

引用格式:王维,高岭,高全力.融合用户信任 and 用户兴趣漂移的协同过滤算法[J].微电子学与计算机,2019,36(7):103-108.
[WANG W,GAO L,GAO Q L. Collaborative filtering algorithm based on user trust and interest drift detecting[J]. Microelec-
tronics & Computer,2019,36(7):103-108.]

融合用户信任和用户兴趣漂移的协同过滤算法

王 维^{1,2},高 岭²,高全力²

(1 咸阳师范学院 计算机学院,陕西 咸阳 712000;2 西北大学 信息科学与技术学院,陕西 西安 710069)

摘 要:针对现有的协同过滤算法推荐质量不高,提出了融合用户信任和用户兴趣的协同过滤算法 CF—BI. 首先根据用户历史评分矩阵,充分考虑用户偏好相似性、用户影响力和打分专业性等影响因子,提出综合用户偏好相似度和用户信誉度的信任模型;然后采用融入艾宾浩斯遗忘函数的 Pearson 相关系数计算用户间的兴趣相似度,通过加权融合获取用户信任与用户兴趣间的关联关系,以获取更加准确的最近邻居,并对目标用户采用 Top—N 算法进行推荐.在真实数据集 MovieLens 上的仿真实验结果表明,该算法的平均绝对误差比传统的协同过滤算法提升了 16.98%,有效提高了推荐质量.

关键词:推荐系统;协同过滤;用户信任;遗忘函数;用户兴趣

中图分类号: TP311

文献标识码: A

文章编号: 1000—7180(2019)07—0103—06

Collaborative filtering algorithm based on user trust and interest drift detecting

WANG Wei^{1,2},GAO Ling²,GAO Quan-li²

(1 Computer Department, Xianyang Normal University,Xianyang 712000,China;

2 School of Information Science and Technology, Northwest University, Xi'an 710069,China)

Abstract: To solve this problem, the collaborative filtering algorithm based on user trust and user interest CF — BI was proposed. Firstly, according to the user's history score matrix, the trust model of the comprehensive user preference similarity and user credibility was proposed, which took full account of user preference similarity, user influence and scoring professional and other influencing factors; and then the similarity of users' interests was calculated by Pearson correlation coefficient of Ebbinghaus forgetting function, and the similarity degree and interest similarity degree between users were adjusted by the weighting coefficient, which made the selection of the nearest neighbor more accurate, and recommends the Top—N algorithm to the target users. Experimental results on the MovieLens dataset show that the average absolute error of the algorithm is 16.98% than that of the traditional collaborative filtering algorithm, which improves the quality of recommendation effectively.

Key words: recommender systems; collaborative filtering; user trust; forgetting function; user interest

1 引言

随着网络的迅速发展,网络上的信息量急剧

膨胀,用户面对大量信息却无法获得对自己有用的信息,即“信息超载”问题.推荐系统应运而生,成为学术界的一大研究热点.推荐系统通过挖掘

收稿日期:2018—11—20;修回日期:2018—12—10

基金项目:国家自然科学基金(61572401);陕西省教育科学“十三五”规划项目(SGH17H189);咸阳师范学院“青年骨干教师”培养项目(XSYGG201718);咸阳师范学院专项科研基金(15XSYK044)。

用户和项目间的二元关系,帮助用户从大量数据中发现可能感兴趣的项目,并生成个性化推荐以满足个性化需求^[1].从信息过滤角度,推荐系统被分为以下几类:协同过滤、基于内容的过滤和混合式过滤.其中,协同过滤在个性化推荐系统中应用较多,但在大数据环境下,数据的稀疏性、用户冷启动等问题日益严重^[2],导致推荐质量有所下降.在现实中,用户更倾向相信好友推荐的物品,因此推荐系统若结合用户信任关系,能够进一步提高推荐质量^[3].许多研究人员对推荐系统中用户间的信任关系展开了研究.文献[4]依据主题张量分解挖掘用户在物品选择时对朋友的信任程度;文献[5]根据信任属性建立信任模型,通过信任模型填充评分矩阵;文献[6]通过一种数据挖掘算法填充评分矩阵,并结合信任因子改进协同过滤算法;文献[7]从历史数据中挖掘潜在的信任关系;文献[8]通过分析用户评分信息量化用户间的信任程度,将信任关系引入协同过滤算法.以上研究,充分证明了基于信任关系的推荐更符合用户的需求^[9],但研究的用户信任关系角度较单一,为进一步提高推荐性能提供了改进空间.

