

# 基于重叠社区发现的社会网络推荐算法研究

胡 云<sup>1</sup>, 张 舒<sup>2</sup>, 余侃侃<sup>1</sup>, 李 慧<sup>3,4</sup>, 施 珺<sup>3</sup>

(1.南京中医药大学信息技术学院,江苏 南京 210023)

(2.淮海工学院商学院,江苏 连云港 222005)

(3.淮海工学院计算机工程学院,江苏 连云港 222005)

(4.江苏省海洋资源开发研究院,江苏 连云港 222005)

**[摘要]** 协同过滤算法已成为用来为用户提供个性化服务以处理海量信息最常用的方法之一. 本文提出一种基于重叠社区发现的社会网络推荐算法,该算法同时考虑了群组用户的兴趣以及他们复杂的内部关系,通过将重叠社区发现算法和基于模型的社会推荐算法进行创新融合,以实现重叠社区的发现、建立,和基于社区的智能推荐. 基于开放数据集,本文设计了一系列相关实验以验证算法的有效性和准确性. 实验结果表明本文提出的算法可以实现高效且准确的社会网络推荐.

**[关键词]** 社会网络,推荐,重叠,社区,检测

**[中图分类号]** TP391 **[文献标志码]** A **[文章编号]** 1001-4616(2018)03-0035-07

## Research of Social Recommendation Method Based on Overlapping Community Detection

Hu Yun<sup>1</sup>, Zhang Shu<sup>2</sup>, She Kankan<sup>1</sup>, Li Hui<sup>3,4</sup>, Shi Jun<sup>3</sup>

(1.College of Information Technology, Nanjing University of Chinese Medicine, Nanjing 210023, China)

(2.Business School, Huaihai Institute of Technology, Lianyungang 222005, China)

(3.Department of Computer Science, Huaihai Institute of Technology, Lianyungang 222005, China)

(4.Marine Resources Development Institute of Jiangsu, Lianyungang 222005, China)

**Abstract:** Collaborative filtering algorithms have become one of the most popular approaches to provide personalized services for users to deal with large amounts of information. This paper proposes a new social recommendation methods based on overlapping community discovery. The algorithm considers both the interest of the group users and their complex internal relations. In order to achieve the detection, establishment coalition of overlapping community and intelligent recommendation based on community, it innovates and integrates overlapping community discovery algorithm and social recommendation algorithm based on the model. Based on the open data set, this paper designs a series of the related experiments to validate the accuracy and effectiveness of the algorithm. Experimental results show that the proposed algorithm can achieve highly efficient and accurate social network recommendation.

**Key words:** social network, recommendation, overlapping, community, detection

社交网站的用户往往形成不同的兴趣小组和社区. 比如, Pinterest 网站的用户用不同的钉板形成时尚小组、家庭装修小组和园艺小组. Twitter 用户利用散列(hash)标签根据不同话题对 tweet 进行分组. 研究人员已经发现,根据用户社区或者分组之间的关系对用户偏好进行建模,可提高推荐算法的效率<sup>[1-3]</sup>. 部分社交媒介分析算法采用了社交网站的虚拟社区,比如在线知识社区或论坛. 然而,这些社区在许多时候难以分类. 因此,人们提出了多种社区检测算法. 作为社区结构中的一种,重叠社区中的用户可属于多个社区. 将用户分到重叠社区中,既有助于解决数据稀疏问题,也可获得不同社区的推荐,进而提高推荐的

收稿日期:2018-04-16.

基金项目:国家自然科学基金项目(81674099)、国家重点研发计划项目(2017YFC1703501、2017YFC1703503、2017YFC1703506)、连云港市科技计划项目(JC1608)、江苏高校“青蓝工程”资助项目、连云港市“521工程”科研资助、淮海工学院自然基金项目(Z2017012、Z2015012)、淮海工学院教学改革项目(XJG2017-2-5)、教育部协同育人项目(201702134005、201701028110).

通讯联系人:张舒,讲师,研究方向:智能信息处理. E-mail: shufanzs@126.com

多样性.

对于如何利用社会网络信息来提升推荐系统的准确性,很多学者进行了广泛的研究. 在文献[4]中,为了提高预测质量,Lu 等提出了一个通用的社会环境信息集成框架,将规则化的约束添加到基于文本的预测器中. 在文献[5]中,Zhou 等设计了一种具有社会规则化的矩阵分解目标函数.

