

文章编号: 2095-4980(2021)02-0319-05

基于有限计算环境的推荐信息过滤算法

阳馨, 张晓, 张修阳, 刘语欢

(四川水利职业技术学院 信息工程系, 四川 成都 611231)

摘要: 推荐信息泛滥严重影响了移动智能终端的用户体验, 而有限计算环境制约了移动推荐信息过滤模型与算法的研究。针对上述问题, 结合用户画像技术与信息过滤方法, 提出了一种基于有限计算环境的移动推荐信息过滤算法。该算法通过用户轨迹信息构建用户画像, 根据用户画像与需求特征, 对外界推荐的各类信息进行过滤, 并最终进行二次推荐。仿真实验证明: 该算法过滤精确度高, 个性化服务能力较强, 其无需额外占用过多的系统计算与存储资源, 性价比较高, 因而适用于移动智能终端的有限计算环境, 具有一定的实用性。

关键词: 过滤算法; 有限计算环境; 移动终端; 推荐过滤; 电子商务

中图分类号: TN913.21; TP393 **文献标志码:** A **doi:** 10.11805/TKYDA2020078

Recommendation information filtering algorithm based on limited computing environment

YANG Xin, ZHANG Xiao, ZHANG Xiuyang, LIU Yuhuan

(Information Engineering Department, Sichuan Water Conservancy Vocational College, Chengdu Sichuan 611231, China)

Abstract: The inundation of recommendation information has seriously affected the user experience of mobile intelligent terminal, while the limited computing environment restricts the research on the filtering model and algorithm of mobile recommendation information. A mobile recommendation information filtering algorithm based on limited computing environment is proposed by combining user portrait technology and information filtering method. The algorithm constructs user profile through user trajectory information, filters all kinds of information recommended by the outside world according to user profile and demand characteristics, and finally recommends information the second time. The simulation results show that the algorithm has high filtering accuracy and strong personalized service ability. It needn't occupy too much system computing and storage resources, and has high cost performance. It is suitable for the limited computing environment of mobile intelligent terminal, and has certain practicability.

Keywords: filtering algorithm; limited computing environment; mobile terminal; recommendation filtering; E-commerce

移动电子商务时代的推荐系统仍然通过记录客户偏好, 并与商品的特征进行匹配, 从而引导客户消费^[1-2]。其中的客户偏好与商品特征等信息统称为推荐知识, 这些知识通常是由专家系统或电子商务营销系统从客户的消费行为中挖掘出来。而这些推荐知识的发掘与发布工作, 主要集中在服务器中进行^[3-4]; 通常来说, 服务器将推荐信息发布或传递给客户端之后, 其主要任务即告结束, 而无需估计客户端的信息负载^[5-6]。在当前信息泛滥的移动互联网环境中, 作为有限计算环境的智能手机受到了海量服务器推荐信息的冲击; 大量的智能手机因为计算与存储能力有限, 导致被推荐信息冲击, 严重影响了用户体验^[7-8]。有限计算环境下如何面对这一问题, 需要如何有效给予用户所亟需的信息, 过滤或暂存其他信息, 迫切需要移动智能领域提供一种满足智能手机持有者个性化与高匹配度需求的推荐信息过滤机制^[9-10]。国内外研究者目前解决这个问题的主要办法是在推荐服务

收稿日期: 2020-03-02; 修回日期: 2020-04-26

基金项目: 四川省 2018~2020 年高等教育人才培养质量和教学改革资助项目(JG2018-1127); 四川水利职业技术学院科研资助项目(KY2020-31)

作者简介: 阳馨(1982-), 女, 学士, 副教授, 主要研究方向为数据挖掘、自然语言处理。email: yang_xin_2020@163.com

器一侧, 通过实施算法的精细化与用户画像持续跟踪等措施, 减少自身发送推荐信息的总量, 从而控制电子商务环境中的推荐信息总数^[11-12]。而实践表明, 由于推荐服务器的发送控制解决方案只能控制自身的推荐信息发布量, 而无法控制其他服务器的发布量, 因此无法从根本上解决这一问题; 因而有部分研究人员提出在智能移动终端上加载过滤模块解决这一问题的思路, 但尚无相关算法与模型问世。本研究设计了基于有限计算环境的移动推荐信息过滤算法, 在智能移动终端中对收到的推荐信息进行过滤, 从而节省整个系统的处理开销, 取得了一定的成效。