传统的协同过滤算法不能及时反映用户的兴趣变化,影响了推荐质量.但在现实中,用户的兴趣随时间推移不断变化,有些研究者引入用户兴趣漂移的概念,跟踪和捕捉用户兴趣的变化.文献[10]利用基于指数遗忘的数据权重减小资源相似度的权重;文献[11]将历史信息的时效量化函数引入到未知评分资源计算中,研究了基于遗忘曲线的协同过滤推荐算法;文献[12]结合用户兴趣随时间转移的特点,改进了相似度的度量方法.但以上研究只考虑了用户兴趣,并未考虑影响推荐质量的其他因素.

因此,本文提出基于用户信任 and 用户兴趣的协同过滤算法,通过分析用户项目评分数据构建用户信任关系,采用基于艾宾浩斯遗忘曲线的时间函数描述用户兴趣的变化,引入权重因子调整用户信任和用户兴趣计算综合相似度,结合协同过滤算法,完成对用户的推荐.

$$\text{rely_belief}(u,v)=\begin{cases}0 & \text{total(item)}=0 \\ \frac{\text{intersect}(u,v)}{\text{total}(\text{item})} & \text{likely}(\text{item})+\text{unlikely}(\text{item})=0 \\ \alpha \frac{\text{intersect}(u,v)}{\text{total}(\text{item})}+(1-\alpha) \frac{\text{likely}(\text{item})}{\text{likely}(\text{item})+\text{unlikely}(\text{item})} & \text{else} \end{cases}$$

(3)

式中,intersect(*u*,*v*)表示 $U \cap V$ 的数量,即用户*U*和用户*V*共同评分的项目数量;total(item)表示*U*

2 基于用户信任和用户兴趣的协同过滤推荐模型

2.1 用户信任模型

目前,用户在社交网络中的信息分享、用户间的通信越来越频繁,通过用户的社交化行为可以构建用户的信任关系网络、信息共享网络等社会网络.传统的基于用户或项目的协同过滤算法存在用户评分数量不均、数据稀疏性等问题,因此,将社会化信息引入推荐能有效提高推荐性能.在构建信任模型时,充分考虑用户偏好相似性、用户影响力和打分专业性等影响因子.

(1) 用户偏好相似度

在推荐系统中,两个用户共同评分的项目越多,偏好相似度越高,基于对方所产生推荐的项目信任度越高^[13].因此本文通过用户历史评分数据隐式获取用户偏好相似度. Jaccard 相似性考虑两个用户共同评分项目的数量,可用于表示用户之间的偏好相似度,如公式(1)所示.

$$\text{belief1}(u,v)=\frac{U \cap V}{U \cup V}$$

(1)

式中,*u*和*v*分别表示两个用户;*U*和*V*分别表示用户*u*和用户*v*评分的项目集合.公式(2)能够反映用户*u*和*v*共同评分项目的比例,但无法区分用户对共同评分项目的偏好程度.因此本文将用户共同评分的项目细分为用户喜欢项目和用户不喜欢项目.将用户对所有打分项目的平均值作为阈值,高于阈值的项目定义为用户喜欢的项目,低于阈值的项目定义为用户不喜欢的项目.用户在共同打分的项目中,共同喜欢的项目比重越大,偏好相似度越高,如公式(2)所示.

$$\text{belief2}(u,v)=\frac{\text{likely}(\text{item})}{\text{likely}(\text{item})+\text{unlikely}(\text{item})}$$

(2)

式中,likely(item)表示用户*u*和用户*v*共同评分项目中,用户*u*和用户*v*共同喜欢项目的数量;unlikely(item)表示用户*u*和用户*v*共同评分项目中,用户*u*和用户*v*都不喜欢项目的数量.

综合公式(1)、(2),用户*u*和*v*之间的偏好相似度如公式(3)所示.

$U \cup V$ 的数量,即用户*U*和用户*V*评分的项目总数; α 表示权重因子,取值范围在[0,1]之间.