该函数基于两个假设,一是每个用户的口味接近其朋友的平均口味,二是一个人的口味及喜好可能在朋友之间传播. 然而,由于数据的稀疏性,朋友之间共同评价的项目数量可能是非常小甚至为零. 为了解决这个问题,文献[6]通过采用社会化适应相似度,提高预测准确度. 在参考文献[7]中,作者从学习用户相似性、用户信息传播性、学习兴趣受限性等 3 个方面对社会矩阵分解的目标函数进行了改进,考虑了用户在特定领域的相似偏好. 在参考文献[8]中,作者建立了一个联合友谊的兴趣传播(FIP)模型,充分利用双方兴趣和友谊信息形成了一个统一的框架.

上述方法将社会信息加入到推荐模型中,提高了传统协同过滤算法的准确性,但并未考虑社区或群体对推荐模型的影响. 在同一社区的用户往往具有相同的兴趣爱好,并且有不少社区是重叠的. 因此在重叠社区检测的基础上再进行社会推荐是提高推荐精度的有效方法. 本文提出一种新的重叠社区检测的推荐算法(social recommendation based on overlapping community, SROC),以达到提高社会网络推荐性能的目标. 通过在真实世界的数据集上进行实验,验证了本文所提算法的有效性.

1 问题定义及算法框架

1.1 问题定义

假设  $U=u_1, u_2, \dots, u_n, I=I_1, I_2, \dots, I_m, U, I$  分别表示用户项和事务项. 其中  $n$  表示用户的数量,  $m$  表示事务对象的数量. 在这里,我们也有从 OSN 得来的社会信息. 并且我们使用  $G=(U, E, R)$  来表示由用户形成的网络.  $G$  的顶点表示所有的用户,如果用户  $i$  关注了用户  $j$ ,这里将是一个有向边  $(u_i, u_j) \in E$ .  $R$  代表用户历史评分矩阵,用  $r_{ij}$  来表示用户  $U_i$  对项目  $j$  的评分. 而  $R$  在实践中往往是非常稀疏的.

1.2 算法框架

SROC 算法主要分为 2 个步骤,如图 1 所示. 第一步是重叠社区发现,主要包括构建时域用户图、重叠社区检测两个环节. 第二步是在社区发现的基础上对不同重叠社区用户进行推荐,最终为各个用户生成一个 Top-N 推荐列表.

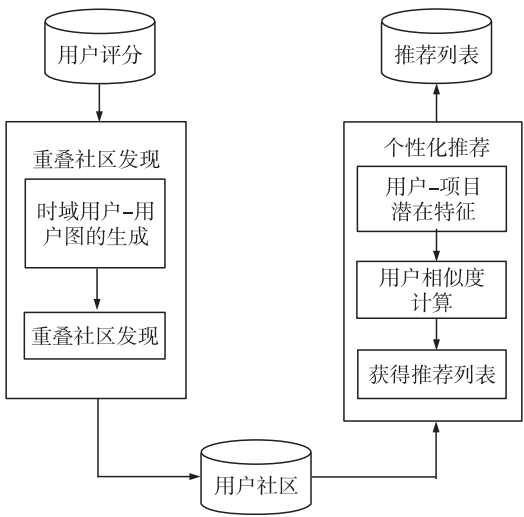


图 1 SROC 算法框架

Fig. 1 Alogrithm framework of SROC

2 重叠社区的发现

已知一组用户和一组对象,这些用户和对象间的事务关系可表示为一个用户—对象关系图,该图中的用户结点只与其感兴趣的对象相连. 请注意,本文的重点是预测用户兴趣随时间的变化. 因此,我们重点考察用户表示出兴趣的事务(而不是实际购买). 然后,可将用户—对象关系图转化为用户—用户关系图,且用户—用户关系图中两个用户间的链接表示这两个用户共同喜欢某些对象,且链接权重表示这些共同对象的数量. 考虑到用户兴趣会随着时间的变化而变化,我们假设两个用户共同事务的时间越近,这两个用户具有共同兴趣的概率越大,越会在用户—用户图中形成相应的时间加权链接.

