

基于用户间动态信任关系的推荐算法研究

郑 旻¹ 石 刚^{1,2}

(新疆大学信息科学与工程学院 乌鲁木齐 830046)¹ (清华大学计算机科学与技术系 北京 100084)²

摘 要 在电子商务中,用户对商品的决策很大程度上取决于用户间的社会信任关系。传统的推荐算法往往考虑用户间的静态关系,即决策依赖的社会关系图是不变的。实际上,用户对好友的信任度往往随着时间的变化而变化。为了描述动态的信任关系在推荐系统中的作用,提出了一种基于动态信任关系的推荐算法。首先,提出了一种考虑用户的静态兴趣和静态信任关系的产生式模型;然后,分别将时序因素加入到用户兴趣和信任关系的描述,并提出了相应的动态产生式模型。实验表明,提出的算法能很好地描述用户之间信任关系随时间的变化,并且与其它相关算法相比,评价值的预测准确性得到了明显的提高。

关键词 电子商务,推荐系统,信任关系,协同过滤

中图分类号 TP393 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.9.044

Recommender Algorithm Based on Dynamical Trust Relationship between Users

ZHENG Jiong¹ SHI Gang^{1,2}

(School of Information Science and Engineering, Xinjiang University, Urumqi 830046, China)¹

(Department of Computer Science and Technology, Tsinghua University, Beijing 100084, China)²

Abstract In e-commerce, a user's selection of item largely depends on the trust relationship of users. Traditional recommender algorithms usually consider the static relationship between users, that is, the depended relationship for decision is changeless. In order to describe the importance of static trust relationship in recommender system, this paper proposed a dynamical trust relationship based recommender algorithm. First, we proposed a generative model that takes both static user interest and static trust relationship into consideration. Then, we added temporal factor into user interest and trust relationship, and proposed corresponding dynamical generative model. The experiments show that the proposed algorithm can describe the dynamical trust relationship between users, and has better prediction accuracy than related algorithms.

Keywords E-commerce, Recommender system, Trust relationship, Collaborative filtering

在电子商务系统中,用户往往面对着海量的商品及其相关信息,如何从众多的商品中选择有用的商品是一个充满挑战的问题。随着用户行为信息即用户对某商品的喜好值的增加,推荐系统通常采用协同过滤技术发现目标用户的相似用户,然后根据相似用户对商品的评价值来估计用户对商品的喜好^[1]。当系统收集了大量的用户行为数据,并且用户的行为不随着时间而改变时,协同过滤方法可有效地预测用户对未知商品的喜好程度。然而,当用户的个人行为受短期兴趣影响时,对用户兴趣的动态变化进行建模可以提高推荐系统的准确性。这种方法对每个用户引入一个个性化的时间因子,通过时间的变化动态地反映用户的兴趣变化^[2]。随着社交网络的普及,电子商务中出现了基于社交网络的推荐系统^[3]。基于社交网络的推荐系统基于如下假设:好友或者可信用户的行为在用户进行决策时起着重要的作用。因此,在推荐系统中,可以应用用户间的社会关系进一步提高推荐的准确性。

在推荐系统中,用户间的社会关系并不是静态的,而是随着时间的推移不断变化的。由于社会关系及兴趣爱好的转变,用户会结识新的好友,原先的好友的意见会变得弱化。例如,在时刻 T_1 ,用户 U_1 仅有一个好友 U_2 ,随着时间的推移,用户 U_1 在 T_2 时刻的好友为 U_2 和 U_3 。如果在时刻 T_2 对用户 U_1 进行推荐,那么推荐什么商品才最可能被购买呢?为了回答这一问题,必须对该用户的短期和长期兴趣,以及随着时间而演化的社会信任关系加以量化。由于用户的兴趣和社会信任关系这两个因素并不是独立的,因此当两个用户的短期和长期兴趣相匹配时,他们很可能成为好友,并且更有可能接受彼此的建议;相反,虽然两个用户相互为好友关系,但是如果他们的短期和长期兴趣并不匹配,那么他们的兴趣向着不同的方向发展,并且在一段时间之后彼此的意见变得弱化。

本文提出了一种基于动态信任关系的推荐算法,该算法通过概率产生式方法调整用户的社会信任网络与用户评价行为为历史记录的关系。

到稿日期:2014-09-05 返修日期:2014-11-18 本文受新疆维吾尔自治区高校科研启动基金(XJEDU2011S06)资助。

郑 旻(1977—),女,硕士,讲师,主要研究方向为软件工程、数据库应用,E-mail:sky_gingo@126.com;石 刚(1972—),男,博士生,主要研究方向为操作系统、程序设计语言形式化验证。