(2) 用户信誉度

在推荐系统中,用户对项目的评分数量越多,其影响力越高,并且随着评价经验的积累,评价质量会不断提高,其他用户对他的信任程度也会提高.因此用户信誉度也是一个重要因素.用户信誉度可以通过用户评分项目的数量及用户对项目评分的差异程度来表示.用户评分项目的数量通过用户评分项目数占总项目数的比例来衡量,如公式(4)所示.

$$M_i = \frac{\text{rate}(\text{item})}{\text{total}(\text{item})} \quad (4)$$

式中, $\text{total}(\text{item})$ 表示总项目数量; $\text{rate}(\text{item})$ 表示用户 i 已评分项目的总数量.

用户对项目评分的差异程度以用户对项目评分的平均偏差来衡量,如公式(5)所示.其中, $\text{total}(\text{item}_i)$ 表示用户 i 非零评分的总数量.

$$\text{error}_i = \frac{\sqrt{\sum_{j=1}^n (r_{i,j} - \overline{\text{item}_j})^2}}{\text{total}(\text{item}_i)} \quad (5)$$

用户评分项目数占总项目数的比例越大,平均偏差越小,用户评分越准确,信誉度越高,用户信誉度模型如公式(6)所示.

$$\text{person_rely}(u) = M(u) \cdot \text{error}_u \quad (6)$$

根据以上分析,得到用户信任模型,如公式(7)所示.

$$\text{belief}(u, v) = \beta \text{relation_rely}(u, v) + (1 - \beta) \text{person_rely}(v) \quad (7)$$

式中, β 为用户偏好相似度权重; $1 - \beta$ 为用户信誉度权重,取值范围在 $[0, 1]$ 之间.

2.2 用户兴趣模型

传统的协同过滤算法基于用户的评分寻找最近邻居用户,忽略了用户兴趣的改变.如果用户兴趣发生变化,但推荐结果不变,将严重影响推荐质量,因此需要研究用户兴趣的改变对推荐性能的影响.

德国心理学家艾宾浩斯(H. Ebbinghaus)研究发现,遗忘在学习之后立即开始,而且遗忘的过程是非线性的.最初遗忘速度很快,以后逐渐缓慢,最后会保持在一个水平^[14].他认为“保持和遗忘是时间的函数”,并根据他的实验结果绘成描述遗忘进程的曲线,即著名的艾宾浩斯记忆遗忘曲线,如图1所示,对应的函数如公式(8)所示.其中, t 表示时距,即从第一次学习到当前时间的间隔长度,以分钟为单位;参数 c 和 k 是两个常量,通过反复实验,发现 $c = 1.25$, $k = 1.84$ ^[15],比较符合人的记忆遗忘规律.函数表明:保存量和遗忘量的比值与时距的对比成

反比关系.

$$f(t) = \frac{100k}{(\log t)^c + k} \quad (8)$$




图1 艾宾浩斯遗忘曲线

用户的兴趣随时间的推移发生变化是人的自然遗忘过程,即符合遗忘曲线规律^[14],因此对艾宾浩斯公式改进得到用户兴趣余量,如公式(9)所示,其中, T 表示用户对项目的评分时间与该用户的第一个评分项目时间的差值,以秒为单位, $w'_{u,i}$ 表示偏好项衰减后的偏好值, $w_{u,i}$ 表示偏好项衰减前的偏好值.

$$w'_{u,i} = w_{u,i} \times f(T) = w_{u,i} \times \frac{k}{(\log T)^c + k} \quad (9)$$

用户兴趣相似度通过引入遗忘函数的 Pearson 相关系数计算,如公式(10)所示:

$$\text{like}(u, v) = \frac{\sum_i (f(T)W_{u,i} - \overline{R}_u) \times (f(T)W_{v,i} - \overline{R}_v)}{\sqrt{\sum_i (f(T)W_{u,i} - \overline{R}_u)^2} \times \sqrt{\sum_i (f(T)W_{v,i} - \overline{R}_v)^2}} \quad (10)$$

2.3 综合相似度计算

用户相似度由用户信任相似度和用户兴趣相似度两部分组成,如公式(11)所示.

$$\text{sim}(u, v) = (1 - \lambda) \text{belief}(u, v) + \lambda \text{like}(u, v) \quad (11)$$

式中, λ 表示用户信任相似度权重因子; $1 - \lambda$ 表示用户兴趣相似度权重因子,取值范围为 $[0, 1]$.

