac{1}{N} \sum_{(u,i) \in I} (\hat{R}_{u,i} - R_{u,i})^2} \quad (19)$$

通常, 这些评估指标是彼此一致的, 即, 如果一个模型在一个指标上比另一个模型表现得更好, 那么它也更有可能在另一个指标上产生更好效果.

4.4 模型对比

为了验证文中提出的 ACGIF 模型的推荐效果, 本文选取下面几种相关的推荐模型作为对比.

(1) 贝叶斯个性化排序 (BPR)^[42]: 该模型是一个基于隐式反馈的推荐模型, 它是一个简单且使用广泛地用于推荐的排序算法. 通过学习每个用户评分和未评分项目的 pairwise 关系来实现, 而不是直接学习预测评分.

(2) 因子分解机模型 (FM)^[43]: 该模型是支持向量机和分解模型的结合, 适用于推荐系统稀疏性问题的解决, 同时复杂度是线性的, 同时相对于其他模型具有更好的普适性.

(3) 融合评分数值和评论文本的推荐模型 (DTMF)^[8]: 该模型同时将用户评论文本和商品评论文本的潜在主题与矩阵分解的潜在因子进行映射, 综合考虑了评分和评论两种数据类型.

(4) 融合多源异构信息的推荐算法 (MSRA)^[9]: 该模型致力于整合多源异构数据来实现数据的价值最大化, 通过为不同的数据设计不同的建模方式, 融合多关系数据和视觉信息来缓解数据稀疏问题. 主要考虑了评分和信任两种数据信息.

(5) 分层个性化注意力推荐模型 (NRPA)^[19]: 该模型从评论文本中学习用户和项目的个性化表示. 通过注意力模型的加入, 可以重点学习有效评论, 提高效率.

(6) 社交影响扩散模型 (DiffNet)^[24]: 该模型建模社交推荐中的递归动态社交扩散过程. 主要设计了一个 layer-wise 影响扩散部分来建模用户的潜在偏好如何被他信任的用户递归地影响.

(7) 基于神经影响和兴趣扩散网络的社交推荐模型 (DiffNet++)^[25]: 该模型同时考虑用户-用户社交网络以及用户-项目兴趣网络, 通过设计影响和兴趣扩散层来迭代更新用户和项目嵌入.

对于这几个对比模型, 本文全部考虑深度模型. 除此之外, 这几种模型分别考虑了不同的信息来源, BPR 和 FM 只考虑评分, MSRA 和 DiffNet 考虑评分和信任, DTMF 和 NRPA 考虑评分和评论, DiffNet++考虑了评分、信任和评论. 这有利于从多方面与本文提出的模型 ACGIF 展开对比分析, 从而更充分地说明本文信息融合的有效性. 这些模型比较如表 6 所示. 其中打对勾处表示该模型用到了该信息或方法.

表 6 各模型特征对比

模型	评分	信任	评论	CNN	注意力	GNN	模型	评分	信任	评论	CNN	注意力	GNN
BPR	√	—	—	—	—	—	FM	√	—	—	—	—	—
DTMF	√	—	√	—	—	—	MSRA	√	√	—	—	—	—
NRPA	√	—	√	√	√	—	DiffNet	√	√	—	—	—	√
DiffNet++	√	√	√	—	√	√	ACGIF	√	√	√	√	√	√

4.5 实验结果分析

4.5.1 信息融合对推荐效果的影响

在第 4.4 节中, 将本文的 ACGIF 模型和其他几个流行的模型进行了对比, 这几种模型均采用了深度学习技术,

主要区别在于信息融合的程度不同.

表 7 列出了这几个模型在本文的 4 个数据集、两种评价指标下的最佳结果. 本文模型和最佳效果模型的评价指标值采用加粗显示, 最后一列计算出 ACGIF 相对于某一最佳模型 (见粗体数据表示) 的改进情况. 由于 MovieLens 数据集只有评分数据, 因此只考虑在 BPR 模型和 FM 模型上的实验结果. 类似地, Flickr 数据集只有评分和信任数据, 因此不考虑 DTMF 模型、NRPA 模型及 DiffNet++模型上的实验结果.

表 7 在 4 个数据集上的各模型性能对比

数据集	评价指标	模型名称								改进情况 (%)
		BPR	FM	DTMF	MSRA	DiffNet	NRPA	DiffNet++	ACGIF	
Epinions	MAE	0.9134	0.9062	0.8732	0.8511	0.8216	0.8353	0.8122	0.8086	0.44
	RMSE	1.1247	1.1183	1.0826	1.0703	1.0581	1.0633	1.0438	1.0420	0.17
Yelp	MAE	0.8375	0.8257	0.7913	0.7829	0.7632	0.7549	0.7408	0.7382	0.35
	RMSE	1.0891	1.0674	1.0302	1.0142	1.0081	0.9786	0.9656	0.9633	0.24
Flickr	MAE	1.0261	0.9533	—	0.8941	0.8535	—	—	0.8369	1.94
	RMSE	1.1294	1.1235	—	1.1063	1.0924	—	—	1.0816	0.99
MovieLens	MAE	0.6825	0.6729	—	—	—	—	—	0.6522	1.97
	RMSE	0.8354	0.8153	—	—	—	—	—	0.7916	2.19

图 2 展示了这几个模型在 4 个数据集、两种评价指标下的实验结果对比曲线. 图 2(a)–图 2(c) 子图依次表示在 Epinions、Yelp、Flickr 和 MovieLens 数据集上的结果, 横坐标选取不同模型, 纵坐标为评价指标值. 每个图中均有两条曲线, 分别表示 MAE 和 RMSE 两种评价指标值.