1 相关工作

现有的向用户推荐项的推荐系统可以粗略地分为两类：基于内容的推荐系统和基于协同过滤方法的推荐系统。基于内容的推荐系统^[4]显式地应用用户的资料 and 商品的说明来描述各自的特征。基于协同过滤方法的推荐系统^[5,6]并不显式地应用用户的资料,而是通过用户过去的行为,如交易记录或对商品的评价记录,对用户的特征进行描述。早期的协同过滤方法^[7]主要是基于最近邻的方法,即根据一定的相似性度量方法,在用户的行为记录中寻找目标用户或商品的若干最近邻,然后根据这些最近邻的评价对目标进行估算。近年来,Porteous 等^[8]提出了一种贝叶斯模型,该模型应用 LDA^[9]将用户和项聚类成组,并用相同的组成员对待估值进行预测。Bi-LDA 模型^[10]对上述模型进行了扩展。在 Bi-LDA 模型中,用户或项可以属于多个组,并且在每个组中都有一个预测值。

上述协同过滤推荐方法都忽略了时间因素的重要性,Koren^[11]提出了一种时间敏感的基于奇异值分解的推荐算法。该方法通过引入时间变量对标准的矩阵分解模型进行了扩展。在该方法中,用户对项的偏好以及用户的潜在因子都与时间有关,并通过时间的变化来描述用户或项的特征变化。Xiong 等^[12]将时间作为第 3 个维度,并应用张量分解技术对时间维度进行分解。在这种方法中,用户对项的评价值不仅依赖于用户和项的特征,还依赖于特定时间的潜在因素。为了应对隐式用户反馈数据中的时序动态性,Xiang 等^[13]提出了一种加权的随机游走模型。在该模型中,为了刻画时间的重要性,用户的近期偏好有着更大的权重,因此这类边在随机游走过程中有着较大的游走概率。Rendle 等人^[14]将潜在因子模型与马尔科夫模型相结合,以此来预测用户未来可能感兴趣的项。这些模型虽然都可以对用户的兴趣以及兴趣随着时间的变化进行描述,但是都没有考虑用户之间的信任网络以及信任关系的动态变化。

近期的研究表明,用户间的信任关系在推荐系统中起着非常重要的作用。文献[15-17]应用矩阵分解技术来学习用户和项的潜在因子,并采用不同的方法将社会信任网络与推荐模型结合。基于文献[15]的研究,Jamali 等^[18]提出了一种信任扩张的产生式方法。Shen 等^[19]提出了一种个人与社会潜在因子相结合的推荐模型。在推荐过程中,该模型将协同过滤方法与社会网络模型方法相结合。为了对项选择时的决策过程进行建模,Ye 等^[20]提出了一种基于社会影响力选择的概率模型。然而,上述推荐模型都假设用户间的社会信任关系是静态的,并且没有考虑用户的偏好随着时间的变化。

2 动态推荐模型

2.1 问题定义

在推荐系统中,令用户集合为 $U = \{u_1, \dots, u_n\}$, 项的集合为 $M = \{m_1, \dots, m_b\}$ 。在时刻 t , 用户 u 对项 m 的评价值的取值范围为 1 到 5, 其中 1 表示最不喜欢, 5 表示最喜欢。用户对项的历史评价记录为一个 $a \times b$ 的评价矩阵 $S^{(t)}$, 其中元素 $s^{(t)}(u, m)$ 表示用户 u 在时刻 t 对项 m 的评价值。

推荐系统除了含有用户对项的评价矩阵外,还包含用户

间的社会网络。在时刻 t , 用户间的社会网络 $S^{(t)}$ 是一个 $a \times a$ 的矩阵, 其中元素 $s^{(t)}(u, v) = 1$ 表示用户 u 在时刻 t 信任用户 v , $s^{(t)}(u, v) = 0$ 表示用户 u 在时刻 t 不信任用户 v 。由于信任关系是单方向的, 因此矩阵 $S^{(t)}$ 是非对称的。

本文研究问题的定义如下: 在时刻 t' , 给定用户 $u \in U$ 和项 $m \in M$, 根据用户之间的信任关系 $S^{(t)}$ ($1 \leq t \leq t'$) 以及历史评价记录 $R^{(t)}$ ($1 \leq t \leq t'$) 预测用户 u 在时刻 t' 下对项 m 的评价值 $s^{(t')}(u, v)$ 。

