

个性化广告推荐系统及其应用研究

张玉洁 董政 孟祥武

(北京邮电大学智能通信软件与多媒体北京市重点实验室 北京 100876)

(北京邮电大学计算机学院 北京 100876)

摘要 近年来,随着互联网及智能移动设备的发展和普及,丰富了广告的推送方式和投放平台.但是传统的广告推送无法满足用户对个性化广告的需求,导致用户对广告产生抵触情绪,给广告推送带来极大的挑战.个性化广告推荐系统作为应对这些挑战的有效手段,成为个性化服务领域的研究热点之一.个性化广告推荐系统获取用户兴趣偏好,利用多种个性化广告推荐技术,通过 PC 端、移动终端等多平台为用户提供个性化广告,并且已经在一些应用系统中取得不错的效果.本文对个性化广告推荐系统的研究进展进行系统地综述,从个性化广告推荐的概述出发,对近年来个性化广告推荐的关键技术进行深入分析,包括数据采集与预处理、用户偏好获取、个性化广告推荐技术等.统计分析了个性化广告推荐中使用的多种数据集和评价指标,总结当前个性化广告推荐在传统互联网、移动服务、数字标牌、IPTV 等场景下的应用.最后对个性化广告推荐系统存在问题和未来深入研究的方向进行讨论和展望.

关键词 个性化广告;推荐系统;用户偏好获取;上下文推荐;应用领域;数据挖掘

Research on Personalized Advertising Recommendation Systems and their Applications

ZHANG Yu-Jie DONG Zheng MENG Xiang-Wu

(Beijing Key Laboratory of Intelligent Telecommunications Software and Multimedia,

Beijing University of Posts and Telecommunications, Beijing 100876)

(School of Computer Science, Beijing University of Posts and Telecommunications, Beijing 100876)

Abstract In recent years, with the development and popularization of the Internet and smart mobile devices, the promotion methods and delivery platforms of advertisements have enriched. However, the traditional advertising push can't meet the needs of users for personalized advertising, resulting in users' resistance to advertising, which brings great challenges to advertising push. As an effective means to deal with these challenges, personalized advertising recommendation system has become one of the hottest research topics in the field of personalized services. Personalized advertising recommendation system obtains users' interests and preferences, uses a variety of personalized advertising recommendation technologies, provides personalized advertising for users through PC-side, mobile terminals and other platforms, and has achieved good results in some application systems. Therefore, personalized advertising recommendation system can alleviate the influence on users caused by the content of advertisements does not meet the needs of users, or the time or location of advertisements is not appropriate. At the same time, personalized advertising recommendation system can effectively deal with the

challenges brought by advertisement recommendation due to the negative emotions of users and the decrease of advertising profits, and reduce users' resistance to advertisements and enhance user experience, which not only meets users' personalized needs, but also considers the economic benefits generated by advertisements. This paper summarizes the research progress of personalized advertising recommendation system. Starting from the introduction of personalized advertising recommendation, this paper expounds the differences between this paper and the review of the existing advertising recommendation system, and leads to the writing motivation of this paper. It points out the similarities and differences between personalized advertising and non-personalized advertising such as other forms of advertising and traditional advertising, analyzes the differences between personalized advertising recommendation and other personalized recommendation, highlights the uniqueness of this field. Then, this paper deeply analyses the key technologies of personalized advertising recommendation, including data acquisition and preprocessing, acquisition techniques for explicit and potential user preferences, collaborative filtering, context, hybrid recommendation, click rate prediction and other personalized advertising recommendation technologies, and classifies these key technologies in detail, finds their advantages and disadvantages, and draws the direction of improvement. Subsequently, this paper makes a statistical analysis of the internal data set, the open data set and the data set captured by some researchers in personalized advertising recommendation. After that, it summarizes the traditional evaluation indicators and specific evaluation indicators commonly used in advertising recommendation, and makes a comparative analysis and explanation of some studies combining with the main data sets and evaluation indicators. Then it organizes the current application of personalized advertising recommendation in traditional Internet, mobile service, digital signage, IPTV and other scenarios, and finds out the future development direction of each scenario, and some typical applications are listed and analyzed. In addition, advertising recommendation needs to be improved in the aspects of the timeliness of advertising recommendation, privacy protection of users, cold start in advertising recommendation, content sensitivity of advertising recommendation, dynamic preference acquisition of users, extension of content-based advertising context recommendation, localization of mobile advertising recommendation system, and utilization of multi-source data. Finally, in order to develop the personalized advertising recommendation system, this paper discusses and prospects the problems and the further research in the future in the above aspects of advertising recommendation.

Key words personalized advertising; recommendation system; user preference acquisition; context recommendation; application domain; data mining

1 引言

在当今时代,互联网已经成为人们信息传递的最迅速,最便捷,最有效的媒介.相对于传统媒体,互联网的优势在于其具有较强的交互性和生动性^[1].并且伴随着智能移动终端的兴起和普及,为广告推送带来极大的便利.当用户浏览网页或者浏览社交软件动态时,会出现各种形式的广告,为用户提供多种信息,一定程度上丰富了用户的生活.但是由于每位用户的背景差异,大范围无差别的广告投放方式难以满足所有用户的个性化需求,因此也难以以为广告公司带来可观的经济效益.正是基于满足用户需求和最大化广告经济效益的考虑,个性化广告推荐系统(Personalized Advertising Recommendation

System, PAR)^[2]应运而生.

近年来,互联网的发展对广告行业的帮助卓有成效,使得广告在人们生活中无处不在,在线广告变得越来越受欢迎.中国广告市场回顾报告中指出,2018年中国广告市场中互联网媒体所占比例增长稳定,为7.3%^①.IAB的报告中指出,2018年全年美国的互联网广告收入达到1075亿美元,相比2017年总体增长21.8%,其中2018年全年移动终端广告收入占总体广告收入的53.8%^②.在一个成功的广告活动中,用户和商家都会从中获益,用户会获得满足其

① CTR:2018年中国广告市场回顾报告. <http://www.199it.com/archives/831411.html>

② IAB Internet Advertising Revenue Report 2018 Full Year Results. <https://www.iab.com/wp-content/uploads/2019/05/Full-Year-2018-IAB-Internet-Advertising-Revenue-Report.pdf>

潜在兴趣的产品.商家会通过广告掩盖其弱点,并强调其优势来打败竞争者^[3].同时,一个成功的广告推送,必须要满足 5 个合适原则,即在合适的时间,在合适的场合,通过合适的方法,将合适的广告展示到合适的用户面前.个性化的广告推荐根据上述原则并结合用户的偏好和兴趣,吸引用户的注意力^[4].因此,个性化广告推荐系统对于 Google、百度等大多数专业技术公司来讲是一项内在要求.

在过去几年内,已经出现许多推荐系统相关的综述.例如,Burke 等人^[5]对混合推荐系统进行综述,Su 等人^[6]对协同过滤技术进行综述,Meng 等人^[7]对移动新闻推荐技术进行综述,Zhang 等人^[8]对基于深度学习的推荐系统进行综述等.虽然上述文章对推荐系统的一些子领域及其方法技术进行较为全面的综述,但是这类文章多具有较强的针对性和专业性,即针对某一领域、某一技术归纳分析并进行论述.类似文章可以为个性化广告推荐系统的综述提供参考和帮助,但是其中的方法或技术不能完全适应个性化广告推荐系统.具体原因如下.

一是涉及的推荐对象及数据不同.不同于其他自然内容推荐(如新闻、电影等),个性化广告推荐系统为用户推荐的是可能感兴趣的广告.推荐对象的不同导致其他综述中涉及广告推荐的内容较少且不全面,也造成了数据集的差异.例如,个性化广告推荐系统借助广告领域相关数据开展研究,新闻推荐则借助新闻相关数据进行研究,而且在对不同推荐对象的研究中对数据的利用方式和程度也不同.

二是研究的方法、技术的覆盖面不同.许多综述文章针对某一特定推荐方法、技术进行总结论述,例如协同过滤等.而个性化广告推荐系统中涵盖上下文推荐、混合推荐等多种方法、技术,并且拥有点击率、转化率等专用评价指标.

三是存在的问题和未来研究方向不同.相对于其他推荐对象,广告具有规模大、传播广、更新快、易交互等特性,因此广告推荐在应用中面临着时效性、隐私保护、冷启动、用户偏好变化等方面的挑战.为应对广告推荐领域的这些挑战,可以从获取用户动态偏好、扩展上下文推荐技术、发展移动广告推荐系统、利用多源数据等方面进行研究.

在个性化广告推荐领域已经存在大量研究,许多研究希望通过个性化广告推荐系统解决实际问题,并尝试使该领域能够形成体系.然而,近 10 年内缺少对该领域进行系统研究并全面总结该领域研究进展的综述文章.并且很少有人对该领域当前的

研究方法、技术进行深入分析并指出该领域的应用现状和存在的问题.根据调研,目前只有 2 个相关的简短综述文章^[1,9]正式出版,Zhang^[1]针对网络广告的个性化进行简单总结,并将推荐技术分为:基于内容、协同过滤、基于人口统计、基于效用、基于知识的推荐.Li^[9]分析基于用户偏好的网络广告中的重要技术,并将个性化推荐技术分为:基于内容、协同过滤、基于知识和基于情景感知的推荐.但是这两篇文章中介绍的技术相对久远,技术分类方法比较传统且没有涉及到新兴的研究,对广告推荐中存在的问题和未来的研究方向没有深入讨论.随着新的研究工作不断出现,上述推荐分类方法不再适用.因此,需要一个更新的具有包容性的框架帮助理解该领域.本文从多种角度对个性化广告推荐领域中的关键技术、应用现状进行全面总结,并通过对比分析,指出当前限制个性化广告推荐系统发展的问题,点明该研究领域未来的研究方向.鉴于个性化广告推荐系统不断发展和普及的趋势,对其进行系统综述将更加具有理论和实践意义.

通过个性化广告推荐系统,广告由原来的大范围投放转变为个性化推荐.个性化广告推荐的最终目的,就是削弱用户对广告的反感态度,同时增大广告商经济效益,使广告的投放更具针对性^[10].本文对个性化广告推荐系统及其应用研究进行综述,文章结构如图 1 所示.



图 1 个性化广告推荐系统及其应用研究综述框架

本文结构上主要分为 4 个部分.本文第 2 节为个

性化广告推荐系统概述,主要概括个性化广告推荐的现状、常用技术及应用以及分析个性化广告与非个性化广告之间的异同点,分析个性化广告推荐与其他个性化推荐的区别;第3节重点介绍个性化广告推荐的关键技术,包括用户偏好获取、个性化广告推荐技术,以及个性化广告推荐的效用评价,包括介绍部分个性化广告数据集以及评价指标;第4节对个性化广告推荐的应用领域以及代表应用进行总结分析;第5节对当前存在的问题和未来研究方向进行讨论和展望,最后是结束语。

2 个性化广告推荐系统概述

2.1 个性化广告推荐

个性化广告推荐系统是推荐系统典型应用之一,是当前互联网广告的重要表现形式,众多电子商务网站利用个性化广告推广自己的产品。在这方面,Alibaba、Amazon 等公司将数据挖掘与程序算法发展到一个新的高度,其通过算法挖掘用户的历史数据和比较用户的消费偏好,预测和推荐用户可能感兴趣并触发购买行为的商品。

所谓个性化广告推荐系统,大的方面来讲是利用技术手段进行广告交易和管理的一种广告形态。小的方面来讲,是利用算法和技术精准地确定目标受众,为正确的用户做出广告推荐,是一种有效提取网络有用信息的方法^[11]。个性化广告推荐系统能够有效利用用户行为记录^[12]、点击^[13]、评分^[11]等信息,预测每位用户对各种商品的可能需求和偏好,并结合用户的位置^[14]、时间^[15]上下文等信息,利用个性化广告推荐技术为用户推荐其最有可能浏览的广告,以实现广告投放产生效益的最大化的目标。

早期的广告推荐系统的推荐技术过于单一,主要通过比较用户相似度的方式实现推荐的协同过滤技术^[10]。同时这些技术的应用过程中存在着如冷启动^[16,17]、用户反馈矩阵稀疏^[18]、维度过高^[19]等问题。因此不足以满足用户之间需求和偏好的差异,然而对广告精准投放的需求依旧是互联网广告不断演进的根动力。为了解决这些问题,近年来个性化广告推荐系统中采用多种关键技术,例如用户偏好获取技术^[3,20]、个性化广告推荐技术^[21,22,23]等。这些新的技术从一定程度上解决了上文提到的个性化广告推荐的现实问题,并分别在各自的对比测试中展现出良好的推荐效果,反映出个性化广告推荐的良好发展现状和其积极的未来发展趋势。

最终将这些关键技术应用于传统互联网^[24,25]、移动服务^[26,27]、数字标牌^[28,29]和 IPTV^[30,31]广告推荐当中,提高广告推荐的个性化程度,满足用户需求,同时增加广告盈利。

2.2 个性化广告与非个性化广告之间的异同点

通过判断广告是否根据用户偏好精准投放,将广告分为个性化广告与非个性化广告。为阐述二者的异同点,先对搜索广告、展示广告与个性化广告进行比较,随后将传统广告推送与个性化广告推荐进行对比。

首先,个性化广告与搜索广告、展示广告等其他形式的广告有着明显不同。搜索广告是竞价广告中最典型的系统之一,与一般网络广告的区别在于其注重上下文信息,并且用户标签的作用受到很大限制,一般不考虑用户的影响,用户在查询过程的实时输入为上下文信息,其重点在于查询扩展^[32]。展示广告是按照展示次数计费的视觉广告形式,一般投放在第三方网站,展示广告是基于用户行为和人口统计等因素^[33],以个人或群体为目标。表1中通过几个评测标准对搜索广告、展示广告和个性化广告进行对比。

表1 个性化广告与其他广告形式的对比

	搜索广告	展示广告	个性化广告
检索规模	可达千万级	可达百万级	可达亿级
驱动原则	利润驱动	利润驱动	用户兴趣驱动
达成目标	提高广告质量	提高广告质量	多样化、新颖化
个性化需求	需求较少	需求较大	需求较大

除了上述对比内容外,搜索广告、展示广告与个性化广告之间有一定的联系。例如,广告在某种意义上接近用户查询^[16],搜索广告中查询的重要性极高,粒度非常细,因此需要进行查询扩展,以获得更多的匹配结果。而查询扩展的技术又包含个性化广告中的技术,例如基于协同过滤^[34]等方法。展示广告需要满足用户的需求,对用户行为进行分析,利用基于人口统计学的方法进行推荐。所以,为了使得广告能够满足用户的真正需求,并符合用户兴趣和个性化行为习惯,借助个性化广告推荐的相关技术是不错的选择。

其次,传统广告通常指的是没有涉及到个性化精准推荐的广告,通过竞价等传统方式对广告进行推送,与个性化广告推荐不同。此外,推荐也属于一种推送,不同的是,推荐常与个性化联系起来,推送过程

中常常不以个性化为主要目标.目前,广告的投放模式从传统粗放型的广告广播模式向集约型的精准传播模式转变.这里通过 RTB(Real Time Bidding)实时竞价广告为例,如图 2、图 3,对传统广告推送和个性化广告推荐的异同进行说明.

图 2 展示的是传统 RTB 广告系统,当用户访问具有广告空间的网站时,供应方平台 SSP(Sell-Side Platform)发送竞价请求,需求方平台 DSP(Demand-Side Platform)分析从 SSP 发来的请求,根据用户历史判断是否要显示广告.随后通过 DSP 之间的竞价拍卖,将竞价结果返回到 SSP,并将胜出 DSP 中广告进行分配.如图 2 中 DSP1、DSP2、DSP3 分别出价 50、100、150,DSP4 不参与竞价,出价最高的 DSP3 胜出,SSP 将 DSP3 的广告分配到具有广告空间的网站.

图 3 展示的是基于用户兴趣的网络广告推荐系统,图 3 与图 2 相比,主要不同在于 DSP 中存在广告推荐系统及其决策模块.该决策模块根据用户浏览历史关键字(假如为手机)确定用户兴趣,判断用户浏览历史关键字与目标网址内容的关键字是否相同,若网址关键字也为手机,则申请目标网址广告并将满足用户兴趣的广告推荐给用户.

综上所述,个性化广告推荐为广告主和媒体带来营销效率和效果的双方面的提升.同时,个性化广告推荐又更加贴合每个用户的需求,因此易提升用户体验.

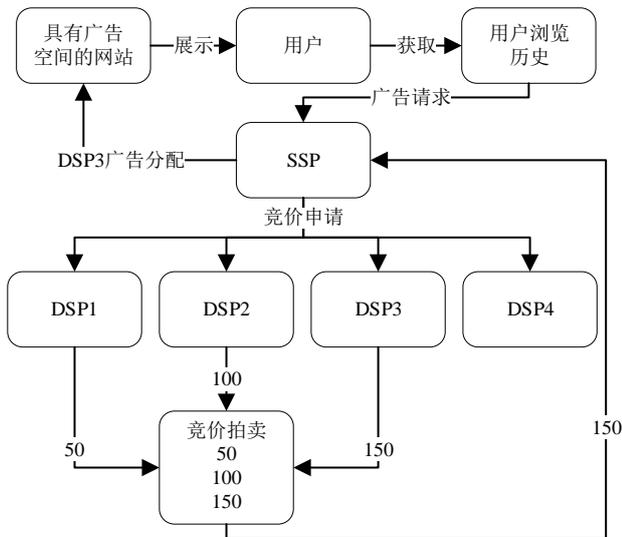


图 2 传统网络广告系统

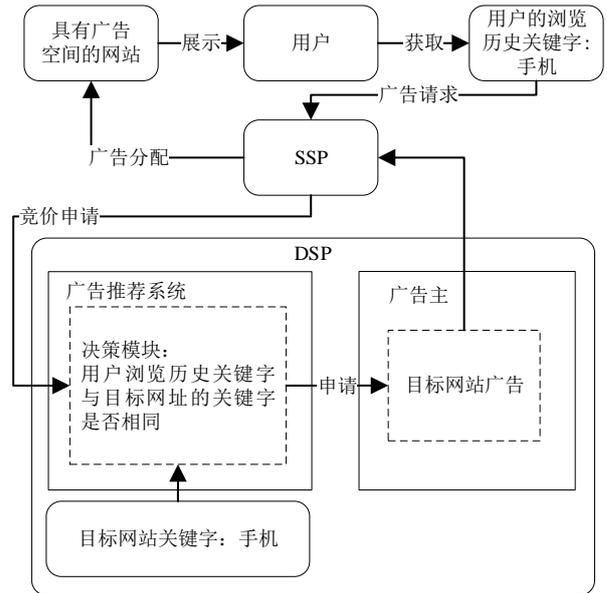


图 3 基于用户兴趣的网络广告推荐系统

2.3 个性化广告推荐与其他个性化推荐的区别

用户利用互联网进行的活动多种多样,主要包括接收推广(广告、推送等)、时事(新闻、比赛等)、交流(微信、QQ 等社交网络)、购物(Taobao、Amazon 等)、娱乐(音乐、电影、游戏)、出行、应用程序下载等.针对用户不同的活动,能够产生对应领域的推荐系统,例如表 2 中列举的广告推荐系统、新闻推荐系统、购物推荐系统、音乐推荐系统、兴趣点推荐等,表 2 还对列举推荐系统应用的推荐方法进行简单说明.

