

基于改进加权二部图和用户信任度的协同过滤推荐算法^①



邓小燕¹, 张晓彬²

¹(重庆医药高等专科学校 医学技术学院, 重庆 401331)

²(重庆农村商业银行 科技信息部, 重庆 400023)

通讯作者: 张晓彬, E-mail: 175075043@qq.com

摘 要: 基于复杂网络物质扩散原理的二部图理论在协同过滤推荐领域的应用受到越来越多学者的关注, 现有算法计算邻居用户时主要考察用户对项目的正向评价, 未充分考虑用户的负向评价. 为进一步提高推荐算法的准确度, 提出了改进算法, 将用户正向评价和负向评价量化成二部图上的路径权重, 控制用户能量的分配, 并在邻居用户预测评分阶段考虑用户的信任度, 推荐结果更加准确. 采用 MovieLens 和 Eachmovie 数据集对改进算法以及现有算法进行对比实验分析, 证明改进算法具有更低的平均绝对偏差.

关键词: 协同过滤; 二部图; 信任度; 平均绝对偏差

引用格式: 邓小燕, 张晓彬. 基于改进加权二部图和用户信任度的协同过滤推荐算法. 计算机系统应用, 2019, 28(5): 125-130. <http://www.c-s-a.org.cn/1003-3254/6874.html>

Collaborative Filtering Recommendation System Based on Improved Bipartite Graph and User Reliability

DENG Xiao-Yan¹, ZHANG Xiao-Bin²

¹(Medical Technology Department, Chongqing Medical and Pharmaceutical College, Chongqing 401331, China)

²(Science and Technology Information Department, Chongqing Rural Commercial Bank, Chongqing 400023, China)

Abstract: The application of bipartite graph theory in collaborative filtering recommendation based on substance diffusion theory of complex networks has attracted more and more attention from scholars. Existing algorithms mainly consider the positive rating when calculating neighbor users, ignoring the negative rating of users. In order to improve the accuracy of recommendation algorithm, a collaborative filtering recommendation algorithm based on improved bipartite graph and user reliability is proposed. The algorithm quantifies both positive ratings and negative ratings into the weight of the path, which controls the user's energy distribution, and takes users' reliability into account when predicting the rating, therefore, the accuracy of recommendation result is significantly improved. A series of comparative experiments are carried out on MovieLens and Eachmove datasets. The experimental results show that the improved algorithm has lower mean absolute error.

Key words: collaborative filtering; bipartite graph; reliability; mean absolute error

协同过滤算法通过计算用户的兴趣相似性, 筛选兴趣最相近的用户为邻居为用户推荐商品, 是推荐系统研究的热点^[1,2]. 有学者将物质扩散和热传导理论^[3-5]

应用于协同过滤推荐技术, 取得了很好的效果, 典型的是基于二部图的协同过滤推荐研究, 该算法令能量在“用户-项目”以及“项目-其他用户”间扩散, 扩散完成后

① 收稿时间: 2018-11-06; 修改时间: 2018-11-23; 采用时间: 2018-11-27; csa 在线出版时间: 2019-05-01

即获取到准确的邻居用户, 预测评分更加准确, 已经成为协同过滤领域研究的一个新方向^[6], 不断有学者在此基础上研究新的改进措施来进一步提高推荐的准确度. 文献[7]提出了一种基于随机森林修正的加权二部图推荐算法, 首先建立评分权重矩阵, 再用二部图做能量分配, 获取到初始推荐结果, 最后采用随机森林对推荐结果进行再次修正, 提高了推荐的准确度; 文献[8]提出了一种利用差异路径权重控制能量传递的二部图算法, 该算法在第一阶段能量传递时采用用户相似性作为路径权重, 使与目标用户相似的用户节点获得更多的能量; 在第二阶段采用项目属性的相似性作为路径权重, 使与目标用户已购项目具有相似属性的项目获得更多的能量, 达到了提高推荐结果多样性的目标; 文献[9,10]综合考虑项目度、用户评分标准信息和时间动态因素, 对二部图上的用户-项目关联关系做了加权处理, 推荐列表的平均绝对偏差和均方根误差都有明显下降.

