

文章编号: 2095-2163(2019)01-0173-05

中图分类号: TP311

文献标志码: A

电子商务环境下多元个性化服务推荐研究

崔睿宇, 杨怀洲

(西安石油大学 计算机学院, 西安 710065)

摘要: 在分析电子商务服务推荐系统基本工作原理的基础上,给出了推荐技术的分类标准。系统介绍了基于内容、协同过滤、基于关联规则、基于知识和基于人口统计信息等主要服务推荐算法。对这些算法的优缺点进行综合对比,对组合推荐算法的思路进行了简要介绍,给出了算法评价标准和实验常用数据集。最后,对推荐系统现存的主要问题进行了分析,并对未来的研究热点进行了预测和展望。

关键词: 服务推荐; 电子商务; 协同过滤; 算法评价

Research on personalized and diversified recommendations in E-business

CUI Ruiyu, YANG Huaizhou

(School of Computer Science, Xi'an Shiyou University, Xi'an 710065, China)

【Abstract】 On the basis of analyzing the basic working principles of e-business recommendation system, the technical recommendation standard is given. The paper systematically introduces some common recommend technologies such as recommendation based on contents, collaborative filtering recommendation, rules, Knowledge-based and demographic-based recommendations. After that, the advantages and disadvantages of these above-mentioned technical recommendations are provided. The combined recommendation algorithm is briefly introduced. Recommendation evaluation and common data sets are also introduced. Then, existing problems on personalized recommendation are analyzed. Finally, Future research challenges facing e-business recommendation are presented.

【Key words】 service recommendation; E-business; collaborative filtering; algorithm evaluation

0 引言

随着通信技术和经济环境的改变,消费者的消费模式发生了迅速的变化,网购的趋势也在逐年增加。而购物网站上海量的商品信息对消费者快速选择目标商品起到了一定的限制作用^[1]。在这种背景下,推荐系统(recommender systems)应运而生。服务推荐算法作为推荐系统的核心组成部分,成为个性化推荐领域的研究热点。由于每种推荐算法都存在各自的优点和不足,所以,服务推荐算法的组合和多元化研究对于提高推荐系统的准确性和性能具有重要意义。

1 个性化推荐技术

1.1 推荐技术分类标准

目前,对推荐系统的分类并没有统一标准,很多学者从不同角度对推荐方法进行了不同的划

分^[2-3]。文献[4]给出了区别推荐技术的二维属性:自动化程度(degree of automation)与持久性程度(degree of persistence)。

1.2 主流推荐算法

(1) 基于内容的推荐算法。基于内容的推荐,又被称为基于信息过滤的推荐,是由信息检索(Information Retrieve)领域提出来的,是指用户根据选择的对象,推荐其它类似属性的对象作为推荐结果。其核心思想是根据用户兴趣和物品特征的相似性进行推荐^[5]。

(2) 协同过滤推荐算法。协同过滤推荐(collaborative filtering recommendation)是目前研究最多的个性化推荐技术。该算法的基本思想是将用户按照兴趣的不同进行分类,同类用户具有极为相似的兴趣,因此可以由其它用户的偏好协同过滤得到对目标用户的推荐。

协同过滤主要分为两大类别^[6]: Memory-Based

基金项目: 西安市科技计划项目(201805038YD16CG22(2))。

作者简介: 崔睿宇(1995-),女,硕士研究生,主要研究方向:电子商务、服务推荐; 杨怀洲(1970-),男,博士,副教授,主要研究方向:物联网、服务计算。

通讯作者: 杨怀洲 Email: xsyu-jsjcry@163.com

收稿日期: 2018-11-02

Collaborative Filtering 和 Model-Based Collaborative Filtering。Memory-Based 方法又进一步分为 User-Based Collaborative Filtering (UBCF) 和 Item-Based Collaborative Filtering (IBCF)。