1 算法原理与结构

基于上文中的思路, 本研究提出了移动推荐信息过滤算法(Mobile Recommendation Information Filtering, MRIF); 该算法的核心原理如图 1 所示。

步骤 1: 该算法首先将接收到的推荐信息全部汇总到缓冲中待处理, 如果缓冲溢出, 则丢弃部分信息, 并采集智能终端当前的场景与用户信息;

步骤 2: 根据手机中现有的用户使用信息, 提取智能终端用户的特征、偏好与需求, 并以概率图方法, 构建用户画像;

步骤 3: 根据用户画像信息与当前场景信息, 对缓冲中的推荐信息进行过滤与分级, 意义较为重要的推荐信息将被提交给用户, 否则将提取推荐信息的摘要, 在用户空闲时提交给用户或直接丢弃;

步骤 4: 根据用户实际选择推荐信息的情况, 对其画像与算法相关参数进行反馈调整。

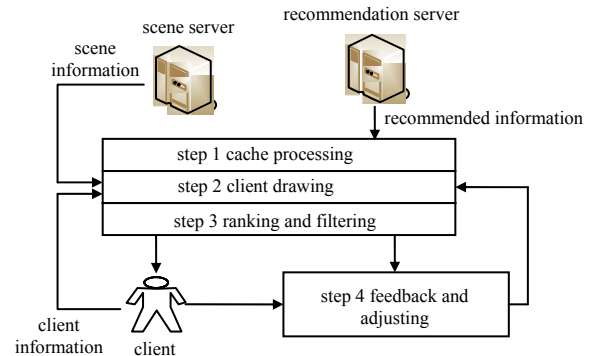


Fig.1 Principle and structure of MRIF algorithm
图 1 算法原理与结构

2 算法描述

MRIF 算法的核心内容表述如下(缓冲处理部分略去), 首先通过概率图方法, 进行用户画像构建:

$$P(l) = \begin{cases} p, & L_{\min}^{\text{lim}} < L < L_{\max}^{\text{lim}} \\ p + \frac{1-p}{L_{\max} - L_{\max}^{\text{lim}}} (L - L_{\max}^{\text{lim}}), & L_{\max}^{\text{lim}} \leq L \leq L_{\max} \\ 1, & L \geq L_{\max} \end{cases} \quad (1)$$

式中: $P(l)$ 是用户采用 l 操作的概率; 而 L 是用户 l 操作的关键词合集; L_{\min}^{lim} 以及 L_{\max}^{lim} 是 l 操作的上下确界; L_{\max} 则是 l 操作的场景适用范围限定。该用户的当前状态设定为 p , 由智能终端的社交、传感、定位信息综合生成, 当前状态(关键词合集)在 L_{\max}^{lim} 与 L_{\max} 之间时, 用户配套的关键词的强度不断提升, 并不断充实新的关键词。反之, 当用户高速变动场景, 切换关键词时, 将停止更新关键词。

根据该用户既往采用某类推荐信息的约束概率, 有:

$$P(E_i) = P(E_{i-1})P(E_i|E_{i-1}), i > 1 \quad (2)$$

式中 $P(E_i|E_{i-1})$ 是在第 $i-1$ 次采用了某类推荐信息的条件下, 当前 i 推荐信息被采用的概率。

基于上述定义, 可以构建下列三种推荐信息与用户特征匹配的情况:

日常状态, 用户信息采集密度较为均匀, 整个系统疏漏用户特征的概率较低, 而此时用户匹配多样推荐信息的过滤能力就会得到加强, 基于此, 本算法在非采购与浏览状态时, 通过日常状态采集勾勒用户画像, 有:

$$\mu_i = \left| \frac{F_i}{F_i^{\max}} \right|, i = 1, 2, \dots, N \quad (3)$$

$$P(k) = \frac{l_k}{\sum_{k=1}^{n-1} l_k} \quad (4)$$

$$H(P) = -C \sum_{k=1}^{n-1} P(k) \ln P(k) \quad (5)$$

式中: μ_i 是匹配操作 i 的当前价值系数; F_i 是匹配操作 i 相关的反馈价值系数; F_i^{\max} 是操作 i 的价值系数;

N 是当前过滤的推荐信息数； l_k 是在缓冲 k 中的推荐信息数； $P(k)$ 是缓冲 k 中推荐信息数被采纳的概率； C 是调剂系数，而 $H(P)$ 是匹配推荐的成功概率表征值。