1 基于加权二部图的协同过滤推荐算法

二部图是图论中的一种特殊的无向图, 图中顶点集合 V 被划分成 V_1 和 V_2 两部分, 且 $V_1 \cap V_2 = \varphi$, 图中的每条边所关联的两个顶点都分别属于这两个顶点集^[11-13]. 二部图应用于协同过滤推荐研究时, 将用户 $U = \{u_1, u_2, u_3, \dots, u_p\}$ 和项目 $I = \{i_1, i_2, i_3, \dots, i_q\}$ 作为图中两个不相交的集合, 用户 u_w 选择过项目 i_k 则在用户和项目间连一条边 a_{wk} ^[14]. 基于二部图的协同过滤推荐算法^[3] (BNCF) 通过两次能量分配计算邻居用户, 假定每个用户有一单位的能量, 第一次分配时用户把自己的能量平均分配给与其有连边的项目; 第二次分配时每个项目把自己获得的能量平均分配回与其有连边的用户; 经过两次能量分配后, 用户能量被分散到与其有共同项目顶点连边的用户节点上, 用户获得的能量越多, 说明用户间兴趣越相似^[15], 用户 u_v 从用户 u_w 获得的能量用 eng_{wv} 表示, 计算方法如式 (1) 所示.

$$eng_{wv} = \frac{1}{d(u_v)} \sum_{k=1}^q \frac{a_{wk} a_{vk}}{d(i_k)} \quad (1)$$

其中, $d(u_v)$ 代表用户 u_v 选择过的项目数, 即二部图中 u_v 顶点的度; $d(i_k)$ 代表项目 i_k 被多少用户选择过, 即二部图中 i_k 的度; a_{wk} 代表用户 u_w 和项目 i_k 间是否有连边, 若有, 则 $a_{wk} = 1$; 若没有, 则 $a_{wk} = 0$. eng_{wv} 越高表示用户 u_v 和用户 u_w 共同选择过的项目数越多, 兴趣越相似. 按照 eng_{wv} 由高到低排列, 选取前 M 个用户作为邻居用

户. 最后, 由邻居用户对当前用户进行推荐, 计算用户 u_w 对项目 i_k 的评分 r_{wk} 的方法如式 (2) 所示.

$$r_{wk} = \frac{\sum_{v=1, v \neq w}^p eng_{wv} a_{vk}}{\sum_{v=1, v \neq w}^p eng_{wv}} \quad (2)$$

按 r_{wk} 值由高到低排列, 取前 N 项作为对用户的最终推荐.

BNCF 算法在建立用户-项目模型时仅考虑用户是否选择过项目, 用户选择过某一个项目则说明用户对该项目有偏好. 这种假设具有很大的局限性, 仅适用于粗略的用户偏好统计, 在基于用户评分的体系中, 用户偏好划分更加精细, BNCF 算法的推荐结果就不再准确. 例如在一个 5 分等级的评价系统中, 用户对某一个项目给出 5 分的评价说明用户喜欢该项目, 若用户对某一个项目给出 2 分的评价, 则不能再认为用户喜欢该项目. 为避免低分评价对判断用户偏好的影响, 部分学者提出忽略低分评价、只考虑高分评价的算法, 这种算法更加符合用户偏好的实际, 能取得更加准确的评分预测结果. 更进一步地, 部分学者认为低分评价中也具有参考意义, 不应该直接丢弃, 提出基于加权二部图的协同过滤推荐算法, 其中典型的是基于参数化的加权二部图算法 (PB-BNCF) 和基于比例的加权二部图算法 (RB-BNCF).