2.1 利用时间加权链接构建用户—用户关系图

根据数据的时间标签,将训练数据集分成不同时间段的数据子集. 假设第  $i$  个用户在第  $t$  段时间对第  $j$  个对象打分,其中  $i=1, \dots, n; j=1, \dots, m; t \in \{1, \dots, TL\}$ , 用  $n$  表示用户数量,  $m$  表示事务对象的数量,  $TL$  表示训练数据集中所有事务的总时间. 如果没有事务信息或者打分低于预期阈值,则将  $t$  设置为 0.

于是,利用如下类似于遗忘曲线的函数,将事务情况表示为时间加权用户—对象矩阵  $G=[g_{ij}]_{n \times m}$ :

$$g_{ij} = \begin{cases} e^{-(T-t)/\theta_1}, & \text{若 } t > 0, \\ 0, & \text{若 } t = 0, \end{cases} \quad (1)$$

式中,  $\theta_1 > 0$  表示预先指定的实数,用于反映事务的时间效应.  $\theta_1$  数值越大,时间对用户和对象间事务的影响越小. 例如,当  $\theta_1 \rightarrow +\infty$  时,  $g_{ij} = 1$ , 时间加权用户—对象图转化为没有考虑时间效应的传统图. 然后,对具有相同对象喜好的用户间添加链路,将用户—对象图转化为时间加权用户—用户关系图. 从矩阵角度讲,可将用户—用户关系图描述为用户—用户矩阵.

$$U = G \times G^T = [u_{il}]_{n \times n}. \quad (2)$$

因此,用户间的链接反映了用户兴趣的相似度,且用户兴趣的相似度主要取决于用户共同喜欢的对象数量以及喜欢这些对象的时间. 矩阵  $U$  中的元素  $u_{il}$  表示第  $i$  个和第  $l$  个用户间的兴趣相似度,且  $u_{il} =$

$$\sum_{j=1}^m g_{ij} \times g_{jl}, \quad i = 1, \dots, n, l = 1, \dots, n$$

## 2.2 重叠社区检测

我们检测时间加权用户—用户关系图中的重叠社区之前,首先根据结点度排序来选择初始结点. 其次,我们规定社区中的结点停止增长了才能进行结点删除操作. 再次,为了避免死循环,我们规定初始结点不得删除. 利用结点度的概念来衡量结点的重要性,对用户—用户关系图有  $d_i = \sum_{l=1}^n u_{il}$ .

计算结点度并选择了初始结点后,通过使如下效用函数最大化便可实现社区检测,社区适应度的计算公式如下:

$$f_k = \frac{w_k^{\text{in}}}{(w_k^{\text{in}} + w_k^{\text{out}})^\alpha}, \quad (3)$$

式中,  $w_k^{\text{in}}$  表示第  $k$  个社区的总体内部度(internal degree),且等于第  $k$  个社区所有链接权重的两倍;  $w_k^{\text{out}}$  表示第  $k$  个社区总体外部度(external degree),且等于第  $k$  个社区内部结点和外部结点间的链路权重之和;  $\alpha \in [1, 2]$  表示预定义实数,用于控制社区规模;  $k \in \{1, \dots, K\}$  且  $K$  表示重叠社区的总体数量. 具体的重叠社区检测算法如下:

### 算法 1 重叠社区检测算法

Algorithm 1 Overlapping community detection algorithm

步骤 1: 选择整个用户—用户图中结点度最高的结点  $A$  作为起始结点;

步骤 2: 通过如下步骤检测出这个结点的自然社区(natural community):

(1) 利用被选结点对社区  $C$  初始化,将社区的初始适应度设置为 0;

(2) 确定社区  $C$  有哪些相邻结点没有包含在  $C$  中但与  $C$  中结点具有直接联系;

(3) 确定每个相邻结点对于社区  $C$  的适应度,即存在和不存在相邻结点时社区  $C$  的适应度变化. 从所有相邻结点中选择正值适应度最大的结点纳入社区  $C$ ,然后再次计算社区的适应度.

(4) 重复步骤(2)和(3),直到没有相邻结点对社区  $C$  的适应度为正;

(5) 计算  $C$  中各个结点的适应度,即包含和不包含该结点时社区  $C$  的适应度变化. 删除与社区  $C$  的适应度为负且数值最大的结点(该社区的起始结点例外),然后再次计算社区的适应度;

(6) 重复步骤(5),直到社区  $C$  中没有结点的适应度为负.

步骤 3: 如果存在部分结点未被分配到任何当前社区,则从这些结点中选择结点度最高的结点,然后跳到步骤(2);否则,输出最终社区.