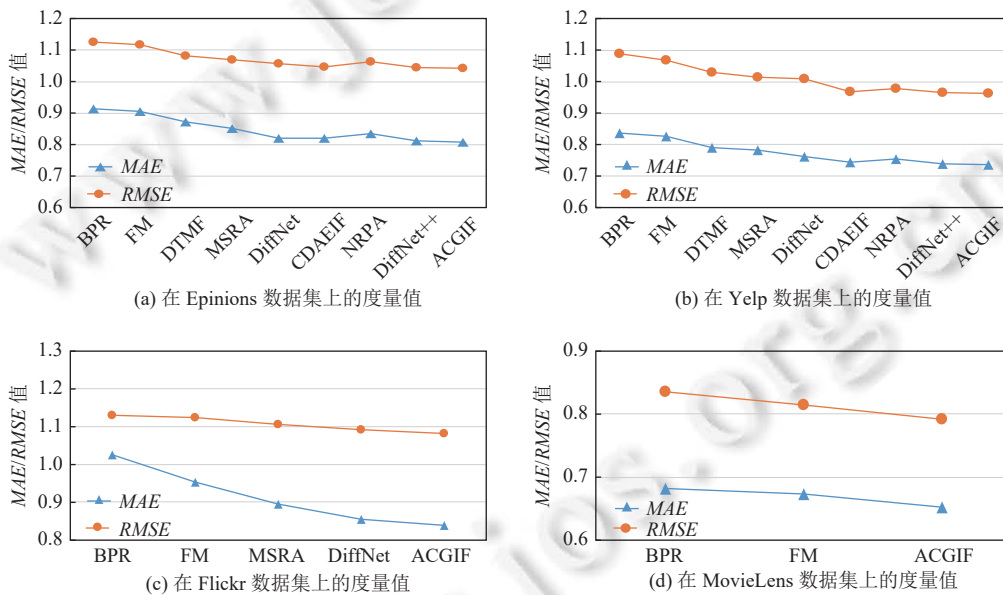


图 2 在 4 个数据集上的模型性能对比

通过表 7 以及图 2 中的 4 个折线图对比可以发现, 融合两种信息的模型 DTMF、MSRA、DiffNet 以及 NRPA 明显优于只融合了评分信息的模型 BPR 和 FM, 这表明信息融合技术在改善推荐性能方面有巨大潜力. 尤其对于本文融合了 3 种信息的 ACGIF 模型来说, 在 4 个数据集以及两种评价指标上, 性能均优于其他几个模型, 这主要是由于 ACGIF 融合了较多种类的信息, 从而对用户偏好有更为充分的了解.

模型 DiffNet 性能优于模型 MSRA, 这是由于前者加入了 GNN, 可以更为有效地学习用户之间的信任关系. 模型 NRPA 性能优于模型 DTMF, 这是因为 NRPA 中加入了注意力机制, 能有效筛选重要评论文本, 提高推荐效率.

模型 DiffNet++在对比模型中性能最优, 主要由于其融合了评分、信任以及社交评论文本信息, 同时运用了 GNN 以及注意力机制。

通过观察表 7 中的实验结果可发现, 本文模型 ACGIF 与对比模型中性能最佳的 DiffNet++模型的实验效果相当, 仅有少许提升。这主要是由于两个模型均考虑了评分、信任和评论 3 种数据信息, 且运用了 GNN 模型。两者不同之处是 DiffNet++考虑社交评论文本, 并用 GNN 来处理该文本和信任数据; 而本文模型考虑用户对项目的评论文本, 并通过注意力 CNN 处理评论文本来提取有效信息, 通过 GNN 来处理信任信息。本文模型的优势主要体现在两个方面。一方面, 考虑用户对项目的评论文本, 而不是社交评论文本, 社交评论文本和信任数据有一定的重叠性, 而采用用户对项目的评论文本更有利于体现数据信息的多元性。另一方面, 考虑注意力 CNN 处理评论文本, 而不是与信任数据采取相同的模型, 这样能对不同的数据信息采取更合适的模型来处理, 从而达到更佳的推荐效果。