1.1 基于参数化的加权二部图算法

基于参数化的加权二部图算法对图中每条用户-项目的连边赋予一个权值 e , 当用户 u_w 未评价过项目 i_k 时, $e_{wk} = 0$; 当用户 u_w 对项目 i_k 评分大于等于 3 时, $e_{wk} = 1$; 当用户 u_w 对项目 i_k 评分小于 3 时, $e_{wk} = \lambda$, 其中 λ 为可调因子, 用于调节低分对推荐结果的影响, 取值在 0 和 1 之间, 当 λ 取值为 0 时, 算法变成忽略低分评价的算法; 当 λ 取值为 1 时, 算法变成只考虑用户是否评价过项目的算法. 用户 u_v 和用户 u_w 相似性使用式 (3) 计算.

$$eng_{wv} = \frac{1}{f(u_v)} \sum_{k=1}^q \frac{e_{wk} e_{vk}}{f(i_k)} \quad (3)$$

其中, 函数 f 表示对图中某一点有连边的权值进行求和, 即 $f(u_v) = \sum_{k=1}^q e_{vk}$; $f(i_k) = \sum_{v=1}^p e_{vk}$.

计算用户 u_w 对项目 i_k 的评分 r_{wk} 的方法如式 (4).

$$r_{wk} = \frac{\sum_{v=1, v \neq w}^p eng_{wv} \cdot e_{vk}}{\sum_{v=1, v \neq w}^p eng_{wv}} \quad (4)$$

PB-BNCF 算法使用参数 λ 作为调节因子, 控制低分评价对用户偏好的影响, 起到了提高推荐准确度的效果, λ 取值大小与数据集关系较大, 需要通过大量数据分析取得适合具体数据集的最佳 λ 值。

1.2 基于比例的加权二部图算法

基于比例的加权二部图算法考虑用户评分习惯问题, 部分用户可能习惯性地给所有项目高分, 而部分用户习惯性地给所有项目低分, 单纯地以某一个绝对分值来判定用户偏好不准确, 因此提出先对用户评分数据按照式(5)进行处理。

$$t_{wk} = \frac{r_{wk}}{\bar{r}_{u_w}} \quad (5)$$

其中, \bar{r}_{u_w} 代表用户 u_w 的平均评分, t_{wk} 即是用户 u_w 和项目 i_k 的连边的权值, 用户 u_v 和用户 u_w 相似性使用式(6)计算。

$$eng_{wv} = \frac{1}{f(u_v)} \sum_{k=1}^q \frac{t_{wk} t_{vk}}{f(i_k)} \quad (6)$$

计算用户 u_w 对项目 i_k 的评分 r_{wk} 的方法如式(7)。

$$r_{wk} = \frac{\sum_{v=1, v \neq w}^p eng_{wv} \cdot r_{vk}}{\sum_{v=1, v \neq w}^p eng_{wv}} \quad (7)$$

RB-BNCF 算法通过数据预处理消除了用户评分习惯对分析用户偏好的影响, 并且不需要输入控制参数, 对不同数据集都有较高的推荐准确度。

2 基于改进加权二部图和用户信任度的协同过滤推荐算法

PB-BNCF 算法和 RB-BNCF 算法根据用户对项目的评分为用户-项目的连边赋予一定的权重, 当边上权重较小时, 通过这条边传递的用户能量就较少, 达到弱化低分评价对判断用户偏好的影响的目的。这两种算法的共同点将用户共同喜欢的项目作为衡量是否有共同的兴趣偏好的量化标准, 对于用户不喜欢的项目采取的是忽略或弱化影响的处理方式。但是, 不难想象,

两个用户如果共同不喜欢的项目较多, 也能说明两个用户兴趣偏好相似, 用户的低分评价也蕴含着用户偏好信息, 需要进行挖掘和分析。

2.1 评分数据处理

在本文的改进算法中, 为体现用户评分对用户喜欢或不喜欢某一个项目的判断, 需要对用户的评分用式(8)进行预处理。

$$t_{wk} = \frac{r_{wk} - \bar{r}_{u_w}}{\bar{r}_{u_w}} \quad (8)$$

其中, \bar{r}_{u_w} 表示用户 u_w 对所有项目的平均评分, t_{wk} 可能为正值, 也可能是负值。当 t_{wk} 为正值时代表用户 u_w 喜欢项目 i_k , 且 t_{wk} 值越大说明喜欢程度越高; 当 t_{wk} 为负值时代表用户 u_w 不喜欢项目 i_k , 且 t_{wk} 值越大说明不喜欢程度越高, 式(8)经简化后得到式(9), 计算得到的 t_{wk} 作为连接用户 u_w 和项目 i_k 的边上的权重。在沿权值为正值的边扩散的是用户“喜欢”的能量, 在沿权值为负值的边扩散的是用户“不喜欢”的能量。