## 3 SROC 推荐模型

本文具体通过概率矩阵分解技术<sup>[9-10]</sup>对用户—项目评分矩阵  $R_{u,v}$  进行矩阵分解,从而获得用户  $u$  对项目  $v$  评分的预期值. PMF 通过矩阵分解获得用户、项目两项因素的低维潜在特征矩阵. 将一个稀疏的评分矩阵  $R$  分解为两个矩阵  $U$  和  $V$  就是矩阵分解的目标,其中  $U$  和  $V$  分别表示用户特征矩阵和项目特征矩阵,这些特征是描述用户和推荐对象的关键因素. 分别取上述矩阵的一行与一列向量进行内积处理,就能够获得用户对项目评分的预测值:

$$R \approx U^T V. \quad (4)$$

在现实中,由于每个用户对项目的评分较少,因而导致用户-项目评分矩阵成为一个稀疏矩阵. 传统地使用奇异值分解(SVD)方法使评分预测误差最小,即

$$\frac{1}{2} \| \mathbf{R} - \mathbf{U}^T \mathbf{V} \|_F^2. \quad (5)$$

在等式(5)中,  $\| \cdot \|$  表示 Frobenius 标准. 但是,由于  $\mathbf{R}$  限制了许多丢失值,我们只需要将矩阵  $\mathbf{R}$  中的保留值因式分解即可. 因此,我们对等式(5)做出如下改变:

$$\min_{\mathbf{U}, \mathbf{V}} \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n I_{ij} (\mathbf{R}_{ij} - \mathbf{U}_i^T \mathbf{V}_j)^2. \quad (6)$$

在等式(6)中,如果用户  $u$  对事件  $j$  做出评级,指标函数  $I_{ij}$  就等于 1,否则  $I_{ij}$  为 0. 为了防止过度拟合问题,我们在等式(6)中加入了两个正则项. 因此,我们得到了下列目标函数:

$$\min_{\mathbf{U}, \mathbf{V}} \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n I_{ij} (\mathbf{R}_{ij} - \mathbf{U}_i^T \mathbf{V}_j)^2 + \frac{\lambda_U}{2} \| \mathbf{U} \|_F^2 + \frac{\lambda_V}{2} \| \mathbf{V} \|_F^2. \quad (7)$$

在等式(7)中,  $\lambda_U > \lambda_V > 0$ . 并且,通过二次正则化项,等式(7)最优解问题相当于对带二次正则项的误差平方和函数求最小值的问题.

在 SROC 中,由于同一社区中的用户具有相似的品味和偏好. 因此,将式(7)改进如下:

$$\min_{\mathbf{U}, \mathbf{V}} \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n I_{ij} (\mathbf{R}_{ij} - \mathbf{U}_i^T \mathbf{V}_j)^2 + \frac{\lambda_U}{2} \| \mathbf{U} \|_F^2 + \frac{\lambda_V}{2} \| \mathbf{V} \|_F^2 + \frac{\sigma}{2} \sum_{i=1}^m \left\| \mathbf{U}_i - \frac{\sum_{f \in \phi^+(i) \cap N(C_i)} \text{Sim}(i, f) \times \mathbf{U}_f}{\sum_{f \in \phi^+(i) \cap N(C_i)} \text{Sim}(i, f)} \right\|_F^2, \quad (8)$$

$$\text{Sim}(i, f) = \frac{\sum_{a \in I_i \cap I_f} (r_{ai} - \bar{r}_i)(r_{fa} - \bar{r}_f)}{\sqrt{\sum_{a \in I_i \cap I_f} (r_{ai} - \bar{r}_i)^2 \sum_{a \in I_i \cap I_f} (r_{fa} - \bar{r}_f)^2}}. \quad (9)$$

在等式(8)中,  $\phi^+(i)$  是用户  $u_i$  的外部邻居集,  $N(C_i)$  代表社区  $C_i$  中的所有成员. 参数  $\sigma$  是用于社会规范化的社会因素. 利用(9)可以求出用户相似度  $\text{Sim}(i, f)$ . 我们将公式(8)表示为  $\min_{\mathbf{U}, \mathbf{V}} \Gamma(\mathbf{R}, \mathbf{V}, \mathbf{U})$ , 并且使用梯度下降方法来进行参数的求解.

