



计算机科学

COMPUTER SCIENCE

结合物品相似性的社交信任推荐算法

余皓欣, 冯秀芳, 孙静宇

引用本文

余皓欣, 冯秀芳, 孙静宇. [结合物品相似性的社交信任推荐算法](#)[J]. 计算机科学, 2022, 49(5): 144-151.

YU Ai-xin, FENG Xiu-fang, SUN Jing-yu. [Social Trust Recommendation Algorithm Combining Item Similarity](#)[J]. Computer Science, 2022, 49(5): 144-151.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

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

[基于用户覆盖及评分差异的多样性推荐算法](#)

Diversity Recommendation Algorithm Based on User Coverage and Rating Differences

计算机科学, 2022, 49(5): 159-164. <https://doi.org/10.11896/jsjcx.210300263>

[融合快速注意力机制的节点无特征网络链路预测算法](#)

Link Prediction for Node Featureless Networks Based on Faster Attention Mechanism

计算机科学, 2022, 49(4): 43-48. <https://doi.org/10.11896/jsjcx.210800276>

[基于 SEIR 的微信公众号信息传播建模与分析](#)

Modeling and Analysis of WeChat Official Account Information Dissemination Based on SEIR

计算机科学, 2022, 49(4): 56-66. <https://doi.org/10.11896/jsjcx.210900169>

[成本受限条件下的社交网络影响最大化方法](#)

Budget-aware Influence Maximization in Social Networks

计算机科学, 2022, 49(4): 100-109. <https://doi.org/10.11896/jsjcx.210300228>

[图神经网络在 Text-to-SQL 解析中的技术研究](#)

Technical Research of Graph Neural Network for Text-to-SQL Parsing

计算机科学, 2022, 49(4): 110-115. <https://doi.org/10.11896/jsjcx.210200173>

结合物品相似性的社交信任推荐算法

余皓欣 冯秀芳 孙静宇

太原理工大学软件学院 太原 030024

(yax_1203@163.com)

摘要 随着互联网的快速发展,用户很难在大量的网络数据中找到自己感兴趣的内容,而推荐系统能帮助解决这一问题。传统的推荐系统仅依赖用户历史行为数据进行推荐,存在数据稀疏和冷启动的问题。将社交网络信息融入推荐系统中被证明能够有效地解决传统推荐系统的问题,提高了推荐质量。但是,大部分基于社交网络的推荐仅关注用户之间的单向信任关系,忽略了被信任关系和物品自身因素对推荐结果的影响,因此提出了结合物品相似性的社交信任推荐算法 SocialIS。SocialIS 算法考虑了用户作为信任者和被信任者时邻居用户对用户的影响,并采用 Node2vec 算法训练得到包含用户偏好的物品相似性向量,再使用图神经网络学习用户和物品的特征向量进行评分预测。在 Epinions 和 Ciao 数据集上进行了大量实验,采用基于误差的指标(MAE 和 RMSE)对所提算法的性能进行度量,并与其他算法进行对比,验证了所提算法的性能。实验结果表明,与其他算法相比,所提算法的评分预测误差更小,推荐效果更好。

关键词: Node2vec; 图神经网络; 信任推荐; 社交网络; 推荐系统

中图法分类号 TP391

Social Trust Recommendation Algorithm Combining Item Similarity

YU Ai-xin, FENG Xiu-fang and SUN Jing-yu

College of Software, Taiyuan University of Technology, Taiyuan 030024, China

Abstract With the rapid development of Internet, it is difficult for users to find the content they are interested in from massive network data, while the recommendation system can solve this problem. Traditional recommendation systems only rely on user's historical behavior data for recommendation, which has the problems of data sparsity and cold start. The integration of social network information into the recommendation system has been proven to effectively solve the problems of the traditional recommendation system and improve the quality of recommendation system. However, most recommendation systems based on social networks only focus on the one-way trust relationships between users, and ignore the influence of the trusted relationship and the item's own factors on recommendation results. Therefore, a social trust recommendation algorithm, called SocialIS, which combines item similarity, is proposed. The influence of neighbor users on user when the user is trustor and trustee is considered by SocialIS, and the Node2vec algorithm is used to train the item similarity vector containing the user's preference, and then the graph neural network is used to learn the feature vector of the user and the item to predict the score. A large number of experiments are conducted on the Epinions and Ciao data sets, and the performance of the proposed algorithm is measured by error-based indicators (MAE and RMSE), and compared with other algorithms to verify its performance. Experimental results show that compared with other algorithms, the proposed algorithm had smaller scoring prediction error and better recommendation effect.

Keywords Node2vec, Graph neural network, Trust recommendation, Social network, Recommendation system

1 引言

随着互联网的高速发展,网络上的数据呈指数级增长,用户想在信息爆炸的互联网上找到自己想要的内容变得十分困难。在此背景下,研究者提出推荐系统,用于解决信息过载导致用户无法找到自己感兴趣的内容的问题。推荐系统通过用户的历史行为或者用户的兴趣偏好生成算法来给用户推荐他们可能感兴趣的内容。

传统的推荐方法主要分为基于内容的推荐方法、协同过滤的推荐方法以及混合推荐方法^[1]。但是这些技术往往只针对目标用户的历史行为记录进行分析,根据用户的偏好来进行推荐,如果用户的历史记录不足,推荐的性能就会受到数据稀疏性的影响^[2-3]。为了解决数据稀疏的问题,研究者们提出了许多解决办法^[4],包括引入一些辅助信息来提高推荐精度。例如, Ma 等^[5]提出了一种基于标签的个性化推荐算法,通过马尔可夫链模型来计算用户对标签的兴趣度,再通过推荐

到稿日期:2021-03-22 返修日期:2021-09-13

基金项目:山西省重点研发计划(201903D121121)

This work was supported by the Key Research and Development Plan of Shanxi Province(201903D121121).