观察图 2(a)、图 2(b) 可以发现, 在 Epinions 数据集上, 对比模型中 DiffNet++模型性能最优, DiffNet 模型次之; 在 Yelp 数据集上, 对比模型中 DiffNet++模型性能最优, NRPA 模型次之。这主要是由于 Epinions 数据集相对于 Yelp 数据集来说, 用户之间的人均信任关系数据更多, 且 DiffNet 模型重点考虑信任信息, 因此在两个数据集上的表现会有所差异。由图 2 还可以看到, 对于同一数据集上的同一模型来说, 8 个模型评价指标的整体趋势基本一致。如, 对于 Epinions 数据集来说, ACGIF 的 MAE 小于 NRPA, 往往相应的 RMSE 值也是前者小于后者。

4.5.2 融合组件对推荐效果的影响

评论、评分和信任 3 种信息在不同程度上对推荐效果均有一定的影响, 因此对比 3 种融合组件以及它们的组合对推荐结果的影响程度, 有利于更好地改进推荐模型。

本节从两个角度对融合组件的效果进行对比。第 1 个角度是对于本文的模型 ACGIF, 分别考虑评分、评分+信任、评分+评论以及评分+信任+评论 4 种情况, 简称为 Rating、Rating+Trust、Rating+Review、ACGIF, 对比 4 种情况下的评价指标。第 2 个角度是本文模型只考虑部分数据信息的情况下, 与考虑相同数据信息的其他对比模型做比较。从横向和纵向两个角度更加充分地说明本文方法的有效性。

图 3 展示了本文模型的 4 种融合组件在两个数据集 (Epinions 和 Yelp)、2 种评价指标 (MAE 和 RMSE) 下的实验结果对比柱状图。横坐标选取不同融合组件, 纵坐标为评价指标值。每个图中均有两种底纹的柱状图, 分别表示 MAE 和 RMSE 两种评价指标值。

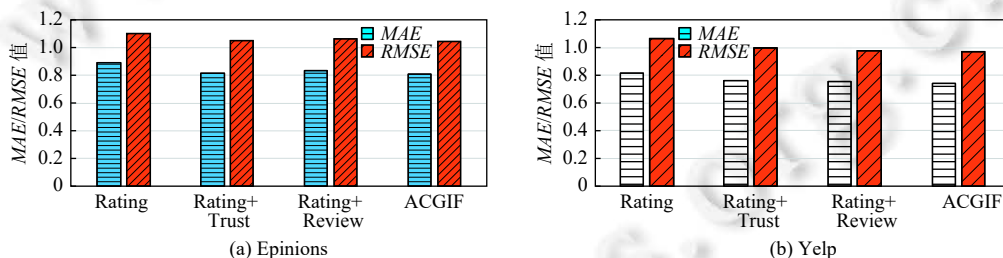


图 3 本文模型融合组件的性能对比

由图 3 可以看到, 在两个数据集上, 融合两种信息的效果优于只融合评分数据的, 融合 3 种信息的优于融合两种信息的。这说明在评分数据的基础上, 信任和评论信息对于改善推荐效果都有一定的价值。在 Epinions 数据集上, Rating+Trust 的效果优于 Rating+Review; 而在 Yelp 数据集上, 正好相反。这主要是由于前文提到的, Epinions 数据集相对于 Yelp 数据集来说, 用户之间的人均信任关系数据更多。

图 4 展示了本文模型的 3 种融合组件 (Rating、Rating+Trust、Rating+Review) 与只考虑相应信息的对比模型的柱状图对比情况。同样也是对于在 2 个数据集 (Epinions 和 Yelp)、2 种评价指标 (MAE 和 RMSE) 下的实验结果进行对比。横坐标选取不同融合组件或者对比模型, 纵坐标为评价指标值。每个图中均有 2 种底纹的柱状图, 分别表示 MAE 和 RMSE 两种评价指标值。图 4(a)–图 4(c) 依次表示只考虑评分、考虑评分和信任信息、考虑评分和评论 3 种情况下的结果。