选购状态，针对某些推荐信息，在日常状态画像勾勒算法上做了较大改进。

选购状态的画像处理过程如下：

$$v_i = \left| \frac{U_i}{U_n} \right|, i = 1, 2, \dots, M \quad (6)$$

$$D(k) = \frac{v_k}{\sum_{k=1}^{n-1} v_k} \quad (7)$$

$$H(V) = -C \sum_{k=1}^{n-1} D(k) \ln D(k) \quad (8)$$

式中： v_i 是匹配操作 i 的当前处理向量；而 U_i 是 i 的价值系数； U_n 是操作 i 的期望系数； M 是当前关键词匹配较高的 TOPN(前 N) 个推荐信息； v_k 是缓冲 k 中的推荐信息数； $D(k)$ 是缓冲 k 中推荐信息数被采纳的概率； $H(V)$ 是匹配推荐的成功概率表征值，该数越大，说明用户的选择范围越宽。

最后是浏览状态，该状态的画像处理过程如下：

$$\zeta_i = \left| \frac{S_i}{S_{\text{total}}} \right|, i = 1, 2, \dots, G \quad (9)$$

$$F(k) = \frac{s_k}{\sum_{k=1}^{n-1} s_k} \quad (10)$$

$$H(S) = -C \sum_{k=1}^{n-1} F(k) \ln F(k) \quad (11)$$

由于浏览状态是非针对性操作状态的，因而对日常状态画像勾勒算法进行了改进。其中的 ζ_i 是匹配操作 i 的当前价值系数； S_i 是匹配操作 i 相关的反馈价值系数； S_{total} 为用户当前总的价值获取量； G 则是用户与信息的匹配系数； s_k 是缓冲 k 的推荐信息数； $F(k)$ 是缓冲 k 中推荐信息数被采纳的总体概率； $H(S)$ 是匹配推荐的成功概率表征值，该数越大，说明用户未来选择上述推荐信息的概率越大。

完成上述用户画像勾勒后，将进行下列操作，从而实现推荐信息与用户的匹配。对于匹配操作 l ，可以将其匹配程度描述为：

$$S(P_l) = \begin{cases} \frac{P_l - P_d}{P_{\text{lim}} - P_d}, & P_l \geq P_d \\ 0, & P_l < P_d \end{cases} \quad (12)$$

式中： P_l 是无条件匹配概率； P_d 是匹配度极限； P_{lim} 是根据上述三种状态求得的有条件匹配概率。进一步，加载了当前场景影响因子的匹配程度如下：

$$S(P) = H(P) \times \sum_{l=1}^N W(l) \times S(P_l) \quad (13)$$

式中： N 是所有推荐信息数量；而 $W(l)$ 是上文中计算得到的匹配度权值因子。

最终，对于具体的推荐信息 n ，其匹配度函数表示为：

$$S(U_n) = \begin{cases} 0, & U_n \geq U_d \\ \frac{U_d - U_n}{U_d - U_{\text{lim}}}, & U_n < U_d \end{cases} \quad (14)$$

在这一组匹配计算公式中， U_n 是当前具体的推荐信息的价值系数； U_d 是计算获得的用户期望系数； U_{lim} 是匹配度极限。进一步，当考虑场景因素时，可以最终构建其匹配度计算公式为：

$$S(U) = H(V) \times \sum_{n=1}^M W(n) \times S(U_n) \quad (15)$$

式中： M 是相关推荐信息的集合； $W(n)$ 是当前推荐信息 n 的价值系数。

最终被保留的推荐信息处理，需要对下列三种情况进行分别的排队提交给客户，首先需要对三种情况进行归类，本研究通过下列归因函数进行推荐信息的分类：

$$S_{load} = \begin{cases} \frac{\eta}{\eta_{lim}}, \eta < \eta_{lim} \\ 1, \eta \geq \eta_{lim} \end{cases} \quad (16)$$

$$\eta = H(S) \times \frac{\sum_{i \in L} \varepsilon_i P_{lossi}}{\sum_{j \in L} P_j} \quad (17)$$