通信作者:冯秀芳(feng_xf2008@126.com)

标签集来匹配与其对应的物品。Chen^[6]将用户对物品的评价信息作为辅助信息来学习用户的兴趣,以帮助解决数据稀疏的问题。

社交网络和社交媒体服务的发展使得获取用户之间的社交关系成为可能,研究者也将目光投向社交网络与推荐系统的结合上。基于社交网络的推荐算法也被证明是科学的,一方面,人们在生活中更愿意听取自己信任的人的意见;另一方面,用户在选择自己信任的用户时更倾向于选择与自己有相同爱好的用户。结合社交网络信息的推荐算法考虑了用户之间的信任关系对推荐算法的影响,使得推荐算法更加真实和完善,能进一步提高推荐的准确性^[7-8]。

Wang等^[9]从社交网络获得用户之间的相似度,再利用聚类算法填充评分矩阵的缺失值,最后通过协同过滤算法进行推荐。Ma等^[10]于2008年提出了SoRec模型,通过共享分解评分矩阵和用户社交矩阵来得到用户特征矩阵,以此得到结合社交关系的推荐。但是该模型把社交关系矩阵分解成用户特征矩阵与社交特征矩阵缺乏自然规律解释,忽略了用户间的信任传播,不能反映真实世界的推荐过程。Jamali等^[11]于2010年提出了SocialMF模型,在矩阵分解中引入信任传播,令目标用户的兴趣偏好与其邻居用户的平均偏好相似,弥补了SoRec模型的缺陷。但是,SocialMF模型仅考虑了社交邻居的平均偏好,忽略了社交网络中用户间信任程度的区别。而社交网络中不仅有显性信任关系,一些潜在好友关系也对推荐结果有显著影响。Xiang等^[12]提出了一种基于关联规则和碎片相似度的社交好友推荐算法,利用改进后的Apriori-Tid算法计算获得潜在好友。Long等^[13]考虑用户的多种交互,提出了一种基于用户交互的社交网络用户相似度计算算法KIFLink。Han等^[14]基于Spark框架,提出了一种社区发现算法FPCD,提高了社交网络社区发现的效率和准确性,帮助用户更快建立社交关系以进行推荐。

以上研究从不同角度提升了社会化推荐算法的性能,但目前社交网络推荐仍存在着不足之处。

首先,在社交网络中用户之间的信任强度是有差异的,要想提高推荐算法的准确度,就需要计算用户之间不同的信任度,不能一概而论。基于具有信任关系的用户之间、具有相似信任关系的用户之间或历史行为数据相似的用户之间具有相似的兴趣偏好的假设,用户间的信任度可从信任数据或用户历史行为数据的角度进行度量。但是,大多数研究仅考虑了用户间单向的信任关系。实际上,用户作为不同角色时所表现出的偏好并不相同^[15]。

其次,基于社交网络的推荐大多仅考虑了信任关系对用户的影响,而忽略了用户和物品自身因素对推荐性能的影响,考虑过于单一且片面。

为此,本文提出了一种结合物品相似性的社交信任推荐算法,根据用户之间的信任关系以及用户历史行为数据,利用图神经网络训练得到用户和物品的特征向量,同时使用Node2vec算法得到包含用户偏好和物品相似性的物品相似性向量,对物品特征进行约束,最后将用户和物品的特征向量输入到神经网络进行训练,从而得到目标用户对物品的最终预测评分。在两个公开的社交网络数据集Epinions和Ciao

上进行了大量实验,实验结果表明,本文提出的推荐算法优于同类的社交推荐算法。本文的主要贡献包括:1)在计算用户的信任关系的同时考虑用户作为信任者和被信任者时的信任关系,进而提高了推荐精度;2)在基于信任关系的推荐中引入了带有用户偏好的物品相似性特征,解决了传统的基于社交网络的推荐算法忽略物品自身因素影响的问题;3)综合考虑了用户历史行为和信任关系对用户的影响,得到了更精确的推荐模型。

2 相关工作

在基于社交网络的推荐中,存在着用户-物品的评分图和用户-用户社交关系图,而图神经网络对这种图结构数据具有良好的适应性。同时,Node2vec算法可以提取图中的节点和权重数据,利用自然语言处理的思路得到各节点的特征。因此,本文采用图神经网络和Node2vec算法来处理图数据,学习用户和物品的特征。

2.1 图神经网络

近年来,深度学习的快速发展和广泛应用为推荐系统的研究提供了新的途径。基于深度学习的推荐算法通过学习一种深层次的非线性网络结构,能从大量的数据中发现用户意想不到或不可理解的行为,提取到用户和物品深层次的特征表示。同时,深度学习从辅助信息中提取特征,并将高维稀疏的特征降低为低维且密集的特征,从而获得数据的统一表征,再融合传统的推荐方法进行推荐,有效缓解了传统推荐系统中的数据稀疏和冷启动的问题^[16]。

随着互联网的发展,越来越多的图结构数据遍布各个领域,图形数据的深度网络也有了十足的发展,我们将这些图形数据的深度网络称为图神经网络(Graph Neural Networks, GNN)。

图神经网络的主要思想是使用神经网络迭代地从局部图邻域聚集特征信息,得到包含邻居节点信息和图形拓扑结构特点的特征,然后将这些节点信息通过转换和聚合后在图上进行传播。其基本结构如图1所示。

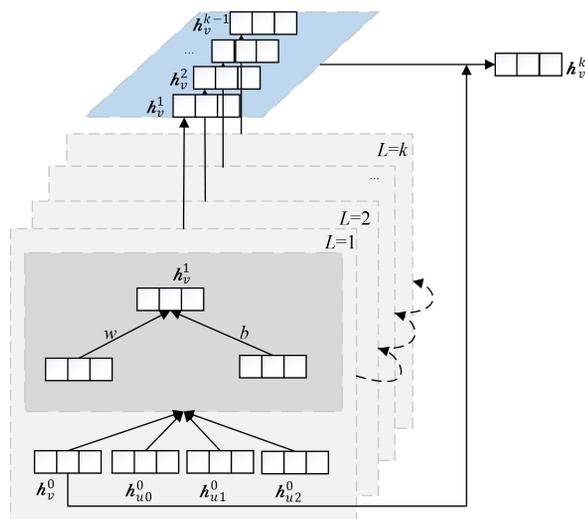


图1 图神经网络结构

Fig. 1 Structure of graph neural network

(1) $layer=0$ 。在初始化的图中,通过图嵌入技术得到

节点的初始特征 \mathbf{h}_v^0 。

(2) $layer=k$ 。在聚合邻居信息时,将邻居节点的 \mathbf{h}_v^{k-1} 进行平均并使用神经网络将其与目标节点的上一层嵌入向量 \mathbf{h}_v^{k-1} 进行聚合得到此节点在 $layer=k$ 时的嵌入向量。

(3)在达到规定的层数 k 后,将每个节点每层的嵌入向量连接起来,作为该节点最终的嵌入向量,具体表达式为:

$$\mathbf{h}_v^0 = \mathbf{x}_v \quad (1)$$

$$\mathbf{h}_v^k = \sigma \left(\mathbf{W}_k \cdot \sum_{u \in N(v)} \frac{\mathbf{h}_u^{k-1}}{|N(v)|} + B_k \mathbf{h}_v^{k-1} \right), \forall k > 0 \quad (2)$$