2.2 基本模型描述

在众多基于用户特征的推荐系统中, Bi-LDA 算法的性能在实际应用中较好。然而, Bi-LDA 算法没有考虑用户间的社会关系, 本文在该算法中加入了用户间的社会关系, 提出了 Bi-LDA^{social} 模型。

在 Bi-LDA^{social} 模型中, 每个用户 u 的偏好分布 π_u^{friend} 表明该用户的好友在评分时对用户的贡献度分布, 其中每个好友的贡献度与该用户对好友的信任度成正比。本文令用户 u 为其自身的特殊好友, 即 $u \in F(u)$ 。此外, 每个用户 u 和项 m 都分别服从参数为 π_u^{user} 和 π_m^{item} 的话题分布。在对项 m 进行排名时, 用户 u 从相应的分布中提取出用户话题 $z_{u,m}^{\text{user}}$, 项 m 提取出项的话题 $z_{u,m}^{\text{item}}$ 。 $\Phi_{z_{u,m}^{\text{user}}, z_{u,m}^{\text{item}}} \in \{1, \dots, R\}$ 是 $z_{u,m}^{\text{user}}$ 和 $z_{u,m}^{\text{item}}$ 的话题联合分布。在产生式过程中, 排名值通过如下方式产生。

- 1) 为评价值选择一个 $K \times L$ 的联合分布 $\Phi \sim \text{Dir}(\beta)$ 。
- 2) 为每个用户选择一个好友分布 $\pi_u^{\text{friend}} \sim \text{Dir}(\alpha^{\text{friend}})$ 。
- 3) 为每个用户选择一个包含 K 个用户话题的分布 $\pi_u^{\text{user}} \sim \text{Dir}(\alpha^{\text{user}})$ 。
- 4) 为每个项选择一个包含 L 个项话题的分布 $\pi_m^{\text{item}} \sim \text{Dir}(\alpha^{\text{item}})$ 。
- 5) 对每个评价值 $r_{u,m}$:
 - 选择信任好友 $z_{u,m}^{\text{friend}} \sim \text{Multinomial}(\pi_u^{\text{friend}})$;
 - 选择用户话题 $z_{u,m}^{\text{user}} \sim \text{Multinomial}(\pi_u^{\text{user}})$;
 - 选择项的话题 $z_{u,m}^{\text{item}} \sim \text{Multinomial}(\pi_m^{\text{item}})$;
 - 选择评价值 $r_{u,m} \sim \Phi_{z_{u,m}^{\text{user}}, z_{u,m}^{\text{item}}}$ 。

其中, Dir 和 Multinomial 分别为 Dirichlet 和多项式分布, α 和 β 为分布的参数, K 和 L 分别为用户话题和项的话题的个数。在预测用户 u 对项 m 的评价值时, 该决策过程与好友的信任度有关(包含用户本身)。

为了计算 u 对项 m 的评价值 $r_{u,m}$, 需要先得到如下参数 $\Theta = \{\pi_u^{\text{friend}}, z_{u,m}^{\text{friend}}, \pi_u^{\text{user}}, \pi_u, z_{u,m}^{\text{user}}, z_{u,m}^{\text{item}}, \Phi_{z_{u,m}^{\text{user}}, z_{u,m}^{\text{item}}}\}$ 。在这些参数当中, $\pi_u^{\text{friend}} \in \mathbb{R}^{1 \times |U|}$ 描述了用户对 friend 的信任度, $\pi_u^{\text{user}} \in \mathbb{R}^{1 \times K}$ 描述了用户 u 对 K 个用户话题的偏好分布, $\pi_m^{\text{item}} \in \mathbb{R}^{1 \times L}$ 描述了用户 u 对 L 个项的话题的偏好分布, $\Phi_{z_{u,m}^{\text{user}}, z_{u,m}^{\text{item}}} \in \mathbb{R}^{K \times L}$ 描述了用户项联合话题的混合比例, $z_{u,m}^{\text{friend}}$ 描述了用户 u 对项 m 进行评价时的信任好友, $z_{u,m}^{\text{user}}$ 描述了用户 u 选择的用户话题, $z_{u,m}^{\text{item}}$ 描述了用户 u 选择的项的话题。如文献[8]所示, 本文令 Dirichlet 分布的先验参数 $\alpha^{\text{friend}}, \alpha^{\text{user}}, \alpha^{\text{item}}$ 和 β 为 1。