$$t_{wk} = \frac{r_{wk}}{\bar{r}_{u_w}} - 1 \quad (9)$$

计算用户 u_v 和用户 u_w 相似性的时候需要分别计算 u_v 沿正值边获取的能量 eng^+_{wv} 和 u_v 沿负值边获取的能量 eng^-_{wv} , 计算公式如式(10)和式(11)所示。

$$eng^+_{wv} = \frac{1}{f^+(u_v)} \sum_{k=1}^q \frac{t_{wk} t_{vk}}{f^+(i_k)} \quad (10)$$

函数 f^+ 表示从某一点出发的所有边上权值为正值的权值加和, 即 $f^+(u_v) = \sum_{k=1}^q t_{vk}$, 其中 $t_{vk} > 0$; $f^+(i_k) = \sum_{v=1}^p t_{vk}$, 其中 $t_{vk} > 0$ 。

$$eng^-_{wv} = \frac{1}{f^-(u_v)} \sum_{k=1}^q \frac{|t_{wk} t_{vk}|}{f^-(i_k)} \quad (11)$$

函数 f^- 表示从某一点出发的所有边上权值为负值的权值加和的绝对值, 即 $f^-(u_v) = \sum_{k=1}^q |t_{vk}|$, 其中 $t_{vk} < 0$; $f^-(i_k) = \sum_{v=1}^p |t_{vk}|$, 其中 $t_{vk} < 0$ 。

用户 u_v 和用户 u_w 相似性采用式(12)计算。

$$eng_{wv} = \sqrt{(eng^-_{wv})^2 + (eng^+_{wv})^2} \quad (12)$$

2.2 用户信任度

为进一步提高推荐准确度, 众多学者在推荐过程中引入用户信任度。比较有代表性的是卢竹兵等人提出的基于信任网络的协同过滤推荐算法^[16], 算法认为用户的信任度具有传递性, 用户A信任用户B, 用户

B信任用户C,则认为用户A也信任用户C.根据用户的信任关系结合用户评分构建邻居用户模型,可以得到更加准确的推荐结果.分析此类算法后发现,学者还隐含地认为用户信任度具有全局性,即如果AB间有信任关系,则对用户A推荐所有领域的项目时都采用B做邻居用户,这与实际情况不符,现实情况是很难有一个用户对所有领域都熟悉,用户A在选择不同领域的项目时更倾向于咨询具体领域内的可信用户.因而本文将用户信任度的形式定义如表1所示.

表1 用户信任度表示形式

	c_1	c_2	D	c_χ	...	c_n
u_1	$T_{1,1}$	$T_{1,2}$...	$T_{1,\chi}$...	$T_{1,n}$
u_2	$T_{2,1}$	$T_{2,2}$...	$T_{2,\chi}$...	$T_{2,n}$
...
u_w	$T_{w,1}$	$T_{w,2}$...	$T_{w,\chi}$...	$T_{w,n}$
...
u_p	$T_{p,1}$	$T_{p,2}$...	$T_{p,\chi}$...	$T_{p,n}$

若用户 u_w 在领域 c_χ 下信任度 $T_{w,\chi}$ 比较高需满足两个条件,一是用户 u_w 在该领域内的评分数量比较多,二是用户的评分比较准确.