式中： η 是推荐信息的采纳率； L 是相关推荐信息的集合； L' 是既往被采纳的推荐信息的集合； ε_i 是当前推荐信息 i 意义权重； P_{lossi} 是推荐信息 i 的损失影响程度； P_j 是信息 j 的影响程度； S_{load} 是当前推荐信息的意义负载； η_{lim} 是采纳推荐信息的重要程度阈值，初始值 30%，可以根据总体队列长度与处理速度进行调节。

至此：

$$\varepsilon_i = \varepsilon_{i1} \frac{L_{loss1}}{L_{loss}} + \varepsilon_{i2} \frac{L_{loss2}}{L_{loss}} + \varepsilon_{i3} \frac{L_{loss3}}{L_{loss}} \quad (18)$$

式中 L 是三类推荐信息各自的意义负载。由此，可以指定下列处理流程：

步骤 1：对数据进行归一化处理，有：

$$y_{ij} = \frac{x_{ij} - \min_{1 \leq i \leq n} \{x_{ij}\}}{\max_{1 \leq i \leq n} \{x_{ij}\} - \min_{1 \leq i \leq n} \{x_{ij}\}}, j = 1, 2, \dots, m \quad (19)$$

步骤 2：将归一化后的数据，根据下列方法进行重要性判断，有： $x_{min} = \{x_{1,min}, x_{2,min}, \dots, x_{m,min}\}$ ($i = 1, 2, \dots, m$)，为最紧迫推荐信息。而 $x_{max} = \{x_{1,max}, x_{2,max}, \dots, x_{m,max}\}$ ，为非实时推荐信息。

步骤 3：通过意义负载矩阵 R 中的重要性系数 r_{ij} 测度各推荐信息的紧迫性：

$$R = \begin{bmatrix} r_{11} & r_{12} & \dots & r_{1,m} & r_{1,min} & r_{1,max} \\ r_{21} & r_{22} & \dots & r_{2,m} & r_{2,min} & r_{2,max} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ r_{n1} & r_{n2} & \dots & r_{nm} & r_{n,min} & r_{n,max} \\ r_{1,min} & r_{2,min} & \dots & r_{m,min} & r_{min} & r_{min} \\ r_{1,max} & r_{2,max} & \dots & r_{m,max} & r_{max} & r_{max} \end{bmatrix} \quad (20)$$

步骤 4：三类推荐信息划分，将意义系数 ω_k 与最高及最低优先级进行尺度分解，求得其分类系数 r_{ij} ：

$$d(x_i, x_j) = \sqrt{\sum_{k=1}^m \omega_k (x_{ik} - x_{jk})^2} \quad (21)$$

$$c = \frac{1}{\max \sqrt{\sum_{k=1}^m \omega_k (x_{ik} - x_{jk})^2}} \quad (22)$$

$$r_{ij} = 1 - cd(x_i, x_j) \quad (23)$$

最终，根据上述系数与最高/最低优先级推荐信息的相似程度区分出三类推荐信息。

3 仿真实验结果

为验证本算法的实际效能，采用了 ACM 学会提供的开源移动用户测试集，模拟了 228 个移动智能手机用户 (设定为双核 CPU，3 GB 运行内存)，在 15 个场景 (包括工作场景 5 个、学习场景 2 个、消费场景 4 个、娱乐休闲场景 3 个、社区场景 1 个) 中的推荐信息采纳过程，并与电子商务推荐管理 (E-Commerce Management Recommendation, ECMR) 算法进行了效能对比。最终的实验结果见表 1 和图 2。

表 1 两种算法使用对比

algorithm performance index	algorithm	
	MRIF	ECMR
average storage occupation	44.07 Mb	83.34 Mb
peak storage occupation	62.51 Gb	135.96 Gb
adoption rate of secondary recommendation	47.57%	33.39%
average filtration ratio	58.71%	40.72%
peak filtration ratio	77.62%	61.38%

表 1 中对比两种算法的基本性能指标。图 2 是两种算法的系统资源(计算资源)占用率对比,其中纵轴为计算资源(CPU 占用率,单位为%)。

从表 1 和图 2 中可以看出,本算法的总体性能均超过了 ECMR 算法,且占用系统资源与之相当,具有较高的性价比。

4 结论

本算法针对推荐信息泛滥严重的实际问题,结合用户画像技术与信息过滤方法,提出了一种基于有限计算环境的移动推荐信息过滤算法。该算法根据用户画像与需求特征,对推荐信息进行过滤。仿真实验表明该算法的综合性能较好,适用于有限计算环境,后续将研究该算法的服务端反馈应用、移动终端过滤信息共享等新型推荐信息过滤机制。