为了得到特征矢量  $\mathbf{U}$  和  $\mathbf{V}$ , 我们运用公式(10)和(11)分别对式(8)进行求导:

$$\frac{\partial \Gamma}{\partial \mathbf{U}_i} = \sum_{j=1}^n I_{ij} (\mathbf{R}_{ij} - \mathbf{U}_i^T \mathbf{V}_j) \mathbf{V}_j + \lambda_U \mathbf{U}_i + \sigma \left[ \mathbf{U}_i - \frac{\sum_{f \in \phi^+(i) \cap N(C_i)} \text{Sim}(i, f) \times \mathbf{U}_f}{\sum_{f \in \phi^+(i) \cap N(C_i)} \text{Sim}(i, f)} \right] + \sigma \sum_{g \in \phi^+(i) \cap N(C_i)} \frac{\text{Sim}(i, g) (\mathbf{U}_g - \frac{\sum_{f \in \phi^+(i) \cap N(C_i)} \text{Sim}(i, f) \times \mathbf{U}_f}{\sum_{f \in \phi^+(i) \cap N(C_i)} \text{Sim}(i, f)})}{\sum_{f \in \phi^+(i) \cap N(C_i)} \text{Sim}(g, f)}, \quad (10)$$

$$\frac{\partial \Gamma}{\partial \mathbf{V}_j} = \sum_{i=1}^m I_{ij} (\mathbf{R}_{ij} - \mathbf{U}_i^T \mathbf{V}_j) \mathbf{U}_i + \lambda_V \mathbf{V}_j. \quad (11)$$

推测出特征矩阵  $\mathbf{U}$  和  $\mathbf{V}$  后,用户  $u$  对于事件  $i$  的预估评分如下所示:

$$p_{ui} = \mathbf{U}_i^T \mathbf{V}_j. \quad (12)$$

## 4 实验与结果分析

为了验证本文提出的 SROC 算法的有效性,我们利用应用广泛的真实网络进行全面的仿真实验.

### 4.1 评估指标

我们采用了参考文献[5]中收集到的数据集. 这个数据集包含 1 290 个独立用户和 58 541 个独特的电影,拥有 16 830 839 个电影评分. 至于社交好友网络,用户之间的好友链接总数为 1 692 952. 每个用户的平均评分为 12.21,平均每部影片的用户数为 7.56. 我们将数据集分为两部分:训练集和测试集. 并且在不同的训练数据设置下,对推荐算法的性能进行了评估. 为了评测推荐算法的效率,我们将它与现有算



法,包括 UFC、ICF、ASR 进行对比分析. 在实施过程中,我们设定参数  $l=20$  以及  $\lambda_U=\lambda_V=0.5$ .

实验使用平均绝对误差(MAE),均方根误差(RMSE)作为算法性能的评价指标.

MAE(mean absolute error)表示所有单个观测值与算术平均值的偏差的绝对值,该值越小,表明推荐算法的性能越好,其定义如下:

$$MAE = \frac{\sum_{i,j} |r_{i,j} - \bar{r}_{i,j}|}{N}. \quad (13)$$

$r_{i,j}$  的含义为用户  $i$  向项目  $j$  做出的具体评分,  $\bar{r}_{i,j}$  的含义为基于应用推荐模型,用户对项目评分的预期值,  $N$  为评分样本个数.

RMSE(Root Mean Square Error)表示观测值与真值偏差的平方与观测次数  $N$  比值的平方根,该值越小,表明推荐算法的性能越好,其定义如下:

$$RMSE = \sqrt{\frac{\sum_{i,j} (r_{i,j} - \bar{r}_{i,j})^2}{N}}. \quad (14)$$

#### 4.2 实验结果分析

为了验证 SROC 算法的有效性,本文利用衡量推荐算法性能所常用的几种算法进行仿真测试. 实验与以下几种算法进行对比,以验证本文所提模型的正确性:

UCF:该方法是利用每个用户对项目评分的均值进行用户未评分项的预测.

ICF:该方法是利用每个项目评分的平均值对评分数据进行预测.

PMF(Probabilistic Matrix Factorization)<sup>[11]</sup>:该研究分析工具来自于 Salakhutdinov 等人的研究成果. PMF 具体以概率分布的矩阵因式分解为基础,对用户-项目评分矩阵开展协同推荐计算.