(1) 评分数量权重

本文定义评分数量因子 $\omega_{w,\chi}$ 来衡量用户 u_w 在领域 χ 下的权重,如式(13)所示.

$$\omega_{w,\chi} = \begin{cases} 1, & n_{w,\chi} \geq H \\ n_{w,\chi}/H, & n_{w,\chi} < H \end{cases} \quad (13)$$

其中, $n_{w,\chi}$ 代表用户 u_w 评价过并且属于领域 χ 的项目数量, H 为常量,通常取该领域下项目数量的一定比例(如领域下项目数量的80%),若用户 u_w 评价过领域 χ 的项目数达到 H 时,认为用户 u_w 比较可信,否则,不太可信,评分数量因子等于用户 u_w 评价过的项目数量与 H 的比值.

(2) 评分准确度权重

衡量用户 u_w 对项目 i_k 评分准确度权重 $E_{w,k}$ 采用式(14)计算.

$$E_{w,k} = 1 - \frac{|r_{wk} - \bar{r}_{i_k}|}{S} \quad (14)$$

其中, S 为项目的评分范围,若项目评分采用5分制,则 $S=5$; \bar{r}_{i_k} 代表所有用户对项目 i_k 评分的平均值.

由评分数量因素 $\omega_{w,\chi}$ 和评分准确度因素 $E_{w,k}$ 确定的用户 u_w 在领域 χ 内的信任度 $T_{w,\chi}$ 以式(15)计算.

$$T_{w,\chi} = \omega_{w,\chi} \times \frac{\sum_{k \in \chi} E_{w,k}}{|\chi|} \quad (15)$$

其中, $|\chi|$ 代表分类 χ 内的项目数量, $T_{w,\chi}$ 的取值范围是 $[0, 1]$.

2.3 评分预测

综合以上用户相似性和用户信任度的因素,计算用户 u_w 对某一未评分项目 i_k 的预测评分时用式(16)计算.

$$r_{wk} = \frac{\sum_{v=1, v \neq w, k \in \chi}^p eng_{wv} \cdot T_{w,\chi} \cdot r_{vk}}{\sum_{v=1, v \neq w}^p eng_{wv}} \quad (16)$$

2.4 推荐流程

用户在某一领域内的信任度相对比较稳定,因此采用离线方式计算用户信任度,在线推荐时将信任度矩阵作为算法输入,算法推荐流程如图1所示.

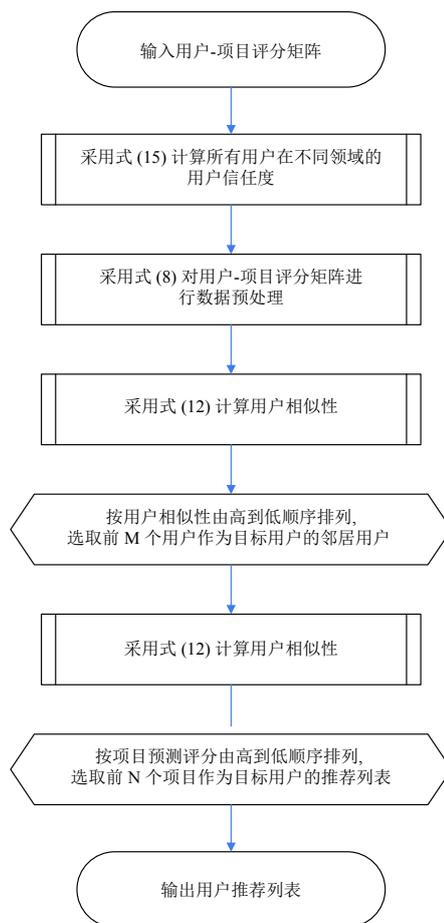


图1 本文算法推荐流程

3 实验分析

3.1 实验设计

本文采用美国 Minnesota 大学的 GroupLens 项目 MovieLens 和 Eachmovie 两个真实的电影评分数据集进行实验,其中 MovieLens 数据集中包括 943 个用户对 1682 部电影的 100 000 个评分记录,每个用户至少对 20 部电影进行了评分,评分范围为 1-5; Eachmovie 数据集中有 72 916 个用户对 1628 部电影的 2811 983 个评分记录,评分范围为 0-1,为使不同数据集的实验结果具有可比性,将 Eachmovie 数据集中的用户评分进行线性处理,使评分落在 1-5 之间.随机选取每个数据集中的 80% 作为训练集,构建协同过滤推荐模型,剩余 20% 作为测试集,检验推荐效果.