其中, \mathbf{h}_v^0 是图神经网络在初始化的图中通过图嵌入技术得到的节点初始特征 \mathbf{x}_v 。而图嵌入技术就是将图转换到保存图信息的低维空间,将图表示为一组或多组低维向量。图嵌入的输出表示整个图或者部分图的低维向量,然后将输出的低维向量应用到其他机器学习方法中。 \mathbf{h}_u^{k-1} 指节点 v 的邻居节点在 $k-1$ 层的嵌入,而 \mathbf{h}_v^{k-1} 指节点 v 在上一层神经网络中的嵌入特征, \mathbf{h}_v^k 则代表了节点 v 在当前第 k 层的特征。 $N(v)$ 是节点 v 的邻居集合, σ 是激活函数, \mathbf{W}_k 和 B_k 是神经网络的权重和偏置。

2.2 Node2Vec 算法

Node2vec 算法与 Deepwalk 算法的思想类似。首先利用随机游走算法从网络图中提取一些顶点序列,然后借助自然语言处理的思路,将生成的顶点序列看作由单词组成的句子,所有的序列可以看作一个大的语料库,最后利用自然语言处理工具 word2vec 将每一个顶点表示为一个维度为 d 的向量。但是,Node2vec 对随机游走算法进行了改进,采用了有偏的随机游走算法。改进的随机游走有两个参数 p 和 q ,假设刚走完边 (t, v) ,如图 2 所示,此时在节点 v 处需要根据节点的转移概率 π_{ve} 选择游走的下一个节点 e ,转移概率 π_{ve} 表示为:

$$\pi_{ve} = \alpha_{pq}(t, e) * \omega_{ve} \quad (3)$$

其中, ω_{ve} 代表两个物品之间被 n 个用户共同给了较高评分的权重, $\alpha_{pq}(t, e)$ 表示节点 v 向节点 e 移动的偏移度,表达式如下:

$$\alpha_{pq}(t, e) = \begin{cases} \frac{1}{p}, & d_{te} = 0 \\ 1, & d_{te} = 1 \\ \frac{1}{q}, & d_{te} = 2 \end{cases} \quad (4)$$

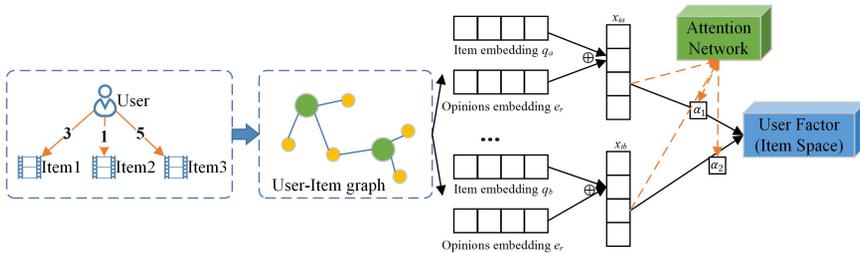


图 3 项目空间用户特征的结构图

Fig. 3 Structure diagram of user feature in item space

一般的聚合函数 $Aggre_{items}$ 常用的均值算子假设所有交互的贡献都相同,但这不是最优的方案,因为不同的物品对用户的影响是有区别的,所以给每个交互分配一个权重,允许交互对用户的特征作出不同的贡献,具体可以表示为:

其中, d_{te} 表示节点 t 和 e 间的距离,当节点 t 和 e 直接相连时, $d_{te} = 1$;当下一个节点为 t 时, $d_{te} = 0$;当节点 e 和 t 未相连时, $d_{te} = 2$ 。因此,随机游走的概率变成由边的权重和节点之间的连接共同决定。

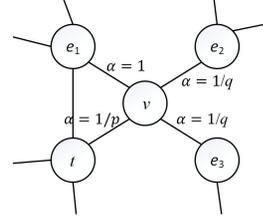


图 2 随机游走算法示意图

Fig. 2 Schematic diagram of random walk algorithm

3 结物品相似性的基于社交信任的推荐算法

本节主要介绍本文提出的结物品相似性的社交信任推荐算法 (Social Trust Recommendation Algorithm Combining Item Similarity, SocialIS)。首先利用图神经网络分别从社交信任关系和用户评分两方面进行建模,以提取用户特征和物品特征,然后利用 Node2Vec 算法得到的具有用户偏好的物品相似性特征对物品特征进行约束,最后根据物品特征和用户特征进行评分预测。

3.1 用户特征模型

3.1.1 项目空间用户特征

项目空间的用户特征是根据用户对物品的历史评分学习得到的,其结构如图 3 所示。本文通过聚合用户在所有物品上的评分信息,采用图神经网络训练得到用户在项目空间上的特征向量 \mathbf{h}_i^l ,其表达式为:

$$\mathbf{h}_i^l = \sigma(\mathbf{W} \cdot Aggre_{items}(\{\mathbf{x}_{ia}, \forall a \in C(i)\}) + b) \quad (5)$$

其中, $C(i)$ 是与用户 u_i 交互的物品集合, \mathbf{W} 和 b 是权重和偏置, σ 是非线性激活函数,向量 \mathbf{x}_{ia} 是用户 u_i 与物品 v_a 之间交互行为的特征表示, $Aggre_{items}$ 是与用户 u_i 交互的物品的聚合函数。用户根据对每个物品的喜爱程度会给予不同的评分,因此可以通过一个多层感知机 (MLP) 对物品嵌入向量 \mathbf{q}_a 和评分嵌入向量 \mathbf{e}_r 进行合并来得到 \mathbf{x}_{ia} ,具体过程可以表示为:

$$\mathbf{x}_{ia} = g_v([\mathbf{q}_a \oplus \mathbf{e}_r]) \quad (6)$$

其中, \oplus 表示两个向量间的级联运算, g_v 表示多层感知机。

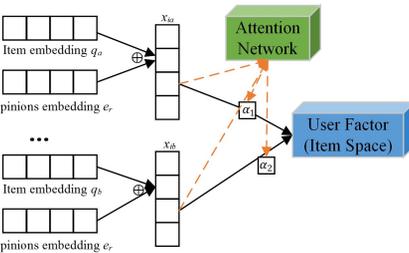


图 3 项目空间用户特征的结构图

Fig. 3 Structure diagram of user feature in item space

$$\mathbf{h}_i^l = \sigma(\mathbf{W} \cdot \{ \sum_{a \in C(i)} \alpha_{ia} \mathbf{x}_{ia} \} + b) \quad (7)$$

