

基于联合概率矩阵分解的移动社会化推荐

熊丽荣 刘 坚 汤 颖

(浙江工业大学计算机科学与技术学院 杭州 310023)

摘 要 利用移动设备上下文、移动社会化网络等信息进一步提高推荐系统的预测准确率,并缓解可能存在的数据稀疏性和冷启动问题,已经成为移动推荐系统的主要任务。采用基于矩阵分解的因子分析方法,结合用户、服务和用户社会化网络信息进行服务推荐,可以缓解数据稀疏性和冷启动问题;同时,为了增加信任矩阵密度,引入间接信任关系,提出了一种符合移动社会化网络特点的信任度计算方法,该方法仅利用移动社会化网络结构信息构建信任矩阵,从而减少用户对信任关系的主动标识。实验结果表明,引入间接信任关系能够提高预测精度,同时比传统的协同过滤算法和已有的一些矩阵分解方法具有更好的预测准确率,特别是在评分数据稀疏的情况下。

关键词 移动推荐,社会化推荐,矩阵分解,信任度,数据稀疏性

中图法分类号 TP181 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.9.051

Mobile Social Recommendation Based on Unified Probabilistic Matrix Factorization

XIONG Li-rong LIU Jian TANG Ying

(School of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China)

Abstract It has become the main task of mobile recommender systems to further improve the prediction quality and solve the data sparsity and cold-start problems that may exist by employing mobile context and mobile social network information etc. We combined users, services and users' social network information for recommendation to alleviate the data sparsity and cold-start problems by using the factor analysis method based on matrix factorization (MF). In order to increase the trust matrix density, in this paper we imported the indirect trust relationship, and then proposed a trust relationship calculation method which only use the mobile social network information to build trust matrix to reduce the user's active identification for trust relationship. And the trust calculation method is in line with the characteristics of mobile social network. The experimental results show that the introduction of the indirect trust relationship can improve the prediction accuracy, and our method outperforms some existing MF methods and traditional collaborative filtering algorithm in the aspect of accuracy, especially in the circumstance that users have made very few ratings or even none at all.

Keywords Mobile recommendation, Social recommendation, Matrix factorization, Trust, Data sparsity

1 引言

随着移动互联网信息和服务的日益增长,“移动信息过载”^[1]给移动用户带来了很大的信息负担。移动推荐系统^[2]作为传统互联网推荐系统在移动互联网领域的延伸,通过获取和预测潜在移动用户偏好来过滤不相关的信息,从而为用户提供满足其个性化需求的结果,已逐渐成为缓解“移动信息过载”的有效手段^[3,4]。

目前,对移动推荐系统的研究仍处于起步阶段,现有的一些研究^[5,6]主要基于传统互联网推荐模型,采用协同过滤算法生成移动推荐。为了提高推荐性能,一些研究者^[7-10]将用户上下文环境信息(如时间、位置、周围人员、网络条件等)引入到推荐系统中,然而这些方法大多基于传统的推荐技术,存在数据稀疏性和冷启动问题。

为了缓解数据稀疏性和冷启动问题,一些研究者^[11-13]将

社会化信息引入到推荐系统中,利用显示的社会化网络或者隐式社会化群体行为对信息内容进行推荐。

为了进一步解决数据稀疏性和冷启动问题,一些现代的推荐系统^[14-16]采用矩阵分解(MF)技术进行推荐。传统的矩阵分解算法包括奇异值分解(Singular Value Decomposition, SVD)^[17]、非负矩阵分解(Non-negative Matrix Factorization, NMF)^[18]、概率矩阵分解(Probabilistic Matrix Factorization, PMF)^[19]等。这些算法的共同点是,通过将高维的矩阵分解为两个或多个低维矩阵的乘积实现维度规约,以便于在一个低维空间研究高维数据的性质。然而这些方法只能结合单方面信息进行两维分解,并不能结合多个上下文信息进行推荐。为了结合多个上下文信息进行矩阵分解,Ma等人提出了一种联合概率矩阵分解(Unified Probabilistic Matrix Factorization, UPMF)方法^[15],即结合用户社会化网络信息和评分信息进行推荐。实验结果表明该方法优于已有的一些方

收到日期:2015-07-17 返修日期:2015-11-12 本文受浙江省重大科技专项重大工业项目(2012C11026-2)资助。

熊丽荣(1973-),女,硕士,副教授,CCF会员,主要研究方向为服务计算、软件中间件,E-mail:lilybear@zjut.edu.cn;刘坚(1990-),男,硕士生,主要研究方向为服务计算;汤颖(1976-),女,博士,副教授,主要研究方向为大数据处理、可视化分析(通信作者)。

法,特别是在用户很少评分甚至没有评分的情况下。然而,文献[15]在计算用户之间的信任度时,需要用户显著地标识与其他用户的信任关系,增加了操作的复杂性。相比于文献[15],本文关注的是在降低移动用户主动参与的前提下提高预测准确率。

本文将 UPMF 方法应用于移动推荐,结合移动用户的评分信息和社会化网络信息进行矩阵分解。针对移动社会化网络的特点,提出一种新的信任度计算方法,该方法仅利用用户社会化网络结构信息构建信任矩阵来减少用户对信任关系的主动标识;同时,引入间接信任关系来增加信任矩阵密度。在 Epinions 测试集上的实验结果表明,所提方法在预测准确率上要优于传统的协同过滤算法和已有的一些矩阵分解算法。

本文第 2 节阐述了移动推荐系统的主要方法和相关工作;第 3 节描述了问题的相关定义;第 4 节详细阐述了提出的基于 UPMF 的移动社会化推荐方法 MsRec (Mobile Social Recommender);第 5 节给出了实验与结果分析;最后总结全文并指出进一步的工作。