令用户 u 对项 m 的预测值为 x , 那么 Bi-LDA^{social} 的联合概率分布为

$$\begin{aligned} & Pr(x, z^{\text{friend}}, z^{\text{user}}, z^{\text{item}}, \Phi, \pi^{\text{user}}, \pi^{\text{item}}) \\ &= Pr(x | z^{\text{user}}, z^{\text{item}}, \Phi) \times Pr(\Phi | \beta) \times Pr(z^{\text{user}} | \pi^{\text{user}}) \times \\ & Pr(\pi^{\text{user}} | \alpha^{\text{user}}, z^{\text{friend}}) \times Pr(z^{\text{friend}} | \pi^{\text{friend}}) \times \\ & Pr(\pi^{\text{friend}} | \alpha^{\text{r}}) \times Pr(z^{\text{item}} | \pi^{\text{item}}) \times Pr(\pi^{\text{item}} | \alpha^{\text{item}}) \quad (1) \end{aligned}$$

直接对式(1)进行计算显然是不可行的,本文采用 Gibbs 采样方法对模型的参数进行学习。首先,得到 π^{user} , Φ , π^{item} 和 π^{friend} 的边缘分布,以及联合分布 $P(x, z^{user}, z^{item}, z^{friend})$,并根据这些分布函数计算 Gibbs 采样必须的条件分布。令 x 为 $r_{u,m}$ 的预测值, $k = z_{u,m}^{user}$, $l = z_{u,m}^{item}$, 于是有

$$P(f = z_{u,m}^{friend} | \Theta \setminus z_{u,m}^{friend}, x) \propto ((n_{u,f}^{friend})^{-\langle u,m \rangle} + \alpha^{friend}) \times ((n_{f,k}^{user})^{-\langle u,m \rangle} + \alpha^{user}) \times \left(\frac{N_{k,l,x}^{-\langle u,m \rangle} + \beta}{\sum_r (N_{k,l,x}^{-\langle u,m \rangle} + \beta)} \right) \quad (2)$$

其中, $n_{u,f}^{friend}$ 表示用户 u 在对所有项的评价中信任 f 的次数, $(n_{u,f}^{friend})^{-\langle u,m \rangle}$ 表示用户 u 在对除了 $r_{u,m}$ 之外的所有项的评价中信任 f 的次数, $(n_{f,k}^{user})^{-\langle u,m \rangle}$ 表示用户 u 在对除了 $r_{u,m}$ 之外的所有项的评价中属于用户话题 k 的次数, $N_{k,l,x}$ 表示用户话题 k 中的用户对包含项 r 的项话题 l 进行评价的次数, $N_{k,l,x}^{-\langle u,m \rangle}$ 表示用户话题 k 中的用户对项话题 l 中除了 $r_{u,m}$ 之外的项进行评价的次数, 并且 $N_{k,l,x}$ 和 $N_{k,l,x}^{-\langle u,m \rangle}$ 的评价值都为 x 。

本文定义用户话题 $z_{u,m}^{user}$ 的条件概率为

$$P(z_{u,m}^{user} = k | \Theta \setminus z_{u,m}^{user}, x) \propto ((n_{f,k}^{user})^{-\langle u,m \rangle} + \alpha^{user}) \times \left(\frac{N_{k,l,x}^{-\langle u,m \rangle} + \beta}{\sum_r (N_{k,l,x}^{-\langle u,m \rangle} + \beta)} \right) \quad (3)$$

如果将用户和项的位置互换, 那么项的话题 $z_{u,m}^{item}$ 的条件概率为

$$P(z_{u,m}^{item} = l | \Theta \setminus z_{u,m}^{item}, x) \propto ((n_{m,l}^{item})^{-\langle u,m \rangle} + \alpha^{item}) \times \left(\frac{N_{k,l,x}^{-\langle u,m \rangle} + \beta}{\sum_r (N_{k,l,x}^{-\langle u,m \rangle} + \beta)} \right) \quad (4)$$

其中, $(n_{m,l}^{item})^{-\langle u,m \rangle}$ 表示在除了 $r_{u,m}$ 以外的所有评价中项 m 属于项话题 l 的次数, $N_{k,l,x}$ 表示用户话题 k 中的用户对项话题 l 中的项的评价值为 r 的次数。