表 2 一些典型的推荐系统

推荐领域	典型系统	推荐方法
广告推荐	SARSIS ^[22]	混合推荐
新闻推荐	DRN ^[35,36]	深度学习、混合推荐
购物推荐	ConTagNet ^[37]	上下文推荐
音乐推荐	CoFoSIM ^[38]	协同过滤
兴趣点推荐	VPOI ^[39]	深度学习

虽然广告推荐与一些自然内容推荐均追求推荐结果的准确,提高用户的满意程度,但是广告推荐与不同推荐之间仍有不同的侧重点,导致存在一定的区别.例如,在新闻推荐中需特别关注推荐结果的时效性,因为新鲜感是新闻存在的价值之一.但是在广告推荐中不存在这样的禁忌,尤其是对于目前快节奏的视听媒体而言,广告的多次出现能够引起消费者注意,加深印象.且两者之间的时效性不同,新闻推荐的时效性多侧重于内容的新颖,广告推荐的时效性多侧重于对用户响应的及时性、准确性.购物推

荐与广告推荐类似,均是以期达到收益目的的信息传播活动,二者最主要的不同在于,购物推荐的应用多局限于购物平台,而广告推荐可以不受平台的局限.因此,当消费者浏览其他类型的平台时,购物推荐就无能为力,但是广告推荐可以跨不同平台为消费者展示可能感兴趣的商品.同理,音乐推荐也受到平台的限制.兴趣点推荐多考虑用户位置的变化,推荐的内容也与位置相关,其与广告推荐最大的区别在于数据的获取方式.兴趣点推荐的数据集是用户亲自访问现实中某一地点并留下的签到记录,而广告推荐的数据则多为用户与广告的线上交互记录,拥有各自的交互场景.广告推荐与其他自然内容推荐之间的区别体现了个性化广告推荐系统与其他领域的个性化推荐系统之间的差异性.

由于互联网上的广告本身具有数量巨大、交互性强、更新灵活以及传播高效等特点,个性化广告推荐系统与其他领域的个性化推荐系统之间的差异性除了推荐对象的不同外,还主要表现在这几个方面:偏好获取来源的灵活性、推荐技术的全面性、应用场景的多样性.

(1) 偏好获取来源的灵活性

用户偏好获取是推荐过程中非常关键的一步.其他推荐领域的偏好获取来源通常相对固定.例如,电影推荐中通常根据用户对电影的评分等,新闻推荐通常根据用户浏览的内容信息,兴趣点推荐根据用户的签到记录等.相对于其他推荐领域,个性化广告推荐领域中的用户偏好获取来源非常灵活.可以通过用户的评论、评分、点击、浏览记录、应用安装使用情况、IP 地址、社交网络等信息,以及将不同信息之间的组合作为偏好获取来源,甚至通过使用其他领域的数据完善用户偏好.

(2) 推荐技术的全面性

个性化广告推荐中涉及到多种方面的推荐技术.这些技术既包括传统的协同过滤、基于内容的推荐技术,又包含较新的多种上下文推荐技术、混合推荐技术、点击率预测技术及其他技术.其中点击率预测技术对于广告推荐来讲是一个非常特殊的技术.点击率一方面作为评价指标,另一方面又作为预测结果,这属于广告推荐领域的特色之一.不同于对电影推荐和音乐推荐等,广告的种类多种多样,例如视频广告、音频广告、文本广告等.不仅仅需要对文本内容进行处理,还需要对视频、音频等内容进行处理,需要多方面的技术加以实现.

(3) 应用场景的多样性

个性化广告推荐系统与其他领域的个性化推荐系统相比最大的不同在于其应用场景的多样性.其他领域的推荐系统,比如新闻推荐系统或者音乐推荐系统等,通常在可以支持浏览新闻或听音乐的设备中,使用特定的新闻或者音乐应用平台实现推荐,经常在传播途径或平台上受到限制.而广告推荐系统突破传播途径的限制,可以在 PC、移动端、IPTV 等多终端使用.还突破了领域和平台的限制,例如在新闻、音乐等应用平台中推荐广告,广告推荐与新闻、音乐推荐在同一应用平台中并不冲突.应用场景的多样性使得人们感觉广告无处不在.

3 个性化广告推荐的关键技术

个性化广告根据特定的用户和特定的场景,通过个性化算法或技术确定与之匹配的广告,并实现个性化创意、制作和精准化投放、传播以及人性化互动的广告业态.通过算法集合自动寻找广告、情景与用户三者之间的最佳匹配是个性化推荐的主要目的,而在实现该目标的过程中,个性化推荐技术和广告相关数据无疑是两个重要的推动因素.而数据的挖掘和处理能力则成为个性化广告区别于传统广告的核心能力.目前通用的个性化广告推荐整体框架如图 4 所示.

在图 4 中,根据服务对象的不同,分为客户端与服务端.根据功能模块的不同分为输出模块、输入模块和个性化推荐模块.输出模块属于客户端,由广告展示设备和目标用户组成,一方面通过广告展示设备将目标用户信息、行为历史等交互内容记录并输出到服务端的输入模块中,在 RTB 广告中通常通过竞价请求的方式将上述信息传递到推荐模块中^[40].另一方面将推荐生成的广告展示给用户并生成用户反馈.输入模块属于服务端,负责接收输出模块传来的信息和从广告源采集的广告数据等相关信息,其主要功能是将这些信息输入到个性化推荐模块.整个框架最关键的部分在于个性化推荐模块,通过对输入模块传来的目标用户相关信息进行提取并预处理,将处理好的数据输入个性化推荐模块.然后利用用户偏好获取技术得到用户的显性偏好或者潜在偏好.随后结合用户偏好,利用协同过滤、上下文推荐、混合推荐、点击率预测、深度学习及其他技术,生成推荐方法或模型,这部分是个性化广告推荐的核心部分.接着,将推荐方法结合输入模块传来的广告数据,生成广告推荐器.最后,广告推荐器为目标

用户推送产生的推荐广告,并通过目标用户对被推荐广告的效用评价反馈,达到衡量广告推荐器性能并对广告推荐器进行优化调整的目的.本节根据上述流程,重点对数据采集与预处理、用户偏好获取技术、个性化广告推荐技术以及个性化广告推荐效用评价进行分析总结:

(1)数据采集与预处理:该部分主要对应图 4 中的“广告采集”、“记录并传递”、“提取、预处理”过程,说明广告数据和用户数据的主要来源,并指出原始数据中存在数据噪声、数据缺失等情况.随后,为缓解上述情况的影响,需要对数据进行浅层和深层预处理.

(2)用户偏好获取技术:该部分根据用户信息、评分信息得到用户显性偏好^[11].根据行为信息,包括对广告的点击、浏览,以及应用使用情况等,获取用

户潜在偏好^[3].在用户潜在偏好中又可以通过构建用户画像^[41],或对用户进行建模^[40],达到获取用户兴趣以及对用户偏好进行预测的目的.

(3)个性化广告推荐技术:利用传统的协同过滤推荐技术^[42,43],利用广告关键词^[44,45]、内容^[46]、分类^[47,48]等信息的基于上下文的推荐技术;将多种推荐技术按照一定组合方式进行混合的混合推荐技术^[49,50];广告点击率预测^[23,51];其他推荐技术等.其中又包括一些深度学习相关方法,例如卷积神经网络(Convolutional Neural Networks, CNN)^[52]、循环神经网络(Recurrent Neural Network, RNN)^[53]等.

(4)个性化广告推荐效用评价:对不同来源的广告推荐数据集进行整理,并对个性化广告推荐中常用的传统评价指标和专用评价指标进行汇总,举例评估个性化广告推荐的性能.

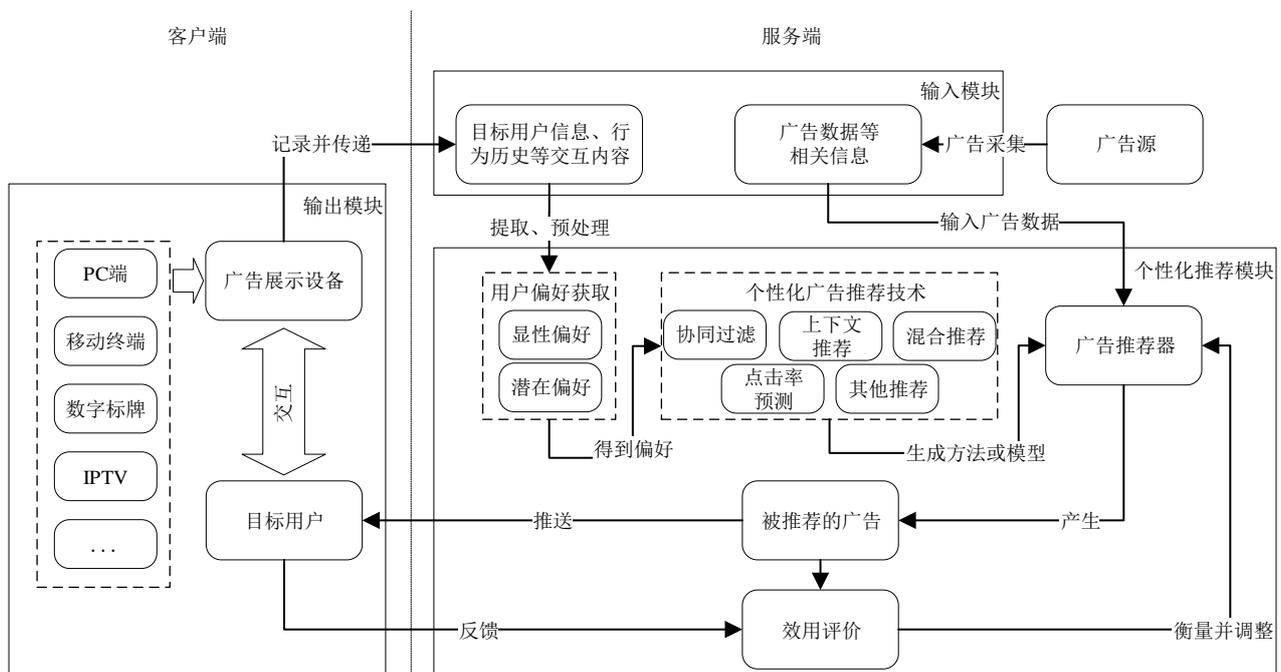


图 4 个性化广告推荐整体框架

3.1 数据采集与预处理

个性化广告推荐系统整个过程从数据采集开始,需要采集的相关数据主要包括用户基本信息、广告数据、时间位置等上下文信息、用户评论等交互行为信息、用户浏览历史等信息.其中用户基本信息主要来自用户注册以及相关平台系统中的信息完善功能.广告数据可以通过一些公司机构公开的数据集获取,也可以通过自行抓取的方式获取,但是多数研究中的数据集并没有公开或者使用的是内部数据.时间位置等上下文信息由设备时间、GPS 等获取.用户评论等交互信息以及用户浏览历史等需要

从系统的 cookies 等相关日志中获取^[40].

上述数据采集阶段获取的数据可能存在数据噪声、数据缺失等情况,对用户偏好获取以及后续的推荐过程的效果产生影响.因此,为了规范化个性化广告推荐系统的输入数据,需要进一步对获取的数据进行预处理,例如计算、量化等^[7].根据数据处理的复杂程度和处理结果的直观程度,分为浅层处理和深层处理.浅层处理多利用用户直观数据,通过相对简单的标准和方法,得到量化程度较高的结果.例如,根据用户对项目的行为模式(搜索、浏览等),对用户的兴趣进行等级化(1-5 级)表示^[22],或者自行规定对

项目的评分^[12],缓解数据缺失影响;对用户浏览历史进行分布式表示,进而得到用户的向量表示^[40];通过与设定的阈值进行比较,达到筛选数据噪声的目的^[24];为不同的时间段设置不同的量化值进行区分,例如将工作日和休息日赋予不同的值进行表示;将数据集中的旧状态整合为单个历史状态,保留有限数量的最新状态^[54]等.另外,为了能够对研究成果有一个全面的评价,可以改变数据集的划分标准,例如修改用于筛选数据集的阈值,或者修改训练集与测试集的划分比例等.

上述内容通过对浅层方式进行数据处理或扩展,对推荐过程的帮助有限,难以应对复杂场景,需要考虑对数据进行深度处理.而深层处理多针对用户复杂数据,利用相关挖掘或获取技术,得到潜在的可扩展的数据特征或表示等.例如,使用主题获取或挖掘技术,将用户历史发文、转发等行为映射到潜在主题空间当中,帮助获取用户偏好^[55];根据点击等行为数据和广告信息,参数化潜在空间^[56];通过用户对投放广告的评论和反馈,获取关键词,并分析用户对相关主题的态度^[21];通过处理微博数据,得到用户的情感数据^[57]等.

3.2 用户偏好获取技术

由于个性化的广告推荐的本质是推送满足用户需要,或者使用户感兴趣的广告,所以获取用户的偏好是实现个性化推荐的前提.用户属性的完整也是网络广告成功的关键^[24],广告能否被有效地分配,很大程度上取决于系统是否对用户偏好有很明确的理解^[58].用户的偏好,既包括用户对不同事物的喜好、评价,也包括用户在不同环境下的需求.用户的偏好可通过与特定上下文相关的广告评级来表达,该评级是由用户提供的显性评分,也可由系统隐式推断得到^[59].因此可以将用户的偏好可以分为显性偏好和潜在偏好,也可以分别称为显式偏好和隐式偏好^[60].显性偏好通过明确指标表示出喜欢或者厌恶,通常能够在用户个人信息中直接得知,或者通过用户对项目的评分反映.潜在偏好是根据数据集合的状况,通过分析用户浏览历史、用户行为等,得到用户的潜在习惯或者偏好.所以,本部分从显性偏好获取和潜在偏好获取两个方面分析个性化广告推荐系统的用户偏好获取技术.

3.2.1 显性偏好获取

显性偏好获取通常依赖于用户的显性信息,这些显性信息主要是用户对部分项目的评级或评分

信息.值得注意的是用户的评分信息主要由两个来源:一个是交互式^[11,19],即用户通过系统交互,在给定评分范围的前提下对特定项目进行打分操作;另一个是辅助判定^[12,27],即根据用户对项目的行为模式,人为或由系统辅助给定评分标准并判定用户对项目的评分.

交互式要求用户对指定广告进行评分.Dao 等人^[19]调查三所大学的学生,并要求这些学生对部分广告进行评分操作.将筛选后的显性评分结果作为实验数据集,预测用户偏好.Gu 等人^[11]搜集特定网站的广告评分记录,利用用户对广告的显性评分,采用协同过滤技术预测用户对未知广告的评分.另外,由于显性信息中包含用户的多种信息,可能会造成用户隐私泄露,例如网站会要求用户在注册时输入自己的多种兴趣信息构建个人资料^[61].而且目前广告和用户的规模非常大,用户对广告的评分信息相对较少,易产生冷启动和数据稀疏问题^[59],导致无法精确获取用户偏好.

通过辅助判定的方式可以生成更多的用户评分信息,针对用户的不同行为,生成用户对广告的评分以缓解数据稀疏和冷启动问题.文献[12]中将用户对广告的行为分为转发、点赞、评论、无行为四种,分别赋予 3、2、1、0 的评分,即规定用户对广告的评分范围为[0,3].文献[27]中将用户对广告的行为分为转发或喜欢、接受、忽略,分别赋予 2、1、0 的评分,用户对广告的评分范围为[0,2].上述两种均根据用户对广告的行为,创建广告评级表,显示用户对广告的偏好,且采用协同过滤技术计算用户对广告的评分.但是由于用户的一些操作失误或者为获取奖励而产生的转发行为等,不能准确地反映用户偏好,因此需要验证数据的可靠性.

3.2.2 潜在偏好获取

潜在偏好获取通常依赖于用户的历史浏览信息、行为信息等一些不能明显反映用户偏好的信息.但是由于广告推荐中偏好获取来源具有灵活性的特点,所以从何种数据中获取用户偏好并不固定,且针对不同数据均有相关研究.目前个性化广告推荐研究中主要通过构建用户画像(user profile)^[3,41]或用户建模(user model)^[25,40]等方式表示用户的潜在偏好.用户画像和用户建模等均反映用户对广告的偏好,描述上有相似之处.许多研究通过构造某种数学模型来分解用户大量而稀疏的信息,并从中分析出用户的偏好.常用的模型有决策树模型^[20]、回归模型^[13]等.根据广告推荐中潜在偏好获取的来源,将潜在

偏好获取分为基于用户发文、评论或点击的潜在偏好获取、基于浏览行为历史的潜在偏好获取、基于应用安装使用情况的潜在偏好获取、基于多方面的潜在偏好获取。

(1) 基于用户发文、评论或点击的潜在偏好获取

用户在参与网络生活时,经常与网络平台产生互动,例如发文、评论、评分、点击等方式中的一种,在网络空间产生可见的反馈信息.这些反馈信息中隐藏着用户的对一些内容的看法或者偏好.例如,文献[61]中指出,博客服务商除了利用用户注册时填充的信息外,还利用用户的发布的帖子或标签构建用户画像,以表示用户的长期兴趣.但是考虑到利用用户注册的信息获取偏好会出现隐私泄露问题,一些研究通过减少用户输入个人信息的方式保护用户隐私.文献[62]和文献[43]利用用户对广告的反应行为得到用户偏好,同时不在服务端存储用户个人数据.另外,用户的评论信息对于用户潜在偏好获取有一定帮助,Varlamis 等人^[3]根据用户反馈的评论内容,利用潜在语义分析、层次聚类等主题建模技术,得到一个整体的用户画像.随后聚合各个用户和项目的固有特性,进一步细化用户画像.Hwang 等人^[47]通过在线或电话调查收集用户对广告的反馈,并根据反馈信息利用逻辑回归得到用户画像.生成的用户画像是一组对广告类别的偏好权重值,用于描述用户对这些广告的偏好.

针对用户评论,一些深度学习方法可用于获取用户潜在偏好.Zheng 等人^[63]利用两个平行的 CNN 根据评论内容进行用户建模,利用一种词汇嵌入技术,将评论文本映射到一个较低维度的语义空间,增强了评论文本的语义表示,提高模型的可解释性.但是仅仅在目标用户对目标项目的评论存在时才能正常使用.Tay 等人^[64]利用多指标的协同注意力机制从用户评论内容中获取用户与项目的交互特征.但是不同推荐领域的有用信息的聚合模式不同,在不同场景下的实际效果不容易确定.

广告点击反馈数据也可以用于获取用户潜在偏好.Chan 等人^[65]根据用户的广告点击历史,用向量表示用户画像,并将用户画像之间的相似度作为广告推荐的部分依据.Qudah 等人^[4]在用户使用其系统之初,就将用户对广告的点击行为进行记录,并根据用户的点击记录,为用户推荐相似广告,不断更新用户模型,并逐步解决了数据稀疏问题.文献[13]每隔半个小时收集用户的点击信息,获得丰富的点击数据,随后利用用户的点击记录构建回归模型,形成动

态广告推荐系统.Tan 等人^[66]根据用户最近的点击行为,通过序列处理和 dropout 正则化来生成点击序列,利用 RNN 获取用户较新的偏好,并通过将项目嵌入减少参数数量.

虽然可以通过多种反馈信息获取用户偏好,但是在上述研究中,若存在用户评论过短、交互历史较少等情况,即反馈数据不充分不全面,会影响用户偏好获取的精准度.

(2) 基于浏览行为历史的潜在偏好获取

用户模型可以基于用户过去的浏览行为进行构建^[25].Yuan 等人^[41]从用户浏览的隐含行为中学习并生成用户画像,该用户画像是一组对广告特征的偏好权重值,用于捕获用户偏好.文献[40]中认为对广告有明确或潜在兴趣的用户之间具有相似的浏览历史,因此系统提前获取访问过目标站点的其他用户的浏览历史,通过浏览历史构造用户模型以及针对用户模型的分器,通过分器判断用户是否对目标站点有潜在兴趣.Wu 等人^[54]针对用户浏览历史,提出深度循环网络 DRNN 对用户浏览模式建模,预测用户下一步行为,将旧的历史状态整合为单个状态,有助于权衡计算成本和预测精度.Okura 等人^[67]提出一种基于嵌入的分布式表示方法,将用户浏览历史序列作为输入,使用 RNN 生成用户表示.并对学习方式改进,使得用户浏览历史的聚合拥有更强的表达性.