2 相关工作

当前的移动推荐系统大多基于传统的推荐技术,例如协同过滤推荐、基于内容的推荐、混合推荐等,其中混合推荐中研究和应用最多的是将协同过滤推荐与基于内容的推荐相混合。

文献[7-10]考虑了移动用户当前的上下文信息对推荐结果的影响。Yu 等人^[7]考虑了用户偏好、情景语境以及智能手机的性能上下文信息,提出了一种通用和灵活的 N2M 推荐模型;考虑到单推荐方法无法同时处理 3 个上下文信息,他们提出了一种混合推荐方法,即结合基于内容的推荐、贝叶斯分类和基于规则的方法进行推荐。Abowd 等人^[8]提出了一种移动上下文感知的导游系统 Cyberguide,其通过引入用户的当前位置的上下文信息来推荐用户周边的热门景点和服务(比如餐馆、酒店等)。文献[9]将多维上下文信息引入到推荐系统中,考虑多维上下文(日期、天气、同伴等)对移动用户餐厅食物选择的影响,并采用协同过滤算法进行推荐。实验结果表明,基于多维上下文的方法可以提高推荐质量。Girardello 等人^[10]提出了一种移动推荐系统 AppAware,其利用用户当前位置的上下文分析该位置附近手机应用程序的使用情况,将使用最频繁的程序推荐给用户,但它并没有考虑移动用户的个人偏好。

上述工作考虑到了移动用户当前的一些上下文信息,但是忽略了移动用户间更广泛的社会化关系。社会化网络用户之间的互动行为是人类社会行为的在线网络组织形式,间接地体现了网络用户之间的社会关系。大量的社会学研究表明,在相同社会化网络中的人们将会影响到他人并最终共享某些共同的兴趣爱好。一些研究者^[11-13]已经将社会化信息引入到移动推荐中。

Huang 等人^[11]通过信任网络中的信任度来获取用户的邻居,从而利用协同过滤算法完成推荐,并在公共的数据集和模拟的数据集上验证了算法的可行性和灵活性。Wang 等人^[12]提出了一种基于用户上下文和信任网络的服务选择机制,其将上下文相似度引入到服务选择过程中,同时考虑到了用户的信任值,在计算用户间的相似性时同时考虑了用户对项目评分的相似性和用户间信任关系的相似性,将两者融合

作为用户间相似的最终权重,并根据用户的最终相似权重采用基于用户的协同过滤算法进行兴趣点推荐。Groh 和 Eh-mig^[13]通过社交网站的朋友关系来构建协同过滤算法中的邻居,并通过大量的实证研究表明了社交网站中的朋友关系能够提高传统协同过滤算法的推荐准确率。

上述研究主要基于传统的推荐技术,通常面临着数据稀疏性和冷启动问题。已证实基于矩阵分解的方法^[15,16]比传统的推荐技术具有更好的性能,特别是在用户很少评分甚至没有评分的情况下。Ma 等人^[15]提出了一种基于概率矩阵分解的因子分析方法 SoRec,其结合用户社会化网络信息和评分记录进行联合推荐。实验结果表明,该方法在评分数据稀疏的情况下相比于已有的一些方法具有更好的预测精度。文献[16]提出了一种新型的社会化感知推荐方法,通过一个联合矩阵模型来描述潜在用户的社会化关系、主题、Mashups 和服务之间的多维关系。在真实的数据集上的实验结果表明,该方法要优于现有的一些方法。上述两种方法主要针对 Web 服务,在计算信任矩阵时需要用户显著标识与其他用户的信任度,增加了操作的复杂性,并且没有考虑间接信任关系对用户偏好的影响。

本文将 UPMF 方法应用于移动推荐,结合移动社会化网络多为群组结构的特点,提出了一种符合该特点的信任度计算方法。相比于因子分析方法^[15,16],所提方法 MsRec 主要有以下几点不同:1) MsRec 主要适用于移动推荐环境;2) 引入间接信任关系增加信任矩阵密度,从而提高了预测准确率;3) 提出一种符合移动社会化网络特点的信任度计算方法,仅利用社会化网络结构信息计算信任矩阵,从而减小了用户主动标识的复杂性。

3 问题的定义

移动用户的社会化网络多以群组的形式存在,目标用户通过创建群组(1 个或多个),主动添加好友构建移动社会化网络。本文主要基于该群组结构构建信任矩阵。

图 1 示出了移动社会化推荐案例,其中用户 u_1 创建了群组 msn_1 ,并添加了 u_2, u_3, u_4 作为其群组成员,因此认为用户 u_1 和 u_2, u_3, u_4 之间存在直接信任关系, u_2, u_3, u_4 是用户 u_1 的邻居;同理, u_3, u_4 是用户 u_5 的邻居。用户 u_1 和 u_5 之间尽管没有直接信任关系,但存在共同的邻居 u_3 和 u_4 ,因此认为 u_1 和 u_5 之间存在间接信任关系,即 u_1 和 u_5 互为间接邻居。邻居 u_2 和 u_4 分别对服务 s_2 和 s_3 的使用和评分情况会影响用户 u_1 对 s_2 和 s_3 的偏好;间接邻居 u_5 对服务 s_4 的使用和评分情况也会影响 u_1 对 s_4 的偏好。因此,结合移动用户的社会化网络信息和评分信息进行服务推荐,通过显式的邻居关系和隐式的间接邻居关系来提高推荐精度。