此外, 参数 $\pi_{u,f}^{friend}$, $\Phi_{k,l,x}$, $\pi_{u,k}^{user}$ 和 $\pi_{m,l}^{item}$ 的定义分别如下:

$$\pi_{u,f}^{friend} = \frac{n_{u,f}^{friend} + \alpha^{friend}}{\sum_{f \in F(u)} (n_{u,f}^{friend} + \alpha^{friend})} \quad (5)$$

$$\Phi_{k,l,x} = \frac{N_{k,l,x} + \beta}{\sum_r (N_{k,l,x} + \beta)} \quad (6)$$

$$\pi_{u,k}^{user} = \frac{n_{u,k}^{user} + \alpha^{user}}{\sum_k (n_{u,k}^{user} + \alpha^{user})} \quad (7)$$

$$\pi_{m,l}^{item} = \frac{n_{m,l}^{item} + \alpha^{item}}{\sum_{f \in F(u)} (n_{m,l}^{item} + \alpha^{item})} \quad (8)$$

2.3 加入时序信任关系的模型

上述模型仅考虑了用户间的静态关系, 即好友关系是不变的。然而实际上, 用户间的信任关系是随着时间的改变而改变的。为了描述这种时序特征, 令时刻 t 的好友为 $t-1$ 时刻下的先验条件概率, 即

$$\pi^{friend(t)} = P(\pi^{friend(t)} | \pi^{friend(t-1)}) \quad (9)$$

其 Dirichlet 分布描述为

$$\pi^{friend(t)} \sim Dir(\lambda \pi^{friend(t-1)}) \quad (10)$$

其中, 先验参数 $\lambda \pi^{friend(t-1)}$ 表示在时刻 t 之前用户的信任好友。同理, 可以得到用户话题和项的话题与用户话题的时序分布的参数为

$$\pi^{user(t)} \sim Dir(\lambda \pi^{user(t-1)}) \quad (11)$$

$$\pi^{item(t)} \sim Dir(\lambda \pi^{item(t-1)}) \quad (12)$$

将式(10)一式(12)分别代入式(2)一式(8), 可得到用户信任关系动态变化下的推荐模型。由于篇幅关系, 此处不重复给出相关公式。

在上述模型下, 当给定用户 u 和项 m , 在时刻 t 下评价

$r_{u,m}^{(t)}$ 的计算公式为

$$r_{u,m}^{(t)} = \sum_{f \in F(u)} \pi_{u,f}^{friend(t)} [\pi_u^{user(t)}]^T \Phi \pi_m^{item(t)} \quad (13)$$

3 实验设计与结果分析

3.1 对比算法

本文提出一种用户的兴趣和信任关系都随时间动态变化的推荐模型, 将其记为 RTM。实验分别实现了 RTM 的两个变体形式, 并将这些算法与常用的社会推荐算法相比较。各个算法的定义如下。

- RTM-StaticSocial: 该算法是 RTM 的一个变体形式。在该算法中, 假设用户间的信任关系不随着时间的变化而改变, 即用户间的社会信任关系在所有时间点下都等于最终的信任关系。

- RTM-StaticInterest: 该算法也是 RTM 的一个变体形式。在该算法中, 假设用户的兴趣偏好不随着时间的变化而改变。该算法中用户的信任关系是动态变化的, 用户在所有时间点下的兴趣都是最终的评价值矩阵。

- 概率矩阵分解 PMF^[21]: 该算法是一种基于矩阵分解的协同过滤算法。在该算法中, 用户的兴趣特征和信任关系都是静态的。

- Bi-LDA^[8]: 该算法是一种用于静态评价预测的产生式算法。该算法同样不考虑用户的兴趣特征和信任关系的动态变化。

- TimeSVD++^[11]: 该算法是一种时序的协同过滤算法。在该算法中, 用户的兴趣特征是动态的, 用户间的社会关系是静态的。

- SocialMF^[18]: 该算法是一种静态的协同过滤算法。该算法考虑的是静态的社会关系, 且用户的兴趣也是静态的。

3.2 数据集与评价标准

实验采用的数据集为 Epinions 数据集¹⁾。该数据集包含两个文件。一个文件包含 717667 个用户信任关系, 每个信任关系都有一个时间戳。另一个文件为用户对项的评价, 包含了 120492 个用户对 755760 部电影的 13668319 个评价。评价值的取值范围为 1 到 6 之间的整数, 1 表示没有帮助, 6 表示帮助最大。同时, 每个评价值都有一个时间戳。