其中, α_{ia} 代表每个交互的注意力权重。注意力网络将 \mathbf{x}_{ia} 和用户嵌入 \mathbf{p}_i 作为输入,经过训练得到注意力得分 α_{ia}^* ,最后使用 softmax 函数进行归一化得到注意力权重,具体表达式为:

$$\alpha_{ia}^* = \mathbf{W}_2^T \cdot \sigma(\mathbf{W}_1 \cdot [\mathbf{x}_{ia} \oplus \mathbf{p}_i] + b_1) + b_2 \quad (8)$$

$$\alpha_{ia} = \frac{\exp(\alpha_{ia}^*)}{\sum_{a \in C(i)} \exp(\alpha_{ia}^*)} \quad (9)$$

其中, \mathbf{W}_1 和 \mathbf{W}_2 是权重, b_1 和 b_2 是偏置, \oplus 表示两个向量间的级联运算。

3.1.2 社交空间用户特征

随着社交网络和在线平台的广泛应用,在线用户的行为和习惯越来越体现出社区和网络的特征。社交网络分析的研究结果也表明,社交网络中相互关联的用户之间的兴趣爱好和行为规范相似且相互影响。在社交网络中,用户担任着信任者和被信任者两个角色。信任者指用户会关注一些兴趣爱好与其相似的用户,此时用户作为信任者,他所信任的邻居用户的兴趣会对该用户的用户特征产生影响。而被信任者指用户会被社交网络中的其他用户关注,这些关注者的兴趣爱好大多与该用户的兴趣爱好一致,因此用户作为被信任者时,关注他的邻居用户的兴趣也会对该用户的用户特征产生影响。但大多数针对社交网络的信任研究只关注用户作为信任者时其信任用户对他产生的影响,忽略了用户作为被信任者时的影响。一些社会学的研究表明,用户作为关注者和被关注者时都会对其产生一定的影响,并且影响程度不尽相同。为了更全面地从社交的角度表示用户的特征向量,本文分别从信任者和被信任者两个角色入手。首先,在社交网络图上将目标用户信任的邻居用户的特征进行聚合,则目标用户在社交空间上作为信任者时的用户特征 \mathbf{h}_i^{S1} 可表示为:

$$\mathbf{h}_i^{S1} = \sigma(\mathbf{W} \cdot \text{Aggre}_{\text{neighb}}(\{\mathbf{h}_{o1}^I, \forall o1 \in N_1(i)\}) + b) \quad (10)$$

其中, $N_1(i)$ 表示用户 u_i 所信任的邻居用户集合, \mathbf{W} 和 b 是权重和偏置, σ 是非线性激活函数, $\text{Aggre}_{\text{neighb}}$ 表示目标用户所信任的邻居节点的聚合函数,而 \mathbf{h}_{o1}^I 则表示这些邻居节点在项目空间上的用户特征。

因为用户之间相互的影响也是有区别的,给每个交互分配一个权重,允许交互对用户的特征作出不同的贡献,具体表达式为:

$$\mathbf{h}_i^{S1} = \sigma(\mathbf{W} \cdot \{\sum_{o1 \in N_1(i)} \beta_{wo1} \mathbf{h}_{o1}^I\} + b) \quad (11)$$

其中, β_{wo1} 代表每个交互的注意力权重,注意力网络将所有邻居用户在项目空间上的特征向量 \mathbf{h}_{o1}^I 和用户嵌入 \mathbf{p}_i 作为输入,通过训练得到注意力得分 β_{wo1}^* ,最后使用 softmax 函数进行归一化得到注意力权重,可表示为:

$$\beta_{wo1}^* = \mathbf{W}_2^T \cdot \sigma(\mathbf{W}_1 \cdot [\mathbf{h}_{o1}^I \oplus \mathbf{p}_i] + b_1) + b_2 \quad (12)$$

$$\beta_{wo1} = \frac{\exp(\beta_{wo1}^*)}{\sum_{o1 \in N_1(i)} \exp(\beta_{wo1}^*)} \quad (13)$$

其中, \mathbf{W}_1 和 \mathbf{W}_2 是权重, b_1 和 b_2 是偏置, \oplus 表示两个向量间的级联运算。

同样地,本文引入用户作为被信任者时的用户特征,并与其作为信任者时的用户特征相结合,得到用户在社交空间的特征向量。目标用户作为被信任者时的用户特征 \mathbf{h}_i^{S2} 可表示为:

$$\mathbf{h}_i^{S2} = \sigma(\mathbf{W} \cdot \text{Aggre}_{\text{neighb}}(\{\mathbf{h}_{o2}^I, \forall o2 \in N_2(i)\}) + b) \quad (14)$$

其中, $N_2(i)$ 表示信任用户 u_i 的邻居用户集合, \mathbf{W} 和 b 是权重和偏置, σ 是非线性激活函数, $\text{Aggre}_{\text{neighb}}$ 表示信任目标用户的邻居节点的聚合函数, \mathbf{h}_{o2}^I 则表示这些邻居节点在项目空间上的用户特征。同样地,给每一个交互分配一个权重,并通过

注意力网络和 softmax 函数来得到最终的注意力权重 β_{wo2} , 可表示为:

$$\mathbf{h}_i^{S2} = \sigma(\mathbf{W} \cdot \{\sum_{o2 \in N_2(i)} \beta_{wo2} \mathbf{h}_{o2}^I\} + b) \quad (15)$$

$$\beta_{wo2}^* = \mathbf{W}_2^T \cdot \sigma(\mathbf{W}_1 \cdot [\mathbf{h}_{o2}^I \oplus \mathbf{p}_i] + b_1) + b_2 \quad (16)$$

$$\beta_{wo2} = \frac{\exp(\beta_{wo2}^*)}{\sum_{o2 \in N_2(i)} \exp(\beta_{wo2}^*)} \quad (17)$$

其中, β_{wo2}^* 为注意力得分, \mathbf{p}_i 为用户嵌入向量, $\mathbf{W}, \mathbf{W}_1, \mathbf{W}_2$ 是权重, b, b_1, b_2 是偏置, \oplus 表示两个向量间的级联运算。

用户作为信任者和被信任者时影响程度并不相同,因此本文引入一个权重 ω 来权衡这两种不同的影响机制,进而得到最终的社交空间上的用户特征向量 \mathbf{h}_i^S , 可表示为:

$$\mathbf{h}_i^S = (1 - \omega) \mathbf{h}_i^{S1} + \omega \mathbf{h}_i^{S2} \quad (18)$$