UBCF 是一种基于用户最近邻 (K-Nearest Neighbor, KNN) 实现的推荐算法, 该算法的关键过程在于对用户最近邻的查找——可以通过各种相似度量方法进行度量。UBCF 中常用的相似度量方法有: 皮尔森相关系数 (Pearson Correlation Coefficient, PCC)、夹角余弦相似度 (Cosine Similarity, COSIM) 及 Jaccard 系数 (Jaccard Coefficient) 等。由于用户之间的相似度量稳定性较差, 需要对用户之间的相似度量进行频繁更新等问题, UBCF 不适用于用户量大的信息系统。针对这一问题, 基于项目的协同过滤算法 (Item-Based Collaborative Filtering, IBCF) 被 Sarwar 等人^[7] 提出。

IBCF 的关键在于挖掘项目间的相似性, 分类相似项目, IBCF 基本采用了与 UBCF 类似的相似性计算度量方法。常见的基于项目的相似度量方法有以下几种: 基于项目的皮尔森相关系数 (Item-based Pearson Correlation Coefficient)、基于项目的夹角余弦相似度 (Item-based Cosine Similarity) 和基于项目的修正夹角余弦相似度 (Adjusted Item-based Cosine Similarity) 等。

由于基于内存的协同推荐直接应用评分数据进行相似度量计算和评分预测, 基于模型的协作推荐大量采用机器学习和数据挖掘算法。在基于模型的协同过滤推荐算法中常用的模型和算法有贝叶斯网络、聚类算法、回归算法、马尔科夫决策模型和关联规则挖掘等。

(3) 基于关联规则的推荐算法。基于关联规则的推荐 (association rule-based recommendation) 是根据关联规则对项目排序产生的推荐^[8]。电子商务领域中的购物车效应就是关联规则效应运用的典型, 通过研究分析用户频繁购买的商品之间所存在的联系, 再利用商品之间的这种关联关系为其它用户产生推荐。

(4) 基于知识的推荐算法。基于知识的推荐 (Knowledge-based recommendation) 不是建立在用户需要和偏好上的推荐, 即无需考虑用户-项目矩阵的历史信息^[9]。在某种程度上可以看做一种推理技术。

(5) 基于人口统计学的推荐算法。基于人口统计学 (Demographic-based Recommendation) 的推荐

算法是基于用户个人属性对用户进行分类, 再按照类别的不同对各类中的用户进行推荐^[10]。

1.3 各推荐技术优缺点比较

每种推荐技术的优缺点对比见表 1。

表 1 各推荐算法优缺点对比

Tab. 1 Comparison of various recommended algorithms

推荐技术	优点	缺点
基于内容的推荐算法	无冷启动问题及数据稀疏性问题; 推荐结果直观, 容易解释	复杂属性处理困难; 难以发现用户潜在兴趣
协同过滤推荐算法	推荐个性化程度高; 可发现用户的潜在兴趣; 处理复杂的非结构化对象较为容易	新用户问题; 新项目问题; 稀疏性问题; 模糊用户问题
基于关联规则的推荐算法	可离线进行; 可以发现用户的新兴兴趣点	算法较为耗时; 商品名称同义性问题难解决
基于知识的推荐算法	交互性较强; 无冷启动问题	知识发现较困难
基于用户人口统计信息的推荐算法	不存在新用户问题; 不需要领域知识	用户人口信息统计资料获取困难

1.4 组合推荐技术

组合推荐 (hybrid recommendation) 的一个最重要原则就是通过组合后应能避免或弥补各自推荐技术的弱点。理论上有很多推荐组合方法, 不同的组合思路适用于不同的应用场景。

混合推荐的分类方法大致有 2 种, 一种按照不同推荐技术混合发生阶段的不同分为前融合、中融合和后融合^[9]; 另外, 根据不同的结合方式, Robin^[11] 提出 7 种组合思路: 加权组合、变换、混合、特征组合、层叠、特征扩充以及元层次组合^[12]。

1.5 推荐算法的评价

推荐算法的评价要综合考虑实验数据集和评价标准 2 方面的选择。

1.5.1 推荐算法的实验数据集

推荐算法评价依赖的实验数据集有 2 种选择——真实数据集或者人工加工数据集。真实数据集可反映目标推荐系统的真实数据分布, 但成本高, 时效性差, 缺乏统一的评价参考性。人工加工数据集往往具有较好的一致性, 可人为控制数据的分布特征, 但只能对特定应用领域的算法评价, 数据分布特征难以反映实际应用环境中的数据特征。