2.4 产生推荐

根据用户信任模型和用户兴趣模型,计算用户综合相似度矩阵,采用最近邻算法选取 k 个最相似邻居,根据目标用户的评分记录,通过公式(12)预测项目的评分,并将项目评分降序排列选取排名靠前的项目推荐给目标用户.

$$R_{u,j} = \overline{R}_v + \frac{\sum_{v \in S_u} (\text{sim}(u, v)) \times R_{u,j} - \overline{R}_v}{\sum_{v \in S_u} (\text{sim}(u, v))} \quad (12)$$

2.5 算法过程

- 输入:用户—项目评分矩阵
输出:预测评分矩阵
- 步骤 1 建立用户—项目评分矩阵 $R_{u \times v}$,将矩阵中所有用户、项目及目标用户标记为 U, I, u ;
- 步骤 2 根据用户信任模型建立用户信任矩阵 RB;
- 步骤 3 根据用户兴趣模型建立用户兴趣矩阵 RL;
- 步骤 4 根据用户信任矩阵 RB 和用户兴趣矩阵 RL,利用公式(4)计算用户综合相似度矩阵 R;
- 步骤 5 选取相似度最高的 k 个用户,建立用户 u 的最近邻集合 S_u ,根据公式(4)预测用户对目标项目的评分 $R_{u,i}$,其中 S_u 表示用户 u 的最近邻集合.
- 步骤 6 将预测项目评分降序排列,进行 Top-N 推荐.

3 实验与结果

3.1 数据集

本实验采用 Movielens 站点提供的最新数据集,记录了从 1995 年 1 月 6 日到 2016 年 10 月 16 日期间,671 个用户对 9 125 部电影的 100 004 条评分数据,每个用户对至少 20 部的电影进行评分,评分范围为 1~5,评分数据的稀疏度为 $1-(100\ 004/(671 \times 9\ 125))=98.37\%$.

3.2 评估标准

目前,大多数的推荐系统均采用预测准确度来评价推荐算法的性能.预测准确度是比较推荐算法的预测评分与用户实际评分的相似程度,常用度量方法有平均绝对误差(MAE)、根均方误差(RMSE)等.其中,MAE 属于统计精度方法,是目前度量推荐性能广泛使用的标准,因此本文也选用 MAE 作为评价指标.MAE 表示预测评分与用户实际评分之间的平均绝对误差值,计算公式如(13)所示.

$$MAE = \frac{\sum_{(u,i) \in R_{test}} |R_{u,i} - \hat{R}_{u,i}|}{|R_{test}|} \tag{13}$$

式中, $R_{u,i}$ 表示用户 u 对项目 i 的实际评分; $\hat{R}_{u,i}$ 表示用户 u 对项目 i 的实际评分; R_{test} 表示测试集数据集; $|R_{test}|$ 表示测试集中数据个数.预测误差越小,推荐质量越高.

3.3 实验结果

实验选用计算机处理器为 Intel(R)Core(TM) i5-4590、3.30 GHz CPU,8 GB 内存,Windows7 专业版操作系统,算法使用 MatlabR2014b 实现.本文

实验将 MovieLens 数据集分别以 7 : 3 和 8 : 2 进行两次随机划分,前者作为训练集,构造推荐模型;后者作为测试集,测试模型性能.

3.3.1 参数选取

在实验之前,首先需要确定算法中的参数.参数的选取方法采用在训练集上进行训练,根据实验情况求出各权重因子的最优值.

(1) α 对 MAE 的影响
 α 是用户共同评分的项目比重与用户共同喜欢的项目比重之间的平衡因子,根据不同的数据集特点可以动态调整.