图 1 移动社会化推荐案例

结合图 1 中的移动社会化网络结构,定义两个相关概念: 1)用户之间的相关度;2)用户的可信度。其中用户之间的相关度主要依赖于用户之间是否具有直接或间接信任关系,若用户之间具有直接信任关系,则其相关度取决于邻居在目标用户所有创建的移动网络中出现的频率;若用户之间具有间接信任关系,则其相关度取决于用户双方共同好友的比例。用户的可信度指用户在整个移动社会化网络中的可信程度,若用户的邻居数量越多,则其可信度越低;反之,若用户作为他人邻居的次数越多,则其可信度越高。

表 1 列出本文涉及到的一些符号及其相关解释。

表 1 符号及其相关解释

符号	含义
$US=\{u_1, u_2, \dots, u_m\}$	用户集合,共有 m 个用户
$SS=\{s_1, s_2, \dots, s_n\}$	服务集合,共有 n 个服务
$MSN=\{msn_1, msn_2, \dots, msn_t\}$	移动社会化网络集,共有 t 个网络
$U \in \mathbb{R}^{l \times m}$	用户潜在特征矩阵
$V \in \mathbb{R}^{l \times n}$	服务潜在特征矩阵
$Z \in \mathbb{R}^{l \times m}$	信任潜在特征矩阵
$l \in \mathbb{R}$	潜在特征空间维度
$R=[r_{ij}]_{m \times n}$	R 为用户-服务评分矩阵
$S=[s_{ik}]_{m \times m}$	S 为用户-用户信任矩阵

4 MsRec 模型框架

本文提出的基于联合概率矩阵分解(UPMF)的移动社会化推荐方法 MsRec 主要由以下 3 部分组成:

(1)求解潜在特征向量。该算法以最大化联合后验概率为目标函数,基于梯度下降方法学习得到用户潜在特征向量 U_i 和服务潜在特征向量 V_j 。

(2)根据得到的用户潜在特征向量 U_i 和服务潜在特征向量 V_j ,重构得到 r_{ij} 。

(3)推荐 Top-k 移动服务。根据预测得到的评分值 r_{ij} ,按目标用户对服务进行排序。

本节首先介绍如何计算获得评分矩阵、信任矩阵,然后详细介绍求解用户潜在特征向量和服务潜在特征向量的 UPMF 方法,接着对 MsRec 方法的时间复杂度进行了分析,最后给出了系统的基本框架。

4.1 评分矩阵

表 1 中, R 表示 m 个用户对 n 个服务的评分矩阵。 R 中元素 r_{ij} ($r_{ij} \in [0, 1]$) 表示用户 u_i 对服务 s_j 的喜欢程度。通常多数推荐系统采用整型评分值 1 到 R_{\max} 来表示用户的喜欢程度,为了不失一般性,本文将 $1, \dots, R_{\max}$ 映射到 $[0, 1]$ 区间,参考文献[15]中给出的映射方法,具体如式(1)所示:

$$r_{ij} = f(R_{ij}) = (R_{ij} - 1) / (R_{\max} - 1) \quad (1)$$

4.2 信任矩阵

表 1 中, S 表示 m 个用户之间的信任关系, S 中元素 s_{ik} ($s_{ik} \in [0, 1]$) 表示用户 u_i 对用户 u_k 的信任程度。本文结合用户之间的相关度和用户的可信度,提出了一种新的信任度计算方法。信任度 s_{ik} 的计算规则如下:

(1) If u_i 和 u_k 之间存在直接信任关系,则 s_{ik} 置为直接信任度 $DT_{u_i \rightarrow u_k}$;

(2) Else if u_i 和 u_k 之间存在间接信任关系,则 s_{ik} 置为间接信任度 $IDT_{u_i \rightarrow u_k}$;

(3) Else $s_{ik} = 0$ 。

4.2.1 直接信任度计算

若用户 u_i 和 u_k 之间存在直接信任关系,即 u_k 是 u_i 的邻居,则直接信任度值 $DT_{u_i \rightarrow u_k}$ 如式(2)所示:

$$DT_{u_i \rightarrow u_k} = \alpha \cdot ds_{ik} + (1 - \alpha) \cdot t_{ik}, 0 < \alpha < 1 \quad (2)$$

其中, ds_{ik} 表示用户 u_i 对 u_k 的直接相关度,具体计算公式如式(3)所示:

$$ds_{ik} = \frac{|msn_{u_k \in msn_i}|}{|msn_i|} \quad (3)$$

其中, $|msn_i|$ 是用户 u_i 创建的移动社会化网络数量, $|msn_{u_k \in msn_i}|$ 是用户 u_i 创建的移动社会化网络中包含 u_k 的网络数量。

t_{ik} 为用户 u_i 对 u_k 的可信度,参考文献[20]中给出的方法,具体如式(4)所示:

$$t_{ik} = \sqrt{\frac{|N^-(u_k)|}{|N^+(u_i)| + |N^-(u_k)|}} \quad (4)$$

其中, $N^-(u_k)$ 是在整个社会化网络中信任用户 u_k 的用户集合,即将 u_k 作为邻居的用户集合, $|N^-(u_k)|$ 是用户 u_k 的入度,即信任用户 u_k 的用户集合大小; $N^+(u_i)$ 是用户 u_i 在整个社会化网络中的邻居集合, $|N^+(u_i)|$ 是用户 u_i 的出度,即用户 u_i 的邻居集合大小。

4.2.2 间接信任度计算

若用户 u_i 和 u_k 之间存在间接信任关系,则间接信任度值 $IDT_{u_i \rightarrow u_k}$ 如式(5)所示:

$$IDT_{u_i \rightarrow u_k} = \beta \cdot is_{ik} + (1 - \beta) \cdot t_{ik}, 0 < \beta < 1 \quad (5)$$