用户浏览历史记录获取周期对用户偏好获取存在一定的影响.文献[25]针对不同的目标网站选择不同的历史获取周期进行训练.利用不同的记录构建用户模型,有很好的扩展性.为了研究用户长短期潜在偏好,Siriaraya 等人^[68]认为用户的浏览历史的单个部分(一周或一个月等)无法充分表示用户偏好,通过将用户模型中的短期和长期兴趣分离,更好地反映用户的整体偏好.与访问过目标网站的用户的浏览历史进行比较,利用逻辑回归预测用户对从未访问过的目标网站是否感兴趣.但是其使用逻辑回归方法的原因主要是根据经验所得,可以尝试用其他的时间序列方法,并测试他们在预测用户潜在偏好上的表现,例如循环神经网络 RNN 及其变体等.这些研究中存在一些不足,对浏览历史的周期划分标准不统一,不同研究中对长短期偏好的时间跨度定义不同.另外若用户记录较少或者不存在,则容易出现冷启动问题.

(3) 基于应用安装使用情况的潜在偏好获取

应用程序是用户在日常生活中经常使用的工

具,无论是 PC 还是移动端应用程序,均存在大量可利用数据用于分析用户潜在偏好,这些可利用数据记录了应用的安装和使用情况,例如是否安装应用、应用安装卸载时间、应用使用时间、应用使用频率等.在移动端 App(Application)环境中,移动网络广告快速发展.为了获得更加准确的用户偏好,Jiang 等人^[69]认为利用决策树训练的模型会出现过拟合的情况,因此他们使用随机决策树解决过拟合的问题.为预测用户是否会安装目标 App 应用,其在训练过程中选择随机样本代替训练集,利用训练集训练单个决策树,并通过所有单个决策树的结果平均值来预测对未知样本的偏好.Xia 等人^[42]利用 Yahoo 提供的丰富的移动用户行为数据,对用户在 App 上的不同行为进行加权聚合,发现用户行为偏好,并对活跃的用户推荐有关 App 的广告.上述研究中对应用的安装使用数据比较依赖,需要在已有数据中提取有效信息,减少数据噪声产生的影响.

(4) 基于多方面的潜在偏好获取

随着互联网技术的发展,用户和产品的规模不断扩大,用户与网络交互的过程中可以获取大量各种方面的数据.利用多方面数据获取用户潜在偏好能够弥补单一数据不全面的不足,进一步提升对用户偏好的掌握,主要有以下 3 种方式.

1) 基于多种用户相关数据

该方式通过用户的多种方面的数据获取用户的潜在偏好,例如基本信息、多种行为数据等.Roh 等人^[70]基于智能手机平台,收集用户的位置信息、支付信息、经常使用的 App 等,并结合用户年龄、性别等静态信息,将用户画像表示为一组向量,随后将用户画像与上下文信息的匹配作为推荐过程的一部分.Wang 等人^[71]提出用户一种用户细分模型,该模型根据用户特征数据、用户行为数据、用户情感数据进行特征分类、行为建模、情感建模.用户特征数据主要包括性别、年龄、职业等,行为数据主要是用户的浏览或购买行为等,情感数据主要来自对用户的调查问卷.随后,根据用户兴趣将用户划分为不同的群体,对群组进行关联规则挖掘.基于多方面的潜在偏好获取方法可以利用多种信息,获得用户较全面的偏好.但是,数据获取的来源以及数据的可靠性是该方法需要考虑的关键部分.

在推荐系统领域,图嵌入方法利用多种信息对精确识别用户偏好发挥了很好的作用,目前存在很多的方法可以为广告推荐中的用户偏好获取提供参考.例如,由于许多信息之间存在异构性,Wang 等

人^[72]构造一个异构信息图对不同种类的异构信息进行编码,在此基础上,提出一种潜在低维表示的异构信息图嵌入方法 HIGE,通过将项目的部分内容嵌入到历史记录中,得到用户的全局和上下文偏好.同样,Liu 等人^[73]构建异构的用户-项目网络,并将该网络嵌入到共享的低维空间中,统一捕捉时间语义效应、社会关系和用户行为序列模式.

除此之外,知识图谱嵌入在近几年中也被广泛应用,其关键思想在于将包含多种实体和关系的知识图谱组件嵌入到连续向量空间中,从而在保持知识图谱固有结构的同时简化操作^[74].例如,Grad-Gyenge 等人^[75]对提出一种知识图谱的二维嵌入方法,将用户和项目映射到相同的向量空间.Sun 等人^[76]提出一种循环知识图谱嵌入框架 RKGE,自动学习实体的语义表示与实体之间的路径,对每个合格路径通过循环网络建模,并用 pooling 操作区分不同路径的特征,描述用户对项目的偏好.并指出,用户对项目的偏好是由不同因素的组合决定的.上述方法对广告推荐中的用户潜在偏好获取具有很强的指导意义,并且广告推荐容易满足上述方法对数据和场景上的要求,因此将图嵌入方式应用到广告推荐中具有很高的可行性.

2) 基于社交平台的多种信息

社交平台的多种信息对于用户偏好精确度的提高有很大的帮助.Li 等人^[55]构造一个黑盒框架用于构建用户画像,该黑盒中可以使用多种主题获取或挖掘技术,将用户历史发文、转发等活动转化到潜在主题空间当中,生成的用户画像是一个加权主题的集合.但是这种方式获取的用户偏好是静态的,对广告推荐起到的有效作用有限.Simsek 等人^[57]除了利用微博消息中的文本、标题、Web 链接、哈希标签等微博特征外,还将通过混合 TF-IDF^[77]处理微博得到的情感数据、用户之间关注与被关注的关系考虑进去,进一步加强对用户偏好的把握.

3) 基于多领域数据

基于多方面的潜在偏好获取不仅仅指的是利用多种类型的数据获取偏好,还可以指借助其他领域或来源的数据完善用户偏好.单一领域的推荐系统仅仅关注一个领域,忽略了用户对其他领域的兴趣,不利于解决稀疏性和冷启动问题^[78].迁移学习是多领域推荐研究中的热点之一,目的是通过其他领域迁移的知识改进一个领域的学习任务^[79].深度学习非常适用于迁移学习,其可以学习高级抽象,从而分离不同领域的变化^[81].例如,利用深度学习技术和

非广告领域数据为用户推荐广告.Yan 等人^[80]使用应用程序的安装和使用以及许多其他非广告领域的移动数据,利用深度学习技术构建统一的用户画像,并从不同方面进行建模,包括用户基本画像、广告画像等等,缓解了冷启动问题带来的影响.但是在广告推荐领域利用深度学习、迁移学习获取用户潜在偏好的研究较少,需要在广告推荐领域中对如何应用这些方面技术以及如何缓解冷启动问题进行深入研究.

综上所述,为获取用户偏好,许多研究利用评分、评论、浏览记录、点击记录等多种信息,采用构建用户画像或用户建模等多种方式描述用户兴趣.相比之下,显性偏好获取实现简单,主要通过预测评分进行推荐,使用的方法比较传统,但是对数据集的数量和质量要求较高,对精准获取偏好的帮助效果不明显.而潜在偏好获取通过用户行为历史等信息深入挖掘用户偏好,获取的用户偏好比较精准.但是因涉及到构建模型等步骤,实现过程相对复杂.然而无论是显性偏好获取还是潜在偏好获取,均需要丰富的数据以满足获取精准偏好的要求.数据的缺失对用户偏好描述产生明显的影响,因此冷启动和数据稀疏问题在个性化广告推荐领域中仍是一个挑战.另外,用户的偏好通常是动态变化的,静态的用户偏好难以满足用户的实际需求.用户的偏好处在不断的更新和调整之中,对用户的偏好获取应该是动态的,用户动态偏好获取依旧是重要的研究方向.

3.3 个性化广告推荐技术

早期的个性化广告的推荐技术主要应用协同过滤技术推荐技术.随着个性化广告推荐的研究不断发展,为了解决如冷启动、用户-反馈矩阵稀疏等问题,逐渐出现了利用上下文信息的推荐技术,还有综合多种技术的混合推荐技术、点击率预测技术及其他推荐技术.

3.3.1 协同过滤技术

协同过滤技术是指通过比较用户之间的偏好、习惯等属性的相似度,或不同商品之间的相似度的方式来为目标用户实现个性化推荐的一种算法^[16].通常来说,具有相似偏好或习惯的用户往往会对相似的商品产生兴趣,即协同过滤就是一种将受到相似用户好评的商品推荐给目标用户的算法.协同过滤可分为基于记忆和基于模型两种^[19].

(1) 基于记忆的协同过滤

基于记忆的协同过滤技术及其改进方法主要

通过对用户间、项目间的相似度进行分析,得出广告推荐结果.文献[81]提出一种带标签的协同过滤推荐算法(ADR-CF_T),探索标签与项目间的关联关系,将广告关键词作为标签引入到查询页的相似性计算中,采用查询页加权综合相似度度量方法降低相似矩阵的稀疏性,同时又具有很好的扩展性.Xia 等人^[42]围绕基于记忆的协同过滤算法展开讨论,将其分为基于 App 和基于用户的推荐,并将算法应用于大规模数据中的推荐场景中.Dao 等人^[19]利用遗传算法得到上下文相似度,并将得到的相似度用于协同过滤的计算过程中,缓解了因上下文相似性模糊带来的限制.上述基于记忆的协同过滤技术均有效地解决数据稀疏问题,提高推荐结果的精度.但是上述对于影响因素的利用不充分,需要对数据集中可用信息进行深入分析,挖掘更深层次的特征.

(2) 基于模型的协同过滤

基于模型的协同过滤通过历史数据训练模型,预测用户对广告的评分或喜爱程度.文献[59]针对个体情境提出基于模型的协同过滤算法.在此基础上,引入多维匹配模型,将移动广告场景提取后的多维张量表示进行正则化分解,增强算法的可扩展性.同时将历史评分信息与上下文信息结合用于评分预测,但是随着数据量的增加计算效率会降低,因此可以考虑移除部分多余推荐规则.文献[27]中考虑车辆的位置,将距离小于设定阈值的车辆视为邻居,使用协同过滤技术预测用户对一些广告类别的评分,并将广告推荐给目标用户.但是用户的评分信息不是针对具体项目,而是针对广告类别,评分机制需要改进.上述基于模型的方法考虑的多种场景因素,有效提高推荐准确率,但是需要注意算法效率问题.

上述两种方法比较依赖用户的历史数据或评分信息等.因此,从另一方面考虑,若利用较多的用户信息,会涉及到用户的隐私保护问题.用户的访问数据信息通常被做隐私处理,或不被网页的数据库所保存,这使得广告推荐系统没有原始的用户偏好获取来源.为缓解隐私保护对推荐产生的影响,Kazienko 等人^[43]搭建 AdROSA 系统,用户的个人详细信息没有存储到数据库中,减少用户输入,尊重用户隐私.通过数据挖掘技术对网页内容、在线用户的会话历史以及当前行为进行处理,获取用户偏好.通过对这些偏好进行比较,找出具有相似偏好的用户实现个性化推荐.采用这种对用户友善的信息获取方式,使得该模型在一些具有匿名处理或隐私保护的网页环境下,依然可以通过应用协同过滤进行

广告推荐,其研究方式具有一定的借鉴意义。

许多研究利用深度学习对基于模型的协同过滤进行扩展,并在推荐领域取得不错的成果。He 等人^[82]提出一种神经协同过滤 NCF,构建双重神经网络模拟用户和项目之间的双向交互,传统的矩阵分解可以看作 NCF 的一种特例,并且可以将 NCF 应用于跨领域推荐当中。Ouyang 等人^[83]提出一种自编码协同过滤 ACF,其不使用原始的观测向量,而使用整数评分对它们进行分解,但是其不能处理非整数评分,且观测向量的分解增加了输入数据的稀疏性。He 等人^[84]利用 CNN 改进 NCF,得到 ConvNCF,其利用外积对用户和项目的交互模式进行建模,而不是使用点积。将神经网络应用于外积结果上,捕获嵌入维度之间的高阶关联。上述方法均涉及深度学习,对在广告推荐中使用深度学习有启发意义,但是对于数据集质量有一定的要求。

综上所述,基于记忆的协同过滤计算过程简单,适合用户偏好快速或频繁更新的环境,但是对数据集的依赖较大,易出现数据稀疏和冷启动问题。基于模型的协同过滤通常需要更多的时间训练数据集,但是其具有很好的扩展性和推荐效果。两种协同过滤技术的优缺点具体见表 3。协同过滤技术的选择取决于应用领域^[59],结合技术的自身特性和对数据集的依赖性,正确分析各技术的优劣。例如在无法获取用户历史行为内容或者浏览记录等信息的情况下,容易出现数据稀疏问题,对于基于记忆的协同过滤是不适用的。而对于实时性要求高的场景,基于模型的协同过滤是不适用的。未来可以考虑多种因素考虑对协同过滤的影响,或者利用深度学习进一步扩展协同过滤技术。另外,在注意保护用户隐私的前提下,充分利用已有用户信息也是值得研究的方向。

表 3 协同过滤技术比较

协同过滤技术	优点	缺点
基于记忆的协同过滤	计算方法简单,适合用户偏好变化较快的场景,可满足实时性要求	数据集的质量和数量对其影响较大,易出现数据稀疏和冷启动问题
基于模型的协同过滤	有效提高推荐的效果,可以考虑多种场景因素的影响	计算复杂度高,训练模型较耗时,难以满足实时性

3.3.2 上下文推荐技术

上下文最初指的是用户位置、用户的好友关系、周围的对象等^[85],上下文常被定义为描述实体情况的任何信息^[86]。用户的行为高度依赖于他们的偏

好和上下文条件^[59],在给定用户当前状态和给定广告当前的上下文的情况下,上下文推荐技术利用上下文信息向用户推荐该情况下合适的广告^[56]。这里将广告上下文推荐技术分为基于用户位置和时间广告上下文推荐、基于内容和关键词的广告上下文推荐、基于类别的广告上下文推荐、其他上下文推荐四种。

(1) 基于用户位置和时间广告上下文推荐

对于位置和时间上下文的利用也是个性化广告推荐的研究方向之一。基于位置是广告领域中应用最早的上下文方法,它围绕用户的地理位置信息而构建^[87]。Hristova 等人^[14]通过 GPS 获取用户位置,开发出一个位置感知的个性化广告系统,并指出移动广告属于一种上下文感知应用程序,上下文通常由用户位置确定。Yuan 等人^[41]根据用户移动设备所在位置,通过分析用户隐式浏览行为和神经网络学习,对指定位置附近的手机广告打分排名,并将排名靠前的广告推荐给用户。

对于时间上下文的利用为广告推荐提供了很大的帮助。文献[15]中提出一种时间上下文感知的广告推荐系统,该系统通过分析用户在时间轴上的推文信息,利用基于记忆的粗糙集理论的方法了解用户在时间轴上的兴趣变化,从而在合适的时间推荐满足用户兴趣的广告。Kodialam 等人^[31]和 Wu 等人^[13]在其各自的应用系统或者服务中对广告推荐的时间段的反馈效果进行重点分析,并选择在效果较好的时间间隔推荐广告。

同时应用位置和时间上下文也会取得不错的效果,文献[17]利用位置和时间推演出最合适的用户群体,运用模糊逻辑寻找最合适的广告类别并向用户群体推荐相关广告。

上述基于位置或时间的广告上下文推荐方法不依赖用户的个人信息,有效解决冷启动问题。但是使用的方法过于陈旧,尤其是基于位置方面,对于用户移动信息利用不充分。因此可以将移动广告推荐等作为未来研究方向,并可以通过划分时间窗口的方式,描述用户动态偏好,将广告进行序列化推荐等。

(2) 基于内容和关键词的广告上下文推荐

通常,投放的广告内容和页面内容相关,因为阅读该页面的用户往往是对该网页内容感兴趣的,投放与页面内容相似的广告则容易满足这些用户的偏好^[10]。因此个性化广告推荐需要对内容做出分析,如分析微博用户发布的内容或者用户在网页上的评论内容^[21],分析博客页面内容并选择与用户

兴趣匹配的广告^[61]等,页面上放置的广告内容取决于广告与页面内容的相关性.但是利用的内容多为文本信息,没有充分利用页面上的其他信息,例如图片、视频等.同时,仅仅结合网页内容的广告推荐策略存在一些不足,例如内容较少且无核心词汇,会造成广告投放效果较差.

为弥补内容在广告推荐上的不足,将关键词引入广告推荐过程中,并逐渐从单一的关键词技术向多维关键词技术发展.文献[21]中提出基于关键词和用户情感的多维上下文推荐方法.通过搜集用户对投放广告的评论和反馈,提取语句中的广告关键词,并分析和获取用户对相关主题的态度.最终将符合用户态度同时又与广告关键词相关的广告推荐给用户.然而用户的情感非常复杂,推荐符合用户情感的广告难度较大,其次就是难以评估广告的推荐是否真正符合用户的情感 and 需求.文献[44]中提出多关键词推测算法,通过以往的搜索历史预先推测出用户的潜在搜索目标,并将该推测以多个关键词的形式呈现给用户以实现推荐.该算法还可以推荐一些登录页面没有的其他关联商品.可以尝试抓取登录页面的结构化内容,帮助提高准确性.文献[46]中将广告商提供的每个关键词与主题的多项分布相关联,提出关键字-主题模型.然后,将具有多个关键词的广告表示为与关键词相关联的主题分布之间的混合,得出合适的广告推荐结果.另外,该方法允许使用不同粒度的信息,但是不同粒度的区分标准不明确,需要进一步改进.文献[88]中的方法与现有的大多数关键词提取算法不同,其利用实体命名标记等NLP(Neuro-Linguistic Programming)新特性,生成一些网页中不存在的相关关键词,提高广告相关性.但是该方法对历史搜索的关键字依赖较大,易存在冷启动问题.

使用链接预测模型进行关键词推荐具有一定的借鉴意义.Wang 等人^[24]利用链接预测模型提供足够的关键词及其评分排名,缓解冷启动问题,但是对浏览器中存在的特性数据利用较少,仅仅考虑了IP.Yang 等人^[45]基于不同的数据资源构建一个广告主与关键词链接的异构网络,提出一种在多元关系网络下基于监督的链接预测模型SLPM的关键词推荐方法.该方法结合基于语义特征学习和网络嵌入信息,对关键词进行评分排序,但是复杂的网络需要消耗大量的计算资源,需要考虑效率问题.

(3) 基于类别的广告上下文推荐

由于广告语言的稀疏性和缺乏相关的语境,通

过简单的关键字或句法对广告和被浏览页面内容之间进行匹配,往往会导致选择出与用户兴趣无关的广告,从而产生不好的广告推荐效果.为了解决这样的问题,引入类别机制并通过相似度计算等方法来增强个性化广告推荐的精度^[47,48],对关键词进行分类处理对于推荐也具有一定的帮助^[47].Hwang 等人^[47]根据Yahoo提供的商业化分类规则对广告进行分类,并利用CKIP中文语义系统提取广告中的关键词,然后利用TF-IDF确定与每个广告类型相关的关键词.随后,利用标准Google距离构建广告特性向量,并通过在线调查结果构建用户画像,通过广告特征向量和用户画像的匹配生成广告推荐.但是在线调查的结果难以真实反映用户偏好,数据的真实性需要考虑.Hu 等人^[48]提出一种基于两级用户相似度方法MobRec,该方法将上下文缓慢改变的特性与用户反馈中反映的用户偏好结合.同时,MobRec利用上下文特征进行聚类,包含离线聚类和在线聚类两个阶段,分别得到用户的固定聚类和用户偏好.采用在线和离线结合的方式可以提高推荐结果的质量和可扩展性.

获取用户对某些广告类别的偏好,在广告类别的层次上进行推荐,能够为用户推荐属于这些类别的广告.文献[89]中将用户画像通过从参考分类中提取的一组类别表示,并根据用户画像向用户推荐新的广告,发现用户对某类广告的偏好.文献[90]基于动态数据分析,对用户共享中的文字模式进行分类识别.随后根据这些类别,可以确定用户感兴趣的领域,为用户推荐该领域的广告.但是这些方法推荐的广告仅仅停留在广告类别或领域的层次上,粒度较大,不能达到精确推荐的目的.为弥补粒度较大为广告推荐带来的不足,文献[91]利用神经网络分类器将广告分为预先定义的类别,对广告的语义和情感内容建模,随后将广告与运营具有类似语义和情感特征的广告媒体渠道相匹配,从而对用户分发广告,该方法优势在于可以对用户未浏览的广告进行分类.