推荐系统经过多年的发展, 收集和累积了大量的真实数据, 这些数据既具有一定的数量规模, 又在

一定程度上反映了各领域真实数据的分布特征, 具有较强的代表性。常用的具有参考意义的数据集有: MovieLens 数据集、EachMovie 数据集、Book - Crossing 数据集、Jester Joke 数据集和 Netflix 数据集。

1.5.2 推荐算法的准确性评价

推荐系统及算法准确性的度量至今仍无统一的标准, 一般可从预测准确性和分类准确性 2 个方面度量推荐算法的推荐质量。

1.5.2.1 预测准确性

针对评分预测推荐任务, 预测准确性是主要的度量标准。常用的预测准确性度量标准包括平均绝对误差 (Mean Absolute Error, MAE)、归一化平均绝对误差 (Normalized Mean Absolute Error, NMAE) 和均方根误差 (Root Mean Squared Error, RMSE)。

MAE 通过统计预测评分与真实评分之间绝对距离的均值来实现准确性度量, 与推荐的预测准确性呈反比, 对于 n 个真实评分 $R = \{r_1, r_2, \dots, r_n\}$, 推荐算法生成的预测评分为 $P = \{p_1, p_2, \dots, p_n\}$, 则 MAE 可表示为:

$$\varepsilon_n = \frac{\sum_{i=1}^n |p_i - r_i|}{n} \quad (1)$$

MAE 是一种绝对误差评价标准, 其往往因为评分范围的不同而造成不可比。而 NMAE 的提出通过使用评分范围对 MAE 进行了归一化处理, 从而实现相对误差度量, 克服了 MAE 的不可比性。对于评分上、下限分别为 r_{\max} 和 r_{\min} 数据集, NMAE 可表示为:

$$\varepsilon_n = \frac{MAE}{r_{\max} - r_{\min}} = \frac{\sum_{i=1}^n |p_i - r_i|}{n \times (r_{\max} - r_{\min})} \quad (2)$$

而 RMSE 可以提高预测准确性的区分度, RMSE 可表示为:

$$\varepsilon_n = \sqrt{\frac{\sum_{i=1}^n (p_i - r_i)^2}{n}} \quad (3)$$

1.5.2.2 分类准确性

分类准确性度量标准是对推荐算法进行正确或错误决策的频率统计, 分类准确性的度量与分类问题有着密切的关系, 所以其度量标准大量借用了分类算法研究中使用的标准, 常用的分类准确性度量标准主要有准确率、召回率和 F_1 评分。

准确率量化了在推荐系统所生成的推荐中, 符合用户信息需求的相关推荐结果所占比重, 召回率反映了推荐系统实现推荐的全面性。

系统可能实现的正确推荐和错误推荐状态可以见表 2 的混淆表格表示, 对应不同推荐状态的数量统计见表 3。

则准确率可表示为:

$$P = \frac{N_{rs}}{N_s} = \frac{N_{rs}}{N_{rs} + N_{is}} \quad (4)$$

召回率可表示为:

$$R = \frac{N_{rs}}{N_r} = \frac{N_{rs}}{N_{rs} + N_{rn}} \quad (5)$$

F_1 评分是对准确率与召回率的一种综合度量, 通过二者的协平均将推荐系统的分类准确性度量表示为单一评价标准, 数学表达式如下:

$$F_1 = \frac{2 \times P \times R}{P + R} = \frac{2 \times N_{rs}}{N_s + N_r} \quad (6)$$

表 2 推荐系统混淆

Tab. 2 Confusion matrix of recommended system

类型	相关性	
	相关	无关
推荐决策	推荐	相关推荐 (TP) 无关推荐 (FP)
	过滤	相关过滤 (FN) 无关过滤 (TN)

表 3 推荐系统推荐状态数量混淆

Tab. 3 State number of confusion matrix of recommended system

		相关性		总计
		相关	无关	
推荐	推荐	N_{rs}	N_{is}	$N_s = N_{rs} + N_{is}$
决策	过滤	N_{rn}	N_{in}	$N_n = N_{rn} + N_{in}$
总计		$N_r = N_{rs} + N_{rn}$	$N_i = N_{is} + N_{in}$	$N = N_r + N_i + N_s + N_n$