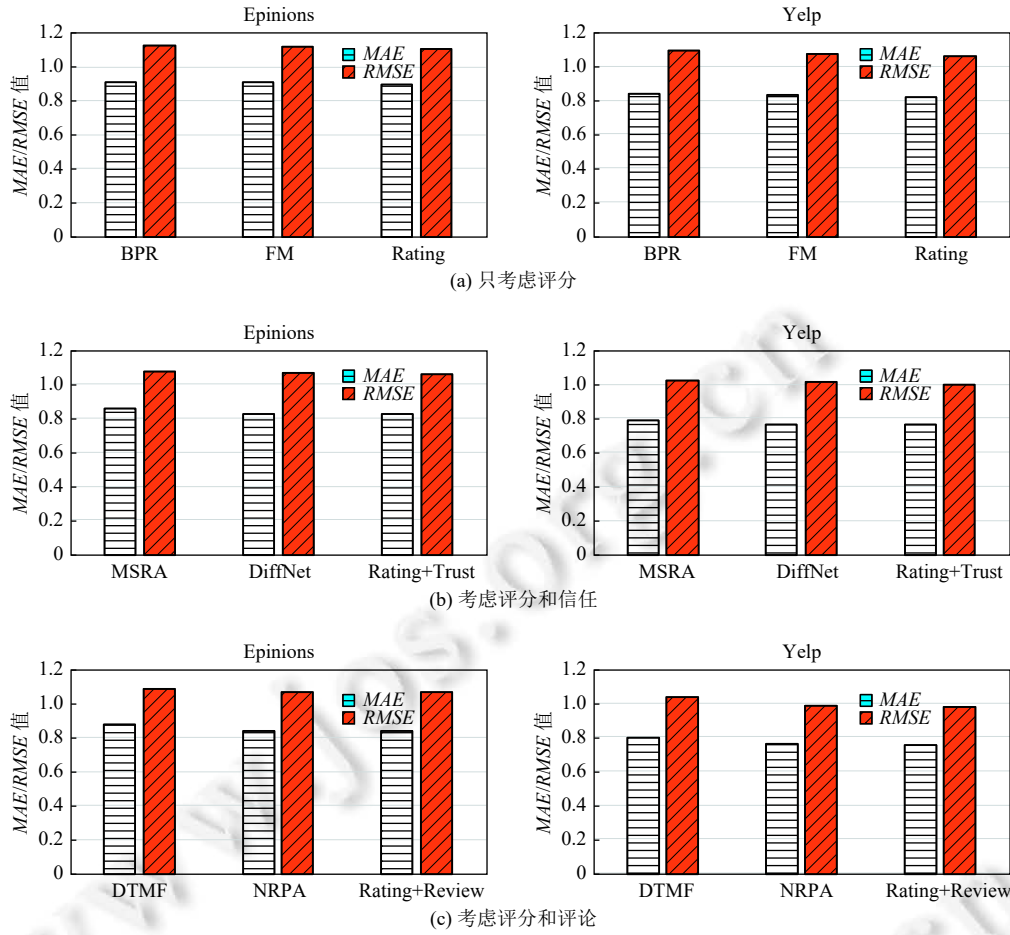


图4 本文融合组件与相应对比模型的性能比较

由图4可以看出,本文模型在只考虑评分、考虑评分和信任、考虑评分和评论3种情况下,性能均优于考虑相同数据信息的对比模型.这进一步说明了本文无论是处理评论信息的注意力CNN模型,还是处理信任信息的GNN模型,均有一定的优势.


4.5.3 模型参数对推荐效果的影响

本文通过参数 α 平衡评论文本和信任数据对结果的影响.对于最终权重参数的选择,采用动态调节的方式, α 在0至1的范围内动态变化,观察在Epinions和Yelp两个数据集上RMSE的大小变化情况,RMSE越小则该处的参数值大小越好.我们对同一个数据集上的不同用户选择相同的权重,这主要是由于最佳权重参数是通过综合考虑数据集上的所有用户得出的结果.

α 越大,表明评论文本对于用户偏好的建模影响越大; $1-\alpha$ 表示信任数据对于用户偏好的影响.假设 $\alpha=1$,则只考虑评论文本和评分数据对于结果的影响,如DTMF和NRPA模型;若 $\alpha=0$,则考虑评分和信任数据对于结果的影响,如MSRA和DiffNet模型.

为了探究在Epinions和Yelp数据集上 α 的变化对推荐效果的影响,绘制了两个曲线图,见图5.

图5中展示了参数 α 在两个数据集(Epinions和Yelp)上对于结果的影响,评价指标选取RMSE.可以看到,当 $\alpha=0.6$ 时,Epinions数据集取得最佳结果;当 $\alpha=0.7$ 时,Yelp数据集取得最佳结果.这表明Epinions中的用户相比于Yelp来说,更加倾向于接受朋友的建议.对于两个数据集, α 的取值均大于0.5,可知评论数据对于结果的影响最大,信任数据次之.这主要是由于评论文本中包含更多与用户偏好相关的信息.

图5 参数 α 对推荐效果的影响(RMSE)

4.6 实验讨论

4.6.1 复杂度分析

就复杂度方面来讲,这里主要考虑本文模型的时间复杂度.分别考虑注意力 CNN 部分和 GNN 部分.对于注意力 CNN 部分,时间花销为 $O(MNn_d)$,其中 M 是用户数, N 是项目数, n_d 是评论文本的数目.对于 GNN 部分,主要的额外时间花销在图传递层.动态扩散过程的花销为 $O(MKL)$,其中 M 是用户数, K 表示动态扩散的深度, L 表示每个用户的人均社交邻居数.两部分总的时间花销为 $O(MNn_d+MKL)$,且额外的时间花销是可接受的.

对比模型 DiffNet 相对于本文模型,只考虑了 GNN 和信任信息,时间复杂度为 $O(MKL)$,小于本文模型的时间复杂度.对于本文提出的 ACGIF 模型来说,虽然引入 CNN 来处理评论信息可能会产生额外的开销,但由于 CNN 模型的并行性,在处理文本信息时的时间开销较小.目前对于大多数的 GPU/CPU 来说,计算任务不算大^[15].