(4) 其他上下文推荐

在广告推荐领域,对上下文信息的利用不仅仅是上述三种情况.Roh 等人^[70]利用用户信息、上下文信息构建基础的推荐模块,并将反馈信息的影响与基础模块进行加权,得到最终推荐,反馈信息越多,反馈信息的影响的权重就越大.文献[16]中提出一种基于概念的上下文推荐技术,利用企业之间的关系、相似商品或服务关键词等,通过关联规则为企业提供服务推荐.但是其中提出的规则效果一般,若要真正

用于企业实际运营中,可以尝试使用已有的更加成熟的框架来提升效果。

将深度学习和机器学习的方法用于上下文分析,对广告推荐也有很大的帮助作用.Kaushilk 等人^[92]认为两个连续帧的内容通常是密切相关的,并对视频和音频分别使用目标和语音识别算法识别广告的上下文.在目标识别中,利用卷积神经网络将视频中的关键帧分为上千个类别,错误率为 3.46%.在语音识别中,利用朴素贝叶斯进行分类,但是识别准确率不高,原因在于广告中存在的背景音乐可能对语音识别造成困扰,这种情况使得算法返回结果有误.但是这种方式有助于预测下一个需要推荐的广告类别,预测的意义重大.Yao 等人^[93]考虑到位置、收入水平等多种上下文,提出一种基于面部的广告推荐系统 FBARS,该系统的关键模块是面部识别模块.在面部识别模块分析完成后,将生成结果以三维数组的形式传递到深度学习推荐模块中.得到的准确度是传统的协同过滤方法的四倍.但是其离线应用场景具有一定的局限性,且与在线推荐方法对比的结果未知.上述内容也体现了推荐技术的全面性,也可表述为表 4 中的良好的可扩展性。

表 4 上下文推荐技术比较

上下文推荐技术	优点	缺点
基于用户位置或时间的广告上下文	有效解决冷启动问题,不依赖用户个人信息.	上下文信息利用不充分,多维上下文等有待深入研究
基于内容和关键词的广告上下文	适用于用户反馈内容、历史数据较丰富的情况,便于通过内容或关键字获取用户偏好	对内容或历史信息依赖较高,易出现冷启动问题、稀疏性问题且对内容的质量要求较高
基于类别的广告上下文	引入类别机制,形成分层结构,逐步满足用户的个性化需求	对分类的机制和推荐的粒度需要谨慎考虑,易导致推荐不精确
其他上下文	涉及多个方面,有良好的可扩展性	缺乏统一的框架或研究方向

其他上下文推荐的对上述几种上下文推荐技术的补充,通过利用不固定的上下文信息完成推荐,使得上下文推荐技术拥有较强的可扩展性.但是在上下文信息利用方面,缺乏统一的理论框架支撑,需要明确上下文推荐技术的研究方向。

表 4 将上述多种上下文推荐技术的优缺点进行

整理分析,从表 4 可以看出目前对于上下文信息的应用主要集中在内容、关键词、类别三个方面,对于用户位置、时间等其他上下文信息的利用还有待提高.另外,多维上下文研究较少,可以尝试将多种上下文信息结合使用.利用上下文信息的推荐技术比较多,但是各种方法特征各异,尝试形成一种统一的分析方法或者推荐框架依旧是需要努力的方向。

3.3.3 混合推荐技术

当下的个性化广告推荐系统很少是由单一的推荐技术组成的,大多是结合多种基本的推荐技术后改进而成.例如文献[50]中提出一种包括基于内容、协同过滤和基于知识的混合推荐系统.该系统中将本体论融合到语义模型中,对用户兴趣和广告特性进行建模,利用 NLP 生成向量表示用户画像和广告画像,通过计算用户和广告向量之间的相似性得到推荐结果.这样将多种推荐技术结合形成的技术称作混合推荐技术^[10],并根据个性化广告推荐中推荐技术之间的组合方式,将其分为加权式、层叠式、切换式^[5]。

(1) 加权式混合推荐

加权式混合通常对各推荐技术的输出赋予权重,最终结果由各输出加权求和得出.Kim 等人^[62]采用基于内容和协同过滤的技术进行个性化内容推荐,对较少的用户输入数据进行深度挖掘并推荐有价值的内容,保护用户隐私.对两种技术产生的推荐结果加权求和,得到最终要推荐的广告.但是实现该混合推荐的过程中需要对数据进行规范化验证,保证数据不存在异常值.且如果缺少用户的偏好信息,则容易产生冷启动问题.因此为了有效处理数据获取有价值信息,并解决推荐过程中存在的冷启动问题,利用语义模型可以取得不错的效果.Pazahr 等人^[22]提出一种语义增强的广告混合推荐系统,包括的推荐技术主要有基于人口统计学推荐技术、上下文感知的推荐技术、基于内容的推荐技术以及协同过滤推荐技术,并提出名为 *irate* 的指标,通过计算这四种技术的 *irate* 指标,将得到的 *irate* 结果进行加权求和,根据求和得到的结果找到最符合用户偏好的结果,并在 SARSIS 系统中实际应用.同时考虑到用户偏好动态变化的特征,不断更新用户信息。

(2) 层叠式混合推荐

层叠式是将上一步操作输出的结果作为下一步操作的输入,有着明显的层次结构.Chan 等人^[65]首先根据用户的历史移动日志定义相似性指标,并根据该指标将用户分组.随后判断目标用户属于哪个

分组,并将该组对应的广告集合推荐给目标用户.Youssef 等人^[49]首先利用目标受众画像对广告进行筛选,将筛选后的结果作为下一步的输入,并将用户偏好考虑进去,利用基于项目的过滤得到第二步的结果.随后,根据第二步的结果,将情绪上下文考虑进去进行重排序得到最终推荐结果.Yang 等人^[12]采用朴素贝叶斯分类算法对用户发布的网络广告文本和微博进行分析处理,随后根据是否属于同一类别,得到粗分类.在粗分类匹配结果的基础上,提出一种基于用户聚类的协同过滤推荐算法,向用户推荐广告,并且在一定程度上解决数据稀疏和冷启动问题.文献[94]中基于微博平台提出一种融合朴素贝叶斯分类和基于用户聚类的协同过滤方法的层叠式混合推荐系统,分步对用户推荐广告.

在深度学习方法中同样存在层叠式混合推荐.Lee 等人^[95]提出结合 CNN 和 RNN 的深度混合模型,首先利用 CNN 从 tweet(对话等)中学习重要的局部语义,并将它们映射到分布式向量当中.随后这些分布式向量由 LSTM(Long Short-Term Memory)进一步处理,计算目标结果与给定 tweet 对话的相关性.Wang 等人^[96]为对文本信息序列建模,将 RNN 与去噪的自动编码器结合.首先设计了一个 RNN 的泛化,称为鲁棒递归网络.随后在鲁棒递归网络的基础上,提出分层贝叶斯推荐模型 CRAE.CRAE 包括编码和解码两部分,但是它用 RNN 代替了前馈神经层,使得 CRAE 能够捕获项目内容信息中的序列化信息.上述层叠式混合推荐方法能够在一定程度上缓解数据稀疏和冷启动问题,并且有效提高算法效率.

(3) 切换式混合推荐

切换式是根据设定的切换标准,在不同操作之间进行切换.切换式需要根据真实情况调整方法,使结果更加符合实际要求.Tian 等人^[97]创建一种数字标牌的广告模型,根据广告模型的置信度的大小在线模式和离线模式之间进行切换.在线模式通过广告模型计算的概率分布选择广告,离线模式根据当前时间从默认广告播放列表中选择广告.Li 等人^[55]考虑到用户兴趣变化缓慢会导致用户收到重复推荐的广告的情况,介绍一种结合用户兴趣与动态信息的广告推荐系统.其中提出贪婪安全区域算法,用于构建并维护安全区.将对安全区域的实际情况的判断结果作为切换式混合推荐的切换标准,以确定是否进行广告的重新推荐,并决定合适的广告检索方式,以便提升推荐速度.文献[98]中构造动态上下文安全区域,根据上下文的变化是否在安全区域

内进行策略之间的切换.若上下文变化在安全区域内,则不改变推荐结果,节省检索成本.若不在安全区域内,则重新进行在线检索,改变推荐结果.

混合方式多种多样,对参与混合的方法的数量没有限制,能够利用多种方法的优点弥补单一方法的不足.表 5 对三种混合推荐技术的优缺点进行总结,可以看出每种组合方式具有不同的优点和缺点.但是在具体场景下利用何种混合方式仍是一个需要思考的问题.如果能够针对不同场景特点,形成一套混合方式的使用标准,会有助于研究的深入进行.

表 5 混合推荐技术比较

混合推荐技术	优点	缺点
加权式混合推荐	综合多种推荐技术的优势,得到的推荐效果比较稳定	确定各推荐技术的权值比较复杂,且耗时
层叠式混合推荐	层次结构明显,逐步提高计算精度,并提高计算效率	中间过程复杂,分层结构对前后的衔接要求较高
切换式混合推荐	切换式根据实际计算情况选择最合适的推荐方式	切换标准对实际效果影响很大,需要慎重考虑

3.3.4 点击率预测技术

广告点击率 CTR(Click-Through Rate)是通常作为指标被用于评价在线广告推荐系统的表现^[65,99],同时 CTR 也可以衡量用户对特定广告的兴趣^[23],广告推荐系统能够通过预测广告的点击率来推荐广告^[100].Liu 等人^[100]基于用户兴趣和 CTR 预测提出一个公平的广告推荐方法,从用户的点击行为、当前阅读新闻和长期阅读行为三个维度,分析用户兴趣,并通过对用户整体和对用户个人的广告推送频率提出广告公平推送机制.提高网站上所有广告的平均 CTR,保证每个广告曝光时间是相似的.Chen 等人^[101]建立一个社会意向语料库,从语料库中发现热门关键词,预测广告 CTR 的未来趋势,帮助广告主提升广告效果.其研究结果表明预先了解公众意见和事件可以有效增强点击预测.因此 CTR 预测是与推荐技术密切相关的技术,目前的 CTR 预测技术可以分为分解式^[102,103]、深度学习式^[104,105]、分解式与深度学习式结合^[106,107]三种.

(1) 分解式

该方式通过分解机(Factorization Machine, FM)类或者矩阵、张量分解等技术得到广告特征.Shan 等人^[102]提出一种基于塔克分解的完全耦合交互模型

FCTF, FCTF 是一个三阶张量分解模型,并且运行时的复杂度是线性的,适合高维计算.在场感知分解机(Field-aware Factorization Machine, FFM)^[51]的基础上进行改进也能有效提高预测效果.例如,文献[103]中使用粒子群优化方法优化 FFM 并提高 FFM 精度.文献[108]中提出一种场加权分解机 FwFMs,相对 FFM 以更加节省内存的方式模拟不同场之间的不同特征交互过程.上述方法均能缓解数据稀疏问题,有效应对高维场景,提高 CTR 预测精度.然而,FM 类不适用于所有的一般非线性模型,例如高阶模式^[109],此外还需要注意过拟合、复杂度较高的问题.

(2)深度学习式

该方式主要通过深度学习中的方法预测 CTR,根据深度学习方法机制的不同,这里可以将深度学习式分为传统的神经网络方法和注意力机制两种.

传统的神经网络方法主要是利用相关神经网络及其变体进行 CTR 预测.例如,在循环神经网络 RNN^[53]的基础上进行改进,用于预测 CTR.文献[104]中提出基于长短期记忆 LSTM 的方法,是 RNN 的一种变体,避免 RNN 因梯度下降而产生的梯度消失和梯度爆炸问题,采用 LSTM 结构代替 RNN 中的隐含层节点,并增加输入输出门等结构,其效果优于线性模型和一般的神经网络.文献[105]中采用门循环单元神经网络(Gated Recurrent Unit, GRU)模型预测广告 CTR,与 RNN 相比,GRU 增加更新门和复位门等结构,使其在较少的迭代次数下更快地到达最优点.上述两种方法均对 RNN 结构进行修改,提高其性能.

另外,在深度信念网络(Deep Belief Network, DBN)^[110]的基础上进行改进,也具有一定的研究意义.例如,Jiang 等人^[111]提出一种将 DBN 与逻辑回归(Logistics Regression, LR)相结合的深度架构模型 DBNLRL,解决上下文点击率预测问题.Xu 等人^[112]提出一种最优深度信念网络 OCDBN 模型,从输入实例中提取全局关键特征,尝试用最优均值去除技术提高点击率预测效率.

除了传统的神经网络方法外,注意力机制也成为近几年的研究热点.将注意力机制用于 CTR 预测方面,能够有效提高建模能力,对用户行为进行更加深入的分析^[113,114].Zhai 等人^[114]认为,注意力可以解释为一种 pooling 方法,类似于平均 pooling 和最大值 pooling,将一系列向量压缩为单个向量.然而与平均和最大值 pooling 不同的是,基于注意力的 pooling 是自适应的,能够将较大权重分配给重要的项目.另

外,Zhai 等人^[114]提出一种新的注意力网络 DeepIntent,利用注意力得分,提供一种用于可视化基于深度神经网络的模型的直观方式,增强深度模型的可解释性,提升向量表示的质量,对于 CTR 预测方面有一定帮助.并且在与 RNN 及其变体进行实验比较中取得明显的提升效果.Wang 等人^[115]利用神经网络建模中注意力机制的优势,探索高阶特征交互,有效挖掘特征之间的关系,提高 CTR 预测的准确率.但是目前大多数研究只关注用户层次的 CTR 预测,忽略了广告商层次的 CTR 预测的重要性.Gao 等人^[116]受到神经网络的启发,提出一种上下文感知注意力卷积神经网络 CACNN,捕捉季节性和趋势性等时间特征,利用注意力机制获取历史 CTR 与上下文信息之间的相关性,更好地预测 CTR.

深度学习式的方法能够以较好的 CTR 预测效果满足研究需求,但是依旧存在较多不足和需要改进的内容.在传统的用于 CTR 预测的神经网络方法中,固定长度的表示方法限制了捕获用户兴趣的多样性.因此提高模型的表示能力有一定重要性,例如 Zhou 等人^[117]提出深度兴趣网络(Deep Interest Network, DIN),通过激活相关的用户行为,获得对不同广告的用户兴趣的自适应表示向量,DIN 也被应用于 Alibaba 在线展示广告系统中.此外,传统的神经网络方法通常在预测过程中,模型的参数规模和特征维度会非常大,训练时间急剧增加.为此,可以尝试通过解决参数冗余问题来应对该现象.

利用注意力机制实现 CTR 预测,与传统的神经网络方法相比,能够取得不错的效果.但是目前将注意力机制应用于 CTR 预测的研究较少,可以在该领域进行深入研究,并尝试将注意力机制应用于各领域的推荐系统当中,提高推荐质量.

还需要注意的是,在深度学习式方法中,数据的噪声会影响模型获取特征信息^[118],参数学习过程受到多种限制,当训练数据受到不确定性干扰时,对 CTR 预测效果影响较大,即鲁棒性较差.因此,对于在噪声环境中的 CTR 预测依旧需要深入研究.

(3)分解式与深度学习式结合

目前将分解式和深度学习式结合的研究较少,但是若将深度学习式中易提取特征的优点与分解式中降低维度的优点结合,对于提升 CTR 预测性能会有帮助.例如,She 等人^[106]利用卷积神经网络提取特征并通过分解机进行分类和预测,产生不错的结果;Liu 等人^[107]尝试使用增强特征嵌入功能的模型,主要将分解机类方法与多层感知机(Multilayer

Perceptron, MLP)结合,例如 FM-MLP、FFM-MLP 等,提升预测的准确率和效率.因此权衡分解式与深度学习式的优缺点,尝试结合两种方式提升预测效果.但是这两种方式单独的训练过程易费时,选择合适的组合方式需要慎重考虑,导致将二者结合的实际效果不容易把握.

表 6 中对三种点击率预测技术的优缺点进行分析,结合实际应用场景,为选择合适的点击率预测技术提供帮助.点击率预测技术中对深度学习的使用较多,且近几年的研究成果丰硕,未来可以考虑将其作为单独的研究领域进行论述.

表 6 点击率预测技术比较

点击率预测技术	优点	缺点
分解式	缓解数据稀疏问题,降低维度,提高模型表达能力	训练过程费时,计算非线性模型有困难
深度学习式	易提取特征,更快得到最优值,提高建模能力	参数规模、特征的维度不断变大,增加训练时间
分解式与深度学习式结合	互相补充不足,可以提升预测的效率和效果	结合需慎重,实际效果不好把握

3.3.5 其他推荐技术

该部分针对一些热点技术进行补充分析,主要包括迁移学习、强化学习等,并对这些方法在广告推荐中的作用进行说明.

目前广告相关数据相对稀缺,一方面,由于目前大部分广告推荐研究中,使用的数据集为内部数据集,即不公开的数据集.另一方面,一些广告数据侧重于广告点击信息等,对其他可用信息涉及较少.为了应对上述情况,可以使用迁移学习的方式.迁移学习能够有效应对广告数据稀缺的情况,从相似任务中进行学习^[119],利用与当前场景类似的数据集训练算法或模型,一定程度上增加算法或模型的泛化能力.Yan 等人^[80]利用迁移学习,通过各种应用程序数据或者关于广告和新闻的内容交叉学习用户行为,分析用户在应用程序中和应用程序间的行为,实现实时的个性化广告和新闻推荐,并有效缓解用户冷启动问题.其新闻应用程序能够使新用户的点击率增长 12%,为用户提供更好的体验.Su 等人^[99]利用已有的广告数据,提出一种转移学习的方法用于提高对缺乏训练数据的新产品的 CTR 预测精度.该方法中使用了改进的 TrAdaBoost^[120],设计了一种基于梯度信息的采样策略,并利用类似于 MapReduce 的机器学习框架,与监督式方法相比,同时提高了计算效

率和 CTR 预测精度.

除迁移学习外,强化学习也可改进个性化广告推荐系统,强化学习算法能够考虑动作的长期影响^[121],并在面向特定任务的算法设计方面取得了长足的进步^[122],使得在广告推荐系统和强化学习之间开辟合作的渠道^[56]具有一定的研究意义.Theocharous 等人^[121]指出强化学习在个性化广告推荐中的研究还处于初级阶段,需要在计算和评估方面进行改进.Rohde 等人^[56]提出基于强化学习环境下的推荐系统 RecoGym,用于在线广告的推荐.它允许参数化潜在空间的维度,同样参数化广告曝光水平对特定时间广告点击率的相对影响程度.这是推荐系统研究领域向前迈出的重要一步,可以使得离线和在线指标能够结合起来,协调线下和线上的性能.

综上所述,目前个性化广告推荐技术主要集中在上述几类当中.在偏好获取技术中缺乏对用户动态偏好获取方面的研究,在上下文推荐技术中对时间、位置等上下文的使用不充分,可以考虑将多种上下文信息综合考虑,开发新的混合方式,并将广告点击率预测作为推荐的参考步骤.此外,对于深度学习、迁移学习、强化学习等在广告推荐中的广泛应用还需要进一步研究.

3.4 个性化广告推荐效用评价

效用评价用于衡量个性化广告推荐系统的性能并直观反映其中存在的优势和不足,是个性化广告推荐过程中不可缺少的环节.对效用评价来讲,主要包括广告数据集和评价指标两个关键元素.

3.4.1 广告推荐数据集

在广告推荐领域研究阶段,通常涉及到广告数据的收集与处理.研究使用的数据集的来源可以分成三种:一是利用作者工作单位提供的现实世界的内部数据集;二是由一些组织举办的竞赛提供的公开数据集或者由相关机构在互联网上公开的数据集;三是由研究人员在互联网上亲自抓取并处理得到的数据集.

(1) 内部数据集

由于研究人员在相关部门工作,易于获取研究需要的广告数据进行推荐的研究与实验.该种数据集具有内容充实、获取灵活、数据较新的特点.Xia 等人^[42]利用 Yahoo 的广告和数据团队提供的移动用户事件数据进行实验,搜集 ios 用户的原始事件,进行大规模评估.Wang 等人^[24]利用 Yahoo 的广告展示平台,利用该平台中某一个月的广告服务日志数据进行

研究.Hwang 等人^[47]根据 Yahoo 公司提供的网络广告进行分类,并利用 CKIP 对关键词进行提取,但是用户对广告的偏好是通过用户对用户采访获得的.Su 等人^[99]利用来自百度的真实在线广告数据进行实验,并在公司的内部 MapReduce 框架上实现其算法,这个框架提供了用户友好的 API 高效的运行环境.