3.1.3 用户特征模型的融合

为了更好地学习用户的特征向量,需要同时考虑用户自身偏好和用户在社交网络中其他用户对其的影响。本文通过一个标准的 MLP 将用户在项目空间的特征向量 \mathbf{h}_i^I 和社交空间的特征向量 \mathbf{h}_i^S 相结合,如图 4 所示,组合成用户最终的特征向量 \mathbf{h}_i , 其表达式为:

$$\mathbf{n}_1 = [\mathbf{h}_i^I \oplus \mathbf{h}_i^S] \quad (19)$$

$$\mathbf{n}_2 = \sigma(\mathbf{W}_2 \cdot \mathbf{n}_1 + b_2) \quad (20)$$

⋮

$$\mathbf{h}_i = \sigma(\mathbf{W}_l \cdot \mathbf{n}_{l-1} + b_l) \quad (21)$$

其中, l 表示神经网络隐藏层的层数, \mathbf{W} 是权重, b 是偏置, \oplus 表示两个向量间的级联运算。

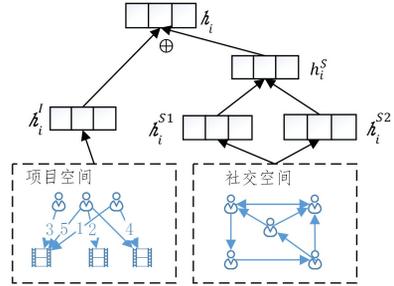


图 4 用户特征结构图

Fig. 4 Structure diagram of user feature

3.2 物品特征模型

3.2.1 用户空间的物品特征

每个物品有多个用户为其评分,构成了一个物品-用户网络,通过提取来自不同用户的意见可以捕捉到同一物品的特征,有助于对物品特征进行建模。用户空间的物品特征 \mathbf{z}_j 通过将与之交互的用户聚合起来得到,可表示为:

$$\mathbf{z}_j = \sigma(\mathbf{W} \cdot \text{Aggre}_{\text{users}}(\{\mathbf{f}_{ji}, \forall i \in B(j)\}) + b) \quad (22)$$

其中, $B(j)$ 表示与物品 v_j 交互的用户集合, \mathbf{W} 和 b 是权重和偏置, σ 是非线性激活函数, $\text{Aggre}_{\text{users}}$ 表示与项目 v_j 交互的用户聚合函数, \mathbf{f}_{ji} 表示用户 u_i 与项目 v_j 的交互行为的特征表示,通过一个 MLP 对用户交互信息 \mathbf{p}_i 和评分交互信息 \mathbf{e}_r 进行合并来得到 \mathbf{f}_{ji} :

$$\mathbf{f}_{ji} = g_u([\mathbf{p}_i \oplus \mathbf{e}_r]) \quad (23)$$

其中, \oplus 表示两个向量间的级联运算, g_u 表示多层感知机。为了区分不同用户的重要性,引入一个两层神经注意力网络来给用户赋予权重 μ_{ji} , 其表达式为:

$$z_j = \sigma(\mathbf{W} \cdot \{ \sum_{i \in B(j)} \mu_{ji} f_{ji} \} + b) \quad (24)$$

$$\mu_{ji}^* = \mathbf{W}_2^T \cdot \sigma(\mathbf{W}_1 \cdot [f_{ji} \oplus \mathbf{q}_j] + b_1) + b_2 \quad (25)$$

$$\mu_{ji} = \frac{\exp(\mu_{ji}^*)}{\sum_{i \in B(j)} \exp(\mu_{ji}^*)} \quad (26)$$

其中, \mathbf{q}_j 是物品 v_j 的嵌入向量, μ_{ji}^* 为注意力得分, $\mathbf{W}, \mathbf{W}_1, \mathbf{W}_2$ 是权重, b, b_1, b_2 是偏置, \oplus 表示两个向量间的级联运算。

3.2.2 结合用户偏好的物品相似性特征

大多数基于社交网络的推荐算法仅关注用户间的信任关系。诚然, 用户间的社交关系对目标用户兴趣偏好的影响十分重要, 但作为唯一的考虑因素可能就有片面。因此, 在社交推荐中引入具有用户偏好的物品相似性向量, 与用户空间的物品特征向量结合来弥补传统社交推荐的缺陷。

本文认为被多个用户共同评分且评分较高的物品之间具有用户偏好相似性。因此, 首先构建物品-物品相似网络, 如图 5 所示。图 5 中, 圆代表物品节点, 边的权重 n 代表两个物品被 n 个用户共同给了较高的评分。

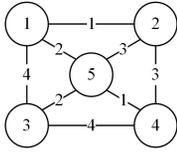


图 5 物品-物品相似网络

Fig. 5 Item-item similar network

采用 Node2vec 算法学习物品-物品相似网络的隐藏信息, 将网络中的各个物品节点表示为包含相似性信息的向量, 具体过程如下。

首先, 使用 Node2vec 算法改进后的有偏随机游走模型在物品-物品相似网络上进行有概率地游走, 将生成的序列看作由单词组成的句子; 然后, 使用 word2vec 中的 Skip-gram 模型对序列进行训练得到物品节点的相似性向量 s_j 。Skip-gram 模型的隐藏层和输出层之间采用全连接的方式, 并且随机游走生成的单词序列也十分庞大, 这意味着 Skip-gram 神经网络会有规模非常大的权重矩阵, 通过反向传播来调整这些权重需要消耗大量计算资源, 且训练起来非常慢。本文采用负采样的方式, 在训练一个样本时每次只更新部分权重, 以此来减少计算量。而权重是否被更新取决于权重相关的节点出现的频次, 节点出现的频次越高, 与该节点相关的权值被更新的概率就越大。

3.2.3 物品特征模型的融合

为了更好地学习物品的特征向量, 本文通过一个 MLP 来结合物品特征和相似性向量, 如图 6 所示, 利用相似性向量 s_j 来约束物品特征 z_j , 组合成物品最终的特征向量 h_j , 具体表达式为:

$$\mathbf{k}_1 = [\mathbf{z}_j \oplus \mathbf{s}_j] \quad (27)$$

$$\mathbf{k}_2 = \sigma(\mathbf{W}_2 \cdot \mathbf{k}_1 + b_2) \quad (28)$$

⋮

$$\mathbf{h}_j = \sigma(\mathbf{W}_l \cdot \mathbf{k}_{l-1} + b_l) \quad (29)$$

其中, l 表示神经网络隐藏层的层数, \mathbf{W} 是权重, b 是偏置, \oplus 表示两个向量间的级联运算。

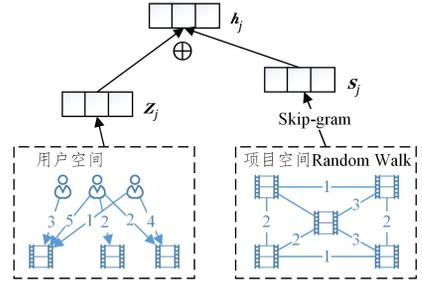


图 6 物品特征结构图

Fig. 6 Structure diagram of item feature

3.3 评分预测模型

本文将提出的 SocialIS 算法应用于评分预测的推荐任务中。将前面求得的用户特征向量 \mathbf{h}_i 和物品特征向量 \mathbf{h}_j 通过 MLP 结合来进行评分预测, 表达式为:

$$\mathbf{g}_1 = [\mathbf{h}_i \oplus \mathbf{h}_j] \quad (30)$$

$$\mathbf{g}_2 = \sigma(\mathbf{W}_2 \cdot \mathbf{g}_1 + b_2) \quad (31)$$

⋮

$$\mathbf{g}_l = \sigma(\mathbf{W}_l \cdot \mathbf{g}_{l-1} + b_l) \quad (32)$$

$$r'_{ij} = \mathbf{w}^T \cdot \mathbf{g}_l \quad (33)$$

其中, l 是隐藏层的层数, \mathbf{W} 是权重, b 是偏置, σ 表示非线性激活函数, \oplus 表示两个向量间的级联运算, 而 r'_{ij} 代表预测的用户 u_i 对物品 v_j 的评分。

4 实验结果和分析

本节主要展示本文算法与其他相关算法的实验结果。首先列出实验的数据集和评价方法, 然后给出实验的参数调优, 最后将本文算法与其他算法进行对比, 分析本文算法的性能。

4.1 数据集与实验环境

为了评估本文算法的性能, 本实验采用两个数据集: Epinions 数据集和 Ciao 数据集。Epinions 和 Ciao 是两个著名的点评网站, 数据集中包含了用户的评分信息和社交信息。用户可以免费注册并为许多不同类型的项目进行评分, 评分的范围是 1-5 分 (1 表示“不喜欢”, 5 表示“喜欢”), 评分信息包含用户信息、物品信息以及评分 (如用户 a -物品 j -4 表示用户 a 给物品 j 的评分为 4 分)。同时, 用户可以关注其他用户, 与其他用户建立信任关系。两个数据集中用户间的信任关系是单向的, 且用二值表示 (如用户 a -用户 b -1), 1 表示用户 a 信任用户 b , 其中用户 a 是信任者, 而用户 b 是被信任者; 0 表示两者不存在信任关系。两个数据集的具体数据如表 1 所列。

表 1 Epinions 和 Ciao 数据集统计

Table 1 Epinions and Ciao dataset statistics

数据集	Epinions	Ciao
用户数量	49 290	7 375
物品数量	139 738	106 797
评分记录	664 824	284 086
信任记录	48 7181	111 781
评分稀疏度/%	0.0965	0.0361
信任稀疏度/%	0.0707	0.0142

实验环境为 Intel (R) Core (TM) i7-7700HQ CPU @ 2.80 GHz 处理器和 8GB 内存, Windows10 64 位操作系统,

运用 Python 编程语言,通过深度学习框架 Pytorch 搭建神经网络。对于每个数据集,使用 $x\%$ 的数据作为训练集, $(1-x\%)/2$ 的数据作为验证集,剩下的 $(1-x\%)/2$ 作为最终性能比较的测试集,其中 x 取 60% 和 80% 。

4.2 评价方法

本文算法的任务是预测用户对物品的评分,预测评分与实际评分的误差越小,说明本文算法的性能越好。因此,评价指标采用被广泛应用的两个精确度指标,平均绝对误差 (Mean Absolute Error, MAE) 和均方根误差 (Root Mean Squared Error, RMSE) 的计算式如下:

$$MAE = \frac{\sum_{(u_i, v_j)} |r_{ij} - r'_{ij}|}{N} \quad (34)$$

$$RMSE = \sqrt{\frac{\sum_{(u_i, v_j)} (r_{ij} - r'_{ij})^2}{N}} \quad (35)$$

其中, N 是测试集中的评分数据的集合, r_{ij} 是用户 u_i 对物品 v_j 的实际评分, r'_{ij} 是用户 u_i 对物品 v_j 的预测评分。

4.3 比较方法

为了评估本文提出的结合物品相似性的信任推荐算法的推荐性能,本实验将 SocialIS 算法与目前主流的社交网络推荐算法进行了比较,主要的比较方法包含如下几种。

(1) PMF。该算法采用了概率矩阵分解的方法,并利用高斯分布对用户和项目的潜在特征进行建模,是最基本的推荐算法^[17]。

(2) SoRec。Ma 等^[10]于 2008 年提出了 SoRec 模型,通过共享分解评分矩阵和用户社交矩阵后得到的用户特征矩阵来得到结合社交关系的推荐。

(3) SoReg。社会化正则模型,将网络信息作为正则化项来约束矩阵分解框架,并采用评分相似性来度量用户之间的信任度^[18]。

(4) SocialMF。Jamali 等^[11]于 2010 年提出了 SocialMF 模型,在矩阵分解中引入信任传播,令目标用户的兴趣偏好与其邻居用户的平均偏好相似,弥补了 SoRec 模型的缺陷。

(5) TrustMF。该算法由 Yang 等^[19]提出,将用户映射为两个低维空间(信任者空间和被信任者空间),根据信任的方向性对信任网络进行分解。

(6) DeepSoR。该算法将深度学习应用于社交网络的推荐中,学习用户的特征并集成到概率矩阵分解中进行评分预测^[20]。

(7) GraphRec。该算法由 Fan 等^[21]提出,利用图神经网络从社交和项目空间学习用户特征和项目特征,并进行评分预测。

4.4 参数调优

分别选取 embedding size 的值为 $[8, 16, 32, 64, 128, 256]$ 进行测试,最终选择了 64 维的大小。分别选取 batch size 的值为 $[32, 64, 128, 256]$ 进行测试,通过实验进行比较,选择了 128 的 batch size。对于式(18)中的 ω ,经过实验验证, ω 取 0.8。同样地,在经过大量的实验对比后,学习率取 0.0004,激活函数采用线性整流函数(Rectified Linear Unit, Relu)。

4.5 实验结果与分析

4.5.1 对比实验

本文选择 MAE 和 RMSE 作为评价指标,并采用了不同的数据集和不同规模的训练集,在进行多次实验并与其他模型对比后,实验结果如表 2 所列。

(1) 从 PMF, SoRec, SoReg, SocialMF 和 TrustMF 的实验结果中可以发现,加入了社交网络数据的后几种算法的 MAE 和 RMSE 明显比只考虑了用户历史评分行为数据而没有加入社交网络数据的 PMF 算法低,评分预测误差更小,这表明充分利用社交网络中的用户信任信息能有效提升推荐系统的推荐性能。