实验采用的评价标准为平均绝对误差 MAE 和均方根误差 RMSE, 其定义分别如下:

$$MAE = \frac{\sum_{r_i \in D} |r_i - \hat{r}_i|}{|D|} \quad (14)$$

$$RMSE = \sqrt{\frac{\sum_{r_i \in D} (r_i - \hat{r}_i)^2}{|D|}} \quad (15)$$

其中, D 为测试数据集, r_i 为预测值, \hat{r}_i 为真实值。MAE 或者 RMSE 越小, 表明算法的预测准确性越高。

¹⁾ <http://www.trustlet.org/wiki/ExtendedEpinionsdataset>

3.3 实验结果

将 Epinions 数据集按照数据的时间戳进行排序,并将其划分为 6 个时间跨度相等的时间片,每个时间片的时间跨度为 3 个月。前 5 个时间片的数据为训练数据,最后一个时间片的数据为测试数据。同时,过滤掉那些评价个数少于 10 的用户。

首先,通过调整潜在因子 K 的大小来观测不同算法的预测准确性,实验结果如图 1 和图 2 所示。从这两幅图中可以看出,随着潜在因子 K 的不断增大,各种算法的 MAE 和 RMSE 都不断降低。由于 RTM 采用了时序的方法来衡量用户的兴趣变化和信任关系变化,因此该算法的预测准确性有了明显的提高。

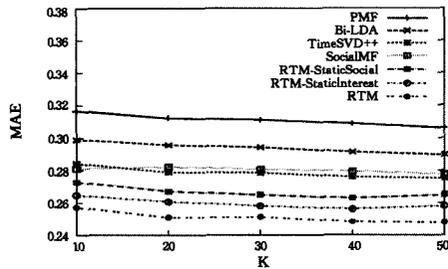


图 1 算法的 MAE 随潜在因子数 K 的变化

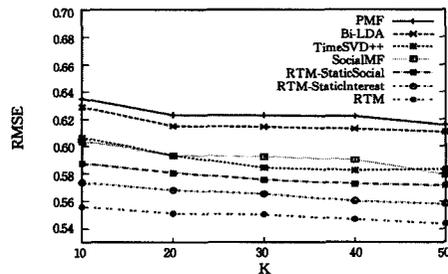


图 2 算法的 RMSE 随潜在因子数 K 的变化

其次,实验分析了用户的社会关系随着时间的变化。图 3 为用户 344 对 109、562 和 34 这 3 个用户的信任度随着时间的变化。从该图可以看出,用户 344 对用户 34 的信任度在 T6 时刻突然增大,而对用户 562 的信任度突然减小。这表明 RTM 模型可以描述用户间的动态信任关系。

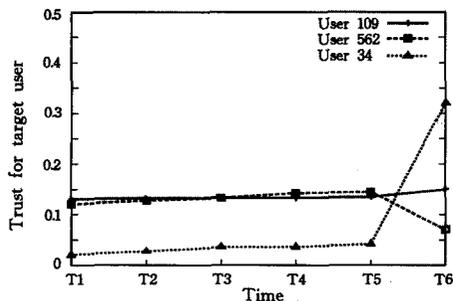


图 3 好友的信任度随时间的变化

最后,实验测试了参数 λ 对算法的预测准确性的影响。参数 λ 描述了先前时间片的先验知识对当前时间片的影响度。当 $\lambda=0$ 时,当前时间片的预测并不依赖于先验知识。图 4 为 RTM 模型的 RMSE 随着 λ 的变化图。从图中可以看出:当 $\lambda=1$ 时,算法的 RMSE 最低,这说明算法此时的预测准确性最高。

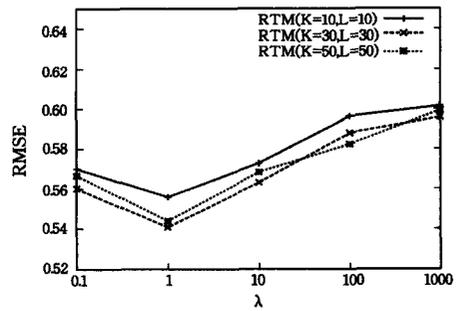


图 4 λ 对算法的 RMSE 的影响

结束语 在电子商务中,用户兴趣以及用户间的信任关系随着时间的动态变化在推荐系统的决策中起着非常重要的作用。随着社交网络的发展,社会推荐系统不仅考虑用户对商品的评价矩阵,还考虑用户之间形成的信任网络。该信任网络在用户购买商品的决策中非常重要。为了描述用户的兴趣随着时间的变化,以及用户的社交网络的动态变化,本文提出了一种基于动态信任关系的推荐算法。该算法基于条件概率的思想,用当前时间点以前的数据作为先验知识对当前的评价值进行预测。实验表明,本文提出的算法能很好地描述用户之间信任关系随时间的变化,与其它相关算法相比预测准确性得到了明显的提高。