其中, is_{ik} 为用户 u_i 对 u_k 的间接相关度,具体计算公式如(6)所示:

$$is_{ik} = \frac{|N^+(u_i) \cap N^+(u_k)|}{|N^+(u_i)|} \quad (6)$$

其中, $|N^+(u_i) \cap N^+(u_k)|$ 为用户 u_i 和 u_k 在整个移动社会化网络中的共同邻居数量。

t_{ik} 为用户 u_i 对 u_k 的可信度,具体如式(4)所示。

4.3 MsRec 模型

具有信任关系的用户之间会影响彼此的行为。本文提出的基于 UPMF 的移动社会化推荐模型 MsRec 如图 2 所示,其中评分矩阵和信任矩阵共享用户潜在特征向量 U_i 。




图 2 MsRec 图模型

MsRec 模型基于以下假设:

假设 U_i, V_j, Z_k 先验概率服从高斯分布且相互独立,即:

$$p(U | \sigma_u^2) = \prod_{i=1}^m N(U_i | 0, \sigma_u^2 I) \quad (7)$$

$$p(V | \sigma_v^2) = \prod_{j=1}^n N(V_j | 0, \sigma_v^2 I) \quad (8)$$

$$p(Z | \sigma_z^2) = \prod_{k=1}^m N(Z_k | 0, \sigma_z^2 I) \quad (9)$$

其中, $N(x | \mu, \sigma^2)$ 表示均值为 μ 、方差为 σ^2 的高斯分布的概率密度函数, I 表示单位矩阵。

在给定用户 u_i 、服务 v_j 的潜在特征向量 U_i, V_j 后, 用户 u_i 对服务 v_j 的评分值 r_{ij} 满足均值为 $g(U_i^T V_j)$ 、方差为 σ_{rk}^2 的正态分布且相互独立。评分矩阵 R 的条件概率分布如式(10)所示:

$$p(R|U, V, \sigma_{rk}^2) = \prod_{i=1}^m \prod_{j=1}^n [N(r_{ij} | g(U_i^T V_j), \sigma_{rk}^2)]^{I_{ij}^R} \quad (10)$$

其中, I_{ij}^R 是指示函数, 若用户 u_i 评分过服务 v_j , 则 $I_{ij}^R = 1$; 否则, $I_{ij}^R = 0$ 。 $g(x) = \frac{1}{(1+e^{-x})}$ 是逻辑斯蒂函数, 将 $U_i^T V_j$ 值映射到 $[0, 1]$ 之间。

同理, 在给定潜在特征向量 U_i, Z_k 后, 信任矩阵 S 的条件概率分布如式(11)所示:

$$p(S|U, Z, \sigma_{sk}^2) = \prod_{i=1}^m \prod_{k=1}^n [N(s_{ik} | g(U_i^T Z_k), \sigma_{sk}^2)]^{I_{ik}^S} \quad (11)$$

其中, I_{ik}^S 是指示函数, 当用户 u_i 与 z_k 有关联关系时, $I_{ik}^S = 1$; 否则, $I_{ik}^S = 0$ 。

基于图 2 可以推导出 U, V, Z 的后验分布函数, 具体公式如式(12)所示:

$$\begin{aligned} \ln p(U, V, Z | S, R, \sigma_{rk}^2, \sigma_{sk}^2, \sigma_U^2, \sigma_V^2, \sigma_Z^2) \\ = -\frac{1}{2\sigma_{rk}^2} \sum_{i=1}^m \sum_{j=1}^n I_{ij}^R (r_{ij} - g(U_i^T V_j))^2 - \frac{1}{2\sigma_{sk}^2} \sum_{i=1}^m \sum_{k=1}^n I_{ik}^S (s_{ik} - \\ g(U_i^T Z_k))^2 - \frac{1}{2\sigma_U^2} \sum_{i=1}^m U_i^T U_i - \frac{1}{2\sigma_V^2} \sum_{j=1}^n V_j^T V_j - \frac{1}{2\sigma_Z^2} \sum_{k=1}^n \\ Z_k^T Z_k - \frac{1}{2} \left(\sum_{i=1}^m \sum_{j=1}^n I_{ij}^R \right) \ln \sigma_{rk}^2 + \left(\sum_{i=1}^m \sum_{k=1}^n I_{ik}^S \right) \ln \sigma_{sk}^2 - \\ \frac{1}{2} (m \ln \sigma_U^2 + n \ln \sigma_V^2 + m \ln \sigma_Z^2) + R \end{aligned} \quad (12)$$

其中, R 是常量。最大化式(12)可视为无约束优化问题, 最小化式(13)等价于最大化式(12):

$$\begin{aligned} E(R, S, U, V, Z) \\ = \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n I_{ij}^R (r_{ij} - g(U_i^T V_j))^2 + \frac{\lambda_S}{2} \sum_{i=1}^m \sum_{k=1}^n I_{ik}^S (s_{ik} - \\ g(U_i^T Z_k))^2 + \frac{\lambda_U}{2} \|U\|_F^2 + \frac{\lambda_V}{2} \|V\|_F^2 + \frac{\lambda_Z}{2} \|Z\|_F^2 \end{aligned} \quad (13)$$

其中, $\lambda_S = \frac{\sigma_{rk}^2}{\sigma_{sk}^2}$, $\lambda_U = \frac{\sigma_{rk}^2}{\sigma_U^2}$, $\lambda_V = \frac{\sigma_{rk}^2}{\sigma_V^2}$, $\lambda_Z = \frac{\sigma_{rk}^2}{\sigma_Z^2}$, $\|\cdot\|_F$ 是弗罗贝尼乌斯范数。式(13)的局部最小值可由梯度下降法求得。参数 U_i, V_j, Z_k 的梯度下降公式如式(14)一式(16)所示:

$$\frac{\partial E}{\partial U_i} = \sum_{j=1}^n I_{ij}^R g'(U_i^T V_j) (g(U_i^T V_j) - r_{ij}) V_j + \lambda_S \sum_{k=1}^n I_{ik}^S g'(U_i^T Z_k) (g(U_i^T Z_k) - s_{ik}) Z_k + \lambda_U U_i \quad (14)$$

$$\frac{\partial E}{\partial V_j} = \sum_{i=1}^m I_{ij}^R g'(U_i^T V_j) (g(U_i^T V_j) - r_{ij}) U_i + \lambda_V V_j \quad (15)$$

$$\frac{\partial E}{\partial Z_k} = \lambda_S \sum_{i=1}^m I_{ik}^S g'(U_i^T Z_k) (g(U_i^T Z_k) - s_{ik}) U_i + \lambda_Z Z_k \quad (16)$$