(2) 从 TrustMF 和 SoRec, SoReg, SocialMF 的结果比较可以看出,加入了信任和被信任双向信任关系的 TrustMF 算法的 MAE 和 RMSE 的误差值小于其他没有考虑用户角色的基于社交网络推荐的算法,这说明了在社交推荐中考虑用户角色(信任者和被信任者)的影响能有效提升推荐性能。

表 2 不同算法的实验结果

Table 2 Experimental results of different algorithms

Model	Ciao(60%)		Ciao(80%)		Epinions(60%)		Epinions(80%)	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
PMF	0.961	1.1984	0.9116	1.1205	1.0318	1.3119	1.0032	1.2214
SoRec	0.8563	1.0798	0.8385	1.0692	0.9165	1.1897	0.8978	1.1425
SoReg	0.8972	1.1147	0.8618	1.0873	0.9312	1.1986	0.9121	1.1756
SocialMF	0.8423	1.0975	0.8287	1.0611	0.8875	1.1510	0.8668	1.1028
TrustMF	0.7998	1.0844	0.7897	1.0779	0.8686	1.1458	0.8460	1.1355
DeepSoR	0.7886	1.0737	0.7736	1.0376	0.8572	1.1167	0.8353	1.0672
GraphRec	0.7540	1.0093	0.7387	0.9794	0.8441	1.0878	0.8168	1.0631
SocialIS	0.7262	0.9956	0.7176	0.9465	0.8142	0.9978	0.7942	0.9842

(3) 从 DeepSoR 和 SoRec, SoReg, SocialMF 这几种算法的实验结果比较可以看出, DeepSoR 算法的 MAE 和 RMSE 明显低于其他几种算法,推荐效果更好。这 4 种算法都利用了用户对物品的评分信息和社交网络信任信息,但是 DeepSoR 采用了神经网络结构,说明神经网络模型在推荐系统算法的研究中起到了提升作用。

(4) 从 DeepSoR 和 GraphRec 算法的实验结果比较可以

看到, GraphRec 算法的 MAE 和 RMSE 都低于 DeepSoR 算法,两者都利用了用户对物品的评分信息和社交网络信任信息,且都是基于神经网络结构的,但是 GraphRec 模型采用了图神经网络(GNN)来进行训练,最后的评分预测更准确,这也充分说明了 GNN 在图形数据表示学习方面具有强大的能力。

(5) 观察实验结果可知,本文提出的 SocialIS 模型与其他

模型相比,其 MAE 和 RMSE 均低于其他模型,说明本文提出的 SocialIS 算法在加入了用户角色和带有用户偏好的物品相似性约束后能有效提升推荐模型的性能,并且对于不同的数据集, SocialIS 算法均优于其他算法,进而验证了算法具有较好的鲁棒性,对特定的数据集并没有明显的偏向性。

4.5.2 消融实验

本文算法对用户特征和物品特征这两方面进行了改进。在用户特征方面,考虑了用户作为信任者和被信任者两种角色时对用户特征的影响;在物品特征方面,引入了包含用户偏好的物品相似性来对物品特征进行约束。因此,为了测试每

一部分的改进对最终结果的影响,本文对两个部分进行了消融实验,实验结果如表 3 所列,其中 SocialIS-s 模型只加了带有用户偏好的物品相似性约束的改进,而 SocialIS-t 模型是仅加入了用户作为信任者和被信任者时的改进模型。

从表 3 可以看出, Social-s 和 Social-t 模型的 MAE 和 RMSE 误差均小于加入了两个改进前的模型,这说明两部分改进对推荐算法均有提升作用。而同时结合了两种改进的 SocialIS 算法的评分预测误差也小于分别只加入一个改进的 Social-s 和 Social-t 模型,这表明将对用户特征和物品特征的两个改进相结合,推荐算法的性能提升会更大。

表 3 两个数据集上的消融实验分析

Table 3 Ablation analysis on two datasets

Model	Ciao(60%)		Ciao(80%)		Epinions(60%)		Epinions(80%)	
	MAE	RMSE	MAE	RMSE	MAE	RMSE	MAE	RMSE
PMF	0.961	1.1984	0.9116	1.1205	1.0318	1.3119	1.0032	1.2214
SocialMF	0.8423	1.0975	0.8287	1.0611	0.8875	1.1510	0.8668	1.1028
GraphRec	0.7540	1.0093	0.7387	0.9794	0.8441	1.0878	0.8168	1.0631
SocialIS-t	0.7296	1.0068	0.7224	0.9642	0.8186	1.0428	0.8034	1.0458
SocialIS-s	0.7300	1.0112	0.7252	0.9678	0.8223	1.0654	0.8048	1.0624
SocialIS	0.7262	0.9956	0.7176	0.9465	0.8142	0.9978	0.7942	0.9842

4.6 探究信任与被信任关系权重的影响

用户作为信任者和被信任者时对其兴趣的影响是有区别的。为了更好地观察公式 $h_i^s = (1-\omega)h_i^{s1} + \omega h_i^{s2}$ 中权重 ω 对推荐结果的影响,本文在 Epinions 和 Ciao 数据集上进行了多次实验,实验结果如图 7 所示,横坐标代表 ω ,纵坐标是 MAE 误差值。

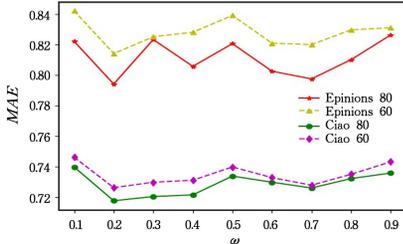


图 7 不同权重 ω 对评分预测的影响

Fig. 7 Impact of different ω weights on score prediction

从图 7 可以看出,在训练集分别占 60%,80% 的 Epinions 数据集和 Ciao 数据集中,目标用户在作为被信任者的情况下,信任该目标用户的邻居用户对目标用户特征的影响权重 ω 为 0.2 时,评分预测的误差最小,推荐性能最好,说明用户作为不同角色时对推荐系统的影响是有区别的,不能简单地定为同等影响。

在引入用户作为被信任者的影响后,评分预测的误差相比引入前明显减小,说明利用信任者和被信任者两种角色对用户特征加以约束能明显提升推荐系统的性能,同时在影响权重 ω 的值为 0.1 或 0.9 时,误差普遍较其他值时高,说明信任和被信任关系两者在算法中都不能被忽略,都会对实验结果产生一定影响。