2 推荐系统存在的问题

随着推荐系统在电子商务领域的广泛应用, 其面临的一系列挑战也得到了越来越广泛的关注。推荐系统面临的主要问题有以下几点:

(1) 特征提取问题。虽然在信息检索中, 文本特征的提取技术已经比较成熟, 但是推荐系统的对象不一定具有文本特征或者利用文本不足以作为描述^[13]。对于多媒体数据, 如视频、音乐、图像等的特征提取方法需要结合多媒体内容分析领域的相关技术。另外, 大规模数据情况下对特征的区分性要求提高。

(2) 数据稀疏性问题。在大型的推荐系统中, 对于一个用户, 总有大量的对象没有经过评价或者查看, 而且这类数据常常比已经有此用户评价的数据量更大^[14]。此外, 用户之间选择的差异性大, 也会加重数据的稀疏性问题。

(3)冷启动问题。冷启动问题是稀疏性问题的特例^[5-14],冷启动问题可以细分为新用户问题和新项目问题^[15-17]。

当系统中出现新用户时,该用户没有对项目进行评分,推荐系统缺乏关于新用户的兴趣信息和知识。对基于内容的过滤算法,推荐系统无法建立关于新用户的兴趣模型;对基于用户的协同过滤算法,推荐系统也无法确定该用户的相似邻居;对于基于项目的协同过滤推荐算法,尽管系统可以确定不同项目之间的相似程度,但由于缺乏新用户的兴趣评分,所以仍无法对项目进行评分预测。

对于协同过滤算法来说,新项目评分的缺失将造成相似度计算和评分预测无法完成。冷启动问题的主要成因在于推荐系统对于评分数据的依赖性,所以需要在推荐系统中引入其它参考信息和知识^[18-19],用来克服评分数据的缺失对推荐系统的影响。

(4)概念漂移问题。用户在与推荐系统交互的过程中,其兴趣与偏好会受到外部各种因素的影响,如社会、家庭、重大事件都会导致用户模型发生变化,从而造成用户兴趣的概念漂移^[20-23]。

作为一种动态人机交互系统,推荐系统的概念漂移问题无法避免,因此应建立感知概念漂移的机制^[24],对用户兴趣变化进行主动跟踪。在用户兴趣模型更新、相似度计算和评分预测等各关键过程中引入关于评分的时间特性,对用户的历史评分进行区分,从而保证推荐结果符合用户需求。

(5)算法伸缩性问题。由于推荐系统的推荐精度和实时性是一对矛盾。目前大部分推荐技术的实时性是以牺牲系统的推荐质量为代价的^[24-26]。推荐系统可采用基于模型的推荐算法来提高其伸缩性,将大计算量的计算任务以离线方式进行,如推荐系统中的特征抽取、用户建模、相似度计算等都可以事先或定期进行离线计算,但是基于模型的推荐算法往往会牺牲一定的推荐准确性,造成推荐质量的下降。

3 研究展望

对目前电子商务个性化推荐方面的研究,笔者认为,协同过滤算法在未来一段时间内仍会是电子商务领域中的主流算法,而该算法自身存在的诸如数据的稀疏性问题和冷启动问题始终是国内外学者的研究热点。除了对协同过滤算法本身进行算法改进之外,数据挖掘技术的兴起无疑为克服协同过滤

算法的短板提供了更多可能。

随着人们对推荐系统认识的逐步深入,用户需求也将更易于被研究者理解,更加符合用户需求的协同过滤算法也终将被提出。同时,评估协同过滤算法的度量也将随着认识的变化不断改进。此外,随着移动终端的普及,对诸如位置、时间和终端等上下文信息进行充分利用也必将成为未来推荐系统的研究重点。