NMF(Non-negative Matrix Factorization)<sup>[12]</sup>:该方法是由 Lee 等人提出的. NMF 也是一种仅利用评分矩阵信息进行推荐的方法.

图 2 展示了不同训练集下不同推荐算法的推荐性能. 不难得到如下结论:SROC 的完成效果比 UCF 要好 21.1%,在 RMSE 中则是优于 15.7%. 在推荐性能上,SROC 算法在不同训练集上的推荐性能均优于其他算法. 这主要是由于经过重叠社区发现及合并后,用户的兴趣度更相似,在此基础上做近邻推荐的准确度将会更高.

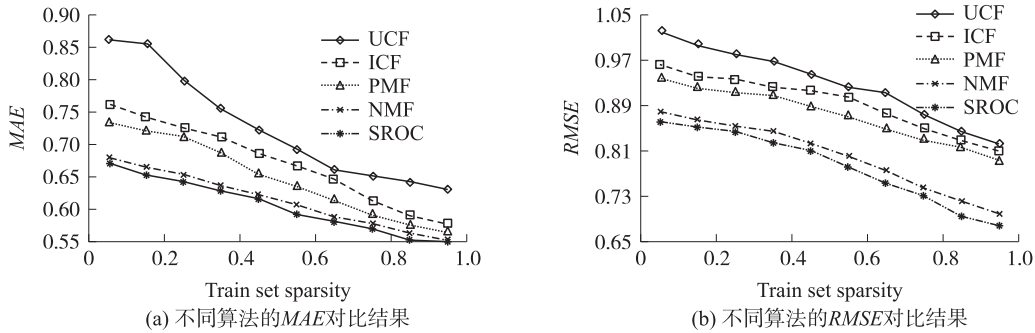


图 2 不同算法在不同的数据稀疏度下的 MAE 与 RMSE 对比结果

Fig. 2 Different performance under different training dataset sparsity

SROC 算法中的参数  $\sigma$  是用于设置社会规范化的社会因素,其取值不同,算法的性能也有所差异. 参数  $\sigma$  的取值越大则说明在推荐过程中考虑社会因素越多. 图 3 给出了参数  $\sigma$  在不同取值下 SROC 算法的 MAE 与 RMSE 指标变化的情况. 不难发现在一开始的时候,随着参数  $\sigma$  的增加, SROC 变得更加准确,但在超过某一临界值后,它的效果开始减弱. 由于社区检测算法中存在错误,社区中存在一些噪声邻居. 随着参数  $\sigma$  的增加,噪声邻居的影响不断扩大,因此减弱了算法效果.

表 1 给出了在不同测试集比例下 SROC 算法与其他各类推荐算法在 MAE、RMSE 上的对比结果. 由表 1 可知本文提出的 SROC 算法在平均绝对误差(MAE)、均方根误差(RMSE)等评估指标结果的准确性均显著高于 Trust、NMF、PMF、SocialMF 等传统推荐算法,尤其在用户评分数据缺乏的条件下, SROC 算法

的优势尤为突出.




图 3 参数  $\sigma$  取值验证实验

Fig. 3 The verification experiment of parameter  $\sigma$

表 1 推荐算法对比实验结果

		Table 1 The comparison result of recommendation algorithms				
		UCF	ICF	PMF	NMF	SROC
90%	MAE	0.913	0.877	0.865	0.871	0.789
	RMSE	1.169	1.238	1.154	1.162	1.021
80%	MAE	0.929	0.891	0.889	0.895	0.801
	RMSE	1.182	1.259	1.177	1.183	1.028
50%	MAE	0.932	0.955	0.923	0.921	0.832
	RMSE	1.192	1.263	1.185	1.193	1.092
20%	MAE	0.946	0.957	0.932	0.929	0.885
	RMSE	1.205	1.206	1.185	1.123	1.085

5 结论

在本文中,我们提出了一种新颖的基于重叠社区发现的社会网络推荐算法(SROC),该方法充分考虑了用户兴趣的时间因素,根据带有时间加权链接的用户—用户图实现重叠社区检测.在社区发现的基础上对不同重叠社区用户进行推荐,最终为各个用户生成一个 Top-N 推荐列表.实验结果表明,本文算法在推荐精度和多样性方面的性能要优于当前多种其他算法.在真实数据集上的实验结果表明:相对于传统的社区发现方法,所提出的方法能够更准确地发现重叠社区,从而有效提高了推荐系统的准确度.