3.2 评估指标

由于改进算法着眼于提高推荐的准确度,因此采用学者最常使用的平均绝对偏差 (MAE) 来评估算法的效果. MAE 表示算法预测评分与用户实际评分之间的差距,计算对单个用户推荐准确度的方法如式 (17).

$$MAE_w = \frac{\sum_{k=1}^N |r_{wk} - r'_{wk}|}{N} \quad (17)$$

其中, N 为测试集中某一用户 u_w 评过分的的项目数量; r_{wk} 为算法预测用户 u_w 对项目 i_k 的评分; r'_{wk} 为用户 u_w 对项目 i_k 的实际评分.计算测试集中所有用户的 MAE_w 值后再取平均值即得到算法的平均绝对偏差 MAE , 算法的 MAE 值越小,说明推荐结果越准确.

3.3 实验结果分析

实验对传统二部图算法、基于参数化的加权二部图算法、基于比例的加权二部图算法以及本文改进算法进行了对比分析,采用两种数据集时各算法的推荐准确度对比情况如图 2 和图 3 所示,图中纵轴是不同算法的 MAE 值,横轴是实验中设置的邻居用户数.

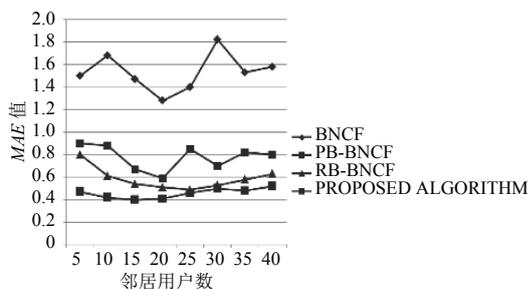


图 2 采用 MovieLens 数据集实验结果

从图 2 纵向来看, BNCf 算法在 MovieLens 数据集中预测评分结果偏差比较大, PB-BNCf 算法和 RB-BNCf 算法 MAE 值明显低于 BNCf 算法,本文提出的算法则在不同邻居用户数情况下均优于对比算法;从横向来看, BNCf 算法随着邻居用户数从 5 增加到 40, 推荐准确度呈现不稳定的表现, PB-BNCf 算法、RB-BNCf 算法以及本文提出的算法在邻居用户数较少 (5-10) 时 MAE 值相对较高, 在邻居数为 15-20 时达到最佳的推荐效果, 在邻居数超过 30 时, MAE 值趋向于稳定.

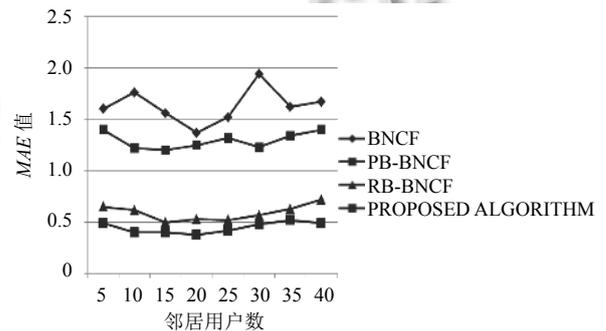


图 3 采用 Eachmovie 数据集实验结果

从图 3 可以看出, BNCf 算法在 Eachmovie 数据集上预测评分结果偏差仍然比较大,说明 BNCf 算法在基于评分的推荐系统上推荐效果不佳,对路径进行加权处理后可以明显提高推荐的准确度; RB-BNCf 在 Eachmovie 数据集上 MAE 值略有升高,可能和 Eachmovie 数据集评分稀疏度比 MovieLens 数据集高有关; PB-BNCf 算法在 Eachmovie 数据集上的 MAE 值远高于在 MovieLens 数据集上的结果,可能原因是 PB-BNCf 算法对不同数据集的最佳参数 λ 取值不同,本实验为进行实验对比分析,统一取 λ 值为 0.5,这一参数更适合 MovieLens 数据集.而本文提出的算法在 Eachmovie 数据集上依然最优.