参考文献

- [1] JEONG S M, PARK S L. A study on the effect of the facilitating factors of B2C e-commerce on the online shopping and the overseas direct purchase [J]. *International Commerce & Information Review*, 2016, 18(2): 27-51.
- [2] DESHPANDE M, KARYPIS G. Item-based top-n recommendation algorithms [J]. *ACM Transactions on Information Systems*, 2004, 22(1):143-177.
- [3] LINDEN G, SMITH B, YORK J. Amazon.com recommendations; Item-to-item collaborative filtering [J]. *IEEE Internet Computing*, 2003, 7(1):76-80.
- [4] SARWAR B, KARYPIS G, KONSTON J, et al. Analysis of recommendation algorithms for E-commerce [C]//*Proceedings of the 2nd ACM Conference on Electronic Commerce*. Minneapolis, Minnesota, USA: ACM, 2000: 158-167.
- [5] PARK S T, PENNOCK D, MADANI O, et al. Naive filterbots for robust cold-start recommendation [C]//*Proceedings of the 12th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Philadelphia, PA, USA: ACM, 2006: 699-705.
- [6] GHAZANFAR M A, PRUGEL-BENNETT A. Fulfilling the needs of gray-sheep users in recommender systems, a clustering solution [C]//*Proceedings of the 2011 International Conference on Information Systems and Computational Intelligence*. China: Southampton Wireless Group, 2011: 201-206.
- [7] SARWAR B, KARYPIS G, KONSTON J, et al. Item-based collaborative filtering recommendation algorithms [C]//*Proceedings of the 10th International World Wide Web Conference (WWW10)*. Hong Kong: ACM, 2001: 285-295.
- [8] ADOMAVICIUS G, TUZHILIN A. Expert-driven validation of rule-based user models in personalization applications [J]. *Data Mining and Knowledge Discovery*, 2001, 5(1-2):33-58.
- [9] 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.
- [10] PAZZANI M J. A framework for collaborative, content-based and demographic filtering [J]. *Artificial Intelligence Review*, 1999, 13(5-6):393-408.
- [11] BURKE R. Hybrid recommender systems: Survey and experiments [J]. *User Modeling and User-Adapted Interaction*, 2002, 12(4): 331-370.
- [12] BENNETT J, LANNING S. The Netflix Prize [C]//*Proceedings of the KDD Cup Workshop*. San Jose: KDD, 2007: 3-6.
- [13] SHARDANAND U, MAES P. Social information filtering: Algorithms for automating "Word of Mouth" [C]//*Proceedings of the Conference on Human Factors in Computing Systems*. New York: ACM Press, 1995: 210-217.
- [14] ADOMAVICIUS G, TUZHILIN A. Toward the next generation of

- recommenders systems; A survey of the state-of-the-art and possible extensions [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2005, 17(6):734-749.
- [15] CLAYPOOL M, GOKHALE A, MIRANDA T, et al. Combining content-based and collaborative filters in an online newspaper [C]//*Proceedings of the ACM SIGIR '99 Workshop Recommender Systems: Algorithms and Evaluation*. New York: ACM Press, 1999: 1-11.
- [16] GOOD N, SCHAFER J B, KONSTAN J A, et al. Combining collaborative filtering with personal agents for better recommendations [C]//*Proceedings of the 16th National Conference on Artificial Intelligence and the eleventh Innovative applications of artificial intelligence conference innovative applications of artificial intelligence*. Orlando, Florida, USA: ACM, 1999: 439-446.
- [17] SARWAR B M, KONSTAN J A, BORCHERS A, et al. Using filtering agents to improve prediction quality in the groupLens research collaborative filtering system [C]//*Proceedings of the 1998 ACM Conference on Computer Supported Cooperative Work*. Seattle, Washington, USA: ACM, 1998: 345-354.
- [18] YU Kai, SCHWAIGHOFER A, TRESP V, et al. Probabilistic memory-based collaborative filtering [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2004, 16(1):56-69.
- [19] RASHID A M, ALBERT I, COSLEY D, et al. Getting to know you; learning new user preferences in recommender systems [C]//*Proceedings of the 7th International Conference on Intelligent User Interfaces*. San Francisco, California, USA: ACM, 2002: 127-134.
- [20] DING Yi, LI Xue. Time weight collaborative filtering [C]//*Proceeding of the 14th ACM International Conference on Information and Knowledge Management*. Bremen, Germany: ACM, 2005: 485-492.
- [21] KOREN Y. Collaborative filtering with temporal dynamics [C]//*Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Paris, France: ACM, 2009: 447-456.
- [22] SUGIYAMA K, HATANO K, YOSHIKAWA M. Adaptive web search based on user profile constructed without any effort from users [C]//*Proceedings of the 13th International Conference on World Wide Web*. New York, NY, USA: ACM, 2004: 675-684.
- [23] WIDMER G, KUBAT M. Learning in the presence of concept drift and hidden contexts [J]. *Machine Learning*, 1996, 23(1): 69-101.
- [24] O'CONNOR M, HERLOCKER J. Clustering items for collaborative filtering [R]. Minneapolis, MN: University of Minnesota, 1999.
- [25] THIESSON B, MEEK C, CHICKERING D M, et al. Learning mixture of DAG models [C]//*Proceedings of the 14th Conference on Uncertainty in Artificial Intelligence*. Madison, Wisconsin: ACM, 1998: 504-513.
- [26] UNGAR L H, FOSTER D P. Clustering methods for collaborative filtering [C]//*Proceedings of the 1998 Workshop on Recommendation Systems*. Menlo Park: AAAI Press, 1998: 112-125.