参考文献:

- [1] 徐林会,鲁新新. 基于协同过滤算法的团购个性化推荐系统[J]. 辽宁工程技术大学学报(自然科学版), 2017,36(7): 761-766. (XU Linhui,LU Xinxin. Collaborative filtering recommendation system based on interest drifting and similar cloud[J]. Journal of Liaoning Technical University(Natural Science), 2017,36(7):761-766.)
- [2] 王磊,高宸,周蓓,等. 基于深度学习与社交感知的地点推荐[J]. 太赫兹科学与电子信息学报, 2019,17(3):502-508. (WANG Lei,GAO Chen,ZHOU Bei,et al. Deep learning based social-aware location recommendation[J]. Journal of Terahertz Science and Electronic Information Technology, 2019,17(3):502-508.)
- [3] 陈海军. 基于 Apriori 数据挖掘算法的信息推荐图书管理系统设计[J]. 现代电子技术, 2019,42(23):115-119,124. (CHEN Haijun. Design of information recommendation book management system based on Apriori data mining algorithm[J]. Modern Electronics Technique, 2019,42(23):115-119,124.)
- [4] 赵冉. 基于云计算平台的图书馆混合推荐技术研究[J]. 现代电子技术, 2019,42(23):145-149. (ZHAO Ran. Research on library hybrid recommendation technology based on cloud computing platform[J]. Modern Electronics Technique, 2019, 42(23):145-149.)
- [5] 成保梅. 基于协同过滤的电子商务个性化推荐算法研究[J]. 现代电子技术, 2019,42(20):37-39,44. (CHENG Baomei. Research on e-commerce personalized recommendation algorithm based on collaborative filtering[J]. Modern Electronics Technique, 2019,42(20):37-39,44.)
- [6] 袁泉,常伟鹏. 基于 Hadoop 平台的图书推荐服务 Apriori 优化算法[J]. 现代电子技术, 2019,42(1):180-182. (YUAN Quan,CHANG Weipeng. Hadoop platform based Apriori optimization algorithm for book recommendation service[J]. Modern Electronics Technique, 2019,42(1):180-182.)
- [7] 王庆桦. 基于数据挖掘技术的图书馆个性化快速推荐算法研究[J]. 现代电子技术, 2019,42(5):149-151,156. (WANG Qinghua. Research on library personalized fast-recommendation algorithm based on data mining technology[J]. Modern Electronics Technique, 2019,42(5):149-151,156.)
- [8] 刘培明,骆新泉. 数字图书馆中的关联书目检索推荐方法改进与设计[J]. 现代电子技术, 2017,40(14):72-74. (LIU Peiming,LUO Xinquan. Improvement and design of recommendation method of related bibliography retrieval in digital library[J]. Modern Electronics Technique, 2017,40(14):72-74.)
- [9] 李萍,彭小华. 基于读者个性化特征的图书馆书目推荐[J]. 现代电子技术, 2018,41(17):182-186. (LI Ping,PENG Xiaohua. Library bibliographic recommendation based on personalized features of readers[J]. Modern Electronics Technique, 2018,41(17):182-186.)
- [10] 常有学,刘建胜,刘旭波. 基于 Spark 的高校图书馆书目推荐系统[J]. 现代电子技术, 2019,42(14):64-67,73. (CHANG Youxue,LIU Jiansheng,LIU Xubo. Spark-based bibliographic recommendation system for university libraries[J]. Modern Electronics Technique, 2019,42(14):64-67,73.)
- [11] 贺怀清,计瑜,惠康华,等. 一种基于稀疏分段的协同过滤推荐算法[J]. 现代电子技术, 2019,42(9):90-94. (HE Huaiqing,JI Yu,HUI Kanghua,et al. A collaborative filtering recommendation method based on sparseness segmentation[J]. Modern Electronics Technique, 2019,42(9):90-94.)
- [12] 王伟伟,段富. 基于情境感知的餐饮推荐模型设计[J]. 现代电子技术, 2018,41(18):154-157. (WANG Weiwei,DUAN Fu. Design of food recommendation model based on context awareness[J]. Modern Electronics Technique, 2018,41(18):154-157.)




Fig.2 Comparison of CPU utilization of the two algorithms
图 2 两种算法的 CPU 占用率对比