(2) 公开数据集

目前还存在公开的数据集提供给开发人员使用,例如某些机构为了举办比赛而公开的数据集,以及某些公司提供的不涉密的广告数据集.该种数据集有数据权威、保护隐私、普遍适用等特点.Li 等人^[55]使用广告数据集和社交网络数据集进行实验,广告数据集是包含 Amazon 的产品^[123]和一些关键词查询等内容的广告存储库,社交网络数据集使用 Twitter 和 News 两个真实世界数据集,两者均来自 SNAP.Chan 等人^[65]利用台湾的的一家手机广告公司 WAYSTORM 提供的移动日志数据集,包括印象数据和点击数据两个两种,分别记录不同信息.文献[2]中在三种不同的数据集上进行实验,其中两个数据集从银行活动中获取,另一个是从大型连锁酒店

的活动中获取,将使用特定策略收集的数据用于训练,将使用随机策略收集的数据用于测试.Roffo 等人^[124]公开了 ADS 数据集,该数据集中首次提供用户对广告的评分信息.Sidana 等人^[125]为方便广告推荐系统的研究,公开了 KASANDR 数据集,该数据集收集自 Kelkoo,其中的点击行为附带丰富的上下文信息,并有助于研究隐式反馈的影响.文献[109,117]中使用 Alibaba 提供的 Ad Display/Click Data on Taobao.com 数据集,该数据集包含用户的行为日志,涵盖了用户在 22 天内的购物行为,可用于根据用户历史购物行为预测用户在接受某个广告曝光时的点击概率.文献[102,118,126]在预测 CTR 时,使用 iPinYou 于 2014 年发布的桌面显示广告数据集,它包括某个全球竞标算法竞赛三个季度的数据集.以及 IFLYTEK 有限公司提供的包含投标和点击数据的 IOS 数据集.Juan 等人^[51]使用来自 Kaggle 比赛的两组 CTR 集合 Criteo 和 Avazu,重点考虑两个数据集的特征因素.Liu 等人^[107]同样借助 Avazu 的数据研究其模型在离线场景下的效果.表 7 对部分公开数据集的特征、优缺点及统计信息进行描述.

表 7 部分公开的广告数据集

数据集	特征	优点	缺点	统计信息
ADS Dataset ^[124]	首次提供广告评分信息	可用信息丰富,有丰富的用户心理性因素可用于情感分析	缺乏社会关系信息,评分标准比较主观	包含人口统计学信息,包含富媒体、图片、文本广告,并将广告分为 20 种,超过 1200 个人图片(被标记为积极或消极).评分不小于 4 即赋予点击标签,小于 4 为未点击
KASANDR ^[125]	从推荐系统中收集数据	数据较新,用户信息和点击信息详细	包含的数据类型较少	记录 2016 年 6 月消费者对欧洲电子商务领导者 Kelkoo 投放的广告的响应行为.包含来自 20 个欧洲国家的 1.23 亿用户提供的 1600 万次点击
Ad Display/Click Data on Taobao.com ^[109,117] (Taobao)	信息脱敏,但不影响使用	用户、广告信息丰富,涵盖比较全面的用户行为信息,应用范围广	用户信息分类标准不明确,用户的行为序列缺少脱敏的广告 id	从 Taobao 网中随机抽样 114 万用户的广告展示/点击日志,构成原始的样本骨架,涵盖了全部广告的基本信息,涵盖了全部用户 22 天内共 7 亿条购物记录
Display Advertising Challenge ^[51,118] (Criteo)	数据特征多元化	数据连续,采样率不固定,正负样本比例不悬殊	应用范围有限,多用于 CTR 预测	广告 CTR 预估的比赛数据,由知名广告公司 Criteo 赞助举办.数据包括 4 千万训练样本,500 万测试样本,特征包括 13 个数值特征,26 个类别特征.
Avazu Click-Through Rate Prediction ^[51,107] (Avazu)	数据清晰明确	内容丰富,包括网站和应用的种类,数据连续	时间跨度有限,特征获取不全面	移动广告 DSP 公司 Avazu 在 Kaggle 上举办的广告点击率预测的比赛数据,前几日为训练集,最后一天为测试集
iPinYou Real-Time Bidding Dataset ^[102,118,126] (iPinYou)	数据特征多元化	数据连续,数据量大	若用于广告推荐中,需要比较复杂的处理	本数据集包含了 iPinYou 全球 RTB 竞价算法竞赛三季的数据.包括在 2013 年内的 10 天内来自 9 个不同公司的用户的 1500 万条反馈

(3) 抓取数据集

若不存在满足研究要求的数据集,研究人员可以自行在网上抓取广告数据.该种数据集有针对性

强、目的明确、内容可控等特点.Wu 等人^[13]利用 HyXen 提供的 AdLocus 服务,每隔半个小时收集一次广告数据.Pazahr 等人^[22]借助 Web 应用程序

SARSIS,尝试从社交网络 Last.fm 获取广告相关数据.Fan 等人^[61]在 Ebay 和 Wikipedia 种收集用户的提交信息等,并将数据处理为不同的格式用于 BCCA 的实验.Azimi 等人^[127]从全球最大的在线广告系统 RightMedia 中提取广告活动创意,并计算两个月内用户对创意的点击率,并为了消除广告位置和大小对性能的影响,创建具有相同位置和大小的一组数据集.Balkan 等人^[128]分析两个不同的商店和两个不同的显示器匿名收集的数据,观察顾客在一天或一周中的不同时间、人口特征和性别上的观看情况,训练模型,得到下一时间要推荐的广告.Hu 等人^[48]收集一组为期三周的用户行为日志,并将用户对广告的隐式反馈分为 6 类,针对上下文特性进行研究.

综上所述,在个性化广告推荐领域中,公开数据集较少,多采用内部数据集或自行抓取的数据集进行研究.因此,需要不断扩充公开数据集的数量,并提升数据集的质量,使数据真正发挥其作用.

3.4.2 个性化广告推荐评价指标

评价的方式分为线下方式和线上方式,线下方式主要是将特定的数据集按照一定的要求划分为训练集和测试集,通过训练集来训练目标算法或者模型,并使用测试集对训练完成的算法或模型进行结果测试,并根据测试的结果利用多种评价指标进行评价.线上方式主要是通过用户对系统提供内容的实时反馈以及操作或者填充调查问卷的方式对系统结果进行评价.

根据评价指标的普遍适用性和专业性原则,将评价指标分为传统评价指标与专用评价指标.文献[129]将推荐系统中使用的评价指标进行系统的介绍,并将评价指标分为准确度指标、基于排序加权指标、覆盖率、多样性和新颖性,共计 5 类 27 种评价指标,并对各自的优缺点以及适用的环境进行深入分析.根据其分析,可以将文献[129]中的评价指标归为传统推荐指标.而在个性化广告推荐领域,在使用传统推荐指标进行效果评测的同时,还需要专用指标进行扩充.

(1)传统评价指标

在个性化广告推荐技术中,大部分采用线下的方式进行评价.推荐技术的评价通常从效率和效果两个方面进行考虑,即考虑其时间复杂度和推荐准确度.对于传统评价指标的使用相当广泛,在个性化广告推荐系统研究中,会经常使用 Precision^[17,22,42,44,45,47,61,89,124,130,131]、Recall^[17,22,42,44,45,61,89,124]、Accuracy^[2,89]、

AUC^[25,99,102,107,109,117,118,124,126]、F1^[17]或 F-measure^[61]等指标进行准确性的评价.当准确性评价不能满足要求,并且遇到预测结果与真实结果都存在时,可以用 MAE^[11,17,19,22,124]、MSE^[124,127]、RMSE^[102,124,126]、Logloss^[51,118]进行评价.为了应对传统推荐指标不适用的场景,可以对传统推荐指标进行改进,例如用 Instance precision^[41]、Instance recall^[41]、Instance fallout^[41]、Avg.MAE^[19]、ACP^[131]进行更加准确的评估.

(2)专用评价指标

除了使用传统评价指标外,还存在一些专用评价指标,专用评价指标是指专门用于广告推荐的评价指标,不同于传统指标的普遍适用性,专用指标有着专业、针对性强的特点.目前适用的专用指标主要有:CTR^[58,61,65]、RR^[13,58]、ER^[58]、Avg%Positive^[2]等,这些专用指标根据研究人员的特定研究内容进行制定.

除了 CTR、RR、ER 这几个专用指标可以在其他研究领域里扩展外,还有一些专用指标具有很强的针对性.例如,Wang 等人^[24]利用转化率的指标评测其广告推荐系统的实际提升效果.Yuan 等人^[41]提出 effect 指标,用于衡量其个性化广告服务 MALCR 的效果,其中考虑广告推送和收到用户反馈之间的时间间隔,以及用户对广告的评分.Yang 等人^[132]在其研究中对 Zapping 行为进行解释,指出 Zapping 行为是指用户停止观看广告的行为,根据这种行为进行分类,即 zapping/non-zapping.并为了解决广告评价中的评价指标匮乏问题,提出 Zapping Index(ZI)评价指标,该评价指标用来度量用户发生 Zapping 行为的概率,同样可以用来度量用户对不同商业类型的偏好.未来可以在 ZI 评价指标中将动态特征考虑进来,不断优化评价指标.

综上所述,个性化广告推荐作为推荐系统的一部分,仍然适用于传统的评价指标,且目前大部分研究中依旧使用传统的评价指标.但是由于其针对广告推荐进行研究的本质,需要用更加具有针对性的专用指标进行评价.虽然目前使用的专用评价指标较少,但是从另一个方面说明个性化广告推荐中的专用评价指标具有很大研究空间,需要努力尝试提出新的评价指标.

为了进一步探讨个性化广告推荐系统的评价指标在研究中的具体应用效果,这里对部分有代表性的个性化广告推荐技术的推荐性能进行定量分析和说明.然而,在 3.4.1 节中可知,虽然存在大量的

个性化广告推荐领域的研究,但是在该领域的公开数据集较少,很难得到一个普适性较强的公开数据集,且各研究中采用的评价指标多是不同的.于是,在表 8 中针对一些研究,结合各自使用的数据集和推

荐指标进行总结说明,其中包含部分使用相同数据集和评价指标的研究.随后结合表 8 中的研究的实验结果,针对各个研究进行实验效果说明,并对部分使用相同数据集和评价指标的研究进行对比分析.

表 8 结合主要数据集和指标的研究总结

数据类型	数据来源	主要指标	研究索引	研究相关说明
内部数据集	Yahoo	Precision	[42,47]	文献[42,47]分别借助 Yahoo 移动事件数据和广告分类信息进行研究,均明显优于对比方法
		转化率	[24]	通过在 Yahoo 广告平台及推荐中加入用户购买记录,提升广告转化率
	百度	AUC	[99]	借助迁移学习在真实的百度广告数据集上进行实验,其方法的效果优于部分监督学习方法
公开数据集	ADS Dataset	Precision, MSE 等	[124]	分为广告点击预测和广告评分预测两种场景,前者用 Precision, Recall, AUC 评价,后者用 RMSE, MSE, MAE 评价,通过对多种方法改进,两种场景下的效果均得到提升
	Taobao	AUC	[109,117]	文献[109]中借助 L1 和 L2,1 正则化得到非凸非光滑优化问题,并采用方向导数和拟牛顿法解决.文献[117]提出深度兴趣网络 DIN 并对其优化,两者已应用于 Alibaba 在线展示广告系统
	Criteo	Logloss	[51,118]	文献[51]在分解机 FMs 中加入领域概念,提出场感知分解机 FFM.文献[118]提出模糊深层神经网络 FDNN,并利用逐层的无监督方法和模糊逻辑回归方法,二者均可用于 CTR 预测
	Avazu	AUC	[51,107]	文献[107]将文献[51]中的 FFM 用于特征嵌入得到 FFM-MLP,并在在线场景中表现不错
	iPinYou	AUC	[102,118,126]	文献[102,126]分别提出基于特征的完全耦合交互张量分解和稀疏分解机的方法,均能够有效应对数据稀疏问题.文献[118]提出 FDNN,增强数据表示能力和健壮性
	HyXen	RR	[13]	通过构建点击概率模型和多种回归模型,形成动态广告推荐系统
抓取数据集	Last.fm	MAE	[22]	通过语义信息提高推荐的准确性和鲁棒性,利用用户意见不断更新推荐知识库
	Ebay, Wikipedia	CTR	[61]	收集用户提交的信息,对内容进行文本挖掘得到内容与广告的相关度,根据相关度选择广告

在借助内部数据集进行的研究中,文献[42,47]借助 Yahoo 提供的数据进行实验并进行推荐,文献[42]中基于 App 的方法的 Precision 在 top-2 时可达 0.2 左右.文献[47]通过对 32 个用户进行真实测试,其的方法相对于随机推荐的 Precision 提升了 0.2116,达到 0.3940.文献[24]的方法借助 Yahoo 提供的广告平台数据改进广告推荐效果,在产品表现上,广告转化率提升了 1.92%.文献[99]在百度在线广告数据集上实验并提升点击率预测效果,通过迭代更新数据权值,将不同数据有选择地结合起来进行训练,得到的 AUC 达到 0.7341,证明迁移学习在类似场景下具有研究价值.

在借助公开数据集进行的研究中,文献[124]在其公开的 ADS 数据集上实验,在广告点击率预测场景中,其方法 LR-B5*在类别层次上得到的 Precision、Recall 在所有方法中均为最大,分别达到 0.4120、0.5210.广告评分预测场景中,发现产品类别数量为 8 时,其方法 SVR-rbf B5 得到的 RMSE、MSE、MAE 在所有方法中均为最小,分别为 0.1010、0.0110、0.0890.文献[109,117]在 Taobao 数据集上实验并用于广告点击率预测,文献[109]从大量稀疏数据中抓取非线性

性模式,AUC 达到 0.6629.文献[117]通过对 DIN 进行小批量正则化以及加入骰子激活函数,训练后得到的 AUC 达到 0.6083.文献[109]的方法能够较好地拟合复杂的非线性函数,并能够有效应对数据稀疏问题,相对于文献[117]有一定优势.文献[51,118]在 Criteo 数据集上实验并提升 CTR 预测效果,文献[51]的方法能够很好地应用于稀疏但包含大量类别特征的数据,其在公共数据集上的 Logloss 为 0.4461.文献[118]的方法对噪声数据有很好的鲁棒性,能够学习有用的高阶特征交互,其 Logloss 为 0.4510.文献[51]相对于文献[118]能够在数据稀疏的场景中有更好的表现,具有更少的损失.文献[107]在 Avazu 数据集上实验,通过将文献[51]中的 FFM 用于增强特征嵌入得到 FFM-MLP,其 AUC 达到 0.7498,并在在线实验中提升了对新广告的点击率.文献[102,118,126]均在 iPinYou 数据集上实验,且采用的实验方式不同,但是从整体上看三者的 AUC 由高到低为:文献[118]>文献[102]>文献[126].文献[102,126]分别采用交互张量分解和稀疏分解机的方法,相对于文献[118]中的模糊深层神经网络方法,不能充分获取数据中的高阶非线性代表特征和复杂的内在映射关

系。

在借助抓取数据集进行的研究中,文献[13]借助在 HyXen 公司获取的数据,构建 16 种回归模型用于广告推荐,其中效果最好的模型的 RR 达到 0.9569。文献[22]在 Last.fm 中获取相关数据并进行实验,其借助数据中的语义逻辑信息,通过融合多种推荐技术得到广告推荐结果,并应用与 SARSIS 系统中。随着用户数量的增多,SARSIS 的 MAE 逐渐变小,当用户数目大于 50 人时,MAE 降到 0.1 及以下。文献[61]从 Ebay、Wikipedia 获取训练数据并进行实验,根据博客内容获取用户兴趣,文中方法在所有触发页中得到的广告 CTR 达到 57%。上述研究的方法多种多样,对应的效果也有提升,进一步验证了广告推荐技

术的全面性。

4 个性化广告推荐的应用现状

由于个性化广告推荐通过获取用户偏好,利用多种推荐技术为用户推荐广告,更好地满足用户需求,使其拥有可期的应用前景,也使得广告推荐系统应用场景拥有多样性的特点。本节整理了个性化广告推荐的一些典型应用场景,主要包括面向传统互联网、移动服务、数字标牌、IPTV 这四种场景。并在表 9 中列举了上述四种应用场景中的一些个性化广告推荐系统典型应用,且对各个应用中的主要利用信息以及使用的个性化广告推荐技术进行总结。

表 9 个性化广告推荐应用

应用场景	主要利用信息	典型应用	个性化广告推荐技术
传统互联网	网页内容	AdROSA ^[43]	协同过滤
	文本内容	BCCA ^[61]	基于内容的广告上下文推荐
	Cookie	Yahoo's display advertising platform ^[24]	基于关键词的广告上下文推荐
	用户活动记录,用户信息	SARSIS ^[22]	加权式混合推荐
	点击数据	RecoGym ^[56]	强化学习
	面部信息	FBARS ^[93]	深度学习
移动服务	时间	AdLocus ^[13]	基于时间的上下文推荐
	位置	MALCR ^[41]	基于用户位置的上下文推荐
	应用使用和点击历史	RAM ^[65]	层叠式混合推荐
	反馈信息,天气日期等环境信息,年龄等上下文信息	Wallet ^[70]	其他上下文
	位置	Ad-me ^[14]	基于用户位置的上下文推荐
	位置、评分	ADA ^[27]	协同过滤
数字标牌	收视率、销售数据	IAF ^[97]	切换式混合推荐
IPTV	用户信息、电影信息、访问日志	On-Demand IPTV ^[30]	协同过滤
	时间	Murali's prototype ^[31]	基于时间的上下文推荐

4.1 面向传统互联网的广告推荐

利用网络平台对用户偏好进行追踪、研究,使得在网络平台在投放广告方面相对于报纸、杂志、电视等传播媒体有着得天独厚的优势。传统互联网代表的是 PC 端的时代,在 PC 上投放广告已经成为越来越多广告商的选择。根据个性化广告推荐是否涉及社交平台,将面向传统的互联网的广告推荐类型分为一般网页广告和社交平台广告。

一般网页广告上的广告推荐通常根据网页内容、网址链接信息、用户记录等,通过内容获取或者分类器等技术,实现在网页上的广告推荐。目前已经

存在大量针对网页的广告推荐的研究^[57],例如,AdROSA^[43]集成网页和内容获取技术,通过考虑多种因素实现为用户推荐个性化广告,并具有很好的扩展性。Wang 等人^[24]利用辅助标识来找到用户在不同 cookie 中的联系,生成二部图架构,使用先进的随机游走模型对与每个浏览器 cookie 相关特性衍生。另外,其提出一种监督式的链接预测模型,该模型能提供足够的候选关键词并提供推荐的关键词的评分排名。将上述研究内容应用于 Yahoo's display advertising platform,虽然很大程度上缓解冷启动问题,但是只将 IP 地址作为辅助标识,还有提升的空间。文献[25]中研究不同的浏览历史的获取周期如何影

响分类器的预测精度,发现利用网址的分类信息提高了分类器的准确率,并使用分类的浏览历史数据构建用户模型.其更多的关注确定潜在感兴趣的广告受众,分析网站的链接模式与之前访问过本网址的用户比较后的相似度.该研究有效地缓解冷启动问题,但是仍可以将数据获取的时间间隔进行细化.RecoGym^[56]根据用户在页面上对广告的点击数据,利用强化学习技术,判断用户在特定时间对广告的点击率,生成对用户的推荐,协调在线和离线的性能.若推荐系统无法与互联网连接,则可以考虑推荐离线广告.FBARS^[93]是在离线场景下使用的基于面部的广告推荐系统,对面部信息进行识别、跟踪和存储,随后利用深度学习的技术,借助用户多种信息,为用户生成推荐.但是该离线应用场景存在局限性,其利用摄像设备记录人脸,在应用过程中可能会在硬件设备、隐私保护上产生问题.