4.7 探究嵌入维度对算法的影响

本文算法采用图嵌入技术获得初始向量。图嵌入是一种将高维的图数据映射为低维稠密向量的过程,而向量空间中还应保持连接的节点彼此靠近。因此,采用不同的嵌入维度

时,算法的结果也不尽相同,实验分别选取了 [8, 16, 32, 64, 128, 256] 维进行实验,实验结果如图 8 所示。

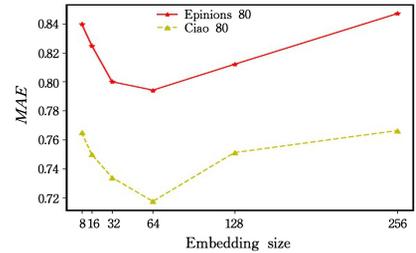


图 8 不同嵌入维度对评分预测的影响

Fig. 8 Impact of different embedding size on score prediction

从图 8 可以看出,随着嵌入维度的增大,评分误差先减小再增大,即推荐算法的性能先提升再降低。嵌入维度从 8 增加到 64 维时,MAE 误差明显减小,而从 64 维增加到 256 维时,MAE 误差又逐渐增加。

实验结果表明,嵌入维度采用一个较大的值时,能很好地表示物品和用户的深层特征,有助于提升推荐算法的性能。但是,当嵌入维度增大到一定维度时,特征的表示过于细致,模型的复杂度会显著增加,导致算法性能下降。

因此,实验时不是维度越大越好,需要进行多种嵌入维度的对比实验,选择最适合的维度。在本实验中,维度为 64 时算法的性能最好。

结束语 为了提升推荐系统的性能,本文将社交网络中用户间的信任信息作为辅助信息与用户的历史评分信息相结合,深入研究了信任关系和用户历史行为信息对用户评分产生的影响,从而提出了结合物品相似性的社交信任推荐算法。与已有的算法相比,本文结合图神经网络提出了一种考虑用户角色和物品相似性的推荐算法。首先,本文提出的 SocialIS 算法充分考虑了用户作为不同角色(信任者和被信任者)时对其评分的影响,同时加入了具有用户偏好的物品相似性向量来对物品的特征进行约束,从两方面进行改进以得到更深层

的用户特征和物品特征,从而提高推荐算法的精度。在 Epinions 和 Ciao 公开数据集上的大量实验表明,本文提出的结合物品相似性的社交信任推荐算法能够有效地提升推荐系统的性能,降低评分预测的误差。

目前,我们的研究针对的还是静态数据,如何通过图神经网络捕获动态数据来进行推荐是下一步的研究重点。同时,未来的工作还将考虑结合用户评论对用户特征和物品特征进行进一步的刻画,从而继续完善本文算法的评分预测技术。

参 考 文 献

- [1] ZHOU W Z, CAO D, XU Y F, et al. Review of Recommendation System Research[J]. Journal of Hebei University of Science and Technology, 2020, 41(1): 76-87.
- [2] DU D F, XU T, LU Y N, et al. User Rating Prediction Based on Probability Matrix Decomposition under Trust Mechanism[J]. Journal of Software, 2018, 29(12): 3747-3763.
- [3] WANG G X, LIU H P. Summary of personalized recommendation system[J]. Computer Engineering and Applications, 2012, 48(7): 66-76.
- [4] JANNACH D, ZANKER M, FELFERNIG A, et al. Recommender Systems: An Introduction [M]. Cambridge University Press, 2010.
- [5] MA W K, LI G, LI Z Y, et al. A Top-N personalized recommendation algorithm based on tags[J]. Computer Science, 2019, 46(S2): 224-229.
- [6] CHEN H. The Impact of Comments and Recommendation System on Online Shopper Buying Behaviour[J]. Journal of Networks, 2012, 7(2): 345-350.
- [7] GUO L, MA J, CHEN Z M. A social recommendation algorithm sensitive to the strength of trust relationship[J]. Computer Research and Development, 2013, 50(9): 1805-1813.
- [8] LI Y S, SONG M N, E H H, et al. Social recommendation algorithm fusing user interest social network[J]. Journal of China Universities of Posts & Telecommunications, 2014, 21(14): 26-33.
- [9] WANG W H, ZENG Y. Collaborative filtering recommendation algorithm based on clustering and user preference[J]. Computer Engineering and Applications, 2020, 56(3): 68-73.
- [10] MA H, YANG H X, LYU M R, et al. SoRec: social recommendation using probabilistic matrix factorization[C]// Proceedings of the 17th ACM Conference on Information and Knowledge Management. Association for Computing Machinery, 2008: 931-940.
- [11] JAMALI M, ESTER M. A matrix factorization technique with trust propagation for recommendation in social networks[C]// Proceedings of the fourth ACM conference on Recommender systems. Association for Computing Machinery, 2010: 135-142.
- [12] XIANG C G, XIONG S H, WANG D, et al. Social Friend Recommendation Algorithm Based on Association Rules and Similarity[J]. Computer Engineering, 2019, 45(4): 175-180.
- [13] LONG Z Y, CHEN Z G, XU C L. Social Network Friend Recommendation Algorithm Based on User Interaction[J]. Computer Engineering, 2019, 45(3): 132-137.
- [14] HAN N, QIAO S J, YUAN C A, et al. A Fast Parallel Community Detection Algorithm for Mobile Social Networks[J]. Journal of Chongqing University of Technology (Natural Science), 2020, 34(1): 94-102.
- [15] PAN Y T, HE F Z, YU H P. A social recommendation algorithm based on implicit similarity of trust relationships[J]. Chinese Journal of Computers, 2018, 41(1): 65-81.
- [16] HUANG L W, JIANG B T, LV S Y, et al. Research review of recommendation system based on deep learning [J]. Chinese Journal of Computers, 2018, 41(7): 1619-1647.
- [17] SALAKHUTDINOV R, MNH A. Probabilistic Matrix Factorization[C]// Proceedings of the 20th International Conference on Neural Information Processing Systems. 2007: 1257-1264.
- [18] MA H, ZHOU D, LIU C, et al. Recommendation system with social regularization[C] // Proceedings of the 4th ACM International Conference on Web Search and Data Mining. Hong Kong, China, 2011: 287-296.
- [19] YANG B, LEI Y, LIU J, et al. Social collaborative filtering by trust[J]. IEEE Transactions on Software Engineering, 2016, 39(8): 1633-1647.
- [20] FAN W Q, LI Q, CHENG M. Deep modeling of social relations for recommendation[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2018: 8075-8076.
- [21] FAN W Q, MA Y, LI Q, et al. Graph Neural Networks for Social Recommendation[C]// The World Wide Web Conference. Association for Computing Machinery, 2019: 417-426.



YU Ai-xin, born in 1996, postgraduate, is a member of China Computer Federation. Her main research interests include recommendation system and data mining.



FENG Xiu-fang, born in 1966, Ph. D., professor, is a member of China Computer Federation. Her main research interests include artificial intelligence, Internet of things and cloud computing.