经过反复实验测试,选取出有代表性的 α 取值序列,如表 1 所示.根据表 1 中的每一组 α 取值,依次选取邻居个数为 5、10、15、20、25、30、35、40、45、50,分别对电影预测评分,并求出推荐精度 MAE 值.由于训练集的选取具有随机性,当训练集发生变化时,根据算法得出的预测评分会有浮动.因此,本实验将数据集以 7:3 和 8:2 进行两次随机划分.在每次划分的数据集中重复试验 5 次,然后取其平均值.权重因子 α 对算法的影响如图 2、图 3 所示.根据实验结果可以看出,在数据集划分为 7:3、 α 在 0.7~0.9 之间时,随着邻居数的增加,MAE 值相差很小,达到最优值,而当数据集划分为 8:2、 α 为 0.9,在不同的邻居数量时,MAE 值均优于其它的 α 取值,推荐性能最好.通过对比两种数据集划分的测试结果,可以看出,当训练集的数据量增大时,推荐性能提高,选取 α 的最优值为 0.9.这说明用户共同评分的项目比重为 0.9,用户共同喜欢的项目比重为 0.1 时,推荐性能最优,原因是测试所用的数据集过于稀疏,导致共同喜欢的项目比重远小于共同评分的项目比重.

表 1 权重因子 α 取值									
权重因子	取值 1	取值 2	取值 3	取值 4	取值 5	取值 6	取值 7	取值 8	取值 9
α	0.1	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9




图 2 数据集划分为 7:3 时不同的参数 α 对 MAE 的影响




图 3 数据集划分为 8:2 时不同的参数 α 对 MAE 的影响

(2) β 对 MAE 的影响

β 表示用户偏好相似度和用户信誉度之间的调和因子. 权重因子 β 对算法的影响如图 4、图 5 所示. 根据实验结果可以看出, 当测试集为 7:3 时, 随着邻居的数量增加, β 为 0.4~0.5 时 MAE 值相差很小, 并且达到最低值; 当测试集为 8:2 时, 随着邻居的数量增加, β 为 0.4 时的 MAE 值略优于 β 为 0.5, 达到最低值. 因此, 选取 β 取值为 0.4, 即当用户偏好相似度在用户信任度计算中权重为 0.4, 用户信誉度权重为 0.6 时, 推荐性能最好. 由此可知, 当用户偏好接近时, 用户评价的项目数量越多, 对项目评分的差异程度越小, 该用户越值得信任, 其推荐的项目越可靠.




图 4 数据集划分为 7:3 时不同的参数 β 对 MAE 的影响




图 5 数据集划分为 8:2 时不同的参数 β 对 MAE 的影响

(3) λ 对 MAE 的影响

λ 表示用户信任度和用户兴趣度之间的调和因

子. 权重因子 λ 对算法的影响如图 6、图 7 所示. 根据实验结果可以看出, 当测试集为 7:3, 随着 λ 值的增加, MAE 值呈现较明显的下降趋势. 当 λ 为 0.9 时, MAE 值最低, 同时当推荐集中邻居个数不大于 30 时, MAE 值总体呈现下降趋势, 当推荐集中邻居个数大于 30 时, MAE 值缓慢上升, 其原因是新增加的推荐项目同用户相关的项目比值开始减小, 即推荐集中开始引入与用户相关性不高的项目; 当测试集为 8:2 时, 随着 λ 值的增加, MAE 值依然呈现明显的下降趋势, 在 λ 为 0.9 时达到最优值. 由此可见, 当用户信任相似度在用户综合相似度计算中权重为 0.9, 用户兴趣权重为 0.1 时, 推荐性能最好. 之所以导致用户兴趣权重值较小, 原因可能是本文所选的数据集中用户对项目随时间变化导致兴趣发生的变化不明显.




图 6 数据集划分为 7:3 时不同的参数 λ 对 MAE 的影响




图 7 数据集划分为 8:2 时不同的参数 λ 对 MAE 的影响

3.2.2 算法对比

为了评价推荐算法的精度, 将本文提出的综合信任 and 用户兴趣的协同过滤推荐算法 CF-BI 与传统的协同过滤推荐算法 CF 进行对比实验. 同时, 和采用单一要素的协同过滤算法进行了对比, 包括基于用户信任的协同推荐算法 CF-B、基于用户兴趣的协同推荐算法 CF-I. 采用 MovieLens 数据集, 对数据集进行两次随机划分, 分别为 7:3 和 8:2, 然后依次对目标用户选取不同的邻居个数得到的推荐精度 MAE 值进行对比, 结果如图 8 和图 9 所示.