4.4 算法复杂度分析

算法的计算开销主要来自于间接信任关系的训练以及目标函数 E 和对应的梯度下降公式。在训练间接信任关系时, 假设每个用户的邻居集合大小为 k , 则间接信任关系的训练时间复杂度为 $O(m^2 k^2)$, 其中 k 通常较小, 可以认为是常数, 则时间复杂度趋向于 $O(m^2)$ 。目标函数 E 的时间复杂度为 $O(p_{rl} + p_{sl})$, 其中 p_r, p_s 分别表示矩阵 R, S 中非零元素的个数。同理可以推导出梯度下降式(14)一式(16)的时间复杂度分别为 $O(p_{rl} + p_{sl}), O(p_{rl})$ 和 $O(p_{sl})$ 。因此每次迭代的

总时间复杂度为 $O(p_{rl} + p_{sl})$ 。

4.5 系统基本框架

系统的基本框架如图 3 所示。

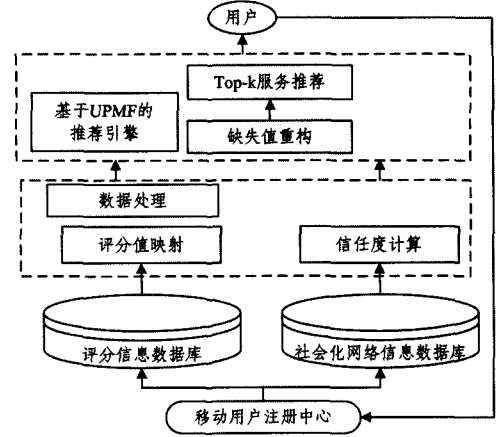


图 3 MsRec 系统的基本框架

系统主要包含以下几个基本模块: 移动用户注册中心、评分信息数据库、社会化网络信息数据库、数据处理模块、基于 UPMF 的推荐引擎模块。

(1) 移动用户注册中心: 这是整个系统的基础部件, 只有注册用户才能对移动服务进行使用与评价;

(2) 评分信息数据库: 存储用户的个性化评分记录, 包括用户 ID、服务 ID 以及相应的评分值;

(3) 社会化网络信息数据库: 存储用户的社会化网络信息的相关记录, 包括网络 ID (通常是用户创建的群组 ID)、用户 ID 及对应邻居 ID;

(4) 数据处理模块: 对原始数据进行预处理, 包括评分值映射以及信任度计算;

(5) 基于 UPMF 的推荐引擎: 根据数据处理模块得到的数据, 采用基于 UPMF 的方法重构缺失值, 从而达到推荐目的, 该模块是整个推荐系统的核心模块。

5 实验与结果分析

5.1 实验数据

本文涉及到的实验数据主要包含两方面: 1) 用户评分数据; 2) 用户社会化网络关系数据。其中评分数据可以通过移动服务注册中心来获取用户的反馈信息记录, 通常包含用户 ID、服务 ID 以及相应的评分值。用户的社会化网络关系数据可以通过第三方社交网络服务平台获取, 通常包括移动社会化网络 ID、用户 ID、邻居 ID 等。第三方社交网络服务平台是指微信、QQ、Facebook 等, 可以通过其官方 API 获取相应的接口。

为了验证本文提出的方法, 选择了基于现实的社会网络数据集 Epinions 作为实验数据。Epinions 是一个大众消费点评网站, 用户可以通过注册该网站会员对网站上的物品进行点评, 同时 Epinions 还提供了一个“信任机制”, 允许用户通过对他人的产品点评质量的优劣做出判断, 并选择是否将这些用户纳入信任列表。该数据集主要包含两个文本文件: rating.txt 和 trust.txt。rating.txt 提供用户 ID、物品 ID 和评分值 (1 到 5 的整数), 其中评分值越高, 代表用户对该商品的喜欢程度越高。为了结合本系统, 用户 ID 对应用户 ID, 物品 ID 对应服务 ID, 评分值对应评分值。trust.txt 提供用户 ID、

朋友 ID 和信任值(默认为 1)。考虑到实验硬件环境的局限性,为了减少间接信任关系的训练时间,分别从原始数据集中随机选取 10% 的评分数据和信任数据作为实验数据集。

5.2 评价指标

本文采用平均绝对误差(Mean Absolute Error, MAE)^[21]作为准确性度量标准。

MAE 根据预测评分和实际评分之间的差值来评价算法,差值越小,算法准确度越高,推荐质量越高。假设预测得到的评分集合为 $\{p_1, p_2, \dots, p_n\}$, 测试集评分集合为 $\{q_1, q_2, \dots, q_n\}$, 则 MAE 的计算公式如式(17)所示:

$$MAE = \frac{\sum_{i=1}^n |p_i - q_i|}{n} \quad (17)$$

其中, n 为测试集大小。

5.3 方法比较

为了验证 MsRec 算法的预测准确率,将其与当前一些比较先进的方法如 PMF^[19]方法、文献[15]提出的 SoRec 方法以及传统的协同过滤方法 User-Based 和 Item-Based 方法进行比较。其中在 SoRec 方法中,本文将信任度计算过程中的 c_{ik} 设置为 1,两个传统的协同过滤方法采用 Pearson 相关系数^[22]计算用户之间的相似度。