对比各种算法在 Eachmovie 和 MovieLens 数据集的实验结果来看,本文提出的算法在不同的数据集上 MAE 值均低于其它算法,推荐效果准确且稳定.

4 总结和展望

为了提高协同过滤推荐的准确度,本文提出了一种基于改进的加权二部图和用户信任度的协同过滤推荐系统.算法充分挖掘了用户低分评价中包含的用户兴趣信息,在二部图进行能量扩散过程中同时扩散“喜欢”和“不喜欢”的能量,并结合用户在具体领域中的信

程度对项目进行预测评分. 实验结果表明, 改进算法在两种数据集上均能取得更准确的推荐结果, 算法表现稳定. 由于算法充分挖掘了隐藏的用户兴趣信息, 因而可以更进一步地解决协同过滤数据稀疏性的问题, 笔者将在接下来的工作中在此方面进行研究和探讨, 不断优化算法的推荐效果.

参考文献

- 1 李龙生, 艾均, 苏湛, 等. 结合用户行为和物品标签的协同过滤推荐算法. 计算机应用与软件, 2018, 35(6): 248–253. [doi: 10.3969/j.issn.1000-386x.2018.06.045]
- 2 赵宇峰, 李新卫. 基于歌曲标签聚类的协同过滤推荐算法的研究. 计算机应用与软件, 2018, 35(6): 259–262. [doi: 10.3969/j.issn.1000-386x.2018.06.047]
- 3 Zhou T, Ren J, Medo M, *et al.* Bipartite network projection and personal recommendation. *Physical Review E*, 2007, 76: 046115. [doi: 10.1103/PhysRevE.76.046115]
- 4 Liu JG, Wang BH, Guo Q. Improved collaborative filtering algorithm via information transformation. *International Journal of Modern Physics C*, 2009, 20(2): 285–293. [doi: 10.1142/S0129183109013613]
- 5 Zhang YC, Blattner M, Yu YK. Heat conduction process on community networks as a recommendation model. *Physical Review Letters*, 2007, 99(15): 154301. [doi: 10.1103/PhysRevLett.99.154301]
- 6 刘朋. 混合个性化推荐方法研究[硕士学位论文]. 北京: 北方工业大学, 2018.
- 7 李玲. 基于二部图的个性化推荐系统研究[硕士学位论文]. 北京: 北方工业大学, 2018.
- 8 高长元, 段文彬, 张树臣. 基于差异路径权重的二部图网络推荐算法. 计算机应用研究, 2019, (3): 1–6.
- 9 陈诚. 基于二部图的推荐算法的研究与应用[硕士学位论文]. 北京: 北京邮电大学, 2016.
- 10 王茜, 段双艳. 一种改进的基于二部图网络结构的推荐算法. 计算机应用研究, 2013, 30(3): 771–774. [doi: 10.3969/j.issn.1001-3695.2013.03.033]
- 11 曹易, 张宁. 二部图在用户-网站中的实证研究. 计算机系统应用, 2012, 21(6): 132–135. [doi: 10.3969/j.issn.1003-3254.2012.06.028]
- 12 唐敏, 关键, 邓国强, 等. 一种求解二部图最大匹配问题新算法及其应用. 计算机系统应用, 2012, 21(3): 72–75, 28. [doi: 10.3969/j.issn.1003-3254.2012.03.016]
- 13 黄波, 严宣辉, 林建辉. 基于有向图分割的推荐算法. 计算机系统应用, 2015, 24(12): 196–203. [doi: 10.3969/j.issn.1003-3254.2015.12.031]
- 14 任琛. 融入生活体验的二部图推荐算法[硕士学位论文]. 西安: 西安电子科技大学, 2017.
- 15 黄熠姿, 杨金鑫, 孙维. 基于改进二部图与专家信任的混合推荐算法. 价值工程, 2017, 36(19): 160–164.
- 16 卢竹兵, 唐雁. 一种基于信任网络的协同过滤推荐策略. 西南师范大学学报(自然科学版), 2008, 33(2): 123–126.