此外,广告推荐还应用到如博客、微博等社会化交流的大型平台之中,产生社交平台广告.由于这种社交平台的访问用户数量大,个性化的定向投放就显得尤为重要.BCCA^[61]利用文本挖掘技术来发掘博客中的特征,采用一种提高在线广告效益的上下文推荐算法.结合上下文广告文本挖掘技术形成以博客为中心的上下文广告框架,选择出与个人兴趣匹配的广告,并根据广告与用户兴趣的相关性进行排名.SARSIS 框架^[22]通过搜集社交网络用户活动记录,不断更新用户偏好,同时考虑用户信息的安全性,使用语义技术提高社交平台广告推荐的精度和健壮性.但是随着用户和项目数量的增加,需要在更复杂的场景下对该框架进行测试.上述在社交平台的广告推荐,虽然针对社交网络用户的行为为其推荐满足其需求的广告,但是没有充分利用社交平台中丰富的社交关系的优势,多侧重于用户在社交平台的行为反馈.

综上,面向传统互联网的广告推荐拥有丰富的可利用信息且利用方式非常灵活.但是没有充分利用网络环境给其带来的数据优势,例如同时结合多种上下文辅助信息、社交关系等,这方面有待扩展.另外,还需要注意保护用户的隐私.

4.2 面向移动服务的广告推荐

随着移动服务的高速发展和移动用户数量的不断增加,在移动设备上投放广告不仅可以弥补电视等传统平台上的广告投放的劣势,更可以达到比传统平台更加迅速高效的传播效果^[41].交互式宽带移动服务和个性化广告的融合为移动产业创造新

的商业模式提供了可能^[26],使得移动设备上的广告投放更容易实现个性化的定向投放.因此,越来越多的广告商逐渐将广告投放的重心移向移动平台,如何将新业务带给合适的客户成为移动运营商提供移动服务面临的主要问题^[133].根据面向移动服务广告推荐的使用场景,将其分为一般移动广告、移动App广告.

一般的移动广告主要通过短信、移动网页等比较传统的方式将推荐结果传递给目标用户.Yuan 等人^[41]提出一种基于位置的定制化移动广告推荐的基础设施,称为 MALCR.其通过分析用户的隐式浏览行为构建用户画像,根据用户所在位置处的广告与用户画像的相关性为用户推荐广告,移动终端通过短信获取推荐结果.Wu 等人^[133]提出一种新的广告用户选择方法,利用通话费用、短信费用、短信数量等数据,用最大频繁项发现理论进行推荐,并根据用户的反馈情况将用户分成正负样本,研究特征的区间映射.其实验结果表明,该方法能够显著提高广告的成功率,减少垃圾广告的数量.Liu 等人^[134]设计并实现移动互联网下基于用户行为的广告推荐系统,该推荐系统包括用户行为分析、广告生成、WAP(wireless application protocol)网页分析三个子系统.通过用户的行为特征分析算法,可以得到包括长期兴趣和短期兴趣的用户画像.最后计算用户特征与广告的相似度,用于排序和选择出最合适的广告呈现在移动网页上.

移动App广告主要在App应用程序内为用户呈现广告,用户在使用App提供的服务时,广告会以多种形式出现在App内部.Ad-me^[14]采用非侵入式方法,利用移动用户位置上下文信息和用户情感对目标用户提供个性化的移动广告.得知用户在什么地点需要广告,并在本地应用内采取合适的方式展示广告.Wallet^[70]是一款智能钱包App,其收集用户使用信息、位置信息等,生成用户画像传送到服务器.服务器根据广告内容、用户画像以及环境上下文信息选择目标广告,并将广告传回智能手机客户端.另外,用户对广告的反馈会被服务器用于完善用户及上下文信息,提高用户对广告的满意率.Wu 等人^[13]提出一种动态广告推荐系统,采用回归模型和点击概率模型对动态广告推荐系统进行设计.同时针对用户对广告点击率较高的时间段进行重点分析,优化点击概率模型,并尝试应用于名为 AdLocus 的App 当中.动态广告推荐系统的应用帮助 AdLocus 在避免冗余广告,减少系统开销方面有一定的改

进.RAM^[65]考虑用户画像、App 使用情况、点击历史这三种因素.RAM 利用 DBSCAN 算法对用户进行分类,然后对已经分类的用户群组进行广告分派.在推荐阶段,利用定义的线性加权相似度算法计算出目标用户属于哪一组用户分类,并将适合该用户分组的广告推荐给目标用户.

广告传播方式不局限于上述形式.随着自动驾驶汽车的无线通信与物联网的发展,对车辆自组织网络 VANET^[27]的应用引起人们的注意.并且由于车辆的移动性,当通过车辆进行通信时,广告可以扩散到更多地方.鉴于这种优势,ADA^[27]通过遗传算法和社交网络中的点中心度,选择一组种子车辆,用于向附近车辆投放广告.并且引入用于广告分类和转发的缓冲方案,采用基于协同过滤和基于位置服务的广告推荐算法,发现用户偏好,将广告的推荐到目标车辆的应用当中.但是考虑到行车安全,应将更多场景信息考虑进去,例如推荐时间、用户的时速、用户周围的车辆数目等.

面向移动服务的广告推荐与面向传统互联网的广告推荐相比,最主要的区别在于前者打破了空间上的束缚,与用户的交互也更加方便.综上所述,对于手机设备、移动应用等移动终端的广告推荐研究逐渐成为一种趋势,移动终端凭借其独有的移动性以及能对反映用户偏好相关信息的强大收集能力,能够为移动广告推荐提供更多的数据,方便研究人员进一步扩展移动广告推荐系统.

4.3 面向数字标牌的广告推荐

数字标牌指在大型商场、饭店、影院等人流汇集的公共场所,通过大屏幕终端显示设备,在特定场所、特定时间段对特定人群进行广告播放,这种特性使其具有广告效应.虽然数字标牌主要用于向观众提供广告内容的单向媒体,但是依旧可以通过其他设备与观众进行交互.例如,Ravnik 等人^[29]开发出一种带有摄像头增强的数字标牌显示器,通过计算机视觉算法获得观众的测量指标.包括提取人的停留时间、注意时间等时间度量,以及确定性别和年龄的人口统计指标.Ravnik 等人^[28]还指出收集观众测量数据可用作观看模式的统计分析、交互式显示应用以及对观察者建模的基础.

由于智能视频分析(Intelligent Video Analytics, IVA)的新技术的最新加入,这些显示器能够实时调整其内容以适应观众的人口和时间特征,以实现有效的实时信息或广告更新.Addicam 等人^[128]使用 IVA 系统收集的数据来构建预测模型,以便在正确

的时间为正确的客户识别正确的消息传递.并创建“观众感知显示”,可以根据观众行为和时间属性动态更改显示的广告. IAF^[97]率先将匿名浏览者分析和数据挖掘技术相结合,得到有针对性和交互性的广告.另外,IAF 将相关收视率信息与销售点数据关联起来,将特定人群对广告的反应时间与广告产品的销售效果建立联系.

综上所述,针对数字标牌的研究主要集中在广告自适应的方向上,根据多种环境或用户的信息提高推荐的准确度.未来可以将确定销售与观看时间或观众数量之间的关系纳入研究范围.并研究如何将天气或公众假期等外部因素纳入模型当中,考虑外部信息的影响,提高性能.

4.4 面向IPTV的广告推荐

IPTV 即交互式网络电视,由于数字技术、移动互联网技术、网络通讯等的快速发展,IPTV 逐渐被各大运营商采用和部署.IPTV 以家用电视为主要终端,相比于传统的广播电视媒体有着更强的交互性.鉴于此特性,广告商们纷纷将目标瞄准到 IPTV,在 IPTV 场景下的个性化广告推荐快速发展起来.

IPTV 的个性化广告的选择同样用到一些场景信息.Konow 等人^[30]提出一种视频点播场景下的上下文感知目标广告推荐系统,利用协同过滤推荐技术研究具有相似偏好的用户的行为和历史记录,对目标用户提供最合适的广告,并尝试将该系统应用于一项 On-Demand IPTV 服务中.

通过 IPTV 向用户群组推荐广告也是常见的应用场景之一.文献[31]中在 IPTV 系统中插入个性化广告的技术选项,描述一种由 Google 的 AdWords 扩展的出价模式,提出一种在线广告调度算法,在特定时间间隙中向一组用户展示多个广告,并构建 Murali's prototype 应用.文献[135]提供用于 IPTV 系统中的个性化广告推送的系统和方法,他们选择的广告取决于地理位置,人口统计,时间和电视节目.文献[135]与文献[31]共同意识到由于带宽有限,在 IPTV 上实现完全个性化是不可行的,因此他们对用户进行分组并评估,并对同一用户分组展示相同广告.但是文献[135]中的用户分组主要根据地理分布区域完成,容易造成年龄、性别等参数平均化,将导致系统变为传统广告的模式.

综上所述,在用于 IPTV 系统的上下文广告推荐中存在提升的空间,应进一步研究利用更多上下文信息的推荐引擎.此外,在注意冷启动、数据稀疏等问题的同时,还需要保证推荐体系结构的可扩展性,

以完成复杂场景下的推荐任务。

从上述总结及表 9 中可以看出,个性化广告推荐的应用场景多集中于传统互联网和移动服务当中,其他场景中应用较少.并且,表 9 中的主要利用信息和个性化广告推荐技术也多种多样,体现了偏好获取来源的灵活性和推荐技术的全面性.此外,随着 5G 技术的发展,无论是在提高数据传输效率方面还是在减缓时延方面有很大改进.尤其对移动场景下的广告推荐来讲,拥有相当广阔的应用前景,有助于进一步发展移动广告推荐系统.

5 个性化广告推荐存在的问题及研究方向

个性化广告推荐使得广告更加符合用户的兴趣,在研究和应用方面都取得不错的进展.然而,广告推荐中同时存在传统推荐的问题和广告推荐特有的问题.这部分主要讨论个性化广告推荐中存在的重点问题,并分析未来个性化广告推荐研究的方向,主要包括以下几个方面:

(1) 广告推荐的时效性问题

广告推荐的时效性需要考虑到用户需求的变化和时间上下文之间的联系,即广告的时效性由用户需求的时效性决定,用户的需求和偏好在一定时间内是允许存在变化的.例如,用户上周经常搜索计算机的商品信息,并在这周购买了一台计算机.但是购买后的一段时间后,购物平台或者网站依旧为其推荐计算机的相关广告,这种情况就是忽视用户需求的时效性,导致用户对该商品甚至该商品所属企业产生反感或抵触的情绪.

广告推荐的时效性不同于其他领域的时效性,例如,新闻推荐中的时效性是以时间为节点,新闻推荐区别于其他推荐的最大特点就是和时间上下文关联性很强,超过一定时间发布的新闻对用户来讲是没有意义的^[7].而广告推荐的目的是引起用户产生购买行为,可以在用户角度和广告产品角度对广告推荐的时效性进行把握.从用户角度来讲,可以将用户行为的变化作为参考.获取用户偏好的变化,并做出实时响应.从广告产品的角度来讲,根据产品推出的时间、广告发布的时间等,考虑广告效用随时间的衰减情况即产品是否还能满足当前用户需求.

因此,为给用户提供更新颖的、及时的推荐结果,个性化广告推荐系统同时考虑用户偏好变化和广

告效用的衰减,这是未来的研究重点之一.除了对用户动态偏好获取外,还应在系统设计上进行改进.对此,可借助 Hadoop 等建立分布式推荐系统,利用 MapReduce 等编程模型及 MongoDB 等 NoSQL 数据库技术,提高数据处理的能力和效率,进一步增强个性化广告推荐系统的可扩展性、灵活性、多样性,在保证性能的同时减少延迟.

(2) 用户的隐私保护问题

个性化广告在消费者隐私和数据安全方面引起广泛的关注^[26],存在发展也引起争议.近几年,用户在门户网站和金融公司的个人信息被大量暴露并被滥用^[70],许多国家已经制定有关该问题的法律^[26].最近,IAS 发布的“2019 广告行业脉动”的报告中指出,55.8%的受访者首要关注数据隐私问题,并且 93.3%的受访者认为数据隐私条例需要在全世界范围内得到完善^①.

在推荐技术的角度来讲,当前大多数广告推荐技术需要调用并分析用户的历史信息(如协同过滤技术,上下文信息等),即使例如基于社会化网络的推荐系统^[58]或基于位置-时间的推荐系统^[17]这些不依赖历史信息的推荐方式,也需要访问并分析某些用户的其他资料,如用户的社会关系,地理位置等等.而这些信息在一定程度上属于用户的个人隐私.另外,数据隐私处理会使得可以利用的数据量减少^[43],导致对推荐效果产生影响.

所以在具有隐私保护的广告推荐系统中存在两个方面的挑战,一方面是需要推荐系统有效保护用户的这些隐私信息,保证这些隐私不被他人过度访问.例如当用户共享智能设备时,先前用户的行为或偏好会通过广告透露给后续用户,进而造成隐私泄露.为解决类似挑战,除了减少对用户隐私信息的获取外,还可以进行用户切换检测.具体来讲,可以通过 cookie 等信息跟踪用户行为,根据用户经常使用的应用程序和网站等,进行用户的行为特征匹配.除此之外,可以在更细的粒度上进行研究,通过对用户浏览的图片或者关键词进行精确分析,发现用户之间的差异,防止个人偏好隐私泄露给他人.

另一方面的挑战是需要缓解因数据隐私处理对推荐产生的影响.为应对挑战,可以考虑在用户给项目进行评分时,用假名保护隐私^[136],而不是直接将相关内容直接删除.同时,将隐私信息对推荐的影响程度进行评级,对不具备代表性和说明性的用户

① IAS:2019 年广告行业发展趋势报告. <http://www.199it.com/archives/847084.html>

属性或信息进行筛选,尽量减少对用户直接信息的过度访问,或者根据影响程度将信息进行脱敏。

因此,权衡上述两个方面的挑战,提出有效的隐私保护机制(用户切换检测等)是今后研究的重点。

(3) 广告推荐中的冷启动问题

广告推荐中的冷启动问题产生的原因多由于产生了新用户或者新广告,并且新用户没有访问过广告,新广告也没有被用户访问。冷启动问题是推荐系统中的重要挑战^[80],解决冷启动问题也成为推荐系统中的关键任务。在广告推荐领域,已经存在很多研究用于应对冷启动问题。文献[12,27]根据用户行为种类产生用户对广告的评分信息。文献[17,41]不依赖用户信息,利用位置或时间上下文信息缓解冷启动问题。文献[12,62]将不同推荐技术按照一定组合规则混合使用,使得推荐技术之间能够优势互补,提升推荐效果。目前存在的冷启动解决方法中,主要是创造数据、利用其他辅助数据以及改进传统推荐技术等,属于比较常见的冷启动解决方法。

冷启动问题产生的根源在于相关数据不存在或者相当稀少,根据广告推荐系统中数据缺失的情况,将冷启动问题分为用户冷启动、广告冷启动以及系统冷启动问题,系统冷启动指既存在用户冷启动,又存在广告冷启动的情况。针对上述三种冷启动问题,可以考虑如下几种方法。

针对用户冷启动问题,一方面可利用迁移学习的方式,使用其他相关领域的的数据,弥补本研究领域数据不足的劣势,例如将新闻数据集和广告数据集混合^[80]。通过该方式,交叉学习用户行为特征,改善各自领域数据集不丰富的情况,还能提高模型或算法的泛化能力。目前,迁移学习在个性化广告推荐领域的研究较少,但是为解决广告推荐中的冷启动问题提供了新的思路。另一方面可引导用户通过社交账号登录,在降低注册成本的同时,获取用户的社交网络信息,提高新用户变老用户的转化率。尽可能扩展用户画像,增加更多维度的信息。

针对广告冷启动问题,主要通过新增广告的内容属性进行挖掘,包括广告的主题、主题类别、关键字等。例如可将广告转化为关键字向量,通过计算向量的相似度,实现广告聚类,并将其推荐给对类似广告感兴趣的广告用户。此外,利用深度学习等技术,舍去对一些广告的交互或评级信息,减少神经网络对类似信息的依赖,使其对新项目具有鲁棒性。

针对系统冷启动问题,主要通过专家标注的方式,引入专家知识。由于用户的兴趣可能性较多,需要

对用户提供具有代表性、区分性、多样性的广告,保证广告具有很高的覆盖率,可以较快地收集用户的反馈信息,并构建用户画像。类似于老虎机问题,即推荐系统并不明确哪些广告受用户喜欢,也不清楚用户喜欢特定广告的概率。此时可对用户随机推荐不同主题或内容的广告,根据用户的反馈再做判断。

(4) 广告推荐的内容敏感性问题

广告推荐的内容要符合在满足用户偏好的同时,也需要注意于当前上下文的匹配程度。广告推荐的内容敏感性问题主要体现在广告推荐当前的内容是否合理,会对用户的体验和感受以及商家的信誉产生很大的影响^[137]。例如,用户在手机应用中浏览一条事故新闻时,新闻中提到某景区设备发生事故,这时推荐系统可能根据该景区信息推荐该景区的广告,此时该广告的内容就涉及到推荐内容敏感性问题。而且,一些涉及违法犯罪内容的广告也会经常出现,对用户产生极大的误导与消极影响。

目前,针对广告推荐的内容敏感性的研究比较少,主要是通过构建分类器发现敏感内容。例如, Jin 等人^[138]设计一种独特的网页敏感内容分类标准。然后,构建一种分级分类器,在不需太多人工标记的情况下,形成具有良好精度的敏感内容分类器。Peng 等人^[139]在移动广告环境下提出一种基于两阶段的敏感性校核方法,包括广告分类和敏感性检测两个阶段,分别用于判断广告分类和审核文本内容中是否有敏感信息。上述方法均构建层次分类器,获取敏感内容,但是敏感性的确定过程存在主观因素,对敏感标准的确定和衡量是一个有趣的研究内容。

另外,深度学习技术的应用有助于确定广告中是否存在敏感性内容。Sanzgiri 等人^[137]利用预先训练的卷积神经网络处理广告图像素材,将图像内容与目标网页中的信息结合,以确定广告素材中是否存在敏感内容。但是其实验环境为离线实验,能否应对在线环境中实时改变的场景区还需要进一步验证。

因此,广告推荐内容敏感性分析中确定一个统一的敏感性标准,在减少主观因素干扰的同时,实现敏感内容的在线自动检测是未来值得研究的方向。同时,不能仅仅对广告的文本文本内容进行分析,还可以借助深度学习的方法对图像、视频、音频等格式的广告进行筛选,全方位防止敏感信息对用户产生不良影响。

(5) 用户动态偏好获取

在实际场景中,用户的兴趣偏好会随着时间的推移发生改变,静态的用户偏好无法满足用户的实

时需求.许多研究中通过考虑用户的长期兴趣^[40,61,100]、短期兴趣^[25],或者共同考虑用户的长期和短期兴趣^[104,134],获取用户偏好.但是用户长期和短期偏好的划分没有固定标准,并且随着时间的推移,用户的长短期偏好依旧需要重新获取.一些研究中尝试获取用户的动态偏好,通过多种推荐技术来保证对用户偏好的动态掌握^[22],根据用户反馈或者广告推荐系统效果评价及时更新用户信息^[4].但是用户动态偏好获取没有统一的理论框架或者方法,评价标准多种多样,无法在各种偏好获取技术之间进行效果对比.此外,用户偏好更新可能需要消耗大量的时间或计算资源,不能在短时间内对用户的即时需求做出响应.

因此,考虑到用户偏好更新的评价和效率问题,可以将以下几个方面作为未来研究方向:①构建统一的动态偏好获取和评价框架,为动态偏好获取提供理论和方法上的支撑;②划分时间窗口,提出有效的评价指标,衡量用户偏好在时间窗口之间变化的强度,并根据指标结果做出响应调整;③尽量减少用户的输入,降低计算规模,若用户具有结构简单的用户画像,可以提高用户偏好的更新速度^[14].