4.6.2 实验小结

本文融合了评论、评分以及信任 3 种多源异构数据,充分利用了不同数据的特点,在 4 个数据集上主要进行了 3 种实验,分别是信息融合对推荐效果的影响、融合组件对推荐效果的影响以及参数对推荐效果的影响.下面对实验总结如下.

- 在信息融合实验中,主要是将融合多种数据信息的本文模型 ACGIF 与其他几种推荐方法进行对比.以 8 个模型为横坐标,评价指标 MAE 及 RMSE 为纵坐标绘制了 4 个折线图,清晰地展示了本文模型及对比模型 BPR、FM、DTMF、MSRA、DiffNet、NRPA 及 DiffNet++ 在不同数据集下的变化情况.可以发现,本文模型在 4 个数据集及两个评价指标下效果均最佳,然后是 DiffNet++, DiffNet 与 NRPA 不相上下,接下来依次是 MSRA、DTMF、FM、BPR.这主要是由于 BPR 和 FM 只考虑了评分信息,MSRA 和 DiffNet 考虑了评分的同时也考虑了信任,DTMF 和 NRPA 在评分的基础上增加了评论文本,而 DiffNet++ 和本文模型同时涵盖了 3 种数据信息,且增加了注意力机制和 GNN.

- 在融合组件实验中,从两个角度对融合组件的效果进行对比.横向对比了本文不同组件融合的效果,包括考虑评分、评分+信任、评分+评论以及评分+信任+评论 4 种情况.可以发现,融合多种数据信息的组件效果要优于融合一种或者两种信息的组件,这充分说明了信息融合的有效性.纵向对比了本文不同组件与相应对比模型的效果,可以发现本文模型的效果更优,体现了本文深度模型的有效性.通过这两个角度比较全面地展示了本文模型在改善推荐效果方面的优越性.

- 在模型参数实验中,主要考虑了平衡评论以及信任之间影响的参数 α ,其中参数 α 是评论文本对应的超参数, $1-\alpha$ 是信任对应的超参数.以 α 为横坐标,评价指标 RMSE 为纵坐标,绘制了两个数据集上的折线图.从图中可以清楚地看到,当 $\alpha=0.6$ 时 Epinions 数据集取得最佳结果,当 $\alpha=0.7$ 时 Yelp 数据集取得最佳结果.控制评论文本的参数值最大,控制信任数据的参数值最小,由此可看出,评论文本对于推荐结果的重要程度.

上面从 3 个角度对本文实验进行了总结,表 8 归纳了本文模型与对比模型的性能,主要从推荐准确率、信息挖掘程度以及算法复杂度 3 个方面进行对比.

5 总结与下一步工作

本文提出了一种结合注意力 CNN 与 GNN 的信息融合推荐模型 ACGIF.该模型尝试从两个角度对用户偏好

进行建模: 基于评论信息的表示、基于评分和信任数据的表示. 该模型在 CNN 中加入注意力机制来处理评论信息, 通过 GNN 来处理评分和信任信息. 对于这两部分得到的用户对项目的偏好向量进行加权融合, 得到最终的用户对于项目的偏好向量.

表 8 各模型性能对比概览

模型	推荐准确率	信息挖掘程度	算法复杂度	模型	推荐准确率	信息挖掘程度	算法复杂度
BPR	较低	较浅	较低	DiffNet	较高	中等	中等
FM	较低	较浅	较低	NRPA	较高	中等	中等
DTMF	中等	中等	较低	DiffNet++	较高	较深	中等
MSRA	中等	中等	较低	ACGIF	最高	较深	中等

为了能够全面地验证 ACGIF 模型的有效性, 在 Epinions、Yelp、Flickr、MovieLens 这 4 个数据集上, 以推荐结果的 *MAE* 和 *RMSE* 为评估指标进行了实验, 将 ACGIF 模型与其他 7 种典型推荐模型进行了对比. 实验结果表明, 本文模型的推荐效果和运行时间均优于其他模型, 同时有效缓解了稀疏性问题对推荐产生的影响.

该模型为神经网络在推荐系统中的应用增强了信心. 在未来的工作中, 考虑加入用户之间的不信任关系, 并与信任关系结合, 更加全面地对用户信息进行建模, 从而进一步改善推荐性能.

References:

- [1] Shi FJ, Ghedira C. Improving recommender systems with an intention-based algorithm switching strategy. In: Proc. of the 2017 Symp. on Applied Computing. Marrakech: ACM, 2017. 1668–1673. [doi: 10.1145/3019612.3019761]
- [2] Brovman YM, Jacob M, Srinivasan N, Neola S, Galron D, Snyder R, Wang P. Optimizing similar item recommendations in a semi-structured marketplace to maximize conversion. In: Proc. of the 10th ACM Conf. on Recommender Systems. Boston: ACM, 2016. 199–202. [doi: 10.1145/2959100.2959166]
- [3] Goldberg D, Nichols D, Oki BM, Terry D. Using collaborative filtering to weave an information tapestry. Communications of the ACM, 1992, 35(12): 61–70. [doi: 10.1145/138859.138867]
- [4] Wu Y, DuBois C, Zheng AX, Ester M. Collaborative denoising auto-encoders for top-n recommender systems. In: Proc. of the 9th ACM Int'l Conf. on Web Search and Data Mining. San Francisco: ACM, 2016. 153–162. [doi: 10.1145/2835776.2835837]
- [5] Zhang S, Yao LN, Sun AX, Tay Y. Deep learning based recommender system: A survey and new perspectives. ACM Computing Surveys, 2019, 52(1): 5. [doi: 10.1145/3285029]
- [6] Kim D, Park C, Oh J, Li S, Yu H. Convolutional matrix factorization for document context-aware recommendation. In: Proc. of the 10th ACM Conf. on Recommender Systems. Boston: ACM, 2016. 233–240. [doi: 10.1145/2959100.2959165]
- [7] Dai L, Meng XW, Zhang YJ, Ji WY. Restaurant recommendation model with multiple information fusion. Ruan Jian Xue Bao/Journal of Software, 2019, 30(9): 2869–2885 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5540.htm> [doi: 10.13328/j.cnki.jos.005540]
- [8] Li L, Liu JH, Meng XF, Su C, Li X, Zhong L. Recommendation models by exploiting rating matrix and review text. Chinese Journal of Computers, 2018, 41(7): 1559–1573 (in Chinese with English abstract). [doi: 10.11897/SP.J.1016.2018.01559]
- [9] Wu B, Lou ZZ, Ye YD. A collaborative filtering recommendation algorithm for multi-source heterogeneous data. Journal of Computer Research and Development, 2019, 56(5): 1034–1047 (in Chinese with English abstract). [doi: 10.7544/j.issn1000-1239.2019.20180461]
- [10] Chen T, Zhu Q, Zhou MX, Wang S. Trust-based recommendation algorithm in social network. Ruan Jian Xue Bao/Journal of Software, 2017, 28(3): 721–731 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5159.htm> [doi: 10.13328/j.cnki.jos.005159]
- [11] Liu HF, Jing LP, Yu J. Survey of matrix factorization based recommendation methods by integrating social information. Ruan Jian Xue Bao/Journal of Software, 2018, 29(2): 340–362 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5391.htm> [doi: 10.13328/j.cnki.jos.005391]
- [12] Pan YT, He FZ, Yu HP. Social recommendation algorithm using implicit similarity in trust. Chinese Journal of Computers, 2018, 41(1): 65–81 (in Chinese with English abstract). [doi: 10.11897/SP.J.1016.2018.00065]
- [13] Michlmayr E, Cayzer S. Learning user profiles from tagging data and leveraging them for personal(ized) information access. In: Proc. of the 2007 WWW2007. Banff, 2007. 1–7.
- [14] Mooney RJ, Roy L. Content-based book recommending using learning for text categorization. In: Proc. of the 5th ACM Conf. on Digital