[ 参考文献 ]

[ 1 ] ZHAO W X, LI S, CHANG E Y, et al. Connecting social media to e-commerce: cold-start product recommendation using microblogging information[ J]. IEEE transactions on knowledge and data engineering, 2016, 28( 5 ) : 1147–1159.

[ 2 ] HE C, LI H, FEI X, et al. A topic community-based method for friend recommendation in large-scale online social networks[ J]. Concurrency and computation practice and experience, 2017, 29( 6 ) : 1–10.

[ 3 ] HONG M, JUNG J J, PICCIALLI F, et al. Social recommendation service for cultural heritage[ J]. Personal and ubiquitous computing, 2017, 21( 2 ) : 191–201.

[ 4 ] LU Y, TSAPARAS P, NTOULAS A, et al. Exploiting Social Context for Review Quality Prediction[ C]//www2010, ACM. New York, USA, 2010: 691–700.

[ 5 ] MA H, ZHOU D Y, LIU C, et al. Recommender Systems with Social Regularization[ C]//WSDM, ACM. New York, USA, 2011: 287–295.

[ 6 ] LIU F, LEE H J. Use of social network information to enhance collaborative filtering performance[ J]. Expert system application, 2010, 37( 7 ) : 4772–4778.

[ 7 ] NOEL J, SANNER S, TRAN K N, et al. New objective functions for social collaborative filtering[ C]//WWW2012. Lyon, France, 2012: 1–10.

- [ 8 ] YANG S H, LONG B, SMOLA A J, et al. Like alike: joint friendship and interest propagation in social networks[ C ]// WWW2011, ACM. New York, USA, WWW, 2011: 537–546.
- [ 9 ] XIAO R L, LI Y N, CHEN H T, et al. SRSP-PMF: a novel probabilistic matrix factorization recommendation algorithm using social reliable similarity propagation[ J ]. Lecture notes in computer science, 2015: 80–91.
- [ 10 ] JI K, SUN R Y, LI X, et al. Improving matrix approximation for recommendation via a clustering-based reconstructive method[ J ]. Neurocomputing, 2016( 173 ): 912–920.
- [ 11 ] SALAKHUTDINOV R, MNH A. Probabilistic matrix factorization[ C ]// Proc of the 21st Annual Conf on Neural Information Processing Systems. New York: Curran Associates Inc, 2008: 1257–1264.
- [ 12 ] LEE D D, SEUNG H S. Learning the parts of objects by non-negative matrix factorization[ J ]. Nature, 1999, 401( 6755 ): 788–791.

[ 责任编辑: 顾晓天 ]

---

( 上接第 34 页 )

- [ 10 ] JEONG S, YOON I, JEON J, et al. Multi-frame example-based super-resolution using locally directional self-similarity[ C ]// Proc of IEEE International Conference on Consumer Electronics, LV: IEEE, 2015: 631–632.
- [ 11 ] VAPNIK V. Statistical learning theory[ M ]. New York: John Wiley and Sons, 1998.
- [ 12 ] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: from error measurement to structural similarity[ J ]. IEEE Transactions on image processing, 2004, 13( 4 ): 600–612.
- [ 13 ] 梅树立. 基于变分法和剪切波耦合算法的蝗虫切片保纹理图像降噪[ J ]. 农业工程学报, 2016, 32( 17 ): 152–159.
- [ 14 ] 朱志刚, 林学闾, 石定机. 数字图像处理[ M ]. 北京: 电子工业出版社, 2011.
- [ 15 ] 汤嘉立, 左健民, 黄陈蓉. 基于 SVM 预分类学习的图像超分辨率重建算法[ J ]. 计算机应用研究, 2012, 29( 8 ): 3151–3175.
- [ 16 ] 张卫国, 李景妹. 改进的基于纹理特征的图像配准算法[ J ]. 计算机工程与应用, 2016, 52( 6 ): 214–218.
- [ 17 ] 曹杨, 李晓光, 王素玉, 等. 基于预分类学习的超分辨率复原算法[ J ]. 数据采集与处理, 2009, 24( 4 ): 514–518.
- [ 18 ] 柳益君, 朱广萍, 钱进, 等. 基于支持向量机的绿色战略选择模型研究[ J ]. 计算机仿真, 2010, 27( 11 ): 307–310.

[ 责任编辑: 顾晓天 ]