参考文献

- [1] 许海玲,吴潇,李晓东,等. 互联网推荐系统比较研究[J]. 软件学报,2009,20(2):350-362
Xu Hai-ling, Wu Xiao, Li Xiao-dong, et al. Comparison study of Internet recommendation system [J]. Journal of Software, 2009, 20(2): 350-362
- [2] Esparza G S, O'Mahony M P, Smyth B. Mining the real-time web: a novel approach to product recommendation [J]. Knowledge-Based Systems, 2012, 29(3): 3-11
- [3] Pham M C, Cao Y, Klamma R, et al. A Clustering Approach for Collaborative Filtering Recommendation Using Social Network Analysis [J]. J. UCS, 2011, 17(4): 583-604
- [4] Lops P, de Gemmis M, Semeraro G. Content-based recommender systems: State of the art and trends [M] // Recommender Systems Handbook. Springer US, 2011: 73-105
- [5] Koren Y, Bell R. Advances in collaborative filtering [M] // Recommender Systems Handbook. Springer US, 2011: 145-186
- [6] 罗辛,欧阳元新,熊璋,等. 通过相似度支持度优化基于 K 近邻的协同过滤算法 [J]. 计算机学报, 2010, 33(8): 1437-1445
Luo Xin, Ouyang Yuan-xin, Xiong Zhang, et al. The Effect of Similarity Support in k-Nearest-Neighborhood Based Collaborative Filtering [J]. Chinese Journal of Computers, 2010, 33(8): 1437-1445
- [7] Breese J S, Heckerman D, Kadie C. Empirical analysis of predictive algorithms for collaborative filtering [C] // Proceedings of the Fourteenth Conference on Uncertainty in Artificial Intelligence. 1998: 43-52
- [8] Porteous I, Bart E, Welling M. Multi-HDP: A Non Parametric Bayesian Model for Tensor Factorization [C] // AAAI. 2008: 1487-1490
- [9] Blei D M, Ng A Y, Jordan M I. Latent dirichlet allocation [J]. The Journal of Machine Learning Research, 2003(3): 993-1022
- [10] Mackey L W, Weiss D, Jordan M I. Mixed membership matrix

- factorization[C]//Proceedings of the 27th International Conference on Machine Learning(ICML-10). 2010;711-718
- [11] Koren Y. Collaborative filtering with temporal dynamics [J]. Communications of the ACM, 2010, 53(4): 89-97
- [12] Xiong L, Chen X, Huang T K, et al. Temporal Collaborative Filtering with Bayesian Probabilistic Tensor Factorization[C]//SDM. 2010;211-222
- [13] Xiang L, Yuan Q, Zhao S, et al. Temporal recommendation on graphs via long-and short-term preference fusion[C]//Proceedings of the 16th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2010;723-732
- [14] Rendle S, Freudenthaler C, Schmidt-Thieme L. Factorizing personalized markov chains for next-basket recommendation[C]//Proceedings of the 19th International Conference on World Wide Web. ACM, 2010;811-820
- [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] Yuan Q, Chen L, Zhao S. Factorization vs. regularization: fusing heterogeneous social relationships in top-n recommendation[C]//Proceedings of the fifth ACM Conference on Recommender Systems. ACM, 2011;245-252
- [17] Ma H, Zhou D, Liu C, et al. Recommender systems with social regularization[C]// Proceedings of the fourth ACM International Conference on Web Search and Data Mining. ACM, 2011; 287-296
- [18] Jamali M, Ester M. A transitivity aware matrix factorization model for recommendation in social networks[C]//Proceedings of the Twenty-Second international joint conference on Artificial Intelligence. 2011;2644-2649
- [19] Shen Y, Jin R. Learning personal+social latent factor model for social recommendation [C] // Proceedings of the 18th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2012;1303-1311
- [20] Ye M, Liu X, Lee W C. Exploring social influence for recommendation: a generative model approach [C] // Proceedings of the 35th International ACM SIGIR Conference on Research and Development in Information Retrieval. ACM, 2012;671-680
- [21] Salakhutdinov R, Mnih A. Probabilistic Matrix Factorization [OL]. <http://www.cs.torontv.edu/~amnih/papers/pmf.pdf>
- [22] 王越, 程昌正. 协同过滤算法在电影推荐中的应用[J]. 四川兵工学报, 2014, 35(5): 86-88
- Wang Yue, Cheng Chang-zheng. Application of Collaborative Filtering Algorithms in Movie Recommendation[J]. Journal of Sichuan Ordnance, 2014, 35(5): 86-88