- Libraries. San Antonio: ACM, 2000. 195–204. [doi: [10.1145/336597.336662](https://doi.org/10.1145/336597.336662)]
- [15] Huo H, Zhang W, Liu L, Li Y. Collaborative filtering recommendation model based on convolutional denoising auto encoder. In: Proc. of the 12th Chinese Conf. on Computer Supported Cooperative Work and Social Computing. Chongqing: ACM, 2017. 64–71. [doi: [10.1145/3127404.3127420](https://doi.org/10.1145/3127404.3127420)]
- [16] Zhang YH, Zhu XF, Xu CY, Dong SD. Hybrid recommendation approach based on deep sentiment analysis of user reviews and multi-view collaborative fusion. Chinese Journal of Computers, 2019, 42(6): 1316–1333 (in Chinese with English abstract). [doi: [10.11897/SP.J.1016.2019.01316](https://doi.org/10.11897/SP.J.1016.2019.01316)]
- [17] Huang LW, Jiang BT, Lv SY, Liu YB, Li YD. Survey on deep learning based recommender systems. Chinese Journal of Computers, 2018, 41(7): 1619–1647 (in Chinese with English abstract). [doi: [10.11897/SP.J.1016.2018.01619](https://doi.org/10.11897/SP.J.1016.2018.01619)]
- [18] Lu YC, Dong RH, Smyth B. Coevolutionary recommendation model: Mutual learning between ratings and reviews. In: Proc. of the 2018 World Wide Web Conf. Lyon: ACM, 2018. 773–782. [doi: [10.1145/3178876.3186158](https://doi.org/10.1145/3178876.3186158)]
- [19] Liu HT, Wu FZ, Wang WJ, Wang XC, Jiao PF, Wu CH. NRPA: Neural recommendation with personalized attention. In: Proc. of the 42nd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Paris: ACM, 2019: 1233–1236. [doi: [10.1145/3331184.3331371](https://doi.org/10.1145/3331184.3331371)]
- [20] Kipf TN, Welling M. Semi-supervised classification with graph convolutional networks. In: Proc. of the 5th Int'l Conf. on Learning Representations. Toulon: OpenReview.net, 2017. 24–26.
- [21] Hamilton WL, Ying R, Leskovec J. Inductive representation learning on large graphs. In: Proc. of the 31st Int'l Conf. on Neural Information Processing Systems. Long Beach: ACM, 2017. 1025–1035.
- [22] Hamilton WL, Ying R, Leskovec J. Representation learning on graphs: Methods and applications. IEEE Data Engineering Bulletin, 2017, 40(3): 52–74.
- [23] van den Berg R, Kipf TN, Welling M. Graph convolutional matrix completion. arXiv:1706.02263, 2017.
- [24] Wu L, Sun PJ, Fu YJ, Hong RC, Wang XT, Wang M. A neural influence diffusion model for social recommendation. In: Proc. of the 42nd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Paris: ACM, 2019: 235–244. [doi: [10.1145/3331184.3331214](https://doi.org/10.1145/3331184.3331214)]
- [25] Wu L, Li JW, Sun PJ, Hong RC, Ge Y, Wang M. DiffNet++: A neural influence and interest diffusion network for social recommendation. IEEE Trans. on Knowledge and Data Engineering. [doi: [10.1109/TKDE.2020.3048414](https://doi.org/10.1109/TKDE.2020.3048414)]
- [26] Zhang YF, Ai QY, Chen X, Croft WB. Joint representation learning for top-n recommendation with heterogeneous information sources. In: Proc. of the 2017 ACM Conf. on Information and Knowledge Management. Singapore: ACM, 2017. 1449–1458. [doi: [10.1145/3132847.3132892](https://doi.org/10.1145/3132847.3132892)]
- [27] Koren Y. Factorization meets the neighborhood: A multifaceted collaborative filtering model. In: Proc. of the 14th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. Las Vegas: ACM, 2008. 426–434. [doi: [10.1145/1401890.1401944](https://doi.org/10.1145/1401890.1401944)]
- [28] Guo GB, Zhang J, Yorke-Smith N. TrustSVD: Collaborative filtering with both the explicit and implicit influence of user trust and of item ratings. In: Proc. of the 29th AAAI Conf. on Artificial Intelligence. Austin: AAAI Press, 2015. 123–129.
- [29] Kim Y. Convolutional neural networks for sentence classification. In: Proc. of the 2014 Conf. on Empirical Methods in Natural Language Processing. Doha: Association for Computational Linguistics, 2014. 1746–1751. [doi: [10.3115/v1/D14-1181](https://doi.org/10.3115/v1/D14-1181)]
- [30] Wang H, Wang NY, Yeung DY. Collaborative deep learning for recommender systems. In: Proc. of the 21st ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. Sydney: ACM, 2014. 1235–1244. [doi: [10.1145/2783258.2783273](https://doi.org/10.1145/2783258.2783273)]
- [31] Wang ML, Ma J. A novel recommendation approach based on users' weighted trust relations and the rating similarities. Soft Computing, 2016, 20(10): 3981–3990. [doi: [10.1007/s00500-015-1734-1](https://doi.org/10.1007/s00500-015-1734-1)]
- [32] Noda K, Yamaguchi Y, Nakadai K, Okuno HG, Ogata T. Audio-visual speech recognition using deep learning. Applied Intelligence, 2015, 42(4): 722–737. [doi: [10.1007/s10489-014-0629-7](https://doi.org/10.1007/s10489-014-0629-7)]
- [33] Shen YL, He XD, Gao JF, Deng L, Mesnil G. A latent semantic model with convolutional-pooling structure for information retrieval. In: Proc. of the 23rd ACM Int'l Conf. on Conf. on Information and Knowledge Management. Shanghai: ACM, 2014. 101–110. [doi: [10.1145/2661829.2661935](https://doi.org/10.1145/2661829.2661935)]
- [34] Kalchbrenner N, Grefenstette E, Blunsom P. A convolutional neural network for modelling sentences. In: Proc. of the 52nd Annual Meeting of the Association for Computational Linguistics. Baltimore: Association for Computational Linguistics, 2014. 655–665. [doi: [10.3115/v1/P14-1062](https://doi.org/10.3115/v1/P14-1062)]
- [35] Pennington J, Socher R, Manning C. GloVe: Global vectors for word representation. In: Proc. of the 2014 Conf. on Empirical Methods in Natural Language Processing. Doha: Association for Computational Linguistics, 2014. 1532–1543. [doi: [10.3115/v1/D14-1162](https://doi.org/10.3115/v1/D14-1162)]
- [36] Collobert R, Weston J, Bottou L, Karlen M, Kavukcuoglu K, Kuksa P. Natural language processing (almost) from scratch. The Journal of