从图 8 和图 9 可知,当训练集从 70%增加到 80%时,MAE 值在四种算法中都有明显的下降,说明随着训练集的增大,推荐精度有了明显提高.从图 9 可知,本文提出的用户信任模型明显优于传统的协同过滤算法,MAE 值最小达到了 0.71;用户兴趣模型在邻居数超过 15 时,算法性能有显著提高,MAE 值最小达到了 0.69;综合考虑用户信任和用户兴趣的算法时,MAE 值达到了 0.66,比传统的基于用户的协同过滤算法提高了 16.98%.由此可见,综合考虑用户信任和用户兴趣的协同过滤算法,能够有效提高系统的推荐性能.




图 8 数据集划分为 7:3 时不同的推荐算法对 MAE 的影响




图 9 数据集划分为 8:2 时不同的推荐算法对 MAE 的影响

4 结束语

协同过滤算法在推荐系统中的应用非常广泛,但存在推荐准确度不高、数据稀疏性和冷启动等问题,因此本文结合用户信任和用户兴趣两个因素,对传统的协同过滤算法进行了改进.在用户信任模型中,考虑对项目共同评分及评分反映的项目偏好的影响;在用户兴趣模型中,考虑用户兴趣随时间的变化,采用艾宾浩斯遗忘曲线模拟用户兴趣的衰减规律,然后将用户信任和用户兴趣结合,通过权重因子调整两者在相似度中的比例,经过实验确定权重因子的最优值,最后根据最近邻居预测评分并进行推荐.实验结果表明,该算法能够有效提高推荐的准确性.在未来的研究中将下一步研究用户属性的权重分配对用户信任在推荐系统中的影响.

参考文献:

[1] 王立才,孟祥武,张玉洁. 上下文感知推荐系统[J]. 软件学报,2012,23(1):1-20.

[2] 郭宁宁,王宝亮,侯永宏,常鹏. 融合社交网络特征的协同过滤推荐算法[J]. 计算机科学与探索,2018,12(02):208-217.

[3] OZSOY M G,POLAT F. Trust based recommendation systems [C]//Proceedings of the 17th International Conference on World Wide Web, New York: ACM, 2013:1267-1274.

[4] 邹本友,李翠平,谭力文,等. 基于用户信任和张量分解的社会网络推荐[J]. 软件学报,2014,25(12):2852-2864.

[5] 杨兴耀,于炯,吐尔根. 依布拉音,等. 基于信任模型填充的协同过滤推荐模型[J]. 计算机工程,2015,41(5):6-13.

[6] 郝立燕,王靖. 基于填充和相似性信任因子的协同过滤推荐算法[J]. 计算机应用,2013,33(3):834-837.

[7] 陆坤,谢玲,李明楚. 一种融合隐式信任的协同过滤推荐算法[J]. 小型微型计算机系统,2016,37(2):241-245.

[8] 郑洁,钱育蓉,杨兴耀,等. 基于信任和项目偏好的协调过滤算法[J]. 计算机应用,2016,36(10):2784-2788.

[9] LIY M, MUC T, LAIC Y. A social recommender mechanism for e-commerce combining similarity, trust and relationship [J]. Decision Support Systems, 2013, 55(3):740-752.

[10] 李克潮,梁正友. 适应用户兴趣变化的指数遗忘协同过滤算法[J]. 计算机工程与应用,2011,47(13):154-156.

[11] 印桂生,崔晓晖,马志强. 遗忘曲线的协同过滤推荐模型[J]. 哈尔滨工程大学学报,2012,33(1):85-90.

[12] 胡伟健,滕飞,李灵芳,等. 适应用户兴趣变化的改进型协同过滤算法[J]. 计算机应用,2016,36(8):2087-2097.

[13] 文俊浩,舒珊. 一种改进相似性度量的协同过滤推荐算法[J]. 计算机科学,2014,41(5):68-71.

[14] 于洪,李转运. 基于遗忘曲线的协同过滤推荐算法[J]. 南京大学学报(自然科学),2010,46(5):520-527.

[15] 江志恒,刘乃岑. 论遗忘函数—关于记忆心理学的数学讨论[J]. 心理科学进展,1988(3):56-60.

作者简介:

王 维 女,(1981-),硕士,讲师. 研究方向为智能信息处理、机器学习. E-mail: wangw850@126. com.

高 岭 男,(1964-),博士,教授. 研究方向为智能信息处理、网络安全.

高全力 男,(1988-),博士研究生. 研究方向为上下文感知推荐系统、机器学习、数据挖掘.