(上接第 229 页)

- [2] 曾玉钰, 翁金钟. 函数数据聚类分析方法探析[J]. 统计与信息论坛, 2007, 22(5): 10-14
- Zeng Yu-yu, Weng Jin-zhong. Initiative research of the clustering approach about functional data [J]. Statistics and Information Forum, 2007, 22(5): 10-14
- [3] 丁晗. 基于函数型数据分析的高中学习成绩评价与预测[D]. 吉林: 东北师范大学, 2009
- Ding Han. High school academic performance evaluation and prediction based on functional data analysis [D]. Jilin: Northeast Normal University, 2009
- [4] 李树良. 心电图形状分析的统计方法[D]. 上海: 华东师范大学, 2011
- Li Shu-liang. Electrocardiogram (ecg) shape analysis of statistical method [D]. Shanghai: East China Normal University, 2011
- [5] Florindo J B, Backes A R, de Castro M, et al. A comparative study on multiscale fractal dimension descriptors [J]. Pattern Recognition Letters, 2012, 33(6): 798-806
- [6] Song J J, Deng W, Lee H J, et al. Optimal classification for time-course gene expression data using functional data analysis [J]. Computational Biology and Chemistry, 2008, 32(6): 426-432
- [7] Park C, Koo J Y, Kim S, et al. Classification of gene functions using support vector machine for time-course gene expression data[J]. Computational Statistics & Data Analysis, 2008, 52(5): 2578-2587
- [8] Suhaila J, Jemain A A, Hamdan M F, et al. Comparing rainfall patterns between regions in Peninsular Malaysia via a functional data analysis technique[J]. Journal of Hydrology, 2011, 411(3): 197-206
- [9] 朱建平. 基于模型参数基展开的函数回归及其应用[J]. 商业经济与管理, 2009, 208(2): 81-85
- Zhu Jian-ping. The functional regression model based on basis function expansion of model parameter and its application [J]. Journal of business economics, 2009, 208(2): 81-85
- [10] 靳刘蕊. 函数型数据分析方法及应用研究[D]. 厦门: 厦门大学, 2008
- Jin Liu-rui. The study on the methods of functional data analysis and their application [D]. Xiamen: Xiamen University, 2008
- [11] 李静, 田卫东. 基于 B 样条隶属函数的模糊推理系统[J]. 计算机应用, 2011, 31(2): 490-492
- Li Jing, Tian Wei-dong. Fuzzy inference system based on B-spline membership function [J]. Journal of Computer Applications, 2011, 31(2): 490-492
- [12] 李红广. 基于 B 样条基粗糙惩罚的某些约束函数型数据光滑方法研究[D]. 上海: 华东师范大学, 2008
- Li Hong-guang. Research on methods of functional data with some constraints Based on b-spline basis with roughness penalty [D]. Shanghai: East China Normal University, 2008
- [13] 王剑. 线性回归系数的 Stein 估计[D]. 武汉: 华中科技大学, 2007
- Wang Jian. Stein estimation for linear regression coefficient [D]. Wuhan: Huazhong University of Science and Technology, 2007
- [14] Ramsay J O, Silverman B W. Functional Data Analysis (second edition)[M]. New York: Springer, 2005
- [15] 姜高霞, 王文剑. 经济周期波动的函数型时序分解方法[J]. 统计与信息论坛, 2014, 29(3): 22-28
- Jiang Gao-xia, Wang Wen-jian. Functional decomposition model of time series on business cycle analysis [J]. Statistics and Information Forum, 2014, 29(3): 22-28
- [16] Graven P, Wabba G. Smoothing noisy data with spline functions [J]. Number Math, 1979, 31(4): 377-403
- [17] Ramsay J O, Silverman B W. Applied functional data analysis: methods and case studies [M]. Springer, 2002
- [18] 顾坚, 刘伟. 面向 NUMA 集群的代数多重网格算法优化[J]. 计算机科学, 2014, 4(2): 114-118
- Gu Jian, Liu Wei. Optimizing algebraic multigrid on NUMA-based cluster system [J]. Computer Science, 2014, 41(2): 114-118