另外,随着交互方式的进步,许多系统或设备还可以获取更多的用户交互记录和实时反馈.例如通过扫描二维码或其他接触方式等^[140].因此,可以通过 cookies 或者其他软件信息等,对用户进行行为定向,跟踪并计算用户的实时偏好或趋势.一方面可以通过用户在网上留下的近期内容提取特征,并分析时间对用户兴趣的影响.另一方面,在广告展示时段内对用户行为重定向,在根据用户兴趣变化及时推荐广告的同时,可定向特定广告或服务的潜在用户,进而使广告推荐更加精准.

(6) 基于内容的广告上下文推荐的扩展

目前基于内容的上下文推荐多依赖于页面上的文本内容,例如用户评论^[21]、用户浏览的博文^[61]等.然而,随着媒体传播方式的丰富,页面上不仅仅具有文本信息,还充斥着大量的图片、音频、视频等信息.若有效利用这些媒体资源,根据图片或者视频中的内容,结合用户偏好,为用户推荐与图片、视频内容相关的广告,能够有效提高个性化广告推荐的效果.例如,文献^[141,142]中根据图像或视频内容分析,自动将视频广告与相关互联网信息链接.

对图片、视频内容的抽取能力不足是该研究方向的主要阻碍,导致无法准确推荐产品或服务.为此,对图片来讲,展示图片多是静态的,可借助模式识别

方面的算法模型,对图片进行特征抽取和内容识别.而对于视频来讲,可通过获取视频关键帧中的特征得到内容.因此,发展视觉搜索能力,利用深度学习等技术发现图片或视频等媒体中包含的内容,深入挖掘用户偏好,对扩展基于内容的广告上下文推荐具有重要的意义.

(7) 移动广告推荐系统本地化

智能移动设备的普及和移动互联网技术的进步为移动广告推荐系统的发展创造了条件,移动情景信息(用户位置、时间、轨迹等)和本地资源信息(用户附近商家发布的广告、推送等)的结合是移动广告推荐系统的重要发展方向.移动广告推荐系统根据移动情景和本地资源,考虑用户偏好,使广告推荐不受时间和位置等条件的限制,用户在更容易接受广告的同时^[143],也有助于本地商家进行宣传和营销,真正实现共赢.

但是目前对于移动广告推荐系统本地化的研究较少,其面临的挑战主要有下面几个方面:①传统的广告推荐技术通常忽略了用户在移动特定场景中与系统交互产生的大量有用信息,例如轨迹信息、签到等;②移动情景的多样性会给移动广告推荐系统增加情景信息利用的难度,既要防止引入噪声数据,又要注意广告的敏感性问题;③本地化商家缺乏一个统一的广告发布平台,广告发布不方便,且位置、距离等本地化信息以及商品、活动等推广信息等需要进一步完善.

因此,研究合适的情景信息利用策略,并结合本地化推广信息将广告推荐给目标用户是移动广告推荐系统本地化的未来研究重点.另外,移动广告推荐在考虑广告敏感性的同时,需要充分发挥移动情景中大量有用信息的作用,尝试与其他相关领域结合,增加其扩展性,使其具有更大的研究意义.例如,根据本地资源的精确定位和亟需推广的特性,可以将移动广告推荐与 POI(Point-of-Interest)推荐结合.POI 推荐可以根据用户位置、轨迹等信息将用户可能感兴趣的 POI 推荐给用户^[144],广告推荐可以将 POI 自身或者附近的用户感兴趣的本地资源推送给用户,帮助本地资源进行推广,主动满足用户需求.最后,协助本地商家构建系统完善的广告发布平台,加之 5G 技术的发展与进步,方便本地化资源的传播与展示,拉动局部经济发展,真正从更细的粒度上实现广告推荐系统的覆盖率.

(8) 多源数据利用

目前大多数研究基于单数据源^[145],在实际研究

中经常会遇到用户数据或者历史数据较少的情况,由此会在研究过程中出现高维数据稀疏或者矩阵稀疏等情况,从而影响对用户兴趣的分析以及对用户的推荐工作.为缓解因数据量较少引起的数据稀疏问题,可以采用以下三种方法.

第一种方法是尝试获取多个平台下的同一用户信息.同一用户可能在多个网络平台上注册账号,根据各平台的账号信息以及活动行为历史等,判断各个账户是否属于同一个用户,从而获取丰富的用户数据.或者将某用户在浏览器上对各平台的浏览记录进行收集分析,得到用户兴趣.跨平台的信息获取依旧需要考虑用户信息的隐私性,并保证信息具有一定的利用价值.

第二种方法是利用某些平台或设备同时支持用户使用同一账户进行登录的情况,例如多个音乐软件可以使用同一微信账号进行登录,且可以在 PC 端、手机端同时使用.

最后一种方法是将不同数据集联合起来^[146],充分发挥每个数据集的优点,弥补各自的不足.例如 Triple Play 服务^[31]可以从语音、数据流量、电视三个领域获取数据,生成更加详细的用户画像.Chen 等人^[26]表示,移动广告公司必须合作收集足够的信息,各相关机构需要达成建立协作模型的共识,努力构建良好健康的广告生态系统.

多源数据利用能够更加精确地刻画用户偏好,提供更加个性化的推荐,满足比较苛刻的用户需求,对上述三种方法进行深入研究是非常有价值的.

6 总 结

传统广告推荐通常无法满足用户的个性化需求,随着互联网的高速发展,实现个性化的广告推荐已经成为广告商了解用户偏好以及提高广告收益的首要途径.近几年,个性化广告推荐技术研究有着可观的进展,在实际场景中的应用也取得不错的效果.本文从个性化广告推荐系统的概述入手,分析了数据采集与预处理、用户偏好获取、个性化广告推荐技术等关键技术,整理常用数据集和评价指标,总结了个性化广告推荐系统在传统互联网、移动服务、数字标牌、IPTV 等多个应用场景的发展状况.最后根据广告推荐的研究内容,对个性化广告推荐系统中存在的问题和研究方向进行讨论和展望.

参 考 文 献

- [1] Zhang D Y. Review of personalized Internet advertising recommendation technology. Haerbin Gongye University Xuebao/Journal of Haerbin Gongcheng University, 2009,11(5):108-112. (in Chinese)
(张大勇. 个性化网络广告推荐技术研究评述. 哈尔滨工业大学学报, 2009, 11(5): 108-112.)
- [2] Chaudhuri S, Theocharous G, Ghavamzadeh M. Importance of recommendation policy space in addressing click sparsity in personalized advertisement display//Proceedings of the International Conference on Machine Learning and Data Mining in Pattern Recognition. New York, USA, 2017: 32-46.
- [3] Varlamis I, Eirinaki M, Proios D. Tipme: personalized advertising and aspect-based opinion mining for users and businesses//Proceedings of the 2015 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM). Paris, France, 2015: 1489-1494.
- [4] Al Qudah D A, Cristea A I, Bazdarevic S H, et al. Personalized e-advertisement and experience: recommending user targeted ads//Proceedings of the 2015 IEEE 12th International Conference on e-Business Engineering. Beijing, China, 2015: 56-61.
- [5] Burke R. Hybrid recommender systems: survey and experiments. User modeling and user-adapted interaction, 2002, 12(4): 331-370.
- [6] Su X, Khoshgoftaar T M. A survey of collaborative filtering techniques. Advances in artificial intelligence, 2009, 2009: 1-19.
- [7] Meng XW, Chen C, Zhang YJ. A survey of mobile news recommend techniques and applications. Chinese Journal of Computers, 2016, 39(4): 685-703. (in Chinese)
(孟祥武, 陈诚, 张玉洁. 移动新闻推荐技术及其应用研究综述. 计算机学报, 2016, 39(4): 685-703.)
- [8] Zhang S, Yao L, Sun A, et al. Deep learning based recommender system: a survey and new perspectives. ACM Computing Surveys (CSUR), 2019, 52(1): 1-35.
- [9] Li SF. Review of patented technology of personalized internet advertising recommended based on user preference. Henan Science and Technology, 2018(18):42-44. (in Chinese)
(李邵飞. 基于用户偏好的个性化网络广告推荐专利技术综述. 河南科技, 2018(18): 42-44.)
- [10] Burke R. Recommender Systems: an Introduction, by Dietmar Jannach, Markus Zanker, Alexander Felfernig, and Gerhard Friedrich. International Journal of Human & computer Interaction, 2012, 28(1): 72-73.
- [11] Gu Q, Guo P. Research on personalized recommendation model for mobile advertising//Proceedings of the 2012 International Conference on Management Science & Engineering 19th Annual

- Conference Proceedings. Dallas, USA, 2012: 59-63.
- [12] Yang Y. Research on the recommendation of microblog network advertisement based on hybrid recommendation algorithm. *Sciend Migration.Current Trends in Computer Science and Mechanical Automation*. 2017, 1: 171-180.
- [13] Wu T J, Fang S H, Wu Y B, et al. A study of mobile advertisement recommendation using real big data from adlocus//*Proceedings of the 2016 IEEE 5th Global Conference on Consumer Electronics*. Kyoto, Japan, 2016: 1-2.
- [14] Hristova N, O'Hare G M P. Ad-me: wireless advertising adapted to the user location, device and emotions//*Proceedings of the 37th Hawaii International Conference on System Sciences*. Big Island, USA, 2004: 1-10.
- [15] Boffa S, De Maio C, Gerla B, et al. Context-aware advertisement recommendation on twitter through rough sets//*Proceedings of the 2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*. Rio de Janeiro, Brazil, 2018: 1-8.
- [16] Ignatov D I, Kuznetsov S O. Concept-based recommendations for internet advertisement//*Proceedings of the 6th International Conference Concept Lattices and Their Applications*. Olomouc, Czech Republic, 2008: 157-166.
- [17] Lo C Y, Yu K M, Ouyang W, et al. Design a location-time based ethnic advertising recommendation system using degree of memberships//*Proceedings of the 2012 International Conference on Machine Learning and Cybernetics*. Xian, China, 2012: 1708-1714.
- [18] Tu D D, Shu C C, Yu H Y. Using unified probabilistic matrix factorization for contextual advertisement recommendation. *Ruanjian Xuebao/Journal of Software*, 2013, 24(3): 454-464. (in Chinese)
(涂丹丹, 舒承椿, 余海燕, 基于联合概率矩阵分解的上下文广告推荐算法. *软件学报*, 2013, 24(3): 454-464.)
- [19] Dao T H, Jeong S R, Ahn H. A novel recommendation model of location-based advertising: context-aware collaborative filtering using GA approach. *Expert Systems with Applications*, 2012, 39(3): 3731-3739.
- [20] Meng X W, Wang F, Shi Y C, Zhang Y J. Mobile user requirements acquisition techniques and their applications. *Ruan Jian Xue Bao/Journal of Software*, 2014, 25(3): 439-456 (in Chinese).
(孟祥武, 王凡, 史艳翠, 张玉洁. 移动用户需求获取技术及其应用. *软件学报*, 2014, 25(3): 439-456.)
- [21] Lu J X, He Y L, Assocprof M P, et al. Advertising recommended technology based on the internet multidimensional context. *Journal of Wuhan University of Technology*, 2013, 35(4): 543-546. (in Chinese)
(陆济湘, 何云丽, 繆平. 互联网多维上下文广告推荐技术的研究. *武汉理工大学学报(信息与管理工程版)*, 2013, 35(4): 543-546.)
- [22] Pazahr A, Zapater J, Sánchez F G, et al. Semantically-enhanced advertisement recommender systems in social networks//*Proceedings of the 18th International Conference on Information Integration and Web-based Applications and Services*. Singapore, 2016: 179-189.
- [23] Liu G, Huang H, Qu H, et al. Evaluating click-through-rates of recommended ads displaying in different page groups. *Journal of Computational Information Systems*, 2014, 10(2): 799-806.
- [24] Wang L, Lee K, Lu Q. Improving advertisement recommendation by enriching user browser cookie attributes//*Proceedings of the 25th ACM International on Conference on Information and Knowledge Management*. Indianapolis, Indiana, USA, 2016: 2401-2404.
- [25] Siriaraya P, Yamaguchi Y, Morishita M, et al. Using categorized web browsing history to estimate the user's latent interests for web advertisement recommendation//*Proceedings of the 2017 IEEE International Conference on Big Data (Big Data)*. Boston, MA, USA, 2017: 4429-4434.
- [26] Chen P T, Cheng J Z, Yu Y W, et al. Mobile advertising setting analysis and its strategic implications. *Technology in Society*, 2014, 39: 129-141.
- [27] Lu Y, Zhao Z, Zhang B, et al. A context-aware budget-constrained targeted advertising system for vehicular networks. *IEEE Access*, 2018, 6: 8704-8713.
- [28] Ravnik R, Solina F, Zabkar V. Modelling in-store consumer behaviour using machine learning and digital signage audience measurement data//*Proceedings of the International Workshop on Video Analytics for Audience Measurement in Retail and Digital Signage*. Stockholm, Sweden, 2014: 123-133.
- [29] Ravnik R, Solina F. Audience measurement of digital signage: quantitative study in real-world environment using computer vision. *Interacting with Computers*, 2013, 25(3): 218-228.
- [30] Konow R, Tan W, Loyola L, et al. Recommender system for contextual advertising in iptv scenarios//*Proceedings of the 2010 14th International Conference on Computer Supported Cooperative Work in Design*. Shanghai, China, 2010: 617-622.
- [31] Kodialam M S, Lakshman T V, Mukherjee S, et al. Online scheduling of targeted advertisements for iptv. *IEEE/ACM Transactions on Networking*, 2011, 19(6): 1825-1834.
- [32] Abhishek V, Hosanagar K. Keyword generation for search engine advertising using semantic similarity between terms//*Proceedings of the ninth international conference on Electronic commerce*. Minneapolis, USA, 2007: 89-94.
- [33] Chen B, Wang J. A lattice framework for pricing display advertisement options with the stochastic volatility underlying

- model. *Electronic Commerce Research and Applications*, 2015, 14(6): 465-479.
- [34] Melville P, Sindhvani V. Recommender systems. *Encyclopedia of Machine Learning and Data Mining*, Springer: Berlin, 2017: 1056-1066.
- [35] Zheng G, Zhang F, Zheng Z, et al. Drrn: a deep reinforcement learning framework for news recommendation//*Proceedings of the 2018 World Wide Web Conference on World Wide Web*. Lyon, France, 2018: 167-176.
- [36] Yeung K F, Yang Y, Ndzi D. A proactive personalised mobile recommendation system using analytic hierarchy process and bayesian network. *Journal of Internet Services and Applications*, 2012, 3(2): 195-214.
- [37] Rawat Y S, Kankanhalli M S. Contagnet: exploiting user context for image tag recommendation//*Proceedings of the 24th ACM international conference on Multimedia*. Amsterdam, Netherlands, 2016: 1102-1106.
- [38] Lee S K, Cho Y H, Kim S H. Collaborative filtering with ordinal scale-based implicit ratings for mobile music recommendations. *Information Sciences*, 2010, 180(11): 2142-2155.
- [39] Wang S, Wang Y, Tang J, et al. What your images reveal: exploiting visual contents for point-of-interest recommendation//*Proceedings of the 26th International Conference on World Wide Web*. Perth, Australia, 2017: 391-400.
- [40] Yamaguchi Y, Morishita M, Inagaki Y, et al. Web advertising recommender system based on estimating users' latent interests//*Proceedings of the 18th International Conference on Information Integration and Web-based Applications and Services*. Singapore, Singapore, 2016: 42-49.
- [41] Yuan S T, Tsao Y W. A recommendation mechanism for contextualized mobile advertising. *Expert Systems with Applications*, 2003, 24(4): 399-414.
- [42] Xia Z, Wen M S, Wang L, et al. Building a bi-directed recommendation system for mobile users and app-install ad campaigns//*Proceedings of the TargetAd-2nd International Workshop on Ad Targeting at Scale at Web Search and Data Mining*. San Francisco, USA, 2016: 1-5.
- [43] Kazienko P, Adamski M. Adrosa—adaptive personalization of web advertising. *Information Sciences*, 2007, 177(11): 2269-2295.
- [44] Thomaidou S, Vazirgiannis M. Multiword keyword recommendation system for online advertising//*Proceedings of the 2011 International Conference on Advances in Social Networks Analysis and Mining*. Kaohsiung, China, 2011: 423-427.
- [45] Yang X, Deng T, Guo Z, et al. Advertising keyword recommendation based on supervised link prediction in multi-relational network//*Proceedings of the 26th International Conference on World Wide Web Companion*. Perth, Australia, 2017: 863-864.
- [46] Phuong D V, Phuong T M. A keyword-topic model for contextual advertising//*Proceedings of the Third Symposium on Information and Communication Technology*. Ha Long, Vietnam, 2012: 63-70.
- [47] Hwang W H, Chen Y S, Jiang T M. Personalized internet advertisement recommendation service based on keyword similarity//*Proceedings of the 2015 IEEE 39th Annual Computer Software and Applications Conference*. Taichung, China, 2015, 1: 29-33.
- [48] Hu J, Liang J, Kuang Y, et al. A user similarity-based top-n recommendation approach for mobile in-application advertising. *Expert Systems with Applications*, 2018, 111: 51-60.
- [49] Youssef Y, Aly S G. Towards the integration of diverse context into advertisement recommendation on mobile devices//*Proceedings of the 2017 13th International Wireless Communications and Mobile Computing Conference (IWCMC)*. Valencia, Spain, 2017: 1734-1739.
- [50] Garc ía-S á nchez F, Garc ía-D í az J A, G ómez-Berb é s J M, et al. Ontology-based advertisement recommendation in social networks//*Proceedings of the 15th International Conference on Distributed Computing and Artificial Intelligence*. Toledo, Spain, 2018: 36-44.
- [51] Juan Y, Zhuang Y, Chin W S, et al. Field-aware factorization machines for ctr prediction//*Proceedings of the 10th ACM Conference on Recommender Systems*. Boston, USA, 2016: 43-50.
- [52] Lecun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition. *Neural computation*, 1989, 1(4): 541-551.
- [53] Zhang Y, Dai H, Xu C, et al. Sequential click prediction for sponsored search with recurrent neural networks//*Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence*. Qu ébec Canada, 2014:1369-1375.
- [54] Wu S, Ren W, Yu C, et al. Personal recommendation using deep recurrent neural networks in netease//*Proceedings of the 2016 IEEE 32nd International Conference on Data Engineering (ICDE)*. Helsinki, Finland, 2016: 1218-1229.
- [55] Li Y, Zhang D, Lan Z, et al. Context-aware advertisement recommendation for high-speed social news feeding//*Proceedings of the 2016 IEEE 32nd International Conference on Data Engineering (ICDE)*. Helsinki, Finland, 2016: 505-516.
- [56] Rohde D, Bonner S, Dunlop T, et al. Recogym: a reinforcement learning environment for the problem of product recommendation in