利用不同稀疏度评分训练数据(99%, 80%, 50%, 20%, 10%)对以上算法进行实验。99% 的训练集意味着从实验数据集中随机选取 99% 的评分数据来预测剩下的 1% 的评分数据。为了降低算法的复杂度,将 λ_U, λ_V 和 λ_Z 分别设置为 0.001,同时根据 5.4.3 节中得到的实验结果,将 λ_S 设置为 0.5,用于接下来的实验中。

5.4 实验分析

5.4.1 参数 α 和 β 的评估

为了得到更加准确的直接信任度值和间接信任度值,实验 1(见图 4)和实验 2(见图 5)分别对直接信任度和间接信任度中的权重参数 α 和 β 进行了评价,以考查 α 和 β 取不同比例时对信任度的影响。评价指标采用 MAE,相比于式(17),实验 1 和实验 2 中的 p_i, q_i 和 n 的涵义有所区别,其中,实验 1 中的 p_i 指通过社会化关系训练集得到的直接信任度值, q_i 指通过整个社会化关系数据集得到的直接信任度值, n 指训练集大小;实验 2 中的 p_i 指通过社会化关系训练集得到的间接信任度值, q_i 分为两种情况:当通过训练集得到的具有间接信任关系的用户在整个数据集中存在直接信任关系时, q_i 为通过整个数据集得到的直接信任度值,否则 q_i 为通过整个数据集得到的间接信任度值, n 为通过社会化关系训练集得到的间接信任关系集大小。

将 α 和 β 分别设置为 0.1, 0.2, 0.5, 0.8, 0.99, 训练集大小分别设置为 10%, 50%, 90%, 实验结果分别如图 4 和图 5 所示。




图 4 参数 α 的影响

由图 4 可知,随着 α 的逐渐增大, MAE 逐渐减小,效果越来越好,当 α 趋向于 1 时, MAE 趋向于 0。上述结果一方面是由于 Epinions 信任数据集的特殊性,该数据集中一条记录只包含用户 ID、信任用户 ID 及信任度(默认为 1),并没有对应的社会化网络 ID,因此,本文将与目标用户有信任关系的邻居都默认为处于该目标用户创建的一个网络中,则该用户与其邻居之间的直接相关度为 1,在整个信任度计算中占据主导作用;另一方面也符合我们的认知,即用户对于邻居的信任度通常是比较高的,与邻居在整个社会化网络中的可信度相关不大。




图 5 参数 β 的影响

由图 5 可知,随着 β 的逐渐增大, MAE 先减小后增大,在 $\beta=0.5$ 时取得较优值。根据实验结果可以得到,对于移动用户之间的间接信任度,不仅要考虑到用户之间的间接相关度,而且还要考虑用户在整个社会化网络中的可信度,两者重要性基本相当。

根据上述实验结果,将 α 设置为 0.99, β 设置为 0.5 用于接下来的实验。

5.4.2 社会化关系训练集大小对推荐准确率的影响

实验 3(见图 6)测试了通过不同大小的社会化关系训练集训练得到的信任关系对推荐准确率的影响,其中社会化关系训练集的大小分别设置为 0.1, 0.3, 0.5, 0.7 和 1.0, 评分训练集的大小分别设置为 0.1, 0.2, 0.5, 0.8 和 0.99, 潜在特征向量维度 l 设置为 5。




图 6 社会化关系训练集大小对推荐准确率的影响

由图 6 可知,随着用于训练的社会化关系数据的增加,不同评分训练集情况下的推荐准确率都逐渐提高,采用完整的社会化关系训练集得到的平均预测精度要比采用 10% 的训练集得到的平均预测精度提高 7.68%。进一步观察图 6 可以发现,仅考虑用户之间的直接信任关系进行推荐时,虽然采用了完整的训练集,但其预测精度也仅比采用了 10% 的训练集训练得到的直接和间接信任关系的预测精度高一点。这一方面表明所提方法在社会化关系数据不完善的情况下同样能取得较好的推荐效果,另一方面也表明引入间接信任关系能显著提升预测精度。

5.4.3 参数 λ_s 对推荐准确率的影响

参数 λ_s 决定了社会化网络信息对算法效果的影响。当 λ_s 设置为 0 时,意味着仅利用用户评分信息;当 λ_s 设为 $+\infty$ 时,意味着仅利用社会化网络信息。实验 4(见图 7)测试了参数 λ_s 对算法的影响。




图 7 参数 λ_s 的影响

由图 7 可知,参数 λ_s 对推荐结果的影响是非常显著的,这也验证了将用户评分信息和社会化网络信息结合起来可以有效提高预测精度。随着 λ_s 的增加,MAE 值先减小,但当 λ_s 大于某阈值时,继续增加 λ_s 的值,MAE 值逐渐增加,预测精度逐渐降低。其原因在于:仅利用用户评分信息或社会化网络信息时,算法推荐效果无法超越结合两方面信息所得的结果。当 $\lambda_s \in [0, 1, 5]$ 时,算法的准确率最高。

5.4.4 推荐质量分析

实验 5(见表 2、图 8)主要比较了本文提出的 MsRec 算法和传统的协同过滤算法(User-Based 和 Item-Based)以及已有的矩阵分解方法 PMF^[19] 和 SoRec^[15] 方法的预测效果。