- Machine Learning Research, 2011, 12: 2493–2537. [doi: [10.5555/1953048.2078186](https://doi.org/10.5555/1953048.2078186)]
- [37] Glorot X, Bordes A, Bengio Y. Deep sparse rectifier neural networks. In: Proc. of the 14th Int'l Conf. on Artificial Intelligence and Statistics. Lauderdale: JMLR. org, 2011. 315–323.
- [38] Maas AL, Hannun AY, Ng AY. Rectifier nonlinearities improve neural network acoustic models. In: Proc. of the 30th Int'l Conf. on Machine Learning. Atlanta: JMLR, 2013. 1152–1160.
- [39] Pi HY. Hybrid recommendation models based on multi-source heterogeneous data [MS. Thesis]. Beijing: Beijing Jiaotong University, 2019 (in Chinese with English abstract).
- [40] Wang C, Blei DM. Collaborative topic modeling for recommending scientific articles. In: Proc. of the 17th ACM SIGKDD Int'l Conf. on Knowledge Discovery and Data Mining. San Diego: ACM, 2011. 448–456. [doi: [10.1145/2020408.2020480](https://doi.org/10.1145/2020408.2020480)]
- [41] Shani G, Gunawardana A. Evaluating recommendation systems. In: Ricci F, Rokach L, Shapira B, Kantor PB, eds. Recommender Systems Handbook. Boston: Springer, 2011. 257–297. [doi: [10.1007/978-0-387-85820-3_8](https://doi.org/10.1007/978-0-387-85820-3_8)]
- [42] Rendle S, Freudenthaler C, Gantner Z, Schmidt-Thieme L. BPR: Bayesian personalized ranking from implicit feedback. In: Proc. of the 25th Conf. on Uncertainty in Artificial Intelligence. Montreal: AUAI Press, 2009. 452–461.
- [43] Rendle S. Factorization machines. In: Proc. of the 2010 IEEE Int'l Conf. on Data Mining. Sydney: IEEE, 2010. 995–1000. [doi: [10.1109/ICDM.2010.127](https://doi.org/10.1109/ICDM.2010.127)]

附中文参考文献:

- [7] 戴琳, 孟祥武, 张玉洁, 纪威宇. 融合多种数据信息的餐馆推荐模型. 软件学报, 2019, 30(9): 2869–2885. <http://www.jos.org.cn/1000-9825/5540.htm> [doi: [10.13328/j.cnki.jos.005540](https://doi.org/10.13328/j.cnki.jos.005540)]
- [8] 李琳, 刘锦行, 孟祥福, 苏畅, 李鑫, 钟珞. 融合评分矩阵与评论文本的商品推荐模型. 计算机学报, 2018, 41(7): 1559–1573. [doi: [10.11897/SP.J.1016.2018.01559](https://doi.org/10.11897/SP.J.1016.2018.01559)]
- [9] 吴宾, 娄铮铮, 叶阳东. 一种面向多源异构数据的协同过滤推荐算法. 计算机研究与发展, 2019, 56(5): 1034–1047. [doi: [10.7544/issn1000-1239.2019.20180461](https://doi.org/10.7544/issn1000-1239.2019.20180461)]
- [10] 陈婷, 朱青, 周梦溪, 王珊. 社交网络环境下基于信任的推荐算法. 软件学报, 2017, 28(3): 721–731. <http://www.jos.org.cn/1000-9825/5159.htm> [doi: [10.13328/j.cnki.jos.005159](https://doi.org/10.13328/j.cnki.jos.005159)]
- [11] 刘华锋, 景丽萍, 于剑. 融合社交信息的矩阵分解推荐方法研究综述. 软件学报, 2018, 29(2): 340–362. <http://www.jos.org.cn/1000-9825/5391.htm> [doi: [10.13328/j.cnki.jos.005391](https://doi.org/10.13328/j.cnki.jos.005391)]
- [12] 潘一腾, 何发智, 于海平. 一种基于信任关系隐含相似度的社会化推荐算法. 计算机学报, 2018, 41(1): 65–81. [doi: [10.11897/SP.J.1016.2018.00065](https://doi.org/10.11897/SP.J.1016.2018.00065)]
- [16] 张宜浩, 朱小飞, 徐传运, 董世都. 基于用户评论的深度情感分析和多视图协同融合的混合推荐方法. 计算机学报, 2019, 42(6): 1316–1333. [doi: [10.11897/SP.J.1016.2019.01316](https://doi.org/10.11897/SP.J.1016.2019.01316)]
- [17] 黄立威, 江碧涛, 吕业业, 刘艳博, 李毅德. 基于深度学习的推荐系统研究综述. 计算机学报, 2018, 41(7): 1619–1647. [doi: [10.11897/SP.J.1016.2018.01619](https://doi.org/10.11897/SP.J.1016.2018.01619)]
- [39] 皮怀雨. 基于多源异构数据的混合推荐模型 [硕士学位论文]. 北京: 北京交通大学, 2019.



钱忠胜(1977—), 男, 博士, 教授, 博士生导师, CCF 专业会员, 主要研究领域为推荐系统, 机器学习, 算法设计, 软件工程.



俞情媛(1997—), 女, 博士生, 主要研究领域为软件工程, 机器学习.



赵畅(1995—), 女, 硕士, 主要研究领域为推荐系统, 机器学习.



李端明(1995—), 男, 硕士, 主要研究领域为推荐系统, 机器学习.