- online advertising. arXiv preprint arXiv:1808.00720, 2018.
- [57] Simsek A, Karagoz P. Wikipedia enriched advertisement recommendation for microblogs by using sentiment enhanced user profiles. *Journal of Intelligent Information Systems*, 2018, 3(6): 1-25.
- [58] Li Y M, Shiu Y L. A diffusion mechanism for social advertising over microblogs. *Decision Support Systems*, 2012, 54(1): 9-22.
- [59] Yang H, McKay E. A context-aware recommendation system for improving the performance of targeted mobile advertising//*Proceedings of the 2017 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computed, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCOM/IOP/SCI)*. San Francisco, CA, USA, 2017: 1-7.
- [60] Zhang Y, Du Y, Meng X. Research on grouprecommender systems and their applications. *Chinese Journal of Computers*, 2016, 39(4): 745-764. (in Chinese)
(张玉洁, 杜雨露, 孟祥武. 组推荐系统及其应用研究. *计算机学报*, 2016, 39(4): 745-764.)
- [61] Fan T K, Chang C H. Blogger-centric contextual advertising. *Expert systems with applications*, 2011, 38(3): 1777-1788.
- [62] Kim S Y, Barrameda K B, Sang H L. An intelligent advertisement recommendation system considering user profiles and view statistics. *Journal of Advanced Research in Dynamical and Control Systems*, 2017, 9(12): 13-18.
- [63] Zheng L, Noroozi V, Yu P S. Joint deep modeling of users and items using reviews for recommendation//*Proceedings of the Tenth ACM International Conference on Web Search and Data Mining*. Cambridge, United Kingdom, 2017: 425-434.
- [64] Tay Y, Luu A T, Hui S C. Multi-pointer co-attention networks for recommendation//*Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. London, United Kingdom, 2018: 2309-2318.
- [65] Chan C C, Lin Y C, Chen M S. Recommendation for advertising messages on mobile devices//*Proceedings of the 23rd International Conference on World Wide Web*. Seoul, Korea, 2014: 235-236.
- [66] Tan Y K, Xu X, Liu Y. Improved recurrent neural networks for session-based recommendations//*Proceedings of the 1st Workshop on Deep Learning for Recommender Systems*. Boston, USA, 2016: 17-22.
- [67] Okura S, Tagami Y, Ono S, et al. Embedding-based news recommendation for millions of users//*Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Halifax, Canada, 2017: 1933-1942.
- [68] Siritiraya P, Yamaguchi Y, Morishita M, et al. Recommending web advertisements based on long-short term user interest//*Proceedings of the ACM IUI 2019 Workshops*. Los Angeles, USA, 2019: 1-5.
- [69] Jiang Y H, Yue Z X. Mobile advertising predicted conversion rate model a recommendation system with machine learning approach//*Proceedings of the 10th EAI International Conference on Simulation Tools and Techniques*. Hong Kong, China, 2017: 117-119.
- [70] Roh J H, Jin S. Personalized advertisement recommendation system based on user profile in the smart phone//*Proceedings of the 2012 14th International Conference on Advanced Communication Technology (ICACT)*. PyeongChang, South Korea, 2012: 1300-1303.
- [71] Wang L, Liu Y, Wu J. Research on financial advertisement personalised recommendation method based on customer segmentation. *International Journal of Wireless and Mobile Computing*, 2018, 14(1): 97-101.
- [72] Wang D, Xu G, Deng S. Music recommendation via heterogeneous information graph embedding//*Proceedings of the 2017 International Joint Conference on Neural Networks (IJCNN)*. Anchorage, USA, 2017: 596-603.
- [73] Liu P, Zhang L, Gulla J A. Real-time social recommendation based on graph embedding and temporal context. *International Journal of Human-Computer Studies*, 2019, 121: 58-72.
- [74] Wang Q, Mao Z, Wang B, et al. Knowledge graph embedding: a survey of approaches and applications. *IEEE Transactions on Knowledge and Data Engineering*, 2017, 29(12): 2724-2743.
- [75] Grad-Gyenge L, Kiss A, Filzmoser P. Graph embedding based recommendation techniques on the knowledge graph//*Proceedings of the Adjunct Publication of the 25th Conference on User Modeling, Adaptation and Personalization*. Bratislava, Slovakia, 2017: 354-359.
- [76] Sun Z, Yang J, Zhang J, et al. Recurrent knowledge graph embedding for effective recommendation//*Proceedings of the 12th ACM Conference on Recommender Systems*. Vancouver, Canada, 2018: 297-305.
- [77] Simsek A, Karagoz P. Sentiment enhanced hybrid tf-idf for microblogs//*Proceedings of the 2014 IEEE Fourth International Conference on Big Data and Cloud Computing*. Sydney, Australia, 2014: 311-317.
- [78] Khan M M, Ibrahim R, Ghani I. Cross domain recommender systems: a systematic literature review. *ACM Computing Surveys (CSUR)*, 2017, 50(3): 1-34.
- [79] Fernández-Tobías I, Cantador I, Kaminskas M, et al. Cross-domain recommender systems: a survey of the state of the art//*Proceedings of the 2nd Spanish Conference on Information Retrieval*. Valencia,

- Spain, 2012: 1-24.
- [80] Yan Z, Wei L, Lu Y, et al. You are what apps you use: transfer learning for personalized content and ad recommendation//Proceedings of the Eleventh ACM Conference on Recommender Systems. Como, Italy, 2017: 350-350.
- [81] Jin Z Y, Zhang J , Li X J , et al. A collaborative filtering advertising recommendation algorithm with tag. *Computer Engineering*, 2018, 44(4): 236-247. (in Chinese)
(金紫嫣, 张娟, 李向军,等.一种带标签的协同过滤广告推荐算法. *计算机工程*, 2018, 44(4): 236-247.)
- [82] He X, Liao L, Zhang H, et al. Neural collaborative filtering//Proceedings of the 26th International Conference on World Wide Web. Perth, Australia, 2017: 173-182.
- [83] Ouyang Y, Liu W, Rong W, et al. Autoencoder-based collaborative filtering//Proceedings of the International Conference on Neural Information Processing. Kuching, Malaysia, 2014: 284-291.
- [84] He X, Du X, Wang X, et al. Outer product-based neural collaborative filtering. *arXiv preprint arXiv:1808.03912*, 2018.
- [85] Chen G, Kotz D. A survey of context-aware mobile computing research. Hanover: Dartmouth College, Technical Report TR2000-381, 2000.
- [86] Abowd G D, Dey A K, Brown P J, et al. Towards a better understanding of context and context-awareness//Proceedings of the 1st International symposium on handheld and ubiquitous computing. Springer, Karlsruhe, Germany, 1999: 304-307.
- [87] Persaud A, Azhar I. Innovative mobile marketing via smartphones: are consumers ready?. *Marketing Intelligence & Planning*, 2012, 30(4): 418-443.
- [88] Liu P, Azimi J, Zhang R. Automatic keywords generation for contextual advertising//Proceedings of the 23rd International Conference on World Wide Web. Seoul, Korea, 2014: 345-346.
- [89] Addis A, Armano G, Giuliani A, et al. A recommender system based on a generic contextual advertising approach//Proceedings of the IEEE symposium on Computers and Communications. Riccione, Italy, 2010: 859-861.
- [90] Sevli O, K üçüksille E U. Advertising recommendation system based on dynamic data analysis on turkish speaking twitter users. *Technical Gazette*, 2017, 24(2): 571-578.
- [91] Abrahams A S, Coupey E, Zhong E X, et al. Audience targeting by b-to-b advertisement classification: a neural network approach. *Expert systems with applications*, 2013, 40(8): 2777-2791.
- [92] Kaushik R V, Raghu R, Reddy L M, et al. Ad analysis using machine learning: classifying and recommending advertisements for a given category of videos, using machine learning//Proceedings of the 2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS). Chennai, India, 2017: 2434-2437.
- [93] Yao X, Chen Y, Liao R, et al. Face based advertisement recommendation with deep learning: a case study//Proceedings of the International Conference on Smart Computing and Communication. Shenzhen, China, 2017: 96-102.
- [94] Yang Y. An improved recommendation algorithm for micro-blog network advertisement//Proceedings of the 2018 17th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES). Wuxi, China, 2018: 284-287.
- [95] Lee H, Ahn Y, Lee H, et al. Quote recommendation in dialogue using deep neural network//Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval. Pisa, Italy, 2016: 957-960.
- [96] Wang H, Xingjian S, Yeung D-Y. Collaborative recurrent autoencoder: recommend while learning to fill in the blanks//Proceedings of the Advances in Neural Information Processing Systems. Barcelona, Spain, 2016: 415-423.
- [97] Tian P, Sanjay A V, Chiranjeevi K, et al. Intelligent advertising framework for digital signage//Proceedings of the 18th ACM SIGKDD international conference on Knowledge discovery and data mining. Beijing, China, 2012: 1532-1535.
- [98] Mr. Aatish B. Jadhav M R M P, Mr. Gaurav D. Chavan advertisement recommendation using social media. *Imperial Journal of Interdisciplinary Research (IJIR)* 2017, 3(2): 404-407.
- [99] Su Y, Jin Z, Chen Y, et al. Improving click-through rate prediction accuracy in online advertising by transfer learning//Proceedings of the International Conference on Web Intelligence. Leipzig, Germany, 2017: 1018-1025.
- [100] Liu D R, Liao Y S, Chung Y H, et al. Advertisement recommendation based on personal interests and ad push fairness. *Kybernetes*, 2018, 48(8): 1586-1605.
- [101] Chen Y T, Kao H Y. Constructing social intentional corpora to predict click-through rate for search advertising//Proceedings of the 25th Conference on Computational Linguistics and Speech Processing (ROCLING 2013). Kaohsiung, China, 2013: 278-287.
- [102] Shan L, Lin L, Sun C, et al. Predicting ad click-through rates via feature-based fully coupled interaction tensor factorization. *Electronic Commerce Research and Applications*, 2016, 16: 30-42.
- [103] Phangtrastu M R, Isa S M. Optimizing field-aware factorization machine with particle swarm optimization on online ads click-through rate prediction//Proceedings of the 2018 3rd International Conference on Computer and Communication Systems (ICCCS). Nagoya, Japan, 2018: 1-5.

- [104] Chen Q H, Yu S M, Guo Z X, et al. Estimating ads' click through rate with recurrent neural network//Proceedings of the 3rd Annual International Conference on Information Technology and Applications. Hangzhou, China, 2016: 04001.
- [105] Chen Q H, Dong W, et al. Ads' click-through rates predicting based on gated recurrent unit neural networks. Journal of Zhejiang Sci-Tech University(Natural Sciences Edition), 2018, 39(5): 587-592.
(陈巧红, 董雯, 孙麒, 等. 基于门控循环单元神经网络的广告点击率预估. 浙江理工大学学报(自然科学版), 2018, 39(5): 587-592.)
- [106] She X, Wang S. Research on advertising click-through rate prediction based on cnn-fm hybrid model//Proceedings of the 2018 10th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC). Hangzhou, China, 2018: 56-59.
- [107] Liu X, Xue W, Xiao L, et al. Pbodl: parallel bayesian online deep learning for click-through rate prediction in tencent advertising system. arXiv preprint arXiv:1707.00802, 2017.
- [108] Pan J, Xu J, Ruiz A L, et al. Field-weighted factorization machines for click-through rate prediction in display advertising//Proceedings of the 2018 World Wide Web Conference. Lyon, France, 2018: 1349-1357.
- [109] Gai K, Zhu X, Li H, et al. Learning piece-wise linear models from large scale data for ad click prediction. arXiv preprint arXiv:1704.05194, 2017.
- [110] Lange S, Riedmiller M. Deep auto-encoder neural networks in reinforcement learning//Proceedings of the 2010 International Joint Conference on Neural Networks (IJCNN). Barcelona, Spain, 2010: 1-8.
- [111] Jiang Z. Research on ctr prediction for contextual advertising based on deep architecture model. Journal of Control Engineering and Applied Informatics, 2016, 18(1): 11-19.
- [112] Xu R, Wang M, Xie Y. Optimally connected deep belief net for click through rate prediction in online advertising. IEEE Access, 2018, 6: 43009-43020.
- [113] Zhai S, Chang K H, Zhang R, et al. Attention based recurrent neural networks for online advertising//Proceedings of the 25th International Conference Companion on World Wide Web. Montréal, Canada, 2016: 141-142.
- [114] Zhai S, Chang K H, Zhang R, et al. Deepintent: learning attentions for online advertising with recurrent neural networks//Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining. San Francisco, USA, 2016: 1295-1304.
- [115] Wang Q L F, Xing S, Et Al. A new approach for advertising ctr prediction based on deep neural network via attention mechanism. Computational and mathematical methods in medicine, 2018, 2018: 1-11.
- [116] Gao H, Kong D, Lu M, et al. Attention convolutional neural network for advertiser-level click-through rate forecasting//Proceedings of the 2018 World Wide Web Conference. Lyon, France, 2018: 1855-1864.
- [117] Zhou G, Zhu X, Song C, et al. Deep interest network for click-through rate prediction//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, United Kingdom, 2018: 1059-1068.
- [118] Jiang Z, Gao S, Li M. An improved advertising ctr prediction approach based on the fuzzy deep neural network. Plos One, 2018, 13(5): 1-24
- [119] Han D, Liu Q, Fan W. A new image classification method using cnn transfer learning and web data augmentation. Expert Systems with Applications, 2018, 95: 43-56.
- [120] Dai W, Yang Q, Xue G-R, et al. Boosting for transfer learning//Proceedings of the 24th international conference on Machine learning. Corvallis, USA, 2007: 193-200.
- [121] Theocharous G, Thomas P S, Ghavamzadeh M. Personalized ad recommendation systems for life-time value optimization with guarantees//Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence. Buenos Aires, Argentina, 2015: 1806-1812.
- [122] Hessel M, Soyer H, Espeholt L, et al. Multi-task deep reinforcement learning with popart//Proceedings of the Thirty-Third AAAI Conference on Artificial Intelligence. Honolulu, USA, 2019: 3796-3803.
- [123] Leskovec J, Adamic L A, Huberman B A. The dynamics of viral marketing. ACM Transactions on the Web (TWEB), 2007, 1(1): 1-5.
- [124] Roffo G, Vinciarelli A. Personality in computational advertising: a benchmark//Proceedings of the 4th Workshop on Emotions & Personality in Personalized Systems. Boston, USA, 2016: 18-25.
- [125] Sidana S, Laclau C, Amini M R, et al. Kasandr: A large-scale dataset with implicit feedback for recommendation//Proceedings of the International ACM SIGIR Conference. Shinjuku, Japan, 2017: 1245-1248.
- [126] Pan Z, Chen E, Liu Q, et al. Sparse factorization machines for click-through rate prediction//Proceedings of the 2016 IEEE 16th International Conference on Data Mining (ICDM). Barcelona, Spain, 2016: 400-409.
- [127] Azimi J, Zhang R, Zhou Y, et al. The impact of visual appearance on user response in online display advertising//Proceedings of the 21st International Conference on World Wide Web. Lyon, France, 2012: 457-458.

- [128] Balkan S, Baydogan M, Addicam S. Adaptive advertisement recommender systems for digital signage//Proceedings of the 21st Americas Conference on Information Systems. Fajardo, USA, 2015: 1-13.
- [129] Zhu Y X, Lu L Y. Evaluation metrics for recommender systems. Journal of University of Electronic Science and Technology of China, 2012, 41(2): 163-175. (in Chinese)
(朱郁筱, 吕琳媛. 推荐系统评价指标综述. 电子科技大学学报, 2012, 41(2): 163-175.)
- [130] Zhang W, Wang D, Xue G R, et al. Advertising keywords recommendation for short-text web pages using wikipedia. ACM Transactions on Intelligent Systems and Technology (TIST), 2012, 3(2): 1-25.
- [131] Li K, Du T C. Building a targeted mobile advertising system for location-based services. Decision Support Systems, 2012, 54(1): 1-8.
- [132] Yang S, Kafai M, An L, et al. Zapping index: using smile to measure advertisement zapping likelihood. IEEE Transactions on Affective Computing, 2014, 5(4): 432-444.
- [133] Wu X, Xiao B, Lin Z. A user selection method in advertising recommendations//Proceedings of the 2009 IEEE International Conference on Network Infrastructure and Digital Content. Beijing, China, 2009: 410-413.
- [134] Liu J, Wang C, Zhang R, et al. Research on behavioral targeted advertising in mobile Internet. The Journal of China Universities of Posts and Telecommunications, 2014, 21: 1-5.
- [135] Cankaya H. System and method for providing context-aware local advertising in iptv systems, U.S., 2007-6-21.
- [136] Resnick P, Iacovou N, Suchak M, et al. GroupLens: an open architecture for collaborative filtering of netnews//Proceedings of the 1994 ACM conference on Computer supported cooperative work. Chapel Hill, USA, 1994: 175-186.
- [137] Sanzgiri A, Austin D, Sankaran K, et al. Classifying sensitive content in online advertisements with deep learning//Proceedings of the 2018 IEEE 5th International Conference on Data Science and Advanced Analytics (DSAA). Turin, Italy, 2018: 434-441.
- [138] Jin X, Li Y, Mah T, et al. Sensitive webpage classification for content advertising//Proceedings of the 1st international workshop on Data mining and audience intelligence for advertising. San Jose, USA, 2007: 28-33.
- [139] Peng G, Liu S, Wang J. Sensitivity-proof content advertising based on two-stage text classification//Proceedings of the 2010 International Conference on Computational Intelligence and Software Engineering. Wuhan, China, 2010: 1-4.
- [140] Liu C, Wang Z. The research on advertising model of self-driving car platform//Proceedings of the 2017 IEEE 3rd Information Technology and Mechatronics Engineering Conference (ITOEC). Chongqing, China, 2017: 95-99.
- [141] Wang J, Duan L, Wang B, et al. Linking video ads with product or service information by web search//Proceedings of the 2009 IEEE International Conference on Multimedia and Expo. New York, USA, 2009: 274-277.
- [142] Wang B, Wang J, Chen S, et al. Semantic linking between video ads and web services with progressive search//Proceedings of the 2009 IEEE International Conference on Data Mining Workshops. Miami, USA, 2009: 196-201.
- [143] Wong C H, Tan G W H, Tan B I, et al. Mobile advertising: the changing landscape of the advertising industry. Telematics and Informatics, 2015, 32(4): 720-734.
- [144] Massimo D, Ricci F. Harnessing a generalised user behaviour model for next-POI recommendation//Proceedings of the 12th ACM Conference on Recommender Systems. Vancouver, Canada, 2018: 402-406.
- [145] Meng X W, Li R C, Zhang Y J, Ji W Y. Survey on mobile recommender systems based on user trajectory data. Ruan Jian Xue Bao/Journal of Software, 2018, 29(10): 3111-3133. (in Chinese)
(孟祥武, 李瑞昌, 张玉洁, et al. 基于用户轨迹数据的移动推荐系统研究. 软件学报, 2018, 29(10): 3111-3133.)
- [146] Wang W, Yin H, Sadiq S, et al. Spore: a sequential personalized spatial item recommender system//Proceedings of the 2016 IEEE 32nd International Conference on Data Engineering (ICDE). Helsinki, Finland, 2016: 954-965.



ZHANG Yu-Jie, born in 1969, associate professor. Her research interests include recommendation systems and user preference acquisition.

DONG Zheng, born in 1995, Ph.D. candidate. His current research interests include recommendation systems and intelligent information processing.

MENG Xiang-Wu, born in 1966, professor, Ph.D. supervisor. His research interests include recommendation algorithm, user preference acquisition and context recommendation.

Background

Recently, with the development and popularity of the Internet and smart mobile devices, it is of great help to push advertisements. Advertisements can be seen everywhere in daily life. Whether browsing the web or using mobile applications, advertisements will appear in front of users in various ways. However, the traditional large-scale indiscriminate advertising cannot fully meet the personalized needs of users. In addition, advertisements may have negative effects on users due to inappropriate content, time and location, weakening the effect of advertisement and reducing the profit brought by advertisement. The above situation brings great challenge to push advertisements. In order to reduce users' resistance to advertisements and enhance user experience, it is necessary to know users' preferences when pushing advertisements. Advertisements should meet users' personalized needs, and considering the economic benefits generated by advertisements at the same time, recommendation system (RS) is a good solution. RS is widely used to help users find items or services in line with their preferences due to the consideration of users' tastes or interests. Coupled with users' personalized needs for advertisements, the personalized

advertising recommendation system (PAR) comes into being.

In recent years, PAR has become one of the hottest research topics in the field of personalized services and RS. PAR uses a specific data set, through the acquisition of user preferences, using a variety of personalized advertising recommendation technology, through the PC-side online pages, mobile terminals and other platforms to provide personalized advertising for users, and in some application systems to achieve good results. This paper reviews the current research progress and practical application of PAR. Starting from the overview of personalized advertisement recommendation, this paper mainly analyses the personalized advertisement recommendation technologies of PAR, such as explicit or potential user preference acquisition, collaborative filtering, context recommendation, hybrid recommendation, click rate prediction, and some commonly used advertising data sets and some evaluation indicators are sorted out. And the application of PAR in traditional Internet, mobile service, digital signage, IPTV and other scenarios are sorted out. Finally, this paper summarizes and prospects the existing problems and future research directions of PAR.