利用不同稀疏程度的评分训练集(99%, 80%, 50%, 20%, 10%)对以上算法进行实验。在进行实验分析时,将潜在特征向量维度 l 设置为 5。

根据表 2 和图 8,随着训练集的增大,5 种算法的 MAE 值都逐渐减小,MsRec 算法在不同训练集下的 MAE 值都显著小于其它 4 种方法,特别是相对于两种传统的协同过滤方法 Item-Based 和 User-Based,其平均预测精度提高了 19.16% 和 18.1%。在数据稀疏的情形下,MsRec 算法的推荐效果提高显著,其预测精度相比于 PMF 和 SoRec 方法提高了 7.12%~7.87%。

表 2 5 种方法的 MAE 值

Training Data	Item-Based	User-Based	PMF	SoRec	MsRec
99%	1.0691	1.0562	1.0168	0.9970	0.9366
80%	1.0879	1.0786	1.0227	1.0150	0.9516
50%	1.1283	1.1189	1.0358	1.0270	0.9668
20%	1.2205	1.2096	1.0601	1.0536	0.9842
10%	1.2792	1.2687	1.0667	1.0592	0.9880




图 8 算法推荐效果比较

综合上述分析,MsRec 方法在预测精度方面要优于其它 4 种方法,并且更适用于数据稀疏情形下的推荐。但是,MsRec 方法需要对间接信任关系进行训练,时间复杂度相对

较高,在硬件环境有限且训练数据较大时并不适用。

结束语 本文提出了一种基于 UPMF 的移动社会化推荐算法 MsRec,其结合移动用户的评分信息和社会化网络信息提高了预测精度。针对移动社会化网络多为群组结构的特点,提出了一种符合该特点的信任度计算方法,其利用显式的邻居关系与隐式的间接邻居关系进行移动社会化推荐,在减少移动用户对信任关系主动标识的同时提高了预测精度。在 Epinions 测试集上的实验结果表明,MsRec 算法在预测精度上要优于传统的协同过滤方法和已有的一些矩阵分解方法,特别是在评分数据稀疏的情况下,推荐效果提高显著。下一步将改善间接信任关系训练模型,在保证预测精度的前提下降低训练的复杂度;同时结合更多的移动用户上下文信息如时间、位置信息等进一步提高算法的性能。

参考文献

- [1] Wang L C, Meng X W, Zhang Y J. A cognitive psychology-based approach to user preferences elicitation for mobile network services[J]. Acta Electronica Sinica, 2011, 39(11): 2547-2553 (in Chinese)
王立才,孟祥武,张玉洁. 移动网络服务中基于认知心理学的用户偏好提取方法[J]. 电子学报, 2011, 39(11): 2547-2553
- [2] Ricci F. Mobile recommender systems [J]. Information Technology & Tourism, 2010, 12(3): 205-231
- [3] Modsching M, Kramer R, Ten Hagen K, et al. Effectiveness of mobile recommender systems for tourist destinations: a user evaluation[C]//4th IEEE Workshop on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications, 2007 (IDAACS 2007). IEEE, 2007: 663-668
- [4] Miller B N, Albert I, Lam S K, et al. MovieLens unplugged: experiences with an occasionally connected recommender system [C]//Proceedings of the 8th International Conference on Intelligent User Interfaces. ACM, 2003: 263-266
- [5] Lee S K, Cho Y H, Kim S H. Collaborative filtering with ordinal scale-based implicit ratings for mobile music recommendations [J]. Information Sciences, 2010, 180(11): 2142-2155
- [6] Kim J K, Cho Y H, Kim S. MOBICORS-Movie: A mobile contents recommender system for movie[C]//ICEB. 2004: 789-794
- [7] Yu Z, Zhou X, Zhang D, et al. Supporting context-aware media recommendations for smart phones[J]. Pervasive Computing, IEEE, 2006, 5(3): 68-75
- [8] Abowd G D, Atkeson C G, Hong J, et al. Cyberguide: A mobile context-aware tour guide[J]. Wireless Networks, 1997, 3(5): 421-433
- [9] Hosseinipozveh M, Nematbakhsh M, Movahhedinia N. A multi-dimensional approach for context-aware recommendation in mobile commerce[C]//International Conference on Wireless Networks. 2009: 657-663
- [10] Girardello A, Michahelles F. AppAware: Which mobile applications are hot? [C]//Proceedings of the 12th International Conference on Human Computer Interaction with Mobile Devices and Services. ACM, 2010: 431-434
- [11] Huang W H, Meng X W, Wang L C. A collaborative filtering algorithm based on users' social relationship mining in mobile communication network[J]. Journal of Electronics and Information Technology, 2011, 33(12): 3002-3007 (in Chinese)

程中,对各子主题下的句子使用基于时间和权重特性的 Lex-PageRank 算法,抽取信息最全面、影响力最充分的句子加入摘要,而对冗余信息的处理又使主题内容表现得清晰明了,大大节省了用户阅读博文的时间,提高了阅读效率。综上所述,提出的基于 Lex-PageRank 算法的微博摘要优化方法可以有效挖掘微博中的热点,为用户提供较为准确和全面的信息。

结束语 由于目前微博上的在线文本日益增多,通过摘要抽取文本内容帮助用户提高阅读效率、缩短阅读时间已经变得很有必要。本文给出的主题模型下基于 Lex-PageRank 算法的微博摘要优化方法,其特点是在微博话题中引入摘要抽取技术,通过聚类在过滤孤立信息的同时将相同主题的博文组织在一起,然后优化选择主题下的句子生成摘要。实验结果表明,所提方法在生成摘要的过程中表现出较理想的覆盖率。但其不足之处在于,以“句子”为知识粒度来表示摘要并不十分贴合用户体验。在以句子为单元的摘要基础上,抽取主旨事件,并排序与润色,形成高可读性的内容摘要,将是下一步的工作。