(上接第 172 页)

- [5] ZHANG Meishan, DENG Zhilong, CHE Wanxiang, et al. Combining statistical model and dictionary for domain adaption of Chinese word segmentation [J]. *Journal of Chinese Information Processing*, 2012, 26(2): 8-12.
- [6] LAFFERTY J, MCCALLUM A, PEREIRA F C N. Conditional random fields: Probabilistic models for segmenting and labeling sequence data [C]//*Proceedings of the eighteenth international conference on machine learning (ICML)*. Williamstown, MA, USA: Morgan Kaufmann, 2001: 282-289.
- [7] COLLINS M. Discriminative training methods for hidden markov models: Theory and experiments with perceptron algorithms [C]//*Proceedings of the ACL-02 conference on Empirical methods in natural language processing—Volume 10*. Philadelphia: Association for Computational Linguistics, 2002: 1-8.
- [8] COLLOBERT R, WESTON J, BOTTOU L, et al. Natural language processing (almost) from scratch [J]. *Journal of Machine Learning Research*, 2011, 12(8): 2493-2537.
- [9] MANSUR M, PEI Wenzhe, CHANG Baobao. Feature-based neural language model and Chinese word segmentation [C]//*IJCNLP*. Nagoya, Japan: ACL, 2013: 1271-1277.
- [10] PEI Wenzhe, GE Tao, CHANG Baobao. Max-margin tensor neural network for Chinese word segmentation [C]//*Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics*. Maryland, USA: ACL, 2014: 293-303.
- [11] CHEN Xinchu, QIU Xipeng, ZHU Chenxi, et al. Gated recursive neural network for Chinese word segmentation [C]//*Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing*. Beijing, China: ACL, 2015: 1744-1753.
- [12] CHEN Xinchu, QIU Xipeng, ZHU Chenxi, et al. Long short-term memory neural networks for Chinese word segmentation [C]//*Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*. Lisbon, Portugal: ACL, 2015: 1197-1206.
- [13] ZHANG Jinchao, MENG Fandong, WANG Mingxuan, et al. Is local Window essential for neural network based Chinese word segmentation? [M]//SUN M, HUANG X, LIN H, et al. *Chinese computational linguistics and natural language processing based on naturally annotated big data*. Cham: Springer, 2016, 10035: 450-457.
- [14] WANG Peilu, QIAN Yao, SOONG F K, et al. A unified tagging solution; Bidirectional LSTM recurrent neural network with word embedding [J]. *arXiv preprint arXiv:1511.00215*, 2015.
- [15] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. *Neural computation*, 1997, 9(8): 1735-1780.
- [16] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks [J]. *IEEE Transactions on Signal Processing*, 1997, 45(11): 2673-2681.
- [17] CHE Wanxiang, LI Zhenghua, LIU Ting. Ltp: A Chinese language technology platform [C]//*Proceedings of the 23rd International Conference on Computational Linguistics: Demonstrations*. Beijing: Association for Computational Linguistics, 2010: 13-16.