参考文献

- [1] Kwak H, Lee C, Park H, et al. What is Twitter, a social network or a news media [C] // Proceedings of the 19th International Conference on World Wide Web. ACM, 2010: 591-600
- [2] Brandow R, Mitze K, Rau L F. Automatic condensation of electronic publication by sentence selection [J]. Information Processing Manage, 1995, 31(5): 575-685
- [3] Luhn H P. The Automatic Creation of Literature Abstracts [J]. IBM Journal of Research and Development, 1958, 2(2): 159-165
- [4] Cao Yang, Cheng Ying, Pei Lei. A Review on Machine Learning Oriented Automatic Summarization [J]. Library and Information Service, 2014, 58(18): 122-130 (in Chinese)
曹洋, 成颖, 裴雷. 基于机器学习的自动文摘研究综述 [J]. 图书情报工作, 2014, 58(18): 122-130
- [5] Han Yong-feng, Xu Xu-yang, Li Bi-cheng, et al. Web News Multi-document Summarization Based on Event Extraction [J]. Journal of Chinese Information Processing, 2012, 26(1): 58-66 (in Chinese)
韩永峰, 许旭阳, 李弼程, 等. 基于事件抽取的网络新闻多文档自动摘要 [J]. 中文信息学报, 2012, 26(1): 58-66
- [6] Hu M, Sun A, Lim E P. Comments-oriented blog summarization by sentence extraction [C] // Proceedings of the Sixteenth ACM Conference on Conference on Information and Knowledge Management. ACM CIKM, 2007: 901-904
- [7] Chen Yan-min, Wang Xiao-long, Liu Yuan-chao, et al. Automatic Text Summarization Based on Topic and Content [J]. Computer Engineering and Applications, 2004, 33(5): 11-14 (in Chinese)
陈燕敏, 王晓龙, 刘远超, 等. 一种基于文章主题和内容的自动摘要方法 [J]. 计算机工程与应用, 2004, 33(5): 11-14
- [8] Xie Hao, Sun Wei. Paragraph-Sentence Mutual Reinforcement Based Automatic Summarization Algorithm [J]. Computer Science, 2013, 40(11A): 246-250 (in Chinese)
谢浩, 孙伟. 基于段落-句子互增强的自动文摘算法 [J]. 计算机科学, 2013, 40(11A): 246-250
- [9] Yang Chang-chun, Zhou Meng. An Improved Hot Topic Detection Method for Microblog Based on CURE Algorithm [J]. Computer Simulation, 2013, 30(11): 383-387 (in Chinese)
杨长春, 周猛. 基于改进 CURE 算法的微博热点话题发现 [J]. 计算机仿真, 2013, 30(11): 383-387
- [10] Ammar M B, Neji M, Alimi A M. The integration of an emotional system in the Intelligent Tutoring System [C] // The 3rd ACS/IEEE International Conference on Computer Systems and Applications. 2005: 145
- [11] Langville A N, Meyer C D. Deeper inside pagerank [J]. Internet Mathematics, 2004, 1(3): 335-380
- [12] Jin X, Deng Y F, Zhong Y X. Mixture feature selection strategy applied in cancer classification from gene expression [D]. Shanghai: IEEE Press, 2005: 4807-4809
- [13] (上接第 260 页)
黄武汉, 孟祥武, 王立才. 移动通信网中基于用户社会化关系挖掘的协同过滤算法 [J]. 电子与信息学报, 2011, 33(12): 3002-3007
- [12] Wang Y X, Qiao X Q, Li X F, et al. Research on context-awareness mobile SNS service selection mechanism [J]. Chinese Journal of Computers, 2010, 33(11): 2126-2135 (in Chinese)
王玉祥, 乔秀全, 李晓峰, 等. 上下文感知的移动社交网络服务选择机制研究 [J]. 计算机学报, 2010, 33(11): 2126-2135
- [13] Groh G, Ehmgig C. Recommendations in taste related domains: collaborative filtering vs. social filtering [C] // Proceedings of the 2007 International ACM Conference on Supporting Group Work. ACM, 2007: 127-136
- [14] Shangguan Q, Hu L, Cao J, et al. Book Recommendation Based on Joint Multi-relational Model [C] // 2012 Second International Conference on Cloud and Green Computing (CGC). IEEE, 2012: 523-530
- [15] Ma H, Yang H, Lyu M R, et al. Sorec: social recommendation using probabilistic matrix factorization [C] // Proceedings of the 17th ACM Conference on Information and Knowledge Management. ACM, 2008: 931-940
- [16] Xu W, Cao J, Hu L, et al. A social-aware service recommendation approach for mashup creation [C] // 2013 IEEE 20th International Conference on Web Services (ICWS). IEEE, 2013: 107-114
- [17] Golub G, Kahan W. Calculating the singular values and pseudo-inverse of a matrix [J]. Journal of the Society for Industrial & Applied Mathematics, Series B: Numerical Analysis, 1965, 2(2): 205-224
- [18] Lee D D, Seung H S. Algorithms for non-negative matrix factorization [C] // Advances in Neural Information Processing Systems, 2001: 556-562
- [19] Mnih A, Salakhutdinov R. Probabilistic matrix factorization [C] // Advances in Neural Information Processing Systems, 2007: 1257-1264
- [20] Zhou D, Hofmann T, Schölkopf B. Semi-supervised learning on directed graphs [C] // Advances in Neural Information Processing Systems, 2004: 1633-1640
- [21] Schafer J B, Frankowski D, Herlocker J, et al. Collaborative filtering recommender systems [M] // The adaptive Web. Springer Berlin Heidelberg, 2007: 291-324
- [22] George T, Merugu S. A scalable collaborative filtering framework based on co-clustering [C] // Fifth IEEE International Conference on Data Mining. IEEE, 2005: 625-628